

**UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
ELÉTRICA**

DISSERTAÇÃO DE MESTRADO

RAMZ LUIZ FRAIHA LOPES

**MODELAGEM PARAMÉTRICA LINEAR APLICADA À FAIXA
DE SINAL DE TELEVISÃO DIGITAL PARA CIDADES
DENSAMENTE ARBORIZADAS**

DM – 06/2014

UFPA/ITEC/PPGEE

Campus Universitário do Guamá

Belém-Pará-Brasil

2014

**UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
ELÉTRICA**

RAMZ LUIZ FRAIHA LOPES

**MODELAGEM PARAMÉTRICA LINEAR APLICADA À FAIXA
DE SINAL DE TELEVISÃO DIGITAL PARA CIDADES
DENSAMENTE ARBORIZADAS**

Dissertação de Mestrado submetida à Banca Examinadora do Programa de Pós-Graduação em Engenharia Elétrica como quesito a obtenção do Grau de Mestre em Engenharia Elétrica, com ênfase em Telecomunicações.

UFPA/ITEC/PPGEE

Campus Universitário do Guamá

Belém-Pará-Brasil

2014

**UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
ELÉTRICA**

**MODELAGEM PARAMÉTRICA LINEAR APLICADA À FAIXA
DE SINAL DE TELEVISÃO DIGITAL PARA CIDADES
DENSAMENTE ARBORIZADAS**

AUTOR: RAMZ LUIZ FRAIHA LOPES

DISSERTAÇÃO DE MESTRADO SUBMETIDA À AVALIAÇÃO DA BANCA EXAMINADORA APROVADA PELO COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA DA UNIVERSIDADE FEDERAL DO PARÁ E JULGADA ADEQUADA PARA OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA ELÉTRICA COM ÊNFASE EM TELECOMUNICAÇÕES

APROVADA EM ____/____/____

Professor Dr. Gervásio Protásio dos Santos Cavalcante

ORIENTADOR

Professor. Dr. Fabrício José Brito Barros - UFPA

MEMBRO – UFPA/Tucuruí

Professor. Dr. Antônio Marcos de Lima Araújo – IESAM

MEMBRO - EXTERNO

Visto:

Prof. Dr. Evaldo Gonçalves Pelaes
COORDENADOR DO PPGE/ITEC/UFPA

Agradecimentos

Gostaria de agradecer primeiramente à minha família, por me proporcionar as oportunidades que tive (e ainda tenho) e a tranquilidade para dedicar-me somente aos meus estudos, fato não tão comum no contexto universitário no qual convivo já há alguns anos como estudante e, mais recentemente, professor. Em seguida, estendo meus agradecimentos aos professores que tive até hoje, em sua esmagadora maioria, competentes e dedicados a seu trabalho.

Agradeço ao Instituto Nacional de Ciência e Tecnologia de Comunicação Sem Fio (INCT-CSF) pelo suporte prestado e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro no formato de bolsa e à Universidade Federal do Pará (UFPA), pela oportunidade em realizar e concluir esta pós-graduação.

Agradeço também ao Laboratório de Pesquisa e Experimentação em Multimídia, em especial à Suelen Miyuki, que executou o procedimento de sincronização dos vídeos medidos em tempo recorde e de forma excelente.

Agradeço aos integrantes do Laboratório de Computação e Telecomunicações (LCT), onde tenho amigos de confiança e que também são profissionais competentes em suas respectivas áreas. Em especial agradeço a: Allan Costa, Allan Braga, Bruno Lyra, Bruno Quadros, Cristiane Gomes, Fabricio Barros, Hélio Ferreira, Igor Gomes, Michele Almeida, Nelson Santos, João Victor, Josiane Rodrigues, Regina Nascimento. Dentre estes, os que participaram diretamente das campanhas de medição foram Allan Braga, Bruno Quadros e Michele Almeida, esta de fundamental papel na obtenção dos vídeos utilizados neste trabalho.

Muito obrigado a todos.

Sumário

Agradecimentos	4
Sumário	5
Resumo	8
Abstract	9
Lista de Acrônimos	9
Lista de Figuras	11
Lista de Tabelas	12
Capítulo 1 - Introdução	13
Capítulo 2 - Estado da Arte e Trabalhos Correlatos	15
2.1- Considerações Iniciais	15
2.2- Estado da Arte	15
2.3- Trabalhos Correlatos	16
2.4- Considerações Finais	16
Capítulo 3 - Tópicos Sobre Propagação de Ondas Eletromagnéticas e Qualidade de Experiência (QoE)	17
3.1- Considerações Iniciais	17
3.2- Propagação de Ondas Eletromagnéticas	17
3.2.1- Propagação em Canais Sem Fio (<i>wireless</i>)	18
3.2.2- Modelos Físicos de Propagação	19
3.2.2.1- Propagação no Espaço Livre	19
3.2.2.2- Modelo Terra-Plana	19
3.2.2.3- Perdas por Difração	19
3.2.3- Modelos Estatísticos de Propagação	20
3.2.3.1- Modelo de Okumura-Hata	21
3.3- Qualidade de Experiência (QoE)	23
3.3.1- PSNR (Peak Signal-to-Noise Ratio)	24
3.4- Considerações Finais	24
Capítulo 4 - Algoritmo Genético (AG) e Método dos Mínimos Quadrados Lineares (MQL)	25
4.1- Considerações Iniciais	25
4.2- Algoritmo Genético (AG)	25
4.2.1- Definição e Aspectos Importantes	25
4.2.2- Etapas de um AG	27
4.2.3- Parâmetros Genéticos	29

4.3- Método dos Mínimos Quadrados Lineares (MQL).....	29
4.4 – Considerações Finais.....	31
Capítulo 5 - Tópicos em Probabilidade, Processos Estocásticos e Séries Temporais	32
5.1- Considerações Iniciais	32
5.2- Tópicos Sobre Teoria da Probabilidade.....	32
5.2.1- Espaço Amostral	32
5.2.2- Axiomas da Probabilidade	32
5.3- Variável Aleatória e Processos Estocásticos.....	33
5.3.1- Variável Aleatória (VA)	33
5.3.1.1- Definição.....	33
5.3.1.2- Função Distribuição de Probabilidade (FD) e Função Densidade de Probabilidade (fdp).....	33
5.3.1.3- Função Densidade de Probabilidade (fdp)	33
5.3.1.4- Momentos	33
5.3.1.4.1- Média ou Valor Esperado $E\mathbf{x}$	33
5.3.1.4.2- Variância $\sigma\mathbf{x}^2$	33
5.3.1.4.3- Covariância	34
5.3.2- Processo Estocástico	34
5.3.2.1- Definição.....	34
5.3.2.2- Autocorelação e Autocovariância	35
5.3.2.2.1- Autocorrelação.....	35
5.3.2.2.2- Autocovariância	35
5.3.2.2.3- Coeficiente de Correlação de um Processo $\mathbf{x}(\mathbf{t})$	35
5.3.2.3- Estacionariedade	35
5.3.2.3.1- Estacionariedade no Sentido Estrito (forte ou de primeira ordem).....	36
5.3.2.3.2- Estacionariedade no Sentido Amplo (fraca, de segunda ordem ou estacionária em covariância)	36
5.3.2.4- Ergodicidade	36
5.4- Séries Temporais.....	37
5.4.1- Definição e Considerações Gerais	37
5.5- Operadores de Transição de Estado	39
5.5.1- Operador Translação para o Passado (Atraso).....	39
5.5.2- Operador Translação para o Futuro (Adiantamento)	39
5.5.3- Operador Diferença Finita Ascendente.....	40
5.5.4- Operador Soma	40

5.6- Modelos Paramétricos Estacionários para Séries Temporais.....	40
5.6.1- Processo Linear Geral.....	40
5.6.2- Modelos Auto-regressivos (AR).....	41
5.6.2.1- Estacionariedade e Invertibilidade.....	41
5.6.2.2- Função de Autocorrelação (fac).....	42
5.6.3- Modelos de Médias Móveis (MA).....	42
5.6.3.1- Estacionariedade e Invertibilidade.....	43
5.6.3.2- Função de Autocorrelação (fac).....	43
5.6.4- Modelos Auto-regressivos e de Médias Móveis (ARMA)	43
5.6.4.1- Estacionariedade e Invertibilidade.....	43
5.6.4.2- Função de Autocorrelação (fac).....	43
5.7 – Considerações Finais.....	43
Capítulo 6 - Modelo Proposto e Metodologia Adotada.....	44
6.1 – Considerações Iniciais.....	44
6.2- Modelo Proposto.....	44
6.3- Metodologia.....	44
6.3.1- Aquisição de Dados (medições).....	44
6.3.2- Tratamento dos Dados	49
6.3.2.1- Dados de Potência.....	49
6.3.2.2- Tratamento dos Dados de Vídeo.....	50
6.4- Considerações Finais	50
Capítulo 7 - Resultados	51
7.1- Considerações Iniciais	51
7.2- Metodologia.....	51
7.3- Resultados Acerca da Previsão da Potência Recebida Como Função da Distância.....	54
7.4- Resultados Acerca da Previsão da PSNR Como Função da Potência Recebida.....	60
7.5- Considerações Finais	64
Capítulo 8 – Conclusões, Dificuldades Encontradas e Trabalhos Futuros	65
8.1- Considerações Iniciais	65
8.2- Conclusões do Estudo.....	65
8.3- Dificuldades Encontradas	66
8.4- Trabalhos Futuros	66
8.5- Considerações Finais	67
Referências Bibliográficas	68

Resumo

Este trabalho apresenta uma modelagem paramétrica (auto-regressiva) linear aplicável a estudos de propagação de televisão digital e telefonia celular para cidades densamente arborizadas. A modelagem proposta apresenta um forte embasamento estatístico e depende apenas de dados provenientes de medição, no caso dados relativos a potência recebida e o valor de PSNR (*Peak Signal-to-Noise Ratio*). Um algoritmo genético é utilizado no cálculo dos parâmetros de ajuste do modelo a um conjunto de dados. O trabalho foi realizado na faixa de televisão digital e foram analisadas duas variáveis: a potência recebida do sinal e o valor de PSNR. Foram executadas campanhas de medição na cidade de Belém. Nestas medições foram coletados dados de potência e gravados vídeos da programação diária de uma emissora de televisão. Os resultados podem ser aplicados no planejamento de serviços de telecomunicações.

Palavras-chave – Algoritmo Genético, Modelo Auto-Regressivo, Modelos de Propagação, Potência de Sinal, PSNR, Séries Temporais.

Abstract

This work proposes a linear parametric (auto-regressive) model applicable to digital television and mobile phone signals propagation studies on densely arborized cities. The proposed model has a strong statistic basis and depends only on measured data, in case, power signal and PSNR (Peak Signal-to-Noise Ratio) values data. A genetic algorithm was used to adjust the parameters of the model to a measured data set. This work was carried out on the digital television frequency and the signal power level and PSNR values were analyzed. Measurement campaigns were carried out in Belém city. Power signal data was collected as well as videos form the daily schedule of a television station. The results indicate that the model applicability is feasible on planning telecommunication services.

Key-words – Auto-Rregressive Model, Genetic Algorithm, Propagation Models, PSNR, Signal Power, Temporal Series.

Lista de Acrônimos

- AEDI** - Assessoria de Educação à Distância
- AG** - Algoritmo Genético
- AR** - Auto-Regressivo
- ARMA** - Auto-Regressivo de Médias Móveis
- ESA** - Estacionáriedade no Sentido Amplo
- ESE** - Estacionáriedade no Sentido Estrito
- fac** - Função de Autocorrelação
- fd** - Func Densidade de Probabilidade
- FD** - Func Distribuição de Probabilidade
- IPTV** - Televisão Sobre/Via IP
- ISDB-T** - *Integrated Services Digital Broadcasting Terrestrial*
- ITU** - *International Communication Union*
- LCT** - Laboratório de Computação e Telecomunicações
- MA** - Médias Móveis
- MOS** - *Mean Square Opinion*
- MPEG** - *Moving Pictures Expert Group*
- MQL** - Mínimos Quadrados Lineares
- MSE** - *Mean Sqaure Error*
- PSNR** - *Peak Signal-to-Noise Ratio*
- QoE** - Qualidade de Experiência
- RMB** - Região Metropolitana de Belém
- RMSE** - *Root-Mean-Square Error*
- RNA** - Redes Neurais Artificiais
- Rx** - Receptor
- Rx_P** - Receptor de Potência
- Rx_V** - Receptor de Vídeo
- SBTVD** - Sistema Brasileiro de Televisão Digital
- SSIM** - Structural Similarity index
- TVD** - TV Digital
- Tx** - Transmissor

UFPA - Universidade Federal do Pará

VA - Variável Aleatória

Lista de Figuras

Fig. 3.1- Esquema do Modelo Terra-Plana	19
Fig. 3.2- Difração	20
Fig. 5.1(a)- Tendência Constante	38
Fig. 5.1(b)- Tendência Linear	38
Fig. 5.1(c)- Tendência Quadrática	39
Fig. 5.2- Filtro linear com entrada a_t e saída Z_t e função de transferência $\psi(B)$	40
Fig. 6.1(a)- Região Metropolitana de Belém (RMB)	45
Fig. 6.1(b)- Pontos medidos na RMB. Radiais 1, 2 e 3, respectivamente, no sentido cartesiano e originando-se em “Tx”	46
Fig. 6.2(a)- Antena Anritsu MPP615A	47
Fig. 6.2(b)- Posicionamento de Rx_P	47
Fig. 6.3- Anritsu S332E	48
Fig. 6.4- Posicionamento de Rx_V	49
Fig. 7.1- Pictórica da Metodologia	53
Fig. 7.2(a)- Dados calibrados X dados originais (Radial 3)	55
Fig. 7.2(b)- Dados previstos/propostos X dados originais (Radial 2)	55
Fig. 7.3(a)- Dados simulados X dados originais (Radial 3)	57
Fig. 7.3(b)- Dados simulados X dados originais (Radial 2)	57
Fig. 7.4(a)- Modelo de Okumura-Hata e dados originais (Radial 3)	58
Fig. 7.4(b)- Modelo de Okumura-Hata e dados originais (Radial 2)	59
Fig. 7.5(a)- Dados calibrados X dados originais (Radial 3)	61
Fig. 7.5(b)- Dados previstos/propostos X dados originais (Radial 2)	61
Fig. 7.6(a)- Dados simulados X dados originais (Radial 3)	62
Fig. 7.6(b)- Dados simulados X dados originais (Radial 2)	63

Lista de Tabelas

Tabela 7.1- Valores de b , c e d para os dados de potência como função da distância	56
Tabela 7.2- Valores dos parâmetros obtidos através de um sistema do tipo (5.38)	56
Tabela 7.3- Valores de RMSE para potência recebida X distância	59
Tabela 7.4- Valores de b , c e d para os dados de PSNR em função da potência recebida	62
Tabela 7.5- Valores dos parâmetros obtidos através de um sistema do tipo (5.38)	63
Tabela 7.6- Valores de RMSE para PSNR X potência recebida	63

Capítulo 1 - Introdução

O estudo da propagação de ondas eletromagnéticas data do século XIX, começando com J. C. Maxwell [1], no momento em que descobriu a existência da relação entre magnetismo e eletricidade e que as respectivas ondas eletromagnéticas se moviam com a velocidade da luz. A partir daí, diversos outros cientistas descobriram resultados até hoje utilizados, com especial destaque para J. A. W. Zenneck, A. J. W. Sommerfeld, H. K. H. Weyl e K. A. Norton (com Weyl e Norton que contribuíram com correções no trabalho de Sommerfeld) [2-5].

Novas tecnologias foram desenvolvidas envolvendo ondas eletromagnéticas, com especial atenção para as telecomunicações. Em particular, diversos modelos teóricos e empíricos foram propostos de modo a facilitar o entendimento do fenômeno da propagação de ondas eletromagnéticas. Exemplos podem ser vistos em [6-7]. Cada tipo de modelo tem suas peculiaridades. Os modelos teóricos conseguem representar com bom grau de exatidão muitas das situações contidas na teoria eletromagnética. Entretanto, sua implementação computacional costuma exigir bastante poder de processamento, tornando-se assim inviável em muitas situações. Já os modelos empíricos, por serem desenvolvidos com base em experimentos/medições nos ambientes específicos de aplicação, são mais simples de implementar (exigem menor custo computacional). Porém sua aplicação para diferentes ambientes é restrita, visto que foram criados com foco em um determinado tipo de ambiente. Exemplos de modelos empíricos constam em [7-8].

Um dos serviços dependentes da teoria eletromagnética de propagação de ondas mais relevantes no cenário brasileiro atual é o da transmissão de sinal digital televisivo, ou simplesmente, televisão digital (TVD). Sendo o meio de comunicação de maior significância no Brasil [9], a televisão tem fundamental importância como fonte de entretenimento e informação. Com a implantação da tecnologia digital de transmissão, que opera em frequência diferente da transmissão de sinal analógico, estudos acerca da qualidade do serviço prestado tornaram-se necessários. Em especial, o estudo do comportamento da potência recebida pelo receptor é de vital importância.

O presente trabalho propõe uma modelagem auto-regressiva (AR) para a previsão da potência de um sinal recebido por um usuário/receptor (Rx) em função da distância ao transmissor (Tx) e para previsão do valor de PSNR (*Peak Signal-to-Noise Ratio*) em função da potência recebida. Em poucas palavras, a PSNR é a relação entre o valor de pico de um sinal e seu respectivo nível de ruído. Este estudo é aplicado à faixa de TVD brasileira. Este trabalho considera ainda o caso especial de cidades densamente arborizadas na Amazônia brasileira. Esta modelagem considera técnicas modernas de otimização, em especial, um algoritmo genético (AG) usado para a obtenção dos parâmetros (ajuste) do modelo. Este aspecto do estudo é exposto no capítulo 4.

A modelagem AR é uma modelagem paramétrica linear oriunda do estudo de séries temporais. É um caso particular do chamado modelo linear geral e tem diversas aplicações na previsão em modelos temporais. As modelagens paramétricas são

inicialmente consideradas problemas inversos. Na utilização de modelos paramétricos são realizadas duas etapas: cálculo de parâmetros e utilização dos parâmetros para alimentar o modelo. Nos modelos diretos, em contrapartida, já são conhecidos os parâmetros, bastando alimentar os modelos com os dados desejados.

A escolha deste modelo se deve ao fato de ter forte embasamento estatístico e de depender unicamente de seus dados intrínsecos para sua aplicação. Isto é, apenas com os dados obtidos, pode-se “alimentar” o modelo, descobrir seus parâmetros e, a partir daí, fazer as previsões/análises necessárias acerca da série (dos dados). Os modelos AR, portanto, se contrapõem aos modelos de baixo teor estatístico, como, por exemplo, as redes neurais artificiais (RNA).

Os resultados deste trabalho mostram a viabilidade da modelagem proposta, mesmo com uma base de dados reduzida. Tais resultados baseiam-se na comparação com modelos de referência e em resultados obtidos através da teoria de séries temporais, tendo como referência os valores de RMSE (*Root Mean-Square-Error*). Ao se considerar as etapas futuras de desenvolvimento do estudo (entre elas o aumento da base de dados), espera-se uma melhora na significância e precisão dos resultados. Com os resultados obtidos até então, pode-se inclusive, utilizar o modelo no planejamento de serviços de telecomunicações, dada a escassez de modelos adaptados para a realidade das cidades densamente arborizadas e que ainda proponham uma relação entre potência de sinal e a qualidade do serviço prestado.

O estado da arte é visto no capítulo 2, juntamente com alguns trabalhos correlatos a este estudo; o capítulo 3 expõe brevemente a teoria de propagação de ondas eletromagnéticas e de qualidade de experiência (QoE), que são necessárias para o entendimento do trabalho; a teoria sobre algoritmos genéticos é exposta no capítulo 4; a teoria de probabilidade, processos estocásticos e séries temporais utilizada neste trabalho é mostrada no capítulo 5; o modelo proposto e a metodologia utilizada neste trabalho estão descritas no capítulo 6; o capítulo 7 trata dos resultados obtidos com a modelagem proposta aplicada ao conjunto de dados obtidos; finalmente, as conclusões e dificuldades encontradas durante este estudo encontram-se descritas no capítulo 8.

Capítulo 2 - Estado da Arte e Trabalhos Correlatos

2.1- Considerações Iniciais

Neste capítulo é mostrado o que há atualmente em termos de trabalhos sobre propagação e aplicação de modelos baseados em séries temporais (modelos auto-regressivos, médias móveis, etc.), bem como alguns exemplos de trabalhos relacionados a este estudo.

2.2- Estado da Arte

Propagação de ondas eletromagnéticas é uma área de estudo bastante difundida, sendo presente em quase todas as atividades humanas. Podem-se destacar aplicações às telecomunicações, desde a criação/proposição de modelos (empíricos e/ou determinísticos) que regem a propagação de ondas em diferentes frequências e ambientes (exteriores e interiores) até a verificação de limites para exposição humana à radiação dessas ondas. Exemplos de modelagens para ambientes exteriores (*outdoor*) podem ser encontrados em [6, 10, 11].

O Sistema Brasileiro de Televisão Digital (SBTVD) foi inicialmente discutido em 1999 [12]. Desde então, estudos foram realizados para a definição das diretrizes do padrão brasileiro, este está baseado no padrão japonês de televisão digital, o ISDB-T (*Integrated Services Digital Broadcasting Terrestrial*). Pesquisas regionais, levando em consideração as particularidades de cada região (nível de urbanização, relevo e/ou vegetação) não foram efetuadas a contento, ou ainda estão em andamento, isto, em vários casos implica em um serviço de qualidade inferior à prevista inicialmente para o usuário. Isso é verificado, particularmente, em regiões como a Amazônia, devido à reclamações de usuários do sistema. Os modelos fornecidos pelas recomendações ITU-R P.1546 [13] e ITU-R P.1812 [14] apresentam importantes limitações quando aplicados em determinadas regiões do Brasil, entre essas, regiões de clima tropical, como é caso da região amazônica, seja por características climáticas ou pelas características urbanas, como, tipos de prédios, vegetações, etc. Pretende-se, até 2016, extinguir o sinal de televisão analógica [15]. Tal fato exalta a importância de se alcançar uma qualidade satisfatória do sinal transmitido digitalmente, isto é uma boa qualidade de experiência para o usuário.

Conforme exposto, nota-se que há um campo importante de estudo/aplicação de modelagens acerca da propagação de ondas eletromagnéticas e da qualidade de experiência, que possam obter bons resultados com um custo relativamente reduzido.

No tocante à teoria/aplicação de séries temporais pode-se destacar as várias aplicações de modelagens paramétricas semelhantes à proposta, como modelos ARMA (Auto-regressivos e de Médias Móveis), MA (Médias Móveis) e AR (Auto-regressivo). Exemplos encontram-se em [16-19]. Percebe-se a aplicação desse tipo de modelagem em áreas de estudo tão diversas quanto a biologia, a geologia e, evidentemente, a estatística aplicada. Isto ocorre pelo fato de uma modelagem paramétrica desse tipo

dependem apenas dos dados estudados, podendo eles ter qualquer representatividade desejada, isto é, os parâmetros vão quantificar o acontecimento real. Os modelos mais simples são de fácil implementação computacional.

2.3- Trabalhos Correlatos

Outro ponto de suma importância, tratado a seguir, para a fundamentação do trabalho diz respeito ao que já foi desenvolvido e está relacionado a este trabalho, seja no estudo de propagação seja na aplicação de modelos de séries temporais.

Alguns exemplos de trabalhos correlatos são [11], [20], [21]. Em [11], tem-se um tipo de modelagem similar à adotada neste trabalho, porém em uma frequência de transmissão diferente. O trabalho correlato em [20] trata da propagação eletromagnética (na faixa de telefonia celular) na região amazônica, em especial nos centros urbanos, característica que coincide com o trabalho aqui proposto. [21] é um trabalho que faz uma análise das características elétricas do solo (permissividade e condutividade), com foco na propagação de ondas em frequências inferiores a 30MHz. Este último é um trabalho de cunho empírico, que utiliza técnicas de inteligência computacional, no caso, uma rede neural artificial (RNA). Dessa forma, tem-se que [21] tem sua metodologia similar à do estudo aqui proposto.

Os trabalhos [22] e [23] deram origem ao presente estudo. Ambos aplicam modelos ARMA às telecomunicações. Estes últimos têm como foco a previsão de potência do sinal em função da distância. O trabalho [22] estuda ambientes interiores (*indoor*) na frequência de 2.4GHz (*Wireless LAN*). [23] considera ambientes *outdoor* na frequência de 877.44MHz (telefonia celular). A partir destes dois trabalhos, originou-se a ideia de aplicar modelagem semelhante também na previsão da qualidade de experiência do usuário (ou de uma das respectivas métricas representativas de QoE) do serviço de TVD em cidades densamente arborizadas brasileiras, em particular, na região amazônica.

2.4- Considerações Finais

Neste capítulo alguns trabalhos relacionados a este estudo foram expostos visando situar o leitor na grande diversidade de aplicações da modelagem AR e seus derivados (a modelagem ARMA, por exemplo). Essa variedade de aplicações da modelagem oriunda do estudo de séries temporais foi um dos motivos para a adoção da mesma neste estudo.

Capítulo 3 - Tópicos Sobre Propagação de Ondas Eletromagnéticas e Qualidade de Experiência (QoE)

3.1- Considerações Iniciais

Neste capítulo serão abordados com brevidade os conceitos relativos à propagação de ondas eletromagnéticas e QoE que mais se adequam a este estudo. Uma breve descrição do fenômeno de propagação eletromagnética é exposta, bem como alguns dos modelos físicos e estatísticos clássicos. Em seguida, é mostrada uma definição de QoE e de uma de suas métricas, a PSNR (*Peak Signal-to-Noise Ratio*). Em particular, esta métrica foi escolhida para a análise realizada neste trabalho.

3.2- Propagação de Ondas Eletromagnéticas

O estudo da propagação de ondas eletromagnéticas é de suma importância para o desenvolvimento e aprimoramento das tecnologias de comunicação. Conseguir entender/prever como um sinal emitido chega ao receptor é fundamental para uma comunicação eficiente. Neste tópico, o foco será a propagação em meio sem fio (*wireless*), visto que neste trabalho é analisado um sinal propagado por um meio deste tipo.

No estudo de propagação alguns fenômenos físicos têm uma contribuição acentuada na eficiência da recepção de uma onda eletromagnética. Estes são: reflexão, difração e refração. O sinal recebido pelo Rx sofre influência de todos esses fenômenos físicos, bem como está sujeito ao que se chama de multipercurso, que ocorre quando um sinal, ao se propagar por um ambiente com obstáculos, reflete/refrata/difrata em nestes obstáculos, assim caminhos diferentes são tomados pelo sinal transmitido. O multipercurso pode implicar também em interferências, sejam elas construtivas (acarretam aumento da potência do sinal recebido) ou destrutivas (acarretam no decréscimo da potência do sinal recebido). Vale destacar que interferências podem ocorrer também de equipamentos semelhantes emitindo sinais em frequências próximas à do sinal estudado e também do próprio receptor, isto é, dos componentes que o constituem [24].

Outra fonte de limitação nas comunicações é o ruído. Em poucas palavras, considera-se o ruído como sendo sinais eletromagnéticos indesejados (e usualmente incontrolláveis) que interferem com os sinais transmitidos. Ruídos podem ser oriundos tanto de fontes naturais (meio ambiente) quanto de fontes artificiais (construídas pelo homem) [24].

Um efeito comum nos sistemas móveis de comunicação é o desvanecimento. Este desmembra-se em dois tipos: lento e rápido. O desvanecimento lento caracteriza-se por mudanças lentas e graduais no sinal recebido devido ao movimento, também lento, do receptor, em relação à posição dos obstáculos no percurso do sinal. Pode-se entender também como movimento em distâncias longas. É também chamado de somreamento ou desvanecimento lognormal, já que pode ser representado por uma distribuição

lognormal [24]. Já o desvanecimento rápido caracteriza-se por mudanças rápidas e frequentes (em geral movimento em distâncias curtas) no sinal recebido, oriundo de uma movimentação rápida do receptor em relação aos obstáculos do ambiente. Contribui para o desvanecimento rápido também as componentes refletidas do sinal transmitido, que podem implicar em interferências construtivas e/ou destrutivas [24].

3.2.1- Propagação em Canais Sem Fio (*wireless*)

Ao se tratar de propagação em canais sem fio, todas as observações iniciais sobre os fenômenos que acarretam em perdas continuam válidas. Em contrapartida, um canal sem fio propicia um alcance maior de uma mesma transmissão sem os custos de, por exemplo, cabear todo o percurso.

Um conceito teórico muito utilizado no trato de comunicações *wireless* é o da operação da antena isotrópica. Este tipo de antena irradia igualmente em todas as direções. Tal antena não existe na prática (toda antena real possui alguma diretividade associada), entretanto, o conceito de antena isotrópica é importante do ponto de vista comparativo com as antenas reais, sendo útil na explicação de fundamentos, como a ganho direcional, por exemplo [24]. Define-se diretividade como o direcionamento de maior irradiação de uma antena.

Uma antena direcional possui um ganho dependente de dois ângulos: azimutal e elevação. O ângulo azimutal, denotado por θ , é medido no plano horizontal da antena relativamente a uma direção horizontal de referência. Já o ângulo de elevação, denotado por ϕ , é medido na direção vertical acima do plano horizontal da antena. Assim, o ganho de uma antena, em função de sua área efetiva A_e , é dado por

$$G = \frac{4\pi}{\lambda^2} A_e \quad (3.1)$$

Tal ganho na antena transmissora é denotado por G_T . Já na antena receptora é denotado por G_R .

A equação de Friis permite estimar a potência do sinal recebido em função do comprimento de onda λ e da distância entre transmissor e receptor R . É dada por (3.2)

$$P_R = \frac{P_T G_T G_R}{L_p} \quad (3.2)$$

com $L_p = \left(\frac{4\pi R}{\lambda}\right)^2$

Em (3.2), a grandeza L_p refere-se ao fator de perda de propagação. Em escala logarítmica (*dB*), (3.2) é escrita na forma

$$P_R(\text{dB}) = P_T(\text{dB}) + G_T(\text{dB}) + G_R(\text{dB}) - L_p(\text{dB}) \quad (3.3)$$

3.2.2- Modelos Físicos de Propagação

Nos próximos três subtópicos uma breve descrição dos modelos físicos de propagação é mostrada, bem como quais modelos possuem maior significância no cenário de medições adotado neste trabalho.

3.2.2.1- Propagação no Espaço Livre

Diz-se que a propagação em espaço livre ocorre em um canal sem fio livre de obstáculos (visada direta). Dessa forma, a perda de intensidade do sinal transmitido se dá apenas em função da distância percorrida pelo sinal. As equações de Maxwell conseguem descrever esse tipo de propagação com um bom grau de exatidão.

3.2.2.2- Modelo Terra-Plana

O modelo Terra-Plana considera as ondas em visada direta e as refletidas na superfície da terra, conforme visto na figura 3.1.




Fig. 3.1 – Esquema do modelo Terra-Plana [24]

O modelo Terra-Plana considera transmissor e receptor fixos. A equação que rege a propagação segundo este modelo é dada em (3.4),

$$P_R = P_T G_T G_R \left(\frac{h_T h_R}{R^2} \right)^2, \quad (3.4)$$

com h_T sendo a altura da antena transmissora, h_R sendo a altura da antena receptora e R sendo a distância horizontal (conforme a figura 3.1) entre as antenas transmissora e receptora.

Este modelo é considerado no caso de propagação em distâncias pequenas (poucas dezenas de quilômetros) e, por isso, desconsidera a curvatura da Terra [24].

3.2.2.3- Perdas por Difração

Dá-se o nome de difração ao fenômeno de espalhamento de uma onda (eletromagnética ou mecânica) ao passar por uma fenda, orifício ou borda de um obstáculo, conforme ilustrado na figura 3.2(a). Este fenômeno é comumente descrito pelo princípio de Huygens: “Todos os pontos em uma frente de onda podem ser considerados como fontes pontuais para produção de ondas eletromagnéticas

elementares. Contudo, cada fonte pontual não irradia igualmente em todas as direções, mas favorece a direção da frente de onda”. Tal princípio é derivado explicitamente das equações de Maxwell [24] e explica o fato de ondas contornarem obstáculos como montanhas e edificações, conforme a figura 3.2(b). Neste caso, uma região que, a princípio deveria ser uma região de sombra eletromagnética, fica “iluminada” pela frente de onda que contornou a borda do obstáculo.




Fig. 3.2 – Difração [24]

Na propagação de um sinal eletromagnético, a difração provoca perdas de forma mais acentuada que no caso das perdas em espaço livre, para uma mesma distância entre Tx e Rx (bem como no caso do modelo plano-terra). Pode ser demonstrado [24] que à medida que o receptor se move na direção da região de sombra do obstáculo, as perdas por difração se acentuam. Deve-se ressaltar que o fenômeno da difração está intimamente ligado à frequência/comprimento de onda do sinal transmitido. A significância de um obstáculo está diretamente ligada às suas dimensões e ao comprimento de onda do sinal transmitido que passa por ele.

3.2.3- Modelos Estatísticos de Propagação

Os modelos físicos vistos no último subtópico podem acarretar em cálculos de complexidade elevada, dado a variedade de ambientes possíveis, inviabilizando inclusive a solução analítica das suas respectivas equações. Assim, deve-se recorrer à análise/cálculo numérico desses modelos. Ou simplesmente adotar outro tipo de modelagem, que são os modelos estatísticos. Modelos estatísticos baseiam-se em aproximar empiricamente o problema com base em medidas realizadas em ambientes semelhantes ao estudado (caso no qual se enquadra este trabalho). Estes modelos consideram dois tipos principais de perdas: perdas de percurso médio e perdas locais de propagação.

O estudo da perda em percurso médio acarreta no problema de encontrar parâmetros referentes ao ambiente estudado, que permitam prever o comportamento do sinal no

percurso estudado. Um exemplo de modelo que se utiliza desse tipo de abordagem é o modelo de Okumura-Hata [24]. Entretanto, cada tipo de ambiente possui parâmetros distintos, logo, é muito difícil uma caracterização geral do problema [24].

A perda local de propagação pode ser compreendida como uma espécie de refinamento da perda em percurso médio, pois considera as particularidades de cada local. Os estudos neste tipo de perda consideram variações no valor médio (da perda) intrínsecas de cada localidade estudada. Muitos destes estudos concluíram que uma distribuição lognormal rege esse tipo de variação acerca dos valores médios [24].

3.2.3.1- Modelo de Okumura-Hata

Por desempenhar papel fundamental neste trabalho ao servir de referência para a comparação com a modelagem proposta este subtópico trata da descrição deste modelo.

Baseado em medições ao redor de Tokyo nos anos 1960, executadas por Okumura, este é um dos modelos mais utilizados para previsões de perda de sinal em ambientes urbanos. Tais medições resultaram em um conjunto inicial de equações de difícil tratamento computacional à época. A equação principal do modelo de Okumura é mostrada em (3.4).

$$L_{50} = L_{FS} + A_{mu} + H_{tu} + H_{ru} \quad (3.4)$$

Com:

- L_{50} = Perda de percurso média entre Tx e Rx em (dB);
- L_{FS} = Perda no espaço livre (dB);
- A_{mu} = Perdas devido à propagação em ambientes urbanos (dB);
- H_{tu} = Fator de correção de altura do Tx (dB);
- H_{ru} = Fator de correção de altura do Rx (dB).

O termo de perda no espaço livre pode ser encontrado analiticamente por (3.5)

$$L_{FS} = 32,45 + 20 \log\left(\frac{d}{1km}\right) + 20 \log\left(\frac{f}{1MHz}\right) - 10 \log(G_t) - 10 \log(G_r) \quad (3.5)$$

Com:

- d = Distância entre Tx e Rx (km);
- f = Frequência operante do sinal (MHz)
- G_t, G_r = Ganhos lineares das antenas Tx e Rx, respectivamente.

Apesar de ser um modelo simples, além de ter sido o primeiro a ser utilizado para o ambiente de propagação dos serviços de telefonia celular, a sua implantação em linguagem computacional apresenta algumas dificuldades. Tais dificuldades são oriundas do fato de que, à época, os fatores A_{mu} , H_{tu} , H_{ru} consistiam em um conjunto

de curvas (figuras) e, a partir delas obtinham-se os valores necessários para a previsão requerida.

Algumas das dificuldades em implantar o modelo de Okumura computacionalmente eram:

- 1) As curvas base, A_{mu} , H_{tu} , H_{ru} , tinham de ser digitalizadas e transformadas em dados tabelados para uma consulta facilitada;
- 2) A natureza empírica do modelo de Okumura representava uma limitação em sua aplicabilidade. Caso algum dos parâmetros estivesse fora da faixa originalmente pretendida, as curvas/dados tabelados deveriam ser extrapoladas. Isto pode afetar negativamente a precisão/validade do modelo;

Dificuldades deste tipo acarretaram em várias correções e ajustes ao modelo inicial. Dentre elas, destacar-se-á neste estudo a contribuição de Hata, que facilitou a implantação em linguagem computacional do modelo ao ajustar as curvas tabeladas para equações analíticas. Dessa forma, a perda de percurso, segundo a contribuição de Hata, é dada por:

$$L_p = A + B \log(d) \quad (3.6)$$

$$L_p = A + B \log(d) - C \quad (3.7)$$

$$L_p = A + B \log(d) - D \quad (3.8)$$

Com:

- (3.6) referente à perda em ambiente urbano;
- (3.7) referente à perda em ambiente suburbano;
- (3.8) referente à perda em ambiente aberto;
- d = Distância entre Tx e Rx (km) tal que $1 \leq d \leq 20$;
- A = Perda fixa dependente da frequência do sinal (dB), dada em (3.9);
- B = Expoente de perda de percurso;
- C, D = Decréscimos nas perdas fixas para os ambientes suburbano e aberto, respectivamente.

Os fatores A, B, C e D são dados por:

$$A = 69,55 + 26,16 \log(f) - 13,82 \log(h_t) - a(h_r) \quad (3.9)$$

$$B = 44,9 - 6,55 \log(h_t) \quad (3.10)$$

$$C = 5,4 + 2 \left[\log \left(\frac{f}{28} \right) \right]^2 \quad (3.11)$$

$$D = 40,94 + 4,78 [\log(f)]^2 - 18,33 \log(f) \quad (3.12)$$

Com:

- h_t = Altura do Tx (m) tal que $30 \leq h_t \leq 200$;

- h_r = Altura do Rx (m) tal que $1 \leq h_r \leq 10$;
- f = Frequência do sinal transmitido (MHz) tal que $100 \leq f \leq 1500$;
- $a(h_r)$ = Fator de correção baseado na altura do Rx, dado em (3.13);

$$a(h_r) = 8,29(\log(1,54 h_r))^2 - 1,1dB \quad , \quad f \leq 300MHz \quad (3.13-a)$$

$$a(h_r) = 3,2 (\log(11,75 h_r))^2 - 4,97dB \quad , \quad f > 300MHz$$

$$a(h_r) = [1,1 \log(f) - 0,7]h_r - [1,56 \log(f) - 0,8]dB \quad (3.13-b)$$

Com (3.13-a) referindo-se a cidades grandes e (3.13-b) referindo-se a cidades médias e pequenas.

Uma consideração importante deve ser feita a respeito do modelo de Okumura-Hata. Por ser um ajuste das curvas do modelo de Okumura, o modelo está “calibrado” para as ambientações de Tokyo dos anos 1960. Além disso, as definições de cidade “grande”, “média” e “pequena” e de ambiente “urbano”, “suburbano” e “aberto”. Dessa forma, pode ser necessário ajustar os fatores do modelo caso o ambiente escolhido para sua aplicação difira muito do ambiente original das medições. O modelo de Okumura e suas variações, como o modelo de Okumura-Hata adotado neste trabalho, continuam importantes nos dias atuais.

3.3- Qualidade de Experiência (QoE)

O conceito de qualidade de experiência diz respeito ao modo como o usuário percebe o serviço a ele fornecido, isto é, se ele considera tal serviço bom ou ruim [25]. Por ser a maneira como cada usuário percebe um dado serviço, tem-se um alto grau de subjetividade implícito, pois um usuário pode ter uma opinião diferente de outro em condições similares de avaliação. Uma quantificação da opinião dos usuários é possível com o uso de métricas.

Um dos modos mais comuns de se obter a qualidade de um dado serviço (transmissão de voz, dados, vídeo, etc.) é com o uso do MOS (*Mean Opinion Score*), uma métrica subjetiva de qualificação. Nesta métrica, os usuários dão uma nota ao serviço variando de 1 a 5, sendo 1 para serviço na pior qualidade possível e 5 para a melhor qualidade possível. O ITU (*International Telecommunication Union*), organismo internacional regulamentador de telecomunicações, determinou uma série de condições para a obtenção do valor de MOS, isto é, uma metodologia de “medição” para o MOS. Um exemplo desse tipo de recomendação, para serviços de voz, encontra-se em [26]. Para serviços de vídeo, pode-se entender o MOS da mesma forma, como explicitado em [27], para o caso de televisão via internet/IP, ou, simplesmente, IPTV.

De modo a evitar a utilização de métricas subjetivas, foram desenvolvidas métricas objetivas, como a PSNR e o SSIM (*Structural Similarity index*). Neste trabalho, utiliza-se apenas a métrica PSNR. Esta é a mais utilizada dentre as métricas objetivas, apesar de não ser a mais precisa para serviços via canal de transmissão sem fio [28]. O cálculo da PSNR se dá através da comparação, de cada pixel, quadro (*frame*) a quadro de um mesmo vídeo antes de ser transmitido e após ser recebido.

3.3.1- PSNR (Peak Signal-to-Noise Ratio)

A PSNR é a métrica objetiva mais simples e a mais utilizada para análise qualitativa de imagens, móveis e estáticas. É de fácil implantação computacional e é facilmente interpretada utilizando intervalos de qualidade “padrão” [29]. É utilizada, em particular na avaliação de diferentes codificadores de imagens (codecs) [30]. Mesmo alguns estudos mostrando que a PSNR não tem uma forte correlação com métricas subjetivas [31], ela é considerada uma métrica de referência na avaliação qualitativa de imagens.

A PSNR é definida como a razão do quadrado do sinal útil pela média quadrática do erro em dB. Em particular, a PSNR entre o i -ésimo quadro do vídeo original não comprimido e o j -ésimo quadro do vídeo reconstruído (após processo de decodificação no receptor) é definida como:

$$PSNR(i, j) = 10 \log \left(\frac{(2^P - 1)^2}{MSE(i, j)} \right). \quad (3.14)$$

$2^P - 1$ é o valor máximo assumido por um pixel em uma representação de P bits (por exemplo, em uma representação de 8 bits esse valor é 255). O MSE (*Mean Square Error*) é uma medida de erro que é calculada como a média quadrática da diferença, pixel por pixel entre o *frame* do vídeo original, $f_i(x, y)$, e o *frame* vídeo decodificado, $g_j(x, y)$:

$$MSE(i, j) = \frac{1}{MN} \sum_{x=1}^M \sum_{y=1}^N [f_i(x, y) - g_j(x, y)]^2. \quad (3.15)$$

M e N representam as dimensões do *frame*, isto é, sua resolução.

A PSNR pode ser calculada para nas componentes de luminância e crominância (sistema de cores YUV), bem como no sistema de cores RGB. A PSNR de um vídeo é obtida pela média aritmética dos valores de PSNR de cada *frame* do vídeo estudado. Neste estudo, por simplicidade, a PSNR é obtida apenas na componente da luminância.

3.4- Considerações Finais

Estudos relacionando QoE, potência recebida e TVD na região amazônica são escassos, e, como ocorre em outros serviços/faixas de frequência, os modelos adotados pelas fornecedoras (de serviços de telecomunicações) não são, de uma forma geral precisos o suficiente para que o serviço fornecido chegue ao usuário com a qualidade desejada por este e anunciada pela fornecedora. Esta lacuna propicia o surgimento de modelagens específicas para ambientes similares ao da região amazônica. Nos capítulos seguintes, os fundamentos teóricos de algoritmos genéticos e de séries temporais, necessários para o entendimento do modelo serão explicados, bem como a apresentação do modelo e os resultados obtidos neste trabalho.

Capítulo 4 - Algoritmo Genético (AG) e Método dos Mínimos Quadrados Lineares (MQL)

4.1- Considerações Iniciais

Técnicas de otimização e ajuste são uma ferramenta bastante utilizada na resolução de problemas práticos de difícil solução analítica. Tais dificuldades acabam propiciando uma abordagem numérica para um dado problema. É nesta lacuna que métodos de otimização e/ou ajuste tornam-se ferramentas importantes. Neste capítulo trata-se de duas técnicas desse tipo: o algoritmo genético e o método dos mínimos quadrados lineares. Elas são utilizadas em etapas distintas do tratamento de dados/obtenção de resultados durante o trabalho. O AG tem papel principal na metodologia de obtenção dos resultados, pois os coeficientes do modelo proposto (explicado no capítulo 6) são encontrados através de um AG. Já o MQL é utilizado para obter a tendência linear dos dados tratados. Tal procedimento é aqui chamado de “horizontalização” e é explicado no capítulo 6.

4.2- Algoritmo Genético (AG)

4.2.1- Definição e Aspectos Importantes

Os algoritmos genéticos (AG) surgiram inspirados na Teoria Darwiniana da Evolução Natural, segundo a qual os mais aptos ao ambiente em que vivem têm mais chances de passar adiante suas características genéticas.

O mecanismo principal da evolução natural é conhecido como seleção natural. Este processo ocorre lentamente, ao decorrer de muitas gerações, e permite que a diversidade oriunda dos cruzamentos entre indivíduos com informações genéticas diferentes possa determinar o futuro de uma espécie, significando sua permanência, mesmo com algumas mudanças, ou sua extinção. Um dos exemplos mais famosos deste mecanismo é o das mariposas de Manchester, na Inglaterra. Antes da revolução industrial, o número de mariposas brancas era muito superior ao de mariposas negras, porém, com o passar do tempo, o crescimento no número de indústrias e, conseqüentemente, da poluição, fez com que as mariposas pretas superassem, em quantidade, as brancas. Isso ocorreu porque, com a poluição, as plantas ficavam com uma coloração escura, dificultando assim a camuflagem das mariposas brancas e facilitando a das pretas. Dessa forma, a primeira espécie se tornou alvo fácil para seus predadores e, portanto, teve mais dificuldades de passar adiante sua carga genética, o que acarretou em uma diminuição drástica no número de mariposas brancas.

Um dos principais criadores dos AGs foi John Holland (1929-). Norte-americano, natural de Fort Wayne, no estado de Indiana, foi graduado em Física pelo MIT (Instituto de Tecnologia de Massachusetts), Mestre em Matemática (Universidade de Michigan) e Doutor em Ciência da Computação na primeira turma da Universidade de Michigan.

Atualmente é professor na Universidade de Michigan. É conhecido como o “pai dos Algoritmos Genéticos”.

A partir de meados da década de 1970 (em especial 1975, após o lançamento da obra *Adaptation in Natural and Artificial Systems*, de autoria de Holland) e durante a década de 1980, métodos computacionais para os AGs começaram a ser aplicados com sucesso em uma grande gama de problemas [32]. Um AG resolve o seguinte tipo de problema:

$$\text{Minimizar } f(x); x \in \Omega,$$

onde $x \in \mathbb{R}^n$ e Ω é um conjunto de restrições bem gerais, podendo ser não-lineares, restrições de lista, ou ainda restrições estocásticas.

Um AG consegue resolver problemas mais gerais que técnicas de otimização clássica.

Os AGs, assim como os outros métodos modernos de otimização, são meta-heurísticas (convergência para o ponto ótimo não é garantida) e diferem dos métodos tradicionais de busca em, principalmente, quatro aspectos:

1. Trabalham com uma codificação do conjunto de parâmetros, e não com os próprios;
2. Trabalham com uma população, e não com um único ponto;
3. Utilizam informações de custo e recompensa, em contraposição ao cálculo de derivadas ou outras informações auxiliares;
4. Utilizam também informações probabilísticas e não somente determinísticas.

Ao aplicar um AG em um problema, deve-se levantar algumas características a respeito do problema:

1. O espaço de busca (possíveis soluções) do problema deve estar delimitado em uma certa faixa de valores;
2. Deve ser possível a definição de uma função de aptidão (*fitness*) que indique o quão boa ou não é uma solução. Serve de métrica para o problema;
3. As soluções devem poder ser codificadas de tal forma a facilitar a sua implementação em linguagem computacional.

De uma forma geral, um AG trabalha da seguinte forma [32]:

1. Primeiramente, deve-se definir uma função de aptidão, que é a representante da função objetivo no problema de otimização;
2. Gera-se uma população formada por um conjunto aleatório de indivíduos que são possíveis soluções do problema;
3. Avaliação da população: Para cada indivíduo dá-se uma nota, isto é, calcula-se o valor de sua função fitness, que reflete sua habilidade de adaptação ao ambiente em questão;

4. Forma-se um novo conjunto com parte dos indivíduos mais aptos e outros novos indivíduos enquanto outros (velhos indivíduos) são descartados;
5. Os membros mantidos pela seleção anterior podem sofrer modificações através de mutações e cruzamentos (*crossover*) ou recombinação genética, gerando descendentes para a nova geração;
6. Uma nova geração é formada, repetindo-se o ciclo.

Existem, basicamente, três tipos de codificação para um AG [32]: binária (utiliza-se de cadeias (*strings*) de bits), real (trabalha diretamente com valores reais) e inteira (trabalha com valores inteiros). O presente trabalho irá considerar a codificação real.

4.2.2- Etapas de um AG

Etapa 1: Definição da função de aptidão (*fitness*)

Nessa etapa, uma função de aptidão, que atribui uma medida a cada membro da população para o problema em questão, é definida. A função aptidão traduz a função objetivo em um problema de otimização.

Etapa 2: Criação da população

Cria-se uma população com n indivíduos, ou cromossomos, como também podem ser chamados os componentes da população. Todos eles são possíveis soluções para o problema. Em geral, recebem valores aleatórios dentro de um conjunto chamado de região viável, porém, dependendo do conhecimento da situação pelo projetista, podem receber valores direcionados de modo a facilitar o funcionamento do algoritmo.

Etapa 3: Avaliação da população

Cada cromossomo é medido pela função de aptidão. De acordo com esses valores os indivíduos podem ser classificados quanto ao nível de aptidão à situação problema.

Etapa 4: Seleção dos indivíduos

Nesta fase, os indivíduos da atual geração que se mostraram mais aptos (de acordo com seus respectivos valores da função de aptidão), são utilizados para gerar uma nova população. Tal processo é realizado, geralmente, através de três mecanismos:

- a) Amostragem direta: O conjunto de indivíduos representantes da geração é escolhido com base em um critério fixo;
- b) Amostragem aleatória simples ou equiprovável: Todos os elementos possuem a mesma probabilidade de serem escolhidos;
- c) Amostragem estocástica: A chance de cada indivíduo é diretamente proporcional ao grau de seu fitness;

Durante a seleção dos indivíduos, alguns dos melhores indivíduos podem ser recolocados para a próxima geração, isto é o elitismo. O elitismo é uma técnica bastante utilizada para garantir uma convergência uniforme de um AG. Entretanto, deve-se

atentar para que este operador não seja utilizado de forma exagerada, pois, dessa forma, o algoritmo pode convergir prematuramente, atingindo assim um mínimo local [32].

Etapa 5: Cruzamento (*crossover*)

Na codificação real, são utilizados operadores de cruzamento aritmético para cruzar os cromossomos. Alguns exemplos de operadores são: média simples ou média geométrica. Também pode ser utilizado outro método heurístico.

O cruzamento simples, no qual dois indivíduos são escolhidos aleatoriamente, geram cromossomos filhos (*offspring*: componentes da geração seguinte) com metade dos genes de cada um dos dois pais (componentes da geração atual). Esse tipo de cruzamento é baseado na média simples, dada por

$$C = \frac{P_1 + P_2}{2}. \quad (4.1)$$

$C_i = \text{Valor do cromossomo filho}$; $P_i = \text{Valores dos cromossomos pais}$

De forma similar ocorre o cruzamento geométrico, porém esse é baseado na média geométrica, definida por

$$C = \sqrt{P_1 P_2}. \quad (4.2)$$

$C_i = \text{Valor do cromossomo filho}$; $P_i = \text{Valores dos cromossomos pais}$

Já o cruzamento aritmético é regulado pelas equações abaixo, que são combinações lineares convexas dos pais

$$C_1 = \beta P_1 + (1 - \beta)P_2 \text{ e } C_2 = (1 - \beta)P_1 + \beta P_2. \quad (4.3)$$

$\beta \in U(0,1)$; $C_i = \text{Valor do cromossomo filho}$, $P_i = \text{Valor dos pais}$

No cruzamento heurístico, deve-se conhecer os valores da função *fitness* dos pais. O filho é gerado a partir de uma interpolação linear entre os pais usando a informação da função de aptidão, assim favorecendo o pai com maior *fitness*. Tal cruzamento é gerido pela seguinte fórmula:

$$C = P_1 + r(P_2 - P_1) ; f(P_1) > f(P_2) \text{ e } 0 < r < 1. \quad (4.4)$$

$C_i = \text{Valor do cromossomo filho}$, $P_i = \text{Valor dos pais}$

Etapa 6: Mutação

É a etapa/operador cuja função é alterar, probabilisticamente, um ou mais componentes da estrutura genética de um cromossomo, logo após o cruzamento. A mutação é importante para garantir a diversidade, isto faz com que qualquer ponto do espaço de busca tenha alguma probabilidade de ser escolhido.

Na codificação real existem várias maneiras de se realizar a mutação:

- a) Mutação uniforme: Substitui-se o gene (estrutura primária de um cromossomo) selecionado por outro gene gerado aleatoriamente, segundo uma distribuição uniforme, entre os limites mínimo e máximo permitidos;

- b) Mutaç o gaussiana: similar   uniforme, por m, nesse caso, usa-se a distribui o gaussiana;
- c) Mutaç o n o-uniforme: Substitui-se um gene por um n mero extra do de uma distribui o n o-uniforme.

4.2.3- Par metros Gen ticos

O comportamento de um AG   influenciado por v rios par metros, os mais comuns s o:

- a) Tamanho da popula o: Estabelece o n mero de cromossomos da popula o. Se for muito baixo, o desempenho pode ser comprometido. Se for muito alto, h  a necessidade de maiores recursos computacionais, acarretando assim em um tempo maior para a execu o do algoritmo;
- b) Taxa de cruzamento: Controla a rapidez com que novas estruturas s o introduzidas na popula o. Se for muito baixa, o algoritmo pode se tornar lento, e, caso seja muito alta, grande parte da popula o pode ser substituída, aumentando as chances de se perder estruturas (genes) de alta aptid o;
- c) Taxa de muta o: Determina a probabilidade com que uma muta o ocorrer . Recomenda-se para a maior parte dos problemas, uma taxa de 1% [33]. Caso essa taxa seja muito alta, aumentam-se as chances de se perder uma boa (ou  tima) solu o para o problema;
- d) Intervalo da gera o: Determina a porcentagem da gera o substituída na gera o seguinte. Se for muito alta, muitos cromossomos ser o substituídos, aumentando as chances de se perder indiv duos com alta aptid o. Se for muito baixa, o algoritmo pode se tornar muito lento.

4.3- M todo dos M nimos Quadrados Lineares (MQL)

A origem do MQL se d  no problema de ajuste de curvas a partir de um conjunto de pontos. Seja ent o um conjunto de pontos $(x_1, f(x_1)), (x_2, f(x_2)), \dots, (x_m, f(x_m))$ com x_1, x_2, \dots, x_m pertencentes a um intervalo $[a, b]$. O problema de ajuste consiste em escolher n fun es $g_1(x), g_2(x), \dots, g_n(x)$ cont nuas em $[a, b]$, obter constantes $\alpha_1, \alpha_2, \dots, \alpha_n$ tais que a fun o $\varphi(x) = \alpha_1 g_1(x) + \alpha_2 g_2(x) + \dots + \alpha_n g_n(x)$ se aproxime ao m ximo de $f(x)$ [34]. Existem v rios crit rios de verifica o da proximidade ente $\varphi(x)$ e $f(x)$, um deles   o desvio, definido como a diferen a ponto a ponto entre as fun es $f(x)$ e $\varphi(x)$, isto  , $d_k = f(x_k) - \varphi(x_k), k = 1, 2, \dots, m$.

Diz-se que este tipo de modelo matem tico   linear pelo fato de os coeficientes $\alpha_j, j = 1, 2, \dots, n$ aparecerem linearmente, embora as fun es $g_j(x), j = 1, 2, \dots, n$ possam ser n o lineares. Deste modo, tem-se liberdade na escolha das fun es $g_j(x)$ de acordo com o problema a ser representado/ajustado. Esta escolha em geral se d  a partir

de fundamentos teóricos do experimento em estudo, ou seja, que tipo de função, teoricamente, representa o problema [34].

O método do MQL consiste em uma metodologia para encontrar os coeficientes α_j a partir de um ajuste linear da função $f(x)$. Ela se baseia na minimização da soma dos quadrados dos desvios d_k , por isso o nome Mínimos Quadrados Lineares. Este é um método válido pelo fato de que se d_k^2 é mínimo, tem-se que d_k também é mínimo.

Portanto, dentro do critério dos quadrados mínimos, os coeficientes α_k que fazem com que $\varphi(x)$ se aproxime ao máximo de $f(x)$ são os que minimizam a função em (4.5).

$$\begin{aligned} F(\alpha_1, \dots, \alpha_n) &= \sum_{k=1}^m [f(x_k) - \varphi(x_k)]^2 \\ &= \sum_{k=1}^m [f(x) - (\alpha_1 g_1(x_k) + \alpha_2 g_2(x_k) + \dots + \alpha_n g_n(x_k))]^2 \end{aligned} \quad (4.5)$$

Do cálculo diferencial, tem-se que, para encontrar os mínimos de uma função, deve-se primeiramente encontrar os pontos críticos, ou seja, os $(\alpha_1, \alpha_2, \dots, \alpha_n)$ tais que

$$\left. \frac{\partial F}{\partial \alpha_j} \right|_{(\alpha_1, \alpha_2, \dots, \alpha_n)} = 0, \quad j = 1, 2, \dots, n. \quad (4.6)$$

Calculando as derivadas parciais para cada $j = 1, 2, \dots, n$, tem-se

$$\left. \frac{\partial F}{\partial \alpha_j} \right|_{(\alpha_1, \alpha_2, \dots, \alpha_n)} = 2 \sum_{k=1}^m [f(x) - (\alpha_1 g_1(x_k) + \dots + \alpha_n g_n(x_k))] [-g_j(x_k)]. \quad (4.7)$$

Impondo a condição em (4.6), obtém-se

$$\left. \frac{\partial F}{\partial \alpha_j} \right|_{(\alpha_1, \alpha_2, \dots, \alpha_n)} = \sum_{k=1}^m [f(x) - (\alpha_1 g_1(x_k) + \dots + \alpha_n g_n(x_k))] [-g_j(x_k)] = 0. \quad (4.8)$$

Escrevendo (4.7) para cada valor de j e organizando de maneira conveniente [34], tem-se um sistema linear (da forma $Ax = b$) com n equações e n incógnitas: $\alpha_1, \alpha_2, \dots, \alpha_n$. Este sistema é dado por (4.9).

$$\begin{cases} a_{11}\alpha_1 + a_{12}\alpha_2 + \dots + a_{1n}\alpha_n = b_1 \\ a_{21}\alpha_1 + a_{22}\alpha_2 + \dots + a_{2n}\alpha_n = b_2 \\ \vdots \\ a_{n1}\alpha_1 + a_{n2}\alpha_2 + \dots + a_{nn}\alpha_n = b_n \end{cases} \quad (4.9)$$

Com $A = (a_{ij})$ tal que $a_{ij} = \sum_{k=1}^m g_j(x_k)g_i(x_k) = a_{ji}$ (ou seja, a matriz A é simétrica). Tem-se também que

$$\begin{aligned} \alpha &= (\alpha_1, \alpha_2, \dots, \alpha_n)^t \text{ e } b = (b_1, b_2, \dots, b_n)^t \text{ tal que} \\ b_i &= \sum_{k=1}^m f(x_k)g_i(x_k). \end{aligned} \quad (4.10)$$

Em suma, o MQL consiste em resolver o sistema mostrado em (4.9) para as variáveis α_j . Neste trabalho, utiliza-se o MQL para obter a tendência linear dos dados tratados. Tal procedimento é aqui chamado de “horizontalização” e é explicado no capítulo 6.

4.4 – Considerações Finais

Do exposto no capítulo, têm-se condições de compreender o funcionamento básico de um AG e de entender o MQL. Além disso, algumas de suas características (válidas para ambas as técnicas de ajuste/otimização), como a robustez e a facilidade em se adaptar em uma grande variedade de problemas vão de encontro à proposta do trabalho, uma modelagem simples e que também possa ser aplicada em várias situações. Esta modelagem proposta baseia-se na teoria de séries temporais, tema do próximo capítulo.

Capítulo 5 - Tópicos em Probabilidade, Processos Estocásticos e Séries Temporais

5.1- Considerações Iniciais

Neste capítulo os tópicos básicos de probabilidade, processos estocásticos e teoria de séries temporais necessários ao entendimento deste trabalho são expostos. Isto se faz necessário devido ao papel fundamental que a teoria de séries temporais exerce neste trabalho, pois é uma das ferramentas para justificar os resultados obtidos.

5.2- Tópicos Sobre Teoria da Probabilidade

Neste tópico alguns conceitos importantes para este trabalho acerca da teoria de probabilidade serão tratados. Servindo assim de introdução aos tópicos sobre processos estocásticos e séries temporais.

5.2.1- Espaço Amostral

É o conjunto onde todas as possibilidades acerca de um dado experimento são agrupadas. Em geral denotado por S ou Ω . Qualquer subconjunto de S é chamado de subespaço amostral, incluído o próprio S e o conjunto vazio $\{\emptyset\}$. Uma ocorrência, ou conjunto de ocorrências equivalentes, dentro do espaço amostral é chamada de evento [35].

5.2.2- Axiomas da Probabilidade

Seja um evento A . O número $P(A)$, denominado de probabilidade do evento A , é associado a A . Esta associação segue três condições, chamadas de axiomas da probabilidade [35]:

$$P(A) \geq 0 \quad (5.1)$$

$$P(S) = 1 \quad (5.2)$$

$$\text{Se } A \cap B = \{\emptyset\}, \text{ então } P(A \cup B) = P(A) + P(B) \quad (5.3)$$

A interpretação mais comum para $P(A)$ é como a frequência de um dado acontecimento. Seja n_A o número de ocorrências de A e seja n o número total de ocorrências, dentre todos os eventos possíveis de um experimento [35]. Então a probabilidade de A , denotada por $P(A)$ é dada por

$$P(A) = \frac{n_A}{n} \quad (5.4)$$

5.3- Variável Aleatória e Processos Estocásticos

5.3.1- Variável Aleatória (VA)

5.3.1.1- Definição

Seja um experimento e seu espaço amostral S . Associar um valor $\mathbf{x}(\zeta)$ a cada saída ζ do experimento equivale a criar uma função que, sob certas condições, é chamada de variável aleatória (VA). Tais condições são especificadas em (5.5) e (5.6) [35].

O conjunto $\{\mathbf{x} \leq x\}$ é um evento para todo x (5.5)

As probabilidades dos eventos $\{\mathbf{x} = \infty\}$ e $\{\mathbf{x} = -\infty\}$ são iguais a zero, ou seja, (5.6)

$$P\{\mathbf{x} = \infty\} = 0 \text{ e } P\{\mathbf{x} = -\infty\} = 0$$

5.3.1.2- Função Distribuição de Probabilidade (FD) e Função Densidade de Probabilidade (fdp)

A FD da VA \mathbf{x} é a função

$$F(x) = P\{\mathbf{x} \leq x\}, \quad (5.7)$$

definida para todo x de $-\infty$ a $+\infty$ [35].

5.3.1.3- Função Densidade de Probabilidade (fdp)

A fdp da VA \mathbf{x} é a derivada da FD de \mathbf{x} [35], isto é

$$f(x) = \frac{dF(x)}{dx}. \quad (5.8)$$

5.3.1.4- Momentos

5.3.1.4.1- Média ou Valor Esperado ($E\{\mathbf{x}\}$)

A média, ou valor esperado, de uma VA \mathbf{x} é dada pela integral

$$E\{\mathbf{x}\} = \int_{-\infty}^{+\infty} xf(x)dx. \quad (5.9)$$

Denota-se a média de \mathbf{x} também como μ_x , ou simplesmente μ [35]. A média é o momento de primeira ordem

5.3.1.4.2- Variância (σ_x^2)

A variância de uma VA x é definida como a média quadrática da variação de \mathbf{x} em relação ao seu valor médio μ_x [35]. Assim,

$$\sigma_x^2(x) = E\{(x - \mu)^2\} = \int_{-\infty}^{+\infty} (x - \mu)^2 f(x) dx \quad (5.10)$$

A variância é o momento de segunda ordem.

5.3.1.4.3- Covariância

Sejam \mathbf{x} e \mathbf{y} duas VAs, então, define-se a covariância entre \mathbf{x} e \mathbf{y} como [35]:

$$C_{xy} = E\{(\mathbf{x} - \mu_x)(\mathbf{y} - \mu_y)\} = E\{\mathbf{xy}\} - E\{\mathbf{x}\}E\{\mathbf{y}\}. \quad (5.11)$$

5.3.2- Processo Estocástico

5.3.2.1- Definição

Como explicitado em 5.2.1.1, uma VA é uma regra para associar a cada saída ζ um valor $\mathbf{x}(\zeta)$. Um processo estocástico é uma regra para associar a cada valor ζ uma função $\mathbf{x}(t, \zeta)$, do tempo [35]. Portanto, um processo estocástico é uma família de funções temporais com parâmetro ζ , ou, de forma equivalente, uma função de t e ζ [35]. O domínio ζ agrega todos os experimentos possíveis e o domínio t agrega a variação no tempo. Este último pode ter uma variação contínua ou uma simplificação que leva ao caso de tempo discreto (forma mais utilizada).

Existem quatro principais interpretações para um processo estocástico [35]:

- 1) Uma família de funções $\mathbf{x}(t, \zeta)$. Neste caso, uma função de t e ζ ;
- 2) Uma função temporal, apenas. Assim, t é variável e ζ fixo;
- 3) Para ζ fixo e t variável, tem-se uma função que representa o estado do processo em um tempo t ;
- 4) Com ambas as variáveis fixas, tem-se um número.

Neste trabalho, estudar-se-á a interpretação 2), ou seja, os dados e o modelo apresentado tratar-se-ão de modelos variáveis no tempo, ou simplesmente de modelos variáveis em uma dimensão apenas, unidimensionais. As séries temporais, interpretação 2), são um caso particular de um processo estocástico.

Pode-se considerar um processo estocástico como uma família de variáveis aleatórias. Uma para cada valor de t . As notações para indicar uma VA e suas FD e fd, são as mesmas já citadas nos subtópicos em 5.3.1. O mesmo é válido para os conceitos de média, variância e covariância.

Resta então a representação de distribuição/densidade do processo $\mathbf{x}(t)$ de ordem n . A distribuição de ordem n do processo $\mathbf{x}(t)$ é dada por

$$F(x_1, \dots, x_n; t_1, \dots, t_n) = P\{\mathbf{x}(t_1) \leq x_1, \dots, \mathbf{x}(t_n) \leq x_n\}. \quad (5.12)$$

Isto equivale à distribuição conjunta das VAs $\mathbf{x}(t_1), \dots, \mathbf{x}(t_n)$ [35].

Consequentemente, a n -ésima densidade correspondente é

$$f(x_1, \dots, x_n; t_1, \dots, t_n) = \frac{\partial^n F(x_1, \dots, x_n; t_1, \dots, t_n)}{\partial x_1 \dots \partial x_n}. \quad (5.13)$$

No subtópico 5.3.2.2, conceitos dos momentos de segunda ordem autocorrelação e autocovariância são expostos.

5.3.2.2- Autocorrelação e Autocovariância

5.3.2.2.1- Autocorrelação

A autocorrelação $R(t_1, t_2)$ de $\mathbf{x}(t)$ é o valor esperado do produto $\mathbf{x}(t_1) \mathbf{x}(t_2)$, isto é

$$R(t_1, t_2) = E\{\mathbf{x}(t_1)\mathbf{x}(t_2)\} = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} x_1 x_2 f(x_1, x_2; t_1 t_2) dx_1 dx_2 \quad (5.14)$$

Em um dado instante de tempo $t_1 = t_2 = t$, tem-se o valor médio de intensidade do processo $\mathbf{x}(t)$ [35].

$$R(t, t) = E\{\mathbf{x}^2(t)\} \quad (5.15)$$

5.3.2.2.2- Autocovariância

A autocovariância $C(t_1, t_2)$ de $\mathbf{x}(t)$ é a covariância das VAs $\mathbf{x}(t_1)$ e $\mathbf{x}(t_2)$

$$C(t_1, t_2) = R(t_1, t_2) - \mu(t_1)\mu(t_2). \quad (5.16)$$

O valor em $t_1 = t_2 = t$ é a variância de $\mathbf{x}(t)$ [35].

5.3.2.2.3- Coeficiente de Correlação de um Processo $\mathbf{x}(t)$

Definido como a razão [35]

$$\rho(t_1, t_2) = \frac{C(t_1, t_2)}{\sqrt{C(t_1, t_1)C(t_2, t_2)}}. \quad (5.17)$$

5.3.2.3- Estacionariedade

Existem dois tipos de estacionariedade para um processo estocástico: Estacionariedade no Sentido Estrito (ESE) e Estacionariedade no Senido Amplo (ESA) [35].

5.3.2.3.1- Estacionariedade no Sentido Estrito (forte ou de primeira ordem)

Um processo estocástico é ESE se as suas características estatísticas não se alteram com uma mudança na origem. Isto equivale a dizer que os processos $\mathbf{x}(t)$ e $\mathbf{x}(t + c)$ tem as mesmas estatísticas para qualquer valor de c [35]. Da definição, tem-se que a densidade de ordem n de um processo ESE obedece à (5.18)

$$f(x_1, \dots, x_n; t_1, \dots, t_n) = f(x_1, \dots, x_n; t_1 + c, \dots, t_n + c) \quad (5.18)$$

para qualquer valor de c .

De (5.18), segue que $f(x; t) = f(x; t + c)$ para qualquer c . Portanto, a densidade de primeira ordem de $\mathbf{x}(t)$ é independente de t [35]:

$$f(x; t) = f(x). \quad (5.19)$$

O mesmo é válido para densidades de ordem maior.

5.3.2.3.2- Estacionariedade no Sentido Amplo (fraca, de segunda ordem ou estacionária em covariância)

Um processo estocástico $\mathbf{x}(t)$ é dito ESA se sua média é constante [35]

$$E\{\mathbf{x}(t)\} = \mu. \quad (5.20)$$

E sua autocorrelação depende somente da variação de tempo $\tau = t_1 - t_2$ [35]:

$$E\{\mathbf{x}(t + \tau)\mathbf{x}^*(t)\} = R(\tau). \quad (5.21)$$

Vale destacar que, o processo conjugado $\mathbf{x}^*(t)$, no caso de processos estocásticos reais (tratados nesse trabalho), equivale a $\mathbf{x}(t)$.

Como τ é a distância de t a $t + \tau$, a função $R(\tau)$ pode ser escrita em uma forma simétrica

$$R(\tau) = E\left\{\mathbf{x}\left(t + \frac{\tau}{2}\right)\mathbf{x}^*\left(t - \frac{\tau}{2}\right)\right\}. \quad (5.22)$$

Em particular

$$R(0) = E\{|\mathbf{x}(t)|^2\}. \quad (5.23)$$

Portanto, a intensidade média de um processo estacionário independe de t e é igual a $R(0)$ [35].

5.3.2.4- Ergodicidade

Um processo ergódico é aquele em que apenas uma realização é suficiente para obter todos os seus dados estatísticos. Isto quer dizer que qualquer realização do processo tem as mesmas características estatísticas.

Sendo satisfeitas as condições de ergodicidade de um processo, pode-se, por exemplo, encontrar a média (um dos problemas mais comuns na análise de séries temporais) de um processo analisando apenas uma realização [35].

5.4- Séries Temporais

5.4.1- Definição e Considerações Gerais

Uma série temporal é qualquer conjunto de observações ordenadas no tempo [36]. Este mesmo conceito pode ser estendido a qualquer conjunto de observações dependentes de apenas uma variável, caso no qual se encaixa este trabalho.

Existem, basicamente, dois enfoques acerca da análise de séries temporais. Ambos objetivam a criação de modelos para as respectivas séries. Um deles consiste em analisar as observações no domínio do tempo de modo a construir um modelo paramétrico (com um número finito de parâmetros). O outro corresponde à análise da série no domínio da frequência e os modelos oriundos são modelos não paramétricos [36]. Este trabalho tem como objetivo a construção de um modelo paramétrico e a análise é realizada no domínio correspondente ao tempo.

Pode-se considerar como série temporal uma observação de um processo estocástico [31, 32].

Existem quatro principais objetivos da análise de séries temporais [36]:

- 1) Investigar o mecanismo gerador da série, isto é, o processo estocástico;
- 2) Fazer previsões de valores futuros da série (objetivo deste trabalho);
- 3) Descrever o comportamento da série (construção de gráficos, histogramas, verificação de tendências, componentes sazonais, etc.);
- 4) Procurar periodicidades relevantes nos dados. A análise espectral pode ser de bastante valia nesse caso.

Uma das suposições mais frequentes a respeito de uma série temporal é a de que ela é estacionária, ou seja, que o processo estocástico gerador seja estacionário. Quando se tem uma série não estacionária, deve-se transformar os dados originais até que estes configurem uma série estacionária [36].

Uma série temporal tem três componentes principais, segundo os métodos tradicionais de decomposição de séries [37]:

- a) Componente de Tendência: Tipo de variação onde a série flutua em torno de uma curva média [11]. Os tipos mais comuns são tendência linear, quadrática e exponencial, como pode ser visto nas figuras 5.1(a), (b) e (c) respectivamente;

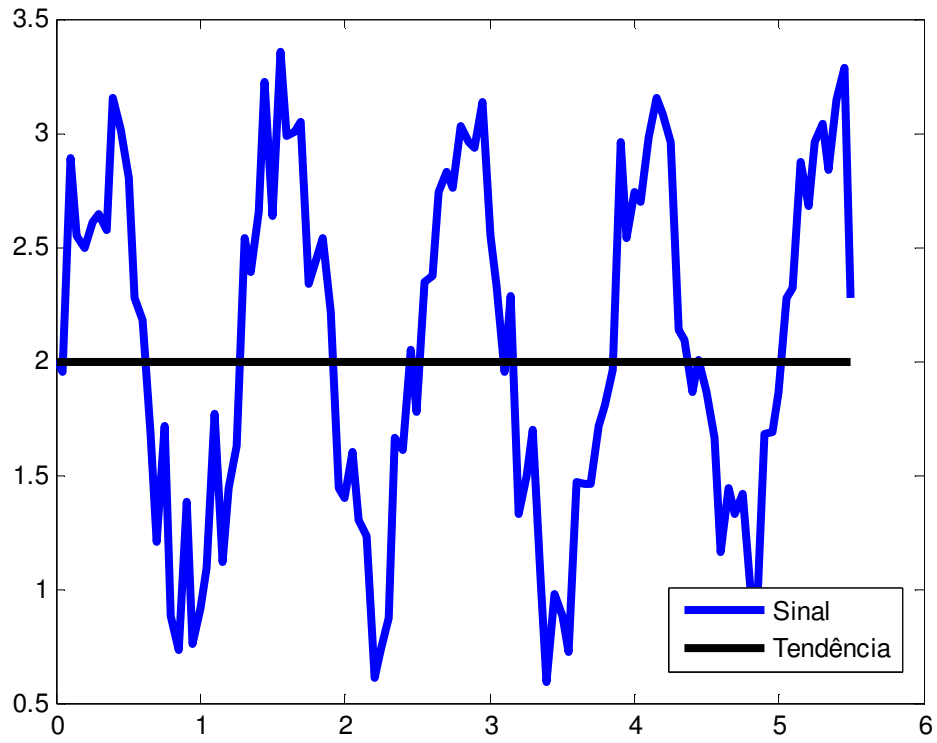


Fig. 5.1(a) Tendência Constante




Fig. 5.1(b) Tendência Linear

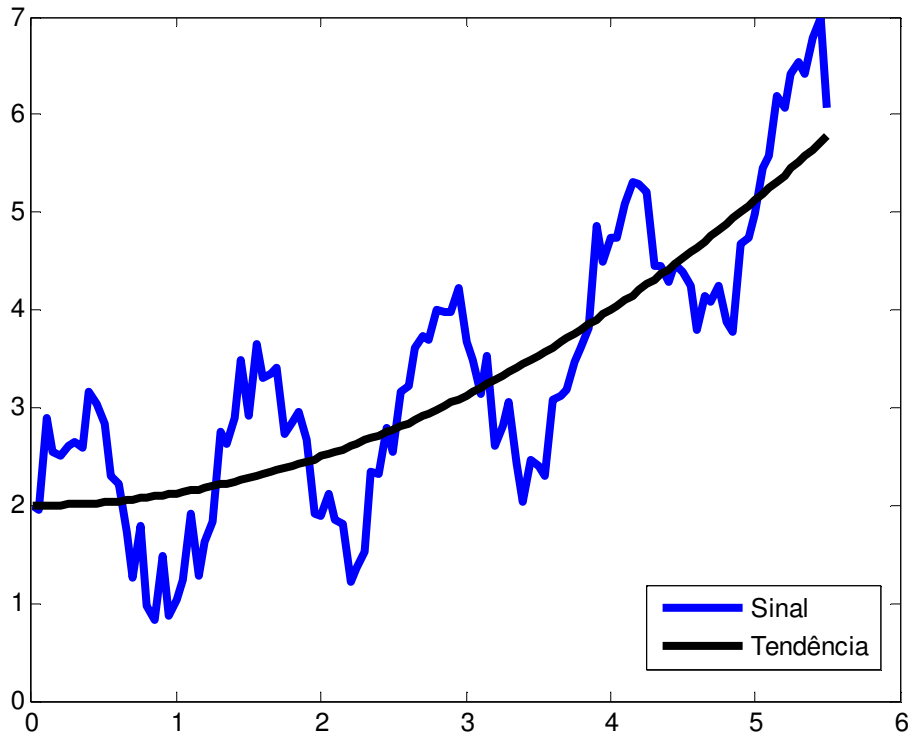


Fig. 5.1(c) Tendência Quadrática

- b) Componente Sazonal: Tipo de variação periódica exibida por certas séries. Por exemplo, o aumento de vendas de passagens de avião durante o verão e o aumento de vendas durante o natal [36];
- c) Componente Aleatória: Flutuações irregulares obtidas após a remoção das outras componentes da série [11].

5.5- Operadores de Transição de Estado

Neste subtópico, os operadores algébricos utilizados nos próximos tópicos e subtópicos serão apresentados. Deve-se considerar, daqui em diante, Z uma série temporal e Z_t seu valor no instante de tempo t .

5.5.1- Operador Translação para o Passado (Atraso)

Denotado por B e definido como:

$$BZ_t = Z_{t-1}; B^m Z_t = Z_{t-m}. \quad (5.24)$$

5.5.2- Operador Translação para o Futuro (Adiantamento)

Denotado por F e definido como:

$$FZ_t = Z_{t+1}; F^m Z_t = Z_{t+m}. \quad (5.25)$$

5.5.3- Operador Diferença Finita Ascendente

Denotado por Δ e definido como:

$$\Delta Z_t = Z_t - Z_{t-1} = (1 - B)Z_t. \quad (5.26)$$

Segue-se que $\Delta = 1 - B$.

5.5.4- Operador Soma

Denotado por S e definido como:

$$SZ_t = \sum_{j=0}^{+\infty} Z_{t-j} = Z_t + Z_{t-1} + \dots = (1 + B + B^2 + \dots)Z_t \quad (5.27)$$

$$SZ_t = (1 - B)^{-1}Z_t = \Delta^{-1}Z_t \quad \Rightarrow \quad S = \Delta^{-1}$$

5.6- Modelos Paramétricos Estacionários para Séries Temporais

Neste subtópico alguns dos modelos utilizados na análise de séries temporais serão explicitados, juntamente com o(s) parâmetro(s) de teste adotado(s) neste trabalho (com exceção às respectivas funções de densidade espectral, não utilizadas neste trabalho). Serão tratados apenas os modelos estacionários, visto que, neste estudo, o processo estudado é considerado estacionário e o modelo proposto também se enquadra nesta categoria.

5.6.1- Processo Linear Geral

Os processos/modelos abordados neste subtópico são casos particulares do processo linear geral, ou modelo de filtro linear. Este modelo supõe que a série temporal seja gerada através de um filtro linear, cuja entrada é o ruído branco (ou ruído gaussiano, uma componente aleatória que segue uma distribuição do tipo gaussiana) [36], como na figura 5.2.




Fig. 5.2 Filtro linear com entrada a_t e saída Z_t e função de transferência $\psi(B)$

Formalmente, tem-se que

$$Z_t = \mu + a_t + \psi_1 a_{t-1} + \psi_2 a_{t-2} + \dots = \mu + \psi(B)a_t, \quad (5.28)$$

$$\text{Com } \psi(B) = 1 + \psi_1 B + \psi_2 B^2 + \dots$$

$\psi(B)$ é a função de transferência do filtro e μ é um parâmetro determinando o nível da série.

De (5.28), tem-se um processo linear discreto, onde valem:

$$\begin{aligned} E(a_t) &= 0, \forall t, \\ Var(a_t) &= \sigma_a^2, \forall t \\ E(a_t a_s) &= 0, s \neq t. \end{aligned} \quad (5.29)$$

Chamando $\tilde{Z}_t = Z_t - \mu$, tem-se que

$$\tilde{Z}_t = \psi(B)a_t \quad (5.30)$$

Se a sequência de pesos $\{\psi_j, j \geq 1\}$ for finita (ou infinita) e convergente, o filtro é estável (somável) e Z_t é estacionária. Nesse caso, μ é a média do processo.

Sabe-se também que [36]:

$$\pi(B) = \psi^{-1}(B) \quad (5.31)$$

Adicionalmente, pode ser demonstrado [37] que, se a série $\psi(B)$ convergir para $|B| \leq 1$ o processo linear será estacionário e se $\pi(B)$ convergir para $|B| \leq 1$ este mesmo processo será invertível.

5.6.2- Modelos Auto-regressivos (AR)

Um modelo auto-regressivo de ordem p , denotado por $AR(p)$ é um modelo linear da forma

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \phi_2 \tilde{Z}_{t-2} + \dots + \phi_p \tilde{Z}_{t-p} + a_t. \quad (5.32)$$

Com $\phi(B) = \pi(B)$, isto é, $\phi_j = \pi_j$ [36].

Definindo o operador auto-regressivo estacionário de ordem p como [36]

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p. \quad (5.33)$$

Pode-se escrever

$$\phi(B)\tilde{Z}_t = a_t. \quad (5.34)$$

5.6.2.1- Estacionariedade e Invertibilidade

Para que o modelo $AR(p)$ seja estacionário, é necessário que sua equação característica $\phi(B) = 0$ tenha raízes fora do círculo unitário. Dessa forma, tem-se que a condição de estacionariedade exposta para o modelo de filtro linear, $\psi(B) \rightarrow |B| \leq 1$, é satisfeita. A demonstração desse fato pode ser encontrada em [36]. Já para a invertibilidade, não há parâmetros para assegurar que um modelo $AR(p)$ seja invertível.

5.6.2.2- Função de Autocorrelação (fac)

Ao multiplicar ambos os lados de (5.32) por \tilde{Z}_{t-j} e encontrando o valor esperado [36], obtém-se

$$E(Z_t \tilde{Z}_{t-j}) = \phi_1 E(\tilde{Z}_{t-1} \tilde{Z}_{t-j}) + \phi_2 E(\tilde{Z}_{t-2} \tilde{Z}_{t-j}) + \dots + \phi_p E(\tilde{Z}_{t-p} \tilde{Z}_{t-j}) + E(a_t \tilde{Z}_{t-j}) \quad (5.35)$$

De (5.32), Z_{t-j} envolve apenas ruídos até a_{t-j} , não-correlacionados com a_t , $E(a_t Z_{t-j}) = 0$, $j > 0$, resultando em

$$\gamma_j = \phi_1 \gamma_{j-1} + \phi_2 \gamma_{j-2} + \dots + \phi_p \gamma_{j-p}, \quad 0 < j \leq p. \quad (5.36)$$

Dividindo por $\gamma_0 = Var(Z_t)$, tem-se

$$\rho_j = \phi_j \rho_{j-1} + \phi_2 \rho_{j-2} + \dots + \phi_p \rho_{j-p}, \quad 0 < j \leq p. \quad (5.37)$$

Para cada valor de j tem-se uma equação. Esse conjunto de equações é chamado de equações de Yule-Walker. Então, para encontrar os valores ρ_j , isto é, os coeficientes de correlação, deve-se resolver um sistema linear composto das equações de Yule-Walker. Este sistema, em forma matricial, é escrito na forma

$$\begin{bmatrix} 1 & \rho_1 & \dots & \rho_{p-1} \\ \rho_1 & 1 & \dots & \rho_{p-2} \\ \vdots & \dots & \ddots & \vdots \\ \rho_{p-1} & \rho_{p-2} & \dots & 1 \end{bmatrix} \begin{bmatrix} \phi_1 \\ \phi_2 \\ \vdots \\ \phi_p \end{bmatrix} = \begin{bmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_p \end{bmatrix} \quad (5.38)$$

Uma forma muito utilizada para resolver (5.38), é o algoritmo de Durbin-Levinson, que não será mostrado aqui, devido a não ter sido utilizado neste trabalho na resolução de (5.38). Como resultado, obtém-se os valores ϕ_j , equivalentes aos coeficientes do modelo $AR(p)$.

5.6.3- Modelos de Médias Móveis (MA)

Um modelo de médias móveis de ordem q , denotado por $MA(q)$ é um modelo da forma

$$Z_t = \mu + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}. \quad (5.39)$$

Com $\theta(B) = \psi(B)$, isto é, $\theta_j = \psi_j$ [36].

Sendo $\tilde{Z}_t = Z_t - \mu$, tem-se

$$\tilde{Z}_t = (1 - \theta_1 B - \dots - \theta_q B^q) a_t = \theta(B) a_t. \quad (5.40)$$

Com $\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$ sendo o operador de médias móveis de ordem q .

5.6.3.1- Estacionariedade e Invertibilidade

Dado que $\psi(B) = \theta(B)$, não há restrições sobre os parâmetros θ_j para que o processo seja estacionário. Já considerando a invertibilidade, basta que as raízes da equação característica $\theta(B) = 0$ estejam fora do círculo unitário [36].

5.6.3.2- Função de Autocorrelação (fac)

Pode ser demonstrado [36], utilizando a mesma ideia que em 5.6.2.2 que a fac de um modelo $MA(q)$ é

$$\rho_j = \begin{cases} \frac{-\theta_j + \theta_1\theta_{j+1} + \theta_2\theta_{j+2} + \dots + \theta_{q-j}\theta_q}{1 + \theta_1^2 + \theta_2^2 + \theta_3^2 + \dots + \theta_q^2}, & j = 1, \dots, q \\ 0, & j > q \end{cases} \quad (5.41)$$

5.6.4- Modelos Auto-regressivos e de Médias Móveis (ARMA)

É a junção dos modelos $AR(p)$ e $MA(q)$. Chama-se de modelo $ARMA(p, q)$ e define-se como

$$\tilde{Z}_t = \phi_1\tilde{Z}_{t-1} + \dots + \phi_p\tilde{Z}_{t-p} + a_t - \theta_1a_{t-1} - \dots - \theta_qa_{t-q}. \quad (5.42)$$

Sendo $\phi(B)$ e $\theta(B)$ os operadores auto-regressivos e de médias móveis, respectivamente, pode-se escrever (5.42) na forma compacta [36]

$$\phi(B)\tilde{Z}_t = \theta(B)a_t, \quad (5.43)$$

5.6.4.1- Estacionariedade e Invertibilidade

Do exposto sobre os modelos $AR(p)$ e $MA(q)$, tem-se que o modelo $ARMA(p, q)$ é estacionário se todas as raízes de $\phi(B) = 0$ estiverem fora do círculo unitário e invertível se todas as raízes de $\theta(B) = 0$ não estiverem contidas no círculo unitário.

5.6.4.2- Função de Autocorrelação (fac)

Novamente, aplicando a mesma ideia que em 5.6.2.2 [36], pode-se deduzir que a fac do modelo $ARMA(p, q)$ é dada por

$$\rho_j = \phi_1\rho_{j-1} + \phi_2\rho_{j-2} + \dots + \phi_p\rho_{j-p}, \quad j > q \quad (5.44)$$

5.7 – Considerações Finais

Neste capítulo os fundamentos de probabilidade e processos estocásticos básicos para a compreensão da teoria básica de séries temporais foi exposto. Isto se fez necessário devido ao fato de o modelo proposto ser amplamente utilizado em problemas de séries temporais e também que uma das etapas de comparação/justificativa de resultados se basear na teoria de séries temporais. Portanto, é conveniente fazer um prelúdio sobre o assunto.

Capítulo 6 - Modelo Proposto e Metodologia Adotada

6.1 – Considerações Iniciais

Neste capítulo o modelo proposto e a metodologia adotada para aquisição e tratamento dos dados são expostos. Com destaque para as razões de escolha do modelo e para o procedimento adotado na aquisição de dados, etapa fundamental e a mais custosa do trabalho. Tais informações servem de prelúdio para o capítulo 7, que trata dos resultados obtidos e dos passos executados para tal.

6.2- Modelo Proposto

Como comentado anteriormente, o modelo proposto é um modelo empírico paramétrico linear do tipo AR. O modelo é de segunda ordem, logo, denota-se o modelo como $AR(2)$. A equação do modelo, seguindo a notação apresentada no capítulo 5 é exposta em (6.1)

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \mathbf{a}. \quad (6.1)$$

Tem-se então dois coeficientes e um terceiro termo independente. Os valores de $\phi_j, j = 1,2,3$ e de \mathbf{a} são encontrados através da utilização de um algoritmo genético com o uso de um conjunto de dados para alimentação inicial do modelo.

A escolha do modelo proposto baseou-se em sua simplicidade, tanto do ponto de vista da manipulação analítica, quanto da implementação computacional. Este modelo baseou-se em medidas obtidas na região metropolitana de Belém (RMB), explicadas no subtópico 6.3.1.

O modelo exposto em (6.1) tem como objetivo realizar previsões da potência recebida em função da distância e do valor de PSNR em função da potência recebida de um sinal na faixa de TVD em Belém, cidade caracterizada por ser densamente arborizada (em especial na região central) e estar situada na região amazônica.

6.3- Metodologia

6.3.1- Aquisição de Dados (medições)

Os dados para este trabalho foram adquiridos através de campanhas de medições de potência recebida e de recepção/gravação de vídeos na frequência de TVD na RMB. Todos os vídeos gravados foram de uma mesma emissora, aqui chamada de Emissora A, operante na faixa de frequência de 518.14-524.14MHz (transmissão de sinal digital de televisão, com frequência central de 521.14MHz). Uma foto de satélite (oriunda do *software* GoogleEarth®) da região de Belém e a localização dos pontos medidos seguem nas figuras 6.1(a) e 6.1(b). Eles foram divididos em três radiais: Radial 1, Radial 2 e Radial 3. Dispostas, nesta ordem, em sentido cartesiano na figura 6.1(b), com origem na antena transmissora (Tx). Os pontos estão a uma distância mínima de 1km do Tx e, entre si, os pontos tem distância média de 500m.




Fig. 6.1(a)- Região Metropolitana de Belém (RMB)

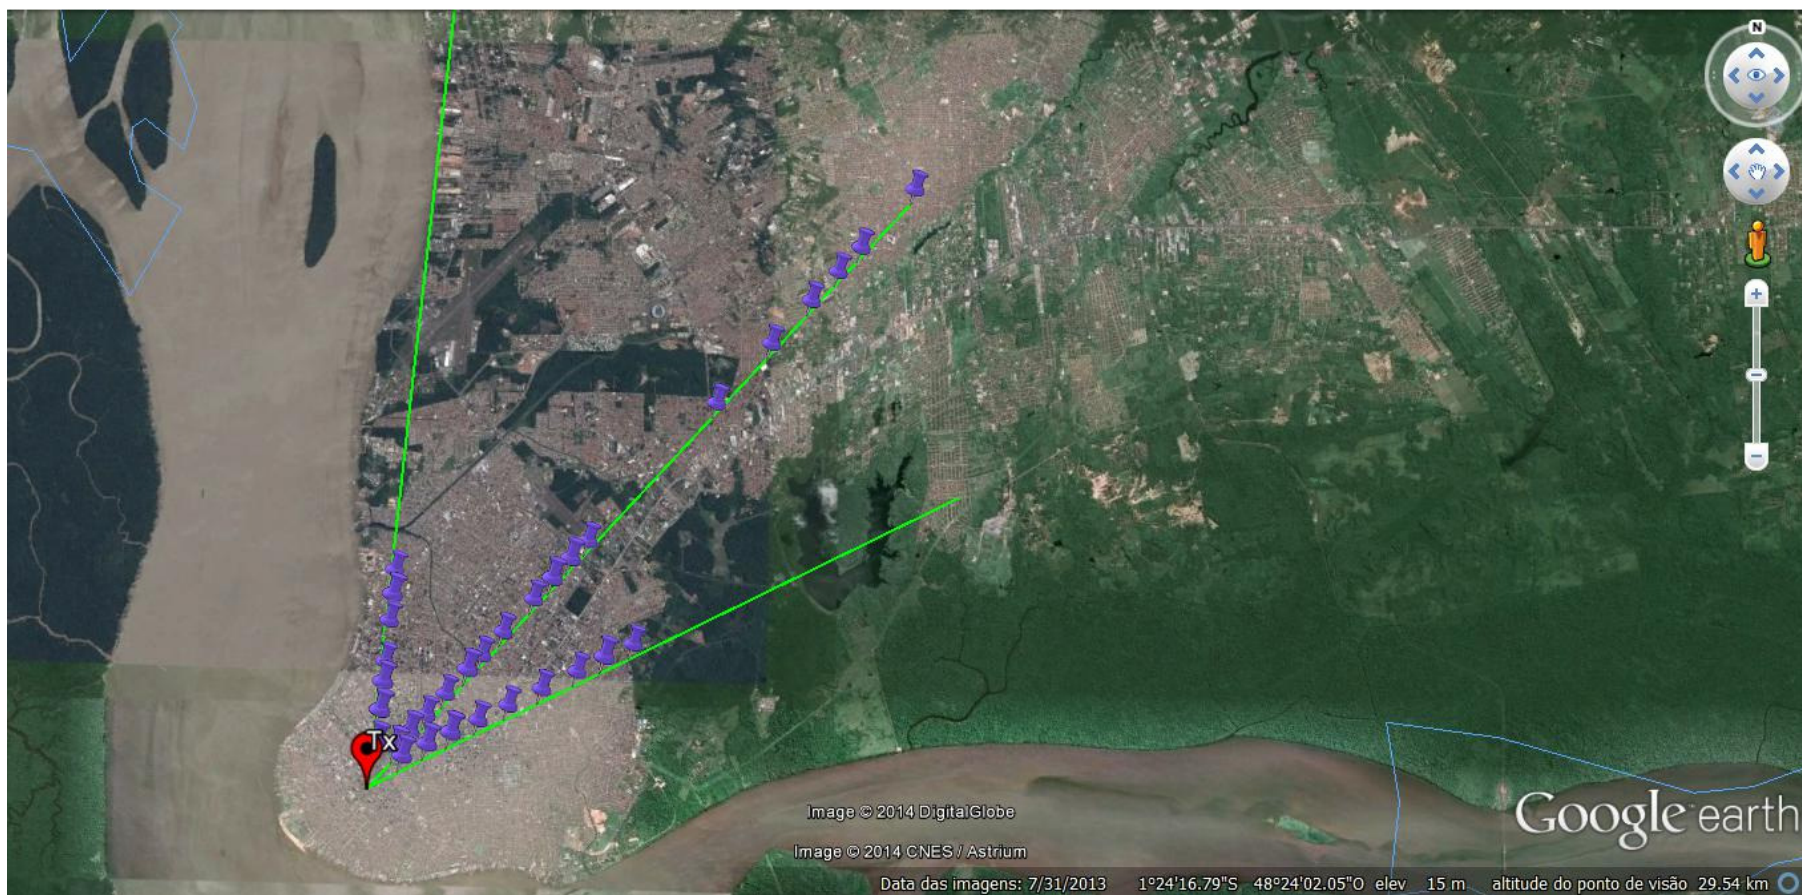


Fig. 6.1(b)- Pontos medidos na RMB. Radiais 1, 2 e 3, respectivamente, no sentido cartesiano e originando-se em “Tx”

O transmissor de TVD está situado a uma altura de 114.58m do solo. O receptor de potência (Rx_P), estava situado a 1,5m de altura do solo, no teto de um carro de passeio, devidamente isolado da lataria. Rx_P trata-se de uma antena dipolo Anritsu MP615A, conforme visualizado em figura 6.2(a). O posicionamento de Rx_P durante as medições pode ser visto na figura 6.2 (b).




Fig. 6.2(a)- Antena Anritsu MPP615A



Fig. 6.2(b)- Posicionamento de Rx_P

Os dados de potência recebida foram coletados com o equipamento Anritsu S332E, mostrado na figura 6.3. O receptor de vídeo (Rx_V), uma antena dipolo e um adaptador USB, estava acoplado a um computador *notebook* segundo a configuração exposta na figura 6.4.



Fig. 6.3- Anritsu S332E



Fig. 6.4- Posicionamento de Rx_V

Todas as medições foram executadas no período da manhã com tempo bom e temperaturas semelhantes, de aproximadamente 30°C. As condições de trânsito também podem ser consideradas normais, isto é, sem engarrafamentos nas proximidades dos pontos. As campanhas de medições dividem-se em três etapas: uma no mês de Março de 2013, outra no mês de Julho de 2013 e, finalmente, outra que incluiu os meses de Dezembro de 2013 e Janeiro de 2014. Os cuidados/condições supracitados referentes às condições de medições foram mantidos em todas as campanhas.

6.3.2- Tratamento dos Dados

6.3.2.1- Dados de Potência

Os dados de potência obtidos foram tratados utilizando o *software* MATLAB® [38]. De cada ponto, foi extraído um valor médio de potência proveniente de centenas de amostras por ponto. Cada conjunto de pontos (radial) foi tratado individualmente, de modo que, por exemplo, pontos da Radial 1 não se misturem com pontos da Radial 2. Após a obtenção dos valores médios de potência em cada ponto, fez-se uma “horizontalização” dos dados, isto é, encontrou-se uma tendência linear, através de MQL, para os dados. Em seguida subtraiu-se os dados dessa tendência linear. Isto resulta em dados com variações em torno do zero (tendo como referência o eixo das ordenadas). Trabalha-se com a tendência linear (de primeira ordem) pelo fato de a base

de dados reduzida não fornecer a informação de sazonalidade, que seria equivalente à tendências de segunda ordem ou superior.

Após a “horizontalização” uma suavização dos dados por médias móveis de segunda ordem ($MA(2)$) foi realizada, aproximando os dados da sua curva de tendência (no caso, a reta $y = 0$). A partir desta etapa, consideram-se os dados suavizados e “horizontalizados” como dados de trabalho. Parte dos dados foi utilizada para alimentar e calibrar o modelo e outra para comparação com os resultados da previsão da modelagem proposta e também com os resultados do modelo de Okumura-Hata.

6.3.2.2- Tratamento dos Dados de Vídeo

Para obtenção dos valores de PSNR, os vídeos transmitidos pelo Tx e recebidos pelo Rx_V foram gravados em formato MPEG4 (.mp4), no transmissor, e formato MPEG em Rx_V (devido a limitações no dispositivo de gravação), respectivamente. Após uma conversão inicial dos vídeos recebidos para MPEG4, cada par de vídeos (um para cada ponto) foi sincronizado e teve sua duração limitada a 10 segundos, resultando em dois vídeos sincronizados com duração de 10 segundos para cada ponto medido. Deve-se entender por sincronização dos vídeos a equivalência *frame a frame* de cada um dos vídeos. Por exemplo, o *frame 1* do vídeo oriundo da Emissora A (vídeo original) deve coincidir com o *frame 1* do vídeo recebido/gravado por Rx_V, o *frame 2* do vídeo original deve coincidir com o *frame 2* do vídeo recebido/gravado em Rx_V e assim por diante. Para todos os pontos/pares de vídeo esse procedimento foi adotado.

De posse dos pares de vídeos sincronizados, uma conversão para o formato .yuv foi executada com o aplicativo ffmpeg [39]. Esta conversão é necessária para que outro aplicativo, o *software* MSU-VQMT [40] possa, a partir de um dado par de vídeos sincronizados e em formato .yuv, obter os valores de PSNR dos vídeos oriundos de Rx_V. Isto se dá por comparação do vídeo original e o vídeo gravado em Rx_V. Após a obtenção dos valores de PSNR em cada ponto, procede-se de forma análoga ao explicado no subtópico 6.3.2.1 (“horizontalização” e suavização por $MA(2)$) para então aplicar os dados ao modelo.

6.4- Considerações Finais

O planejamento e desenvolvimento das campanhas de medições é uma fase crucial para este estudo, já que se trata da proposição de uma modelagem empírica. O tratamento dos dados também é uma etapa de suma importância neste trabalho e, notadamente, a que pode acarretar em maior dificuldade de execução, principalmente na sincronização dos vídeos. Em suma, estas duas etapas são as que mais consumiram tempo durante a execução deste trabalho.

Capítulo 7 - Resultados

7.1- Considerações Iniciais

Neste capítulo, os resultados da análise, da modelagem proposta com base na teoria de séries temporais e na comparação com modelos da literatura são expostos. Pode-se constatar que os resultados apresentados neste trabalho incentivam um aprofundamento da metodologia adotada, visando aquisição de novos dados e aperfeiçoamento da modelagem. Dessa forma acarretando em um modelo capaz de contribuir para a melhoria dos serviços fornecidos na região amazônica. É possível adequar qualquer frequência ao modelo, dada a sua dependência exclusiva dos dados adquiridos nas campanhas de medição. A seguir, a metodologia para obtenção de resultados é descrita.

7.2- Metodologia

Para todos os testes executados, a metodologia de obtenção de resultados consiste em:

- 1) Adotar um conjunto de dados para calibração do modelo via AG. No caso, o conjunto de dados “Radial 3”;
- 2) Utilizar os parâmetros obtidos via AG para prever resultados de outra radial (Radial 2) e comparar com os dados oriundos das campanhas de medições;
- 3) Comparação com os resultados obtidos pela teoria de séries temporais para os conjuntos de dados utilizados, isto é, os conjuntos Radial 2 e Radial 3;
- 4) Comparação com modelos da literatura quando possível;
- 5) Estimativas com base na teoria de séries temporais visando a comparação com os resultados da metodologia proposta.

O AG foi adotado como técnica de otimização para cálculo dos parâmetros devido ao fato de o problema não ser facilmente adaptável para otimização clássica. Isto ocorre porque as derivadas primeiras e segundas com relação aos parâmetros são de obtenção analítica muito trabalhosa. Além disso o problema é fortemente condicionado (restrições de parâmetros estão fortemente interligadas).

O conjunto de pontos Radial 1 não é utilizado na obtenção de resultados devido a seu comportamento distinto em relação aos conjuntos Radial 2 e Radial 3 (por exemplo, verifica-se que a potência aumenta com o aumento da distância). O conjunto Radial 3 é utilizado para calibração do modelo e o conjunto Radial 2 serve de comparação à previsão do modelo com os coeficientes obtidos na etapa de calibração, isto é, obtidos com o conjunto Radial 3.

Os parâmetros intrínsecos do AG foram:

- 1) População: 40;
- 2) Intervalo possível para os parâmetros b , c , e d : $-1 \leq b, c, d \leq 1$. Estes parâmetros equivalem aos coeficientes ϕ_1 , ϕ_2 e α de acordo com (6.1);

- 3) Número de iterações internas: 2000;
- 4) Probabilidade de mutação: 3%;

Os coeficientes b e c representam o histórico de contribuição para o valor atual. Quanto mais próximo de 1 for o valor absoluto do parâmetro, maior a contribuição do valor anterior correspondente. No caso de um parâmetro com valor 1, tem-se uma série constante, sendo o outro parâmetro de valor zero. Já o coeficiente d representa um *shift* vertical na série. Um parâmetro de valor negativo significa que ele é um atenuante e um valor positivo significa que ele é um estimulante do processo. Nos processos estacionários, os parâmetros do segundo membro da equação deverão ser sempre menores que 1, caso contrário, o processo será não-estacionário.

Todos os resultados foram obtidos com o uso do *software* MATLAB®. Partiu-se da hipótese de que os dados medidos formam uma série temporal estacionária. Isto é fundamental para a justificativa baseada na teoria de séries temporais apresentada neste capítulo. Aqui, quando mencionado dados “simulados”, deve-se entender como os dados obtidos através da teoria de séries temporais e dados ou curvas “propostas/previstas” significam os resultados oriundos da modelagem proposta. Dados “originais” referem-se aos dados brutos das campanhas de medição.

Outro ponto de fundamental importância é o fato de que, neste trabalho são feitas duas previsões: uma da potência recebida como função da distância (previsão 1) e outra do valor de PSNR como função da potência recebida (previsão 2). Isto é, não se realiza a previsão 2 com os resultados da previsão 1. Ambas as previsões utilizam-se de dados medidos e devem ser entendidas como duas previsões distintas.

Serão mostrados primeiramente os resultados de potência do sinal recebido como função da distância. Em seguida, mostram-se os resultados da previsão da PSNR em função da potência recebida.

Uma pictórica representando a metodologia adotada consta na figura 7.1.

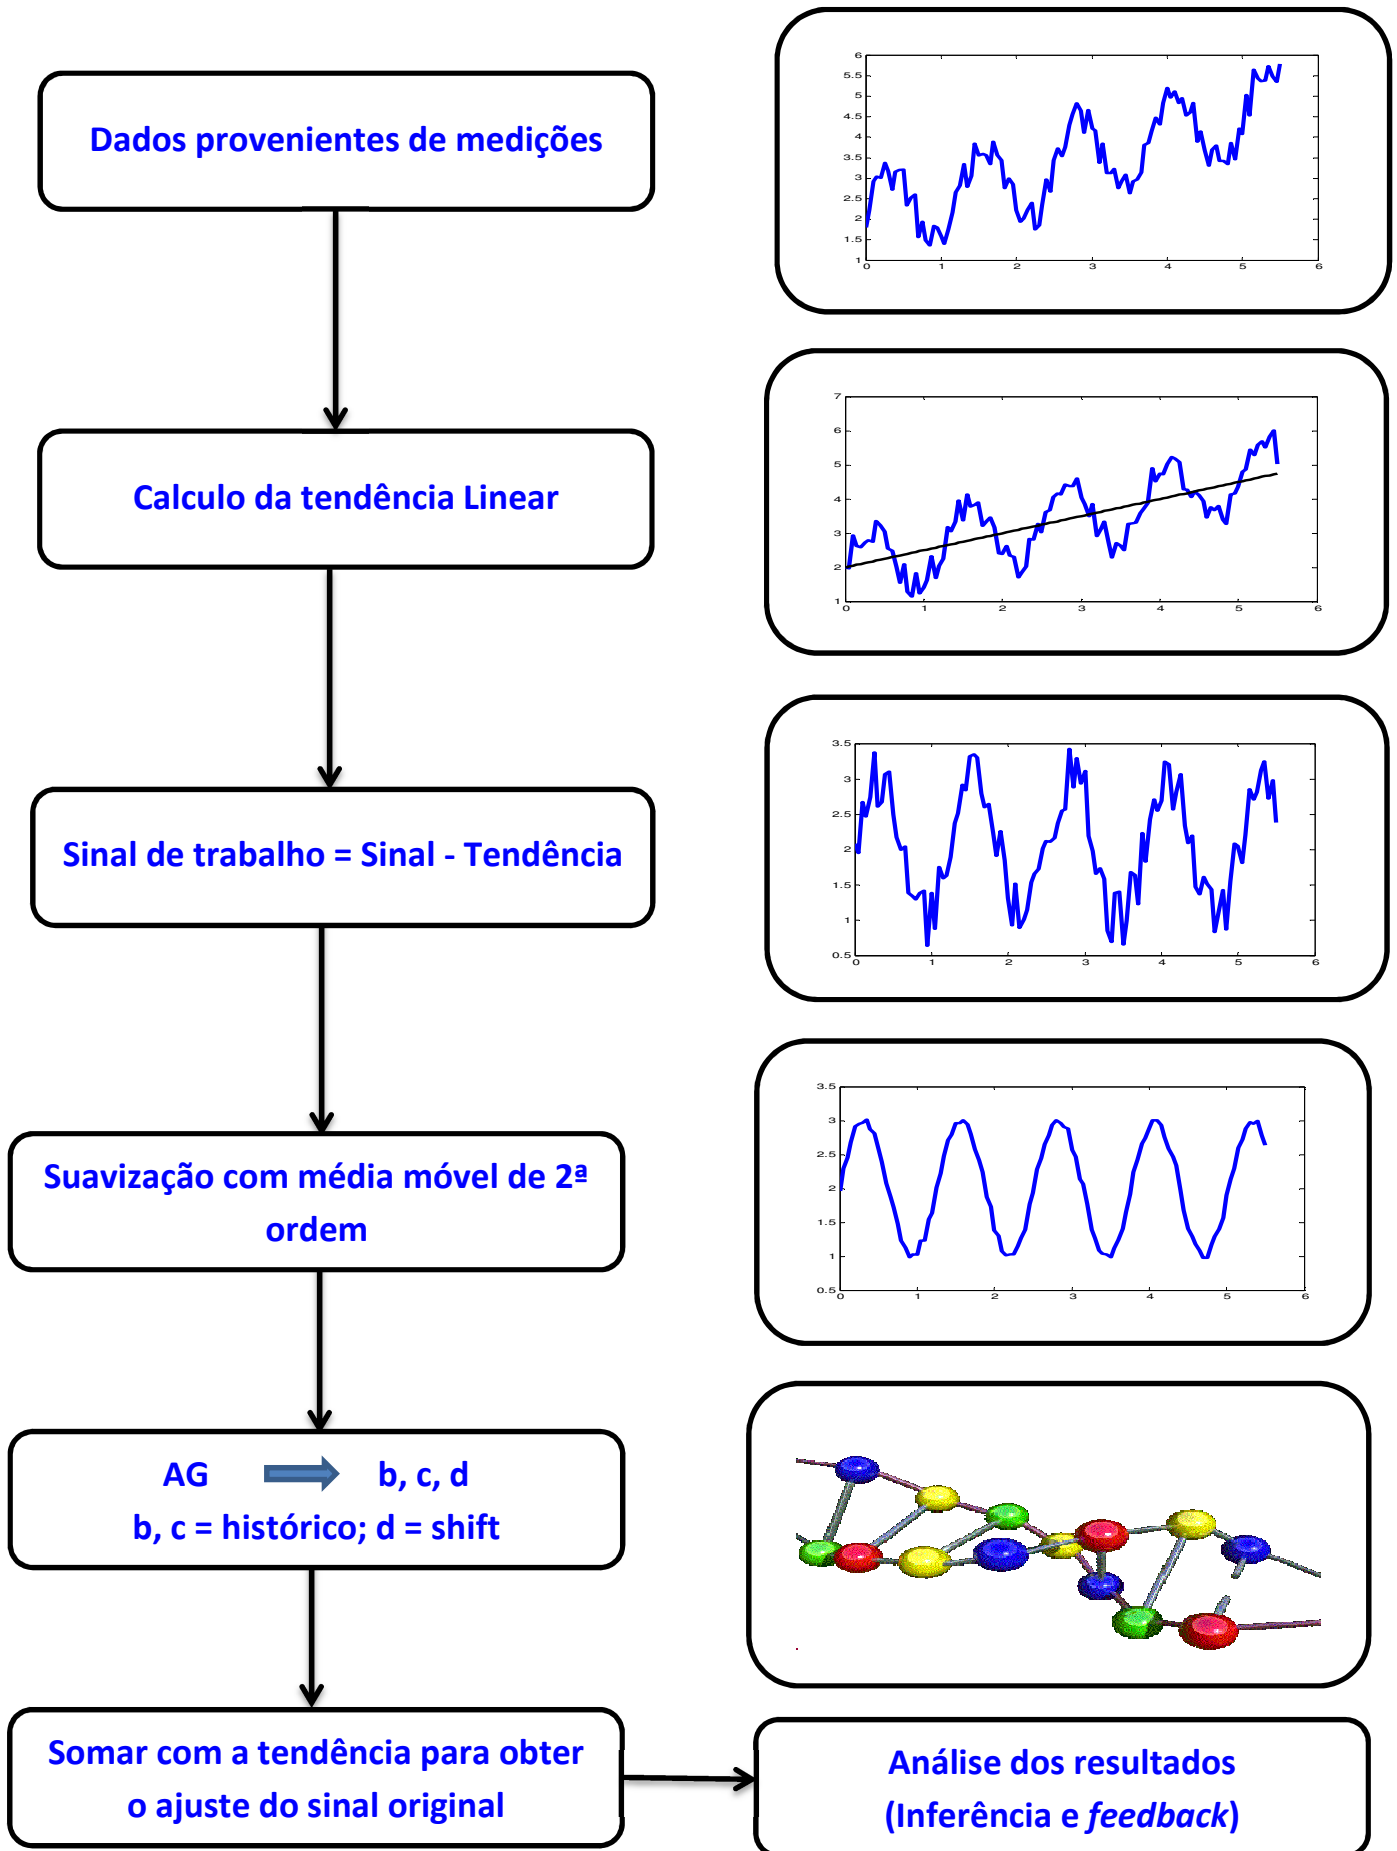


Fig. 7.-1 Pictórica da Metodologia

7.3- Resultados Acerca da Previsão da Potência Recebida Como Função da Distância

Estudos de potência como função da distância são largamente conhecidos na literatura, existindo, portanto, vários modelos para os mais variados cenários possíveis (variações na frequência, distância entre Tx e Rx, geografia da região estudada, etc.). Neste trabalho, faz-se uma comparação da previsão de potência em função da distância com o modelo de Okumura-Hata. Este modelo foi escolhido por ser o mais adequado à comparação, já que possui um número limitado de parâmetros e suas faixas de frequência e distância se enquadram ao cenário estudado neste trabalho. Outros modelos clássicos empíricos, como Walfisch-Bertoni e Ibrahim-Parsons, por exemplo, fazem considerações específicas à morfologia das cidades (altura de edificações e distância média entre elas, etc.), implicando em um “desmembramento” das perdas (por reflexão, difração e atenuação). Este tipo de consideração foge ao propósito do modelo (ao menos até o presente momento), que considera apenas os dados utilizados em sua calibração. Tais dados já “carregam” as informações das perdas por multipercurso, por exemplo, específicas de cada obstáculo. Dessa forma, conclui-se que o modelo de Okumura-Hata é o mais adequado à comparação por também não desmembrar estas perdas. Os parâmetros do modelo de Okumura-Hata adotados foram: cidade média/pequena e ambiente suburbano.

Os resultados serão expostos da seguinte forma:

- 1) Gráficos das curvas calibradas e previstas juntamente com as curvas originais dos dados;
- 2) Valores de b, c, d
- 3) Gráficos das curvas propostas e simuladas com base na teoria de séries temporais juntamente com as curvas originais;
- 4) Valores dos coeficientes do modelo obtidos através da teoria de séries temporais;
- 5) Valores de RMSE (*Root-Mean-Square Error*), ou erro médio quadrático entre:
 - a) Os dados propostos e originais;
 - b) Dados simulados (teoria de séries temporais) e originais;
 - c) Modelo de Okumura-Hata e dados originais.
- 6) Valores médios da autocorrelação entre os dados originais e propostos.

Lembrando que a frequência central do sinal transmitido é 521.14MHz, tem-se, na figura 7.2(a) e figura 7.2 (b) os gráficos da curva calibrada (Radial 3) e da curva prevista (Radial 2) respectivamente, ambas em comparação aos respectivos conjuntos de dados originais.




Fig. 7.2(a)- Dados calibrados X dados originais (Radial 3)




Fig. 7.2(b)- Dados previstos/propostos X dados originais (Radial 2)

Neste caso, os valores de b , c , e d são mostrados na Tabela 7.1.

Tabela 7.1 – Valores de b , c e d para os dados de potência como função da distância

Parâmetro	b	c	d
Valor	0.855	-0.943	-0.436

Os valores dos parâmetros simulados, encontrados através de um sistema similar ao mostrado em (5.38) seguem na Tabela 7.2.

Tabela 7.2 – Valores dos parâmetros obtidos através de um sistema do tipo (5.38)

Parâmetro	ϕ_1	ϕ_2
Valor – Radial 3	0.035	-0.164
Valor – Radial 2	-0.075	-0.446

Deve-se destacar a ausência de um terceiro parâmetro na Tabela 7.2. Isto se deve ao fato que o parâmetro do termo independente, de acordo com a teoria de séries temporais, representa uma componente aleatória. Dessa forma, ao modelo de parâmetros a e b foi adicionado um termo aleatório regido por uma distribuição normal, resultando nas curvas exibidas em figura 7.3(a) e figura 7.3(b). De acordo com os dados na tabela 7.2 verifica-se que as séries em estudo realmente podem ser consideradas estacionárias, corroborando a abordagem adotada no ajuste via AG.

Nos resultados obtidos via AG, ou seja, de acordo com a modelagem proposta, calcula-se três parâmetros pelo fato de o AG ser calibrado com dados empíricos, que já “carregam” as informações de aleatoriedade em contribuição de dados anteriores/posteriores (tendo como referencial a distância entre cada ponto e o transmissor).

Em figura 7.3(a) e figura 7.3(b) constam as comparações entre as curvas simuladas por séries temporais e as curvas/dados originais.




Fig. 7.3(a)- Dados simulados X dados originais (Radial 3)




Fig. 7.3(b)- Dados simulados X dados originais (Radial 2)

Na figura 7.4 consta o gráfico de comparação entre o modelo de Okumura-Hata e os dados originais para ambas as radiais.




Fig. 7.4(a)- Modelo de Okumura-Hata e dados originais (Radial 3)




Fig. 7.4(b)- Modelo de Okumura-Hata e dados originais (Radial 2)

A seguir, na Tabela 7.3, os valores de RMSE são mostrados

Tabela 7.3- Valores de RMSE para potência recebida X distância

Conjuntos de dados	Propostos X Originais	Simulados X Originais	Okumura-Hata X Originais
RMSE (dB) – Radial 3	4.553	5.526	23.047
RMSE (dB) – Radial 2	4.383	3.891	31.017

Pode-se verificar que, mesmo com uma base de dados pequena (poucos pontos para calibração/previsão) o modelo mostra bons resultados, seja comparado ao modelo de Okumura-Hata, seja comparado ao resultado simulado (séries temporais). Na tabela 7.3 tem-se a comparação entre os RMSE para a Radial 3, conjunto de dados ajustado pelo AG e utilizado como elemento de calibração do modelo, bem como a comparação entre os RMSE para a Radial 2 (conjunto de dados para comparação com a previsão do modelo). Ainda de acordo com a tabela 7.3, nota-se que o modelo obteve resultados ligeiramente divergentes aos obtidos através de séries temporais, considerando o conjunto de previsão (Radial 2). Uma das possíveis causas para esse comportamento pode ser a pequena base de dados utilizada até então. Um conjunto maior/melhor de dados representativos do problema para calibração do modelo certamente implicaria em resultados melhores.

Do exposto neste subtópico, verifica-se um modelo promissor, pois mesmo com uma base de dados reduzida, obteve resultados interessantes mesmo se comparado aos resultados teóricos de séries temporais. Tal modelagem, acrescida da robustez do AG, permite ainda aprimoramentos do modelo, tais como componente(s) não-linear(es), por exemplo. Outro ponto importante é o aumento da base de dados. Isto contribuiria para diminuir a dependência de fatores aleatórios no modelo. O AG faz uso de números aleatórios em seu funcionamento e, ao executar vários experimentos, ainda é possível notar certa variabilidade nos resultados. Este tipo de variabilidade deve ser combatido com um aumento na base de dados de calibração, acarretando na obtenção de parâmetros que melhor representam o problema e, por consequência, em uma melhor previsão do modelo, independente de qualquer aleatoriedade intrínseca ao AG. Além disso, uma melhor base de dados para calibração implicaria em resultados mais precisos (menor RMSE).

7.4- Resultados Acerca da Previsão da PSNR Como Função da Potência Recebida

Estudos relacionando diretamente a PSNR de um vídeo transmitido por um sinal e a potência recebida deste sinal são escassos na literatura. Tal fato implica na inexistência de uma modelagem “clássica” relacionando ambas as variáveis, tal como o modelo de Okumura-Hata é para a potência recebida em função da distância. Portanto, os resultados desse segundo grupo de previsões/simulações têm como justificativa apenas a teoria de séries temporais. Isto implica na necessidade de futuras campanhas de medições na RMB e em outros locais de modo a verificar se a justificativa apresentada a seguir se verifica ou não.

Os resultados serão expostos da seguinte forma:

- 1) Gráficos das curvas calibradas/previstas juntamente com as curvas originais dos dados;
- 2) Valores de b, c, d
- 3) Gráficos das curvas propostas e simuladas com base na teoria de séries temporais juntamente com as curvas originais;
- 4) Valores dos coeficientes do modelo obtidos através da teoria de séries temporais;
- 5) Valores de RMSE (*Root-Mean-Square Error*), ou erro médio quadrático entre:
 - a) Os dados propostos e originais;
 - b) Dados simulados (teoria de séries temporais) e originais;
- 6) Valores médios da autocorrelação entre os dados originais e propostos

Tem-se, em figura 7.5(a) e figura 7.5(b) os gráficos da curva calibrada (Radial 3) e da curva prevista (Radial 2) respectivamente, ambas em comparação aos respectivos conjuntos de dados originais.




Fig. 7.5(a)- Dados calibrados X dados originais (Radial 3)




Fig. 7.5(b)- Dados previstos/propostos X dados originais (Radial 2)

Neste caso, os valores de b , c , e d são mostrados na Tabela 7.1.

Tabela 7.4- Valores de b , c e d para os dados de PSNR em função da potência recebida

Parâmetro	b	c	d
Valor – Radial 3	-0.720	-0.654	-0.272

Em figura 7.6(a) e figura 7.6(b) constam as comparações entre as curvas simuladas por séries temporais e as curvas/dados originais.




Fig. 7.6(a)- Dados simulados X dados originais (Radial 3)




Fig. 7.6(b)- Dados simulados X dados originais (Radial 2)

Os valores dos parâmetros simulados, encontrados através de um sistema similar ao mostrado em (5.38) seguem na Tabela 7.5.

Tabela 7.5- Valores dos parâmetros obtidos através de um sistema do tipo (5.38)

Parâmetro	ϕ_1	ϕ_2
Valor – Radial 3	-0.759	-0.492
Valor – Radial 2	-0.435	-0.394

As mesmas observações acerca do terceiro parâmetro “simulado” e da estacionariedade das séries feita no subtópico 7.2 obviamente valem também para este conjunto de dados, visto que a metodologia de obtenção destes resultados é a mesma.

A seguir, na Tabela 7.6, os valores de RMSE são mostrados

Tabela 7.6- Valores de RMSE para PSNR X potência recebida

Conjuntos de dados	Propostos X Originais	Simulados X Originais
RMSE (dB) – Radial 3	6.970	5.822
RMSE (dB) – Radial 2	5.573	5.853

Os dados de PSNR em função da potência recebida são os mais complicados de se abordar, dados os escassos estudos relacionando essas duas grandezas. Nota-se uma oscilação significativa nestes dados. Isto dificulta o ajuste pelo AG, o que contribui para justificar o RMSE maior do ajuste em relação ao resultado obtido por séries temporais para o conjunto Radial 3 (conjunto de calibração do modelo). Entretanto, com a

aplicação dos parâmetros da Radial 3, os resultados de previsão (considerando o conjunto Radial 2) foram melhores que os teóricos.

7.5- Considerações Finais

Do exposto neste capítulo, nota-se que a metodologia associada à modelagem proposta fornece resultados interessantes, mesmo considerando uma base de dados reduzida. O modelo foi proposto com a ideia de se trabalhar com poucos dados, apesar de que uma base de dados pouco maior e mais representativa era pensada inicialmente (detalhes sobre as dificuldades encontradas e aprimoramentos futuros encontram-se no capítulo 8). Em especial para os dados de potência em função da distância o modelo obteve bons resultados, pois é uma relação já conhecida e estudada desde os primórdios dos estudos em telecomunicações. Já os dados de PSNR em função da potência recebida, dados os escassos estudos e a falta de uma modelagem de referência relacionando essas duas grandezas (caso exista realmente essa relação), podem ser observados considerando apenas a comparação com a teoria de séries temporais. Neste caso, os resultados ainda não são os ideais, pois os dados simulados ainda apresentam melhores resultados (considerando RMSE). Entretanto, com o aumento/melhoramento da base de dados os resultados do modelo proposto tendem a ser melhores, pois o AG teria então dados mais representativos, auxiliando assim no ajuste.

Posteriormente, no capítulo 8, seguem as conclusões deste estudo, bem como apresentação das dificuldades encontradas e etapas futuras de aprimoramento da modelagem/metodologia proposta.

Capítulo 8 – Conclusões, Dificuldades Encontradas e Trabalhos Futuros

8.1- Considerações Iniciais

Este capítulo finaliza a apresentação deste estudo e contém as conclusões acerca dos resultados apresentados em relação à proposta do modelo, as dificuldades encontradas na execução do trabalho e etapas futuras de aprimoramento da modelagem proposta.

8.2- Conclusões do Estudo

Neste estudo uma modelagem paramétrica linear para previsão de potência em função da distância e do valor da PSNR de um vídeo em função da potência recebida do sinal transmissor desse vídeo foi proposta e testada sob as condições citadas nos capítulos 6 e 7. Como conclusão ao estudo, pode-se afirmar que esta modelagem é uma alternativa viável a que se propõe, tendo em vista comparações com um modelo clássico (Okumura-Hata, para o caso da potência recebida em função da distância) ou justificativas com resultados oriundos da teoria de séries temporais, no caso da previsão de PSNR em função da potência recebida. No conjunto de pontos Radial 2, alguns dos valores de RMSE são maiores no modelo proposto do que os obtidos segundo a teoria de séries temporais. Mesmo assim, a modelagem proposta é viável à estudos na região amazônica. Seus resultados são equivalentes ou melhores que os do modelo de referência ou a teoria de séries temporais.

Um ponto importante e que deve ser lembrado é o uso de um AG para o ajuste dos coeficientes do modelo proposto. O AG é uma técnica de otimização que se mostrou eficiente para o cálculo dos parâmetros neste trabalho. É conhecido pela sua robustez e versatilidade, nem tanto pela sua rapidez ou precisão em alguns casos. A sua utilização neste estudo se fez com o intuito de permitir futuros aprimoramentos no modelo, dada a facilidade de alteração no AG para se adequar a um novo modelo.

Os bons resultados atingidos já nesta etapa de elaboração do modelo encorajam um refinamento do mesmo, sem perder de vista que a principal vantagem do modelo é aliar simplicidade à obtenção de bons resultados.

Idealmente, o modelo proposto baseia-se no mesmo princípio do modelo de Okumura/Okumura-Hata. Este é um modelo largamente aplicado, de origem empírica e, até certo ponto, de simples entendimento, pois considera fatores macroscópicos, como o tipo de cidade/ambiente onde se pretende aplica-lo. Modelos como Ibrahim-Parsons e Walfisch-Ikegami/Walfisch-Bertoni já consideram especificamente fatores de menor dimensão, como a distância entre construções e suas respectivas alturas. Considerando cidades brasileiras (e muitas outras ao redor do mundo), onde seu crescimento deu-se desordenadamente durante muito tempo, as informações específicas a respeito da morfologia são difíceis de serem obtidas. Em muitos casos, as informações disponíveis nos órgãos públicos são desatualizadas. Dessa forma, em regiões onde o acesso a informações específicas é dificultado, modelos simples, porém eficientes, são uma

alternativa viável aos fornecedores de serviços de telecomunicações ao planejar a aplicação de seus serviços.

8.3- Dificuldades Encontradas

No decorrer da execução deste trabalho, houve dificuldades principalmente nas etapas de medição e tratamento dos vídeos gravados. Por se tratar de um estudo empírico no qual as medições ocorreram em vias públicas, com o uso de carros particulares, muitas vezes sessões de medição tiveram de ser canceladas devido a problemas de ordem logística (indisponibilidade de veículos, equipamento e pessoal, mal tempo, etc.). Pelo fato de a Universidade Federal do Pará (UFPA) não dispor de uma torre transmissora de TVD própria, ficou-se dependente da Emissora A. Entretanto, quando as condições logísticas eram favoráveis, as medições fluíam sem percalços.

No tocante ao tratamento dos vídeos gravados, novamente, a dependência de pessoas externas à equipe do autor do trabalho mostrou-se um “gargalo” na execução do estudo. Destaca-se a etapa de sincronização dos vídeos gravados em Rx_V e Tx. Esta dificuldade foi superada com o auxílio do Laboratório Multimídia, pertencente à Assessoria de Educação à Distância (AEDI) da UFPA, que participa de um projeto em parceria com o Laboratório de Computação e Telecomunicações (LCT), também pertencente à UFPA e onde o autor deste estudo trabalha. Novamente, ao superar este “gargalo” o trabalho pôde ser executado sem maiores problemas.

Em suma, as dificuldades podem ser separadas em duas categorias: material (em especial viaturas e torre de transmissão) e pessoal (profissionais capacitados para os serviços de edição/sincronização de vídeos).

8.4- Trabalhos Futuros

Como descrito em 8.2, para que o modelo torne-se mais refinado, algumas etapas e aprimoramentos devem ser executados. Estes são:

- 1) Aumentar a base de dados com novas campanhas de medições na RMB e em municípios/distritos adjacentes. Assim os dados serão mais representativos, facilitando um ajuste mais preciso por meio do AG e minimizando os efeitos aleatórios intrínsecos do AG;
- 2) De posse da base de dados aumentada, pode-se adicionar uma componente específica de ambiente. Nota-se nas regiões medidas uma diversidade de tipo de construções, nível de urbanização e arborização. Criar componentes de regiões arborizadas, urbanizadas e, em particular para a região amazônica, uma componente de perda em rios (grandes trechos de água doce). A Amazônia é caracterizada por grandes rios, considerando a largura de margem a margem, diferente dos rios de outras regiões onde outros modelos clássicos foram elaborados;

- 3) Testar o modelo proposto em outras regiões, de modo a perceber semelhanças e descobrir os limites do modelo sem recorrer a ajustes específicos para outras regiões (descoberta de adequações do modelo);
- 4) Testar o modelo em diferentes regiões para encontrar componentes representativas de diferentes ambientes. O AG, por sua robustez, facilita tal procedimento e o modelo, por ser de simples manipulação também contribui neste sentido.

Com a realização das etapas acima, ter-se-á um modelo com alto grau de confiabilidade e aplicabilidade, em especial na região amazônica, onde existem poucos exemplos concretizados de modelagens aplicadas pelos fornecedores de serviços de telecomunicações.

8.5- Considerações Finais

Neste estudo foi proposta uma modelagem que, além de prever a potência do sinal recebido, pode ser utilizada para prever uma métrica de QoE em função da potência de sinal recebida. Existem poucos estudos relacionando PSNR e potência recebida, em especial, se considerando a região amazônica como ambiente de estudo. Uma modelagem simples que aponte uma relação entre qualidade e potência de sinal é de grande valia para auxiliar os fornecedores de serviços de telecomunicações na aplicação de seus serviços de forma otimizada. Percebe-se um bom potencial de aplicação prática na modelagem proposta, mesmo com uma quantidade de dados reduzida. Desta forma, o autor conclui que a proposta do trabalho em indicar uma modelagem apropriada para ambientes densamente arborizados obteve êxito.

Referências Bibliográficas

- [1] MAXWELL, J. C. “A dynamical theory of the electromagnetic field (1864). In: NOVEN, W. D. The scientific papers of James Clerk Maxwell”. Cambridge: Cambridge University Press, 1890. v. 1, p. 526-97.
- [2] ZENNECK, J. W. A. “Über die Fortpflanzung ebener elektromagnetischer Wellen längs einer ebenen Leiterfläche und ihre Beziehung zur drahtlosen Telegraphie”, Annalen der Physik Volume 328, Issue 10, pages 846–866, 1907.
- [3] SOMMERFELD, A. J. W. “Mathematische Theorie der Diffraction” Mathematische Annalen Volume 47, Issue 2-3 , pp 317-374 ,1896;
- [4] WEYL, H. K. H. “Gravitation and Electricity”, 1918.
- [5] NORTON, K. A. “The propagation of radio waves over the surface of the earth and in the upper atmosphere” Part II, Proc. I.R.E., vol. 25, pags 1203-1236, september 1937.
- [6] CAVALCANTE, G. P.S., GIAROLA, A. J. “Optimizations, of Radio Communications in Media with Three Layers”, IEEE Transactions on Antennas and Propagation, vol. AP. 31, January 1983.
- [7] MENG, Y.S., LEE, Y.H., NG, B.C. “Study of Propagation Loss Prediction in Forest Environment”, 2009.
- [8] FRAIHA, S. G. C., “Localização Ótima de Pontos de Acesso em Ambientes Indoor em Projetos de Sistemas Wireless” Tese de Doutorado, PPGEE-UFPA, 2009.
- [9] IBGE, “PNAD - Pesquisa Nacional por Amostra de Domicílios”. Disponível em [http://www.ibge.gov.br/home/estatistica%20-%20populacao/trabalho e rendimento- /pnad2009/default.shtm](http://www.ibge.gov.br/home/estatistica%20-%20populacao/trabalho%20e%20rendimento/pnad2009/default.shtm), 2009
- [10] SOUZA, J. F., MAGNO, F. N. B, COSTA, J. C. CAVALCANTE, G. P. S. “Path Loss Exponents for Medium Waves Using Parabolic Equations”, EuCAP 2012.
- [11] ROZAL, E. O. “Modelagem de Canais de Comunicações Móveis com a Utilização de Séries Temporais e Geoestatística”, Tese de Doutorado, PPGEE-UFPA, 2013.
- [12] “História da Televisão Digital”. Disponível em: <http://www.dtv.org.br/informacoes-tecnicas/historia-da-tv-digital-no-brasil/>, Acesso em 30 de Dezembro de 2012.
- [13] ITU-R “Recommendation ITU-R P.1546-4”, 2009
- [14] ITU-R “Recommendation ITU-R M. 1812”, 2002
- [15] MINISTÉRIO DAS COMUNICAÇÕES; Disponível em: <http://www.mc.gov.br/acoes-e-programas/tv-digital>, Acesso em 30 de Dezembro de 2012.
- [16] MEFTAH, R. “Efficient computation of tire/road contact forces using an ARMA model of the Green function”. France: XVIIth Symposium Vibrations, 2010.

- [17] CAO, Y., CHEN, X. B. "A Novel Discrete ARMA-Based Model for Piezoelectric Actuator Hysteresis"; IEEE/ASME Transactions on Mechatronics, 2012.
- [18] SEETAL, P., NATARAJAN, N. "Image Segmentation for rock fractures based on ARMA model". International Journal of Engineering Science and Technology, vol 2, no. 5, 2010.
- [19] PHAM, H. T., YANG, BO-SUN. "Estimation and forecasting of machine health condition using ARMA/GARCH model". Mechanical Systems and Signal Processing, vol. 24, no. 2, pp. 546-558, 2010.
- [20] RODRIGUES, J. C., et al. "Channel Propagation Model for Mobile Network Project in Densely Arboreous Environments", Journal of Microwave and Optoelectronics, vol 6, no 1, 2007.
- [21] MONTEIRO, B. G. "Predição dos Parâmetros Elétricos do Solo em Ambiente Rural Utilizando Redes Neurais", Dissertação de Mestrado PPGEE-UFGA 2007
- [22] FRAIHA LOPES, R. L. "Empirical ARMA Indoor Propagation Model for WLAN Signals in 2.4GHz", EuCAP 2013.
- [23] FRAIHA LOPES, R. L. "Empirical ARMA Outdoor Propagation Model for Amazon Cities", EuCAP 2013.
- [24] HAYKIN, S., MOHER, M., "Sistemas Modernos de Comunicações Wireless", Porto Alegre: Bookman 2008.
- [25] ITU-R. "ITU-R Recommendation P.10/G.100, Amendment 2", 2008.
- [26] ITU-R. "ITU-R Recommendation P.800.1", 2006.
- [27] ITU. "Telecommunication Standardization Sector: Contribution - IPTV QoS/QoE Metrics". 3rd FG IPTV meeting, USA, 2007.
- [28] CHAN, A., et al. "Metrics for Evaluating Video Streaming Quality in Lossy IEEE 802.11 Wireless Networks". IEEE INFOCOM 2010.
- [29] PULLANO, V., et al. "PSNR Evaluation and Alignment Recovery for Mobile Satellite Video Broadcasting" 6th Advanced Satellite Multimedia Systems Conference, 2012.
- [30] WIEGAND, T., et al. "Rate constrained coder control and comparison of video coding standards". IEEE Transactions on Circuits and Systems for Video Technology, vol. 13, no. 7, pp. 688-703, July 2003.
- [31] GIORD, B., "What's wrong with mean squared error?". Digital images and human vision, Andrew B. Watson, pp. 207-220, 1993.
- [32] BRUN, A. L. "Algoritmos Genéticos", 2004.
- [33] SARAMAGO, S. F. P. "Métodos de Otimização Randômica: Algoritmos Genéticos e Simulated Annealing", São Carlos, 2003.

- [34] RUGGIERO, M. A. G., LOPES, V. L. R. “Cálculo Numérico - Aspectos Teóricos e Computacionais”. 2ª ed. São Paulo, Pearson Makron Books, 1996.
- [35] PAPAULIS, A. “Probability, Random Variables and Stochastic Processes”. 4th edition, McGraw Hill, 2002.
- [36] MORETTIN, P. A., TOLOI C. M. C. “Análise de Séries Temporais”. São Paulo, Edgard Blucher, 2006.
- [37] BOX JENKINS, G. E. P. et al. “Time Series Analysis: Forecasting and Control” 4th edition, New Jersey, John Wiley & Sons, 2008.
- [38] MATLAB version 8.0.0.783. In Technical Documentation, 2012.
- [39] FFmpeg. Fabrice Bellard, 2009.
- [40] MSU Graphics & Media Lab (Video Group), 2012.