

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

Cristiane Bündchen

**PREVISÃO DE DEMANDA TURÍSTICA E A
ACURÁCIA DAS PREVISÕES FRENTE À
REALIZAÇÃO DE MEGAEVENTOS**

Porto Alegre

2016

Cristiane Bündchen

**Previsão de demanda turística e a acurácia das previsões frente à realização de
megaeventos**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal do Rio Grande do Sul como requisito parcial à obtenção do título de Mestre em Engenharia de Produção, modalidade Acadêmica, na área de concentração em Sistemas de Qualidade.

Orientadora: Liane Werner, Dr^a.

Porto Alegre

2016

Cristiane Bündchen

Previsão de demanda turística e a acurácia das previsões frente à realização de megaeventos

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia de Produção na modalidade Acadêmica e aprovada em sua forma final pelo Orientador e pela Banca Examinadora designada pelo Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal do Rio Grande do Sul.

Prof^a. Liane Werner, Dr^a.

Orientador PPGEP/UFRGS

Prof. José Duarte Ribeiro, Ph.D.

Coordenador PPGEP/UFRGS

Banca Examinadora:

Professor Michel Anzanello, Ph.D (PPGEP/UFRGS)

Professora Mary Sandra Guerra Ashton, Dr^a (FEEVALE)

Professora Vera Lúcia Milani Martins, Dr^a. (IFRS)

Dedico esta dissertação aos meus pais.

RESUMO

O turismo entrou em um período de forte expansão após a Segunda Guerra Mundial que perdura até os dias atuais. O aumento da circulação de turistas repercute na geração de renda e empregos para os países visitados, além do enriquecimento adquirido através das trocas culturais. Este crescimento tem despertado o interesse da comunidade científica, bem como profissional, com o intuito de explorar as metodologias para a modelagem e previsão da demanda turística. Estimativas acuradas da demanda servem de apoio para corretas tomadas de decisão por parte dos gestores quanto ao dimensionamento adequado de recursos financeiros, especialmente frente à realização de um evento de grandes proporções. Neste sentido, este trabalho tem por objetivos verificar quais são as técnicas atualmente mais utilizadas para previsão de demandas turísticas através de revisão da literatura, desde 2005 até 2015; utilizar dois métodos de modelagem (ARIMA e RNA) para modelar e prever a demanda turística de duas sedes olímpicas recentes; comparar essas previsões com as previsões obtidas por cinco métodos de combinação de previsões (médias aritmética, harmônica e geométrica, variância mínima e regressão linear) e; aplicar o método mais acurado para prever a demanda turística do Brasil. Os resultados foram avaliados através de três medidas de acurácia. Em virtude da realização dos Jogos Olímpicos em 2016, a demanda brasileira para este período foi modelada e prevista e a previsão foi ajustada segundo um ajuste matemático sazonal, objetivando ganho de acurácia. Foi observado ganho de acurácia quando as previsões foram combinadas e, na série brasileira, o ajuste adotado indicou um acréscimo de 175% na demanda original para agosto de 2016.

Palavras-chave: Previsão de demanda, Turismo, Acurácia, Megaeventos

ABSTRACT

Tourism has experienced a strong increase since the end of World War II. The increase in tourist circulation results in income and employment expansion, besides the cultural enrichment involved in such experiences. This growth has attracted attention from the scientific community as well as professional, with the objective of exploring the methodologies for tourism demand modelling and forecasts. Accurate demand estimates serve as support for correct decision making by managers especially considering financial resource scaling for major events. In this sense, this study aims to verify which techniques are more currently used for forecasting tourism demand through review of the literature from 2005 to 2015; using two modeling methods (ARIMA and ANN) to make models and forecasting the tourism demand of two recent Olympic hosts; comparing these forecasts with the forecasts obtained for five methods of combining forecasts (arithmetic, harmonic and geometric means, minimum variance and linear regression) and; applying the most accurated method to forecast the tourism demand in Brazil. The results were evaluated using three different accuracy measurements. By virtue of the 2016 Olympic Games, the Brazilian tourism demand was modeled and the forecast was adjusted by a seasonal mathematical adjustment, designed for better precision. A gain in preciseness was observed when forecasts were combined and, for the Brazilian series, the adopted adjustment indicated an increase of 175% when compared with the original demand for August 2016.

Keywords: Demand forecast, Tourism, Accuracy, Megaevents

LISTA DE ABREVIATURAS E SIGLAS

ADLM: <i>Autoregressive Distributed Lag Model</i>	ESSS: <i>Exponential Smoothing Based On</i>
EC-ADLM: <i>Error Correction - Autoregressive</i>	
<i>distributed lag model</i>	EUA: <i>Estados Unidos da América</i>
RE-ADLM: <i>Reduced Autoregressive</i>	FCM: <i>Fuzzy c-means</i>
<i>Distributed Lag Model</i>	FIFA: <i>Fédération Internationale de Football</i>
AFuzzy: <i>Adaptive Fuzzy Time Series Model</i>	<i>Association</i>
AIDS: <i>Almost Ideal Demand Models</i>	FSARIMA: <i>Fourier-modified seasonal ARIMA</i>
ANFIS: <i>Adaptive Neuro-Fuzzy Inference</i>	FOURIER: <i>Fourier analysis</i>
<i>System</i>	FTDN: <i>Focused Tapped Delay Line Neural</i>
ANN: <i>Artificial Neural Networks</i>	<i>Network</i>
ARIMA: <i>Autoregressive Fractionally</i>	FUZZY: <i>Fuzzy Time Series Model</i>
<i>Integrated Moving Average</i>	GA: <i>Genetic Algorithms</i>
ARFIMA: <i>Autoregressive Integrated Moving</i>	GARCH: <i>Generalized Autoregressive</i>
<i>Average</i>	<i>Conditional Heteroskedasticity</i>
BPN: <i>Back-propagation neural network</i>	GEO: <i>Geometric Mean</i>
BSM: <i>Basic Structural Model</i>	GEOW: <i>Weighted geometric mean</i>
CGA: <i>Chaotic Genetic Algorithm</i>	GEPM: <i>Grey Envelop Prediction Model</i>
CGE: <i>General Equilibrium Model</i>	GFA: <i>Gaussian-Fitting Algorithm</i>
COMB: <i>Combinação via regressão linear</i>	GM: <i>Grey Model</i>
CP: <i>Cubic Polinomial Model</i>	GP: <i>Goal programming</i>
DEL: <i>Delphi method</i>	GPR: <i>Gaussian process regression</i>
DIM: <i>Diffusion Index Models</i>	HARMW: <i>Weighted harmonic mean</i>
DMA: <i>Double Moving Average</i>	HCA: <i>Hierarchical Cluster Analysis</i>
DMSFE: <i>Discounted Mean Square Forecast</i>	HIER: <i>Hierarchical Forecast Combination</i>
<i>Error</i>	INV-MSE: <i>Inverse of the Mean Square Error</i>
ECM: <i>Error Correction Model</i>	IOWA: <i>Induced Ordered Weighted Averaging</i>
ELMANN: <i>Elmann Neural Networks</i>	JML-ECM: <i>Johansen maximum likelihood</i>
EMBRATUR: <i>Instituto Brasileiro do Turismo</i>	<i>error correction model</i>
EMD: <i>Empirical Mode Decomposition</i>	WB-ECM: <i>Wickens and Breusch error</i>
EMN: <i>Electromagnetism-like Mechanism</i>	<i>correction model</i>
<i>Neural Network</i>	LTL: <i>Long Trend Line</i>
ES: <i>Exponential smoothing</i>	LSE: <i>Least squares estimation</i>

LLS-SVR: <i>Least-Squares Support Vector Regression</i>	SARS: <i>Severe Acute Respiratory Syndrome</i>
MA: <i>Moving Average</i>	SETAR: <i>Self-Exciting Threshold AutoRegressive Model</i>
MAE: <i>Mean Absolute Error</i>	SHIRNK: <i>Shrinkage Method</i>
MAPE: <i>Mean Absolute Percentage Error</i>	SOM: <i>Self- Organizing Map</i>
MGFFS: <i>Modular Genetic-Fuzzy Forecasting System</i>	SSA: <i>Singular Spectrum Analysis</i>
MI: <i>Modelagem individual</i>	STL: <i>Short Trend Line</i>
MKTAR: <i>Markov Switching Model</i>	SVM: <i>Support Vector Machine Model</i>
MLOG: <i>Logistic Model</i>	SVR: <i>Support Vector Regression</i>
MLP: <i>Multi-Layer Perception Neural Networks</i>	SW: <i>Sine-Wave Time-Series Regression</i>
MSE: <i>Mean Square Error</i>	SWITCH: <i>Method based on testing the performance difference</i>
MSVM: <i>Multifactor Support Vector Machine Model</i>	TDFS: <i>Web-Based Tourism Demand Forecasting System</i>
Naive 1: <i>No Change Model</i>	TC: <i>Técnicas de combinação</i>
Naive 2: <i>Constant Growth Model</i>	TVP: <i>Time-Varying-Parameter Model</i>
NM: <i>Nelder-Mead Simplex Method</i>	TVP-EC: <i>Time-Varying-Parameter error correction Model</i>
OMT: <i>Organização Mundial do Turismo</i>	TVP-EC-LAIDS: <i>Time Varying Parameter Linear Almost Ideal Demand System Models In Short-Run Error Correction Form</i>
PASIP: <i>Partitive Simulation Process</i>	TVP-LR-LAIDS: <i>time varying parameter linear almost ideal demand system models in long-run static form</i>
PIB: <i>Produto Interno Bruto</i>	UTM: <i>Utility Theory Model.</i>
PLM: <i>Piecewise Linear Function</i>	VACO: <i>Variance-Covariance Method</i>
RAE: <i>Regiões Administrativas Especiais</i>	VAR: <i>Vector Autoregressive model</i>
RANK: <i>Rank Based Weighting</i>	VAR-NO-COR: <i>Variance Based Method</i>
RBF: <i>Radial Basis Function Network</i>	WC: <i>Weight combination Method</i>
REG: <i>Regression analysis</i>	WTV: <i>Willingness-To-Visit Survey</i>
RNA: <i>Redes Neurais Artificias</i>	
RMSE: <i>Root Mean Square Error</i>	
RMSPE: <i>Root Mean Square Percentage Error</i>	
SA: <i>Simple Average</i>	

LISTA DE FIGURAS E QUADROS

CAPÍTULO II: Artigo 1

Figura 1: Processo de consolidação dos artigos encontrados	25
Figura 2: Evolução temporal das publicações	27
Quadro 1: Artigos mapeados de acordo com a abordagem exploratória.....	30
Quadro 2: Artigos de carácter de proposição	33
Quadro 3: Artigos que utilizaram métodos de combinações	35

CAPÍTULO III: Artigo 2

Figura 1: Etapas da análise de cada série de dados	59
Quadro 1: Medidas de acurácia utilizadas	60
Figura 2: Número de chegadas internacionais no Reino Unido (jan/1980 – julho/2011)	64
Figura 3: Número de chegadas internacionais na Grécia (jan/1994 – ago/2003).....	64

CAPÍTULO IV: Artigo 3

Figura 1: Etapas da análise da série histórica	78
Figura 2: Procedimento para cálculo dos componentes sazonais.....	79
Quadro 1: Medidas de acurácia utilizadas	80
Figura 3: Número de chegadas internacionais na Brasil (jan/2003 – dez/2014).....	81

LISTA DE TABELAS

CAPÍTULO I: Introdução

Tabela 1: Variação do número de chegadas internacionais.....	14
--	----

CAPÍTULO II: Artigo 1

Tabela 1: Quantidade de artigos encontrados por base de dados	24
Tabela 2: Quantidade de artigos conforme periódico e ano de publicação	26
Tabela 3: Autores com maior volume de publicações no período.....	26
Tabela 4: Principais medidas de acurácia encontradas.....	28
Tabela 5: Principais países emissores e receptores analisados	29

CAPÍTULO III: Artigo 2

Tabela 1: Pesos utilizados em cada técnica de combinação	62
Tabela 2: Medidas de acurácia dentro do período de modelagem.....	63
Tabela 3: Acurácia das predições para a demanda britânica, de acordo com período	64
Tabela 4: Acurácia das predições para a demanda grega, de acordo com período	66
Tabela 5: Medidas de acurácia fora do período de modelagem – 12 meses.....	67
Tabela 6: Demandas turísticas observada e prevista para o mês de realização do evento	68

CAPÍTULO IV: Artigo 3

Tabela 1: Medidas de acurácia para as predições	82
Tabela 2: Acurácia das predições para a demanda brasileira, de acordo com período	83
Tabela 3: Previsões inicial e ajustada pelo índice sazonal	84

SUMÁRIO

I. INTRODUÇÃO	13
1.1 COMENTÁRIOS INICIAIS	13
1.2 TEMA E OBJETIVOS	15
1.3 JUSTIFICATIVA.....	16
1.4 MÉTODO.....	17
1.5 DELIMITAÇÕES DO TRABALHO.....	18
1.6 ESTRUTURA DO TRABALHO	19
II. ARTIGO 1: PREVISÃO DE DEMANDA TURÍSTICA: UMA REVISÃO DA LITERATURA ENTRE 2005 E 2015.....	21
1. INTRODUÇÃO	22
2. PROCEDIMENTOS METODOLÓGICOS.....	23
3. ARTIGOS MAPEADOS	25
4. CONSIDERAÇÕES FINAIS	42
REFERÊNCIAS	44
III. ARTIGO 2: COMPARAÇÃO DA ACURÁCIA DE PREVISÕES DE DEMANDA TURÍSTICA EM SEDES OLÍMPICAS	53
1. INTRODUÇÃO	54
2. O TURISMO DE MEGAEVENTOS E SUAS PREVISÕES	56
3. TÉCNICAS DE PREVISÃO	57
4. PROCEDIMENTOS METODOLÓGICOS	61
5. RESULTADOS	63
6. DISCUSSÕES E CONCLUSÕES	71
REFERÊNCIAS	72
IV. ARTIGO 3: PREVISÃO DA DEMANDA TURÍSTICA BRASILEIRA PARA OS JOGOS OLÍMPICOS 2016 COM AJUSTE MATEMÁTICO	75
1. INTRODUÇÃO	76
2. TÉCNICAS DE PREVISÃO	77
3. PROCEDIMENTOS METODOLÓGICOS	81
4. RESULTADOS	84
5. DISCUSSÕES E CONCLUSÕES	88
REFERÊNCIAS	89

V. CONSIDERAÇÕES FINAIS	92
5.1 DISCUSSÕES E CONCLUSÕES	92
5.2 SUGESTÕES PARA TRABALHOS FUTUROS.....	90
REFERÊNCIAS	94

I. INTRODUÇÃO

1.1 Comentários iniciais

Barretto (2006) comenta que alguns autores atribuem os inventores da moeda e do comércio, os fenícios, como sendo os primeiros viajantes, enquanto que outros situam o início do turismo na Grécia antiga onde as pessoas viajavam para ver os Jogos Olímpicos a cada quatro anos. Decorrido muito tempo após esses precursores do turismo, o período das grandes viagens transoceânicas, que resultaram no descobrimento de diversos países, caracterizou o turismo de elite, onde os futuros dirigentes da classe dominante eram incentivados a viajar pelo espírito de aventura e pela aquisição de experiência de vida em outro país (BARRETTO, 2006).

Com o passar do tempo, diversas definições de turismo surgiram, sempre vinculadas ao tema viagens. Para Panosso Neto (2010), turismo remete uma idéia de férias para o turista; lucro, para o empreendedor; geração de emprego e renda, para os trabalhadores e desenvolvimento local, para a comunidade. Em síntese, a Organização Mundial do Turismo (OMT) define que o turismo compreende todas as atividades realizadas durante uma viagem e estadia diferentes do entorno habitual, por um período consecutivo inferior a um ano (OMT, 2001).

Um conceito interessante mencionado por Boyer (2003) é o de turismo de massa, que é caracterizado pela grande quantidade de turistas que tem acesso ao turismo. Após a Segunda Guerra Mundial houve um acesso facilitado à diversão e ao lazer, pois foi um período caracterizado por grandes conquistas das classes trabalhadoras como, por exemplo, férias remuneradas (TRIGO, 1998), além do desenvolvimento dos meios de comunicação (BOYER, 2003). Urry (2001) salienta que este fenômeno representa uma democratização da viagem, já que até então viajar era privilégio somente de quem era das classes sociais mais abastadas. O crescimento do turismo foi notório, onde em 1950, período subsequente a Segunda Guerra Mundial, foram contabilizadas mundialmente 25 milhões de chegadas internacionais, enquanto que em 2014 este número bateu todos os recordes, chegando a 1.133 milhões (WTO, 2015a).

Com base nessas informações a partir de 1950, o turismo apresentou queda em apenas quatro períodos: 1982, 2001, 2003 e 2009. Em 1982 a retração ocorreu devido às restrições aplicadas às viagens no Leste Europeu e Europa Central, ocorridas pelo estado de sítio na Polônia e pelo clima econômico desfavorável. Já em 2001 a queda justificou-se pelos

atentados de 11 de setembro em Nova Iorque o que gerou um ambiente de insegurança. A queda em 2003 foi devido a múltiplos fatores como a guerra no Iraque, o surgimento do vírus *Severe Acute Respiratory Syndrome* (SARS) na China, que se espalhou para outros países, além do adiamento do relançamento da economia mundial. A queda mais recente, em 2009, deu-se devido ao clima de instabilidade econômica e financeira mundial (DANIEL, 2010).

Passada a crise econômica de 2009, o número de turistas internacionais voltou a aumentar até os dias atuais. Em 2014 foram observadas cerca de 46 milhões de chegadas internacionais a mais que em 2013, o que representou um aumento de 4,2%, conforme pode ser observado na Tabela 1. A região das Américas foi a que apresentou maior aumento em 2014, 8,4% em relação a 2013, correspondendo a 14,1 milhões de chegadas adicionais. Destaque também para a região do Oriente Médio que apresentou crescimento em 2014 depois da queda observada na comparação 2013/2012 (WTO, 2015b).

A Tabela 1 também apresenta projeções para 2015, onde são esperados novos recordes uma vez que com as informações obtidas no período de janeiro a agosto, com relação ao mesmo período em 2014, o crescimento observado foi similar ao encontrado na comparação de 2014/2013. Já para a região das Américas também se espera crescimento, porém inferior aos 8,4% encontrados anteriormente.

Tabela 1: Variação do número de chegadas internacionais

Região	Variação (%)			
	2012/11	2013/12	2014/13	2015/14*
Mundo	4,6	4,6	4,2	4,3
Europa	3,9	4,8	2,4	5,3
Ásia e Pacífico	7,0	6,9	5,7	4,3
Américas	4,5	3,1	8,4	4,2
África	4,7	4,7	1,8	-5,4
Oriente Médio	1,7	-2,9	6,2	3,6

* Calculada com base de janeiro a agosto

Fonte: Organização Mundial do Turismo (OMT)

A circulação de turistas repercute em renda para os países visitados. Segundo dados fornecidos pela OMT, em 2014 foram arrecados US\$1.245 bilhões com serviços de acomodação, alimentação, entretenimento e compras. Em termos relativos, esta arrecadação foi 3,7% superior à observada em 2013, sendo que na América do Sul esse aumento foi ainda mais expressivo, 5,7% para o mesmo período. Curiosamente, os turistas brasileiros estão na décima posição entre os que mais gastam em viagens internacionais, apesar da crise econômica pela qual o país passa, sendo que gastaram mais de US\$25 bilhões em 2014 (WTO, 2015a).

Em virtude da alta circulação de dinheiro, para muitos países o turismo é um catalizador da economia local através da geração de emprego e renda. No Brasil, de acordo com dados fornecidos pelo Instituto Brasileiro do Turismo (EMBRATUR), o turismo representa 3,6% do Produto Interno Bruto (PIB), gerando emprego, direta e indiretamente, para mais de 10 milhões de pessoas (EMBRATUR, 2015). Além do cunho econômico, o desenvolvimento do turismo, quando bem planejado, pode ajudar na preservação de parques, na manutenção de áreas de recreação públicas e locais históricos e na valorização de hábitos e costumes locais (BARBOSA, 2005).

Tendo em vista o desenvolvimento de uma região, ter um bom planejamento é fundamental. Os tomadores de decisão necessitam ter em mãos previsões confiáveis e acuradas acerca da demanda turística, a fim de realizar um correto dimensionamento de recursos destinados a investimentos (GOH; LAW, 2002). Esta necessidade foi percebida pela comunidade científica que tem publicado estudos com foco na modelagem e previsão da demanda turística (SONG; LI, 2008). De acordo com a revisão realizada por Li, Song e Witt (2005), 420 estudos sobre o tema de previsão de demanda turística foram publicados durante o período 1960-2002, sendo o foco da maioria a aplicação de diferentes técnicas, tanto qualitativas como quantitativas, para modelar e prever a demanda turística dos mais diversos destinos.

Por fim, em situações que compreendem grande volume de turistas em curtos períodos, como na realização de megaeventos esportivos, por exemplo, a demanda turística precisa ser muito bem estimada para que os gestores possam investir corretamente os recursos financeiros em limpeza e renovação dos espaços das cidades, novas instalações e melhoria da infraestrutura de transportes e aeroportos (LONDON ASSEMBLY, 2007). Uma demanda subestimada resultaria em sérios prejuízos para o país anfitrião como congestionamento dos pontos de entrada e atrações turísticas, dificuldade de acesso ao transporte, baixos níveis de qualidade dos serviços, degradação da imagem do país, além da perda de oportunidades de mercado (TIDESWELL; MULES; FAULKNER, 2001; STEKLER, 2003).

1.2 Tema e objetivos

O tema desta dissertação é previsão da demanda turística com avaliação da acurácia dessas estimativas.

O objetivo principal é obter uma estimativa acurada para a demanda turística do Brasil no período de início dos Jogos Olímpicos, agosto de 2016. Os objetivos secundários são:

- Verificar por meio de uma revisão sistemática quais as técnicas atualmente mais utilizadas para previsão de demandas turísticas;
- Utilizar dois métodos de modelagens, um linear e outro não linear, para modelar e prever a demanda turística das últimas sedes olímpicas;
- Comparar as previsões geradas por cada método de modelagem com as previsões obtidas por cinco métodos de combinação de previsões: médias aritmética, harmônica e geométrica, variância mínima e regressão linear;
- Aplicar o método mais acurado para prever a demanda turística do Brasil, ajustando as previsões através de ajuste matemático.

1.3 Justificativa

Após a crise econômica de 2009, o número de turistas internacionais só aumentou. Em 2014, a região das Américas apresentou um crescimento de 8,4% no volume de chegadas internacionais em relação a 2013, enquanto que mundialmente o crescimento foi de 4,2% (WTO, 2015b). Especificamente no Brasil, dados divulgados no Anuário Estatístico de 2015 do Ministério Brasileiro do Turismo mostraram que o número de chegadas internacionais aumentou 10,6% em 2014 em relação a 2013 (BRASIL, 2015).

Esse grande volume de turistas oportuniza a geração de renda para os países visitados. De acordo com os dados mundiais fornecidos pela OMT, verificou-se que, em 2014, o gasto com serviços de acomodação, alimentação, entretenimento e compras foi de US\$ 1.099, por turista. A renda obtida através desses serviços foi 3,7% superior à observada em 2013, sendo que na América do Sul esse aumento foi ainda mais expressivo, 5,7%, para o mesmo período (WTO, 2015b).

Dessa forma, para muitos países o turismo é uma importante fonte de circulação de dinheiro, o que alavanca a economia local através da geração de emprego e renda. De acordo com dados do Instituto Brasileiro do Turismo, o turismo brasileiro representa 3,6% do PIB (Produto Interno Bruto), gerando emprego, direta e indiretamente, para mais de 10 milhões de pessoas (EMBRATUR, 2015). Em paralelo à visão econômica, o turismo pode atuar como catalizador da valorização de hábitos e costumes locais frente à globalização, uma vez que estes aspectos caracterizam a diferença entre os povos (BARBOSA, 2005). Em virtude das razões expostas se salienta a necessidade de voltar esforços para o melhor conhecimento nessa área.

Fatores como sazonalidade (FOURIE; SANTANA-GALLEG0, 2011), condições climáticas (GOH, 2012), atentados (CHEN, 2005), surto de doenças (MIN, 2008) e crises econômicas (POUDYAL; PAUDEL; TARRANT, 2013) são alguns exemplos de fenômenos que podem impactar negativamente o volume de visitas a um determinado local, porém a realização de algum evento esportivo de grandes proporções como, por exemplo, a Copa do Mundo (FIFA) (MARTINS, WERNER; BELLEZA, 2013), gera visibilidade e impactos positivos na demanda turística.

Megaeventos envolvem grandes volumes de público, gastos do setor público, mercado consumidor, cobertura da mídia, construção de instalações e tem impacto sobre a economia e a sociedade do país anfitrião (HALL, 2006). Além desses legados físicos apontados, Roche (1994) destaca a imagem e a identidade da nação anfitriã como legados subjetivos que, segundo Santovito (2010), também servem como atrativo para a chegada de novos turistas após a realização do evento.

O conhecimento da capacidade turística de um país, principalmente diante da realização de um megaevento, auxilia na tomada de decisão quanto a investimentos em melhorias de serviços, infraestruturas, transporte, etc e a utilização de modelos preditivos, que geram estimativas confiáveis do volume de turistas, serve de importante ferramenta para que tais decisões sejam corretas (MOURA; MONTINI, 2010). Diante da ausência de consenso quanto um tipo de modelagem que seja mais adequado para prever demanda turística em qualquer situação (SONG; LI, 2008; SONG; HYNDMAN, 2011), a utilização de combinação de previsões é uma boa alternativa para fins de acurácia segundo Song e Li (2008).

1.4 Método

Esta pesquisa se caracteriza de natureza aplicada devido à finalidade prática e a abordagem é quantitativa com ênfase em análises numéricas. Os objetivos visam maior conhecimento sobre o assunto estudado, sendo do tipo exploratório.

Este trabalho foi desenvolvido em três etapas sequenciais, durante o ano de 2015, que podem ser resumidas em: 1) pesquisa bibliográfica, efetuada em agosto; 2) investigação, realizada em outubro; e 3) aplicação, executada em dezembro. A pesquisa bibliográfica foi realizada através de uma revisão sistemática para identificar as metodologias utilizadas para previsão de demanda turística. A segunda etapa compete à investigação da acurácia das modelagens e combinações de previsões frente à ocorrência de megaeventos em países que já foram sedes olímpicas. O método mais acurado na segunda etapa foi aplicado para a previsão

da demanda brasileira para os Jogos Olímpicos de 2016, na terceira etapa. Os softwares utilizados para armazenamento e análise dos dados foram planilha eletrônica, SPSS v.18 e GRETL 2015.

A revisão sistemática apresentada no Artigo 1 é resultado do mapeamento de artigos que abordaram previsões de demanda turística, publicados entre janeiro de 2005 a agosto de 2015 em periódicos nacionais e internacionais. Buscou-se por artigos que tivessem em seu resumo os termos *forecast* AND touris* AND demand*, sendo o caractere curinga “*” utilizado para recuperar variações dos sufixos que poderiam ser empregados, o idioma inglês e livros ou capítulos de livros foram desconsiderados. Após filtros de seleção, 135 artigos foram caracterizados pelo periódico, pelo ano de publicação e pela autoria. A classificação das abordagens foi realizada com base 129 artigos, pois seis artigos se tratavam de revisões ou resumos da literatura e foram analisados separadamente dos demais em uma categoria própria. No Artigo 2, a demanda turística de duas sedes olímpicas recentes, Reino Unido e Grécia, foi modelada por uma metodologia que captura efeitos lineares (modelos ARIMA), e por uma metodologia capaz de capturar efeitos não lineares (modelos de RNA). Foi analisada a acurácia das previsões geradas por estas metodologias bem como dessas previsões combinadas por cinco técnicas: médias aritmética, harmônica e geométrica, variância mínima e regressão linear. A avaliação deu-se de forma equivalente pelas três medidas de acurácia mais observadas no levantamento apresentado no Artigo 1: MAPE (*Mean Absolute Percentage Error*), RMSE (*Root Mean Square Error*) e MAE (*Mean Absolute Error*).

Por fim, a metodologia que gerou previsões mais acuradas no Artigo 2, de acordo com as medidas de acurácia avaliadas, foi aplicada para gerar as previsões da demanda turística brasileira para os Jogos Olímpicos de 2016 (Artigo 3) e esta previsão foi corrigida através de um ajuste matemático sazonal com base no adicional de chegadas observadas em 2014 durante a realização da Copa do Mundo (FIFA).

1.5 Delimitações do trabalho

A pesquisa na literatura sobre previsão de demanda com aplicações no turismo não contemplou todos os trabalhos desenvolvidos e aplicados com esta finalidade, uma vez que a busca foi delimitada aos periódicos registrados no portal da Capes e contemplou 10 bases de dados. Além disso, alguns artigos não estavam disponibilizados no Brasil e não houve retorno por parte dos autores. Portanto, estes artigos não puderam ser analisados, sendo excluídos na etapa de leitura da introdução e resultados.

As técnicas de previsão utilizadas foram restringidas à metodologia de Box-Jenkins (ARIMA) e ao modelo de RNA *Perceptron* multicamadas (MLP). Analogamente, as técnicas de combinação escolhidas para o estudo foram: médias aritmética, harmônica e geométrica, variância mínima e regressão linear. A verificação da qualidade das previsões foi realizada através de três medidas: MAPE, RMSE e MAE.

A opção de substituir uma observação atípica na série brasileira por uma estimativa obtida de acordo com um ajuste por índices sazonais foi realizada com o intuito de alterar o mínimo possível a série original, sendo outras alternativas de ajuste possíveis como, por exemplo, através da média mensal simples. Para o ajuste da previsão final, outras opções de ajuste também eram possíveis como, por exemplo, a utilização do erro de previsão observado em outras sedes olímpicas no mês de realização do evento.

1.6 Estrutura do trabalho

Esta dissertação está organizada em formato de artigos científicos e dividida em cinco capítulos, incluindo este capítulo introdutório. Neste capítulo são apresentados os comentários iniciais, o tema, os objetivos principal e específicos, a justificativa, a metodologia utilizada, algumas delimitações do estudo e por último a sua estrutura.

Nos capítulos 2 a 4 são apresentados os artigos que respondem aos objetivos específicos desta pesquisa. O primeiro artigo intitulado “Previsão de demanda turística: uma revisão da literatura entre 2005 e 2015” foi desenvolvido a partir da revisão sistemática sobre o atual cenário das metodologias utilizadas para a previsão de demanda turística. Algumas características principais foram verificadas como as variáveis que representavam a demanda turística, as medidas de acurácia utilizadas e os principais países emissores e receptores de turistas analisados. Quanto à abordagem, os artigos foram apresentados pelo caráter exploratório, propositivo de modelos e de combinação de previsões. Este artigo foi submetido em março de 2016 na *Communication in Statistics – Theory and Methods*.

O segundo artigo intitulado “Comparação da acurácia de previsões de demanda turística em sedes olímpicas” é o resultado da utilização de duas modelagens (ARIMA e RNA), que procuram explicar através de modelos estatísticos o comportamento dos dados e geram previsões para a demanda turística de dois países que sediaram os Jogos Olímpicos de verão (Reino Unido e Grécia). O desempenho das previsões de cada modelagem é também comparado com o desempenho dessas previsões combinadas por cinco métodos tradicionais de combinação: médias aritmética, harmônica e geométrica, variância mínima e regressão

linear. A acurácia das previsões é analisada através de três medidas: MAPE, RMSE e MAE. A combinação via regressão linear melhorou a acurácia das previsões para o mês de início dos Jogos em cada sede analisada, sendo que as previsões apresentaram alta acurácia mesmo no período de realização do evento. Este artigo foi submetido para publicação em março de 2016 na Revista Journal of Applied Statistics.

No artigo 3 “Previsão da demanda turística brasileira para os Jogos Olímpicos 2016”, a demanda turística do Brasil para o mês de agosto de 2016 é prevista utilizando a metodologia que apresentou melhor desempenho no Artigo 2 e a previsão é ajustada através de um acerto matemático sazonal obtido com informações sobre os dados de 2003 a 2013 daquela série. A acurácia das previsões é analisada através de três medidas: MAPE, RMSE e MAE. Este artigo foi submetido para publicação em março de 2016 na Revista Produção.

Por fim, no Capítulo 5 são abordadas as considerações finais desta dissertação referentes às discussões e conclusões do resultados obtidos e algumas sugestões para trabalhos futuros.

II. ARTIGO 1: Previsão de Demanda Turística: Uma Revisão da Literatura entre 2005 e 2015

Resumo: Devido à relevante contribuição do setor de turismo para o desenvolvimento socioeconômico de uma região - sendo responsável pela geração de um em cada onze empregos no mundo (277 milhões), em 2014 - o conhecimento deste mercado é primordial. Após uma criteriosa seleção, 135 artigos sobre previsão de demanda turística publicados entre os anos de 2005 e 2015 foram analisados, sendo 6 analisados separadamente. Os resultados encontrados revelam que a principal medida de demanda turística é o número de chegadas e a medida de acurácia mais comumente utilizada nas publicações é o MAPE. Os artigos de caráter exploratório foram os mais encontrados, sendo alguns voltados para a avaliação da influência de fatores não econômicos na demanda turística. Destaque também para o desenvolvimento de novos modelos resultantes da combinação de modelos de séries temporais ou econométricos com modelos de inteligência artificial e também o surgimento de novas técnicas de ponderação para combinação de previsões.

Palavras-chave: previsão; demanda turística; revisão da literatura; combinação de previsões.

Abstract: Because of the relevant contribution from the touristic sector for the social and economic development of a region – tourism is responsible for the generation of one in every eleven job opportunities in the world (277 million in 2014) -, understanding this market sector is primordial. After a thorough selection, 135 articles about tourism demand forecasting published between 2005 and 2015 were analyzed, six analyzed separately. The results found reveal that the principal measurement of tourism demand is the number of arrivals and that the accuracy measuring most commonly utilized in publications is MAPE. Most articles were of an exploratory character, some aimed toward the evaluating of non-economic factors in touristic demand. The development of new models resulting from the combination of time series or econometric models with artificial intelligence must also be highlighted, as well as the advent of new ponderation techniques for forecast combination.

Keywords: Forecast; Tourism demand; Literature revision; Forecast combination.

1. Introdução

O setor de turismo, juntamente com as atividades que o engloba, é de extrema relevância, uma vez que estimula o crescimento da economia. Atividades como o comércio, transportes, hotelaria, alimentação, artesanato; bem como o desenvolvimento de infraestrutura, por meio da construção e manutenção de rodovias e aeroportos, melhores condições de geração e distribuição de energia, implantação e manutenção de sistemas de comunicações, entre outras atividades, além da geração direta e indireta de empregos e renda local são beneficiadas com o aumento do fluxo de turistas (CUNHA; CUNHA, 2006). No ano de 2014, o setor turístico foi responsável pela geração de um em cada onze empregos no mundo (277 milhões), além de contribuir para economia global com cerca de US\$ 7,6 trilhões (9,8% do PIB) (WTTC, 2015).

O número de turistas internacionais mundialmente só aumentou após a crise de 2009. O ano de 2014 apresentou aumento de cerca de 46 milhões de turistas (4,2%) em relação ao ano anterior e estima-se que em 2015 aumente de 3% a 4% em relação a 2014 (WTO, 2015a). Ainda, segundo o relatório da Organização Mundial do Turismo (OMT), a região das Américas, em 2014, teve aumento de 8,4% em relação ao ano anterior, com destaque para o crescimento de 9,5% da América do Norte, que na comparação de 2013/2012 havia crescido apenas 3,6%. O Brasil, apesar da desvalorização do real frente ao dólar e do lento crescimento econômico, em 2014 teve aumento de 10,6% no número de chegadas de turistas internacionais em relação a 2013, muito provavelmente devido a realização da Copa do Mundo de futebol (FIFA).

Devido à acentuada contribuição do turismo no desenvolvimento socioeconômico de uma região, o conhecimento do mercado em que atua é primordial. Segundo Moura e Montini (2010), a utilização de modelos preditivos para a estimação da demanda auxilia na tomada de decisão por parte dos gestores, como no dimensionamento da capacidade produtiva ou mesmo no gerenciamento da mão-de-obra. Sendo assim, para adequar as necessidades apresentadas pelo setor é preciso realizar previsões da sua demanda.

Witt e Song (2002) citaram o local (origem/destino) e também o tamanho do horizonte de previsão como fatores que afetam a boa capacidade de um modelo fazer previsões acuradas. Peng, Song e Crouch (2014), além desses fatores, citaram também a época da viagem, a forma de mensuração da demanda, o tamanho da amostra e o método de modelagem adotado, como possíveis fatores de influência da capacidade preditiva de um modelo. De forma geral, não há consenso quanto à escolha de um modelo único ideal capaz

de gerar boas previsões em todas as situações, contudo na modelagem econométrica, as previsões estimadas por modelos de regressão com parâmetros variáveis no tempo via Filtro de Kalman e modelagem estrutural de séries temporais com variáveis causais apresentaram bom desempenho em grande parte dos estudos analisados por Li, Song e Witt (2005).

Na área do turismo, como em diversas outras áreas, pode-se utilizar combinação de previsões geradas por diferentes modelos. Há cada vez mais evidências, por meio de estudos empíricos, que o método de combinar previsões, desenvolvido originalmente por John Bates e Clive Granger em 1969, gera previsões mais acuradas em comparação com as previsões individuais (ANDRAWIS; ATIYA; EL-SHISHINY, 2011; CHENG; LIU, 2014). Em 1984, ao analisarem a previsão para a demanda de turistas na Flórida, Fritz, Brandon e Xander (1984) concluíram que a precisão das previsões geradas pelos modelos de regressão e pelos modelos ARIMA (*Auto-Regressive Integrated Moving Average*) era inferior à precisão das previsões combinadas por estes dois modelos. Ao analisarem a demanda turística oriunda do Reino Unido para sete outros países, Shen, Li e Song (2011) concluíram que, em geral, as previsões combinadas foram melhores que as previsões individuais, os métodos mais sofisticados de combinação tinham desempenho superior ao da média aritmética e a inclusão de até três previsões individuais na combinação aumentava a probabilidade de resultar em previsões mais acuradas. No Brasil, ao estimarem a demanda turística para a Copa do Mundo de 2014, Martins, Werner e Belleza (2013) reiteraram o ganho de precisão com a combinação das previsões.

Tendo em vista a potencialidade do setor de turismo e a necessidade de obter previsões precisas, a contribuição deste trabalho consiste em fazer uma revisão da literatura entre os anos de 2005 e 2015 sobre previsão de demanda turística. Após esta introdução, este artigo apresentará os procedimentos metodológicos utilizados no levantamento bibliográfico, além dos principais resultados encontrados e alguns comentários gerais acerca dos achados finalizarão este artigo na última seção.

2. Procedimentos metodológicos

Este trabalho trata-se de uma revisão sistemática (estudo secundário) acerca das técnicas utilizadas na previsão de demanda turística, realizada através de pesquisa bibliográfica de publicações (estudos primários), com caráter descritivo quantitativo, uma vez que os estudos encontrados serão classificados, analisados e interpretados (KITCHENHAM, 2007).

A seleção das bases de dados que foram utilizadas na busca dos artigos foi feita a partir do resultado da busca pelo assunto que tivesse as palavras *tourism* AND *forecasting*, realizada no portal de Periódicos da Capes, em agosto de 2015. Todas as bases de dados que abordaram o tópico referente à previsão na área do turismo foram selecionadas, totalizando 10 bases e se encontram listadas na Tabela 1.

Tabela 1: Quantidade de artigos encontrados por base de dados

Coleção	Nº de artigos	%
<i>Scopus</i>	234	53,9
<i>Technology Research Database</i>	46	11,0
<i>Science Direct (Elsevier)</i>	71	16,7
<i>Engineering Research Database</i>	31	7,1
<i>Civil Engineering Abstracts</i>	21	4,8
<i>Materials Business File</i>	9	2,3
<i>Materials Research Database</i>	9	2,3
<i>Wiley Online Library</i>	7	1,8
<i>Emerald Journals</i>	7	1,8
<i>SpringerLink</i>	3	0,7
Total	438	100,0

Uma vez definidas as bases de dados, a busca por artigos levou em consideração as variações nos termos referentes a previsões aplicadas à demanda turística. Desse modo, ao final das palavras-chave foi inserido um caractere curinga, “*”, para recuperar as variações dos sufixos que poderiam ser empregados. Buscou-se por artigos que tivessem em seu resumo previsões de algum tipo de demanda turística através da expressão *forecast* AND touris* AND demand*. Além disso, foram aplicados filtros de seleção, tais como a restrição do período de publicação para os últimos 10 anos (2005-2015), o idioma inglês e a exclusão de livros ou capítulos. Nesta etapa foram encontrados 438 artigos.

Como na base de dados *Springer Link* a busca pelas palavras desejadas era realizada no documento inteiro, optou-se por um procedimento de busca distinto das demais bases. Após a aplicação dos filtros de seleção a busca resultou em 1.170 artigos, definiu-se que a busca manual pelas palavras-chaves nos resumos seria somente nos artigos contemplados nas disciplinas de *Business & Management* (n=154) e *Economics* (n=365). Além das 10 bases selecionadas, a Tabela 1 apresenta a quantidade de artigos encontrados em cada uma delas.

Após a etapa de identificação foi realizado o procedimento de consolidação dos artigos encontrados. Aqueles encontrados em mais de uma base foram contabilizados apenas uma vez. Com isto, houve uma redução na quantidade de artigos de 438 para 252. Posteriormente os resumos de todos os artigos restantes foram lidos e aqueles que não continham informações

sobre previsão de demanda turística também foram excluídos, permanecendo 209 artigos. O último filtro foi realizado através da leitura da introdução e dos resultados, onde foram retirados 74 artigos da análise final, pois não abordaram o tema ou ainda modelavam demandas de serviços turísticos específicos como turismo espacial, serviços (número de empregados, por exemplo) e capacidade hoteleira. A Figura 1 resume o processo de consolidação dos artigos.



Figura 1: Processo de consolidação dos artigos encontrados

3. Artigos mapeados

3.1. Caracterização

Antecedendo à análise da identificação das abordagens, algumas informações acerca da caracterização do cenário dos últimos 10 anos de publicações sobre previsão de demanda turística foram apresentadas, tais como os periódicos com maior volume de publicações com esse enfoque, bem como, os principais pesquisadores atuais, além de uma breve análise temporal da frequência de publicações.

A Tabela 2 apresenta o número de artigos conforme o periódico de publicação, sendo que todos os periódicos com apenas uma publicação no período foram contabilizados na categoria “Outros”. Observa-se que, no período analisado, 33,3% das publicações acerca de previsão de demanda turística foram encontradas em apenas três periódicos: *Tourism Management*, responsável por 17,8% (n=24) das publicações, seguido pelo *Journal of Travel*

Research, responsável por 9,6% (n=13) e, na terceira posição, *Tourism Economics*, com oito artigos (5,9%) publicados.

Tabela 2: Quantidade de artigos conforme periódico e ano de publicação

Periódico	n	%
<i>Tourism Management</i>	24	17,8
<i>Journal of Travel Research</i>	13	9,6
<i>Tourism Economics</i>	8	5,9
<i>International Journal of Forecasting</i>	6	4,4
<i>Expert Systems with Applications</i>	5	3,7
<i>Annals of Tourism Research</i>	4	3,0
<i>International Journal of Culture, Tourism and Hospitality Research</i>	2	1,5
<i>International Journal of Tourism Research</i>	2	1,5
<i>Journal of Travel & Tourism Marketing</i>	2	1,5
<i>Knowledge-Based Systems</i>	2	1,5
<i>Tourism Management Perspectives</i>	2	1,5
<i>Tourismos</i>	2	1,5
Outros	63	46,7
Total	135	100,0

Quanto à autoria, a Tabela 3 apresenta os autores com pelo menos três artigos publicados durante o período. Somente estes 14 autores contribuíram para elaboração de 57,8% de todos os artigos analisados. Com 19 artigos publicados, Haiyan Song foi o autor com maior volume de publicações no período. Com pouco mais da metade das publicações do primeiro colocado, Gang Li (n=11) ocupou a segunda colocação, seguido de Stephen F. Witt com sete publicações. A principal área de pesquisa desses autores é em economia do turismo, com ênfase sobre modelagem e previsão de demanda turística.

Tabela 3: Autores com maior volume de publicações no período

Autor	n (%)	Autor	n (%)	Autor	n (%)
Haiyan Song	19 (14,1)	Oscar Claveria	4 (3,0)	Michael McAleer	3 (2,2)
Gang Li	11 (8,1)	Shanshan Lin	4 (3,0)	João Paulo Teixeira	3 (2,2)
Stephen F. Witt	7 (5,2)	George Athanasopoulos	4 (3,0)	Paula Odete Fernandes	3 (2,2)
Fong-Lin Chu	5 (3,7)	Rob J. Hyndman	4 (3,0)	Shujie Shen	3 (2,2)
Kevin K. F. Wong	5 (3,7)	Salvador Torra	3 (2,2)		

Observando a quantidade de artigos publicados anualmente, o ano de 2014 foi o que contemplou o maior volume de publicações, 25 artigos e, o ano de 2007, o menor volume, com apenas quatro publicações. Lembrando que a quantidade de artigos de 2015 é com base até agosto desse ano.




Figura 2: Evolução temporal das publicações

3.2. Classificação/Análise

No levantamento realizado foram encontrados seis artigos que se tratavam de revisões ou resumos da literatura acerca de previsão de demanda turística. Devido à peculiaridade desse tipo de publicação, estes artigos serão discutidos posteriormente na sessão 3.3. Portanto, a classificação e as análises serão embasadas em um total de 129 artigos e não nos 135 selecionados.

3.2.1 Variáveis dependente e independentes

Foi observada mais de uma forma de mensurar a demanda turística (variável independente), sendo o número de chegadas a variável mais utilizada nos estudos (79,1% das observações), seguida pelas variáveis referentes a gastos/despesas com turismo em 7,8%. Na modelagem econométrica, algumas variáveis econômicas como renda, PIB (Produto Interno Bruto), custos de viagem, entre outras foram inseridas nos modelos como candidatas a predictoras (independentes) da demanda turística.

3.2.2 Medidas de acurácia

Ao se falar em modelagem e principalmente em predição, a capacidade preditiva de um modelo deve ser avaliada de forma consistente. Há diversas medidas de acurácia amplamente aceitas e difundidas. O erro percentual absoluto médio (MAPE) foi a medida mais utilizada, sendo citado em 85 estudos (65,9%), seguido pela raiz quadrada do erro quadrático médio (RMSE), observada em 43 estudos (33,3%). Destaque para as variações

dessas duas medidas, sendo o MAPE também apresentado sem o percentual, denominado MAE (erro absoluto médio) e a RMSE sob a forma de percentual através da RMSPE (raiz quadrada percentual do erro quadrático médio). A Tabela 4 resume as principais medidas de acurácia encontradas. Os percentuais não totalizam 100% porque foi comum encontrar mais de uma medida por artigo.

Tabela 4: Principais medidas de acurácia encontradas

Medida de acurácia	n	%
MAPE (Erro Percentual Absoluto Médio)	85	65,9
RMSE (Raiz Quadrada do Erro Quadrático Médio)	43	33,3
MAE (Erro Absoluto Médio)	19	14,7
RMSPE (Raiz Quadrada Percentual do Erro Quadrático Médio)	16	12,4
Coefficiente de Desigualdade de Theil	12	9,3
MSE (Erro Quadrático Médio)	8	6,2

3.2.3 Emissores e receptores de turistas

Com o intuito de conhecer quais foram os locais cuja demanda foi analisada com maior frequência se optou por padronizar os locais por países. Vale salientar, contudo, que embora a maioria dos artigos apresentasse modelagem para um ou mais países, foram encontradas também modelagens intercontinentais (CHEN, 2011), para algumas cidades portuguesas (SERRA; CORREIA; RODRIGUES, 2014), distritos chineses (LIU, 2012; ZHOU-GRUNDY; TURNER, 2014; YANG et al., 2015), estados do Pará e Amazônia no Brasil (DIVINO; MCALEER, 2009), cidade de Las Vegas (CHU, 2014) e Ilhas Baleares (Espanha) (MEDEIROS et al., 2008; ALVAREZ-DIAZ; ROSSELLO-NADAL, 2008; ALVAREZ-DIAZ; MATEU-SBERT; ROSSELLO-NADAL, 2009). Dessa forma, os locais específicos foram analisados de acordo com o país de sua localização e a abordagem intercontinental, apresentada por Chen (2011), foi desconsiderada dessa análise específica por não ser possível identificar países. Para as demandas domésticas (dentro do mesmo país) foi contabilizado apenas o país receptor e as regiões administrativas especiais (RAE) da China (Hong-Kong e Macau) foram classificadas como países independentes entre si e da China.

Sendo assim, Hong-Kong foi o principal receptor de turistas analisado nos últimos anos (20 artigos), seguido da China, analisada em 18 artigos. Em contrapartida, a demanda de saída de residentes do Reino Unido foi modelada em 42 artigos, seguida pelos residentes norte-americanos (Tabela 5). Como alguns artigos apresentaram mais de um país emissor ou receptor, os percentuais não totalizam 100%.

Tabela 5: Principais países emissores e receptores analisados

Emissores	n	%	Receptores	n	%
Reino Unido	42	32,6	Hong-Kong	20	15,5
EUA	28	21,7	China	18	14,0
Alemanha	21	17,1	Espanha	15	11,6
Japão	21	16,3	Taiwan	15	11,6
Austrália	16	12,4	Austrália	12	9,3
França	14	10,9	Itália	12	9,3

3.2.4 Abordagem

Com relação à abordagem, os artigos foram classificados em três tipos distintos, podendo ser de caráter exploratório, de proposição de modelos ou ainda de combinação de previsões, sendo estas classificações puramente sugestivas uma vez a maioria dos artigos busca encontrar o modelo que melhor se ajusta à demanda analisada.

3.2.4.1 Artigos exploratórios

A característica dos artigos classificados como exploratórios é a busca pelo modelo com melhor desempenho em relação às previsões de determinada situação analisada, sendo que o foco de exploração pode ser voltado para a investigação da influência de fatores não econômicos e a competição entre modelos de previsão. A influência de fatores refere-se à investigação de outras variáveis independentes, além daquelas variáveis econômicas usualmente inseridas nos modelos econométricos, e a competição entre modelos compreende artigos cujo intuito era avaliar o desempenho entre diferentes técnicas. Dessa forma, da totalidade de artigos analisados, a maioria foi classificada como de abordagem exploratória (78 artigos) e o Quadro 1 apresenta os artigos de acordo com o respectivo foco explorado.

Quadro 1: Artigos mapeados de acordo com a abordagem exploratória

Foco de exploração	Referência
Influência de fatores (15 artigos)	Chen (2005), Chu (2008b), Álvarez-Díaz e Rosselló-Nadal (2008), Goh e Mok (2008), Min (2008), Ouerfelli (2008), Divino e McAleer (2009), Claveria e Datzira (2010), Guizzard e Mazzocchi (2010), Song e Li (2010), Goh (2012), Poudyal, Paudel e Tarrant (2013), Fan e Liu (2013), Bangwayo-Skeete e Skeete (2015), Yang et al. (2015)
Competição (63 artigos)	Kulendran e Wong (2005), Lim e McAleer (2005), Smeral e Wüger (2005), Han, Durbarry e Sinclair (2006), Song e Witt (2006), Vu e Turner (2006), Yu e Schwartz (2006), Wong, Chon e Song (2006), Shareef (2007), Chu (2008a), Fernandes et al (2008), Hsu e Wang (2008), Moutinho, Huarng e Yu (2008), Álvarez-Díaz, Bonhama, Gangnes e Zhou (2009), Andraz, Gouveia e Rodrigues (2009), Chang, Sriboonchitta e Wiboonpongse (2009), Chu (2009), , Krasić e Gatti (2009), Rosselló-Nadal e Mateu-Sbert (2009), Shen, Li e Song (2009), Yujie e Zheng (2009), Castelluccio (2010), Chen, Ying e Pan (2010), Chon et al (2010), Divino e McAleer (2010), Song et al (2010a), Song et al (2010b), Wu et al (2010), Ayeh e Lin (2011), Brida e Risso (2011), Cheung e Yap (2011), Chu (2011), Guo (2011), Huang e Lin (2011), Kulendran e Wong (2011), Rufino (2011), Tsaour e Kuo (2011), Xiuha (2011), Botha e Saayman (2012), Elena et al. (2012), Gounopoulos, Santamaria e Petmezas (2012), Nanthakumar, Kogid e Subramaniam (2012), Wu, Law e Xu (2012), Fernandes et al (2013), Panchev e Theocharous (2013), Petrevska (2013), Bo e Shi-ting (2014), Borhan e Arsad (2014), Chou, Tseng e Hsieh (2014), Chu (2014), Kaynak e Rojas-Méndez (2014), Liang (2014), Serra, Rodrigues e Correia (2014), Claveria e Torra (2014), Min (2014), Yong e Brook (2014), Zhou-Grundy e Turner (2014), Claveria, Monte e Torra (2014), Baldigara e Mamula (2015), Claveria, Torra e Monte (2015), Gunter e Önder (2015), Hassani et al (2015), Lin, Song e Liu (2015).

Alguns estudos constataram a importância da inclusão de informações não econômicas como Min (2008), que inseriu a ocorrência de dois eventos: o terremoto ocorrido em 21 de setembro de 1999 e a Síndrome Respiratória Aguda Severa (SARS, do original em inglês, *Severe Acute Respiratory Syndrome*) para a previsão da procura de turistas japoneses por Taiwan. Com a inclusão da intervenção referente ao atentado de 11 de setembro de 2001, obteve-se o menor erro de previsão para a demanda dos EUA (CHEN, 2005). Ouerfelli (2008) analisou o fator que compreende o patrimônio natural (clima, praias ensolaradas, capacidade hoteleira) conjuntamente com as variáveis econômicas no processo de escolha de destinos como a Tunísia. Na mesma linha, Goh e Mok (2008) inseriram fatores qualitativos como um índice de tempo de lazer e um índice climático para a previsão da demanda de Hong-Kong. A

variável de índice climático também melhorou o poder explicativo do modelo aplicado por Goh (2012) e as variáveis meteorológicas inseridas por Álvarez-Díaz e Rosselló-Nadal (2008) também aumentaram a capacidade de previsão da demanda das Ilhas Baleares na Espanha, no entanto as melhores previsões ainda foram geradas por modelos de redes neurais artificiais

Ainda, mais atualmente a utilização do volume de pesquisas feitas em dois mecanismos de busca (*Google e Baidu*) melhorou o desempenho da previsão para o número de visitantes em Hainan (China) no estudo de Yang et al. (2015) e o uso de informações do *Google* referentes a vôos e reservas de hotéis também melhorou as previsões para cinco destinos populares caribenhos (BANGWAYO-SKEETE; SKEETE, 2015). Já Claveria e Datzira (2010) não conseguiram afirmar que a utilização de informações obtidas por pesquisas de consumidor poderia melhorar as previsões geradas por dois modelos não-lineares, SETAR (*Self-Exciting Threshold AutoRegressiveModel*) e MKTAR (*Markov Switching Model*), para a demanda da Catalunha.

Os artigos de competição avaliaram o desempenho de diferentes técnicas, podendo ser encontrados dois tipos básicos de aplicações:

a) Aplicação de apenas uma técnica, como por exemplo, a avaliação da capacidade preditiva de modelos ARIMA, analisada por Chang, Sriboonchitta e Wiboonpongse (2009), Nanthakumar, Kogid e Subramaniam (2012), Borhan e Arsad (2014), Min (2014), Baldigara e Mamula (2015). Divino e McAleer (2009) também utilizaram modelos ARIMA para modelar as demandas dos estados do Pará e Amazonas e não encontraram diferenças significativas para a demanda total utilizando dados mensais ou dados anuais. Chou, Tseng e Hsieh (2014) modelaram a demanda para Taiwan via análise de regressão (REG) e a modelagem via ADLM (*Autoregressive Distributed Lag Model*) foi utilizada por Lin, Song e Liu (2015) para caracterizar a demanda de turistas chineses para 11 destinos internacionais. O estudo de Kaynak e Rojas-Méndez (2014) utilizou uma técnica qualitativa de previsão, Delphi (DEL, *Delphi method*), para prever o potencial do mercado de turismo chileno.

b) Comparação de técnicas, como a avaliação do desempenho de distintas técnicas de redes neurais artificiais realizada por Claveria, Monte e Torra (2014). Os autores constataram que as redes neurais artificiais MLP (*Multi-Layer Perception Neural Networks*) e RBF (*Radial Basis Function Network*) geraram previsões mais acuradas que as redes Elmann (*Elmann Neural Network*) para a procura pela Catalunha por turistas de diversos países europeus. Yu e Schwartz (2006) compararam o desempenho de dois métodos complexos de inteligência artificial, Fuzzy (*Fuzzy Time Series Model*) e modelo GM (*Grey Model*), com dois métodos simples de séries temporais, DMA (*Double Moving Average*) e ES (*Exponential Smoothing*),

para a previsão da demanda anual dos EUA, conforme o país de origem, baseados em séries históricas com poucas observações. Neste estudo, os modelos complexos não geraram previsões significativamente mais precisas que os métodos simples. Álvarez-Díaz, Rosselló-Nadal e Mateu-Sbert (2009) também compararam as previsões geradas por algoritmos genéticos GA (*Genetic Algorithms*), que são algoritmos de otimização inspirados nos princípios da evolução natural e na genética, com as previsões geradas por métodos mais simples (ARIMA, MA (*Moving Average*) e modelo Naive 1 (*No Change Model*)) para a demanda das Ilhas Baleares.

Chu (2009) constatou que as modelagens ARIMA e ARFIMA (*Autoregressive Fractionally Integrated Moving Average*) funcionaram bem tanto para dados mensais quanto trimestrais, com vantagem para os modelos ARFIMA. Claveria e Torra (2014) constataram que a modelagem via ARIMA apresentou melhor capacidade preditiva que as redes neurais artificiais (ANN, *Artificial Neural Networks*) e SETAR para a demanda da Catalunha. Já no estudo de Andraz, Gouveia e Rodrigues (2009), os modelos DIM (*Diffusion index models*) mostram superioridade em relação ao ARIMA para a demanda portuguesa, assim como no estudo de Chu (2011), onde as previsões geradas pelos modelos ARIMA foram menos acuradas que as geradas pelo modelo PLM (*Piecewise linear function*) para demanda de Macau em 2011 e que o modelo MLOG (*Logistic Model*) para a demanda de Las Vegas em 2014 (CHU, 2014).

A previsão para a demanda de Hong-Kong foi utilizada nas avaliações dos desempenhos da rede neural EMN (*electromagnetism-like mechanism neural network*) (WU et al., 2010), apresentando excelente desempenho, e do modelo não paramétrico GPR (*Gaussian process regression*) (WU; LAW; XU, 2012) também com desempenhos superiores aos modelos testados (ARIMA e SVM (*Support vector machine model*)). Para a demanda norte-americana, Rassani et al. (2015) utilizaram SSA (*Singular Spectrum Analysis*) e comprovaram que as previsões foram melhores que as geradas via ARIMA, ES e ANN. Gunter e Önder (2015) compararam o desempenho de modelos univariados (ARIMA, ES e Naive 1) e multivariados como VAR (*Vector autoregressive model*) (bayesiano e clássico), TVP (*Time-Varying-Parameter Model*) e EC-ADLM (*Error Correction - Autoregressive distributed lag model*), para a previsão da demanda turística de Paris e os resultados variaram conforme os países de origem dos turistas, sendo superado o desempenho do modelo mais simples (Naive 1) pelos demais em grande parte dos países e horizontes de previsão analisados.

3.2.4.2 Proposição de modelos

A inovação é a característica marcante dos artigos citados nesta seção. Os artigos de proposição combinaram matematicamente abordagens com o intuito de construir um novo modelo. Geralmente os modelos propostos são comparados com modelos já usualmente conhecidos e utilizados com o intuito de atestar o bom ajuste ou a boa capacidade preditiva. Foram classificados 29 artigos com essa abordagem e o Quadro 2 apresenta os modelos propostos.

Quadro 2: Artigos de caráter de proposição

Referência	Modelos propostos	Referência	Modelos propostos
Aguiló et al. (2005)	DIM + UTM	Song et al. (2011)	TVP+BSM
Pai et al. (2005)	MSVM + BPN	Chen, Lai e Yeh (2012)	EMD + BPN
Profillidis et al. (2005)	FUZZY + ECM	Huang et al. (2012)	ANN + Fuzzy
Li e Witt (2006)	TVP-EC-LAIDS, TVP-LR-LAIDS	Teixeira e Fernandes (2012)	ANN com variação do tempo como entrada
Li et al (2006)	TVP-ECM	Shahrabi, Hadavandi e Asadi (2013)	MGFFS (Fuzzy + processamento de dados)
Atsalakis e Ucenic (2007)	ANN + Fuzzy	Aladag et al. (2014)	ANN + Fuzzy
Chen e Wang (2007)	SVR+GA	Botzoris et al. (2014)	Fuzzy com informação de ECM
Medeiros et al (2008)	ANN-GARCH	Ko et al (2014)	GM + Fourier
Athanasopoulos e Hyndman (2008)	ETS + REG	Pai, Hung e Lin (2014)	FCM + LLS-SVR
Cai et al. (2009)	SVR+GA	Shu et al. (2014)	FSARIMA (ARIMA+Fourier)
Chou et al. (2010)	FUZZY + Cluster	Tsaur e Kuo (2014)	Fuzzy + Fourier
Hadavandi e Ghanbari (2010)	ANFIS+ SOM	Wang et al. (2014)	SVR+EMD
Ao (2011)	VAR+ANN+GA	Yao (2014)	HCA + GFA
Chen (2011)	Combinações lineares vs não lineares	Berenguer et al. (2015)	ANN com variação do tempo como entrada
Hong et al. (2011)	SVR+CGA		

AFuzzy: Adaptive Fuzzy Time Series Model; ANFIS: Adaptive Neuro-Fuzzy Inference System; ANN: Artificial Neural Networks; BPN: Back-propagation neural network; CGA: Chaotic Genetic Algorithm; DIM: Diffusion index models; BSM: Basic Structural Model; ECM: Error Correction Model; EMD: Empirical Mode Decomposition; FCM: Fuzzy c-means; FSARIMA: Fourier-modified seasonal ARIMA; Fourier: Fourier analysis; Fuzzy: Fuzzy Time Series Model; FTDN: Focused Tapped Delay Line Neural Network; GA: Genetic Algorithms; GEPM: Grey Envelop Prediction Model; GFA: Gaussian Fitting Algorithm; GM: Grey Model; GPR: Gaussian Process Regression; HCA: Hierarchical Cluster Analysis; LLS-SVR: Least-Squares Support Vector Regression; MGFFS: Modular Genetic-Fuzzy Forecasting System; MSVM: Multifactor Support Vector Machine Model; PASIP: Partitive Simulation Process; SOM: Self- Organizing Map; VAR: Vector

Autoregressive Model; SSA: Singular Spectrum Analysis; SVR: Support Vector Regression; TVP: Time-Varying-Parameter Model; TVP-EC: Time-Varying-Parameter error correction Model; TVP-EC-LAIDS: Time Varying Parameter Linear Almost Ideal Demand System Models In Short-Run Error Correction Form; TVP-LR-LAIDS: time varying parameter linear almost ideal demand system models in long-run static form; UTM: Utility Theory Model.

Os modelos *FUZZY* de séries temporais foram combinados com ANN (ATSALAKIS; UCENIC, 2007, HUARNG et al., 2012; ALADAG et al., 2014), também foram combinados com informação de ECM (*Error correction model*) (PROFILLIDIS; BOTZORIS; LATHIRAS, 2005; BOTZORIS et al., 2014) e também com o método de Fourier (TSAUR; KUO, 2014). Este último, o método de Fourier, também foi combinado com outro método de inteligência artificial, GM (KO et al., 2014) e com a modelagem tradicional de séries temporais ARIMA (SHU et al., 2014), gerando bons resultados em ambos os estudos. Os modelos de inteligência artificial SVR foram otimizados por GA e obtiveram desempenhos superiores as redes BPN (*Back-propagation neural network*) (CHEN; WANG, 2007; CAI; LU; ZHANG, 2009) e também ARIMA (CHEN; WANG, (2007). Athanasopoulos e Hyndman (2008) mostraram que o desempenho das previsões geradas por três modelos distintos (REG, ES e REG+ES) superaram o desempenho das previsões geradas pelo *Tourism Forecasting Committee* da Austrália, sendo o modelo combinado (ES com variável exógena) o mais acurado.

3.2.4.3 Combinação de previsões

Além da combinação de modelos, há um ainda a combinação de previsões. As previsões geradas individualmente pelos modelos já discutidos podem ser combinadas, de acordo com algum método, e a capacidade preditiva dessas novas previsões foi avaliada. Os 22 estudos encontrados com este tipo de enfoque estão listados no Quadro 3, onde são apresentadas as modelagens individuais (MI) utilizadas para gerar as previsões e/ou comparar os resultados, as técnicas utilizadas para combinar essas previsões (TC) e os principais resultados.

A média aritmética simples, SA (*Simple average*), foi o método mais utilizado entre os estudos analisados, encontrado na metade das publicações. Entre os demais métodos encontrados destaque para a VACO (*Variance-Covariance method*), também conhecida como variância mínima, que foi o segundo método de combinação mais utilizado, tanto para combinar previsões geradas apenas por modelos de séries temporais (COSHALL, 2009; COSHALL e CHARLESWORTH, 2011), quanto apenas econométricos (SHEN, LI e SONG, 2011) ou econométricos e de séries temporais (CHENG, SONG e LI, 2008; SONG et al, 2009) e ainda de séries temporais e inteligência artificial (ANDRAWIS, ATIYA e EL-

SHISHINY, 2011; MARTINS, BELLEZA e WERNER, 2013; CANG, 2014; CANG e YU, 2014).

Quadro 3: Artigos que utilizaram métodos de combinações

Autores	MI	TC	Resultados principais
Oh e Morzuch (2005)	Naive 1, Naive 2, REG, ES, ARIMA, SW	SA	O desempenho quanto à acurácia das previsões combinadas não foi pior que o desempenho do pior componente (modelo) utilizado na combinação; Em alguns casos, o desempenho das previsões combinadas foi superior ao desempenho dos melhores modelos individuais.
Petropoulos et al (2005)	LTL, STL	SA	As previsões combinadas foram as mais precisas no horizonte de um ano; No horizonte de dois anos, as previsões combinadas ficaram atrás das geradas pelo método de autorregressão.
Blake et al. (2006)	BSM, CGE	Decomposição	O acréscimo de CGE é particularmente útil para quantificar os efeitos macroeconômicos ou de alternativa de possíveis cenários para a economia.
Petropoulos et al (2006)	LTL, STL	SA	As previsões combinadas foram as mais precisas no horizonte de um ano; No horizonte de dois anos, as previsões mais acuradas variaram conforme o país, podendo ser as combinadas ou as geradas pelos modelos ARIMA ou Naive 1.
Cheng, Song e Li (2008)	RE-ADLM, TVP, WB-ECM, JML-ECM, VAR, Naive 1, ARIMA	SA, DMSFE, VACO	A combinação VACO é a melhor entre os três métodos de combinação; As previsões globais combinadas tiveram melhor desempenho que as do melhor modelo individual ao longo de diferentes horizontes de previsão.
Lee, Mjelde e Song (2008)	ARIMA, ES, WTV, REG, DEL	Multiplicação	Na comparação entre as previsões combinadas, as previsões geradas pelo modelo ARIMA combinado com WTV foram mais acuradas; As previsões geradas pelo método DEL foram mais conservadoras do que as geradas pela combinação ARIMA+WTV.
Song, Witt e Zhang (2008)	VAR, DEL	TDFS	Software TDFS baseado na Web amplamente acessível que utiliza VAR para previsão de demanda e combina suas previsões com julgamento de especialistas na área.

Athanasopoulos, Ahmed e Hyndman (2009)	ESSS	<i>Botton-up, Optimal, Top-Down (A e B)</i>	Os métodos de combinação hierárquica <i>Optimal</i> e <i>Top-Down B</i> superam o desempenho das combinações hierárquicas <i>Botton-up</i> e <i>Top-Down A</i> .
Coshall (2009)	GARCH, ES, Naive 2	VACO, SA	As previsões individuais via GARCH e ES foram mais acuradas que as via Naive 2; O desempenho das previsões combinadas foi superior às individuais em todos os três horizontes de tempo examinados, exceto quando se considera a medida MedAPE para as previsões de 1 ano à frente.
Song et al (2009)	ARIMA, ECM, VAR, ADLM	SA, VACO, DMSFE	As previsões combinadas foram mais acuradas que as previsões do pior componente utilizado na combinação em todos os horizontes de previsão; DMSFE foi o método com melhor desempenho e VACO com o pior; A precisão das previsões geradas por modelos combinados não melhora necessariamente com o acréscimo de previsões individuais.
Andrawis, Atiya e El-Shishiny (2011)	PLF	SA, VACO, INV-MSE, RANK, LSE, SHIRNK, GEO, GEOW, HARM, HARMW, SWITCH, HIER, VAR-NO-COR	As previsões combinadas por LSE, INV-MSE, GEOW e HARMW foram superiores às previsões do melhor modelo individual; Destaque para as combinações realizadas por MGW e MHW que tiveram excelente desempenho e até então não haviam sido analisadas; Se as previsões individuais têm desempenhos semelhantes, a combinação através da SA é uma boa opção. Caso contrário, é preferível qualquer outro método de ponderação baseada no desempenho.
Coshall e Charlesworth (2011)	ARIMA, REG, Naive 2, ES	VACO, SA, GP	O método de combinação GP gerou previsões tão acuradas quanto as previsões geradas pelos métodos SA e VACO.
Hyndman et al (2011)	ARIMA	<i>Botton-up, Optimal, Top-Down</i>	Os métodos de combinação hierárquica <i>Optimal</i> e <i>Botton-up</i> superam o desempenho da combinação hierárquica <i>Top-Down</i> .

Shen, Li e Song (2011)	RE-ADLM, TVP WB-ECM, JML-ECM, VAR	SA, VACO, SHIRNK, TVP, DMSFE, LSE	<p>O desempenho das previsões geradas por combinações, no geral, superou o desempenho das melhores previsões de modelos individuais;</p> <p>Previsões mais precisas são geradas por combinações com até três previsões individuais;</p> <p>Os métodos de combinação mais sofisticados (levam o desempenho histórico das previsões individuais em consideração) tiveram melhor desempenho do que a SA;</p> <p>O desempenho das previsões combinadas está associado com a consistência do desempenho das previsões individuais.</p>
Liu (2012)	REG, ES, GM	WC	Os valores previstos aproximaram-se consideravelmente dos valores médios anuais e a precisão da previsão foi superior a dos modelos individuais.
Martins, Belleza e Werner (2013)	ANN, ARIMA	VACO	As previsões combinadas foram mais precisas que as previsões geradas pelos modelos individuais.
Song, Gao e Lin (2013)	ADLM, DEL	TDFS	O modelo combinado (quantitativo + qualitativo) gerou previsões mais acuradas que as previsões individuais em quatro de seis mercados emissores analisados.
Lin e Goodwin (2014)	EC-ADLM, DEL	TDFS	Em média, o acréscimo das informações da técnica Delphi melhorou a precisão das previsões, embora algumas fossem tendenciosas para alguns dos mercados individuais.
Cang (2014)	SVR, ES, ARIMA, Naive 1, Naive 2	SA, DMSFE, VACO, SVR, MLP, RBF	<p>Desempenho superior dos métodos de combinação não-linear em relação aos melhores modelos individuais e aos modelos de combinação linear na maioria dos casos (séries com padrões sazonais ou semi-sazonais);</p> <p>A combinação VACO gerou melhores previsões que a DMSFE em geral;</p> <p>As previsões via ES foram as melhores entre os modelos individuais e combinados (séries não sazonais).</p>
Cheng e Liu (2014)	CP, GM	NM	As previsões combinadas foram mais precisas que as previsões geradas pelos modelos individuais.

Cang e Yu (2014)	SVR, ES, ARIMA, Naive 1, Naive 2	SA, DMSFE, VACO	As previsões combinadas (com dois a cinco modelos individuais selecionados a partir dos subconjuntos ótimos) tiveram desempenho superior comparado ao desempenho do melhor modelo individual e ao desempenho da combinação feita com todos os modelos disponíveis.
Lu, Zhu e Peng (2015)	ARIMA, GM	IOWA	As previsões combinadas tiveram menor erro e foram mais precisas que as previsões geradas pelos modelos individuais.

ADLM: Autoregressive Distributed Lag Model; EC-ADLM: Error Correction - Autoregressive distributed lag model; RE-ADLM: Reduced Autoregressive Distributed Lag Model; ANN: Artificial Neural Networks; ARIMA: Auto-Regressive Integrated Moving Average; Botton-up: Bottom-Up Approach; BSM: Basic Structural Model; CGE: General Equilibrium Model; CP: Cubic Polinomial Model; DMSFE: Discounted Mean Square Forecast Error; ECM: Error Correction Model; ES: Exponential smoothing; ESSS: Exponential Smoothing Based On Innovations State Space Models; GARCH: Generalized Autoregressive Conditional Heteroskedasticity; GEO: Geometric Mean; GEOW: Weighted geometric mean, GM: Modelo Grey (Grey Model); GP: Goal programming; HARM: Harmonic mean; HARMW: Weighted harmonic mean; HIER: Hierarchical Forecast Combination; INV-MSE: Inverse Of The Mean Square Error; IOWA: Induced Ordered Weighted Averaging; JML-ECM: Johansen maximum likelihood error correction model; WB-ECM: Wickens and Breusch error correction model; LTL: Long Trend Line; LSE: Least squares estimation; MLP: Multi-Layer Perception Neural Networks; Naive 1: *No Change Model*; Naive 2: *Constant Growth Model*; NM: Nelder-Mead Simplex Method; Optimal: Optimal Hierarchical Combination; RANK: Rank Based Weighting; RBF: *Radial Basis Function Network*; REG: Regression analysis; SA: Simple Average; SHIRNK: Shrinkage Method; STL: Short Trend Line; SVR; Support Vector Regression; SW: Sine-Wave Time-Series Regression; SWITCH: Method based on testing the performance difference; TDFS: Web-Based Tourism Demand Forecasting System; Top-Down A: Top-Down Approaches Based On Historical Proportions; Top-Down B: Top-Down Approaches Based On Forecasted Proportions; TVP: Time-Varying-Parameter Model; VACO: Variance-Covariance Method; VAR: Vector autoregressive model; VAR-NO-COR: Variance Based Method; WC: Weight combination Method; WTV: Willingness-To-Visit Surveys.

Outros métodos de combinação também foram analisados como métodos hierárquicos onde o método *Optimal* de combinação foi aplicado por Athanasopoulos, Ahmed e Hyndman (2009) e Hyndman et al. (2011), e apresentou bons resultados em ambos estudos. Combinações não lineares pouco utilizadas como da média geométrica ponderada (GEOW) e média harmônica ponderada (HARMW) também apresentaram resultados superiores às previsões individuais (ANDRAWIS, ATIYA e EL-SHISHINY, 2011). Lu, Zhu e Peng (2015) propuseram um método IOWA de combinação e as previsões combinadas foram mais acuradas que as individuais geradas por ARIMA e GM.

Três estudos avaliaram a utilização de informações qualitativas para tornar as previsões mais acuradas e as conclusões foram distintas. Os trabalhos mais recentes, Song, Gao e Lin (2013) e Lin e Goodwin (2014) concordaram que as previsões geradas pelo modelo ADLM combinadas com informações de especialistas (método Delphi) foram mais precisas que as previsões geradas apenas pelo modelo quantitativo em questão, porém no trabalho de Lin e Goodwin (2014) algumas previsões mostraram-se tendenciosas para alguns mercados analisados. Já na avaliação de Lee, Mjelde e Song (2008), as informações de pesquisas de opinião WTV (*Willingness-To-Visit Surveys*) foram combinadas com as previsões de um modelo ARIMA (modelo que obteve melhores previsões entre os modelos quantitativos avaliados) e comparadas com as previsões de especialistas (Delphi). As previsões do modelo combinado mostraram-se superestimadas (LEE; MJELDE; SONG, 2008).

3.3 Artigos resumo ou de revisão

Os artigos classificados como resumo ou de revisão sistemática foram aqueles que utilizaram como fonte a literatura já publicada sobre previsão de demanda turística em determinado período de tempo. Durante os últimos 10 anos foram encontrados seis artigos com esse tipo de abordagem.

A revisão feita por Tseng, Ma e Chou (2010) não foi sobre previsão de demanda turística, mas sim sobre turismo em geral. Contudo, um dos achados dessa revisão foi a identificação do crescente número de artigos cuja temática era voltada para a previsão de demanda turística. As revisões de Li, Song e Witt (2005) e Li e Song (2007) foram acerca da modelagem econométrica. Na primeira, os autores destacaram que o número de visitas (chegadas) foi a medida de demanda mais utilizada entre os 84 artigos analisados. Destaque também para o surgimento de técnicas mais avançadas para a época como CI/ECM, VAR, TVP e AIDS (*Almost Ideal Demand System Models*) (LI; SONG; WITT, 2005). Li e Song (2007) discutiram e exemplificaram técnicas simples de previsão como a TVP e suas

aplicações em modelos dinâmicos mais complexos como AIDS. Uma limitação apontada foi que esse tipo de modelagem não considera padrões sazonais e deve ser utilizada em dados anuais.

Duas revisões mostraram-se concordantes quanto a não convergência entre os artigos analisados acerca de um modelo único que gerasse previsões mais acuradas que outros modelos em todas as situações analisadas (SONG; LI, 2008; SONG; HYNDMAN, 2011). Já Peng, Song e Crouch (2014) destacaram o bom desempenho na previsão de demanda realizada por modelos econométricos dinâmicos e também mostraram, através de uma meta-regressão, que a acurácia dos modelos de previsão era influenciada por diversos fatores: local de origem e destino dos turistas, época da viagem, frequência de observação dos dados, método de modelagem adotado, forma de mensuração da demanda e tamanho da amostra. Song e Li (2008) sugeriram a combinação de previsões para fins de melhoria da precisão.

4. Considerações finais

A medida utilizada para mensurar a demanda turística pode influenciar no desempenho das suas previsões. Segundo Peng, Song e Cronch (2014) previsões mais precisas são encontradas quando a demanda não é mensurada por despesas ou receitas turísticas, uma vez que estas variáveis são mais instáveis do que o número de chegadas, por exemplo, que foi a medida encontrada com maior frequência neste levantamento, assim como nos achados de Li, Song e Witt (2005), Song e Li (2008) e Song et al. (2009).

Vale ressaltar, contudo, que o número de chegadas se refere ao número de turistas que viaja para um país diferente daquele da sua residência habitual e permanece por um período superior a uma noite e inferior a 12 meses. Dessa forma, uma pessoa que faz várias viagens a um país, durante um determinado período, é contabilizada cada vez como uma nova chegada, assim como uma pessoa que viaja por diversos países em uma mesma viagem é contabilizada como uma nova chegada (nos diversos países). Quando os dados de turistas nas fronteiras não estão disponíveis, informações provenientes de hotéis ou estabelecimentos similares podem ser utilizados (WTO, 2015c). Além disso, essa medida é referente à demanda geral, podendo ainda ser explorada e analisada de forma desagregada através do motivo da viagem (férias, a negócios, para visitar amigos e parentes ou outro motivo).

O grande volume de artigos analisando as demandas de turistas por destinos espanhóis, chineses e italianos se justifica pelo fato deles serem destinos muito procurados, onde em 2013, por exemplo, foram terceiro, quarto e quinto destinos com maior número de

chegadas internacionais, respectivamente. Da mesma forma que as demandas de turistas norte-americanos e britânicos por outros destinos, uma vez que foram o segundo e o terceiro países com maior volume de saídas em 2013 (WTO, 2015b). Quanto à demanda brasileira, que não está nem entre os 20 primeiros países com maior volume de chegadas nem de saídas, foram encontrados apenas dois artigos voltados para a sua previsão. Divino e McAleer (2009) avaliaram a demanda por turismo sustentável nos estados do Amazonas e do Pará via modelagem de Box-Jenkins. O número de chegadas (domésticas e internacionais) foi analisado através de dados mensais e anuais e as previsões para 2006 e 2007 não diferiram de forma significativa e apontaram um improvável aumento da chegada de turistas internacionais na região amazônica. Já Martins, Werner e Belleza (2013) utilizaram o método de combinação de previsões através da variância mínima e um ajuste matemático para prever o número de turistas que viriam para a Copa do Mundo (FIFA) em 2014.

Quanto à modelagem, nota-se grande interesse por parte dos pesquisadores em utilizar as ferramentas computacionais disponíveis ao analisar a capacidade de técnicas de inteligência artificial no contexto turístico. Novos modelos foram sugeridos e avaliados, sobretudo modelos de lógica *FUZZY* combinados com redes neurais artificiais ou ainda modelos lineares (econométricos) combinados com modelos não lineares como de redes neurais. Ainda, a combinação de previsões também tem um destaque importante, onde novas técnicas de combinação foram sugeridas e avaliadas. De forma geral, as previsões combinadas mostram-se mais precisas que as previsões geradas pelos modelos individuais, em conformidade com outros estudos não voltados necessariamente à aplicação no turismo (ARMSTRONG, 2001; WONG et al., 2007).

Deve-se destacar, contudo que o bom desempenho da abordagem de combinação de previsões está muito associado à boa escolha dos modelos geradores das previsões individuais (SHEN; LI; SONG, 2011) e também à escolha da técnica de combinação mais adequada para cada situação. Andrawis, Atiya e El-Shishiny (2011) destacaram que a combinação através da média aritmética simples pode ser adequada quando, por exemplo, o desempenho das previsões individuais é similar. Porém, quando o desempenho das previsões obtidas por um modelo é superior ao de outro, a utilização de métodos de combinação cuja ponderação considera o desempenho histórico pode ser mais oportuna.

Referências

- AGUILÓ, E; RIERA, A; ROSSELLO-NADAL, J. The short-term price effect of a tourist tax through a dynamic demand model: The case of the Balearic Islands. **Tourism Management**, v.26, n.3, p.359-365, 2005.
- ALADAG, C.H; EGRIOGLU, E; YOLCU, U; USLU, V.R. A high order seasonal fuzzy time series model and application to international tourism demand of Turkey. **Journal of Intelligent & Fuzzy Systems: Applications in Engineering and Technology**, v.26, n.1, p.295-302, 2014.
- ALVAREZ-DIAZ, M; MATEU-SBERT, J; ROSSELLO-NADAL, J. Forecasting tourist arrivals to Balearic Islands using genetic programming. **International Journal of Computational Economics and Econometrics**, v.1, n.1, p.64-75, 2009.
- ALVAREZ-DIAZ, M; ROSSELLO-NADAL, J. Forecasting British Tourist Arrivals to Balearic Islands Using Meteorological Variables and Artificial Neural Networks. **Centre de Recerca Econòmica**, 2008.
- ANDRAWIS, R.R; ATIYA, A.F; EL-SHISHINY, H. Combination of long term and short term forecasts, with application to tourism demand forecasting. **International Journal of Forecasting**, v.27, n.3, p.870-886, 2011.
- ANDRAZ, J.L.M; GOUVEIA, P.M.D.C.B; RODRIGUES, P.M.M. Modelling and forecasting the UK tourism growth cycle in Algarve. **Tourism Economics**, v.15, n.2, p.323-338, 2009.
- AO, S.I. A hybrid neural network cybernetic system for quantifying cross-market dynamics and business forecasting. **Soft computing**, v.15, n.6, p.1041-1053, 2011.
- ARMSTRONG, J, S. **Principles of forecasting: A Handbook for Researchers and Practitioners**. Kluwer Academic Publishers 2001.
- ATHANASOPOULOS, G; AHMED, R.A; HYNDMAN, R.J. Hierarchical forecasts for Australian domestic tourism. **International Journal of Forecasting**, v.25, n.1, p.146-166, 2009.
- ATHANASOPOULOS, G; HYNDMAN, R.J. Modelling and forecasting Australian domestic tourism. **Tourism Management**, v.29, n.1, p.19-31, 2008.
- ATSALAKIS G.S; UCENIC C.I. Evolutionary Computing and Applications in the Tourism Sector for its Sustainable Development Case Study: Using ANFIS for Forecasting Tourism Demand. **Wseas transactions on business and economics**; v.4, n.1; p.1-8, 2007.
- AYEH, J.K; LIN, S. 'Estimating tomorrow's tourist arrivals': forecasting the demand for China's tourism using the general-to-specific approach. **Tourism and Hospitality Research**, v.11, n.3, p.197-206, 2011.
- BALDIGARA, T; MAMULA, M. Modelling international tourism demand using seasonal ARIMA models. **Tourism and Hospitality Management**, v.21, n.1, p.19-31, 2015.
- BANGWAYO-SKEETE, P.F; SKEETE, R.W. Can Google data improve the forecasting performance of tourist arrivals? Mixed-data sampling approach. **Tourism Management**, v.46, p.454-464, 2015.
- BERENGUER, T.M; BERENGUER, J.A.M; GARCÍA, M.E.B; POL, A.P; MORENO, J.J.M. Models of artificial neural networks applied to demand forecasting in nonconsolidated tourist destinations. **European Journal of Research Methods for the Behavioral and Social Sciences**, v.11, n.2, p.35-44, 2015.

- BLAKE, A., DURBARRY, R., EUGENIO-MARTIN, J.L., GOOROOCHURN, N., HAY, B., LENNON, J, SINCLAIR, M.T; SUGIYARTO, G; YEOMAN, I. Integrating forecasting and CGE models: The case of tourism in Scotland. **Tourism Management**, v.27, n.2, p.292-305, 2006.
- BO, X; SHI-TING, L. Management of Tourism Resources and Demand Based on Neural Networks. **Intelligent Computation Technology and Automation (ICICTA), 2014 7th International Conference on.IEEE**, 2014.p.348-351.
- BONHAM, C; GANGNES, B; ZHOU, T. Modeling tourism: A fully identified VECM approach. **International Journal of Forecasting**, v.25, n.3, p.531-549, 2009.
- BORHAN, N; ARSAD, Z. Forecasting international tourism demand from the US, Japan and South Korea to Malaysia: A SARIMA approach.In: **Proceedings Of The 21st National Symposium On Mathematical Sciences (Sksm21): Germination of Mathematical Sciences Education and Research towards Global Sustainability**.AIP Publishing, 2014.p.955-960.
- BOTHA, I; SAAYMAN, A. Time varying parameter error correction model approach to forecasting tourist arrivals in South Africa. **Studies in Economics and Econometrics**, v.36, n.1, p.23-42, 2012.
- BOTZORIS, G; VARAGOULI, E; PROFILLIDIS, V; PAPADOPOULOS, B; LATHIRAS, P. Forecast of tourism demand with the use of fuzzy and cointegration econometric techniques. **Journal of Computational Methods in Sciences and Engineering**, v.14, n.4, 5, p.245-257, 2014.
- BRIDA, J.G; RISSO, W.A. Research note: Tourism demand forecasting with SARIMA models—the case of South Tyrol. **Tourism Economics**, v.17, n.1, p.209-221, 2011.
- CAI, Z; LU, S; ZHANG, X. Tourism demand forecasting by support vector regression and genetic algorithm. **Computer Science and Information Technology, 2009.ICCSIT 2009.2nd IEEE International Conference on.IEEE**, 2009.p.144-146.
- CANG, S. A Comparative Analysis of Three Types of Tourism Demand Forecasting Models: Individual, Linear Combination and Non-linear Combination. **International Journal of Tourism Research**, v.16, n.6, p.596-607, 2014.
- CANG, S; YU, H. A combination selection algorithm on forecasting. **European Journal of Operational Research**, v.234, n.1, p.127-139, 2014.
- CHANG, C; SRIBOONCHITTA, S; WIBOONPONGSE, A. Modelling and forecasting tourism from East Asia to Thailand under temporal and spatial aggregation. **Mathematics and Computers in Simulation**, v.79, n.5, p.1730-1744, 2009.
- CHEN, C; LAI, M; YEH, C. Forecasting tourism demand based on empirical mode decomposition and neural network. **Knowledge-Based Systems**, v.26, p.281-287, 2012.
- CHEN, K. Combining linear and nonlinear model in forecasting tourism demand. **Expert Systems with Applications**, v.38, n.8, p.10368-10376, 2011.
- CHEN, K; WANG, C. Support vector regression with genetic algorithms in forecasting tourism demand. **Tourism Management**, v.28, n.1, p.215-226, 2007.
- CHEN, M; YING, L; PAN, M. Forecasting tourist arrivals by using the adaptive network-based fuzzy inference system. **Expert Systems with Applications**, v.37, n.2, p.1185-1191, 2010.

- CHEN, R.J.C. Before and after the inclusion of intervention events: an evaluation of alternative forecasting methods for tourist flows. **Tourism Analysis**, v.10, n.3, p.269-276, 2005.
- CHENG, D; LIU, L. Forecasting of tourism demand for Guilin based on combined model. **Computational Sciences and Optimization (CSO), 2014 Seventh International Joint Conference on.IEEE**, 2014,p.100-103.
- CHEUNG, Y; YAP, G.C.L. Bootstrapping Australian inbound tourism. **International Congress on Modelling and Simulation**, 12–16 December 2011.
- CHON, K., LI, G; LIN, S; GAO, Z. Recovery of Tourism Demand in Hong Kong From the Global Financial and Economic Crisis. **Journal of China Tourism Research**, v.6, n.3, p.259-278, 2010.
- CHOU, C; HSIEH, S; TSENG, H.The crowding-out effects of Chinese tourists on inbound tourism in Taiwan. **Tourism Economics**, v.20, n.6, p.1235-1251, 2014.
- CHU, F. A fractionally integrated autoregressive moving average approach to forecasting tourism demand. **Tourism Management**, v.29, n.1, p.79-88, 2008(a).
- CHU, F. Analyzing and forecasting tourism demand with ARAR algorithm. **Tourism Management**, v.29, n.6, p.1185-1196, 2008(b).
- CHU, F. Forecasting tourism demand with ARMA-based methods.**Tourism Management**, v.30, n.5, p.740-751, 2009.
- CHU, F. A piecewise linear approach to modeling and forecasting demand for Macau tourism. **Tourism Management**, v.32, n.6, p.1414-1420, 2011.
- CHU, F. Using a logistic growth regression model to forecast the demand for tourism in Las Vegas. **Tourism Management Perspectives**, v.12, p.62-67, 2014.
- CLAVERIA, O; DATZIRA, J. Forecasting tourism demand using consumer expectations. **Tourism Review**, v.65, n.1, p.18-36, 2010.
- CLAVERIA, O; MONTE, E; TORRA, S. Tourism demand forecasting with neural network models: different ways of treating information. **International Journal of Tourism Research**, 2014.
- CLAVERIA, O; MONTE, E; TORRA, S. Common trends in international tourism demand: Are they useful to improve tourism predictions? **Tourism Management Perspectives**, v.16, p.116-122, 2015.
- CLAVERIA, O; TORRA, S. Forecasting tourism demand to Catalonia: Neural networks vs.time series models. **Economic Modelling**, v.36, p.220-228, 2014.
- COSHALL, J.T. Combining volatility and smoothing forecasts of UK demand for international tourism. **Tourism Management**, v.30, n.4, p.495-511, 2009.
- COSHALL, J.T; CHARLESWORTH, R. A management orientated approach to combination forecasting of tourism demand. **Tourism Management**, v.32, n.4, p.759-769, 2011.
- CUNHA, S.K., CUNHA, J.C. Clusters de turismo: abordagem teórica e avaliação. **Revista de desenvolvimento econômico**, Salvador, BA. Ano VIII, n.13, p.60-67, Jan.2006.
- DIVINO, J.A; MCALEER, M. Modelling sustainable international tourism demand to the Brazilian Amazon. **Environmental Modelling & Software**, v.24, n.12, p.1411-1419, 2009.

- DIVINO, J.A; MCALEER, M. Modelling and forecasting daily international mass tourism to Peru. **Tourism Management**, v.31, n.6, p.846-854, 2010.
- ELENA, M; LEE, M.H; SUHARTONO, H; HOSSEIN, I; RAHMAN, N.H.A; BAZILAH, N. A.Fuzzy Time Series and Sarima Model for Forecasting Tourist Arrivals to Bali. **Jurnal Teknologi**, v.57, n.1, 2012.
- FAN, G; LIU, Z.An analysis and forecast of tourism demand based on web data mining in china.**Journal of Theoretical & Applied Information Technology**, v.48, n.2, 2013.
- FERNANDES, P.O; TEIXEIRA, J.P; FERREIRA, J.J; AZEVEDO, S.G. Modelling tourism demand: a comparative study between artificial neural networks and the Box-Jenkins methodology. **Romanian Journal of Economic Forecasting**, v.3, 2008.
- FERNANDES, P.O; TEIXEIRA, J.P; FERREIRA, J.J; AZEVEDO, S.G.Training neural networks by resilient backpropagation algorithm for tourism forecasting. **Management Intelligent Systems**. p.41-49, 2013.
- FRITZ, R.G; BRANDON, C; XANDER, J. Combining Time-Series and Econometric Forecasts of Tourism Activity. **Annals of Tourism Research**, v.11, n.2, p.219 - 230, 1984.
- GOH, C. Exploring impact of climate on tourism demand. **Annals of Tourism Research**, v.39, n.4, p.1859-1883, 2012.
- GOH, C; LAW, R; MOK, H.M.K. Analyzing and forecasting tourism demand: A rough sets approach. **Journal of Travel Research**, v.46, n.3, p.327-338, 2008.
- GOUNOPOULOS, D; PETMEZAS, D; SANTAMARIA, D. Forecasting tourist arrivals in Greece and the impact of macroeconomic shocks from the countries of tourists' origin. **Annals of Tourism Research**, v.39, n.2, p.641-666, 2012.
- GUIZZARDI, A; MAZZOCCHI, M. Tourism demand for Italy and the business cycle.**Tourism Management**, v.31, n.3, p.367-377, 2010.
- GUNTER, U; ÖNDER, I. Forecasting international city tourism demand for Paris: Accuracy of uni-and multivariate models employing monthly data. **Tourism Management**, v.46, p.123-135, 2015.
- GUO, J. Tourism Demand Forecast and Analysis to Shanxi Based on SVM. **Informatics in Control, Automation and Robotics**, p.793-797, 2011.
- HADAVANDI, E; SHAVANDI, H; GHANBARI, A. Notice of Retraction Hybridization of adaptive Neuro-Fuzzy Inference System and data preprocessing techniques for tourist arrivals forecasting. **Natural Computation (ICNC), 2010 Sixth International Conference on.IEEE**, 2010.p.1692-1695.
- HAN, Z; DURBARRY, R; SINCLAIR, M.T. Modelling US tourism demand for European destinations. **Tourism management**, v.27, n.1, p.1-10, 2006.
- HONG, W.C; DONG, Y; CHEN, L.Y; WEI, S.Y. SVR with hybrid chaotic genetic algorithms for tourism demand forecasting. **Applied Soft Computing**, v.11, n.2, p.1881-1890, 2011.
- HSU, L; WANG, C. Applied multivariate forecasting model to tourism industry.**Turizam: znanstveno-stručni časopis**, v.56, n.2, p.159-172, 2008.
- HUANG, Y; LIN, C. Developing an interval forecasting method to predict undulated demand.**Quality & Quantity**, v.45, n.3, p.513-524, 2011.

- HUARNG, K.H; HUI-KUANG YU, T; MOUTINHO, L; WANG, Y.C. Forecasting tourism demand by fuzzy time series models. **International Journal of Culture, Tourism and Hospitality Research**, v.6, n.4, p.377-388, 2012.
- HYNDMAN, R.J; AHMED, R.A; ATHANASOPOULOS, G; SHANG, H.L. Optimal combination forecasts for hierarchical time series. **Computational Statistics & Data Analysis**, v.55, n.9, p.2579-2589, 2011.
- KAYNAK, E; I.ROJAS-MÉNDEZ, J. Predicting tourism market potential of Chile by use of a qualitative forecasting technique. **International Journal of Commerce and Management**, v.24, n.2, p.167-179, 2014.
- KITCHENHAM, B. Guidelines for performing Systematic Literature Reviews in Software Engineering, Version 2.3, **EBSE Technical Report**, Keele University and University of Durham, 2007.
- KO, K.M; CHEN, J.F; NGUYEN, T.L; HSU, B; SHU, M.H. Forecasting Inbound Tourism Demand in Thailand with Grey model. **WSEAS Transactions On Mathematics**, v.13, p.96-104, 2014.
- KRASIĆ, D; GATTI, P. Forecasting methodology of maritime passenger demand in a tourist destination. **PROMET-Traffic&Transportation**, v.21, n.3, p.183-190, 2009.
- KULENDRAN, N; WONG, K.K.F. Modeling seasonality in tourism forecasting. **Journal of Travel Research**, v.44, n.2, p.163-170, 2005.
- KULENDRAN, N; WONG, K.K.F. Determinants versus composite leading indicators in predicting turning points in growth cycle. **Journal of Travel Research**, v.50, n.4, p.417-430, 2011.
- LA FRANCA, L; CATALANO, M; CASTELLUCCIO, F; MONTANO, F. Travelling towards and from minor islands through non-conventional air transport: demand and cost analysis. **WIT Transactions on Ecology and the Environment**, v.130, p.251-266, 2010.
- LEE, C; SONG, H; MJELDE, J. The forecasting of International Expo tourism using quantitative and qualitative techniques. **Tourism Management**, v.29, n.6, p.1084-1098, 2008.
- LI, G; SONG, H. New forecasting models. **Journal of Travel & Tourism Marketing**, v.21, n.4, p.3-13, 2007.
- LI, G; SONG, H; WITT, S.F. Recent Developments in Econometric Modeling and Forecasting. **Journal of Travel Research**, v.44, p.82-99, August 2005.
- LI, G; SONG, H; WITT, S.F. Time varying parameter and fixed parameter linear AIDS: An application to tourism demand forecasting. **International Journal of Forecasting**, v.22, n.1, p.57-71, 2006.
- LI, G; WONG, K.K; SONG, H; WITT, S.F. Tourism demand forecasting: A time varying parameter error correction model. **Journal of Travel Research**, v.45, n.2, p.175-185, 2006.
- LIANG, Y. Forecasting models for Taiwanese tourism demand after allowance for Mainland China tourists visiting Taiwan. **Computers & Industrial Engineering**, v.74, p.111-119, 2014.
- LIM, C; MCALEER, M. Analyzing the behavioral trends in tourist arrivals from Japan to Australia. **Journal of Travel Research**, v.43, n.4, p.414-421, 2005.
- LIN, V.S; GOODWIN, P; SONG, H. Accuracy and bias of experts' adjusted forecasts. **Annals of Tourism Research**, v.48, p.156-174, 2014.

- LIN, V.S; LIU, A; SONG, H. Modeling and Forecasting Chinese Outbound Tourism: An Econometric Approach. **Journal of Travel & Tourism Marketing**, v.32, n.1-2, p.34-49, 2015.
- LIU, L. Demand forecast of regional tourism based on variable weight combination model. **Information Computing and Applications**.2012.p.665-670.
- LU, F; ZHU, X; PENG, Z; ZHOU, X. Combination forecast on tourism demands based on IOWA operator. **Metallurgical and Mining Industry**, No.4, 2015.
- MARTINS, V.L.M; WERNER, L; BELLEZA, M.R. Tourism Demand In The World Cup 2014 In Brazil: An estimate based on the combination of forecasts and mathematical adjustment. **Espacios**. v.34, n.8, p.5, 2013.
- MEDEIROS, M.C; MCALEER, M; SLOTTJE, D; RAMOS, V; REY-MAQUIEIRA, J. An alternative approach to estimating demand: Neural network regression with conditional volatility for high frequency air passenger arrivals. **Journal of Econometrics**, v.147, n.2, p.372-383, 2008.
- MIN, J.C.H. Forecasting Japanese tourism demand in Taiwan using an intervention analysis. **International Journal of Culture, Tourism and Hospitality Research**, v.2, n.3, p.197-216, 2008.
- MIN, W.A. Research on Tourism Market Forecast and Evaluation Based on the Application of Linear Regression Model. **International Journal of u-and e-Service, Science and Technology**, v.7, n.6, p.213-226, 2014.
- MOURA, F.A; MONTINI, A. A. Modelagem da Demanda Turística Internacional para o Estado de São Paulo, **Sociedade, Contabilidade e Gestão**, Rio de Janeiro, v.5, n.2, jul/dez 2010.
- MOUTINHO, L; HUARNG, K.H; YU, T.H.K; CHEN, C.Y. Modeling and forecasting tourism demand: the case of flows from Mainland China to Taiwan. **Service Business**, v.2, n.3, p.219-232, 2008.
- BRASIL. Ministério do Turismo. **Anuário Estatístico de Turismo**. v.40, ano base 2013, 2014.
- NANTHAKUMAR, L; SUBRAMANIAM, T; KOGID, M. Is 'Malaysia truly Asia'? forecasting tourism demand from ASEAN using SARIMA approach. **TOURISMOS: An International Multidisciplinary Journal of Tourism**, v.7, n.1, p.367-381, 2012.
- OH, C; MORZUCH, B.J. Evaluating time-series models to forecast the demand for tourism in singapore comparing within-sample and postsample results. **Journal of Travel Research**, v.43, n.4, p.404-413, 2005.
- OUERFELLI, C. Co-integration analysis of quarterly European tourism demand in Tunisia. **Tourism Management**, v.29, n.1, p.127-137, 2008.
- PAI, P; HONG, W; LIN, C. Forecasting tourism demand using a multifactor support vector machine model. **Computational Intelligence and Security**, p.512-519, 2005.
- PAI, P; HUNG, K; LIN, K. Tourism demand forecasting using novel hybrid system. **Expert Systems with Applications**, v.41, n.8, p.3691-3702, 2014.
- PANCHEV, C; THEOCHAROUS, A. A Neural Network model of the impact of political instability on tourism. Neural Networks (IJCNN), **The 2013 International Joint Conference on.IEEE**, p.1-7, 2013

- PENG, B; SONG, H; CROUCH, G I. A meta-analysis of international tourism demand forecasting and implications for practice. **Tourism Management**, v.45, p.181-193, 2014.
- PETREVSKA, B. Estimating tourism demand: the case of FYROM. **Tourismos: An International Multidisciplinary Journal of Tourism**, v.8, n.1, p.199-212, 2013.
- PETROPOULOS, C; NIKOLOPOULOS, K; PATELIS, A; ASSIMAKOPOULOS, V. A technical analysis approach to tourism demand forecasting. **Applied Economics Letters**, v.12, n.6, p.327-333, 2005.
- PETROPOULOS, C; NIKOLOPOULOS, K; PATELIS, A; ASSIMAKOPOULOS, V; ASKOUNIS, D. Tourism technical analysis system. **Tourism Economics**, v.12, n.4, p.543-563, 2006.
- POUDYAL, N.C; PAUDEL, B; TARRANT, M.A. A time series analysis of the impact of recession on national park visitation in the United States. **Tourism Management**, v.35, p.181-189, 2013.
- PROFILLIDIS, V.A; BOTZORIS, G.N; LATHIRAS, P. Fuzzy Models and Cointegration Analysis for the Forecast of Tourist Demand. **EUSFLAT Conf.** 2005. p.53-60.
- RUFINO, C.C. Forecasting international demand for Philippine tourism. **DLSU Business & Economics Review**, v.21, n.1, p.61-76, 2011.
- SERRA, J; CORREIA, A; RODRIGUES, P.M.M. A comparative analysis of tourism destination demand in Portugal. **Journal of Destination Marketing & Management**, v.2, n.4, p.221-227, 2014.
- SHAHRABI, J; HADAVANDI, E; ASADI, S. Developing a hybrid intelligent model for forecasting problems: Case study of tourism demand time series. **Knowledge-Based Systems**, v.43, p.112-122, 2013.
- SHAREEF, R. Modelling the Impact of Extreme Events in Forecasting Tourism Demand. **International Congress on Modelling and Simulation - Land, Water and Environmental Management: Integrated Systems for Sustainability (MODSIM)**, 2007
- SHEN, S; LI, G; SONG, H. Combination forecasts of International tourism demand. **Annals of Tourism Research**, v.38, n.1, p.72-89, 2011.
- SHEN, S; LI, G; SONG, H. An assessment of combining tourism demand forecasts over different time horizons. **Journal of Travel Research**, v.47, n.2, p.197-207, 2008.
- SHEN, S; LI, G; SONG, H. Effect of seasonality treatment on the forecasting performance of tourism demand models. **Tourism Economics**, v.15, n.4, p.693-708, 2009.
- SHU, M.H; HUNG, W; HSU, B; NGUYEN, T.L; LU, C. Forecasting with Fourier Residual Modified ARIMA Model-An Empirical Case of Inbound Tourism Demand in New Zealand. **WSEAS Transactions on Mathematics**, v.13, p.12-21, 2014.
- SMERAL, E; WÜGER, M. Does complexity matter? Methods for improving forecasting accuracy in tourism: the case of Austria. **Journal of Travel Research**, v.44, n.1, p.100-110, 2005.
- SONG, H; GAO, B.Z; LIN, V; S. Combining statistical and judgmental forecasts via a web-based tourism demand forecasting system. **International Journal of Forecasting**, v.29, n.2, p.295-310, 2013.
- SONG, H; HYNDMAN, R.J. Tourism forecasting: An introduction. **International Journal of Forecasting**, v.27, n.3, p.817-821, 2011.

- SONG, H; LI, G. Tourism demand modelling and forecasting — A review of recent research. **Tourism Management**, v.29, n.2, p.203-220, 2008.
- SONG, H; LI, G; WITT, S.F; ATHANASOPOULOS, G. Forecasting tourist arrivals using time-varying parameter structural time series models. **International Journal of Forecasting**, v.27, n.3, p.855-869, 2011.
- SONG, H., LI, G; WITT, S.F; FEI, B. Tourism demand modelling and forecasting: how should demand be measured?, **Tourism Economics**, v.16, n.1, p.63-81, 2010.
- SONG, H; LIN, S. Impacts of the financial and economic crisis on tourism in Asia. **Journal of Travel Research**, 2009.
- SONG, H; LIN, S; ZHANG, X; GAO, Z. Global financial/economic crisis and tourist arrival forecasts for Hong Kong. **Asia Pacific Journal of Tourism Research**, v.15, n.2, p.223-242, 2010.
- SONG, H; WITT, S.F. Forecasting international tourist flows to Macau. **Tourism management**, v.27, n.2, p.214-224, 2006.
- SONG, H; WITT, S.F.; ZHANG, X. Developing a web-based tourism demand forecasting system. **Tourism Economics**, v.14, n.3, p.445-468, 2008.
- SONG, H; WITT, S.F; WONG, K.F; WU, D.C. An empirical study of forecast combination in tourism. **Journal of Hospitality & Tourism Research**, v.33, n.1, p.3-29, 2009.
- TEIXEIRA, J.P; FERNANDES, P.O. Tourism time series forecast-different ANN architectures with time index input. **Procedia Technology**, v.5, p.445-454, 2012.
- TSAUR, R; KUO, T. The adaptive fuzzy time series model with an application to Taiwan's tourism demand. **Expert systems with Applications**, v.38, n.8, p.9164-9171, 2011.
- TSAUR, R; KUO, T. Tourism Demand Forecasting Using A Novel High-Precision Fuzzy Time Series Model. **International Journal of Innovative Computing, Information and Control**, v.10, p.695-701, 2014.
- TSENG, H; MA, Z; CHOU, L. An Author-based Citation and Co-citation Analysis on Tourism Research. **Asia Pacific Management Review**, v.15, n.4, p.585-600, 2010.
- VU, J.C; TURNER, L.W. Regional data forecasting accuracy: the case of Thailand. **Journal of Travel Research**, v.45, n.2, p.186-193, 2006.
- WANG, J; HU, M.M; GE, P; REN, P.Y; ZHAO, R. A Forecasting Model for Short Term Tourist Arrival Based on the Empirical Mode Decomposition and Support Vector Regression. **Proceedings of 2013 4th International Asia Conference on Industrial Engineering and Management Innovation (IEMI2013)**, p.1009-1021, 2014.
- WITT, S.F; SONG, H. Forecasting tourism flows. In A.Lockwood, & S.Medlik (Eds.), **Tourism and hospitality in the 21st Century**.p.106–118, 2002.
- WITT, S.F; WITT, C.A. Forecasting tourism demand: A review of empirical research. **International Journal of Forecasting**, n.11, p.447-475, 2011.
- WONG, K.K.F; SONG, H; CHON, K.S. Bayesian models for tourism demand forecasting. **Tourism Management**, v.27, n.5, p.773-780, 2006.
- WONG, K.K.F; SONG, H; WITT, S.F; WU, D.C. Tourism forecasting: To combine or not to combine? **Tourism Management**, 28, 1068–1078, 2007.

WTO (World Tourism Organization). **Tourism Highlights**: 2015 Edition. 2015. Disponível em: <http://www.unwto.org/facts/menu.html>. Acesso em: dez. 2015. 2015a

_____. **World Tourism Barometer**. v.13, n.5, 2015 Disponível em: <http://www.unwto.org/facts/menu.html>. Acesso em: dez. 2015. 2015a

_____. **Methodological Notes**, Disponível em: <http://www.unwto.org/facts/menu.html>. Acesso em: dez. 2015. 2015c

WTTC. World Travel & Tourism Council. **Economic Impact of Travel & Tourism**, 2015 annual update summary.2015. Disponível em: <http://www.wttc.org/research/economic-research/economic-impact-analysis/>. Acesso em: Ago.2015

WU, Q; ZHANG, C.J; GAO, L; LI, X. Training neural networks by electromagnetism-like mechanism algorithm for tourism arrivals forecasting. **Bio-Inspired Computing: Theories and Applications (BIC-TA), 2010 IEEE Fifth International Conference on.IEEE**, p.679-688, 2010.

WU, Q; LAW, R; XU, X. A sparse Gaussian process regression model for tourism demand forecasting in Hong Kong. *Expert Systems with Applications*, v.39, n.5, p.4769-4774, 2012.

XIUHA, L. Tourism Demand Forecasting in Weifang Based on Artificial Neural Network.**Control, Automation and Systems Engineering (CASE), 2011 International Conference on.IEEE**, p.1-4, 2011.

YANG, X; PAN, B; EVANS, J.A; LV, B. Forecasting Chinese tourist volume with search engine data.*Tourism Management*, v.46, p.386-397, 2015.

YAO, L; MA, R; JIN, M; GE, P; REN, P. Forecasting Real-Time Tourist Arrivals using Hierarchical Cluster and Gaussian Fitting Algorithm: A Case Study of Jiuzhai Valley. **Appl.Math**, v.8, n.3, p.1425-1434, 2014.

YONG, Z; BROOK, R. Modeling and Forecasting International Arrivals from China to Australia. **International Conference on Management Science and Engineering Management**, 2014.

YU, G; SCHWARTZ, Z. Forecasting short time-series tourism demand with artificial intelligence models. **Journal of travel Research**, v.45, n.2, p.194-203, 2006.

YUJIE, Y; ZHENG, W. Modelling Inbound Tourism Demand in Shanghai. **Management and Service Science, 2009.MASS'09.International Conference on.IEEE**, p.1-4, 2009.

ZHOU-GRUNDY, Y; TURNER, L.W. The Challenge of Regional Tourism Demand Forecasting: The Case of China. **Journal of Travel Research**, January 6, 2014.

III. ARTIGO 2: Comparação da Acurácia de Previsões de Demanda Turística em Sedes Olímpicas

Resumo: Boas previsões acerca da demanda turística de um local servem de apoio para corretas tomadas de decisão por parte dos gestores, especialmente quando se tem em vista a realização de um evento de grandes proporções que afeta diretamente no desenvolvimento urbano e econômico locais. Este estudo tem o objetivo de avaliar o comportamento da demanda turística frente à realização de um dos maiores megaeventos da atualidade. Para tanto, a demanda turística de dois países que sediaram Jogos Olímpicos foi modelada e prevista através das duas metodologias, uma linear e outra não linear e as previsões obtidas foram combinadas por cinco métodos, sendo três lineares e dois não lineares. Os dados foram divididos em observações para modelagem e as últimas doze observações foram utilizadas para avaliação da acurácia das previsões obtidas. Em ambas as séries, as previsões individuais para as observações utilizadas na modelagem, obtidas pelo modelo RNA, foram mais acuradas que as geradas pelo modelo SARIMA, de acordo com as três medidas de acurácia analisadas. A utilização de técnicas de combinação, sobretudo pelo método de regressão linear, aumentou ainda mais a acurácia das previsões. Ambos os modelos selecionados se mostraram acurados para as previsões de julho de 2012 no Reino Unido e agosto de 2004 na Grécia (MAPE < 10%). Todas as previsões combinadas apresentaram melhor desempenho que a previsão obtida pela modelagem ARIMA, sendo a combinação via regressão linear o método que proporcionou melhor acurácia às previsões. Não foi observado impacto na demanda devido à realização dos Jogos Olímpicos uma vez que o evento ocorreu em um período de alta temporada onde os modelos escolhidos mostraram-se mais precisos.

Palavras-chave: Previsão de Demanda, Combinação de Previsões, Megaeventos

Abstract: Precise forecasts concerning tourism demand for a certain place serve as support for correct decision making by managers, especially when the realization of a mega event directly affecting urban and economic local development is considered. This study aims to evaluate the behavior of tourism demand regarding the holding of one of the biggest mega-events of our days. In this regard, the tourism demand of two countries that hosted the Olympic Games was modeled and forecasted using two different methodologies, a linear and a non-linear and the resulting forecasts were combined utilizing five methods – three linear and two non-linear. The data were divided into observations for modeling and the latest

twelve observations were used to evaluate the accuracy of the obtained forecasts. In both series, the individual predictions obtained by ANN model, for the observations used in the modeling step, were more accurate than those obtained by SARIMA model, according to the three analyzed accuracy measurements. The use of techniques of combination, especially considering the linear regression method, further increased the precision of the predictions. Both selected models were accurate to forecast July 2012 in the UK and August 2004 in Greece (MAPE < 10%). All forecasts combined performed better than the forecast obtained by ARIMA modeling, and the combination via linear regression method provided better accuracy to the forecasts. No impact in demand was observed because of the holding of the Olympic Games because the event took place during the high season, when the chosen models displayed more exactitude.

Keywords: Demand forecast, Forecast combination, Mega-events

1. Introdução

Megaeventos, tais como Jogos Olímpicos, Copa do Mundo e Jogos Pan-Americanos estão associados a um grande volume de gastos públicos, à construção de instalações e infraestrutura e às estratégias de desenvolvimento e revitalização de áreas públicas que geram ganhos a curto prazo para as partes envolvidas (HALL, 2006). Esses megaeventos esportivos citados podem servir de incentivo para a construção de novas instalações, limpeza e renovação dos espaços das cidades e melhoria da infraestrutura de transportes nos países que os sediam (LONDON ASSEMBLY, 2007). Além dos legados físicos citados, Fourie e Santana-Gallego (2011) também destacam a construção do sentimento de patriotismo ou identidade da nação.

No levantamento realizado por Fourie e Santana-Gallego (2011) em sedes de megaeventos foi verificado que houve aumento médio de 8,1% no número de turistas, movimentos significativos de volume de turistas entre os países vizinhos ou que compartilham a língua, moeda ou laços coloniais e, por se tratar de eventos internacionais, aumento de 12,5% no fluxo de turistas oriundos de países que também participam do evento. Além disso, os autores apontam o efeito da sazonalidade, onde só houve aumentos significativos do número de turistas quando o evento ocorreu no período de baixa-temporada.

Para Goh e Law (2002) a alocação dos recursos financeiros suficientes para as operações, comercializações, investimentos e planejamento por parte dos governantes, ou

tomadores de decisão, deve ser embasada em previsões confiáveis e acuradas acerca do volume de turistas. Uma demanda superestimada resultaria no uso ineficiente de recursos e baixos retornos de investimento, ao passo que uma demanda subestimada teria como resultado congestionamentos dos pontos de entrada e atrações turísticas, transporte inadequado, perda de oportunidades de mercado, além da degradação da imagem do país anfitrião (TIDESWELL; MULES; FAULKNER, 2001; STEKLER, 2003).

Ao avaliar o crescimento do campo de pesquisa com relação ao turismo, Tseng, Ma e Chou (2010) constaram o crescente número de artigos voltados para previsão de sua demanda, ratificando a importância desse tipo de análise. Diversos estudos procuraram encontrar o tipo de modelagem mais adequado para prever dados de demanda turística (SONG; LI, 2008; SONG; HYNDMAN, 2011) e Song e Li (2008) sugeriram a utilização da combinação de previsões como alternativa para melhoria da acurácia.

Segundo Armstrong (2001), o fato de combinar previsões obtidas de técnicas distintas melhora a acurácia das previsões justamente pelo fato de assumir-se que as técnicas individuais de previsão capturam características distintas da série. No âmbito do turismo, Oh e Morzuch (2005) combinaram, através da média aritmética, as previsões geradas por modelos distintos de séries temporais para a demanda de Singapura e concluíram que o desempenho das previsões combinadas foi no mínimo tão acurado quanto o desempenho da pior previsão individual.

Diante da importância de realizar boas previsões, deseja-se compreender o comportamento da demanda turística em frente à realização de um megaevento. A demanda de países que já sediaram Jogos Olímpicos de verão foi modelada e prevista até a realização do evento e os desempenhos das previsões foram analisados. As previsões foram estimadas via duas modelagens quantitativas, ARIMA (*autorregressive integrated moving average*) e RNA (*artificial neural networks*) e combinadas por cinco métodos: médias aritmética, geométrica e harmônica, variância mínima e regressão linear.

A seção posterior a esta introdução aprofunda os conhecimentos sobre o turismo em megaeventos, bem como detalha as técnicas quantitativas de previsão e combinação de previsões. Os procedimentos metodológicos utilizados para o levantamento dos dados e análises serão descritos na seção correspondente, seguida pela seção que apresentará os principais resultados encontrados. O artigo se encerra com algumas discussões e conclusões acerca dos achados.

2. O Turismo de megaeventos e suas previsões

Um megaevento pode ser definido por um acontecimento de curta duração, porém de grande escala (ROCHE, 1994) e envolve grandes volumes de público, gastos do setor público, mercado consumidor, cobertura da mídia, construção de instalações e impacto sobre a economia e a sociedade do país anfitrião (HALL, 2006). Dessa forma, feiras e exposições também poderiam ser incluídas na categoria de megaeventos, porém, no senso comum, os megaeventos estão associados a grandes competições esportivas (TAVARES, 2011). Horne e Manzenreiter (2006) mencionam que o impacto e exploração de eventos voltados ao esporte foram ampliados com a cobertura televisiva em escala mundial, onde a sua transmissão virou uma rede de negócios (direito de transmissão, patrocínios, etc) e de oportunidades de promoção (legados) para os anfitriões.

Dois legados apontados por Roche (1994) são a imagem e a identidade da nação anfitriã. De acordo com Hall (1992), os megaeventos criam um impacto de crescimento potencial no número de viagens internacionais para o país sede. Para Santovito (2010), os turistas que chegam para acompanhar um evento, acabam retornando em outro momento, além do aumento da chegada de outros turistas após a realização do evento, motivados pelo legado de imagem positiva da nação. Solberg e Preuss (2007) destacam que o período de preparações (pré-evento) também pode gerar atividades consideráveis que acabam repercutindo no turismo.

Para avaliar o impacto econômico de um megaevento é importante destacar que as estimativas dependem fortemente de contagens precisas dos seus visitantes (CROMPTON, 2010). O autor menciona que muitas vezes o impacto econômico de um megaevento pode ser inflado pelo fato de que aproximadamente um terço dos visitantes contabilizados durante a sua realização veio atraído também por outros recursos do país, de modo que suas despesas seriam geradas independentemente da realização do megaevento.

Além da avaliação do impacto econômico, as previsões precisas de demanda turística servem de suporte para corretas tomadas de decisão por parte dos gestores, como no dimensionamento da capacidade produtiva e gerenciamento da mão-de-obra para o período de realização do megaevento (MOURA; MONTINI, 2010). A realização desses eventos afeta diretamente no desenvolvimento urbano de um local. Segundo Solberg e Preuss (2007) o país que pretende sediar este tipo de evento com o intuito de melhorar a sua atratividade como destino turístico deve analisar o desenvolvimento urbano sob três perspectivas: (i) o desenvolvimento planejado para a cidade independentemente da realização do evento; (ii) a

infraestrutura demandada pelo evento que está inclusa no plano de desenvolvimento da cidade e (iii) a infraestrutura específica para o evento que não faz parte do planejamento inicial.

Visando dar suporte a implementação de ações que promovam o desenvolvimento urbano, faz-se necessário dimensionar adequadamente a demanda para suprir as necessidades para que tal desenvolvimento ocorra. Segundo a meta-análise sobre previsão de demanda turística internacional realizada por Peng, Song e Crouch (2014), as três categorias principais de métodos quantitativos de previsão são: modelos de séries temporais, os modelos econométricos e os de inteligência artificial. No levantamento realizado pelos autores, entre os modelos de séries temporais, os mais utilizados para previsão de demanda voltada ao turismo foram os modelos ARIMA e entre os métodos de inteligência artificial estavam os modelos RNA.

3. Técnicas de previsão

3.1 Metodologia de Box-Jenkins

A análise de uma série temporal é o procedimento de descrever o processo gerador da série através da identificação dos seus padrões, características e propriedades importantes, sendo o maior objetivo a geração de modelos voltados à previsão de observações futuras (GOLDSCHMIDT; PASSOS, 2005). Entre as metodologias criadas para analisar uma série de tempo, os modelos de Box-Jenkins ou ARIMA, desenvolvidos na década de 1970, até hoje são os modelos mais divulgados e utilizados. Esses modelos são classificados como estacionários, pois são baseados na hipótese de que o processo permanece em equilíbrio em torno de um nível médio constante ao longo do tempo (MORETTIN; TOLOI, 2006).

Diversos modelos ARIMA podem ser utilizados para modelar uma série temporal de acordo com as suas características, sendo que os modelos podem ter apenas componentes autoregressivos (AR), componentes de média móvel (MA) e ambos componentes (ARMA). Além disso, séries não estacionárias podem ser modeladas através de modelos ARIMA, onde são realizadas diferenças com o intuito de tornar a série estacionária, e séries com componente sazonal são modeladas através de modelos denominados SARIMA. Pai *et al* (2010) comentam que, tendo em vista a presença de sazonalidade nos dados de previsão voltados para a demanda turística, este último modelo acaba sendo mais amplamente utilizado.

O modelo SARIMA(p,d,q)(P,D,Q)_s é definido conforme a Equação 1.

$$\phi(B)\Phi_p(B^s)\Delta^d\Delta_s^D Z_t = \theta(B)\Theta_Q(B^s)\varepsilon_t$$

Equação 1

Onde $\phi(B)$ é o operador autorregressivo (AR) de ordem p ; $\theta(B)_t$ é o operador médias móveis (MA) de ordem q ; Φ_P é o operador AR sazonal de ordem P ; Θ_Q é o operador MA sazonal de ordem Q ; Δ^d é o operador diferença não sazonal; Δ_s^D é o operador diferença sazonal de ordem s , s é o período sazonal e ε_t é um ruído branco.

3.2 Redes Neurais Artificiais (RNA)

Uma RNA tenta capturar a informação ou conhecimento através de aprendizado de forma similar ao cérebro humano. As unidades de processamento simples (neurônios) que compõem uma RNA são adaptáveis ao ambiente através de interligações (sinapses). Nestas interligações é onde ocorre o processo de aprendizagem por meio de conhecimento experimental adquirido que fica armazenado e disponível para uso (HAYKIN, 2001).

De acordo com Zhang, Patuwo e Hu (1998), esse tipo de modelagem apresenta três características particulares: (i) diferentemente dos métodos tradicionais, as RNAs são métodos auto-adaptativos em que há poucas suposições acerca as características dos dados analisados, podendo ser interpretadas como um método não linear não paramétrico; (ii) possuem capacidade de generalização pois aprendem com os dados; (iii) conseguem aproximar qualquer função contínua que tente explicar a relação entre entradas e saídas a qualquer precisão desejada. Entre os diversos tipos de modelos de RNA, o *perceptron* multicamadas (MLP, *multilayer perceptron*) é o tipo de rede *feedforward* mais utilizada com o intuito de realizar previsões voltadas ao turismo (KON; TURNER, 2005; CLAVERIA; TORRA, 2014).

Uma rede MLP é tipicamente composta por camadas que contêm neurônios, sendo a primeira camada uma entrada onde são recebidas informações externas e a última camada é uma saída com a solução obtida. Entre estas camadas estão as camadas intermediárias ou ocultas. Segundo Braga, Carvalho e Ludermir (2000), o poder computacional desse tipo de rede com múltiplas camadas é muito superior ao das redes sem elas. As camadas interna e externa são fixas, pois são construídas de acordo com a entrada e saída desejadas, já as camadas ocultas e o algoritmo de treino são ajustáveis de modo a maximizar o desempenho da rede. Dessa forma, podem-se obter modelos exploratórios ou causais equivalentes a um modelo de regressão não linear ou modelos de séries temporais não lineares (ZHANG; PATUWO; HU, 1998).

O algoritmo mais utilizado para a fase de treino (aprendizagem) de uma rede é o algoritmo de retropropagação do erro. Neste algoritmo, o treinamento ocorre em duas fases de sentidos opostos, para frente e para trás. No processamento para frente o sinal de entrada parte

da primeira camada e vai de camada em camada (quando há mais de uma camada oculta) até a camada de saída, onde se transforma no resultado da rede (sinal de saída). Na fase para trás, esse sinal de saída é comparado a uma resposta verdadeira e o erro gerado pela diferença entre as duas respostas segue caminho inverso do sinal de entrada de modo a reajustar os pesos sinápticos minimizando este erro (BRAGA; CARVALHO; LUDERMIR, 2000).

A limitação do modelo MLP é que a saída é um modelo não linear resultante de várias combinações lineares das variáveis de entrada, portanto contém muitos parâmetros que são não interpretáveis (KUTNER *et al*, 2005).

3.3 Métodos de combinações de previsões

Com o intuito de melhorar a acurácia das previsões, uma estratégia utilizada com frequência é a de combinar as previsões dos modelos individuais através de algum método (CONSTANTINE; PAPPALARDO, 2010). Essa estratégia foi desenvolvida inicialmente por Bates e Granger no final da década de 1960 e desde então diversos estudos propuseram diferentes métodos de combinação.

A previsão combinada pode ser escrita como uma combinação linear de duas previsões não viesadas, conforme a Equação 2.

$$F_c = wF_1 + (1-w)F_2 \quad \text{Equação 2}$$

Onde F_c é a previsão combinada pelas duas previsões individuais, F_1 e F_2 , e w e $(1-w)$ são os pesos designados para F_1 e F_2 , respectivamente.

O método da variância mínima atribui maior peso à previsão que possui menor variabilidade dos erros. Dessa forma, para calcular os pesos é utilizada a matriz de covariância dos erros das previsões individuais. Para encontrar o valor ótimo de w da Equação 2 é preciso minimizar a variância dos erros da previsão combinada. O peso que minimiza essa variância é dado pela Equação 3.

$$w^* = \frac{(\sigma_2^2 - \rho\sigma_1\sigma_2)}{(\sigma_1^2 + \sigma_2^2 - 2\rho\sigma_1\sigma_2)} \quad \text{Equação 3}$$

Onde σ_1^2 e σ_2^2 são as variâncias dos erros das previsões individuais e ρ o coeficiente de correlação dos erros das previsões.

Este tipo de combinação utilizando duas previsões pode ser estendido para a combinação de n previsões. Newbold e Granger (1974) concluíram que para erros não correlacionados, o termo ρ poderia ser ignorado na estimação dos pesos, pois na prática ele

teria pouca influência nos resultados. Desse modo, a Equação 3 fica resumida como apresentado na Equação 4.

$$w^* = \frac{(\sigma_2^2)}{(\sigma_2^2 + \sigma_1^2)} \quad \text{Equação 4}$$

Os pesos também podem ser estimados através de uma regressão linear, onde a variável resposta é a previsão combinada e as previsões individuais são as variáveis explicativas. Este método possui três variantes conforme o grau de flexibilidade permitida aos pesos. As variantes são expressas pelas Equações 5 a 7.

$$F_c = c + w_1F_1 + w_2F_2 + \varepsilon \quad \text{Equação 5}$$

$$F_c = w_1F_1 + w_2F_2 + \varepsilon \quad \text{Equação 6}$$

$$F_c = w_1F_1 + (1 - w_1)F_2 + \varepsilon \quad \text{Equação 7}$$

O modelo da Equação 5 contém uma constante (intercepto) que pode ser benéfica na correção de eventuais vieses das previsões individuais e não contém restrição sobre os pesos. O segundo e terceiro modelos (Equações 6 e 7) assumem que as previsões individuais são não viesadas. O modelo da Equação 7 possui uma restrição nos pesos que devem somar um. Neste artigo o método para combinação através de uma regressão linear a ser utilizado será o sem restrição nos pesos, podendo ser com ou sem constante de ajuste.

A técnica de combinação através da média aritmética é a mais comumente utilizada e a mais simples (SONG *et al*, 2009). Nesta técnica de combinação linear, diferentemente das outras duas apresentadas, o mesmo peso é atribuído a cada uma das previsões, conforme a Equação 8.

$$F_c = 0,5F_1 + 0,5F_2 \quad \text{Equação 8}$$

Já a combinação por média geométrica é bem menos utilizada que a média aritmética, sendo mais aplicada em situações especiais, principalmente no cenário econômico (PATTON; SHEPPARD, 2009). A vantagem dessa técnica de combinação é fornecer previsões inferiores às da média aritmética, proporcionando uma diminuição na estimativa da previsão, além de ser uma opção alternativa de método de combinação não linear. A Equação 9 expressa como obter a previsão combinada através da média geométrica.

$$F_c = \sqrt{F_1 \times F_2} \quad \text{Equação 9}$$

Com ainda menos aplicações que a média geométrica, a média harmônica é outra forma não linear de combinar as previsões. Esse método também fornece previsões inferiores as obtidas pela média aritmética e é dada pela Equação 10.

$$F_c = \frac{2F_1 \times F_2}{F_1 + F_2} \quad \text{Equação 10}$$

4 Procedimentos metodológicos

Definiu-se inicialmente que seriam modeladas as demandas turísticas das três mais recentes sedes olímpicas: Reino Unido (Londres, 2012), China (Pequim, 2008) e Grécia (Atenas, 2004). A variável escolhida como representativa da demanda turística foi o número de chegadas de turistas internacionais no país analisado que, de acordo com a metanálise de Peng, Song e Crouch (2014), é uma medida mais estável que as receitas turísticas, por exemplo. Uma pessoa pode realizar diversas viagens a um mesmo destino em um determinado período de tempo, sendo cada retorno contabilizado como uma nova chegada (WTO, 2015).

As informações acerca do número de chegadas foram obtidas diretamente das fontes oficiais dos governos dos países analisados, com exceção da China que não disponibilizou estas informações. Dessa forma, as análises foram realizadas com as informações obtidas do número de chegadas internacionais do Reino Unido e da Grécia. Para a série do Reino Unido foram obtidas 391 observações mensais, desde janeiro de 1980 até julho de 2012 e para a série grega, 104 observações mensais desde janeiro de 1996 a agosto de 2004.

A modelagem de ambas as séries foi realizada com uma parte dos dados, sendo os últimos 12 meses retirados para posterior avaliação das previsões. Na modelagem do Reino Unido, a previsão foi realizada para julho de 2012, mês de início dos Jogos Olímpicos, que ocorreram entre 27 de julho a 12 de agosto de 2012.

As etapas para a análise de cada série temporal estão resumidas na Figura 1, sendo elas: i) etapa de modelagem individual e escolha do melhor modelo ARIMA (via critério de informação bayesiana normalizado – BIC Normalizado) e RNA (menor relação entre o erro quadrático médio das fases de treino e teste); ii) etapa de estimação das previsões individuais de cada modelo selecionado e das suas estimativas combinadas e, iii) etapa destinada à comparação, com auxílio de medidas de acurácia, das previsões individuais e combinadas, dentro e fora do período reservado para modelagem dos dados.

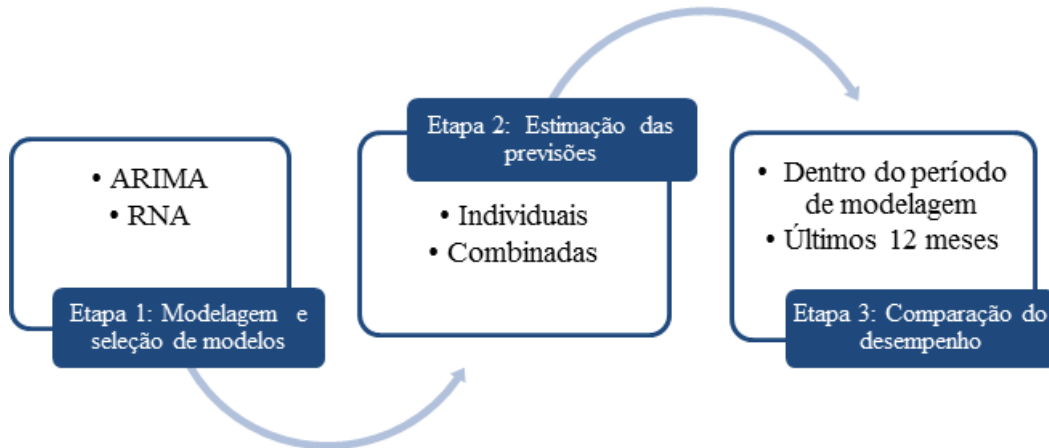


Figura 1: Etapas da análise de cada série de dados

Para a modelagem via metodologia de Box-Jenkins, alguns procedimentos de ajuste dos dados foram realizados, quando necessário, tais como: i) Transformação logarítmica: aplicada para estabilizar a variância; ii) verificação da estacionariedade através do teste ADF – (*Augmented Dickley-Fuller*); iii) operação da diferença para eliminar a tendência; iv) operação da diferença sazonal para eliminar a sazonalidade da série. Para cada modelo selecionado também foi utilizado o teste de Ljung-Box para verificar se os resíduos não estavam autocorrelacionados.

Na modelagem por RNA/MLP, os dados destinados à modelagem foram divididos em dois conjuntos, sendo 70% dos dados destinados para aprendizagem ou padrão de treinamento e 30% destinados para teste. As redes geradas deveriam ter uma camada oculta com função de ativação não linear, como a tangente hiperbólica, e uma camada de saída com função de ativação do tipo linear (identidade), que segundo Fernandes et al. (2008) é a arquitetura mais adequada para esse tipo de dado. Quanto ao aprendizado, o algoritmo adotado foi o anteriormente exposto, retropropagação do erro, e essa fase se encerrava quando o erro quadrático médio da base de treino não apresentava mais diminuição, pois uma rede muito treinada tende a piorar sua capacidade de generalização.

Na Etapa 2 foram obtidas as previsões pelos modelos ARIMA e RNA selecionados e estas previsões foram combinadas de acordo com os cinco métodos sugeridos (variância mínima, regressão linear, médias aritmética, harmônica e geométrica) sendo que para o método de regressão linear foram consideradas as Equações 5 e 6, devido à flexibilidade quanto aos parâmetros.

A etapa 3 consiste da comparação das previsões obtidas na Etapa 2. As comparações foram realizadas através das três principais medidas de acurácia encontradas na literatura, e estão resumidas no Quadro 1, sendo elas: MAPE (*Mean Absolute Percentage Error*), RMSE

(*Root Mean Square Error*) e MAE (*Mean Absolute Error*). A primeira fornece uma medida percentual e as outras duas são avaliações de acurácia mensuradas na escala da variável utilizada. Cabe ressaltar que, de acordo com Lewis (1982), modelos cujo MAPE é inferior a 10% podem ser classificados com alta acurácia.

Quadro 1: Medidas de acurácia utilizadas

Medida	Fórmula
MAPE	$\frac{1}{n} \sum_{t=1}^n \left \frac{A_t - F_t}{A_t} \right \times 100$
RMSE	$\sqrt{\frac{1}{n} \sum_{t=1}^n (A_t - F_t)^2}$
MAE	$\frac{1}{n} \sum_{t=1}^n A_t - F_t $

A_t : o valor observado no tempo $t=1,2,\dots,n$; F_t : valor previsto no tempo $t=1,2,\dots,n$

Os dados foram dispostos em planilha eletrônica. Inicialmente foi utilizado o software Gretl 2015 para verificação da suposição de estacionariedade e as demais análises (modelagem, adequação e cálculo das combinações de previsões) foram realizadas com auxílio do software SPSS v.18. Foi adotada significância de 0,05 para os testes estatísticos.

5 Resultados

As Figuras 2 e 3 ilustram as séries históricas mensais do número de chegadas internacionais no Reino Unido e na Grécia, respectivamente, utilizadas para modelagem. Em ambas as séries, os meses com maior volume de chegadas foram julho e agosto, período de férias e verão na Europa e, nos meses de janeiro e fevereiro foram observadas as menores demandas. Em alguns anos, no Reino Unido, a demanda de julho chegou a ser o dobro da demanda observada em fevereiro e, na Grécia, em alguns anos o volume de turistas em agosto chegou a ser dez vezes superior à demanda observada em fevereiro.

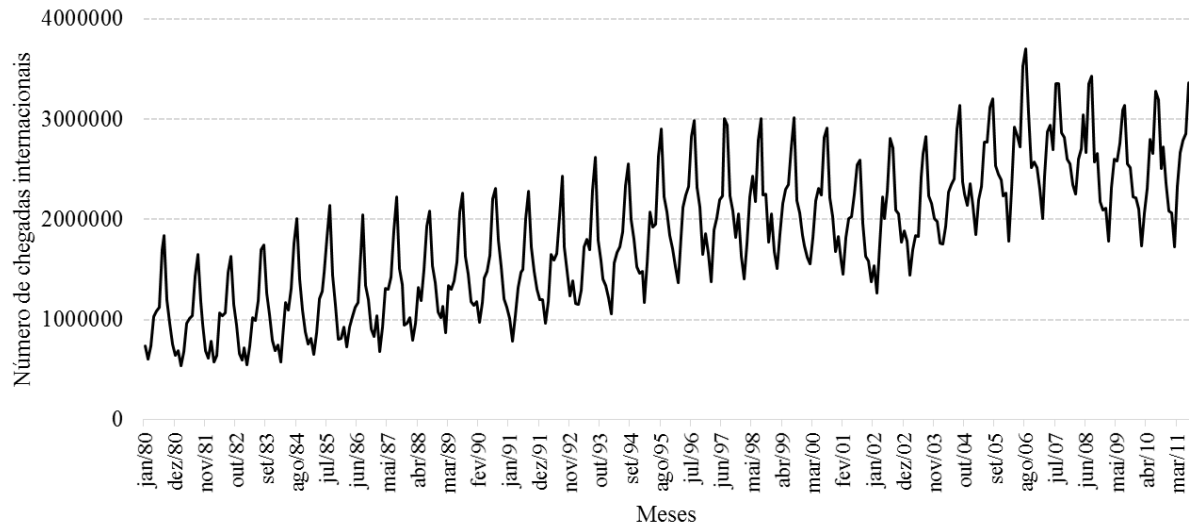


Figura 2: Número de chegadas internacionais no Reino Unido (jan/1980 – julho/2011)

Fonte: *Office for National Statistics (ONS)*




Figura 3: Número de chegadas internacionais na Grécia (jan/1994 – ago/2003)

Fonte: *Hellenic Statistical Authority (ELSTAT)*

Após a identificação da não estacionariedade e sazonalidade na série britânica, o modelo que obteve menor BIC, entre todos os modelos SARIMA analisados, foi o SARIMA(0,1,1)(0,1,1). Para a série grega também foram observadas a não estacionariedade e a sazonalidade, além da não estabilidade da variância. O modelo com menor BIC utilizado para a modelagem dessa série foi o SARIMA (1,1,1)(0,1,0). Para os modelos RNA definidos com uma camada oculta, com função de ativação tangente hiperbólica e uma camada de saída com função de ativação linear, foram testados de 2 a 12 neurônios na camada oculta, sendo que na série britânica o modelo com cinco neurônios obteve melhor resultado e na série grega o modelo com dois.

Na Tabela 2 estão discriminados os pesos atribuídos para cada previsão individual, de acordo com a técnica de combinação utilizada. Para as combinações obtidas através das médias aritmética, geométrica e harmônica foram dados pesos equivalentes as duas previsões individuais. Os métodos de variância mínima e regressão linear atribuíram pesos maiores às previsões obtidas pelo modelo RNA, especialmente na combinação via regressão linear.

Tabela 1: Pesos utilizados em cada técnica de combinação

Técnica de combinação	Reino Unido			Grécia		
	SARIMA	RNA	c	SARIMA	RNA	c
Média Aritmética	0,500	0,500	-	0,500	0,500	-
Média Geométrica	0,500	0,500	-	0,500	0,500	-
Média Harmônica	0,500	0,500	-	0,500	0,500	-
Variância Mínima	0,441	0,559	-	0,465	0,535	-
Regressão Linear	0,327*	0,671*	-6.955 ^{ns}	0,348*	0,651*	-830 ^{ns}

* p-valor<0,001; c: Constante; ns: Não significativa

A acurácia das predições individuais, obtidas pelos SARIMA e RNA, e das suas combinações está discriminada na Tabela 2. As predições do modelo RNA se mostraram mais acuradas que do modelo SARIMA, sob as três medidas avaliadas, em ambas as séries analisadas. Já na comparação somente entre os métodos de combinação de previsões, em ambas as séries a combinação via regressão linear foi a que apresentou melhor desempenho também sob as três medidas avaliadas. No geral, para as duas séries analisadas, todas as predições combinadas, independentemente do método, mostraram-se mais precisas que as predições geradas pelos dois modelos individuais em ambas as três medidas.

Tabela 2: Medidas de acurácia dentro do período de modelagem

Sede olímpica	Modelos	Medida		
		MAPE	RMSE	MAE
Reino Unido (379 meses)	SARIMA	5,21% (7)	117.360,69 (7)	91.326,30 (7)
	RNA	4,80% (6)	104.447,97 (6)	79.961,53 (6)
	Média Aritmética	4,48% (3)	102.794,77 (4)	78.295,23 (3)
	Média Geométrica	4,48% (3)	102.815,89 (3)	78.358,92 (4)
	Média Harmônica	4,48% (3)	102.846,96 (5)	78.422,39 (5)
	Variância Mínima	4,47% (2)	102.177,32 (2)	77.872,06 (2)
	Regressão	4,45% (1)	101.669,68 (1)	77.356,08 (1)
Grécia (79 meses)	SARIMA	8,27% (7)	74.736,64 (7)	55.693,19 (7)
	RNA	8,13% (6)	68.775,82 (6)	49.837,42 (6)
	Média Aritmética	7,25% (5)	55.095,08 (3)	44.165,35 (5)
	Média Geométrica	7,21% (3)	54.830,44 (5)	44.067,98 (4)
	Média Harmônica	7,18% (1)	54.609,75 (4)	43.971,60 (3)
	Variância Mínima	7,22% (4)	54.533,17 (2)	43.780,50 (2)
Regressão	7,18% (1)	53.611,15 (1)	43.021,06 (1)	

Valores entre parênteses indicam a posição de cada técnica quanto ao desempenho obtido, de acordo com a medida de acurácia avaliada

Diferentemente da Tabela 2 que apresenta um resumo da capacidade preditiva de cada técnica levando em conta todas as previsões, nas Tabelas 3 e 4 as três medidas de acurácia foram calculadas utilizando os meses correspondentes a cada previsão, nas séries britânica e grega, respectivamente. Para a série britânica, Tabela 3, tanto as previsões obtidas pelos modelos individuais quanto pela combinação via regressão, que obteve melhor desempenho na Tabela 2, apresentaram MAPE inferior a 10%, independentemente do período, demonstrando alta acurácia. As previsões obtidas pelo modelo SARIMA se mostraram mais precisas para os meses de setembro e dezembro, de acordo com as três medidas de acurácia. Unanimidade da acurácia também foi observada para as previsões do modelo RNA para abril e junho. Já fevereiro, março, maio, julho e novembro foram melhor preditos pela combinação via regressão linear, também em consenso das medidas avaliadas.

Tabela 3: Acurácia das predições para a demanda britânica, de acordo com período

Período	MAPE			RMSE			MAE		
	SARIMA	RNA	REG	SARIMA	RNA	REG	SARIMA	RNA	REG
Janeiro	6,64% (3)	5,48% (2)	5,15 (1)	106.944,5 (3)	86.427,4 (2)	78.695,6 (1)	86.728,3 (3)	71.374,8 (2)	65.914,4 (1)
Fevereiro	6,57% (3)	6,20% (2)	5,69 (1)	97.959,2 (3)	97.788,1 (2)	91.570,7 (1)	81.738,8 (3)	78.658,6 (2)	72.657,3 (1)
Março	5,52% (3)	4,50% (2)	4,09 (1)	103.483,5 (3)	80.998,8 (2)	77.050,5 (1)	80.407,5 (3)	67.029,6 (2)	61.339,6 (1)
Abril	6,72% (3)	4,53% (1)	4,89 (2)	157.082,6 (3)	105.783,8 (1)	116.325,7 (2)	123.939,7 (3)	82.795,9 (1)	90.611,3 (2)
Maiο	4,84% (2)	4,98% (3)	4,57 (1)	122.986,0 (3)	115.085,5 (2)	110.632,5 (1)	94.575,9 (3)	91.322,7 (2)	86.856,4 (1)
Junho	5,59% (3)	3,85% (1)	4,27 (2)	142.255,8 (3)	96.314,7 (1)	105.445,6 (2)	113.356,6 (3)	77.419,7 (1)	87.059,2 (2)
Julho	3,38% (3)	2,93% (2)	2,51 (1)	108.075,2 (3)	104.947,1 (2)	96.669,1 (1)	85.632,1 (3)	78.347,3 (2)	68.661,4 (1)
Agosto	3,81% (3)	3,00% (1)	3,01 (2)	115.172,4 (3)	104.669,4 (2)	101.224,9 (1)	99.534,6 (3)	77.998,6 (2)	77.939,2 (1)
Setembro	3,52% (1)	5,16% (3)	4,24 (2)	92.759,6 (1)	121.328,6 (3)	103.118,4 (2)	73.670,7 (1)	101.966,2 (3)	84.590,5 (2)
Outubro	4,99% (3)	4,17% (2)	4,16 (1)	121.286,7 (3)	109.878,2 (2)	109.114,1 (1)	93.635,4 (3)	76.377,7 (1)	77.822,1 (2)
Novembro	5,43% (3)	5,14% (2)	4,80 (1)	109.040,3 (2)	109.056,8 (3)	103.891,4 (1)	83.316,3 (3)	80.716,6 (2)	74.984,0 (1)
Dezembro	5,44% (1)	7,38% (3)	6,29 (2)	125.572,4 (1)	137.784,1 (3)	128.604,7 (2)	91.674,0 (1)	104.523,2 (3)	95.202,0 (2)

Valores entre parênteses indicam a posição de cada técnica quanto ao desempenho obtido em cada período, de acordo com a medida de acurácia avaliada. Em itálico e negrito o desempenho médio das predições realizadas para o mês em que os Jogos Olímpicos foram realizados no país.

Na Tabela 4 são apresentadas as medidas de acurácia de acordo com o mês de predição para a demanda grega. No período de alta temporada, maio a outubro, o MAPE não ultrapassou 5%, com exceção de outubro predito pelo modelo RNA. Contudo, na baixa temporada, novembro a abril, o MAPE médio foi de 13,23%, sendo observado 7,24% para a demanda média de abril, obtida pela combinação via regressão, e 20,74% na predição para janeiro via modelo SARIMA. Ainda, de acordo com as três medidas de acurácia, as predições obtidas pelo modelo SARIMA se mostraram mais precisas para os meses de fevereiro, outubro e dezembro. As demandas de junho, julho e novembro foram unanimemente melhor preditas pelo modelo RNA. Já maio e agosto foram melhor preditos pela combinação via regressão, também em consenso das três medidas de acurácia adotadas. As predições para agosto, quando obtidas pela combinação linear, apresentaram MAPE inferior a 2% para esta sede olímpica

Tabela 4: Acurácia das predições para a demanda grega, de acordo com período

Período	MAPE			RMSE			MAE		
	SARIMA	RNA	REG	SARIMA	RNA	REG	SARIMA	RNA	REG
Janeiro	20,74 (3)	17,44 (1)	18,48 (2)	82.576,2 (3)	56.484,3 (2)	55.995,0 (1)	57.098,4 (3)	45.122,5 (1)	49.110,2 (2)
Fevereiro	9,10 (1)	15,25 (3)	12,04 (2)	29.275,6 (1)	56.129,1 (3)	41.693,5 (2)	19.672,0 (1)	44.003,6 (3)	33.643,9 (2)
Março	15,38 (3)	12,29 (1)	13,15 (2)	60.968,1 (3)	54.089,1 (2)	51.287,1 (1)	55.430,4 (3)	41.569,8 (1)	45.667,5 (2)
Abril	9,83 (3)	8,26 (2)	7,24 (1)	84.524,3 (3)	63.648,0 (1)	63.999,7 (2)	69.023,7 (3)	57.616,0 (2)	49.826,8 (1)
Maió	2,89 (3)	2,22 (2)	1,77 (1)	50.659,3 (3)	39.914,2 (2)	32.132,5 (1)	42.362,7 (3)	31.801,9 (2)	26.323,4 (1)
Junho	2,72 (3)	1,40 (1)	1,92 (2)	63.796,5 (3)	33.882,6 (1)	38.059,4 (2)	52.539,7 (3)	25.192,5 (1)	35.811,1 (2)
Julho	3,41 (3)	1,40 (1)	1,64 (2)	110.057,4 (3)	41.868,9 (1)	48.837,1 (2)	81.301,0 (3)	34.917,4 (1)	40.219,6 (2)
Agosto	2,39 (2)	2,51 (3)	1,72 (1)	75.895,7 (3)	73.771,9 (2)	49.484,8 (1)	59.171,8 (2)	62.987,7 (3)	42.380,6 (1)
Setembro	3,45 (3)	1,61 (1)	1,67 (2)	80.273,7 (3)	40.452,3 (2)	39.617,7 (1)	69.356,1 (3)	29.925,4 (1)	32.098,7 (2)
Outubro	3,32 (1)	5,40 (3)	4,65 (2)	50.234,4 (1)	69.404,8 (3)	55.669,3 (2)	39.083,8 (1)	58.822,0 (3)	51.611,9 (2)
Novembro	18,09 (3)	14,16 (1)	14,62 (2)	104.707,7 (3)	55.228,5 (1)	65.192,2 (2)	76.219,7 (3)	51.639,6 (1)	57.114,5 (2)
Dezembro	8,01 (1)	13,21 (3)	10,89 (2)	34.599,9 (1)	59.703,3 (3)	50.352,1 (2)	28.226,7 (1)	46.259,8 (3)	38.788,5 (2)

Valores entre parênteses indicam a posição de cada técnica quanto ao desempenho obtido em cada período, de acordo com a medida de acurácia avaliada. Em itálico e negrito o desempenho médio das predições realizadas para o mês em que os Jogos Olímpicos foram realizados no país.

A comparação da acurácia das previsões para o período de 12 meses, de forma que o último mês fosse o de realização dos Jogos Olímpicos está discriminada na Tabela 5. Em ambas as séries, as previsões individuais obtidas pelo modelo RNA foram mais acuradas que as geradas pelo modelo SARIMA, de acordo com as três medidas de acurácia. Na comparação somente entre métodos de combinação de previsões, para a série britânica a combinação via regressão foi a mais acurada, de acordo com MAPE e o MAE, enquanto que a combinação via média harmônica obteve o menor RMSE. Na série grega, o método de combinação via regressão foi o mais acurado de acordo com a medida MAPE e o segundo melhor nas outras duas medidas avaliadas.

Na avaliação geral, o pior desempenho apontado pelas três medidas de acurácia foi observado nas previsões geradas pelo modelo SARIMA, em ambas as séries. Na série britânica, as previsões via RNA apresentaram o melhor e o segundo melhor desempenho quanto ao MAPE e MAE, respectivamente, porém o segundo pior RMSE. Já as previsões combinadas via regressão estiveram sempre entre as melhores nas três medidas avaliadas. O desempenho da acurácia das previsões gregas foi semelhante, onde o modelo RNA produziu os melhores resultados quanto ao RMSE e MAE e o segundo pior quanto ao MAPE, e as previsões combinadas pelo método de regressão linear estiveram sempre entre as melhores nas três medidas avaliadas.

Tabela 5: Medidas de acurácia fora do período de modelagem – 12 meses

Sede olímpica	Modelos	Medida		
		MAPE	RMSE	MAE
Reino Unido	SARIMA	6,42% (7)	175.019,33 (7)	160.587,21 (7)
	RNA	5,80% (1)	173.544,98 (6)	146.160,75 (2)
	Média Aritmética	6,00% (3)	161.758,03 (4)	149.831,16 (6)
	Média Geométrica	5,98% (6)	161.525,92 (2)	149.428,22 (5)
	Média Harmônica	5,97% (5)	161.303,10 (1)	149.025,66 (4)
	Variância Mínima	5,95% (4)	161.843,97 (5)	148.568,91 (3)
	Regressão	5,80% (1)	161.609,59 (3)	144.870,21 (1)
Grécia	SARIMA	9,08% (7)	130.684,88 (7)	104.059,76 (7)
	RNA	8,23% (6)	95.710,96 (1)	77.403,30 (1)
	Média Aritmética	7,66% (5)	108.653,92 (6)	86.444,63 (6)
	Média Geométrica	7,59% (4)	108.515,03 (5)	86.051,61 (5)
	Média Harmônica	7,52% (2)	108.428,07 (4)	85.665,08 (4)
	Variância Mínima	7,56% (3)	107.405,95 (3)	85.216,48 (3)
	Regressão	7,21% (1)	102.301,89 (2)	80.433,50 (2)

Valores entre parênteses indicam a posição de cada técnica quanto ao desempenho obtido, de acordo com a medida de acurácia avaliada

A previsão final para julho de 2012 no Reino Unido, obtida pela combinação por regressão linear, foi de 3.197.579 chegadas, estimando 39.579 chegadas acima do real número de chegadas observado no período. A previsão para agosto de 2004 na Grécia, obtida também através da combinação via regressão linear, foi de 2.585.009 chegadas, sendo superestimada em 5,83%. Os resultados encontram-se na Tabela 6.

Tabela 6: Demandas turísticas observada e prevista para o mês de realização do evento

Sede olímpica	Observada	Prevista	MAPE	RMSE	MAE
Reino Unido – julho/2012	3.158.000	3.197.579	1,25%	39.579,64	39.579,64
Grécia – agosto/2004	2.442.560	2.585.009	5,83%	142.443,15	142.443,15

6. Discussões e conclusões

Este artigo teve como objetivo avaliar a acurácia das previsões para a demanda turística de duas sedes olímpicas: Reino Unido, sede em 2012 e Grécia, sede em 2004. Para tanto, foi utilizado o maior número disponível de informações históricas do número mensal de chegadas nestes países. As previsões foram obtidas por dois modelos reconhecidamente robustos para realizar este tipo de análise (SARIMA e RNA) e combinadas por cinco métodos, através das médias aritmética, geométrica e harmônica, do método da variância mínima e através de regressão linear. A acurácia foi avaliada pelo posicionamento das previsões de acordo com três medidas amplamente utilizadas e igualmente ponderadas, tanto para as predições para os dados utilizados na fase de modelagem quanto para a previsão das últimas 12 observações.

Constatou-se que os modelos SARIMA e RNA que estavam mais bem ajustados aos dados de ambas as séries também eram modelos com excelente capacidade preditiva, particularmente para a demanda britânica cujas previsões foram ainda mais acuradas que as previsões para a demanda grega. Para as predições das observações que foram utilizadas na modelagem, o MAPE não ultrapassou 8,27% e para as últimas 12 observações, o maior MAPE foi de 9,08%, ambos obtidos pela modelagem SARIMA na série Grega, sendo que a modelagem via RNA apresentou ainda menores valores. Para as previsões combinadas os resultados foram ainda melhores, onde o maior MAPE para as previsões amostradas foi de 7,18% e 7,21% para as previsões não amostradas, ambos da série grega.

Na avaliação geral, em ambas as séries analisadas, todas as previsões combinadas apresentaram melhor desempenho que a previsão obtida pela modelagem SARIMA, sob as três medidas de acurácia analisadas. Oh e Morzuch (2005) e Song *et al* (2009) encontraram resultado semelhante onde o desempenho das previsões combinadas não foi inferior ao desempenho do pior componente utilizado na combinação. A combinação via regressão

também apresentou melhor desempenho para a previsão das demandas da Austrália, Estados Unidos e Canadá no estudo de Shen, Li e Song (2011).

A alta acurácia observada na estimativa pontual para a demanda para os Jogos Olímpicos, além da utilização do método de combinação que demonstrou melhor resultado, pode ter sido em função do efeito da sazonalidade apontado por Fourie e Santana-Gallego (2011). Como os Jogos Olímpicos ocorreram em períodos de alta temporada nos dois países, onde historicamente as previsões para os meses de julho e agosto eram mais precisas, tanto na modelagem ARIMA quanto RNA, não foi observado aumento do volume de chegadas.

O impacto na demanda devido à realização de um megaevento não foi observado em nenhuma das sedes analisadas uma vez que o evento ocorreu em um período de alta temporada, justamente onde os modelos escolhidos mostraram-se mais precisos. A escolha de boas modelagens individuais foi essencial para a obtenção de boas previsões. Além disso, através da combinação pelo método de regressão, as previsões britânicas foram as mais acuradas nas medidas MAPE e MAE e obtiveram a terceira colocação quanto ao RMSE e, na série grega, foram as mais acuradas quanto ao MAPE e obtiveram a segunda colocação nas outras duas medidas. Novamente, o ganho de acurácia pode ser observado também na avaliação do desempenho histórico dos meses de julho no Reino Unido e agosto na Grécia, segundo as três medidas avaliadas.

Referências

- ARMSTRONG, J.S. **Principles of forecasting**: A handbook for researchers and practitioners. Springer Science & Business Media, 2001.
- BRAGA, A.P; CARVALHO, A.C.P.L.F; LUDERMIR, T.B. **Redes neurais artificiais**: teoria e aplicações. Rio de Janeiro, Livros Técnicos Científicos, 2007.
- CLAVERIA, O; TORRA, S. Forecasting tourism demand to Catalonia: Neural networks vs. time series models. **Economic Modelling**, v.36, p.220-228, janeiro 2014.
- CONSTANTINE, C.; PAPPALARDO, C. A hierarchical procedure for combination of forecasts. **International Journal of Forecasting**. v.26, p.725-743, 2010.
- CROMPTON, J.L. Measuring the Economic Impact of Park and Recreation Services. Ashburn, VA: **National Recreation and Park Association**, 2010.
- FERNANDES, P; TEIXEIRA, J; FERREIRA, J.M; AZEVEDO, S.G. Modelling Tourism Demand: A Comparative Study between Artificial Neural Networks and the Box-Jenkins Methodology. **Romanian Journal of Economic Forecasting**, v.9, n.3, p.30-50, 2008.
- FOURIE, J; SANTANA-GALLEGO, M. The impact of mega-sport events on tourist arrivals. **Tourism Management**, v.32, n.6, p.1364 – 1370, 2011.

- GOH, C; LAW, R. Modeling and forecasting tourism demand for arrivals with stochastic nonstationary seasonality and intervention. *Tourism Management*, v.23, n.5, p.499–510, 2002.
- GOLDSCHMIDT, R., PASSOS, E. **Data mining: Um guia prático**. Rio de Janeiro: Editora Campus, 2005.
- HALL, C.M. **Hallmark tourist events: Impacts, management and planning**. London: Bellhaven Press. 1992.
- HALL, C.M. Urban entrepreneurship, corporate interests and sports mega-events: the thin policies of competitiveness within the hard outcomes of neoliberalism. *The Sociological Review*, v.54, n. s2, p. 59–70, December 2006.
- HAYKIN, S. **Redes neurais: Princípios e prática**. Bookman, 2ª Ed, 2001.
- HORNE, J; MANZENREITER, W. An introduction to the sociology of sports megaevents. *The Sociological Review*, v.54, n.2, p.1-24, December 2006.
- KON, S.C; TURNER, W.L. Neural network forecasting of tourism demand, *Tourism Economics*, v.11, n.3, p.301-328, 2005.
- KUTNER, M, H; NACHTSHEIM, C.J; NETER, J; LI, W. **Applied Linear Statistical Models**, McGraw-Hill/Irvin. 5ª Ed, 2005. 1396 p.
- LEWIS, C.D. **Industrial and Business Forecasting Methods: A practical guide to exponential smoothing and curve fitting**. Butterworth Scientific. London, 1982
- LONDON ASSEMBLY. **Legacy for London? Assessing the legacy of the Olympic Games and Paralympic Games**. Greater London Authority, 2007.
- MORETTIN, P.A; TOLOI, C.M. **Análise de Séries Temporais**. São Paulo: Editora Edgard Blücher, 2006. 531 p.
- MOURA, F.A; MONTINI, A.A. Modelagem da Demanda Turística Internacional para o Estado de São Paulo. *Sociedade, Contabilidade e Gestão*, v.5, n.2, jul/dez 2010.
- NEWBOLD, P., GRANGER, C, W, J. Experience with forecasting univariate time series and the combination of forecasts. *Journal of the Royal Statistical Society, Series A*, v.137, n.2, p.131–146, 1974.
- OH, C; MORZUCH, B.J. Evaluating Time-Series Models to Forecast the Demand for Tourism in Singapore. *Journal of Travel Research*, v.43, n.4, p.404-413, 2005.
- PAI, A.P.F; LIN, B.K.P; LIN, C.C.S; CHANG, P.T. Time series forecasting by a seasonal support vector regression model. *Expert Systems with Applications*, v.37, n.6, p.4261–4265, 2010.
- PATTON, A.J; SHEPPARD, K. Optimal combinations of realized volatility estimators. *International Journal of Forecasting*, v.25, n.2, p. 218–238, 2009.
- PENG, B; SONG, H; CROUCH, G.I. A meta-analysis of international tourism demand forecasting and implications for practice. *Tourism Management*, v.45, p.181-193, 2014.
- ROCHE, M. Mega events and urban policy. *Annals of tourism research*, v.21, n.1, p.1-19, 1994.
- SANTOVITO, T.C. A copa do mundo 2006: megaevento esportivo como atração turística, instrumento de comunicação e interação entre os povos. *Comunicação & Inovação*, v7, n.13, 2010.

- SHEN, S; LI, G; SONG, H. Combination forecasts of International tourism demand. **Annals of Tourism Research**, v.38, n. 1, p. 72-89, 2011.
- SOLBERG, H.A; PREUSS, H. Major Sport Events and Long-Term Tourism Impacts. **Journal of Sport Management**, v. 21, n.2, p.213-234, 2007.
- SONG, H; HYNDMAN, R.J. Tourism forecasting: An introduction. **International Journal of Forecasting**, v.27, n.3, p.817-821, 2011.
- SONG, H.; LI, G. Tourism demand modelling and forecasting — A review of recent research. **Tourism Management**, v.29, n.2, p.203-220, 2008.
- SONG, H; WITT, S.F; WONG, K.F; WU, D.C. An empirical study of forecast combination in tourism. **Journal of Hospitality & Tourism Research**, v.33, n.1, p.3-29, 2009.
- STEKLER, H.O. Improving Our Ability to Predict the Unusual Event. **International Journal of Forecasting**, v.19, n.2, p.161-63, 2003.
- TAVARES, O. Megaeventos esportivos. **Movimento (ESEF/UFRGS)**, v.17, n.3, p.11-35, 2011.
- TIDESWELL, C; MULES, T; FAULKNER, B. An Integrative Approach to Tourism Forecasting: A Glance in the Rearview Mirror. **Journal of Travel Research**, v.40, n.2, p.162-171, 2001.
- TSENG, H; MA, Z; CHOU, L. An Author-based Citation and Co-citation Analysis on Tourism Research. **Asia Pacific Management Review**, v.15, n.4, p.585-600, 2010.
- WTO (World Tourism Organization). **Methodological Notes**, Disponível em: <http://www.unwto.org/facts/menu.html>. Acesso em: dez. 2015. 2015
- ZHANG, G; PATUWO, B.E; HU, M.Y. Forecasting with artificial neural networks: The state of the art. **International Journal of Forecasting** v.14, n.1, p.35–62, March 1998.

IV. ARTIGO 3: Previsão da Demanda Turística Brasileira para os Jogos Olímpicos 2016

Resumo: Previsões acuradas do número de turistas que visitam um local durante a realização de um megaevento servem de apoio para corretas tomadas de decisão por parte dos gestores como no gerenciamento da mão-de-obra, por exemplo. Diante da aproximação da realização dos Jogos Olímpicos no Brasil, o objetivo deste artigo é modelar a demanda turística brasileira visando obter uma previsão acurada para agosto de 2016. Para tanto, foram utilizadas duas metodologias (ARIMA e RNA), as previsões obtidas foram combinadas através da técnica de regressão linear e a previsão para agosto foi corrigida através de um ajuste sazonal matemático. A combinação das previsões individuais resultou em menor MAPE e MAE, enquanto que as previsões obtidas pelo modelo RNA foram mais acuradas quanto ao RMSE. Os modelos RNA e SARIMA se mostraram acurados para as previsões de agosto (MAPE<10%), sendo que a previsão combinada apresentou ainda melhor desempenho quanto ao RMSE e MAE. O efeito observado na demanda de 2014 devido à realização da Copa do Mundo em um período de baixa temporada foi acentuado e o ajuste matemático fez-se imprescindível para a obtenção de uma boa previsão para o número de chegadas para agosto de 2016. A previsão para o número de turistas foi aproximadamente três vezes superior ao esperado sem a realização do evento.

Palavras-chave: Previsão de Demanda, Combinação de Previsões, Megaeventos, Ajuste de previsões, Jogos Olímpicos

Abstract: Accurate forecasts of the number of tourists visiting a place during the holding of a mega-event serve as support for precise decision-making by managers concerning labor, for instance. As the holding of the Olympic Games in Brazil nears, the objective of this paper is to model the Brazilian tourism demand aiming for an accurate forecast for August 2016. In this regard, two methodologies were used (ARIMA and ANN), the forecasts obtained were combined using the linear regression technique and the August forecast was corrected with the use of a seasonal mathematical adjustment. The combination of the individual forecasts resulted in a smaller MAPE and MAE, while the forecasts obtained by the ANN model were more accurate regarding RMSE. The ANN and SARIMA models showed good precision for the August forecasts (MAPE<10%) and an even better performance for the combined forecasts regarding RMSE and MAE. The effect observed in the 2014 demand because of the

holding of the World Cup during the low season was important and the mathematical adjustment was absolutely necessary for the obtainment of good forecasts for the number of arrivals for August 2016. The prediction of the number of arrivals was approximately three times bigger than what was expected without the hosting of the event.

Key-Words: Demand forecast, Forecast combination, Mega-Events, Forecast adjustment, Olympic Games

1. Introdução

O Brasil já sediou a Copa do Mundo em 1950 e 2014, os Jogos Pan-Americanos em 2007, realizou a Copa América de Futebol em diversas ocasiões e irá também sediar os Jogos Olímpicos de 2016. Além do desempenho como participante, o país também será avaliado como país anfitrião do megaevento. Segundo Hall (2006), a megaeventos associa-se grandes gastos do setor público, estratégias de ampliação e revalorização de áreas públicas e construção de instalações e infraestrutura que geram ganhos, em um curto espaço de tempo, para as partes envolvidas.

Os megaeventos esportivos podem ser encarados como catalizadores de legados para os países que os sediam. Esses legados podem ser novas instalações, limpeza e revitalização dos espaços da cidade, novos tipos de uso da terra e melhoria da infraestrutura de transportes (LONDON ASSEMBLY, 2007). Fourie e Santana-Gallego (2011) também destacam a construção do sentimento de patriotismo ou identidade da nação como legados. Preuss (2007) ressalta, contudo, que para aumentar o turismo pós-evento, por exemplo, é necessário aumentar a atratividade da cidade visitada através da melhora nas áreas de comércio, instalações esportivas de qualidade, etc. Porém, quando as pessoas mais pobres não tem acesso a estas instalações, devido ao seu menor poder de compra, isto torna-se um legado negativo.

Ter um bom planejamento é fundamental quando se objetiva o desenvolvimento do turismo em uma região, podendo ser encarado como uma tomada de decisão envolvendo o futuro. Dessa forma, os tomadores de decisão necessitam ter em mãos previsões confiáveis e acuradas acerca da demanda turística a fim de alocar recursos financeiros suficientes para as

operações, comercializações, investimentos e planejamento (GOH; LAW, 2002), para atender adequadamente às expectativas dos consumidores (BALLOU, 2004).

Diversos artigos com o objetivo de modelagem e previsão de demanda turística foram publicados, porém ainda não há consenso sobre um tipo de modelagem que seja mais adequado para prever dados de demanda turística (SONG; LI, 2008; SONG; HYNDMAN, 2011) e, uma alternativa para melhoria da acurácia sugerida por Song e Li (2008), é a utilização da combinação das previsões.

A metodologia baseada na combinação de previsões com o intuito de torná-las mais acuradas foi sugerida no final dos anos 60 por Bates e Granger e tem aplicações em diversas áreas. No turismo, Oh e Morzuch (2005) combinaram, através da média aritmética, duas previsões do número de turistas que chegaram a Singapura, geradas por modelos de séries temporais distintos, e concluíram que o desempenho das previsões combinadas não foi pior que o desempenho do pior componente (modelo) utilizado na combinação. Além disso, há formas alternativas de busca pela precisão das previsões como integrá-las através da utilização de informações do próprio ambiente realizando ajustes (WERNER, 2005).

Com a proximidade da realização dos jogos Olímpicos no Brasil em 2016, julga-se de extremo interesse realizar previsões acuradas da demanda turística brasileira. Neste artigo a demanda turística será modelada e prevista por duas metodologias, Box-Jenkins e Redes Neurais Artificiais (RNA), e as previsões serão combinadas através da técnica de regressão linear. Por fim, a previsão será corrigida através de um ajuste matemático baseado nos índices sazonais observados.

A seção posterior a esta introdução detalha as modelagens utilizadas para as previsões individuais e a técnica de combinação utilizada. O levantamento dos dados e os procedimentos de análise e ajuste serão descritos na seção correspondente, seguida pela seção dos resultados encontrados. Algumas conclusões e discussões acerca dos achados encerram este artigo na última seção.

2. Técnicas de previsão

Ao se realizar previsões para determinada demanda, como não se sabe o processo gerador da série, alguns modelos de predição são testados e avaliados (ZHANG, 2003). Entre os modelos largamente encontrados na literatura, que capturam padrões lineares existentes na série, estão os modelos Box-Jenkins ou ARIMA e, entre os modelos que conseguem capturar padrões não lineares, estão os modelos de RNA (LEE; TONG, 2011).

2.1 Metodologia de Box-Jenkins

A metodologia de Box-Jenkins é a mais difundida e utilizada para realização de previsões através de séries temporais em praticamente todas as áreas do conhecimento. No âmbito de previsões voltadas à demanda turística, a modelagem por modelos ARIMA também tem se mostrado apropriada com ótimo desempenho (PETROPOULOS *et al*, 2006; DIVINO; MCALEER, 2009; CLAVERIA; TORRA, 2014). Morettin e Tolo (2006) salientam que, embora popular, esta metodologia exige experiência por parte do pesquisador para escolha dos modelos, além de um pacote computacional adequado. Zhang (2003) ressalta que nem sempre a relação entre variáveis independente e dependente é linear, sendo esta também uma limitação dessa metodologia.

A escolha dos modelos ARIMA utilizados para modelar uma série temporal depende muito das características da série, sendo que os modelos podem ter apenas componentes autorregressivos (AR), componentes de média móvel (MA) ou ambos (ARMA). Para a correta aplicação dos modelos descritos, é necessário que a condição de estacionariedade seja satisfeita, ou seja, a suposição de que com o passar do tempo, as características do processo mantenham o mesmo comportamento, o que nem sempre acontece (GUJARATI, 2000). Para que estas séries possam ser modeladas corretamente, pode-se recorrer ao recurso de diferenciação de modo a torná-las estacionárias, resultando na modelagem através de modelos do tipo ARIMA.

Ainda, há situações onde existe a presença de um componente sazonal, sobretudo em séries voltadas à demanda turística. Nestes casos, o modelo do tipo SARIMA, que incorpora este componente, acaba sendo o mais adequado (PAI *et al*, 2010).

O modelo SARIMA(p,d,q)(P,D,Q)_s é definido conforme a Equação 1.

$$\phi(B)\Phi_p(B^s)\Delta^d\Delta_s^D Z_t = \theta(B)\Theta_Q(B^s)\varepsilon_t \quad \text{Equação 1}$$

Onde $\phi(B)$ é o operador autorregressivo (AR) de ordem p ; $\theta(B)_t$ é o operador médias móveis (MA) de ordem q ; Φ_p é o operador AR sazonal de ordem P ; Θ_Q é o operador MA sazonal de ordem Q ; Δ^d é o operador diferença não sazonal; Δ_s^D é o operador diferença sazonal de ordem s ; s é o período sazonal e ε_t é um ruído branco.

2.2 Redes Neurais Artificiais

Diferentemente dos métodos tradicionais como a metodologia de Box-Jenkins, que buscam relações lineares, as RNAs são métodos auto-adaptativos em que há poucas suposições acerca das características dos dados analisados, podendo ser interpretadas como um método não linear não-paramétrico (ZHANG; PATUWO; HU, 1998).

Uma RNA é uma técnica computacional que constrói um modelo matemático inspirado no cérebro humano para realizar análises descritivas e preditivas. Essa metodologia tem sido utilizada com sucesso para modelar relações envolvendo séries temporais complexas em várias áreas do conhecimento (KOVÁCS, 2002). No turismo, há um grande número de estudos que utilizou esse tipo de modelagem para realizar previsões de suas demandas (CLAVERIA; TORRA; MONTE, 2014; WU *et al*, 2010). Entre as vantagens desse método estão a realização de aproximações não lineares com alto grau de acurácia (KHASHEI; BIJARI, 2010; ZHANG, 2003), o fato de haver poucas suposições acerca das características dos dados analisados e a capacidade de aprender com os dados (generalização) (ZHANG; PATUWO; HU, 1998).

Há diversos tipos de redes neurais, porém a utilização com objetivo de previsão tem se baseado, sobretudo, em RNA do tipo *feedforward*, com uma camada oculta, treinada por meio do algoritmo de retropropagação dos erros (YO; CHOI; HUI, 2011). Na área do turismo diversos estudos também fizeram uso dessa técnica para realizar previsões (BO; SHI-TING, 2014; CLAVERIA; TORRA; MONTE, 2014). As redes com múltiplas camadas tem um poder computacional superior ao das redes sem elas (BRAGA, CARVALHO e LUDERMIR 2000).

A rede *perceptron* multicamadas (MLP, *multilayer perceptron*) possui uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. A relação entre as saídas da rede e as entradas pode ser expressa pela Equação 2.

$$y_t = w_0 + \sum_{j=1}^q w_j g(w_{0j} + \sum_{i=1}^p w_{ij} y_{t-i}) + \varepsilon_t \quad \text{Equação 2}$$

onde w_j ($j=0,1,\dots,q$) e w_{ij} ($j=0,1,\dots,p ; i=0,1,\dots,q$) são os parâmetros do modelo geralmente chamados de pesos; p é o número de neurônios na camada de entrada e q o número de neurônios na camada oculta; $g(\cdot)$ é a função de transferência. A função de transferência geralmente utilizada na camada oculta é uma função não linear, como a tangente hiperbólica, segundo Fernandes *et al* (2008) e, na camada de saída, Khashei e Bijari (2010) sugerem a

função linear justificando que o uso de funções não lineares nessa etapa poderia resultar em distorções na capacidade preditiva da rede.

O treinamento via algoritmo de retropropagação do erro utiliza as informações dos padrões de entrada fornecidos e a respectiva saída desejada para ajustar os parâmetros (pesos) da rede através de um mecanismo de correção dos erros. Dessa forma, o treinamento ocorre em duas fases de sentidos opostos, para frente e para trás. A fase para frente é utilizada para definir a saída da rede para um dado padrão de entrada. A fase para trás utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões.

2.3 Combinações de previsões

A estratégia de combinar previsões de modelos através de algum método foi desenvolvida inicialmente em 1969 por Bates e Granger desde então diversos estudos propuseram diferentes métodos de combinação. A previsão combinada pode ser escrita como uma combinação linear de duas previsões não viesadas, conforme a Equação 3.

$$F_c = wF_1 + (1-w)F_2 \quad \text{Equação 3}$$

Onde F_c é a previsão combinada pelas duas previsões individuais, F_1 e F_2 , e w e $(1-w)$ são os pesos designados para F_1 e F_2 , respectivamente.

Entre os métodos mais utilizados para calcular os pesos de forma linear estão o método da variância mínima e a combinação via média aritmética. Na técnica baseada na variância mínima, por exemplo, os pesos são calculados com base na matriz de covariância dos erros das previsões individuais. No método proposto por Granger e Ramanathan (1984), os pesos são estimados via mínimos quadrados ordinários através de uma regressão. Os pesos calculados sem restrição estão expressos pelas Equações 4 e 5, onde na primeira há uma constante para correção de eventuais vieses nas previsões individuais. Na equação 6, o cálculo dos pesos é menos flexível pois há uma restrição de que eles devem somar um.

$$F_c = c + w_1F_1 + w_2F_2 + \varepsilon \quad \text{Equação 4}$$

$$F_c = w_1F_1 + w_2F_2 + \varepsilon \quad \text{Equação 5}$$

$$F_c = w_1F_1 + (1-w_1)F_2 + \varepsilon \quad \text{Equação 6}$$

3. Procedimentos metodológicos

A escolha da variável representativa da demanda turística internacional foi baseada na metanálise de Peng, Song e Crouch (2014), que destacam o número de chegadas como uma boa medida, sendo mais estável que, por exemplo, as receitas turísticas. Dessa forma, conforme a definição da Organização Mundial do Turismo (OMT), a contagem de uma nova chegada se faz a cada viagem realizada por uma pessoa a um país durante um determinado período de tempo superior a uma noite e inferior a um ano (OMT, 2001).

As informações acerca do número mensal de chegadas de turistas estrangeiros foram obtidas diretamente do anuário estatístico disponibilizado pelo Ministério do Turismo (BRASIL, 2015). Foram obtidas 144 observações, desde janeiro de 2003 a dezembro de 2014.

A análise da série histórica foi realizada em quatro etapas resumidas na Figura 1. Na Etapa 1 foi realizada a modelagem individual e escolha do melhor modelo ARIMA (via critério de informação bayesiana normalizado – BIC Normalizado) e RNA (menor relação entre o erro quadrático médio das fases de treino e teste). Na Etapa 2 para cada modelo selecionado foram estimadas as previsões individuais e estas previsões foram combinadas pelo método de regressão linear. O desempenho das previsões individuais e combinadas foi avaliado através de três medidas de acurácia (Etapa 3). Na última etapa, Etapa 4, foi realizado um ajuste matemático para a estimativa da previsão para agosto de 2016.

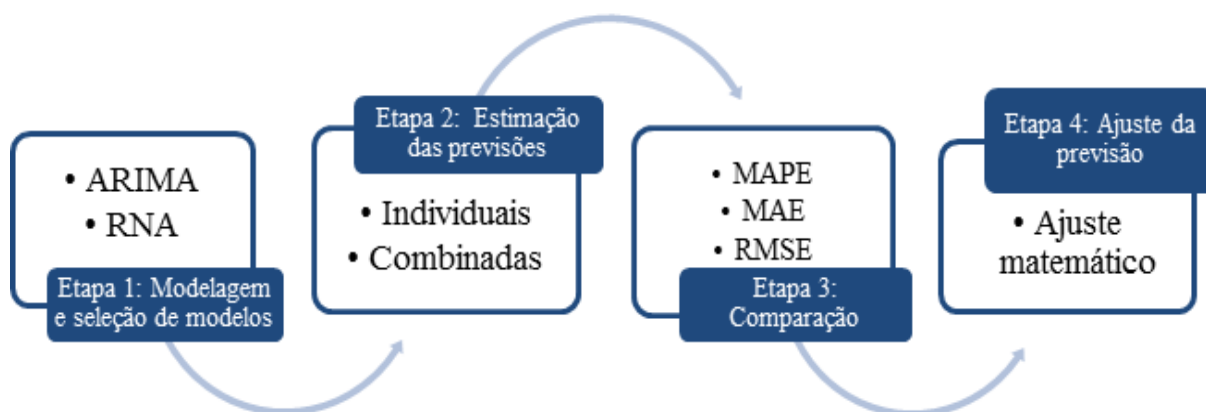


Figura 1: Etapas da análise da série histórica

Na Etapa 1 da análise constatou-se que esta série possuía uma peculiaridade, pois em 2014 o país sediou outro megaevento, a Copa do Mundo de Futebol. Desse modo, procurou-se corrigir o efeito causado na demanda do mês de junho, a fim de que os modelos utilizados para previsão, sobretudo a modelagem ARIMA, não interpretassem esse acontecimento atípico como inerente aos dados.

O ajuste dos dados utilizados na modelagem foi baseado na sazonalidade das observações (ajustamento sazonal). Para realizar o ajustamento sazonal foram calculados os componentes sazonais, conforme mostra a Figura 2. No procedimento 1, foi calculada a média móvel para obtenção das variações sazonais, para um período de 12 meses. Como a quantidade de períodos é par, a média foi centralizada mediante uma nova média móvel entre dois períodos. No procedimento 2 foi obtida a razão do valor observado na série pelo valor obtido pela média móvel centrada, gerando o relativo sazonal. Para a realização do procedimento 3 foram considerados dois períodos (A e B): A) período até o ano de realização da Copa do Mundo (janeiro/2003-dezembro/2013) e B) período que compreende o ano de realização da Copa do Mundo (janeiro/2014-dezembro/2014). Para o primeiro período foi calculado o componente sazonal de cada mês através da média dos relativos sazonais obtidos no procedimento 2, dessa forma o componente sazonal de janeiro foi calculado utilizando a média de todos os relativos sazonais observados nos meses de janeiro de 2003 a 2013. Para o segundo período, o componente sazonal consistiu do relativo sazonal obtido no procedimento 2.

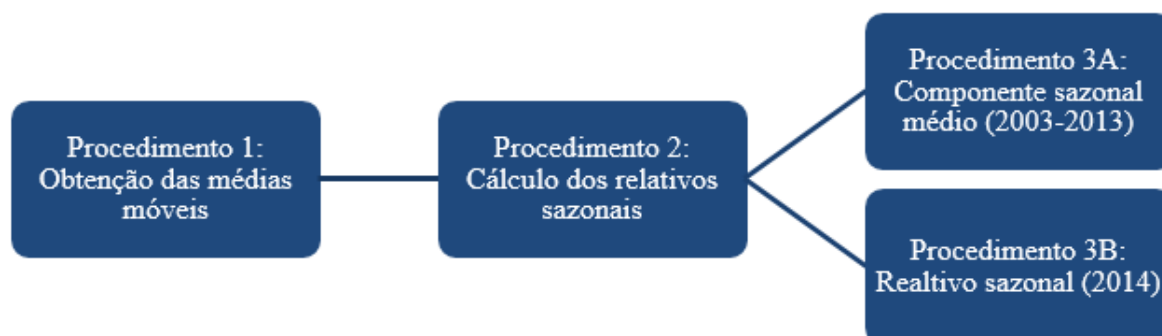


Figura 2: Procedimento para cálculo dos componentes sazonais

Dessa forma, a demanda observada em junho de 2014 foi ajustada através da sua substituição pela demanda esperada para aquele mês, calculada de acordo com o componente sazonal médio de junho, obtido no procedimento 3A da Figura 2. Somente após este ajuste a série histórica foi modelada pelas duas metodologias escolhidas.

Para a modelagem via metodologia Box-Jenkins, mais alguns procedimentos de ajuste dos dados foram realizados como a verificação da estacionariedade através do teste ADF – (*Augmented Dickley-Fuller*) e a operação da diferença sazonal para eliminar a sazonalidade da série. Para cada modelo selecionado também foi utilizado o teste de Ljung-Box para verificar se os resíduos não estavam autocorrelacionados. A escolha do melhor modelo deu-se através do critério de informação bayesiana normalizado – BIC Normalizado.

Para a modelagem por RNA, os dados foram aleatoriamente divididos em dois conjuntos, treinamento e teste, correspondendo a 70% e 30% das observações, respectivamente. Foi utilizada a arquitetura sugerida por Fernandes *et al* (2008), com uma camada oculta com função de ativação não linear, tangente hiperbólica, enquanto que na camada de saída a função de ativação foi do tipo linear (identidade). A fase de aprendizado deu-se através do algoritmo de retropropagação do erro e se encerrava quando o erro quadrático médio da base de treinamento não apresentava mais diminuição, para não comprometer a capacidade de generalização da rede. A escolha da melhor rede deu-se pela menor relação entre o erro quadrático médio das fases de treino e teste.

Na Etapa 2 foram obtidas as previsões pelos modelos ARIMA e RNA selecionados e estas previsões foram combinadas pelo método de regressão linear mais flexível (sem restrição dos pesos), expresso pelas Equações 4 e 5, de acordo com a significância estatística de cada termo da equação da regressão.

A comparação entre as previsões individuais e combinadas (Etapa 3) foi realizada através das três principais medidas de acurácia encontradas na literatura de previsão para demanda turística, resumidas no Quadro 1. As medidas utilizadas foram MAPE (*Mean Absolute Percentage Error*), RMSE (*Root Mean Square Error*) e MAE (*Mean Absolute Error*) e cabe ressaltar que não houve hierarquia quanto a preferência entre elas e que, de acordo com Lewis (1982), modelos cujo MAPE é inferior a 10% podem ser classificados com alta acurácia

Quadro: 1: Medidas de acurácia utilizadas

Medida	Fórmula
MAPE	$\frac{1}{n} \sum_{t=1}^n \left \frac{A_t - F_t}{A_t} \right \times 100$
RMSE	$\sqrt{\frac{1}{n} \sum_{t=1}^n (A_t - F_t)^2}$
MAE	$\frac{1}{n} \sum_{t=1}^n A_t - F_t $

A_t : valor observado no tempo $t=1,2,\dots,n$; F_t : valor previsto no tempo $t=1,2,\dots,n$

A previsão pontual mais acurada para o número de chegadas de turistas internacionais para agosto de 2016 foi selecionada entre as previsões obtidas pelos modelos individuais e via combinação de acordo com as três medidas descritas no Quadro 1. Para o ajuste dessa previsão (Etapa 4), atribuiu-se que o percentual de aumento observado no relativo sazonal de junho de 2014 (obtido no procedimento 3B) em relação ao componente sazonal médio de

junho (procedimento 3A) foi devido à realização da Copa Mundo (FIFA). Este percentual de aumento foi utilizado para ajustar a previsão obtida inicialmente para o número de chegadas de agosto de 2016.

O cálculo dos componentes sazonais e ajuste foram realizados em planilha eletrônica. A verificação da suposição de estacionariedade foi realizada no software Gretl 2015 e para as demais análises foi utilizado o software SPSS v.18. Foi adotada significância de 0,05 para os testes estatísticos.

4. Resultados

A Figura 3 ilustra a série histórica mensal do número de chegadas internacionais no Brasil. Os meses com maior volume de chegadas foram janeiro e fevereiro, período de férias e verão e, nos meses de maio a setembro foram observadas as menores demandas, com exceção de julho que apresenta uma leve alta, devido ao fato de também ser período de férias no país. Em alguns anos a demanda de janeiro chegou a ser mais que o dobro da demanda observada em setembro.

A partir de 2013 percebem-se algumas características distintas dos demais anos até então analisados como, por exemplo, aumento da demanda em março, ao passo que as demandas de janeiro, fevereiro e março de 2014 apresentaram diminuição. Contudo, o maior efeito foi observado na demanda de junho de 2014, devido à realização da Copa do Mundo (FIFA).




Figura 3: Número de chegadas internacionais na Brasil (jan/2003 – dez/2014)

Fonte: Ministério do Turismo (BRASIL, 2015)

Após realizar o ajustamento sazonal, a demanda observada em junho de 2014 de mais de um milhão de chegadas internacionais foi substituída pela demanda esperada para aquele mês de acordo com o componente sazonal de junho, pouco menos de 350 mil chegadas.

Foram identificadas a estacionariedade e a sazonalidade e, entre todos os modelos SARIMA analisados, o modelo que obteve menor BIC normalizado foi o SARIMA(1,0,1)(0,1,1). Para os modelos RNA definidos com uma camada oculta, com função de ativação tangente hiperbólica e uma camada de saída com função de ativação linear, foram testados de 2 a 12 neurônios na camada oculta, sendo o modelo com dois neurônios aquele que obteve melhor resultado.

A Equação 7 expressa os pesos atribuídos a cada previsão individual obtidos através do desempenho histórico das previsões analisado via regressão linear sem intercepto, uma vez que ele foi não significativo ($p\text{-valor}_c=0,742$; $p\text{-valor}_{\text{sarima}}=0,05$ e $p\text{-valor}_{\text{rna}}<0,001$). Neste método o maior peso foi atribuído às previsões obtidas pelo modelo RNA.

$$F_{\text{COMB}} = 0,278F_{\text{ARIMA}} + 0,719F_{\text{RNA}} \quad \text{Equação 7}$$

Na Tabela 1, a acurácia das predições estimadas pelos modelos SARIMA e RNA definidos, bem como a combinação dessas predições foram avaliadas. Tanto as previsões individuais quanto a combinação apresentaram excelente poder preditivo, sendo o maior MAPE observado nas predições via modelo SARIMA, 8,72%. As predições do modelo RNA se mostraram mais acuradas que do modelo SARIMA, sob as três medidas avaliadas. As previsões combinadas apresentaram desempenho ainda melhor que o desempenho observado nas predições do modelo RNA, sob os critérios MAPE e MAE.

Tabela 1: Medidas de acurácia para as predições

Modelos	Medida		
	MAPE	RMSE	MAE
SARIMA	8,72% (3)	58.676,18 (3)	37.879,64 (3)
RNA	7,26% (2)	51.342,01 (1)	31.467,81 (2)
COMBINAÇÃO	6,91% (1)	52.567,28 (2)	30.791,37 (1)

Valores entre parênteses indicam a posição de cada técnica quanto ao desempenho obtido, de acordo com a medida de acurácia avaliada.

Com o intuito de detalhar melhor a capacidade preditiva de cada técnica, na Tabela 2 as três medidas de acurácia foram calculadas utilizando os meses correspondentes a cada predição. O MAPE médio para as previsões de oito meses não ultrapassou 10%, dentre esses o maior MAPE médio observado foi de 8,72% para as previsões para setembro, via modelagem SARIMA. Os meses de março, abril e julho foram os que apresentaram pior

MAPE onde nesse último mês foi obtido MAPE médio de 17,39% pela modelagem SARIMA. De acordo com o MAPE e o MSE, o mês de fevereiro foi mais bem predito pela modelagem SARIMA. A modelagem RNA previu melhor os meses de setembro e novembro, de acordo com as três medidas de acurácia. Já a combinação apresentou melhor desempenho para as previsões de janeiro, abril a junho, outubro e dezembro, sob as três medidas avaliadas. Agosto, mês em que serão realizados os Jogos Olímpicos, historicamente mostrou-se um mês em que ambas as modelagens (SARIMA e RNA) apresentaram alta acurácia e, sobretudo, as previsões obtidas via combinação.

Tabela 2: Acurácia das previsões para a demanda brasileira, de acordo com período

Período	MAPE			RMSE			MAE		
	SARIMA	RNA	COMB	SARIMA	RNA	COMB	SARIMA	RNA	COMB
Janeiro	6,98% (3)	6,93% (2)	6,54% (1)	67.005,1 (3)	60.323,9 (2)	59.962,0 (1)	46.557,8 (2)	47.042,0 (3)	44.231,4 (1)
Fevereiro	6,20% (1)	6,81% (3)	6,49% (2)	44.208,0 (1)	50.540,1 (3)	44.839,0 (2)	35.985,1 (1)	38.468,5 (3)	36.966,5 (2)
Março	12,76% (2)	12,01% (2)	11,65% (1)	89.925,6 (3)	80.439,2 (1)	81.979,6 (2)	53.943,6 (3)	49.965,7 (2)	48.649,0 (1)
Abril	11,00% (1)	7,65% (2)	7,52% (1)	49.408,8 (3)	34.915,0 (2)	34.270,8 (1)	42.248,8 (3)	29.308,7 (2)	28.856,7 (1)
Maiο	6,65% (3)	5,00% (2)	4,22% (1)	26.197,2 (3)	19.122,9 (2)	15.777,0 (1)	21.272,1 (3)	15.770,1 (2)	13.346,8 (1)
Junho	7,26% (3)	5,42% (2)	4,96% (1)	27.387,8 (3)	20.942,7 (2)	20.848,4 (1)	22.114,3 (3)	16.434,7 (2)	15.065,8 (1)
Julho	17,39% (3)	14,61% (2)	14,22% (1)	103.219,5 (3)	93.215,1 (1)	93.933,4 (2)	77.579,8 (3)	66.166,7 (2)	65.323,7 (1)
<i>Agosto</i>	<i>6,06% (3)</i>	<i>5,70% (1)</i>	<i>5,72% (2)</i>	<i>26.844,5 (2)</i>	<i>27.258,5 (3)</i>	<i>26.196,9 (1)</i>	<i>22.449,1 (3)</i>	<i>21.796,9 (2)</i>	<i>21.670,2 (1)</i>
Setembro	8,72% (3)	6,96% (1)	7,13% (2)	39.271,3 (3)	32.458,7 (1)	32.745,3 (2)	27.711,5 (3)	22.763,4 (1)	23.092,9 (2)
Outubro	5,87% (3)	4,10% (2)	3,73% (1)	27.453,8 (3)	18.489,9 (2)	16.639,6 (1)	22.609,8 (3)	15.689,5 (2)	13.941,1 (1)
Novembro	5,69% (3)	2,96% (1)	3,15% (2)	29.327,7 (3)	14.983,3 (1)	17.571,4 (2)	23.366,4 (3)	12.677,1 (1)	13.308,7 (2)
Dezembro	10,02% (3)	7,92% (2)	7,52% (1)	91.517,7 (3)	88.105,4 (2)	87.082,6 (1)	58.717,0 (3)	46.841,7 (2)	45.043,1 (1)

Valores entre parênteses indicam a posição de cada técnica quanto ao desempenho obtido em cada período, de acordo com a medida de acurácia avaliada. Em itálico e negrito o desempenho médio das previsões realizadas para o mês em que os Jogos Olímpicos serão realizados no país.

Visto que a combinação das previsões apresentou melhora quanto à acurácia em pelo menos duas das três medidas de acurácia, bem como no mês de agosto, as previsões individuais foram obtidas e combinadas conforme a Equação 5. Na Tabela 3 duas previsões são apresentadas: a previsão inicial para agosto de 2016, obtida pelo método de combinação e, esta previsão ajustada pelo percentual de aumento das chegadas de turistas observado durante a realização do evento Copa do Mundo (FIFA) em 2014 (previsão final). Foi estimado um aumento de 175,01% na previsão inicial de 424.507 chegadas para agosto de 2016 baseado no aumento percentual estimado pelo relativo sazonal de junho de 2014 em relação ao componente sazonal médio de junho até 2013 devido a realização da Copa do Mundo. A previsão final ficou estimada em pouco mais de um milhão de chegadas.

Tabela 3: Previsões inicial e ajustada pelo índice sazonal

Previsão inicial Agosto/16	Aumento de turistas observado em junho/2014	Previsão final Agosto/2016
424.507	175,01%	1.167.436

5. Discussões e conclusões

Neste artigo a demanda turística brasileira foi modelada e prevista. Para tanto, foi utilizado o maior número disponível de informações históricas do número mensal de chegadas no Brasil. As previsões foram obtidas por dois modelos reconhecidamente robustos para realizar este tipo de análise (SARIMA e RNA) e combinadas através de regressão linear. Este método de combinação apresentou ótimo desempenho na avaliação realizada no capítulo III, que modelou a demanda turística de duas sedes olímpicas. A avaliação da acurácia se deu pelo posicionamento das previsões de acordo com três medidas amplamente utilizadas e igualmente ponderadas.

Após o ajuste para retirar o efeito da realização da Copa do Mundo (FIFA) na fase de modelagem dos dados, constatou-se que os modelos utilizados além de bem ajustados aos dados eram modelos com boa capacidade preditiva, onde o maior MAPE foi 8,72%, para as previsões via modelagem SARIMA e 6,91% para as previsões combinadas. Nas três medidas de acurácia avaliadas, as previsões combinadas apresentaram melhor desempenho que a previsão obtida pela modelagem SARIMA.

As previsões históricas para o mês de agosto mostraram-se bem acuradas nas três metodologias utilizadas, especialmente com relação ao MAPE médio que foi inferior a 10% (LEWIS, 1982). Os resultados obtidos via combinação obtiveram melhor desempenho quanto

ao RMSE e MAE, enquanto que as previsões obtidas pelo modelo RNA foram mais acuradas quanto ao MAPE, 5,70%, seguidas pelo MAPE da combinação, 5,72%.

Ao analisar o efeito do megaevento Copa do Mundo (FIFA), além das chegadas previstas, estimou-se um adicional de 175,01% no volume de chegadas internacionais para o mês de realização do evento. Este efeito ficou muito acima do mencionado por Fourie e Santana-Gallego (2011), que estimaram um aumento médio de 18% no volume de turistas durante a realização de um megaevento em um período de baixa temporada.

Segundo Remus *et al* (1995), a utilização de modelos matemáticos com o intuito de realizar previsões apresenta melhor desempenho diante de um cenário sob condições estáveis. Porém, a série apresentada neste estudo apresentou uma mudança no padrão dos dados devido justamente a um acontecimento atípico e a realização de algum tipo de ajuste fez-se imprescindível para a obtenção de uma previsão mais verossímil.

A utilização da informação do adicional de turistas observado em um megaevento ocorrido no próprio país foi extremamente valiosa para o ajuste da previsão para agosto de 2016. Junho e agosto são meses que apresentam características similares quanto ao volume de demanda, sendo razoável a hipótese utilizada neste artigo de que a quantidade adicional de turistas observada em junho possa ocorrer em agosto. Sem esse ajuste de previsão, a demanda turística para o mês de agosto provavelmente estaria subestimada resultando em situações críticas no Brasil como congestionamento dos pontos de entrada e atrações turísticas, dificuldade de acesso ao transporte, baixos níveis de qualidade dos serviços, degradação da imagem do Brasil, além da perda de oportunidades de mercado (TIDESWELL; MULES; FAULKNER, 2001; STEKLER, 2003).

Referências

- BALLOU, A.R.H. **Business logistics supply chain management: planning, organizing and controlling the supply chain.** 5 ed. Upper Saddle River: Pearson Prentice Hall, 2004. 789 p.
- BO, X; SHI-TING, L. Management of Tourism Resources and Demand Based on Neural Networks. **Intelligent Computation Technology and Automation (ICICTA)**, 2014 7th International Conference on. IEEE, p. 348-351, 2014.
- BRAGA, A.P; CARVALHO, A.C.P.L.F; LUDERMIR, T.B. **Redes neurais artificiais: teoria e aplicações.** Rio de Janeiro, Livros Técnicos Científicos, 2007.

BRASIL. Ministério do Turismo. **Anuário Estatístico de Turismo**. Disponível em: <http://www.dadosefatos.turismo.gov.br/dadosefatos/anuario/index.html>. Acesso em: dez. 2015.

DIVINO, J.A; MCALEER, M. Modelling sustainable international tourism demand to the Brazilian Amazon. **Environmental Modelling & Software**, v. 24, n.12, p.1411-1419, 2009.

CLAVERIA, O; MONTE, E; TORRA, S. Tourism demand forecasting with neural network models: different ways of treating information. **International Journal of Tourism Research**, v.17, n.5, p.492-500, September/October 2014.

CLAVERIA, O; TORRA, S. Forecasting tourism demand to Catalonia: Neural networks vs. time series models. **Economic Modelling**, v.36, p.220-228, janeiro 2014.

HALL, C.M. Urban entrepreneurship, corporate interests and sports mega-events: the thin policies of competitiveness within the hard outcomes of neoliberalism. **The Sociological Review**, v.54, n. s2, p. 59–70, December 2006.

FERNANDES, P; TEIXEIRA, J; FERREIRA, J.M; AZEVEDO, S.G. Modelling Tourism Demand: A Comparative Study between Artificial Neural Networks and the Box-Jenkins Methodology. **Romanian Journal of Economic Forecasting**, v.9, n.3, p.30-50, 2008.

FOURIE, J; SANTANA-GALLEGO, M. The impact of mega-sport events on tourist arrivals. **Tourism Management**, v.32, n.6, p.1364 – 1370, 2011.

GOH, C; LAW, R. Modeling and forecasting tourism demand for arrivals with stochastic nonstationary seasonality and intervention. **Tourism Management**, v.23, n.5, p.499–510, 2002.

GRANGER, C.W.J; RAMANATHAN, R. Improved methods of combining forecasts. **Journal of Forecasting**, v.3, n.2, p.197–204, April/June 1984.

GUJARATI, D.M. **Econometria básica**. 3ª Ed. Makron books, São Paulo, 2000.

KOVÁCS, Z.L. **Redes neurais artificiais: fundamentos e aplicações**. 3a Ed. rev. São Paulo: Livraria da Física; 2002.

KHASHEI, M; BIJARI, M. An artificial neural network (p, d, q) model for timeseries forecasting. **Expert Systems with Applications**, v.37, p.479–489, 2010.

LEE, Y.S; TONG, L.I. Forecasting time series using a methodology based on autoregressive integrated moving average and genetic programming. **Knowledge-Based Systems**, v.24, n.1, p.66-72, February, 2011.

LEWIS, C.D. **Industrial and Business Forecasting Methods**: A practical guide to exponential smoothing and curve fitting. Butterworth Scientific. London, 1982.

LONDON ASSEMBLY. **Legacy for London? Assessing the legacy of the Olympic Games and Paralympic Games**. Greater London Authority, 2007.

MORETTIN, P.A; TOLOI, C.M. **Análise de Séries Temporais**. São Paulo: Editora Edgard Blücher, 2006. 531 p.

OH, C; MORZUCH, B.J. Evaluating Time-Series Models to Forecast the Demand for Tourism in Singapore. **Journal of Travel Research**, v.43, n.4, p.404-413, 2005.

OMT (ORGANIZAÇÃO MUNDIAL DO TURISMO). **Introdução ao turismo**. São Paulo: Roca, 2001.

- PAI, A.P.F; LIN, B.K.P; LIN, C.C.S; CHANG, P.T. Time series forecasting by a seasonal support vector regression model. **Expert Systems with Applications**, v.37, n.6, p.4261–4265, 2010.
- PENG, B; SONG, H; CROUCH, G I. A meta-analysis of international tourism demand forecasting and implications for practice. **Tourism Management**, v.45, p.181-193, 2014.
- PETROPOULOS, C; NIKOLOPOULOS, K; PATELIS, A; ASSIMAKOPOULOS, V; ASKOUNIS, D. Tourism technical analysis system. **Tourism Economics**, v.12, n.4, p.543-563, 2006.
- PREUSS, H. The conceptualisation and measurement of mega sport event legacies. **Journal of Sport & Tourism**, v.12, n.3-4, p.207–227, 2007.
- REMUS, W; O'CONNOR, M; GRIGGS, K. Does reliable information improve the accuracy of judgmental forecasts? **International Journal of Forecasting**, v.11, p.285-293, 1995.
- SONG, H; HYNDMAN, R.J. Tourism forecasting: An introduction. **International Journal of Forecasting**, v.27, n.3, p.817-821, 2011.
- SONG, H.; LI, G. Tourism demand modelling and forecasting — A review of recent research. **Tourism Management**, v.29, n.2, p.203-220, 2008.
- STEKLER, H.O. Improving Our Ability to Predict the Unusual Event. **International Journal of Forecasting**, v.19, n.2, p.161-63, 2003.
- TIDESWELL, C; MULES, T; FAULKNER, B. An Integrative Approach to Tourism Forecasting: A Glance in the Rearview Mirror. **Journal of Travel Research**, v.40, n.2, p.162-171, 2001.
- WERNER, L. Um modelo composto para realizar previsão de demanda através da integração da combinação de previsões e do ajuste baseado na opinião. **Tese de doutorado**. Universidade Federal do Rio Grande do Sul, 2005.
- ZHANG, G; PATUWO, B.E; HU, M.Y. Forecasting with artificial neural networks: The state of the art. **International Journal of Forecasting** v.14, n.1, p.35–62, March 1998.
- ZHANG, G.P. Time series forecasting using a hybrid SARIMA and neural network model. **Neurocomputing**, v.50, p.159–175, January 2003.
- WU, Q; ZHANG, C.J; GAO, L; LI, X. Training neural networks by electromagnetism-like mechanism algorithm for tourism arrivals forecasting. **Bio-Inspired Computing: Theories and Applications (BIC-TA), 2010 IEEE Fifth International Conference on. IEEE**, 2010. p. 679-688.
- YO, Y; CHOI, T; HUI, C. An intelligent fast sales forecasting model for fashion products. **Expert Systems with Applications**, v.38, n.6, p.7373-7379, 2011.

V. CONSIDERAÇÕES FINAIS

5.1 Discussões e conclusões

O turismo é um fenômeno com muitos fatores econômicos positivos, tais como a criação de empregos, a arrecadação de impostos e o estímulo ao desenvolvimento, além dos ganhos sociais como a valorização da cultura local, porém se for mal planejado e implantado, pode ser fator de poluição, exclusão social e concentração de renda, por exemplo (TRIGO, MAZARO, 2012). Campo e Alvarez (2013) mencionam também que a cada ano, países investem grandes somas de dinheiro em atividades de marketing voltadas para promoção dos seus destinos turísticos, aquecendo a indústria de viagens, atraindo turistas potenciais e, dessa forma, chegando até mesmo a desconstruir uma eventual imagem comprometida nos mercados internacionais.

Para obter os ganhos positivos mencionados e desenvolver o crescimento do turismo, é fundamental ter um bom planejamento, de modo que os tomadores de decisão possam dimensionar da melhor forma possível os recursos financeiros destinados a investimentos. Este planejamento deve ser embasado em previsões confiáveis e acuradas acerca da demanda turística

A análise das mais recentes publicações acerca da previsão de demanda voltada ao turismo realizada no Artigo 1 foi valiosa para a elaboração, desenvolvimento e entendimento dos resultados obtidos nos dois artigos subsequentes. A demanda turística pode ser mensurada por distintas variáveis, sendo o número de chegadas a mais frequentemente utilizada nos artigos analisados e também a variável que tende a gerar previsões mais acuradas que as despesas turísticas, por exemplo, que é uma medida mais sensível à influência de outros fatores.

O desempenho de técnicas de inteligência artificial, originadas através da crescente gama de recursos computacionais disponível, tem despertado o interesse dos pesquisadores nas mais distintas áreas de aplicação, bem como no turismo. Combinações de modelos e combinação de previsões também tem sido utilizadas como alternativa para melhora da acurácia uma vez que tem apresentado desempenho satisfatório na maioria dos estudos analisados.

Ter mais de uma medida de avaliação do desempenho das previsões também é importante pois cada medida possui vantagens e desvantagens. Nesse sentido também é importante uma convenção quanto às medidas para fins de comparação entre publicações,

sendo utilizadas nos Artigos 2 e 3 as três medidas mais observadas no levantamento bibliográfico do Artigo 1.

Nas aplicações do Artigo 2, todas as modelagens utilizadas apresentaram bons ajustes aos respectivos dados e excelente capacidade preditiva, porém as previsões obtidas pela metodologia tradicional ARIMA, de forma geral, foram as que se mostraram menos acuradas pelas três medidas de acurácia utilizadas. Neste artigo, as previsões combinadas pelos cinco métodos sugeridos mostraram ganho de acurácia em relação à modelagem ARIMA e na maioria das vezes também em relação a modelagem RNA, sendo o método de regressão o que, para aquela aplicação, gerou previsões ainda mais precisas, em conformidade com alguns achados da literatura (ANDRAWIS; ATIYA; EL-SHISHINY, 2011, SHEN; LI; SONG, 2011).

O alto grau de acurácia observado nas previsões para as demandas analisadas no Artigo 2, mesmo sob a realização dos Jogos Olímpicos, atribuiu-se além da boa escolha das técnicas de previsão e de combinação também ao efeito sazonal pelo fato dos Jogos Olímpicos terem sido realizados em períodos tipicamente de alta temporada nos dois países analisados.

Para a análise da demanda turística internacional brasileira no Artigo 3 alguns ajustes tiveram que ser realizados, diferentemente das séries analisadas no Artigo 2, já que em 2014 houve a realização da Copa do Mundo (FIFA) no Brasil, o que impactou fortemente a sua demanda turística internacional. Procurou-se amenizar o impacto desse efeito no mês de junho, mês de início do evento Copa do Mundo, para a realização da modelagem da série. Sob estas condições, os modelos ARIMA e RNA escolhidos mostraram-se bem ajustados e com excelente capacidade preditiva. A combinação dessas previsões através da técnica de regressão linear contribuiu para a melhora acurácia e foi utilizada para a geração da previsão para agosto de 2016.

A utilização da estimativa percentual da quantidade adicional de chegadas internacionais em um mês que ocorreu um megaevento (junho de 2014), em relação ao comportamento histórico observado até 2013, para estimar a demanda de um mês em que ocorrerá outro megaevento (agosto de 2016) foi a alternativa sugerida nesta dissertação e justifica-se pelo fato de junho e agosto serem o segundo e o quarto meses com menor quantidade de chegadas internacionais, respectivamente, deduzindo-se que estes meses tem características semelhantes quanto a sazonalidade do número de chegadas. Dessa forma, conclui-se que a estimativa obtida é plausível para o desfecho em questão e destaca-se que o tipo de ajuste utilizado aplica-se apenas para a sede olímpica em questão analisada.

5.2 Sugestões para trabalhos futuros

Através do Artigo 1 observou-se o grande volume de publicações que procuraram analisar a demanda do turismo receptivo de destinos turísticos muito procurados como Espanha, China e Itália, porém foram encontrados somente dois artigos brasileiros voltados para previsão da sua demanda. O Brasil não está nem entre os vinte países com maior volume de chegadas, mas está na décima posição dos turistas que mais gastam quando viajam para outros países. Haja visto esta propensão dos brasileiros em gastar com lazer e o grande potencial turístico do país observado sobretudo no ano de 2014 com a realização da Copa do Mundo (FIFA), seria benéfico para o país aumentar a quantidade de chegadas (nacionais e internacionais) para gerar renda, emprego e estimular o desenvolvimento local, favorecendo tanto o turista estrangeiro quanto a população brasileira.

A determinação do comportamento da demanda suportada por boas previsões, principalmente frente à realização de um megaevento, é imprescindível para um correto dimensionamento de recursos por parte da gestão pública, quando prevista em tempo hábil para tal finalidade. Sugere-se a utilização desta dissertação como motivação para a realização de mais estudos, utilizando outros modelos, outras técnicas de combinação e horizonte maior de previsão, sempre objetivando o ganho de qualidade nas previsões.

REFERÊNCIAS

- ANDRAWIS, R.R; ATIYA, A.F; EL-SHISHINY, H. Combination of long term and short term forecasts, with application to tourism demand forecasting. **International Journal of Forecasting**, v.27, n.3, p.870-886, 2011
- BARBOSA, F.F. O turismo como um fator de desenvolvimento local e/ ou regional, **Caminhos de Geografia**, v.10, n.14, p.107-114, Fev/2005.
- BARRETTO, M. **Manual de iniciação ao estudo do turismo**. 17.Ed. Campinas: SP - Papirus Editora, 2006.
- BOYER, M. **História do turismo de massa**. Bauru: EDUFBA/EDUSC.2003
- BRASIL. Ministério do Turismo. **Anuário Estatístico de Turismo**. v.42, ano base 2014, 2015.
- CAMPO, S.; ALVAREZ, M.D. Can tourism promotions influence a country's negative image? An experimental study on Israel's image. **Current Issues in Tourism**, v.7, n.3: 201–219, 2013.
- CHEN, R.J. C. Before and after the inclusion of intervention events: an evaluation of alternative forecasting methods for tourist flows. **Tourism Analysis**, v. 10, n. 3, p. 269-276, 2005.

DANIEL, A.C.M. Caracterização do Sector Turístico em Portugal, **Revista de Estudos Politécnicos**, v.8, n.14, p.255-276, 2010.

EMBRATUR, Instituto Brasileiro do Turismo. **Turismo contribui com 9% do PIB mundial.** Disponível em: http://www.embratur.gov.br/piembratur-new/opencms/salaImprensa/artigos/arquivos/Turismo_contribui_com_9_do_PIB_mundial.html Acesso em: dez. 2015.

FOURIE, J; SANTANA-GALLEGO, M. The impact of mega-sport events on tourist arrivals. **Tourism Management**, v.32, n.6, p.1364 – 1370, 2011.

GOH, C. Exploring impact of climate on tourism demand. **Annals of Tourism Research**, v.39, n.4, p.1859-1883, 2012.

GOH, C; LAW, R. Modeling and forecasting tourism demand for arrivals with stochastic nonstationary seasonality and intervention. **Tourism Management**, v.23, n.5, p.499–510, 2002.

HALL, C.M. Urban entrepreneurship, corporate interests and sports mega-events: the thin policies of competitiveness within the hard outcomes of neoliberalism. **The Sociological Review**, v.54, n. s2, p. 59–70, December 2006.

LI, G.; SONG, H.; WITT, S.F. Recent Developments in Econometric Modeling and Forecasting. **Journal of Travel Research**, v.44, p.82-99, August 2005.

LONDON ASSEMBLY. **Legacy for London? Assessing the legacy of the Olympic Games and Paralympic Games.** Greater London Authority, 2007.

MARTINS, V.L.M; WERNER, L; BELLEZA, M.R. Tourism Demand In The World Cup 2014 In Brazil: An estimate based on the combination of forecasts and mathematical adjustment. **Espacios**, v.34, n.8, 2013.

MIN, J.C.H. Forecasting Japanese tourism demand in Taiwan using an intervention analysis. **International Journal of Culture, Tourism and Hospitality Research**, v.2, n.3, p.197-216, 2008.

MOURA, F.A; MONTINI, A.A. Modelagem da Demanda Turística Internacional para o Estado de São Paulo. **Sociedade, Contabilidade e Gestão**, v.5, n.2, jul/dez 2010.

OMT (ORGANIZAÇÃO MUNDIAL DO TURISMO). **Introdução ao turismo.** São Paulo: Roca, 2001.

PANOSSO NETTO, A. **O que é turismo.** São Paulo: Brasiliense, 2010.

POUDYAL, N.C; PAUDEL, B; TARRANT, M.A. A time series analysis of the impact of recession on national park visitation in the United States. **Tourism Management**, v.35, p.181-189, 2013.

ROCHE, M. Mega events and urban policy. **Annals of tourism research**, v.21, n.1, p.1-19, 1994.

SANTOVITO, T.C. A Copa do Mundo 2006: megaevento esportivo como atração turística, instrumento de comunicação e interação entre os povos. **Comunicação & Inovação**, v7, n.13, 2010.

SHEN, S; LI, G; SONG, H. Combination forecasts of International tourism demand. **Annals of Tourism Research**, v.38, n.1, p.72-89, 2011.

SONG, H; HYNDMAN, R.J. Tourism forecasting: An introduction. **International Journal of Forecasting**, v.27, n.3, p.817-821, 2011.

SONG, H.; LI, G. Tourism demand modelling and forecasting — A review of recent research. **Tourism Management**, v.29, n.2, p.203-220, 2008.

STEKLER, H.O. Improving Our Ability to Predict the Unusual Event. *International Journal of Forecasting*, v.19, n.2, p.161-63, 2003.

TRIGO, L.G.G. **A sociedade pós-industrial e o profissional em turismo**. Papirus Editora, 1998.

TRIGO, L.G.G; MAZARO, R. **Movimentos Globais e Cenários em Turismo**: uma realidade dinâmica, uma viagem ao futuro, *Turismo em análise*, v.23, n.3, 2012.

TIDESWELL, C; MULES, T; FAULKNER, B. An Integrative Approach to Tourism Forecasting: A Glance in the Rearview Mirror. **Journal of Travel Research**, v.40, n.2, p.162-171, 2001.

URRY, J. . **O Olhar do turista: lazer e viagem nas sociedades contemporâneas** (3a ed.). São Paulo: Studio Nobel, SESC. 2001.

WTO (World Tourism Organization). **Tourism Highlights**: 2015 Edition. 2015. Disponível em: <http://www.unwto.org/facts/menu.html>. Acesso em: dez. 2015. 2015a

_____. **World Tourism Barometer**. v.13, n.5, 2015 Disponível em: <http://www.unwto.org/facts/menu.html>. Acesso em: dez. 2015. 2015b