

**UNIVERSIDADE FEDERAL DE SANTA CATARINA  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA  
COMPUTAÇÃO**

Guilherme Steinmann

**MÉTODO PARA PREVISÃO DE CHAMADAS EM CENTRAIS DE  
ATENDIMENTO RECEPTIVAS**

Florianópolis

2013



Guilherme Steinmann

**MÉTODO PARA PREVISÃO DE CHAMADAS EM CENTRAIS DE  
ATENDIMENTO RECEPTIVAS**

Dissertação submetida à Universidade Federal de Santa Catarina para a obtenção do Grau de Mestre em Ciência da Computação.  
Orientador: Paulo José de Freitas Filho,  
Dr.

Florianópolis

2013

Ficha de identificação da obra elaborada pelo autor,  
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Steinmann, Guilherme

Método para previsão de chamadas em centrais de  
atendimento receptivas / Guilherme Steinmann ; orientador,  
Paulo José de Freitas Filho - Florianópolis, SC, 2013.  
105 p.

Dissertação (mestrado) - Universidade Federal de Santa  
Catarina, Centro Tecnológico. Programa de Pós-Graduação em  
Ciência da Computação.

Inclui referências

1. Ciência da Computação. 2. Redes bayesianas. 3.  
Previsão de dados. 4. Centrais de atendimento. 5. Call  
center. I. Freitas Filho, Paulo José de. II. Universidade  
Federal de Santa Catarina. Programa de Pós-Graduação em  
Ciência da Computação. III. Título.

Guilherme Steinmann

**MÉTODO PARA PREVISÃO DE CHAMADAS EM CENTRAIS  
DE ATENDIMENTO RECEPTIVAS**

Esta Dissertação foi julgada adequada para obtenção do Título de Mestre em Ciência da Computação e aprovada em sua forma final pelo Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Santa Catarina.

Florianópolis, 19 de abril de 2013.

---

Ronaldo dos Santos Mello, Dr.  
Coordenador do Curso

**Banca Examinadora:**

---

Paulo José de Freitas Filho, Dr.  
Orientador  
Universidade Federal de Santa Catarina

---

Sílvia Modesto Nassar, Dra.  
Universidade Federal de Santa Catarina

---

Rogério Cid Bastos, Dr.  
Universidade Federal de Santa Catarina

---

Rivalino Matias Júnior, Dr.  
Universidade Federal de Uberlândia



## AGRADECIMENTOS

Agradeço à minha mãe, Marli, e ao meu irmão, Lucas, por serem uma parte fundamental da minha vida e por sempre estarem ao meu lado.

Ao meu pai, Sérgio, e à minha irmã, Natália, por sempre confiarem em mim e por me apoiarem nas minhas decisões.

Ao meu orientador, Prof. Paulo Freitas, pela oportunidade, confiança e paciência. Muito obrigado por todo o esforço despendido.

À Professora Sílvia Modesto Nassar pelas contribuições dadas durante o desenvolvimento do trabalho e pelas palavras encorajadoras.

À minha “colega de orientador”, Jocimara Segantini Ferranti, pelos momentos de dúvidas e de dicas compartilhados.

Aos meus colegas do Laboratório de Circuitos e Processamento de Sinais (Linse), que vêm me acompanhando há anos, o agradecimento pelo apoio, pelas palavras de motivação e pelos momentos de compreensão. Um agradecimento especial ao Neco, que sempre deu o seu total apoio no desenvolvimento do trabalho.

Agradeço também aos meus amigos, dentre eles, Carlos, Katherine e Geovani, que de uma forma ou de outra, perto ou longe, contribuíram com a sua amizade para a realização deste trabalho.

Um agradecimento também àquelas pessoas que, de forma direta ou indireta, deram a sua contribuição.



*That's one small step for [a] man,  
one giant leap for mankind.*

Neil Armstrong



## RESUMO

Os algoritmos de previsão de chamadas em centrais de atendimento conseguem apresentar resultados aceitáveis diante de uma série de dados longa e bem comportada. Uma série de dados com essas características raramente é encontrada, o que restringe o uso dos algoritmos de previsão. Além disso, a falta de unidade das séries implica na presença de fenômenos que perturbam os dados. Esses fenômenos fazem com que o uso de métodos empíricos se multipliquem dentre os membros das equipes de planejamento.

O trabalho propõe um método de previsão de chamadas recebidas utilizando redes bayesianas para o tratamento desses fenômenos que perturbam de sobremaneira os dados. Com a proposta, é possível incorporar o conhecimento acerca desses fenômenos em um modelo de previsão computacionalmente eficiente.

Para elaborar um método de previsão de chamadas em centrais de atendimento, algumas ferramentas precisaram ser desenvolvidas durante a elaboração do modelo. Primeiramente, foi necessário resolver a dificuldade da obtenção de dados de centrais de atendimento para o estudo do comportamento das chamadas recebidas. Foi então criado um simulador de call center onde é possível gerar dados de chamadas para serem utilizados nos modelos de previsão de chamadas. Em seguida, para o melhor entendimento dos algoritmos de previsão de dados, uma ferramenta de previsão por suavização exponencial foi criada como suplemento do Microsoft Excel. Por fim, foi proposto um método de previsão que utiliza as redes bayesianas para tratar os fatores aleatórios.

As redes bayesianas se mostram uma boa alternativa para tratar a aleatoriedade presente nos fatores aleatórios. Os resultados obtidos mostram que o tratamento se faz necessário para a diminuição dos erros de previsão em centrais de atendimento. O modelo apresentado não requer grandes conhecimentos matemáticos por parte das equipes de planejamento, o que estimula o uso desse tipo de formalização.

**Palavras-chave:** Redes bayesianas; previsão de dados; centrais de atendimento; call center



## ABSTRACT

The forecasting calls algorithms in contact centers can provide acceptable results before a long and well behaved time series dataset. However a time series with such characteristics is rarely found, which restricts the use of forecasting algorithms. Moreover, the lack of unity of these series implies the presence of some phenomena which disturb the data series. These phenomena make the use of empirical methods to multiply among the members of the planning team.

This paper proposes a method of forecasting incoming calls using bayesian networks for the treatment of such phenomena which disturb the data. With this proposal, it is possible to incorporate the knowledge of these phenomena in a computationally efficient forecasting model.

To develop a forecasting calls model in call centers, some tools needed to be developed during the elaboration of the forecasting model. First, to deal with the difficulty of obtaining data records from call centers to study the behavior of incoming calls. A simulated call center was developed, where it is possible to generate call data for use in forecasting models of calls. Then, for better understanding of data prediction algorithms, a forecasting tool for exponential smoothing was created as a supplement to Microsoft Excel. Finally, it was proposed a forecasting model that uses bayesian networks to deal with the random factors.

Bayesian networks are shown as a good alternative for treating the randomness present in random factors. The results show that the treatment is necessary to reduce the forecasting errors in call centers. The model presented does not require great mathematical knowledge by planning teams, which encourages the use of this kind of formalization.

**Keywords:** Bayesian networks; data forecast; contact center; call center



## LISTA DE FIGURAS

Figura 1	Matriz de Desempenho de call center . . . . .	22
Figura 2	Exemplo de impacto dos fatores nas chamadas recebidas . . . . .	25
Figura 3	Atividades do processo de previsão . . . . .	37
Figura 4	Suavização de um conjunto de dados . . . . .	43
Figura 5	Classificação de Pegels . . . . .	44
Figura 6	Modelo hierárquico da ignorância . . . . .	46
Figura 7	Evento $e$ em um conjunto de hipóteses $H$ . . . . .	49
Figura 8	Inferência Bayesiana . . . . .	50
Figura 9	Exemplo de uma Rede Bayesiana para diagnóstico médico . . . . .	52
Figura 10	Tratamento dos fatores aleatórios e as soluções desenvolvidas . . . . .	55
Figura 11	Diagrama de blocos do simulador de chamadas . . . . .	57
Figura 12	Conjuntos de chamadas geradas pelo simulador . . . . .	58
Figura 13	Ferramenta EZF . . . . .	60
Figura 14	Modelo proposto de previsão . . . . .	61
Figura 15	Diagrama do processo de normalização . . . . .	62
Figura 16	Série histórica mensal de chamadas do estudo de caso . . . . .	70
Figura 17	Série histórica mensal simulada de chamadas recebidas . . . . .	71
Figura 18	Comparativo de séries históricas mensais simuladas . . . . .	72
Figura 19	Dados mensais dos casos de testes . . . . .	74
Figura 20	Dados diários de fevereiro de 2009 dos casos de testes . . . . .	75
Figura 21	Dados gerados pelo simulador para o caso de teste 1 . . . . .	76
Figura 22	Dados gerados pelo simulador para o caso de teste 2 . . . . .	76
Figura 23	Dados mensais do caso de teste 1 . . . . .	77
Figura 24	Dados mensais do caso de teste 2 . . . . .	77
Figura 25	Rede bayesiana mensal para o caso de teste 1 . . . . .	79
Figura 26	Rede bayesiana mensal instanciada para o caso de teste 1 . . . . .	79
Figura 27	Rede bayesiana mensal instanciada para o caso de teste 1 . . . . .	80
Figura 28	Erro da previsão para o caso de teste 1 . . . . .	81
Figura 29	Previsão mensal do caso de teste 1 com o modelo proposto . . . . .	82
Figura 30	Previsão mensal do caso de teste 1 com o modelo proposto e os fatores conhecidos . . . . .	83
Figura 31	Erro da previsão para o caso de teste 2 . . . . .	83

Figura 32	Previsão mensal do caso de teste 2 com o modelo proposto ..	85
Figura 33	Previsão mensal do caso de teste 2 com o modelo proposto e os fatores conhecidos .....	85
Figura 34	Rede bayesiana diária com 11 classes para o caso de teste 1..	87
Figura 35	Rede bayesiana diária instanciada com 11 classes percentuais	88
Figura 36	Previsão diária com 11 classes para o caso de teste 1 .....	89
Figura 37	Detalhe da previsão diária com 11 classes .....	89
Figura 38	Erro da previsão diária com 11 classes para o caso de teste 1 .	90
Figura 39	Erro da previsão diária com 33 classes para o caso de teste 1 .	91
Figura 40	Detalhe da previsão diária com 33 classes .....	92
Figura 41	Erro da previsão diária com 33 classes para o caso de teste 1 .	92

## LISTA DE TABELAS

Tabela 1	Diferenças entre um call center ativo e receptivo . . . . .	31
Tabela 2	Notação de Pegels para suavização exponencial . . . . .	44
Tabela 3	Fórmulas da previsão segundo a classificação de Pegels . . . . .	45
Tabela 4	Ferramentas de suavização exponencial . . . . .	59
Tabela 5	Fatores aplicados nos casos de testes . . . . .	73
Tabela 6	Fatores aplicados nos dados de testes . . . . .	74
Tabela 7	Pesos dos fatores encontrados pela normalização . . . . .	75
Tabela 8	EPAM dos modelos de previsão do caso de teste 1 . . . . .	78
Tabela 9	EPAM dos modelos de previsão do caso de teste 2 . . . . .	78
Tabela 10	EPAM dos dados de teste para o caso de teste 1 . . . . .	81
Tabela 11	EPAM dos dados de teste para o caso de teste 2 . . . . .	84
Tabela 12	EPAM da previsão diária para o caso de teste 1 . . . . .	90
Tabela 13	EPAM da previsão diária para o caso de teste 1 . . . . .	93



## LISTA DE ABREVIATURAS E SIGLAS

SAC	Serviço de Atendimento ao Consumidor .....	22
IA	Inteligência Artificial .....	25
PABX	Private Automated Business Exchanges .....	30
DAC	Distribuidor Automático de Chamadas .....	30
CTI	Computer Telephone Integration .....	30
URA	Unidade de Resposta Audível .....	30
CRM	Customer Relationship Management .....	30
EM	Erro Médio .....	40
EAM	Erro Absoluto Médio .....	40
EQM	Erro Quadrático Médio .....	40
EP	Erro Percentual .....	41
EPM	Erro Percentual Médio .....	41
EPAM	Erro Percentual Absoluto Médio .....	41
SEP	Sistemas Especialistas Probabilísticos .....	50



## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	21
1.1 JUSTIFICATIVA E MOTIVAÇÃO .....	22
1.2 PROBLEMA .....	23
1.3 PROPOSTA .....	26
1.4 OBJETIVO GERAL .....	26
1.5 OBJETIVOS ESPECÍFICOS .....	26
1.6 ESTRUTURA DO TRABALHO .....	27
<b>2 REVISÃO BIBLIOGRÁFICA</b> .....	29
2.1 CENTRAIS DE ATENDIMENTO .....	29
2.1.1 Tecnologias em centrais de atendimento .....	30
2.1.2 Classificação do tráfego em um call center .....	31
2.1.3 Tratamento das chamadas receptivas em um call center .....	31
2.1.4 Métricas de desempenho de call center .....	33
2.1.5 Relação de custo e produtividade .....	34
2.1.6 Problemas em call centers .....	34
2.2 PREVISÃO DE DADOS .....	36
2.2.1 Processo de previsão .....	37
2.3 SÉRIES TEMPORAIS .....	39
2.3.1 Acurácia do modelo de previsão .....	40
2.3.2 Decomposição de séries temporais .....	41
2.3.3 Métodos de suavização .....	42
2.4 TRATAMENTO DA INCERTEZA .....	45
2.4.1 Probabilidade .....	47
2.4.2 Teorema de Bayes .....	48
2.4.3 Sistemas Especialistas Probabilísticos .....	50
2.4.4 Redes Bayesianas .....	51
2.4.5 Uso de Redes Bayesianas .....	53
2.5 COMENTÁRIOS FINAIS .....	54
<b>3 MODELO DE PREVISÃO</b> .....	55
3.1 SIMULADOR DE CALL CENTER .....	56
3.2 FERRAMENTA EZF .....	58
3.3 MODELO PROPOSTO DE PREVISÃO EM CALL CENTER .....	59
3.3.1 Identificação dos fatores .....	62
3.3.2 Normalização dos dados .....	63
3.3.3 Previsão da série .....	64
3.3.4 Inversa da normalização do dado previsto .....	64
3.3.5 Otimização dos parâmetros do algoritmo de previsão .....	65

<b>3.3.6</b>	<b>Previsão dos dados futuros</b>	65
<b>3.3.7</b>	<b>Rede bayesiana na previsão de dados</b>	65
3.4	COMENTÁRIOS FINAIS	66
<b>4</b>	<b>ANÁLISE DE RESULTADOS DO MODELO</b>	69
4.1	EXPERIMENTAÇÃO DO SIMULADOR	69
4.2	AVALIAÇÃO DO MODELO PROPOSTO	71
<b>4.2.1</b>	<b>Dados históricos</b>	72
<b>4.2.2</b>	<b>Previsão mensal</b>	75
<b>4.2.3</b>	<b>Previsão diária</b>	85
4.3	COMENTÁRIOS FINAIS	93
<b>5</b>	<b>CONSIDERAÇÕES FINAIS</b>	95
5.1	PROPOSTA E RESULTADOS	96
5.2	LIMITAÇÕES	99
5.3	TRABALHOS FUTUROS	100
	<b>Referências Bibliográficas</b>	101

## 1 INTRODUÇÃO

Os call centers e centrais de atendimento são ferramentas utilizadas por empresas, governo e serviços de emergência para relacionamento com clientes. A diferença de um call center para uma central de atendimento é que o call center utiliza o telefone como meio de comunicação, enquanto que a central de atendimento utiliza também outros meios, como e-mail, fax, página da internet ou bate-papo online (GANS; KOOLE; MANDELBAUM, 2003).

Segundo Gans, Koole e Mandelbaum (2003), o meio de contato preferido entre as empresas e seus clientes são as centrais de atendimento. Com os custos de telefonia e de tecnologia de informação caindo nos últimos anos, cada vez mais a escolha do atendimento ao cliente através de centrais de atendimento vem sendo consolidada (AKSIN; ARMONY; MEHROTRA, 2007). Para empresas, esse forma de relacionamento é uma importante ferramenta estratégica para conquistar novos clientes.

De acordo com Franzese (2005), existe uma tendência de migração dos call centers (*offshoring*) dos Estados Unidos e dos países da Europa para países emergentes como o Brasil. Essa migração é impulsionada pela redução de custos, uma vez que os custos nos Estados Unidos e Europa são altos, pela queda nos custos de comunicação e pelo acesso à mão-de-obra especializada de baixo custo fora dos Estados Unidos e Europa (ROBINSON; KALAKOTA, 2005).

Friedman (2005) cita em seu livro exemplos de call centers indianos que, apresentando um custo menor, contratam jovens à baixos salários e oferecem treinamento para neutralização do sotaque para atender, principalmente, clientes dos Estados Unidos. Assim empresas americanas poderiam atender seus clientes a um custo menor, fazendo parecer que os seus atendentes sejam americanos.

O setor de centrais de atendimento é um dos setores que mais empregam no Brasil. Nos últimos anos o setor vem apresentando um crescimento da ordem de 10% ao ano (CALLCENTER.INF.BR, 2012a). O setor fechou o ano de 2012 com 1,5 milhões de pessoas empregadas e mais de 29 bilhões de reais de faturamento somente no Brasil (CALLCENTER.INF.BR, 2012a). Boa parte da mão-de-obra desse setor é composta por jovens entre 18 e 24 anos que, em muitos casos, têm essa experiência profissional como a primeira de suas vidas. Outro dado relevante, é que o setor consolidou 1,5 bilhão de chamadas por mês, o que é equivalente a mais de sete vezes o tamanho da população brasileira no ano de 2012 (CALLCENTER.INF.BR, 2012b).

## 1.1 JUSTIFICATIVA E MOTIVAÇÃO

Esse rápido crescimento do setor tem impulsionado uma série de pesquisas em gerência de produção em vários domínios que incluem previsão, planejamento de capacidade, teoria de filas e gerenciamento de escala (AK-SIN; ARMONY; MEHROTRA, 2007).

Hall e Anton (1998) definem duas dimensões de qualidade de serviços a clientes de um call center que servem como medida de desempenho: eficiência do negócio e eficiência do atendimento. A figura 1 mostra a relação entre essas duas dimensões.

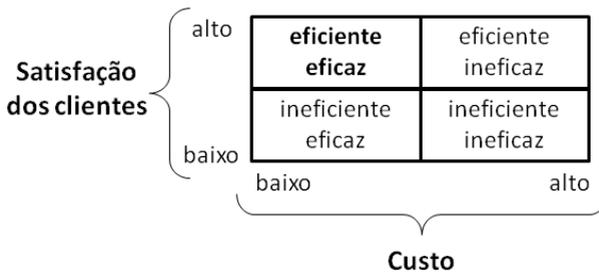


Figura 1 – Matriz de Desempenho de call center (HALL; ANTON, 1998).

Em paralelo, a legislação brasileira tenta acompanhar as novas tendências de atendimento ao consumidor regulamentando o setor. A criação do Lei Nº 8.078 em 1990, também conhecida como Código de Defesa do Consumidor, fixou normas sobre o Serviço de Atendimento ao Consumidor (SAC) (PLANALTO, b). Recentemente o Decreto Nº 6523 do ano de 2008 regulamentou a Lei Nº 8.078 e fixou normas gerais sobre o Serviço de Atendimento ao Consumidor (PLANALTO, a).

Call centers que se encaixam em baixo custo de operação e alto nível de satisfação dos clientes são denominados de “*world class*”. Com o crescimento do setor de call center, a busca por menores custos e a legislação que regulamenta o setor, torna-se necessária a pesquisa por métodos de previsão mais acurados que possibilitem aumentar a eficiência e eficácia.

De acordo com Franzese (2002), o processo de dimensionamento de um call center deve:

“Garantir a quantidade necessária de recursos e pessoas qualificadas no momento correto, para atendimento do volume previsto, com a garantia de qualidade e nível de serviço, ao menor custo possível.”

Em um call center, os algoritmos de previsão de chamadas recebidas são ferramentas utilizadas para antever a carga de uma operação e, conseqüentemente, para o dimensionamento de recursos. Porém, alguns fenômenos podem impactar no volume de chamadas recebidas, fazendo com que algoritmos de previsão clássicos, como os de Box-Jenkins, gerem resultados aquém do esperado.

## 1.2 PROBLEMA

Desde a invenção do telefone em 1876, os serviços de telefonia tiveram uma proliferação muito rápida e logo seu público passou a depender de um serviço confiável. Conforme o número de assinantes do serviço crescia, as companhias telefônicas começaram a enfrentar problemas de planejamento de recursos. Um grande problema era saber quantas telefonistas eram necessárias, pois em pouca quantidade, elas não conseguiriam atender a demanda e em muita quantidade, aumentariam muito o custo para as companhias, o que, conseqüentemente, seria repassado aos clientes. Outra questão que complicava o planejamento era que as chamadas chegavam em um padrão aleatório impulsionadas por diversos motivos (CLEVELAND; MAYBEN, 1999).

Nos anos seguintes muitos estudiosos propuseram soluções para lidar com os desafios da gestão dos recursos na área de telefonia. Um desses foi A.K. Erlang, que em 1917, em seu trabalho “Solution of some Problems in the Theory of Probabilities of Significance in Automatic Telephone Exchanges”, propôs fórmulas para perda e tempo de espera na área de tráfego de telefonia (ERLANG, 2007).

A partir do século XX, o processo de automação dos sistemas de telefonia extinguiu a necessidade de telefonistas. Porém, as centrais de atendimento modernas também enfrentam problemas semelhantes aos primeiros sistemas de telefonia: previsão acurada do volume de chamadas e alocação de pessoas e recursos nos lugares e no momento correto (CLEVELAND; MAYBEN, 1999).

Reynolds (2005) aponta três abordagens que podem ser utilizadas para a previsão do volume de chamadas:

- Estimativa de ponto: é a mais simples e assume que um ponto no futuro corresponde a algum ponto no passado. Entretanto, por não levar em conta qualquer tendência para cima ou para baixo, pode apresentar um grande erro, ainda mais se houver dados atípicos no passado;
- Estimativa por médias: nessa abordagem podem ser utilizados vários

métodos, como médias simples, médias móveis e médias ponderadas. Cada método descarta uma quantidade diferente de dados do passado que refletirão em uma previsão baseada mais no histórico ou mais nos acontecimentos presentes. A média ponderada dá pesos maiores aos dados mais recentes e é possivelmente o método que consegue melhor prever o volume de chamadas. Contudo, a abordagem de médias não consegue identificar tendências de aumento no volume;

- Séries temporais: levam informações históricas e permitem o isolamento dos efeitos de nível, tendência e de sazonalidade. É uma abordagem bastante utilizada, pois parte do pressuposto que as chamadas recebidas em um call center seguem alguns padrões que podem ser identificados e reproduzidos na previsão.

A previsão do volume de chamadas é uma forma de indicar as principais decisões da central de atendimento, que devem ser tomadas para alocação de mão de obra e de recursos (tanto físicos quanto tecnológicos) para atender este volume previsto, bem como indicar se o nível de serviço será adequado. A importância de uma previsão de chamadas recebidas com o menor erro possível é ressaltada pelo alto custo dos recursos humanos, que respondem aproximadamente por 60% a 70% dos custos de uma operação de call center (GANS; KOOLE; MANDELBAUM, 2003; BORST; MANDELBAUM; REIMAN, 2004).

Os modelos clássicos de previsão em séries temporais, como o de Box-Jenkins, costumam apresentar resultados aceitáveis quando diante de séries relativamente longas e bem comportadas. Este não é o caso da maioria das séries de dados relativos à demanda por serviços em call centers. A dinâmica desses ambientes faz com que raramente se tenha séries de longa duração (três anos ou mais), consistentes e homogêneas. Ao contrário. Em sua grande maioria, as séries possuem menos do que três anos e pouca homogeneidade. Séries curtas restringem a aplicação de ferramentas mais poderosas de previsão estatística, como ARIMA, por exemplo. Por sua vez, a falta de unidade nas séries implica na presença de fenômenos que, muitas vezes, perturbam sobremaneira os dados, trazendo resultados aquém do esperado quando se emprega unicamente processos clássicos de previsão.

Tal situação faz com se multipliquem, dentre os membros das equipes de planejamento, a geração de métodos empíricos complementares aos modelos clássicos. Este tipo de “conhecimento” não pode ser ignorado. Trata-se, muitas vezes, de um importante legado que deve ser aproveitado pelas equipes de previsão e planejamento. Segundo Mehrotra e Fama (2003), uma previsão em um Call Center é uma combinação de dados históricos, modelo de séries temporais e o julgamento do especialista.

As campanhas de marketing estimulam ações publicitárias e vendas e são um exemplo de fenômeno que influencia no aumento da demanda (REYNOLDS, 2005). A figura 2 apresenta um exemplo de dois fatores (eventos aleatórios) que causam impacto no número de chamadas recebidas seja maior do que o número de chamadas esperadas. No exemplo é apresentado uma série de dados que seria o comportamento padrão (esperado) em contraste com o valor real, que é o valor esperado influenciado pelos fatores A e B.

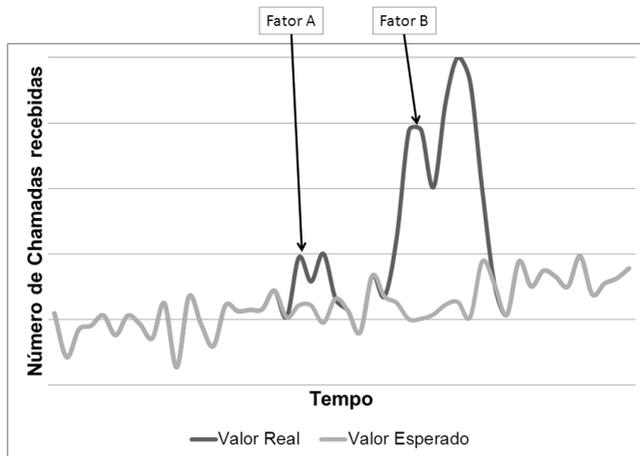


Figura 2 – Exemplo de impacto dos fatores nas chamadas recebidas.

Nas últimas duas décadas a possibilidade de se empregar ferramentas computacionais que capturam o conhecimento dos especialistas e proporcionam sua disseminação e utilização em diversos processos decisórios é uma realidade. No entanto, na grande maioria dos ambientes corporativos das centrais de atendimento, essa realidade ainda não está presente.

Várias técnicas sobre previsão demanda de chamadas em call center foram apresentados em trabalhos nos últimos anos (AVRAMIDIS; DESLAURIERS; L'ECUYER, 2004; BOUZADA, 2006; TAYLOR, 2008; SHEN; HUANG, 2008; LOPES et al., 2009; FRANZESE et al., 2009; ALDORNOIMAN; FEIGIN; MANDELBAUM, 2010; JIAN; WU-FENG; CHUNYAN, 2010; LIAO et al., 2011; AKTEKIN; SOYER, 2011). Alguns desses trabalhos utilizam técnicas de inteligência artificial (IA) para auxiliar na modelagem dos fatores que irão influenciar na previsão. No entanto muitas das propostas são para um cenário específico ou simplesmente não tratam eventos que possam a vir alterar a previsão, gerando assim um subdimensionamento ou superdimensionamento na equipe de atendentes de um call center.

### 1.3 PROPOSTA

No contexto de previsão de volume de chamadas para call center, esta pesquisa visa o desenvolvimento de ferramentas de previsão do volume de chamadas para call centers. Neste projeto, pretende-se trabalhar tanto com os chamados modelos clássicos de previsão, como os de suavização exponencial, incorporando a esses algumas técnicas de inteligência computacional e de decisão sob incerteza. O objetivo é permitir que um analista possa incorporar o seu conhecimento tácito sobre o call center visando a diminuir o erro de previsão dos dados gerados pelos modelos de previsão para, então, calcular com menor erro a quantidade de recursos necessários para uma operação de call center.

A ideia é desenvolver um método que combine técnicas clássicas, conhecimento empírico e ferramentas de apoio à decisão sob incerteza. A proposta é propor um método permita incorporar, aos modelos de previsão, o conhecimento empírico adquirido através das observações do comportamento da demanda ao call center, diante de inúmeros fatores aleatórios que podem influenciar no valor resultante da previsão. É possível, também, simular vários cenários, permitindo avaliar as influências dos diferentes fatores aleatórios, em distintos graus de intensidade, sobre a variabilidade nas cargas exercidas sobre os sistemas avaliados.

### 1.4 OBJETIVO GERAL

Desenvolver um método de previsão de volume de chamadas recebidas que seja possível adicionar fatores aleatórios no qual serão tratados por técnicas de inteligência artificial.

### 1.5 OBJETIVOS ESPECÍFICOS

Dentre as etapas do trabalho, pode-se citar os seguintes objetivos específicos:

- Entender o processo de previsão em um call center, os dados que o compõe, os métodos utilizados bem como os fatores que irão influenciar no valor previsto;
- Propor um módulo de refino da previsão, onde os fatores aleatórios inseridos indicam o ajuste que deve ser feito na previsão;

- Avaliar a ferramenta de previsão com refino em um call center.

## 1.6 ESTRUTURA DO TRABALHO

Este trabalho está organizado em 5 capítulos. O capítulo 1 apresenta uma introdução e uma visão geral sobre as centrais de atendimento e previsão do volume de chamadas. Neste capítulo também são expostos os problemas a serem abordados e os objetivos a serem desenvolvidos neste trabalho.

O capítulo 2 traz uma revisão bibliográfica dos principais assuntos relacionados à pesquisa. Inicialmente, são apresentados alguns conceitos sobre call center, como tecnologias existentes e métricas de desempenho. Em seguida, são abordados conceitos de previsão de dados e, em especial, de séries temporais. Por último, são apresentados Sistemas Especialistas Probabilísticos e o raciocínio bayesiano.

O capítulo 3 apresenta uma proposta de processo de previsão de dados que inclui os fatores aleatórios e as ferramentas desenvolvidas para auxiliar no processo. No capítulo, primeiramente é mostrado um simulador de call center desenvolvido para gerar sinteticamente dados de chamadas recebidas, no qual será possível testar diversos cenários em call centers. Em seguida, é apresentada uma ferramenta que foi desenvolvida para auxiliar no método de escolha do modelo de previsão de série temporal, o EZF. Por último, é apresentada uma proposta de modelo de previsão para call center, que utiliza um processo de normalização para extração dos fatores aleatórios e redes bayesianas para estimação da ocorrência dos fatores aleatórios nas chamadas previstas.

O capítulo 4 apresenta uma avaliação do simulador de call center e do modelo proposto de previsão de chamadas. A avaliação do modelo de previsão proposto compreende na avaliação dos dados históricos, que serão utilizados na previsão, avaliação da previsão mensal feita através do modelo proposto e avaliação da previsão diária também feita utilizando o modelo proposto.

Por último, o capítulo 5 apresenta as conclusões obtidas com o desenvolvimento deste trabalho, bem como a indicação de trabalhos futuros para a continuidade desta pesquisa.



## 2 REVISÃO BIBLIOGRÁFICA

Para o desenvolvimento de uma proposta de previsão de chamadas que incorpore os fatores aleatórios, alguns conceitos como centrais de atendimento, previsão de dados, séries temporais e tratamento da incerteza devem ser abordados. Esses conceitos são base para o entendimento de todos os processos em uma central de atendimento, desde o recebimento de chamadas até a previsão do número de chamadas recebidas, e base também para a elaboração de uma proposta de modelo de previsão.

### 2.1 CENTRAIS DE ATENDIMENTO

Minghelli (apud FREITAS, 2000) comenta que, em 1970, a Ford Motor Company resolveu investir maciçamente em uma campanha de marketing por telefone. Para isso, foram recrutadas 15 mil donas-de-casa que, de suas próprias residências, efetuaram 20 milhões de ligações para definir o mercado potencial de clientes. A essa iniciativa de campanhas de marketing por telefone deu-se o nome de *telemarketing*.

Já na década de 1990, Minghelli (apud COSTA, 1999) cita o crescimento acelerado desse tipo de atividade, principalmente devido ao surgimento de novas tecnologias e ao acirramento da concorrência, o que forçou empresas a focarem na fidelização de seus clientes. Foi nesse momento que, integrado às soluções de informática, o *telemarketing* evoluiu para call center.

Para Sakamoto (2001), um call center pode ser definido como “o lugar onde os chamados são feitos, ou recebidos, em grandes quantidades, com o objetivo de apoiar processos de vendas, *marketing*, serviços ao cliente ou outra atividade específica”.

Já Minghelli (2002) define call centers como “centros integrados de contato entre empresas e consumidores, estabelecidos de forma remota e/ou virtual, através do uso da tecnologia”.

Atualmente, mesmo com a popularização da internet, as pessoas ainda utilizam o telefone (fixo ou celular) para se comunicarem, mas também utilizam outros meios de comunicação com o e-mail, bate-papo online, fóruns da internet e mensagens instantâneas (BERGEVIN et al., 2010). A nova tendência para atender esses novos meios de comunicação é a ampliação dos call centers para centrais de atendimento (GANS; KOOLE; MANDELBAUM, 2003).

### 2.1.1 Tecnologias em centrais de atendimento

Antes da década de 1970, algumas empresas utilizavam salas de telefonia (precuroras do call center) espalhadas em várias regiões. Essas salas possuíam várias mesas, telefones com extensões e muito papel para rastrear o que acontecia neste centro de operação. Algumas pessoas diziam que essas salas eram muito barulhentas e confusas (BERGEVIN et al., 2010).

Na metade da década de 1960, as empresas começaram a utilizar o PABX (Private Automated Business Exchanges) que conseguia lidar com um grande número de chamadas (HELPER, 2011).

Já na década de 1970, surgiram os primeiros distribuidores automáticos de chamadas (DAC) que conseguiam direcionar uma chamada, conectada através de um PABX, para um atendente (GANS; KOOLE; MANDELBAUM, 2003). A empresa Rockwell afirma ter criado em 1973 o primeiro DAC, que possibilitava a Continental Airlines executar um sistema de reservas por telefone (HELPER, 2011).

Com o avanço das tecnologias computacionais, os call centers passaram a utilizar a integração entre telefonia e computação (CTI - Computer Telephone Integration) que une os serviços de telefonia com recursos computacionais como interface gráfica amigável, banco de dados, apresentação automática dos dados dos clientes em tela, automatização dos processos durante o atendimento de uma ligação e sistema de repasse de informações do cliente com o roteamento de chamadas (MINGHELLI, 2002).

Outras tecnologias também são utilizadas em call centers e algumas delas estão listadas abaixo (MINGHELLI, 2002; FRANZESE, 2005; SOUZA, 2010):

- Unidade de Resposta Audível (URA): equipamento responsável pelo atendimento automático das chamadas e navegação de opções de serviço através do teclado do telefone. Em conjunto com o DAC, possibilita encaminhar a chamada ao atendente com a habilidade de atender a solicitação;
- Customer Relationship Management (CRM): estratégias de negócios que possibilitam o atendimento dos clientes conforme suas características e necessidades individuais, o que lhes confere tratamento diferenciado. Essas estratégias definem ferramentas que automatizam as funções de contatos e mudanças de atitude corporativa;
- Gravador digital: possibilita a gravação da conversa entre o atendente e o cliente, garantindo segurança para ambas as partes. Essa gravação

pode ser utilizada posteriormente para análise de capacitação dos atendentes.

### 2.1.2 Classificação do tráfego em um call center

As centrais de atendimento, no que diz respeito ao tipo de tráfego, podem ser classificadas com ativas, receptivas ou mistas. As centrais ativas (*Outbound*) são caracterizadas por realizar um contato com um cliente externo, enquanto as centrais receptivas (*Inbound*) são caracterizadas por receberem o contato de seus clientes. As centrais de atendimento mistas (*Blended*) realizam e recebem contato de seus clientes, ou seja, são ativas e receptivas ao mesmo tempo (GANS; KOOLE; MANDELBAUM, 2003).

Na Tabela 1 são apresentadas as principais diferenças entre call centers ativos e receptivos segundo Freitas (2000).

Tabela 1 – Diferenças entre um call center ativo e receptivo (FREITAS, 2000).

Receptivo ( <i>Inbound</i> )	Ativo ( <i>Outbound</i> )
- O cliente liga para o call center	- O call center realiza a ligação
- Gera cadastro nos contatos	- Requer cadastro para as ligações
- Público comanda a ligação	- Operador comanda a ligação
- Picos de demanda sazonais	- Picos previstos
- Menor objeção dos clientes	- Maior objeção dos <i>prospects</i> <sup>1</sup>
- Maior conhecimento do produto pelo atendente	- Maior conhecimento da técnica pelo atendente
- Equipamento e estrutura adequadas à demanda	- Adequado ao tamanho do esforço de vendas
- Não possui <i>scripts</i> <sup>2</sup>	- Requer <i>scripts</i>

### 2.1.3 Tratamento das chamadas receptivas em um call center

Em um call center receptivo, as chamadas recebidas seguem os seguintes passos (GANS; KOOLE; MANDELBAUM, 2003; AVRAMIDIS; L'ECUYER, 2005):

1. Os clientes, utilizando a rede de telefonia de serviço público (PSTN),

<sup>1</sup>*prospects*: aqueles que ainda não são clientes

<sup>2</sup>*scripts*: roteiros preparados para conversa

ligam para a empresa de call center.

2. A chamada é recebida pelo PABX da empresa e, caso existam troncos disponíveis, a chamada é conectada ao PABX.
3. Ao conectar a chamada, uma URA pode tomar a chamada e direcioná-la para um distribuidor automático de chamadas (DAC).
4. O DAC roteia a chamada para um agente disponível. Se não houverem agentes disponíveis no momento, o DAC pode segurar a chamada em uma fila de espera até que algum agente se torne disponível. Os clientes podem abandonar a fila de espera antes de serem atendidos se ficaram impacientes.
5. Um vez conectada a chamada ao agente, ele pode utilizar um computador ou terminal para realizar o atendimento.
6. No final do atendimento, o agente ainda pode executar operações de pós-atendimento, para então se tornar disponível para receber novas chamadas.

Durante uma operação de call center, todos os passos executados são gravados em arquivos de *log*, desde o recebimento das chamadas até a finalização delas, incluindo os tempos de espera em fila, os agentes que atenderam a chamada e os tempos de atendimento (*talk time*) das chamadas. Todos estes registros detalhados (*traces*) contêm uma grande quantidade de informações e mostram o desempenho da operação do call center. Em geral, estes registros são sumarizados pelas operações do DAC, calculando-se as médias para cada intervalo de tempo, que normalmente é de 15 ou 30 minutos (BROWN et al., 2005; SHEN; HUANG, 2008).

Os registros podem mostrar a taxa de chegadas de chamadas e seu comportamento durante a operação de call center em vários períodos de tempo, que podem ser de hora em hora, diária, semanal, mensal ou até mesmo anual. Essas taxas de chegadas podem apresentar alguma variabilidade previsível ou algum padrão sazonal.

As taxas de chegadas de chamadas, na maioria das vezes, são previstas usando a abordagem *top-down* (GANS; KOOLE; MANDELBAUM, 2003), ou seja, é feita uma previsão de tempo para um período extenso e então este valor previsto é distribuído em períodos menores de tempo. Em geral, primeiramente, os registros de chegadas são acumulados mensalmente e são utilizados em métodos de previsão de séries temporais para obter os valores mensais do volume de chamadas recebidas.

Entretanto, o valor final do volume previsto muito raramente é aquele apontado pelo modelo matemático de previsão. O comum é que um ou mais

analistas opinem e corrijam o valor obtido. A experiência e conhecimento tácito desses analistas são, então, incorporados ajustando os valores dos modelos, para cima ou para baixo, conforme a intuição destes decisores, baseada, principalmente, em expectativas de comportamentos de fatores aleatórios não capturados, ou apenas parcialmente capturados, pelos modelos matemáticos de previsão.

#### **2.1.4 Métricas de desempenho de call center**

Para Franzese et al. (2009), um call center bem dimensionado, além de reduzir custos de operações e de implantação, também pode melhorar as seguintes variáveis:

- Tempo de espera: se o número de atendentes for apropriado, o tempo de espera em fila fica apropriado para o consumidor e, como consequência, os custos de telefonia são reduzidos;
- Taxa de ocupação dos atendentes: uma das principais métricas do correto dimensionamento, a taxa de ocupação, quando em valores altos, significa que os atendentes estão quase sempre em atendimento de uma chamada, o que pode levar a uma aumento no tempo de espera do cliente (já que os atendentes estarão ocupados) e aumento no cansaço dos atendentes. O contrário, quando a taxa de ocupação é muito baixa, significa que os atendentes estão passando muito tempo ociosos, o que leva a grandes custos operacionais;
- Sinal de ocupado: esse fator se refere ao número de linhas disponíveis. Caso o número de linhas seja pequeno, alguns clientes poderão ser perdidos, uma vez que nem conseguem chegar na fila de espera;
- Abandono: caso o número de atendentes não supra a demanda, uma fila logo se formará e muitos clientes acabarão abandonando esta fila por não terem paciência de esperar.

Na visão de Gans, Koole e Mandelbaum (2003), a eficiência e a qualidade operacional de uma central de atendimento poderia ser extraordinária, uma vez que os atendentes teriam os níveis de ocupação médio entre 90% e 95%, nenhum cliente receberia sinal de ocupado, mais da metade dos clientes seriam atendidos imediatamente e o restante teria tempo de espera medido em segundos e ainda a taxa de abandono iria variar de um valor desprezível até o nível de 1-2%. Porém, os próprios autores citam que as centrais de atendimento que exercem boas práticas são exceção.

## 2.1.5 Relação de custo e produtividade

É notável que o principal custo nos call centers são os atendentes e, por isso, eles devem trabalhar de maneira mais eficaz e eficiente possível.

O melhor indicador de eficácia é o percentual de resolução na primeira chamada, que indica se foi dada uma solução à solicitação evitando assim rechamadas. Outro indicador importante de eficiência é o tempo médio de espera, que indica o quanto uma chamada precisa esperar em média para conseguir um atendente no call center. O aumento da resolução na primeira chamada e a diminuição do tempo de espera são duas métricas que os call centers devem ter em seus objetivos (KOOLE, 2007).

Já para medir a eficiência é utilizada a métrica de produtividade, que é o percentual do tempo trabalhado sobre o tempo em que o atendente foi escalado (KOOLE, 2007).

No entanto, os indicadores têm de ser considerados em conjunto, pois não adianta ter uma eficiência alta se a resolução na primeira chamadas for baixa. Nessa situação, os atendentes estariam trabalhando bastante, porém sem conseguir resolver as solicitações (KOOLE, 2007).

## 2.1.6 Problemas em call centers

De acordo com callcentrehelper.com (2010), os dez maiores problemas em um call center são:

1. Absentismo dos agentes: De acordo com os dados da empresa Dimension Data, a taxa média anual de ausência dos agentes em centrais de atendimento é de 11%. Isso significa que menos agentes podem estar disponíveis, o que ocasiona um aumento nas filas de espera de atendimento. Com isso os agentes disponíveis são colocados sob pressão para gastar menos tempo no atendimento e diminuir a fila de espera. Caso o absentismo for alto, pode haver impacto sobre a moral da equipe.
2. Atrito da equipe: A alta rotatividade de agentes pode ter um impacto negativo no call center, uma vez que cada agente treinado que deixa a equipe, significa que menos agentes treinados estarão prontamente disponíveis para manter os níveis de serviço. Além disso, os custos de recrutamento, contratação, treinamento e desenvolvimento de uma nova equipe de atendimento são altos, o que faz com que recrutadores batalhem para evitar uma queda na produtividade.
3. Engajamento dos agentes: Devido à sua natureza, o trabalho pode ser

monótono por um lado, pelo trabalho repetitivo, mas por outro lado pode ser estressante, pelas metas que devem ser atingidas pela equipe. Por causa disso os agentes podem se tornar desmotivados, o que pode levar ao absentismo.

4. Estrutura planas: Uma pesquisa da empresa Dimension Data mostrou que menos de um terço das empresas de call centers têm um plano de carreira para os seus funcionários. Com isso as empresas correm o risco de perder pessoas talentosas por não oferecerem oportunidades de carreira adequadas.
5. Corte de custos: Orçamentos apertados são um problema constante nos call centers. Devido ao alto custo de pessoal, muitos executivos tem como objetivo cortar gastos com pessoal, o que pressiona as equipes existentes.
6. Taxa de resolução na primeira chamada baixa: A resolução na primeira chamada é uma importante métrica de satisfação do cliente. Ela mostra se um cliente necessita realizar uma nova ligação para resolver o seu questionamento. Baixas taxas de resolução apontam que pode haver uma ineficiência nas equipes de atendimento.
7. Incapacidade de melhorias nos níveis de performance: A maioria dos call centers procura aumentar os seus níveis de desempenho. Em muitos casos a estagnação dos níveis de desempenho ou, em um pior caso, a queda dos níveis de desempenho podem levar a desmotivação dos gerentes e dos funcionários.
8. Fraca integração: As centrais de atendimento possuem atualmente vários softwares que auxiliam o atendimento das chamadas. Dentre os principais software estão os discadores preditivos, bases de dados de clientes, softwares de *workforce management* (gestão de pessoal), aplicações de cartão de crédito e unidades de resposta audível. No entanto muitos softwares distintos podem tornar as tarefas de atendimento mais complicadas se eles não forem integrados.
9. Proliferação das tecnologias de comunicação: Atualmente existem vários meios de comunicação que podem ser utilizados para o atendimento do cliente, desde o telefone, passando pela internet e chegando até as redes sociais. Algumas empresas focam o atendimento em certos meios em detrimento de outros, porém os clientes esperam que o atendimento seja conduzido da mesma maneira nos diferentes meios.

10. Rotatividade dos clientes: O atrito com os clientes é um problema frequente em call centers. O custo da perda dos clientes ou da desistência da aquisição de um produto ou serviço nas empresas é enorme e impacta no orçamento do atendimento.

## 2.2 PREVISÃO DE DADOS

Na década de 1970, segundo Bouzada (apud HANKE, 1992), administradores tomavam decisões segundo seus sentimentos e intuições. Com o passar do tempo, o “sentimento” foi complementado com técnicas de previsão, reforçadas pela utilização do computador.

Para melhor entendimento do significado de previsão, Martins e Lau-geni (2005) conceituam três palavras que são utilizadas em processos administrativos:

- Planejamento: é o processo lógico que descreve as atividades necessárias para ir do ponto em que se está até o objetivo definido;
- Predição: processo para determinação de um acontecimento futuro, baseado em dados completamente subjetivos e sem uma metodologia clara;
- Previsão: processo metodológico para 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 definida.

Makridakis, Wheelwright e Hyndman (1998) definem três categorias de métodos de previsão: imprevisível, qualitativo e quantitativo. A categoria imprevisível é atribuída quando há pouco ou nenhum dado disponível. Exemplo dessa categoria são previsões dos efeitos de uma nova tecnologia.

O tipo de previsão qualitativa é utilizada quando há pouco, ou nenhum, dado quantitativo mas existe conhecimento qualitativo suficiente. A previsão da velocidade das telecomunicações nos próximos vinte anos e a previsão de quanto o consumo de petróleo será afetado após uma alta de preço são dois exemplos de previsão qualitativa.

O outro tipo de previsão é a quantitativa, que ocorre quando há informação de acontecimentos passados que podem ser quantificados na forma numérica e que também o padrão pode ser assumido que acontecerá no futuro. Esse tipo de previsão pode ser dividida em modelos de análise exploratória e de série temporal. Um exemplo de análise exploratória é a análise das variáveis como preço e publicidade afetam as vendas de um produto. Já

um exemplo de previsão por série temporal é a previsão da continuidade dos padrões de crescimento de vendas de um produto.

Segundo Cleveland e Mayben (1999), previsão é uma mistura de arte e ciência. Tudo começa ao se predizer quantas transações ocorrerão em um período futuro e, em seguida, modificando esses valores de acordo com condições que não refletem no histórico de dados.

Bergevin et al. (2010) mostram que em um ambiente de call center podemos ter três tipos de impacto das previsões:

- Longo prazo: são previsões superiores a três meses e utilizadas em planejamento de orçamento operacional (quantidade de dinheiro para manter um call center em funcionamento) e projeção de capital (quantidade de dinheiro para construir um call center);
- Médio prazo: este tipo de previsão informa quantas pessoas serão necessárias na operação e, também a quantidade de equipamento deve estar disponível;
- Curto prazo: geralmente são previsões de no máximo uma semana, que definem ajustes de escala de pessoal para acomodar mudanças recentes na demanda ou na disponibilidade de pessoal.

### 2.2.1 Processo de previsão

O processo de previsão de séries temporais pode ser descrito como uma ou mais entradas que se transformam em uma ou mais saídas (MONTGOMERY; JENNINGS; KULAHCI, 2008). A figura 3 mostra esquematicamente as atividades para uma previsão descritas por Montgomery, Jennings e Kulahci (2008).

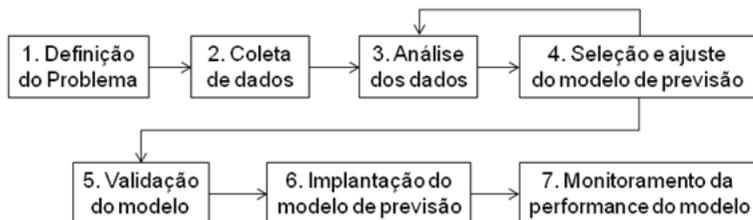


Figura 3 – Atividades do processo de previsão.

1. A Definição do problema compreende em entender como a previsão será utilizada em conjunto com as expectativas dos usuários da previsão. Nesta etapa definem-se os formatos desejados de previsão, o horizonte de previsão e o intervalo de previsão, a frequência de revisão da previsão e o nível de acurácia da previsão. Ainda nesta etapa os tomadores de decisão tomam conhecimento de risco associado aos intervalos de previsão.
2. A coleta de dados consiste em obter um histórico relevante das variáveis que serão tratadas na previsão, incluindo informação histórica de variáveis com potencial de preditoras. Essas informações geralmente são coletadas nos métodos de armazenamento e em sistemas que mudam ao longo do tempo, sendo que nem todos os dados históricos podem ser úteis para o problema. Algumas vezes é necessário lidar com a falta de valores de algumas variáveis. Nesta fase é útil fazer um planejamento da coleta e do armazenamento para o futuro de modo que os dados sejam confiáveis e íntegros.
3. O próximo passo é a análise de dados, onde os dados são plotados em forma de séries temporais para serem identificados visualmente algum padrão como tendência, sazonalidade ou ciclos. Algumas análises como médias, desvios padrões, percentis e autocorrelações podem também ser avaliadas. Essas informações avaliadas podem servir para uma sugestão inicial de métodos quantitativos e modelos a serem explorados.
4. A seleção e ajuste do modelo é a etapa seguinte à análise de dados. A seleção consiste em escolher um ou mais modelos de previsão para os dados analisados e o ajuste compreende em estimar os parâmetros do modelo. É possível retornar a etapa anterior para auxiliar na seleção de outros possíveis modelos de previsão.
5. A validação do modelo compreende em avaliar o modelo de previsão e determinar como será a performance na aplicação do problema, o que deve, além de simplesmente avaliar a “aderência” do modelo aos dados históricos, examinar a magnitude dos erros de previsão que serão experimentados em um modelo “novo”.
6. A implantação do modelo de previsão envolve obter o modelo e a previsão resultante em uso. Nesta etapa, é importante assegurar que o uso do modelo e das previsões devem se tornar tão rotineiras quanto possíveis.

7. O monitoramento da performance do modelo deve ser uma atividade contínua após a implantação do modelo para garantir que a previsão continua sendo feita de forma satisfatória. É natural da previsão que as condições mudem ao longo do tempo, e que um modelo que teve bom desempenho no passado possa não ter um bom desempenho no futuro. Geralmente, uma deterioração no desempenho resulta em erros de previsão maiores ou mais sistemáticos.

## 2.3 SÉRIES TEMPORAIS

Uma série temporal é um conjunto de observações ordenadas no tempo (MORETTIN; TOLOI, 2006). Exemplos de séries temporais são: temperaturas médias diárias, preço semanal da cesta básica, vendas mensais de um determinado produto, número de estudantes formados em engenharia anualmente, etc.

Alguns padrões de dados podem ser encontrados em séries temporais tais como aleatoriedade, tendência, nível, período, ciclo, observações não usuais e combinação de padrões (MONTGOMERY; JENNINGS; KULLAHCI, 2008). Dentre estes padrões, Makridakis, Wheelwright e Hyndman (1998) destacam alguns que são apresentados abaixo.

- **Horizontal:** Este tipo de padrão ocorre quando os valores flutuam em torno de uma média constante. As séries com este padrão são chamadas de estacionárias. Um exemplo deste padrão é um produto cujas vendas não aumentam nem diminuem ao passar do tempo;
- **Sazonal:** Existe em séries influenciadas por fatores sazonais, como, por exemplo, fatores semanais, mensais ou trimestrais. Consumo de energia elétrica e vendas de sorvetes são exemplos de séries que apresentam este tipo de padrão. Séries com padrão sazonal também são chamadas de periódicas;
- **Cíclico:** Ocorre quando os valores aumentam ou diminuem em um período não fixo de tempo. Um exemplo de padrão cíclico são séries econômicas que apresentam flutuações associadas ao ciclo de negócios. A principal diferença entre o padrão sazonal e cíclico é que o primeiro apresenta tamanho fixo do período das variações que se repetem em períodos regulares de tempo enquanto o segundo não apresenta tamanho fixo dessas variações;
- **Tendência:** Acontece quando há aumento ou diminuição dos dados a longo prazo. Valores do PIB (produto interno bruto) de uma região são

exemplos de dados que apresentam tendência.

De acordo com Morettin e Toloi (2006), possíveis análises em séries temporais são: (a) investigação do mecanismo gerador da série temporal, (b) previsão dos valores futuros da série, (c) descrição do comportamento da série, verificando a existência de tendências, ciclos, variações sazonais, dentre outras e (d) procura de periodicidade relevante nos dados.

Em muitas situações de gerência e administração, fazer previsão é necessário para tomada de decisão, que pode ser de curto prazo (como em roteamento de telecomunicações e de sistemas de energia elétrica), médio prazo (no caso de planejamento de escala de funcionários em uma empresa) e de longo prazo (em investimento de capitais) (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

### 2.3.1 Acurácia do modelo de previsão

Acurácia no processo de previsão é tratada como critério dominante na escolha de um modelo de previsão. Também pode ser tratada, em muitos casos, como o grau de precisão (*goodness-of-fit*) de um modelo reproduzir dados que já são conhecidos (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Seja  $Y_t$  o valor observado atual em um período  $t$  e  $F_t$  o valor previsto para o mesmo período, o erro  $e_t$  é definido como a diferença entre o valor observado e o valor previsto (2.1), ou seja:

$$e_t = Y_t - F_t \quad (2.1)$$

Em uma série que possua  $n$  observações, as seguintes medidas estatísticas podem ser definidas:

$$EM = \frac{1}{n} \sum_{t=1}^n e_t \quad (2.2)$$

$$EAM = \frac{1}{n} \sum_{t=1}^n |e_t| \quad (2.3)$$

$$EQM = \frac{1}{n} \sum_{t=1}^n e_t^2 \quad (2.4)$$

A Equação (2.2) pode ser definida como o erro médio (EM) dos valores previstos da série. O EM, em geral, apresenta valores baixos, pois a soma de erros positivos acabam sendo anulada pela soma dos erros negativos, não

indicando, assim, o tamanho dos erros típicos da previsão.

O erro absoluto médio (EAM), apresentado na equação (2.3), pode ser definido como a média dos erros de previsão em valores absolutos. O EAM tem a vantagem de ser mais apresentável à não-especialistas.

Uma terceira medida é o erro quadrático médio (EQM), que é mostrado na equação (2.4) e é definido como a média dos erros quadráticos da previsão. Nesta medida estatísticas os erros são forçados para valores positivos pela operação quadrática.

A escolha de qual medida utilizar irá depender da quantidade e da escala dos dados da série (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998). Porém, nas três medidas estatísticas apresentadas, os valores de erro médio encontrados não representam de forma adequada a magnitude do erro, por exemplo: um erro de 10 unidades é muito mais representativo em um série onde o valor médio é de 50 unidades do que em uma série com média de 5000 unidades.

Para melhor representar a magnitude do erro de previsão, o erro percentual (EP) ou relativo pode ser definido como:

$$EP_t = \left( \frac{Y_t - F_t}{Y_t} \right) \times 100 \quad (2.5)$$

Assim o EP é apresenta o erro relevativo à serie. As duas medidas estatísticas do erro relativo geralmente utilizadas são:

$$EPM = \frac{1}{n} \sum_{t=1}^n EP_t \quad (2.6)$$

$$EPAM = \frac{1}{n} \sum_{t=1}^n |EP_t| \quad (2.7)$$

A equação (2.6) mostra o erro percentual médio (EPM). Esse tipo de medida estatística também pode apresentar valores baixos pela soma de valores positivos e negativos de erros percentuais (assim como o erro médio).

O erro percentual absoluto médio (EPAM), apresentado em (2.7), consegue apresentar melhor a magnitude do erro de previsão do que o EPM. Porém, tanto o EPM e o EPAM apresentam problemas quando a série apresenta dados com valores contendo zeros, uma vez que são utilizados no denominador do erro percentual (EP).

### 2.3.2 Decomposição de séries temporais

De maneira geral, um valor na série temporal pode ser descrito como:

$$Y_t = f(T_t, S_t, E_t) \quad (2.8)$$

Onde:  $Y_t$  é um valor na série temporal no período  $t$ ,  $T_t$  é o componente de tendência da série no período  $t$ ,  $S_t$  é o componente sazonal no período  $t$  e  $E_t$  é o componente irregular (ou erro) no período  $t$ .

No modelo aditivo (2.9), os componentes da série simplesmente são somados para obter o valor da série temporal. Este tipo de modelo é apropriado se a amplitude das flutuações do componente sazonal não varia com o nível médio da série.

$$Y_t = T_t + S_t + E_t \quad (2.9)$$

Outro modelo de decomposição é o multiplicativo (2.10), os componentes são multiplicados. Esse tipo de modelo é apropriado se a amplitude das flutuações do componente sazonal aumenta ou diminui com o nível médio da série.

$$Y_t = T_t \times S_t \times E_t \quad (2.10)$$

Ainda podem ser utilizados modelos combinando fatores de decomposição de diferentes maneiras. Maiores detalhes estão disponíveis em Makridakis, Wheelwright e Hyndman (1998).

### 2.3.3 Métodos de suavização

De acordo com Montgomery, Jennings e Kulahci (2008), pode-se pensar que um conjunto de dados de uma série pode ser definido pela combinação de dois componentes: sinal e ruído. Sinal representa a dinâmica presente nos dados coletados e o ruído é a interferência (erro) no valor do sinal.

Os métodos de suavização podem ser definidos como técnicas de separar melhor o sinal e o ruído de forma com que a suavização funcione como um filtro que consiga estimar o sinal, ou seja, funcione de modo a capturar a dinâmica do processo de formação dos dados de uma série. A figura 4 mostra alguns exemplos de reconstrução de sinal onde o padrão subjacente é recuperado até certo ponto.

Os métodos de suavização podem ser divididos em dois grupos: métodos de média e métodos de suavização exponencial. O primeiro grupo é caracterizado por definir o comportamento do sinal (dados) através do uso de médias. Média simples e média móvel pertencem a esse primeiro grupo de suavização (MONTGOMERY; JENNINGS; KULAHCI, 2008).

O grupo dos métodos de suavização exponencial é caracterizado por

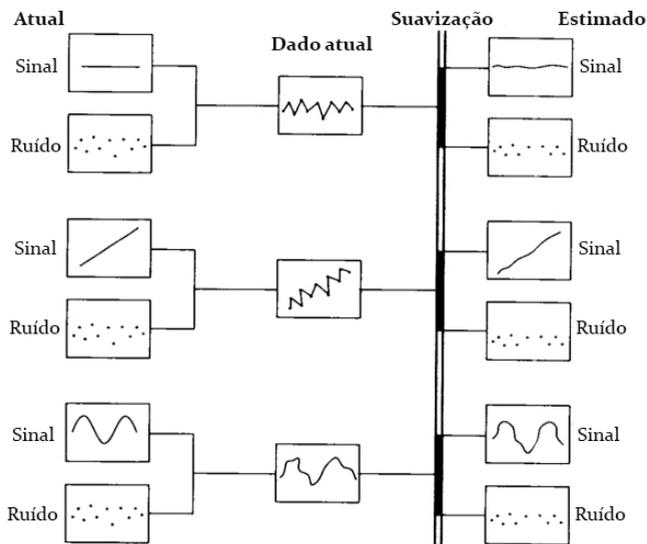


Figura 4 – Suavização de um conjunto de dados (MONTGOMERY; JENNINGS; KULAHCI, 2008).

dar pesos diferentes aos dados do passado, sendo que eles decaem do dado mais recente até o mais antigo. Todos os métodos desse grupo precisam de parâmetros entre 0 e 1 que irão determinar os pesos desiguais aos dados do passado.

A ideia da suavização exponencial teve origem com Robert G. Brown em 1944, enquanto trabalhava na Marinha Americana e foi utilizada para monitorar a velocidade e o ângulo dos disparos de armas em submarinos (HYNDMAN et al., 2008).

Os métodos de suavização exponencial foram classificados por Pegels em 1969 de acordo com a tendência e a sazonalidade da série temporal, dependendo se são aditivos ou multiplicativos (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998). A figura 5 mostra esta classificação.

Pegels ainda criou uma notação para melhor representar os métodos de suavização exponencial (apresentados na figura 5). A notação é mostrada na Tabela 2.

Conforme a classificação de Pegels, os métodos de previsão indicados por A-1, B-1, B-2 e B-3 são denominados suavização exponencial simples (SES), método de Holt, método de Holt-Winters aditivo e método de Holt-Winters multiplicativo.



Figura 5 – Classificação de Pegels (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Tabela 2 – Notação de Pegels para suavização exponencial.

Tendência	Sazonalidade		
	1 (Nenhuma)	2 (Aditiva)	3 (Multiplicativa)
A (Nenhuma)	A-1	A-2	A-3
B (Aditiva)	B-1	B-2	B-3
C (Multiplicativa)	C-1	C-2	C-3

De maneira geral, os componentes de uma série temporal para o cálculo da previsão por suavização exponencial podem ser representados por (2.11), (2.12) e (2.13), em que  $L$  representa o nível (componente horizontal) da série,  $b$  representa a tendência e  $S$  representa a sazonalidade. Cada um desses componentes pode dar mais peso aos dados mais recentes ou mais antigos conforme o valor de seu parâmetro correspondente. Os parâmetros  $\alpha$ ,  $\beta$  e  $\gamma$ , que devem apresentar valores entre 0 e 1, são parâmetros de suavização que dão peso aos componentes  $L$ ,  $b$  e  $S$  respectivamente.

$$L_t = \alpha P_t + (1 - \alpha) Q_t \quad (2.11)$$

$$b_t = \beta R_t + (1 - \beta) b_{t-1} \quad (2.12)$$

$$S_t = \gamma T_t + (1 - \gamma) b_{t-s} \quad (2.13)$$

Os valores  $P$ ,  $Q$ ,  $R$  e  $T$  variam de acordo com o método de suavização exponencial e são apresentados na Tabela 3. Com os componentes calculados, é possível fazer a previsão  $F$  para  $m$  períodos a frente.

Tabela 3 – Fórmulas da previsão segundo a classificação de Pegels.

Tendência	Sazonalidade		
	1 (Nenhum)	2 (Aditiva)	3 (Multiplicativa)
A (Nenhum)	$P_t = Y_t$ $Q_t = L_{t-1}$ $T_t = Y_t - L_t$ $F_{t+m} = L_t$	$P_t = Y_t - S_{t-s}$ $Q_t = L_{t-1}$ $T_t = Y_t - L_t$ $F_{t+m} = L_t + S_{t+m-s}$	$P_t = Y_t / S_{t-s}$ $Q_t = L_{t-1}$ $T_t = Y_t / L_t$ $F_{t+m} = L_t S_{t+m-s}$
B (Aditiva)	$P_t = Y_t$ $Q_t = L_{t-1} + b_{t-1}$ $R_t = L_t - L_{t-1}$ $F_{t+m} = L_t + mb_t$	$P_t = Y_t - S_{t-s}$ $Q_t = L_{t-1} + b_{t-1}$ $R_t = L_t - L_{t-1}$ $T_t = Y_t - L_t$ $F_{t+m} = L_t + mb_t + S_{t+m-s}$	$P_t = Y_t / S_{t-s}$ $Q_t = L_{t-1} + b_{t-1}$ $R_t = L_t - L_{t-1}$ $T_t = Y_t / L_t$ $F_{t+m} = (L_t + mb_t) S_{t+m-s}$
C (Multiplic.)	$P_t = Y_t$ $Q_t = L_{t-1} b_{t-1}$ $R_t = L_t / L_{t-1}$ $F_{t+m} = L_t b_t^m$	$P_t = Y_t - S_{t-s}$ $Q_t = L_{t-1} b_{t-1}$ $R_t = L_t / L_{t-1}$ $T_t = Y_t - L_t$ $F_{t+m} = L_t b_t^m + S_{t+m-s}$	$P_t = Y_t / S_{t-s}$ $Q_t = L_{t-1} b_{t-1}$ $R_t = L_t / L_{t-1}$ $T_t = Y_t / L_t$ $F_{t+m} = (L_t + b_t^m) S_{t+m-s}$

Aplicado um método de suavização exponencial, é possível otimizar os parâmetros que controlam o peso dos dados mais recentes e mais antigos de modo a minimizar as medidas estatísticas como EQM ou EPAM. A otimização desses parâmetros é feita com um algoritmo de otimização não-linear (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

## 2.4 TRATAMENTO DA INCERTEZA

Na lógica clássica, as variáveis de um problema possuem valores determinados com precisão, tais como verdadeiro ou falso. Segundo a teoria clássica dos conjuntos, essas características podem ser evidenciadas através da classificação de um elemento como sendo pertencente ou não a um conjunto. Entretanto, muitas das informações não podem ser classificadas segundo a lógica clássica, pois carregam indefinições nos limites de valor de veracidade de uma variável, tais como as variáveis qualitativas. Os métodos de modelagem não-clássicos surgiram, então, como forma de incorporar as características observadas para a resolução de problemas em que as técnicas clássicas não conseguem contemplar.

Conforme as condições da informação com a qual se está trabalhando

e o tipo de problema, pode-se escolher uma técnica de modelagem. Um modelo hierárquico de ignorância que aborda alguns dos problemas relacionadas com as informações é apresentado na figura 6 (AYYUB, 2001).

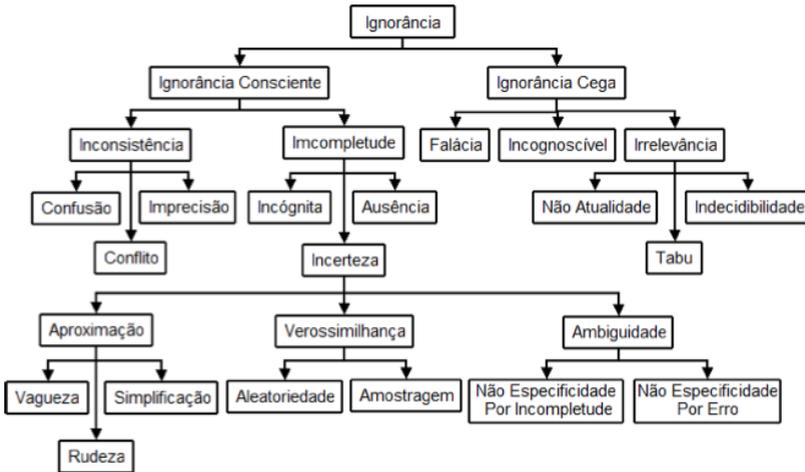


Figura 6 – Modelo hierárquico da ignorância (AYYUB, 2001).

O modelo de Ayyub (2001) parte da ignorância de alguma informação, isso é, da ausência de conhecimento a respeito de problema. A ignorância pode ser classificada em ignorância cega e ignorância consciente.

A ignorância cega, também chamada de meta-ignorância, pode ser descrita como a ignorância da própria ignorância, ou seja, quando não há consciência que não tem a informação. Esse tipo de ignorância pode ser classificada como: falácia, quando o conhecimento é ilusório; icognoscível, quando o conhecimento não pode ser obtido; e irrelevância, quando o conhecimento é ignorado.

A irrelevância pode ser classificada como: não-atualidade, quando a intuição de *experts* não pode ser compartilhada com outros em termos de relevância cognitiva; tabu, quando a sociedade reforça a irrelevância do conhecimento; e indecidibilidade, quando questões não podem ser consideradas verdadeiras ou falsas por não apresentarem solução.

O outro tipo de ignorância, a ignorância consciente, se refere à ignorância reconhecida, ou seja, quando há consciência de que não se tem informação. Esse tipo de ignorância se divide em inconsistência e incompletude. A inconsistência pode ser atribuída a informação distorcida como resultado de imprecisão, conflito ou confusão. Já a incompletude se refere

ao conhecimento incompleto por ausência de conhecimento, pela presença de icôgnitas ou pela incerteza da informação.

A incerteza pode ser definida pelas deficiências inerentes à aquisição do conhecimento. Uma das classificações da incerteza é a aproximação, que ocorre quando são realizadas aproximações no desenvolvimento do conhecimento por meio de redução e generalização. Esse processo de aproximação pode gerar informações vagas, rudes ou simplificadas, ou seja, informações que podem ser classificadas como vagueza, rudeza e simplificação respectivamente.

Outra classificação da incerteza é a verossimilhança, que pode ser definida através dos componentes de aleatoriedade, estatísticos e modelagem, e pode ser classificada em aleatoriedade e amostragem.

Uma outra classificação da incerteza é a ambiguidade, que ocorre quando há possibilidade de múltiplas saídas para um processo. A ambiguidade pode ser definida como não especificidade por incompletude, quando as saídas reconhecidas são apenas uma parte das saídas possíveis, e não especificidade por erro, quando as saídas não são propriamente definidas.

Ayyub (2001) ainda cita que alguns modelos são mais adequados para o tratamento de determinados tipos de incerteza do que outros. A teoria dos conjuntos clássica é eficaz com ambiguidade, modelando as não-especificidades. Já os conjuntos fuzzy e *rough sets* podem ser usados na modelagem de vagueza, rudeza e simplificação. As teorias de probabilidade e estatística geralmente são utilizadas para modelar aleatoriedade e amostragem. Por sua vez, os métodos bayesianos podem ser utilizados para combinar aleatoriedade e amostragem com informações subjetivas e podem ser consideradas como uma forma de simplificação.

A utilização de métodos bayesianos vai ao encontro com o processo de previsão de chamadas em uma central de atendimento, uma vez que durante uma operação alguns fenômenos aleatórios podem impactar no volume de chamadas recebidas.

### **2.4.1 Probabilidade**

A probabilidade é um ramo da matemática ligado aos estudos dos fenômenos que envolvem aleatoriedade e incerteza. A probabilidade tem relação com experimentos que têm resultados distintos. Um conjunto de resultados de um experimento, que pode ser de tamanho infinito, pode ser chamado de espaço amostral. Se o espaço amostral tiver tamanho finito, então cada subconjunto pode ser chamado de evento. Um subconjunto do espaço amostral contendo um único elemento é chamado de elemento primário (NE-

APOLITAN, 2004).

Suponha que se tenha o espaço amostral  $\Omega$  contendo  $n$  elementos distintos, isso é,  $\Omega = \{e_1, e_2, \dots, e_n\}$ , a função que atribui um número real  $P(E)$  a cada  $E \subseteq \Omega$  é chamada de função de probabilidade em um conjunto de subconjuntos de  $\Omega$  se satisfizer as seguintes condições (NEAPOLITAN, 2004):

1.  $0 \leq P(\{e_i\}) \leq 1$  para cada  $1 \leq i \leq n$
2.  $P(\{e_1\}) + P(\{e_2\}) + \dots + P(\{e_n\}) = 1$
3. Para cada  $E = \{e_{i1}, e_{i2}, \dots, e_{ik}\}$  que não seja um evento primário,  
 $P(E) = P\{e_{i1}\} + P\{e_{i2}\} + \dots + P\{e_{ik}\}$

O par  $(\Omega, P)$  é chamado de espaço de probabilidade. Em geral, é dito que  $P$  é a função de probabilidade em  $\Omega$ , ao invés de dizer que é um conjunto de subconjuntos de  $\Omega$ . Sendo assim, conforme o teorema nomeado por Kolmogorov como axioma da teoria da probabilidade,  $(\Omega, P)$  deve:

1.  $P(\Omega) = 1$
2.  $0 \leq P(E) \leq 1$  para cada  $E \subseteq \Omega$
3. Para  $E$  e  $F \subseteq \Omega$ , tal que  $E \cap F = \emptyset$ ,  
 $P(E \cup F) = P(E) + P(F)$

Quando os conjuntos  $E$  e  $F$  não são disjuntos (condição 3 do axioma), as probabilidades não são aditivas, então  $P(E \cup F) = P(E) + P(F) - P(E \cap F)$ .

Sejam  $E$  e  $F$  eventos tal que  $P(F) \neq 0$ , então a probabilidade condicional e  $E$  dado  $F$  pode ser denominada como:

$$P(E|F) = \frac{P(E \cap F)}{P(F)} \quad (2.14)$$

Dois eventos  $E$  e  $F$  são independentes se seguirem uma das seguintes condições:

1.  $P(E|F) = P(E)$  e  $P(F) \neq 0, P(F) \neq 0$
2.  $P(E) = 0$  ou  $P(F) = 0$

### 2.4.2 Teorema de Bayes

O Teorema de Bayes, na teoria da probabilidade, mostra a relação entre uma probabilidade condicional e a sua inversa. Dado os eventos  $E$  e  $F$  e

as probabilidades  $P(E) \neq 0$  e  $P(F) \neq 0$ , o teorema de Bayes pode ser definido como (RUSSELL; NORVIG, 2003):

$$P(E|F) = \frac{P(F|E)P(E)}{P(F)} \quad (2.15)$$

Onde  $P(E)$  e  $P(F)$  são probabilidades *a priori* de  $E$  e  $F$  respectivamente. As probabilidades  $P(E|F)$  e  $P(F|E)$  representam as probabilidades *a posteriori* de  $E$  condicional de  $F$  e de  $F$  condicional de  $E$  respectivamente.

A probabilidade de uma hipótese dada a observação de uma evidência e a probabilidade da evidência dada pela hipótese são exemplos do teorema de Bayes.

Seja um espaço de probabilidade  $(\varepsilon, P)$  e os eventos  $H_1, H_2, \dots, H_n \subseteq \varepsilon$  (mostrado na figura 7), desde que nenhum destes eventos tenham probabilidade nula, então a probabilidade de ocorrer  $H_i$ , condicionada ao evento  $e$ , é descrita na equação 2.16:

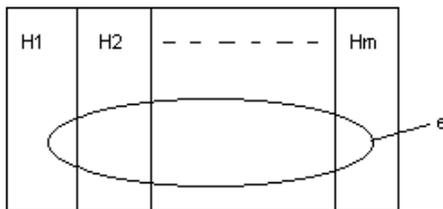


Figura 7 – Evento  $e$  em um conjunto de hipóteses  $H$ .

$$P(H_i|e) = \frac{P(e|H_i) \cdot P(H_i)}{P(e)} \quad (2.16)$$

A equação 2.16, que também é conhecida como Teorema de Bayes, pode ser lida como: a probabilidade de uma hipótese  $H_i$  dado um evento  $e$  é igual ao produto da probabilidade do evento  $e$ , dada a hipótese  $H_i$  com a probabilidade da hipótese  $H_i$  dividido pela probabilidade do evento  $e$ . O Teorema de Bayes deve:

1.  $P(H_i \wedge e) \neq \emptyset$  para todo  $i$
2.  $H_1 \cup H_2 \cup \dots \cup H_n = \varepsilon$  e  $H_i \cap H_j = \emptyset$  para todo  $i \neq j$

O raciocínio probabilístico bayesiano vem sendo utilizado na área de inteligência artificial desde a década de 1960 (RUSSELL; NORVIG, 2003). Com o Teorema de Bayes, é possível calcular a densidade *a posteriori* de uma

variável aleatória a partir de sua densidade *a priori* e o conjunto de dados (PLENTZ, 2003). A figura 8 mostra o processo de inferência.

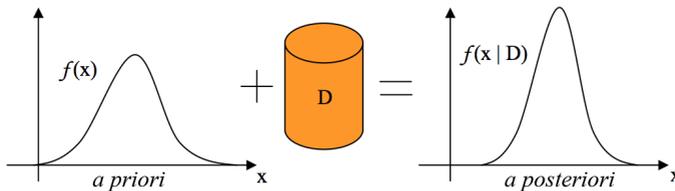


Figura 8 – Inferência Bayesiana (PLENTZ, 2003).

### 2.4.3 Sistemas Especialistas Probabilísticos

Os Sistemas Especialistas Probabilísticos (SEP) possuem em sua base regras e fatos que expressam o conhecimento de um especialista em um domínio de aplicação, associados às incertezas presentes no domínio explicitados pelas chances de ocorrência por valores de probabilidade (NASSAR, 2011).

A partir de dados de entradas (*input*), associadas a um vetor de probabilidades, um conjunto de categorias de classificação do sistema (*output*) é obtido através do raciocínio realizado pelo SEP. A ocorrência com maior probabilidade pode ser considerada a conclusão do sistema, que está associada a um grau de certeza da resposta (NASSAR, 2011).

Nas aplicações desse tipo de sistema, as hipóteses  $H_i$  são as hipóteses diagnósticas, relacionadas com os nós de saída. Já os eventos  $e$  podem ser considerados como evidências e estão relacionados com os nós de entrada. O conhecimento da ocorrência das evidências leva a mudanças na probabilidade *a priori*  $P(H_i)$  para a probabilidade condicional  $P(H_i|e)$ , em que a evidência  $e$  é considerada na probabilidade (NASSAR, 2011).

Para desenvolver uma representação do conhecimento em um sistema especialista probabilístico podem ser utilizados esquemas de representação chamados de Redes Bayesianas, que utilizam o Teorema de Bayes para estimar os valores de probabilidade do nó de saída (NASSAR, 2011).

#### 2.4.4 Redes Bayesianas

A partir da metade da década de 1980, as Redes de Crença Bayesianas forma introduzidas como resultado das pesquisas sobre raciocínio probabilístico em sistemas especialistas (NASSAR, 2011). Para realizar inferências, utiliza-se uma Rede Bayesiana, que é um grafo acíclico direcionado no qual os nós representam as variáveis de interesse (parte qualitativa da rede) e os arcos representam a dependência condicional entre as variáveis (parte quantitativa da rede) (PLENTZ, 2003; MAKIYAMA, 2006).

A base de conhecimento de uma Rede Bayesiana é formado por probabilidades, e os cálculos usados para gerar a saída são baseados no Teorema de Bayes (TIBIRIÇÁ; NASSAR, 2003). Essas probabilidades, que podem ser providas por especialistas ou por uma base dados, representam as incertezas encontradas nas relações entre as variáveis e estão associadas às Tabelas de Probabilidade Condicional (*Conditional Probability Table*) presentes em cada nó (MAKIYAMA, 2006 apud MATTOS, 2003).

Quando a Rede Bayesiana é instanciada para determinando caso, isto é, quando são fornecidas informações sobre determinadas variáveis com o objetivo de se realizar uma consulta ao sistema, a Rede Bayesiana calcula os valores de probabilidade *a posteriori* das outras variáveis (NASSAR, 2011).

A figura 9 mostra um exemplo de Rede Bayesiana para diagnóstico médico implementada no shell Netica<sup>1</sup> da Norsys Software Corp. O exemplo apresenta um problema do diagnóstico de câncer de pulmão mostrado em Korb e Nicholson (2010). Neste exemplo, um paciente vem sofrendo de falta de ar (dispnéia) e visita um médico temendo ter um câncer de pulmão. O médico sabe que outras doenças, como tuberculose e bronquite, podem ser possíveis causas da dispnéia, bem como o câncer. Também é conhecido que outros fatores - como ser fumante (que aumentam as chances de câncer e bronquite) e o ar a qual o paciente foi exposto (que aumentam as chances de tuberculose) - podem indicar qual a doença. Um resultado anormal do raio-x indicaria um caso de tuberculose ou câncer.

Nesse exemplo, pode-se fazer vários tipos de raciocínio sobre a Rede Bayesiana: (1) diagnóstico, no qual o raciocínio é feita a partir dos sintomas, (2) preventivo, no qual o raciocínio é feito a partir dos fatores contribuintes para as doenças, (3) intercausal, no qual o raciocínio de uma causa é feito a partir de um efeito desta causa e de uma outra causa que provoca o efeito e (4) misto, no qual existe a combinação dos raciocínios anteriores. No raciocínio diagnóstico, por exemplo, o médico pode observar a presença de dispnéia para atualizar as crenças de câncer. Já no raciocínio preventivo, a observação

---

<sup>1</sup>Disponível em: <http://www.norsys.com/netica.html>

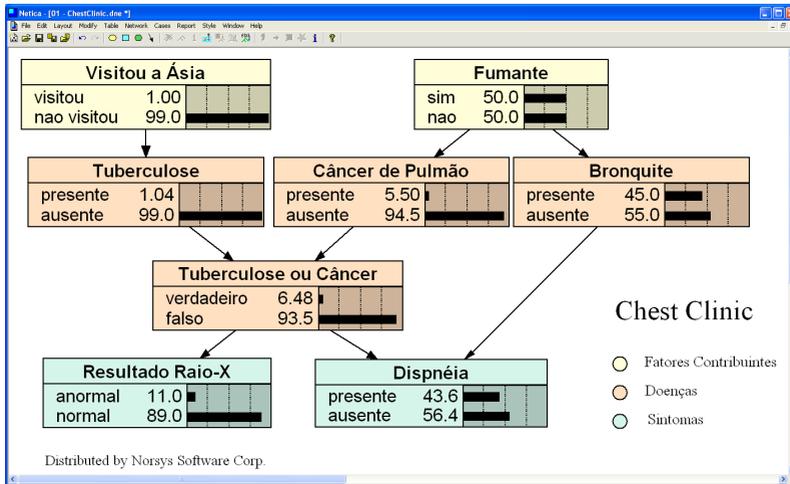


Figura 9 – Exemplo de uma Rede Bayesiana para diagnóstico médico.

do paciente ser fumante, mesmo antes de apresentar qualquer sintoma, pode alterar as chances de câncer. O raciocínio intercausal, a observação de “tuberculose ou câncer” e de câncer irá alterar as chances de tuberculose.

No exemplo apresentado, caso o médico tenha a informação (também chamada de evidência) de que o paciente é fumante, a Rede Bayesiana pode ser utilizada para calcular novas crenças das doenças e dos sintomas segundo essa nova informação disponível (KORB; NICHOLSON, 2010).

Segundo Luna (2004), a tarefa mais comum em Redes Bayesianas é a utilização para inferência probabilística, que consiste em obter conclusões à medida que novas evidências forem conhecidas. As Redes Bayesianas permitem analisar grandes quantidades de dados com o objetivo de extrair conhecimento útil para tomada de decisão, controle ou previsão do comportamento de um sistema, diagnóstico das causas de um fenômeno, entre outras aplicações (LUNA, 2004).

Dentre os motivos para a utilização de Redes Bayesianas, destacam-se: (1) possibilidade de expressar as assertivas de independência de forma visual e de fácil percepção, (2) representação e armazenamento de forma econômica, explorando a esparsidade do relacionamento entre as variáveis e (3) eficiente computacionalmente (LUNA, 2004).

Luna (2004) ainda cita que as Redes Bayesianas são utilizadas em vários domínios de aplicação, como saúde (diagnóstico, localização de genes), indústria (controle de robôs ou de autômatos), computação e redes (agen-

tes inteligentes), marketing (mineração de dados, gestão de relação com clientes), bancos e financeiras (análise financeira) e gestão (tomada de decisão e gestão de conhecimento e risco).

### 2.4.5 Uso de Redes Bayesianas

Outro passo da pesquisa foi a busca de trabalhos sobre a utilização das Redes Bayesianas no suporte de previsão de dados e como consequência no auxílio na tomada de decisão. A seguir serão mostrados alguns trabalhos que discutem essa utilização das Redes Bayesianas.

Issicaba et al. (2004) apresentaram um sistema especialista probabilístico, que dá suporte ao dimensionamento de equipes de manutenção de energia elétrica em condições climáticas adversas. A Rede Bayesiana é alimentada com variáveis que indicam as condições climáticas e, então, é possível estimar o número de atendimentos diários que a concessionária de energia precisará realizar. Com isso, pode-se então dimensionar a equipe que atenderá estes chamados.

L'Astorina (2009) utilizou Redes Bayesianas para prever a rentabilidade de empresas. Indicadores econômico-financeiros das empresas, disponíveis através do balanço destas empresas, fornecem informações que para uma Rede Bayesiana, que fornece uma previsão do retorno dessas empresas. Esse trabalho é relevante, pois mostra o uso das Redes Bayesianas auxiliando na previsão de uma variável.

Segundo Aktekin e Soyer (2011), os trabalhos pioneiros na modelagem do volume de chamadas de call center, segundo abordagem Bayesiana, foram Weinberg, Brown e Stroud (2007) e Soyer e Tarimcilar (2008).

O trabalho de Weinberg, Brown e Stroud (2007) apresentou um modelo de efeitos multiplicativos para a previsão de taxas de chegada de Poisson para curtos intervalos de tempo, geralmente 15, 30 ou 60 minutos de duração, com um tempo de espera de 1 dia em um call center de um banco americano. Para estimar os parâmetros do modelo, foi adotado um *framework* Bayesiano, propondo um conjunto de distribuições *a priori*, e usando um modelo de Cadeia de Markov Monte Carlo (algoritmo MCMC) para estimar os parâmetros da distribuição *a posteriori*. Porém, essa abordagem possui um custo computacional elevado se comparado a outros métodos. Além disso, nesse trabalho foi apresentada uma modificação do método apresentado para atualizar uma previsão intra-dia e, assim, possibilitar ajustes na alocação dos atendentes.

Soyer e Tarimcilar (2008) analisaram como o efeito da publicidade estimulava os clientes a realizar chamadas para um call center de uma empresa de eletrônicos. Os parâmetros de intensidade de chamada associados

com cada tipo de publicidade e intervalo de tempo futuro foram modelados por uma Rede Bayesiana. Sua Análise é baseada no processo de chegadas de Poisson medido em um período de dias com uma função de taxa de chegada cumulativa. Suas conclusões foram de que o modelo de efeitos aleatórios se ajusta melhor do que o modelo de efeitos fixos.

Já Aktekin e Soyer (2011) apresentaram três modelos de espaço de estados Bayesianos para a modelagem a chegada de chamadas em um call center. A inferência Bayesiana fornece a atualização e suavização das taxas de chegada de chamadas e foi aplicados em um banco americano.

## 2.5 COMENTÁRIOS FINAIS

Este capítulo apresentou a fundamentação teórica dos principais assuntos relacionadas a centrais de atendimento e previsão de chamadas, descrevendo também os conceitos do processo de previsão de dados, das séries temporais e do tratamento de incerteza.

Na área de call centers, a previsão de chamadas é importante para o planejamento de orçamento, previsão de recursos necessários e alocação de pessoal na operação de call center para, assim, manter-se o nível de serviço adequado para os clientes. Caso o número de chamadas previstas seja maior do que for recebido, o gasto da operação conseqüentemente será maior, pois um excesso de mão de obra seria contratado.

O conceito de previsão e alguns dos seus tipos foram apresentados. No caso de call centers, as previsões de longo prazo são importantes para o planejamento, as previsões de médio prazo são importantes operacionalmente e as previsões de curto prazo são importantes na escala de pessoal.

Algumas medidas de acurácia dos modelos de previsão também foram mostradas, bem como os conceitos de previsões em séries temporais, em especial os algoritmos de suavização exponencial, que são algoritmos que não necessitam de séries temporais muito longas para realizar a previsão.

O raciocínio bayesiano também foi abordado neste capítulo. Foi mostrado como as redes bayesianas podem ajudar na solução de problemas de aleatoriedade e suas aplicações em diversas áreas.

No caso dos call centers, as redes bayesianas podem tratar a aleatoriedade dos fatores que provocam alterações no número de chamadas recebidas em um call center e contribuir para diminuir o erro de previsão, feita através dos algoritmos de previsão em séries temporais. O uso de métodos bayesianos é um complemento aos métodos clássicos de previsão, uma vez que os fatores aleatórios não são tratados nesses métodos clássicos.

### 3 MODELO DE PREVISÃO

Para elaborar um modelo de previsão capaz de incorporar o conhecimento empírico, de modo a tratar os fatores aleatórios que geram alterações no volume de chamadas recebidas em um call center, foram seguidas as etapas mostradas na figura 10. As soluções desenvolvidas durante o processo também estão mostradas na figura 10.

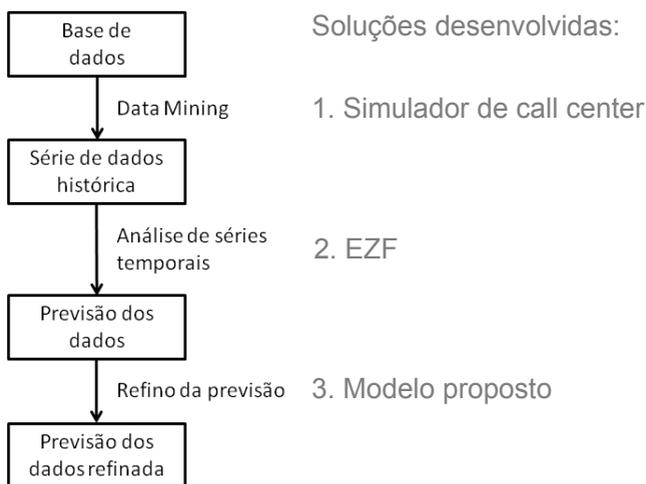


Figura 10 – Tratamento dos fatores aleatórios e as soluções desenvolvidas.

A primeira etapa do processo é a seleção dos dados em uma base dados. Essa etapa é caracterizada por uma exploração na base dados para extração dos dados pertinentes à previsão. Essa base de dados, que pode ser registros de operação (*log*) ou um banco de dados, irá gerar uma série temporal, que descreve o comportamento da variável ao longo do tempo. Para gerar dados que serão utilizados para a previsão, foi desenvolvido um simulador de call center.

Obtida a série temporal, o próximo passo é fazer a decomposição da série para descobrir quais algoritmos de previsão podem ser utilizados para os dados do problema. Nessa etapa, verifica-se a tendência e a sazonalidade, para então escolher o método de previsão mais adequado. Os métodos de suavização exponencial se mostram adequados ao uso na previsão de chamadas recebidas em call center, pois, na sua grande maioria, as séries de dados não são muito longas e possuem pouca homogeneidade. Para facilitar o es-

tudo das séries temporais, foi criada a ferramenta EZF que auxilia na escolha de um algoritmo de suavização exponencial da série temporal e também na previsão dos dados da série.

Por último, são feitas inferências na previsão, de acordo com o conhecimento empírico de especialistas que alteram os valores da previsão, para mais ou para menos, na tentativa de trazer os valores mais próximos à realidade dos dados, ou seja, prevendo um comportamento *a posteriori* baseado em conhecimento *a priori*. Para incorporar o conhecimento dos especialistas, foi proposto um modelo de previsão de call center.

### 3.1 SIMULADOR DE CALL CENTER

Dada a dificuldade em analisar séries históricas de dados de call center, pela falta de registros disponíveis, surgiu então a necessidade de se construir um simulador de dados sintéticos para gerar diversos tipos de cenários de operações e de analisar o desempenho dos métodos de previsão de dados. Para uma análise mais consistente, seria necessário obter dados históricos referentes às operações de call center de pelo menos três anos, o que, tecnicamente, é muito difícil de ser obtido, mas que pode ser facilmente gerado por um simulador de chamadas recebidas.

Para avaliar e testar o modelo de simulação sintética de dados do volume de chamadas, foi utilizado um arquivo histórico de dados que retrata a operação de serviços de atendimento a proprietários de cartões de crédito.

Esses dados referem-se a uma operação com duração de 44 meses. Além da clara influência dos fatores como tendência e sazonalidade, identificados na série histórica, a operação apresenta, também, algumas anomalias cujos motivos não foram, inicialmente, esclarecidos, mas que, claramente, contribuíram para o aumento do valor esperado. Após um estudo mais detalhado, foram determinados dois fatores que haviam provocado fortes influências no comportamento da variável. O primeiro fator foi uma campanha de marketing com duração de 12 meses, incentivando os clientes a adquirir cartões de crédito. O segundo fator identificado foi a presença de duas greves nos correios, que aconteceram durante essa operação, e que duraram aproximadamente 30 dias cada uma. Essa greve forçava os clientes a contatarem o banco a fim de buscar formas alternativas de receber a sua fatura do cartão de crédito. Com base nos logs dessa operação de cartão de crédito, foi possível entender o comportamento histórico das chamadas recebidas e também compreender a influência dos fatores nesta operação. Mais detalhes dessa série serão apresentados no estudo de caso do capítulo 4.1.

Baseado nas informações disponíveis e na análise dos dados da opera-

ção de cartão de crédito, um simulador Monte Carlo foi desenvolvido, como requisito para a avaliação dos modelos de previsão e análise de sensibilidade destes modelos. Por possuir apenas os dados mensais, a série de dados da operação de cartão de crédito foi utilizada apenas na avaliação do simulador, uma vez que também era preciso os dados diários para a realização da previsão diária. O desenvolvimento do simulador permitiu a geração de séries de dados com a granularidade desejada (no caso deste trabalho diária) e com a influência de fatores aleatórios em diferentes períodos e intensidades.

O simulador é constituído de três elementos: um gerador de chamadas que simula as ligações recebidas pelo call center; um gerador de eventos aleatórios, responsável por alterar o comportamento da variável número de chamadas geradas, de acordo com o tipo de evento e de sua intensidade; e por um registrador de chamadas, responsável por gerar as estatísticas das chamadas recebidas e por listar os fatores e seu respectivo impacto. A figura 11 mostra, de maneira simplificada, os componentes do gerador de chamadas.

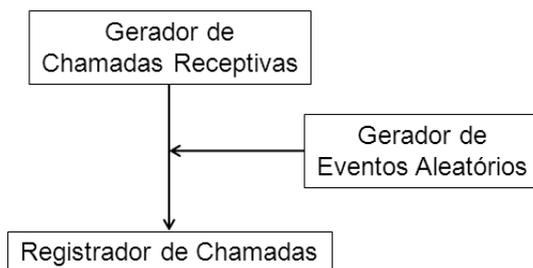


Figura 11 – Diagrama de blocos do simulador de chamadas.

No simulador é possível gerar diferentes tipos de chamadas recebidas bem como é possível gerar diversos tipos de eventos aleatórios com formas diferenciadas de impactos sobre o número de chamadas recebidas. Para cada evento, podem ser atribuídos diferentes impactos na geração de chamadas recebidas, aumentando ou reduzindo seu valor, com diferentes graus de intensidade.

O registrador de chamadas, responsável pelas estatísticas, fornece ao analista uma visão do cenário do volume de chamadas recebidas com as respectivas influências de cada evento, para que este possa entender o real impacto no valor esperado e o erro causado no valor previsto. De posse do entendimento da relação dos eventos nas chamadas recebidas, é possível calibrar os modelos clássicos de previsão.

A principal métrica para a avaliação do modelo de previsão utilizada é o erro percentual absoluto médio (EPAM) entre o valor previsto e o va-

lor ocorrido. Para tal verificação, devem ser geradas chamadas conforme a sequência abaixo:

1. Os dados da série histórica devem ser gerados começando em um tempo  $t_0$  e seguindo até um tempo  $t_n$ . Esses dados, que representam as chamadas ocorridas no passado, devem ser utilizados para o treinamento do modelo de previsão.
2. Os dados futuros precisam também ser gerados para um período  $t_{n+f}$  e devem ser utilizados posteriormente para controle do modelo de previsão.
3. Com o modelo de previsão já treinado com os dados históricos gerados pelo simulador, deve-se gerar dados para o período futuro  $t_{n+f}$  através do algoritmo do modelo de previsão.
4. A verificação do modelo é feito com o cálculo do EPAM dos valores futuros gerados pelo simulador e os dados previstos gerados pelo algoritmo de previsão.

O período dos dados de treinamento e de controle está detalhado na figura 12.

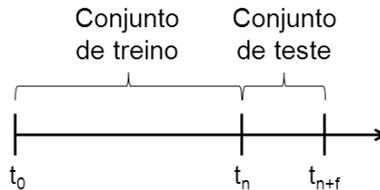


Figura 12 – Conjuntos de chamadas geradas pelo simulador.

### 3.2 FERRAMENTA EZF

No processo de pesquisa de métodos de previsão em séries temporais foi feita a busca por ferramentas para apoiar os estudos sobre este tema. Algumas dessas ferramentas, que fazem previsão de séries temporais pelo método de suavização exponencial, estão listadas na tabela 4.

Uma alternativa gratuita é o suplemento para Microsoft Excel<sup>®</sup>, chamado Phicast<sup>1</sup>, que foi desenvolvido pela Monash University. Esse suple-

<sup>1</sup>Disponível em: <http://www.buseco.monash.edu.au/units/forecasting/software/phicast>

Tabela 4 – Ferramentas de suavização exponencial.

Ferramenta	Empresa	Licença
Autobox <sup>®</sup>	Automatic Forecasting Systems	comercial
Forecast Pro <sup>®</sup>	Business Forecast Systems Inc.	comercial
Minitab <sup>®</sup>	Minitab Inc.	comercial
SAS/ETS <sup>®</sup>	SAS Institute Inc.	comercial
StatGraphics <sup>®</sup>	StatPoint Technologies Inc.	comercial
Statistica	Statsoft <sup>®</sup>	comercial
SPSS	IBM <sup>®</sup>	comercial

mento é bastante intuitivo, porém não é compatível com as versões mais novas do Excel<sup>®</sup> (a partir da versão 2007) e possui limitação de 300 dados de entrada.

Para melhor entendimento do processo de previsão em séries temporais, foi criada uma ferramenta chamada EZF (do inglês *Easy Forecast*). Essa ferramenta, escrita na linguagem VBA, foi desenvolvida como um suplemento para o Microsoft Excel<sup>®</sup>, que visa a suprir a pouca oferta de ferramentas gratuitas de apoio à tomada de decisão sobre qual método de previsão utilizar em uma séries temporal.

Na ferramenta EZF, é possível escolher entre quatro métodos de suavização exponencial para previsão: suavização exponencial simples, método de Holt, método de Holt-Winters aditivo e método de Holt-Winters multiplicativo. Nos métodos de Holt-Winters, é possível escolher o período da sazonalidade dos dados. A figura 13 mostra a tela de escolha dos métodos de suavização disponíveis no EZF.

Outra característica importante da ferramenta EZF é a possibilidade de otimização dos parâmetros dos métodos de suavização. Assim, o usuário pode entrar com os valores dos parâmetros  $\alpha$ ,  $\beta$  e  $\gamma$  (caso necessário para o método escolhido) na ferramenta. Alternativamente, pode-se escolher a minimização do EPAM pela otimização dos parâmetros, processo esse que é realizado através do Microsoft Solver<sup>®</sup>, um suplemento de otimização presente no pacote Microsoft Office<sup>®</sup>.

### 3.3 MODELO PROPOSTO DE PREVISÃO EM CALL CENTER

Um fator aleatório pode influenciar na quantidade de chamadas recebidas esperada por um call center. Para tratar os fatores aleatórios na pre-

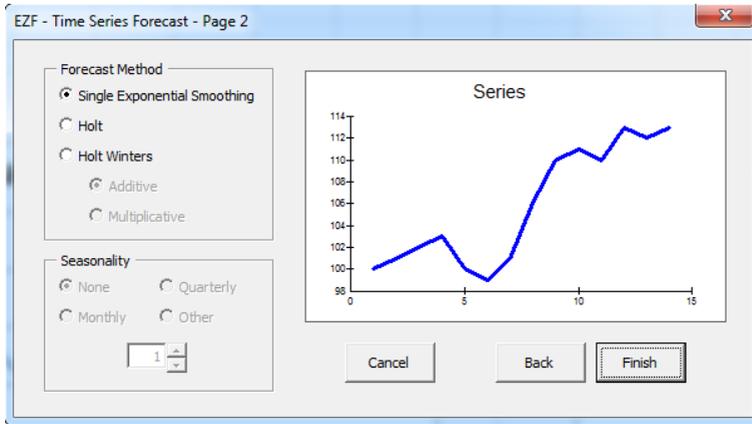


Figura 13 – Ferramenta EZF.

visão de chamadas em um call center, um método de normalização da série histórica de chamadas recebidas pode ser aplicado para remover o efeito dos fatores aleatórios que perturbam estes dados.

O processo de eliminar o efeito causado pelos fatores aleatórios oferece ao algoritmo de previsão os dados em sua forma típica, sem as perturbações que causam alterações no comportamento esperado dos dados. Essas alterações causadas pelos fatores podem não se repetirem no futuro. Em uma previsão feita com os dados brutos (dados com a influência dos fatores aleatórios), assume-se que esses fatores aleatórios se repetirão no futuro com a mesma periodicidade e intensidade do passado.

O modelo de normalização proposto visa fazer a previsão das chamadas utilizando os algoritmos de previsão de séries temporais em conjunto com os dados na forma normalizada. Esse processo de previsão irá gerar dados previstos na forma normalizada, tanto para os períodos  $t$  quanto para os períodos  $m$  a frente. A figura 14 mostra a sequência de previsão de dados segundo o modelo proposto de normalização.

O dado previsto para o tempo  $t$  é, então, desnormalizado, ou seja, a perturbação causada pelos fatores aleatórios é recolocada no dado. A otimização dos parâmetros do algoritmo de previsão deve ser feita através da minimização dos erros entre o dado bruto no tempo  $t$  e o dado previsto desnormalizado no tempo  $t$ . Para os dados previstos  $m$  períodos a frente, a ocorrência dos fatores aleatórios ainda não é conhecida. Para calcular o possível impacto causado pelos fatores aleatórios no tempo  $t + m$ , utiliza-se a rede bayesiana para calcular a probabilidade de ocorrência dos fatores

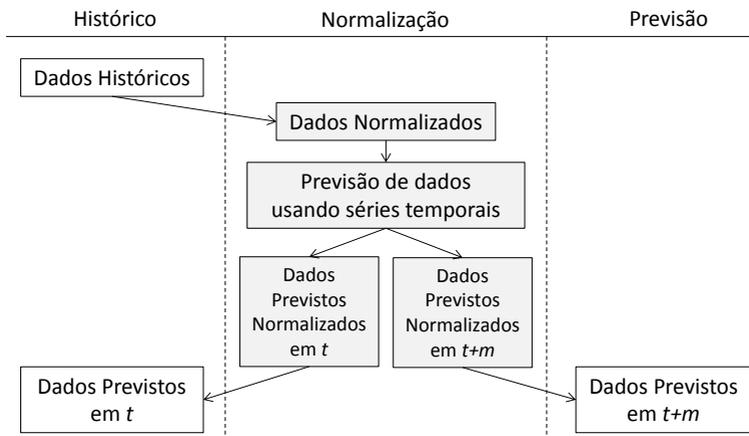


Figura 14 – Modelo proposto de previsão.

aleatórios e estimar a perturbação que os fatores causarão no dado previsto.

As probabilidades da rede bayesiana são resultantes do treinamento dos dados históricos. O treinamento consiste em, a partir de uma amostra de dados, induzir as distribuições de probabilidades simples e condicionais e/ou identificar as relações de interdependência entre as variáveis de um domínio de dados (LUNA, 2004).

Conhecendo a ocorrência e a perturbação dos fatores aleatórios nos dados históricos, pode-se, então, calcular o ajuste que deve ser feito no dado previsto normalizado, conforme a probabilidade de ocorrência dos fatores no período previsto e a perturbação causada pelos fatores nos dados históricos.

A figura 15 apresenta um diagrama do modelo de normalização dos fatores aleatórios na previsão, em que:

- $Y_t$  é o dado bruto no tempo  $t$
- $\hat{Y}_t$  é o dado normalizado no tempo  $t$
- $\hat{F}_t$  é o dado previsto normalizado no tempo  $t$
- $\hat{F}_{t+m}$  é o dado previsto normalizado no tempo  $t + m$
- $F_t$  é o dado previsto no tempo  $t$
- $F_{t+m}$  é o dado previsto no tempo  $t + m$
- $N_t$  é a normalização no tempo  $t$
- $N_t^{-1}$  é a inversa da normalização no tempo  $t$
- $N_p^{-1}$  é a inversa da normalização do dado previsto no tempo  $t + m$  ajustado pelo peso resultante da rede bayesiana instanciada para o caso do tempo  $t + m$

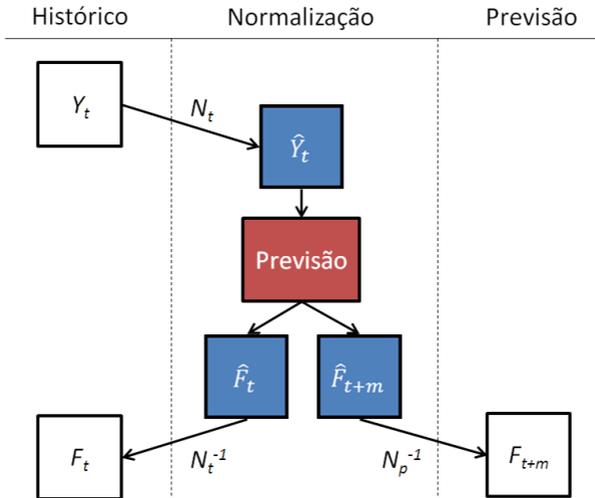


Figura 15 – Diagrama do processo de normalização.

No modelo de normalização, os fatores são identificados e sua influência é retirada. Com o dado normalizado, a previsão é feita e, então, são obtidos os dados previstos na forma normalizada. Os dados históricos previstos devem ser ajustados de acordo com a ocorrência dos fatores durante aquele tempo, que é feita pela normalização inversa. Já os dados futuros previstos devem ser ajustados de acordo com a probabilidade de ocorrência dos fatores dada pelo resultado da rede bayesiana, processo denominado de normalização pela bayesiana. As etapas do modelo de normalização são descritas nas seções a seguir.

### 3.3.1 Identificação dos fatores

A primeira etapa da normalização dos dados é a identificação dos fatores que alteram os valores na série de dados. Entende-se por fatores os acontecimentos que impactam no desvio do comportamento esperado nos dados, tanto no aumento quanto na diminuição do valor esperado. Para a identificação dos fatores, um especialista deve elicitar as causas da variação nos dados e registrar os períodos em que esses fatores afetam os dados.

Em centrais de atendimento, um exemplo de fator são as campanhas publicitárias que geralmente provocam a atenção de novos consumidores, es-

estimulando-os a entrarem em contato com o call center da empresa para adquirir produtos ou serviços, impactando assim no aumento do volume de chamadas recebidas.

Feita a identificação dos fatores, deve-se então calcular o peso de cada um deles nos dados da série. Uma maneira de se fazer isso é através de regressão múltipla. Marcando os fatores com zero ou um de acordo com a ocorrência (zero para a não ocorrência e um para a ocorrência), pode-se aplicar a regressão e com os coeficientes dos fatores para calcular o seu respectivo peso através da fórmula:

$$W_i = \frac{\sum_{t=1}^n I_{it}}{\sum_{t=1}^n f_{it}} - 1 \quad (3.1)$$

Sendo que:

$$I_{it} = f_{it} \frac{Y_t}{(Y_t - c_i f_{it})} \quad (3.2)$$

$$f_{it} = \begin{cases} 1 & \text{fator } i \text{ presente em } t \\ 0 & \text{fator } i \text{ ausente em } t \end{cases} \quad (3.3)$$

onde  $W_i$  é o peso do fator  $i$ ,  $n$  é o número de dados da série,  $I_{it}$  é o impacto do fator  $i$  no tempo  $t$ ,  $f_{it}$  é o valor de presença do fator  $i$  no tempo  $t$ ,  $Y_t$  é o dado no tempo  $t$  e  $c_i$  é o coeficiente do fator  $i$  resultante da regressão múltipla.

Para melhor ajustar o modelo de regressão, é necessário verificar os fatores que podem ser adicionados ou removidos a fim de melhorar o ajuste do modelo aos dados e consequentemente aumentar o coeficiente R-quadrado da regressão.

### 3.3.2 Normalização dos dados

Identificados os fatores e seus respectivos pesos, os dados devem ser normalizados, isso é, a influência dos fatores nos dados deve ser removida. O dado normalizado é obtido através da seguinte fórmula:

$$\hat{Y}_t = \frac{Y_t}{1 + \sum_{i=1}^n (W_i f_{it})} \quad (3.4)$$

onde  $\hat{Y}_t$  é o dado normalizado no tempo  $t$ ,  $Y_t$  é o dado bruto no período

$t$ ,  $W_i$  é o peso do fator  $i$  e  $f_{it}$  é o valor de presença do fator  $i$  no tempo  $t$ .

O denominador da equação 3.4 pode ser chamado de coeficiente de ajuste de normalização.

O dado normalizado é importante, pois não apresenta as perturbações causadas pelos fatores aleatórios que atrapalham no processo de previsão da série temporal. Em um modelo de previsão no qual os dados estão influenciados por fatores aleatórios, assume-se que esse é o comportamento esperado para os dados.

### 3.3.3 Previsão da série

O próximo passo é aplicar o algoritmo de previsão. Para isso são utilizados os dados normalizados e aplicado o algoritmo adequado à tendência e sazonalidade da série. As previsões geradas pelos algoritmos de previsão sem dados normalizados assumiriam que os fatores aleatórios iriam se repetir na mesma frequência e intensidade do ocorrido no passado, o que pode levar o algoritmo a gerar dados previstos para o futuro descolados da realidade.

O algoritmo de Holt-Winters (tanto aditivo quanto multiplicativo) pode ser aplicado em centrais de atendimento, pois os resultados obtidos são bastante satisfatórios, uma vez que trata a sazonalidade e não é necessário que se tenha uma série de dados muito longa. Existe também a possibilidade do uso de outros algoritmos como o de suavização exponencial simples (SES) e o linear de Holt dependendo dos componentes de tendência e sazonalidade da série.

### 3.3.4 Inversa da normalização do dado previsto

Para colocar os efeitos nos dados previstos, tornando-os mais próximos da realidade, é feita a inversa da normalização dos dados, que é a recolocação dos pesos dos fatores aleatórios correspondentes aos dados do período previsto, ou simplesmente multiplicando-se pelo coeficiente de ajuste da normalização. A inversa da normalização do dado previsto pode ser representada por:

$$F_t = \hat{F}_t \left( 1 + \sum_{i=1}^n (W_i f_{it}) \right) \quad (3.5)$$

onde  $F_t$  é o dado previsto desnormalizado no tempo  $t$ ,  $\hat{F}_t$  é o dado previsto normalizado no tempo  $t$ ,  $W_i$  é o peso do fator  $i$  e  $f_{it}$  é o valor de presença do fator  $i$  no tempo  $t$ .

A desnormalização dos dados previstos é importante para recolocar as perturbações geradas pelos fatores e verificar o erro do dado previsto em relação ao dado real.

### 3.3.5 Otimização dos parâmetros do algoritmo de previsão

Para verificar a acurácia da previsão, calcula-se o EPA (erro percentual absoluto) utilizando o dado bruto (não normalizado) e o dado previsto desnormalizado. Com isso, é possível calcular o EPAM (erro percentual absoluto médio) do modelo e verificar a significância do modelo.

Para minimização do EPAM, os parâmetros do algoritmo devem ser otimizados, de maneira a gerar dados futuros previstos oriundos de um modelo mais representativo dos dados históricos.

### 3.3.6 Previsão dos dados futuros

O passo final é a inversa da normalização dos dados futuros previstos de acordo com a expectativa dos fatores acontecerem. Esse passo é feito através do cálculo do peso do fator e a probabilidade da ocorrência do fator aplicado em uma rede bayesiana. A inversa da normalização do dado futuro é representado por:

$$F_{t+m} = \hat{F}_{t+m} B_{t+m} \quad (3.6)$$

onde  $\hat{F}_{t+m}$  é o dado previsto normalizado para o próximo período  $m$ ,  $B_{t+m}$  é o ajuste calculado pela rede bayesiana para o período  $t + m$  e  $F_{t+m}$  é o dado previsto desnormalizado pela probabilidade de ocorrência dos fatores dada pela rede bayesiana.

### 3.3.7 Rede bayesiana na previsão de dados

No processo de desnormalização dos dados futuros previstos, é utilizada uma rede bayesiana para calcular os impactos dos fatores de acordo com as suas probabilidades de ocorrência. Com os impactos dos fatores avaliados pela rede bayesiana, o valor de ajuste das chamadas previstas é calculado para cada caso instanciado. Abaixo estão enumerados os passos para a criação de uma rede bayesiana de normalização e obtenção do peso de ajuste, calculado conforme a probabilidade dos fatores aleatórios acontecerem.

1. Organização dos dados históricos, identificação dos fatores aleatórios e dos seus respectivos pesos nas chamadas recebidas e organização das informações levantadas em casos de treinamento de redes bayesianas.
2. Identificação das dependências entre as variáveis para criação da topologia da rede bayesiana. Alguns softwares podem ajudar na tarefa de descoberta da topologia da rede, como é o caso do software Hugin<sup>1</sup> da Hugin Expert A/S.
3. Escolha de um algoritmo de aprendizado das probabilidades condicionais da rede bayesiana. Em Redes Bayesianas, a aprendizagem consiste em determinar a estrutura ou seus parâmetros a partir de dados de treinamento (LUNA, 2004). Os algoritmos de *expectation-maximization* (*EM learning*) e de gradiente descendente são dois exemplos de algoritmos utilizados na aprendizagem.
4. Instanciação de casos para os dados futuros previstos e coleta dos valores de ajuste para as chamadas previstas, isso é, os valores que representam o impacto dos fatores nas chamadas.

### 3.4 COMENTÁRIOS FINAIS

Neste capítulo foram apresentadas algumas soluções para o problema de previsão de chamadas recebidas em call centers. Para cada etapa do desenvolvimento da proposta, foram criadas ferramentas e modelos que auxiliam nas diferentes etapas do processo de previsão de chamadas recebidas.

Primeiramente, foi mostrado um simulador de call center, que gera sinteticamente chamadas recebidas em um call center de forma a simular um ambiente real. No simulador podem ser colocados geradores de eventos aleatórios, que simulam o efeito dos fatores aleatórios que alteram a quantidade de chamadas recebidas esperadas. Essa ferramenta é importante para a geração de dados que serão utilizados para os testes do modelo de previsão de chamadas proposto.

Outra ferramenta apresentada foi o EZF, que gera a previsão de séries temporais utilizando os principais algoritmos de suavização exponencial, como a suavização exponencial simples, o algoritmo de Holt e o algoritmo de Holt-Winters. A ferramenta foi criada como suplemento para o Microsoft Excel e serve não só para aplicações de call center, mas para qualquer aplicação que necessite de previsão de séries temporais.

---

<sup>1</sup>Disponível em: <http://www.hugin.com>

Por último, foi apresentada uma proposta de modelo de previsão de chamadas recebidas que trata os fatores aleatórios utilizando um modelo de normalização dos dados. Esse modelo de normalização tem como base a remoção do efeito dos fatores aleatórios na série de chamadas recebidas durante o processo de previsão dos dados. Com os dados previstos, os fatores são recolocados para obter os valores com os respectivos efeitos.

Para tratar a aleatoriedade dos fatores, é criada e treinada uma rede bayesiana dos dados históricos contendo principalmente as ocorrências dos fatores aleatórios, as variáveis de tempo e os impactos (ajustes) dos fatores na série de chamadas recebidas. Com isso, é possível instanciar casos que indicarão a probabilidade de ocorrência dos fatores para o período de tempo futuro  $t + m$  desejado e o respectivo ajuste que deve ser aplicado.



## 4 ANÁLISE DE RESULTADOS DO MODELO

Este capítulo apresenta os resultados obtidos nessa pesquisa. Primeiramente, são apresentados alguns experimentos feitos com o simulador de call center, criado para gerar os dados de chamadas. Em seguida, são experimentos com previsão mensal e diária de chamadas, utilizando o modelo proposto de previsão com normalização. Todos os experimentos têm como objetivo replicar, aproximando-se ao máximo da realidade, o comportamento de um call center receptivo.

### 4.1 EXPERIMENTAÇÃO DO SIMULADOR

Tomou-se a série de dados da operação de cartão de crédito, citada no capítulo 3.1, como um estudo de caso. Além do comportamento da variável, propriamente dita, examinaram-se, também, as informações a respeito da ocorrência de fatores desconhecidos, verificando-se o impacto destas ocorrências sobre o volume de chamadas recebidas. Nesse estudo de caso, dois fatores (eventos) alteraram sobremaneira o volume de chamadas durante o período de observação, causando o aumento do valor esperado das chamadas recebidas: (1) campanha de marketing e, (2) greves da empresa de correios. A figura 16 apresenta essa série de dados destacando-se os picos de demanda causados pelos dois eventos.

O objetivo desta análise é verificar os componentes que necessitam ser calibrados no simulador de chamadas. Após investigação e descarte dos parâmetros menos importantes, foram analisados os componentes de tendência, sazonalidade e de eventos aleatórios.

Construiu-se, então, um simulador de chamadas recebidas que trata os componentes identificados. O gerador de chamadas tem como parâmetros as funções de variáveis aleatórias de tendência e de sazonalidade das chamadas recebidas. O gerador de eventos aleatórios tem como parâmetro as funções de variáveis aleatórias de frequência de ocorrência e de impacto.

Na primeira simulação, foram geradas chamadas considerando os dois eventos que influenciaram na operação. A simulação seguiu os seguintes parâmetros:

1. O fator A tem ocorrência nos meses 09, 10, 34 e 35, e possui sua função aleatória de influência de:  $UNIF(1,15;1,19)$ ;
2. O fator B tem ocorrência entre os meses 27 e 36, e a função aleatória de influência é:  $UNIF(1,22;1,33)$ .

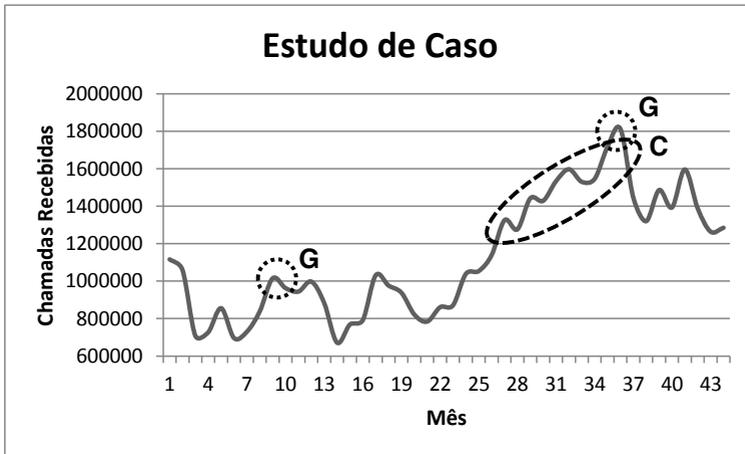


Figura 16 – Série histórica mensal de chamadas do estudo de caso. C é o períodos de ocorrência de campanha de marketing e G são os períodos de ocorrência de greve.

Os parâmetros da simulação indicam que o fator A causará um aumento entre 15% e 19% das chamadas recebidas em quatro meses da simulação. Já o fator B provocará um aumento variando de 22% a 33% em 10 meses da simulação.

Para validação do caso, foram geradas amostras com 5000 replicações. A figura 17 mostra o resultado da média dessas replicações na primeira simulação, com a influência dos dois fatores. Para melhor visualização, apenas as médias mensais das replicações foram apresentadas. O intervalo médio de confiança não foi apresentado na figura 17, pois o seu valor médio representa 0,1% do valor da média, o que é estatisticamente desprezível.

Além de incluir eventos aleatórios que provoquem alteração no número de chamadas esperadas, pode-se também enfatizar esses fatores. Esse aumento tem como objetivo analisar seu impacto no volume de chamadas recebidas e, por consequência, no próprio algoritmo de previsão.

Outro teste realizado foi para comparar os diferentes impactos dos fatores nas chamadas recebidas. Para esse teste, utilizou-se a primeira simulação como base, e os seguintes parâmetros da função aleatória para os fatores:

1. Fator A: UNIF(1,33;1,41);
2. Fator B: UNIF(1,48;1,73).

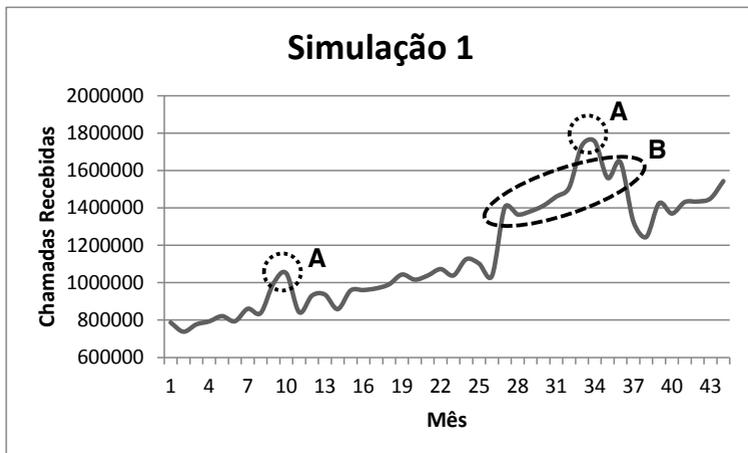


Figura 17 – Série histórica mensal simulada de chamadas recebidas. A indica o fator A e B indica fator B.

Os parâmetros de impacto dos fatores aleatórios foram aumentados em 220% para destacar o seu comportamento nas chamadas esperadas. Os resultados da média mensal de 5000 replicações deste comparativo estão apresentados na figura 18.

#### 4.2 AVALIAÇÃO DO MODELO PROPOSTO

Para avaliar o modelo de previsão proposto, foi criado um caso de teste que gera dados históricos e dados futuros. Os dados históricos representam o passado da central de atendimento, ou seja, representam as chamadas recebidas, que serão utilizadas como dados de treinamento para a previsão. Os dados futuros são aqueles gerados apenas para fins comparativos da previsão feita com os dados históricos.

Baseado na operação de call center apresentada no capítulo 3.1, criou-se então um caso de teste semelhante. Por opção, não foram utilizados os mesmos dados da operação de cartão de crédito, pois não haviam os dados diários disponíveis, o que inviabilizaria a avaliação da previsão diária que seria realizada posteriormente. Outro ponto para a não utilização desses dados é a falta de flexibilidade da avaliação da previsão mensal do modelo, uma vez que não seria possível alterar o peso de influência dos fatores aleatórios.

Com o simulador de dados, foram gerados históricos utilizando a abor-

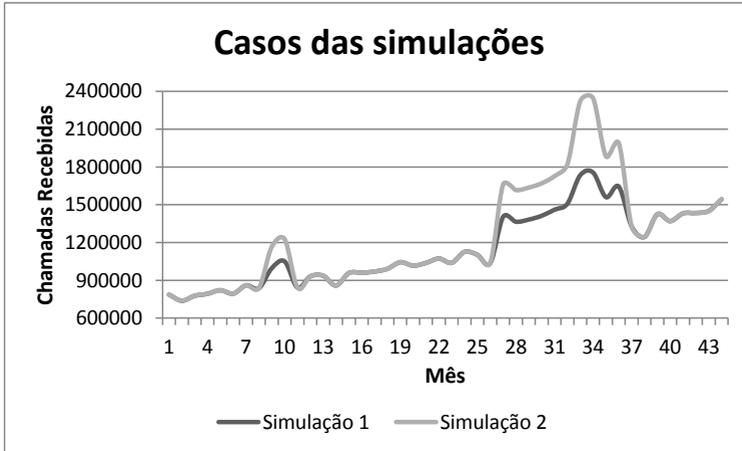


Figura 18 – Comparativo de séries históricas mensais simuladas.

dagem *bottom-up*, na qual os dados diários são gerados e os dados mensais e anuais são resultantes do acúmulo dos dados diários. Para a previsão do volume de chamadas recebidas, foi feita utilizando a abordagem *top-down*, na qual, primeiramente, são geradas as previsões mensais e, a partir delas, são geradas as previsões diárias.

Para avaliar o modelo em relação ao comportamento em função dos fatores aleatórios, subdividiu-se, então, o caso de teste em dois, realizando-se uma avaliação do modelo com os mesmos dados, porém com diferentes pesos dos fatores aleatórios.

#### 4.2.1 Dados históricos

Para os casos de testes, optou-se por gerar uma série histórica de chamadas de 3 anos consecutivos, período escolhido por apresentar 3 ciclos de 12 meses para a sazonalidade mensal e por fornecer informação sazonal mínima ao algoritmo de suavização exponencial para previsão mensal.

As chamadas foram geradas pelo simulador de acordo com as informações reais do período de 2009 a 2011, levando-se em conta os dias da semana, os anos bissextos, os feriados brasileiros e os dias após os feriados em dias úteis (pós-feriados).

Alguns feriados possuem um dia fixo no ano, tais como o Dia do Tra-

balho, o Dia da Independência e o Natal. Outros feriados possuem uma data variável no ano, tais como o Carnaval e a Páscoa. O próximo dia útil após um feriado que ocorra em um dia útil, o chamado pós-feriado, é caracterizado por apresentar um aumento no volume de chamadas, causado pelo acúmulo de demanda de chamadas relativas ao feriado.

Para simular os fatores aleatórios nos casos de testes, foram inseridos dois módulos de eventos aleatórios que geram dois fatores que alteram o número de chamadas recebidas, semelhantes aos do capítulo 3.1: (1) campanha publicitária e (2) greve nos correios. A tabela 5 apresenta mais detalhes da aplicação dos fatores nas chamadas e seu respectivo impacto no seu volume recebido para dois casos de testes.

Tabela 5 – Fatores aplicados nos casos de testes.

Caso	Fator	Ocorrência	Impacto
Caso 1	Campanha	maio a dezembro de 2010	45% aumento
	Greve	setembro a novembro de 2009	30% aumento
		setembro a novembro de 2010	30% aumento
Caso 2	Campanha	maio a dezembro de 2010	15% aumento
	Greve	setembro a novembro de 2009	10% aumento
		setembro a novembro de 2010	10% aumento

As diferenças entre os dados históricos mensais gerados pelo simulador para os casos de testes, conforme os fatores apresentados na tabela 5, estão mostrados na figura 19.

Para mostrar melhor o impacto dos feriados nas chamadas diárias recebidas, a figura 20 apresenta as chamadas diárias geradas para o mês de fevereiro de 2009, em que aconteceu o feriado de carnaval no dia 24 e, no dia 25, aconteceu o pós-feriado de carnaval. Para os dois casos de testes o número de chamadas será o mesmo pois não houve a ocorrência de nenhum fator durante esse mês. Observa-se que, durante o feriado de carnaval, aconteceu uma diminuição nas chamadas recebidas, o que acabou por gerar maior volume no dia útil seguinte, em uma semana em que seriam esperadas cerca 9 mil chamadas diárias. Também é possível observar a flutuação semanal, com diferenças entre as diferentes semanas do mês e com queda no número de chamadas durante os finais de semana.

As demandas de chamadas mensais, geradas pelo simulador para os casos de testes 1 e 2, com os dados históricos (utilizados para o treinamento) e os dados futuros (utilizados nos testes), estão apresentadas nas figuras 21 e 22 respectivamente. É possível notar que nos meses de ocorrência dos fatores, houve um aumento no número de chamadas recebidas. No caso de teste 1, o

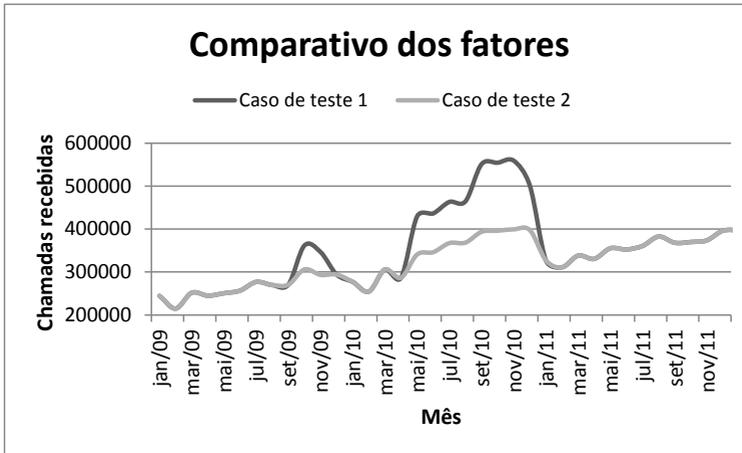


Figura 19 – Dados mensais dos casos de testes.

aumento causado pelos fatores pode ser melhor percebido por ter um impacto maior nas chamadas do que no caso de teste 2.

Para os casos de testes, foram gerados os dados de 12 meses do ano de 2012 para serem utilizados como dados de testes, pois prever dados para períodos mais longos aumentaria muito o intervalo de confiança da previsão. A tabela 6 apresenta os fatores aleatórios aplicados nos dados de testes.

Tabela 6 – Fatores aplicados nos dados de testes.

Caso	Fator	Ocorrência	Impacto
Caso 1	Campanha	julho e agosto de 2012	45% aumento
	Greve	agosto e setembro de 2012	30% aumento
Caso 2	Campanha	julho e agosto de 2012	15% aumento
	Greve	agosto e setembro de 2012	10% aumento

Com os dados históricos coletados, o primeiro passo para a previsão é a normalização dos dados. Com os fatores identificados, são calculados os pesos de cada um deles, para então eliminar as suas influências dos dados históricos. As figuras 23 e 24 mostram a identificação dos fatores nos casos de testes 1 e 2 as suas respectivas normalização dos dados.

Os pesos dos fatores de campanha e greve encontrados pelo processo de normalização estão apresentados na tabela 7. É possível perceber que o

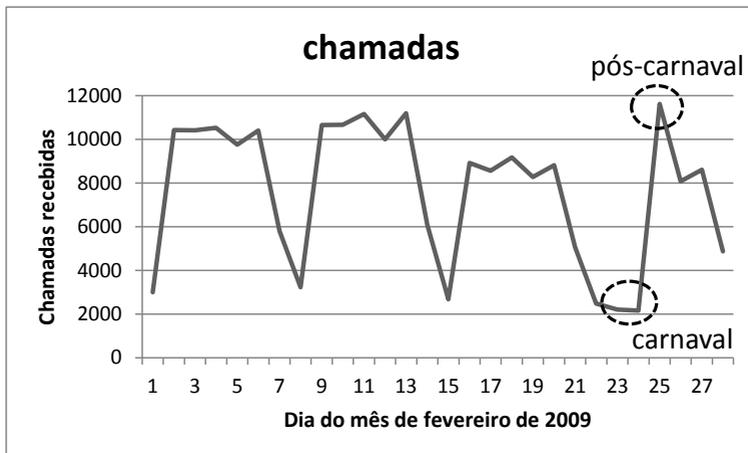


Figura 20 – Dados diários de fevereiro de 2009 dos casos de testes. Em destaque o feriado de carnaval e o seu respectivo pós-feriado.

peso do fator campanha encontrado ficou mais próximo do valor real do que do fator greve.

Tabela 7 – Pesos dos fatores encontrados pela normalização.

Caso	Peso campanha	Peso greve
Caso 1	42,87%	19,71%
Caso 2	15,25%	4,43%

#### 4.2.2 Previsão mensal

Seguindo a abordagem *top-down*, os dados mensais futuros são gerados primeiramente pelo algoritmo de previsão de suavização exponencial para posteriormente serem comparados com os dados de testes mensais gerados pelo simulador. Com os dados normalizados, são escolhidos os algoritmos de acordo com os componentes da série temporal.

Utilizando a ferramenta EZF, os dados futuros são calculados assim como os EPAM dos modelos de previsão. Como existe sazonalidade nos meses do ano, isto é, sazonalidade de 12 meses, optou-se por utilizar o algoritmo

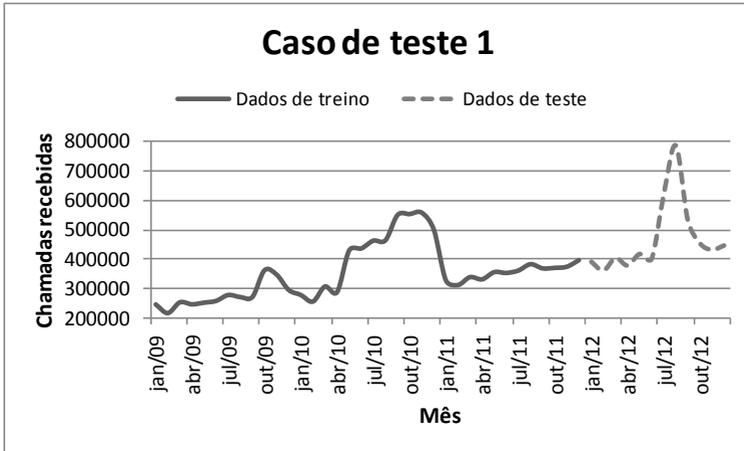


Figura 21 – Dados gerados pelo simulador para o caso de teste 1.

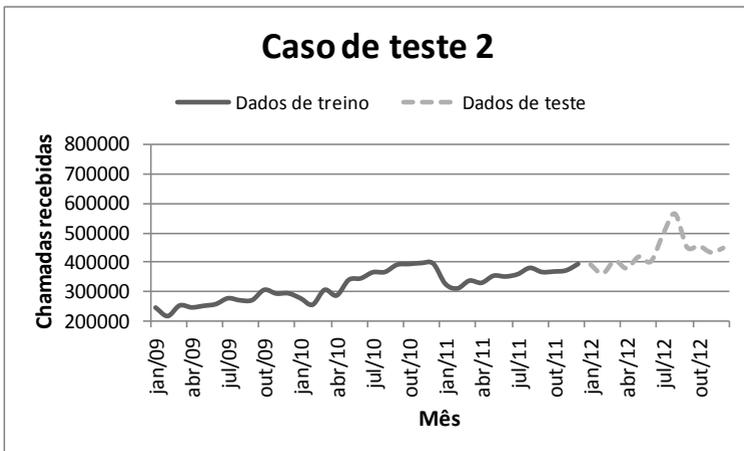


Figura 22 – Dados gerados pelo simulador para o caso de teste 2.

de Holt-Winters. Os algoritmos de suavização exponencial simples e de Holt foram testados, mas como eles não tratam a flutuação mensal e o EPAM gerado por eles foi maior que o do Holt-Wintes, o seu uso foi descartado.

As tabelas 8 e 9 apresentam os valores de erro percentual absoluto médio (EPAM) dos dados históricos em relação aos dados previstos pelos

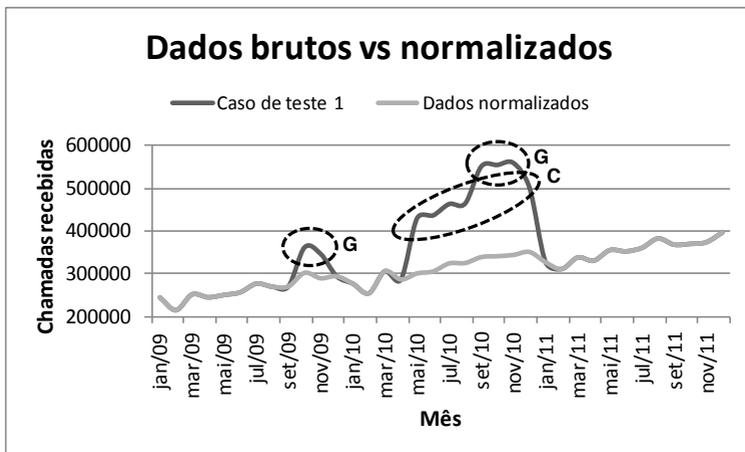


Figura 23 – Dados mensais do caso de teste 1. C e G destacam o período de atuação dos fatores campanha e greve respectivamente.

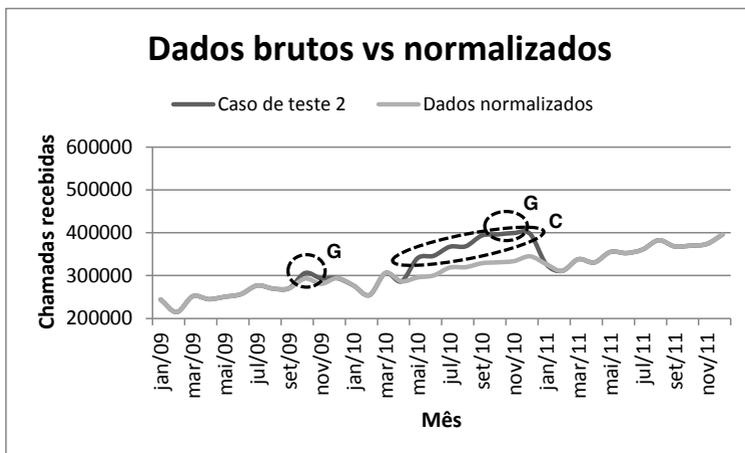


Figura 24 – Dados mensais do caso de teste 2. C e G destacam o período de atuação dos fatores campanha e greve respectivamente.

algoritmos de previsão de Holt-Winters para os casos 1 e 2 respectivamente. Foram testados os modelos com e sem o processo de normalização. Nos dois casos de testes, os modelos que utilizaram o processo de normalização

obtiveram menor erro, pois conseguiram tratar os fatores aleatórios. O caso de teste 1 obteve uma maior diferença do erro no uso da normalização por causa do tratamento dos fatores que causaram uma maior influência do que no caso de teste 2.

Tabela 8 – EPAM dos modelos de previsão do caso de teste 1.

Normalização	Método	EPAM
Não	Holt-Winters aditivo	8,28%
	Holt-Winters multiplicativo	9,09%
Sim	Holt-Winters aditivo	3,42%
	Holt-Winters multiplicativo	4,12%

Tabela 9 – EPAM dos modelos de previsão do caso de teste 2.

Normalização	Método	EPAM
Não	Holt-Winters aditivo	4,05%
	Holt-Winters multiplicativo	4,53%
Sim	Holt-Winters aditivo	3,32%
	Holt-Winters multiplicativo	4,01%

No caso dos dados futuros, uma rede bayesiana foi criada para calcular o ajuste dos valores da previsão segundo a probabilidade de ocorrência dos fatores e seus respectivos pesos. Para criar a rede bayesiana, utilizou-se a API do shell Netica para automatizar das tarefas de aprendizagem e instanciação da rede. Primeiramente, os dados históricos são convertidos em casos que contém informações como mês, fatores de campanha e de greve e o coeficiente de ajuste da normalização. Em seguida, é criada a topologia da rede e os casos de uso são utilizados por um algoritmo de aprendizagem para calcular as tabelas de probabilidades condicionais da rede bayesiana.

A figura 25 mostra a rede bayesiana para dados mensais futuros, criada e treinada a partir dos dados históricos do caso de teste 1. Observa-se que os meses do ano estão codificados em números de 1 a 12, e os fatores estão codificados em sim ou não (de acordo com a sua ocorrência). O valor de ajuste da normalização é o valor que se deseja encontrar para aplicar na fórmula da inversa da normalização do dado previsto, apresentada no capítulo 3.3.6.

Um exemplo de instanciação da rede bayesiana apresentada pela figura 25, está mostrado na figura 26. Nesse exemplo, foi instanciado o mês de

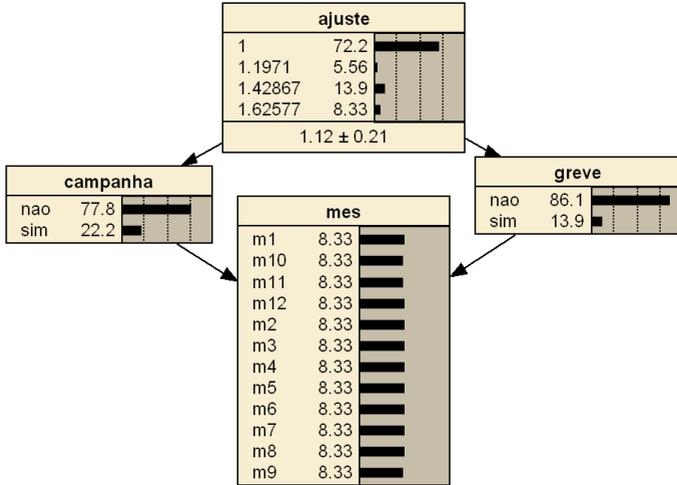


Figura 25 – Rede bayesiana mensal para o caso de teste 1.

maio (mês número 5), mas não foram instanciados nenhum dos dois fatores. Segundo esse cenário, o coeficiente de ajuste da normalização resultante é de 1,14 com desvio padrão de 0,2.

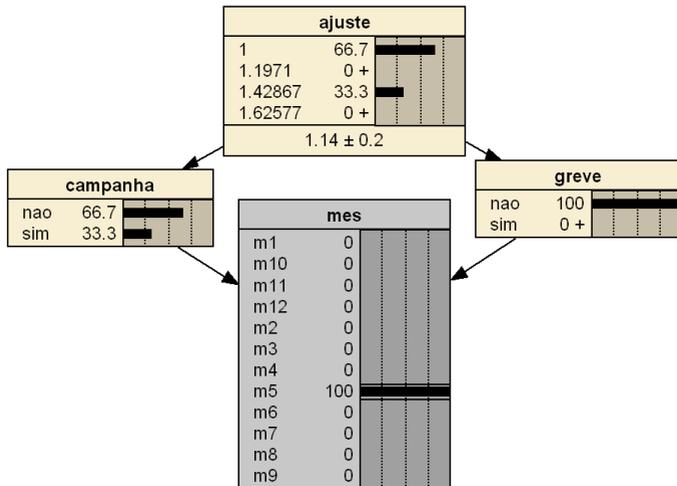


Figura 26 – Rede bayesiana mensal instanciada para o caso de teste 1.

Caso houvesse mais informações acerca dos acontecimentos futuros dos fatores aleatórios, elas poderiam, também, ajudar na instânciação dos fatores. Na figura 27, os fatores de campanha e greve foram instanciados com valor zero, pois o conhecimento disponível apontava para que os fatores não iriam ocorrer no mês de maio. Nesse cenário, o coeficiente de ajuste da normalização resultante esperado é de 1,0 com desvio padrão de 0,003.

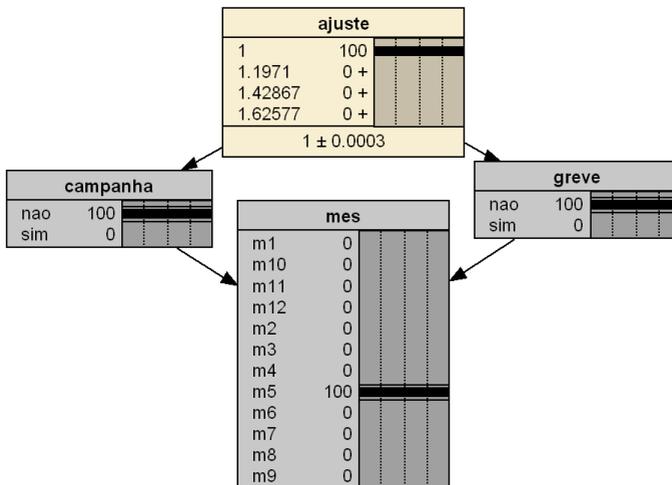


Figura 27 – Rede bayesiana mensal instanciada para o caso de teste 1.

Para a previsão dos dados nos casos de testes, apenas o nó referente ao mês foi instanciado. Os fatores de campanha e greve não foram instanciados e seguiram a probabilidade condicional resultante do treinamento da rede bayesiana com os dados históricos.

As previsões mensais se enquadram no tipo de previsão de longo prazo, em que o objetivo é fazer um planejamento operacional da operação do call center. Para os casos de teste, foram feitas previsões mensais para um período de 12 meses. Os erros percentuais absolutos (EPA) dos dados mensais futuros, calculados utilizando o algoritmo de Holt-Winters em relação aos dados de teste, estão apresentados na figura 28. Os modelos que utilizaram o processo de normalização obtiveram uma previsão com menor erro, com exceção dos últimos 3 meses.

Separando a previsão em períodos de 3, 6 e 12 meses para análise dos resultados da previsão, os erros percentuais absolutos médios da previsão dos dados futuros dos modelos testados em relação aos dados de teste do caso de teste 1 são apresentadas na tabela 10.

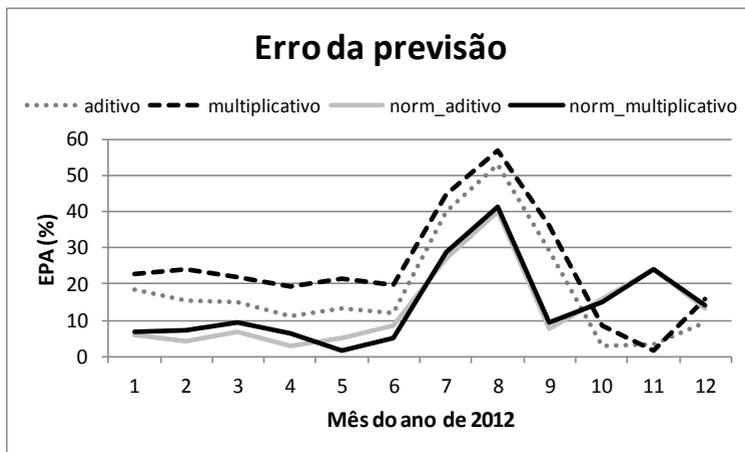


Figura 28 – Erro da previsão para o caso de teste 1.

Tabela 10 – EPAM dos dados de teste para o caso de teste 1.

Período previsto	Normalização	Método de Holt-Winters	Erro
3 meses	Não	aditivo	16,32%
		multiplicativo	23,04%
	Sim	aditivo	<b>5,60%</b>
		multiplicativo	7,89%
6 meses	Não	aditivo	14,26%
		multiplicativo	21,60%
	Sim	aditivo	<b>5,64%</b>
		multiplicativo	6,19%
12 meses	Não	aditivo	18,58%
		multiplicativo	24,46%
	Sim	aditivo	<b>13,51%</b>
		multiplicativo	14,17%

Os modelos que utilizaram o processo de normalização dos fatores aleatórios obtiveram menores erros dos valores previstos do que os modelos sem o tratamento dos fatores no caso de teste 1. Dentre esses modelos, o que utilizou o algoritmo de Holt-Winters aditivo obteve os menores erros de previsão nos três períodos testados e teve os seus valores destacados na tabela

10. Cabe ressaltar que esse modelo foi o que apresentou o menor EPAM entre os dados históricos e os previstos.

Utilizando as probabilidades de ocorrência dos fatores calculadas pela rede bayesiana, isso é, sem instanciar os fatores aleatórios, os dados previstos com o modelo que gerou os menores erros (modelo de Holt-Winters aditivo com normalização) foram plotados em conjunto com os dados de teste na figura 29.

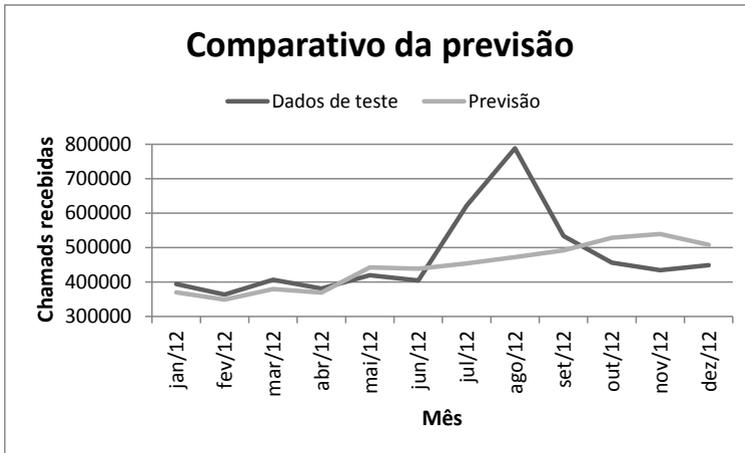


Figura 29 – Previsão mensal do caso de teste 1 com o modelo proposto.

Caso o conhecimento de ocorrência dos fatores seja utilizado, é possível obter uma previsão com um erro menor. A figura 30 mostra a previsão do caso de teste 1, utilizando os valores de ajuste calculados pela rede bayesiana, instanciando os fatores aleatórios de acordo com a sua ocorrência segundo os dados de teste.

É importante destacar que o analista nem sempre faz um julgamento correto da ocorrência dos fatores. Pelo fato de os fatores aleatórios não serem determinísticos, pode haver um comportamento diferente do esperado pelo analista. Sendo assim, quando o analista não tiver certeza da ocorrência dos fatores, o melhor é não instanciar os fatores na rede bayesiana e utilizar as probabilidades de ocorrência calculadas pelo treinamento.

Para o caso de teste 2, a rede bayesiana é igual à do caso de teste 1, apenas o valor de ajuste é diferente, pois os pesos dos fatores aleatórios, descritos na tabela 7, são diferentes. Seguindo os testes feitos no caso de teste 1, apenas o nó referente ao mês foi instanciado. Os erros percentuais absolutos obtidos da previsão utilizando o algoritmo de Holt-Winters estão

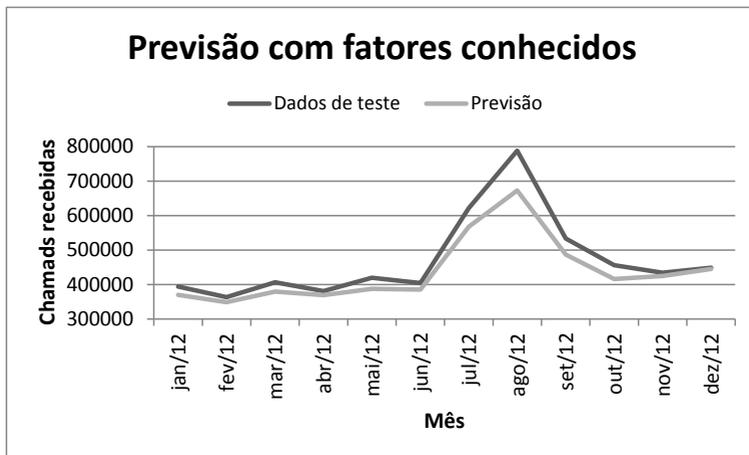


Figura 30 – Previsão mensal do caso de teste 1 com o modelo proposto e os fatores conhecidos.

apresentados na figura 31. Neste caso de teste, os modelos que utilizaram o processo de normalização obtiveram os menores erros em todos os dados previstos.

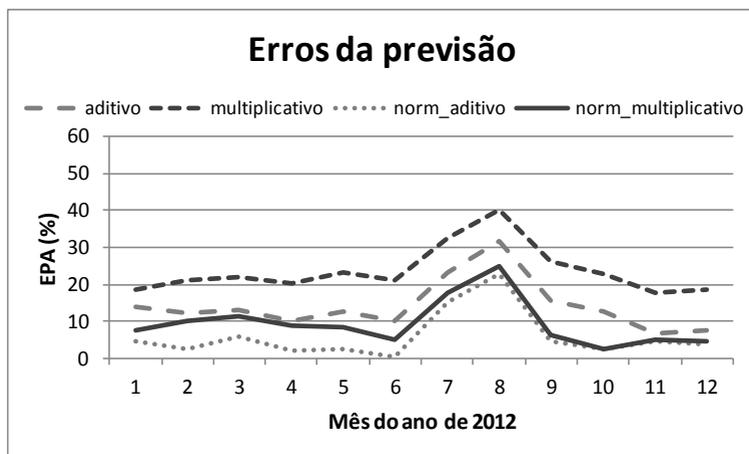


Figura 31 – Erro da previsão para o caso de teste 2.

Os resultados das análises dos erros percentuais absolutos médios da previsão dos dados futuros do caso de teste 2 para os períodos de 3, 6 e 12 meses, estão apresentados na tabela 11. Assim como no caso de teste 1, os modelos que utilizaram a normalização apresentaram menores erros de previsão. Destaque também para o modelo que utilizou o processo de normalização e o algoritmo de Holt-Winters aditivo, cujos os valores de erro estão em destaque, o qual obteve os menores erros de previsão e já era apontado pelos dados históricos como sendo o melhor modelo para ser utilizado neste caso de teste.

Tabela 11 – EPAM dos dados de teste para o caso de teste 2.

Período previsto	Normalização	Método de Holt-Winters	Erro
3 meses	Não	aditivo	13,09%
		multiplicativo	20,49%
	Sim	aditivo	<b>4,27%</b>
		multiplicativo	9,60%
6 meses	Não	aditivo	11,98%
		multiplicativo	21,03%
	Sim	aditivo	<b>2,96%</b>
		multiplicativo	5,88%
12 meses	Não	aditivo	14,13%
		multiplicativo	23,66%
	Sim	aditivo	<b>5,88%</b>
		multiplicativo	9,33%

Sem instanciar a ocorrência dos fatores na rede bayesiana, o valor final dos dados mensais previstos para o caso de teste 2 utilizando o algoritmo de Holt-Winters aditivo com normalização estão apresentados na figura 32 em conjunto os dados de teste gerados pelo simulador.

Utilizando a rede bayesiana instanciada conforme a ocorrência dos fatores segundo os dados de teste, a previsão obtida apresenta um erro menor. Os valores previstos estão apresentados na figura 33.

Diante dos resultados desses experimentos dos casos de testes, é possível concluir que os fatores aleatórios causam perturbações significativas na previsão de dados. O tratamento desses fatores aleatórios se faz necessário para diminuir os erros de previsão. Nos dois casos de testes, o uso da normalização na previsão mensal possibilitou uma melhora nos resultados da previsão.

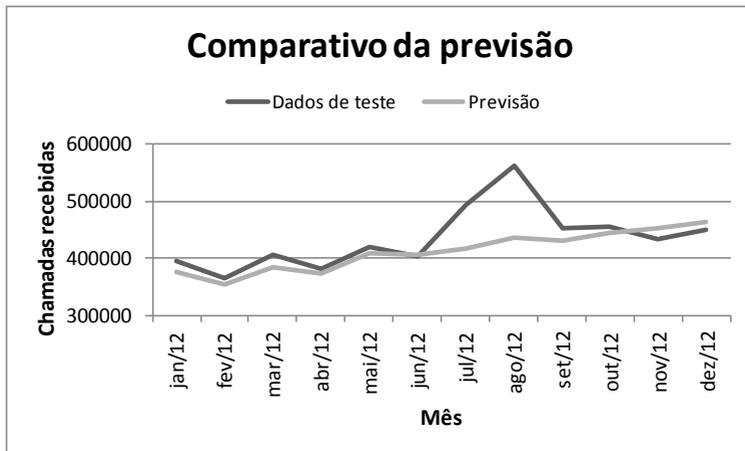


Figura 32 – Previsão mensal do caso de teste 2 com o modelo proposto.

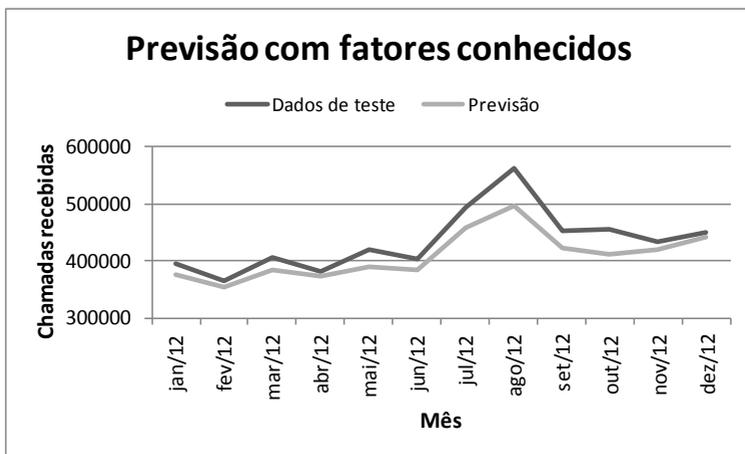


Figura 33 – Previsão mensal do caso de teste 2 com o modelo proposto e os fatores conhecidos.

#### 4.2.3 Previsão diária

Conforme a abordagem *top-down*, utilizada para a previsão das chamadas recebidas, as chamadas diárias são previstas a partir da previsão mensal.

Com o valor mensal previsto, as chamadas são distribuídas nos dias do mês, de acordo com o dia da semana, a semana do mês, a ocorrência de feriado e de pós-feriado e os outros fatores que interfiram na distribuição. Para o cálculo da quantidade de chamadas relativas ao dia do mês, foi optado por utilizar o valor percentual das chamadas do dia em relação ao mês.

Para os casos de testes, os dados diários foram convertidos em casos de treinamento de rede bayesiana que continham o dia do mês, o dia da semana, o mês do ano, as ocorrências de feriado e de pós-feriados, a presença de fatores de campanha e greve e os valores de chamadas percentuais mensais. Pode-se dizer que os feriados e pós-feriados são fatores que alteram o número de chamadas recebidas, porém são fatores previsíveis pelo calendário.

Com os casos de treino, o próximo passo é definir a topologia da rede bayesiana e utilizar os casos para treinamento da rede. O percentual mensal das chamadas foi dividido em classes por ser uma variável contínua, uma vez que se faz necessário o agrupamento dos dados para o uso na rede bayesiana. Para a distribuição de frequências com classes, existem duas fórmulas para calcular uma aproximação do número de classes ( $k$ ) conforme o número de elementos da amostra ( $n$ ):

$$1. k = \begin{cases} 5 & \text{se } n < 25 \\ \sqrt{n} & \text{se } n \geq 25 \end{cases}$$

$$2. \text{Fórmula de Sturges: } k = 1 + 3,32 \cdot \log(n)$$

Somando-se os três anos de estatísticas diárias dos casos de testes, são obtidos 1095 dados. Pela aproximação da raiz quadrada, os dados seriam agrupados em 33 classes. Já pela fórmula de Sturges, os dados seriam divididos em 11 classes. As duas abordagens de números de classes serão mostradas a seguir. Primeiramente será mostrado a previsão do percentual diário utilizando a Fórmula de Sturges e em seguida utilizando a raiz quadrada para posteriormente serem comparadas.

Utilizando o número de classes segundo a fórmula de Sturges, foram criados casos de treinamento com os dados diários contendo o dia do mês, os dias da semana, o mês do ano, a ocorrência de feriado e de pós-feriado, e a ocorrência dos fatores de campanha e greve.

O software utilizado para a criação de redes bayesianas, o shell Netica, possui uma limitação de 1000 casos de treinamento na sua versão de demonstração gratuita. Sendo assim, os últimos 95 dias dos casos foram ignorados para o treinamento da rede pelo software, o que representa cerca de 8,7% dos casos disponíveis.

A figura 34 mostra a rede bayesiana para os dados diários criada e treinada com os dados históricos do caso de teste 1 e com os percentuais de

chamadas divididos em 11 classes. Os dias do mês estão codificados de 1 a 31, os dias da semana estão codificados de 0 a 6 (0 representa domingo, 1 segunda-feira, e assim por diante), os meses do ano estão codificados de 1 a 12, e os feriados, pós-feriados e fatores estão codificados como sim e não (conforme a ocorrência).

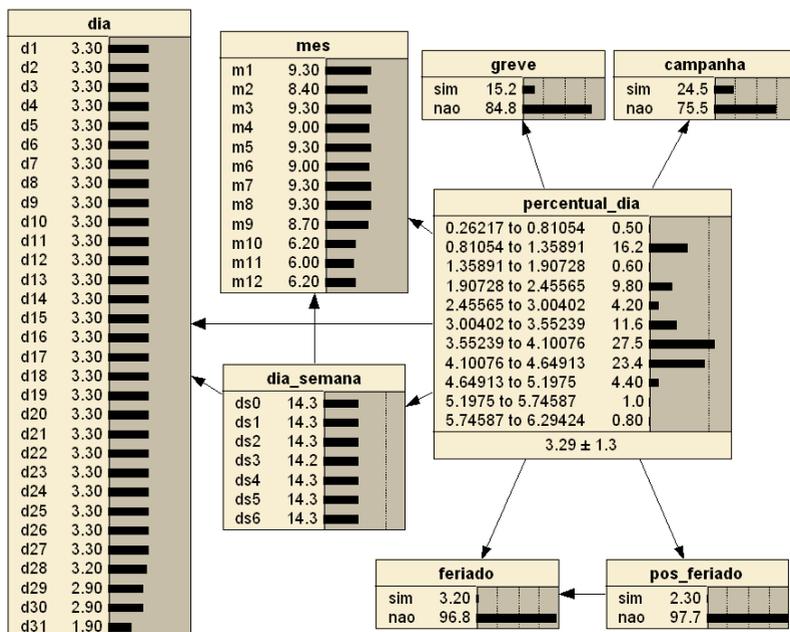


Figura 34 – Rede bayesiana diária com 11 classes para o caso de teste 1.

Como alguns dos dados de treinamento foram ignorados pela versão gratuita do Netica, as probabilidades de ocorrência do nó de mês não ficaram iguais. Os três últimos meses do ano ficaram com probabilidades de ocorrência menores que os outros meses do ano. Também houveram diferenças nos outros meses do ano em razão deles apresentarem entre de 28 a 31 dias. O mesmo ocorre diferenças nas probabilidade de ocorrência dos dias do mês, também em razão dos diferentes números de dias de cada mês.

Um exemplo de instanciação da rede bayesiana diária, para o caso de teste 1, está apresentado na figura 35. Nesse exemplo foi instanciado o dia 02 de fevereiro de 2012, que aconteceu em uma quinta-feira e não era um dia de feriado e nem de pós-feriado. Sem instanciar os fatores de campanha e de greve, o valor esperado para o percentual de chamadas no mês para o dia é de

4,02 com desvio padrão de 0,31.

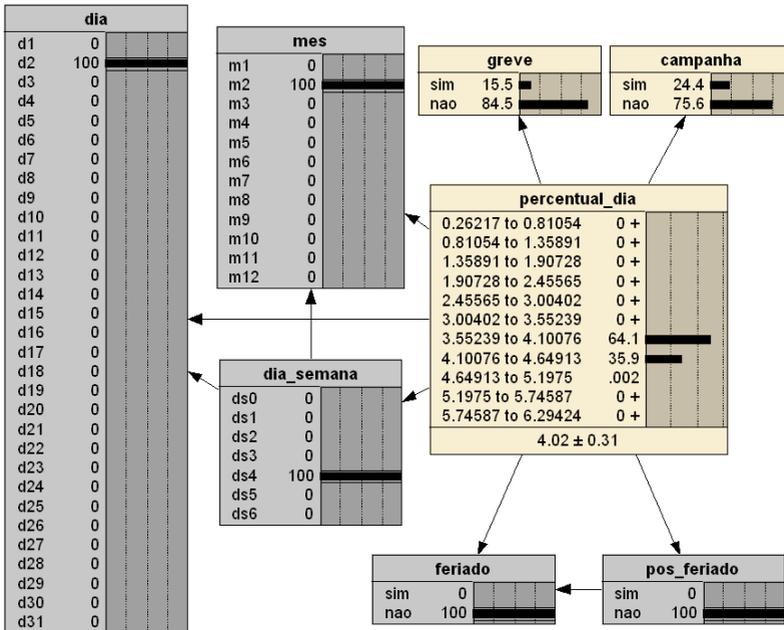


Figura 35 – Rede bayesiana diária instanciada com 11 classes percentuais.

Para a previsão diária, não é comum realizar previsões para períodos muito longos. Esse tipo de previsão se encaixa melhor em previsão de médio prazo, cujo objetivo é avaliar a quantidade de recursos (humanos e físicos) necessárias para uma operação.

Com os valores da previsão mensal de chamadas e se instanciando a rede bayesiana diária para cada dia que se deseja prever, é possível obter as previsões de percentuais diários de chamadas previstas. Os valores previstos para as chamadas diárias, instanciando-se os nós de dia do mês, dia da semana, mês do ano, feriado e pós-feriado para o período de 3 meses, estão apresentados na figura 36.

A previsão diária para o mês de fevereiro, no qual aconteceu o feriado de carnaval nos dias 20 e 21 e o pós-feriado de carnaval no dia 22, está destacado na figura 37. É possível notar que os valores de previsão para os dias de feriado ficaram próximos aos valores de chamadas dos dados de teste. Mais da metade das previsões diárias obtiveram um valor de erro percentual absoluto menor do que 5%. A previsão para o dia 07 de fevereiro apresentou um

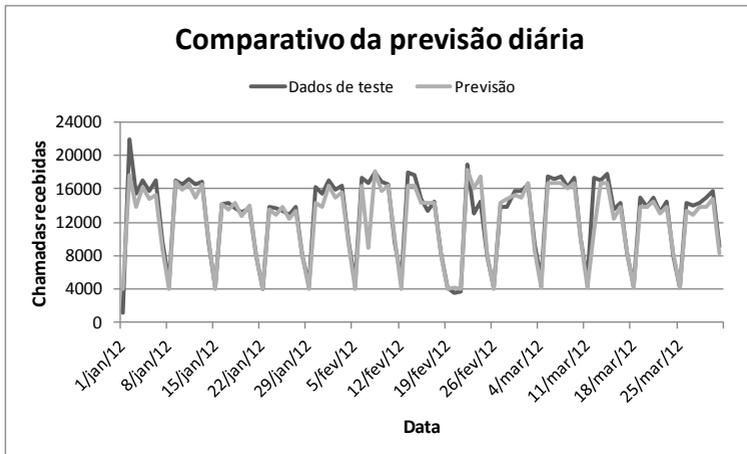


Figura 36 – Previsão diária com 11 classes para o caso de teste 1.

erro percentual absoluto de 46,2%, o maior erro para o do mês de fevereiro.

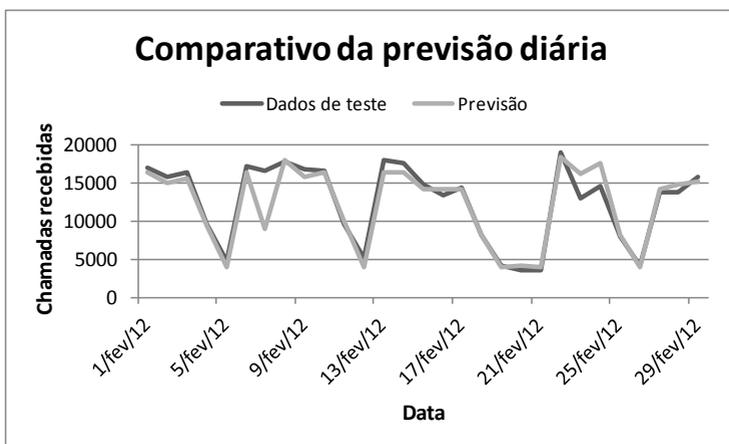


Figura 37 – Detalhe da previsão diária com 11 classes.

O gráfico dos erros percentuais absolutos diários dos dados previstos em relação aos dados de teste para os 3 meses de previsão diária estão apresentados na figura 38. Cabe destacar o dia 01 de janeiro, que apresentou um erro percentual absoluto de 231,5%, um valor bastante discrepante em relação aos outros dias de previsão.

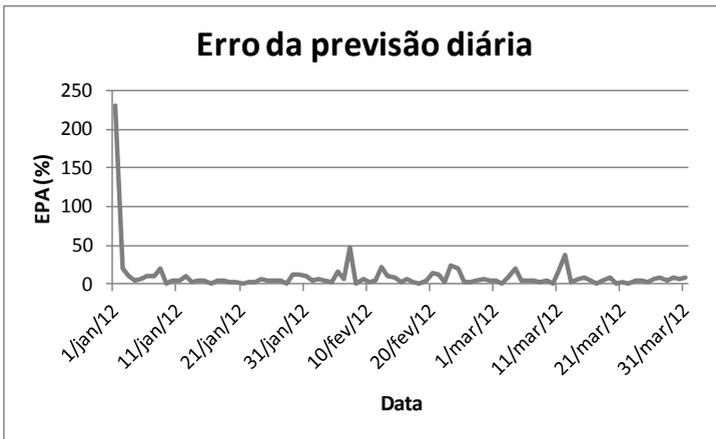


Figura 38 – Erro da previsão diária com 11 classes para o caso de teste 1.

Esse erro discrepante acabou por aumentar consideravelmente o erro percentual absoluto médio (EPAM) do mês de janeiro. Os valores dos EPAM dos meses de janeiro, fevereiro e março, juntamente com a média dos 91 dias dos três meses estão mostrados na tabela 12.

Tabela 12 – EPAM da previsão diária para o caso de teste 1.

Percentual diário	Mês	Erro
11 classes	janeiro	13,21%
	fevereiro	8,35%
	março	6,14%
	<b>janeiro a março</b>	<b>9,26%</b>

Por outro lado, caso sejam utilizadas 33 classes de percentuais diários,

número obtido pela raiz quadrada no número de amostras, outros valores de previsão são encontrados. Os valores de previsão diária em comparação com os dados de teste estão mostrados na figura 39. Com esse número de classes também houve uma previsão de acordo com os dias da semana, as semanas do mês e os feriados e pós-feriados.

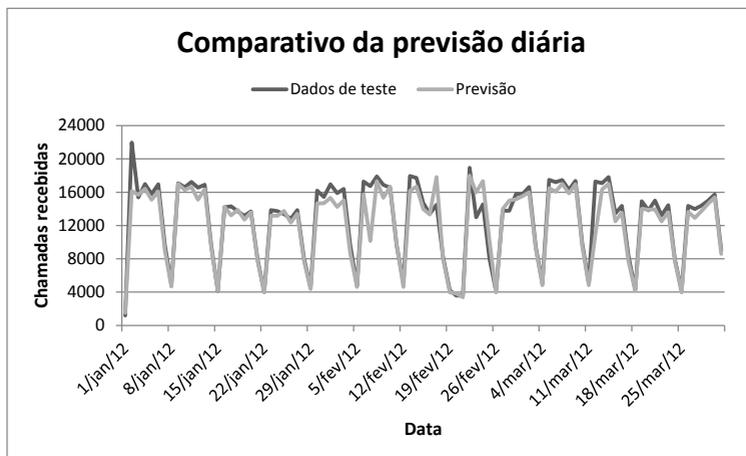


Figura 39 – Erro da previsão diária com 33 classes para o caso de teste 1.

O mês de fevereiro, mostrado em detalhe na figura 40, obteve valores compatíveis para o feriado de carnaval (dias 20 e 21 de fevereiro) e o pós-feriado de carnaval (dia 22 de fevereiro). Nota-se que, em geral, os valores dos dados diários previstos estão próximos aos dos dados de teste. Assim como na previsão com 11 classes, também aconteceu de, algumas previsões, ocorrerem um erro maior, tal como a previsão do dia 07 de fevereiro.

A figura 41 apresenta o gráfico com os erros percentuais absolutos (EPA) para os 3 meses de previsão com 33 classes. Na maioria dos dias, os valores de EPA ficaram abaixo de 10%. No dia 01 de janeiro, o EPA baixou de 231,5% (com 11 classes) para 26,8% (com 33 classes).

Em relação à previsão com 11 classes, houve uma diminuição nos erros de previsão. Os valores de erro percentual médio absoluto para os 3 meses de previsão estão apresentados na tabela 13.

Os fatores aleatórios podem causar um erro grande na previsão diária de chamadas. Essa deficiência na previsão causa alguns problemas no planejamento de recursos. Nos dois casos de testes, os diferentes tratamentos dos fatores aleatórios produziram valores de previsão distintos, mas ambos

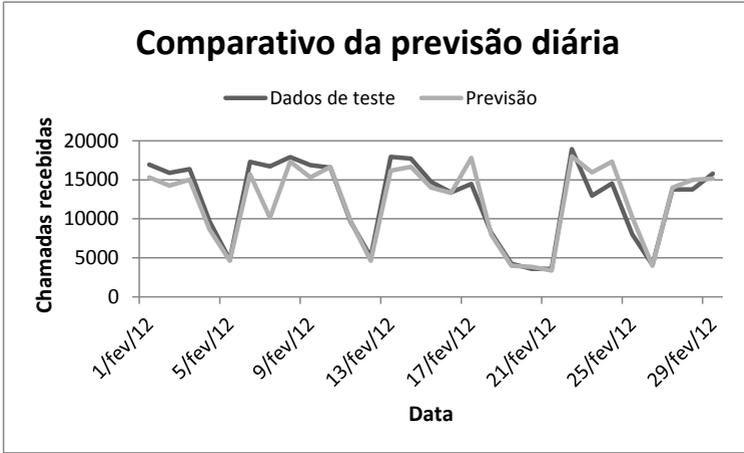


Figura 40 – Detalhe da previsão diária com 33 classes.

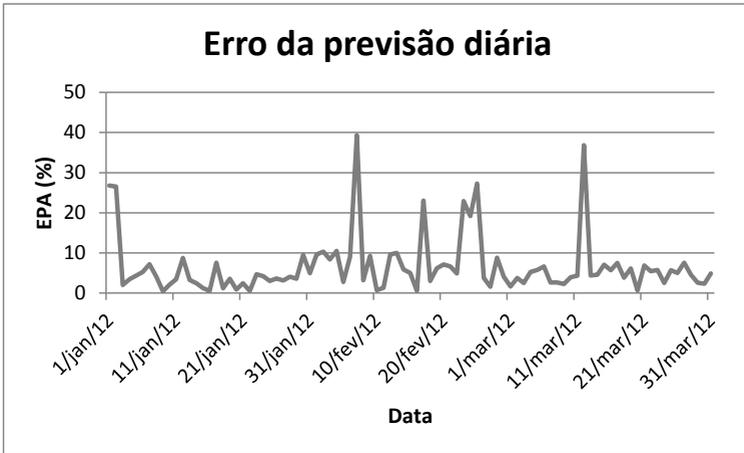


Figura 41 – Erro da previsão diária com 33 classes para o caso de teste 1.

seguem o padrão dos dados de teste, isso é, conseguem gerar um previsão com erros aceitáveis, e conseguem diferenciar a ocorrência de feriados e pós-feriados dos dias úteis.

Tabela 13 – EPAM da previsão diária para o caso de teste 1.

Percentual diário	Mês	Erro
33 classes	janeiro	5,11%
	fevereiro	9,44%
	março	5,51%
	<b>janeiro a março</b>	<b>6,62%</b>

### 4.3 COMENTÁRIOS FINAIS

Este capítulo apresentou a avaliação da previsão obtida com o processo de normalização. Para isso, primeiro foi avaliado o simulador de chamadas, que gerou sinteticamente as chamadas. A dificuldade na obtenção de dados de chamadas de centrais de atendimento criou a necessidade de um gerador de dados que pudesse criar vários cenários de testes para o modelo de previsão.

A avaliação do simulador de chamadas mostrou que é possível criar um gerador de chamadas e colocar geradores de eventos aleatórios para os fatores que alteram a geração de chamadas. Os fatores podem ser alterados de forma a colocar diferentes impactos na alteração das chamadas geradas. Foram realizados 5000 replicações de um cenário de teste, e o resultado obtido mostrou a influência os fatores aleatórios.

Em seguida, o modelo de previsão normalizado foi avaliado com os dados gerados pelo simulador de chamadas. Foram gerados dois casos de testes com fatores aleatórios que causavam diferentes impactos no volume de chamadas recebidas. Primeiramente, foram avaliados os dados históricos, nos quais foram identificados e quantificados os fatores aleatórios. Foi apresentado que o modelo de normalização consegue capturar o peso de impacto dos fatores e utilizá-los para normalizar os dados.

Na previsão mensal, os dados futuros foram previstos utilizando a ferramenta EZF e o processo de normalização. Os dados mensais previstos com o processo de normalização obtiveram menores erros, sendo que ambos os casos de testes utilizam-se das as probabilidades de ocorrência dos fatores aleatórios calculados pelo treinamento da rede bayesiana. Caso o analista tenha conhecimento da ocorrência dos fatores, é possível instanciar este conhecimento para obter uma previsão com menor erro. Vale ressaltar que instanciando o conhecimento de forma errada, pode-se gerar uma previsão considerando a ocorrência contrária dos fatores.

Para a previsão diária, foram utilizados os dados mensais previstos e a rede bayesiana diária para o cálculo dos percentuais diários de chamadas. Em

ambos os testes, com diferentes números de classes de percentuais diários, os feriados e os pós-feriados são tratados pela rede bayesiana. Os valores diários previstos são bastante satisfatórios em relação aos dados de teste. A ressalva fica em alguns dias que obtiveram um erro de previsão grande em relação aos outros dias.

Uma possível melhora na previsão diária é o uso de mais casos de treinamento para a rede bayesiana, mas, devido à limitação da versão de demonstração do software, não foi possível avaliar o modelo de previsão com a rede treinada com uma quantidade maior de dados históricos.

## 5 CONSIDERAÇÕES FINAIS

Este trabalho apresentou uma proposta para incorporar o conhecimento sobre os fatores aleatórios na previsão de chamadas recebidas em uma central de atendimento utilizando-se redes bayesianas. O setor de centrais de atendimento é um dos setores que mais empregam no Brasil e muitas pesquisas tem sido desenvolvidas para melhorar a previsão de chamadas recebidas.

O gasto com recursos humanos tem grande impacto no orçamento das empresas de central de atendimento. O corte de custos é um dos problemas que essas empresas enfrentam; todavia a necessidade da melhor alocação dos recursos humanos surge então como forma de evitar o desperdício desses recursos.

Desde o começo do século XX, com a automação de sistemas de telefonia, as centrais de atendimento precisam de uma previsão acurada de chamadas recebidas para alocação de recursos na quantidade e no momento correto exigidos pela demanda de atendimento. Porém, alguns fenômenos podem impactar na quantidade de chamadas recebidas em uma central de atendimento, fazendo com que algoritmos de previsão clássicos gerem resultados aquém do esperado. Esses fenômenos fazem com que se multipliquem, dentre os membros da equipe de planejamento, a criação de métodos empíricos complementares aos métodos clássicos.

A revisão bibliográfica apresentada no capítulo 2 abordou os principais assuntos apresentados nesta pesquisa, descrevendo desde as centrais de atendimento, passando pelos processos de previsão de dados e previsão de séries temporais, até o tratamento de incerteza. Este trabalho foi desenvolvido utilizando os conceitos de previsão de dados, em especial os conceitos de previsão de séries temporais, aplicados às centrais de atendimento. Junto à isso, foram incorporados métodos bayesianos para incorporação dos fatores aleatórios que perturbam o volume de chamadas recebidas nas previsões de chamadas recebidas.

As redes bayesianas, nas quais o conhecimento é formado por probabilidades que representam as incertezas entre as variáveis do problema, são uma boa alternativa para tratar a aleatoriedade presente nos fatores e para a contribuição na diminuição dos erros das previsões feitas pelos métodos clássicos. O uso das redes bayesianas é indicado, pois possibilita expressar o conhecimento de uma forma visual e de fácil percepção e também por terem um baixo custo computacional para realizar os cálculos. Sendo assim, a equipe de planejamento pode colocar o seu conhecimento acerca dos fatores aleatórios no processo de previsão de uma maneira formal e simples, sem grandes fórmulas matemáticas que exigem um maior conhecimento numérico

e, muitas das vezes, podem ser utilizadas somente em condições específicas da operação de atendimento. Com isso, é possível transformar o conhecimento em informação útil durante o processo de previsão, evitando assim o uso de adivinhações e de métodos empíricos.

## 5.1 PROPOSTA E RESULTADOS

O modelo de previsão proposto visa a incorporar o conhecimento empírico da equipe de planejamento, conhecimento este utilizado para fazer ajustes nos valores de chamadas previstos por métodos clássicos conforme sua intuição dos possíveis fatores aleatórios que podem ocorrer no futuro.

A primeira etapa para elaboração de um modelo proposto para o refinamento da previsão é a obtenção dos dados de centrais de atendimento para estudo do comportamento dos fatores aleatórios nas chamadas recebidas. Tecnicamente, é muito difícil de se obter os dados de operações de call centers de pelo menos três anos, e isso levou a criação de um simulador de chamadas recebidas, que gera sinteticamente as chamadas. O simulador possui um módulo de geração de eventos aleatórios que é responsável por alterar o comportamento das chamadas geradas de acordo com o tipo de evento e a sua intensidade. No simulador de call center, é possível gerar dados que serão utilizadas para o treinamento do modelo de previsão e dados que serão utilizados como teste dos resultados obtidos pelo modelo, a efeito de comparação.

Seguindo a elaboração do modelo proposto, uma ferramenta de previsão de séries temporais é necessária. A ferramenta EZF foi criada então para possibilitar o estudo dos métodos de suavização exponencial, que são métodos que não exigem uma série temporal muito longa. Criada como suplemento para o Microsoft Excel<sup>®</sup>, a ferramenta EZF possibilita a entrada dos parâmetros dos algoritmos de suavização exponencial pelo usuário ou a otimização dos parâmetros utilizando o Microsoft Solver<sup>®</sup>.

A última etapa de desenvolvimento de um modelo é a proposição de um modelo que utiliza as redes bayesianas para tratar os fatores aleatórios. Para isso, um modelo de normalização foi proposto, tendo como objetivo eliminar o efeito causado pelos fatores aleatórios na série de dados das chamadas recebidas, fazer a previsão utilizando os métodos clássicos, e reinserir o efeito dos fatores nas chamadas.

O primeiro passo do modelo de normalização é a identificação e quantificação dos fatores aleatórios nas chamadas. A identificação é feita por um especialista, e a quantificação pode ser feita utilizando regressão múltipla. Com os valores de pesos dos fatores, é aplicada a normalização dos dados com o objetivo de obter os dados sem a influência dos fatores.

A previsão da série é, então, feita com os dados na forma normalizada. Os algoritmos de Holt-Winters (tanto aditivo quanto multiplicativo) são indicados pois tratam o componente de sazonalidade da série de dados. Os valores previstos estarão na forma normalizada, pois os dados de entrada se encontram na forma normalizada.

Para desnormalizar os dados, a operação inversa da normalização deve ser aplicada. Essa operação consiste em recolocar os efeitos dos fatores aleatórios novamente nos dados. Para os dados previstos da série histórica, basta relocar os pesos dos fatores de acordo com a ocorrência no respectivo período. Já para os dados previstos futuros, é necessário utilizar uma rede bayesiana, pois o conhecimento de ocorrência dos fatores não é certa.

A rede bayesiana é utilizada para calcular os pesos dos fatores aleatórios na série de dados de acordo com as probabilidades de ocorrência deles. Os dados históricos são organizados em casos para o treinamento da rede bayesiana, para então ser definida a topologia da rede. Em seguida, um algoritmo de aprendizagem deve ser utilizado para o cálculo das probabilidades condicionais da rede. Com a rede bayesiana treinada, pode-se então instanciar casos para os dados futuros e obter os valores de ajuste que devem ser aplicados na previsão futura feita com os dados normalizados.

Proposto o modelo, o capítulo 4 apresentou a análise dos testes do simulador de call center e do modelo de previsão proposto. Os dados de uma operação de cartão de crédito foram analisados e os fatores aleatórios foram identificados, para então construir um simulador. A partir desta análise, foi criada uma simulação que continha dois fatores aleatórios e foi replicada por 5 mil vezes. Foram verificadas alterações significativas no número de chamadas mensais recebidas nos períodos em que os fatores atuavam. Ainda nos testes do simulador, foi criado um caso de teste alternativo com um peso maior para os fatores aleatórios, através do qual também foi possível verificar as diferentes influências dos fatores aleatórios nas chamadas recebidas.

A avaliação do modelo foi dividida em três partes: avaliação dos dados históricos, da previsão mensal e da previsão diária. Para os dois casos de testes desenvolvidos, optou-se por gerar chamadas pelo simulador com as informações reais do período de 2009 a 2011. Os dados de testes, aqueles gerados para comparação do modelo de previsão, foram gerados para o período do ano de 2012. Para os fatores aleatórios, foram escolhidos campanha de marketing e greve nos correios.

Na análise dos dados históricos, foi mostrado que os dois fatores provocaram um aumento no número de chamadas recebidas em certos períodos da operação. Também foi mostrado como os feriados podem provocar alterações nas chamadas diárias recebidas assim como o pós-feriados, que é caracterizado pela acumulação de demanda do feriado, também provocou

alterações.

Ainda na análise dos dados históricos, começou-se a analisar o modelo de previsão proposto. Primeiramente, os fatores aleatórios foram identificados e, através da regressão múltipla, os fatores foram quantificados para então normalizar os dados mensais de chamadas recebidas. Os valores de peso dos fatores encontrados foram coerentes com os utilizados nos casos de testes e os valores normalizados seguiram a tendência das chamadas recebidas nos períodos em que não houve atuação dos fatores aleatórios.

Seguindo a avaliação do modelo, a próxima avaliação foi a da previsão mensal. Para essa avaliação, foram mostrados os dados de teste que foram utilizados e foram feitas as previsões mensais de chamadas utilizando a ferramenta EZF. Em ambos os casos de testes, os modelos que utilizaram os dados normalizados ao invés dos dados brutos geraram um EPAM menor. Para os dados previstos futuros, definiu-se a topologia da rede bayesiana e utilizou-se os dados históricos mensais para o treinamento.

Para calcular o ajuste aplicado na previsão mensal, utilizou-se a rede bayesiana com apenas o período instanciado. Os fatores aleatórios não foram instanciados e os fatores aleatórios seguiram a probabilidade de ocorrência obtida através do treinamento da rede. Os modelos que utilizaram o processo de normalização e as redes bayesianas obtiveram dados futuros com menores erros, quando comparados com os dados de teste. Para um período futuro de 3, 6 e 12 meses, mostrou-se que os menores erros foram do modelo de normalização e redes bayesianas.

Uma última análise da previsão mensal apontou os erros obtidos quando os fatores aleatórios são instanciados da rede bayesiana de acordo com a sua ocorrência. Mostrou-se que, ao instanciar corretamente, o EPAM dos dados futuros é menor do que sem instanciar os fatores. Com isso, fica evidente que ao conhecer a ocorrência dos fatores aleatórios *a priori*, pode-se gerar uma previsão de chamadas recebidas com menores erros.

Na avaliação da previsão diária, que seguiu a abordagem *top-down*, a previsão foi feita a partir da previsão mensal e o cálculo do percentual de chamadas do dia. Por ser uma variável contínua, o percentual diário foi agrupado em classes. Dois tamanhos de classes foram feitos nos casos de testes: raiz quadrada e fórmula de Sturges. Definiu-se então uma topologia que continha as informações de data, os fatores aleatórios, os feriados e pós-feriados e ainda o percentual diário de chamadas.

Mostrou-se como a previsão diária utilizando o percentual diário de chamadas consegue acompanhar as características dos dados de teste, ou seja, nos finais de semana e feriados os percentuais obtidos são menores assim como ocorreu nos dados de teste. O comportamento da rede bayesiana no feriado de carnaval foi bom, conseguindo capturar a demanda acumulada para

o pós-feriado.

Diante dos resultados, pode-se dizer que o modelo de previsão proposto, o qual utiliza as redes bayesianas para tratar os fatores aleatórios, conseguiu uma previsão de chamadas recebidas. O tratamento dos fatores aleatórios se mostra fundamental para a diminuição dos erros de previsão. O modelo proposto não requer grandes conhecimentos matemáticos por parte das equipes de planejamento, o que faz com que seu uso seja estimulado para a formalização dos métodos de previsão utilizados nas centrais de atendimento.

Com uma previsão com menos erros, é possível alocar melhor os recursos humanos para uma operação de atendimento. Consequentemente as empresas de atendimento, ao utilizarem melhor os seus recursos humanos, podem equilibrar o orçamento com a manutenção da qualidade de seu atendimento, uma vez que os recursos humanos serão alocados na quantidade e nos momentos necessários.

## 5.2 LIMITAÇÕES

Apesar dos resultados promissores obtidos com o modelo de previsão proposto utilizando normalização e redes bayesianas, a dificuldade de obter dados de chamadas de centrais de atendimento reais, tanto nos números de chamadas quanto na ocorrência de fatores aleatórios, impôs certas dificuldades no desenvolvimento do trabalho. Abaixo estão listados itens que criaram algumas limitações no trabalho:

- A obtenção de apenas uma única base de dados de chamadas recebidas de um call center, base esta que apresentava somente os valores mensais de chamadas recebidas em um período de 44 meses, possibilitou o desenvolvimento de uma proposta de previsão de dados voltada para centrais de atendimento do tipo receptiva.
- A falta de dados com casos de fatores aleatórios possibilitou uma avaliação limitada dos efeitos que esses fatores causam nas chamadas recebidas em centrais de atendimento reais.
- A limitação de utilização dos dados de treinamento na versão gratuita utilizada do software Netica, limitou as séries históricas diárias em 1000 dias, o que representa um pouco menos do que 3 anos completos. Com isso, séries históricas diárias com mais de 1000 dias não puderam ser avaliadas.

### 5.3 TRABALHOS FUTUROS

O modelo de previsão proposto ainda necessita de melhorias. Métodos alternativos podem ser pesquisados para a avaliação dos pesos dos fatores aleatórios, além do método de regressão múltipla que foram utilizados neste trabalho. O processo de regressão múltipla permite avaliar a significância dos efeitos que os fatores aleatórios causam nas chamadas, o que também deve ser levado em consideração nos métodos alternativos.

Os métodos de intervenção em séries temporais também podem ser pesquisados para a análise dos fatores aleatórios e seus respectivos impactos na série temporal. Segundo Morettin e Toloí (2006), a ocorrência de algum tipo de evento em um instante de tempo  $T$ , conhecido *a priori*, pode ser entendida como intervenção. A avaliação do impacto de tal evento no comportamento da série temporal é um dos objetivos da análise de intervenção. Mais detalhes em (MORETTIN; TOLOI, 2006).

Na rede bayesiana diária, durante os testes, ocorreram erros discrepantes obtidos pelos valores de ajuste encontrados que necessitam de uma maior investigação. Um exemplo de erro nos testes foi o dia 07 de fevereiro, que apresentou um erro significativo em relação aos outros dias daquela semana. Uma das linhas de investigação do erro seria a verificação dos dados que foram treinados na rede bayesiana, a sensibilidade da rede com o número de casos de diferentes dias do ano que foram utilizados e o conjunto de dados com os feriados de carnaval (que também podem ocorrer no mês de março).

Uma análise secundária a ser feita são as correlações dos *clusters* de valores de ajuste e de percentuais diários com os fatores aleatórios. Para os problemas envolvendo redes bayesianas, uma alternativa é a adoção de topologia alternativas e/ou a utilização de hibridismo, como a modelagem *fuzzy*.

## REFERÊNCIAS BIBLIOGRÁFICAS

- AKSIN, Z.; ARMONY, M.; MEHROTRA, V. The modern call center: A multi-disciplinary perspective on operations management research. *Production and Operations Management*, v. 16, n. 5, p. 665–688, 2007.
- AKTEKIN, T.; SOYER, R. Call center arrival modeling: A bayesian state-space approach. *Naval Research Logistics*, v. 58, n. 1, p. 28–42, 2011.
- ALDOR-NOIMAN, S.; FEIGIN, P. D.; MANDELBAUM, A. Workload forecasting for a call center: Methodology and a case study. *The Annals of Applied Statistics*, v. 3, n. 4, p. 1403–1447, 2010.
- AVRAMIDIS, A. N.; DESLAURIERS, A.; L'ECUYER, P. Modeling daily arrivals to a telephone call center. *Management Science*, v. 50, n. 7, p. 896–908, 2004.
- AVRAMIDIS, A. N.; L'ECUYER, P. Modeling and simulation of call center. In: *Proceedings of the 2005 Winter Simulation Conference*. Miami, FL: [s.n.], 2005. p. 144–152.
- AYYUB, B. M. *Elicitation of Expert Opinions for Uncertainty and Risks*. [S.l.]: CRC Press, 2001.
- BERGEVIN, R. et al. *Call Center for Dummies*. 2a. ed. Ontario: Wiley, 2010.
- BORST, S. C.; MANDELBAUM, A.; REIMAN, M. I. Dimensioning large call centers. *Operations Research*, v. 52, p. 17–34, 2004.
- BOUZADA, M. A. C. *O uso de ferramentas quantitativas em call centers - o caso Contax*. Tese (Doutorado) — Universidade Federal do Rio de Janeiro. Instituto COPPEAD de Administração, Rio de Janeiro, RJ, 2006.
- BROWN, L. et al. Statistical analysis of a telephone call center: A queueing-science perspective. *Journal of the American Statistical Association*, v. 100, n. 469, p. 36–50, 2005.
- CALLCENTER.INF.BR. *callcenter.inf.br*. 2012. O call center e o Nordeste. <<http://www.callcenter.inf.br/artigos/48641/o-call-center-e-o-nordeste/ler.aspx>>. Acessado em 06/12/2012.

CALLCENTER.INF.BR. *callcenter.inf.br*. 2012. Setor prevê crescimento de 11% no ano. <<http://www.callcenter.inf.br/outourcing/46011/setor-preve-crescimento-de-11-no-ano/ler.aspx>>. Acessado em 07/10/2012.

CALLCENTREHELPER.COM. *callcentrehelper.com*. 2010. Top Ten Call Centre Problems. <<http://www.callcentrehelper.com/top-ten-call-centre-problems-12637.htm>>. Acessado em 20/02/2013.

CLEVELAND, B.; MAYBEN, J. *Call Center Management on Fast Forward: Succeeding in Today's Dynamic Inbound Environment*. 2a. ed. Annapolis, Maryland: Call Center Press, 1999.

COSTA, T. Crescimento supera expectativas. *Gazeta Mercantil*, 29 nov. 1999.

ERLANG. *Agner Krarup Erlang*. 2007. Erlang: Dimensionamento, nível de serviço, tabelas erlang e calculadoras para Call Centers. <<http://www.erlang.com.br/brhistor.asp>>. Acessado em 23/12/2011.

FRANZESE, L. A. G. Dimensionamento de telemarketing ativo. *Revista da Associação Brasileira de Telesserviços (ABT)*, 2002.

FRANZESE, L. A. G. *Método para o Dimensionamento de Centrais de Atendimento*. Dissertação (Mestrado) — Escola Politécnica de Universidade de São Paulo, São Paulo, SP, 2005.

FRANZESE, L. A. G. et al. Comparison of call center models. In: *Proceedings of the 2009 Winter Simulation Conference*. Austin, TX: [s.n.], 2009. p. 2963–2970.

FREITAS, L. M. *Call center: modismo ou realidade?* São Paulo: Record, 2000.

FRIEDMAN, T. *O mundo é plano: uma breve história do século XXI*. [S.l.]: Objetiva, 2005.

GANS, N.; KOOLE, G.; MANDELBAUM, A. Telephone call centers: Tutorial, review, and research prospects. *Manufacturing & Service Operations Management*, v. 5, p. 79–141, 2003.

HALL, B.; ANTON, J. Optimizing your call center through simulation. *Call Center Solutions*, out 1998.

HANKE, J. E. *Business Forecasting*. New Jersey: Prentice Hall, 1992.

HELPER, C. C. *Call Centre Helper*. 19 jan. 2011. The history of the call centre. <<http://www.callcentrehelper.com/the-history-of-the-call-centre-15085.htm>>. Acessado em 29/12/2011.

HYNDMAN, R. J. et al. *Forecasting with Exponential Smoothing: The State Space Approach*. 1a. ed. [S.l.]: Springer, 2008.

ISSICABA, D. et al. Dimensionamento de equipes de manutenção das redes de energia elétrica. In: *XV Congresso Brasileiro de Automática*. Gramado, RS: [s.n.], 2004. p. 1–6.

JIAN, Z.; WU-FENG, T.; CHUN-YAN, C. Traffic forecasting of mobile communication in call center. In: *3rd IEEE International Conference on Computer Science and Information Technology (ICCSIT)*. Chengdu: [s.n.], 2010. p. 160–164.

KOOLE, G. *Call Center Mathematics - A scientific method for understanding and improving contact centers*. 26 jan. 2007. <<http://www.cs.vu.nl/~koole/ccmath/book.pdf>>. Acessado em 29/12/2011.

KORB, K. B.; NICHOLSON, A. E. *Bayesian Artificial Intelligence*. 2a. ed. [S.l.]: CRC Press, 2010.

L'ASTORINA, H. C. *Usando Redes Bayesianas para a Previsão da Rentabilidade de Empresas*. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, 2009.

LIAO, S. et al. Staffing a call center with uncertain non-stationary arrival rate and flexibility. *OR Spectrum*, p. 1–31, 2011.

LOPES, F. B. et al. A importância da previsão de demanda na racionalização de recursos no setor de call center. *Revista INGEPRO - Inovação, Gestão e Produção - Universidade de Santa Maria, RS*, v. 1, n. 1, p. 39–50, 2009.

LUNA, J. E. O. *Algoritmos EM para Aprendizagem de Redes Bayesianas a partir de Dados Incompletos*. Dissertação (Mestrado) — Universidade Federal de Mato Grosso do Sul, Campo Grande, MS, 2004.

MAKIYAMA, F. A. *Cenários Bayesianos para Análise de Risco*. Monografia (Bacharelado em Ciência da Computação) — Universidade Federal de Santa Catarina, Florianópolis, SC, 2006.

MAKRIDAKIS, S. G.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. *Forecasting: Methods and Applications*. 3a. ed. Nova York: Wiley, 1998.

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

MATTOS, N. P. de. *Sistema de apoio à decisão para planejamento em saúde*. Dissertação (Mestrado) — Pontifícia Universidade Católica do Paraná, 2003.

MEHROTRA, V.; FAMA, J. Call center simulation modeling: methods, challenges, and opportunities. In: *Proceedings of the 2003 Winter Simulation Conference*. [S.l.: s.n.], 2003. p. 135–143.

MINGHELLI, G. R. *Call center: estudo de casos múltiplos em empresas de telefonia do Estado do Rio Grande do Sul*. Monografia (Bacharelado em Informática) — Universidade do Vale do Rio dos Sinos, São Leopoldo, RS, 2002.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. *Introduction to Time Series Analysis and Forecasting*. [S.l.]: Wiley, 2008.

MORETTIN, P. A.; TOLOI, C. M. C. *Análise de Séries Temporais*. 2a. ed. São Paulo: Blücher, 2006.

NASSAR, S. M. Sistemas especialistas probabilísticos. Sistemas Especialistas Probabilísticos. jun. 2011. <<http://www.inf.ufsc.br/~silvia>>. Acessado em 28/12/2011.

NEAPOLITAN, R. E. *Learning Bayesian Networks*. [S.l.]: Prentice Hall, 2004.

PLANALTO, P. do. *Decreto No. 6523 de 31 de julho de 2008*. <[http://www.planalto.gov.br/ccivil\\_03/\\_Ato2007-2010/2008/Decreto/D6523.htm](http://www.planalto.gov.br/ccivil_03/_Ato2007-2010/2008/Decreto/D6523.htm)>. Acessado em 28/12/2011.

PLANALTO, P. do. *Lei No. 8078 de 11 de setembro de 1990*. <[http://www.planalto.gov.br/ccivil\\_03/leis/L8078.htm](http://www.planalto.gov.br/ccivil_03/leis/L8078.htm)>. Acessado em 28/12/2011.

PLENTZ, R. D. *Redes Bayesianas para Análise de Comportamento Aplicadas a Telefonia Celular*. Dissertação (Mestrado) — Universidade Federal de Santa Catarina, Florianópolis, SC, 2003.

REYNOLDS, P. *Forecasting Fundamentals: The Art and Science of Predicting Call Center Workload*. 2005. <<http://www.tmcnet.com/channels/workforce-optimization/workforce-optimization-articles/forecasting-call-center-workload.htm>>. Acessado em 26/12/2011.

ROBINSON, M.; KALAKOTA, R. *Offshore outsourcing: business models, ROI and best practices*. 2a. ed. [S.l.]: Mivar Press, 2005.

RUSSELL, S. J.; NORVIG, P. *Artificial Intelligence - A Modern Approach*. 2a. ed. Upper Saddle River, New Jersey: Pearson Education, 2003.

SAKAMOTO, K. *Como implementar um call center*. São Paulo: Happy Few, 2001.

SHEN, H.; HUANG, J. Z. Interday forecasting and intraday updating of call center arrivals. *Manufacturing & Service Operations Management*, v. 10, n. 3, p. 391–410, 2008.

SOUZA, R. A. de. *Otimização das escalas de trabalho dos atendentes e dimensionamento de um Call Center receptivo*. Tese (Doutorado) — Universidade Federal de Santa Catarina, Florianópolis, SC, 2010.

SOYER, R.; TARIMCILAR, M. M. Modeling and analysis of call center arrival data: A bayesian approach. *Management Science*, INFORMS, v. 54, n. 2, p. 266–278, 2008.

TAYLOR, J. W. A comparison of univariate time series methods for forecasting intraday arrivals at a call center. *Management Science*, INFORMS, Institute for Operations Research and the Management Sciences, Linticum, Maryland, USA, v. 54, p. 253–265, 2008.

TIBIRIÇÁ, C. A. G.; NASSAR, S. M. Desenvolvimento de uma abordagem híbrida difuso-probabilística para a modelagem da incerteza. Departamento de Informática e Estatística. nov. 2003.

WEINBERG, J.; BROWN, L. D.; STROUD, J. R. Bayesian forecasting of an inhomogeneous poisson process with applications to call center data. to appear. *Journal of the American Statistical Association*, v. 102, p. 1185–1198, 2007.