

INSTITUTO TECNOLÓGICO DE AERONÁUTICA



Marcelo Bálbio Moraes

**AVALIAÇÃO DA GEOESTATÍSTICA COMO MÉTODO
DE PREVISÃO DE MOVIMENTO DE PASSAGEIROS NO
AEROPORTO INTERNACIONAL DO RIO DE JANEIRO
ATRAVÉS DE COMPARAÇÃO COM MÉTODOS
CONVENCIONAIS**

Trabalho de Graduação

2009

Civil

Marcelo Bálbio Moraes

**AVALIAÇÃO DA GEOESTATÍSTICA COMO MÉTODO DE
PREVISÃO DE MOVIMENTO DE PASSAGEIROS NO
AEROPORTO INTERNACIONAL DO RIO DE JANEIRO
ATRAVÉS DE COMPARAÇÃO COM MÉTODOS
CONVENCIONAIS**

Orientador

Paulo Ivo Braga de Queiroz, Professor Doutor

Co-orientador

Carlos Müller, Professor Doutor

Divisão de Engenharia Civil

SÃO JOSÉ DOS CAMPOS
COMANDO GERAL DE TECNOLOGIA AEROESPACIAL
INSTITUTO TECNOLÓGICO DE AERONÁUTICA

Dados Internacionais de Catalogação na Publicação (CIP)
Divisão de Informação e Documentação

Moraes, Marcelo Bálbio

Avaliação da Geoestatística como Método de Previsão de Movimento de Passageiros no Aeroporto Internacional do Rio de Janeiro Através de Comparação com Modelos Convencionais / Marcelo Bálbio Moraes

São José dos Campos, 2009.

50f.

Trabalho de Graduação – Divisão de Engenharia Civil –
Instituto Tecnológico de Aeronáutica, 2009. Orientador: Dr Paulo Ivo Braga de Queiroz

1. Geoestatística. 2. Transporte aéreo. 3. Planejamento de aeroportos. I. Departamento de Ciência e Tecnologia Aeroespacial. Instituto Tecnológico de Aeronáutica. Divisão de Engenharia Civil. II. Título.

REFERÊNCIA BIBLIOGRÁFICA

MORAES, Marcelo Bálbio. **Avaliação da Geoestatística como Método de Previsão de Movimento de Passageiros no Aeroporto Internacional do Rio de Janeiro Através de Comparação com Modelos Convencionais**. 2009. 50f. Trabalho de Conclusão de Curso (Graduação) – Instituto Tecnológico de Aeronáutica, São José dos Campos.

CESSÃO DE DIREITOS

NOME DO AUTOR: Marcelo Bálbio Moraes

TÍTULO DO TRABALHO: Avaliação da Geoestatística como Método de Previsão de Movimento de Passageiros no Aeroporto Internacional do Rio de Janeiro Através de Comparação com Modelos Convencionais

TIPO DO TRABALHO: Graduação / 2009

É concedido ao Instituto Tecnológico de Aeronáutica permissão para reproduzir cópias deste trabalho de graduação e para emprestar ou vender cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta monografia de graduação pode ser reproduzida sem a autorização do autor.

Marcelo Bálbio Moraes
Rua Santa Bárbara, 696, Sagrada Família
Belo Horizonte, MG

AVALIAÇÃO DA GEOESTATÍSTICA COMO MÉTODO DE PREVISÃO DE MOVIMENTO DE PASSAGEIROS NO AEROPORTO INTERNACIONAL DO RIO DE JANEIRO ATRAVÉS DE COMPARAÇÃO COM MÉTODOS CONVENCIONAIS

Essa publicação foi aceita como Relatório Final de Trabalho de Graduação.



Marcelo Bálbio Moraes, Asp Of
Autor



Paulo Ivo Braga de Queiroz, Prof. Dr. (ITA)
Orientador



Carlos Müller, Prof. Dr. (ITA)
Co-orientador



Eliseu Lucena Neto, Prof. Dr.
Coordenador do Curso de Engenharia Civil-Aeronáutica

São José dos Campos, 23 de novembro de 2009.

Dedico este trabalho a meu avô Zé (in memoriam), que com certeza me acompanhou de perto durante essa empreitada, compartilhando comigo as felicidades e dificuldades

Agradecimentos

A Deus por me dar saúde, paciência e perseverança durante essa longa jornada.

Aos meus pais pelo amor dedicado, incentivo e sacrifício para a concretização dos meus objetivos.

A minha família por acreditar em mim e pelo apoio incondicional aos meus sonhos.

A minha noiva, Fabiana, pela paciência e por estar sempre ao meu lado nos bons e maus momentos.

Ao professor PI também pela paciência, pela disponibilidade e pela excelente orientação.

A meu amigo, Hugo Jales, pelo grande auxílio na modelagem de séries temporais.

A INFRAERO pela base de dados e ao professor Carlos Müller por torná-la disponível e pelo auxílio no tratamento dos dados.

“Aquilo que puder ser destruído pela verdade deve ser.”
(P.C. Hodgell)

Resumo

O presente trabalho tem por objetivo aplicar a Geoestatística à previsão de demanda por transporte aéreo no Aeroporto Internacional do Rio de Janeiro e comparar os resultados com previsões geradas por modelagens mais comumente utilizadas na atualidade, como as séries temporais.

A base de dados utilizada foi fornecida pela INFRAERO e trabalhou-se com o movimento de passageiros de transporte regular nacional doméstico entre agosto de 1990 e julho de 2001, a fim de prever o movimento dos seis meses subsequentes. Mostra-se que a variável é estacionária quando se subtraem as médias mensais e que o variograma experimental levantado teve excelente ajuste com o modelo teórico esférico. O conhecimento prévio da média levou à opção pela Krigagem Simples como modelagem geoestatística e o cálculo dos pesos evidenciou o efeito tela com relação à observação mais recente; a variância do processo mostrou que o método é superior a métodos estatísticos convencionais baseados apenas em média e desvio padrão.

Foram geradas previsões através da Krigagem Simples e de um modelo estrutural básico de séries temporais, que se caracteriza como um processo estocástico. A comparação das previsões com os valores observados evidenciou que a modelagem por séries temporais é mais eficiente que a geoestatística, seja por apresentar menor erro em todos os casos, seja por conseguir captar as peculiaridades da série de dados. O fato de a Krigagem apresentar menor variância que o modelo de séries temporais indicou uma tendência na modelagem geoestatística, certamente gerada pela consideração das médias mensais e não de uma única média global.

Abstract

This work aims to apply geostatistics to forecast demand for air transportation at the International Airport of Rio de Janeiro and compare the results with predictions generated by models commonly used today, such as time series.

The database used was provided by INFRAERO and the movement of passenger of regular national domestic transport between August 1990 and July 2001 was considered, in order to predict the demand of the next six months. It is shown that the variable is stationary when the monthly averages were subtract and the experimental variogram has achieved excellent fit with the theoretical spherical model. Prior knowledge of the average value led to the choice of Simple Kriging geostatistical modeling and the weights calculation showed the screen effect regarding the most recent observation; the variance of the process proved that the method is superior to conventional statistical methods based only on mean and standard deviation.

Using the Simple Kriging and a basic structural model of time series, which is characterized as a stochastic process, forecasts were generated. Comparison of predictions with observed values showed that time series modeling is more efficient than geostatistics, due to present a lower error in all cases and to be able to capture the database particularities. The fact that the Kriging has shown lower variance than the time series model indicated a trend in geostatistical modeling, certainly generated by the consideration of the monthly average rather than a single global average.

LISTA DE FIGURAS

Figura 2.1 - Movimento de Passageiros no Galeão entre 2003 e 2008	19
Figura 4.1 - Amostragem em duas dimensões.....	29
Figura 5.1 - Movimento Mensal de Passageiros em SBGL entre janeiro de 1990 e julho de 2008	39
Figura 5.2 - Comportamento da Variável.....	41
Figura 5.3 - Variogramas Experimental e Teóricos Ajustados	42
Figura 5.4 - Comportamento da Variância da KS com o Horizonte de Previsão.....	43
Figura 5.5 - Previsões por KS e Séries Temporais e Valores Observados.....	46

LISTA DE TABELAS

Tabela 5.1 - Dados de Movimento Total de Passageiros de Transporte Regular Doméstico Nacional em SBGL.....	40
Tabela 5.2 - Pesos e Variância da KS.....	44
Tabela 5.3 - Previsões por KS	45
Tabela 5.4 - Previsões Geradas por Séries Temporais	46
Tabela 5.5 - Resultados das Previsões por KS	48
Tabela 5.6 - Resultados das Previsões por Séries Temporais.....	48

LISTA DE ABREVIATURAS, SIGLAS E SÍMBOLOS

$S_1, S_2, S_3, \dots, S_T$	Série temporal de tamanho T
T	Último instante disponível em uma série temporal
\bar{S}_{T+k}	Previsão da série temporal no instante T+k
$e_k(t)$	Erro de previsão k passos à frente do instante t
N	Número de observações de uma série temporal
\mathbf{x}	Posição em uma, duas ou três dimensões
Z	Variável regionalizada
$Z(\mathbf{x})$	Valor da variável Z em \mathbf{x}
$m(\mathbf{x})$	função determinística que descreve a componente estrutural de Z em \mathbf{x}
$e\phi(\mathbf{x})$	termo estocástico que varia localmente e depende espacialmente de $m(\mathbf{x})$
e^2	ruído aleatório não correlacionado com distribuição normal com média zero e variância σ^2
σ^2	Variância
E	Valor esperado
C	Função de covariância
Var	Variância
$\gamma(\mathbf{h})$	Função semi-variograma
\mathbf{h}	Vetor distância
C	Patamar do variograma
a	Alcance do variograma
$ \mathbf{h} $	Módulo do vetor \mathbf{h}
exp	Exponencial de base e
$\gamma^*(\mathbf{h})$	Função variograma experimental
$N(\mathbf{h})$	Número de pares $(\mathbf{x}_i, \mathbf{x}_i+\mathbf{h})$ separados pela distância \mathbf{h}
\mathbf{x}_i	i-ésimo local de amostra, representado pelo par de coordenadas (x_i, y_i)
$\sum_{i=1}^{N(\mathbf{h})}$	Somatório com i variando de 1 a $N(\mathbf{h})$

KO	Krigagem Ordinária
KS	Krigagem Simples
Z_v^*	Estimativa do valor de Z em um ponto definido
n	Número de valores observados para prever Z_v^*
λ_i	Peso da KO relativo à i-ésima observação
Y	Variável regionalizada de média nula
λ_i'	Peso da KS relativo à i-ésima observação
λ_m	Peso da média na KS
PAX	Passageiros
E_x^2	Erro quadrático médio do processo X

SUMÁRIO

1	Introdução.....	15
2	Demanda por Transporte Aéreo	17
2.1	O Aeroporto Internacional do Rio de Janeiro	18
3	Séries Temporais	20
3.1	Alguns Modelos Univariados	21
3.1.1	Naive.....	22
3.1.2	Médias Móveis (de tamanho N)	22
3.1.3	Amortecimento Exponencial	22
3.1.4	Modelos ARIMA de Box & Jenkins	23
3.2	Decomposição de uma Série Temporal	23
3.3	Características de Uma Série Temporal e Estimadores	23
4	Geoestatística	25
4.1	Fundamentação Teórica: Variáveis Regionalizadas	26
4.1.1	Hipóteses Assumidas	27
4.1.2	Função de Covariância Espacial.....	28
4.2	O Variograma	28
4.2.1	Alcance e Janela de Influência	29
4.2.2	Comportamento Próximo à Origem	30
4.2.3	Modelos Comuns de Variograma.....	30
4.3	Variogramas Experimentais.....	31
4.4	Teoria da Krigagem	32
4.4.1	A Proposta da Krigagem	32
4.4.2	Krigagem Ordinária.....	33
4.4.3	Krigagem Simples	34
4.5	Efeito Tela.....	36
5	Resultados e Análise	37
5.1	Base de Dados.....	37
5.2	Tratamento e Análise dos Dados	37
5.3	Verificação de Estacionariedade.....	38
5.4	Levantamento e Ajuste do Variograma Experimental.....	41
5.5	Determinação dos Pesos de Krigagem e da Variância do Processo	43
5.6	Previsões Através de Krigagem Simples	45
5.7	Previsões por Séries Temporais	45
5.8	Comparação dos Modelos.....	46

6	Conclusão	49
	Referências	51

1 Introdução

A previsão de movimento de passageiros e aeronaves no transporte aéreo constitui um dado extremamente importante no dimensionamento das estruturas de um aeroporto, tais como pista, pátio, terminal de passageiros e estacionamento. Esses dados podem ser usados tanto em projetos para novos aeroportos como em planos de ampliação. Além disso, essas previsões, em especial de movimento de passageiros, são fundamentais para as empresas aéreas manterem atualizados seus planos de negócios, identificando ações que as mantenham sólidas no ambiente competitivo.

Tendo em vista a importância dessas previsões, faz-se necessário o uso adequado de modelagens eficientes, capazes de produzir resultados o mais próximo possível da realidade, com uma confiabilidade aceitável. O objetivo desse trabalho é verificar se a Geoestatística pode ser considerada uma dessas modelagens eficientes para prever a demanda no transporte aéreo. Para isso, serão gerados resultados de previsão por um modelo Geoestatístico, a Krigagem Simples, bem como os parâmetros de confiabilidade do modelo, cabendo-se destacar a variância. Esses resultados serão comparados com uma modelagem básica de séries temporais, o método de previsão mais utilizado quando se dispõe apenas da série histórica de movimentos como base de dados.

A motivação para a realização desse trabalho está pautada em observar como os modelos Geoestatísticos, amplamente usados em prospecção de minas e Sistemas de Informação Geográficas, se comportam ao ter sua variável espacial substituída por uma variável temporal. Como o cerne dessas modelagens se baseia nas correlações espaciais entre as observações feitas, parece extremamente pertinente avaliar, ao invés das correlações espaciais, as correlações temporais. Caso os resultados sejam satisfatórios, haverá um campo mais amplo para aplicação dessa ciência. Além disso, previsões mais precisas e confiáveis em transporte aéreo podem gerar economias para empresas e administradoras de aeroportos ao permitir a redução de ociosidades no sistema.

Este trabalho está estruturado em cinco capítulos. O Capítulo 2 mostra, tanto do ponto de vista das operadoras de aeroportos como das empresas aéreas, a importância de se prever, da melhor forma possível, a demanda por transporte aéreo. Os modelos mais comuns de previsão, dentre os quais o econométrico, as séries temporais e as pesquisas de mercado, são brevemente apresentados. Além disso, busca-se justificar a escolha do Aeroporto

Internacional do Rio de Janeiro para se fazerem as previsões, apresentando-se dados de capacidade e histórico recente de movimentos, bem como suas peculiaridades.

O Capítulo 3 traz uma breve abordagem sobre as séries temporais, método que será utilizado para gerar resultados que serão comparados com os obtidos pelo uso da Geoestatística. São apresentadas definições básicas, bem como os modelos mais consagrados pela literatura. Além disso, mostra-se as componentes geradas pela decomposição de uma série temporal e as características que descrevem um processo estocástico estacionário, como uma série temporal por exemplo, no domínio do tempo.

O Capítulo 4 trata da teoria da Geoestatística, apresentando suas principais utilizações e procedimentos. É apresentado um breve histórico sobre estudos envolvendo variabilidade espacial, que culminam na formulação da Teoria da Variáveis Regionalizadas. São apresentadas as hipóteses de estacionariedade dessa teoria, bem como as propriedades de covariância espacial advindas dela. O variograma é mostrado como a ferramenta básica do principal procedimento da Geoestatística, a Krigagem, por ser capaz de estabelecer as correlações espaciais/temporais entre as observações e os principais modelos teóricos dessa ferramenta são apresentados, bem como o procedimento para o levantamento de um variograma experimental. Ainda nesse capítulo, são apresentados os procedimentos para o cálculo dos pesos a serem dados nas observações na previsão, seja quando se desconhece a média-Krigagem Ordinária-, seja quando a média é conhecida-Krigagem Simples-, além daqueles para se efetuar as previsões e para se obter as variâncias de ambos processos. Faz-se, também, uma breve abordagem sobre o efeito tela, que pode ocorrer na obtenção dos pesos de Krigagem.

No Capítulo 5 são mostrados os resultados do trabalho: a base de dados de movimento de passageiros no Aeroporto Internacional do Rio de Janeiro é apresentada, bem como os processos de tratamento de dados utilizados. É feita uma verificação de estacionariedade da variável e o levantamento do variograma experimental, com posterior ajuste de variograma teórico. Os pesos a serem dados às observações são determinados através da Krigagem Simples, que possibilita também que se avalie a variância do processo. Por fim, são geradas as previsões pelo modelo geoestatístico e também por uma modelagem simples de séries temporais, permitindo a comparação dos dois modelos.

O Capítulo 6 mostra as conclusões obtidas ao se empregar a Geoestatística como modelo de previsão de demanda no transporte aéreo, bem como oferece sugestões para trabalhos futuros.

2 Demanda por Transporte Aéreo

As pesquisas por demanda em transporte aéreo têm uma influência considerável nos projetos de construção e manutenção de aeroportos, tanto do lado ar como do lado terra, visto que ambos dependem da quantidade de passageiros que utilizarão o aeroporto no período de projeto.

Devido à maior acessibilidade ao transporte aéreo, à concorrência entre empresas aéreas e às necessidades de um transporte rápido em um país de grande geografia como o Brasil, a demanda por esse serviço tem sido continuamente crescente. Deve-se somar a esses fatos os eventos esportivos a serem realizados em 2014 (Copa do Mundo de Futebol) e 2016 (Olimpíadas do Rio de Janeiro), que causarão, certamente, aumento considerável na demanda por transporte aéreo.

Além dos projetistas de aeroportos, as empresas aéreas também têm largo interesse em modelos de demanda e simulações, visto que se trata de um mercado competitivo e no qual o usuário pode escolher diferentes níveis de serviço. Isso se intensificou nos últimos anos, com a entrada de novas empresas e alianças no setor, intensificando a complexidade de um mercado peculiar, que oferece diferentes tarifas, origens/destinos, e serviços de bordo [1].

Existem diversos modelos e métodos para se estimar a demanda por transporte aéreo, dentre os quais se destacam o econométrico, as séries temporais e as pesquisas de mercado.

No modelo econométrico, busca-se estimar a demanda como uma função que depende de parâmetros diversos, tais como produto interno bruto do país, tarifas praticadas pelas empresa aéreas ou qualquer variável que tenha alta correlação com o movimento de passageiros observado (excluindo as correlata entre si). Aqui cabe deixar claro que há diferença entre demanda e movimento observado: o movimento é a melhor expressão da demanda, porém há casos de demanda reprimida em que o movimento não reflete de forma real a demanda.

Os modelos de séries temporais têm sido largamente utilizados, principalmente modelos autoregressivos; existem na literatura poucos exemplos de modelos mais complexos, como modelos ARIMA [1]. Trata-se de fazer previsões baseando-se em um conjunto de observações ordenadas no tempo, com dependência serial.

As pesquisas de mercado também são ótimas fontes de informação, e tanto os aeroportos como as empresas aéreas podem coletar dados dos passageiros enquanto eles

esperam pelo embarque. Entretanto, poucos aeroportos coletam regularmente dados através de entrevistas com passageiros, enquanto as empresas aéreas baseiam suas pesquisas na satisfação dos clientes e outros itens mais focados na área financeira que nas simulações de demanda [1].

Outras técnicas menos utilizadas usam modelagens com redes neurais, uma ferramenta que tenta simular as decisões do cérebro humano; modelos de redes neurais usando lógica fuzzy foram usados recentemente para pesquisar modos de escolha. Porém, esses modelos não permitem visualizar de forma explícita os valores dos parâmetros a serem obtidos, de forma que não se pode utilizar os modelos para estimar elasticidades e correlações [1].

O presente trabalho fará uso, dentre os métodos acima, das séries temporais como forma de comparação com os resultados obtidos pelo emprego da Geoestatística.

Cabe lembrar, ainda, que o crescimento da demanda pode acarretar um esgotamento da capacidade de determinados componentes de um aeroporto. “A construção de um novo aeroporto ou de novas instalações para um aeroporto congestionado de fato traz grandes benefícios à indústria do transporte aéreo, entretanto, não é uma solução fácil de ser adotada e seus benefícios são notados apenas no longo prazo” [2]. Dessa forma, os estudos de demanda são de extrema importância para evitar o estrangulamento da rede aeroportuária.

2.1 O Aeroporto Internacional do Rio de Janeiro

O Aeroporto Internacional do Rio de Janeiro é de fundamental importância para o desenvolvimento do turismo e negócios na região em que está localizado e terá papel de destaque na estrutura dos eventos esportivos a serem sediados pelo Rio de Janeiro (Copa do Mundo de Futebol em 2014 e Olimpíadas em 2016). Além disso, o Galeão é uma das principais portas de entrada para o Brasil, sendo ligado a 19 destinos internacionais, além de 32 localidades nacionais [3]. No que diz respeito ao tráfego aéreo nacional, o Galeão concorre com o do Aeroporto Santos Dumont, situado na região central da cidade do Rio de Janeiro, e tem tido seu movimento alterado por regulamentações que restringem o uso deste último.

Do ponto de vista da capacidade, o Galeão vem operando bem abaixo do máximo possível, o que tem direcionado esforços do Governo em melhorias no acesso e em políticas direcionadoras de movimento para esse aeroporto. Também, se necessário, o Galeão apresenta

possibilidades de ampliar sua capacidade devido às suas dimensões e às do entorno. “Possui dois sistemas de pistas com operações simultâneas de pousos e decolagens. São 167 balcões de check in, 35 esteiras de bagagens, 23 pontes de embarque e 23 posições remotas. Ao todo 20 empresas aéreas prestam serviços nos dois terminais, atendendo um movimento diário de 30 mil passageiros” [3].

A Figura 2.1 apresenta a evolução do movimento de passageiros no Galeão, mostrando uma estagnação no movimento internacional e o movimento interno em franca ascendência, de acordo com dados da INFRAERO [3].

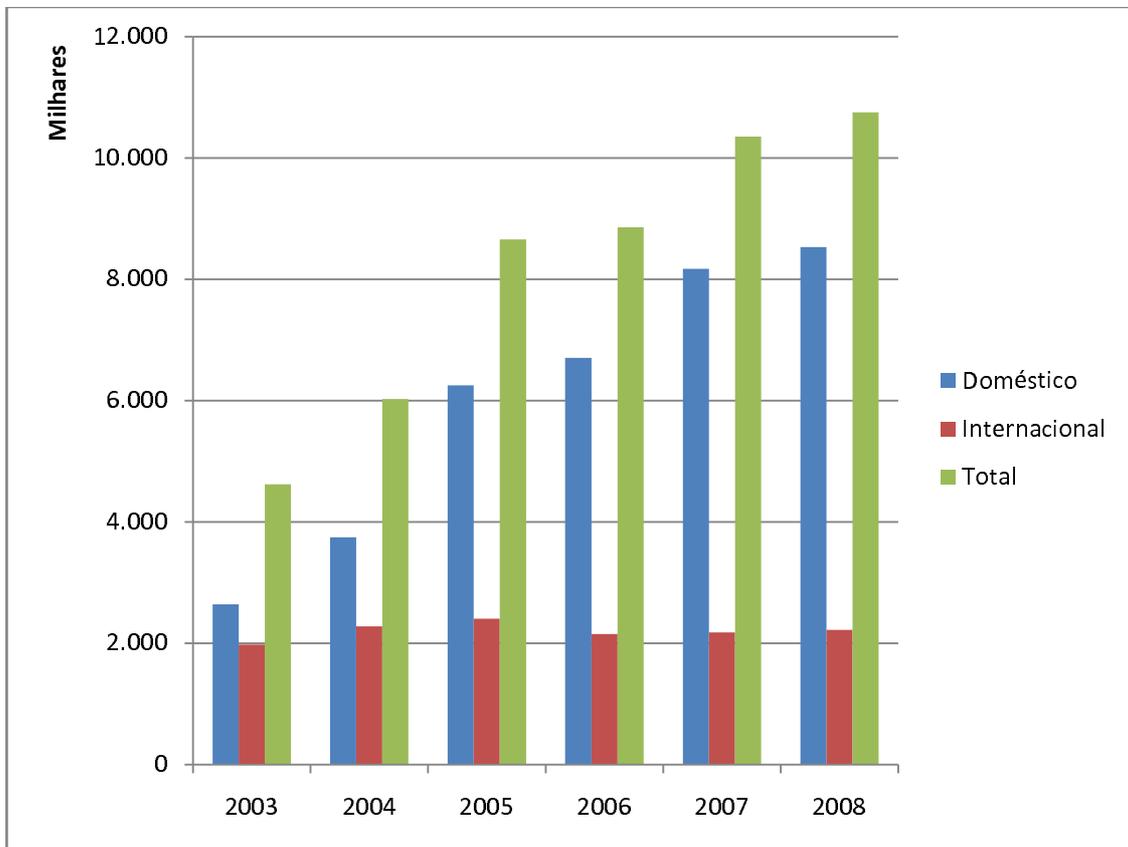


Figura 2.1 - Movimento de Passageiros no Galeão entre 2003 e 2008

3 Séries Temporais

O objetivo desse capítulo é apenas dar introdução às séries temporais, oferecendo definições básicas e mostrando os métodos mais consagrados pela literatura. Não se busca aqui aprofundar na metodologia de gerar previsões a partir de uma série temporal, e sim explicar de forma sucinta o método que será contraposto à Geoestatística nos capítulos seguintes.

No estudo das séries temporais a noção de dependência entre as observações é fundamental, ao contrário da maioria dos processos estatísticos em que supõe-se que as observações formam uma amostra aleatória, isto é, são independentes e identicamente distribuídas.

Por definição, uma série temporal é um conjunto de observações ordenadas no tempo, não igualmente espaçadas, e que apresentam dependência serial, isto é, dependência entre instantes de tempo. A notação que será aqui usada para denotar uma série temporal é $S_1, S_2, S_3, \dots, S_T$, que indica uma série de tamanho T . Em geral, o instante T indica o último instante disponível. De uma maneira mais formal, diz-se que uma série temporal é uma realização de um processo estocástico [4].

Outra definição importante é a de processo ergódico: um processo estocástico é dito ergódico se uma única realização do processo é suficiente para caracterizá-lo [4]. Na análise de séries temporais existe apenas uma realização do processo disponível e, portanto, é necessário supor que o processo subjacente é ergódico, pois apenas uma de suas realizações será usada para caracterizá-lo.

O estudo de uma série temporal, em geral, tem dois objetivos: o primeiro é a análise e modelagem da série temporal em questão, em que se busca descrever a série, verificar suas características mais relevantes e suas possíveis relações com outras séries. O segundo objetivo é a previsão da série temporal: a partir de valores passados da série (e, talvez, de outras séries), busca-se encontrar boas previsões, em geral de curto prazo, de valores futuros da série. A previsão da série no instante $T+k$ será denotada por \bar{S}_{T+k} . O número de instantes à frente para o qual é feita a previsão é chamado horizonte de previsão.

A dependência serial entre os valores da série é um aspecto essencial, pois é ela que permite que se gere previsões de valores futuros da série. Cabe lembrar também que diferentes séries possuem diferentes graus de previsibilidade. Dessa forma, não se pode

afirmar que um método é sempre melhor que outro, visto que esses métodos procuram captar particularidades das séries. Com relação ao horizonte de previsão, pode-se afirmar o nível de incerteza aumenta com o aumento desse horizonte.

Uma forma de se medir a eficácia da previsão feita é o erro de previsão k passos à frente ($k \geq 1$) do instante t , definido como a diferença entre o valor real da série no instante t e a previsão deste valor feita k instantes antes, isto é:

$$e_k(t) = S_t - \bar{S}_{t-k}(k) \quad (3.1)$$

Um bom modelo de previsão produz previsões com erro relativamente pequeno, e assim é interessante que se acompanhe quantidades como a soma dos quadrados dos erros de previsão, ou a soma dos valores absolutos dos erros de previsão [4].

De uma forma geral e simplificada, a modelagem de uma série temporal deve buscar capturar toda a estrutura de dependência existente na série. Dessa forma, não deve haver estrutura nos resíduos, pois ela já foi captada pelo modelo (o resíduo é a diferença entre o valor real e o ajustado por um modelo qualquer): uma boa modelagem não deve apresentar correlação serial, isto é, correlação entre os resíduos em diferentes instantes). Também, deve-se buscar explicar o comportamento da série com o menor número de parâmetros.

Um primeiro passo a ser dado ao iniciar o estudo de uma série, bastante esclarecedor, é o traçado de um gráfico para mostrar a evolução da série no tempo. Esse simples procedimento permite identificar como evolui a tendência da série, se há sazonalidade ou outliers.

Há duas grandes classes de modelos: nos modelos univariados, a série temporal é explicada apenas pelos seus valores passados; nos modelos multivariados, ou causais, a série é explicada pelos seus valores passados e também pelos valores passados de outras variáveis.

3.1 Alguns Modelos Univariados

Aqui serão apresentados alguns modelos univariados comumente usados no tratamento das séries temporais.

3.1.1 Naive

Também chamado de ingênuo, traz como valor de previsão de S_{T+1} a última observação, isto é, S_T . Claramente, não é um método eficiente, mas, às vezes, o único disponível [4].

3.1.2 Médias Móveis (de tamanho N)

A cada instante, a previsão é apenas a média das últimas N observações. Um dos problemas com esse método é a escolha de N, o tamanho da janela a ser utilizado. Quanto maior o valor de N, mais suave é a previsão; se N é relativamente pequeno, a previsão tende a oscilar muito. Uma característica importante do método das médias móveis é que todas as observações usadas para cálculo têm o mesmo peso ($1/N$) [4]. Mas, na prática, é razoável supor que as observações mais recentes sejam mais relevantes para a previsão dos próximos valores da série, devendo, portanto, receber um peso maior que as observações mais antigas.

3.1.3 Amortecimento Exponencial

Existem inúmeras variações destes métodos, para séries sazonais e não sazonais. É um método semelhante ao das médias móveis, porém os pesos das observações decrescem à medida que as observações estarão mais longe no passado. A taxa de decréscimo do(s) peso(s) é determinada por uma ou mais constantes de amortecimento [4]. A maior dificuldade na aplicação é escolher a(s) constante(s) de amortecimento, mas alguns softwares já ajustam os modelos de amortecimento automaticamente com constantes otimizadas.

Na prática, os métodos de amortecimento são os métodos de previsão mais usados, o que é em parte explicado pela sua facilidade de implementação e capacidade em gerar boas previsões [4].

3.1.4 Modelos ARIMA de Box & Jenkins

São modelos mais sofisticados, que usam as correlações entre as observações em diversos instantes. A idéia por trás dos modelos ARIMA envolve filtros lineares e Teoria de Sistemas [4]. A identificação da estrutura do modelo é um pouco complicada, mas alguns softwares já identificam automaticamente a estrutura do modelo ARIMA, evitando o passo mais complicado da análise. Como casos particulares dos modelos ARIMA temos os processos AR (autoregressivo) e MA (médias móveis ou moving average).

Os modelos ARIMA costumam apresentar melhores resultados que os métodos de amortecimento quando a série é longa e com comportamento regular.

Existe também modelos ARIMA multivariados, geralmente chamados modelos de função de transferência.

3.2 Decomposição de uma Série Temporal

A maneira tradicional de se analisar uma série temporal é através da sua decomposição nas componentes de tendência, ciclo e sazonalidade.

A tendência de uma série indica o seu comportamento de longo prazo, isto é, se ela cresce, decresce ou permanece estável, e qual a velocidade destas mudanças. Nos casos mais comuns, trabalham-se com tendência constante, linear ou quadrática [4].

A sazonalidade indica a repetição de um padrão na série dentro do período de um ano [4].

Os ciclos indicam padrões que se repetem na série em períodos superiores a um ano [4].

3.3 Características de Uma Série Temporal e Estimadores

Um processo estocástico estacionário como o que origina séries temporais pode ser descrito no domínio do tempo por sua média, variância e função de autocovariância (ou de

autocorrelação). Na prática, não se conhece totalmente o processo estocástico que gerou a série que está sendo observada, e estas quantidades devem ser estimadas a partir da série temporal [4].

4 Geoestatística

A Geoestatística é uma ciência relativamente recente, que vem sendo usada há aproximadamente quarenta anos como uma metodologia mais precisa na estimativa de vários tipos de minas (metais preciosos, minério de ferro, etc.); na indústria do petróleo também tem sido largamente utilizada. Além disso, pode ter sua utilidade estendida para outras áreas, como hidrologia, agricultura, pesca e qualquer outra que tenha a componente de tempo ou a variabilidade espacial como fator importante [5]. Como a demanda por transporte aéreo é uma variável fortemente influenciada pela componente temporal, a Geoestatística se aplica ao seu estudo e esse é o objetivo desse trabalho. Cabe ressaltar que a Geoestatística tem larga aplicação em Sistemas de Informação Geográfica mais robustos, porém é pouco aplicado em situações de observações espaçadas no tempo e não no terreno.

A ferramenta básica da qual a Geoestatística se utiliza é o variograma, que quantifica a correlação espacial entre as observações e permite, entre outras coisas, determinar o tamanho ideal da janela de estimação, estimar valores não amostrados e quantificar incertezas associadas aos valores estimados. Para tanto, é necessário que uma função matemática se ajuste ao variograma experimental [5].

O procedimento para estimativa de parâmetros se chama Krigagem e sua base conceitual está fundamentada na teoria das variáveis regionalizadas, formalizada por Georges Matheron em 1971. O termo Krigagem é derivado do nome de Daniel G. Krige, que foi o pioneiro em introduzir o uso de médias móveis para evitar a superestimação sistemática de reservas em mineração. O que diferencia a Krigagem de outros métodos de interpolação é a estimação de uma matriz de covariância espacial que determina os pesos atribuídos às diferentes amostras, o tratamento da redundância dos dados, a vizinhança a ser considerada no procedimento inferencial e o erro associado ao valor estimado. Além disso, a Krigagem também fornece estimadores exatos com propriedades de não tendenciosidade e eficiência [6].

4.1 Fundamentação Teórica: Variáveis Regionalizadas

A variabilidade espacial de algumas características do solo vem sendo uma das preocupações de pesquisadores praticamente desde o início do século. Smith, em 1910, estudou a disposição de parcelas no campo em experimentos de rendimento de variedades de milho, numa tentativa de eliminar o efeito de variações do solo. Montgomery, em 1913, preocupado com o efeito do nitrogênio no rendimento do trigo, fez um experimento em 224 parcelas, medindo o rendimento de grãos. Vários outros autores, como Waynick e Sharp em 1919, também estudaram variações de nitrogênio e o carbono no solo [6].

Os procedimentos usados na época baseavam-se na estatística clássica e utilizavam grandes quantidades de dados amostrais, visando caracterizar ou descrever a distribuição espacial da característica em estudo. Por estatística clássica entende-se aquela que se utiliza de parâmetros como média e desvio padrão para representar um fenômeno e se baseia na hipótese principal de que as variações de um local para outro são aleatórias [6].

Krige, em 1951, trabalhando com dados de concentração de ouro, concluiu que somente a informação dada pela variância seria insuficiente para explicar o fenômeno em estudo. Para tal, seria necessário levar em consideração a distância entre as observações. A partir daí surge o conceito da Geoestatística, que leva em consideração a localização geográfica e a dependência espacial [6].

Matheron, em 1963, baseado nas observações de Krige, desenvolveu a teoria das variáveis regionalizadas. Uma variável regionalizada é uma função numérica com distribuição espacial, que varia de um ponto a outro com continuidade aparente, mas cujas variações não podem ser representadas por uma função matemática simples [6].

A teoria das variáveis regionalizadas pressupõe que a variação de uma variável pode ser expressa pela soma de três componentes: uma componente estrutural, associada a um valor médio constante ou a uma tendência constante, uma componente aleatória, espacialmente correlacionada e um ruído aleatório ou erro residual [6].

Se \mathbf{x} representa uma posição em uma, duas ou três dimensões, então o valor da variável Z , em \mathbf{x} , é dada por:

$$Z(\mathbf{x}) = m(\mathbf{x}) + e\phi(\mathbf{x}) + e^2 \quad (4.1)$$

onde:

- $m(\mathbf{x})$ é uma função determinística que descreve a componente estrutural de Z em \mathbf{x} ;
- $e\varphi(\mathbf{x})$ é um termo estocástico, que varia localmente e depende espacialmente de $m(\mathbf{x})$;
- e^2 é um ruído aleatório não correlacionado, com distribuição normal com média zero e variância σ^2 .

4.1.1 Hipóteses Assumidas

A hipótese mais comum, visto que a Krigagem está fundamentada na teoria das variáveis regionalizadas, é a estacionaridade de segunda ordem, que implica em:

- A componente determinística $m(\mathbf{x})$ é constante, não havendo tendências na região, isto é:

$$E(Z(\mathbf{x}))=m(\mathbf{x})=m \quad (4.2)$$

- A função de covariância entre dois pontos \mathbf{x} e $\mathbf{x}+\mathbf{h}$ depende do vetor \mathbf{h} mas não de \mathbf{x} , isto é:

$$E[Z(\mathbf{x})Z(\mathbf{x}+\mathbf{h})]-m^2=C(\mathbf{h}) \quad (4.3)$$

Não há necessidade de fazer suposições sobre a variância, pois ela acaba por ser igual à covariância para $\mathbf{h}=\mathbf{0}$, $C(\mathbf{0})$ [5].

Tanto na teoria como na prática é conveniente enfraquecer essas hipóteses, motivo pelo qual Matheron, em 1963, desenvolveu as hipóteses intrínsecas: elas assumem que os incrementos da função são fracamente estacionários, isto é, a média e a variância do incremento $Z(\mathbf{x}+\mathbf{h})-Z(\mathbf{x})$ existem e são independentes do ponto \mathbf{x} [5]:

$$E[Z(\mathbf{x}+\mathbf{h})-Z(\mathbf{x})]=0 \quad (4.4)$$

$$\text{Var}[Z(\mathbf{x}+\mathbf{h})-Z(\mathbf{x})]=2\gamma(\mathbf{h}) \quad (4.5)$$

A função $\gamma(\mathbf{h})$ é chamada semi-variograma e consiste na ferramenta básica para a interpretação estrutural da estimativa.

4.1.2 Função de Covariância Espacial

Aqui serão apresentadas propriedades básicas da covariância espacial e as relações entre ela e o variograma de funções aleatórias estacionárias (não existe covariância para uma função aleatória que é intrínseca mas não estacionária) [5]. Tratão-se de três propriedades e uma relação:

$$C(\mathbf{0})=\sigma^2 \quad (4.6)$$

$$C(\mathbf{h})=C(-\mathbf{h}) \quad (4.7)$$

$$|C(\mathbf{h})|\leq C(\mathbf{0}) \quad (4.8)$$

$$\gamma(\mathbf{h})=C(\mathbf{0})-C(\mathbf{h}) \quad (4.9)$$

$C(\mathbf{h})$ representa o valor da função de covariância entre pontos separados pelo vetor \mathbf{h} .

4.2 O Variograma

O variograma é uma ferramenta básica de suporte às técnicas de Krigagem, que permite representar quantitativamente a variação de um fenômeno regionalizado no espaço. Considere duas variáveis regionalizadas, X e Y, onde $X = Z(\mathbf{x})$ e $Y = Z(\mathbf{x}+\mathbf{h})$. Neste caso, referem-se ao mesmo atributo medido em duas posições diferentes, conforme ilustra a Figura 4.1, onde \mathbf{x} denota uma posição em duas dimensões, com componentes (x_i, y_i) , e \mathbf{h} um vetor distância (módulo e direção) que separa os pontos [6].

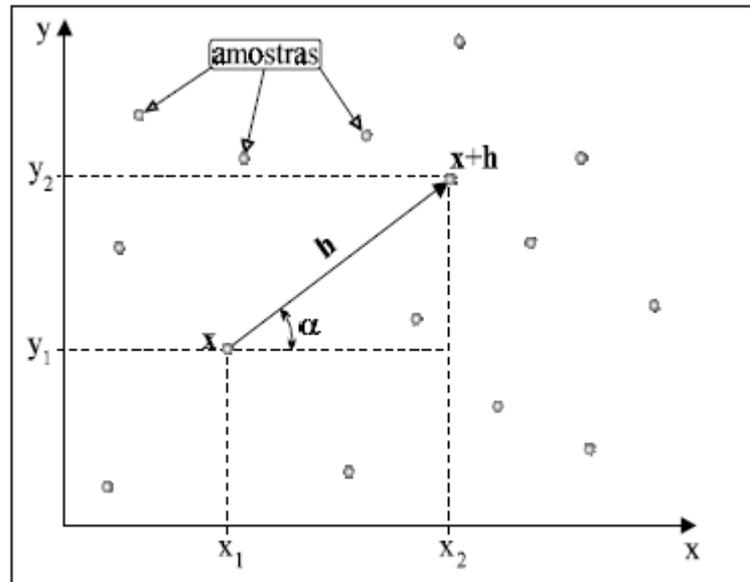


Figura 4.1 - Amostragem em duas dimensões

O nível de dependência entre essas duas variáveis regionalizadas, X e Y , é representado pelo semi-variograma, $\gamma(\mathbf{h})$, o qual é definido pela fórmula 4.5. Além disso, aplicando 4.4 a 4.5 chega-se a:

$$2\gamma(\mathbf{h}) = E[Z(\mathbf{x}+\mathbf{h}) - Z(\mathbf{x})]^2 \quad (4.10)$$

O variograma teórico apresenta as seguintes características:

- Sempre se inicia em 0 (para $\mathbf{h}=\mathbf{0}$, $Z(\mathbf{x}+\mathbf{h})=Z(\mathbf{x})$). Ele pode ser descontínuo na origem;
- em geral, é função crescente em h ;
- cresce até um valor chamado patamar, permanecendo constante após atingir esse patamar.

4.2.1 Alcance e Janela de Influência

A taxa de crescimento do variograma com a distância indica o quão rapidamente a influência de uma amostra cai com a distância. Após o variograma atingir seu valor limite, o patamar, não há mais correlação espacial entre as amostras. Essa distância crítica, chamada

alcance, dá uma definição precisa da noção de janela de influência [5]. Para variáveis estacionárias, $\gamma(\mathbf{h})$ é igual à variância para distâncias maiores que o alcance, isto é:

$$\gamma(\mathbf{h})=0.5\text{Var}[Z(\mathbf{x}+\mathbf{h})-Z(\mathbf{x})]=0.5[\text{Var}(Z(\mathbf{x}+\mathbf{h}))+\text{Var}(Z(\mathbf{x}))]=\sigma^2 \quad (4.11)$$

4.2.2 Comportamento Próximo à Origem

Até aqui, foi examinado o comportamento do variograma para longas distâncias. Porém, é extremamente importante o estudo do comportamento dele para valores pequenos de h , pois possibilita obter informações sobre a continuidade e a regularidade espacial da variável [5]. Podem-se citar quatro comportamentos:

- Quadrático: indica que a variável regionalizada é contínua e diferenciável;
- Linear: a variável regionalizada é contínua, mas não diferenciável; apresenta comportamento menos regular que a anterior;
- Descontínuo na origem: isto é, $\gamma(\mathbf{h})$ não tende a zero quando h tende a 0. Isso indica uma variável com fortes irregularidades a pequenas distâncias;
- Plano: ruído branco; as variáveis regionalizadas $Z(\mathbf{x}+\mathbf{h})$ e $Z(\mathbf{x})$ não estão correlacionadas para qualquer valor de h , não importando a proximidade delas. Indica total falta de estrutura.

O variograma da maioria das funções geográficas é descontínua na origem. Isso é chamado efeito pepita pois foi verificado pela primeira vez em depósitos de ouro na África do Sul associados com a presença de pepitas de ouro [5].

4.2.3 Modelos Comuns de Variograma

Como o variograma deve obedecer a condições restritas, torna-se mais fácil determinar parâmetros de modelos já estabelecidos do que propor um modelo ainda não estudado. Serão apresentados aqui três modelos, que servem para ajustar a maioria dos variogramas obtidos:

- Efeito Pepita: corresponde ao ruído branco, em que não há correlação entre as observações, independente da distância [5].

$$\gamma(h) = \begin{cases} 0, h = 0 \\ C, |h| \geq 0 \end{cases} \quad (4.12)$$

- Modelo Esférico: é provavelmente o modelo mais usado; trata-se de uma expressão polinomial simples que se ajusta bem ao que mais se observa: um crescimento quase linear até uma certa distância, em que ocorre a estabilização.

$$\gamma(h) = \begin{cases} C\left(\frac{3|h|}{2a} - \frac{1}{2}\left(\frac{|h|}{a}\right)^3\right), |h| < a \\ C, |h| \geq a \end{cases} \quad (4.13)$$

A tangente à origem intercepta o patamar no ponto de abscissa $2a\sqrt{3}$, o que pode ser usado para ajustar parâmetros do modelo [5].

- Modelo Exponencial:

$$\gamma(h) = C\left(1 - \exp\left(-\frac{|h|}{a}\right)\right) \quad (4.14)$$

O alcance prático desse modelo é $3a$, pois é a distância em que se atinge 95% do valor do patamar. A tangente na origem intercepta o patamar no ponto de abscissa a . Como o variograma exponencial é praticamente linear para pequenas distâncias, convém compará-lo com o esférico [5].

4.3 Variogramas Experimentais

O variograma experimental pode ser calculado usando a seguinte fórmula:

$$\gamma^*(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(x_i + h) - Z(x_i)]^2 \quad (4.15)$$

Nesse caso, x_i são os locais de amostra, $Z(x_i)$ seus valores e $N(h)$ o número de pares (x_i, x_i+h) separados pela distância h . Essa fórmula pode ser aplicada sem problemas para amostras regularmente espaçadas [5].

4.4 Teoria da Krigagem

A Krigagem é um método de estimação que oferece os melhores estimadores lineares não viesados para valores dos pontos e médias dos blocos (por melhores entende-se os de menor variância). Serão apresentados dois tipos de Krigagem: Krigagem Ordinária (KO), usada quando a média é desconhecida e Krigagem Simples (KS), usada quando a média é conhecida.

4.4.1 A Proposta da Krigagem

As amostras fornecem informações precisas dos pontos amostrados, entretanto não fornecem respostas sobre o que acontece entre elas. Precisa-se de um método com acurácia para determinar os valores intermediários ou as médias dos blocos. Essa acurácia depende de vários fatores:

- o número de amostras e a qualidade dos dados em cada ponto;
- a posição dos pontos amostrados;
- a distância entre os pontos amostrados;
- a continuidade espacial da variável em questão.

4.4.2 Krigagem Ordinária

Considere uma superfície sobre a qual se observe alguma propriedade do solo, Z , em n pontos distintos, com coordenadas representadas pelo vetor \mathbf{x} . Assim, tem-se um conjunto de valores $\{Z(\mathbf{x}_i), i=1, \dots, n\}$, onde \mathbf{x}_i , identifica uma posição em duas dimensões representada pelos pares de coordenadas (x_i, y_i) . Suponha que se objetive estimar o valor de Z no ponto \mathbf{x}_0 . O valor desconhecido de $Z_{\mathbf{v}}^*$ pode ser estimado a partir de uma combinação linear dos n valores observados, adicionado a um parâmetro, λ_0 [6]:

$$Z_{\mathbf{v}}^* = \lambda_0 + \sum \lambda_i Z(\mathbf{x}_i) \quad (4.16)$$

Como se deseja um estimador não tendencioso:

$$E[Z(\mathbf{x})] = m = E[Z_{\mathbf{v}}] \quad (4.17)$$

Dessa forma, pode-se escrever:

$$E[Z_{\mathbf{v}}^*] = E[\lambda_0 + \sum \lambda_i Z(\mathbf{x}_i)] \Leftrightarrow m = \lambda_0 + \sum \lambda_i m \quad (4.18)$$

Como essa Krigagem não requer o prévio conhecimento da média m , para que a igualdade acima seja satisfeita, é necessário que $\lambda_0 = 0$ e $\sum_i^N \lambda_i = 1$.

O estimador da KO é, portanto:

$$Z_{\mathbf{v}}^* = \sum \lambda_i Z(\mathbf{x}_i), \text{ com } \sum_i^N \lambda_i = 1 \quad (4.19)$$

O fato de o estimador ser não enviesado permite que se avalie sua qualidade pela mínima variância. Em termos do variograma, consegue-se isso resolvendo o seguinte sistema:

$$\begin{cases} \sum_{j=1}^N \lambda_j \gamma(x_i, x_j) + \mu = \bar{\gamma}(x_i, V), i = 1, 2, \dots, N \\ \sum_i \lambda_i = 1 \end{cases} \quad (4.20)$$

A variância mínima é dada por:

$$\sigma_K^2 = \sum \lambda_i \bar{\gamma}(x_i, V) - \bar{\gamma}(V, V) + \mu \quad (4.21)$$

- μ é o multiplicador de Lagrange associado à minimização da variância.

Obviamente, esse sistema pode ser escrito em termos da covariância, chegando-se a:

$$\begin{cases} \sum_{j=1}^N \lambda_j C(x_i, x_j) + \mu' = \bar{C}(x_i, V), i = 1, 2, \dots, N \\ \sum_i \lambda_i = 1 \end{cases} \quad (4.22)$$

Nesses termos, a variância mínima é dada por:

$$\sigma_K^2 = \bar{C}(V, V) - \mu' - \sum \lambda_i \bar{C}(x_i, V) \quad (4.23)$$

4.4.3 Krigagem Simples

Este tipo de Krigagem é usado quando a média m da variável regionalizada é conhecida. Inicialmente, deve-se considerar uma variável regionalizada $Y(\mathbf{x})$ de média nula. A variável regionalizada inicial pode ser dada por $Z(\mathbf{x})=Y(\mathbf{x})+m$. O estimador de Y pode ser dado por:

$$Y_V^* = \sum \lambda_i Y(x_i) \quad (4.24)$$

Deve-se ter um estimador não enviesado e de mínima variância. Por ser não enviesado, o erro estimado deve ter valor esperado nulo, isto é:

$$E[Y_V^* - Y_V] = E[\sum \lambda_i' Y(x_i) - Y_V] = 0 \quad (4.25)$$

Como a média de $Y(\mathbf{x})$ é nula, o estimador é automaticamente não enviesado. Portanto, não há condições para a soma dos pesos e a variância do erro da estimativa pode ser dado por:

$$\begin{aligned} \text{Var}[Y_V^* - Y_V] &= E[\sum \lambda_i' Y(x_i) - Y_V]^2 \\ &= \sum_j \sum_i \lambda_i' \lambda_j' C(x_i, x_j) + \bar{C}(V, V) - 2 \sum_i \lambda_i' \bar{C}(x_i, V) \end{aligned} \quad (4.26)$$

Como não há condição para a soma dos pesos, não há necessidade do multiplicador de Lagrange. Portanto, o sistema de Krigagem pode ser escrito como:

$$\sum_{j=1}^N \lambda_j' C(x_i, x_j) = \bar{C}(x_i, V), i = 1, 2, \dots, N \quad (4.27)$$

A variância correspondente à resolução do sistema acima é dada por:

$$\sigma_{KS}^2 = \bar{C}(V, V) - \sum \lambda_i' \bar{C}(x_i, V) \quad (4.28)$$

A resolução do sistema acima dá os pesos de Krigagem e, portanto, o estimador de Y_V . O estimador de Z_V pode ser deduzido substituindo $Y(\mathbf{x})$ por $Z(\mathbf{x}) - m$, o que dá:

$$\begin{aligned} Z_V^* &= Y_V^* + m = \sum \lambda_i' [Z(x_i) - m] + m \\ &= \sum \lambda_i' Z(x_i) + m[1 - \sum \lambda_i'] = \sum \lambda_i' Z(x_i) + m\lambda_m \end{aligned} \quad (4.29)$$

O termo λ_m é chamado de peso da média na KS.

4.5 Efeito Tela

Trata-se do efeito que ocorre em variáveis que possuem variograma bem estruturado, isto é, com pequeno efeito pepita: as amostras mais próximas do ponto a ser estimado criam uma “tela” nas amostras que são mais distantes e estão na mesma direção, tornando os pesos de Krigagem relativos a essas últimas desprezíveis. Isso ocorre pelo bom comportamento da variável, que indica que a variância aumenta com a distância; como se busca minimizar a variância, as amostras próximas tendem a ter maior peso.

O estudo do comportamento da variável antes de se tomar amostras à exaustão é importante e pode levar a uma economia significativa em sondagens e demais formas de obter amostras [5].

5 Resultados e Análise

Serão apresentados aqui os resultados do tratamento dos dados de uma base de movimento de passageiros no Aeroporto Internacional do Rio de Janeiro fornecida pela INFRAERO, bem como as previsões de movimento de passageiros para os seis meses futuros usando os conceitos da Geoestatística e das Séries Temporais. A comparação dos resultados obtidos pelos dois métodos permite escolher o melhor modelo.

5.1 Base de Dados

A base de dados utilizada foi fornecida, através de solicitação, pela INFRAERO. Trata-se de uma base desagregada, com o movimento mensal de passageiros em todos aeroportos da rede INFRAERO, entre janeiro de 1990 e julho de 2008. A base considera passageiros domésticos de transporte regular regional e nacional, de voos charter fretados (nacionais e internacionais), de táxi aéreo (nacional e internacional), de voos militares (nacional e internacional), de transporte regular internacional, de helicópteros (nacional e internacional) e de voos de cabotagem, regulares ou não. Além disso, os passageiros estão separados por: origem, destino, conexão de origem, conexão de destino e em bordo.

5.2 Tratamento e Análise dos Dados

Inicialmente, tomaram-se apenas os dados relativos ao Aeroporto Internacional do Rio de Janeiro (SBGL). Optou-se por trabalhar apenas com o movimento de passageiros de transporte regular nacional doméstico, visto que se trata de um movimento com maior padrão observável, possibilitando evidenciar tendências e sazonalidades.

Considerou-se que o movimento total de passageiros é dado pela soma dos passageiros de origem e destino, subtraindo-se a parcela dos passageiros em conexão de origem (ou destino, visto que as duas são iguais), pois esses são considerados tanto na parcela de origem

como na de destino. Os passageiros em bordo não causam incremento no movimento de passageiros do aeroporto.

Para melhor análise dos dados, o movimento total obtido foi plotado, ano a ano. A Figura 5.1 apresenta o resultado. Cabe ressaltar duas observações:

- ocorre um viés nos dados até julho de 1990, pois foi verificado o mesmo movimento em todos os meses;
- o movimento tem um padrão bem definido até 2004, quando se altera de forma considerável, provavelmente devido ao fechamento do Aeroporto Santos Dumont em 2003.

Dessa forma, optou-se por trabalhar com o horizonte compreendido entre agosto de 1990 e julho de 2003, sendo que os dados de datas posteriores a julho de 2001 não serão usados para fazer previsões, mas para testes. A Tabela 5.1 apresenta a base de dados utilizada para fazer previsões e testes.

Esses dados foram usados para a verificação da estacionariedade da variável, para o levantamento do variograma experimental e para as previsões utilizando os pesos de Krigagem e utilizando uma modelagem de séries temporais. Também, utilizaram-se os dados para comparar as previsões com o movimento observado, afim de comparar os modelos.

5.3 Verificação de Estacionariedade

Como se deseja fazer previsões de movimento com o auxílio da Geoestatística, é necessário avaliar o comportamento da variável estudada, de forma a verificar sua estacionariedade. O item 4.1.1. evidencia a estacionariedade como hipótese para que seja feito o processo de Krigagem, visto que esse processo se baseia na teoria da variáveis regionalizadas. Sabe-se que o movimento de passageiros não é uma variável estacionária devido a tendências e ruídos brancos. Observando a Figura 5.1 para o período em estudo, nota-se que os ruídos têm maior efeito que a tendência. Entendeu-se que a subtração da média do mês a que o dado se refere é uma boa alternativa para eliminar o ruído branco.

Para a avaliação de estacionariedade, adotou-se o seguinte procedimento:

- determinaram-se as médias de movimento de cada mês;
- subtraiu-se, de cada dado, a média do mês a que ele se refere;
- com a média já subtraída dos dados, extraiu-se, para cada ano, a média dos movimentos mensais, plotando-se esse resultado;

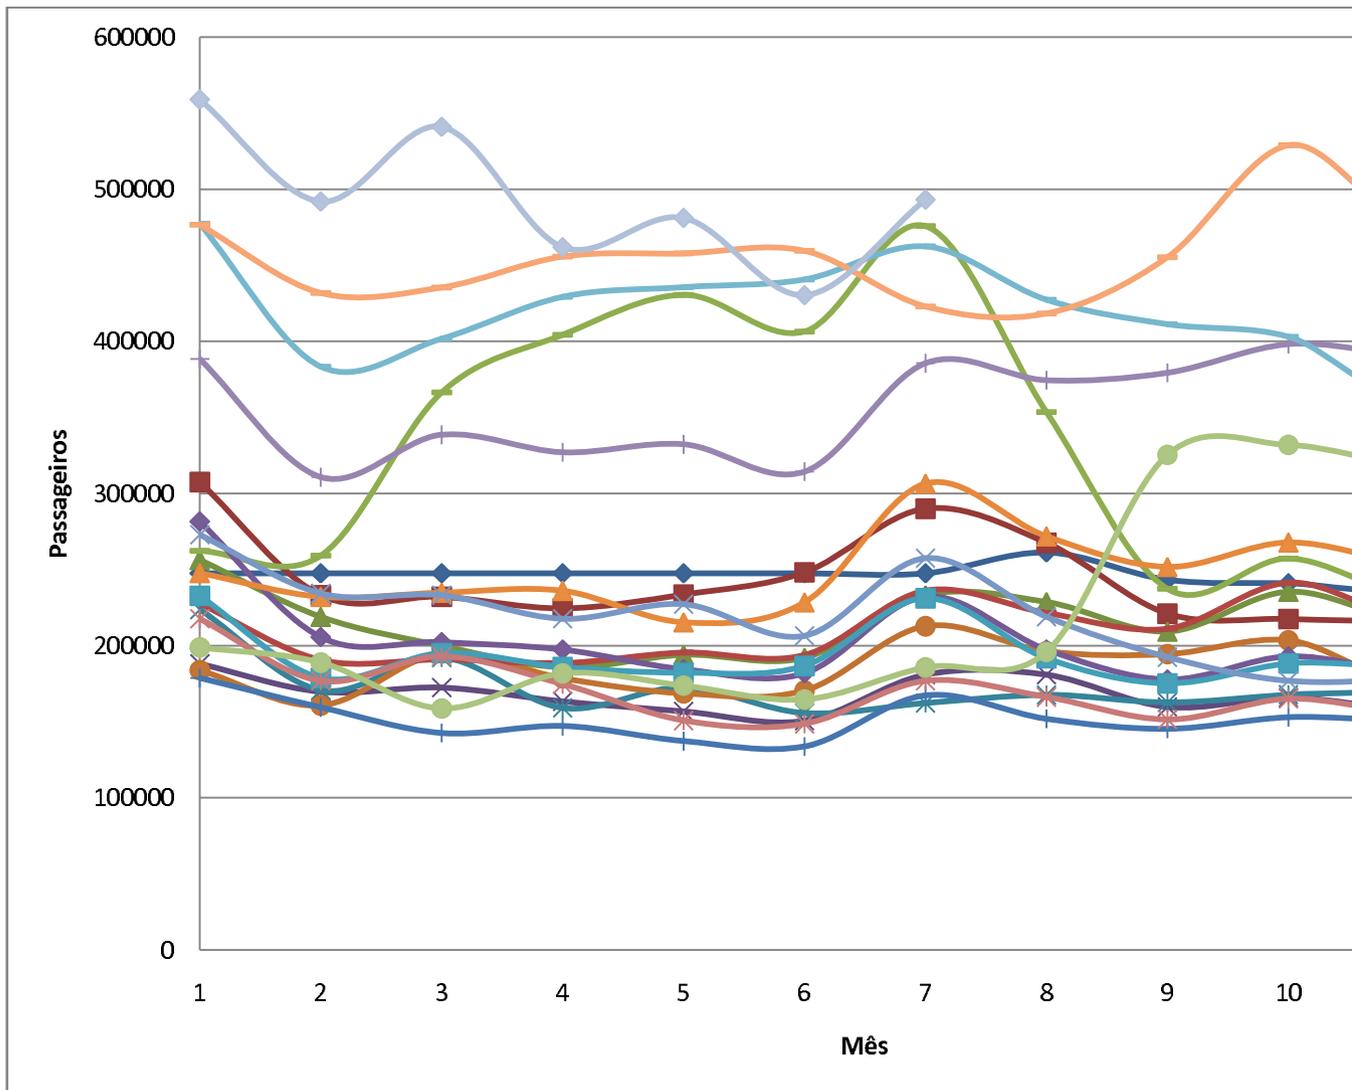


Figura 5.1 - Movimento Mensal de Passageiros em SBGL entre janeiro de 1990 e julho

Tabela 5.1 - Dados de Movimento Total de Passageiros de Transporte Regular Doméstico N

	1990	1991	1992	1993	1994	1995	1996	1997	1998	1999	2000
1	-	307.521	256.314	188.088	223.758	183.951	178.900	227.655	262.437	281.626	232.77
2	-	233.099	219.055	169.787	170.782	160.733	159.510	190.599	259.124	205.646	178.88
3	-	232.100	200.015	172.442	192.284	195.055	142.607	190.976	366.433	202.344	195.1
4	-	224.554	185.676	163.445	159.093	178.656	147.180	188.529	404.352	197.501	186.00
5	-	233.595	194.023	156.876	172.501	168.640	137.301	195.408	430.583	184.597	182.22
6	-	248.161	192.097	150.651	155.810	170.448	133.847	193.808	406.400	181.895	186.77
7	-	289.943	233.176	180.967	162.281	212.799	167.413	236.075	475.643	232.359	231.1
8	261.268	267.563	228.693	180.889	167.638	196.307	152.003	221.453	353.548	197.402	191.77
9	243.237	221.014	209.343	159.741	162.735	194.441	145.413	211.176	237.335	177.752	175.22
10	240.986	217.535	235.492	165.934	167.774	203.505	152.986	241.318	257.344	192.987	188.4
11	240.278	215.931	217.400	158.594	172.124	177.902	151.608	221.289	235.287	184.144	189.1
12	291.193	216.652	229.748	162.855	193.246	211.974	160.239	252.486	256.383	197.194	215.22

- adicionou-se, no gráfico com os dados anuais, uma linha de tendência. O resultado é apresentado na Figura 5.2.

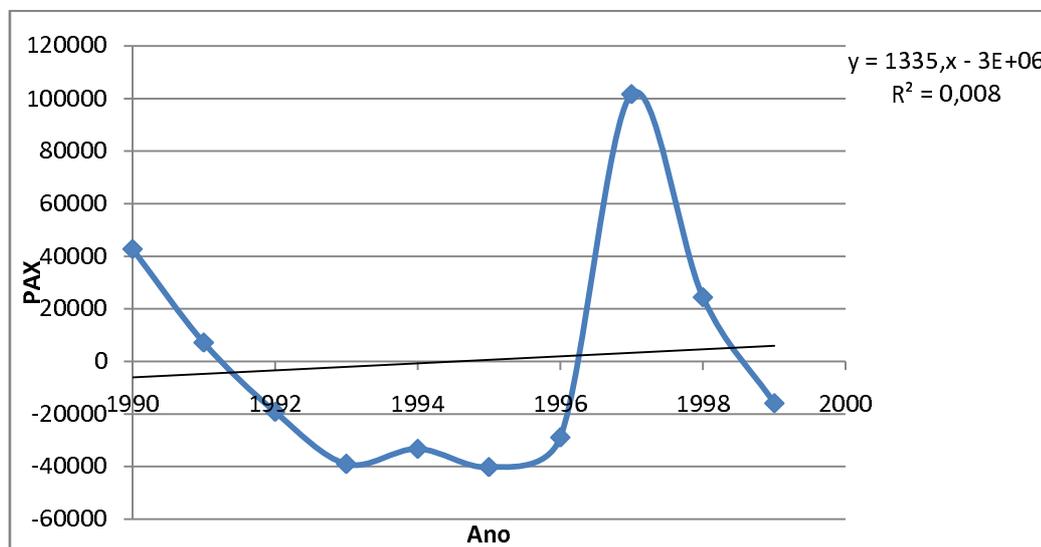


Figura 5.2 - Comportamento da Variável

A Figura 5.2 mostra uma linha de tendência praticamente horizontal, o que é evidenciado pelo baixo valor de R-quadrado. Dessa forma, é possível concluir que a variável em questão (movimento de passageiros subtraído da média mensal) pode ser considerada estacionária.

Cabe ressaltar que o uso de médias mensais, e não de uma única média total, constitui uma aproximação, visto que o procedimento geoestatístico usado prevê o uso de apenas uma média, de acordo com o item 4.1.1. Considerou-se, no entanto, que o uso dessas médias em separado é capaz de captar melhor fenômenos inerentes ao movimento de passageiros, como, por exemplo, a sazonalidade.

5.4 Levantamento e Ajuste do Variograma Experimental

Afim de verificar a correlação das observações no tempo, foi levantado o variograma experimental, de acordo com a fórmula 4.15, com x representando um determinado instante e h a separação temporal. O resultado é apresentado na Figura 5.3 e permite determinar o patamar teórico, também apresentado na mesma figura.

A partir do variograma experimental, buscou-se ajustar um modelo já conhecido de variograma teórico, ferramenta indispensável à Krigagem. Inicialmente e por tentativa e erro, buscou-se ajustar a derivada na origem com um polinômio de terceiro grau. Após isso, procurou-se ajustar um variograma esférico ao experimental, de acordo com a fórmula 4.13. Também foi feito um ajuste de modelo exponencial, conforme a fórmula 4.14 e um modelo mais simplificado, bi-linear, que consiste de uma reta até se atingir o patamar. O patamar dos ajustes foi determinado pela região em que o variograma experimental passa a oscilar em torno de um valor e o alcance como o número de meses necessários para cada ajuste atingir esse patamar. Todos os resultados são apresentados na Figura 5.3.

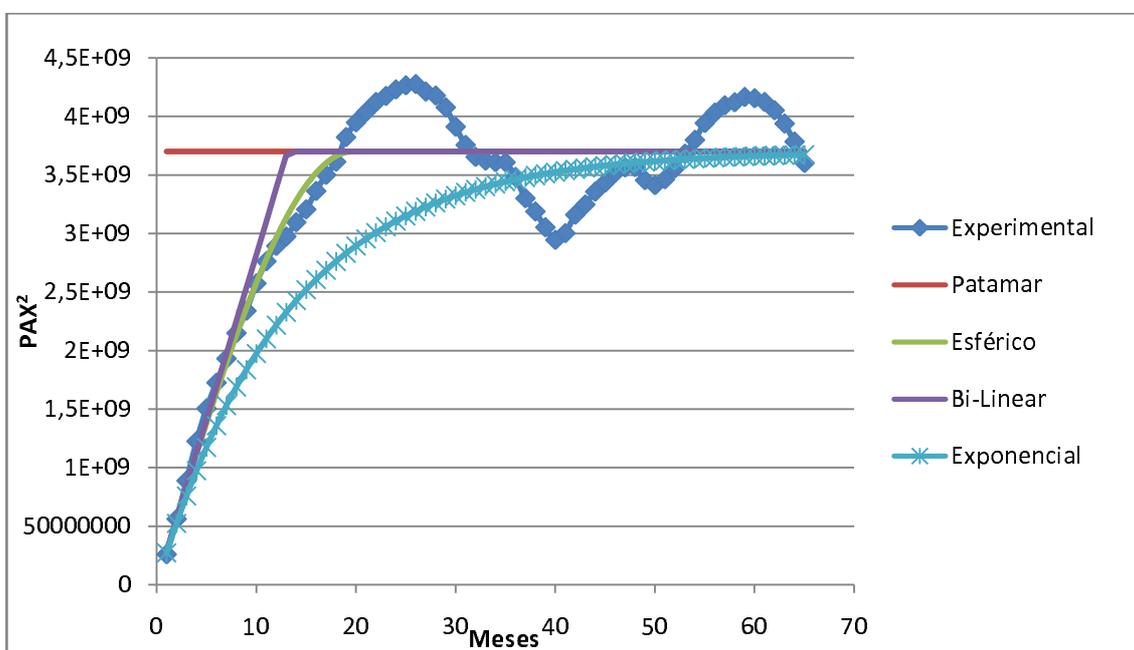


Figura 5.3 - Variogramas Experimental e Teóricos Ajustados

A análise qualitativa dos ajustes teóricos mostra que o variograma esférico é o que melhor se ajusta ao experimental. Esse variograma tem as seguintes características:

- alcance de 19 meses, isto é, após esse alcance não há mais correlação temporal entre as observações;

- patamar de $3,7 \cdot 10^9$ PAX², que indica a variância do processo quando as observações não se correlacionam no tempo.

5.5 Determinação dos Pesos de Krigagem e da Variância do Processo

Como se conhece a média, optou-se por fazer a Krigagem Simples, apresentada no item 4.4.3. Os pesos das observações foram determinados trabalhando-se matricialmente com o sistema apresentado na fórmula 4.27, e o peso da média da KS de acordo com a fórmula 4.29. A variância do processo de KS foi obtido conforme prevê a fórmula 4.28.

Foram determinados pesos da KS para horizontes de um a seis meses, o que possibilita que sejam feitas previsões de movimento para esses horizontes. Os pesos das observações, da média e a variância são apresentados na Tabela 5.2.

A Figura 5.4 apresenta o comportamento da variância com o aumento do horizonte de previsão.

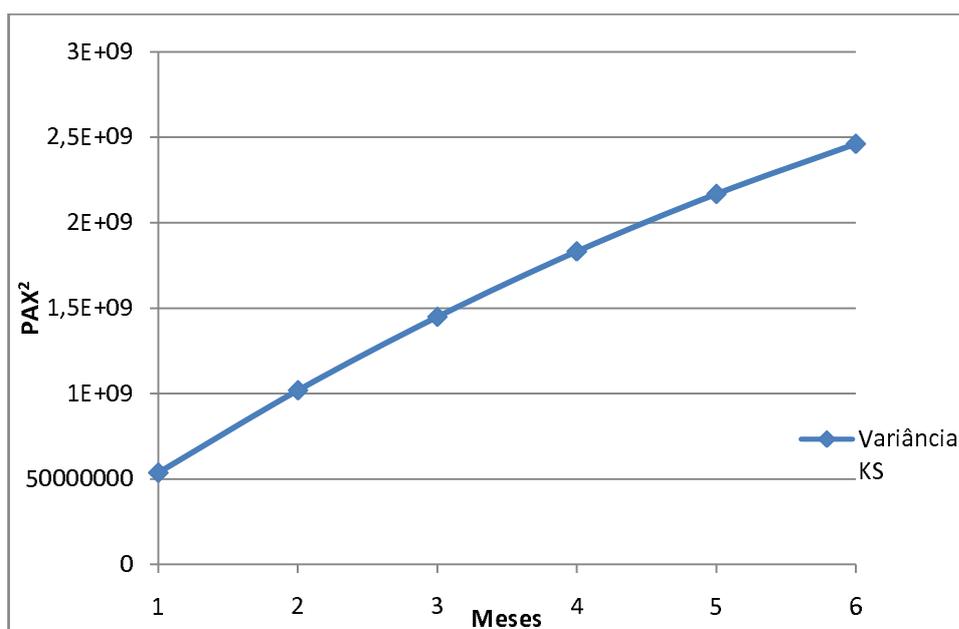


Figura 5.4 - Comportamento da Variância da KS com o Horizonte de Previsão

Tabela 5.2 - Pesos e Variância da KS

Pesos KS	Horizonte de Previsão (meses)					
	1	2	3	4	5	6
λ_1	0,949	0,897	0,844	0,792	0,739	0,687
λ_2	-0,003	-0,006	-0,009	-0,012	-0,015	-0,017
λ_3	-0,003	-0,006	-0,009	-0,012	-0,015	-0,018
λ_4	-0,003	-0,006	-0,009	-0,012	-0,015	-0,018
λ_5	-0,003	-0,007	-0,010	-0,013	-0,016	-0,019
λ_6	-0,003	-0,007	-0,010	-0,013	-0,016	-0,020
λ_7	-0,004	-0,007	-0,010	-0,014	-0,017	-0,020
λ_8	-0,004	-0,007	-0,011	-0,014	-0,018	-0,021
λ_9	-0,004	-0,008	-0,011	-0,015	-0,019	-0,022
λ_{10}	-0,004	-0,008	-0,012	-0,016	-0,020	-0,023
λ_{11}	-0,004	-0,008	-0,012	-0,016	-0,021	-0,025
λ_{12}	-0,004	-0,009	-0,013	-0,017	-0,022	-0,026
λ_{13}	-0,005	-0,009	-0,014	-0,018	-0,023	-0,028
λ_{14}	-0,005	-0,010	-0,014	-0,019	-0,024	-0,027
λ_{15}	-0,005	-0,010	-0,015	-0,020	-0,023	0,009
λ_{16}	-0,005	-0,011	-0,016	-0,019	0,013	0,021
λ_{17}	-0,006	-0,011	-0,015	0,017	0,025	0,022
λ_{18}	-0,006	-0,010	0,022	0,030	0,027	0,023
λ_{19}	0,025	0,054	0,051	0,038	0,027	0,017
λ_m	0,098	0,188	0,274	0,355	0,432	0,505
$\sigma^2[\text{KS}] (\text{PAX}^2)$	5,37E+08	1,02E+09	1,45E+09	1,83E+09	2,17E+09	2,46E+09
$\sigma^2[\text{Total}] / \sigma^2[\text{KS}]$	6,90	3,63	2,55	2,02	1,71	1,50

Os maiores pesos atribuídos à observação mais recente evidenciam que ocorre o efeito tela desta em relação às demais, o que indica que observações mais recentes têm capacidade pronunciada, em relação às demais, de diminuir o valor da variância.

Outro resultado, já esperado, é o aumento do peso da média com o horizonte de previsão. Isso é bastante razoável, pois quanto maior o horizonte de previsão, mais se deve confiar na média para fazer previsões e menor a confiança de que as observações podem gerar uma boa previsão.

Por fim, cabe ressaltar que a variância da KS, mesmo para um horizonte de seis meses, é menor que a variância total, evidenciando a superioridade da KS em relação a métodos estatísticos tradicionais caracterizados por média e desvio padrão.

5.6 Previsões Através de Krigagem Simples

Conhecidos os pesos da KS, a fórmula 4.29 permitiu efetuar as previsões. O mês de julho de 2001 foi fixado como primeiro mês para todos os horizontes de previsão. Dessa forma, foram feitas previsões para o período compreendido entre agosto de 2001 e janeiro de 2002. O valor usado como média, na fórmula 4.29, foi a média de movimento no respectivo mês, ao longo dos anos considerados. A Tabela 5.3 apresenta as previsões feitas, bem como os desvios padrão.

Tabela 5.3 - Previsões por KS

Mês	Previsão (PAX)	Desvio Padrão (PAX)
ago/01	303.893	23.166
set/01	296.072	31.917
out/01	292.161	38.067
nov/01	282.450	42.791
dez/01	283.946	46.554
jan/02	286.784	49.605

5.7 Previsões por Séries Temporais

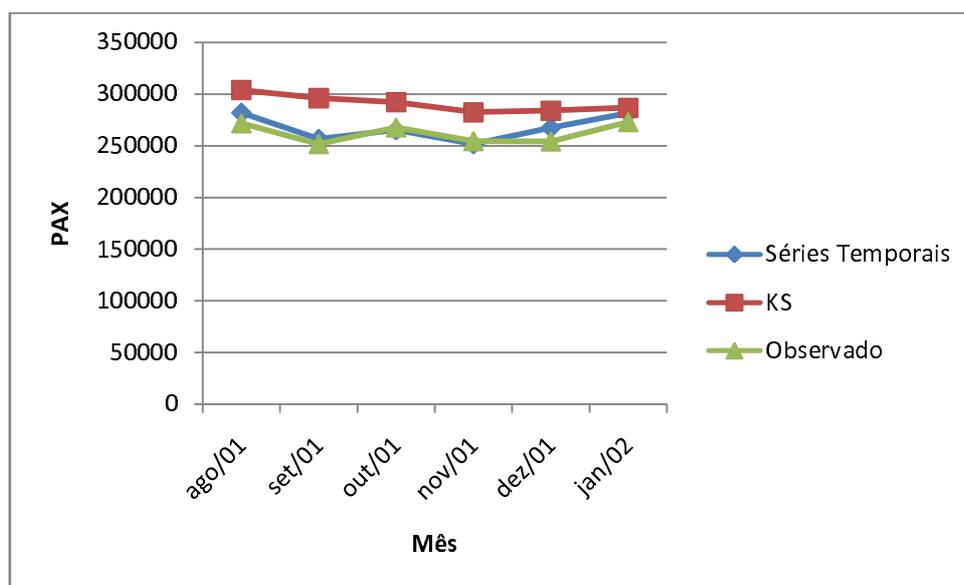
A modelagem por séries temporais foi feita com o uso do software OxMetrics[®], utilizando o Modelo Estrutural Básico com inferência de parâmetros por Filtro de Kalman proposto por FRANCO & SANTOS [7]. Não faz parte do escopo desse trabalho a teoria envolvida por trás dessa modelagem, interessando apenas os resultados gerados. A modelagem utilizada gera estimadores não tendenciosos. A Tabela 5.4 apresenta os resultados.

Tabela 5.4 - Previsões Geradas por Séries Temporais

Mês	Previsão (PAX)	Desvio Padrão (PAX)
ago/01	281.980	24.395
set/01	256.660	35.488
out/01	265.086	44.437
nov/01	251.567	51.363
dez/01	267.326	56.668
jan/02	281.622	60.753

5.8 Comparação dos Modelos

A Figura 5.5 apresenta as previsões por KS e por séries temporais, bem como os valores observados.

**Figura 5.5 - Previsões por KS e Séries Temporais e Valores Observados**

As Tabelas 5.5 e 5.6 apresentam dados que possibilitam uma comparação quantitativa dos modelos. Na coluna “Teste” considerou-se “ok” quando a observação estava entre os limites superior e inferior de um desvio padrão e “não ok” em caso contrário.

Além dos resultados presentes nas tabelas, calculou-se o erro quadrático médio relativo a cada modelo. Seguem os resultados:

$$E_{ST}^2 = 64.564.838$$

$$E_{KS}^2 = 904.929.474$$

É possível notar que, para todos horizontes, as previsões por séries temporais apresentam menor erro e, conseqüentemente, menor erro quadrático médio. Isso indica que as previsões feitas utilizando essa modelagem são significativamente melhores.

A análise da Figura 5.5 permite verificar que o modelo de KS não capta as variações da série, o que é feito de forma excelente pelo modelo de séries temporais. Dessa forma, o modelo de KS ficou vulnerável a variações sazonais, como ocorre, em geral, no mês de julho: foi a observação que recebeu o maior peso na previsão, o que contribuiu para elevar seu valor, pois a modelagem é incapaz de considerar picos de movimento. Além disso, a análise dos valores de erro para as previsões por KS mostra uma redução considerável no erro da previsão para janeiro de 2002, que é quando ocorre um novo pico, o que diminui o erro de se colocar um peso alto no mês de julho de 2001.

Em todos os casos, o modelo de KS apresenta menor variância que o modelo de séries temporais: como este último se mostrou melhor para fazer previsões, conclui-se que a menor variância não é um bom parâmetro para escolha de modelo. Considerando que o modelo de séries temporais é não enviesado, a conclusão que se chega é que a modelagem por KS feita é tendenciosa. Os conceitos apresentados no Capítulo 4 geram estimadores não enviesados, o que indica que a tendência foi gerada na consideração de médias mensais e não de uma única média global. Outra hipótese para o fato de a previsão por séries temporais ser melhor e apresentar maior variância é que a aplicação do filtro de Kalman pode reduzir a variância e tal fenômeno não ser captado no cálculo da mesma neste modelo.

Por fim, o modelo de KS apresentou coerência estatística por possuir 66 % das observações no intervalo de um desvio padrão da previsão. Na modelagem por séries temporais, todas as observações se inseriram no intervalo de um desvio padrão, o que pode indicar, novamente, que a aplicação do filtro de Kalman reduz a variância do processo e tal redução não é considerada no modelo.

Tabela 5.5 - Resultados das Previsões por KS

Mês	Previsão (PAX)	Variância (PAX ²)	Lim. Inf. (PAX)	Lim. Sup. (PAX)	Observado (PAX)	T
ago/01	303.893	536.672.830	280.726	327.059	271.865	não o
set/01	296.072	1.018.704.566	264.155	327.989	251.766	não o
out/01	292.161	1.449.132.942	254.093	330.228	267.820	ok
nov/01	282.450	1.831.085.883	239.659	325.241	254.560	ok
dez/01	283.946	2.167.313.425	237.391	330.500	254.271	ok
jan/02	286.784	2.460.632.240	237.180	336.389	273.005	ok

Tabela 5.6 - Resultados das Previsões por Séries Temporais

Mês	Previsão (PAX)	Variância (PAX ²)	Lim. Inf. (PAX)	Lim. Sup. (PAX)	Observado (PAX)	T
ago/01	281.980	595.110.170	257.585	306.375	271.865	ok
set/01	256.660	1.259.399.564	221.172	292.148	251.766	ok
out/01	265.086	1.974.673.631	220.649	309.524	267.820	ok
nov/01	251.567	2.638.130.033	200.204	302.929	254.560	ok
dez/01	267.326	3.211.287.158	210.658	323.994	254.271	ok
jan/02	281.622	3.690.985.332	220.869	342.376	273.005	ok

6 Conclusão

O trabalho realizado gerou resultados capazes de cumprir o objetivo proposto: avaliar a Geoestatística como modelo de previsão de demanda no transporte aéreo. Embora pareça extremamente coerente substituir a variável espacial pela temporal nesse tipo de modelagem, os resultados obtidos mostram que ela não se adequa à previsão de movimento de passageiros.

Os resultados apresentados no Capítulo 5 permitiram verificar que a demanda por transporte aéreo no Aeroporto Internacional do Rio de Janeiro, no período de agosto de 1990 a julho de 2001, pode ser considerada uma variável estacionária, desde que sejam subtraídas as médias mensais. O variograma experimental levantado apresentou excelente ajuste com o modelo esférico de variograma teórico, o que gerou expectativas de bons resultados de previsão.

O processo de Krigagem Simples foi escolhido para se fazerem as previsões de movimento de passageiros, visto que a média era conhecida. No entanto, os pesos obtidos evidenciaram o efeito tela relativo à observação mais recente, o que foi tido como um mau indício, visto que a última observação teria dominância em relação às demais, independente do mês a que ela se refere. Isso impediu o modelo de captar variações sazonais, visto que o último mês observado, fosse ele pico de movimento ou não, teria um peso relativamente grande na previsão. Analisando-se a variância do processo de Krigagem Simples, a modelagem usada se mostrou mais confiável que métodos estatísticos convencionais, que utilizam pesos iguais para as observações.

A Krigagem Simples foi realizada utilizando as médias mensais, gerando previsões para o horizonte compreendido entre agosto de 2001 e janeiro de 2002. Além disso, criou-se um modelo estrutural básico de séries temporais para fazer previsões afim de comparar os resultados com os obtidos por meio da Geoestatística.

Ao comparar os resultados dos dois grupos de previsões feitos com o observado na realidade, a modelagem por séries temporais se mostrou extremamente superior à modelagem Geoestatística: os erros de previsão foram menores em todos os meses e as variações da série foram todas captadas; a Krigagem Simples foi incapaz de captar essas variações. Em se tratando de duas modelagens não enviesadas, esperava-se que a de menor variância fosse oferecer melhores resultados. No entanto, o modelo geoestatístico apresentou menor variância que o de séries temporais e as previsões foram piores: isso

permitiu concluir que, considerando o modelo de séries temporais não enviesado, a modelagem geoestatística apresentou uma tendência que certamente foi gerada ao se considerar as médias mensais ao invés de uma média global. Outra hipótese levantada para se explicar a maior variância do modelo de séries temporais é o fato de ele possivelmente não considerar a redução desse parâmetro pela aplicação do filtro de Kalman, que de fato ocorre. Tal hipótese ganha força pelo fato de que todas as observações estão entre os limites de um desvio padrão na modelagem por séries temporais, enquanto estatisticamente se espera que apenas dois terços das observações estejam entre esses limites, fato observado na modelagem por KS.

Dessa forma, foi possível notar que a modelagem geoestatística utilizada não é capaz de substituir as metodologias comumente empregadas na previsão de demanda por transporte aéreo, por apresentar previsões menos precisas.

É interessante que trabalhos futuros avaliem o mesmo método aqui utilizado para outros aeroportos, verificando o comportamento da variável e validando ou não as conclusões aqui obtidas. Sugere-se também estudar a influência da aplicação do filtro de Kalman na variância e a possibilidade de usar esse filtro em uma modelagem geoestatística. Outro ponto interessante a ser discutido é a proposta de um modelo geoestatístico agregado com séries temporais que seja capaz de captar as sazonalidades e oferecer previsões com variância mínima e sem tendências. Por fim, sugere-se o uso de uma modelagem geoestatística mais ampla, robusta e complexa, a Krigagem Universal, nas previsões de movimento de passageiros, para verificar se ela pode vir a substituir os modelos convencionais de previsão, visto que ela é capaz de captar tendências na série.

Referências

- [1] ANDREONI, A.; PASTORINO, M.N. A multivariate ARIMA model to forecast air transport demand. In: EUROPEAN TRANSPORT CONFERENCE, 2006, Strasbourg. **Anais eletrônicos...** Strasbourg: AET, 2006. Disponível em: <<http://www.etcproceedings.org/paper/a-multivariate-arima-model-to-forecast-air-transport-demand>>. Acesso em: 02 nov. 2009.
- [2] CARVALHO, Betânia Gonçalves de. **Uma metodologia para obtenção de um diagnóstico dos principais aeroportos no Brasil através da avaliação da relação demanda e capacidade**. 2006. 161f. Dissertação (Mestrado em Transporte Aéreo e Aeroportos) – Instituto Tecnológico de Aeronáutica, São José dos Campos.
- [3] BRASIL. Empresa Brasileira de Infra-Estrutura Aeroportuária. Acesso à página institucional. Disponível em: <<http://www.infraero.gov.br/>>. Acesso em: 28 out. 2009.
- [4] POLLOCK, D. S. G. **A handbook of time-series analysis, signal processing and dynamics**. London: Academic Press, 1999. 782p.
- [5] ARMSTRONG, M. **Basic linear geostatistics**. Berlin: Springer, 1998. 153p.
- [6] CAMARGO, E. C. G. **Geoestatística: fundamentos e aplicações**. São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 2001. Disponível em: <http://www.dpi.inpe.br/gilberto/tutoriais/gis_ambiente/5geoest.pdf>. Acesso em: 23 out. 2009.
- [7] FRANCO, G. C.; SANTOS, T. R. Inferência sobre os hiperparâmetros em modelos estruturais sob as perspectivas clássica e bayesiana. In: REUNIÃO ANUAL DA REGIÃO BRASILEIRA DA SOCIEDADE INTERNACIONAL DE BIOMETRIA, 53., 2008, Lavras. **Anais eletrônicos...** Lavras: UFLA, 2008. Disponível em: <<http://www.dex.ufla.br/53rbras/trabalhos/67.doc>>. Acesso em: 05 nov. 2009.

FOLHA DE REGISTRO DO DOCUMENTO

1. CLASSIFICAÇÃO/TIPO <p style="text-align: center;">TC</p>	2. DATA 17 de novembro de 2009	3. REGISTRO N° CTA/ITA/TC-129/2009	4. N° DE PÁGINAS <p style="text-align: center;">51</p>
5. TÍTULO E SUBTÍTULO: Avaliação da Geoestatística como Método de Previsão de Movimento de Passageiros no Aeroporto Internacional do Rio de Janeiro Através de Comparação com Modelos Convencionais			
6. AUTOR(ES): Marcelo Bálbio Moraes			
7. INSTITUIÇÃO(ÕES)/ÓRGÃO(S) INTERNO(S)/DIVISÃO(ÕES): Instituto Tecnológico de Aeronáutica - ITA			
8. PALAVRAS-CHAVE SUGERIDAS PELO AUTOR: 1. Geoestatística. 2. Demanda por transporte aéreo. 3. Planejamento de aeroportos.			
9. PALAVRAS-CHAVE RESULTANTES DE INDEXAÇÃO: Análise estatística; Demanda (Economia); Transporte aéreo; Planejamento de aeroportos; Krigagem; Análise de séries temporais; Transporte de passageiros; Predição linear; Matemática aplicada; Transportes			
10. APRESENTAÇÃO: <p style="text-align: right;">X Nacional Internacional</p> ITA, São José dos Campos. Curso de Graduação em Engenharia Civil-Aeronáutica. Orientador: Prof. Dr. Paulo Ivo Braga de Queiroz; co-orientador: Prof. Dr. Carlos Müller. Publicado em 2009.			
11. RESUMO: <p>O presente trabalho tem por objetivo aplicar a Geoestatística à previsão de demanda por transporte aéreo no Aeroporto Internacional do Rio de Janeiro e comparar os resultados com previsões geradas por séries temporais, modelagem mais comumente utilizada.</p> <p>A base de dados utilizada foi fornecida pela INFRAERO e trabalhou-se com o movimento de passageiros de transporte regular nacional doméstico entre agosto de 1990 e julho de 2001, a fim de prever o movimento dos seis meses subsequentes. Mostra-se que a variável é estacionária quando se consideram médias mensais e que o variograma experimental levantado teve excelente ajuste com o modelo teórico esférico. O conhecimento prévio da média levou à opção pela Krigagem Simples como modelagem geoestatística e o cálculo dos pesos evidenciou o efeito tela com relação à observação mais recente; a variância do processo mostrou que o método é superior a métodos estatísticos convencionais baseados em média e desvio padrão.</p> <p>Foram geradas previsões através da Krigagem Simples e de um modelo estrutural básico de séries temporais. A comparação das previsões com os valores observados evidenciou que a modelagem por séries temporais é mais eficiente que a geoestatística, seja por apresentar menor erro em todos os casos, seja por conseguir captar as peculiaridades da série de dados. O fato de a Krigagem apresentar menor variância que o modelo de séries temporais indicou uma tendência na modelagem geoestatística, certamente gerada pela consideração das médias mensais.</p>			
12. GRAU DE SIGILO: (X) OSTENSIVO () RESERVADO () CONFIDENCIAL () SECRETO			