

DANIEL CARNEIRO DA SILVA

**MÉTODOS PARA TRATAMENTO DE DADOS DE NEBULOSIDADE PARA
FINS FOTOGRAMÉTRICOS**

**Tese apresentada ao Curso de Pós-
Graduação em Ciências Geodésicas, Setor
de Ciências da Terra, Universidade Federal
do Paraná, como requisito parcial à
obtenção do grau de Doutor em Ciências
Geodésicas – Área de Concentração
Fotogrametria**

**Orientadores: Prof. Dr. Quintino Dalmolin
Prof. Dr. Anselmo Chaves
Neto**

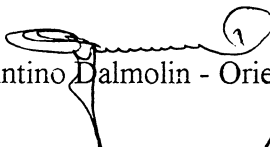
**CURITIBA
2001**

**“MÉTODOS PARA TRATAMENTO DE DADOS DE NEBULOSIDADE
PARA FINS FOTOGRAFAMÉTRICOS”**

POR

DANIEL CARNEIRO DA SILVA

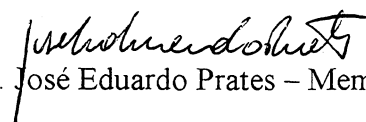
Tese nº 021 aprovada como requisito parcial ao grau de Doutor no Curso de Pós-Graduação em Ciências Geodésicas da Universidade Federal do Paraná, pela Comissão formada pelos professores:


Prof. Dr. Quintino Dalmolin - Orientador e Presidente (UFPR)


Prof. Dr. Anselmo Chaves Neto - Orientador (UFPR)


Prof. Dr. José Bittencourt de Andrade - Membro (UFPR)


Prof. Dr. Aluir Porfirio Dal Poz - Membro (UNESP)


Prof. Dr. José Eduardo Prates - Membro (SIMEPAR)

a Felipe,
Guilherme,
Gustavo e
Diogo

AGRADECIMENTOS

O autor externa seus agradecimentos às seguintes pessoas e instituições:

- À CAPES, pela bolsa de estudos concedida durante o período de realização do curso;
- Ao CPCCG da UFPR, que deu a chance, e os meios necessários, de cumprir tarefa tão árdua e ao mesmo tempo gratificante;
- Ao Prof. Dr. Quintino Dalmolin, pelo apoio e atenção despendidos sob todas as formas, além da orientação essencial ao desenvolvimento dessa tese;
- Ao Prof. Dr. Anselmo Chaves Neto, pelo acolhimento, orientação dedicada e discussões indispensáveis ao desenvolvimento dessa tese;
- A todos os professores e funcionários do Curso de Pós-Graduação em Ciências Geodésicas, pelas colaborações e demonstrações de incentivo;
- Ao INPE, pela presteza em atender os pedidos de informações, bibliografia, imagens de satélites e outros materiais, que tanto apoiaram essa tese;
- Ao INMET, pela cessão gratuita dos dados de nebulosidade de observação de superfície;
- Ao NASA Langley Research Center, pela cessão dos dados tipo DX do ISCCP;
- À Andréa, pela paciência e colaboração permanente durante todos os anos consumidos nessa pesquisa.

ACKNOWLEDGMENTS

The DX data were obtained from the NASA Langley Research Center
EOSDIS Distributed Active Archive Center

SUMÁRIO

LISTA DE FIGURAS	V
LISTA DE TABELAS	VIII
LISTA DE ABREVIATURAS E SIGLAS	IX
RESUMO	XI
ABSTRACT	XII
1. INTRODUÇÃO	1
1.1 Objetivos	4
1.2 Justificativas	5
1.3 Estruturação dos capítulos	5
2. DEFINIÇÕES, CONCEITOS E CONSIDERAÇÕES INICIAIS	7
2.1 Condições meteorológicas ideais para fotogrametria	8
2.2 Mapas de céu claro	9
2.3 Classificação das nuvens	11
2.3.1 Nuvens orográficas	12
2.4 Dados de nebulosidade	14
2.5 Relações entre alturas de nuvens e escalas de fotografias	15
2.6 Simulações de missões de imageamento	17
2.6.1 Cadeias de Markov	18
2.6.2 O método de Monte Carlo	20
3. DADOS DE NEBULOSIDADE DISPONÍVEIS	22
3.1 Descrição da área de estudos	22
3.1.1 Aspectos importantes do relevo da região	23
3.2 Observações de nebulosidade de superfície do INMET	25
3.2.1 Registros de observações meteorológicas	25
3.2.2 Método de observação da nebulosidade	25
3.2.2.1 Cálculo do raio máximo de visibilidade	27
3.2.2.2 Observação segundo o ângulo vertical	29
3.2.2.3 Cálculo de áreas da abóbada	33

3.2.3 Rede de estações meteorológicas utilizadas	37
3.2.3.1 Outros dados de observações terrestres de nebulosidade	41
3.3 Observações de nebulosidade de satélites do programa ISCCP	42
3.3.1 Programa ISCCP	42
3.3.2 Dados do estágio DX	45
3.3.3 Projeção cartográfica usada pelo ISCCP	46
3.3.4 Formato geral dos arquivos de dados DX	48
3.3.5 Características do satélite METEOSAT	49
3.4 Avaliação do uso de imagens do LANDSAT para estudos de nebulosidade	54
3.4.1 Dados geométricos de nuvens em imagens LANDSAT	54
3.4.2 Análise visual da distribuição de nuvens em imagens LANDSAT	55
3.4.3 Verificação do incremento da nebulosidade com o aumento da área	57
4. PROCESSAMENTO DE OBSERVAÇÕES DE SUPERFÍCIE	59
4.1 Tratamento dos dados	59
4.1.1 Descrição dos dados originais do INMET	59
4.1.2 Programa de tratamento dos dados de observação de superfície (OS)	61
4.1.3 Programa ESTAT	62
4.1.4 Gráficos das séries históricas das classes de cobertura	63
4.1.5 Histogramas das médias gerais anuais	64
4.1.6 Histogramas das médias gerais mensais	65
4.1.7 Gráficos das classes 1, 2 e 3	67
4.1.8 Programa ESTCON	69
4.1.9 Banco de dados	70
4.2 Mapa de ocorrência de céu claro	71
4.2.1 Elaboração do mapa	72
4.2.1.1 Separação das sub-regiões	72
4.2.1.2 Elaboração da tabela de índices	75
4.2.1.3 Inclusão no mapa do turno com mais céu claro	79

5. PROCESSAMENTO DOS DADOS ISCCP	82
5.1 Tratamento dos dados do ISCCP	82
5.1.1 Arquivos de dados parciais reduzidos	82
5.1.2 Visualização dos dados	86
5.1.3 Interpolação dos dados	88
5.1.3.1 Interpolação com o programa SURFER	89
5.1.3.2 Dimensões da imagem interpolada	92
5.1.4 Composição das imagens multicanais	92
5.1.4.1 Transformação de dados interpolados em imagens no formato RAW	94
5.1.5 Obtenção de assinaturas de pixels	96
5.2 Classificação de áreas homogêneas de céu claro	97
5.2.1 Método de classificação com o Isodata	97
5.2.2 Testes dos resultados da classificação	98
5.2.3 Classificação de imagens de médias mensais	100
5.3 Resultados obtidos	101
6 COMPARAÇÃO ENTRE OS DADOS OS E DX	104
6.1 Comparação das curvas de freqüência de céu claro	104
6.1.1 Comparação em número absoluto de dias claros	105
6.2 Estudo das correlações e regressões entre dados OS e DX	107
6.2.1 Testes de conversão com as equações de regressão	110
6.3 Proposta de metodologia para estimar as classes 1, 2 e 3 a partir de dados DX	114
6.3.1 Exemplo de aplicação da conversão	117
7. SIMULAÇÕES DE MISSÕES DE VÔO	119
7.1 Considerações iniciais	119
7.2 Algoritmo básico	121
7.3 Modificações do algoritmo básico	122
7.4 Comparação de estimativa de tempo para execução de missões de vôo	127
7.5 Análise do resultado das simulações	129
7.5.1 Simulações com variação na quantidade de classes	130

7.5.2 Simulações com áreas menores que a área de abrangência	133
7.6 Estimativa do intervalo em horas para uma ocorrência de céu claro	136
8 CONCLUSÕES E RECOMENDAÇÕES	141
8.1 Conclusões	141
8.2 Recomendações e sugestões	145
REFERÊNCIAS BIBLIOGRÁFICAS	147
ANEXO 1 - GRÁFICOS DAS SÉRIES HISTÓRICAS	153
ANEXO 2 – GRÁFICOS DAS MÉDIAS GERAIS TOTAIS	157
ANEXO 3 – GRÁFICOS DAS MÉDIAS MENSAIS	161
ANEXO 4 – GRÁFICOS DAS CLASSES 1, 2 E 3	183
ANEXO 5 – GRÁFICOS DE DADOS OS E DX	194
ANEXO 6 – ESTATÍSTICAS DAS REGRESSÕES	201
ANEXO 7 – RESULTADOS DE SIMULAÇÕES	214

LISTA DE FIGURAS

Figura 1	Alturas de vôo para escalas 1:5.000, 1:10.000 e 1:40.000 e sua posição relativa às nuvens baixas, médias e altas	17
Figura 2	Localização da área de estudo no Nordeste do Brasil	24
Figura 3	Abóbada teórica que envolve o observador de nuvens	26
Figura 4	Elementos geométricos para cálculo do raio máximo de visibilidade	28
Figura 5	Elementos geométricos para análise do alcance da visão segundo o ângulo vertical	30
Figura 6	Superfícies no terreno referentes aos raios de visibilidade para ângulos de visão de 0°, 10° e 22,5°	32
Figura 7	Elementos geométricos para cálculo de anéis da abóbada	34
Figura 8	Gráfico LQ (Lado de Quadrado) com céu claro e percentual da abóbada encoberta conforme tabela 6	37
Figura 9	Rede de estações do INMET utilizadas pela pesquisa	39
Figura 10	Esquema de processamento de dados do ISCCP	44
Figura 11	Sistema de projeção usado para satélite geoestacionário	47
Figura 12A	Imagem do METEOSAT, banda do visível, 0,5-0,9 μm	51
Figura 12B	Imagem do METEOSAT, banda do infravermelho, absorção do vapor d' água, 5,7 – 7,1 μm	52
Figura 12C	Imagem do METEOSAT, janela do infravermelho termal, 10,5-12,5 μm	53
Figura 13	Imagem do LANDSAT, órbita 214, ponto 65, de 22.04.1995	57
Figura 14	Planilha eletrônica com os dados de nebulosidade copiados do INMET	60
Figura 15	Exemplo do arquivo de saída do programa ESTAT	62
Figura 16	Gráficos de séries históricas das classes de cobertura obtidos a partir de saída do programa ESTAT	63
Figura 17	Histogramas das médias gerais de ocorrência das classes de cobertura de Recife e Monteiro para as 18h UTC	64
Figura 18	Exemplo de Matrizes de Freqüências e gráficos das médias	

	mensais das classes de cobertura as 12h e 18h UTC, da estação Triunfo	66
Figura 19	Exemplo de gráfico das classes 1, 2 e 3 das 12 e 18 h UTC	68
Figura 20	Um exemplo da saída do programa ESTCON com parte da matriz de probabilidade condicional temporal de 24h da estação 82588 das 12h UTC	70
Figura 21	Mapa de céu claro para o NE do Brasil, segundo sub-regiões homogêneas, obtido a partir de dados de superfície do INMET	74
Figura 22	Gráficos dos índices mensais de dias claros por sub-regiões	78
Figura 23	Fluxograma de retirada dos dados referentes à área de estudos dos arquivos do ISCCP	84
Figura 24	Trecho do arquivo com dados reduzidos gerado pelo programa DXREAD2	86
Figura 25	Exemplo de imagem resultante da contagem de pixels de céu claro de Março de 1993	88
Figura 26	Exemplos do resultado de interpolações da contagem de pixels claros com o programa SURFER	90
Figura 27	Imagens no formato TIFF dos 12 meses de 1988	95
Figura 28	Assinatura de pixel da imagem multicanal, formada com as contagens mensais de céu claro	97
Figura 29	Mapa com a classificação das áreas homogêneas de ocorrência de céu claro obtido de dados ISCCP	101
Figura 30	Gráficos de comparação de comportamento mensal de dados OS e DX em Teresina e Areia	106
Figura 31	Formato da cauda da curva de distribuição das classes de cobertura a esquerda, relacionada com o percentual da classe 1	114
Figura 32	Amostras das classes 1, 2 e 3 para vários intervalos de ocorrência	116
Figura 33	Algoritmo básico para simular imageamento pelo Método de Monte Carlo	124
Figura 34	Simulação com partes fotografadas aleatoriamente em cada tentativa	125

Figura 35	Exemplo de resultados das simulações.	132
Figura 36	Simulações para Recife com as áreas de 100%; 80%; 60%; 40% e 20%	135
Figura 37	Horários de observação dos dados OS (12h, 18h UTC) e DX (12h, 15h, 18h UTC)	137

LISTA DE TABELAS

Tabela 1 – Alturas aproximadas das camadas de nuvens	12
Tabela 2 – Alturas típicas de nuvens, escalas das fotografias e medidas levantadas no terreno	16
Tabela 3 – Raio máximo de visibilidade para altitudes típicas de nuvens	29
Tabela 4 – Distância horizontal, área de abrangência para os ângulos verticais de observação de 0°, 10° e 22,5°	31
Tabela 5 – Cálculo de áreas da abóbada de raio unitário	34
Tabela 6 – Áreas reais do terreno nubladas em relação ao que é visto pelo observador abaixo do ângulo de 22,5°	36
Tabela 7 – Relação de estações do INMET usadas na pesquisa	40
Tabela 8 – Percentuais de cobertura para classes de nuvens de 1 a 5	42
Tabela 9 – Relação dos dados DX disponíveis para a pesquisa por ano e mês	46
Tabela 10 – Exemplo de cálculo de índices de dias claros para a estação João Pessoa	76
Tabela 11 – Índices das estações e índices médios por sub-regiões	77
Tabela 12 – Tabela de índices mensais de ocorrência de dias claros por sub-região para uso em conjunto com o mapa da Figura 21	79
Tabela 13 – Parâmetros físicos para definição do tipo de nuvem	85
Tabela 14 – Exemplo do número absoluto de ocorrências de céu claro com dados OS e DX para o mês de outubro às 12h em Triunfo e Campina Grande	106
Tabela 15 – Estatísticas obtidas do programa STATGRAPHICS para o ajuste do modelo linear simples entre dados DX e OS da estação Cruzeta	107
Tabela 16 – Conversão de dados DX para OS com equações de regressão de cada estação e da região	112
Tabela 17 – Cálculo do Índice de obtenção das classes 1, 2 e 3 a partir de uma média para a ocorrência de observações de céu claro	117
Tabela 18 – Resultados de estimativa de tempo (em dias) entre métodos 1, 2 e 3	129

LISTA DE ABREVIATURAS E SIGLAS

ASP	American Society of Photogrammetry
CPGCG	Curso de Pós-Graduação em Ciências Geodésicas
DAT	Digital Audio Tape
DDS	Digital Data Storage
DECART	Departamento de Engenharia Cartográfica da UFPE
DX	Tipo de dado fornecido pelo ISCCP
INCRA	Instituto Nacional de Colonização e Reforma Agrária
INMET	Instituto Nacional de Meteorologia
INPE	Instituto Nacional de Pesquisas Espaciais
ISCCP	International Satellite Cloud Climatology Project
ISPRS	International Society of Photogrammetry and Remote Sensing
ITC	International Institute for Aerial Survey and Earth Sciences Enschede
M	Manhã
MGA	Média Geral Anual
MIR	Multispectral Imaging Radiometer
MPCE	Matriz de Probabilidade Condicional Espacial
MPCT	Matriz de Probabilidade Condicional Temporal
MPI	Matriz de Probabilidade Incondicional
NASA	National Aeronautics and Space Administration
NOAA	National Oceanic and Atmospheric Administration
OMM	Organização Meteorológica Mundial
OS	Observação de Superfície
RAW	Raw File Format
SAR	Sintetic Aperture Radar
SSP	Sub Satellite Position
SUDENE	Superintendência do Desenvolvimento do Nordeste
T	Tarde
TIFF	Tagged Image File Format
UTC	Universal Time Coordinated
WCRP	World Climate Research Program
WMO	World Meteorological Organization

RESUMO

As nuvens representam um obstáculo para todas as formas de levantamentos por sistemas imageadores remotos, fotogramétricos ou por satélites, que operam na faixa espectral do visível. O problema da nebulosidade ocorre sistematicamente em todo o globo, sendo mais intenso em regiões tropicais e montanhosas. No Brasil, existem várias áreas onde a nebulosidade é constante e excessiva durante o ano todo, para as quais não existem mapas de ocorrência de céu claro atualizados que forneçam informações confiáveis para o planejamento de levantamentos fotogramétricos. Uma dessas áreas, situada na Região Nordeste, foi escolhida para realização de um estudo de caso. Essa pesquisa, que tem por objetivo estudar as possibilidades de soluções para o problema, está dividida em duas partes principais. A primeira consiste na coleta e processamento de dados de ocorrência de céu claro e a segunda refere-se à aplicação prática dos resultados, em forma de mapas ou simulações com o método de Monte Carlo. Foram utilizados dados de observação de superfície (OS) do Instituto Nacional de Meteorologia (INMET) área selecionada, e de satélites meteorológicos do International Satellite Cloud Climatology Project (ISCCP), chamados de DX, os quais sofreram tratamento estatístico apropriado de acordo com suas particularidades. Com os dados do INMET, foi obtido um mapa de céu claro que identifica perfeitamente as sub-áreas onde a ocorrência de céu completamente claro é muito baixa, e também as matrizes de probabilidades necessárias ao método de simulações. Os dados obtidos do ISCCP exigiram um grande esforço computacional para reduzir seu volume e permitir a análise. O método aplicado para visualizar os dados do ISCCP foi a composição de imagens, realizada a partir de matrizes formadas com contagens de ocorrências de pixels claros. Essas imagens formaram, em seguida, imagens multicanais, que foram classificadas pelo método de isodata para separar as áreas de nebulosidade homogêneas. As estatísticas de

ocorrência de céu claro são diferentes entre os dados DX e dados OS e para realizar a conversão entre ambos, empregou-se o cálculo de equações de regressão. Foram ainda realizadas simulações usando o método de Monte Carlo, com um algoritmo no qual foram introduzidas modificações para torná-lo mais realista nas aplicações à fotogrametria. Essas simulações mostraram que para se concluir com sucesso os levantamentos de áreas situadas em regiões de nebulosidade muito alta, a quantidade de tentativas é excessiva e que essa quantidade só pode ser reduzida se for adotado o mapeamento incremental. Ao longo do trabalho, são apresentadas as principais observações a respeito dos erros e limitações dos dados, das dificuldades encontradas no processamento de grande massa de dados e sobre a utilidade dos resultados alcançados.

ABSTRACT

Clouds are an obstacle for all types of surveys by remote imaging systems, photogrammetric or by satellites, that work in the visible spectral range. The problem of cloudiness occurs in all the World, but it is more intensive in tropical and mountainous regions. In Brazil, there are several areas where the cloudiness is constant and excessive in all seasons, and for those areas, there are not updated clear sky maps that provide reliable information to support the photogrammetric survey planning. The main objective of this thesis is searching alternative methods which can help to solve these questions and how statistics of clear sky can be used better. For that, one area, situated on Northeastern, was chosen for a Case Study, and the thesis is divided in two parts. The first one is related to collecting and processing of data, and the second one presents the results of practical applications, as maps and simulations by Monte Carlo Method. Data of surface observations (SO) from INMET (Instituto Nacional de Meteorologia) and DX data type, from meteorological satellite of ISCCP (International Satellite Cloud Climatology Project), were used. The SO data are used to making a clear sky map and to obtain probability matrices to enter in the simulation program. The DX data were used to form multi-channels images, after a big work to compact the mass data. These images were classified by isodata cluster method to separate areas of homogeneous cloudiness. Simulation results by Monte Carlo Method showed that the possible option, to photogrammetric surveys in excessively cloudy areas, is adopting the incremental mapping. Also, problems with data errors and limitations, processing and general results are presented and discussed.

1. INTRODUÇÃO

As nuvens representam um obstáculo para todas as formas de levantamentos baseados em sistemas imageadores aerotransportados ou orbitais que operam na faixa espectral do visível. O problema de nuvens para o imageamento ocorre sistematicamente em todas as regiões do globo, tendo sido estudado intensivamente pela National Aeronautics and Space Administration (NASA) para avaliar a probabilidade de aquisição de imagens de satélites (GREAVES ET AL., 1971). As nuvens são citadas como problema no mapeamento em regiões tropicais (POHL, 1996) e montanhosas (BUCHROITHNER & KOSTKA, 1997). No Brasil esse problema foi estudado pelo Instituto Nacional de Pesquisas Espaciais (INPE) (MAURÍCIO, 1987; MENDONÇA & NETTO, 1983).

A nebulosidade é o fator mais incerto numa missão de levantamento fotogramétrico (SLAMA, 1980) e ainda sem solução. No Brasil, existem áreas da região Norte, Nordeste e do Estado de Minas Gerais especialmente difíceis para levantamentos fotogramétricos devido a uma constante e excessiva nebulosidade.

O procedimento típico da tripulação, quando designada para executar um vôo fotogramétrico, é se deslocar para uma base próxima da área e ficar aguardando condições favoráveis. As decisões sobre os vôos são tomadas diariamente com base na visualização do céu. Caso ocorram nuvens no local a única solução é simplesmente esperar por tempo totalmente claro. De um modo geral, são obedecidas as especificações do contrato e, no máximo, são feitos alguns vôos "tentativas". A maioria das especificações usadas no Brasil, bem como aquelas recomendadas por entidades como a International Society of Photogrammetry and Remote Sensing (ISPRS) e American Society of Photogrammetry (ASP) têm cláusula bem clara, definindo que não serão aceitas fotografias com nuvens e que a faixa ou trecho que as apresentem devem ser revoados. No entanto, existem algumas especificações mais

flexíveis, como as do Instituto Nacional de Colonização e Reforma Agrária (INCRA), para o Projeto Nordeste, ou as do International Institute for Aerial Survey and Earth Sciences Enschede (ITC), que opcionalmente apresentam a possibilidade de serem aceitas fotografias com 5% ou 10% de nuvens.

No Brasil, as empresas usam, para o planejamento do voo e fins de orçamento, cartas ou mapas que trazem a quantidade média mensal dos dias claros (cobertura zero de nuvens) por regiões e que auxiliam a identificar as épocas mais favoráveis à execução de vôos durante o ano. Esses mapas, no entanto, não satisfazem às necessidades de planejamento de vôos em muitas regiões do País por estarem desatualizados, não serem suficientemente detalhados quanto à separação das áreas climatológicas homogêneas e não darem informações complementares quanto ao nível de confiança dos dados usados e do mapa em si.

Na literatura especializada, os artigos e bibliografia que tratam de estatística e mapas de nuvens voltada para a fotogrametria são raros. Não foi localizado nenhum artigo que discutisse algum tipo de solução para as regiões que apresentam nebulosidade constante e excessiva. O Manual of Photogrammetry (SLAMA, 1980) reproduz o mapa da expectativa de dias claros para os EUA elaborado em 1939 por F. J. Sette, atualizado em 1984 por LEE & JOHNSON (1985). Para o Canadá, existem os mapas apresentados em FLEMING (1971) e para a Austrália as tabelas de MYERS & WATTS (1981). KRICK (1956) discute a conveniência de existirem empresas consultoras especializadas na previsão de condições favoráveis para planejamento de vôos fotogramétricos e mostra os mapas e gráficos necessários para isso. THOMAS (1963) apresenta um estudo sobre a possibilidade de uso dos registros de insolação obtidos com o instrumento Campbell-Stokes para estimar as condições de nebulosidade, mas sem bons resultados.

No Brasil, os trabalhos voltados para a fotogrametria têm cunho prático e limitam-se a apresentar mapas mensais com as possíveis áreas favoráveis de céu claro, sem informações sobre os dados utilizados, como o tipo,

procedência e qualidade, como os de CHEDE & CHEDE (1985) e 1°/6° GAV, 19??). Desse último não foi possível conseguir sequer a data de sua elaboração. A exceção é o trabalho de GIRARDI (1973) que é resultado de imagens do satélite meteorológico ESSA, mas que não discute a metodologia usada para gerar os mapas.

A nebulosidade é um problema ainda não resolvido para a fotogrametria e conseqüentemente também para o mapeamento (BUCHROITHNER & KOSTKA, 1997). O mapeamento de grandes áreas pode evidentemente ser realizado também com outras técnicas, incluindo medições diretas. Mas, usando técnicas fotogramétricas, a única proposta encontrada foi a de usar câmaras equipadas com intensificador sensível ao infravermelho que permite a tomada de fotografias à noite (LAPP & GROENING, 1975). Esta seria uma forma de aproveitar as maiores probabilidades de céu limpo que ocorrem à noite, mas não se tem notícia de aplicação desta metodologia que não seja para aplicações militares.

A solução mais completa, usando sistemas imageadores, é o uso de radares de visada lateral do tipo SAR. Este tipo de radar pode gerar modelos digitais do terreno a partir de imagens estereoscópicas ou de imagens processadas com interferometria (MERCER, 1995). A técnica da interferometria que começou recentemente, a partir dos anos 90, permite obter o relevo com alta precisão. As limitações das imagens de radar ainda são a dificuldade para interpretação da cobertura do terreno, quando comparada com as fotografias e as imagens multi-espectrais dos satélites óticos. Algumas empresas comerciais nos EUA e Alemanha já executam mapeamento em escalas grandes como 1:2.000 (MOREIRA, 1996). Imagens de radar foram utilizadas para executar seis cartas na escala 1:100.000 no Nordeste em 1999, patrocinadas pela SUDENE, de uma das áreas onde as nuvens impediram as várias tentativas de levantamento fotogramétrico.

1.1 Objetivos

O objetivo principal deste trabalho é definir uma metodologia capaz de fornecer informações confiáveis sobre as ocorrências de céu claro, inclusive em regiões de nebulosidade excessiva o ano todo, e como utilizar essas informações para o planejamento de vôos fotogramétricos.

Para atingir esse objetivo geral, de definição e testes de metodologias, foi escolhida uma região situada no extremo oriental do Nordeste do Brasil, onde existem áreas já reconhecidas como difíceis para a execução de vôos fotogramétricos. A pesquisa foi dividida em objetivos específicos que envolvem o estudo detalhado da obtenção de estatísticas de nebulosidade, o processamento dos dados e uso dos resultados, incluindo as adaptações à aplicações fotogramétricas. Estes objetivos constituem verdadeiras etapas e são os seguintes:

- estudar as estatísticas existentes de nebulosidade obtidas a partir de observações de superfície e de satélites meteorológicos da região escolhida;
- gerar mapas de ocorrência de céu claro a partir de observações de superfície, com uma metodologia já testada;
- gerar mapas de ocorrência de céu claro a partir de observações de satélites, com uma metodologia proposta;
- verificar as correlações, possibilidades de formas de conversão, vantagens e desvantagens de cada tipo de dado;
- adaptar o uso de simulações com o método de Monte Carlo para obter o número de tentativas de vôos fotogramétricos necessários para fotografar com sucesso 100% da área;
- discutir forma alternativa de execução de vôo fotogramétrico em áreas de nebulosidade excessiva.

1.2 Justificativas

Como a fotogrametria continua sendo o melhor método para a execução de mapeamento de grandes áreas, o problema das nuvens deve ser discutido e melhor estudado, visando fornecer informações confiáveis que possam reduzir o tempo gasto num levantamento. Uma solução que otimize o uso de fotogrametria em regiões com excesso de nuvens contribuirá para aumentar sua área de atuação, para manter a competitividade com outras formas de sensoriamento remoto e para continuar a utilização do enorme potencial instalado nas empresas de aerolevantamentos no Brasil e no exterior.

Existe a necessidade da elaboração para o Brasil de cartas de condições favoráveis à execução de vôos fotogramétricos com maior detalhamento e melhor confiabilidade estatística. Para a elaboração de mapa desse tipo nota-se que falta, não somente no Brasil, uma metodologia específica de coleta e processamento de dados que possa inclusive identificar regiões consideradas problemáticas para a execução de vôos fotogramétricos, devido a existência de nebulosidade constante e excessiva todo o ano e que assim nunca têm uma época favorável.

Além da fotogrametria, as aplicações da presente pesquisa podem ser estendidas para estimativa de sucesso dos satélites imageadores de alta resolução no terreno (1m a 5m) que estão em operação ou previstos para lançamento em breve.

1.3 Estruturação dos capítulos

Os capítulos foram estruturados na mesma seqüência das etapas que foram seguidas ao longo do desenvolvimento das pesquisas.

No capítulo 1 são apresentados a completa identificação do problema, objetivos e justificativas. No capítulo 2 são tratados os conceitos julgados mais

importantes para toda a pesquisa, com citações das referências básicas sobre os diversos assuntos. Nesse sentido, vale salientar a dificuldade de encontrar bibliografia específica para as estatísticas de nebulosidade voltadas para o uso em fotogrametria, sendo que basicamente foram usados estudos feitos para satélites. No capítulo 3 são apresentados em detalhes os dados de nebulosidade de observações de superfície cedidos pelo INMET e os de satélites meteorológicos cedidos pelo ISCCP. No capítulos 4 são descritas as etapas de processamento das observações de superfície, que foram realizadas com os objetivos de se obter as matrizes de probabilidades necessárias ao método de simulações e na preparação um mapa de céu claro. No capítulo 5 são descritas as etapas e os métodos desenvolvidos para manipular, processar e visualizar, a grande massa de dados de satélites, até se chegar a um mapa com a classificação da área de estudo em regiões homogêneas. No capítulo 6 são apresentados estudos de comparação entre os dados, realizados com cálculo das correlações e regressões com o modelo linear simples, e a proposta de um método para a conversão de uma observação de satélite na sua equivalente observação de superfície. No capítulo 7 discute-se o programa, o algoritmo básico do método de Monte Carlo e as modificações introduzidas para adaptá-lo às simulações de vôos fotogramétricos. Além disso, são apresentados e discutidos os números de tentativas necessários para se concluir uma missão de fotogrametria com sucesso, obtidos como resultados das simulações. Finalmente, o capítulo 8 traz as conclusões e recomendações.

2. DEFINIÇÕES, CONCEITOS E CONSIDERAÇÕES INICIAIS

Nesse capítulo são apresentadas algumas definições, conceitos e considerações iniciais que serão abordados nas várias etapas da presente pesquisa. Eles envolvem os procedimentos adotados, a coleta de dados e métodos de trabalho necessários para atingir os objetivos principais e específicos. Ao longo do desenvolvimento dos capítulos serão apresentadas outras definições e conceitos que se fizerem necessários.

2.1 Condições meteorológicas ideais para fotogrametria

Um vôo fotogramétrico, para fornecer fotografias de ótima qualidade, ideais para as etapas posteriores de fototriangulação e restituição, deve necessariamente ser realizado sob condições meteorológicas especiais. Essas condições são as seguintes, segundo SLAMA (1980):

- o ar deve estar livre de nuvens, fumaça e bruma;
- o Sol deve estar suficientemente alto;
- a velocidade do vento e a turbulência do ar na altura do vôo devem ser mínimas.

A presença de nuvens impede a visibilidade do terreno e ainda provoca sombras, sendo assim indesejável nas fotografias. De um modo geral, quase todas as especificações de levantamentos fotogramétricos fazem sérias restrições à existência de nuvens e sombras nas fotografias, com poucas exceções: em alguns casos é permitido, no máximo, 10% em fotografias isoladas e em partes que não prejudiquem a restituição; e em regiões de muita nebulosidade, admitem-se nuvens altas pouco espessas, acima da altura de vôo. FLEMING (1971) admite nessas condições até 20% de nuvens e MYERS & WATTS (1981) chegam a considerar benéficas as nuvens altas tipo cirrus, nas fotografias de baixa altitude, por reduzirem o excesso de luz do Sol. Além

das nuvens, a fumaça de queimadas, comum em vastas regiões do Brasil em certas épocas do ano, e a poluição das cidades, reduzem a visibilidade prejudicando os vôos. O planejamento do vôo em virtude da ocorrência de nuvens é feito com a ajuda de mapas de céu claro.

A altura do Sol, ou ângulo de elevação, influencia a iluminação do terreno e o comprimento das sombras. A superfície do terreno, com o Sol a 30° , tem apenas $2/5$ da luminosidade que teria a 60° . Também o excesso de luminosidade não é desejável nas fotografias, pois prejudica a estereoscopia em superfícies claras (por exemplo, cruzamento de estradas em fotografias de escala pequena); e sombras muito fortes impedem a observação de detalhes. O comprimento das sombras ajuda ou prejudica conforme sua extensão. Quando a sombra é curta, ajuda na interpretação de detalhes, como postes e cercas, e quando é longa encobre detalhes. A especificação normal da altura mínima do Sol é de 30° , mas para as latitudes maiores podem ser aceitos 15° (KRIC, 1956) ou 20° (FLEMMING, 1971). Em regiões tropicais pode ser necessário também definir uma altura máxima para o Sol, como 60° , para evitar reflexos em neblina e superfícies de água. O intervalo das horas do dia em que o Sol está acima dos limites da altura mínima é facilmente determinado utilizando-se nomogramas dos tipos mostrados em PARRY & GOLD (1972) ou MONTENEGRO (1983), ou ainda com ajuda de programas de computador, nos quais se entram com a latitude e a época do ano.

Os ventos influenciam na alteração da posição da aeronave. A turbulência provoca movimentos bruscos com conseqüências danosas para a geometria e resolução da imagem. Ventos fortes em direção transversal às linhas de vôo podem provocar deriva exagerada.

Além das condições meteorológicas ideais no momento da tomada da fotografia, o clima local também influi no comportamento dos componentes da fotogrametria convencional. A temperatura excessivamente baixa ou alta pode influir na eficiência das lentes, na operação da câmara e na conservação do filme. A umidade tem grande efeito na estabilidade dimensional do filme, sendo

necessário prever o controle dessas condições durante a tomada das fotografias e no armazenamento. Umidade muito alta pode causar condensação em várias partes da câmara se a temperatura cair rapidamente. As dificuldades aumentam com a altura do vôo. As aeronaves, para fotografar em altitudes acima de 20.000 pés (6.096m), devem ter dispositivos de aquecimento e cabines pressurizadas. Para as câmaras digitais, com sensores tipo CCD para aplicações fotogramétricas, que atualmente começam a surgir no mercado, ainda não são conhecidos os possíveis efeitos danosos do clima.

Mais detalhes sobre especificações dos cuidados necessários na realização de vôos fotogramétricos podem ser encontrados em SILVA & DAMOLIN (2000a) e SLAMA (1980).

2.2 Mapas de céu claro

O planejamento de vôos fotogramétricos é feito a partir da coleta de vários tipos de informações sobre a área a ser levantada. Entre elas, há a necessidade de conhecimento sobre a frequência de dias de céu completamente claro. Esse tipo de informação, quando disponível, é dado em forma de tabelas, mapas de isolinhas, mapas isopléticos ou mistos. Os exemplos encontrados são os seguintes:

- Tabelas: organizadas por MYERS & WATTS (1981) para a Austrália, por estação meteorológica e por Estado. Mostram a probabilidade média de possível ocorrência de condições favoráveis para fotografias sob céu nublado com nuvens altas e finas, separadas em ideais, boas e aceitáveis;
- Isolinhas: mostram a distribuição média mensal, em horas, favorável para vôo fotogramétrico no Canadá (FLEMING, 1971).
- Isopléticos: são os do tipo usado no Brasil atualmente, como os de GIRARDI (1975), CHEDE & CHEDE (1985) e 1º/6º GRUPO DE AVIAÇÃO (GAV) da Aeronáutica. Os mapas, um para cada mês, mostram as áreas consideradas favoráveis para vôos;

- Misto : do tipo produzido por Sette para os EUA em 1939 e atualizados por LEE & JOHSON (1985). É formado por um único mapa dividido em regiões e uma tabela com os índices multiplicadores mensais de cada região, que são aplicados sobre as médias de dias claros de cada estação. Esse tipo será adotado como modelo para produzir um mapa com os dados de nebulosidade do INMET no capítulo 4.

Os mapas de céu claro devem trazer informações que permitam ao planejador conhecer as épocas favoráveis do ano para a realização dos vôos. Por outro lado como a região de estudos tem problemas com a existência de muita nuvem serão definidos a seguir os termos usados com frequência em todo o trabalho:

- a) Nebulosidade é a quantidade de nuvens que existe no céu;
- b) Época favorável. Uma época será considerada favorável, para fins dessa pesquisa, quando ocorrerem no mínimo 23% dos dias de um mês (sete dias) de céu limpo em determinada região. Esse valor é o adotado por GIRARDI (1973) e abaixo dos 30% adotados nos mapas do 1°/6° GRUPO DE AVIAÇÃO (19??).
- c) Região de nebulosidade alta ou excessiva. É a região que apresenta nebulosidade acima da quantidade admitida para a realização de vôos fotogramétricos.
- d) Região de nebulosidade constante. É a região que apresenta pouco ou nenhum mês que seja classificado como época favorável.

2.3 Classificação das nuvens

O processo de formação das nuvens, sua classificação e importância no clima e na previsão do tempo são assuntos tratados em detalhe nos livros de meteorologia básica. Esse trabalho aborda, portanto, o mínimo necessário que tem implicações diretas com o entendimento da origem das estatísticas usadas.

A formação das nuvens é resultado da condensação de vapor de água e da existência de três condições: ar saturado, da presença de núcleos higroscópicos e resfriamento por movimento ascendente do ar. O ar está saturado quando atinge a quantidade máxima de vapor d'água que pode conter numa certa temperatura. A saturação pode então ocorrer pelo aumento da quantidade de vapor d'água ou pelo resfriamento por movimento ascendente do ar. A presença de núcleos higroscópicos, também chamados de núcleos de condensação ou aerossóis, favorecem o processo de condensação do vapor, mesmo com o ar não saturado, e estão na atmosfera sob a forma de partículas de poeira, sal marinho, fuligem ou fumaça. Nas grandes altitudes, o vapor pode passar diretamente para o estado sólido, formando também nuvens, sem necessidade do núcleo higroscópico.

As nuvens estão em processo contínuo de evolução, passando por fases de desenvolvimento, maturação e dissipação. Mesmo assim, é possível definir formas características e classificá-las por gênero, espécie ou variedade. Entre essas classificações, a mais importante no contexto desta pesquisa é a classificação por gênero, em que se pode distinguir os seguintes tipos de nuvens: cirrus, cirrocumulus, cirrostratus, altocumulus, altostratus, nimbostratus, stratocumulus, stratus, cumulus e cumulonimbus. Além da classificação, convencionou-se dividir a atmosfera em três camadas: inferior ou baixa, média, e superior ou alta. Os limites das camadas não são precisos e

entre outras coisas, variam com a latitude. A Tabela 1 mostra os limites que segundo SONNEMAKER (1997) são do Atlas Internacional de Nuvens da Organização Meteorológica Mundial (OMM).

Tabela 1 - Alturas aproximadas das camadas de nuvens

Camadas	Região Polar	Região Temperada	Região Tropical
Inferior	0 a 2 km	0 a 2 km	0 a 2 km
Media	2 a 4 km	2 a 7 km	2 a 8 km
Superior	3 a 8 km	5 a 13 km	6 a 18 km

Fonte: SONNEMAKER (1997)

O INMET usa a classificação e a codificação apresentada no Quadro 1, que também segue o padrão da OMM. As nuvens da camada inferior são codificadas por C_L , as da média, por C_M e as da superior, por C_H .

2.3.1 Nuvens Orográficas

As nuvens orográficas são formadas a barlavento de uma colina, montanha isolada ou cadeia de montanhas, quando o ar úmido e instável é forçado a ascender pelas encostas.

Observa-se, na área de estudo, a ocorrência freqüente desse tipo de nuvem, quando as serras da região barram os vento úmidos de Sudeste, vindos do Oceano Atlântico.

As nuvens orográficas formadas por acidentes topográficos dentro da área de abrangência de uma estação meteorológica contribuem para elevar a média local da nebulosidade, sem que seja possível quantificar essas nuvens separadamente. A forma de avaliação da nebulosidade que é empregado nas estações meteorológicas será visto em detalhes no capítulo 3.

Quadro 1 - Classificação de nuvens usada pelo INMET de acordo com a OMM

NUVENS BAIXAS C _L
1. Cumulus de bom tempo
2. Cumulus (h=600-1000m) congestus com torres
3. cumulus nimbus (h=600-1000m) (sem coroa de cirrus)
4. Stratocumulus (h=1000-1500m) derivado de cumulus
5. Stratocumulus (h=1000-1500m)
6. Stratus (h= 50-100m)
7. Nimbostratus ou Stratus de mau tempo
8. Cumulus e Stratocumulus não derivado de cumulus (h=300-600m)
9. Cumulonimbus com coroa de cirrus
NUVENS MÉDIAS C _M
1. Altostratus translúcidos (h> 2500m)
2. Altostratus opacos ou nimbostratos
3. Altocumulus translúcidos num só nível (h>2500)
4. Altocumulus translúcidos em bancos ou lenticulares (h>2500)
5. Altocumulos em faixas ou camadas, aumentando ou espessando (h>2000 a 2500)
6. Altocumulus derivados de cumulus
7. Altocumulus em camada dupla, ou opacos ou associados a altostratus (h = 2000–2500)
8. Altocumulus em tufo cumuliformes (h=2000-2500)
9. altocumulus em céu caótico entre véus fibrosos
NUVENS ALTAS C _H
1. Cirrus em filamentos, esparsos não aumentando
2. Cirrus densos, em bancos
3. Cirrus derivados em cumulonimbus
4. Cirrus em fibras, com garras, aumentando
5. Cirrus ou cirrostratos, em faixa aumentando, não atingindo 45° de altura
6. Cirrus ou cirrostratos, em faixa aumentando, excedendo 45° de altura
7. Cirrostratus cobrindo todo o céu
8. Cirrostratus não cobrindo todo o céu
9. Cirroscumulus predominantes

Fonte: INMET

2.4 Dados de nebulosidade

Os dados estatísticos de nebulosidade mais comuns são os dados de observação de superfície (OS) e de satélites meteorológicos. Para as aplicações em fotogrametria interessam principalmente as estatísticas de nebulosidade zero, ou céu claro.

Os dados de nebulosidade de observações de superfície são obtidos diariamente em estações meteorológicas do INMET, aeroportos e outras organizações públicas estaduais e federais, por um observador que avalia e registra a quantidade de nuvens que cobre o céu. A quantidade de nuvens pode ser avaliada em décimos ou oitavos do céu que estão cobertos. Para fins desta pesquisa adotou-se a convenção que a nebulosidade é dividida em classes de cobertura que variam de 1 a 10, incluindo na classe 1 a ocorrência de céu completamente claro (classe 0).

Os satélites passaram a ser uma fonte importante de dados para estudos meteorológicos desde os anos 60 (MANSON & SCHMETZ, 1992). Os satélites como NOAA, GOES ou METEOSAT registram imagens digitais de uma ou mais bandas do espectro eletromagnético, em intervalos de trinta minutos e têm alta resolução no terreno, de 1km a 7 km. As imagens mostram as grandes massas de nuvens, mas para se ter certeza se um pixel é nublado ou não, há necessidade de um processamento posterior complexo. As classes de nebulosidade, nesse caso, são obtidas calculando-se o percentual dos pixels nublado sem relação aos claros presentes em uma área de determinado tamanho.

Devido à sua alta resolução temporal e espacial, as imagens de satélites meteorológicos têm as características ideais para o estudo estatístico de nebulosidade para fins fotogramétricos, porém o processamento envolve um grande esforço computacional, além de algoritmos sofisticados para detecção das nuvens, que torna inviável usar os dados na forma original. Devido a essa

dificuldade, serão usados dados já pré-processados cedidos pelo International Satellite Cloud Climatology Project (ISCCP).

2.5 Relações entre alturas de nuvens e escalas de fotografias

As relações entre as alturas das bases das nuvens, que ocorrem em dado momento, e a altura de vôo necessária para a escala prevista das fotografias, podem definir se é possível ou não executar um vôo. Além disso, as escalas determinam as áreas fotografadas no terreno e têm relação com a produtividade.

Nessa seção, serão mostrados exemplos meramente ilustrativos que envolvem alturas de nuvens e de vôos. O primeiro exemplo, representado na Figura 1, mostra as alturas de vôo e de nuvens. O segundo, apresentado na Tabela 2, mostra os resultados dos cálculos relacionados com áreas fotografadas no terreno e áreas levantadas em uma hora de vôo. Esses resultados serão úteis em futuras discussões, e foram obtidos a partir de considerações detalhadas a seguir.

As alturas das bases das nuvens variam desde o nível do solo até vários quilômetros, como visto no Quadro 1, mas para o exemplo foram escolhidas como representativas para cada nível baixo, médio e alto, respectivamente, 600m, 2.000m e 6.000m.

As escalas escolhidas 1:5.000, 1:10.000, 1:20.000 e 1:40.000 representam bem a maioria dos vôos executados no Brasil e abrangem as alturas das bases das nuvens baixas (600m), médias (2000m) e altas (6000m), dos gêneros cumulus, altocumulus e cirrus respectivamente. Como as alturas de vôo dependem das características da câmara fotogramétrica elas são: distância focal de 153mm, formato do negativo 23 cm x 23cm.

A Figura 1 mostra as posições relativas das alturas de vôos para cada escala e a posição correspondentes das nuvens. A figura mostra ainda que as nuvens mais comuns na região, cumulus e altocumulos impedem os vôos em


escala grande de 1:5.000. Por outro lado, as nuvens altas, tipo cirrus, a 6km de altitude, podem permitir vôos até a escala 1:20.000, porém não é possível, com os tipos de dados disponibilizados para esta pesquisa, separar as ocorrências dos tipos de nuvens por área, como fez MYERS & WATTS (1971) para a Austrália, e tirar vantagem dessa possibilidade.

Para completar o exemplo, serão calculados para cada escala a extensão total coberta no terreno por uma fotografia, a extensão útil para um recobrimento longitudinal de 60%, a área útil fotografada no terreno descontando o recobrimento lateral de 20%, o intervalo entre a tomada de duas fotografias consecutivas, considerando-se uma aeronave com velocidade de 280 km/h (77,77 m/s); e a área total levantada em uma hora de vôo. A Tabela 2 mostra os valores do exemplo calculado.

Tabela 2 - Extensões cobertas no terrenos para fotografias nas escalas 1:5.000, 1:20.000 e 1:40.000 e áreas totais levantadas em uma hora de vôo

ESCALA	ALTURA DE VÔO	EXTENSÃO TOTAL	EXTENSÃO ÚTIL	ÁREA ÚTIL (LAT 20%)	INTERVALO	ÁREA TOTAL
	m	Km	Km	km²	s	km²
1:5.000	765,0	1,14	0,69	0,42	6	250,8
1:10.000	1530,0	2,28	1,38	1,68	12	504,0
1:20.000	3060,0	4,57	2,74	6,69	23	1043,5
1:40.000	6060,0	9,14	5,49	26,76	47	2033,4

Figura 1 - Alturas de vôo para escalas 1:5.000, 1:10.000, 1:20.000 e 1:40.000 e sua posição relativa às nuvens baixas, médias e altas.



2.6 Simulações de missões de imageamento

As simulações para levantamentos fotogramétricos devem dar ao planejador das missões de vôo informações sobre as probabilidades de sucesso de se executar um vôo em determinada região, numa certa época do ano ou na melhor época. Devem ser respondidas perguntas do tipo: "Quantos dias ou horas serão gastos a um nível de confiança de 95% para fotografar 100% da área x?". Ou, caso exista alguma restrição de limite de tempo para a execução do serviço: "Com qual nível de confiança pode-se esperar fotografar a área x em y horas?".

Segundo BROWM (1969) pode ser demonstrado que, para uma região muito nublada, a análise combinatória conclui que podem ser necessárias cem passagens independentes para que seja encontrada uma passagem sem nuvens em condições ideais para fotografar uma área de 100 milhas náuticas

(185,2km) de diâmetro. Já com o método de simulação que aceite a cobertura incremental (com mosaico de imagens sucessivas), a mesma área pode ser fotografada em cerca de dez passagens.

As estatísticas e simulações para planejamento de missões de imageamento por satélite foram estudadas e financiadas inicialmente pela NASA, nos anos 60, o que resultou em vários relatórios de pesquisa (SALOMONSON, 1969 ; GREAVES ET AL., 1971; SHERR ET AL., 1968).

As simulações, para serem efetuadas, necessitam de um modelo do comportamento da ocorrência de cobertura das nuvens. Segundo GRINGORTEN (1966,1970) e outros autores, o processo meteorológico da nebulosidade pode ser adequadamente modelado por cadeias de Markov. Mesmo que a distribuição de probabilidade (frequência) da variável aleatória não seja normal, considera-se que a variável pode ser transformada em uma nova variável Y que obedece à distribuição normal padrão, N(0,1). O processo para realizar essa conformação de variáveis é feito usando o método de Monte Carlo, que funciona, no caso, com base no Teorema Central do Limite (ROSS,1997).

2.6.1 Cadeias de Markov

Observações de variáveis que têm um comportamento aleatório a medida em que o tempo passa constituem processos estocásticos. Certas particularidades nas repetições de seqüências e valores das variáveis definem modelos matemáticos, entre os quais a cadeia de Markov.

A cadeia de Markov é um processo estocástico cuja definição geral é a seguinte: a seqüência aleatória $\{ X_1, X_2, \dots, X_n \}$ é dita seqüência dependente de Markov ou processo de Markov, caso a probabilidade condicional

$$p(i_n | i_1, \dots, i_{n-1}) = P[X_n=i_n | X_1=i_1, \dots, X_{n-1}=i_{n-1}] \quad (1)$$

dependa apenas dos valores de i_n e i_{n-1} , ou seja ,

$$p(i_n | i_1, \dots, i_{n-1}) = p(i_n | i_{n-1}) = P[X_n=i_n | X_{n-1}=i_{n-1}] \quad (2)$$

Em tal processo, o resultado da ocorrência do evento anterior não influi na predição do próximo. O processo de Markov é chamado de processo sem memória, pois os estados anteriores ao presente não influenciam o próximo estado futuro.

As demonstrações das propriedades das cadeias de Markov e suas classificações constam dos textos sobre processos estocásticos como TAYLOR & KARLIN(1994) e KEMENY & SNELL(1960). Aqui serão definidos apenas os conceitos estritamente úteis e incorporados no algoritmo de simulação com o método de Monte Carlo no capítulo 7.

Aos eventos do processo aleatório que ocorrem sucessivamente no tempo, é usual chamá-los de estados. Portanto X_n está no estado i se $X_n=i$. É conveniente para lidar com vetores de probabilidades e matrizes que a notação seja um pouco alterada. Com essa finalidade p_{ij} passa a indicar a probabilidade condicional que X_i ocorreu no tempo n , desde que X_j ocorreu no tempo $n-1$. O conjunto de todas as probabilidades condicionais p_{ij} formam a chamada matriz de transição P . O exemplo abaixo mostra uma matriz com três estados.

$$P = \begin{vmatrix} p_{11} & p_{12} & p_{13} \\ p_{21} & p_{22} & p_{23} \\ p_{31} & p_{32} & p_{33} \end{vmatrix}$$

Nos casos em que se passa do estado i para o estado j independentemente do tempo a cadeia de Markov é chamada de estacionária.

2.6.2 O Método de Monte Carlo

O Método de Monte Carlo começou a ser usado nos anos 40 (MEYER,1954). Atualmente é usado com sucesso em diferentes áreas como administração, economia, sociologia, física e engenharia. O método pode ser considerado como uma representação de um sistema matemático ou físico, que utiliza um procedimento de amostragem que satisfaça às mesmas leis de probabilidade do sistema (BHARUCHE-REID, 1970). Portanto também pode ser aplicado para o estudo de processos estocásticos que envolvem cadeias de Markov (GILKS ET AL, 1999). O método é indicado na solução de problemas quando existem uma das seguintes condições (GIBRA, 1973):

- o sistema a ser estudado não pode ser analisado usando-se diretamente os métodos analíticos formais;
- quando os métodos analíticos são complexos, demorados e custam muito;
- quando não podem ser realizadas experimentações diretas;
- quando as soluções analíticas estão acima do conhecimento matemático dos analistas da operação.

Os elementos básicos do método, que se baseia na Lei dos Grandes Números (ROSS, 1997), são as variáveis aleatórias, suas distribuições de probabilidades e uma seqüência de números aleatórios. Supondo-se que X seja um vetor aleatório discreto, cujo conjunto de valores possíveis é $x_j, j \geq 1$ e seja a função de probabilidade X dada por $P\{X=x_j\}, j \geq 1$, e que se deseja calcular Θ como uma função específica de h :

$$\Theta = E[h(X)] = \sum_{j=1}^{\infty} h(x_j)P\{X = x_j\} \quad (4)$$

Uma vez que a função $h(x_j), j \geq 1$ é difícil de ser avaliada, com o método de Monte Carlo se chega a uma aproximação de Θ . Usando-se números aleatórios é gerada uma seqüência de vetores X_1, X_2, \dots, X_n , independentes e

uniformemente distribuídos, tendo como função de probabilidades $P\{X=x_j\}$, $j \geq 1$.
Pela Lei dos Grandes Números,

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{j=1}^{\infty} h(X_i) = \Theta \quad (5)$$

Pode-se então estimar Θ com um n suficientemente grande e com a média dos valores de $h(x_i)$, $i=1 \dots n$.

O método funciona mesmo nos casos em que X é um vetor de variável aleatória dependente, desde que seja possível gerar uma seqüência de sucessivos estados de vetores de uma cadeia de Markov X_1, X_2, \dots, X_n , com probabilidades estacionárias $P\{X=x_j\}$, $j \geq 1$ (ROSS, 1997).

Mais detalhes sobre as aplicações e teoria do Método de Monte Carlo podem ser encontrados nas referências citadas anteriormente.

3. DADOS DE NEBULOSIDADE DISPONÍVEIS

Nesse capítulo será descrita a área de estudos escolhida para a pesquisa, serão detalhados os dados de nebulosidade de observação de superfície e do ISCCP e avaliadas imagens do satélite LANDSAT.

Para os dados de observação de superfície serão discutidas as questões geométricas que envolvem a avaliação da nebulosidade, que induzem o observador a erros e a superestimá-la, e ainda relaciona-se a rede de estações meteorológicas usadas. Para os dados obtidos do ISCCP, serão dadas informações gerais e as características do satélite METEOSAT que originou os dados.

As imagens do satélite de observação LANDSAT são avaliadas para serem verificadas suas potencialidades de fornecerem elementos geométricos das nuvens.

3.1 Descrição da área de estudo

A área de estudo compreende a parte oriental da região Nordeste do Brasil, situada entre as latitudes 3° e 13° S e longitudes 44° e 34° W (Figura 2).

Essa área foi escolhida porque inclui duas regiões reconhecidamente difíceis para o planejamento de missões de vôos fotogramétricos, onde mesmo o mapeamento sistemático patrocinado pela SUDENE não foi concluído (SUDENE, 1997). Uma delas, que corresponde a seis cartas na escala 1:100.000, situada entre latitudes 6° 30' e 9° 30' S e longitudes 35°30' e 36° W, foi mapeada apenas recentemente, utilizando-se imagens estereoscópicas de radar, que não sofrem a interferência das nuvens. A outra área, situada ao norte da cidade de Feira de Santana-BA ainda não dispõe de cartas.

3.1.1 Aspectos importantes do relevo da região

O relevo da região tem influência marcante na distribuição da nebulosidade. TORSANI & VISWANADHAN (1981) destacam como importantes na área a Serra Grande, no sentido norte-sul, nos Estados do Ceará e Piauí, a Chapada do Araripe, sentido leste-oeste, no centro da área, e a Chapada Diamantina e parte da Serra do Espinhaço, na parte sul da área (Figura 9).

O estudo de TORSANI & VISWANADHAN (1981) analisou a nebulosidade segundo as estações do ano. No verão (Dezembro, Janeiro, Fevereiro), os autores destacam uma região de baixa frequência de nebulosidade, ao sul da Chapada do Araripe, e outra de valores altos localizados na região da Serra Grande e Chapada do Araripe. Uma segunda região com alta nebulosidade, entre as latitudes de 10° e 15° S e de 38° e 43° W com centro da máxima na região do Morro do Chapéu, com a Chapada do Araripe ao norte, a Chapada Diamantina a oeste e a Serra do Espinhaço a sudeste.

No outono (Março, Abril e Maio) aumenta a nebulosidade de modo geral, desaparecendo a área de baixa frequência ao sul da Chapada do Araripe. No inverno (Junho, Julho, Agosto) a nebulosidade ainda é alta, variando de 30% a 80%. Na primavera (Setembro, Outubro e Novembro), os valores médios diminuem e verificam-se regiões de baixa frequência, da mesma forma que no período do verão.

Figura 2 - Localização da área de estudo no Nordeste do Brasil



3.2 Observações de nebulosidade de superfície do INMET

As observações de superfície usadas na pesquisa foram cedidas pelo INMET. O método de observação, avaliação e registro da cobertura de nuvens nas estações meteorológicas será descrito a seguir. Também são detalhados os problemas geométricos que envolvem a observação de superfície e que levam a valores superestimados do percentual de cobertura. Além disso, são relacionadas as estações usadas para essa pesquisa.

3.2.1 Registros das observações meteorológicas

As observações realizadas em superfície pela rede de estações meteorológicas do INMET são coletadas diariamente às 12h, 18h e 24h Universal Time Coordinated (UTC). Toda a área de estudo encontra-se na faixa da hora oficial de Brasília, que são três horas a menos em relação à UTC, assim as horas locais de observação são respectivamente 9h, 15h e 21h. A maioria das observações realizadas nas estações são obtidas a partir de instrumentos de medição que incluem variáveis como pressão, temperatura, vento, precipitação, insolação, visibilidade horizontal, nebulosidade e gênero das nuvens. Para essa pesquisa, os dados utilizados foram apenas os registros de nebulosidade das 12h e 18h UTC, visto que o horário de 24h UTC que corresponde a 21h locais está fora do período útil para a execução de vôos fotogramétricos.


3.2.2 Método de observação da nebulosidade

Não existe um instrumento adequado para medir, com alguma precisão, a quantidade de nuvens existentes no céu num determinado instante. A quantificação é realizada em frações do céu encoberto pelas nuvens e pode ser em décimos, como realiza o INMET, ou oitavos, como faz o Serviço Meteorológico da Aeronáutica. O observador divide o céu em partes iguais e imagina que juntando as nuvens de um lado para o outro tenha por exemplo

50% ou 25% do céu encoberto e daí faz as aproximações necessárias. Para a realização dessa tarefa, o observador recebe apenas um treinamento que inclui o reconhecimento dos gêneros de nuvens. Os códigos variam numa escala de 0 a 10, sendo que o 0 corresponde a céu totalmente limpo, 1 a céu com 10%, 2 a céu com 20%, e assim por diante, até 10 com céu completamente encoberto.

Esse método de observação tem problemas geométricos que induzem a erro de avaliação, difíceis de ser resolvido sem o auxílio de instrumentos de medição. O que o observador percebe é uma projeção das nuvens, que estão em várias altitudes e distâncias diferentes, sobre uma abóbada fictícia. A Figura 3 mostra um corte vertical na abóbada com o observador no centro, sobre o terreno, e os níveis em que se encontram as nuvens, considerados como sendo superfícies de esferas paralelas à superfície da Terra.

Figura 3 - Abóbada teórica que envolve o observador de nuvens.



3.2.2.1 Cálculo do raio máximo de visibilidade

O raio máximo de visibilidade do observador D é medido paralelamente ao plano tangente à superfície da Terra naquele ponto que, para fins práticos, coincide com a linha do horizonte. No caso de céu totalmente limpo, teoricamente esse raio é infinito, nos casos que tem alguma nuvem, o seu comprimento é a distância máxima que uma nuvem com base de altitude H seria ainda vista pelo observador no horizonte. A visibilidade horizontal será na realidade muito menor devido a existência de névoa, fumaça, poeira, refração atmosférica e obstáculos em torno do local de observação.

O raio de atuação considerado na prática para uma observação de superfície (OS), varia entre os autores. Segundo GREAVES ET AL (1971), é cerca de 28km, para BARRET & GRANT (1974) é de 30km e para HENDERSON-SELLERS (1987) é cerca de 40km. Nessa pesquisa, será adotado o raio de 30km como sendo a abrangência típica para as observações de superfície.

A Figura 4 mostra as relações geométricas e as fórmulas que serão úteis para uma análise matemática da questão. Os parâmetros mais usados serão o raio máximo de visibilidade D e a altura da base da nuvem H. A altura do observador não será considerada nos cálculos, por ser muito pequena em relação ao raio da Terra. Na Figura 4, a altura H da base da nuvem é dada por:

$$H = R - r \quad (6)$$

sendo r = raio médio da Terra igual a 6371km (VANICEK & KRAKIWSKY, 1986).


Também na figura o raio médio da Terra tem a seguinte relação:

$$r = R \cos \theta \quad (7)$$

Juntando (6) e (7) obtém-se:

$$\theta = \arccos (r / R) \quad (8)$$

Figura 4 - Elementos geométricos para cálculo do raio máximo de visibilidade



Conhecido o ângulo θ , o cálculo do raio máximo de visibilidade D para uma determinada altitude de base de nuvem é dado por

$$D = R \sin \theta \quad (9)$$

Os raios máximos de visibilidade para nuvens com altitude de base típicas para os níveis baixo, médio e alto, respectivamente, de 600m, 2000m e 6000m, calculados com as fórmulas de (6) a (9) estão na Tabela 3. Os

resultados mostram que mesmo uma nuvem baixa pode teoricamente ser vista a cerca de 90km do local do observador e que uma alta pode estar a cerca de 280km. Estas distâncias têm muita importância nas discussões que se seguirão a respeito do que realmente o observador percebe e registra nos formulários. Os valores da Tabela 3 são bem maiores que o raio de abrangência de 30km considerado nessa pesquisa válido para uma estação meteorológica.

Tabela 3 - Raio máximo de visibilidade para altitudes típicas de bases de nuvens

ALTURA DA BASE (km)	RAIO MÁXIMO DE VISIBILIDADE (km)
0,6	87,43
2,0	159,65
6,0	276,56

3.2.2.2 Observação segundo o ângulo vertical

As relações entre as áreas que o observador percebe na abóbada, as áreas cobertas realmente no terreno, e os ângulos verticais de observação, serão discutidas com a finalidade de mostrar porque as observações de superfície tendem a superestimar a quantidade de nuvens.

O ângulo vertical médio de visão com nitidez do ser humano está em torno de 45°. Portanto, para uma pessoa que está observando a linha do horizonte, o céu fica ocupando a metade superior num ângulo de 22,5° e esse pode ser considerado o ângulo natural de observação. Para que o observador avalie toda a abóbada é necessário então inclinar a cabeça para cima para completar sua observação.

Os cálculos das relações entre área da abóbada, ângulo de visão e áreas do terreno serão realizados para o ângulo natural de 22,5°, o ângulo de

10° que é aproximadamente a metade do outro e 0°. As nuvens observadas têm alturas das bases a 600m, 2000m e 6000m. A Figura 5 mostra os elementos geométricos necessários aos cálculos.

O ângulo α na Figura 5, corresponde ao ângulo vertical de observação mais 90°. As relações entre α e os demais parâmetros são calculadas facilmente usando as fórmulas de resolução de problemas com triângulos, quando são dados alguns elementos e deseja-se calcular os demais. Assim, para cada ângulo vertical foi calculado o raio de visibilidade ou distância horizontal d , a área S correspondente ao círculo sobre o terreno e o ângulo θ , todos mostrados na Tabela 4.

Figura 5 - Elementos geométricos para análise do alcance da visão segundo o ângulo vertical


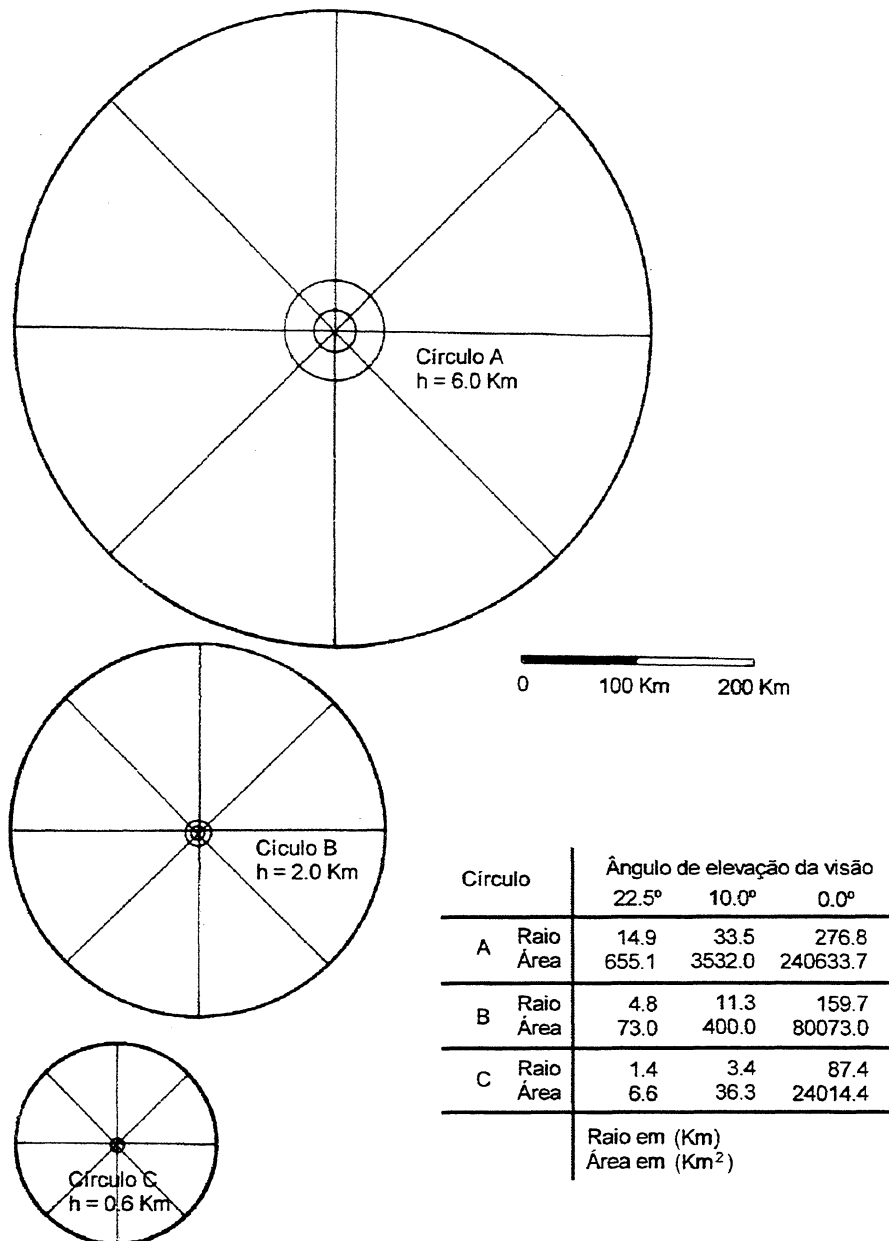


Tabela 4 - Distância horizontal, área de abrangência para os ângulos verticais de observação de 0°, 10° e 22,5°

		BASE DA NUVEM		
		0,6 km	2,0 km	6,0 km
Ângulo θ	0°	0,78631°	1,43546°	2,48564°
	10°	0,03055°	0,10146°	0,30124°
	22,5°	0,01302°	0,04337°	0,12379°
Raio d	0°	87,43 km	159,65 km	276,56km
	10°	3,40 km	11,28 km	33,53km
	22,5°	1,45 km	4,82 km	14,44 km
Área S	0°	24.014,35 km ²	80.763,30 km ²	240.633,73 km ²
	10°	36,32 km ²	399,73 km ²	3.531,97 km ²
	22,5°	6,61 km ²	72,99 km ²	655,06 km ²

A Figura 6 mostra graficamente as proporções entre os vários raios e áreas da Tabela 4. Existe uma redução muito grande entre o raio máximo, com as nuvens no horizonte (ângulo de 0°), e os raios de visibilidade para os ângulos de 10° e 22,5°; por exemplo, para nuvens a 600m de altura, os raios são 87,43km; 3,40km e 1,44km, respectivamente. As diferenças entre os raios de visibilidade também são grandes quando se leva em conta as alturas de base das nuvens, como se pode comparar observando os círculos A (nuvens altas), B (nuvens médias) e C (nuvens baixas) da Figura 6. Os círculos da Figura 6 foram seccionados em oito partes, como no procedimento também empregado de avaliar a nebulosidade em oitavos.

Figura 6 - Superfícies no terreno referentes aos raios de visibilidade para ângulos de visão de 0° , 10° e $22,5^\circ$ para nuvens com altitudes de 600m, 2000m e 6000m



3.2.2.3 Cálculo de áreas da abóbada

Como já foi visto antes, o observador avalia e registra as nuvens que visualiza numa abóbada entre o horizonte e o zênite. O observador divide o céu em dez ou oito partes iguais, segundo meridianos, e procura mentalmente avaliar quantas seções estão preenchidas com nuvens, fazendo ao mesmo tempo uma compensação naquelas que estão parcialmente preenchidas. Mas a medida que a quantidade de nuvens é menor, o erro da avaliação tende a aumentar, principalmente para as nuvens que estão nos ângulos de visão mais baixos. A nebulosidade como vista pelo observador, nessas condições, poderia ser chamada de aparente, enquanto que a nebulosidade real seria a projetada no terreno.

Não existe um instrumento que auxilie o observador a calcular com maior exatidão as áreas da abóbada que estão cobertas de nuvens e muito menos um método que relacione a projeção na abóbada com a projeção real das nuvens sobre o terreno. É possível, porém, fazer alguns cálculos que mostrem as relações entre as áreas observadas na calota e áreas do terreno cobertas com nuvens. Para isso serão, adotadas algumas simplificações e definidos alguns parâmetros.

Inicialmente, para facilitar os cálculos adota-se a abóbada com raio unitário porque o raio real é variável e depende das alturas das nuvens. Em seguida, definem-se os ângulos de visão verticais que determinarão as áreas das zonas da calota e os raios de visibilidade correspondentes sobre o terreno. Esses ângulos são os mesmos da seção anterior: $0,0^\circ$; 10° e $22,5^\circ$. A Figura 7 mostra a abóbada fictícia de raio unitário e os elementos geométricos necessários aos cálculos da superfície da calota e das zonas.

A superfície de uma calota S_c é dada por:


$$S_c = 2\pi R h \quad (10)$$

Sendo $R = 1,0$

$$h = R - a$$

$$a = R \operatorname{sen} \varphi \quad (11)$$

Figura 7 - Elementos geométricos para cálculo de zonas da abóbada



As áreas das calotas de altura h , acima do ângulo de visão vertical, são calculadas por 10 e 11. As áreas de cada zona de altura a foram obtidas por subtração da área total da abóbada. A Tabela 5 mostra as duas áreas para os ângulos de 0° , 10° e $22,5^\circ$ e o percentual da área da zona em relação a área total da abóbada.

Tabela 5 - Cálculo de áreas da abóbada de raio unitário

	ÂNGULO DE VISÃO VERTICAL		
	22,5°	10,0°	0,0°
Altura a	0,383	0,174	0,0
Diferença h	0,617	0,826	1,0
Área da calota	3,88	5,19	6,28
Área da zona	2,40	1,09	0,0
% (zona/calota)	38,2%	17,3%	0,0%

Conforme a Tabela 5, com ângulo de visão vertical de $22,5^\circ$ a zona inteira equivale a aproximadamente 40% da área da abóbada. Se a zona for dividida em oito partes iguais (Considerando-se que as observações sejam avaliadas em oitavos) cada uma corresponde a 5%. No caso de todas as oito partes da zona estarem completamente encobertas de nuvens isso corresponde a 40% do céu para o observador, seis partes correspondem a 30%, quatro partes a 20% e duas partes a 10%.

Para conhecer a nebulosidade real, é necessário reprojeter as partes nubladas sobre as áreas circulares do terreno. A visualização pode ser feita na Figura 6, em que o círculo interno menor corresponde ao raio para o ângulo vertical de $22,5^\circ$ e o externo, maior, é o raio para ângulo 0° ; e as divisões são também em oitavos. Os cálculos, cujos resultado estão na tabela 6, foram efetuados para nuvens altas e médias, considerando-se que estão nublados oito, seis, quatro e dois setores das zonas abaixo de $22,5^\circ$. Esses setores nublados projetados no terreno são as áreas realmente nubladas indicadas por ARN na Tabela 6 e correspondem aos setores externos da Figura 6. A diferença entre a área total do círculo e as áreas consideradas nubladas são as áreas de céu limpo indicadas por ACL na mesma tabela. Essas áreas de céu limpo podem sem dúvida serem fotografadas e se caso formassem figuras regulares como um quadrado, teriam os lados com as extensões indicadas por LQ, ainda na Tabela 6.

Tabela 6 - Áreas reais nubladas do terreno, em relação a oitavos da abóbada para visão abaixo de 22,5°:

Percentual	40%	30%	20%	10%
Oitavos	8	6	4	2
Nuvens altas h=6,0 km área total 240.633,7km ²				
ARN km ²	239.978,67	179.984,04	119.9889,36	59.994,68
ACL km ²	655,06	60.649,69	120.644,37	180.639,05
LQ km	25,59	246,27	347,34	425,02
Nuvens médias h =2,0km área total 80.073,0 km ²				
ARN km ²	80.000,32	60.054,96	40.000,16	20.000,08
ACL km ²	72,99	20.018,34	40.073,14	60.073,22
LQ km	8,54	141,49	200,18	245,10

ARN= Área Real Nublada sobre o terreno

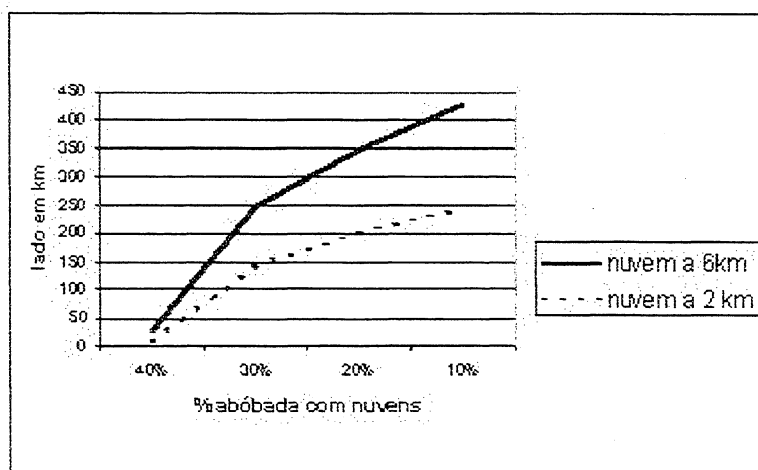
ACL= Área de Céu Limpo

LQ = Lado do Quadrado com área igual a ACL

A Figura 8 mostra as curvas formadas com os lados dos quadrados (LQ) de áreas de céu limpo da Tabela 6, para nuvens altas e médias que ocupam 40, 30, 20 e 10% da abóbada. Com 40%, o lado do quadrado para a nuvem a 6km de altura é de 25km mas quando o percentual é de 30%, o lado do quadrado tem agora 246km. A mesma comparação pode ser feita para a nuvem a 2km de altura. A Figura 8 mostra ainda que a extensão do lado do quadrado aumenta rapidamente de 40 para 30%, que existe um ponto de inflexão em 30%, e que a partir daí o lado cresce mais lentamente. Portanto pode-se admitir, numa primeira aproximação, que em observações de superfície com até 30% de nebulosidade, existe uma área livre de céu claro com extensão considerável que pode ser aproveitada para a execução de fotografias aéreas. Esses cálculos apresentam, naturalmente, algumas simplificações, quando consideram que as nuvens estão agrupadas ocupando

setores bem definidos e que estão em mesmo nível de altitudes, mas provam que são diferentes os percentuais de nebulosidade avaliados por um observador de superfície e a nebulosidade real existente sobre área do terreno, que está dentro dos limites de seu campo de visão até o horizonte.

Figura 8 - Gráfico LQ (Lado de Quadrado) com céu claro e percentual da abóbada encoberta, conforme Tabela 6



3.2.3 Rede de estações meteorológicas utilizadas

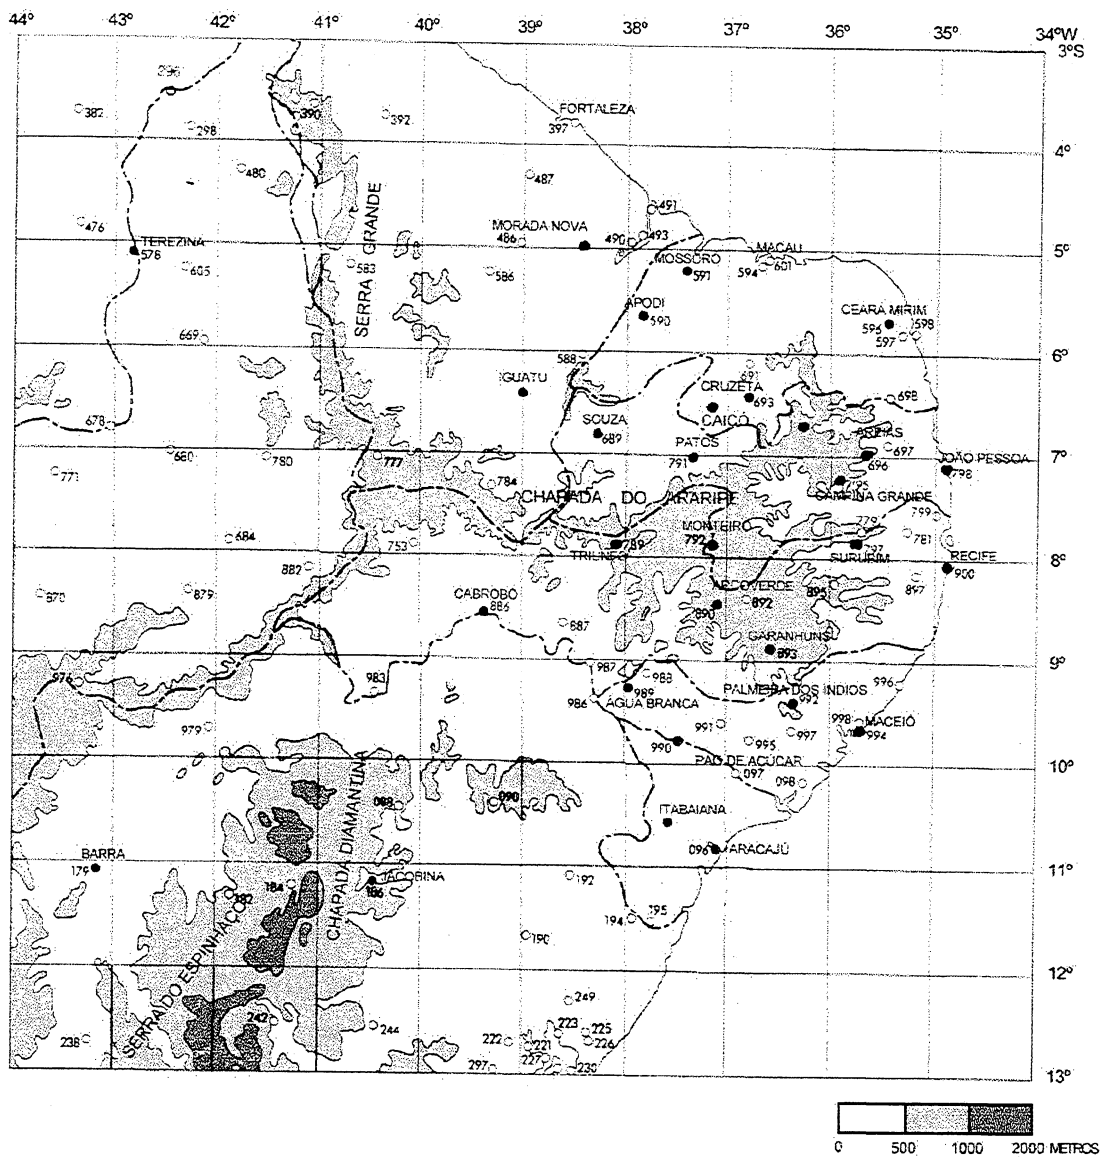
As estações meteorológicas do INMET foram escolhidas levando-se em conta dois fatores. O primeiro era cobrir a área delimitada pelas latitudes $6^{\circ}30'$ e $9^{\circ}30'$ S e longitudes $35^{\circ}30'$ e 36° W, onde se sabia que existe uma área de nebulosidade excessiva todo o ano. O segundo fator era diminuir a quantidade de estações ao mínimo, tendo em vista que a massa de dados a ser trabalhada, de um período de dez anos, seria muito grande. Assim procurou-se escolher estações em grupos de três em três, aproximadamente com mesma latitude, de modo que uma ficasse mais a oeste, uma intermediária e outra no litoral. Essa distribuição facilitaria análises de tendências e, talvez, o traçado de isolinhas. A Figura 9 mostra as posições de

todas as suas estações meteorológicas com os seus três últimos números do código de identificação do INMET. As estações usadas na pesquisa estão marcadas com o círculo preto e com o nome da cidade onde se situam.

As estações inicialmente escolhidas eram vinte, porém, como duas delas têm poucos anos com dados disponíveis, foram acrescentadas mais duas, totalizando as vinte e duas listadas na Tabela 7. A relação das estações da Tabela 7 é constituída pelos números de identificação do INMET, coordenadas geográficas de latitude, longitude e altitude e pelas coordenadas no formato do ISCCP, para facilitar as futuras comparações com os dados dos satélites. A tabela traz ainda uma relação de dez estações das quais se tem apenas dados resumidos, conforme explicação em 3.2.3.1.

A maioria das estações tem quase todos os dados do período de 1989 a 1998, faltando apenas alguns dias ou meses. Mas em outras faltam anos inteiros, como é o caso de Monteiro (falta 1990), Maceió (falta 1991), Areias (faltam 1989, 1990 e 1991), Pão de Açúcar (faltam 1991, 1992 e 1993), Seridó (faltam 1989, 1990, 1991, 1992, 1993 e 1994) e Apodi (faltam 1991, 1992, 1993, 1994, 1995 e 1996).

Figura 9 - Rede de estações do INMET utilizadas pela pesquisa



Fonte do Mapa: INMET

Tabela 7 - Relação de estações do INMET usadas na pesquisa

ESTAÇÃO		COORDENADAS				
Código	Nome	UF	Lat. (G)	Long. (G)	Altit. (m)	Lat. Long. (ISCCP)
82989	Água Branca	AL	9,3	37,9	608,83	807 3221
82590	Apodi	RN	5,7	37,8	65,37	843 3222
82890	Arcoverde	PE	8,4	37,1	682,00	816 3229
82696	Areias	PB	7,0	35,7	561,30	830 3243
82886	Cabrobó	PE	8,5	39,3	342,49	815 3207
82795	Camp. Grande	PB	7,2	35,9	543,66	828 3241
82596	Ceará Mirim	RN	5,7	35,4	62,58	843 3246
82693	Cruzeta	RN	6,4	36,8	227,04	836 3232
82893	Garanhuns	PE	8,9	36,5	822,96	811 3235
82798	João Pessoa	PB	7,1	34,8	7,73	829 3252
82994	Maceió	AL	9,7	35,7	65,10	803 3243
82792	Monteiro	PB	7,9	37,1	604,66	821 3229
82588	Morada Nova	CE	5,1	38,4	44,44	849 3216
82591	Mossoró	RN	5,2	37,3	18,80	848 3227
82992	Pal. Índios	AL	9,5	36,7	275,50	805 3233
82990	Pão Açúcar	AL	9,8	37,4	20,13	802 3226
82791	Patos	PB	7,0	37,3	249,40	830 3227
82900	Recife	PE	8,0	34,9	8,25	820 3251
82689	São Gonçalo	PB	6,8	38,2	233,86	832 3218
82690	Seridó	RN	6,8	36,4	170,65	832 3236
82797	Surubim	PE	7,8	35,7	418,80	822 3243
82789	Triunfo	PE	7,9	38,1	1021,90	821 3219
ESTAÇÕES COM RESUMO DOS DADOS E PERÍODO 1970-1980						
Iguatu	CE		6.4	39.3		837 3207
Macau	RN		5.1	36.6		849 3234
Fortaleza	CE		3.8	38.5		862 3218
Teresina	PI		5.1	42.8		849 3172
Parnaíba	PI		2.9	41.8		871 3182
Barra	BA		11.1	43.1		789 3169
Jacobina	BA		11.1	40.5		789 3195
Aracaju	SE		11.0	37.1		790 3229
Itabaiana	SE		10.7	39.4		793 3206
Bom Jesus da La	BA		13.1	43.4		769 3166
Recife	PE					
Garanhuns	PE					
C Grande	PB					
João Pessoa	PB					

Fonte : INMET

3.2.3.1 Outros dados de observações terrestres de nebulosidade

Além das estações meteorológicas com dados diários de nebulosidade, também foram utilizados dados de outras estações, obtidos de MAURÍCIO (1987). Estes dados também são originários do INMET mas foram organizados e usados pelo INPE em várias pesquisas. Os dados estão em forma resumida e trazem os percentuais de ocorrência de nuvens em cinco classes, conforme a Tabela 8, que as relaciona com as dez classes normais desta pesquisa.

O período é de 1970 a 1980, também nos horários 12h e 18h UTC. A relação de todos os postos com os dados resumidos retirados de Maurício é a seguinte: Fortaleza (CE), Iguatu (CE), Teresina (PI), Parnaíba (PI), Macau (RN), Campina Grande (PB), João Pessoa (PB), Recife (PE), Garanhuns (PE), Maceió (AL), Aracaju (SE), Itabaiana (SE), Barra (BA), Jacobina (BA) e Bom Jesus da Lapa (BA).

A maioria das estações acima destina-se a estender a área coberta pelas estações com dados completos, que é menor que a área coberta pelos dados de satélites. E algumas, como Recife e João Pessoa, destinam-se a conferir se há consistência entre dados de períodos diferentes ou se existe diferença significativa que impeça o uso conjunto desses dados. Também foram introduzidas as estações de Parnaíba (PI) e Bom Jesus da Lapa (BA) que estão um pouco fora da área, ao norte e ao sul, respectivamente, para verificar possíveis tendências nos limites de zonas climatologicamente homogêneas quanto a nebulosidade.

Tabela 8 - Percentuais de cobertura para classes de nuvens de 1 a 5 e relação com as dez classes

Classe Reduzida	Intervalo de Cobertura (%)	Classes Normais (décimos)
I	0-10	1
II	10-30	2,3
III	30-50	4,5
IV	50-90	6,7,8,9
V	90-100	10

3.3 Observações de nebulosidade de satélites do programa ISCCP

Os dados de nebulosidade originados do satélite meteorológico METEOSAT usados nessa pesquisa foram cedidos pelo International Satellite Cloud Climatology Project (ISCCP).

Nesta seção, serão dadas as informações sobre o programa ISCCP e as características gerais dos dados e do satélite METEOSAT e o período de dados disponibilizados.

3.3.1 Programa ISCCP

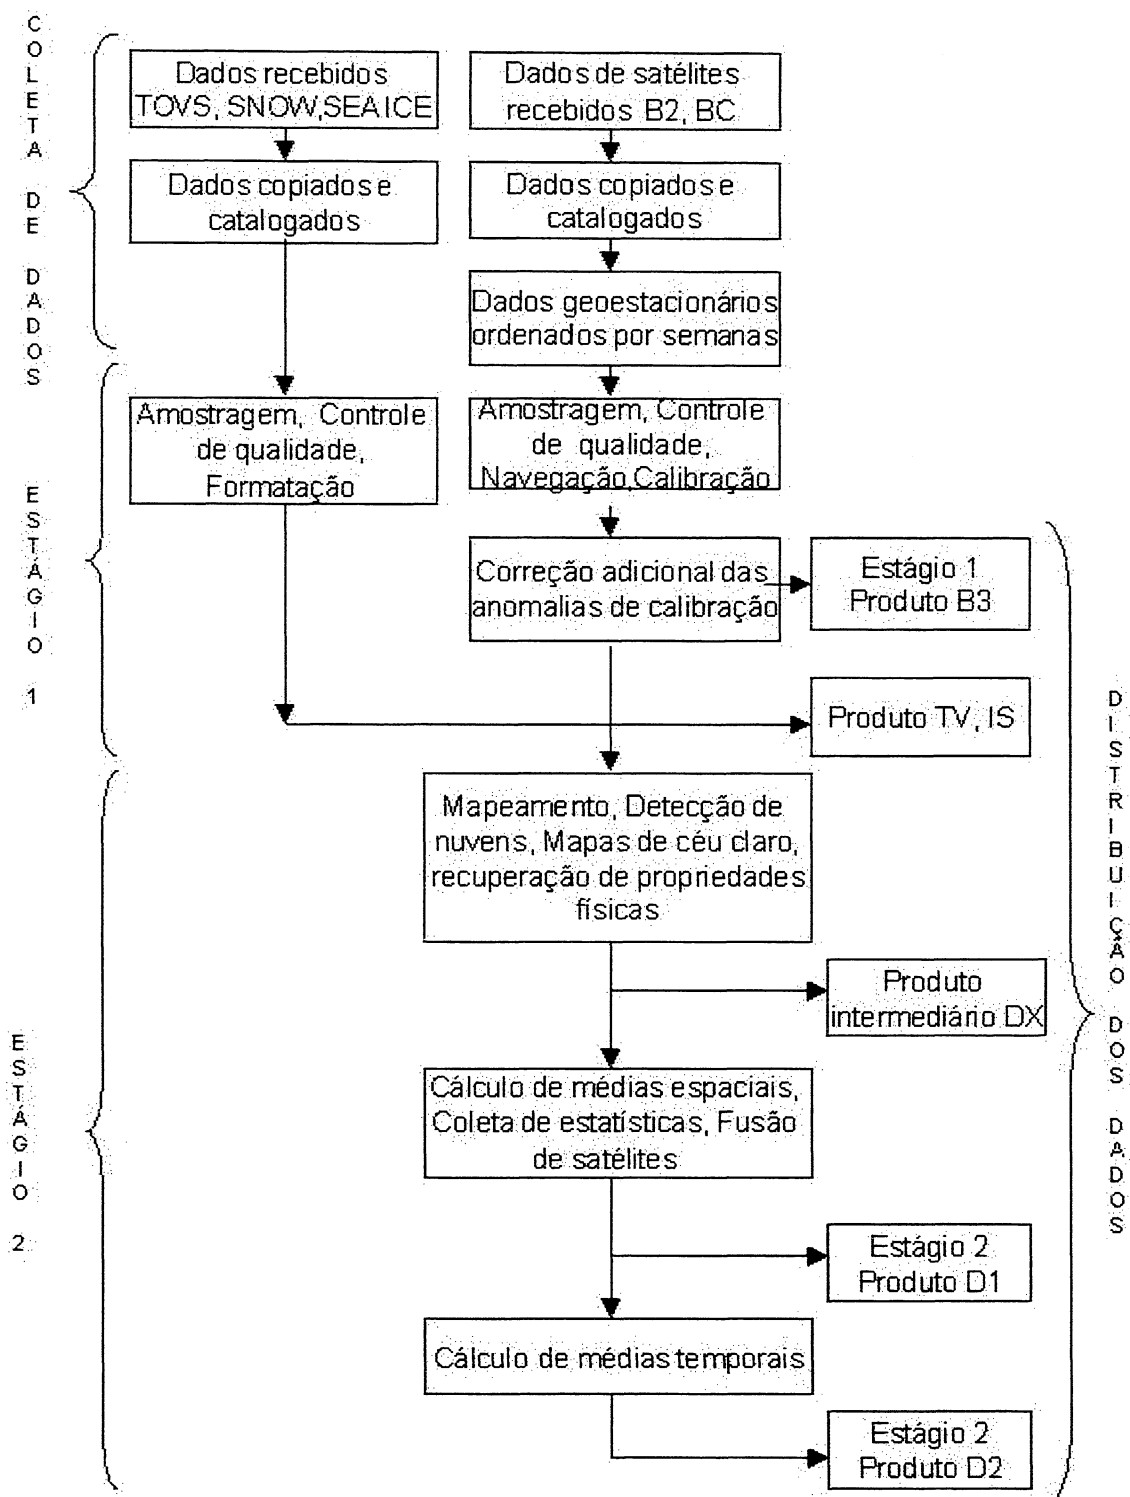
O ISCCP foi o primeiro projeto do World Climate Research Program WCRP estabelecido em 1982 (SCHIFFER & ROSSOW, 1987), com o objetivo de produzir um conjunto de dados normalizados e calibrados de radiâncias, contendo informações básicas de propriedades da atmosfera, dos quais podem ser obtidos parâmetros de nuvens. O programa é executado por um grupo internacional de instituições (NASA, NOAA, European Space Agency, Japan Meteorological Agency, Canadian Atmospheric Environment Service, Centre de

Meteorologie Spatiale e Colorado University) que coleta e analisa medidas de radiâncias de satélites meteorológicos as quais permitem inferir a distribuição global das propriedades de nuvens e suas variações diurnas, sazonais e inter- anuais.

O programa dispõe de dados com resolução no terreno que varia de 280km x 280km a 30km x 30km e intervalos de tempo que variam de um mês a cada três horas, com vários níveis de tratamento. Os dados já coletados, catalogados, calibrados e arquivados são postos à disposição da comunidade científica para pesquisas.

A Figura 10 mostra o fluxograma geral de preparação dos dados e os produtos que vão sendo elaborados em cada etapa. Os detalhes completos sobre o programa, satélites, fluxo de coleta e tratamento dos dados, algoritmos e formato dos dados podem ser encontrados em ROSSOW ET AL. (1996) e ROSSOW & SCHIFFER (1999). Mais informações sobre o programa e bibliografia a respeito do assunto podem ser encontradas no endereço do ISCCP na Internet: URL: <http://isccp.giss.nasa.gov>.

Figura 10 – Esquema de processamento de dados do ISCCP



Fonte: ROSSOW ET AL. (1996)

3.3.2 Dados do estágio DX

O tipo de dado disponível no programa ISCCP mais adequado para esta pesquisa é um produto intermediário, a nível de amostragem de pixel, chamado de DX, cujas características são as seguintes:

- informa diretamente se o pixel está classificado como nublado ou não;
- tem a melhor resolução espacial de 30km x 30km;
- tem a melhor resolução temporal com observações nos horários de 00h, 03h, 06h, 09h, 12h, 15h, 18h e 21h UTC.

Os dados de cada pixel são coletados em intervalos que variam de 25km a 30km nas imagens originais, cujas resoluções variam, conforme o satélite, de 4km a 7km no terreno. Assim, as radiâncias do pixel original passam a ser representativas para todo o pixel do dado DX. Nessa pesquisa, que usa dados dos satélites METEOSAT, a resolução original é de 5 km x 5 km.

O período dos dados disponibilizados é de julho de 1983 a agosto de 1994, com lacunas em alguns meses. Para 1994, existem dados repetidos de dois satélites diferentes. Nesse caso, escolheu-se apenas um deles.

A Tabela 9 mostra os dados disponíveis já organizados por anos e meses num banco de dados.

Tabela 9 - Relação dos Dados DX disponíveis para a pesquisa por ano e mês

ANO	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
1983
1984												
1985												
1986			.			.						
1987	
1988												
1989												
1990		.				.						
1991												
1992												
1993								.				
1994								

dados do mês completo
 p dados do mês parcial
. sem dados

3.3.3 Projeção Cartográfica usada pelo ISCCP


A imagem obtida do satélite é a projeção do globo terrestre no plano do detector. Segundo ROSSOW ET AL. (1996), a projeção resultante é similar ao tipo perspectiva geral. O sistema de coordenadas para os pixels segue o formato da Figura 11, específico para os satélites do tipo geoestacionário.

Os dados processados, no estágio DX, já vêm com a referência geográfica de cada pixel, definida em latitude e longitude, corrigida das variações normais da posição do satélite. Entre dois meses diferentes, no entanto, algumas dessas posições podem mudar. Além das coordenadas

geográficas, os pixels tem um posicionamento em coordenadas retangulares X e Y conforme a Figura 11. No sistema de referência, o centro corresponde ao SSP (Sub Satellite Position), colocado no equador a uma determinada longitude. As coordenadas X e Y indicam a posição na malha com origem no canto inferior esquerdo. A linha central, portanto, corresponde ao Equador.

As coordenadas geográficas são dadas em graus decimais, mas numa forma diferente da usual quanto à precisão, anotação e origem. A precisão vai até o décimo de grau, mas a anotação da coordenada é em inteiros sem a vírgula. Por exemplo, a coordenada 761 equivale a $76,1^\circ$. As longitudes são sempre positivas e para leste de Greenwich. O zero das latitudes é o Pólo Sul, assim o Equador está na latitude 90° e o Pólo Norte na latitude 180° .

Figura 11 Sistema de projeção usado para satélite geoestacionário



Fonte: ROSSOW ET AL. (1996)

A exatidão do posicionamento dos pixels originais, depende da precisão da navegação sendo em média $\pm 25\text{km}$ (ROSSOW ET AL, 1996) e na melhor situação de 15km (ROSSOW, 2000). Foram feitas algumas verificações comparando a linha de costa da região e o lago da barragem de Sobradinho, a qual foi possível identificar perfeitamente em algumas imagens, que mostraram a existência de um erro sistemático de deslocamento que pode chegar a dois pixels ($50\text{-}60\text{km}$), sempre para Oeste. As conseqüências desse erro para estudos de nebulosidade em grande escala parecem não ser um problema. Eles prejudicam quando existe a necessidade de identificar áreas menores, com raios de 10 ou 20km , com problemas de nebulosidade localizada, principalmente de origem orográfica, como ocorre na região de estudo. Outra provável causa do deslocamento dos pixels é que a área de estudos fica bem próxima à borda do disco imageado (canto esquerdo da Figura 12), sendo que nessa posição devido à curvatura da Terra, os ângulos entre superfície do terreno, linha de visada e plano do detector são desfavoráveis.

O posicionamento desfavorável da área de estudo em relação à imagem também impediu que fosse selecionada uma área maior para testes, como toda a superfície do Brasil. O satélite que cobre todo o Brasil é identificado no programa ISCCP como GOES-EAST, cujo intervalo em longitude varia de 15°W a 135°W . Na época da solicitação do dados, no entanto, não foi possível consegui-los.

3.3.4 Formato geral dos arquivos de dados DX

O formato dos arquivos de dados DX originais estão no padrão 32 bits da IBM. Cada arquivo armazena dados correspondentes a uma imagem de um satélite em um horário e é composto de uma quantidade variável de registros. O primeiro é um cabeçalho, com informações sobre o satélite, data, hora, formato, tamanho e quantidade dos registros que se seguem. Os registros seguintes trazem os dados propriamente ditos. Tipicamente, existem de

cinquenta a cem registros em cada arquivo, cada um com um número variável de pixels. Os dados são compactados em simples *bytes* em valores de 0 a 255 obedecendo a um pré determinado esquema de formato que é entendido pelo programa de leitura distribuído também pelo ISCCP.

O programa fonte específico para os dados DX distribuído pelo ISCCP, chamado de DXREAD, vem com as rotinas básicas em linguagem FORTRAN 77, para sistema UNIX e pode facilmente ser adaptado às necessidades do usuário. Esse programa decodifica cada *byte* de acordo com sua posição e recupera o parâmetro correspondente a partir de uma tabela de conversão para valores físicos. Todos os detalhes sobre o formato do arquivo e algoritmo de detecção de nuvens são dados em ROSSOW ET AL. (1996).

Os dados recebidos para esta pesquisa ocupam quarenta e seis fitas magnéticas do tipo DDS-2 (Digital Data Storage) de 4mm, capacidade de 2GB, mais conhecidas como DAT (Digital Audio Tape), cobrindo o período de julho de 1983 a agosto de 1994. Os dados ordenados por mês e ano constam na Tabela 9.

3.3.5 Características do satélite METEOSAT

Os satélites da série METEOSAT começaram a operar em Dezembro de 1977, estando atualmente no número de seqüência 7, sendo que o ISCCP dispõe de dados processados dos satélites de número 2 a 5.

O princípio de operação do METEOSAT se baseia no sensor Multispectral Imaging Radiometer (MIR) que é um radiômetro de varredura que obtém imagens nas regiões do visível e infra vermelho termal do espectro. O dispositivo produz imagens do disco completo da Terra, de uma órbita geoestacionária a 36.000km de altitude sobre o Equador e meridiano de Greenwich, a cada meia hora. As imagens são produzidas em três bandas:

- 0,5-0,9 μm - visível (Figura 12-A)
- 5,7-7,1 μm - banda do infravermelho, absorção do vapor d' água (Figura 12-B);

- 10,5-12,5 μm - janela do infravermelho termal (Figura 12-C).


As imagens do visível tem 5000 x 5000 pixels com uma resolução no Ponto Sub-satélite de 2,5 km. As do infravermelho e vapor d'água tem 2500 x 2500 com resolução de 5 km. Outras informações sobre radiômetro do METEOSAT constam no Quadro 2.

Quadro 2 - Informações gerais sobre o radiômetro do METEOSAT

CARACTERÍSTICAS DO RADIÔMETRO			
Telescópio			
Abertura primária(mm)	400		
Abertura secundária(mm)	140		
Distância focal (mm)	3650		
Bandas espectrais (μm)	5,5-0,9	5,7-7,1	10,5-12,5
Tipo do detector	foto-diodos Si	HgCdTe	HgCdTe
Dimensões (μm)	250 x 250	70 x 70	70 x 70
Ângulo de abertura(mrad)	0-7	0-14	0-14
Detector de temperatura (K)		90	90
Numero de linhas por imagem	5000	2500	2500


Fonte: MANSON & SCHMETZ (1992)

Figura 12-A - Imagem do METEOSAT, banda do visível 0,5-0,9 μm




Copyright © 1995-2001 do INPE Instituto Nacional de Pesquisas Espaciais

Figura 12-B - Imagem do METEOSAT banda do infravermelho, absorção do vapor d' água 5,7-7,1 μm ;



Copyright © 1995-2001 do INPE Instituto Nacional de Pesquisas Espaciais

Figura 12-C - Imagem do METEOSAT janela do infravermelho termal 10,5-12,5 μm



Copyright © 1995-2001 do INPE Instituto Nacional de Pesquisas Espaciais

3.4 Avaliação do uso de imagens do LANDSAT para estudos de nebulosidade

O satélite LANDSAT também pode ser uma fonte de informações sobre as nuvens, embora sua finalidade de imageamento seja exatamente para operar sem elas. A sua repetitividade de 16 dias para imagear o mesmo lugar e o tamanho da imagem no terreno de 185km x 185km não fornece dados com a frequência e extensão exigidas para aplicações meteorológicas.

No entanto as imagens do LANDSAT mostraram-se úteis para:

- fornecer dados geométricos sobre as nuvens;
- fornecer uma visão da nebulosidade da região, numa escala intermediária entre a observação de superfície e a escala menor do satélite meteorológico;
- exemplificar o princípio de que a nebulosidade cresce com o tamanho da área.

3.4.1 Dados geométricos de nuvens em imagens LANDSAT

Não existem estudos específicos para o Nordeste do Brasil que descrevam as características geométricas (dimensões, altura da base e espaçamentos) dos tipos de nuvem que ocorrem. Essas informações seriam úteis para os modelos de nebulosidade e para as simulações de missões de fotogrametria. As imagens do LANDSAT podem auxiliar na obtenção de parte desses dados.

Cada imagem LANDSAT tem um conjunto de informações que incluem, além de seus dados identificadores como órbita, ponto e data, a qualidade da imagem obtida por banda, as coordenadas geográficas, azimute e o ângulo de elevação do sol em relação ao centro da imagem. Essas últimas informações

podem ser utilizadas para o cálculo das alturas da bases das nuvens com a fórmula trigonométrica:

$$h = \text{tg} \alpha \times d \times F / 1000 \quad (12)$$

em que d é medida em milímetros do comprimento da sombra medida em direção paralela ao azimute do sol;

α é o ângulo de elevação do sol;

F o fator de escala da imagem

As dimensões das nuvens (largura e comprimento) e espaçamentos podem ser obtidos com medições diretas sobre cópias em papel, com escala conhecida, ou com ajuda de programas de processamento de imagens georeferenciadas.

O Departamento de Engenharia Cartográfica da UFPE (DECART) cedeu a imagem do LANDSAT 214/66 de 22.04.1995 usada para realizar um teste de medição. Esta imagem tomada às 11:38:06 UTC tem azimute do Sol $63,25^\circ$ e elevação de $45,57^\circ$ com relação ao centro. A média de dez medições, para nuvens do gênero cumulus próximas do litoral, deu uma altura da base de 714 m, que está dentro da faixa apresentada no Quadro 1. A altura obtida não é conclusiva porque ela pode sofrer variações devido a diferenças de pressão e temperatura médias locais, conforme as estações do ano, sendo portanto necessárias várias imagens para se chegar a um valor representativo e também para permitir medições de outros tipos de nuvens.

3.4.2 Análise visual da distribuição de nuvens em imagens LANDSAT

Foram analisadas cinquenta e uma amostras de imagens (*quick-look*) do LANDSAT da área de estudos, disponibilizadas na Internet pelo INPE. Nessas


imagens aparecem todos os tipos de nuvens mais freqüentes na região: cumulus, estratocumulos e cirrus, sendo comum a ocorrência de mais de um tipo ao mesmo tempo. Como as amostras das imagens são muito reduzidas, não é possível realizar medições de nuvens, mas com elas foram esclarecidas duas questões importantes:

- o motivo da alta nebulosidade constante da região, que não tem realmente o céu todo cinza e encoberto permanentemente, é a ocorrência de nuvens cumulus de bom tempo, regularmente espaçadas e distribuídas por grande parte da imagem, como na Figura 13. Estas nuvens espalhadas pelo céu, avaliadas visualmente segundo a geometria discutida no item 3.1, levam o observador a superestimar o percentual de cobertura e implicam valores médios altos de nebulosidade.
- O motivo pelo qual em cidades do litoral, como Recife e João Pessoa, mesmo tendo estatísticas de nebulosidade altas, são realizados vôos fotogramétricos com maior probabilidade do que na área vizinha do interior do continente é a existência freqüente de uma faixa livre de nuvens que acompanha a linha da costa. Isso é observado nas imagens nas quais ao mesmo tempo sobre o oceano não existem nuvens e sobre o continente a nebulosidade é de cumulus de bom tempo, que só começam aparecer após uma faixa que varia entre 1e 5km a partir da linha da costa.

A observação e constatação desta faixa livre de nuvens no litoral não é possível de ser feita com o método atual de registro da observação de superfície e nem com a forma de amostragem dos dados DX. No entanto, existem métodos mais precisos e experimentais que usam técnicas fotogramétricas já usados por GLASS (1963), HARRINGTON(1968), SEIZ & BALTSAVIAS (2000) ou composições estatísticas de imagens de satélites meteorológicos REINKE ET AL. (1992), que podem suprir as deficiências encontradas nos dados OS. A aplicação desses métodos seria útil tanto para verificações do comportamento local dentro da área de abrangência de uma

estação meteorológica como para verificação dos erros sistemáticos de avaliação cometidos por observadores.

Figura 13 - Imagem do LANDSAT, órbita 214, ponto 65, de 22.04.1995



3.4.3 Verificação do incremento da nebulosidade com o aumento da área

As estatísticas da nebulosidade têm relação direta de proporcionalidade com a área de abrangência que representam, como constatado por GREAVES ET AL. (1971) e KRISTJANSSON (1991). Pode-se verificar que a nebulosidade média aumenta na medida em que aumenta também a área sob

consideração. No sentido contrário, pode-se supor que a medida em que a área a fotografar diminui, a nebulosidade diminui e aumenta a probabilidade de sucesso de conclusão do levantamento em menor tempo. Essa relação é importante para as considerações que se farão nos capítulos seguintes sobre as diferenças entre as áreas imageadas por satélites e pela fotogrametria e sua influência em simulações de vôos.

Embora as imagens do LANDSAT não sejam apropriadas para estudo de frequência de ocorrência de nuvens, foi realizado um estudo com estes fins no Brasil por MENDONÇA (1983), que serve para ilustrar a relação proporcional entre a nebulosidade e a área que representa. O trabalho de MENDONÇA (1983) mostra mês a mês, e por região geográfica do Brasil, a média de nebulosidade obtida pelas imagens do LANDSAT no período de 1973 a 1981. Para a região Nordeste, a ocorrência de uma imagem de 185km x 185km completamente livre de nuvens é muito rara e principalmente na parte oriental, que cobre a área desta pesquisa, o intervalo pode ser de vários anos.

Como o trabalho de Mendonça não inclui as estatísticas de nebulosidade referentes aos quadrantes, foi realizado uma contagem com dados de um listagem fornecida pelo INPE. A lista inclui apenas a órbita 214, que tangencia o litoral no extremo oriental do Nordeste, com quatro imagens seqüenciais, identificadas pelos "pontos": 64, 65, 66 e 67. No período de 1984 a 1997 em um total de 658 imagens completas tomadas, nenhuma ficou 100% livre de nuvens. Apenas dois quadrantes (92km x 92km) ocorreram completamente claros e vinte com 10% de nuvens. Esses índices equivalem aos encontrados por Mendonça e mostram que reduzindo-se a área aumentam-se as chances de sucesso do imageamento.

4. PROCESSAMENTO DAS OBSERVAÇÕES DE SUPERFÍCIE

Este capítulo detalha o processamento dos dados de superfície coletados do INMET para duas finalidades principais. A primeira é a obtenção das matrizes de probabilidades incondicionais e condicionais necessárias ao processo de simulação descrito no Capítulo 7. A segunda é o agrupamento das estações em regiões homogêneas visando a preparação de um mapa de céu claro atualizado para a área de estudo e que possa também indicar quais são as áreas onde ocorre nebulosidade constante e excessiva todo o ano.

4.1 Tratamento dos dados

O tratamento dos dados inclui a preparação de programas específicos para processar os dados originais tabulados em planilha eletrônica e o processamento propriamente dito, para gerar tabelas com estatísticas diversas. Essas tabelas permitem gerar gráficos que facilitam as análises dos dados e permitem a elaboração do mapa de céu claro, além de serem úteis para o programa de simulações.

4.1.1 Descrição dos Dados Originais do INMET

Os dados originais de nebulosidade do INMET são os registros feitos diariamente nas estações em um formulário para o mês inteiro. Essas anotações ainda estão em fase de digitação e na época da liberação dos dados pelo INMET, em dezembro de 1999, apenas cerca de 50% estava em meio magnético. O restante foi copiado manualmente e depois digitado em planilha eletrônica de acordo com o formato que aparece na Figura 14. Os dados foram organizados cronologicamente por ano, sendo que as linhas correspondem aos

dias de 1 a 31, e os meses estão separados em colunas. Cada mês tem duas colunas, uma para as observações das 12h UTC e a outra para as 18h UTC. A codificação da quantidade de cobertura é a mesma do INMET, ou seja, de 0 a 10, sendo que a classe 0 é incluída na classe 1 na fase do processamento. Para os casos em que os dados não foram registrados ou foram perdidos o código usado é o número -1, e quando não existem como nos dias 30 e 31 de Fevereiro, o código é -9.

Figura 14 - Planilha eletrônica com os dados de nebulosidade copiados do INMET

APODI	JAN		FEB		MAR		ABR		MAI		JUN		JUL		AGO		SET		OUT		NOV		DEZ	
	12	18	12	18	12	18	12	18	12	18	12	18	12	18	12	18	12	18	12	18	12	18	12	18
01	6	10	7	10	9	10	9	9	9	9	9	9	9	9	9	9	9	9	9	9	9	9	9	9
02	7	7	5	7	9	10	6	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7
03	6	9	9	4	10	6	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7
04	9	7	7	7	9	2	9	10	1	1	5	6	5	9	4	9	5	2	3	2	9	7	7	6
05	6	2	5	1	9	4	10	9	1	1	9	3	10	10	9	1	0	0	7	7	7	4	5	10
06	2	4	3	4	7	9	7	9	1	1	1	2	10	9	-1	3	4	5	0	9	10	9	10	10
07	7	6	7	2	4	4	9	10	1	1	4	7	10	4	4	10	9	5	8	9	10	10	9	10
08	7	7	9	9	10	10	9	10	9	1	9	9	4	6	0	7	10	4	9	4	9	9	9	9
09	5	4	9	6	9	5	9	7	7	1	9	2	10	4	4	0	3	0	10	7	9	9	10	7
10	1	1	9	10	9	8	9	9	7	1	4	5	0	6	3	5	5	1	2	0	9	9	7	9
11	9	9	7	7	7	4	9	10	1	1	6	9	0	4	0	2	7	7	9	7	7	4	9	9
12	7	4	9	9	7	1	9	10	1	1	1	6	9	7	10	9	5	0	7	1	3	7	10	10
13	9	10	9	10	9	0	1	7	10	1	1	4	5	10	4	2	0	0	7	3	9	8	10	10
14	9	5	5	0	0	1	7	10	1	1	7	9	5	10	4	7	5	4	1	4	5	9	10	9
15	6	7	9	5	9	4	10	9	1	1	7	9	10	4	9	2	9	7	7	6	10	4	10	6
16	5	5	9	9	9	7	9	6	1	1	9	9	4	9	5	9	7	7	5	9	9	10	9	9
17	5	4	9	6	9	7	10	9	1	1	9	5	1	7	4	10	7	0	1	4	9	3	9	4
18	7	4	4	7	9	9	7	6	1	1	9	5	0	4	7	7	9	2	7	1	10	9	9	10
19	7	7	2	2	10	5	10	10	1	1	7	4	9	0	9	4	2	2	10	7	9	3	10	10
20	9	4	5	8	7	6	9	9	1	1	7	2	7	10	7	7	9	4	10	10	9	7	10	9
21	5	7	9	2	7	2	10	10	1	1	9	1	9	9	7	5	9	10	9	4	2	10	9	9
22	7	10	10	10	9	10	10	10	1	1	10	9	0	2	3	4	9	2	6	2	7	7	9	9
23	9	9	10	10	9	10	9	10	1	1	7	5	10	9	5	7	3	7	5	7	7	2	10	10
24	10	9	9	10	10	10	9	6	1	1	5	7	6	5	4	5	9	2	6	5	4	4	9	10

4.1.2 Programas de tratamento dos dados de observação de superfície (OS)

Para a manipulação e tratamento da grande massa de dados formada pelas vinte e duas estações, dez anos de observações e dois horários, foram usados vários programas, entre comerciais, como editores de texto e planilhas eletrônicas, e outros preparados em Turbo Pascal especialmente para cada aplicação. O Quadro 3 apresenta a seqüência de tratamento dos dados com os programas utilizados e a aplicação de cada um deles.

Quadro 3 - Programas usados no tratamento dos dados de superfície

PROGRAMA	OBJETIVO
Planilha eletrônica	. Dados já digitados ⇒ Alteração de formato . Dados compilados a mão ⇒ Digitação ↓ . Arquivo de Dados Primário
Programa 1 ESTAT	1. Soma as freqüências absolutas das classes de cobertura mensais de cada ano, ou o total de todos os anos 2. Calcula os percentuais de freqüência ou as probabilidades das classes de cobertura por mês Calcula separadas as observações de 12 e 18 h
Programa 2: ESTCOND	Calcula as probabilidades condicionais temporais entre classes de cobertura, com intervalo de 24 h, entre observações de mesmo horário (12-12 ou 18-18) e no mesmo dia entre 12-18h
Programa 3 CONDESP	3. 1. Calcula as probabilidades condicionais espaciais entre classes de cobertura entre duas estações vizinhas
Planilha Eletrônica	4. 1. Gera gráficos com as saídas dos programas 1 a 3

4.1.3 Programa ESTAT

O primeiro programa, denominado de ESTAT, tem o objetivo de gerar as estatísticas básicas de totalizações, médias mensais e anuais, das freqüências das classes de cobertura.

Os arquivos de dados primários (como o da figura 15) de cada estação são usados como entrada. O programa acumula e totaliza cada classe de cobertura, mês a mês de cada ano, ou soma todos os anos, e em seguida, calcula os percentuais. Todos os cálculos podem ser efetuados acumulando as observações de 12 e 18h ou separadas. A Figura 15 mostra um exemplo da saída do programa ESTAT, da qual podem ser retirados dados para formar gráficos de séries históricas, histogramas da média geral e variação anual das classes de cobertura 1, 2 e 3. A parte inferior da Figura 15 mostra as médias mensais de cada classe de cobertura em percentuais que podem ser considerados as probabilidades de ocorrência de cada classe e formam as Matrizes de Probabilidades Incondicionais (MPI) para as 12h e 18h UTC, para uso no programa de simulações.

Figura 15 - Exemplo do arquivo de saída do programa ESTAT

recife-prn													
Posto	82900	Ano	1989	12 UTC	Num Dias	Claros	0	10	11	12			
meses	1	2	3	4	5	6	7	8	9	10	11	12	
10	0	0	0	0	0	0	0	0	0	0	0	0	
20	0	0	0	0	0	0	0	0	0	0	0	0	
30	0	0	0	0	0	0	0	0	0	0	0	0	
40	0	1	2	0	1	0	0	1	1	1	1	1	
50	5	1	4	1	3	0	2	1	5	2	0	0	
60	4	1	4	0	4	2	1	5	3	4	1	2	
70	4	11	10	3	2	3	4	3	5	7	10	4	
80	11	7	9	9	9	14	11	15	13	11	10	13	
90	2	5	2	12	7	4	3	3	1	5	3	9	
100	5	2	0	5	5	7	10	2	2	1	1	2	
Percentual													
meses	1	2	3	4	5	6	7	8	9	10	11	12	media
10	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
20	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
30	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
40	0.0	3.6	6.5	0.0	3.2	0.0	0.0	3.2	3.3	3.2	3.8	3.2	2.5
50	16.1	3.6	12.9	3.3	9.7	0.0	6.5	3.2	16.7	6.5	0.0	0.0	6.6
60	12.9	3.6	12.9	0.0	12.9	6.7	3.2	19.4	10.0	12.9	3.8	6.5	8.9
70	12.9	39.3	32.3	10.0	6.5	10.0	12.9	9.7	16.7	22.6	38.5	12.9	18.3
80	35.5	25.0	29.0	30.0	29.0	46.7	35.5	48.4	43.3	35.5	38.5	41.9	36.6
90	6.5	17.9	6.5	40.0	22.6	13.3	9.7	9.7	3.3	16.1	11.5	29.0	15.5
100	16.1	7.1	0.0	16.7	16.1	23.3	32.3	6.5	6.7	3.2	3.8	6.5	11.6
Total de observacoes do mes ou ano													
	31	28	31	30	31	30	31	31	30	31	26	31	361


4.1.4 Gráficos das séries históricas das classes de cobertura

As médias de ocorrência de cada classe em percentuais, ano a ano, geram o gráfico da série histórica que permitem analisar as possíveis variações ocorridas no período de 1989 a 1998 (Figura 16).


A análise destes gráficos mostram que o comportamento das médias anuais das classes de cobertura, na grande maioria das estações, não varia significativamente. A Figura 16-a mostra um destes casos. Existem, no entanto, algumas estações, como Morada Nova (Figura 16-b), em que o padrão das freqüências vinha se repetindo até 1994, mas muda em 1995, passando a se repetir com nova distribuição, sugerindo que houve possivelmente uma mudança de observador. Observa-se ainda de modo geral nos gráfico que houve nos anos de 1993 e 1994 uma redução da nebulosidade. Os gráficos de todas as estações para as 12h UTC constam do Anexo 1.

Figura 16 - Gráficos de séries históricas das classes de cobertura obtidos a partir de saída do programa ESTAT

a) PALMEIRA DOS INDIOS



b) MORADA NOVA

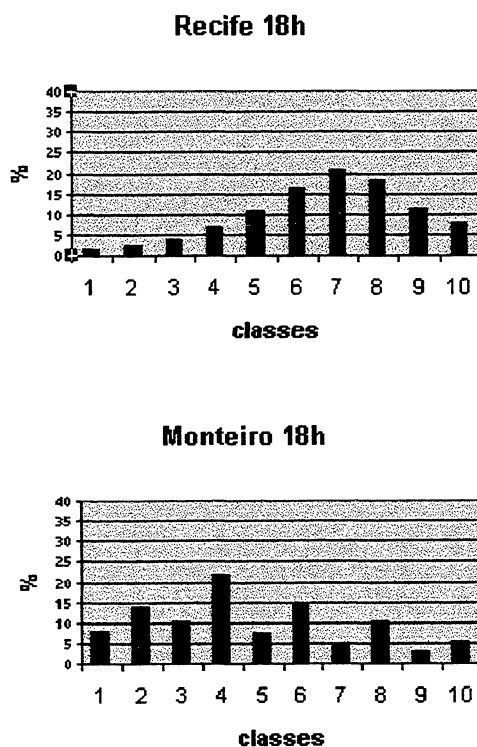


4.1.5 Histogramas das médias gerais anuais

O histograma da média geral das classes de cobertura é formado pelas médias de cada classe de cobertura de todos os anos, sendo um resumo dos gráficos da série histórica. Os percentuais gerais são dados diretamente pela saída do programa ESTAT como aparece na coluna a direita da Figura 15. A Figura 17 mostra exemplos desse histograma para as 18h UTC e no Anexo 2 constam todos os demais para 12 e 18h.

Esses gráficos definem a forma da curva de distribuição das classes de cobertura, contribuindo para inferir quais os melhores modelos estatísticos a empregar. As formas variam de sino, próximas da normal, a “U”, e “J”, e outras tem dois picos. Em muitos casos, conforme pode ser visto nos gráficos do Anexo 2, percebe-se que existe um erro sistemático, introduzido pela preferência do observador em anotar um valor em detrimento de outro, o que provoca gráficos “dentados”. A Figura 17 mostra como a distribuição da estação Recife é contínua e como na estação de Monteiro é dentada.

Figura 17 - Histogramas das médias gerais de ocorrência das classes de cobertura de Recife e Monteiro para as 18h UTC



4.1.6 Histogramas das médias gerais mensais

As matrizes de percentuais, como da Figura 15, foram também utilizadas para gerar gráficos de freqüências mensais, com a finalidade de verificar melhor as variações das curvas de distribuição ao longo do ano, entre o turno da manhã e tarde. As freqüências foram agrupadas em três gráficos com quatro meses cada: janeiro-abril, maio-agosto e setembro-dezembro, para as 12h e 18h UTC. A Figura 18 mostra as matrizes e os gráficos da estação Triunfo e no Anexo 3 estão os gráficos para as vinte e duas estações.

Da análise dos gráficos, observa-se o seguinte:

- tanto a variação mensal como entre a manhã e a tarde, é muito mais dinâmica do que indicam os gráficos da média geral anual. Numa mesma estação ocorrem curvas com forma de sino, “U” e “j”. O tipo de curva que tem condições de absorver toda esta multiplicidade de formas é a distribuição Beta, como sugerido por FALLS (1974);
- em muitas estações percebe-se facilmente, mês a mês, as descontinuidades das curvas sempre nas mesmas classes, indicando a existência de erros sistemáticos, como já foi observado nos gráficos das médias gerais anuais;
- a quantidade da nebulosidade varia entre os dois horários. Na maioria das estações ocorre mais céu claro pela manhã (12h), mas existem áreas nas quais ocorre mais à tarde (18h), como nas sub-regiões 5, 6 e 7 da figura 21. Isto contraria a suposição generalizada dos estudos de cobertura de nuvens de que o período da manhã tem sempre mais céu claro. Nesse horário, inclusive, o satélite LANDSAT passa sobre a região de estudos. No entanto esta separação é melhor percebida com os gráficos das classes 1, 2 e 3 a seguir.

Figura 18- Exemplo de Matrizes de Frequências e Gráficos das Médias Mensais da Estação Triunfo

Triunfo

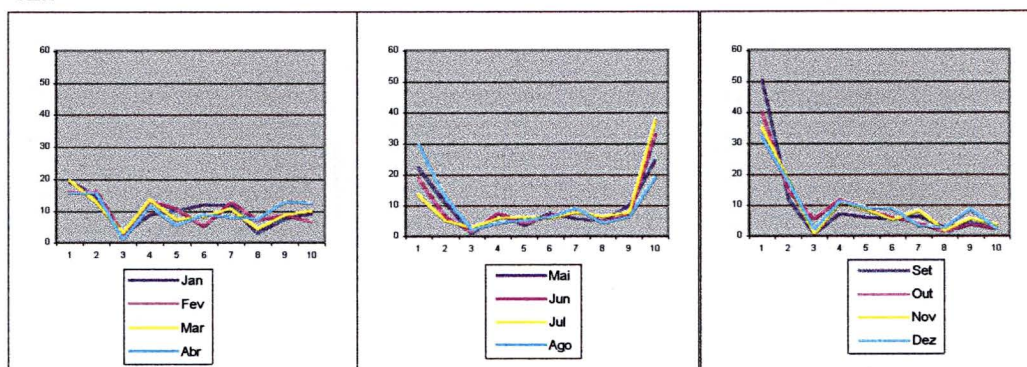
82789 12

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
10	19.4	16	19.8	15.7	22.4	19.1	13.5	29.6	50.5	40.1	35.4	32
20	14.9	16.4	13	15.7	11	6.5	5.3	12.9	12.4	15.1	18.3	18
30	2.8	2.7	3.2	1.3	1.1	1.7	3	2.2	1	5.7	0.8	2.2
40	8.9	13.3	13.8	11.7	7.7	7.8	6	4.3	7.6	12.2	11.3	11.5
50	10.1	10.7	7.3	5.4	3.7	4.3	6.4	5.4	6.2	9	8.8	9.4
60	12.1	5.3	8.5	9	7.7	7	6	6.5	5.7	6.1	5.4	9
70	11.7	12.9	10.9	8.1	5.9	8.7	7.9	9.1	6.7	4.3	8.3	3.6
80	3.2	7.1	4.5	7.6	5.1	4.8	6.4	4.3	2.9	1.4	2.1	2.9
90	7.7	8.9	8.9	13	10.3	7	7.9	6.5	4.8	3.9	5.8	9
100	9.3	6.7	10.1	12.6	25	33	37.6	19.4	2.4	2.2	3.8	2.5

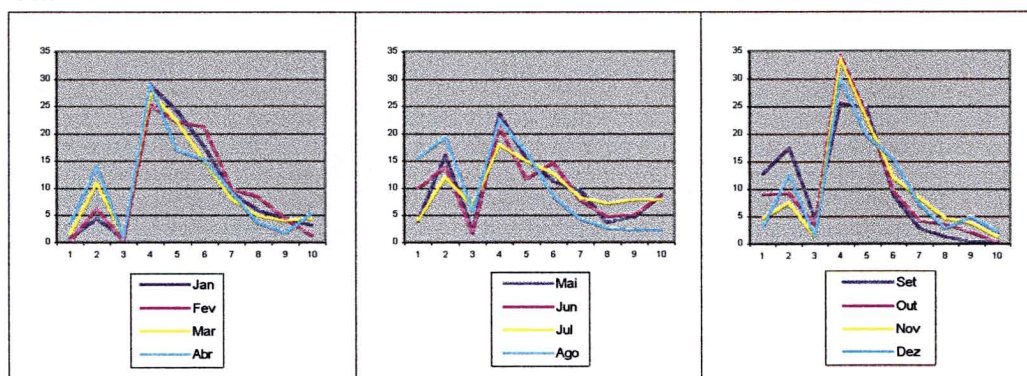
82789 18

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
10	0.8	0.4	1.6	3.6	4	10	4.1	15.6	12.9	9	4.6	3.2
20	4.4	6.2	10.9	13.9	16.2	13.9	12	19.4	17.6	9.3	7.5	12.6
30	0.8	0.4	1.2	0.9	2.2	1.7	6.8	5.9	4.8	3.6	1.3	1.4
40	29	25.3	27.5	29.1	23.9	21.3	18	22.6	25.7	34.4	33.8	30.2
50	24.2	22.2	22.3	17	15.4	11.7	15	16.7	24.8	23.7	22.9	19.8
60	17.7	21.3	15	15.2	11.4	14.8	12.8	8.6	9	9.7	12.1	15.5
70	9.3	9.8	8.1	9.4	9.6	7.8	8.3	4.3	2.9	4.3	8.3	7.2
80	6	8.4	4.9	3.6	3.7	4.8	7.1	2.7	1.4	3.6	4.6	2.9
90	4.4	4.4	4	1.8	4.8	5.2	7.9	2.2	0.5	2.2	3.8	5
100	3.2	1.3	4.5	5.4	8.8	8.7	7.9	2.2	0.5	0.4	1.3	2.2

12h



18h



4.1.7 Gráficos das classes 1, 2 e 3

Sob o ponto de vista fotogramétrico, a classe de cobertura que interessa é apenas a classe 1, com nuvens de 0 a no máximo 10%. Observou-se, porém, que existem estações em que, durante vários ou muitos meses, nunca ocorre a classe 1. Por outro lado, os cálculos realizados em 3.1 sugerem que até com 30% de nebulosidade pode haver uma área significativa de dezenas de quilômetros quadrados de céu limpo que podem ser utilizados para vôo fotogramétrico. Sendo assim, é razoável analisar o comportamento das classes 1, 2 e 3 com o objetivo de avaliar a utilização do percentual médio ou acumulado das três, eventualmente no lugar da classe 1.

O comportamento das classes 1, 2 e 3 é melhor estudado ao longo do ano através de gráficos formados com os dados das três primeiras linhas de matriz do tipo mostrado na Figura 15. Exemplos dos gráficos para as 12 e 18 horas estão na Figura 19. São dois gráficos para cada horário: o superior tem como ordenadas as freqüências relativas simples de cada classe; o inferior tem como ordenadas as classes 1, 2 e 3 acumuladas, uma após a outra.

Com esses gráficos foi possível:

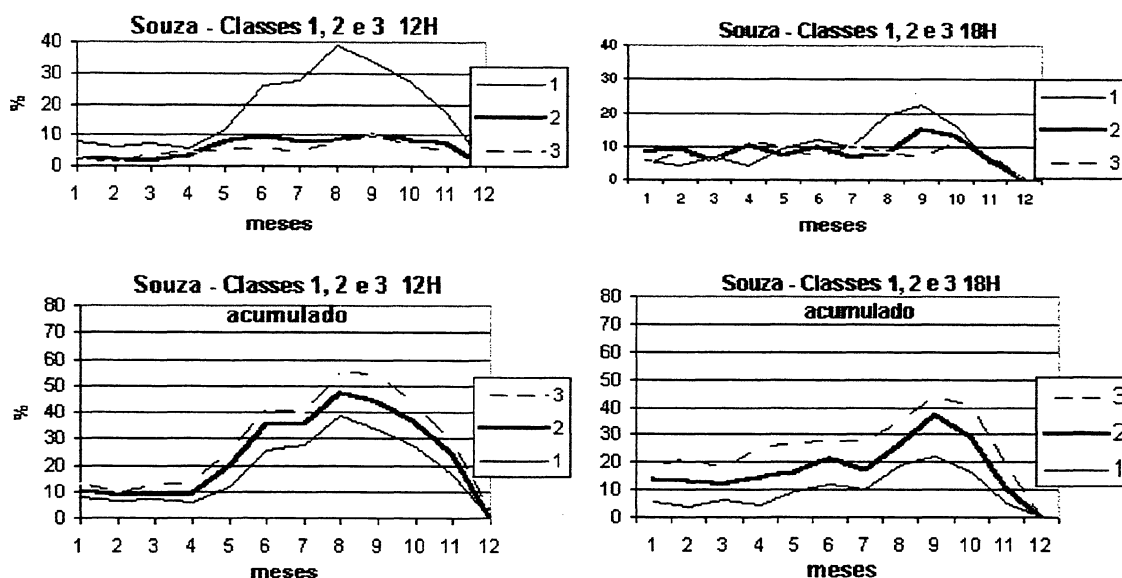
- identificam as estações que tem mais céu claro pela manhã ou pela tarde;
- realçar a variação do comportamento das classe 1, 2, e 3 entre os meses;
- mostrar que, de uma maneira geral, os formatos da distribuição das classes 1, 2 e 3 são bem semelhantes;
- identificar imediatamente as épocas com mais céu claro de cada estação e aquelas onde não ocorrem.

Por exemplo, a estação Souza, tem mais céu claro pela manhã com ocorrência de mais de 30% na classe 1 de Agosto a Outubro, enquanto Ceará Mirim tem ocorrência de céu claro pela manhã no máximo 3,2% em Agosto, melhorando à tarde para 12,3%. Os gráficos de todas as estações estão no Anexo 4.

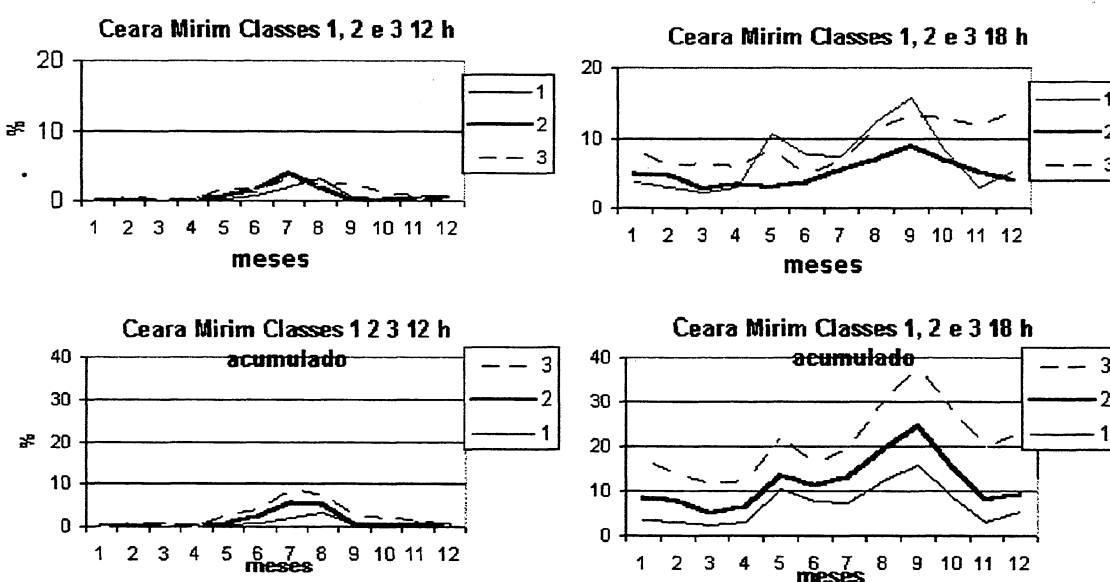
Estes gráficos e seus respectivos dados foram utilizados também na geração da tabela de índices (item 4.2.) e no estudo da correlação entre os dados de superfície e de satélites (Capítulo 6).

Figura 19 - Exemplo de gráfico das classes 1, 2 e 3 das 12h e 18h UTC

a) Estação Souza



b) Estação Ceará Mirim



4.1.8 Programa ESTCON

O programa ESTCON destina-se a calcular as Matrizes de Probabilidades Condicionais Temporais (MPCT) para cada mês.

As MPCT serão calculadas entre observações de mesmo horário, 12-12h, 18-18h com 24 horas de intervalo (MPCT 24, das 12h ou 18h), e entre os horários 12 e 18 do mesmo dia (MPCT 12-18).

A probabilidade condicional de uma classe i ocorrer hoje, desde que tenha ocorrido a classe j no dia anterior, é dada por

$$P(i/j) = \frac{P(i,j)}{P(j)} \quad (13)$$

Sendo $P(i,j)$ é a probabilidade conjunta de i e j ;

$P(i)$ é a probabilidade de ocorrer a classe de nuvens i

O cálculo da MPCT é simples e segue o algoritmo abaixo:

- uma matriz 10x10 é iniciada com zeros;
- a classe 0 é agrupada com a classe 1, de modo que as classes variam de 1 a 10;
- arquivo com as observações de cada dia é lido seqüencialmente de forma que o dia n corresponde à linha i da matriz e o dia $n-1$ à coluna j ;
- para cada dia (i) e o anterior (j) se incrementa de uma unidade a célula da matriz (ij);
- cada célula é dividida pela soma da linha correspondente;

Um exemplo da saída do programa ESTCON é mostrado na Figura 20, com as matrizes de probabilidade condicional temporal de 24h da estação 82588 das 12h UTC, dos meses de Janeiro a Março. As matrizes de todas as estações farão parte do Banco de Dados e serão usadas nas simulações discutidas no Capítulo 7.

Figura 20 - Um exemplo da saída do programa ESTCON com parte da matriz de probabilidade condicional temporal de 24h da estação 82588 das 12h UTC

Matriz de Probabilidade Condicional Temporal 24h

82588	1	12								
10	0.0	0.0	0.0	0.0	33.3	66.7	0.0	0.0	0.0	0.0
20	0.0	14.3	28.6	14.3	14.3	0.0	7.1	14.3	0.0	7.1
30	5.9	5.9	0.0	41.2	35.3	5.9	0.0	0.0	5.9	0.0
40	2.7	10.8	13.5	35.1	10.8	8.1	5.4	10.8	2.7	0.0
50	3.4	10.3	10.3	10.3	10.3	27.6	13.8	10.3	0.0	3.4
60	0.0	0.0	4.0	10.0	12.0	26.0	14.0	16.0	8.0	10.0
70	0.0	4.8	0.0	2.4	11.9	19.0	14.3	19.0	19.0	9.5
80	0.0	1.9	0.0	3.8	3.8	18.9	28.3	20.8	13.2	9.4
90	0.0	3.2	3.2	6.5	3.2	12.9	16.1	22.6	22.6	9.7
100	0.0	0.0	4.2	0.0	0.0	12.5	20.8	33.3	4.2	25.0
82588	2	12								
10	0.0	0.0	0.0	50.0	0.0	0.0	0.0	50.0	0.0	0.0
20	0.0	11.1	33.3	11.1	11.1	33.3	0.0	0.0	0.0	0.0
30	0.0	0.0	8.3	41.7	16.7	16.7	0.0	16.7	0.0	0.0
40	3.1	9.4	9.4	15.6	25.0	6.3	12.5	12.5	0.0	6.3
50	3.6	3.6	3.6	14.3	10.7	17.9	25.0	10.7	7.1	3.6
60	0.0	5.9	2.9	14.7	11.8	11.8	23.5	11.8	11.8	5.9
70	0.0	4.4	2.2	11.1	8.9	8.9	11.1	31.1	11.1	11.1
80	0.0	0.0	1.7	8.6	8.6	10.3	20.7	27.6	13.8	8.6
90	0.0	0.0	6.7	0.0	6.7	16.7	10.0	26.7	33.3	0.0
100	0.0	0.0	0.0	0.0	0.0	5.0	30.0	30.0	5.0	30.0
82588	3	12								
10	0.0	20.0	0.0	20.0	20.0	20.0	0.0	20.0	0.0	0.0
20	25.0	25.0	0.0	25.0	0.0	0.0	0.0	25.0	0.0	0.0
30	25.0	0.0	12.5	25.0	12.5	12.5	12.5	0.0	0.0	0.0
40	9.5	0.0	9.5	19.0	14.3	19.0	14.3	9.5	4.8	0.0
50	0.0	0.0	6.7	13.3	6.7	26.7	13.3	13.3	13.3	6.7
60	0.0	0.0	3.0	12.1	18.2	15.2	15.2	18.2	12.1	6.1
70	0.0	2.8	5.6	11.1	2.8	22.2	27.8	13.9	5.6	8.3
80	0.0	0.0	2.2	6.5	4.3	15.2	17.4	28.3	15.2	10.9
90	0.0	4.0	0.0	0.0	0.0	8.0	16.0	36.0	20.0	16.0

4.1.9 Banco de Dados

Todos os arquivos de dados OS necessários para o processamento das simulações, além dos arquivos originais, foram organizados em um banco de dados.

Os nomes dos arquivos seguem uma codificação que facilita a criação de listas automáticas para entrada nos programas que operam em lote. Esses programas repetem as operações para várias estações, ou abrem vários arquivos ao mesmo tempo sem necessidade de digitar os nomes um a um. O nome tem o seguinte formato: ABCxxxxx.YYY, sendo ABC o código de identificação do tipo do arquivo; xxxxx é o número da estação; e .YYY quando é igual a PRN indica que é arquivo de entrada e .DAT indica que é resultado de saída. Os códigos ABC são:

- Otxxxxx.prn dados originais do INMET
- Pixxxxx.prn matrizes de probabilidades incondicionais de 12 e 18h UTC
- PC1xxxxx.prn matrizes de probabilidades condicionais 24 h entre 12 e 12
- PC2xxxxx.prn matrizes de probabilidades condicionais 24 h entre 18 e 18
- PC3xxxxx.prn matrizes de probabilidades condicionais entre 12 e 18

O Banco de Dados inclui ainda os arquivos com os dados reduzidos retirados dos dados originais DX, comentados no Capítulo 5, separados por ano e mês.

4.2 Mapa de ocorrência de Céu Claro

Um dos objetivos principais de processamento dos dados do INMET é conseguir reduzi-los e apresentá-los numa forma gráfica. A massa de dados originais é muito grande e, mesmo sendo reduzida em tabelas e gráficos, o mínimo a que se chega são a doze mapas, um por mês, para mostrar as épocas mais favoráveis aos vôos, como foi visto no Capítulo 2. A exceção a essa forma de apresentação é o mapa executado por F. J Sette em 1939 para os EUA e atualizado por LEE & JOHNSON (1985). Esse único mapa é dividido em regiões e fornece a quantidade média de dias claros por mês com o auxílio

de uma tabela. Esse tipo de mapa de céu claro tem algumas vantagens em relação aos outros:

- é mais fácil manipular um único mapa que uma coleção com doze;
- mesmo dentro de uma região, cada cidade tem seu índice próprio, o que dá mais precisão do que uma média geral para todas elas;
- é mais fácil fazer interpolações para as áreas que estão entre cidades da mesma região ou mesmo entre regiões diferentes.

O modelo do mapa de Sette foi o escolhido para a representação final dos dados do INMET principalmente por permitir que cidades que apresentem problemas de nebulosidade alta e constante o ano todo possam ter seus índices próprios. Algumas modificações, porém, foram introduzidas como alteração do critério de separação das regiões, adaptação do cálculo da tabela e informação do turno em que mais ocorre céu claro. SILVA & DALMOLIN (2000), numa primeira fase desta pesquisa, já o propuseram como um modelo que pode ser estendido a todo o Brasil.

4.2.1 Elaboração do Mapa

A metodologia para a elaboração do mapa segue a proposta de LEE & JOHNSON (1981) com algumas adaptações e envolve duas etapas. Primeiro, a divisão de toda a região em sub-regiões homogêneas, de acordo com a semelhança das curvas de distribuição da nebulosidade. Depois, a preparação de uma tabela de índices que permite calcular com facilidade o número de dias com céu claro em qualquer localidade da região.

4.2.1.1 Separação das sub-regiões

O mapa de céu claro do modelo de Sette é dividido em regiões de modo que cada uma delas contenha as cidades, ou estações, que apresentam formas semelhantes do histograma das classes de cobertura. Esse processo

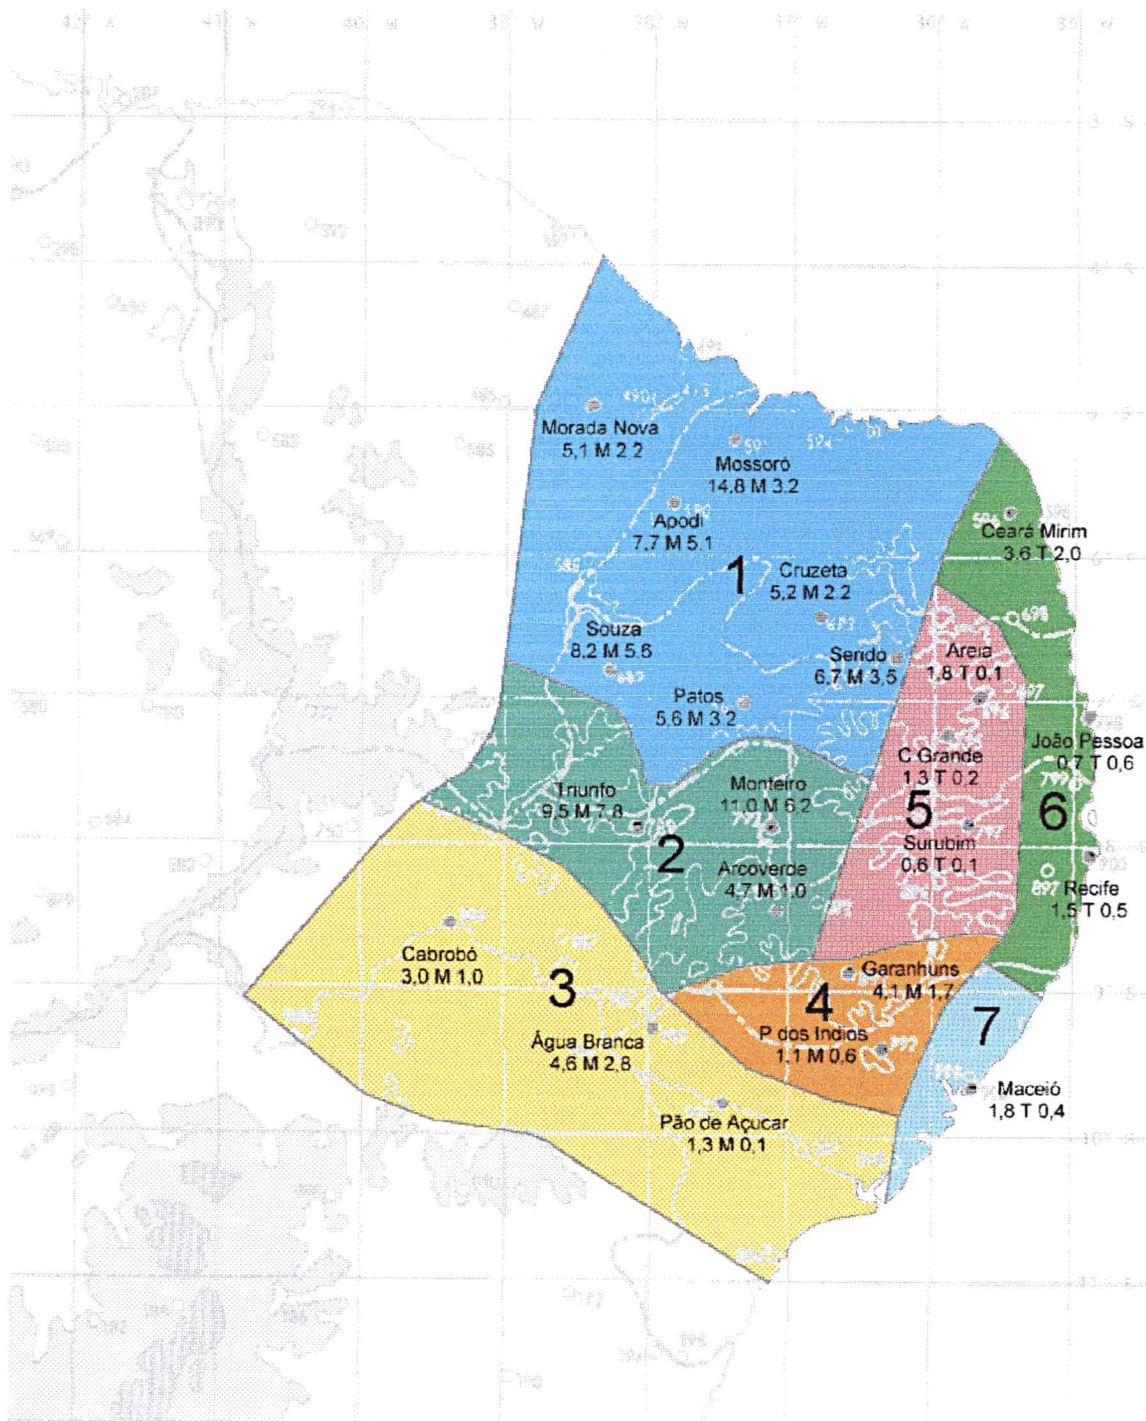
de classificação empregado equivale na verdade ao método de agrupamento largamente usado hoje em várias disciplinas, mas tanto na atualização feita por LEE & JOHNSON (1985) como nessa pesquisa, esta classificação foi visual. No presente caso, optou-se pela comparação do comportamento das curvas de distribuição das classes 1, 2 e 3 ao longo do ano (Anexo 4).

A classificação pode apresentar algumas deficiências devido ao tamanho da amostra e/ou erros de observação. Pode-se notar que nas estações que apresentam frequência muito baixa de céu claro, como João Pessoa, Recife e Maceió, as curvas não têm tendências definidas, dificultando a comparação com as outras e a sua classificação. Maceió, por exemplo, teve uma classificação separada por não se enquadrar nas outras sub-regiões. Os erros da observação do céu, inerentes ao método, podem ser muito difíceis de identificar e estações podem ser classificadas em regiões diferentes daquela em que deveria estar.

Depois da classificação, é necessário definir os limites de cada sub-região, sendo essa tarefa a mais difícil do método. Para uma definição mais precisa dos limites, é necessário que se tenha uma alta densidade de estações. Em caso contrário, quando os dados disponíveis são limitados, pode-se contornar o problema utilizando-se informações auxiliares que tenham relação com nebulosidade, como mapas de precipitação, relevo da região e conhecimento do regime dos processos atmosféricos típicos.

A classificação das estações resultou em sete sub-regiões, consideradas como tendo homogeneidade nas classes 1, 2 e 3. O mapa final com os limites de cada sub-região e estações estão mostrados na Figura 21.

Figura 21 - Mapa de ocorrência de céu claro para o NE do Brasil, segundo sub-regiões homogêneas, obtido a partir de dados de superfície do INMET.



4.2.1.2 Elaboração da tabela de índices

A tabela de índices é montada seguindo o roteiro abaixo para cada estação:

- a) Para evitar probabilidades indefinidas em alguns meses (divisão por zero), optou-se pelo uso da média das classes 1, 2 e 3, dos dois horários, mas que aqui por simplificação continuará a ser considerada como ocorrência de céu claro:

$$M(i) = (S_{12} + S_{18}) / 2 \quad (14)$$

Sendo $M(i)$ a média do mês i e S_{12} e S_{18} dados por

$$S_{12} = P_{12}(1) + P_{12}(2) + P_{12}(3) \quad (15)$$

$$S_{18} = P_{18}(1) + P_{18}(2) + P_{18}(3)$$

$P_{12}(i)$, $P_{18}(i)$ são as probabilidades da classe i , $i=1, \dots, 3$.

- b) Converte-se M de percentual para o equivalente em dias de acordo com o número de dias do mês.

$$Md(i) = M * Nd(i) \quad (16)$$

sendo $Md(i)$ é o número médio de dias de céu claro no mês i .

$Nd(i)$ é o número de dias do mês i (para Fevereiro foram considerados 28 dias)

- c) Calcula-se MGA, a média geral anual de dias com céu claro. MGA é anotado sob o nome da estação no mapa.

$$MGA = (\sum Md(i)) / 12$$

(17)

- d) Calcula-se o Índice de Dias Claros de cada mês i pela fórmula

$$IDC(i) = Md(i) / MGA \quad (18)$$

A Tabela 10 mostra um exemplo de cálculo dos índice para a estação de João Pessoa.

A Figura 22 mostra os gráficos com os índices de cada estação já separados por sub-regiões. O critério de separação das sub-regiões foi comentado na seção anterior.

Depois de calculado o índice de cada estação calcula-se o índice médio por sub-região, conforme mostra a Tabela 11.

A Tabela 11 apresenta também à direita (nas colunas I, II, III) a média anual geral de dias claros (classes 1, 2 e 3), e as médias da classe 1 para as 12 e 18 h (colunas IV e V). O horário com mais ocorrências de céu claro determina a letra a ser colocada sob o nome da estação no mapa da Figura 21, sendo M se às 12h ou T se às 18h. As médias da Tabela 11 são os índices finais que aparecem numa tabela separada (Tabela 12) para facilitar a sua utilização.

Tabela 10 - Exemplo de cálculo de índice de dias claros para a estação João

Pessoa

JOÃO PESSOA		12 H												
		Meses												
		jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez	
Classe 1		0.7	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.7	0.6	0.0	0.0	
Classe 2		0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.3	0.3	0.0	
Classe 3		0.0	0.4	0.0	0.0	0.3	0.3	0.3	0.6	0.4	1.0	0.0	0.6	
SOMA 1		0.7	0.4	0.0	0.0	0.3	0.3	0.3	0.6	1.1	2.9	0.3	0.6	
JOAO PESSOA		18 H												
Classe 1		1.5	2.5	2.6	1.0	0.3	1.7	1.3	3.9	3.0	3.9	0.3	1.3	
Classe 2		0.0	0.0	0.3	0.0	0.3	0.0	0.0	0.0	0.0	1.9	0.0	0.3	
Classe 3		2.6	1.4	1.7	1.0	1.3	0.7	2.0	1.0	1.5	2.3	1.4	3.2	
SOMA2		4.1	3.9	4.6	2.0	1.9	2.4	3.3	4.9	4.5	8.1	1.7	4.8	
Media das 12 e 18h												media geral MG		
M(i)		2.4	2.15	2.3	1.0	1.1	1.35	1.8	2.75	2.8	5.5	1.0	2.7	2.24
Conversão em número de dias por mês														
Dias claros		0.74	0.60	0.71	0.30	0.34	0.41	0.56	0.85	0.84	1.71	0.30	0.84	0.68
Índice Final														
ÍNDICE		1.09	0.88	1.04	0.44	0.50	0.59	0.82	1.25	1.23	2.50	0.44	1.23	

Tabela 11 - Índices das estações e índices médios por sub-regiões

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez	I	II	III	IV	V
Sub-Região 1																	
Mossoró	0.7	0.7	0.6	0.6	1.0	1.0	1.1	1.3	1.4	1.3	1.1	1.0	14.8	10.8	7.2	3.2	2.2
Morada N	0.5	0.3	0.3	0.4	0.7	1.1	1.7	2.1	2.1	1.4	0.7	0.7	5.1	7.3	2.1	2.2	0.6
Apodi	0.4	0.6	0.5	0.3	1.6	1.3	1.5	1.5	2.0	1.2	0.6	0.4	7.7	17.1	11.7	5.1	3.5
S Gonçal	0.6	0.5	0.6	0.7	1.0	1.3	1.3	1.7	1.7	1.6	0.9	0.7	8.2	18.5	10.1	5.6	3.0
Patos	0.4	0.3	0.4	0.5	1.0	1.1	1.1	1.7	2.0	1.6	0.9	0.9	5.6	10.7	2.0	3.2	0.6
Cruzeta	0.4	0.3	0.5	0.4	1.1	1.1	1.2	1.6	1.7	1.6	1.0	0.9	5.2	7.3	1.6	2.2	0.5
Serido	0.5	0.4	0.5	0.6	0.8	1.1	1.0	1.4	2.2	1.7	0.9	1.0	6.7	11.5	2.2	3.5	0.7
Media	0.5	0.4	0.5	0.5	1.0	1.1	1.3	1.6	1.9	1.5	0.9	0.8					
Sub-Região 2																	
Monteiro	0.7	0.6	0.7	0.6	0.8	0.9	0.9	1.2	1.4	1.6	1.2	1.4	11.0	20.8	7.8	6.2	2.3
Triunfo	0.7	0.6	0.8	0.8	0.9	0.8	0.7	1.4	1.6	1.4	1.1	1.1	9.5	26.0	5.5	7.8	1.7
Arcoverd	0.6	0.8	1.1	0.9	0.7	0.7	0.5	0.8	1.4	1.8	1.2	1.4	4.7	3.4	0.5	1.0	0.2
Media	0.7	0.7	0.9	0.8	0.8	0.8	0.7	1.1	1.5	1.6	1.2	1.3					
Sub-Região 3																	
Cabrobó	0.6	0.3	0.3	0.4	0.7	0.1	0.6	1.5	2.3	2.6	1.4	1.2	3.0	3.3	1.4	1.0	0.4
Agua Bra	1.1	0.9	0.6	0.7	0.5	0.5	0.4	0.6	1.6	2.0	1.4	1.6	4.6	9.3	5.2	2.8	1.6
Pao açuc	0.7	1.1	0.5	0.3	1.2	0.8	0.3	1.1	1.6	2.5	1.3	0.6	1.3	0.4	0.0	0.1	0.0
Media	0.8	0.8	0.5	0.5	0.8	0.5	0.4	1.1	1.8	2.4	1.4	1.1					
Sub-Região 4																	
Garanhun	1.0	1.0	0.8	0.7	0.8	0.4	0.4	0.4	1.0	1.8	1.4	2.3	4.1	5.5	2.6	1.7	0.8
P Indios	0.5	1.3	0.7	0.4	1.7	0.7	0.1	0.4	1.8	1.8	1.1	1.7	1.1	1.9	0.9	0.6	0.3
Media	0.8	1.2	0.8	0.6	1.3	0.6	0.3	0.4	1.4	1.8	1.3	2.0					
Sub-Região 5																	
Surubim	0.2	0.3	0.7	0.6	0.8	0.9	0.7	1.2	1.8	1.5	1.2	0.7	0.6	0.1	0.2	0.0	0.1
Areias	0.8	0.3	0.5	0.8	0.9	1.0	0.6	1.3	2.0	2.1	0.6	1.1	1.8	0.2	0.3	0.1	0.1
C Grande	0.4	0.6	0.4	0.6	1.0	0.9	0.9	1.0	1.8	1.8	0.6	2.1	1.3	0.5	0.7	0.2	0.2
Media	0.5	0.4	0.5	0.7	0.9	0.9	0.7	1.2	1.9	1.8	0.8	1.3					
Sub-Região 6																	
Joao Pes	1.0	0.9	1.0	0.4	0.5	0.6	0.8	1.2	1.2	2.5	0.4	1.2	0.7	0.2	1.9	0.1	0.6
Recife	1.8	0.8	0.7	0.5	1.3	1.0	1.3	1.4	1.4	1.2	0.4	1.3	1.5	0.2	1.7	0.1	0.5
Ceara Mi	0.7	0.6	0.5	0.5	1.1	0.8	1.2	1.6	1.7	1.3	0.9	1.0	3.6	0.7	6.8	0.2	2.0
Media	1.2	0.8	0.7	0.5	1.0	0.8	1.1	1.4	1.4	1.7	0.6	1.2					
Sub-Região 7																	
Maceio	0.7	1.6	1.8	1.2	2.1	1.9	0.3	0.3	0.9	0.6	0.4	0.4	1.8	0.6	1.2	0.2	0.4
	0.7	1.6	1.8	1.2	2.1	1.9	0.3	0.3	0.9	0.6	0.4	0.4					

Coluna I: Média de dias claros das classes 1,2 e 3 das 12 e 18h UTC

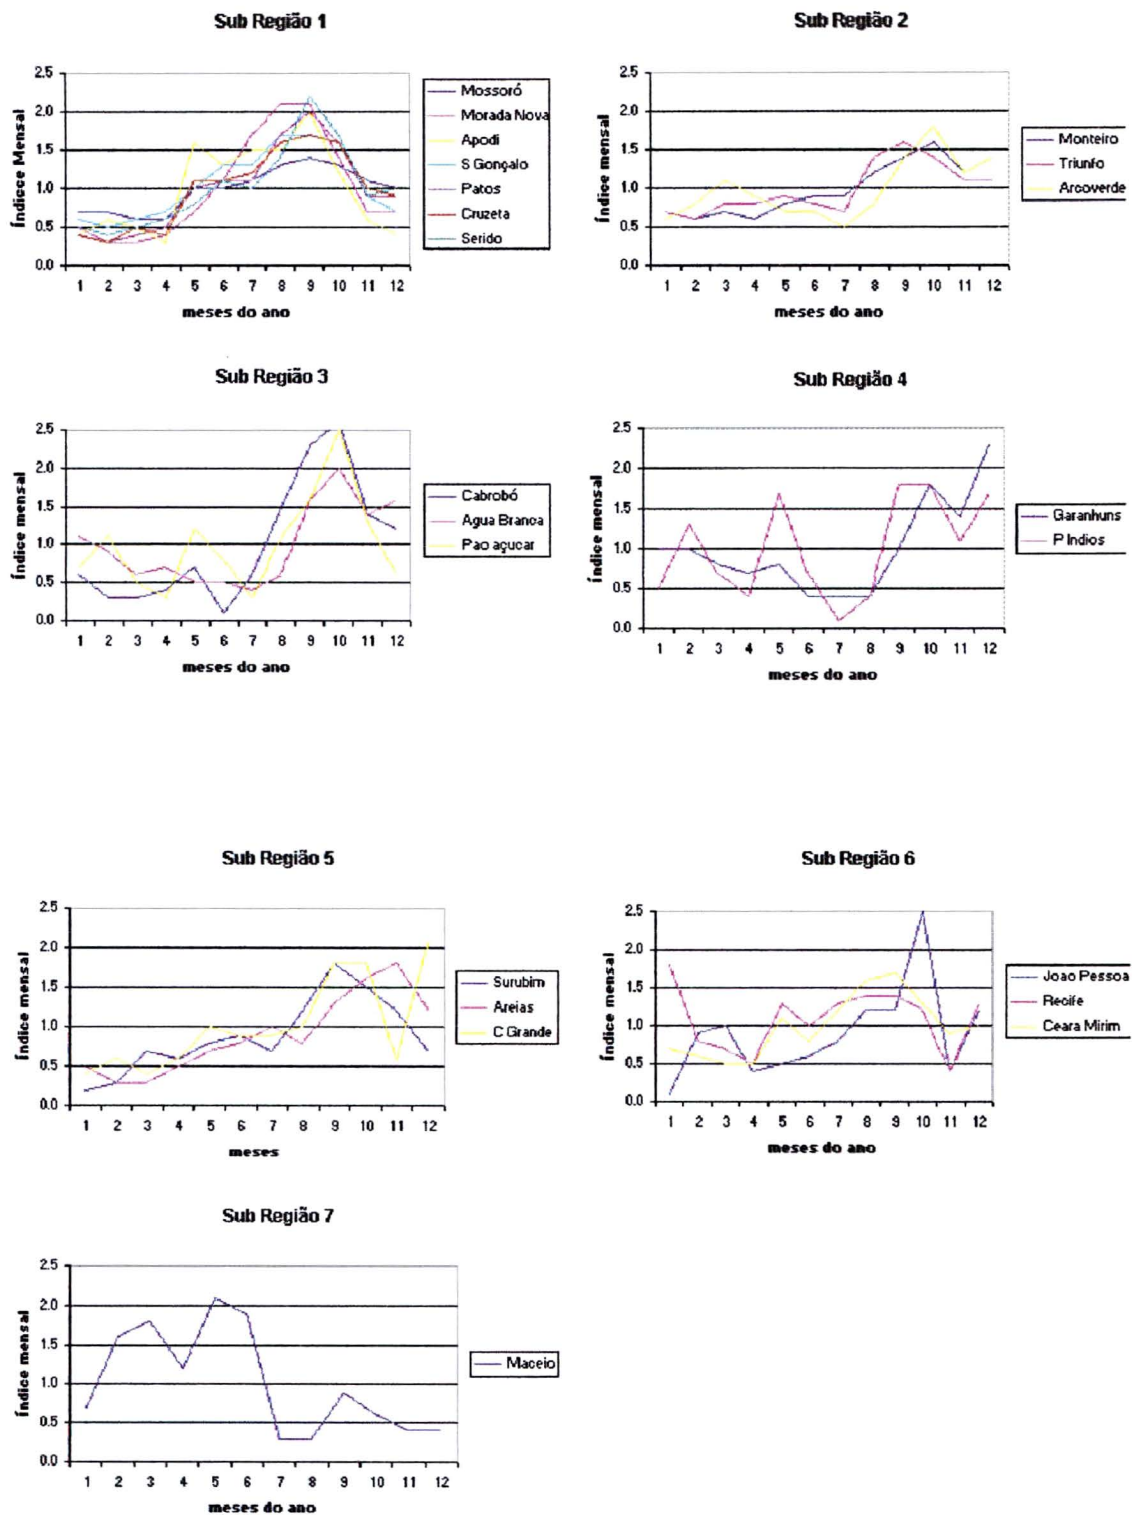
Coluna II: Percentual de ocorrência da classe 1 as 12h UTC

Coluna III: Percentual de ocorrência da classe 1 as 18h UTC

Coluna IV: Número de dias da classe 1 as 12h UTC

Coluna V: Número de dias da classe 1 as 18h UTC

Figura 22 - Gráficos dos índices mensais de dias claros por sub-regiões



Um exemplo da utilização dos índices da Tabela 12 em conjunto com o mapa da Figura 21 é dado a seguir. Deseja-se saber qual a quantidade de dias claros no mês de Outubro na cidade de Garanhuns (PE). Basta procurar no mapa para ver que essa cidade se encontra na sub-região 4. Sob o nome da cidade encontram-se dois números separados pela letra M, cujo significado é explicado em 4.2.1.3. Anota-se o número a esquerda, que é a média geral anual, igual a 4,1 dias claros. Em seguida, entra-se na Tabela 12 pela coluna, com o mês de Outubro, e pela linha da sub-região 4 encontrando-se o índice 1,8. Esse índice multiplicado pela média ($1,8 \times 4,1$) fornece a quantidade esperada de ocorrência de 7,4 dias claros em Outubro para Garanhuns.

Tabela 12 - Tabela de Índices mensais de ocorrência de dias claros por Sub-região para uso em conjunto com o mapa da Figura 21.

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
Sub região 1	0,5	0,4	0,5	0,5	1,0	1,1	1,3	1,6	1,9	1,5	0,9	0,8
Sub região 2	0,7	0,7	0,9	0,8	0,8	0,8	0,7	1,1	1,5	1,6	1,2	1,3
Sub região 3	0,8	0,8	0,5	0,5	0,8	0,5	0,4	1,1	1,8	2,4	1,4	1,1
Sub região 4	0,8	1,2	0,8	0,6	1,3	0,6	0,3	0,4	1,4	1,8	1,3	2,0
Sub região 5	0,5	0,4	0,5	0,7	0,9	0,9	0,7	1,2	1,9	1,8	0,8	1,3
Sub região 6	1,2	0,8	0,7	0,5	1,0	0,8	1,1	1,4	1,4	1,7	0,6	1,2
Sub região 7	0,7	1,6	1,8	1,2	2,1	1,9	0,3	0,3	0,9	0,6	0,4	0,4

4.2.1.3 Inclusão no mapa do turno com mais céu claro

O mapa de céu claro e a sua tabela foram elaborados inicialmente com a média dos dois turnos de observação 12h UTC (manhã) e 18h UTC (tarde) das classes 1, 2 e 3. Porém os dados já processados e existentes permitem que sejam acrescentadas mais duas informações úteis no mapa:

- Os gráficos das classes 1, 2, 3 (Anexo 4), mostram que existem estações com maior incidência de céu claro num ou noutro turno. Essa informação foi acrescida no mapa, ao lado do valor da MGA, usando-se a letra “M” quando ocorre mais céu claro pela manhã e “T” quando ocorre mais a tarde;
- em seguida à letra “M” ou “T”, foi colocada a maior média geral anual da classe 1, de acordo com a indicação das letras. A média geral anual da classe 1 para as 12 e 18h estão nas colunas a direita da Tabela 11, com o valor maior realçado em negrito.

As novas informações inclusas no mapa dão mais uma opção ao planejador. Usar o primeiro valor, que é mais otimista, porque representa uma média das classes 1, 2 e 3 das observações das 12 e 18h. Usar o segundo valor, que é menor e mais rigoroso, porém reflete melhor as estatísticas observadas em campo das ocorrências até 10% de nuvens, segundo o turno manhã ou tarde.

Refazendo o exemplo visto anteriormente para Garanhuns para o mesmo mês de outubro, usando apenas a classe 1, a média anual que era de 4,1 baixa para 1,7 dias, no turno da manhã segundo indica a letra “M”. O índice encontrado 1,8; multiplicado pela média de 1,7 fornece o novo valor, mais pessimista, de 3,1 dias claros no mês de Outubro para Garanhuns.

Não se sabe realmente quanto tempo o céu permanece claro em cada dia obtido com essa metodologia, mas na região dificilmente o céu fica aberto o dia todo. Uma tentativa para estimar esta quantidade em horas será feita no Capítulo 7.

O tipo de mapa produzido, apresenta as vantagens já comentadas em relação aos outros disponíveis no Brasil, e permitiu identificar as sub-regiões com índices muito baixos de ocorrência de céu claro (como a 4, 6 e 7), o que não havia sido devidamente quantificado anteriormente através de estatísticas específicas.

A metodologia que produziu o mapa para uma parte do Nordeste pode ser empregada para gerar um mapa atualizado de céu claro de todo o Brasil, que seria de grande utilidade para o planejamento de levantamentos fotogramétricos e que indicaria com precisão as outras áreas de nebulosidade constante e excessiva das outras regiões do país. Essa tarefa implica na manipulação de uma grande massa de dados que necessita de muitos recursos em pessoal e equipamentos, uma vez que para definir melhor as regiões homogêneas, torna-se necessário utilizar informações do máximo número possível de estações. Para se ter confiabilidade estatística, por outro lado, necessita-se de um período mínimo de dez anos de observações. Além de tudo, o INMET cobra pelos dados, e consegui-los gratuitamente como para essa pesquisa, é muito difícil.

5. PROCESSAMENTO DOS DADOS ISCCP

O processamento dos dados fornecidos pelo ISCCP tem o objetivo de retirar informações espaciais e temporais de ocorrências de céu claro que sejam úteis para o planejamento de vôos fotogramétricos e condensar essas informações na forma de mapas, como foi feito com os dados de observação de superfície.

Para a manipulação e geração de estatísticas, gráficos e imagens, foi necessário o uso de vários programas auxiliares preparados em linguagem FORTRAN 77 e Turbo Pascal, além de programas comerciais e científicos para interpolação, edição de imagens e classificação. O processamento foi realizado inicialmente compondo matrizes com a contagem dos pixels claros. Em seguida foram criadas imagens similares a imagens multi-canais, que puderam ser classificadas com o método de isodata. O resultado final é um mapa com a classificação das áreas homogêneas quanto à variação da nebulosidade durante o ano.

5.1 Tratamento dos dados do ISCCP

Os arquivos originais fornecidos pelo ISCCP formam um volume muito grande porque trazem os dados de imagens completas de satélite em oito horários diferentes. No caso dessa pesquisa, contudo, o volume original é sensivelmente reduzido pois é extraída apenas a área de estudo, que cobre pequena parte da imagem e dos oito horários, apenas três são usados.

5.1.1 Arquivos de dados parciais reduzidos

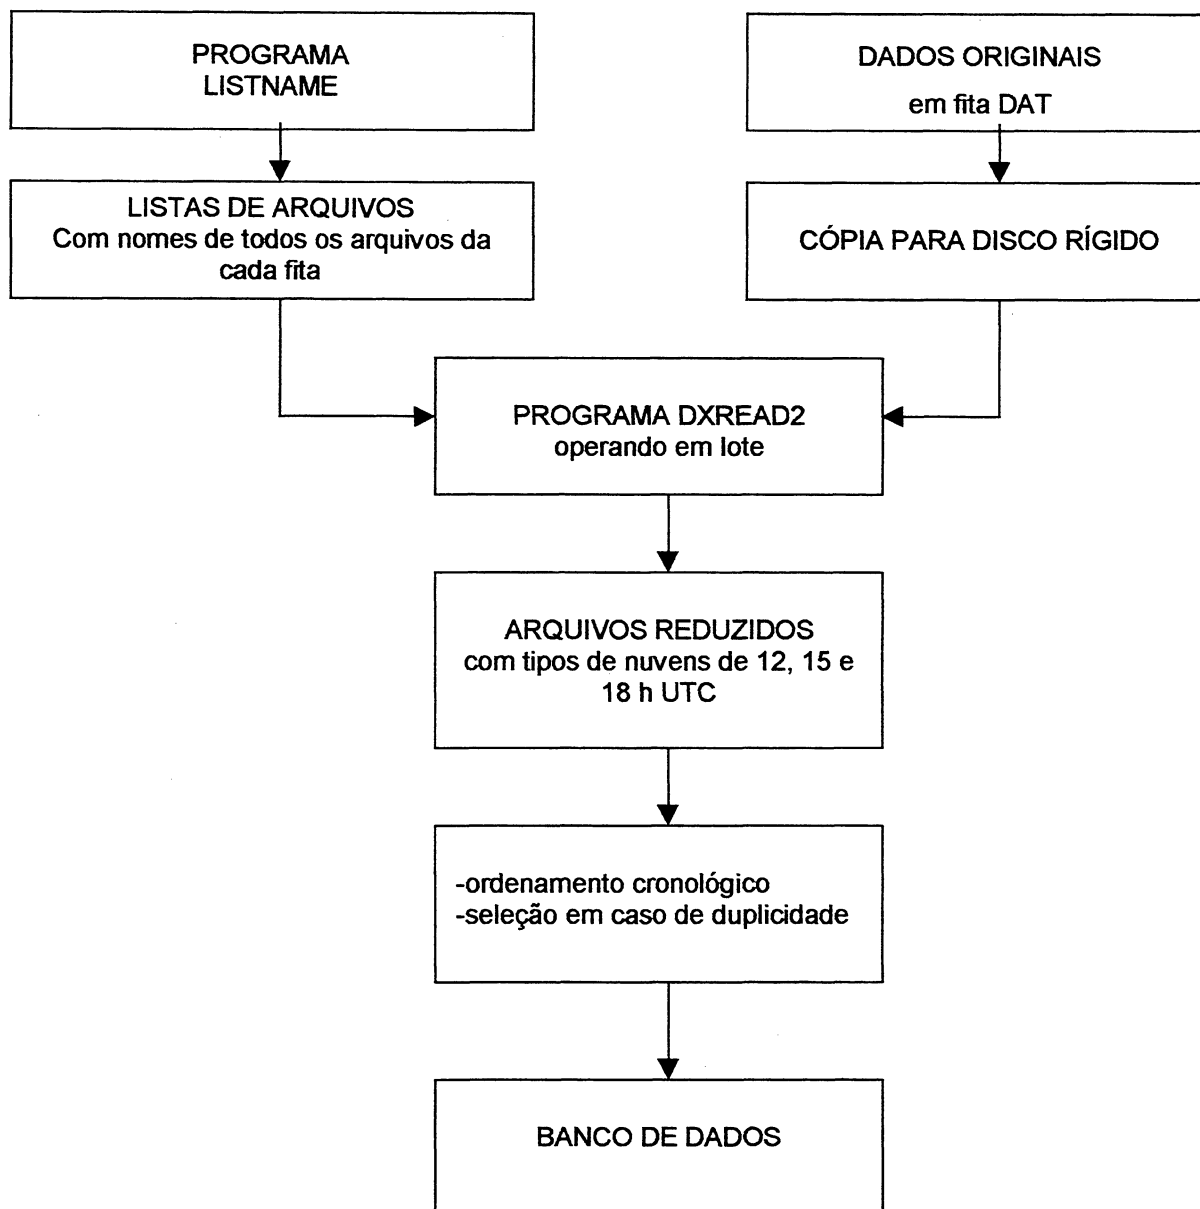
O volume de dados, em cada fita DAT, é em torno de 1,6Gb, mas após leitura e extração da parte que interessa, fica reduzido a cerca de 2,5 Mb. A quantidade de arquivos por fita original varia de 300 a 330. Todas as fitas foram

copiadas para plataforma computacional UNIX e em seguida os arquivos foram processados. Todo o processo de cópia e extração teve que ser planejado, devido ao problema de tempo, cerca de uma hora por fita, e de espaço de armazenamento disponível no computador utilizado. Da cópia eram retirados apenas os dados de interesse, usando a versão adaptada do programa DXREAD. Em seguida os arquivos reduzidos em formato texto eram transferidos para computador tipo PC, para ordenamento por mês e ano, com a finalidade de facilitar os processamentos posteriores.

O fluxograma mostrando os programas e as etapas, da leitura à extração dos arquivos reduzidos, encontra-se na Figura 23.

O programa DXREAD original, fornecido pelo ISCCP, lê os arquivos um a um, o que seria impraticável operacionalmente. Para contornar o problema, foi criada a versão chamada de DXREAD2, que abre e processa vários arquivos de forma contínua ou em lote. Também foi elaborado o programa auxiliar LISTNAME.PAS destinado a criar arquivos com listas de nomes apenas dos arquivos que interessam, dos três horários 12, 15 e 18 h UTC. As listas são criadas para cada uma das fitas DAT que foram copiadas em disco rígido em ambiente UNIX. O programa DXREAD2 lê o arquivo com a lista, abre os arquivos originais DX um após o outro, processa, extrai os dados solicitados e grava os arquivos de saída. Dessa maneira, são processados todos os arquivos de cada diretório.

Figura 23 - Fluxograma de retirada dos dados referentes à área de estudos dos arquivos do ISCCP



A Figura 24 mostra um trecho do arquivo de saída em formato tipo texto. A primeira linha é um cabeçalho com o ano, mês, dia, hora UTC, código de identificação do satélite, tipo do satélite, número de canais e chave dia-noite (noite=1, dia =0). Nas linhas seguintes, a primeira coluna é de longitudes, a segunda latitudes, ambas no formato das coordenadas adotada pelo ISCCP

(capítulo 2), e a terceira corresponde ao gênero de nuvem, segundo a codificação da Tabela 13 para os tipos líquida e sólida (gelo). O código zero indica céu claro.

As modificações e os parâmetros introduzidas no programa DXREAD2 foram:

- delimitação em latitudes e longitudes máximas e mínimas da área de estudo;
- saída apenas dos dados referentes aos pixels sobre o continente, desprezando os pixels sobre o oceano;
- introdução de procedimento de identificação do gênero de nuvem, segundo os limiares estabelecidos em ROSSOW ET AL (1996), mas com a codificação entre o tipo líquida e gelo diferente da tabela original, conforme mostrados na tabela 13. Os dados originais já informam diretamente se o pixel é claro ou nublado.

Tabela 13 - Parâmetros físicos para definição do tipo de nuvem

NÍVEL E GÊNERO DA NUVEM		PRESSÃO mb	OPACIDADE	CODIFICAÇÃO	
				LÍQUIDA	GELO
BAIXO	Cumulus	>680	≤3,55	1	7
	Stratocumulos	>680	3,55 a 22,63	2	8
	Stratus	>680	>22,63	3	9
MÉDIO	Alto cumulos	440-680	≤3,55	4	10
	Altostratus	440-680	3,55 a 22,63	5	11
	Ninbostratus	440-680	>22,63	6	12
ALTO	Cirrus	≤440	≤3,55		13
	Cirrustratus	≤440	3,55 a 22,63		14
	Convectivas	≤440	>22,63		15

Fonte: Rossow et al. (1996)

Figura 24 - Trecho do arquivo com dados reduzidos gerado pelo programa DXREAD2.

	1983	7	1	12	41	0	3	0
3160	770	1						
3165	770	0						
3169	770	0						
3173	770	0						
3177	770	0						
3181	771	0						
3185	771	2						
3189	771	2						
3193	771	2						
3196	771	0						
3200	771	0						
3204	771	0						
3208	771	0						
3211	771	0						
3161	773	0						
3165	773	0						
3169	773	0						
3173	773	0						
3177	773	13						
3181	773	1						
3185	773	2						

5.1.2 Visualização dos dados

Os arquivos com os dados mesmo reduzidos são muitos, cerca de 10.000, e para serem analisados devem estar numa forma conveniente tanto para a visualização como para fornecerem parâmetros estatísticos, no mínimo, mensais.

A solução encontrada para satisfazer as duas necessidades ao mesmo tempo equivale a um mapa digital, onde as coordenadas dos pontos são as latitudes e longitudes dos pixels e as alturas são o resultado da contagem de dias claros. As alturas fornecem os tons de cinza na imagem e os valores para os cálculos estatísticos. Esta solução foi adotada também por REINKE ET AL. (1992) para resolver problema similar.

As estatísticas para o período de um mês é uma composição obtida somando arquivo a arquivo, numa matriz com dimensões que cobre toda a área de estudos em latitude e longitude. A matriz é preenchida com a contagem apenas dos pixels que têm código 0 (céu sem nuvem) de todos os dias e horários (12, 15 e 18h UTC). Isto é facilitado porque as posições dos pixels amostrados, no sistema de processamento do ISCCP (Figura 10), coincidem quase que totalmente dentro de cada mês. A leitura, contagem dos pixels de céu claro e preparação do arquivo de saída, chamado de CONTORNO.DAT, é feita com o programa MAPMES.PAS, que opera em lote, diretório por diretório.

As dimensões da matriz de contagem devem contemplar todas as posições dos pixels da área de interesse e só foram definidas após ser resolvido o problema da não uniformidade de amostragem dos dados ISCCP. As posições dos pixels dos arquivos de entrada não é uniforme em espaçamentos de 30km, em latitudes e longitudes no sistema de coordenadas do ISCCP. Esta distância de 30km equivale grosseiramente a três décimos de grau. Dessa forma, a numeração dos pixels deveria variar de três em três unidades inteiras, mas varia na verdade de duas a quatro unidades, tanto em latitudes como em longitudes. A solução foi criar uma matriz com variação de unidades de uma em uma, garantindo que qualquer pixel tenha uma posição certa e determinada, e deixando os espaços intermediários em branco. A matriz foi então definida com linhas de 770 a 880 e colunas de 3160 a 3260, correspondentes a latitudes e longitudes, respectivamente.

A contagem efetuada pelo programa MAPMES incrementa apenas as posições da matriz cujos dados têm código Zero (céu claro). A Figura 25 mostra uma imagem formada com uma destas matrizes, onde os pontos com vários tons de cinza indicam a variação da contagem, sendo que os pontos mais claros indicam maior número, isto é, mais ocorrência de céu claro. As matrizes geradas para um mês, nas quais são acumuladas as contagens dos três horários, podem ter no máximo 93 ocorrências (3 x 31) em uma posição.

Nota-se claramente nessas imagens que as tonalidades dos pontos não varia brusca ou aleatoriamente, mas de forma bastante contínua. Com essa característica as imagens, que correspondem à matrizes com estatísticas mensais, podem sofrer processos de interpolação para o preenchimento das posições intermediárias em branco, e podem ser comparadas entre si. A seção a seguir trata do processo de interpolação.

Figura 25 - Exemplo de imagem resultante da contagem de pixels de céu claro de março de 1993



5.1.3 Interpolação dos dados

As imagens formadas com as contagens de ocorrência de céu claro, dos arquivos CONTORNO.DAT, como na Figura 25, não são ainda convenientes para estudos, análises estatísticas ou comparações. Uma posição que tem informações num mês, pode não ter nos seguintes, ou certas posições de interesse especial, com por exemplo estações do INMET, podem não ter

dados. Existe, portanto, a necessidade de serem obtidos os dados que faltam usando um processo de interpolação.

5.1.3.1 Interpolação com o programa SURFER

Entre os programas comerciais que efetuam interpolações, o Curso de Pós Graduação de Ciências Geodésicas (CPGCG) dispõe do SURFER. Esse programa oferece opções de interpolação com vários métodos, desde os mais simples até o *kriging*, que usa técnicas sofisticadas de geoestatística. Porém o método escolhido, entre os que foram testados, foi o da triangulação com interpolação linear. O método da triangulação é tido como preciso, uma vez que os valores interpolados não extrapolam os valores dos dados originais. Nesse método, a triangulação de Delaunay é usada para formar triângulos o mais equiláteros possíveis. Segundo o manual do programa o algoritmo adotado é de (LEE & SCHACHTER, 1980). Cada triângulo é tratado como uma superfície plana. A fórmula usada para cada face do triângulo, com coordenadas num sistema cartesiano é:

$$Z = a + bX + cY \quad (19)$$

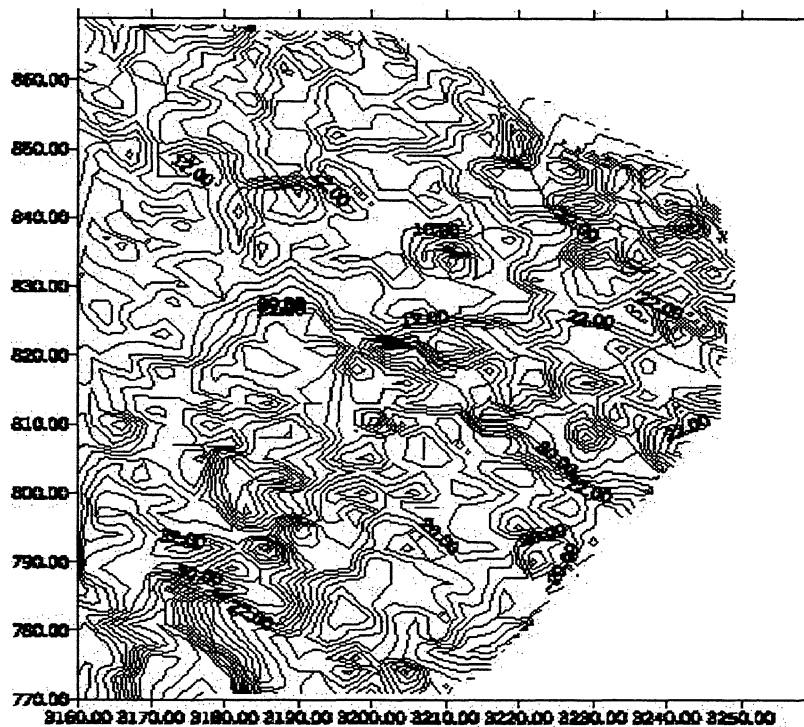
sendo a, b e c coeficientes ;

X, Y e Z coordenadas de cada vértice.

Os coeficientes a, b, e c são resolvidos por um sistema de três equações, formadas com os três vértices, no qual se conhecem X, Y e Z. A equação de cada face é determinada exatamente pelos valores de seus atributos nos três vértices, como por exemplo a altura. No presente caso, Z é um número inteiro que indica a quantidade de pixels claros, X e Y são as coordenadas geográficas. Depois que toda a superfície está formada pelo mosaico de triângulos, a altura de um novo ponto pode ser calculada com (19).

A Figura 26 mostra duas imagens resultantes da interpolação com o método da triangulação com o programa SURFER, com isolinhas e com níveis de cinza.

Figura 26 - Exemplos do resultado de interpolações da contagem de pixels claros com o programa SURFER.



5.1.3.2 Dimensões da imagem interpolada

A matriz com os dados reduzidos retirados dos arquivos originais DX, tem dimensões de 111 linhas x 101 colunas. Devido à limitação do programa SURFER, que interpola no máximo matrizes de 100 x 100, os limites foram reduzidos para 770 a 869 e 3160 a 3259 em latitude e longitude respectivamente, sem que essa redução da área implique em perdas importantes.

O SURFER gera como resultado da interpolação, um outro arquivo com terminação .GRD, que é utilizado pelas outras ferramentas que o programa dispõe, como gerar isolinhas e sombreamento, e que também será usado como o arquivo básico para todas as etapas de processamento dessa pesquisa. Para todos os meses com dados do ISCCP (Tabela 9) foram criados arquivos com o nome CONTORNO.GRD.

5.1.4 Composição das imagens multicanais

A solução para trabalhar com a grande quantidade de arquivos contendo dados estatísticos foi compor imagens de cada mês e em seguida juntá-las por ano, formando uma verdadeira imagem multicanal. A seguir, serão dados detalhes sobre o desenvolvimento desta solução.

O próprio SURFER pode exportar as imagens que cria na interpolação no formato TIFF, com o tamanho desejado. A imagem sofre para isso um escalonamento dos valores interpolados, que ajusta os tons de cinza a uma visualização ótima na tela do computador. No início das pesquisas, foram geradas imagens TIFF para todos os meses de um ano e comparadas uma a uma. Com ou sem as isolinhas, todas elas demonstravam semelhança com mapas de relevo ou com fotografias de terreno. A Figura 27 mostra as doze imagens referentes ao ano 1988.

A experiência anterior com o tratamento dos dados de observações de superfície apresentadas no Capítulo 4, mostrou que as estatísticas de cobertura de nuvens variam gradualmente ao longo do ano, e mudam entre as regiões. Por outro lado as doze imagens da Figura 27 também sugerem isso. Este comportamento pode ser comparado a uma imagem multiespectral, em que as áreas com solo limpo, floresta ou culturas aparecem com tons diferentes em cada canal.

Foram realizadas as primeiras tentativas de trabalhar com as imagens TIFF, como se fossem imagens multiespectrais, usando o programa MULTSPEC, desenvolvido pela Universidade de Purdue nos EUA e distribuído pela Internet via URL: <http://dynamo.ecn.purdue.edu/~biehl/MultiSpec/>. Após constatado que isso era perfeitamente possível, foram feitas tentativas de classificação usando o cálculo de componentes principais, considerando que cada mês correspondia a uma variável (ou a uma banda de uma imagem multiespectral). As componentes principais obtidas mostravam que apenas as três primeiras teriam as informações de 98% dos dados, indicando que a variabilidade pode ser representada por apenas três componentes principais, ou seja,

$$Y_1 = \underline{C}_1 X$$

$$Y_2 = \underline{C}_2 X \Rightarrow 98\%$$

$$Y_3 = \underline{C}_3 X$$

Assim, se ao invés de doze variáveis tivermos apenas três, fica mais simples analisá-las, desde que sejam interpretadas. Realmente percebe-se que os meses de Junho a Setembro são muito semelhantes, e que existem áreas que não tem variação significativa entre as imagens, como a parte mais escura comum na metade inferior de cada imagem mensal da figura 27.

O método de trabalhar com imagens multiespectrais mostrou-se viável, mas foi necessário alterar o formato das imagens de TIFF para RAW e também

verificou-se que o processo de classificação por agrupamento dava melhores resultados.

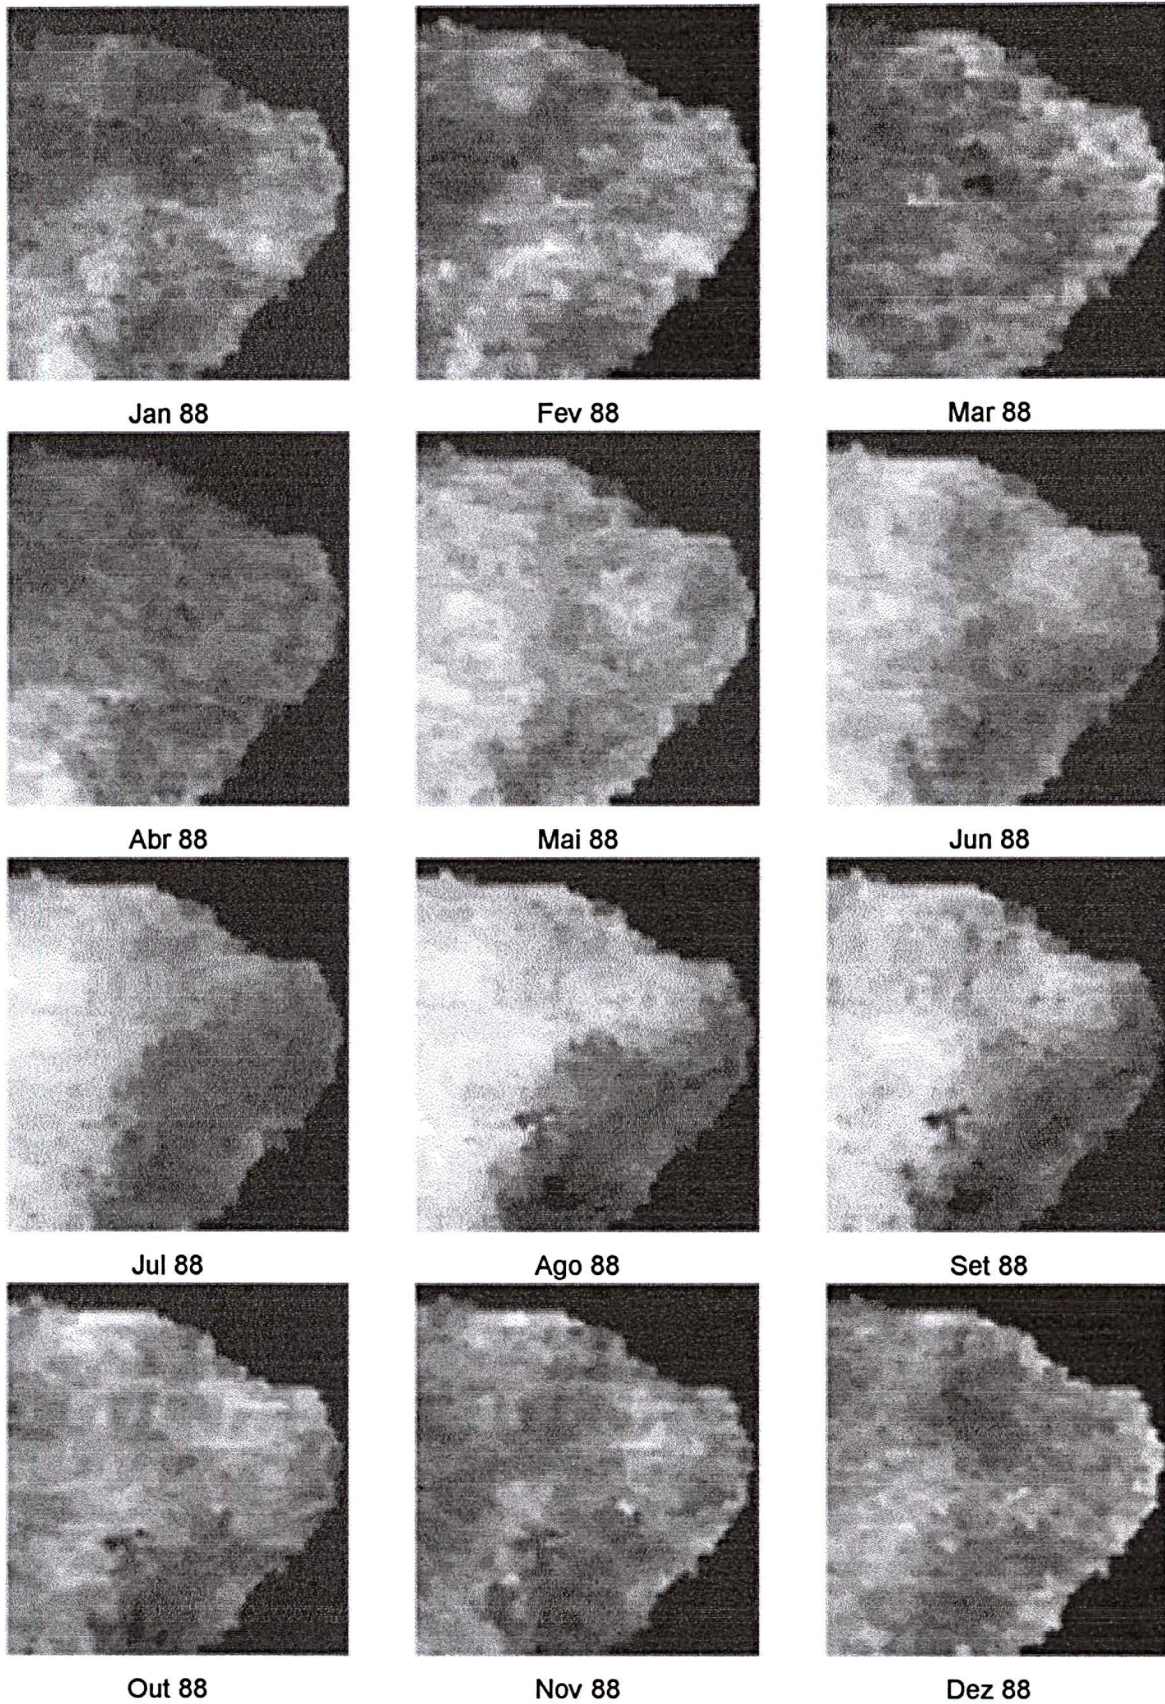
5.1.4.1 Transformação de arquivos interpolados em imagens no formato RAW

As imagens TIFF geradas diretamente pelo SURFER não podem ser usadas para análises estatísticas devido ao seu escalonamento de tons de cinza, que altera completamente cada imagem de forma diferente. A solução mais segura é trabalhar com o arquivo original resultante da interpolação, de terminação .GRD, e convertê-lo diretamente para imagens em tons de cinza mantendo ao máximo a integridade dos dados.

Para essa finalidade foi elaborado o programa CONVMAP que usa os arquivos .GRD gerados pelo SURFER e cria uma imagem binária no formato .RAW que é o mais simples dos formatos de imagens digitais . O valor de cada ponto, que em função da interpolação é um número decimal, é arredondado para um número inteiro, que tem valor máximo igual a 93 (máximo de arquivos existentes num mês). Esse valor está dentro da faixa de níveis de cinza de 0 a 255 das imagens de oito *bits* por pixel.

Para cada mês com dados do ISCCP foi gerada uma imagem no formato RAW, que passa a ser o elemento básico a ser usado nas etapas seguintes de processamento dos dados do ISCCP.

Figura 27 - Imagens no formato TIFF dos 12 meses de 1988



5.1.5 Obtenção de assinaturas de pixels

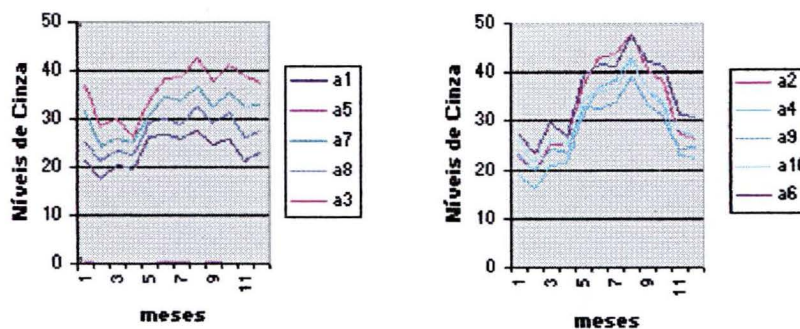
O conjunto das doze imagens com estatísticas de cada ano, que formam uma imagem multicanal no MULTSPEC mostrou, desde o início dos testes, que pode ser manipulado de forma similar a qualquer conjunto de imagens de satélites como o LANDSAT ou SPOT. Igualmente, também é possível obter os histogramas da distribuição dos tons de cinza de toda a imagem, ou a curva com os valores de um pixel de posição determinada nos vários canais. Essa curva é semelhante à assinatura espectral de elementos da paisagem, como tipos de vegetação ou solo, nas imagens de satélites imageadores. Assim, aqui, por similaridade, será chamada de assinatura do pixel.

Nesta pesquisa, o interesse é poder analisar os pixels em posições especiais como aquelas correspondentes às coordenadas das estações do INMET, para comparar as estatísticas mensais da classe 1 (céu claro) com as contagens obtidas nas imagens.

A obtenção da assinatura de pixels no MULTSPEC não é muito prática, porque é necessário entrar com muitos parâmetros até ela ser visualizada em forma de gráfico. A opção melhor foi criar o programa HISTOARQ. Esse programa abre todas as imagens necessárias e retira as informações de todas as posições procuradas. Dessa forma, as assinaturas podem ser obtidos rapidamente. O programa HISTOARQ é útil tanto para as comparações das assinaturas dos pixels equivalentes às posições das estações do INMET, como para a checagem dos resultados das classificações.

A Figura 28 mostra exemplos das assinaturas de alguns pixels e como são semelhantes com as assinaturas de qualquer objeto em imagens do LANDSAT.

Figura 28 - Assinatura de pixel da imagem multicanal, formada com as contagens mensais de céu claro



5.2 Classificação de áreas homogêneas de céu claro

Os conjuntos de imagens classificadas nas primeiras tentativas e as assinaturas dos pixels mostraram a real possibilidade de se conseguir uma separação da área de estudos em zonas que tivessem características comuns, em termos das estatísticas da ocorrência de céu claro, ou obter um mapa contendo a classificação de zonas homogêneas.

5.2.1 Método de Classificação com o Isodata

A técnica de classificação a ser usada com as imagens estatísticas teria de ser necessariamente do tipo não supervisionado, por não haver possibilidade de verificar em campo os resultados alcançados. O método apropriado para o tipo de dado em questão, e também correntemente usado no tratamento das imagens tradicionais, é a técnica do agrupamento que, dependendo da disciplina, tem outros nomes: Análise-Q, Tipologia, Análise

Classificatória ou Taxonomia. A classificação por agrupamento nos programas de tratamento de imagens e no MULTSPEC tem o nome de Isodata.

O MULTSPEC é usado inicialmente para reformatar as imagens binárias em formato RAW de cada mês e criar uma imagem com doze canais (ou bandas). Com essa imagem multicanal escolhe-se a opção de agrupamento (cluster) e entra-se com os parâmetros solicitados. O programa efetua os cálculos rapidamente, gera arquivos com várias estatísticas dos grupos de pixels classificados e o mapa com a classificação. A quantidade final de classes depende dos parâmetros de entrada, e sua redução a um mínimo ótimo depende de muitos testes, experiência e análise das estatísticas produzidas. O método de isodata calcula a média de classes distribuídas uniformemente no espaço dos dados e iterativamente junta os pixels restantes, usando critérios de distâncias mínimas. Em cada iteração, recalcula as médias e reclassifica os pixels com relação às novas médias. Este processo continua até que um número de pixels em cada classe mude menos que o limiar preestabelecido, ou quando atinge o número máximo de iterações.

Todos os detalhes sobre o uso do programa estão no seu manual (MULTSPEC,1995). Sobre os algoritmos de isodata pode-se consultar HAIR ET AL. (1984), RICHARDS (1993) e a literatura sobre técnicas de classificação não supervisionada de imagens.

5.2.2 Testes de resultados da classificação

O processo de classificação usando-se a técnica do agrupamento é sensível ao algoritmo utilizado pelo programa e aos parâmetros de entrada, e dão resultados bem diferentes. Esse problema é conhecido e comentado na literatura relativa ao assunto (HAIR ET AL., 1984) e não dá segurança ao pesquisador se o que obteve numa classificação tem validade. No caso dessa pesquisa de nebulosidade, não se dispõe de outros dados independentes e de

melhor resolução espacial e temporal para comparação. Os primeiros resultados eram tão variáveis que foram feitos testes também com o programa comercial ENVI, que tem alguns recursos diferentes do MULTSPEC, mas os resultados obtidos não foram melhores. Cada ano analisado mostrava distribuições diferentes dos grupos, com exceção das classificações com apenas três classes: uma correspondia ao oceano e duas ao continente. Nesse caso, a grande maioria das imagens tinha uma semelhança de forma. Duas classes, apenas, é muito pouco para representar a complexidade de nebulosidade da região.

A única forma encontrada de testar os resultados das classificações, foi a comparação visual das assinaturas dos pixels, dentro de cada área classificada. Em algumas classes, havia boa coincidência de formato, em outras, não. Por exemplo, as assinaturas dos pixels mais ao norte tinham muita diferença dos situados mais ao sul. Isso é motivado pelo algoritmo que escolhe os primeiros vetores de pixels (as sementes) para iniciar o processo de agrupamento no topo da imagem e com eles calcula as médias iniciais. À medida que vai introduzindo os outros pixels vizinhos, vai calculando novos valores médios que substituem os anteriores. No decorrer do processo, pixels que têm uma assinatura de forma diferente acabam eventualmente sendo classificados como semelhantes.

De modo geral, o método de agrupamento aplicado às imagens de cada ano individualmente não dá uma classificação satisfatória. Uma explicação possível para o problema é que o método é aplicado normalmente à quatro ou cinco bandas, e nesse caso foram usadas doze.

5.2.3 Classificação de imagem de médias mensais

Foram realizados muitos testes, até que se chegou a conclusão que o método de agrupamento aplicado às imagens de cada ano individualmente não davam uma classificação satisfatória.

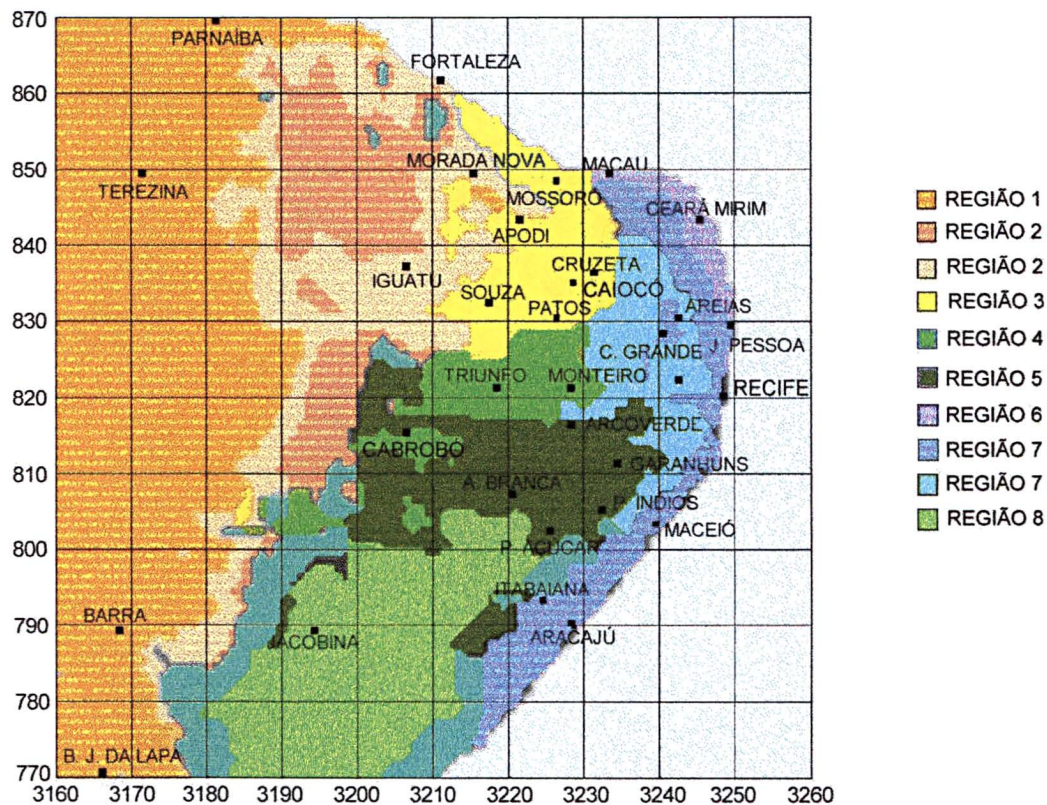
A opção seguinte foi gerar uma imagem média de cada mês, de Janeiro a Dezembro. Cada imagem foi formada com a soma de todas as imagens do mesmo mês e dividido pelo número de meses disponíveis. Este procedimento também permitiu que dados dos meses que estavam de fora dos processamentos anteriores, porque não completavam um ano inteiro, fossem utilizados.

Com a imagem multicanal das médias mensais foi possível obter uma classificação em que os testes de comparação das assinaturas dos pixels comprovaram sua consistência. Mesmo assim, foram feitos outros testes de comparação de assinaturas de pixels, usando assinaturas separadas de duas outras imagem multicanal uma de dados das 12h e outra das 18h. Esses últimos testes de assinaturas quando mostravam tendências diferentes definiam a divisão da classe em duas. Esta subdivisão também torna o resultado da classificação mais próxima das estatísticas dos dados OS.

O resultado final, que está na Figura 29, tem nove classes. As classes de 1 a 5 apresentam número maior de dias claros e as de 6 a 9 são as áreas mais nubladas. Essa grande separação em dois grupos coincide com os resultados preliminares das classificações ano a ano, com a vantagem de os limites terem ficado bem mais estáveis e definidos.

Vale lembrar que o resultado da classificação é válido para imagens compostas pela soma das ocorrências médias dos três horários. Por esse motivo, quando eram comparadas as assinaturas de vários pixels, de mesma região homogênea, das imagens formadas apenas com os horários das 12 e 18h separadamente (idênticos aos horários das OS) alguns apresentavam tendências diferentes.

Figura 29 - Mapa com a classificação das áreas homogêneas de ocorrência de céu claro obtido a partir de dados ISCCP



5.3 Resultados obtidos

Os resultados obtidos com a metodologia desenvolvida para tratar os dados ISCCP permitem algumas considerações e conclusões preliminares:

- os dados ISCCP mostraram-se consistentes e podem ajudar a definir melhor os limites das zonas climatológicas homogêneas e, relação a nebulosidade, obtidas com dados OS;
- a composição de matrizes com a contagem de ocorrências de céu claro (pixel claro) mostrou-se útil e eficiente para a redução do volume de dados a serem manipulados;

- a manipulação das matrizes de contagens mensais como se fossem equivalentes a bandas de imagens multicanais mostrou-se muito útil;
- apesar do algoritmo de isodata do MULTSPEC chegar a um resultado satisfatório, quando foram usadas as imagens das médias mensais, é necessário testar outros, para esse tipo de dado e com doze bandas, até encontrar aquele que dê resultados mais estáveis em menor número de tentativas.
- como desvantagens foi observado ao longo da pesquisa que é difícil identificar áreas de nebulosidade excessiva com diâmetro da ordem de grandeza de 30km (tamanho nominal do pixel no terreno), em imagens isoladas de um mês ou ano. Só foi possível detectar a área de Campina Grande e Areias, classificando todas as imagens com o método do isodata. Os erros de georreferenciamento, e a amostragem em posições diferentes entre meses seguidos devem contribuir para isso.
- os erros máximos encontrados na definição do litoral (2 pixels) e na barragem de Sobradinho (4 pixels), mostram que é conveniente encontrar uma forma de registro e de correção de posições dos dados DX para aplicações fotogramétricas.

O mapa classificado da Figura 29 mostra as zonas homogêneas de nebulosidade, mas para seu emprego em fotogrametria é necessário que sejam definidas as freqüência das classes de coberturas válidas para uma área de abrangência, da mesma forma que dados da OS. As estatísticas de pixels de céu claro, como discutido antes, são uma amostragem de um pixel da imagem original do satélite METEOSAT de 5km que passa a representar nominalmente 30 km. Essa amostragem não preserva as informações sobre a nebulosidade real. Podem ser obtidas as freqüências calculando-se o percentual de pixels claros em relação aos nublados existentes numa área de

dimensões conhecidas, mas estes cálculos não foram efetuados nesta fase da pesquisa.

O mapa apresentado na Figura 29, portanto, necessita de informações auxiliares que podem ser obtidos com o cruzamento de dados com as observações de superfície para que se torne de utilidade para a fotogrametria. O Capítulo 6 destina-se a discussão e análise da comparação de dados de céu claro de OS e DX.

6. COMPARAÇÕES ENTRE OS DADOS OS E DX

Os dados OS e DX têm características próprias e apresentam estatísticas diferentes quando comparadas diretamente, embora devam fornecer o mesmo tipo de informação: a frequência das classes de cobertura de nuvens em determinada área.

Por outro lado, se possível, é útil converter um tipo de dado para o outro, para tirar vantagem de características favoráveis à obtenção de estatísticas melhores para aplicações fotogramétricas. Os dados OS têm mais classes de cobertura (10) e os dados DX apenas duas. Mas os dados DX têm mais horários de observação que os dados OS e podem indicar melhor os limites de regiões climatológicas homogêneas.

Este capítulo mostra as comparações das estatísticas entre os dados OS e DX, a possibilidade de conversão usando a regressão linear e um método de estimar as classe 1, 2 e 3 a partir de dados DX.

6.1 Comparação das curvas de frequência de céu claro

Os dados OS podem gerar gráficos do comportamento de cada uma das dez classes ao longo do ano, enquanto os DX só permitem o comportamento de céu claro ou nublado. Para realizar uma comparação direta, só é possível comparar a classe 1, ou de céu claro, comum a ambos nas posições de cada estação do INMET. Para cada estação já existe o gráfico com as classe 1, 2 e 3 no Anexo 4. Para os dados DX isto foi feito com o auxílio do programa preparado em Turbo Pascal chamado de HISTOARQ.PAS. Entrando-se com as coordenadas geográficas conhecidas das estações, o programa retira do mapa de dados DX a contagem de observações claras mês a mês, da mesma forma que foram obtidas as assinaturas dos pixels em 5.1.5.

A Figura 30 mostra as curvas de dados OS e DX para os horários das 12h e 18h nas estações de Teresina e Areia. Pode-se perceber nesse exemplo que a estação Teresina exibe uma semelhança muito grande entre as curvas enquanto na estação Areia as curvas são bem diferentes. Os gráficos de todas as estações de superfície, inclusive aquelas com dados reduzidos, estão no anexo 5.

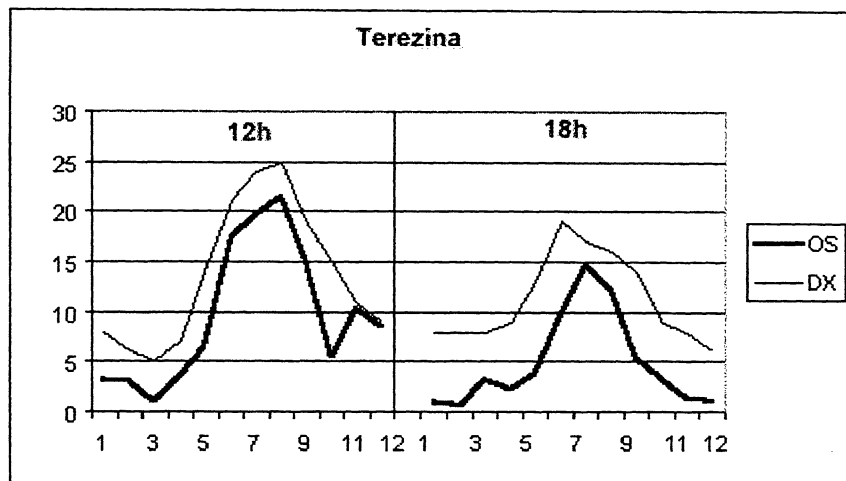
É bom lembrar que as ocorrências de OS são em percentual e os DX são a média da contagem de pixels claros em unidade inteiras, mas a conversão é fácil de ser feita como será mostrado a seguir.

6.1.1 Comparação em número absoluto de dias claros

Os dados dos gráficos da figura 30 estão em unidades diferentes. Para converter os percentuais de OS em unidades inteiras absolutas do DX, basta aplicar o percentual na quantidade de dias de cada mês. A Tabela 14 mostra a quantidade de observações de céu claro para as estações de Triunfo e Campina Grande. O número de ocorrências de céu claro com dados DX é sempre maior que com dados OS. Essa diferença é explicada pelo processo de amostragem dos dados originais DX. Um pixel da imagem do METEOSAT com 5km, amostrado a cada 30km, é nublado se coincide totalmente com uma nuvem ou mesmo se estiver contaminado por uma nuvem menor, mas no caso contrário, de céu claro, toda a área pode estar realmente livre de nuvens ou houve coincidência com o espaçamento entre as nuvens. Imaginando isto sobre a imagem do LANDSAT (Figura 13), é fácil perceber como uma região, considerada nublada pelo observador de superfície, tem muitos pontos com céu claro na imagem de dados DX.

Figura 30 - Gráficos de comparação de comportamento mensal de dados OS e DX em Teresina e Areia

a) Teresina



b) Areia




Tabela 14 - Exemplo ocorrências de céu claro, em números absolutos, com dados Os e DX para o mês de outubro às 12h UTC em Triunfo e Campina Grande.

Estação	Dado OS	Dado DX
Triunfo	12	18
Campina Grande	0	6

6.2 Estudo das correlações e regressões entre dados OS e DX

A simples análise visual dos gráficos de curvas conjuntas OS e DX, como mostradas na Figura 30 e no anexo 5, não permitem assegurar o quanto uma curva tem de semelhança com a outra. Nos casos em que existe uma semelhança estatisticamente significativa, é útil e possível passar de um dado para o outro, usando o cálculo das correlações e regressões.

O programa usado para essas análises foi o STATGRAPHICS. A entrada dos dados é feita facilmente em formato texto, por colunas. O programa pode efetuar a regressão com modelos linear ou polinomiais. Mas em todos os testes o linear foi considerado estatisticamente adequado, de acordo com as análises realizadas pelo próprio programa, e como o polinomial só eventualmente dava melhores resultados optou-se pelo primeiro. Os dados DX entram em valores absolutos como a variável independente X e os dados OS, em percentual, representam a variável dependente Y na fórmula:

$$Y = a + bX \quad (20)$$

Com os dados OS foram realizados dois testes: a) usando somente a classe 1 e b) usando a média das classes 1, 2 e 3. Em alguns casos, as estatísticas da regressão davam melhores resultados com a classe 1, mas adotou-se para todas as comparações a média das classe 1, 2 e 3. Foram obtidas com o STATGRAPHICS as equações de regressão para todas as estações do INMET usadas nessa pesquisa. Nos casos de João Pessoa, Recife, Maceió e Campina Grande foram conseguidos melhores resultados com os dados OS disponíveis de MAURÍCIO (1987). Nesse caso foi necessário juntar as classes I e II que equivalem as classes 1, 2 e 3.

A Tabela 15 mostra um exemplo dos resultados fornecidos pelo STATGRAPHICS para a estação Cruzeta, traduzido para o português. O

quadro padrão do programa traz várias estatísticas das quais as que interessam mais diretamente a essa pesquisa são:

- as constantes a e b da fórmula 20, (ponto de interseção e inclinação da linha reta);
- o coeficiente de correlação (CC), também chamada de Correlação Produto Momento de Pearson, é uma estatística que fornece uma medida normalizada e adimensional de uma associação linear entre duas variáveis, que varia de -1 a $+1$. Uma correlação positiva indica que as variáveis variam na mesma direção e uma negativa, que variam em direções opostas. Variáveis independentes devem ter correlação 0;
- o coeficiente de correlação ao quadrado, R^2 , usado como indicador de quanto a variável dependente é explicada pela independente. É dada em percentual;
- o valor-P, uma componente de uma tabela de ANOVA (Análise de Variância) que serve com uma medida de significância.

Esses e os demais parâmetros que aparecem na tabela são definidos e explicados pela opção de Ajuda do programa e também pode ser consultada a literatura a respeito do assunto.

Para a estação de Cruzeta as constantes são $-4,09752$ e $0,97841$; a correlação entre os dados é de $0,897$, o coeficiente de correlação ao quadrado, R^2 é de $80,5\%$. O valor-P igual a 0 indica que há relação estatisticamente significativa entre as variáveis. No anexo 6 constam as tabelas com os resultados para todas as estações do INMET, como fornecido pelo STATGRAPHICS apenas dispostas com duas colunas para otimização de espaço.

O programa, além de fornecer os resultados, também faz a análise dos valores de P, do coeficiente de correlação e de R^2 , segundo os critérios que aparecem em resumo no Quadro 4.

Tabela 15 - Estatísticas obtidas do programa STATGRAPHICS para o ajuste do modelo linear simples entre dados DX e OS da estação Cruzeta

Análise de Regressão do Modelo Linear : $Y = a + b \cdot X$					
Parâmetro	Estimativa	Erro	Estatística T	Valor-P	
Interseção	-4,09752	1,07994	-3,79421	0,0010	
Inclinação	0,978741	0,102542	9,5448	0,0000	
Análise de Variância (ANOVA)					
Fonte	Soma quadrados	Df	Média quadrada	Razão F	Valor-P
Modelo	289,139	1	289,139	91,10	0,0000
Resíduo	69,8219	22	3,17372		
Total (Corr)	358,958	23			
Coeficiente de Correlação = 0,897489					
$R^2 = 80,5487 \%$					
Erro padrão da estimativa = 1,78149					

Quadro 4 - Critérios de análise do programa STATGRAPHICS

Valor P da ANOVA

- <0,01 há relação estatisticamente significativa entre as variáveis a um nível de confiança de 99%
- <0,05 idem, a 95%
- >0,10 não há relação estatisticamente significativa a um nível de confiança de 90%

Coeficiente de Correlação

- < |0,5| relação relativamente fraca entre as variáveis
- |0,5| a |0,9| relação moderadamente forte entre as variáveis
- > |0,9| relação relativamente forte entre as variáveis

Estatística R^2 , Coeficiente de Correlação ao Quadrado

Indica quanto o modelo explica da variabilidade da variável dependente (neste caso o dado OS)

A análise das equações de regressão do anexo 6 mostra que elas variam de estação para estação. Isso implica que, para se conseguir a desejada conversão dos dados, seriam necessárias equações individuais. O ideal é ter uma equação para uma área muito maior, como as regiões homogêneas resultantes do processo de classificação dos dados DX da Figura 29. Isso foi obtido juntando os dados das estações que estão numa mesma região. A Tabela 16 mostra as equações das estações e regiões, copiadas dos quadros de estatísticas do anexo 6.

Os motivos das diferenças existentes entre as estações, mesmo naquelas situadas próximas, necessitam de mais estudos, mas são possivelmente provocados por diferenças das dimensões das áreas de abrangência e erros na coleta dos dados. Os dados OS informam o percentual de cobertura do céu para uma área representativa de 60km de diâmetro, enquanto os dados DX, que correspondem a um pixel original de 5km espaçados nominalmente de 30 km. Os dados OS têm erros devido à avaliação subjetiva do observador sobre a quantidade de nuvem numa abóbada. O dados DX têm erros de posicionamento, de calibração dos algoritmos de detecção de nuvem e de amostragem (o pixel central pode não ser representativo para uma área de 30km x 30km).

6.2.1 Testes de conversão com as equações de regressão

As equações de regressão devem ser úteis para converter os dados DX em probabilidades que possam ser aplicadas em planejamento de vôos fotogramétricos. Esses dados não podem ser usados diretamente na forma em que estão, principalmente porque apresentam sempre uma frequência maior de céu claro que a real, como mostrado na tabela 14.

Foram realizados testes com as equações de cada estação e região, com dados do mês de Outubro, sendo que os dados OS são considerados

verdadeiros, apesar de se reconhecer que eles têm erros sistemáticos. Os resultados estão na Tabela 16, cujos elementos são:

- a) Coluna 1: nomes das regiões e estações que a compõem.
- b) Coluna 2: a equação de regressão. A variável independente X é o dado DX e o dependente Y é o dado OS.
- c) Coluna 3: dado DX de outubro.
- d) Coluna 4: dados OS de outubro.
- e) Coluna 5: resultado da conversão usando a equação da estação.
- f) Coluna 6: percentual da (coluna 5)/(coluna 4).
- g) Coluna 7: resultado da conversão usando a equação da região.
- h) Coluna 8: percentual da (coluna 7)/(coluna 4).

As variações dos percentuais dos resultados das colunas 6 e 8 permitem que se façam as seguintes observações:

1. Mesmo estações que têm coeficiente de correlação (CC) alto como Teresina (0,9) e Morada Nova (0,9) podem ter resultados isolados de conversão bem diferentes do real, neste caso de 180% e 166%. De modo geral, as estações com CC entre 0,7 e 0,9 das regiões 1 a 4 têm conversões com valores médios de 110%, o que pode ser considerado bom.
2. As equações de regiões formadas por várias estações tem CC e valores de R^2 menores que as estações em separado, como era de se esperar.
3. As regiões 5 a 8 apresentam uma grande variação de valores do CC e R^2 . Na região 5, o CC varia de 0,1 a 0,7. Na região 7, de 0,4 a 0,8.
4. É possível realizar uma conversão com bons resultados em parte das estações e em outras não. Esse fato mostra que é necessário estudar com mais profundidade os motivos de não haver sempre uma boa concordância entre os dados. Essa variação pode ser originada das várias fontes de erros presentes em ambos os dados, como os erros de avaliação da OS e os erros de referenciamento e amostragem dos pixels das imagens do METEOSAT.

Tabela 16 - Conversão de dados DX para dados OS com equações de regressão de cada estação e da região

Região Estação	Y (OS) X (DX)	3 (DX)	4 (OS)	5	6 5/4(%)	7	8 7/4(%)
REGIÃO 1	$Y=-3,21+0,86X$						
Parnaíba	$Y=-1,53+1,16X$	12	13.4	12.4	92	7.1	53
Teresina	$Y=-5,07+0,99X$	15	5.4	9.8	180	6.3	116
Barra	$Y=-7,87+1,27X$	15	11.1	11.2	101	9.7	87
B J Lapa	$Y=-4,28 +1,33X$	13	10.8	13.0	120	8.0	74
REGIÃO 2	$Y=-4,17+0,85X$						
M Nova	$Y= -5,22+1,40X$	15	9.5	15.8	166	8.6	91
Iguatu	$Y=-3,7+0,86X$	11	6.9	5.8	84	5.2	75
REGIÃO 3	$Y=-5,06+1,09X$						
Apodi	$Y=-2,54+0,84X$	16	11.0	10.9	99	12.4	113
Cruzeta	$Y=-4,10+0,98X$	15	12.0	10.6	88	11.3	94
Souza	$Y=-3,2+1,0X$	17	14.0	13.8	99	18.5	132
Serido	$Y=-10,0+1,9X$	11	14.0	10.9	78	6.9	49
Patos	$Y=-6,5 +1,1X$	17	14	12.2	87	13.5	96
Mossoro	$Y=-14,54+1,76X$	15	9.4	11.9	126	11.3	120
REGIÃO 4	$Y=-0,19+1,11X$						
Monteiro	$Y=3,76+0,83X$	16	20.2	17.0	84	17.6	87
Triunfo	$Y=-3,34+1,3X$	18	20.3	20.1	99	18.8	97
REGIÃO 5	$Y=-0,92 +0,60X$						
Arcoverde	$Y=-052+0,60X$	17	12.1	9.7	80	9.	77
Garanhuns	$Y=0,92+0,48X$	7	6.9	4.3	62	3.3	48
P Açucar	$Y=0,67+0,09X$	8	3.2	1.4	44	3.9	122
A Branca	$Y=-2,91+1,1X$	10	9.3	8.1	87	5.1	55
Cabrobó	$Y=-3-96+0,79X$	12	8.8	5.5	62	6.3	72
P Indios	$Y=-0,60+0,18X$	9	3.8	1.0	26	4.5	118

REGIÃO 6	$Y=-0,89+0,21X$						
Macau	$Y=-3,08+0,46X$	12	2.6	2.4	94	1.6	61
C Mirim	$Y=-9,2+0,99X$	12	0.6	2.7	428	1.6	253
REGIÃO 7	$Y= -1,41+0,30X$						
Recife	$Y=-2,76+0,47X$	7	0.7	0.5	78	0.7	102
J Pessoa*	$Y=-3,1+0,42X$	9	1.0	0.7	70	1.3	133
Maceio*	$Y=-10,8+1,1X$	12	2.6	2.4	92	2.2	84
Aracaju*	$Y=-7,8+0,93X$	10	1.8	1.5	83	1.6	88
C Grande*	$Y=-3,84+0,73X$	6	0.2	0.5	270	0.4	195
Areia	$Y=-0,79+0,26X$	7	3.5	1.0	29	0.7	20
Surubim	$Y=-1,4+0,21X$	7	0.3	0.1	23	0.7	230
Itabaiana	$Y=-2,93+0,51X$	8	1.5	1.2	77	1.0	66
REGIÃO 8							
Jacobina	$Y=-0,39+0,36X$	6	3.4	1.8	52	1.8	52


* Com dados OS obtidos de MAURÍCIO(1987)

6.3 Proposta de metodologia para estimar as classes 1, 2 e 3 a partir de dados DX

A seção anterior mostrou que é possível estimar os dados OS a partir de dados DX, com bons resultados em algumas áreas. Mas a estimativa é obtida para a média das classes 1, 2 e 3. Acontece, porém, que nas estações que apresentam maiores probabilidades de ocorrência de céu claro, como por exemplo Triunfo, a média é menor que o percentual da classe 1, devido à forma “U” ou “J” da curva de distribuição das classes de cobertura. Nesses casos, o uso da média não é vantajoso. Portanto, a seguir será proposto um método para estimar as três classes depois que se consegue a transformação de dados DX em OS usando-se as equações de regressão.

O método ora proposto baseia-se nas comparações entre as formas dos histogramas de frequências médias mensais (anexo 3) e o percentual de ocorrência da classe 1. Percebe-se que existe um padrão característico para a cauda à esquerda da curva de distribuição das classes de cobertura, que varia conforme o percentual da classe 1 (Figura 31). As estações que têm até cerca de 5% de ocorrência da classe 1 apresentam sempre a forma de sino. Esta forma vai se alterando para a forma de “U” e finalmente “j” invertido quando a classe 1 tem ocorrência de cerca de 20% ou mais.

Figura 31 - Formato da cauda da curva de distribuição das classes de cobertura a esquerda, relacionada com o percentual da classe 1



O método proposto de relacionar as curvas, frequência da classe 1 e médias das classes 1, 2 e 3, é o seguinte:

- As curvas de distribuição médias mensais de cada estação (anexo 3) têm muitos exemplos das curvas em todos os formatos de sino a “ J “, de onde foram retirados os percentuais das classes 1, 2 e 3 e calculadas suas médias. A Figura 32 mostra os segmentos coletados por intervalos da média das classes 1, 2 e 3, começando em médias menores que 1% até maiores que 15%. Os segmentos coincidem bem com a forma geral definida na figura 6.2, com exceção dos segmentos na faixa de 7 a 10%, na qual ocorrem curvas com inclinações contrárias.
- O processo de normalização das amostras, necessário para que seja possível compará-las, é realizado a partir do cálculo da média das classes 1, 2 e 3. Em seguida, as médias foram ordenadas e separadas por intervalo como na Tabela 17. Graficamente, foi retirada a ordenada média para cada intervalo e obtida a média geral dessas ordenadas. Cada ordenada dividida pela média geral, fornece o índice a ser usado nas conversões. Na Tabela 17 estão os intervalos, as ordenadas e médias para cada classe, e os índices correspondentes. No caso da faixa 7-10 existem os índices para as curvas ascendente e descendente.

A Tabela 17 mostra ainda que os índices apresentam uma uniformidade muito grande entre as vários intervalos. A cauda ascendente varia de 0,2; 0,8; 2,0 até o intervalo de 7-10% que tem 0,5; 0,8; 1,6. Nessa faixa ocorrem curvas com tendências opostas, mas com valores praticamente iguais em ordem invertida. A partir de 10%, os índices apenas trocam de ordem.

Figura 32 - Amostras das classes 1, 2 e 3 para vários intervalos de ocorrências

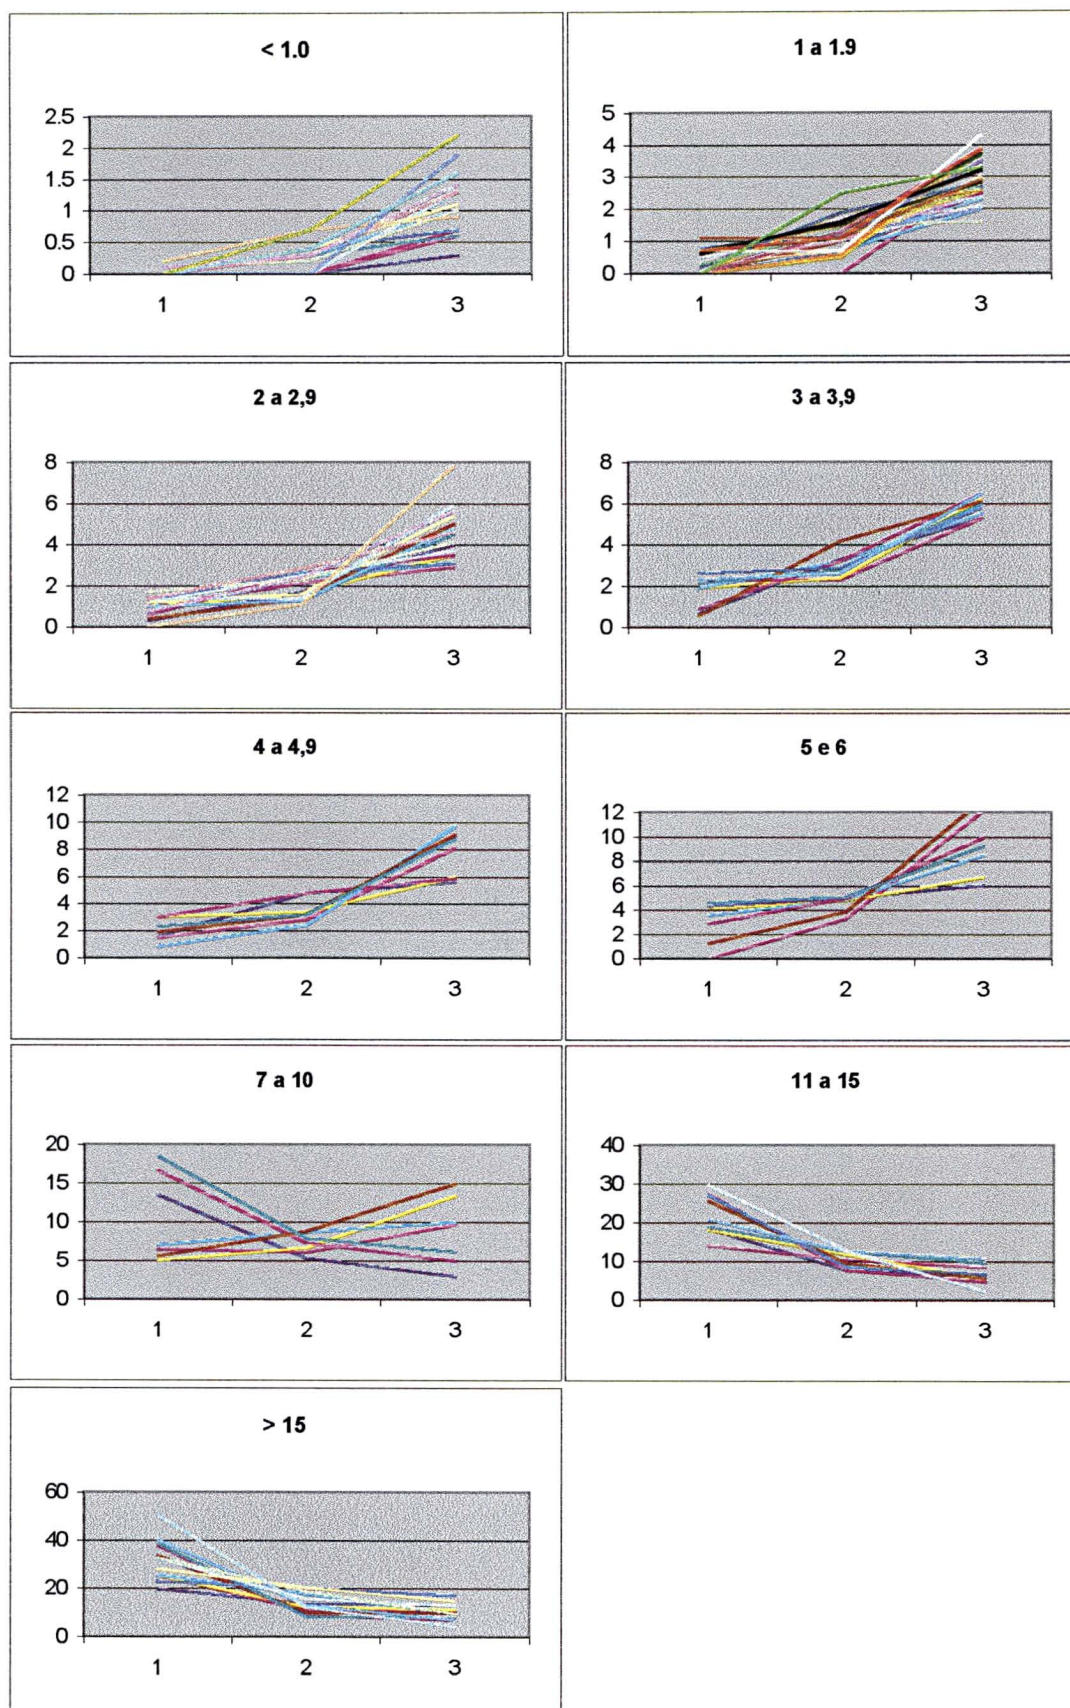


Tabela 17 - Cálculo do índice de obtenção das classe 1, 2 e 3 a partir da média das três classes

Intervalo	Classe de Cobertura			Média	Índice		
	1	2	3		Clas 1	Clas 2	Clas 3
<1%	0,1	0,5	1,2	0,6	0,2	0,8	2,0
1-2	0,5	1,0	3,0	1,5	0,3	0,7	2,0
2-3	0,9	2,0	4,3	2,4	0,4	0,8	1,8
3-3.9	1,7	3,0	5,9	3,5	0,5	0,9	1,7
4-4.8	2,0	3,5	7,6	4,4	0,5	0,8	1,7
5-6.9	3,0	4,6	9,4	5,7	0,5	0,8	1,6
7-10*	6,0	7,6	12,0	8,5	0,7	0,9	1,4
7-10**	15,1	6,3	4,0	8,5	1,8	0,7	0,5
10-15	22,3	10,5	6,7	13,2	1,7	0,8	0,5
>15	31,7	14,1	10,5	18,8	1,7	0,8	0,6

* ascendente ** descendente

6.3.1 Exemplo de aplicação da conversão

A conversão de um número de ocorrência de pixels claros dos dados DX para o equivalente de OS, com as classes 1, 2 e 3 pode ser realizada com a ajuda da equação de regressão da Tabela 16 e dos índices da Tabela 17. Nos casos em que o valor obtido OS, que equivale a média da classes 1, 2 e 3 ficar em torno de 10% necessita-se de uma informação adicional para definir se a curva é ascendente ou descendente. Alguns testes foram realizados e, embora não sejam conclusivos, ela é ascendente para a região em que a média anual de nebulosidade está abaixo de 50% e descendente a partir daí. Para os outros

casos, médias menores que 7% ou maiores que 10 %, não há indefinições deste tipo.

Os exemplos a seguir mostram a seqüência completa de uma conversão.

Para a estação de Patos, no mês de novembro a média DX é 13 observações de céu claro, que por meio da equação de regressão fornece a média 7,8%. Usando agora a Tabela 17, essa média tem índices 0,7; 0,9 e 1,4 para a curva ascendente (Patos tem média anual <50%) que resulta em 5,5% para a classe 1, 7,0% para a classe 2 e 10,9% para a classe 3.

Para a estação de Recife, no mês de novembro a média DX é 9 observações céu claro, que por meio da equação de regressão fornece a média 1,5%. Usando agora a Tabela 17, esta média tem índices 0,3; 0,7 e 2,0 que resulta em 0,4% para a classe 1, 1,1% para a classe 2 e 3,0% para a classe 3.

A indefinição que ocorre quando a média está entre 7-10%, em relação à forma da cauda da curva de distribuição necessita ser melhor estudada, porque não existe método de se passar de um formato de curva para outro. Esse é o mesmo tipo de problema encontrado quando se deseja estimar a curva de distribuição da nebulosidade para áreas muito maiores ou menores que a área de representatividade dos dados, para o qual GREAVES ET AL. (1971) sugere algumas fórmulas e apresenta alguns resultados preliminares promissores.

7. SIMULAÇÕES DE MISSÕES DE VÔO

As simulações discutidas e executadas nesse capítulo, destinam-se a apoiar o planejamento de missões de vôos fotogramétricos, fornecendo a quantidade de dias em que uma área pode ser levantada numa determinada época do ano. O método usado é o de Monte Carlo, aplicado a um algoritmo usado originalmente para simulações de imageamento por satélites, no qual foram introduzidas algumas modificações para adequá-lo aos vôos fotogramétricos. Os dados de entrada são as matrizes de probabilidade condicionais e incondicionais obtidas dos dados OS e os de saída são as probabilidades de sucesso de imageamento e número de tentativas necessárias até completar toda a área.

Nesta pesquisa, o número de tentativas tem o mesmo significado de quantidade de dias consecutivos que se leva até fotografar 100% de uma área, ou o tempo em dias de duração de uma missão de vôo com sucesso.

Além de detalhar o algoritmo usado, são comparados os resultados das simulações com outras estimativas de tempo, sugere-se uma solução para as regiões de baixa frequência de céu claro e elabora-se uma estimativa do intervalo de tempo, em horas, em que o céu permanece limpo, para cada observação registrada de céu claro.

Os resultados de simulações para todas as estações, no mês em que apresentam as maiores probabilidades de ocorrência da classe 1, e são mostrados em gráficos e também discutidos.

7.1 Considerações iniciais

O método de simulação de GREAVES ET AL. (1971) E BROWN (1978) foi desenvolvido originariamente para estimar as probabilidades de sucesso de imageamento por satélite. Nessa pesquisa, a aplicação prevista destina-se a

vãos fotogramétricos que apresentam algumas diferenças significativas. No algoritmo básico devem ser introduzidas modificações para adaptá-lo melhor a vôos fotogramétricos, sobretudo na parte relacionada a diferenças de escala de espaço e de tempo entre as tomadas das imagens:

- Os vôos fotogramétricos têm áreas por fotografias muito menores que as áreas imageadas por um satélite. Alguns exemplos de tamanho da área fotografada no terreno para as escalas de 1:5.000, 1:20.000 e 1:40.000 estão na Tabela 2 e são de 1,14km x 1,14km; 4,57km x 4,57km; 9,14km x 9,14km, respectivamente, contra os 185 km x 185 km do LANDSAT.
- Os exemplos mostram que as fotografias aéreas tem área muito menor que a área de abrangência de uma estação meteorológica (raio de 30km), enquanto que a do LANDSAT é maior.
- A repetibilidade de passagem do satélite é de vários dias enquanto o tempo de revôo de uma faixa pode ser de poucos minutos.
- As imagens de satélites normalmente têm pequena escala e podem formar mosaicos de extensas áreas para aplicações em estudos que exigem pouca precisão posicional. Já as escalas das fotografias são maiores e necessitam do recobrimento estereoscópico e formação de blocos. A formação dos blocos, por exigências técnicas e conveniências operacionais da etapa de fototriangulação e restituição, deve ser feita preferencialmente de forma contínua, faixa a faixa, sem interrupções e até sem emendas dentro das faixas.

As particularidades discutidas acima mostram que a área levantada numa missão de vôo fotogramétrico pode resultar em dezenas de fotografias que são obtidas em um horário flexível, diferente do resultado de satélite, que registra apenas uma imagem por dia, em horário fixo (normalmente pela manhã). Além de levar em conta essas diferenças, é essencial também encontrar uma forma de converter as estatísticas disponíveis com informações de céu claro, que na forma em que se apresentam induzem a consideração que uma ocorrência de

céu claro é válida para o dia inteiro, quando o correto seria conhecer a quantidade mais provável de horas em que o céu permanece sem nuvens.

7.2 Algoritmo básico

O algoritmo básico (Figura 33) usado para as simulações com o método de Monte Carlo, foi usado originariamente por GREAVES ET AL. (1971) e CHANG ET AL. (1972) para simulações de imageamento por satélite. Mas com algumas adaptações pode ser aplicado para vôos fotogramétricos. Os resultados das simulações dão as probabilidades de sucesso, a um certo nível de confiança, e o número de tentativas que são necessárias para fotografar 100% da área. A apresentação dos resultados é feita em dois tipos de gráficos:

- gráfico tipo 1, mostra a probabilidade de sucesso da área fotografada acumuladas de 0 a 100%, em um número fixo de tentativas;
- gráfico tipo 2, mostra as probabilidades de sucesso de fotografar uma área em N tentativas.

O algoritmo foi implementado num programa em Pascal chamado de MCARLO, que usa como dados de entrada as MPI e MPCT, obtidas dos dados OS conforme detalhado no Capítulo 4. Antes do uso do programa principal, as estatísticas de cobertura de nuvens (MPI e MPCT) que estavam em percentuais são transformadas e colocadas em forma acumulada, de modo que a categoria de total nebulosidade seja $\leq 1,0$. São então inicializados o número da passagem n e o número da missão Q. Em seguida, é gerado um número aleatório RAN, uniformemente distribuído no intervalo 0 a 1. Com esse número, entra-se na matriz de probabilidade acumulada no intervalo, que contém RAN, e se encontra a classe de cobertura correspondente G(n). Se a classe de cobertura selecionada G(n) é 1, isto é, céu 100% claro, então se considera que

toda a área foi fotografada e a missão está completa. Se a classe de cobertura não é 1, então a área imageada tem tamanho B. A área B é função da classe de cobertura de nuvens e vai sendo acumulada em cada tentativa, enquanto o número da tentativa é incrementado de um. Um novo número aleatório RAN é gerado e uma segunda classe de cobertura de nuvens é selecionada. Este processo continua até que a área imageada seja 100% ou que se atinja um número fixo de passagens N.

Foram introduzidas algumas modificações no algoritmo básico, na forma de incrementar a área fotografada de cada vez, como sugerido por BROWN (1971) e a possibilidade de entrar com a proporção da áreas a levantar em relação à área de representatividade das estatísticas usadas.

7.3 Modificações do algoritmo básico

No algoritmo acima foram introduzidas três modificações que visam tornar mais realista as aplicações à fotogrametria e verificar a possibilidade do uso do mapeamento realizado por partes, chamado de incremental por BROWN (1969).

1. A primeira é o imageamento da área de forma aleatória;
2. A segunda é a possibilidade incluir o tamanho da área a ser fotografada, conforme o projeto de levantamento;
3. A terceira é a possibilidade de escolher a quantidade de classes de cobertura consideradas úteis para vôo.

A primeira modificação sugerida por BROWN (1970) foi a inclusão da divisão da área em cem partes iguais e o mapeamento aleatório dessa área. No algoritmo da Figura 33, a rotina com modificação entra na letra A. Essa rotina gera números aleatórios de 1 a 100, que definem quais partes serão mapeadas nesta tentativa. Sempre é seguido o incremento parcial definido pela

classe de nuvem e observado se cada parte já não foi mapeada numa tentativa anterior. O processo continua até que toda área esteja mapeada.

A Figura 34 mostra como funciona a rotina. A parte superior mostra a área dividida em 10 x 10 partes, em que o dígito 1 representa nuvem e o 0 céu claro. Na a tentativa 1 a área acumulada é 45%. Na tentativa 2 a área fotografável seria 25%, que, com os 45% anteriores, daria 70%, mas como a distribuição foi aleatória, a área acumulada é menor, atingindo 60%. Na parte inferior da figura estão a evolução da área fotografada B e o número correspondente de tentativas.

Nessa forma de considerar que o imageamento pode ser feito por partes distribuídas aleatoriamente, é necessário definir como é a distribuição em cada tentativa. BROWN (1970) sugere que esta distribuição depende do tipo de nuvem que ocorre em cada época do ano. No caso de massas de nuvens frontais a distribuição deve ser contínua e no caso de massas de nuvens cumulus como nas regiões tropicais todas as partes devem ser espalhadas aleatoriamente.

A segunda modificação é a introdução do tamanho da área a levantar. Isso é feito informando o percentual da área a ser fotografada em relação à área total representativa das estatísticas que geraram os parâmetros para a simulação. Por exemplo se a área a ser fotografada é de 600km^2 e a área total tem cerca de 3.000km^2 , o percentual é de 20%. Essa percentagem é marcada como uma sub-área contínua dentro das cem partes da área total, como foi explicado no preenchimento da tentativa 1 da Figura 34. Essa posição muda em cada missão para simular as constantes alteração nas nuvens. O preenchimento dessa sub-área se dá aleatoriamente seguindo procedimento idêntico à primeira alteração acima.

Figura 33 - Algoritmo básico para simular imageamento pelo Método de Monte Carlo

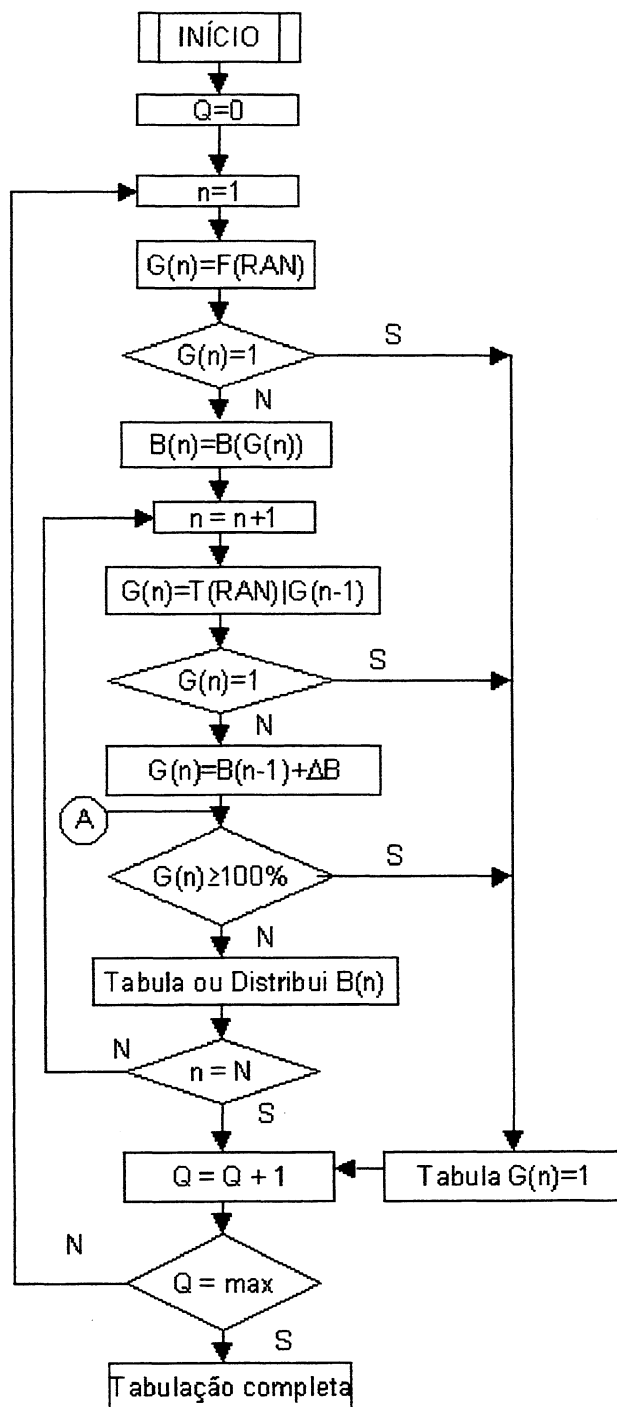


Figura 34 - Simulação com partes fotografadas aleatoriamente em cada tentativa

AFA=45.0	AF=25.0	AFA=60.0
TENT=1	TENT=2	TENT=2
1111111111	1101111101	1101111101
1111111111	0001010011	0001010011
1111111111	1111011111	1111110111
1111111111	1110011011	1110011011
1111111111	1111110111	1111110111
1111100000	0110110111	0110100000
0000000000	1001010111	0000000000
0000000000	1111111011	0000000000
0000000000	0101111111	0000000000
0000000000	0101111111	0000000000

B(N)	N
45.0	1
60.0	2
79.0	3
84.0	4
84.0	5
84.0	6
89.0	7
92.0	8
93.0	9
93.0	10
93.0	11
93.0	12
93.0	13
98.0	14
98.0	15
100.0	16

AFA – Área Fotografada Acum (%)
 AF -- Área Fotografada (%)
 B(N) – Área Fotografada Total
 N - Numero da tentativa

Fonte: Baseada em BROWN (1970)

A terceira modificação é a possibilidade de serem incluídas mais classes de cobertura, além da classe 1. O que se pretende é usar com flexibilidade todos os percentuais de áreas claras disponíveis do céu, permitindo que classes de cobertura com mais nebulosidade sejam aproveitadas. Dessa forma o programa tem três opções: a) classe 1, que tem de 0 a 90% de céu claro; b) classes 1, 2 e 3, que têm de 0 a 70% de céu claro, as quais, como sugerido por

esta pesquisa, podem aumentar significativamente as chances de vôo; c) classes de 1 a 10.

A utilização de todas as dez classes de cobertura, para aproveitar qualquer área livre de nuvens que exista no céu, implica na aceitação da idéia do mapeamento ou levantamento incremental que foi sugerido por BROWN (1969). No final de um levantamento desses, a área estará coberta por um mosaico, mais ou menos irregular, obtidos de vôos e revôos em áreas nubladas, dos quais foram aproveitados blocos e segmentos de faixas de vários tamanhos livres de nuvens e que devem cobrir estereoscopicamente toda a área a mapear. Deve-se lembrar que a formação e duração das nuvens é um processo dinâmico e que sofre a influência dos ventos. Por esse motivo é possível que no vôo de uma faixa ocorram nuvens e essa mesma faixa possa ser revoada poucos minutos em seguida com o céu limpo.

A preparação do mosaico é similar ao que usualmente se faz com as imagens de satélites quando se deseja mapear uma área que não dispõe de imagem completa livre de nuvens e é necessário recorrer a segmentos de várias outras, até de épocas diferentes, como se conseguiu recentemente para toda a Europa (GEODÉSIA ONLINE, 2001). Esse procedimento apesar de não ser admitido nos contratos de serviços fotogramétricos, não é tão raro como se pode imaginar. No dia a dia das empresas de aerolevantamento se encontram exemplos de serviços que foram executados aproveitando todas as brechas que ocorriam de céu claro.

Obviamente não é possível aproveitar integralmente sempre todas as pequenas partes livres de nuvens e sombras, mas as áreas maiores com modelos estereoscópicos completos podem formar os mosaicos. Com as técnicas mais modernas de vôo apoiado com GPS/INS, facilidades de apoio de campo, técnicas de correlação de imagens da fotogrametria digital, uso de restituidores analíticos e programas de fototriangulação que aceitam multi-escalas, não existem mais restrições absolutas para esse tipo de levantamento

que parece ser uma solução viável para as regiões que têm grande nebulosidade.

7.4 Comparação de estimativas de tempo para execução de missões de vôo

Os resultados de simulações podem ser comparados com outras formas de cálculo da duração de uma missão de vôo.

As simulações, como executadas pelo algoritmo básico, são indicadas para eventos onde se supõe que exista a persistência, isto é, que eles sejam considerados dependentes ou sejam um processo de Markov. Quando não existe a persistência, o evento pode ser considerado independente e as probabilidades podem ser calculadas com a equação combinatória básica (BROWN, 1971). Além disso, é conveniente também comparar os resultados com o método adotado por alguns sócios da Associação Nacional das Empresas de Aerolevantamentos (ANEA).

Os métodos usados para cálculo e comparação são:

a). Método da ANEA

Usa o chamado IDM (Índice de Dificuldade Meteorológico), que é determinado pela fórmula :

$$\text{IDM} = 30\text{dias}/N. \quad (21)$$

sendo N número médio de dias claros que ocorrem em determinado mês.

O IDM equivale a quantidade de dias nublados para cada dia claro, ou ainda a quantidade de dias de espera para cada dia de serviço efetivo. Por exemplo, supondo que o planejamento do vôo definiu que seriam necessários

dois dias para a execução de um levantamento fotogramétrico, então o tempo total de mobilização da tripulação e equipamento é igual a [(2dias x IDM) +2dias].

b) Equação combinatória

A equação combinatória pode ser usada se as tentativas de vôo forem consideradas independentes (BROWN,1971). O número de tentativas N para fotografar 100% da área a um nível de confiança de 95% é dado pelas fórmulas:

$$P_{95\%} = 1 - [1 - P(C_1)]^N \quad (22)$$

∴

$$N = \ln(1 - P_{95\%}) / \ln [1 - P(C_1)] \quad (23)$$

em que: $P_{95\%}$ = Probabilidade a 95% de nível de confiança;

$P(C_1)$ = frequência relativa da classe 1;

c) Simulação com o algoritmo básico

A simulação com Monte Carlo usa as MPI e MPCT, ou seja, as observações não são independentes. Para compará-lo com os outros métodos, o programa foi ajustado para usar apenas a MPI e somente a classe 1.

A Tabela 18 mostra os resultados obtidos para as cidades de Triunfo e Recife no mês de Outubro. O método da ANEA é o que dá os menores tempos para a execução do serviço. Os métodos da equação combinatória e da simulação dão praticamente os mesmos valores, servindo esse teste para mostrar que o algoritmo de simulação está correto.

As duas cidades foram escolhidas propositadamente em regiões que apresentam frequências da classe 1 muito diferentes, o que se reflete no número de tentativas:

a) a região de Triunfo tem probabilidade favorável de 40,1% de céu claro, e o número de tentativas variou entre 3,5 a 6, sendo razoável esta quantidade de dias de mobilização;

b) No entanto, para Recife o número excessivo de 41 a 119 dias aponta para a necessidade de adoção do levantamento incremental da área, como já sugerido por BROWN (1971), como solução que assegure que o levantamento termine num tempo menor.

Tabela 18 - Estimativa do número de tentativas, entre métodos 1, 2 e 3 para Triunfo e Recife no mês e horário mais favoráveis

MÉTODO	ESTAÇÃO	
	TRIUNFO	RECIFE
1- ANEA	3,5	41
2- Eq Combinatória	6	118
3- Simulação	6	119

7.5 Análises dos resultados das simulações

Com as matrizes de probabilidades disponíveis para a área de estudos é possível realizar simulações para todos os meses do ano e para qualquer região, basta escolher a estação mais próxima e usar os resultados diretamente. Quando o local do levantamento não estiver próximo de uma das cidades com estação meteorológica, o mapa da figura 29 pode ajudar a identificar em que região se encontra e em seguida eleger uma estação representativa para ela e usar seus dados.

As simulações executadas com o programa MCARLO para análise e comparações de resultados entre elas, foram executadas para todas as estações com dados completos, apenas no mês de maior ocorrência de céu

claro e no melhor horário. De modo geral os meses de mais ocorrência vão de agosto a novembro, para as estações das regiões do interior do continente o melhor horário é da manhã e para as regiões 6 e 7 no horário da tarde.

Os resultados das simulações são dados em número de tentativas e em probabilidades para fotografar 100% da área. O número de tentativas é a quantidade de dias gastos até que a área esteja completamente imageada, visto que as matrizes de probabilidades condicionais que entram na simulação referem-se a intervalos de 24h. As probabilidades que aparecem nos gráficos e tabelas são na verdade o nível de confiança do resultado. Portanto, é estatisticamente aceitável considerar 95% de probabilidade para definir o número de tentativas necessários para completar o levantamento.

7.5.1 Simulações com variação na quantidade de classes

As simulações, com variação da quantidade de classes que podem contribuir com áreas fotografáveis, foram executadas com a finalidade de avaliar a redução do número de tentativas principalmente nas áreas de nebulosidade excessiva.

Foram executadas simulações apenas com classe 1, com as classes 1, 2 e 3, e com todas as classes de 1 a 10. A Figura 35 apresenta um exemplo das simulações realizadas, com os gráficos tipo 1 e tipo 2. Os resultados das demais simulações e suas respectivas tabelas encontram-se no Anexo 7.

Os gráficos tipo 1 são referentes as tabelas do topo e foram obtidos apenas com as dez classes. Mostram as curvas das probabilidades de sucesso da área fotografada acumulada de uma até dez tentativas. Por exemplo, para Arcoverde existe 30% de probabilidade de que 60% da área esteja fotografada na primeira tentativa.

Os gráficos tipo 2 são referentes às colunas 10c, 3c, 1c e 10ci e dão as probabilidades para cada número de tentativa, obtidas com simulações

efetuadas com as dez, três, uma e dez classes respectivamente. As colunas 10ci foram obtidas também com as dez classes mas o algoritmo foi modificado para usar apenas a MPI. Para que cada simulação ocupe apenas uma página quando o número de tentativas passa de 39, foram repetidos os nomes das colunas e colocado o número de tentativas correspondente à 95% de probabilidade. Os gráficos tipo 2 mostram a probabilidade de sucesso do número de tentativas até no máximo 20, para facilitar comparações entre as estações.



A análise desses gráficos permite fazer as seguintes observações:

1. O uso das dez classes apresentam resultados praticamente iguais às simulações usando apenas a MPI (coluna 10 ci);
2. O uso de dez classes, quando comparada com uso da classe 1, reduz o número de tentativas para todas as regiões, sendo mais significativo para as regiões de nebulosidade excessiva, como Recife e Surubim;
3. Há uma redução do número de tentativas quando são usadas as classe 1, 2 e 3, mas esta redução não é sempre satisfatória com relação ao uso isolado da classe 1. Para as regiões 2 a 4, que têm as maiores frequências de dias claros, a melhora é de 0 a 15% na probabilidade do número de tentativas. Para as regiões 5 e 7, que têm mais nebulosidade a melhora chega a 30%, mas não é o suficiente para reduzir as tentativas para um número aceitável.
4. O número exagerado de tentativas para concluir uma missão de vôo, em toda a área de maior nebulosidade da região de estudo, mostra que é necessário adotar forma alternativa de execução de vôo dessas regiões, como o levantamento incremental.

Figura 35 - Exemplo de resultado das simulações

82890		Arcoverde 12h UTC				Mês 10					
1ª	100	88.1	80.4	63.7	49.8	31.2	20.9	3.3	3.3	3.1	
2ª	100	98.4	96.1	93.6	88.8	84.1	78	69.3	62.9	0	
3ª	100	100	99.1	95.6	92.9	88.2	82.9	76.5	69.4	0	
4ª	100	100	100	100	94.8	93.1	88.8	79.3	72.4	0	
5ª	100	100	100	100	100	90.6	87.5	81.3	71.9	0	
6ª	100	100	100	100	100	100	78.6	71.4	57.1	0	
7ª	100	100	100	100	100	100	100	100	100	0	
8ª	100	100	100	100	100	100	100	100	50	0	
9ª	100	100	100	100	100	100	100	100	100	0	
10ª	100	100	100	100	100	100	100	100	100	100	
		10	20	30	40	50	60	70	80	90	100

	10 c	3 c	1 c	10 ci
1	6.4	8.1	8.3	8.5
2	63.2	25.4	13.2	65.7
3	89.1	40.3	18	94.7
4	96.3	51.1	22.6	99.1
5	99.3	61.4	26.7	100
6	100	68.8	33.1	
7		75.4	38	
8		80.2	42.8	
9		83.7	45.3	
10		86.8	48.6	
11		89.5	51.7	
12		91.4	54.4	
13		92.7	56.8	
14		95.5	59.9	
15		96.9	62.5	
16		97.4	64.9	
17		97.9	67.5	
18		98.5	69.6	
19		98.7	71.4	
20		99.3	73.2	
21		99.6	74.5	
22		99.6	76.1	
23		99.7	77.4	
24		99.7	78.8	
25		99.9	80.4	
26		100	81.9	
27			83.1	
28			84	
29			84.8	
30			85.7	
31			86.4	
32			87.2	
33			88.2	
34			89	
35			89.4	
36			89.6	
37			90.1	
38			90.8	
39			91.1	



Número de tentativas para 95% de nível de confiança

3 c	1 c
15	48

7.5.2 Simulações com áreas menores que a área de abrangência

As áreas abrangidas pelos levantamentos fotogramétricos têm uma variação muito grande, podendo ser de poucos quilômetros quadrados até milhares deles, sendo que essa particularidade é difícil de incorporar com realismo no processo de simulação. Nessa seção, é feita uma tentativa com esse sentido e, na seguinte, também são feitas considerações sobre uma forma prática de relacionar diretamente os resultados das simulações com o tempo necessário para realizar um levantamento, em função do tamanho da área e da escala das fotografias.

Foram realizadas simulações com o algoritmo modificado, entrando com áreas iguais a 100%, 80% , 60%, 40% e 20% da área de representatividade dos dados de OS. Considerando a área representativa da OS de 3000km^2 , as áreas de 80% , 60%, 40% e 20% equivalem a 2400, 1800, 1200 e 600km^2 , respectivamente. A Figura 36 mostra os resultados das simulações para Recife com as diversas áreas percentuais e as dez classes. Esses resultados mostram que o imageamento aleatório aumenta muito o número de tentativas. Por exemplo, para Recife, com o algoritmo básico e usando dez classes o número de tentativas para toda a área é de 6 e com o aleatório passa para 21.

Os gráficos de evolução da área fotografada acumulada são os que apresentam comportamento mais variável, mas apenas quando são usadas as dez classes são obtidas curvas contínuas. Com três e uma classe só a partir de 30 e 40% de área acumulada consegue-se os níveis de confiabilidade de 95%. Este tipo de gráfico não mostra-se portanto muito útil para fins fotogramétricos, visto que o objetivo sempre é conseguir levantar 100% da área e que ele não funciona bem para simulações com menos de dez classes.

Os gráficos de número de tentativas x probabilidade de sucesso mostram que redução na quantidade de tentativas não é muito grande quando se varia a área. Com as dez classes o número de tentativas diminui de 21 para


a área de 100% para 17 quando a área é de 20%. Essa redução não é significativa. Pela relação existente, discutida em 3.4.3, de que, à medida em que a área diminui, as chances de céu claro aumentam, era de se esperar que quanto menor a área, bem seria menor o número de tentativas.

A existência dessa relação merece mais estudos tendo em vista suas aplicações diretas na fotogrametria e nos satélites imageadores de alta resolução. A área coberta por uma fotografia depende da escala, por exemplo, na escala 1:5000 cobre apenas 1,1km x 1,1km, assim seria muito mais provável fotografar, em escalas grandes, pequenas áreas de cada vez. No caso da fotogrametria também a aeronave pode se deslocar para a parte da área que está livre de nuvens e executar o levantamento. Essa flexibilidade de deslocamento da aeronave não existe para os satélites imageadores, sendo difícil ou impossível, alterar a direção do imageamento, mas as possibilidades de sucesso serão maiores para eles porque a área de suas imagens são menores a medida que a resolução aumenta.

A solução para efetuar simulações que incorporem áreas a levantar de diversos tamanhos, diferentes das áreas representativas dos dados de nebulosidade, é encontrar um método que determine a forma de mudança da curva de distribuição quando se aumenta ou diminua a área de levantamento à nebulosidade. GREAVES ET AL. (1971) sugere um método usando a curva normal e chega até a apresentar fórmula de cálculo de escalonamento da probabilidade das classes intermediárias, entre céu totalmente claro e totalmente nublado, mas sua metodologia não está completa o suficiente para ser reproduzida. Por outro lado os gráficos das frequências mensais das classes de cobertura (anexo 3), discutidos no item 4.1.6 mostram que a variedade dos tipos de curvas que ocorrem na região está mais próxima da distribuição beta e não da normal. Toda essa questão deve ser melhor estudada antes de ser incorporada no programa de simulação.

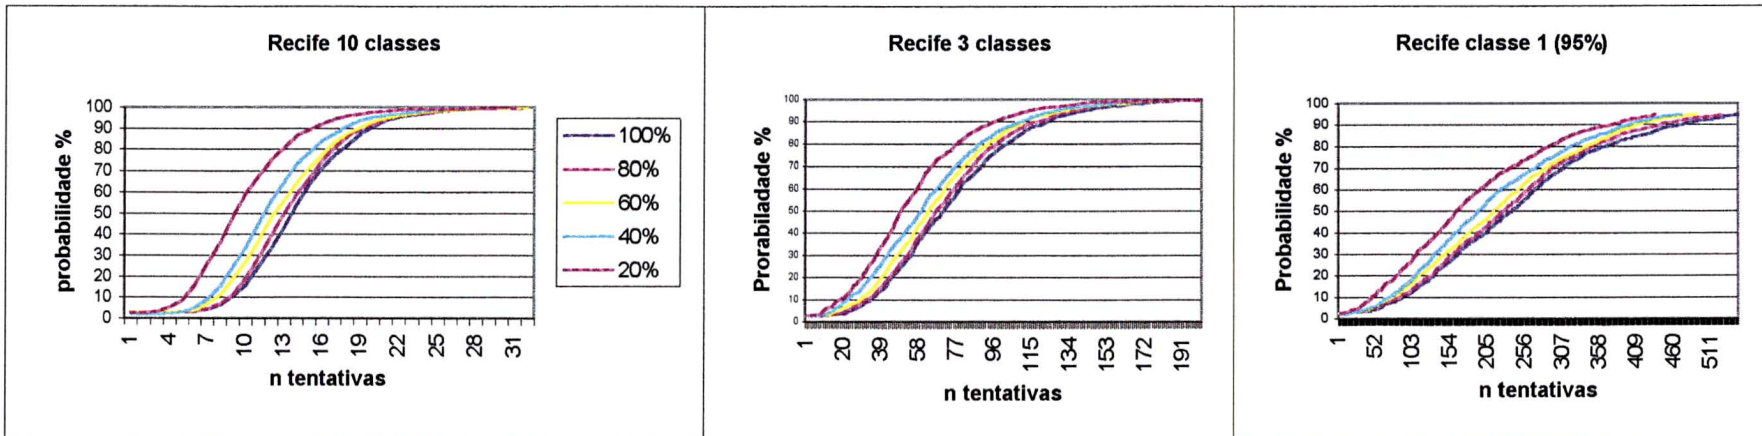
Figura 36 -Simulações para Recife com as Área de 100%, 80%, 60%, 40% e 20%

GRAFICOS TIPO 1: DE PROBABILIDADE DE LEVANTAMENTO DE AREA ACUMULADA NA N-ÉSIMA TENTATIVA



t1 = tentativa numero 1

GRAFICOS TIPO 2: N TENTATIVAS x PROBABILIDADE DE SUCESSO



7.6 Estimativa do intervalo em horas para uma ocorrência de céu claro

A estimativa da duração do intervalo em horas que tem uma ocorrência de céu claro nas estatísticas das OS, permitem avaliar a aplicabilidade do número de tentativas obtidos nas simulações com o programa MCARLO em missões fotogramétricas. Isso é necessário porque as durações dos levantamentos fotogramétricos são normalmente calculadas em horas, diferente das missões por satélite que são em dias.

As estatísticas dos dados OS e DX referem-se a um registro instantâneo da situação do céu em um dos horários de 12h , 15h ou 18h UTC.

No caso do imageamento por satélite, a área imageada normalmente é da ordem de grandeza, ou maior, que a área de representatividade dos dados e o tempo de aquisição é de frações de segundos, ao contrário da fotogrametria que para fotografar a mesma área, necessita de muitas fotografias e de algumas horas.

Por esse motivo é necessário estimar quantas horas o céu permanece aberto. Essa estimativa seria melhor obtida se fossem analisados dados de observações horárias, mas, na falta delas, serão utilizadas considerações teóricas e os resultados obtidos durante esta pesquisa. Segundo GRINGORTEN (1966) existe uma forte correlação de hora para hora, entre eventos meteorológicos, como a nebulosidade, em torno de 0,93%. Apenas esse valor não garante que na região em estudo o período de céu claro seja o dia inteiro, e resultados anteriores já mostram que os turnos da manhã e tarde têm frequências diferentes. Portanto, a estimativa será realizada considerando-se o seguinte:

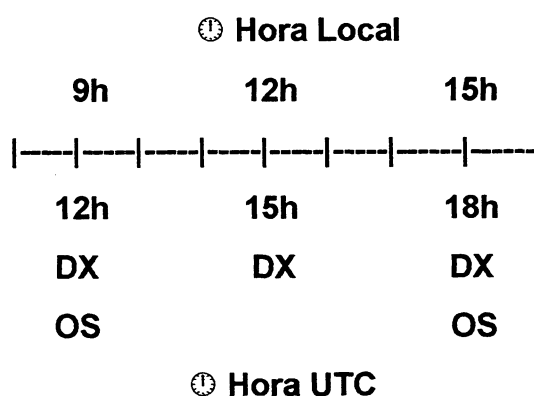
- Os dados OS e DX forneceram às MPI e MPCT, os gráficos de comportamento da classe 1 ao longo do ano, nos horários de 12h e 18h para OS, e 12h, 15h e 18h para DX. Com esses gráficos, foi possível detectar que, embora na maioria das estações haja ocorrência maior da classe1 pela manhã, também existem áreas em que ocorre mais à tarde.

Existe coincidência deste comportamento (mais céu claro pela manhã ou pela tarde) nas regiões entre ambos os dados.

- Com as matrizes PCT entre 12 e 18 horas dos dados OS, é possível verificar que a probabilidade de ocorrer céu claro pela manhã, e se repetir à tarde, é menor que a probabilidade condicional temporal de 24 de ocorrer hoje, e se repetir amanhã.
- Para a região com predominância pela manhã, a curva de DX das 15h é mais próxima da curva de 18h, sugerindo que as ocorrências diminuem a partir das 15 horas e permanecem assim até às 18h. Na região com mais céu claro à tarde acontece o contrário, as curvas das 12h e 15h têm frequências mais baixas e semelhantes, isso sugere que as ocorrências aumentam a partir das 15h para atingir o máximo às 18h.

Pode-se então concluir, de acordo com a última observação acima, que o turno de mais ocorrência de claros termina ou começa às 15h UTC. O início e o fim de cada um desses períodos podem ser estimados com a ajuda da escala da Figura 37. A escala traz os horários de observação em hora local e UTC. Como na região de estudo, o período de horário local em que o sol está acima de 30° , nas épocas mais favoráveis para os vôos, é no mínimo das 8h as 16h, é bem razoável supor que o intervalo de céu claro dure então 4 horas, pela manhã ou pela tarde.

Figura 37 - Horários de observação dos dados OS (12h, 18h UTC) e DX (12h, 15h, 18h UTC)



Com base na estimativa de 4 horas para cada observação de céu claro fornecida pelas estatísticas OS, é possível estimar a quantidade total de horas de céu claro por mês. O cálculo pode ser feito por dois caminhos, conforme o exemplo abaixo para a estação de Monteiro, que apresenta mais céu claro pela manhã, no mês de Novembro:

a) Considerando as ocorrências de céu claro pela manhã que se estendem pela tarde, usando as matrizes MPI e MPCT 12-18 do mesmo mês, da MPI 12h, obtém-se $P(c_1) = 40\%$ que equivale a 12 dias de céu claro pela manhã;
da MPCT 12-18, obtém-se $P(c_{18}/c_{112}) = 24\%$; 24% de 40% equivale a mais 2,9 dias com céu claro a tarde.

A soma de (12 + 2,9) dias, vezes 4 horas equivale ao total de 59,6 horas de céu claro.

b). Considerando independentes as ocorrências da manhã e tarde, usando as matrizes MPI 12h e MPI 18h:

da MPI 12h, obtém-se $P(c_1) = 40\%$ que equivale a 12 dias de céu claro pela manhã;

da MPI 18h, obtém-se $P(c_1) = 16\%$ que equivale a 4,8 dias de céu claro pela tarde;

A soma (12 + 4,8) dias, vezes 4 horas equivale a 67,2 horas de céu claro no mês.

O segundo cálculo forneceu 67,2 horas, maior que o primeiro, isto é, fazendo-se a estimativa considerando os turnos com ocorrências independentes é mais vantajosa que considerar a persistência de céu claro durante 8 horas seguidas. No processo de simulação implementado, são utilizadas as mesmas matrizes do primeiro cálculo (turno com mais céu claro)

e o valor a menor fica por conta de uma margem de segurança para a simulação.

O período útil total de 4 horas dificilmente será integralmente aproveitado numa missão, ou tentativa de vôo, devido a vários fatores, como tempo gasto na mobilização, decolagem, subida e deslocamento até a área do serviço, procedimentos de tomada de faixas, limitação do tamanho do filme e autonomia de vôo da aeronave. Com estes fatores de redução, um tempo efetivo de serviço de 2 duas horas daria para levantar, segundo dados da Tabela 2, as áreas 500 km²; 2.000km² e 4.000km² para as escalas 1:5.000, 1:20.000 e 1:40.000, respectivamente. Estas áreas correspondem a 17%, 70% e 135% da área de abrangência de uma OS. Assim uma simulação de vôo fotogramétrico, para ser mais realista, deve incluir a extensão da área a levantar e escala.

Como isso não foi implementado nessa pesquisa, a sugestão para aplicar os resultados das simulações, como estão, para vôos fotogramétricos é considerar o seguinte:

a) a simulação é válida para fotografar uma área de tamanho e escala variáveis que possa ser concluída num intervalo de quatro horas.

b) o planejamento do vôo deve ser realizado como é usualmente feito, chegando a um cálculo de qual área é possível efetivamente fotografar, considerando todos os atrasos possíveis, em quatro horas de céu claro, essa área é a área de levantamento de referência.

c) Se toda a área pode ser voada dentro desse intervalo utiliza-se diretamente o número de tentativas obtido na simulação.

d) Se a área total é maior que a área de referência, considerar que cada área de referência é independente e multiplicar o número de tentativas da simulação pela relação (área total)/ (área de referência).

Uma solução mais elegante é implementar o método chamado de escalonamento markoviano por GREAVES ET AL. (1971). Esse escalonamento parte da suposição adotada na simulação que as ocorrências das nuvens são

uma cadeia simples de Markov e que as matrizes de probabilidade condicional para áreas N vezes maiores que a área de referência, são obtidas simplesmente elevando as matrizes à potência N . Para áreas menores, as matrizes são elevadas a potências fracionárias proporcionais à relação (área projeto)/ (área de referência).

8. CONCLUSÕES E RECOMENDAÇÕES

Os objetivos dessa pesquisa envolvem o estudo e tratamento de estatísticas de nebulosidade visando sua utilização, sob a forma de mapas atualizados de céu claro, e para fornecer informações para um programa de simulações de previsão de sucesso de missões de levantamentos fotogramétricos. Inclui ainda a exigência que tais estudos alcancem um nível de detalhamento capaz de identificar, com precisão, as áreas de grande nebulosidade e que apresente sugestões de procedimentos alternativos para a execução de levantamentos naquelas áreas. Ao término das várias etapas desenvolvidas ao longo dos trabalhos, serão dadas a seguir as conclusões finais, recomendações e sugestões para o prosseguimento das pesquisas.

8.1 Conclusões

As conclusões finais referem-se às maiores dificuldades encontradas e aos resultados mais importantes sobre os dados coletados, processamento e análise das simulações.

Quanto aos dados usados são as seguintes:

1. Os dados de superfície do INMET apresentam muito erros sistemáticos, introduzidos pela preferência do observador de anotar mais um número que outro. Isto leva a gráficos com formatos dentados e a indefinição do tipo de curva de distribuição.
2. Os dados DX apresentam um deslocamento sistemático para oeste que varia entre 25 e 50km. O motivo pode ser a posição da área de estudos que fica na extremidade da imagem coletada pelo satélite. Esse erro é suficiente para dificultar a localização de áreas com diâmetros menores que o espaçamento nominal dos dados DX (30km), com problemas de nebulosidade de origem orográfica.

3. O método de amostragem de um pixel de 5km que passa a representar uma extensão de 30km, nos dados DX, provocam alteração da curva de distribuição real da nebulosidade de uma região.
4. As imagens do LANDSAT mostram que a ocorrência de nuvens do gênero cumulus cobrem vastas áreas é a responsável pela média alta de nebulosidade da região.
5. Foi detectada com imagens do LANDSAT que é muito comum a ocorrência de uma faixa com largura de 1 a 5 km, paralela à linha do litoral, livre de nuvens. Isto pode ser muito útil para o levantamento das capitais que se situam exatamente nesta faixa.

Quanto ao processamento as principais são:

6. A metodologia adotada para produzir um único mapa de céu claro para todo o ano, a partir de observações de superfície, mostrou-se relativamente fácil de ser empregada.
7. A metodologia desenvolvida para resumir a grande massa de dados originais DX, desde a leitura dos dados, geração de imagens “estatísticas”, processamento como imagens multiespectrais e classificação, mostrou-se adequada para separar as regiões de nebulosidade homogênea.
8. Os testes de medição de altura das nuvens em imagens do LANDSAT mostram que eles podem fornecer informações geométricas para a caracterização mais detalhada das nuvens da região e para o processo de simulação.
9. As equações de regressão entre os dados OS e DX, principalmente nas regiões de maior ocorrência de céu claro, chegam a explicar mais de 80% da variável dependente, indicando que é estatisticamente possível converter um tipo de dado para o outro, conseguindo com isso aproveitar as melhores características de cada tipo de dado úteis para fins fotogramétricos.

10. De modo geral as equações de regressão tem estatísticas piores nas regiões mais nubladas e em algumas delas não chega a existir relação estatística significativa entre os dados OS e DX.
11. O método para recuperar as classes 1, 2 e 3, após a transformação de dados DX para OS, baseado na forma da cauda a esquerda da curva de distribuição, funciona bem na maioria dos casos.

Quanto às análises sobre o uso dos dados processados e os resultados das simulações, são:

12. Uso de uma rede de estações meteorológicas, com a densidade e espaçamento similar a usada, e com o tratamento adotado para os dados OS, permitiram a identificação de área de nebulosidade constante e excessiva, para a qual devem ser adotados cuidados especiais, quando do planejamento de vôos sobre elas.
13. Processamento dos dados DX, efetuado até o nível dessa pesquisa, e considerados como elementos que representam uma área de 30km x 30km, mostrou que eles não são suficientes para fornecerem frequências de céu claro, úteis para a fotogrametria.
14. O método de simulação de Monte Carlo, com as adaptações no algoritmo básico, mostrou-se viável para o planejamento de vôos fotogramétricos.
15. A hipótese de que o uso das classes 1, 2 e 3, aumentaria significativamente as probabilidades de sucesso não se confirmaram em todos os casos testados. Mesmo quando houve aumento da probabilidade de sucesso, nas regiões de alta nebulosidade, os números de tentativas ainda permaneceram exagerados.
16. Foi verificado, e confirmado pelos dados OS e DX, que algumas regiões tem mais céu claro a tarde (18h UTC) que pela manhã (12h UTC).
17. É vantajoso o uso simultâneo de dados com informações diferentes quanto à resolução temporal e espacial para a confecção de mapas confiáveis de céu claro. Os dados com resolução melhor, como os DX, formam um

volume de dados que exige grande esforço e trabalho para manipulá-los, mas auxiliam muito na separação mais precisa dos limites das áreas homogêneas. Já imagens com uma resolução intermediária, como as do LANDSAT, ajudam na obtenção de dados geométricos médios das nuvens, como dimensões, alturas da bases e espaçamentos.

18. As simulações usando as dez classes de cobertura mostram uma redução muito sensível no número de tentativas, sugerindo assim que o uso do levantamento incremental é uma solução a ser seriamente avaliada para as regiões de nebulosidade excessiva e constante todo o ano, ou para levantamentos fora da época ideal.

Quanto a possível solução alternativa, usando câmaras fotogramétricas analógicas ou digitais, para as áreas nubladas excessivamente todo o ano, os resultados das simulações apontam para o uso do levantamento incremental. Esse levantamento, no final, está formado por um mosaico, mais ou menos irregular, obtidos de vôos e revôos em áreas nubladas, dos quais foram aproveitados blocos e segmentos de faixas de vários tamanhos livres de nuvens e que devem cobrir estereoscopicamente toda a área a mapear. Esse procedimento apesar de não ser admitido nos contratos de serviços fotogramétricos, não é tão raro como se pode imaginar. No dia a dia das empresas de aerolevanteamento se encontram exemplos de serviços que foram executados aproveitando todas as brechas que ocorriam de céu claro.

Com as técnicas mais modernas de vôo apoiado com GPS/INS, facilidades de apoio de campo, técnicas de correlação de imagens da fotogrametria digital, uso de restituidores analíticos e programas de fototriangulação que aceitam multi-escalas, não existem mais restrições absolutas para esse tipo de levantamento que parece ser uma solução viável para as regiões que têm alta nebulosidade.

8. 2 Recomendações e sugestões

As recomendações e sugestões visam o prosseguimento de estudos dos problemas encontrados na pesquisa, incluindo as questões que não foram bem resolvidas, ou resolvidas parcialmente, para as quais podem existir soluções melhores e mais eficientes. As principais são:

1. É necessário desenvolver um método prático e mais preciso para avaliação do percentual de cobertura das nuvens, usando técnicas fotogramétricas, que permita obter as frequências em áreas menores que as áreas de abrangência das estações meteorológicas e também corrigir os erros sistemáticos dos observadores.
2. Usar o banco de dados e o método de simulação dessa pesquisa para desenvolver um sistema de programas de computador, que tenha interações com o usuário, saídas gráficas e outras facilidades para emprego nas empresas de aerolevante. Sugere-se também incorporar no programa de simulação a escala do vôo e a área a ser levantada.
3. A metodologia aqui adaptada para a execução de mapa de céu claro com os dados de nebulosidade de superfície do INMET pode perfeitamente ser estendida para um mapa de todo o Brasil.
4. Estender a metodologia de composição de mapas, ou imagens, estatísticas usada no processamento dos dados DX, para as imagens originais (resolução no terreno de 1 a 8 km) do satélite identificado por GOES-E pelo ISCCP. Com esses dados é possível gerar mapa de céu claro de alta resolução para todo o Brasil e definir a duração do intervalo médio em horas de céu claro por dia para cada região.
5. Estudar e desenvolver métodos de previsão de condições ideais para vôos fotogramétricos em tempo real usando imagens de satélites meteorológicos e radares.

6. Melhorar o método para se determinar a forma da curva de distribuição da nebulosidade quando se aumenta ou se diminui a área de representatividade dos dados. Também o estudo dessa curva pode resolver a indefinição existente no método de recuperar as classes 1, 2 e 3, após a transformação de dados DX para OS, quando a média encontra-se entre 7% e 10%.
7. Estudar as relações custo/benefício entre o custo do emprego do levantamento fotogramétrico incremental nas regiões de alta nebulosidade, incluindo as despesas e tempo extras gastos em vôos, revôos, apoio adicional de campo e dificuldades extras na fototriangulação e restituição, e os custos do tempo exagerado de espera por condições ideais de vôo.
8. Estudar para o uso do levantamento incremental, as questões referentes à homogeneidade de precisão dos blocos estereoscópicos formados por mosaicos de fotografias e imagens de várias escalas e a otimização de pontos de apoio, de forma que o produto cartográfico final tenha os padrões de qualidade exigidos.
9. Estudar a freqüência das faixas livres de nuvens que ocorrem paralelas ao litoral, de modo a fornecer estatísticas melhores de céu claro para as capitais que se situam nessa faixa.

REFERÊNCIAS BIBLIOGRÁFICAS

1º/6º GRUPO DE AVIAÇÃO. Seção de informações [do] Setor de Planejamento Meteorológico. **Climatologia Mensal**. [Recife: Base Aérea, 19??] 12 cartogramas de janeiro a dezembro.

APPLEMAN, H. S. A Comparison of Simultaneous Aircraft and Surface Cloud Observations. **Journal of Applied Meteorology**, v. 1, n. 4, p. 548-551. Dec 1962.

BROWN, S. C. A Cloud-Cover Simulation Procedure. **Astronautics & Aeronautics**, v. 17, n. 8, p. 86-88. Aug 1969.

_____. Simulating the Consequence of Cloud Cover on Earth-Viewing Space Mission. **Bulletin American Meteorological Society**. V. 2, n. 51, p. 126-131. 1970.

BUCHROITHNER, M.F; KOSTKA, R. Conceptual Considerations on High-Mountain Cartography and Spaceborne Remote Sensing. In: **18 th ICA/ACI International Cartographic Conference**. Estocolmo: 1997. p. 1597-1603.

CHANG, D. T; WILLARD, J. H. **Further Developments in Cloud Statistics for Computer Simulations**. NASA Contractor Report CR-61389. Alabama: NASA George C. Marshall Space Flight Center, 1972. 109 p.

CHEDE, F. C; CHEDE, I. C. G. **Estudo das Regiões Climatológicas Brasileiras e a sua Utilização Prática na Aerofotogrametria**. 2 ed. Rio de Janeiro: Escola de Aperfeiçoamento e Preparação da Aeronáutica Civil. 1985. 45 p.

FALLS, L. W. The Beta Distribution: A Statistical Model for World Cloud Cover. **Journal of Geophysical Research**. v. 79, n. 9, p. 1261-1264. Mar 1974.

FLEMING, J. Patterns of Aerial Photo Weather in Canada. **The Canadian Surveyor**. v. 25, n. 1. p. 42-48. mar 1971.

GEODÉSIA ON-LINE. Mosaico sem Nuvens da Europa. **Geodésia Online Info 3/2001**. Disponível em < <http://geodesia.ufsc.br/geodesia-nline/infos/2000/Europa/europa.jpg>> Acesso em 5 jul 2001.

GIBRA, I. N. **Probability and Statistical Inference for Scientists and Engineers**. Prentice-Hall, 1973.

GILKS, W. R; RICHARDSON, S; SPIEGELHALTER, D. J. **Markov Chain Monte Carlo in Practice**. Londres: Chapman & Hall. 486 p. 1995.

GIRARDI, L. C. **Áreas e Épocas Favoráveis aos Vôos Aerofotogramétricos. IAE-M-03/73**. S. José dos Campos: Centro Técnico Aeroespacial, Instituto de Atividades Espaciais. 1973. 22p.

GLASS, M; CARLSON, T. N. The Growth Characteristics of Small Cumulus Clouds. **Journal of the Atmospheric Sciences**. v. 20, p. 397-406. set 1963 .

GREAVES, J. R; SPIEGLER, D. B; WILLAND, J. H. **Development of a Global Cloud Model for Simulating Earth-Viewing Space Missions**. NASA Contractor Report CR-61345. Alabama: NASA George C. Marshall Space Flight Center. 1971. 133 p.

GRINGORTEN, I. I. A Stochastic Model of the Frequency and Duration of Weather Events. **Journal of Applied Meteorology**. V. 5, p. 606-624. Oct 1966.

_____. Modelling Conditional Probability. **Journal of Applied Meteorology**. V. 10, p. 646-657. aug 1971.

HAIR, J. F. JR., ANDERSON, R. E., TATHAM, R. L. **Multivariate Data Analysis**. Nova York: Macmillan Publishing Company. 1984. 449 p.

HARRINGTON, E. L. Camera Orientation for Cloud Measurements. **Photogrammetric Engineering & Remote Sensing**. v. 34, n. 4. p. 380-391. april 1968.

HILL, R. A Lens for whole Sky Photographs. **Quartenary Journal of Royal Meteorological Society**. v. 50, p.227-235. 1924.

KEMENY, J. G; SNELL, J. L. **Finite Markov Chains**. Nova York: Van Nostrand Reinhold Company, 1960. 210 p.

KENNEDY JR, W. J; GENTLE, J.E. **Statistical Computing**. Nova York: Marcel Dekkar, Inc. 1980.

KRICK, I. P. Weather Engineering Services for Aerial Photography. **Photogrammetric Engineering**. v. 22, n. 1. p. 33-40. mar 1956.

KRISTJANSSON, J. E. Cloud Parametrization at Different Horizontal Resolutions. **Quartenary Journal of Royal Meteorological Society**. n. 117, p.1255-1280. 1991.

LANDGREBE, D; BIEHL, L. **An Introduction to MultiSpec. Version 2.15.95**. West Lafayette, Indiana, EUA: Purdue Research Foundation. 1995. Disponível em < <http://dynamo.ecn.purdue.edu/~biehl/MultiSpec/>> Acesso em: 20 set 1999.

LAPP, H.S; GROENING, D. I. Night Mapping using Image Intensifier Cameras. In: **Proceedings of the ASP 41 th Annual Meeting**. Washington: American Society of Photogrammetry. 1975. p. 588-593.

LEE, D. T; SCHACHTER, B. J. Two Algoritms for Constructing a Delaunay Triangulation. **International Journal of Computer and Information Sciences**. v. 9, n. 3, p.219-242. 1980.

LEE, J.E; JOHNSON, D. Expectancy of Cloudless Photographic Days in the Contiguous United States. **Photogrammetric Engineering & Remote Sensing**. v. 51, n.12, p. 1883-1891. dec 1985.

MANSON, B; SCHMETZ, J. Meteorological Satellites. **International Journal Remote Sensing**. v. 13, n. 6 e 7, p. 1153-1172. 1992.

MAURÍCIO, J. A. **Efeitos da Cobertura de Nuvens em Sensoriamento Remoto**. Dissertação de Mestrado, Instituto Nacional de Pesquisas Espaciais. São José dos Campos. 1987. 95 p. il.

MENDONÇA, F. J; NETO, G. C. **Levantamento da Frequência de coberturas de Nuvens em Dados do Landsat no Período de 1973 a 1981**. Publicação INPE-2882-RPE/443. São José dos Campos: Instituto Nacional de Pesquisas Espaciais. 1983. 73 p.

MERCER, J. B. SAR Technologies for Topographic Mapping. In: **Photogrammetric Week'95**. Karlsruhe: (Ed) Fritsch/Hobbie. Wichmann. 1995. p. 117-126.

METROPOLIS, N. ULAM. The Monte Carlo Method. **Journal of the American Statistical Association**. v. 44, n. 247, p. 335-341. Sep 1949.

MEYER, A. H. (Ed). **Symposium on Monte Carlo Methods**. University of Florida: John Wiley & Sons, Inc. 1954.

MONTENEGRO, G. A. **A Perspectiva dos Profissionais**. São Paulo: Edgard Blücher Ltda. 1983.155 p.

MOREIRA, J. Design of Airborne Interferometric SAR for Precision DEM Generation. In: **International Archives of Photogrammetry**. Viena: Committee of 18th Congress, v. 31, Part B2. p. 256-260. 1996.

MYERS, B. J; WATTS, S. J. **Shadowless Aerial Photography**. Divisional Report No. 7. Canberra, Australia : Forest Research CSIRO. 1981. 41 p.

ORVILLE, H. D. Cumulus Cloud Photogrammetry. **Photogrammetric Engineering**. v. 27, n. 5, p. 787-791. dez 1961.

PARRY, J. T; GOLD, C. M. Solar-Altitude Nomogram. **Photogrammetric Engineering**. v. 38, n. 9, p. 891-899. 1972.

PAVLOV, S; PETROSYAN, A. The New Photogrammetric Method for Cloud Remote Studies. In: **International Archives of Photogrammetry and Remote Sensing**. Amsterdam: Committee of 19th International Congress ...v. XXXIII, part B7. 2000.

POHL, C. Multisensors Image Map: a Contribution to Topographic Map Updating in the Tropics. In: **International Archives of Photogrammetry**. Viena: Committee of 18th International Congress... v .XXXI, Part B4. P. 655-660.1996.

REINKE, D. L; COMBS, C. L; KIDDER, S. Q; HARR, T. H. Satellite Cloud Composite Climatologies: a new High-resolution Tool in Atmospheric Research and Forecasting. **Bulletin American Meteorological Society**. v. 73, n. 3, p. 278-285. mar 1992.

RICHARDS, J. A. **Remote Sensing Digital Image Analysis**. 2th ed. Springer-Verlag, 255 p. 1993.

ROSS, S. M. **Introduction to Probability Models**. 5th ed. San Diego, EUA: Academic Press, 1993.

ROSSOW, W. B. Comunicação pessoal recebida via email em 19.10.2000.

ROSSOW, W. B; SCHIFFER, R. A. Advances in Understanding Clouds from ISCCP. **Bulletin American Meteorological Society**. v. 80, n. 11, p. 2261-2287. Nov 1999.

ROSSOW, W. B; WALKER, A. W; BEUSCHEL, D.E; ROITER, M.D. **International Satellite Cloud Climatology Project (ISCCP) Documentation of New Cloud Datasets**. Nova York: NASA Goddard Institute for Space Studies. 1996. 115p, il.

SALOMONSON, V. **Cloud Statistics in Earth Resouces Technology Satellite (ERTS) Mission Planning**. NASA TM X-63674. Mariland, EUA: Goddard Space Fligth Center. 1969. 19 p.

SEIZ, G; BALTSAVIAS, M. Cloud Mapping Using Ground-based Imagers. In: **International Archives of Photogrammetry and Remote Sensing**. Amsterdam: Committee of the 19 th International Congress...v. XXXIII, part B7. 2000.

SHENK, W. E; SALOMONSON, V. **A Simulation Study Exploring the Effects of the Sensor Spatial Resolution on Estimates of Cloud Cover from Satellites**. NASA TN-D6247. Mariland, EUA: Goddard Space Flight Center. 10p. 1971.

SILVA, D. C; DALMOLIN, Q. Avaliação de Resolução de Imagens Digitais para Cadastro. In: **Congresso Brasileiro de Cadastro Técnico Multifinalitário-Cobrac 1998**. Florianópolis. Anais Florianópolis: UFSC. 1998. 1 CD.

_____. O Problema das Especificações em Serviços Aerofotogramétricos e Derivados. **Geodésia Online**, Florianópolis, n. 2. 2000a. Disponível em < <http://geodesia.ufsc.br/geodesia-online> > Acesso 6 out 2000.

_____. Mapa de Céu Claro para uso em Aerofotogrametria. In: **Congresso Brasileiro de Cadastro Técnico Multifinalitário- Cobrac 2000**. Florianópolis. Anais Florianópolis: UFSC. 2000b. 1 CD.

SLAMA, C. C (Ed). **Manual of Photogrammetry**. 4th ed. Falls Church, VA, EUA: American Society of Photogrammetry. 1980. 1056p. il.

SONNEMAKER, J. B. **Meteorologia**. São Paulo: ASA. 1997. 205 p. il.

STUBENRAUCH, C. J; ROSSOW, W. B; CHERUY, F; CHEDIN, A; SCOTT, N.A. Clouds as Seen by Satellite Sounders (3i) and Imagers (ISCCP). Part I: Evaluation of Cloud Parameters. **Journal of Climate**. v. 12, p. 2189-2213. Aug 1999.

SUDENE. **Catálogo das Cartas Topográficas do Nordeste do Brasil Escala 1:100.000**. Recife: Superintendência do Desenvolvimento do Nordeste. 1997. 275 p. il.







TAYLOR, H. M; KARLIN, S. **An Introduction to Stochastic Modeling**. 2 th. San Diego, EUA: Academic Press. 1994. 566 p.


THOMAS, M. K. Sunshine Data for Planning Aerial Photography. **The Canadian Surveyor**. p. 36-46. Mar 1963.

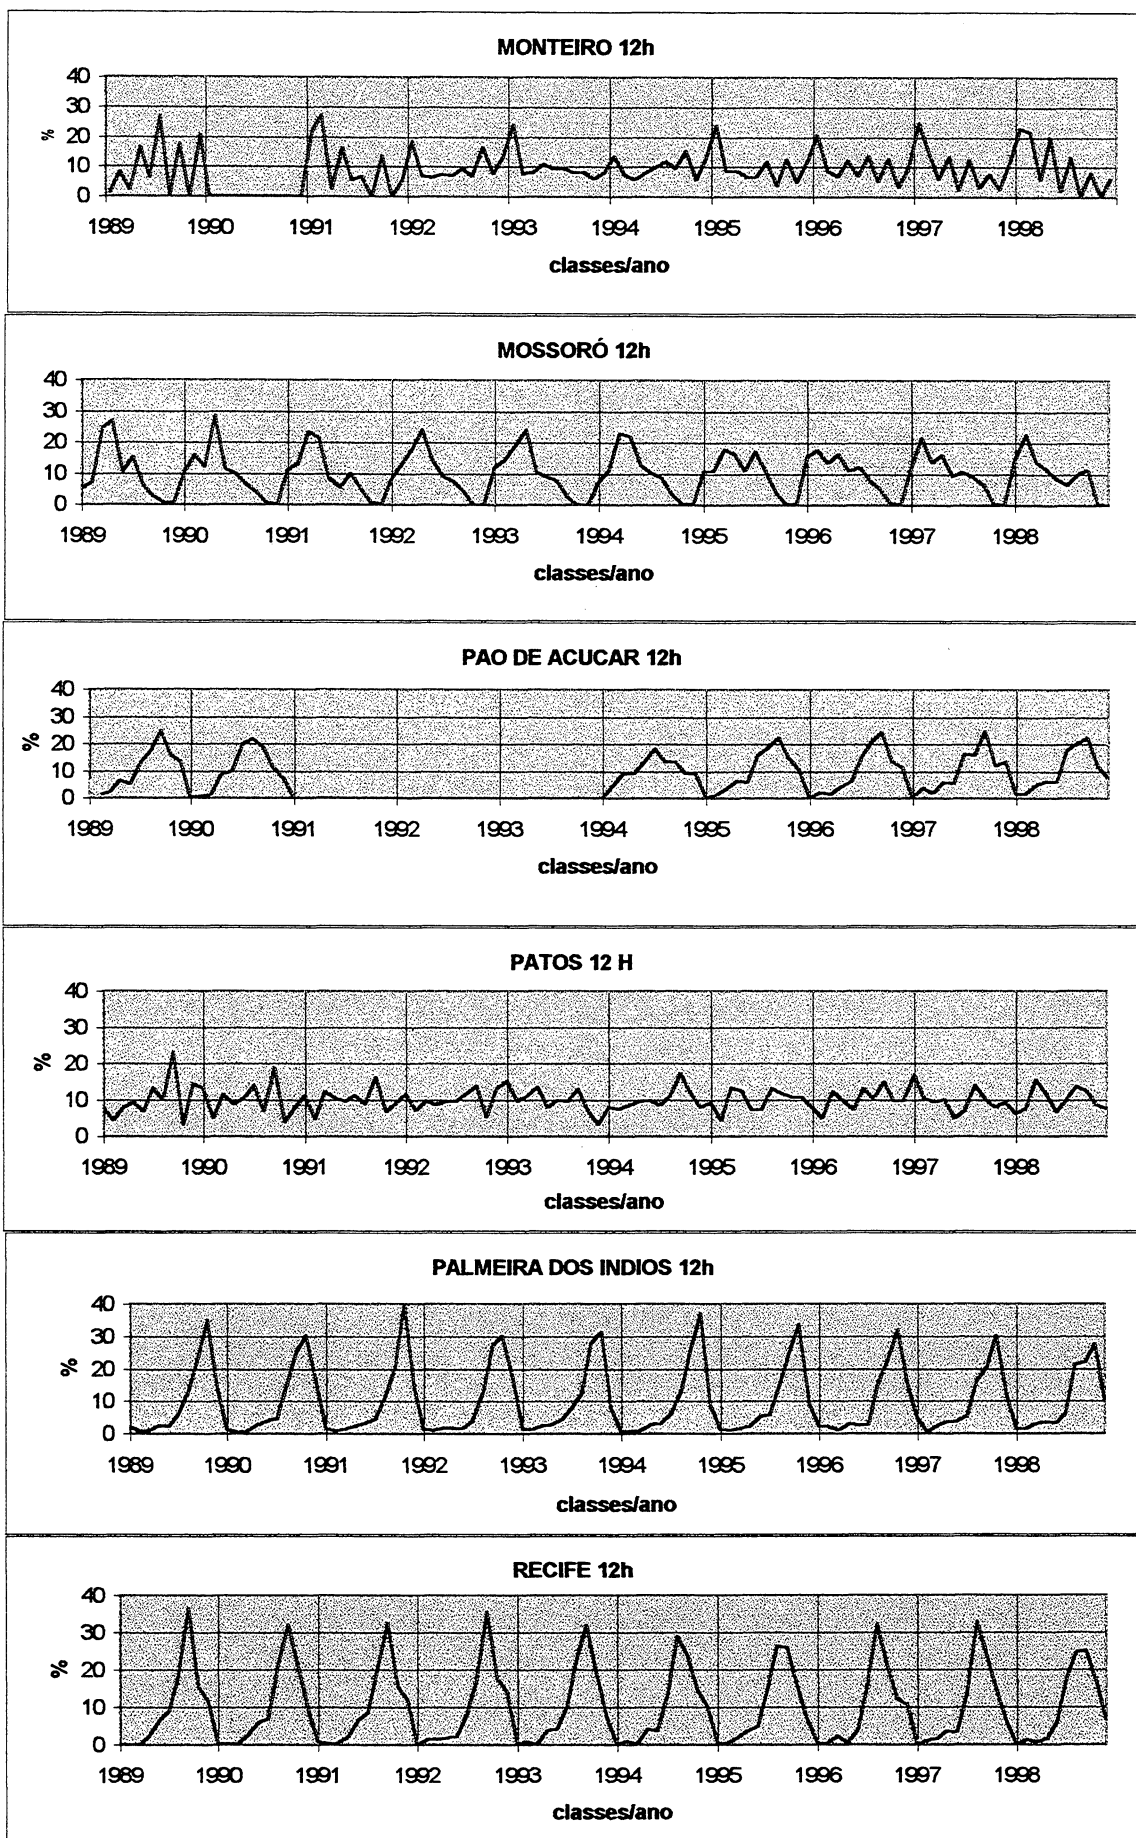
TORSANI, J. A; VISWANADHAM, Y. **Distribuição de Nebulosidade Total no Brasil**. INPE-2575-PRE/223. São José dos Campos: Instituto Nacional de pesquisas Espaciais. 1982. 14 p.





VANICEK, P; KRAKIWSKY, E. J. **Geodesy: the Concepts**. 2th ed. Amsterdam: Elsevier Science Publishers. 1986. 696 p. il.

WEARE, B. C. Combined Satellite and Surface Observations of Clouds. **Journal of Climate**. v. 12, p. 897-913. 1999.

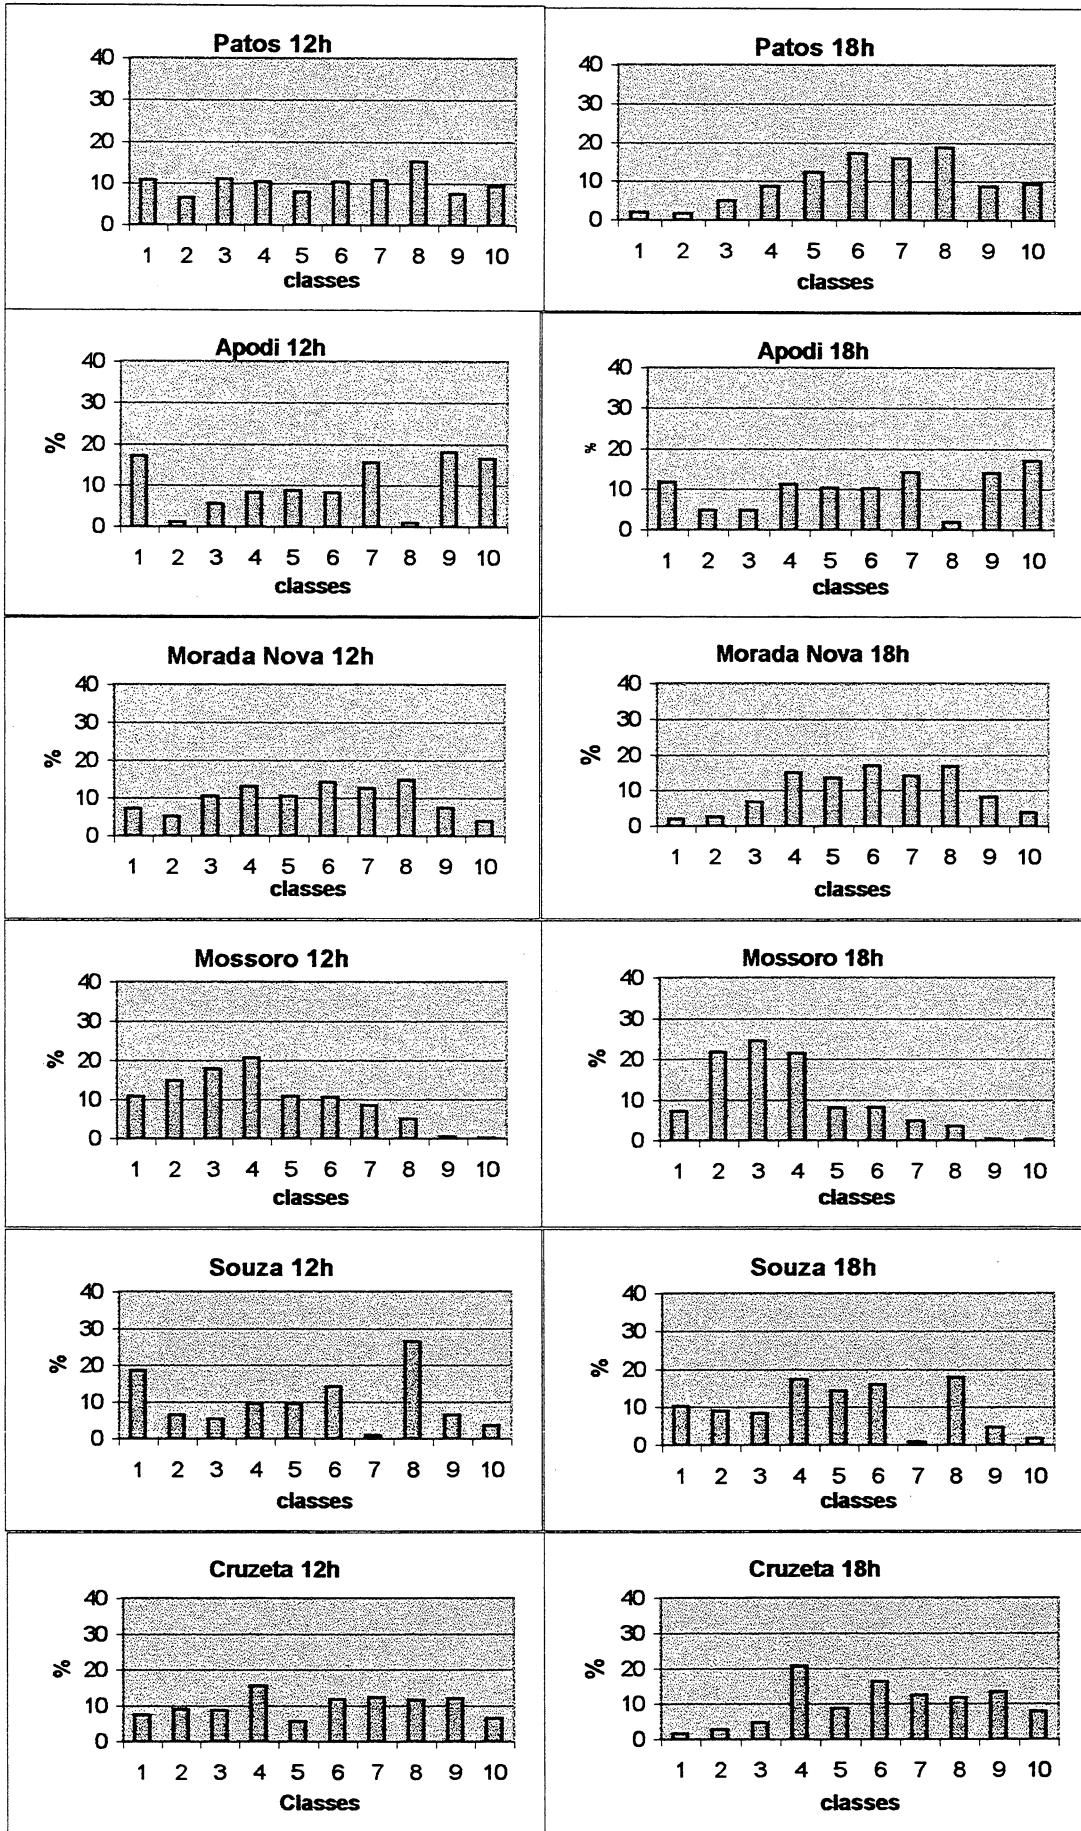










Anexo 2: Histogramas da Média Geral



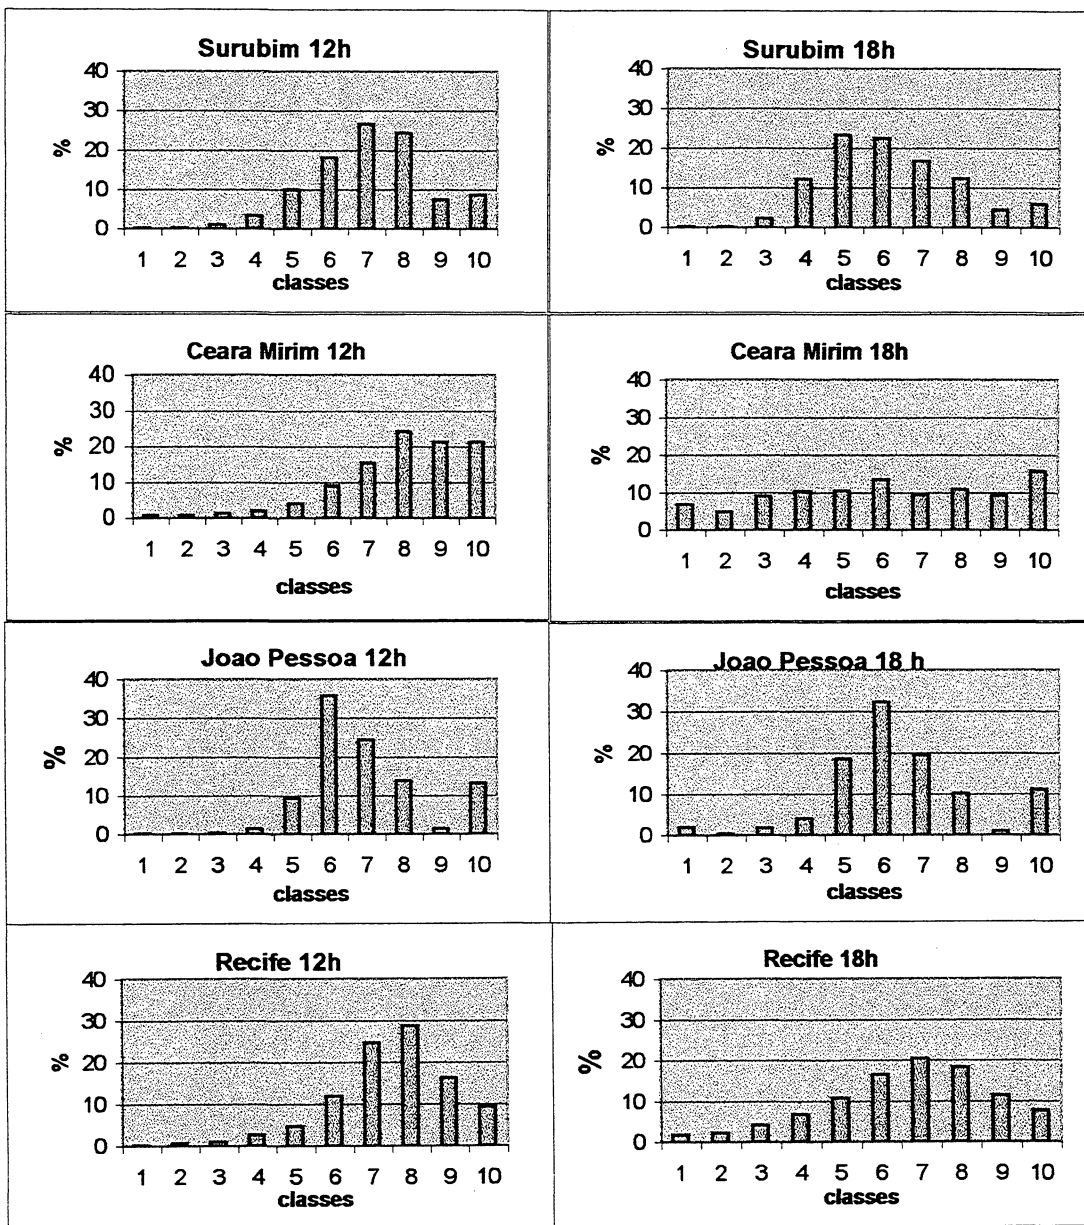
Anexo 2: Histogramas da Média Geral



Anexo 2: Histogramas da Média Geral



Anexo 2: Histogramas da Média Geral



Anexo 3 - Médias Mensais

Água branca


82989 12

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	11.6	7.8	5.8	2.7	3.2	2.7	0.0	1.3	12.2	19.9	16.1	19.9
20	2.6	5.7	3.2	1.3	0.0	0.0	0.0	0.0	2.2	1.6	3.9	5.4
30	6.5	9.9	2.6	4.0	2.6	0.0	0.0	2.6	6.1	6.5	6.1	3.2
40	5.2	7.8	8.4	2.7	3.2	0.7	1.6	1.9	2.8	7.0	10.0	12.9
50	2.6	7.1	0.6	4.0	0.0	0.7	0.8	1.3	3.9	2.7	4.4	2.2
60	7.7	12.8	12.3	6.0	8.4	2.0	1.6	1.3	7.2	7.0	9.4	9.7
70	25.8	18.4	25.2	17.3	17.5	11.3	6.5	8.4	17.2	21.5	15.6	17.7
80	23.9	17.7	23.9	33.3	30.5	30.0	27.4	39.4	27.2	23.1	22.8	21
90	10.3	10.6	12.3	17.3	16.2	18.0	25.0	15.5	12.8	6.5	5.6	5.9
100	3.9	2.1	5.8	11.3	18.2	34.7	37.1	28.4	8.3	4.3	6.1	2.2


82989 18

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	2.6	0.7	1.9	4.0	1.3	4.0	1.6	4.5	9.4	14.5	7.2	6.5
20	1.9	0.7	1.3	3.3	1.3	4.0	4.8	2.6	2.8	3.8	1.1	3.2
30	6.5	4.3	4.5	6.7	7.1	6.0	5.6	8.4	15.6	14.5	9.4	10.2
40	9.7	15.6	9.0	9.3	7.1	8.0	7.3	11.6	18.3	19.9	15.0	16.1
50	9.0	9.9	5.8	4.0	2.6	4.7	5.6	7.7	7.2	8.6	4.4	7.5
60	18.1	24.8	20.6	15.3	16.8	10.0	16.9	16.1	17.2	15.1	20.0	19.9
70	25.8	22.0	23.9	19.3	31.0	16.7	15.3	15.5	17.8	16.7	23.9	18.8
80	19.4	10.6	16.1	24.0	19.4	21.3	23.4	16.8	8.3	2.7	11.1	11.8
90	5.8	9.9	11.0	7.3	5.8	10.0	10.5	4.5	1.7	2.7	5.0	5.9
100	1.3	1.4	5.8	6.7	7.7	15.3	8.9	12.3	1.7	1.6	2.8	0.0

12h



18h



Anexo 3 - Médias Mensais

Apodi


82590 12

1	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	5.4	11.9	4.3	7.8	45.2	25.0	38.7	24.6	33.3	23.9	13.3	7.6
20	1.1	1.2	1.1	0.0	0.0	0.0	1.6	1.6	1.7	3.3	0.0	1.1
30	3.2	3.6	3.3	5.6	6.5	6.7	4.8	11.5	15.0	4.3	4.4	3.3
40	6.5	7.1	6.5	13.3	3.2	6.7	6.5	19.7	6.7	10.9	6.7	4.3
50	8.6	10.7	9.8	7.8	9.7	11.7	12.9	9.8	6.7	9.8	3.3	6.5
60	8.6	7.1	8.7	4.4	6.5	11.7	6.5	6.6	5.0	10.9	8.9	10.9
70	30.1	14.3	17.4	17.8	0.0	10.0	3.2	13.1	5.0	19.6	15.6	19.6
80	0.0	0.0	3.3	0.0	0.0	0.0	0.0	0.0	0.0	1.1	3.3	2.2
90	19.4	25.0	20.7	26.7	16.1	16.7	6.5	8.2	18.3	3.3	28.9	19.6
100	17.2	19.0	25.0	16.7	12.9	11.7	19.4	4.9	8.3	13.0	15.6	25.0


82590 18

1	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	7.7	6.0	9.7	3.3	12.9	15.3	16.1	23.0	30.0	19.6	4.4	5.4
20	3.3	3.6	4.3	1.1	0.0	8.5	6.5	8.2	11.7	5.4	6.7	0.0
30	0.0	4.8	1.1	0.0	12.9	10.2	8.1	6.6	10.0	5.4	4.4	4.3
40	7.7	7.1	6.5	8.9	9.7	5.1	12.9	13.1	16.7	21.7	14.4	10.9
50	9.9	6.0	6.5	6.7	16.1	11.9	12.9	14.8	10.0	12.0	8.9	14.1
60	6.6	16.7	7.5	14.4	6.5	5.1	6.5	4.9	3.3	16.3	12.2	12.0
70	22.0	16.7	15.1	22.2	9.7	10.2	4.8	13.1	10.0	9.8	16.7	10.9
80	0.0	3.6	6.5	0.0	0.0	1.7	0.0	0.0	0.0	1.1	3.3	4.3
90	19.8	10.7	21.5	21.1	9.7	16.9	8.1	8.2	3.3	4.3	17.8	16.3
100	23.1	25.0	21.5	22.2	22.6	15.3	24.2	8.2	5.0	4.3	11.1	21.7

12h



18h



Anexo 3 - Médias Mensais

Arcoverde


82890 12

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	2.8	1.9	2.8	1.3	1.8	1.1	1.3	2.3	4.8	7.8	4.3	7.1
20	7.4	12.8	11.5	10.1	9.2	7.4	4.6	9.3	15.1	18	15.3	15.9
30	5.1	7	8.8	8.1	5.1	3	4.6	3.6	7.9	10.5	10.3	6.8
40	10.1	14.3	12	9.1	11.1	9.6	4.3	10.6	12.7	14.7	15	13.9
50	14.7	16.3	9.2	7.4	6.9	5.9	6	7.9	7.6	11.8	8.3	12.5
60	20.3	14.7	20.3	18.9	17.1	15.2	14.9	13.9	17.9	13.4	14	12.9
70	12.4	8.9	12	15.8	12	10.7	10.6	8.6	12	8.8	10.7	7.8
80	14.7	14	13.8	15.8	13.8	17.4	16.9	15.2	11	9.8	11	12.5
90	8.3	6.6	5.5	6.4	9.7	9.6	16.6	13.6	5.2	2.9	8.3	6.4
100	4.1	3.5	4.1	7.1	13.4	20	20.2	14.9	5.8	2.3	2.7	4.1


82890 18

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	0	0	0	0	0	0.4	0.7	0.7	0.7	1.3	0.3	1.3
20	1.4	3.9	4.6	5.7	4.2	3.7	2	7	6.2	10.1	5.7	4.6
30	2.8	3.1	5.1	3	1.9	5.9	2.3	3	8.3	7.2	2.7	6.6
40	7.4	10.5	11.5	12.8	13.9	10.4	9.9	14.6	15.2	14.4	12	7
50	18	14.7	16.1	13.8	14.4	15.9	12.6	19.2	22.8	21.9	15.3	17.9
60	22.6	25.6	29	24.9	22.7	19.6	22.5	23.5	26.6	27.8	29.3	27.2
70	11.1	14	9.7	11.8	6.9	15.6	11.6	11.6	8.3	8.5	13.3	10.9
80	20.7	19	14.7	17.2	19.9	11.1	14.9	10.6	6.6	5.9	14	14.9
90	9.7	5.8	6	7.1	5.6	9.6	11.3	5.6	3.1	2.6	5.7	5.6
100	6.5	3.5	3.2	3.7	10.6	7.8	12.3	4.3	2.4	0.3	1.7	4

12h



18h



Anexo 3 - Médias Mensais

Areia


82696 12

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	0	0	0	0.5	0	1.4	0	0	0	0.5	0	0
20	0	0	0	0	0	0.5	0	1.4	0	0	0	0.5
30	0	0	0	0	0.9	0	0.5	0.5	0.5	0.5	0	0
40	1.1	2.2	1.4	1.9	3.2	2.9	1.8	1.8	3.3	0	1.1	2.2
50	0.5	3.4	2.3	1.4	5.5	2.9	3.7	2.8	1.9	1.8	2.2	5.4
60	6.5	6.2	6	6.7	6.9	2.4	4.6	4.1	4.8	7.4	10	8.1
70	26.9	21.3	23.5	15.8	16.1	18.6	12.9	9.7	24.8	34.6	31.7	33.9
80	26.3	36.5	33.6	31.6	23.5	18.1	20.3	30	30.5	35.9	36.7	30.1
90	20.4	19.7	15.7	19.6	15.2	13.8	14.7	17.1	10.5	8.3	11.1	9.1
100	18.3	10.7	17.5	22.5	28.6	39.5	41.5	32.7	23.8	11.1	7.2	10.8


82696 18

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	0	0	0	0	0.5	0	0	0	1.9	0.9	0	0
20	0.5	1.1	0	1.4	0.5	1.4	1.9	0	2.4	3.2	0.6	2.7
30	3.8	0.6	2.8	2.4	2.8	2.4	0.9	5.1	6.2	6.5	2.8	2.7
40	8.1	4.5	6.5	4.3	8.3	6.2	3.2	9.3	13.3	21.7	8.3	4.3
50	11.3	7.9	2.3	3.3	5.5	4.8	3.7	5.6	8.1	10.1	8.9	18.8
60	22.6	16.9	18	14.8	14.3	13.4	12.5	14.4	22.9	28.1	31.1	28
70	24.2	19.1	22.6	23.3	18	15.3	22.2	26.9	21.9	16.1	27.8	19.4
80	11.8	25.3	18.4	17.1	18.4	15.8	19.9	16.2	10.5	8.3	13.3	15.6
90	9.1	12.4	15.2	16.2	12.9	12.9	13.9	6	6.7	2.3	3.3	4.8
100	8.6	12.4	14.3	17.1	18.9	27.8	21.8	16.7	6.2	2.8	3.9	3.8

12h



18h



Anexo 3 - Médias Mensais

cabrobo


82886 12

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	1	0.7	1	0.3	1.4	0	2.2	4	8.1	11.3	4.1	4.6
20	1.3	1.1	0.7	0.7	1.1	2.6	0.9	1.6	3.7	7.3	4.8	5.1
30	4.5	3.5	2	3	4.3	0	1.8	4.8	6.7	7.7	6.7	9.3
40	3.2	3.5	1.6	2.3	3.6	0	1.8	2.4	3.7	6	4.8	7.4
50	1.3	2.5	5.9	2.7	2.9	2.6	2.2	2	4.1	4.4	5.2	6
60	17.1	13.8	7.8	9.7	11.1	17.9	11	8.1	14.1	16.1	13.7	19.4
70	21.6	25.2	20.2	23	21.9	20.5	23.7	20.2	20	21.4	26.3	24.5
80	21	24.5	31.6	27	21.5	7.7	18.9	19	16.7	14.1	14.1	10.6
90	17.1	17	15.3	19.7	17.2	28.2	19.7	19.8	12.2	6.5	11.9	6.5
100	11.9	8.2	14	11.7	15.1	20.5	18	18.1	10.7	5.2	8.5	6.5


82886 18

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	0.3	0	0.7	0	0.4	0	1.3	5.6	4.1	3.2	0.4	0
20	1	0	0	1	1.4	0	2.6	4	6.3	6.5	3.8	0.5
30	2.6	0.7	1	2.3	5	0	3.1	9.7	17.8	14.5	7.1	3.5
40	0.6	2.5	2.6	3.7	4.7	7.7	5.7	9.7	10	15.3	5.8	6
50	5.8	4.6	6.2	8	6.5	5.1	7.9	6.5	8.9	7.7	5	6.5
60	23.2	27.3	28.3	33	30.1	23.1	26.8	31.5	29.6	26.6	25	25.5
70	27.4	34	30.9	28	24.4	28.2	25	17.7	13.7	19.4	30.8	30
80	21	16.3	19.2	17.7	14.3	20.5	14	8.5	6.3	5.2	13.3	14.5
90	12.9	12.1	7.8	5	11.1	10.3	10.5	4	1.9	1.2	5	12
100	5.2	2.5	3.3	1.3	2.2	5.1	3.1	2.8	1.5	0.4	3.8	1.5

12h



18h



Anexo 3 - Médias Mensais

Campina Grande


82795 12

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	0	0	0	0.7	0.3	0.7	0.3	0.6	0.7	1.3	0	1
20	0	0.4	0.6	1.3	1.6	0.3	0.3	1.6	1.7	1	0.3	2.6
30	1.7	2.5	1.3	0.7	3.5	1.3	2.9	3.2	3.3	1.3	1	1.9
40	1.7	2.5	2.9	2.7	2.9	3.7	1.9	2.9	3.7	2.9	1.3	6.1
50	5.2	8.5	10.6	6.7	6.5	6.3	6.1	7.4	12.7	17.1	12.7	13.9
60	8.7	9.2	7.7	7.3	8.1	5.3	3.2	3.9	6.3	9	9.3	12.6
70	10.7	8.9	8.4	8.7	8.7	10	7.4	8.4	8	11	14.7	10
80	36	34.4	38.1	32.3	26.1	23	21.9	26.1	37	34.5	34.3	28.4
90	24.2	22.7	16.1	26.3	16.1	13.7	14.2	13.9	11	12.9	16.3	10
100	11.8	11	14.2	13.3	26.1	35.7	41.6	31.9	15.7	9	10	13.5


82795 18

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	0.3	0.4	0	0.3	0.6	0	0.3	0	2.3	2.6	0.3	1
20	0.3	0	0.3	1	0.6	1.3	1	0	2	2.9	1.7	6.1
30	1.4	1.8	1.3	0.7	1.9	3.7	2.3	2.9	5	5.8	2	4.5
40	6.2	4.3	3.5	4	5.8	5.3	4.8	5.8	15	15.5	14.7	11.6
50	15.2	13.8	14.2	11.7	16.8	14.7	12.6	22.6	27.7	23.9	24.3	24.2
60	19.4	17.7	17.7	13.7	12.3	12	9.7	20	21.3	23.5	21	16.1
70	17	11.3	14.2	17.7	10	9.3	11.6	11.9	10.7	11.9	14.7	11.3
80	17.3	21.3	21.3	17.7	17.7	16.7	18.1	14.8	7.7	7.1	9	8.4
90	14.9	17.7	12.6	17.3	16.1	14.3	19.7	8.7	4	4.2	8.3	10
100	8	11.7	14.8	16	18.1	22.7	20	13.2	4.3	2.6	4	6.8

12h



18h



Anexo 3 - Médias Mensais


Ceara Mirim
82596 12

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez	media
10	0	0.4	0.3	0	0.3	0.8	1.9	3.2	0.4	0.3	0.4	0	0.7
20	0	0	0	0	0.7	1.6	3.9	1.9	0	0.3	0.4	0.4	0.8
30	0	0.4	0.3	0	2	1.6	3.2	2.3	2.5	1.3	0.7	0	1.2
40	0.7	0.4	0.6	0.3	1.3	4.4	6.1	2.9	3.3	1.9	0.7	0.8	2
50	4.6	3	1.9	2	4.6	4	3.6	5.8	5.8	6.1	2.6	5.7	4.1
60	10.5	10	6.5	6	12.1	9.3	6.5	9.4	10.4	10.4	8.5	8.9	9
70	13.4	14.9	12	14.4	15.1	12.9	14.2	11.7	17.5	21.7	20	19.8	15.5
80	26.6	25.7	22.1	20.1	22.6	19	14.6	21.7	28.8	30.7	33	27.9	24.2
90	25.2	24.5	29.5	21.7	17.4	19	18.8	18.8	19.6	18.4	19.6	20.6	21.2
100	19	20.8	26.6	35.5	23.9	27.4	27.2	22.3	11.7	8.7	14.1	15.8	21.3


82596 18

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez	media
10	3.6	3	2.3	3	10.5	7.7	7.5	12.3	15.9	8.4	3	5.3	6.8
20	4.9	4.8	2.6	3.4	2.9	3.6	5.5	6.8	8.8	6.8	5.2	4	4.9
30	8.5	5.9	6.5	6	8.5	4.8	6.8	11.3	13.4	12.9	11.9	13.8	9.1
40	13.4	7.8	9.7	6.4	7.2	8.1	10.4	6.8	10.9	18.1	12.6	10.1	10.2
50	12.5	12.3	7.4	6.7	10.1	10.1	7.8	9	9.6	14.9	10.4	15.8	10.5
60	13.1	20.1	14.9	10.7	10.1	15.3	8.4	12.6	14.6	13.6	13.8	15.4	13.4
70	8.2	11.5	6.8	10.7	9.8	6.9	9.4	10.6	9.2	9.1	12.6	7.7	9.4
80	11.8	8.9	10.4	10.4	9.2	12.9	13	13.5	7.1	10.4	12.6	8.1	10.8
90	8.2	11.2	14.2	11.7	11.1	11.7	11.7	6.5	4.6	2.9	8.6	9.3	9.3
100	15.7	14.5	25.2	30.9	20.6	19	19.5	10.6	5.9	2.9	9.3	10.5	15.6

12h



18h



Anexo 3 - Médias Mensais

Cruzeta


82693 12

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	1.9	1.4	1.9	1.3	4.8	9.3	10.6	14.8	19	13.2	4.3	4.8
20	3.2	2.8	3.2	6.7	13.5	10.3	9.7	13.9	12.7	11.6	11	9.4
30	5.5	4.6	9.1	4.7	11	8.3	8.4	8.7	9.7	11.9	10.7	10.3
40	14.8	13.5	13.3	14.7	16.8	15	15.8	14.2	17	18.7	14.3	17.7
50	8.7	6	5.5	7	2.9	2.3	4.8	6.1	4	6.1	5	7.7
60	12.3	17.8	11.7	12	8.7	9.3	7.4	11.9	11	12.6	13.3	13.2
70	14.8	18.9	16.8	9.3	13.5	10.7	7.7	8.7	9.3	9.7	15.3	12.6
80	13.9	16.7	16.8	16.3	10.6	11.3	10	4.5	8	8.4	13	10
90	15.8	11	15.5	22.3	11.6	15	13.5	7.4	5.7	6.1	8.7	10
100	9	7.1	6.1	5.7	6.5	8.3	11.9	9.7	3.7	1.6	4.3	4.2


82693 18

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	0.3	0.4	0	0	1.3	0.7	2.3	4.2	4.7	3.2	1	0.6
20	0.6	0.4	0.3	0	1.9	4	4.2	4.5	6	5.5	2	2.6
30	2.6	1.8	0.6	2	4.2	6	4.8	8.1	7.7	8.4	7	3.6
40	13.5	11.4	9.1	14	21	18	22.3	25.8	31	27.8	26.7	26.2
50	4.8	8.5	6.5	7.7	3.2	5	6.5	13.5	14.3	12.9	14	8.7
60	14.5	17.1	13.9	17.3	15.5	15.7	15.2	15.8	20	18.1	15.7	16.8
70	19.4	17.8	19.4	13	10.3	7	9.4	8.1	9.7	12.6	13.3	10.4
80	17.4	13.2	14.9	9	15.8	16	11.6	7.1	3	8.1	10	13.6
90	15.5	21	26.9	21.3	17.4	13.3	13.5	8.7	2.7	1.9	7.7	11.3
100	11.3	8.5	8.4	15.7	9.4	14.3	10.3	4.2	1	1.3	2.7	6.1

12h



18h



Anexo 3 - Médias Mensais

garanhuns


82893 12

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	6.1	6.4	4.3	3.5	4.2	1.7	2.9	1.6	5.9	10	8.3	13.1
20	5.3	4.5	5	3.5	2.6	2.4	0.7	1.6	1.4	5.2	5.7	11.3
30	6.1	9.1	6.1	3.8	1.6	0.7	2.2	0.7	2.8	5.6	5.7	7.3
40	6.5	4.5	5.4	4.8	3.6	2.4	1.1	0.7	2.8	4.8	7.8	6.5
50	13	10.5	9.6	9	7.8	7	1.8	3.3	4.9	10	8.3	8.7
60	8	9.5	10.4	8.7	8.2	2.4	4.3	4.9	7	5.2	10.9	10.5
70	14.1	20.5	13.6	14.2	12.4	9.4	12	13.4	17.5	17.7	13	12.7
80	21.8	12.7	21.1	17.3	16.3	16.4	10.9	14.4	17.8	20.8	17	13.1
90	7.6	10	9.3	10	13.7	13.9	12.7	15.7	12.2	8.7	12.6	7.3
100	11.5	12.3	15.4	25.3	29.4	43.6	51.4	43.6	27.6	12.1	10.9	9.5


82893 18

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	2.3	1.4	1.1	1.4	2.6	0.7	1.8	0	4.9	7	1.3	6.9
20	2.3	1.4	1.1	2.1	2	2.4	1.4	1.3	3.5	8.7	3.9	11.3
30	5.3	5.9	2.9	4.8	7.2	3.1	2.9	3.9	9.7	10	13.2	10.5
40	9.9	10	9	5.9	8.9	8.4	4.3	6.9	10.1	19.2	13.6	10.2
50	21.8	21.4	23.7	18.7	17.7	12.6	11.6	14.8	25.3	21.8	22.8	20
60	17.2	11.4	16.1	12.1	6.2	8	11.2	14.1	15.3	11.4	13.6	9.8
70	16.4	16.8	12.9	12.5	11.1	9.8	9	15.8	10.1	11.8	12.3	10.9
80	8.8	7.7	5.4	11.8	8.5	12.2	9.7	8.2	4.9	4.4	7.5	4
90	9.2	6.4	12.5	11.4	11.5	11.2	8.7	8.9	4.2	3.1	5.3	8
100	6.9	17.7	15.4	19.4	24.3	31.5	39.4	26	12.2	2.6	6.6	8.4

12h



18h



Anexo 3 - Médias Mensais

João Pessoa


82798 12

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	0.7	0	0	0	0	0	0	0	0.7	0.6	0	0
20	0	0	0	0	0	0	0	0	0	1.3	0.3	0
30	0	0.4	0	0	0.3	0.3	0.3	0.6	0.4	1	0	0.6
40	1.1	1.1	2.3	0.7	1.3	0.3	1.6	1.9	1.1	2.3	2.1	1
50	13.9	7.1	6.6	6.1	6.5	4	5.9	11	13.4	16.8	9.4	10.6
60	38.8	41.8	41.6	33	28.6	25.2	24.8	28.5	36.4	40.3	47.2	45.2
70	24.9	25	24.3	29.6	25.6	27.2	23.5	25.9	23	19.4	20.8	25.2
80	13.2	13.6	10.5	10.5	15.3	16.8	20.5	12.9	17.1	11.3	14.2	10
90	1.8	1.1	0.3	1.4	1.6	3.4	1.6	1	0.7	1.3	1	1
100	5.5	10	14.4	18.7	20.8	22.8	21.8	18.1	7.1	5.8	4.9	6.5


82798 18

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	1.5	2.5	2.6	1	0.3	1.7	1.3	3.9	3	3.9	0.3	1.3
20	0	0	0.3	0	0.3	0	0	0	0	1.9	0	0.3
30	2.6	1.4	1.7	1	1.3	0.7	2	1	1.5	2.3	1.4	3.2
40	5.5	4.3	4.6	4.4	2.6	1.7	2.6	4.5	3.7	6.5	4.2	3.6
50	20.5	17.3	18.2	14.9	14	11.5	10.2	16.5	25.4	25.5	24.3	24.6
60	36.6	34.2	38.3	31.5	27.4	24.1	26.3	26.9	32.8	31.9	36.8	39.8
70	18.7	19.1	14.2	20.7	22.5	22.4	21.7	21.7	18.3	18.1	18.1	18.1
80	9.9	12.2	6.6	9.2	13.7	14.2	15.1	11	9	4.5	9.7	6.1
90	0	0.7	0.3	1	2.6	1.7	1.3	0.3	0.7	1.3	0.3	0
100	4.8	8.3	13.2	16.3	15.3	22	19.4	14.2	5.6	4.2	4.9	2.9

12h



18h



Anexo 3 - Médias Mensais

Maceió


82994 12

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	0	2.7	0.4	1.3	1.4	1.9	0	0	0	0	0	0
20	0	2.7	3.3	2.9	4.2	5.3	0	0	0	0	0	0
30	0.9	1.3	2.4	2.1	4.6	2.9	1.2	1.2	1.4	1.2	0.5	0
40	2.8	3.1	2	2.9	3.2	3.4	1.6	4.4	3.3	6.9	6.7	2.3
50	6.5	4.4	6.1	2.5	3.7	3.9	2	1.2	6.7	4	4.3	7.8
60	26.7	20.4	21.5	17.1	13.4	16.9	13.3	12.5	20	27.5	20	32.7
70	18.9	21.3	22	15.4	19	16.9	13.3	16.9	17.6	20.2	26.7	18.4
80	31.3	28.9	25.6	20.8	22.2	21.3	27.8	29.4	27.6	28.7	28.6	25.8
90	7.8	9.8	10.6	22.5	9.7	11.6	14.1	12.9	15.2	7.7	7.6	8.3
100	5.1	5.3	6.1	12.5	18.5	15.9	26.6	21.4	8.1	3.6	5.7	4.6


82994

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	0	4	2	0.8	2.3	3.4	0	0	1	0.4	1	0.5
20	1.4	4	2.5	2.5	3.2	4.8	0.4	0.4	0.5	0	0	0
30	6.5	6.7	11.1	4.6	8.8	4.3	2.4	1.6	7.6	4.9	3.3	2.8
40	29.5	18.7	17.6	8.3	10.6	5.8	6.5	11.7	11	19.6	19.5	22.1
50	10.6	10.7	9.8	8.8	6.9	7.7	6	4.8	12.9	23.3	15.2	18
60	18.9	15.6	20.5	20.8	17.6	17.4	18.1	23	25.7	24.5	23.3	21.2
70	15.7	18.7	15.6	16.3	16.2	18.4	16.9	20.2	17.6	16.3	17.6	18.9
80	12	10.7	13.1	17.1	19	19.3	22.6	16.9	13.8	7.3	12.4	10.6
90	3.2	4.9	3.3	10.8	8.8	10.6	8.9	9.3	4.8	1.6	3.8	4.1
100	2.3	6.2	4.5	10	6.5	8.2	18.1	12.1	5.2	2	3.8	1.8

12h



18h



Anexo 3 - Médias Mensais

M Nova


82588 12

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	1	0.7	2.3	3.8	2.6	8.5	12.9	19.7	17.8	11.3	2.7	2.6
20	4.5	3.2	1.8	1	3.5	4.4	7.9	9.7	11.7	5.2	4	3.2
30	5.8	4.6	3.7	6.7	9.7	15.6	18.6	17.1	16.4	11.9	7.3	6.5
40	11.9	11.7	9.7	12.4	12.9	15.6	19.7	12.9	15.8	14.5	10	10
50	9.7	10.6	7.4	11.9	11.6	9.6	8.6	10.3	8.7	12.6	12.3	12.9
60	17.4	12.8	16.1	13.3	17.1	15.9	6.8	7.7	10.7	12.6	20.7	20
70	14.5	16.7	17.5	16.7	15.5	11.5	7.2	4.8	4.7	12.3	15	16.8
80	17.1	20.9	21.2	17.1	15.2	11.9	10.8	9.4	8.7	11	20	18.1
90	10	11	12	9	10	4.4	4.7	5.5	4.7	6.5	7	6.8
100	8.1	7.8	8.3	8.1	1.9	2.6	2.9	2.9	0.7	2.3	1	3.2


82588 18

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	1	0	0	0	0.6	1.5	2.9	6.5	5	5.2	1	0.6
20	1	0.4	0.9	0	2.6	1.9	5	6.1	6.7	3.5	1	1.3
30	3.5	1.1	1.8	3.3	3.5	6.7	10	9.7	13.4	10.3	7.3	8.1
40	7.1	6	3.7	8.6	10.6	15.2	20.4	20	23.2	23.2	20	15.8
50	12.6	7.8	6.9	8.1	13.9	10.4	12.9	19.4	15.4	19.7	17	13.5
60	12.6	13.5	16.1	16.2	16.8	15.9	12.2	14.2	20.5	22.9	21	20.6
70	14.5	20.6	15.7	18.6	18.1	16.3	10.8	10.6	8.7	7.7	12.7	17.4
80	23.9	28.4	27.2	22.4	20.3	19.6	15.1	8.4	6	5.8	15	14.8
90	16.5	13.5	20.3	14.3	10.3	8.5	6.1	3.2	0.7	1.3	4.7	5.2
100	7.4	8.9	7.4	8.6	3.2	4.1	4.7	1.9	0.3	0.3	0.3	2.6

12h



18h



Anexo 3 - Médias Mensais

Monteiro


82792 12

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	13.7	12.2	11.5	10.8	14.1	18.1	18.5	25.5	37.8	40.1	25.3	32.7
20	7.3	9.3	10.7	8.8	10.5	11.9	7.9	11.1	8.9	13.2	17.6	18.8
30	7.3	3.9	9	5	5.6	5.7	5.1	7.2	7.2	7.2	6	8.9
40	9.8	18	12.7	12.9	11.3	4.8	7.4	14.4	9.4	13.8	13.7	10.4
50	8.3	6.8	8.2	4.6	7.7	6.2	4.2	4.8	7.2	3.6	5.6	6.4
60	11.7	17.1	16.4	17.1	11.7	15.2	10.2	8.2	11.7	7.8	8.6	7.4
70	7.8	7.3	5.3	6.3	6	3.3	2.8	2.9	3.3	4.2	3.9	3.5
80	16.1	13.2	10.7	17.9	13.3	12.9	12	10.6	8.3	7.2	9	8.9
90	5.9	6.8	3.7	3.8	3.2	8.6	7.9	2.9	2.2	0.6	2.1	1
100	12.2	5.4	11.9	12.9	16.5	13.3	24.1	12.5	3.9	2.4	8.2	2


82792 18

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	5.8	4.9	2.5	3.4	5.2	10.5	3.7	12.4	16.1	13.8	10.3	9.4
20	10.7	6.9	6.7	9.7	12.9	11.9	16.6	15.3	18.9	21	18.9	18.3
30	4.9	7.4	10.9	7.6	8.9	6.7	9.2	16.3	15	16.2	12	13.4
40	14.1	17.6	23.4	22.8	19.8	21	20.3	25.4	22.8	24	24.9	25.7
50	9.2	8.3	7.1	5.5	7.3	7.6	6.9	6.7	6.7	7.8	5.6	9.9
60	18.4	25.5	18.4	16.5	17.7	12.4	16.6	7.2	10.6	9.6	12	12.9
70	8.3	6.4	3.3	6.8	3.6	7.1	8.8	2.9	1.7	1.8	4.3	4
80	17.5	13.7	15.9	16	11.7	11	9.7	7.7	4.4	3	7.3	5
90	3.4	3.4	4.6	3.8	2	5.2	3.2	1.9	2.8	1.8	0.4	0.5
100	7.8	5.9	7.1	8	10.9	6.7	5.1	4.3	1.1	1.2	4.3	1

12h



18h



Anexo 3 - Médias Mensais

Mossoro


82591 12

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	3.2	0.4	2.5	5	11.2	16.4	22.9	28.1	22.2	9.4	3.3	2.9
20	9.7	11.3	11.1	13.4	15.1	17.4	20	20.3	22.2	15.2	10	12.5
30	15.2	23	12.2	15.1	23	25.8	17.1	14.8	16.7	20.3	17.5	14.7
40	23.2	26.2	20.4	19.4	19.4	18.4	15.5	13.5	17.4	22.9	27.9	25.8
50	12.3	11	16.5	14	10.8	9	6.1	6.1	8.5	10.3	12.5	13.3
60	14.8	11.7	13.3	12.4	10.8	6	5.8	8.4	6.7	9	11.3	17.9
70	11.9	9.6	15.1	11.7	5.4	4.3	6.5	5.2	4.8	9	9.2	10
80	8.4	6	7.9	7.7	4.3	2.7	5.5	2.3	1.5	3.5	7.9	2.5
90	1	0.7	0.4	1	0	0	0.3	1.3	0	0.3	0.4	0.4
100	0.3	0	0.7	0.3	0	0	0.3	0	0	0	0	0


82591 18

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	1.6	0.4	2.2	2	1.8	2.7	3.5	6.5	16.7	21.6	15.4	13.3
20	16.1	16	11.8	10.3	16.1	17.1	18.4	21.9	33.5	36.1	36.7	29.7
30	23.5	24.8	16.8	17	23.7	22.7	26.1	33.9	29.4	25.2	25.4	25.1
40	25.5	23.8	28.3	23	22.6	25.1	23.2	22.9	14.1	12.6	14.2	20.1
50	10.3	12.8	10.4	10.3	11.1	10.7	7.1	6.5	4.1	1.6	5.4	5
60	9	8.9	11.8	19	11.1	10.7	12.6	4.2	1.9	2.3	0.8	3.6
70	9.4	6	9	10.3	7.9	4.7	4.5	2.6	0.4	0.6	1.3	0.7
80	3.5	7.1	8.2	5	5.4	6	3.9	1.6	0	0	0.8	1.1
90	0.6	0	0.4	1.7	0.4	0.3	0.6	0	0	0	0	1.1
100	0.3	0.4	1.1	1.3	0	0	0	0	0	0	0	0.4

12h



18h



Anexo 3 - Médias Mensais

Pao de Acucar


82990 12

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	0	1.2	0	0	1	0	0	0	0.7	1.3	0.7	0
20	1.9	2.5	1.1	0.6	1	0.7	0.6	1.9	3.3	6.5	3.3	0.6
30	1.9	3.7	1.1	0.6	4.8	2.7	0.6	2.6	5.3	1.9	3.3	3.9
40	5.8	8.6	9.2	6.1	5.3	3.3	6.5	5.2	6.7	6.5	6	4.5
50	6.5	8.6	8.1	4.5	6.3	4	4.5	5.8	5.3	7.7	3.3	8.4
60	13.5	23.3	18.4	15.1	13	10	10.4	16.2	18.7	21.9	14	17.4
70	25.8	17.8	21.6	20.1	16.9	15.3	13	14.9	16.7	25.2	20	20
80	27.7	19	21.6	25.7	18.4	24	16.2	27.9	24	19.4	28	29
90	11	12.9	12.4	15.6	15.9	16.7	19.5	11.7	13.3	7.7	14	9
100	5.8	2.5	6.5	11.7	17.4	23.3	28.6	13.6	6	1.9	7.3	7.1


82990 18

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	0	0	0	0	0	0	0	0	0	0	0	0
20	0	0	0	0.6	0	0.7	0	0	0.7	3.2	0.7	0.6
30	1.9	3	2.2	1.1	2.9	2.7	1.3	4.5	4	8.4	3.3	0
40	7.1	8.5	5.4	3.9	9.2	4	3.2	3.9	16	18.1	12	9
50	12.3	12.2	13.5	9.4	9.2	8.7	6.5	9	13.3	20	16.7	16.8
60	25.2	25.6	17.3	11.7	15	18	15.6	23.9	28	20.6	25.3	29.7
70	17.4	16.5	18.9	13.9	15	12.7	19.5	13.5	18.7	9.7	15.3	12.9
80	23.2	16.5	20	25.6	21.3	25.3	24.7	20.6	12	14.8	14	17.4
90	5.2	12.2	13.5	20	12.6	11.3	11.7	14.8	5.3	3.9	8.7	5.2
100	7.7	5.5	9.2	13.9	15	16.7	17.5	9.7	2	1.3	4	8.4

12h



18h



Anexo 3 - Médias Mensais

Patos


82791 12

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	3.9	2.1	5.9	3.3	5.6	12.1	12	20.8	25.4	18.8	8	9.9
20	2.3	2.8	1.6	3	8.8	7.7	6.8	10.7	9.8	7.9	8.7	8.2
30	7.7	6	7.2	9	15	11.1	13.6	12.7	13.6	15.8	11	9.9
40	9.7	11.7	8.9	11.4	13.4	10.4	6.5	6.8	11.5	12.2	14.4	8.5
50	10	8.9	9.2	7.7	9.2	6	7.8	7.1	8.1	8.3	5.7	8.5
60	10.6	12.4	13.1	16.1	9.8	8.7	9.1	7.8	7.8	8.9	11.7	8.9
70	15.8	15.2	14.4	11	8.5	8.1	7.8	8.4	8.1	8.3	11.4	13.3
80	16.5	19.5	16.7	19.7	14.4	16.4	16.5	10.4	6.4	14.2	14.4	17.4
90	11.6	8.5	9.5	9	5.6	9.1	7.4	7.8	4.4	2.6	8.7	5.5
100	11.9	12.8	13.4	9.7	9.8	10.4	12.6	7.5	4.7	3	6	9.9


82791 18

1	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	0.6	0	0	0.3	1	1.7	1.9	5.5	7.7	3.9	0.7	1
20	0.3	0	0	0.3	1.3	2	1.6	4.8	4.7	4.5	0.3	0.7
30	0.6	2.5	1.3	2.3	5.8	6.7	5.2	6.5	12.8	8.7	4	3.4
40	3.5	6.4	9.2	11	11.3	5	6.1	10.6	12.8	15.5	6.4	6.8
50	9	9.9	12.2	10	11.3	12.7	11.3	13.9	17.4	17.1	14	10.2
60	15.2	18.1	14.1	14	12.9	16.3	16.5	19.7	17.4	20.6	24.4	18.4
70	17.4	17	13.5	14.3	15.8	11	16.8	16.5	13.4	15.8	16.7	23.2
80	27.4	24.1	22	19.7	18.7	18	21	12.9	10.1	10.3	21.1	20.5
90	11.9	8.2	16.8	15.3	11.3	9.3	6.8	5.2	2	2.6	7.4	8.2
100	13.9	13.8	10.9	12.7	10.6	17.3	12.9	4.5	1.7	1	5	7.5

12h



18h



Anexo 3 - Médias Mensais

Palmeira dos Índios


82992 12

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	1.3	0.7	0.7	1.1	1.5	0.4	0.3	0.3	3	5.8	1.3	5.5
20	0.3	1.1	0.4	0	1.5	0	0.3	1	1	2.9	1	2.9
30	1.6	3.9	0.4	1.5	1.5	0.7	0.3	1	1.7	2.6	2	2.6
40	2.3	3.9	3.2	1.1	2.5	2.2	0	1.6	4.3	4.5	3	4.5
50	2.9	5	4.7	2.6	2.2	1.9	2.9	2.9	2.3	2.9	4	5.8
60	4.8	8.2	5	5.2	4.4	4.1	2.6	3.5	4	6.8	5.3	8.7
70	17.4	14.9	17.6	12.3	13.8	11.1	11.3	10.6	15.3	17.7	17.3	15.8
80	21.6	25.5	28	29.4	20.7	20.7	21.3	22.6	23.7	27.4	27.3	20
90	40.3	31.2	34.4	37.9	36.7	30.4	31.9	35.2	30.3	23.2	32	31.3
100	7.4	5.7	5.7	8.9	15.3	28.5	29	21.3	14.3	6.1	6.7	2.9


82992 18

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	0	0	0.4	0.7	1.8	0.4	0	0	3.3	4.2	0	1.3
20	0.3	0	0.4	0	0.4	0.4	0.6	0	1.7	1.6	0.7	3.9
30	0.6	0.7	0	0.7	0.7	1.1	0.3	0.6	1.7	3.9	3.3	1.9
40	1.3	2.1	0.4	5.2	4	5.2	4.2	1.9	5	7.4	4.3	5.2
50	1.6	3.5	3.6	4.1	7.6	3.7	3.5	4.2	7	8.1	6.3	7.1
60	7.7	8.5	9.7	7.8	9.5	7.8	8.7	11.6	14.3	14.2	14	10.4
70	19	14.2	17.9	12.6	10.9	11.9	13.5	20.3	25	22.7	16.7	18.8
80	22.3	21.6	23.7	16.7	20	20	14.5	12.3	14.7	18.8	21.3	17.5
90	36.1	42.9	32.6	36.4	28	31.1	26.1	30.6	20.3	16.2	27.3	29.1
100	11	6.4	11.5	15.6	17.1	18.5	28.4	18.4	7	2.9	6	4.9

12h



18h



Anexo 3 - Médias Mensais

Recife


82900 12

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	0	0.4	0	0	0	0.3	1	0.6	0.3	0	0	0
20	0.3	0	0	0	1.9	0.7	1	2.3	0	1	0.7	0
30	0	0.7	0.3	0.3	1	2	1.6	1	1.3	1	0	1.3
40	1.6	2.5	2.9	1	2.6	3	3.5	4.2	3.3	2.9	1.7	2.6
50	5.8	2.5	4.2	3.7	4.8	5.3	4.2	6.5	5.3	3.5	4.7	5.2
60	9.7	10.4	10.3	8.7	11.9	12.3	14.5	11.3	13	14.8	11.1	13.9
70	28.1	28.9	31.3	25.7	19.7	20.3	17.7	19.7	27.7	22.9	24.7	30.1
80	29.7	30.7	31.6	32.3	23.2	22	23.2	24.2	29	34.2	35.1	30.7
90	13.9	15.7	13.2	17.3	19.4	17.3	17.4	21	13	15.2	17.9	12.6
100	11	8.2	6.1	11	15.5	16.7	15.8	9.4	7	4.5	4.1	3.6


82900 18

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	1	2.5	2.6	1.7	1.9	0.7	1.9	2.3	2	2.6	0.3	0.6
20	1.3	2.1	1.6	0.7	2.3	1	1.9	2.6	4.7	3.2	1.7	4.2
30	4.8	2.9	2.6	2	5.8	5	4.8	4.5	5.3	3.9	1.7	6.1
40	7.7	9.6	10.7	5.3	4.5	6.3	3.5	5.5	7.7	6.1	6.4	8.7
50	7.7	11.8	8.4	8	9	9.3	8.1	12.7	11.3	13.9	15.5	12.6
60	21.6	14.3	17.8	15.3	14.8	14.3	15.2	11.7	18	19	19.3	16.5
70	17.1	23.6	22	21.3	22.9	15.3	16.5	20.5	20.3	22.6	22.3	22
80	22.6	13.9	20.7	20.3	14.8	18	20	16.9	16.3	16.1	21.3	18.4
90	10	12.5	9.4	16.7	14.2	17	13.9	11.7	9.3	8.1	5.7	8.1
100	6.1	6.8	4.2	8.7	9.7	13	14.2	11.7	5	4.5	5.7	2.6

12h



18h



Anexo 3 - Médias Mensais

Serido


82690 12

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	5.4	2.4	0	4.4	8.9	10	8.9	21	32.5	19.4	6.7	8.9
20	1.1	2.4	3.2	1.1	4	15	8.1	8.9	11.7	9.7	3.3	7.3
30	8.6	9.4	9.7	11.1	12.9	10	12.9	14.5	16.7	12.9	13.3	12.9
40	19.4	17.6	12.9	18.9	18.5	15	12.9	12.9	11.7	13.7	18.9	16.1
50	6.5	15.3	9.7	12.2	6.5	8.3	8.9	5.6	5	12.1	8.9	18.5
60	10.8	14.1	14	13.3	12.1	10	10.5	8.9	12.5	6.5	13.3	9.7
70	16.1	16.5	12.9	14.4	12.9	10	15.3	11.3	4.2	13.7	10	13.7
80	16.1	10.6	16.1	12.2	13.7	10.8	9.7	8.9	3.3	7.3	11.1	12.1
90	10.8	9.4	18.3	8.9	5.6	8.3	10.5	5.6	2.5	4	12.2	0
100	5.4	2.4	3.2	3.3	4.8	2.5	2.4	2.4	0	0.8	2.2	0.8


82690 18

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	2.2	0	0	0	0.8	2.5	0.8	0	9.2	8.1	0	0.8
20	0	0	0	1.1	2.4	1.7	4	6.5	11.7	12.1	3.3	2.4
30	3.2	5.9	6.5	7.8	5.6	10	7.3	10.5	17.5	9.7	12.2	9.7
40	11.8	18.8	11.8	15.6	15.3	13.3	17.7	29	22.5	28.2	15.6	24.2
50	24.7	17.6	14	16.7	13.7	11.7	13.7	21	18.3	17.7	18.9	21
60	17.2	15.3	18.3	18.9	23.4	19.2	12.9	13.7	11.7	9.7	17.8	13.7
70	18.3	15.3	8.6	20	13.7	10.8	12.9	9.7	5	7.3	8.9	15.3
80	10.8	15.3	22.6	7.8	13.7	13.3	12.1	4	3.3	4.8	10	6.5
90	6.5	10.6	12.9	7.8	8.9	14.2	14.5	5.6	0.8	2.4	11.1	5.6
100	5.4	1.2	5.4	4.4	2.4	3.3	4	0	0	0	2.2	0.8

12h



18h



Anexo 3 - Médias Mensais

São Gonçalo Souza


82689 12

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	7.7	6.4	7.1	5.7	11.7	25.7	27.5	38.7	33.6	27.1	16.7	0
20	2.9	2.1	1.6	3.3	8.1	9.7	7.8	8.6	10.4	8.7	7.3	0
30	2.6	1.4	3.9	4.7	5.5	5.7	4.9	7.9	10.1	6.8	5	2.4
40	8.1	7.1	7.1	6	9.1	12	10.7	9.3	11.1	13.2	10.3	0
50	10.3	7.8	9.4	8	12.3	7.7	9.1	6.5	8.4	13.2	10.3	2.4
60	13.9	18.1	17.4	18.3	14.2	13.7	11	8.2	8.7	13.2	17.3	16.7
70	1.6	2.5	1	1.3	0.3	0.7	0.3	0	0.3	0.6	1.3	0
80	31.3	41.1	38.7	40	28.8	20.3	20.7	14.7	13.1	14.2	24.7	42.9
90	10.6	6.4	8.4	11.3	7.1	3.7	7.4	4.3	3	1.9	3.3	16.7
100	11	7.1	5.5	1.3	2.9	1	0.6	1.8	1.3	1	3.7	19


82689

	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	5.5	3.9	6.5	4.3	9.4	11.7	9.8	19.1	22.1	16.1	5	0
20	8.1	9.6	5.5	10.3	7.1	9.7	6.9	7.6	15.1	12.9	6	0
30	4.5	8.2	5.8	11.3	9.7	6.7	10.5	8.3	7	11.6	7.7	0
40	11.3	11.1	13.5	12.3	13.9	18	19	26.3	24.2	23.5	19.7	7.1
50	13.9	13.2	9.7	13.3	14.2	13	14.7	16.9	15.4	14.8	19.7	4.8
60	22.3	17.1	17.7	17.3	16.5	14	14.4	10.8	9.4	12.6	24	7.1
70	1.6	2.1	1.9	0.7	0.3	0.7	1	0	0	0	0.7	0
80	20.6	24.3	27.7	26.3	22	20	16.3	8.6	6	7.7	12.7	50
90	6.1	7.5	9.4	3.7	5.5	4	5.6	2.2	0.7	0.6	4	21.4
100	6.1	2.9	2.3	0.3	1.3	2.3	2	0.4	0	0	0.7	9.5

12h



18h



Anexo 3 - Médias Mensais

Surubim


82797 12

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	0	0	0	0	0	0	0	0	0	0	1	0
20	0	0	0	0	0	0	0.4	0	0	0	1.7	0
30	0	0.4	0.4	1.9	1.8	1.9	0.7	2.5	0.8	1	0.7	0.6
40	1.1	3.9	3.2	0.7	5.4	3.3	3.2	4.3	2.7	1.6	5.7	3.9
50	12.9	8.3	9.7	7.8	9	7.4	2.5	5.4	11.7	16.5	14	13.2
60	24.4	11.4	21.9	17	16.1	10	15.1	15.4	21.5	21.4	17.3	23.9
70	23.7	29.1	29.7	24.8	25.1	25.9	25.8	27.6	28.9	25.2	26	29
80	24.7	32.7	25.4	30.4	23.3	23.3	21.9	22.9	19.9	26.5	23.7	19
90	6.5	7.9	3.9	10.7	9	10.4	12.2	6.5	5.1	5.5	6.7	6.1
100	6.8	6.3	5.7	6.7	10.4	17.8	18.3	15.4	9.4	2.3	3.3	4.2


82797 18

	1 jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
10	0	0	0	0	0	0	0	0	0	0.6	1.7	0
20	0.4	0	0	0	0	0	0	0	0	0.3	1	0
30	0.4	0.8	2.2	0.4	1.4	1.5	1.8	2.2	6.6	3.9	4	2.3
40	12.5	6.3	12.2	7.8	11.5	6.7	6.1	9.7	17.6	21.7	15.7	15.5
50	29.7	16.9	23.3	15.9	16.8	16.7	14.3	21.5	29.7	29.4	27.3	34.8
60	19	22.8	22.6	23.3	21.5	21.1	19	22.6	22.3	25.6	28.3	20.3
70	19	27.2	16.5	15.9	19.7	18.5	19.4	16.8	12.1	10.7	12	15.8
80	9.3	15.4	13.3	17	15.4	17.8	19.4	15.1	7.8	6.1	7.3	5.5
90	5.4	6.7	4.7	9.3	4.3	7.4	6.8	2.9	0.8	1.3	1.3	4.2
100	4.3	3.9	5.4	10.4	9.3	10.4	13.3	9.3	3.1	0.3	1.3	1.6

12h



18h



Anexo 3 - Médias Mensais

Triunfo


82789 12

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
10	19.4	16	19.8	15.7	22.4	19.1	13.5	29.6	50.5	40.1	35.4	32
20	14.9	16.4	13	15.7	11	6.5	5.3	12.9	12.4	15.1	18.3	18
30	2.8	2.7	3.2	1.3	1.1	1.7	3	2.2	1	5.7	0.8	2.2
40	8.9	13.3	13.8	11.7	7.7	7.8	6	4.3	7.6	12.2	11.3	11.5
50	10.1	10.7	7.3	5.4	3.7	4.3	6.4	5.4	6.2	9	8.8	9.4
60	12.1	5.3	8.5	9	7.7	7	6	6.5	5.7	6.1	5.4	9
70	11.7	12.9	10.9	8.1	5.9	8.7	7.9	9.1	6.7	4.3	8.3	3.6
80	3.2	7.1	4.5	7.6	5.1	4.8	6.4	4.3	2.9	1.4	2.1	2.9
90	7.7	8.9	8.9	13	10.3	7	7.9	6.5	4.8	3.9	5.8	9
100	9.3	6.7	10.1	12.6	25	33	37.6	19.4	2.4	2.2	3.8	2.5


82789 18

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
10	0.8	0.4	1.6	3.6	4	10	4.1	15.6	12.9	9	4.6	3.2
20	4.4	6.2	10.9	13.9	16.2	13.9	12	19.4	17.6	9.3	7.5	12.6
30	0.8	0.4	1.2	0.9	2.2	1.7	6.8	5.9	4.8	3.6	1.3	1.4
40	29	25.3	27.5	29.1	23.9	21.3	18	22.6	25.7	34.4	33.8	30.2
50	24.2	22.2	22.3	17	15.4	11.7	15	16.7	24.8	23.7	22.9	19.8
60	17.7	21.3	15	15.2	11.4	14.8	12.8	8.6	9	9.7	12.1	15.5
70	9.3	9.8	8.1	9.4	9.6	7.8	8.3	4.3	2.9	4.3	8.3	7.2
80	6	8.4	4.9	3.6	3.7	4.8	7.1	2.7	1.4	3.6	4.6	2.9
90	4.4	4.4	4	1.8	4.8	5.2	7.9	2.2	0.5	2.2	3.8	5
100	3.2	1.3	4.5	5.4	8.8	8.7	7.9	2.2	0.5	0.4	1.3	2.2





12h








18h







Morada Nova








Mossoro







Souza








APODI







CRUZETA







PATOS







SERIDO








ARCOVERDE







MONTEIRO








TRIUNFO







A BRANCA








CABROBO







P AÇUCAR








GARANHUNS







P DOS INDIOS







J PESSOA







AREIA








C GRANDE







SURUBIM








C MIRIM



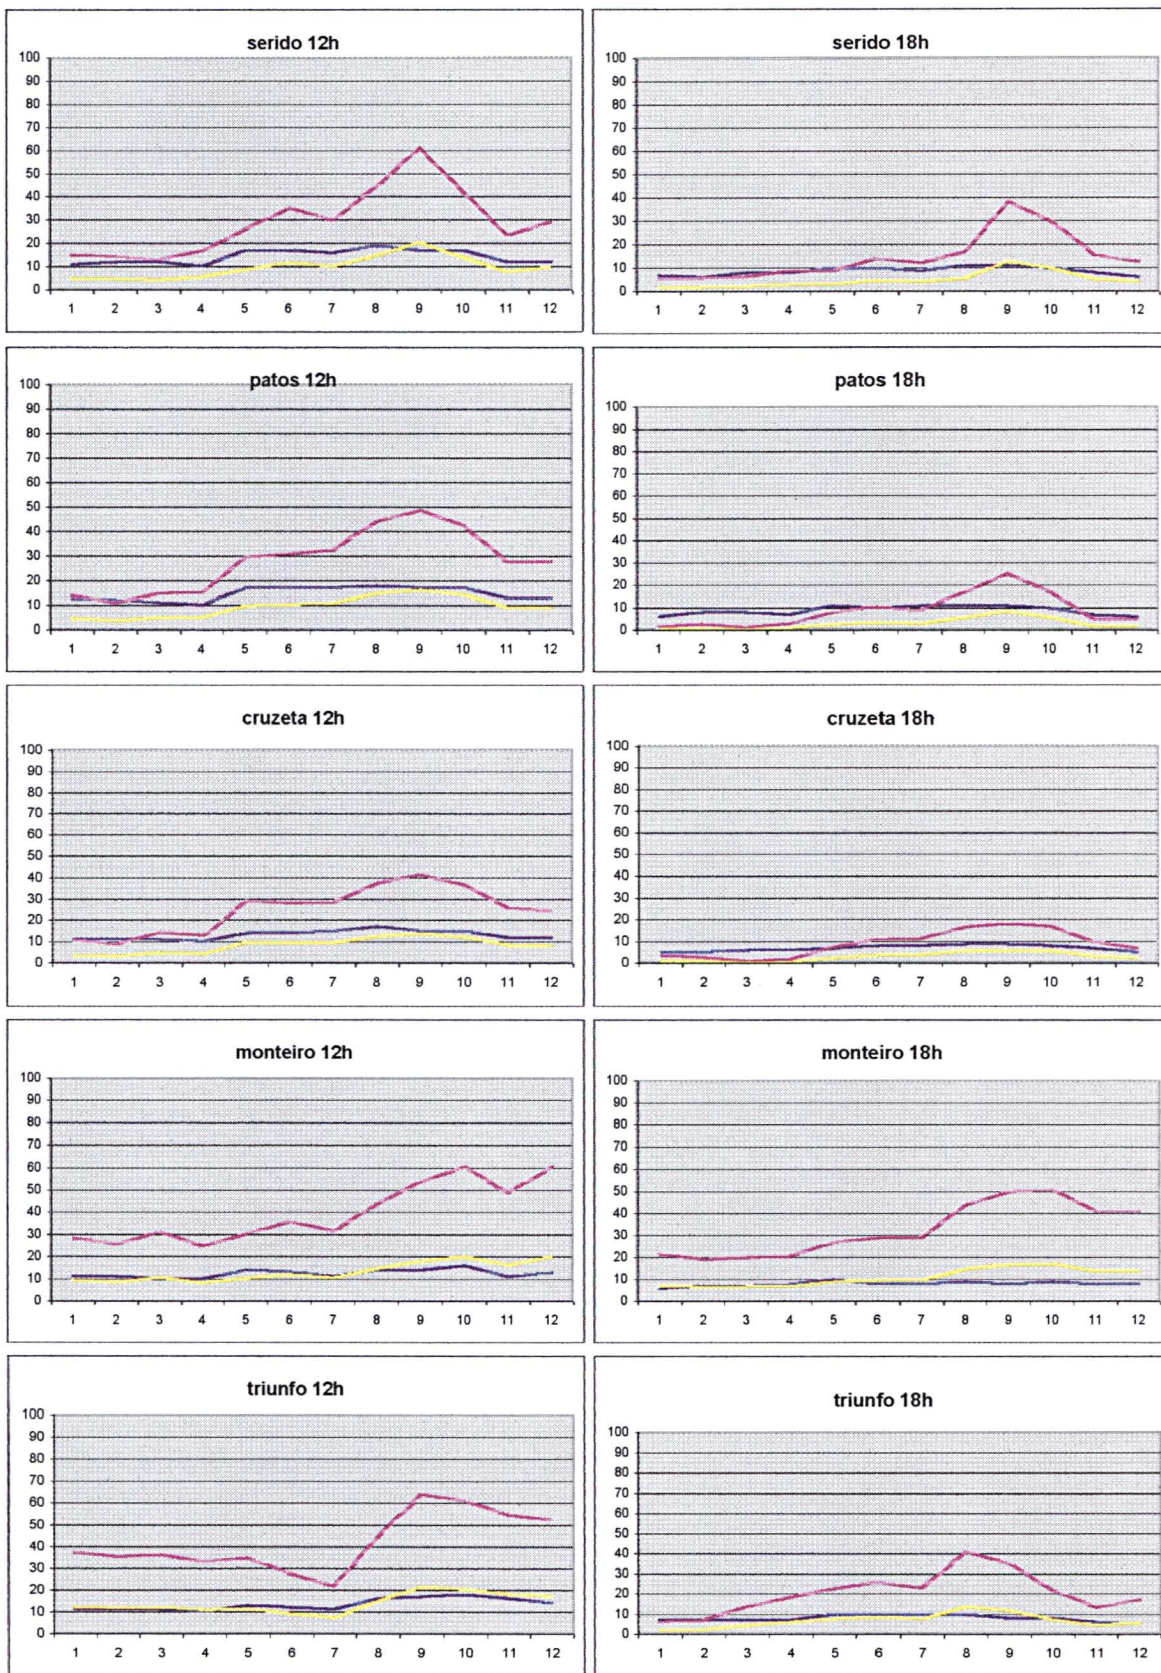
RECIFE



MACEIÓ

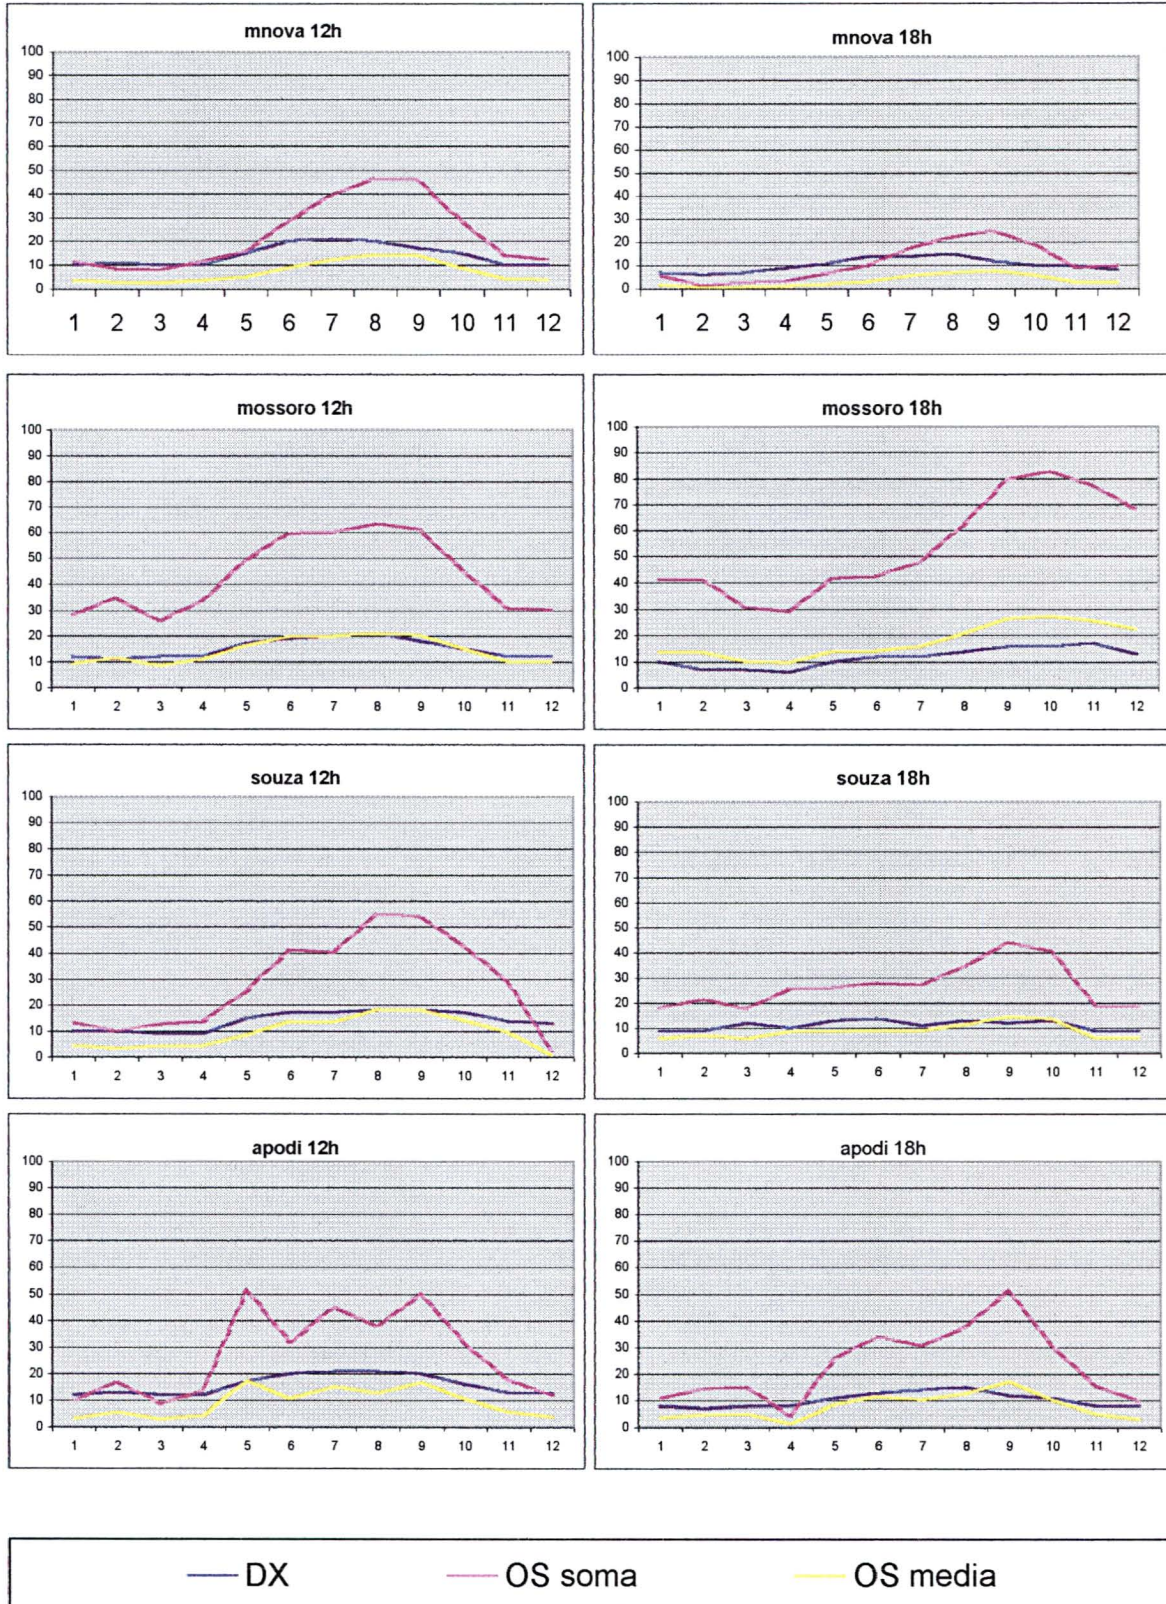


Anexo 5 - Gráficos de dados OS e DX


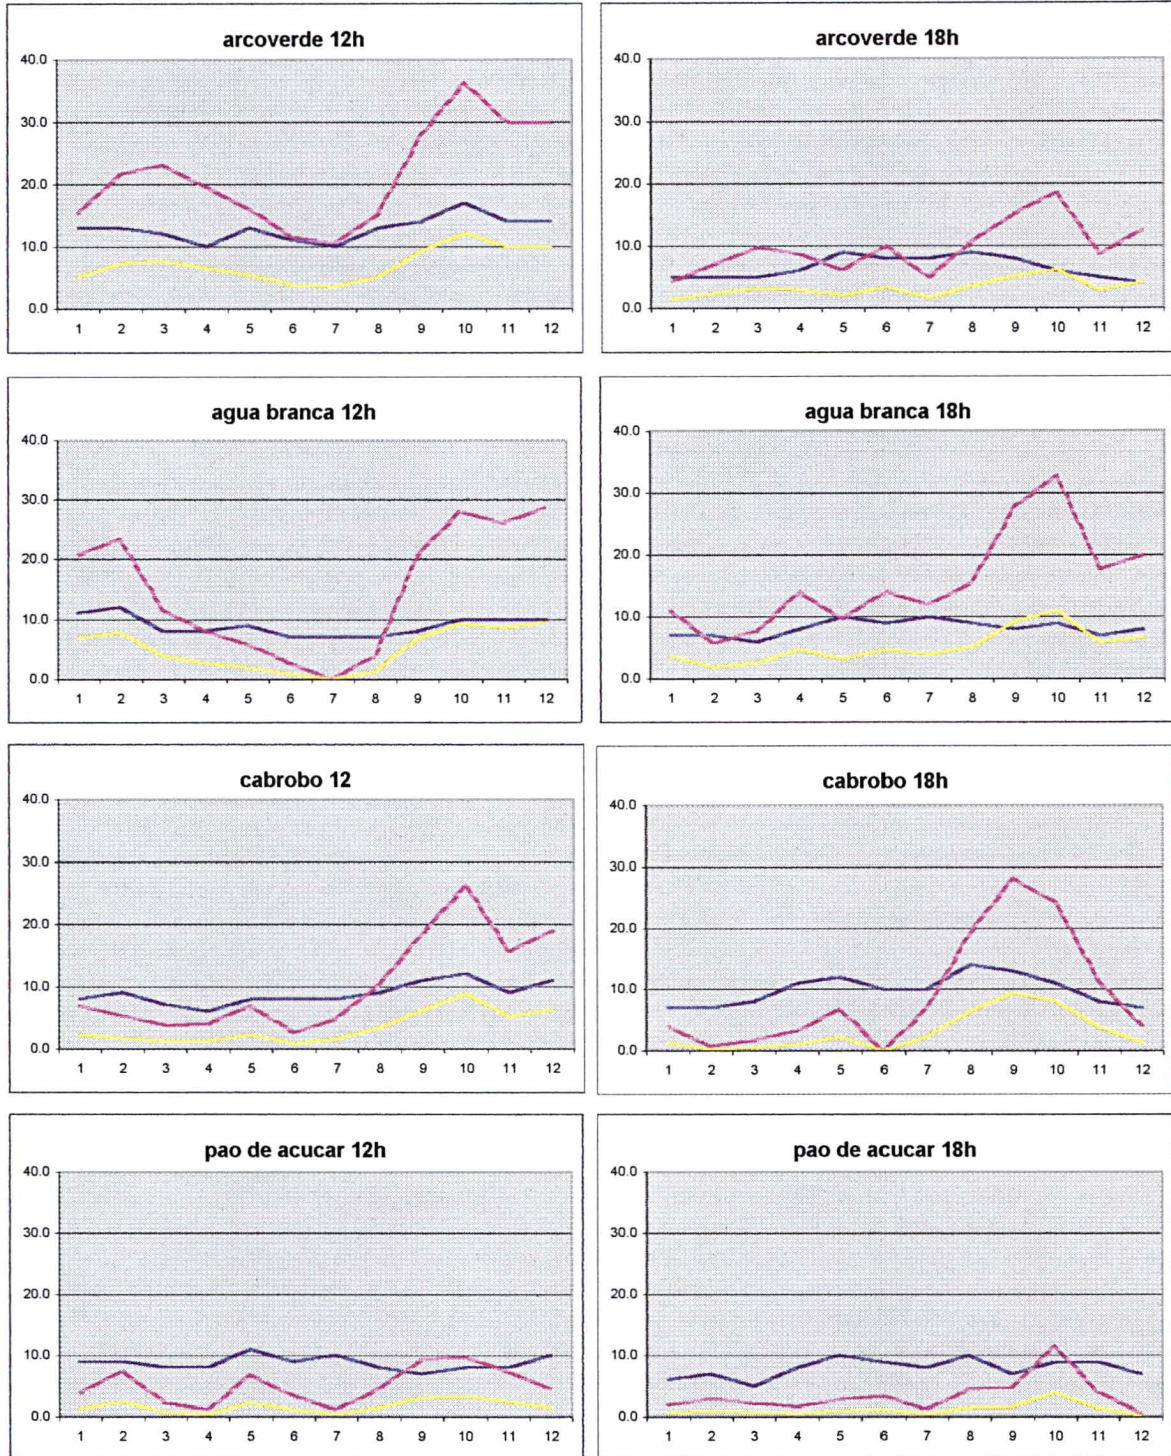


— DX — OS soma — OS media

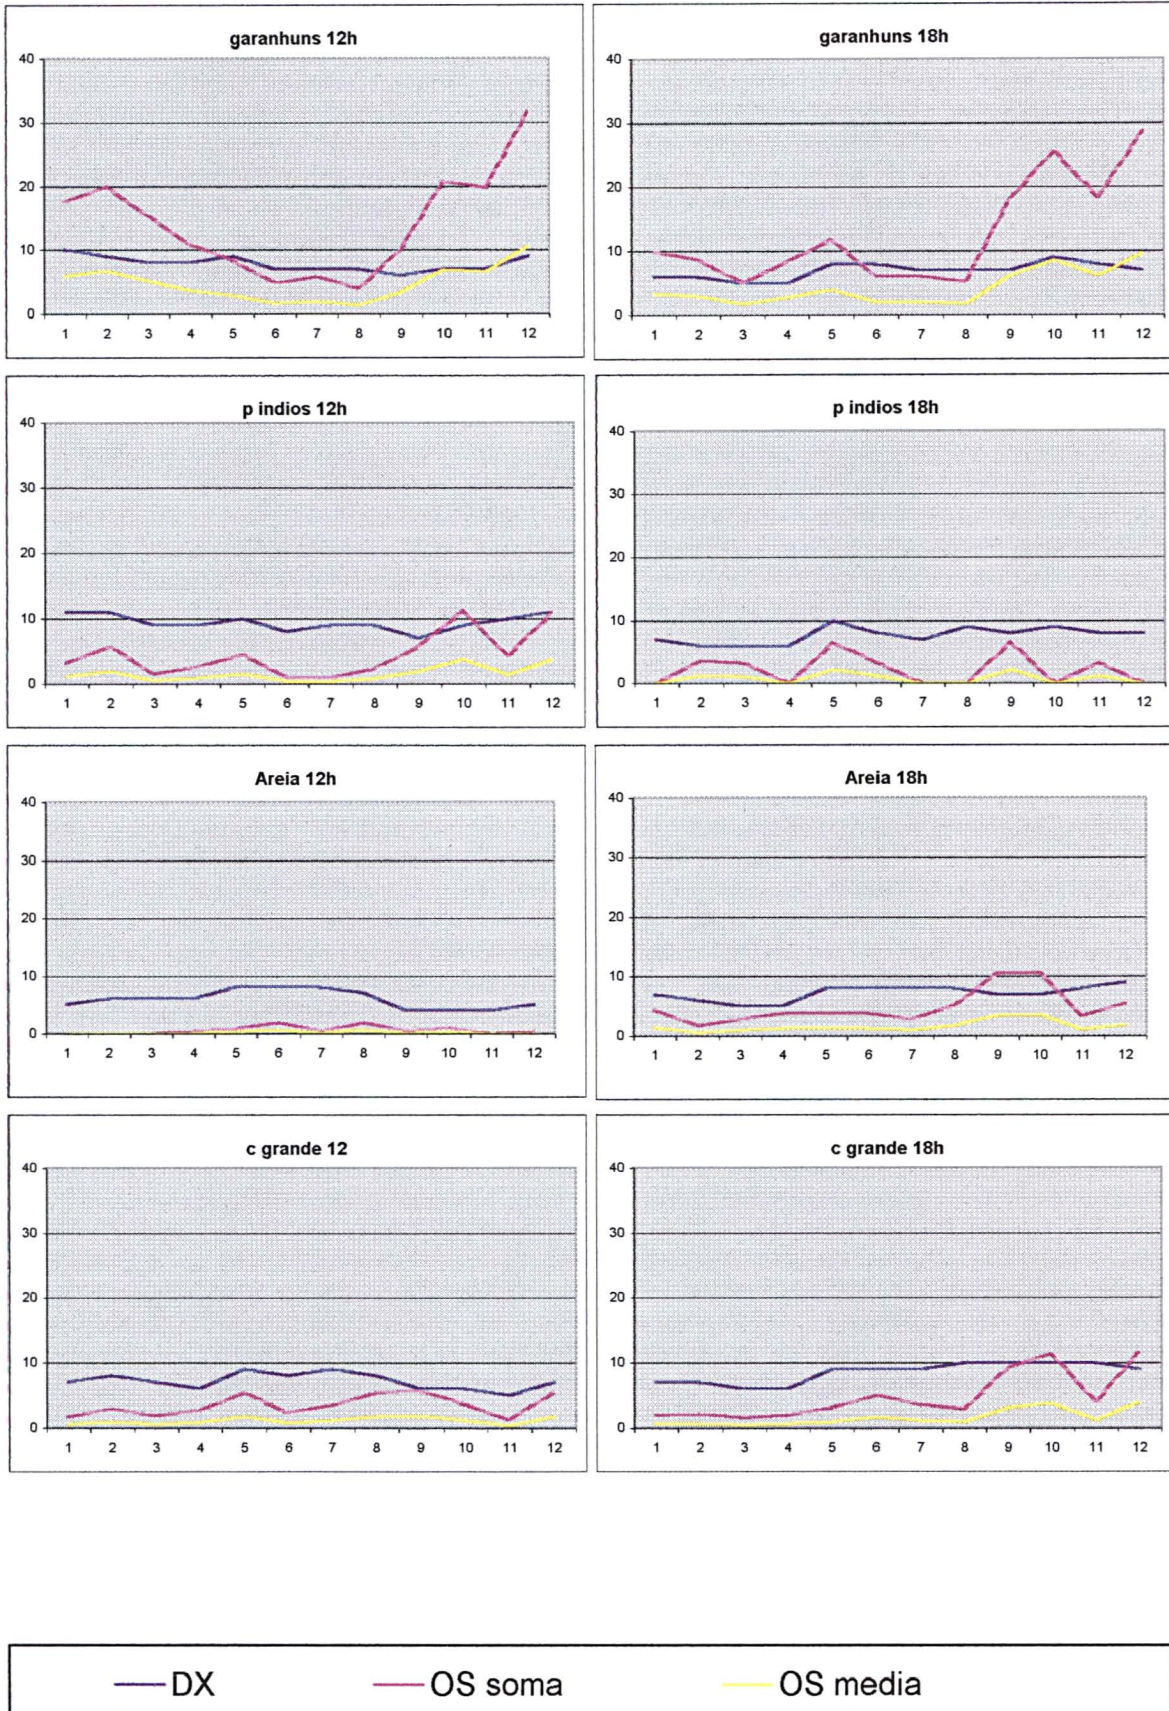
Anexo 5 - Gráficos de dados OS e DX



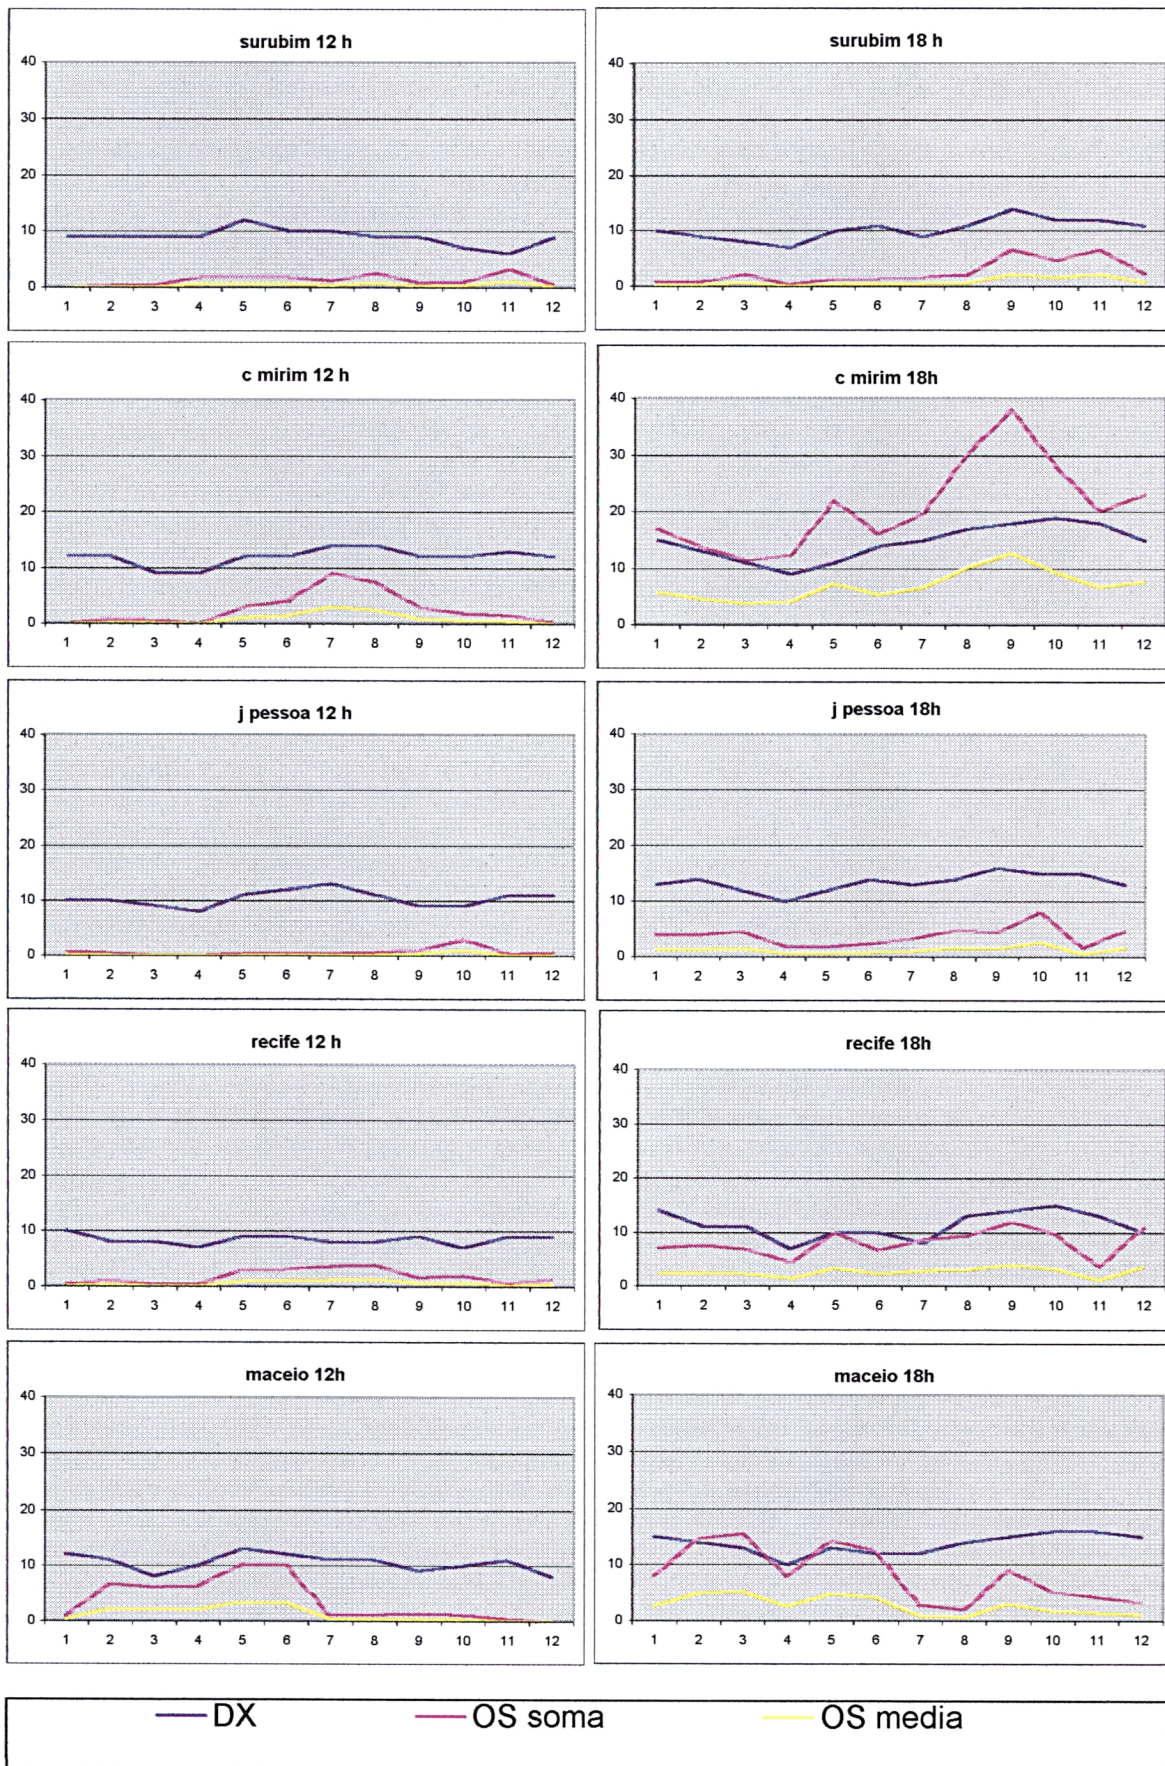
Anexo 5 - Gráficos de dados OS e DX



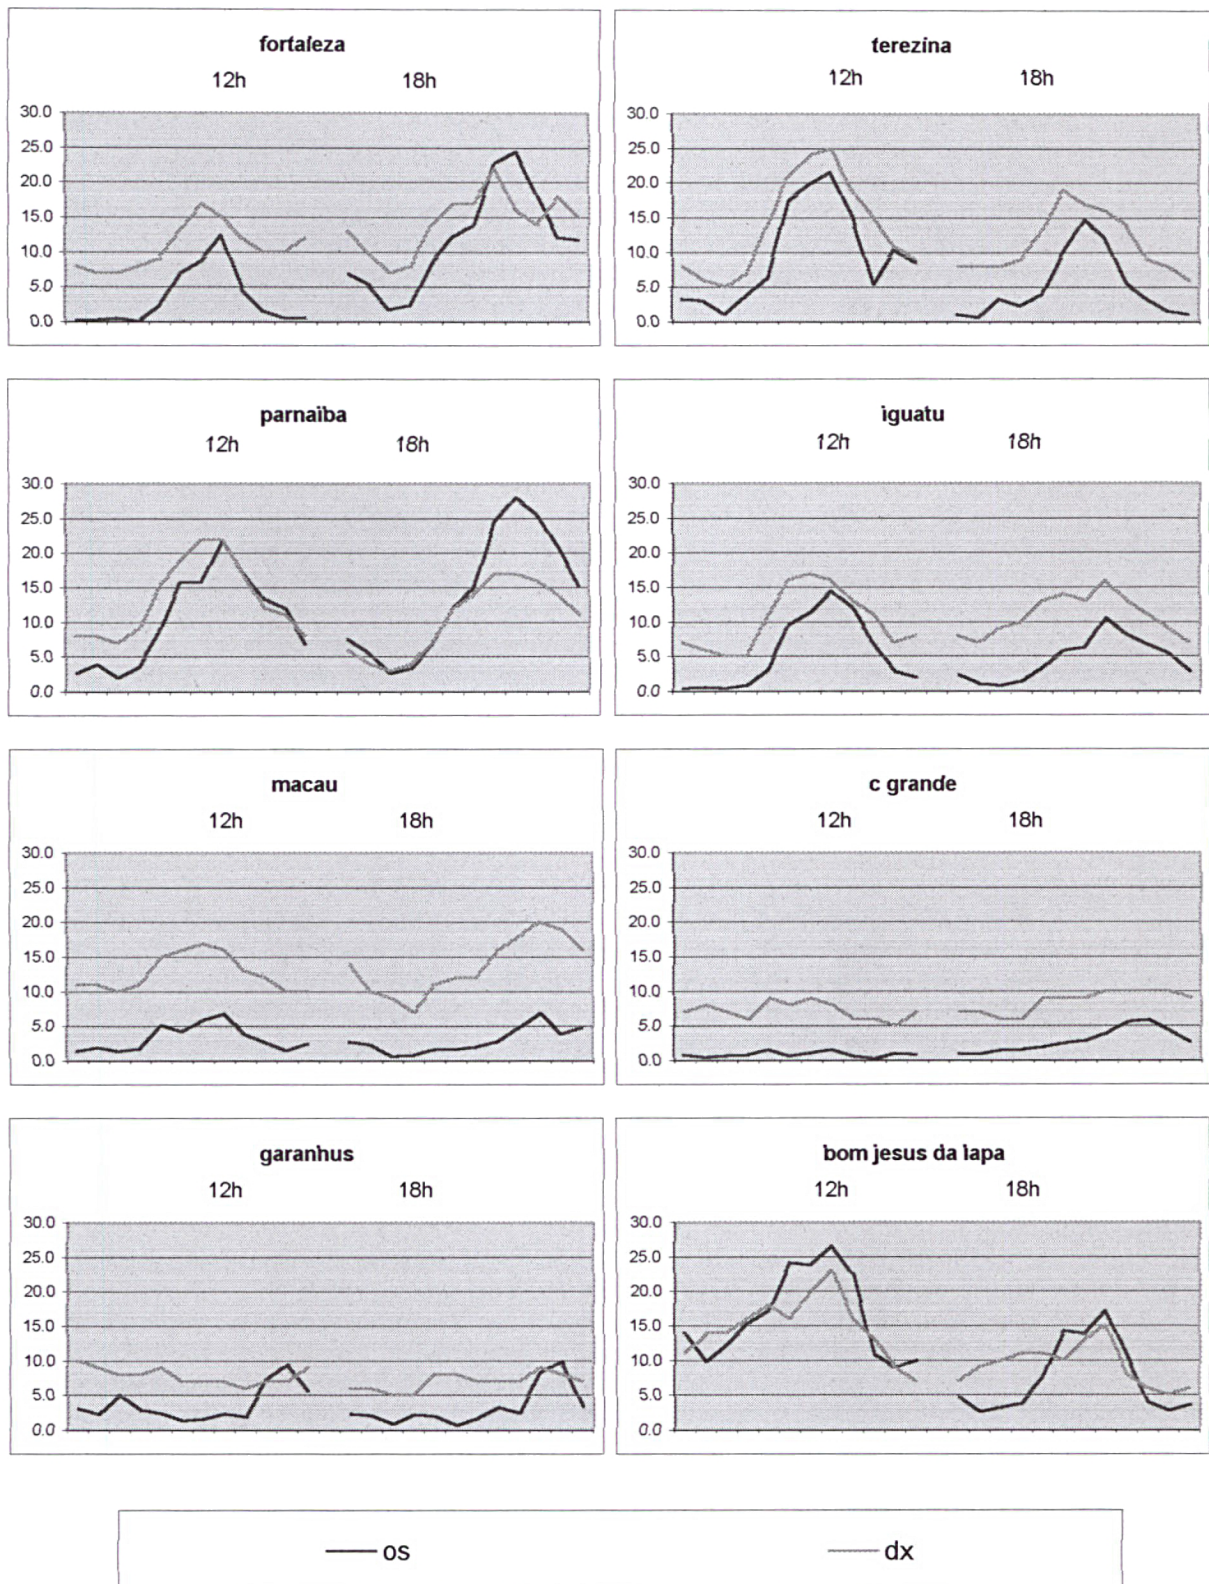
Anexo 5 - Gráficos de dados OS e DX



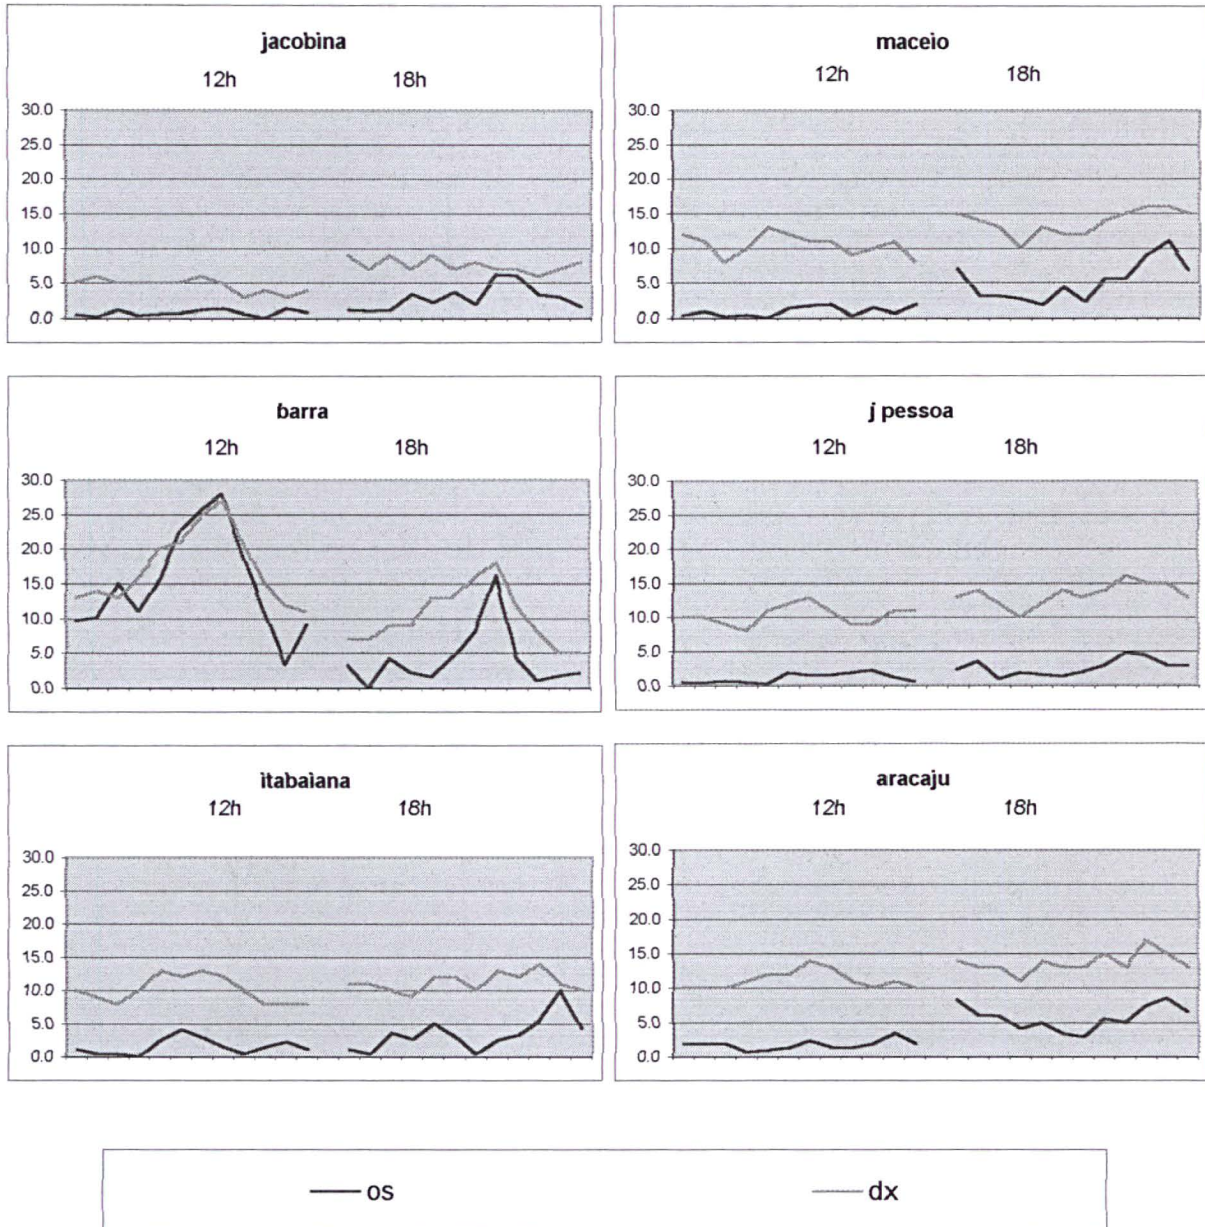
Anexo 5 - Gráficos de dados OS e DX



Anexo 5 - Gráficos de dados OS e DX



Anexo 5 - Gráficos de dados OS e DX



AGUA BRANCA MEDIA123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_3 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value							
Intercept	-2.91468	7.05649	-0.41305	0.6836	Model	62.2782	1	62.2782	1.84	0.1883	
Slope	1.11651	0.822386	1.35765	0.1883	Residual	743.331	22	33.7878			
					Total (Corr.)	805.61	23				
					Correlation Coefficient = 0.278039						
					R-squared = 7.73057 percent						
					Standard Error of Est. = 5.81273						

APODI MEDIA 123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_4 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value							
Intercept	-2.54153	2.29812	-1.10592	0.2807	Model	305.388	1	305.388	25.34	0.0000	
Slope	0.843759	0.167626	5.03358	0.0000	Residual	265.168	22	12.0531			
					Total (Corr.)	570.556	23				
					Correlation Coefficient = 0.731605						
					R-squared = 53.5246 percent						
					Standard Error of Est. = 3.47176						

ARACAJU MEDIA INPE 123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_3 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value							
Intercept	-7.80479	2.42736	-3.21535	0.0040	Model	70.4587	1	70.4587	23.03	0.0001	
Slope	0.927902	0.193365	4.7987	0.0001	Residual	67.3146	22	3.05976			
					Total (Corr.)	137.773	23				
					Correlation Coefficient = 0.71513						
					R-squared = 51.141 percent						
					Standard Error of Est. = 1.74922						

ARCOVERDE MEDIA 123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_5 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value							
Intercept	-0.519855	1.16785	-0.445138	0.6606	Model	107.4	1	107.4	27.13	0.0000	
Slope	0.600336	0.115258	5.2086	0.0000	Residual	87.0933	22	3.95879			
					Total (Corr.)	194.493	23				
					Correlation Coefficient = 0.743104						
					R-squared = 55.2204 percent						
					Standard Error of Est. = 1.98967						

AREIA MEDIA 123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_5 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value							
Intercept	-0.792605	0.857981	-0.923802	0.3656	Model	3.47712	1	3.47712	4.15	0.0539	
Slope	0.259003	0.127196	2.03626	0.0539	Residual	18.4491	22	0.838597			
					Total (Corr.)	21.9263	23				
					Correlation Coefficient = 0.398224						
					R-squared = 15.8582 percent						
					Standard Error of Est. = 0.915749						

BARRA MEDIA INPE 123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_3 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value							
Intercept	-7.87327	1.67309	-4.70583	0.0001	Model	1310.94	1	1310.94	128.22	0.0000	
Slope	1.26866	0.112038	11.3235	0.0000	Residual	224.93	22	10.2241			
					Total (Corr.)	1535.87	23				
					Correlation Coefficient = 0.923877						
					R-squared = 85.3549 percent						
					Standard Error of Est. = 3.19751						

BOM JESUS DA LAPA MEDIA INPE 123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_3 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value							
Intercept	-4.27619	2.18206	-1.9597	0.0628	Model	904.554	1	904.554	62.19	0.0000	
Slope	1.33968	0.169873	7.88636	0.0000	Residual	319.966	22	14.5439			
					Total (Corr.)	1224.52	23				
					Correlation Coefficient = 0.859477						
					R-squared = 73.8701 percent						
					Standard Error of Est. = 3.81365						

CABROBO MEDIA 123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_5 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value							
Intercept	-3.96267	2.01865	-1.96303	0.0624	Model	70.5284	1	70.5284	13.52	0.0013	
Slope	0.791343	0.21524	3.67656	0.0013	Residual	114.79	22	5.21772			
					Total (Corr.)	185.318	23				
					Correlation Coefficient = 0.616912						
					R-squared = 38.058 percent						
					Standard Error of Est. = 2.28423						

CAMPINA GRANDE MEDIA 123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_5 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value							
Intercept	-0.858519	0.907364	-0.946169	0.3543	Model	4.86971	1	4.86971	6.44	0.0187	
Slope	0.289863	0.114204	2.53812	0.0187	Residual	16.6303	22	0.755922			
					Total (Corr.)	21.5	23				
					Correlation Coefficient = 0.475918						
					R-squared = 22.6498 percent						
					Standard Error of Est. = 0.869438						

CAMPINA GRANDE MEDIA 123 INPE

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance					
Dependent variable: Col_4 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value
Parameter	Estimate	Standard Error	T Statistic	P-Value	Model	30.5566	1	30.5566	23.22	0.0001
Intercept	-3.84083	1.19731	-3.20789	0.0041	Residual	28.9568	22	1.31622		
Slope	0.726096	0.150697	4.81824	0.0001	Total (Corr.)	59.5133	23			
					Correlation Coefficient = 0.716548					
					R-squared = 51.344 percent					
					Standard Error of Est. = 1.14727					

CEARA MIRIM MEDIA 123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance					
Dependent variable: Col_3 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value
Parameter	Estimate	Standard Error	T Statistic	P-Value	Model	176.207	1	176.207	28.22	0.0000
Intercept	-9.22297	2.52994	-3.64552	0.0014	Residual	137.351	22	6.24322		
Slope	0.993557	0.187019	5.31261	0.0000	Total (Corr.)	313.558	23			
					Correlation Coefficient = 0.74964					
					R-squared = 56.1961 percent					
					Standard Error of Est. = 2.49864					

CRUZETA MEDIA 123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance					
Dependent variable: Col_5 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value
Parameter	Estimate	Standard Error	T Statistic	P-Value	Model	289.136	1	289.136	91.10	0.0000
Intercept	-4.09752	1.07994	-3.79421	0.0010	Residual	69.8219	22	3.17372		
Slope	0.978741	0.102542	9.5448	0.0000	Total (Corr.)	358.958	23			
					Correlation Coefficient = 0.897489					
					R-squared = 80.5487 percent					
					Standard Error of Est. = 1.78149					

FORTALEZA MEDIA 123 INPE

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance				
Dependent variable: Col_3 Independent variable: Col_2					Source				
Parameter	Estimate	Standard Error	T Statistic	P-Value	Sum of Squares	Df	Mean Square	F-Ratio	P-Value
Intercept	-11.0794	2.59327	-4.27236	0.0003	Model	1	869.513	56.33	0.0000
Slope	1.48564	0.197951	7.50507	0.0000	Residual	22	15.4371		
					Total (Corr.) 1209.13 23				
					Correlation Coefficient = 0.848011				
					R-squared = 71.9123 percent				
					Standard Error of Est. = 3.92901				

GARANHUNS MEDIA123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance				
Dependent variable: Col_5 Independent variable: Col_2					Source				
Parameter	Estimate	Standard Error	T Statistic	P-Value	Sum of Squares	Df	Mean Square	F-Ratio	P-Value
Intercept	0.923113	3.36073	0.274676	0.7861	Model	1	8.21135	1.14	0.2979
Slope	0.482075	0.452135	1.06622	0.2979	Residual	22	7.22304		
					Total (Corr.) 167.118 23				
					Correlation Coefficient = 0.221664				
					R-squared = 4.9135 percent				
					Standard Error of Est. = 2.68757				

GARANHUNS MEDIA 123 INPE

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance				
Dependent variable: Col_3 Independent variable: Col_2					Source				
Parameter	Estimate	Standard Error	T Statistic	P-Value	Sum of Squares	Df	Mean Square	F-Ratio	P-Value
Intercept	1.37052	3.37924	0.40557	0.6890	Model	1	2.94453	0.40	0.5320
Slope	0.288679	0.454624	0.634984	0.5320	Residual	22	7.30281		
					Total (Corr.) 163.606 23				
					Correlation Coefficient = 0.134155				
					R-squared = 1.79977 percent				
					Standard Error of Est. = 2.70237				

IGUATU MEDIA 123 INPE

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_3 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value	Model	234.454	1	234.454	31.72	0.0000	
Intercept	-3.76164	1.69425	-2.22024	0.0370	Residual	162.606	22	7.39117			
Slope	0.858648	0.152456	5.63212	0.0000	Total (Corr.)	397.06	23				
					Correlation Coefficient = 0.768424						
					R-squared = 59.0475 percent						
					Standard Error of Est. = 2.71867						

ITABAIANA MEDIA 123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_3 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value	Model	18.9382	1	18.9382	4.32	0.0496	
Intercept	-2.93727	2.64374	-1.11103	0.2786	Residual	96.5151	22	4.38705			
Slope	0.508182	0.244588	2.0777	0.0496	Total (Corr.)	115.453	23				
					Correlation Coefficient = 0.405011						
					R-squared = 16.4034 percent						
					Standard Error of Est. = 2.09453						

JACOBINA MEDIA 123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_3 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value	Model	9.6513	1	9.6513	3.82	0.0635	
Intercept	-0.391165	1.18764	-0.329364	0.7450	Residual	55.587	22	2.52668			
Slope	0.364544	0.186523	1.95442	0.0635	Total (Corr.)	65.2383	23				
					Correlation Coefficient = 0.384629						
					R-squared = 14.7939 percent						
					Standard Error of Est. = 1.58955						

JOAO PESSOA MEDIA 123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_4 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value	Model	5.38127	1	5.38127	19.04	0.0002	
Intercept	-1.71687	0.574749	-2.98717	0.0068	Residual	6.21831	22	0.282651			
Slope	0.209592	0.0480349	4.36332	0.0002	Total (Corr.)	11.5996	23				
					Correlation Coefficient = 0.681116						
					R-squared = 46.3919 percent						
					Standard Error of Est. = 0.531649						

JOAO PESSOA MEDIA INPE 123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_3 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value	Model	22.3076	1	22.3076	34.39	0.0000	
Intercept	-3.13497	0.870732	-3.60038	0.0016	Residual	14.272	22	0.648729			
Slope	0.426735	0.0727719	5.86401	0.0000	Total (Corr.)	36.5796	23				
					Correlation Coefficient = 0.78092						
					R-squared = 60.9836 percent						
					Standard Error of Est. = 0.805437						

MACAU MEDIA INPE 123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_3 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value	Model	58.6529	1	58.6529	61.72	0.0000	
Intercept	-3.07838	0.801452	-3.84101	0.0009	Residual	20.9067	22	0.950306			
Slope	0.463232	0.0589638	7.85621	0.0000	Total (Corr.)	79.5596	23				
					Correlation Coefficient = 0.858615						
					R-squared = 73.7219 percent						
					Standard Error of Est. = 0.974836						

MACEIO MEDIA 123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_5 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value	Model	3.00194	1	3.00194	1.14	0.2982	
Intercept	0.0393784	1.88912	0.0208448	0.9836	Residual	58.1776	22	2.64444			
Slope	0.162303	0.152333	1.06545	0.2982	Total (Corr.)	61.1796	23	Correlation Coefficient = 0.221512			
					R-squared = 4.90676 percent						
					Standard Error of Est. = 1.62617						

MACEIO MEDIA INPE 123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_4 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value	Model	147.844	1	147.844	55.45	0.0000	
Intercept	-10.8054	1.89688	-5.69645	0.0000	Residual	58.6561	22	2.66619			
Slope	1.13901	0.152958	7.44657	0.0000	Total (Corr.)	206.5	23	Correlation Coefficient = 0.846139			
					R-squared = 71.5951 percent						
					Standard Error of Est. = 1.63285						

MONTEIRO MEDIA123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_5 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value	Model	107.396	1	107.396	7.45	0.0123	
Intercept	3.76037	3.1408	1.19726	0.2439	Residual	317.237	22	14.4199			
Slope	0.827183	0.303102	2.72906	0.0123	Total (Corr.)	424.633	23	Correlation Coefficient = 0.502906			
					R-squared = 25.2915 percent						
					Standard Error of Est. = 3.79735						

MORADA NOVA MEDIA 123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_4 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value	Model	324.013	1	324.013	66.86	0.0000	
Intercept	-5.2205	1.39802	-3.73421	0.0012	Residual	106.616	22	4.84619			
Slope	0.889699	0.108808	8.17676	0.0000	Total (Corr.)	430.63	23				
					Correlation Coefficient = 0.86742						
					R-squared = 75.2418 percent						
					Standard Error of Est. = 2.20141						

MOSSORO MEDIA 123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_5 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value	Model	308.161	1	308.161	13.42	0.0014	
Intercept	4.12717	3.44864	1.19675	0.2441	Residual	505.197	22	22.9635			
Slope	0.905757	0.247253	3.66328	0.0014	Total (Corr.)	813.358	23				
					Correlation Coefficient = 0.615528						
					R-squared = 37.8875 percent						
					Standard Error of Est. = 4.79203						

MOSSORO CLASSE 1

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_3 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value	Model	1157.21	1	1157.21	51.50	0.0000	
Intercept	-14.5426	3.41154	-4.26276	0.0003	Residual	494.385	22	22.472			
Slope	1.75521	0.244593	7.17604	0.0000	Total (Corr.)	1651.59	23				
					Correlation Coefficient = 0.837056						
					R-squared = 70.0662 percent						
					Standard Error of Est. = 4.74047						

PALMEIRA DOS INDIOS MEDIA123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_3 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value	Model	4.40714	1	4.40714	4.32	0.0496	
Intercept	-1.31197	1.19295	-1.09977	0.2833	Residual	22.4624	22	1.02102			
Slope	0.285792	0.137559	2.0776	0.0496	Total (Corr.)	26.8696	23	Correlation Coefficient = 0.404994			
					R-squared = 16.402 percent						
					Standard Error of Est. = 1.01046						

PAO DE ACUCAR MEDIA123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_5 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value	Model	0.362485	1	0.362485	0.36	0.5560	
Intercept	0.667255	1.29076	0.516945	0.6104	Residual	22.3071	22	1.01396			
Slope	0.0923529	0.15446	0.597909	0.5560	Total (Corr.)	22.6696	23	Correlation Coefficient = 0.126451			
					R-squared = 1.59899 percent						
					Standard Error of Est. = 1.00696						

PARNAIBA MEDIA INPE 123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_3 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value	Model	947.184	1	947.184	40.42	0.0000	
Intercept	-1.53247	2.35925	-0.649557	0.5227	Residual	515.562	22	23.4346			
Slope	1.15505	0.181682	6.35753	0.0000	Total (Corr.)	1462.75	23	Correlation Coefficient = 0.804698			
					R-squared = 64.7538 percent						
					Standard Error of Est. = 4.84093						

PATOS MEDIA 123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_5 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value	Model	400.579	1	400.579	77.55	0.0000	
Intercept	-6.53693	1.51262	-4.32159	0.0003	Residual	113.639	22	5.1654			
Slope	1.09851	0.124741	8.80628	0.0000	Total (Corr.)	514.218	23				
					Correlation Coefficient = 0.882614						
					R-squared = 77.9007 percent						
					Standard Error of Est. = 2.27275						

RECIFE MEDIA123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_4 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value	Model	29.7359	1	29.7359	34.73	0.0000	
Intercept	-2.76258	0.799685	-3.45459	0.0023	Residual	18.8375	22	0.856248			
Slope	0.467668	0.0793591	5.89306	0.0000	Total (Corr.)	48.5733	23				
					Correlation Coefficient = 0.782423						
					R-squared = 61.2185 percent						
					Standard Error of Est. = 0.925337						

SERIDO MEDIA 123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_5 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value	Model	346.211	1	346.211	43.22	0.0000	
Intercept	-10.003	2.69584	-3.71054	0.0012	Residual	176.227	22	8.01032			
Slope	1.87997	0.285959	6.57424	0.0000	Total (Corr.)	522.438	23				
					Correlation Coefficient = 0.814054						
					R-squared = 66.2684 percent						
					Standard Error of Est. = 2.83025						

SAO GONÇALO (SOUZA) MEDIA123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_4 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value	Model	240.526	1	240.526	20.41	0.0002	
Intercept	-3.20657	2.83233	-1.13213	0.2698	Residual	259.252	22	11.7842			
Slope	1.00188	0.22176	4.51784	0.0002	Total (Corr.)	499.778	23	Correlation Coefficient = 0.693733			
					R-squared = 48.1265 percent						
					Standard Error of Est. = 3.43281						

SURUBIM MEDIA123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
Dependent variable: Col_5 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value	Model	3.44084	1	3.44084	16.25	0.0006	
Intercept	-1.41593	0.521075	-2.71733	0.0126	Residual	4.65916	22	0.21178			
Slope	0.213717	0.0530211	4.03079	0.0006	Total (Corr.)	8.1	23	Correlation Coefficient = 0.651763			
					R-squared = 42.4795 percent						
					Standard Error of Est. = 0.460196						

TERESINA MEDIA INPE 123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance						
dependent variable: Col_3 Independent variable: Col_2					Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value	
Parameter	Estimate	Standard Error	T Statistic	P-Value	Model	787.474	1	787.474	115.39	0.0000	
Intercept	-5.06907	1.26827	-3.99683	0.0006	Residual	150.144	22	6.82474			
Slope	0.992166	0.0923654	10.7418	0.0000	Total (Corr.)	937.618	23	Correlation Coefficient = 0.916442			
					R-squared = 83.9866 percent						
					Standard Error of Est. = 2.61242						



TRIUNFO MEDIA123

Regression Analysis - Linear model: $Y = a + b \cdot X$					Analysis of Variance					
Dependent variable: Col_5 Independent variable: Col_2										
Parameter	Estimate	Standard Error	T Statistic	P-Value	Source	Sum of Squares	Df	Mean Square	F-Ratio	P-Value
Intercept	-3.34027	1.82887	-1.82641	0.0814	Model	483.446	1	483.446	62.09	0.0000
Slope	1.30943	0.166175	7.8798	0.0000	Residual	171.293	22	7.78606		
					Total (Corr.)	654.74	23			
					Correlation Coefficient = 0.85929					
					R-squared = 73.838 percent					
					Standard Error of Est. = 2.79035					

Anexo 7: Resultados das Simulações

82588 Morada Nova			12h UTC				Mês 8			
1 ^a	100	88.5	82.5	72.8	58.5	41.4	17.3	6.2	6.2	6.2
2 ^a	100	99.6	98.2	94.5	90.6	87	82.7	77.1	63.6	0
3 ^a	100	100	100	99.6	97.5	95.1	92.6	86.9	79.2	0
4 ^a	100	100	100	100	100	97.1	94.1	89.7	86.8	0
5 ^a	100	100	100	100	100	100	84.6	84.6	76.9	0
6 ^a	100	100	100	100	100	100	100	100	66.7	0
7 ^a	100	100	100	100	100	100	100	100	100	0
8 ^a	100	100	100	100	100	100	100	100	100	100
9 ^a	100	100	100	100	100	100	100	100	100	100
10 ^a	100	100	100	100	100	100	100	100	100	100
	10	20	30	40	50	60	70	80	90	100



	10 c	3 c	1 c	10 ci
1	19	21.4	21.6	21.6
2	69.5	45.3	34.9	71.7
3	94	60.6	46.1	94.5
4	98.8	74.2	56.4	99.5
5	99.9	81.2	64.9	99.9
6	100	85.8	70.8	100
7		89.5	76.6	
8		93.2	81.1	
9		95	84	
10		96.2	86.1	
11		97.8	88.6	
12		98.7	89.7	
13		99.2	91.2	
14		99.6	92.8	
15		99.8	94.1	
16		99.8	94.8	
17		99.9	95.5	
18		99.9	96.2	
19		99.9	96.9	
20		99.9	97.6	
21		99.9	97.9	
22		99.9	98.4	
23		99.9	98.8	
24		99.9	99.1	
25		100	99.1	
26			99.4	
27			99.5	
28			99.5	
29			99.6	
30			99.7	
31			99.9	
32			100	



Anexo 7: Resultados das Simulações

82590 Apodi		12h UTC				Mês 9				
1 ^a	100	100	92.2	80.5	70.6	59.2	33.2	30.1	30.1	29.9
2 ^a	100	94.4	94.4	88.1	84.2	79.2	69.7	56.9	51.4	2
3 ^a	100	98.7	96.4	95.7	90.5	87.5	82.9	74.7	61.5	0.7
4 ^a	100	99.4	98.7	96.8	94.3	86	83.4	77.7	70.1	0
5 ^a	100	100	98.1	96.2	94.3	92.5	88.7	83	77.4	0
6 ^a	100	100	100	95.5	95.5	90.9	86.4	81.8	68.2	0
7 ^a	100	100	100	100	100	100	100	100	90.9	0
8 ^a	100	100	100	100	100	100	100	100	100	100
9 ^a	100	100	100	100	100	100	100	100	100	0
10 ^a	100	100	100	100	100	100	100	100	100	100
	10	20	30	40	50	60	70	80	90	100



	10 c	3 c	1 c	10 ci
1	32.2	32.4	33.7	34.1
2	61.7	52.6	54.9	68.5
3	83	68	67	88.6
4	93.4	77.8	76.6	97.2
5	97.7	84.3	81.8	99.7
6	98.8	89.2	86.8	99.9
7	99.6	92.4	90	100
8	99.9	94.6	92.6	
9	99.9	96.4	94	
10	100	97.5	95	
11		98.4	96.3	
12		99	97.3	
13		99.3	98.1	
14		99.3	98.5	
15		99.6	99	
16		99.6	99.3	
17		99.7	99.4	
18		99.9	99.5	
19		99.9	99.6	
20		99.9	99.6	
21		99.9	99.6	
22		99.9	99.6	
23		99.9	99.7	
24		99.9	99.8	
25		99.9	99.8	
26		99.9	99.9	
27		99.9	99.9	
28		99.9	99.9	
29		99.9	99.9	
30		100	100	



Anexo 7: Resultados das Simulações

82591		Mossoro								
1 ^a	100	97.5	90.7	78.1	69.7	50.4	30	2	2	2
2 ^a	100	100	100	100	99.4	97.3	96.5	92.8	88.3	0
3 ^a	100	100	100	100	100	100	100	98.8	96.4	0
4 ^a	100	100	100	100	100	100	100	100	100	0
5 ^a	100	100	100	100	100	100	100	100	100	100
6 ^a	100	100	100	100	100	100	100	100	100	100
7 ^a	100	100	100	100	100	100	100	100	100	100
8 ^a	100	100	100	100	100	100	100	100	100	100
9 ^a	100	100	100	100	100	100	100	100	100	100
10 ^a	100	100	100	100	100	100	100	100	100	100
	10	20	30	40	50	60	70	80	90	100



	10 c	3 c	1 c	10 ci
1	28.1	28.4	27.4	26.8
2	90.3	59.7	45.5	90.3
3	99.5	77.7	60.4	100
4	100	87.7	71.6	
5		93.4	78.6	
6		96.8	85	
7		98.3	88.6	
8		99	91.9	
9		99.4	94.1	
10		99.8	96.1	
11		100	97.3	
12			98.2	
13			98.8	
14			98.9	
15			99.1	
16			99.4	
17			99.5	
18			99.7	
19			99.7	
20			99.8	
21			99.9	
22			100	



Anexo 7: Resultados das Simulações

82596	Ceara Mirim			18h UTC			Mês 9			
1 ^a	100	68.7	48	36.7	29.3	26.1	22.7	22.7	22.7	22.7
2 ^a	100	93.9	77.2	60.3	43.8	30.7	21.7	12.5	10.2	5.2
3 ^a	100	96.3	91.7	83.4	70.9	57.4	43.6	29.9	19.9	0.2
4 ^a	100	98.9	97.9	94	88.4	81.2	68.9	54.7	40.5	0
5 ^a	100	100	98.7	97.3	93.6	85.1	76.3	68.1	54.5	0
6 ^a	100	100	100	99.1	97.8	93.3	82.6	68.8	53.6	0
7 ^a	100	100	100	100	99.2	99.2	95	81.7	63.3	0
8 ^a	100	100	100	100	100	100	95.8	93.8	77.1	0
9 ^a	100	100	100	100	100	100	100	94.7	94.7	0
10 ^a	100	100	100	100	100	100	100	100	100	0
	10	20	30	40	50	60	70	80	90	100

	10 c	3 c 18	1 c 18	10 ci
1	0.3	17.6	16.5	0.3
2	5	37.7	29.7	4.8
3	23.3	51.9	40.3	22
4	49.6	62.2	49.6	48.9
5	71.6	70.4	57.4	74
6	87.3	78.8	64.1	88.5
7	95.3	83.6	68.8	95.3
8	98.6	87.9	73.3	98.5
9	99.5	91.2	75.8	100
10	99.9	93.4	79.5	
11	100	95.7	82.6	
12		96.5	84.8	
13		97.2	87.5	
14		97.8	89	
15		98.7	90.4	
16		99.3	91.5	
17		99.4	92.5	
18		99.6	93.6	
19		99.9	94.8	
20		99.9	95.4	
21		99.9	95.9	
22		99.9	96.4	
23		100	96.7	
24			97.3	
25			97.5	
26			98.1	
27			98.6	
28			98.8	
29			99.1	
30			99.1	
31			99.2	
32			99.4	
33			99.5	
34			99.7	
35			99.8	
36			99.8	
37			99.8	
38			99.8	
39			99.8	





Anexo 7: Resultados das Simulações

82689 Souza (São Gonçalo)

1 ^a	100	79.1	78.8	66	52.4	36.1	22	4.4	4.4	4.2
2 ^a	100	99	98.4	93.7	92.4	85.3	75.3	71.4	63.9	0
3 ^a	100	100	98.3	97.9	96.7	94.1	91.2	84.5	74.5	0
4 ^a	100	100	100	100	98.4	96.9	96.9	89.1	79.7	0
5 ^a	100	100	100	100	100	100	100	100	93.8	0
6 ^a	100	100	100	100	100	100	100	50	50	0
7 ^a	100	100	100	100	100	100	100	100	100	0
8 ^a	100	100	100	100	100	100	100	100	100	100
9 ^a	100	100	100	100	100	100	100	100	100	100
10 ^a	100	100	100	100	100	100	100	100	100	100



	10 c	3 c	1 c	10 ci
1	33.9	33.4	34.2	30.5
2	77.1	54	50.7	79.2
3	94.2	65.4	63.8	96.5
4	98.7	75.6	72.9	99.8
5	99.8	83.1	79.2	100
6	100	88.3	84.1	
7		92.6	87.5	
8		95.1	90.5	
9		96.2	93.6	
10		97.7	95	
11		98.4	95.8	
12		99.1	97	
13		99.6	97.5	
14		99.9	98.3	
15		99.9	98.8	
16		99.9	99	
17		99.9	99.3	
18		99.9	99.4	
19		99.9	99.5	
20		99.9	99.7	
21		99.9	99.8	
22		100	99.9	
23			99.9	
24			99.9	
25			99.9	
26			99.9	
27			99.9	
28			99.9	
29			99.9	
30			100	



Anexo 7: Resultados das Simulações

82690	Serido (Caico)				12h UTC		Mês 9			
1 ^a	100	96.2	90.5	72.9	66.9	48.8	21.7	2.2	2.2	2
2 ^a	100	100	98.8	97.8	95.6	92.6	90.9	84.1	81.5	0
3 ^a	100	100	100	100	100	95.3	91.3	89.8	81.1	0
4 ^a	100	100	100	100	100	100	100	91.7	87.5	0
5 ^a	100	100	100	100	100	100	100	100	100	0
6 ^a	100	100	100	100	100	100	100	100	100	100
7 ^a	100	100	100	100	100	100	100	100	100	100
8 ^a	100	100	100	100	100	100	100	100	100	100
9 ^a	100	100	100	100	100	100	100	100	100	100
10 ^a	100	100	100	100	100	100	100	100	100	100
	10	20	30	40	50	60	70	80	90	100



	10 c	3 c	1 c	10 ci
1	33.1	32.6	33.2	32.6
2	87.9	57.7	54.8	90.3
3	98.2	78.6	69.4	99.6
4	100	89.6	78.1	100
5		96.1	84.9	
6		97.5	89	
7		99	91.2	
8		99.4	93.5	
9		99.8	95.1	
10		99.8	96	
11		99.9	97.4	
12		99.9	98.5	
13		99.9	99.1	
14		100	99.2	
15			99.3	
16			99.7	
17			99.8	
18			100	



Anexo 7: Resultados das Simulações

82693		Cruzeta									
1ª	100	89.8	77.9	61.9	57.3	36.8	22.6	6.5	6.5	6.3	
2ª	100	98.7	95.2	93.3	89.2	82.1	76.9	70.2	55.6	0.5	
3ª	100	99.5	98.9	97.3	95.9	93.2	89.3	85.2	74.9	0	
4ª	100	100	100	100	98	96.1	91.2	86.3	78.4	0	
5ª	100	100	100	100	100	100	96.2	92.3	84.6	0	
6ª	100	100	100	100	100	100	100	100	75	0	
7ª	100	100	100	100	100	100	100	100	100	0	
8ª	100	100	100	100	100	100	100	100	100	100	
9ª	100	100	100	100	100	100	100	100	100	100	
10ª	100	100	100	100	100	100	100	100	100	100	
		10	20	30	40	50	60	70	80	90	100



	10 c	3 c	1 c	10 ci
1	20.3	19.3	20.2	17.2
2	63.4	35.6	30.9	67.5
3	89.3	51.4	42.6	93.2
4	97.3	64	51.8	98.8
5	99.5	72.6	57.6	99.9
6	99.9	78.3	63.3	100
7	100	83.2	68.4	
8		87.7	72.1	
9		90.3	76.3	
10		93.1	80	
11		95	82.8	
12		95.8	85	
13		96.9	87.3	
14		97.8	88.5	
15		98.3	89.5	
16		98.8	90.2	
17		99.2	91.5	
18		99.4	92.9	
19		99.6	93.5	
20		99.6	94.2	
21		99.7	94.9	
22		99.7	95.3	
23		99.7	95.9	
24		99.8	96.5	
25		99.8	97	
26		99.8	97.6	
27		99.9	98	
28		99.9	98.2	
29		99.9	98.3	
30		100	98.4	
31			98.5	
32			98.7	
33			98.8	
34			99.1	
35			99.2	
36			99.4	
37			99.4	
38			99.6	
39			99.6	
40			99.6	



Anexo 7: Resultados das Simulações

82696	Areia									
1ª	100	88.9	65	39.6	31.4	17.8	9.8	6.8	6.8	6.7
2ª	100	98.3	93.4	85.8	77.7	67.8	51.4	41.8	32.4	1
3ª	100	99.5	98	95	91.4	84.1	77.3	65.5	55.1	0.3
4ª	100	99.7	99.7	98.4	96.5	93	86.6	78	67.8	0
5ª	100	100	100	99.2	96.6	94.9	89.8	84.7	66.9	0
6ª	100	100	100	97.9	97.9	95.8	91.7	89.6	81.3	0
7ª	100	100	100	100	100	90	90	90	80	0
8ª	100	100	100	100	100	100	100	100	100	0
9ª	100	100	100	100	100	100	100	100	100	100
10ª	100	100	100	100	100	100	100	100	100	100
	10	20	30	40	50	60	70	80	90	100

	10 c	3 c	1 c	10 ci
1	2.7	1.5	1.2	2.4
2	28.4	3.8	2.2	26.6
3	66.5	6.6	3.7	71.9
4	87	9.7	5.2	93.3
5	95.6	12.5	6.7	99.1
6	99	16.2	8	99.7
7	99.6	19.6	9.5	100
8	99.9	22.7	10.4	
9	100	25.6	12.2	
10		28.7	13	
11		32.5	15	
12		35.5	17.1	
13		38.9	18.9	
14		42.3	20.5	
15		45.1	21.4	
16		48.2	22.7	
17		50.2	24.6	
18		52.8	25.8	
19		56.4	26.9	
20		58.5	28.2	
21		60.2	29.8	
22		61.6	31.2	
23		64.1	32	
24		66.2	32.6	
25		67.6	33.6	
26		69.1	34.7	
27		71	35.3	
28		73.3	36.6	
29		75.5	37.7	
30		76.9	39	
31		78.3	40	
32		80	40.7	
33		81.1	41.7	
34		82.1	42.3	
35		83	43.1	
36		83.9	43.7	
37		85	44.5	
38		86.5	45.1	
39		87.6	45.9	





Número de tentativas para 95% de nível de confiança
 3 c 1 c
 52 184

Anexo 7: Resultados das Simulações

82789	Triunfo		12h UTC		Mês 9					
1ª	100	94	82.1	68.7	52.3	36.3	33.7	10.2	10.2	9.9
2ª	100	95.2	95.2	93	90.4	89.1	81.4	77.5	70.2	1.8
3ª	100	98.2	93.4	92.2	89.8	87.4	85	79.6	70.7	0
4ª	100	100	97.9	95.8	93.8	83.3	72.9	70.8	66.7	0
5ª	100	100	100	95	95	95	85	65	65	0
6ª	100	100	100	85.7	85.7	85.7	85.7	71.4	71.4	0
7ª	100	100	100	100	100	100	100	100	100	0
8ª	100	100	100	100	50	50	50	50	50	0
9ª	100	100	100	100	100	100	100	100	0	0
10ª	100	100	100	100	100	100	100	100	100	0
	10	20	30	40	50	60	70	80	90	100



	10 c	3 c	1 c	10 ci
1	52.7	54.4	51.6	51.5
2	83	71.2	71.6	87.7
3	94.5	82.9	82.5	98
4	97.6	89.7	88.9	99.7
5	99.2	93.7	92.4	100
6	99.4	96.7	95	
7	99.7	98.6	96.9	
8	99.8	99.3	97.9	
9	99.9	99.6	98.9	
10	100	99.7	99.4	
11		99.7	99.4	
12		99.8	99.7	
13		99.9	99.9	
14		100	99.9	
15			100	



Anexo 7: Resultados das Simulações

82791	Patos									
1 ^a	100	90.9	79.5	69.7	59.1	42.5	20	5.6	5.6	5.6
2 ^a	100	100	99	97.1	92.9	86.7	81	73.3	65.8	1.2
3 ^a	100	98.4	98	96.4	95.2	93.3	89.7	83.3	75.4	0
4 ^a	100	100	100	100	97.5	95.1	92.6	86.4	79	1.2
5 ^a	100	100	96.3	92.6	88.9	88.9	81.5	81.5	81.5	0
6 ^a	100	100	88.9	88.9	88.9	77.8	77.8	66.7	66.7	0
7 ^a	100	100	100	100	100	100	100	100	100	0
8 ^a	100	100	100	100	100	100	100	0	0	0
9 ^a	100	100	100	100	100	100	100	100	100	0
10 ^a	100	100	100	100	100	100	100	100	100	100
	10	20	30	40	50	60	70	80	90	100



	10 c	3 c	1 c	10 ci
1	25.1	25.7	24.2	25.1
2	72.2	43.4	40.3	71.9
3	92.4	59.1	51.9	92.7
4	97.8	72.4	60.6	99
5	99.2	82.6	68.8	99.9
6	99.6	89.2	74.6	100
7	99.9	93.7	79.5	
8	100	95.8	83.9	
9		96.6	86.8	
10		97.8	90.2	
11		98.2	91.7	
12		99	93.6	
13		99.2	95	
14		99.5	95.8	
15		99.9	96.8	
16		100	97.6	
17			97.9	
18			98.5	
19			98.6	
20			99.2	
21			99.4	
22			99.7	
23			99.8	
24			99.9	
25			99.9	
26			99.9	
27			99.9	
28			100	



Anexo 7: Resultados das Simulações

82792	Monteiro									
1ª	100	85.2	77.8	66	60.8	38.2	26	1.6	1.6	1.4
2ª	100	100	100	98.3	95.1	90.2	87.6	81.9	75.1	0
3ª	100	100	100	100	100	98.1	96.1	86.5	83.9	0
4ª	100	100	100	100	100	100	100	100	100	0
5ª	100	100	100	100	100	100	100	100	100	0
6ª	100	100	100	100	100	100	100	100	100	100
7ª	100	100	100	100	100	100	100	100	100	100
8ª	100	100	100	100	100	100	100	100	100	100
9ª	100	100	100	100	100	100	100	100	100	100
10ª	100	100	100	100	100	100	100	100	100	100
	10	20	30	40	50	60	70	80	90	100

	10 c	3 c	1 c	10 ci
1	40.2	40.2	40.7	40.6
2	84.6	60.6	56.1	86.2
3	97.9	74.3	67.3	98.2
4	99.8	86	76.1	99.7
5	100	92.1	82.4	100
6		95.5	86.6	
7		97	89.7	
8		98.8	92.2	
9		99.5	93.8	
10		99.8	95.4	
11		100	96	
12			97.3	
13			98	
14			98.5	
15			99.1	
16			99.4	
17			99.5	
18			99.5	
19			99.5	
20			99.7	
21			99.8	
22			99.8	
23			99.8	
24			99.9	
25			100	





Anexo 7: Resultados das Simulações

82795 Campina Grande 18horas

1 ^a	100	91.1	77.9	53.2	28.5	12.6	6.6	3.8	3.8	3.8
2 ^a	100	99.5	98.3	92.5	87.4	77.9	68.8	54.9	41.3	0.4
3 ^a	100	99.8	98.9	98.6	96.2	90.8	86.4	78.8	71.3	0
4 ^a	100	100	100	99.4	98.9	96.7	92.8	81.2	74	0
5 ^a	100	100	100	100	100	100	94.3	88.7	81.1	0
6 ^a	100	100	100	100	100	100	100	100	100	0
7 ^a	100	100	100	100	100	100	100	100	100	0
8 ^a	100	100	100	100	100	100	100	100	100	100
9 ^a	100	100	100	100	100	100	100	100	100	100
10 ^a	100	100	100	100	100	100	100	100	100	100

	10 c	3 c	1 c	10 ci
1	3.6	2.8	2.6	3.1
2	43.4	6.9	4.1	44.9
3	83.8	11	5.3	90
4	95.7	13.7	6.7	98.7
5	98.8	17	8	99.9
6	99.6	20	9.5	100
7	99.8	22.7	11	
8	100	25.9	12.4	
9		28.5	13.9	
10		31.7	14.6	
11		35.5	15.2	
12		38	16.6	
13		40.5	17.3	
14		43.4	18.7	
15		46	19.8	
16		48.5	20.8	
17		49.9	21.5	
18		51.6	22.9	
19		53.8	23.8	
20		55.6	25.3	
21		58.5	26.6	
22		60.1	27.5	
23		62.2	28.5	
24		65	29.1	
25		66.9	30.2	
26		68.9	31.1	
27		70.2	32.1	
28		71.5	33.3	
29		73.1	34.2	
30		74.5	34.9	
31		75.9	35.8	
32		77.2	36.6	
33		78	37.6	
34		78.4	37.8	
35		79.4	38.7	
36		80.6	39.3	
37		81.3	40.6	
38		82.2	41.7	
39		83	42.5	





Número de tent para 95% de nível de confiança
 3 c 1 c
 67 232

Anexo 7: Resultados das Simulações

82797	Surubim		18h							
1 ^a	100	91.8	80.6	50.2	22.1	6.5	1.5	0.9	0.9	0.9
2 ^a	100	99.6	98.5	97.5	95	87.7	76.3	57.1	39.1	0
3 ^a	100	100	100	99.7	99.1	98.6	97.3	94	88.3	0
4 ^a	100	100	100	100	98.8	97.5	95.1	88.9	84	0
5 ^a	100	100	100	100	100	100	100	94.1	94.1	0
6 ^a	100	100	100	100	100	100	100	100	100	0
7 ^a	100	100	100	100	100	100	100	100	100	100
8 ^a	100	100	100	100	100	100	100	100	100	100
9 ^a	100	100	100	100	100	100	100	100	100	100
10 ^a	100	100	100	100	100	100	100	100	100	100
	10	20	30	40	50	60	70	80	90	100

	10 c	3 c	1 c	10 ci
1	1.9	1.6	1.3	1.6
2	40.6	4.4	2.8	39.7
3	93.4	6.1	4	94.1
4	99.3	6.9	5	99.8
5	100	8.3	5.5	100
6		10	6.7	
7		10.9	8.1	
8		12.5	8.6	
9		14.4	9	
10		15.6	9.8	
11		16.8	10.9	
12		18.2	11.8	
13		19.8	12.8	
14		21.7	13.5	
15		22.8	14.3	
16		23.8	15.8	
17		25.4	16.7	
18		26.6	17.2	
19		27.3	18	
20		28.9	18.7	
21		29.8	19.6	
22		30.7	20.4	
23		31.2	20.9	
24		32.2	21.8	
25		33.5	22.4	
26		34.8	23.4	
27		36.2	24	
28		37	24.5	
29		38.3	25	
30		39	25.4	
31		40.2	26.3	
32		41	26.8	
33		42.1	27.2	
34		42.5	27.7	
35		43.4	28.3	
36		44.3	28.9	
37		45.1	29.2	
38		46.3	29.9	
39		47.7	30.6	





Numero de Tentativas com 95% de Nível de Confiança
 3 c 1 c
 159 332

Anexo 7: Resultados das Simulações

82798	Joao Pessoa				18 h						
1 ^a	100	95.7	77.1	40	11.7	5.2	3.5	0.9	0.9	0.9	
2 ^a	100	99.8	98.3	96.9	92.8	84.4	68.6	49.6	31.1	0	
3 ^a	100	100	100	99.7	98.2	96.7	95.4	92	83.4	0	
4 ^a	100	100	100	100	100	96.4	93.5	89.2	80.6	0	
5 ^a	100	100	100	100	97.4	92.1	86.8	84.2	76.3	0	
6 ^a	100	100	93.3	93.3	93.3	93.3	86.7	80	80	0	
7 ^a	100	100	100	100	66.7	66.7	66.7	66.7	66.7	0	
8 ^a	100	100	100	100	100	100	100	100	0	0	
9 ^a	100	100	100	100	100	100	100	100	100	0	
10 ^a	100	100	100	100	100	100	100	100	100	100	
	10	20	30	40	50	60	70	80	90	100	

	10 c	3 c	1 c	10 ci
1	3.3	4	3.7	4.1
2	32.5	7.7	7.4	30.2
3	83.9	12	11.1	86.6
4	96.5	15.6	14.7	99.4
5	98.6	18.8	17.7	100
6	99.5	22.7	21.3	
7	99.9	25.3	23.3	
8	99.9	27.8	26.7	
9	100	30.6	29	
10		33.3	31.8	
11		37	34.1	
12		40.2	36.9	
13		41.9	38.8	
14		43.8	40.6	
15		46.5	42.9	
16		49	44.7	
17		50.8	46.8	
18		53.1	48.5	
19		55.3	50	
20		57.3	51.9	
21		59.3	52.9	
22		60.7	54.4	
23		62.2	56.2	
24		63.7	58	
25		65.1	59.5	
26		66.6	61	
27		67.9	63.2	
28		69.1	64.4	
29		70.1	65.5	
30		71.3	66.2	
31		73.1	67.4	
32		73.7	68.4	
33		74.9	69.6	
34		76.4	70.9	
35		77	72.1	
36		78.8	72.6	
37		79.3	73.5	
38		80.2	74.3	
39		81.1	75.6	





Número de tentativas para 95% de nível de confiança

3 c	1 c
67	83

Anexo 7: Resultados das Simulações

82886	Cabrobo				12h UTC				Mês 10			
1 ^a	100	81.3	54.1	34.7	30.2	24.2	14.4	6.7	6.7	6.7	6.7	6.7
2 ^a	100	97.1	92.7	88.2	78.9	66.4	53.6	44.3	33.2	2.4		
3 ^a	100	98.4	94.9	91.2	87.7	84.4	78.1	70.1	57.1	0.2		
4 ^a	100	99.6	97.8	94.5	90.4	84.2	77.6	70.6	60.7	0.7		
5 ^a	100	98.4	97.5	95.1	90.2	85.2	81.1	75.4	62.3	0		
6 ^a	100	100	98	93.9	91.8	83.7	79.6	77.6	65.3	0		
7 ^a	100	100	100	100	94.7	89.5	84.2	57.9	42.1	0		
8 ^a	100	100	100	90.9	90.9	90.9	90.9	90.9	81.8	0		
9 ^a	100	100	100	100	100	66.7	66.7	66.7	66.7	0		
10 ^a	100	100	100	100	100	100	100	100	100	0		



	10 c	3 c	1 c	10 ci
1	12.1	12.9	12.8	11.9
2	38.9	21.5	18.7	43.2
3	71.3	30.3	25.1	76.9
4	88.9	40.4	32	94.3
5	93.7	47.1	37.1	98.9
6	97.3	54.8	41.9	99.6
7	99.2	60.7	46.1	100
8	99.8	66	50.5	
9	100	70.4	53.6	
10		75.4	57.1	
11		78	60.1	
12		80.4	62.9	
13		83.1	65.7	
14		85.2	68.7	
15		87.3	70.4	
16		88.8	72.7	
17		90.1	74.7	
18		91.5	76.4	
19		93	77.6	
20		94.1	78.6	
21		94.9	80.1	
22		95.8	81.6	
23		96.9	83.1	
24		97.3	84.3	
25		97.8	85.1	
26		98.1	86	
27		98.5	86.9	
28		98.5	87.6	
29		99	88.5	
30		99.1	89	
31		99.4	89.9	
32		99.5	90.5	
33		99.8	91	
34		99.8	91.9	
35		99.9	92.7	
36		99.9	93.6	
37		99.9	94.2	
38		99.9	95.1	
39		99.9	95.5	



Anexo 7: Resultados das Simulações

82890	Arcoverde		12h UTC		Mês 10					
1 ^a	100	88.1	80.4	63.7	49.8	31.2	20.9	3.3	3.3	3.1
2 ^a	100	98.4	96.1	93.6	88.8	84.1	78	69.3	62.9	0
3 ^a	100	100	99.1	95.6	92.9	88.2	82.9	76.5	69.4	0
4 ^a	100	100	100	100	94.8	93.1	88.8	79.3	72.4	0
5 ^a	100	100	100	100	100	90.6	87.5	81.3	71.9	0
6 ^a	100	100	100	100	100	100	78.6	71.4	57.1	0
7 ^a	100	100	100	100	100	100	100	100	100	0
8 ^a	100	100	100	100	100	100	100	100	50	0
9 ^a	100	100	100	100	100	100	100	100	100	0
10 ^a	100	100	100	100	100	100	100	100	100	100

	10 c	3 c	1 c	10 ci
1	6.4	8.1	8.3	8.5
2	63.2	25.4	13.2	65.7
3	89.1	40.3	18	94.7
4	96.3	51.1	22.6	99.1
5	99.3	61.4	26.7	100
6	100	68.8	33.1	
7		75.4	38	
8		80.2	42.8	
9		83.7	45.3	
10		86.8	48.6	
11		89.5	51.7	
12		91.4	54.4	
13		92.7	56.8	
14		95.5	59.9	
15		96.9	62.5	
16		97.4	64.9	
17		97.9	67.5	
18		98.5	69.6	
19		98.7	71.4	
20		99.3	73.2	
21		99.6	74.5	
22		99.6	76.1	
23		99.7	77.4	
24		99.7	78.8	
25		99.9	80.4	
26		100	81.9	
27			83.1	
28			84	
29			84.8	
30			85.7	
31			86.4	
32			87.2	
33			88.2	
34			89	
35			89.4	
36			89.6	
37			90.1	
38			90.8	
39			91.1	





Número de tentativas para 95% de nível de confiança

3 c	1 c
15	48

Anexo 7: Resultados das Simulações

82893	Garanhuns			12h UTC			Mês 10			
1 ^a	100	73.9	51.7	45.2	32.5	27.3	20	11.8	11.8	11.8
2 ^a	100	96	84.8	72.9	58.6	48.6	39.8	31.7	25.7	0.7
3 ^a	100	99	96.5	90.9	82.8	73.4	61.1	49.3	40.9	0.2
4 ^a	100	99.5	99	96	92.4	85.4	76.5	64.1	50.8	0.3
5 ^a	100	100	100	99.1	97.6	95.8	88.2	76.4	60.8	0
6 ^a	100	99	99	98	98	94.9	91.9	88.9	78.8	0
7 ^a	100	100	100	97.1	97.1	97.1	91.4	85.7	74.3	0
8 ^a	100	100	100	100	100	100	100	100	100	0
9 ^a	100	100	100	100	100	100	100	100	100	0
10 ^a	100	100	100	100	100	100	100	100	100	100
	10	20	30	40	50	60	70	80	90	100

	10 c	3 c	1 c	10 ci
1	10.3	11.6	10.8	10.2
2	30.2	21.9	18	30.3
3	53.7	29.4	22.9	59.5
4	73.5	37.9	28	81.7
5	88.3	43.5	32	93.1
6	95.6	49.6	38.4	97
7	98.3	54.4	42.9	98.7
8	99.4	58.1	46.9	99.7
9	99.8	61.4	50.5	100
10	100	65	53.7	
11		67.2	56.5	
12		70.6	59.5	
13		72.8	62.3	
14		76.3	65.2	
15		79.3	67.9	
16		81.5	70.4	
17		83.3	72.6	
18		85.1	74.1	
19		86.3	76.3	
20		87.9	78	
21		89.6	79.2	
22		90	80.2	
23		90.8	80.8	
24		91.9	82.3	
25		92.7	83.5	
26		93.3	84.2	
27		94.2	85.6	
28		94.3	86.3	
29		94.8	87.4	
30		95.4	88	
31		95.8	89	
32		96	89.4	
33		96.4	90.1	
34		97.1	91.4	
35		97.3	92	
36		97.5	92.4	
37		97.6	92.7	
38		98.1	93	
39		98.2	93.4	





Número de tentativas para 95% de nível de confiança

3 c	1 c
30	43

Anexo 7: Resultados das Simulações

82900	Recife		18h UTC		Mês 10					
1 ^a	100	84.1	57.6	37.1	22.2	16	12	8.5	8.5	8.5
2 ^a	100	98.6	94.5	85.8	73.8	59.3	44	31.9	23.5	1
3 ^a	100	99.7	98.9	97.1	94	87.4	79.1	66.2	52.3	0.1
4 ^a	100	99.7	99.2	98.9	96.7	94.2	92	81.8	72.9	0
5 ^a	100	100	100	100	98.3	98.3	93	85.2	78.3	0
6 ^a	100	100	100	100	100	96.6	93.1	86.2	75.9	0
7 ^a	100	100	100	100	100	100	88.9	88.9	88.9	0
8 ^a	100	100	100	100	100	100	100	66.7	66.7	0
9 ^a	100	100	100	100	100	100	100	100	100	0
10 ^a	100	100	100	100	100	100	100	100	100	100
	10	20	30	40	50	60	70	80	90	100

	10 c	3 c	1 c	10 ci
1	2.2	2	2.8	2.8
2	26.9	3.6	4.5	22.8
3	61.3	6	5.7	64.3
4	85	7.6	7.3	90.1
5	95.5	10.5	9.3	97.5
6	98.3	13.7	10.1	99.7
7	99.7	16.6	11.3	100
8	100	20	13.5	
9		23	15.1	
10		25.9	17	
11		29.2	19	
12		32.6	20.7	
13		35.6	22.9	
14		38.8	24.4	
15		41.5	25.9	
16		44.7	27.1	
17		47.2	28.1	
18		49.9	29.1	
19		52.6	29.5	
20		55	30	
21		57.7	31	
22		59.9	32.2	
23		62.6	33.4	
24		64.4	34.2	
25		67.1	35.3	
26		68.7	36.3	
27		70.9	36.9	
28		72.4	37.9	
29		74.2	39.4	
30		76.1	40.8	
31		78.3	41.6	
32		79.1	42.5	
33		80.1	43.2	
34		81.6	44.3	
35		82.8	45.2	
36		84.4	46.2	
37		84.9	47.6	
38		85.7	48.7	
39		86.3	50.2	





Número de tentativas para 95% de nível de confiança

3 c	1 c
56	164

Anexo 7: Resultados das Simulações

82989	Agua Branca			12h UTC		Mês 10				
1 ^a	100	70	40.6	31.2	28.7	19.5	11.2	7.8	7.8	7.8
2 ^a	100	95.8	88.8	78.1	60.9	44.9	39.4	36.4	26	0
3 ^a	100	99.3	96.5	92.2	84.1	77.5	66.5	52.6	40	0
4 ^a	100	99.2	97.7	95.8	91.5	85.8	77.3	70.8	59.2	0
5 ^a	100	100	99.3	98	97.3	91.3	82.6	71.1	56.4	0
6 ^a	100	100	100	97.1	95.7	94.2	88.4	82.6	76.8	0
7 ^a	100	100	100	95	95	90	80	65	45	0
8 ^a	100	92.3	92.3	92.3	92.3	84.6	84.6	84.6	84.6	0
9 ^a	100	83.3	83.3	66.7	66.7	66.7	50	50	33.3	0
10 ^a	100	100	100	100	75	75	50	50	50	0
	10	20	30	40	50	60	70	80	90	100



	10 c	3 c	1 c	10 ci
1	19.1	19.1	19.7	21.3
2	39.8	29.9	29	45.9
3	61.8	39.3	38	74.2
4	82.1	48.3	46.2	92.9
5	91.7	55.7	52	98.9
6	95.4	62.5	58.8	99.8
7	98.2	67.8	64	99.9
8	99.3	71.9	67.9	100
9	99.6	76.2	71.5	
10	99.8	80.6	75.3	
11	100	83.5	78.8	
12		85.4	81.2	
13		87.2	83.4	
14		88.3	85.4	
15		90.1	87.2	
16		91.3	88.5	
17		92.8	90.3	
18		93.7	91.4	
19		94.8	92.2	
20		95.5	93	
21		96.2	93.8	
22		97	94.8	
23		97.3	95.3	
24		97.9	95.7	
25		98.2	96	
26		98.7	97.3	
27		98.7	97.7	
28		99	97.8	
29		99	98.1	
30		99.1	98.4	
31		99.1	98.6	
32		99.3	98.9	
33		99.5	99.1	
34		99.6	99.2	
35		99.7	99.4	
36		99.7	99.5	
37		99.7	99.5	
38		99.7	99.5	
39		99.8	99.6	



Anexo 7: Resultados das Simulações

82990	Pao de Açucar				12h UTC		Mês 10			
1 ^a	100	79.6	53.4	31.2	24.3	16.9	14	7.2	7.2	7.2
2 ^a	100	99	95.2	85.5	70.4	54.2	39.4	27.1	16.7	0.4
3 ^a	100	100	99.6	98.7	95.6	89.2	79.7	67.5	52.6	0.1
4 ^a	100	100	99.7	99.7	99.5	97.7	95.7	86.5	75.4	0
5 ^a	100	100	100	100	100	100	98	94.9	84.8	0
6 ^a	100	100	100	100	100	100	100	100	88.9	0
7 ^a	100	100	100	100	100	100	100	100	100	0
8 ^a	100	100	100	100	100	100	100	100	100	100
9 ^a	100	100	100	100	100	100	100	100	100	100
10 ^a	100	100	100	100	100	100	100	100	100	100
	10	20	30	40	50	60	70	80	90	100

	10 c	3 c	1 c	10 ci
1	1.8	1.6	1.4	1.3
2	18.9	5.8	2.3	22.7
3	62.4	8.7	3	62.9
4	90.6	11.6	3.2	91.5
5	98.8	13.9	4.2	98.5
6	99.9	16.7	4.8	99.8
7	100	18.8	5.6	100
8		21.6	6.3	
9		24	7.3	
10		26.3	7.6	
11		29.2	8.4	
12		31.4	8.7	
13		33.9	9.5	
14		36.8	9.9	
15		39.3	10.8	
16		41.9	11.3	
17		43	12.5	
18		45.2	12.8	
19		47.7	13.4	
20		49.5	14.3	
21		51.5	14.8	
22		53.9	15.3	
23		55.4	16.3	
24		56.9	16.9	
25		58.9	17.8	
26		61.6	18.3	
27		62.8	19.1	
28		64.6	19.7	
29		65.6	20.1	
30		66.9	21.4	
31		68.2	22.1	
32		68.9	22.5	
33		70.6	23.1	
34		71.5	23.5	
35		72.7	23.8	
36		74	24.1	
37		75.5	24.9	
38		77.4	25.8	
39		78.1	26.6	





Número de tentativas para 95% de nível de confiança

3 c	1 c
69	416

Anexo 7: Resultados das Simulações

82992	Palmeira dos Indios				12h UTC		Mês 10			
1 ^a	100	69.3	49.5	43.3	40	34.7	32.6	28.6	28.6	28.6
2 ^a	100	90.2	77.4	52.3	37.7	29.2	22.1	17.9	13.9	2.8
3 ^a	100	96.9	93.4	84.7	68.9	51.5	38.4	28.9	21.6	1
4 ^a	100	98.4	96.4	94.4	87.6	76.5	61	46.6	32.9	0.3
5 ^a	100	99.6	98.7	96.6	94.2	88.6	79.1	65.2	46.9	0
6 ^a	100	99.6	99.2	99.2	97.1	93.4	86.8	77	61.7	0
7 ^a	100	100	100	99.1	98.1	95.3	86.8	81.1	61.3	0
8 ^a	100	100	100	100	100	97.9	91.5	83	68.1	0
9 ^a	100	100	100	100	100	100	94.4	77.8	66.7	0
10 ^a	100	100	100	100	100	100	100	100	80	0
	10	20	30	40	50	60	70	80	90	100

	10 c	3 c	1 c	10 ci
1	5.9	5.7	5.9	7.9
2	17.2	9.9	9.6	20
3	32.1	14	12.9	43.2
4	53.8	18	16.2	64
5	76.2	22	19	83.7
6	90.6	25	21.9	94.4
7	96.3	29.6	25.5	98.1
8	98.6	33.1	27.7	99.8
9	99.5	35.7	30.7	100
10	99.5	39.2	33	
11	99.9	42	35.2	
12	99.9	44.6	37	
13	100	47	39.1	
14		49.5	41.6	
15		52.2	43.3	
16		55	45.2	
17		57.2	47.1	
18		59.1	49.1	
19		61.4	51.1	
20		63.5	52.9	
21		65	54.1	
22		66.8	56.3	
23		67.6	57.2	
24		69.2	59.3	
25		70.6	60.4	
26		71.8	61.3	
27		73.2	62.8	
28		74.2	64.1	
29		74.9	65	
30		76.2	65.4	
31		77.1	66.2	
32		78.1	66.9	
33		79	68.2	
34		80.4	69.4	
35		81.3	70.4	
36		81.8	71.1	
37		83.3	72.4	
38		83.6	72.7	
39		84.9	73.8	





Número de tentativas para 95% de nível de confiança

3 c 1 c
58 192

Anexo 7: Resultados das Simulações

82994	Maceio			18h UTC			Mês 10			
1 ^a	100	76.4	57.4	37.8	30.3	23.7	19.4	12.4	12.4	12.4
2 ^a	100	95	85.8	74.9	58.1	48.9	39.2	27.8	19.3	0.3
3 ^a	100	99.7	96.8	90.6	81.3	72.8	59.8	49.6	36.5	0
4 ^a	100	100	99.6	97.9	94.1	86.5	75.1	67.2	54.5	0
5 ^a	100	100	100	100	99.2	95.9	87.6	75.9	57.3	0
6 ^a	100	100	100	100	98.4	97.6	96.1	88.2	72.4	0
7 ^a	100	100	100	100	100	100	97.6	90.5	78.6	0
8 ^a	100	100	100	100	100	100	100	100	90	0
9 ^a	100	100	100	100	100	100	100	100	100	0
10 ^a	100	100	100	100	100	100	100	100	100	100

	10 c	3 c	1 c	10 ci
1	4.2	3.1	2.9	3.5
2	20.7	10.5	5.3	21.8
3	48.8	12.5	7.1	56.4
4	72.1	14.7	9.3	82.3
5	88.4	16.4	10.7	94.6
6	94.8	18.7	12.8	98.3
7	98.6	20.6	14.8	99.5
8	100	22.7	15.9	99.7
9		23.3	17.2	99.9
10		24.7	18.8	100
11		26.4	19.8	
12		27.5	20.3	
13		29.6	21.7	
14		30.6	23	
15		32.7	24.3	
16		34.2	25.3	
17		35.7	26.3	
18		36.9	27.8	
19		38.7	28.3	
20		39.4	29.2	
21		40.8	30.2	
22		41.8	31.7	
23		43.6	32.9	
24		44.8	34	
25		46.9	34.7	
26		48.2	35.9	
27		49.3	37.8	
28		49.9	38.7	
29		51	39.9	
30		52.2	40.4	
31		52.6	41.6	
32		53.3	42.6	
33		54.7	43.2	
34		55.8	44.2	
35		57.1	45.1	
36		57.8	45.7	
37		58.4	46.6	
38		60	47.4	
39		60.7	48.1	



Número de tentativas para 95% de nível de confiança
 3 c 1 c
 138 193