

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

**PREVISÃO DE RAIOS UTILIZANDO TÉCNICAS DE INTELIGÊNCIA
COMPUTACIONAL E DADOS DE SONDAÇÃO ATMOSFÉRICA POR SATÉLITE**

ELTON RAFAEL ALVES

TD 11/2017

**UPFA/ITEC/PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil
2017**

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

ELTON RAFAEL ALVES

**PREVISÃO DE RAIOS UTILIZANDO TÉCNICAS DE INTELIGÊNCIA
COMPUTACIONAL E DADOS DE SONDAÇÃO ATMOSFÉRICA POR SATÉLITE**

Tese submetida à Banca Examinadora do Programa de Pós-Graduação em Engenharia Elétrica da UFPA para a obtenção do Grau de Doutor em Engenharia Elétrica na Área de Concentração de Sistema de Energia Elétrica.

**UPFA/ITEC/PPGEE
Campus Universitário do Guamá
Belém-Pará-Brasil
2017**

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da Universidade Federal do Pará
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)

- A474p Alves, Elton Rafael Alves
Previsão de raios utilizando técnicas de inteligência computacional e dados de sondagem atmosférica por satélite / Elton Rafael Alves Alves. - 2017.
201 f. : il. color.
- Tese (Doutorado) - Programa de Pós-graduação em Engenharia Elétrica (PPGEE), Instituto de Tecnologia, Universidade Federal do Pará, Belém, 2017.
Orientação: Prof. Dr. Carlos Tavares da Costa Júnior Costa Júnior
Coorientação: Prof. Dr. José Alberto Silva de Sá.
1. Sondagem atmosférica por satélite. 2. Redes Neurais Artificiais. 3. Classificadores. 4. Previsão de Descargas Atmosféricas. I. Costa Júnior, Carlos Tavares da Costa Júnior, *orient.* II. Título
-

621.307209811

CDD

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

AUTOR: ELTON RAFAEL ALVES

**“PREVISÃO DE RAIOS UTILIZANDO TÉCNICAS DE INTELIGÊNCIA
COMPUTACIONAL E DADOS DE SONDAÇÃO ATMOSFÉRICA POR SATÉLITE”**

TESE DE DOUTORADO SUBMETIDA À AVALIAÇÃO DA BANCA EXAMINADORA APROVADA PELO COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA DA UNIVERSIDADE FEDERAL DO PARÁ E JULGADA ADEQUADA PARA OBTENÇÃO DO GRAU DE DOUTOR EM ENGENHARIA ELÉTRICA NA ÁREA DE SISTEMA DE ENERGIA ELÉTRICA

APROVADA EM: 30/11/2017

BANCA EXAMINADORA:

Prof. Dr. Carlos Tavares da Costa Júnior
(ORIENTADOR – PPGEE/UFPA)

Prof. Dr. José Alberto Silva de Sá
(Co-orientador – UEPA)

Prof.^a Dr.^a Brígida Ramati Pereira da Rocha
(Avaliadora Interna – PPGEE/UFPA)

Prof.^a Dr.^a Adriana Rosa Garcez Castro
(Avaliadora Interna – PPGEE/UFPA)

Prof. Dr. Arthur da Costa Almeida
(Avaliador Externo ao Programa – CCAST/UFPA)

Prof. Dr. João Marcelo Brazão Protázio
(Avaliador Externo ao Programa – ICEN/ UFPA)

Prof. Dr. José Pissolato Filho
(Avaliador Externo – UNICAMP)

VISTO:

Prof. Dr. Evaldo Gonçalves Pelaes
(COORDENADOR DO PPGEE/ITEC/UFPA)

A persistência é o caminho do êxito.

Charles Chaplin

AGRADECIMENTOS

Agradeço inicialmente a Deus por ter me dado inspiração e fé durante minha caminhada, vencendo os obstáculos do dia a dia. A minha mãe, Rosilda Alves, por ter me dado educação e apoio durante toda minha vida, pois foi a principal pessoa que contribuiu para meu sucesso profissional. A minha irmã, Elen Cristina, por ser uma pessoa que me ajudou bastante no decorrer da minha caminhada. A minha esposa, Cyntia Alves, que passou dias e noites comigo nessa caminhada, por sua compreensão, dedicação nas horas de estudo, pelo apoio nas horas de tristezas.

Agradeço ao meu orientador Prof. Carlos Tavares da Costa Júnior por me apoiado e ter acreditado neste trabalho desenvolvido.

Ao prof. Brígida Ramati Pereira da Rocha pela proposta de tese apresentada, bem como o suporte operacional junto ao Sistema de Proteção da Amazônia (SIPAM).

Ao prof. José Alberto Silva de Sá pelas contribuições valiosas ao longo do desenvolvimento deste trabalho.

Ao funcionário do SIPAM-CR-Belém, Marcio Nirlando Gomes Lopes pelos esclarecimentos e dicas na área de meteorologia.

Ao SIPAM pela disponibilização da infraestrutura e acesso a base de dados de sondagem atmosférica por satélite através do software TERASCAN®, que permitiu o desenvolvimento desta tese.

A todos que contribuíram diretamente ou indiretamente para a elaboração desta tese.

SUMÁRIO

| | |
|---|-------|
| AGRADECIMENTOS | V |
| SUMÁRIO..... | VII |
| LISTA DE FIGURAS | XIII |
| LISTA DE TABELAS | XVIII |
| LISTA DE ABREVIACÕES | XX |
| RESUMO | XXI |
| ABSTRACT | XXII |
| CAPÍTULO I..... | 23 |
| 1 INTRODUÇÃO..... | 23 |
| 1.1 INTRODUÇÃO | 23 |
| 1.1.1 TEMA E PROBLEMA..... | 23 |
| 1.1.2 MOTIVAÇÃO E CONTRIBUIÇÃO | 29 |
| 1.2 OBJETIVOS | 31 |
| 1.2.1 OBJETIVO GERAL..... | 31 |
| 1.2.2 OBJETIVOS ESPECÍFICOS | 31 |
| 1.3 ESTRUTURA DO TRABALHO | 31 |
| CAPÍTULO II..... | 33 |
| 2 DESCARGAS ATMÓSFERICAS..... | 33 |
| 2.1 INTRODUÇÃO | 33 |
| 2.2 FUNDAMENTOS SOBRE AS DESCARGAS ATMOSFÉRICAS | 33 |
| 2.3 CIRCUITO ELÉTRICO GLOBAL..... | 35 |
| 2.4 TIPIFICAÇÃO DAS DESCARGAS ATMOSFÉRICAS | 37 |
| 2.4.1 TIPIFICAÇÃO PELO PERCURSO DA DESCARGA | 38 |
| 2.4.2 TIPIFICAÇÃO PELO SINAL E DIREÇÃO DE PROPAGAÇÃO DA DESCARGA | 39 |

| | | |
|--------------------|--|----|
| 2.5 | FORMAÇÃO DE UMA NUVEM DE TEMPESTADE | 40 |
| 2.5.1 | FASES DE FORMAÇÃO DE UMA NUVEM DE TEMPESTADE | 41 |
| 2.5.2 | ELETRIFICAÇÃO DAS NUVENS DE TEMPESTADES | 44 |
| 2.6 | MECANISMO DE FORMAÇÃO DA DESCARGA ATMÓSFERICA | 45 |
| 2.7 | PARÂMETROS FÍSICOS DAS DESCARGAS ATMÓSFERICAS | 48 |
| 2.7.1 | CORRENTE DE PICO..... | 48 |
| 2.7.2 | CARGA TRANSFERIDA POR DESCARGA | 49 |
| 2.7.3 | TEMPO DE FRENTE DE ONDA | 50 |
| 2.7.4 | TEMPO DE MEIA ONDA..... | 51 |
| 2.7.5 | TEMPO DE DURAÇÃO TOTAL DE DESCARGA | 52 |
| 2.7.6 | DERIVADA MÁXIMA | 53 |
| 2.7.7 | ENERGIA POR UNIDADE DE RESISTÊNCIA..... | 54 |
| 2.8 | MEDIÇÃO E SISTEMAS DE LOCALIZAÇÃO DE DESCARGAS ATMOSFÉRICAS | 55 |
| 2.8.1 | MEDIÇÃO DIRETA DE PARÂMETROS DESCARGA ATMOSFÉRICA.... | 55 |
| 2.8.2 | MEDIÇÃO INDIRETA DE PARÂMETROS DE DESCARGA ATMOSFÉRICA..... | 57 |
| 2.8.3 | SISTEMA DE LOCALIZAÇÃO DE DESCARGAS ATMOSFÉRICAS..... | 60 |
| CAPÍTULO III | | 65 |
| 3 | INDICADORES DE INSTABILIDADE ATMÓSFERICA..... | 65 |
| 3.1 | INTRODUÇÃO | 65 |
| 3.2 | COMPOSIÇÃO DA ATMOSFERA TERRESTRE..... | 65 |
| 3.3 | ESTRUTURA VERTICAL DA ATMOSFERA TERRESTRE..... | 66 |
| 3.4 | ESTABILIDADE ATMOSFÉRICA | 67 |
| 3.5 | INDICADORES DE INSTABILIDADE ATMOSFÉRICA | 69 |
| 3.5.1 | ÍNDICE SHOWALTER (<i>Showalter index</i>) | 70 |
| 3.5.2 | ÍNDICE DE LEVANTAMENTO (<i>Lifted index - LI</i>) | 71 |
| 3.5.3 | ÍNDICE SWEAT | 71 |

| | | |
|-------------------|---|-----|
| 3.5.4 | ÍNDICE K (K index) | 71 |
| 3.5.5 | ÍNDICE TOTAL TOTALS (<i>Total Totals Index</i> - TTI)..... | 72 |
| 3.5.6 | ÁGUA PRECIPITÁVEL..... | 73 |
| 3.5.7 | ENERGIA POTENCIAL CONVECTIVA DISPONÍVEL (<i>Convective Available Potential Energy</i> - CAPE)..... | 73 |
| 3.5.8 | ENERGIA DE INIBIÇÃO DA CONVECÇÃO (<i>Convective Inhibition Energy</i> - CINE) 74 | |
| 3.6 | CONSIDERAÇÕES FINAIS | 75 |
| CAPÍTULO IV | | 76 |
| 4 | SONDAGEM ATMOSFÉRICA | 76 |
| 4.1 | INTRODUÇÃO | 76 |
| 4.2 | SISTEMA MUNDIAL DE OBSERVAÇÃO (SMO)..... | 76 |
| 4.3 | RADIOSSONDAGEM – ESTAÇÃO DE OBSERVAÇÃO DE ALTITUDE..... | 78 |
| 4.4 | SONDAGEM ATMOSFÉRICA POR SATÉLITE DE ÓRBITA POLAR..... | 83 |
| 4.4.1 | SATÉLITES NOAA..... | 83 |
| 4.4.2 | SATÉLITE NOAA-19..... | 88 |
| 4.4.3 | ESTAÇÃO TERRESTRE DE RECEPÇÃO DE DADOS POR SATÉLITE DO SIPAM-BELÉM-PA | 90 |
| 4.5 | CONSIDERAÇÕES FINAIS | 95 |
| CAPÍTULO V | | 96 |
| 5 | REDES NEURAIS ARTIFICIAIS..... | 96 |
| 5.1 | INTRODUÇÃO | 96 |
| 5.2 | CONCEITO | 97 |
| 5.3 | NEURÔNIO BIOLÓGICO..... | 98 |
| 5.4 | NEURÔNIO ARTIFICIAL | 100 |
| 5.5 | APRENDIZADO DA RNA..... | 102 |
| 5.5.1 | APRENDIZADO SUPERVISIONADO | 102 |
| 5.5.2 | APRENDIZADO NÃO-SUPERVISIONADO | 103 |

| | | |
|-------------------|--|-----|
| 5.6 | ARQUITETURA DAS RNA..... | 104 |
| 5.6.1 | REDE FEEDFORWARD..... | 104 |
| 5.6.2 | REDE FEEDBACK..... | 107 |
| 5.6.3 | REDES AUTO-ORGANIZÁVEIS | 108 |
| 5.7 | ALGORITMO <i>BACKPROPAGATION</i> | 108 |
| 5.7.1 | FORMULAÇÃO TEÓRICA..... | 108 |
| 5.7.2 | FORMULAÇÃO MATEMÁTICA | 110 |
| 5.7.3 | ALGORITMO LEVENBERG-MARQUARDT | 112 |
| 5.8 | AVALIAÇÃO DE MODELOS PREDITIVOS..... | 112 |
| 5.8.1 | MATRIZ DE CONFUSÃO..... | 112 |
| 5.9 | CONSIDERAÇÕES FINAIS | 115 |
| CAPÍTULO VI..... | | 116 |
| 6 | MATERIAS E MÉTODOS..... | 116 |
| 6.1 | INTRODUÇÃO | 116 |
| 6.2 | ÁREA DE ESTUDO | 117 |
| 6.3 | DESCRIÇÃO DOS DADOS | 118 |
| 6.4 | SELEÇÃO DOS DADOS..... | 122 |
| 6.4.1 | MODELO DE TREINAMENTO DA REDE NEURAL | 128 |
| 6.4.2 | MÉTRICAS DE AVALIAÇÃO E VALIDAÇÃO DOS CASOS DE PREVISÃO DE RAIOS | 131 |
| 6.7 | PREVISÃO DE DESCARGAS ATMÓSFERICAS POR ÁREA DE ESTUDO.... | 134 |
| 6.8 | CONSIDERAÇÕES FINAIS | 136 |
| CAPÍTULO VII..... | | 137 |
| 7 | RESULTADOS | 137 |
| 7.1 | INTRODUÇÃO | 137 |
| 7.2 | RESULTADOS DA PREVISÃO DE DESCARGAS ATMÓSFERICAS PARA TODAS AS ÁREAS DE ESTUDO..... | 137 |
| 7.2.1 | VALIDAÇÃO DA PROPOSTA | 141 |

| | | |
|---------------------|---|-----|
| 7.2.2 | COMPARAÇÃO ENTRE ALGORITMOS DE TREINAMENTO DA RNA | 166 |
| 7.3 | PREVISÃO DE DESCARGAS ATMÓSFERICAS POR ÁREA DE ESTUDO.... | 167 |
| 7.3.1 | AVALIAÇÃO DA VALIDAÇÃO DOS DADOS GERAIS DE TESTE | 167 |
| 7.3.2 | VALIDAÇÃO – 13/06/2014 | 168 |
| 7.3.3 | VALIDAÇÃO – 05/07/2014 | 168 |
| 7.3.4 | VALIDAÇÃO – 10/07/2014 | 168 |
| 7.3.5 | VALIDAÇÃO – 01/08/2014 | 169 |
| 7.3.6 | VALIDAÇÃO – 25/08/2014 | 169 |
| 7.3.7 | VALIDAÇÃO – 11/09/2014 | 169 |
| 7.3.8 | VALIDAÇÃO – 23/09/2014 | 170 |
| 7.3.9 | VALIDAÇÃO – 10/10/2014 | 170 |
| 7.3.10 | VALIDAÇÃO – 17/10/2014 | 170 |
| 7.3.11 | VALIDAÇÃO – 04/11/2014 | 171 |
| 7.3.12 | VALIDAÇÃO – 26/11/2014 | 171 |
| 7.3.13 | VALIDAÇÃO – 02/12/2014 | 171 |
| 7.3.14 | VALIDAÇÃO – 03/12/2014 | 172 |
| 7.3.15 | VALIDAÇÃO – 07/01/2015 | 172 |
| 7.3.16 | VALIDAÇÃO – 20/01/2015 | 172 |
| 7.3.17 | VALIDAÇÃO – 11/02/2015 | 173 |
| 7.3.18 | VALIDAÇÃO– 23/02/2015 | 173 |
| 7.3.19 | VALIDAÇÃO – 21/03/2015 | 173 |
| 7.3.20 | VALIDAÇÃO – 06/04/2015 | 174 |
| 7.3.21 | VALIDAÇÃO– 28/04/2015 | 174 |
| 7.3.22 | AVALIAÇÃO DA VALIDAÇÃO POR ÁREA | 174 |
| CAPÍTULO VIII | | 178 |
| 8 | CONCLUSÃO..... | 178 |
| 8.1 | CONSIDERAÇÕES FINAIS | 178 |

| | |
|--|-----|
| 8.2 PROPOSTAS DE TRABALHOS FUTUROS | 181 |
| REFERÊNCIAS | 182 |
| APÊNDICE A – Cálculo do Índice K por área de estudo | 191 |
| APÊNDICE B - Cálculo do Índice Total Totals por área de estudo | 195 |
| APÊNDICE C - Cálculo da CAPE por área de estudo..... | 199 |

LISTA DE FIGURAS

| | |
|---|----|
| Figura 1 - Mortes ocasionadas por raio nos estados do Brasil. | 25 |
| Figura 2 - Mapa da densidade anual de raios nuvem-solo por 100 km ² para região amazônica no ano de 2016..... | 26 |
| Figura 3 – Registro da corrente uma descarga atmosférica..... | 34 |
| Figura 4 - Características elétricas da atmosfera. | 35 |
| Figura 5 - Esquema representativo do circuito elétrico global..... | 37 |
| Figura 6 - Diferentes tipos de descargas atmosféricas. | 38 |
| Figura 7 - Classificação dos raios nuvem-solo por sua polaridade e direção de propagação: (a) Descarga negativa descendente, (b) Descarga negativa ascendente, (c) Descarga positiva descendente e (d) Descarga positiva ascendente. | 40 |
| Figura 8 - Exemplo de uma nuvem CB. | 41 |
| Figura 9 - Classificação das nuvens. | 42 |
| Figura 10 - Estágios de uma nuvem: (a) ao saturar-se, a massa de ar úmido que se elevou da superfície aquecida da Terra cria uma nuvem cumulus, estágio inicial, (b) estágio maduro, (c) inicia-se o processo de dissipação devido ao decréscimo das correntes ascendentes que levam ar úmido ou aumento de temperatura (setas vermelhas – ar quente, setas azuis – ar frio)..... | 42 |
| Figura 11 - Processo de colisão indutivo..... | 44 |
| Figura 12 - Esquema de uma nuvem eletrificada positivamente e negativamente..... | 45 |
| Figura 13 - Etapas de formação de uma descarga atmosférica. (a) formação do líder escalonado, (b) ocorrência da descarga de retorno e (c) múltiplas descargas subsequentes de retorno..... | 46 |
| Figura 14 - Etapas e tempos da descarga atmosférica do tipo nuvem-solo..... | 47 |
| Figura 15- Valores acumulados de corrente de pico: (1) Descarga negativa única ou primeira, (2) descarga negativa subsequente à primeira e (3) descarga positiva. | 49 |
| Figura 16 - Valores de probabilidade acumulados da carga de um impulso da descarga: (1) Descarga negativa única ou primeira, (2) descarga negativa subsequente à primeira e (3) descarga positiva..... | 50 |
| Figura 17 - Valores de probabilidade acumulados de tempo de frente de onda: (1) Descarga negativa única ou primeira, (2) descarga negativa subsequente à primeira e (3) descarga positiva. | 51 |
| Figura 18 - Valores de probabilidade acumulados de tempo de meia onda: (1) Descarga negativa única ou primeira, (2) descarga negativa subsequente à primeira e (3) descarga positiva. | 52 |
| Figura 19 - Valores de probabilidade acumulados do tempo de duração total da descarga: (1) Descarga negativa única ou primeira, (2) descarga negativa subsequente à primeira e (3) descarga positiva..... | 53 |
| Figura 20 - Valores de probabilidade acumulados de derivada máxima: (1) Descarga negativa única ou primeira, (2) descarga negativa subsequente à primeira e (3) descarga positiva..... | 54 |
| Figura 21 - Valores de probabilidade acumulados de energia por unidade de resistência: (1) Descarga negativa única ou primeira, (2) descarga negativa subsequente à primeira e (3) descarga positiva..... | 55 |

| | |
|---|-----|
| Figura 22 - Esquema de uma torre de medição de raios naturais..... | 56 |
| Figura 23 – Mapa da Densidade de Raios do Brasil. | 58 |
| Figura 24 - Mapa de densidade de raios nuvem-solo para o estado de Minas Gerais..... | 60 |
| Figura 25 - Tipos de sistemas de localização de descargas atmosféricas pela faixa de frequência. | 61 |
| Figura 26 - Esquema de um sistema de localização. | 62 |
| Figura 27 - Determinação do ponto de localização da descarga atmosférica pela técnica de indicação de direção. | 63 |
| Figura 28 - Determinação do ponto de localização da descarga atmosférica pela técnica da diferença no tempo de chegada. | 64 |
| Figura 29 - Determinação do ponto de ocorrência de uma descarga atmosférica pela técnica interferométrica. | 64 |
| Figura 30 - Composição da atmosfera terrestre..... | 66 |
| Figura 31 - Consideração de estados de estabilidade ou instabilidade da atmosfera, considerando o método da parcela..... | 68 |
| Figura 32 - Área da CAPE (positiva em vermelho) e Área da CINE (negativa em azul)..... | 75 |
| Figura 33 - Sistema mundial de observação meteorológica. | 77 |
| Figura 34 - Órbitas dos satélites polar e geoestacionário ao redor do planeta Terra..... | 77 |
| Figura 35 - Órbita de satélites polares. | 78 |
| Figura 36 - Radiossondas. | 79 |
| Figura 37 - Esquema simplificado do mecanismo de radiossondagem..... | 80 |
| Figura 38 -Estações de radiossondagem ao redor do mundo. | 80 |
| Figura 39 - Diagrama Skew-T Log-P resultando de uma radiossondagem..... | 81 |
| Figura 40 - Redes de Estações Meteorológicas de Altitude no Brasil. | 82 |
| Figura 41 - Sensores a bordo do satélite NOAA-19..... | 89 |
| Figura 42 - Visualização do percurso do satélite NOAA-19 sobre a América do Sul. | 89 |
| Figura 43 - Antena de Recepção de dados de sondagem do NOAA-19 pelo SIPAM. | 90 |
| Figura 44 - Interface gráfica do Terascan viewer..... | 93 |
| Figura 45 - Pontos de obtenção de dados de sondagens pelo NOAA-19..... | 94 |
| Figura 46 - Diagrama Skew-T Log-P resultando da sondagem do satélite NOAA-19. | 95 |
| Figura 47 - Neurônio Biológico Humano..... | 99 |
| Figura 48 - Representação do mecanismo de propagação dos estímulos nervosos pelos neurônios. | 100 |
| Figura 49 - Modelo do neurônio artificial. | 100 |
| Figura 50 - Analogia entre os neurônios naturais e neurônios artificiais. | 102 |
| Figura 51 - Esquema de aprendizado Supervisionado..... | 103 |
| Figura 52 - Esquema de aprendizado não-supervisionado. | 103 |
| Figura 53 -Redes Feedforwards: uma camada (a) e multicamadas (b). | 105 |
| Figura 54 - MLP aplicada a um problema de classificação..... | 106 |
| Figura 55 - Redes Feedbacks: rede com recorrência entre saídas e camada intermediária (a) e rede com recorrência auto-associativa (b). | 107 |
| Figura 56 - Rede neural auto-organizável. | 108 |
| Figura 57 - Etapa de propagação do algoritmo backpropagation..... | 109 |
| Figura 58 - Etapa de retropropagação do algoritmo backpropagation. | 109 |

| | |
|--|-----|
| Figura 59 - Grafo de fluxo de um neurônio para análise do algoritmo Backpropagation..... | 110 |
| Figura 60 - Espaço ROC..... | 115 |
| Figura 61 - Área de estudo. | 118 |
| Figura 62 - Diagrama Skew-T Log-P mostrando o perfil vertical da temperatura do ar (linha em vermelho) e temperatura do ponto de orvalho (linha azul). Índices de instabilidade atmosférica: K (Índice K), TT (Índice Total Totals), APrec (Água Precipitável), CAPE. | 120 |
| Figura 63 - Casos de previsão de raios..... | 121 |
| Figura 64 - Variabilidade para temperatura do ar..... | 123 |
| Figura 65 - Variabilidade para temperatura do ponto de orvalho. | 124 |
| Figura 66 - Componentes Principais: temperatura do ar. | 125 |
| Figura 67 - Componentes Principais: temperatura do ponto de orvalho. | 126 |
| Figura 68 - Divisão aleatória dos dados em treino, validação e teste..... | 127 |
| Figura 69 - Modelo de treinamento da RNA..... | 128 |
| Figura 70 - Modelo da RNA..... | 130 |
| Figura 71 - Índice K - Área 1. | 191 |
| Figura 72 - Índice K – Área 2..... | 191 |
| Figura 73 - Índice K – Área 3..... | 192 |
| Figura 74 - Índice K – Área 4..... | 192 |
| Figura 75 -Índice K – Área 5..... | 193 |
| Figura 76 - Índice K – Área 6..... | 193 |
| Figura 77 - Índice K – Área 7..... | 194 |
| Figura 78 - Índice K – Área 8..... | 194 |
| Figura 79 - Índice Total Totals – Área 1. | 195 |
| Figura 80 - Índice Total Totals – Área 2. | 195 |
| Figura 81 - Índice Total Totals – Área 3. | 196 |
| Figura 82 - Índice Total Totals – Área 4. | 196 |
| Figura 83 - Índice Total Totals – Área 5. | 197 |
| Figura 84 - Índice Total Totals – Área 6. | 197 |
| Figura 85 - Índice Total Totals – Área 7. | 198 |
| Figura 86 - Índice Total Totals – Área 8. | 198 |
| Figura 87 - Valores de CAPE para Área 1. | 199 |
| Figura 88 - Valores de CAPE para Área 2. | 199 |
| Figura 89 - Valores de CAPE para Área 3. | 200 |
| Figura 90 - Valores de CAPE para Área 4. | 200 |
| Figura 91 - Valores de CAPE para Área 5. | 201 |
| Figura 92 - Valores de CAPE para Área 6. | 201 |
| Figura 93 - Valores de CAPE para Área 7. | 202 |
| Figura 94 - Valores de CAPE para Área 8. | 202 |
| Figura 95 - Comportamento do Índice K e valor limite (linha em vermelho) para ocorrência ou não de tempestades de raios..... | 133 |
| Figura 96 - Comportamento do Índice Total Totals e valor limite (linha em vermelho) para ocorrência ou não de tempestades de raios..... | 133 |
| Figura 97 - Comportamento da CAPE e valor limite (linha em vermelho) para ocorrência ou não de tempestades de raios. | 134 |

| | |
|--|-----|
| Figura 98 - Divisão não aleatória em dados de treino e validação..... | 135 |
| Figura 99 - Gráfico ROC para os melhores resultados dos casos 1, 2, 3, 4 e 5..... | 140 |
| Figura 100 - Comparação entre as acurácias de predição entre MP e MT para Caso 1 aplicado na Área 1..... | 142 |
| Figura 101 - Comparação entre as acurácias de predição entre MP e MT para Caso 2 aplicado na Área 1..... | 143 |
| Figura 102 - Comparação entre as acurácias de predição entre MP e MT para Caso 3 aplicado na Área 1..... | 143 |
| Figura 103 - Comparação entre as acurácias de predição entre MP e MT para Caso 4 aplicado na Área 1..... | 144 |
| Figura 104 - Comparação entre as acurácias de predição entre MP e MT para Caso 5 aplicado na Área 1..... | 144 |
| Figura 105 - Comparação entre as acurácias de predição entre MP e MT para Caso 1 aplicado na Área 2..... | 145 |
| Figura 106 - Comparação entre as acurácias de predição entre MP e MT para Caso 2 aplicado na Área 2..... | 146 |
| Figura 107 - Comparação entre as acurácias de predição entre MP e MT para Caso 3 aplicado na Área 2..... | 146 |
| Figura 108 - Comparação entre as acurácias de predição entre MP e MT para Caso 4 aplicado na Área 2..... | 147 |
| Figura 109 - Comparação entre as acurácias de predição entre MP e MT para Caso 5 aplicado na Área 2..... | 147 |
| Figura 110 - Comparação entre as acurácias de predição entre MP e MT para Caso 1 aplicado na Área 3..... | 148 |
| Figura 111 - Comparação entre as acurácias de predição entre MP e MT para Caso 2 aplicado na Área 3..... | 149 |
| Figura 112 - Comparação entre as acurácias de predição entre MP e MT para Caso 3 aplicado na Área 3..... | 149 |
| Figura 113 - Comparação entre as acurácias de predição entre MP e MT para Caso 4 aplicado na Área 3..... | 150 |
| Figura 114 - Comparação entre as acurácias de predição entre MP e MT para Caso 5 aplicado na Área 3..... | 150 |
| Figura 115 - Comparação entre as acurácias de predição entre MP e MT para Caso 1 aplicado na Área 4..... | 151 |
| Figura 116 - Comparação entre as acurácias de predição entre MP e MT para Caso 2 aplicado na Área 4..... | 152 |
| Figura 117 - Comparação entre as acurácias de predição entre MP e MT para Caso 3 aplicado na Área 4..... | 152 |
| Figura 118 - Comparação entre as acurácias de predição entre MP e MT para Caso 4 aplicado na Área 4..... | 153 |
| Figura 119 - Comparação entre as acurácias de predição entre MP e MT para Caso 5 aplicado na Área 4..... | 153 |
| Figura 120 - Comparação entre as acurácias de predição entre MP e MT para Caso 1 aplicado na Área 5..... | 154 |

| | |
|--|-----|
| Figura 121 - Comparação entre as acurácias de predição entre MP e MT para Caso 2 aplicado na Área 5..... | 155 |
| Figura 122 - Comparação entre as acurácias de predição entre MP e MT para Caso 3 aplicado na Área 5..... | 155 |
| Figura 123 - Comparação entre as acurácias de predição entre MP e MT para Caso 4 aplicado na Área 5..... | 156 |
| Figura 124 - Comparação entre as acurácias de predição entre MP e MT para Caso 5 aplicado na Área 5..... | 156 |
| Figura 125 - Comparação entre as acurácias de predição entre MP e MT para Caso 1 aplicado na Área 6..... | 157 |
| Figura 126 - Comparação entre as acurácias de predição entre MP e MT para Caso 2 aplicado na Área 6..... | 158 |
| Figura 127 - Comparação entre as acurácias de predição entre MP e MT para Caso 3 aplicado na Área 6..... | 158 |
| Figura 128 - Comparação entre as acurácias de predição entre MP e MT para Caso 4 aplicado na Área 6..... | 159 |
| Figura 129 - Comparação entre as acurácias de predição entre MP e MT para Caso 5 aplicado na Área 6..... | 159 |
| Figura 130 - Comparação entre as acurácias de predição entre MP e MT para Caso 1 aplicado na Área 7..... | 160 |
| Figura 131 - Comparação entre as acurácias de predição entre MP e MT para Caso 2 aplicado na Área 7..... | 161 |
| Figura 132 - Comparação entre as acurácias de predição entre MP e MT para Caso 3 aplicado na Área 7..... | 161 |
| Figura 133 - Comparação entre as acurácias de predição entre MP e MT para Caso 4 aplicado na Área 7..... | 162 |
| Figura 134 - Comparação entre as acurácias de predição entre MP e MT para Caso 5 aplicado na Área 7..... | 162 |
| Figura 135 - Comparação entre as acurácias de predição entre MP e MT para Caso 1 aplicado na Área 8..... | 163 |
| Figura 136 - Comparação entre as acurácias de predição entre MP e MT para Caso 2 aplicado na Área 8..... | 164 |
| Figura 137 - Comparação entre as acurácias de predição entre MP e MT para Caso 3 aplicado na Área 8..... | 164 |
| Figura 138 - Comparação entre as acurácias de predição entre MP e MT para Caso 4 aplicado na Área 8..... | 165 |
| Figura 139 - Comparação entre as acurácias de predição entre MP e MT para Caso 5 aplicado na Área 8..... | 165 |

LISTA DE TABELAS

| | |
|--|-----|
| Tabela 1 - Parâmetros físicos da primeira descarga de retorno e descarga de retorno subsequente das descargas nuvem-solo negativas..... | 48 |
| Tabela 2 - Valores de CAPE..... | 74 |
| Tabela 3- História da série de satélites NOAA..... | 84 |
| Tabela 4 - Series de satélites NOAA com seus sondadores. | 86 |
| Tabela 5 - Características do sensor MHS..... | 88 |
| Tabela 6 - Matriz de confusão para avaliação dos modelos de classificação..... | 113 |
| Tabela 7 - Coordenadas geográficas dos centroides de cada área..... | 118 |
| Tabela 8- Propriedades de desenvolvimento das RNA. | 128 |
| Tabela 9 - Cenários de previsões por áreas de estudo em relação as situações observadas... | 135 |
| Tabela 10 - Resultados obtidos para os casos 1, 2, 3 4 e 5..... | 138 |
| Tabela 11 - Matrix de confusão e acurácia..... | 139 |
| Tabela 12 - Resultados da AUC obtida a partir da ROC..... | 141 |
| Tabela 13 - Acurácia de comparação entre algoritmo de treinamento da RNA..... | 166 |
| Tabela 14 - Matriz de confusão geral de teste. | 167 |
| Tabela 15 - Predição para o dia 13/06/2014. | 168 |
| Tabela 16 - Predição para o dia 05/07/2014. | 168 |
| Tabela 17 - Predição para o dia 10/07/2014. | 168 |
| Tabela 18 - Predição para o dia 01/08/2014. | 169 |
| Tabela 19 - Predição para o dia 25/08/2014. | 169 |
| Tabela 20 - Predição para o dia 11/09/2014. | 169 |
| Tabela 21 - Predição para o dia 11/09/2014. | 170 |
| Tabela 22 - Predição para o dia 10/10/2014. | 170 |
| Tabela 23 - Predição para o dia 17/10/2014. | 170 |
| Tabela 24 - Predição para o dia 04/11/2014. | 171 |
| Tabela 25 - Predição para o dia 26/11/2014. | 171 |
| Tabela 26 - Predição para o dia 02/12/2014. | 171 |
| Tabela 27 - Predição para o dia 03/12/2014. | 172 |
| Tabela 28 - Predição para o dia 07/01/2015. | 172 |
| Tabela 29 - Predição para o dia 20/01/2015. | 172 |
| Tabela 30 - Predição para o dia 11/02/2015. | 173 |
| Tabela 31 - Predição para o dia 23/02/2015. | 173 |
| Tabela 32 - Predição para o dia 21/03/2015. | 173 |
| Tabela 33 - Predição para o dia 06/04/2015. | 174 |
| Tabela 34 - Predição para o dia 28/04/2015. | 174 |
| Tabela 35 - Matriz de confusão da Área 1..... | 174 |
| Tabela 36 - Matriz de confusão da Área 2..... | 175 |
| Tabela 37 - Matriz de confusão da Área 3..... | 175 |
| Tabela 38 - Matriz de confusão da Área 4..... | 175 |
| Tabela 39 - Matriz de confusão da Área 5..... | 176 |
| Tabela 40 - Matriz de confusão da Área 6..... | 176 |

| | |
|---|-----|
| Tabela 41 - Matriz de confusão da Área 7..... | 176 |
| Tabela 42 - Matriz de confusão da Área 8..... | 177 |

LISTA DE ABREVIACÕES

| | |
|----------|--|
| CAPE | Energia Potencial Convectiva Disponível |
| Cb | Cumulunimbus |
| CENSIPAM | Centro Gestor e Operacional do Sistema de Proteção da Amazônia |
| CINE | Energia Potencial Convectiva |
| IK | Índice K |
| ITT | Índice Total Totals |
| NASA | National Aeronautics and Space Administration |
| NOAA | National Oceanic and Atmospheric Administration |
| MM | Modelo de Mesoescala |
| RNA | Redes Neurais Artificiais |
| SIPAM | Sistema de Proteção da Amazônia |
| UTC | Tempo Universal Coordenado – do inglês <i>Universal Time Coordinated</i> |
| WMO | Organização Meteorológica Mundial – do inglês <i>World Meteorological Organization</i> |
| WRF | <i>Weather Research and Forecasting</i> |

RESUMO

As descargas atmosféricas oferecem grande risco à população e às atividades que envolvem diferentes sistemas como telecomunicações, transmissão de energia elétrica, transporte e dentre outros. A previsão de ocorrência de raios pode contribuir para minimizar os riscos deste fenômeno natural. Com isso, esta tese apresenta uma proposta de modelo de previsão de raios baseada na utilização de dados de sondagens atmosféricas por satélite, validado com dados históricos de raios para áreas de estudo da região Amazônica no Brasil, mediante um estudo que considerou cinco casos de período de validade de previsão de raios: caso 1 (uma hora), caso 2 (duas horas), caso 3 (três horas), caso 4 (quatro horas) e caso 5 (cinco horas). Foram utilizadas duas metodologias diferentes de previsão: a primeira versão do previsor utilizou os dados de todas as áreas do estudo na formação aleatória dos conjuntos de treinamento, validação e teste. Em uma segunda versão, não se utilizou o critério de aleatoriedade dos dados na formação dos conjuntos de treinamento e teste, e os mesmos foram limitados para cada área do estudo, de forma a criar previsões individualizadas por área geográfica estudada. A ferramenta de engenharia utilizada para previsão foi uma Rede Neural Artificial (RNA) treinada com o algoritmo Levenberg-Marquardt *backpropagation* com a finalidade de classificar as modelagens preditivas de raios. A classificação consistiu na possibilidade de prever a ocorrência ou ausência de raios a partir do perfil vertical de temperatura do ar (temperatura do ar e temperatura do ponto de orvalho) obtido pelo satélite NOAA-19. Os resultados obtidos pela RNA, na primeira abordagem, foram comparados com metodologias tradicionais estabelecidas na literatura de previsão de raios, na segunda abordagem os resultados obtidos mostraram a saída do previsor para dados reais de teste. Os resultados de ambas abordagens mostraram que a RNA foi capaz de identificar adequadamente a que classe pertence um novo exemplo em relação às categorias de ocorrência ou ausência de raios. Para a primeira abordagem, obteve-se o melhor desempenho para caso 5, com uma acurácia de teste de 95,6%, enquanto que para a segunda abordagem obteve-se uma acurácia geral de teste de 82,04%.

Palavras-Chave: Sondagem atmosférica por satélite. Redes Neurais Artificiais. Classificadores. Previsão de Descargas Atmosféricas.

ABSTRACT

Atmospheric discharges offer great risks to the population and activities that involve different systems such as telecommunications, energy distribution and transportation and among others. Lightning prediction can contribute to minimize the risks of this natural phenomenon. Therefore, this thesis presents a model for lightning prediction based on satellite atmospheric sounding data, validated with lightning data for study areas of the Amazon region in Brazil, through an investigation that considered five period cases for validation of lightning prediction: case 1 (one hour), case 2 (two hours), case 3 (three hours), case 4 (four hours) and case 5 (five hours). Two different forecasting methodologies were used: the first version of the predictor used data from all study areas in the random formation of the sets training, validation and test. In a second version, we did not use the criterion of randomness of the data in the formation of the training and test sets, and same were limited for each area of the study, in order to create individualized forecasts by geographical area studied. The machine learning technique used to predict lightning was the Artificial Neural Network (ANN) trained with Levenberg-Marquardt backpropagation algorithm to classify modeling related to lightning prediction. This classification relied on the possibility of lightning prediction from the vertical profile of air temperature obtained from satellite NOAA-19. The results obtained by RNA, in the first approach, were compared with traditional methodologies established in the lightning prediction literature, in the second approach the results obtained showed the predictor's output for real test data. Results show that ANN was capable of identifying adequately the class to which a new event belongs to in relation to categories of occurrence and absence of lightning. For the first approach, the best performance for case 5 was obtained, with a test accuracy of 95.6%, while for the second approach a general test accuracy of 82.04% was obtained.

Keywords: Satellite Atmospheric Sounding. Artificial Neural Network. Classifiers. Prediction of Atmospheric Discharges.

CAPÍTULO I

1 INTRODUÇÃO

1.1 INTRODUÇÃO

Esta tese realiza a apresentação de uma nova proposta de previsão de descargas atmosféricas na região amazônica, tendo como principal inovação, a utilização de dados de sondagem atmosférica por satélite como elementos preditivos de classificadores automáticos baseadas em redes neurais artificiais. Inicialmente é realizada a exposição da temática deste trabalho, bem como os principais problemas relacionados às ocorrências de raios e a problemática que esta tese busca solucionar. Em seguida, é abordada a contribuição e a relevância deste estudo, depois são destacados os objetivos e pôr fim a estrutura no qual este trabalho está organizado.

1.1.1 TEMA E PROBLEMA

Descarga atmosférica ou raio é um fenômeno complexo que acontece na Natureza, desde a formação e evolução do planeta Terra. Dessa forma, há séculos a humanidade convive com a ocorrência deste fenômeno ambiental associado a eventos meteorológicos. Embora majestoso pela sua grandeza e pelo seu poder destrutivo, os raios oferecem grandes riscos à população e as atividades que envolvem diferentes sistemas como telecomunicações, transmissão de energia elétrica, transporte e dentre outras. Com isso, ao longo dos anos a ciência veio buscando mecanismos para tentar compreender, desde seu processo de formação até sua incidência na natureza, com objetivo de diminuir os riscos destes à sociedade. Uma estratégia que minimiza seus danos é a utilização de modelos de previsões de raios. Estes permitem com certa antecedência à identificação de condições favoráveis a ocorrência de raios, assim permitindo a tomada de decisão quanto aos impactos que este fenômeno pode ocasionar.

Segundo Ritenour et al. (2008): “raios atingem a terra mais de 100 vezes por segundo ou 8 milhões de vezes por dia e cerca de 50.000 tempestades de raios ocorrem a cada dia”. Esses dados são reforçados, mais recentemente, em ELAT (2016) que estima que cerca de 50-100 raios ocorram no mundo a cada segundo, o que equivale a cerca de 5 a 10 milhões de raios por dia ou cerca de 1 a 3 bilhões por ano. Portanto, o risco de ser atingido por um raio é

extremamente grande, principalmente em determinadas regiões do planeta que apresentam altas taxas de ocorrências de raios.

A formação da descarga atmosférica é um processo natural em nosso planeta, com isso sua incidência é quase inevitável. Algumas regiões do planeta têm maiores tendências a produzirem descargas atmosféricas, assim uma localidade pode ser atingida com maior ou menor intensidade de acordo com as condições climáticas propícias à sua formação. Ademais, a incidência do raio que pode ser tanto através da descarga direta, isto é, pela incidência direta do raio ou mediante uma descarga indireta, isto é, através de tensões induzidas provocadas quando o raio atinge algum ponto próximo de sua incidência. Ambas as situações trazem consigo inúmeras consequências negativas para a sociedade.

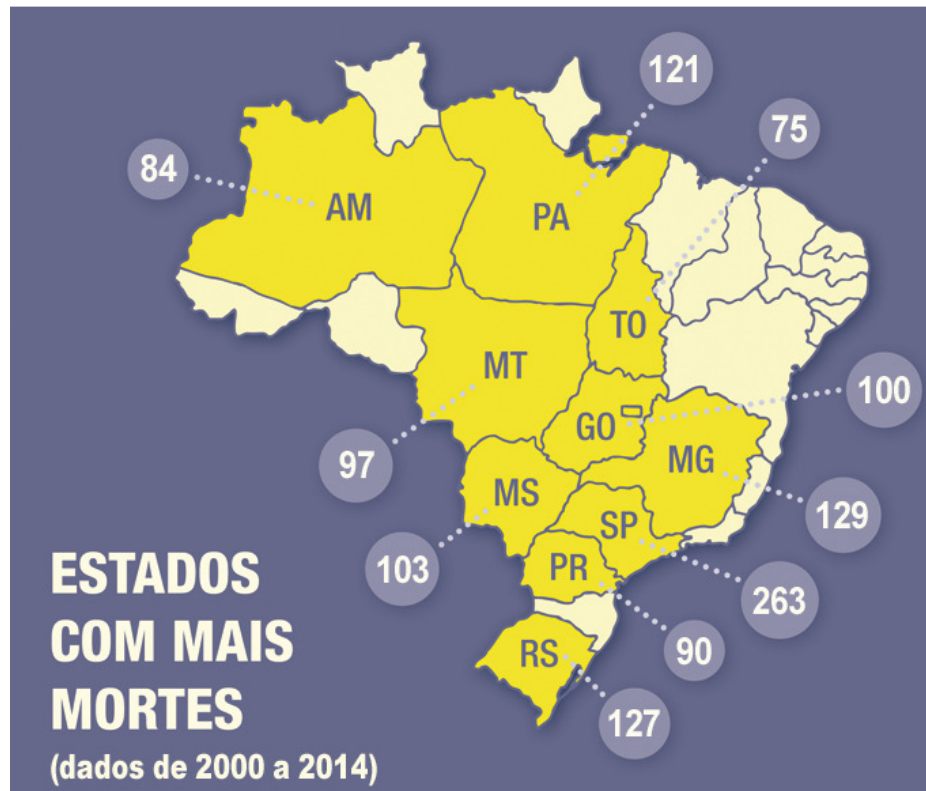
Um dos efeitos mais negativos dos raios para a sociedade está relacionado ao número de mortes e lesões provocadas por este fenômeno e que são fortemente associados às condições de tempo (ZENG et al., 2013).

Estudos globais, nas últimas décadas, estimaram de 6.000 a 24.000 o número de fatalidades ocasionadas por raios (CARDOSO et al., 2011; HOLLE, 2008). No Brasil, no ano de 2009, a taxa de mortalidade ocasionada por raios foi estimada em 0,8 fatalidades por milhão (HOLLE, 2014). Além disso, há prejuízos econômicos e sociais causados em sistemas de telecomunicações, transmissão de energia elétrica e aviação pela incidência direta ou indireta de raios, ocasionando perdas monetárias (WENG et al., 2010; JUNTIAN, 2011; RAKOV et al., 2002).

O Brasil é um dos países que possuem a maior incidência de descarga atmosférica no tipo nuvem-solo. Estima-se que, em média, cerca de 78 milhões de raios atinjam o solo brasileiro por ano (AGÊNCIA BRASIL, 2017). Dados do ELAT (2016) mostram que a cada 50 mortes ocasionadas por raios no mundo, uma ocorre no Brasil.

A Figura 1 exibe a quantidade de mortes ocasionadas por raios no Brasil, nos períodos de 2000 até 2014. Nota-se que os estados que apresentaram maiores taxas de mortalidades foram respectivamente: São Paulo com 263 mortes, Minas Gerais com 129 mortes, Rio Grande do Sul com 127 mortes e o Pará com 121 mortes. Nesse período foram registradas ao todo 1.790 mortes no Brasil.

Figura 1 - Mortes ocasionadas por raio nos estados do Brasil.

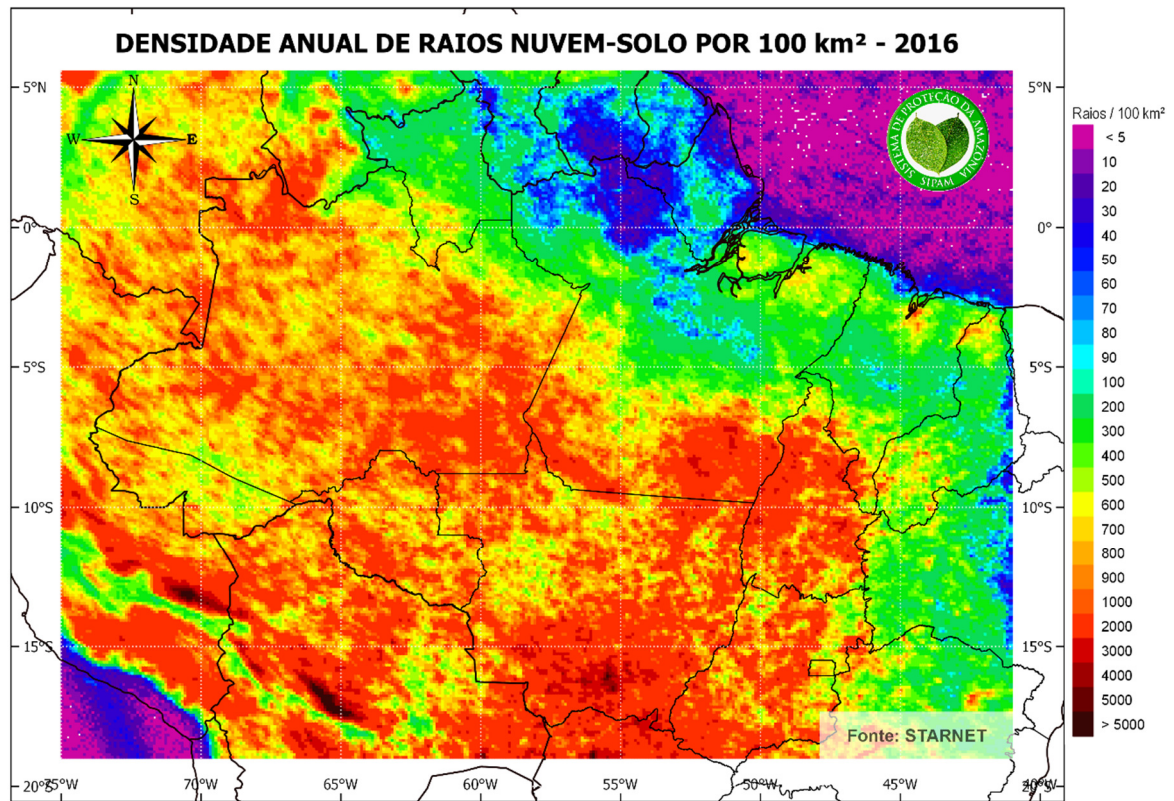


Fonte: ELAT (2016)

A alta incidência de raios no Brasil, ocorre em função da grande dimensão territorial do país e sua localização próxima a linha do equador (região com clima tropical) que favorece condições climáticas de temperaturas propícias à ocorrência de raios, isto é, clima quente e úmido.

No estado do Pará, os dez municípios com maiores concentrações de raios são: Igarapé-Miri, Barcarena, Belém, Benevides, Limoeiro do Ajuru, Ourilândia do Norte, Tucumã, Cametá, Ananindeua e Marituba. Estes apresentaram, respectivamente, as seguintes densidades de descargas atmosféricas em $Km^{-2} \times Ano^{-1}$: 13,91, 13,59, 13,43, 13,38, 13,38, 13,34, 13,33, 12,77, 12,66 e 12,44 (ELAT, 2016). A Figura 2 exhibe o mapa de densidade de raios para a região amazônica, nota-se que a região apresentou altas taxas de incidências de raios durante o ano de 2016.

Figura 2 - Mapa da densidade anual de raios nuvem-solo por 100 km² para região amazônica no ano de 2016.



Fonte: STARNET (2017)

Raios nuvem-solo são um dos principais fatores que afetam o funcionamento de uma rede de energia elétrica, ocasionando interrupção dos serviços (PU et al., 2012). No passado no Brasil, entre 50% e 70% das interrupções em linhas de transmissão estavam especificamente, relacionadas pelos efeitos dos raios nuvem-solo (ZEPKA et al., 2013).

É evidente que os raios podem se tornar uma ameaça em potencial para as diversas atividades da sociedade, ocasionando grandes impactos negativos. As tecnologias atuais não são capazes de evitar a ocorrência de raios (WENG et al., 2010). Assim, a adoção de uma estratégia eficiente para previsão de raios pode contribuir para a diminuição ou eliminação dos impactos ocasionados pelos raios.

Estudos científicos já foram desenvolvidos com objetivo de prever a ocorrência de raios. A maioria das investigações realizadas com este foco estabelece uma associação das condições atmosféricas favoráveis à ocorrência de raios, como por exemplo: Sá (2011), Weng et al. (2010), Zepka et al. (2014) e Wang et al. (2014). Essas condições são determinadas através de índices e parâmetros termodinâmicos derivados, principalmente de radiossondagens convencionais (PIPIER, 1988). São exemplos: Índice SWEAT (MILLER, 1972), Energia

Potencial Convectiva Disponível - CAPE (MONCRIEFF; MILLER, 1976), Inibição Convectiva-CINE (COLBY, 1984), Índice *Showalter* (SHOWALTER, 1953), Índice de Levantamento (*Lifted Index*) (GALWAY, 1956), Índice K (*K Index*) (GEORGE, 1960), Índice Total Totals (*Total Total Index*) (MILLER, 1972), Água Precipitável (*Precipitable Water*) (MILLER, 1972), entre outros.

Alguns estudos tentaram associar alguns índices e parâmetros termodinâmicos usando técnicas de inteligência computacional para desenvolver modelos de previsão de raios. Weng et al. (2010) utilizaram o Índice K e Índice de Levantamento para prever raios na Malásia através do treinamento de uma rede neural *backpropagation*. Enquanto em Johari et al. (2007) utilizaram dados meteorológicos como: vento, temperatura do ar, temperatura do ponto de orvalho, umidade relativa do ar, dentre outros, como parâmetros preditivos de raios para uma rede neural *backpropagation*. Wang et al. (2014) utilizaram CAPE, Índice K, Índice Jefferson e Índice SWEAT, como entradas para uma rede neural *backpropagation*. Outros estudos como: Zepka et al. (2013), Zepka et al. (2014), Zhou et al. (2012) e Sá et al. (2011) também se basearam na análise das condições de instabilidade atmosférica para prever raios. Sendo todos estes índices e parâmetros termodinâmicos obtidos por meio de radiossondagem convencional.

Frankel, et al. (1991) desenvolveram uma arquitetura de rede neural para gerar mapas espaço-temporais para prever raios no *Cape Canaveral Air Force Station* (CCAFS) e em *Kennedy Space Center* (KSC). Lu, et al. (2011) fizeram estudos estatísticos de atividade de raios na província de Huna, na China, resumindo situações típicas de condição de tempo, como propícias para a ocorrência de raios. Outros estudos como Juntian et al. (2011) e Zeng et al. (2013) basearam seus modelos de previsão de raios no campo eletrostático atmosférico formado pelas tempestades.

Zepka (2005) utilizou variáveis meteorológicas oriundas de modelo de mesoescola MM5 como entrada para uma RNA, para prever o local de ocorrência de descargas atmosféricas, no estado do Rio de Janeiro. Entre as variáveis meteorológicas preditoras estão: campo de simulação de divergência (10^{-4} s^{-1}), em superfície e 200 mb, advecção de temperatura (K/h), nos níveis de pressão de 850 e 500 mb, razão de mistura (10^{-3} g/Kg), em superfície e 850 mb, e velocidade vertical do vento (10^{-2} m/s) em 500 mb. Essas variáveis foram correlacionadas com a ocorrência de tempestades elétricas.

Zepka (2011) estabeleceu uma metodologia de previsão de raios combinando variáveis meteorológicas (CAPE, índice de levantamento, índice K, temperatura potencial equivalente, velocidade vertical média e integrado da razão de mistura de gelo) obtidas de simulações numéricas de alta resolução espacial através do modelo de mesoescala *Weather Research and*

Forecasting (WRF). Giannaros et al. (2015) empregou o mesmo modelo WRF para prever dez eventos de raios na Grécia, realizando parametrizações da fronteira planetária e camada de superfície. Apesar dos avanços em modelos de previsão de descargas atmosféricas, muito ainda se tem a discutir, analisar e descobrir.

O Centro Gestor e Operacional do Sistema de Proteção da Amazônia (CENSIPAM) é um órgão vinculado ao Ministério da Defesa do Brasil, cuja missão consiste em promover a proteção da Amazônia Legal, o que inclui ações de monitoramento ambiental da região por meio de sensores orbitais. O CENSIPAM dispõe de três estações situadas nas cidades de Porto Velho-RO, Manaus-AM e Belém-PA, para recepção de dados de satélites de órbita polar, incluindo os satélites NOAA-18 e NOAA-19. Estes satélites possuem sondadores atmosféricos capazes de obter perfis verticais de temperatura, contribuindo para importantes análises do comportamento atmosférico regional. A sondagem atmosférica por satélite constitui uma ferramenta de grande importância para determinar as condições de estabilidade da atmosfera, pois a densidade de estações que realizam radiossondagens convencionais é extremamente baixa na Amazônia.

A avaliação de sondagens verticais por satélite já foi efetuada em escala global (Li et al., 2000), porém na Amazônia isto era um assunto pouco explorado. Assim, a primeira etapa deste trabalho foi validar e quantificar o desempenho do sensor ATOVS embarcado no satélite NOAA-16 para Belém-PA, confrontando as medições com radiossondagens da estação situada no aeroporto Internacional de Belém. Os dados de satélite foram coletados na estação de recepção do SIPAM (Sistema de Proteção da Amazônia), situada em Belém-PA.

A convecção atmosférica é um processo físico, fundamental para a formação e suporte às nuvens de tempestades, em especial aquelas do tipo *Cumulonimbus* (CB) (UMAN, 1994). Estas nuvens geram grandes centros de cargas elétricas nas nuvens e seu processo de formação depende de forçantes termodinâmicas (umidade e temperatura) e/ou forçantes dinâmicas (sistemas meteorológicos e vento).

Um sistema de previsão de raios com tecnologias de proteção de raios existentes pode reduzir drasticamente os danos causados pela descarga direta ou indireta, principalmente onde não há sistemas de cobertura (WENG et. al., 2010). Assim, identificar com certa antecedência a possibilidade de ocorrência de raios através de condições meteorológicas propícias a sua formação permite a adoção de medidas preventivas, como alerta pela defesa civil por conseguinte antecipação de adoção de estratégias que visam tornar mínimos os danos ocasionados pelos raios. Portanto, discutir meios de prever a ocorrência de raios é permitir

conhecer e analisar melhor o ambiente atmosférico onde esse fenômeno natural acontece, pois, cada localidade apresenta diferentes condições climáticas favoráveis à sua formação.

Atualmente, a Amazônia com sua vasta área territorial e sendo bastante “atingida” por raio, ainda não dispõe de um modelo de previsão específico que considere o ambiente desta região para locais que não se dispõem de medidas de radiossondagens convencionais. A maioria dos estudos já desenvolvidos relacionados à previsão de descargas atmosférica, como já citada, por exemplo: Wang et al. (2014), Zepka et al. (2013), Zepka et al. (2014), Zhou et al. (2012), Sá et al. (2011), Johari et al. (2007) e Weng et al. (2010) restringiram seus modelos de previsão ao uso de dados de radiossondagem convencional. Com isso, limitando seus modelos de previsões a locais que possuem estações de radiossondagem.

O único estudo que considerou as particularidades locais (Amazônia) para previsão de raio, foi o realizado por Sá et al. (2011). Em seu estudo, as variáveis preditoras que foram correlacionadas com eventos de raios, foram derivadas por radiossondagem convencional, realizada às 09:00 horas locais, na estação meteorológica de altitude de Belém-PA. Recentemente, Alves et al. (2017) baseado em dados de sondagem atmosférica por satélite, mostrou a possibilidade de realização de predições de raios através de sondagens satelitais para a região amazônica.

Dessa forma, o aspecto inovador desta tese está relacionado à aplicação de dados de sondagem atmosférica por satélite para previsão de descargas atmosféricas, o que caracterizou esse estudo de previsão como sendo inédito nesse campo de pesquisa científica. Todos os dados de satélites utilizados no desenvolver deste trabalho foram obtidos pela estação receptora do SIPAM, localizada em Belém-PA.

Diante do exposto, esta tese visa contribuir com uma nova metodologia de previsão de descargas atmosféricas para a região amazônica, adicionada a valores de percentuais de erros, no qual permitiu o reconhecimento de padrões das características do estado da atmosfera instável associada à formação de descargas atmosféricas, baseados em técnicas de redes neurais artificiais.

1.1.2 MOTIVAÇÃO E CONTRIBUIÇÃO

As estações meteorológicas de altitude são postos utilizados para coleta de dados meteorológicos através de uma radiossonda que ascende na atmosfera acoplada a um balão meteorológico. A radiossonda transporta sensores capazes de coletar dados de temperatura do ar, umidade relativa do ar e, direção e velocidade do vento, e assim traçar um perfil da atmosfera. O perfil da atmosfera permite identificar as condições de estabilidade da atmosfera,

ou seja, se o ambiente está favorável ou não para a ocorrência de tempestades. Tais dados têm inúmeras aplicações, como assimilação de tais dados por modelos numéricos de tempo e previsão de curto prazo (*nowcasting*).

Os horários de realização das radiossondagens são padronizados internacionalmente pela *World Meteorological Organization* (WMO), de maneira que todas as estações da rede mundial realizam as sondagens ao mesmo tempo, ou seja, 00:00 UTC (*Coordinated Universal Time*) e 12:00 UTC. A sondagem das 12:00 UTC na Amazônia ocorre às 08:00 e 09:00 hora local, de acordo com o fuso horário da região. Em razão dos custos operacionais elevados, apenas duas sondagens são realizadas diariamente e, na Amazônia, o número de estações é extremamente reduzido. Como exemplo, o estado do Pará, que têm uma área superior a 1.200.000 km², possui apenas três estações deste tipo, caracterizando uma cobertura muito abaixo do necessário para uma região tão extensa.

O advento do satélite e o uso de sensores sondadores acoplados em plataformas orbitais reduz significativamente o custo operacional de uma sondagem atmosférica e amplia enormemente a área coberta, além de permitir que sejam efetuadas sondagens em horários diversos, distintos daqueles determinados pela WMO.

Os processos termodinâmicos que dão origem a nuvens de tempestades são por vezes muito rápidos e uma radiossondagem realizada muito antecipadamente, 09 horas locais, por exemplo, pode não capturar tão bem as condições que favorecerão a formação de tempestades no período da tarde, quando as temperaturas são mais elevadas devidas à maior incidência de radiação solar. A realização de sondagens logo no início da tarde permite capturar melhor as variáveis termodinâmicas e as ‘nuances’ dos processos convectivos que poderão ocorrer a ponto de desenvolver nuvens de tempestades e desencadear a geração de descargas atmosféricas.

Além de realizar sondagens em maior resolução temporal e cobrir períodos mais representativos da evolução termodinâmica na Amazônia, as sondagens satelitais permitem a realização de previsão para áreas antes sem dados de perfis termodinâmicos até então. Assim, o desenvolvimento de um modelo aplicado que possa utilizar tais informações e antecipar de forma coerente a ocorrência ou não de descargas atmosféricas para a Amazônia representa um avanço tecnológico regional, cuja metodologia ainda não foi empregada na região, mas os resultados mostram-se bastante promissores.

Esta tese utiliza dados de sondagem atmosférica por satélite, como mencionado anteriormente, permite uma maior cobertura do espaço de estudo em comparação às radiossondagens convencionais com balão meteorológico, pois, estas apresentam um custo operacional elevado e são realizadas em poucos pontos na Amazônia. Aliado a carência de

estações de radiossondagens na Amazônia, o que dificulta inúmeros estudos das condições atmosféricas locais, como previsão de raios. A região, também apresenta elevada incidência de descargas atmosféricas, provocando grandes danos humanos, sociais e econômicos. Para tentar solucionar estes dois graves problemas para a região, esta tese visa contribuir com uma nova abordagem de previsão de descargas atmosféricas, utilizando dados de sondagem atmosférica por satélite combinado com redes neurais artificiais.

Ressalta-se que a metodologia proposta não se restringe apenas para a região amazônica, mas como uma nova opção para regiões que não possuem estações de radiossondagem convencional e que dispõem de dados de sondagens de satélites. Com isso, tem-se mais uma nova proposta para auxiliar e contribuir com estudos de previsões de raios.

1.2 OBJETIVOS

Para se situa em relação à proposta desta pesquisa e também deixar claro a sua relevância, este trabalho divide-se em objetivo geral e específicos.

1.2.1 OBJETIVO GERAL

Desenvolver previsores de raios para a Região Amazônica baseados em dados de sondagem atmosférica por satélite e redes neurais artificiais.

1.2.2 OBJETIVOS ESPECÍFICOS

- Coletar dados de sondagem atmosférica, obtidos do satélite NOAA-16 e NOAA-19, através do *software* TERASCAN®;
- Avaliar estatisticamente a semelhança entre os dados de sondagem atmosférica realizada pelo satélite NOAA-16 e dados de radiossondagem, em escala local (região Amazônica).
- Desenvolver algoritmos, baseados em redes neurais artificiais e dados de sondagem do satélite NOAA-19 para previsão de raios para a região Amazônica;
- Validar as metodologias propostas de previsão de raios.

1.3 ESTRUTURA DO TRABALHO

Esta tese encontra-se dividida em 8 capítulos. O primeiro capítulo aborda os aspectos relacionados ao tema, problemática, contribuição e objetivos deste trabalho.

O segundo capítulo aborda conceitos literários relacionados as descargas atmosféricas, como fundamentos, tipificação, formação e parâmetros físicos das descargas atmosféricas.

Apresenta-se também o processo de eletrificação da atmosfera terrestre, formação das nuvens de tempestades, além dos sistemas de medição e localização de descargas atmosféricas.

O terceiro capítulo apresenta uma revisão teórica acerca dos indicadores de instabilidade atmosférica. Inicialmente, expõe-se a composição da atmosfera terrestre, em seguida aborda-se a estrutura vertical da atmosfera terrestre. Discute-se as condições da atmosfera estável, além de destacar alguns indicadores de instabilidade atmosférica.

No capítulo 4 descrevem-se os conceitos relacionados a sondagem atmosférica. Primeiramente, comenta-se sobre o Sistema Mundial de Observações Meteorológicas, em seguida apresentam-se os mecanismos envolvidos na radiossondagem e sondagem atmosférica por satélite. Neste capítulo, apresentam-se os satélites da série NOAA, em especial o NOAA-19. Por fim, é descrito o sistema de recepção de dados de sondagem atmosférica dos satélites NOAA-18 e NOAA-19 pelo SIPAM, e a manipulação destes dados através do software TERASCAN®.

No capítulo 5 são exibidos conceitos relacionados as Redes Neurais Artificiais, em especial, neurônios biológicos, neurônio artificial, aprendizado e as principais arquiteturas das RNA. Comenta-se também sobre o algoritmo de aprendizagem *backpropagation* e Levenberg-Marquardt, apresentando os mecanismos de avaliação dos modelos preditivos utilizados nesta tese.

O sexto capítulo é exposto à metodologia utilizada para o desenvolvimento desta pesquisa científica. Inicialmente é tratado a validação dos dados do satélite NOAA-16 para a cidade de Belém-Pa. Em seguida, descreve-se a área de estudo, descrição dos dados e os mecanismos de pré-processamentos realizados. Apresenta-se duas abordagens diferentes de previsão de descargas atmosféricas através de RNA e dados de sondagem do satélite NOAA-19.

No capítulo 8 é exibido os resultados obtidos nas duas abordagens de previsão de raios, bem como as análises desenvolvidas.

O nono capítulo apresenta as conclusões oriundas desta pesquisa, destacando-se as considerações finais e propostas de trabalhos futuros. Completando a tese, seguem as referências utilizadas no trabalho e apêndices.

CAPÍTULO II

2 DESCARGAS ATMOSFÉRICAS

2.1 INTRODUÇÃO

Neste capítulo serão apresentados conceitos básicos sobre descargas atmosféricas, como: fundamentos, circuito elétrico global, tipificação, formação das nuvens de tempestades, formação dos raios, e medição e localização de suas incidências. Esses conceitos são importantes para o entendimento da metodologia desta tese de doutorado, cujo foco está relacionado às descargas atmosféricas.

2.2 FUNDAMENTOS SOBRE AS DESCARGAS ATMOSFÉRICAS

A ocorrência das descargas atmosféricas sempre exerceu aos seres humanos, principalmente as civilizações da antiguidade, uma grande fascinação, medo e respeito a este poderoso fenômeno natural. Segundo Rakov e Uman (2003) é provável que mesmo antes das civilizações terem evoluído, a cerca de três bilhões de anos atrás, os raios já estavam presentes na Terra.

Nos povos antigos a ocorrência de raios estava ligada a misticismos e crendices populares. Em Golde (1977) é referenciado que símbolos mitológicos e rituais envolvendo os raios já ocorriam desde 2000 a.c. Nessa época, os raios eram considerados símbolos de poder de deuses e divindades, sendo sua formação ligada as origens sobrenaturais.

Atualmente, devido ao crescimento de pesquisas científicas ligadas à área de descargas atmosféricas, este misticismo já não existe, pois, muito se evolui no sentido de conhecer-se a respeito dos mecanismos ligados à ocorrência de raios na natureza.

A descarga atmosférica é um fenômeno natural de origem complexa que se caracteriza por um fluxo de corrente impulsiva de alta intensidade e curta duração, que percorre distâncias de alguns quilômetros em canal ionizado na atmosfera terrestre (RAKOV; UMAN, 2003). Ela pode ser do tipo nuvem-ionosfera, intra-nuvem, nuvem-nuvem e nuvem-solo (AKINYEMI et al., 2004). O fluxo de corrente de uma descarga atmosférica produz aquecimento intenso, com temperaturas superiores a 30.000K, efeito luminoso associado (relâmpago) e rápida expansão do ar próximo ao canal de onda sonora (trovão) (RAKOV; UMAN, 2003).

Pinto Júnior (2005, p.15) define descargas atmosféricas como:

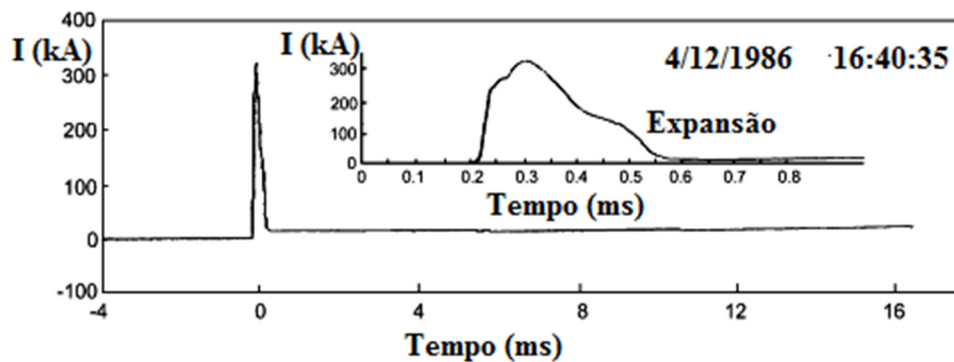
Relâmpagos, também conhecidos como descargas atmosféricas, são descargas elétricas de grande extensão (alguns quilômetros) e de grande intensidade (picos de intensidade de corrente acima de um quiloampère), que ocorrem devido ao acúmulo de cargas elétricas em regiões localizadas da atmosfera, em geral dentro de tempestades. A descarga se inicia quando o campo elétrico produzido por essas cargas excede a capacidade isolante do ar, também conhecida como rigidez dielétrica, em um dado local da atmosfera, que pode ser dentro da nuvem ou próximo ao solo.

Enquanto Visacro Filho (2005, p.18) define descargas atmosféricas como:

A descarga atmosférica, também, conhecida como raio, consiste numa intensa descarga elétrica que ocorre na atmosfera. Trata-se de um fenômeno complexo, que se expressa através do fluxo de uma corrente impulsiva de alta intensidade e curta duração, cujo percurso de alguns quilômetros parte da nuvem e, em alguns casos, atinge a superfície da Terra.

As definições apresentadas de descargas atmosféricas caracterizam, principalmente, o raio como: uma corrente elétrica de alta intensidade em um curto espaço de tempo, cujo percurso é medido em quilômetros (km). A Figura 3 exibe o registro da onda de corrente de uma descarga real entre a nuvem e o solo. Pela Figura 3, nota-se o caráter impulsivo do raio, onde em um curto intervalo de tempo, na ordem dos microssegundos (μs), a corrente elétrica atinge o valor máximo em quiloampère (kA), denominado de pico ou crista. Após atingir o valor de pico, a corrente elétrica cai lentamente até chegar ao valor de 0kA.

Figura 3 – Registro da corrente uma descarga atmosférica.



Fonte: Adaptado Rakov (2007)

Tipicamente raios ocorrem durante as tempestades (JUNTIAN et al., 2011). Em especial, nas nuvens de tempestades chamadas de *Cumulonimbus* (Cb). Outro fator importante é o sentido do fluxo de corrente, este fluxo de corrente tem polaridade negativa para movimento de cargas negativas descendentes, ou movimento de cargas positivas ascendentes, e tem sua polaridade positiva para o movimento de cargas positivas descendentes, ou movimento de cargas negativas ascendente. A polarização da descarga atmosférica será dada em detalhes na seção 2.4

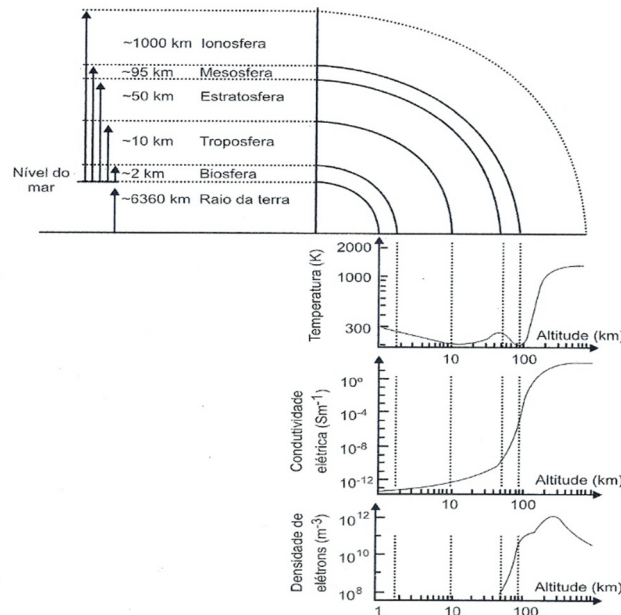
2.3 CIRCUITO ELÉTRICO GLOBAL

A superfície do planeta Terra é carregada negativamente, enquanto o ar é carregado positivamente e o campo elétrico associado ao tempo bom (sem tempestade) é entorno de 100 V/m, sendo que o vetor campo elétrico é voltado para baixo (RAKOV; UMAN, 2003).

Há um constante fluxo de corrente elétrica e manutenção de um potencial elétrico na superfície do planeta Terra, formando o chamado circuito elétrico global. O circuito elétrico global é responsável, dentre outras coisas, pelo equilíbrio da vida na Terra.

O circuito elétrico global é bastante influenciado pela característica elétrica da atmosfera terrestre. A Figura 4 apresenta um esquema das camadas atmosféricas com parâmetros elétricos (condutividade elétrica e densidade de elétrons) e temperatura, variando com a altitude.

Figura 4 - Características elétricas da atmosfera.



Fonte: Visacro Filho (2005)

As características elétricas da atmosférica, em grande parte, são oriundas do processo evolutivo do planeta Terra, enquanto outra parte é originária do seu momento atual. No nível do mar, isto é, na camada de ar mais próxima da superfície da Terra, há um baixo valor de condutividade elétrica (10^{-12} S/m), à medida que a altitude aumenta, tende também a aumentar a condutividade elétrica e diminuir o campo elétrico. A condutividade elétrica maior nas camadas superiores da atmosfera decorre da presença de íons criados por raios cósmicos e radioatividade natural da Terra (RAKOV; UMAN, 2003). Íons pequenos com diâmetros de 0.1 a 1 nm e tempo de vida de cerca de 100 s são os principais contribuintes da condutividade atmosférica mais baixa (RAKOV; UMAN, 2003). Do nível do mar até a altitude de ~95 km (Mesosfera) há uma baixa densidade de elétrons (m^{-3}), enquanto para altitudes superiores a

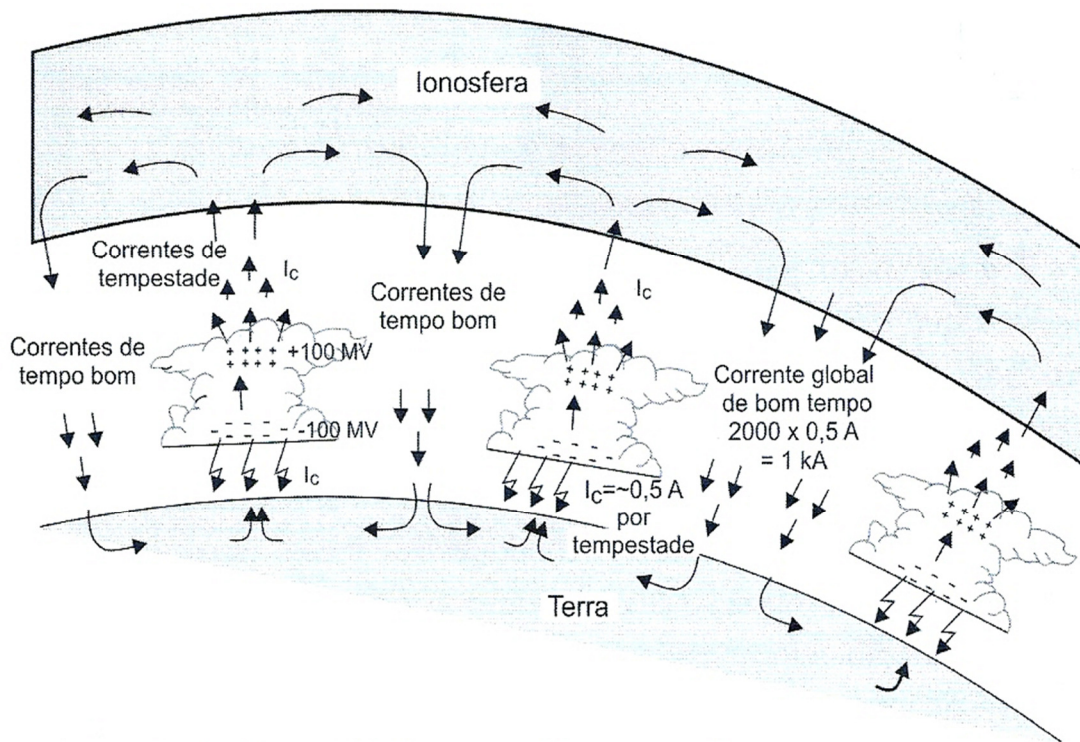
1000 km, a temperatura (K) tende a aumentar a partir da ionosfera, aumentando também a densidade de elétrons nesta camada.

A superfície da Terra é carregada negativamente com magnitude de carga elétrica total de aproximadamente -5×10^5 C, em condições de tempo bom (WILLIAMS; MAREEV, 2014). Há na atmosfera uma carga positiva semelhante. Mesmo em situações de tempo bom, essa carga elétrica permite um fluxo de corrente positiva do ar para o solo. Em consequência, se não houvesse uma fonte geradora de corrente, a carga elétrica armazenada na Terra, depois de um período de tempo, seria neutralizada devido à condutividade do ar, de modo que não haveria um campo elétrico na atmosfera. O campo elétrico perto do solo apresenta uma forte variação.

O conceito de circuito elétrico global é exibido na Figura 5. Este circuito liga o campo elétrico e a corrente elétrica que flui da atmosfera inferior (solo) para a ionosfera, formando um condensador gigante atmosférico, que é carregado pelas nuvens de tempestades com um potencial elétrico de várias centenas de milhares de Volts (SIINGH et al., 2007). As nuvens de tempestades com seus centros de cargas negativas e positivas funcionam como fontes geradoras no circuito.

Pela Figura 5, observa-se que a corrente elétrica circula por um caminho formado entre a ionosfera e a Terra. O circuito elétrico global seria basicamente formado por duas camadas, a inferior (solo) e a superior (ionosfera), e ao centro há uma camada de baixa condutividade (o ar), na qual se encontram as nuvens de tempestades. O fluxo de corrente elétrica circula do topo das nuvens de tempestades (centros de cargas positivas) em direção a regiões de alta condutividade (ionosfera). A partir da ionosfera a corrente circula para o solo através das nuvens de tempo bom. O ciclo se completa na base na nuvem de tempestade que possui centro de carga negativa, gerando as descargas atmosféricas que transferem parte das cargas negativas para o solo através de sua incidência no solo. A corrente ascendente da superfície da Terra para a base da nuvem de tempestade depende de fatores como: corrente de convecção, corrente de relâmpago, corrente de precipitação e corrente de deslocamento.

Figura 5 - Esquema representativo do circuito elétrico global.



Fonte: Visacro Filho (2005)

As principais fontes geradoras de campo elétrico e corrente elétrica no circuito elétrico global são as nuvens de tempestades. A corrente de saída das nuvens de tempestades ao redor do globo terrestre mantém uma diferença de potencial de $\sim 300 \text{ kV}$ entre a nuvem e ionosfera, com uma corrente que flui entorno de 10^3 A (SIINGH et al., 2007). Permanentemente e simultaneamente, ocorrem ao redor do planeta cerca de 2.000 tempestades, cada tempestade gera uma corrente elétrica média de $\sim 0,5 \text{ A}$. Logo, pode-se estimar o fluxo contínuo de corrente ao redor do planeta, sendo de $\sim 1 \text{ kA}$, conforme Figura 5 (VISACRO FILHO, 2005).

Em regiões de tempo bom, o valor da resistência da coluna de ar entre a ionosfera e o solo é $\sim 200 \Omega$, circulando por esta uma corrente que oscila entre 750 e 2 kA. Assim, a diferença de potencial entre a ionosfera e o solo, oscila entre 150 e 600 kV, sendo seu valor médio de 280 kV (VISACRO FILHO, 2005).

2.4 TIPIFICAÇÃO DAS DESCARGAS ATMOSFÉRICAS


Nesta seção serão comentadas tipificações adotadas para classificar as descargas atmosféricas, que incluem o seu percurso realizado, o seu sentido e a sua polarização.

2.4.1 TIPIFICAÇÃO PELO PERCURSO DA DESCARGA

Os raios podem ser classificados em quatro formas, de acordo sua trajetória na atmosfera (RAKOV, 2007). Essa classificação se baseia nos diferentes caminhos que o fluxo de corrente elétrica percorre para conectar centros de cargas de sinais opostos (Figura 6). Assim, tem-se:

- Raio nuvem-solo: caracteriza-se por raios que partindo de uma nuvem, atingem o solo.
- Raio nuvem-nuvem: são raios que podem ocorrer entre nuvens diferentes.
- Raio nuvem-ar: são raios que partem de uma nuvem e terminam na própria atmosfera, sem atingir outra nuvem ou solo.
- Raio intra-nuvem: são os raios que ocorrem dentro da própria nuvem de tempestade.

Figura 6 - Diferentes tipos de descargas atmosféricas.



Fonte: Rakov (2017)

Os raios intra-nuvem são os mais comuns de ocorrerem, seguido pelos raios nuvem-solo (PINTO JUNIOR, 2005). Os raios intra-nuvem representam 75% das ocorrências totais de raios da Terra (AKINNYEMI ET AL., 2014). A predominância desse tipo de descarga decorre da proximidade do centro de carga positiva e negativa dentro da mesma nuvem.

Os raios nuvem-nuvem e nuvem ar são mais raros de acontecerem. As descargas nuvem-nuvem representam um perigo para a navegação aérea, pois, há um risco de uma aeronave ser atingida por uma descarga. Embora, os raios nuvem-solo não sejam os mais frequentes, são os mais estudados, devido seu potencial destrutivo para o homem e outras vidas existentes na face da terra, além da facilidade de obtenção de parâmetros para seu estudo. Logo, os raios nuvem-solo representam grande preocupação para a sociedade.

Neste trabalho foram estudadas as ocorrências relacionadas à incidência dos raios nuvem-solo. Portanto, somente este tipo de descarga será discutida com mais detalhes.

2.4.2 TIPIFICAÇÃO PELO SINAL E DIREÇÃO DE PROPAGAÇÃO DA DESCARGA


Uma forma de classificar os raios nuvem-solo é através de sua polaridade, isto é, através do sinal da carga que são efetivamente transportadas entre a nuvem e o solo (Figura 7). Um raio tem polaridade negativa quando ocorre a transferência de carga negativa pelo líder escalonado e será positiva quando ocorrer transferência de carga positiva pelo líder escalonado. O líder escalonado é resultante da direção das ramificações exibidas na Figura 7 (7a, 7b, 7c e 7d), sendo formado pelo canal ionizado precursor da descarga entre a nuvem de tempestade e o solo.

O raio será descendente quando o canal precursor que forma a descarga se conecta na direção da nuvem para o solo, constituindo a maior parte das descargas originadas na Terra. Um raio será ascendente quando sua origem de conexão ocorre da direção do solo para a nuvem. Tem origem a partir de locais bem elevados sobre os quais estão posicionadas altas estruturas.

Os raios nuvem-solo descendentes negativos (Figura 7a) representam aproximadamente 90% da totalidade das ocorrências de raios, enquanto 10% ou menos das descargas são do tipo descarga descendente positiva (Figura 7c) (RAKOV; UMAN, 2003). As descargas negativas ascendentes (Figura 7b) e descargas positivas ascendentes (Figura 7d) são mais incomuns de acontecerem (DWYER; UMAN, 2014), devido ocorrerem em objetos altos, como topo de montanha. Após o encontro do canal ascendente com o canal descendente na base da nuvem, a carga negativa transferida da nuvem é acumulada no canal descendente, sendo responsável pelo descarregamento do canal. O mesmo processo é válido para as descargas positivas.

Segundo Visacro Filho (2005, p.57) “cerca de 20% dos casos, a descarga negativa tem uma única corrente de retorno”. Geralmente, ocorre uma sequência de correntes de retorno, posterior à primeira, constituindo as descargas subsequentes. Nesse caso haveria as chamadas primeiras descarga e as descargas subsequentes.

Figura 7 - Classificação dos raios nuvem-solo por sua polaridade e direção de propagação: (a) Descarga negativa descendente, (b) Descarga negativa ascendente, (c) Descarga positiva descendente e (d) Descarga positiva ascendente.



Fonte: Visacrato Filho (2005)

2.5 FORMAÇÃO DE UMA NUVEM DE TEMPESTADE

As descargas atmosféricas têm sua origem principalmente nas nuvens de tempestades ou *cumulunimbus* (Cb) (RAKOV; UMAN, 2003). Embora raios também possam ocorrer em tempestades de areias, erupções vulcânicas e explosões nucleares (RAKOV; UMAN, 2003). Raios também podem ocorrer, ainda que raramente, em outros tipos de nuvens, tais como *stratocumulus* ou *nimbustratus* (PINTO JUNIOR; PINTO, 1996).

As nuvens Cb são caracterizadas por intensas atividades convectivas em seu interior e existem vários processos envolvidos na formação da tempestade, como instabilidade atmosférica, umidade em baixos níveis e forçantes dinâmicas e/ou termodinâmicas (GOLDE, 1977).

A Cb difere de outras nuvens por ter uma maior extensão vertical, com sua base situada a 1 km de altura do solo, enquanto o topo pode alcançar 20 km de extensão, gerando chuvas fortes e trovoadas (VISACRO FILHO, 2005). Durante seu desenvolvimento, a velocidade dos ventos dentro da nuvem pode chegar a aproximadamente a 100 km/h (PINTO JUNIOR; PINTO, 1996). Outra característica da Cb é sua coloração acinzentada e a formação de uma bigorna, isto é, uma saliência projetada na direção dos ventos na parte superior da nuvem. A Figura 8 exibe uma nuvem Cb.

Figura 8 - Exemplo de uma nuvem CB.



Fonte: (REDMET, 2014)

Segundo Potier (2010, p.13) “As nuvens Cb provocam tempestades de granizo e são as únicas carregadas eletricamente, ou seja, as únicas de onde se pode originar os raios”. Logo, torna-se necessário conhecer os processos básicos de formação dessas nuvens que irão originar as descargas atmosféricas.


2.5.1 FASES DE FORMAÇÃO DE UMA NUVEM DE TEMPESTADE

As nuvens de tempestade ou nuvens Cb são nuvens de acentuado desenvolvimento vertical que produzem chuvas e raios, geralmente com granizos e fortes rajadas. Esse grande desenvolvimento das Cb encontra-se associados à presença de ar quente, úmido e instável.

As nuvens Cb podem apresentar-se como tempestades isoladas ou tempestades locais, formando tempestades organizadas, conhecidos como sistemas convectivos de mesoescala, com a presença de chuvas severas e ventos intensos (PINTO JUNIOR, 2005).

A Figura 9 exhibe os diversos tipos de nuvens, que de acordo com as condições atmosféricas, podendo crescer de acordo com uma variedade de formas, tamanho e altitude, destacando-se com isto as diferenças das nuvens Cb em relação outros tipos de nuvens. Pode-se perceber pela Figura 9, que as nuvens CB se distinguem dos outros tipos de nuvens pelo seu tamanho, pela sua grande extensão vertical e por possuírem fortes correntes ascendentes verticais de ar.

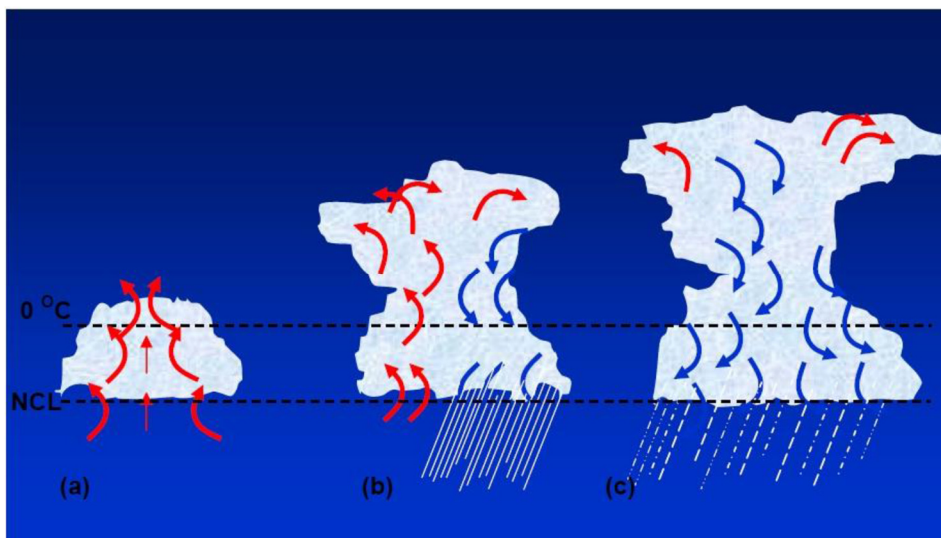
Figura 9 - Classificação das nuvens.



Fonte: Rodrigues (2010)

O Ciclo evolutivo de uma nuvem de tempestade, representado na Figura 10, é composto por três estágios diferentes: (a) formação, (b) maturação e (c) dissipação (BYERS; BRAHAM, 1947).

Figura 10 - Estágios de uma nuvem: (a) ao saturar-se, a massa de ar úmido que se elevou da superfície aquecida da Terra cria uma nuvem cumulus, estágio inicial, (b) estágio maduro, (c) inicia-se o processo de dissipação devido ao decréscimo das correntes ascendentes que levam ar úmido ou aumento de temperatura (setas vermelhas – ar quente, setas azuis – ar frio).



Fonte: Heilmann (2006).

Resumidamente, uma nuvem de tempestade se forma a partir da elevação de uma parcela de ar quente e úmido que pode ser originada do aquecimento do ar próximo à superfície (HEILMANN, 2006). À medida que essa parcela de ar for ascendendo, a umidade do ar pode encontrar nas regiões mais altas uma temperatura baixa, em decorrência da diminuição da pressão atmosférica com a altura, isto provoca a condensação da parcela de ar formando várias gotículas de água que ficam suspensas no ar. Este nível é chamado de nível de condensação por

levantamento (NCL) (Figura 10). Quanto mais rápido for essa diminuição da temperatura do ar com a altura, mais instável será a atmosfera.

As primeiras gotículas de nuvens começam a surgir nessa fase de formação e esse desenvolvimento continuará crescendo, enquanto a parcela de ar levantada estiver com temperatura maior que o ambiente, ou seja, a atmosfera estiver instável. Com isso, a nuvem poderá desenvolver-se verticalmente.

Com o crescimento da nuvem, as gotículas de maiores massas de água acabam capturando as gotículas de menores massas através de processos de colisões. Isto acaba promovendo aumento do tamanho das gotículas e conseqüentemente propiciando a formação de chuvas com o aumento da nuvem.

Quando a parcela de ar atinge a isoterma de 0°C, há a formação gotícula superesfriada na parte superior da nuvem. Nesta parte da formação há pouca ou nenhuma formação de raios e baixo índice pluviométrico. Entretanto, é nesse estágio que a nuvem desenvolve sua instabilidade elétrica.

O estágio de formação é caracterizado pela presença de movimentos ascendentes (Figura 10.a) que arrastam as gotículas de água e gelo para cima. Nesta fase, o diâmetro da nuvem varia entre 3 e 8 km, estando sua base situada a uma altura de 1,5 km e seu topo entre 5 e 8 km, aproximadamente (PINTO JUNIOR; PINTO, 1996).

O estágio de maturação é caracterizado pela formação das tempestades, no qual se desenvolvem quando a temperatura dentro da nuvem é igual ou menor que o ar do ambiente, atingindo o chamado nível de equilíbrio. Nessa fase, a massa de ar levantada começa a formar a “bigorna” (Figura 10.b), em função dos movimentos de convecção do ar dentro da nuvem (ar ascendente em vermelho e ar descendente em azul).

O estágio de maturação é caracterizado pelo estágio de turbulência dentro da nuvem, em função da predominância de correntes ascendentes e descendentes, com ventos fortes, descargas atmosféricas e chuvas. Neste estágio, tais movimentos podem chegar a velocidades de até 100 km/h e seu diâmetro pode atingir até 10 km.


O estágio de dissipação (Figura 10.c) constitui a fase final do ciclo de vida de uma nuvem Cb, no qual é caracterizado predominantemente por movimentos descendentes (linhas azuis). A nuvem será dissipada quando a temperatura no seu interior for igual à temperatura exterior do ambiente, cessando as chuvas e os raios.

2.5.2 ELETRIFICAÇÃO DAS NUVENS DE TEMPESTADES

Para que ocorra a descarga atmosférica é necessário que a nuvem Cb esteja eletrificada. Este processo de eletrificação da nuvem inicia-se em seu estágio de formação. O ambiente físico no qual se dá a formação da nuvem de tempestade é extremamente complexo. Por esse motivo, muitas teorias tentam explicar o processo de eletrificação das nuvens de tempestades. Entretanto, ainda não há uma teoria única, de concordância universal, capaz de explicar tal fenômeno. Isso é influenciado pela complexidade de processos microfísicos e macrofísicos envolvidos no interior da nuvem Cb.

Uma teoria que tenta explicar a ocorrência da eletrificação das nuvens é a de colisões dentro da nuvem entre partículas no seu interior, principalmente entre cristais de gelo e granizo, conforme Figura 11. De acordo com Pinto Júnior e Pinto (2000) os centros de cargas positivas e negativos dentro da nuvem são provenientes dos “choques” entre partículas de gelo em seu interior e não apenas entre gotas de chuvas. Esse processo de separação das cargas no interior da nuvem é o mais aceito pela comunidade acadêmica, sendo chamado de processo indutivo.

Figura 11 - Processo de colisão indutivo.




Fonte: Soares (2014)

Este choque acaba promovendo a formação de íons dentro da nuvem, em função do movimento ascendente e descendente do vento, no qual permitem o choque entre as particulares mais leves (cristais de gelo) com partículas mais pesadas (granizo). Entretanto, detalhes da transferência de cargas durante os processos de colisões ainda não são bem conhecidos.

A caracterização do resultado das colisões dentro na nuvem Cb é mostrada na Figura 12, sendo importante no entendimento do mecanismo de formação das descargas atmosféricas.

Com a nuvem eletricamente carregada, estas partículas tendem, então, a se separar sobre a influência de correntes de ar ascendentes e descendentes e da gravidade, de tal modo que a parte superior da nuvem adquira uma carga líquida positiva e a parte inferior uma carga líquida negativa (Figura 12).

Figura 12 - Esquema de uma nuvem eletrificada positivamente e negativamente.




Fonte: Visacro Filho (2005)

Pela Figura 12, nota-se que a nuvem possui sua extensão toda eletrificada, e segundo Visacro Filho (2005), a base na nuvem que possui predominância de cargas negativas, encontra-se a uma altura em que as temperaturas estão compreendidas entre -10°C e -20°C , sendo que a altitude que se encontra a nuvem, pode variar de acordo com a latitude local. Por sua vez, a parte superior da nuvem, fica com um grande volume de cargas positivas, em altitudes que podem registrar temperaturas entre -25°C e -60°C . A distribuição de cargas positivas e negativas no interior da nuvem é responsável pela geração de campos elétricos intensos que determinam valores intensos de diferença de potencial entre os centros de carga positiva e negativa.

2.6 MECANISMO DE FORMAÇÃO DA DESCARGA ATMOSFÉRICA

A Figura 13 exhibe, resumidamente, as etapas de formação de uma descarga atmosférica nuvem-solo descendente negativa, levando-se em conta a distribuição de cargas elétricas na nuvem.

Figura 13 - Etapas de formação de uma descarga atmosférica. (a) formação do líder escalonado, (b) ocorrência da descarga de retorno e (c) múltiplas descargas subsequentes de retorno.



Fonte: Heilmann (2006)

A ocorrência de um raio nuvem-solo só será possível quando o campo elétrico da nuvem Cb for suficiente maior que a rigidez dielétrica do ar. Quando essa rigidez dielétrica do ar é rompida, o ar que inicialmente era um isolante passa a ser um canal condutor e assim tem-se o início do processo da formação da descarga atmosférica. No caso do ar, a rigidez dielétrica vale aproximadamente 3 MV/m (VISACRO FILHO, 2005).

Este processo de quebra da rigidez dielétrica do ar estabelece os meios para que as cargas sejam levadas ao solo pela formação do líder escalonado ou *Stepped Leader* (Figura 13.a).

Essa etapa de formação do líder escalonado ocorre com o deslocamento do campo elétrico estabelecido entre a base da nuvem (cargas negativas) e o solo (cargas positivas) pelo movimento das nuvens em relação à terra por caminhos não lineares no solo. Com a aproximação do líder escalonado do solo, isto é, com a ponta do líder chegando a alguns metros do solo, uma descarga positiva ascendente de conexão fecha o circuito com o solo, formando uma espécie de canal ionizado, devido ao forte campo elétrico produzido entre o solo e a extremidade do líder escalonado, rompendo-se a rigidez dielétrica do ar.

Quando uma descarga de conexão encontra o líder escalonado, um canal condutor é formado, então isso surge a descarga de retorno ou *return stroke* (Figura 13.b). Essa descarga de retorno é a responsável pela produção da luz que vemos e dura poucas centenas de microssegundos.


O raio pode terminar com apenas uma descarga principal, proveniente do canal de ionização do ar formado. Entretanto, o mais frequente é a formação de raios com múltiplas descargas de retorno, após um período de tempo de incidência da descarga principal (Figura

13.c). Após a descarga de retorno, outros centros de cargas dentro na nuvem, próximos ao canal ionizado apontam este com novas cargas no local onde se formou o líder escalonado, processo denominado de recarregamento do canal (*Dart Leader*). Assim, uma nova descarga rumo ao solo, chamada de líder contínuo, abrirá uma nova conexão para uma nova descarga de retorno subsequente.

As múltiplas descargas podem acontecer quando o centro de carga da nuvem estiver completamente reduzido, conseqüentemente seu potencial elétrico fica bastante reduzido quando comparado a outros centros de cargas existentes da nuvem, e assim podem ocorrer múltiplas descargas subseqüentes (*Subsequent Return Stroke*).

A Figura 14 mostra as etapas do processo de formação da descarga atmosférica com seus respectivos tempos associados (UMAN, 1987). Nota-se que cada etapa, assim como as transições entre cada etapa, ocorre em intervalos curtíssimos de tempo (milissegundos - ms e microssegundos - μ s), a uma distância em relação ao solo de 3 km.

Figura 14 - Etapas e tempos da descarga atmosférica do tipo nuvem-solo.



Fonte: Uman (1987)

Algumas propriedades mais comuns dos raios nuvem-solo negativos são resumidas na Tabela 1. A primeira descarga de retorno e descarga de retorno subsequente apresentam a mesma velocidade de propagação, temperatura do canal e raio do canal. Entretanto, a primeira descarga de retorno apresenta corrente elétrica e transferência de carga maior que a descarga de retorno subsequente. A primeira descarga de retorno também apresenta maior tempo de duração de pico médio de corrente, entretanto, possui menor taxa de subida da corrente.

Tabela 1 - Parâmetros físicos da primeira descarga de retorno e descarga de retorno subsequente das descargas nuvem-solo negativas.

| Parâmetros | Primeira descarga de retorno | Descarga de retorno subsequente |
|---|-------------------------------------|--|
| Corrente de pico (kA) | 30 | 10 – 15 |
| Tempo de subida da corrente, 10%-90% (μs) | 5 | 0,3 - 0,6 |
| Máxima taxa de subida da corrente ($\text{kA } \mu\text{s}^{-1}$) | $\geq 10 - 20$ | 100 |
| Duração da corrente para o valor de pico médio (μs) | 70 – 80 | 30 – 40 |
| Transferência da carga (C) | 5 | 1 |
| Velocidade de propagação (ms^{-1}) | $(1-2) \times 10^8$ | $(1-2) \times 10^8$ |
| Temperatura do canal (K) | $\sim 30\,000$ | $\sim 30\,000$ |
| Raio do canal (cm) | $\sim 1-2$ | $\sim 1-2$ |

Fonte: Rakov e Uman (2003)

2.7 PARÂMETROS FÍSICOS DAS DESCARGAS ATMOSFÉRICAS

Os parâmetros físicos das descargas atmosféricas nuvem-solo podem ser agrupados em três tipos de descargas:

- Primeiras descargas de retorno negativas ou “flashes” com uma única descarga de retorno negativa;
- Descargas de retorno subsequentes;
- Primeiras descargas de retorno positivas ou “flashes” com uma única descarga de retorno positiva.

Dessa forma, serão descritos os seguintes parâmetros físicos dessas descargas atmosféricas: corrente de pico, carga transferida por descarga, tempo de frente de onda, tempo de meia onda, tempo de duração total da descarga, derivada máxima e energia por unidade de resistência.

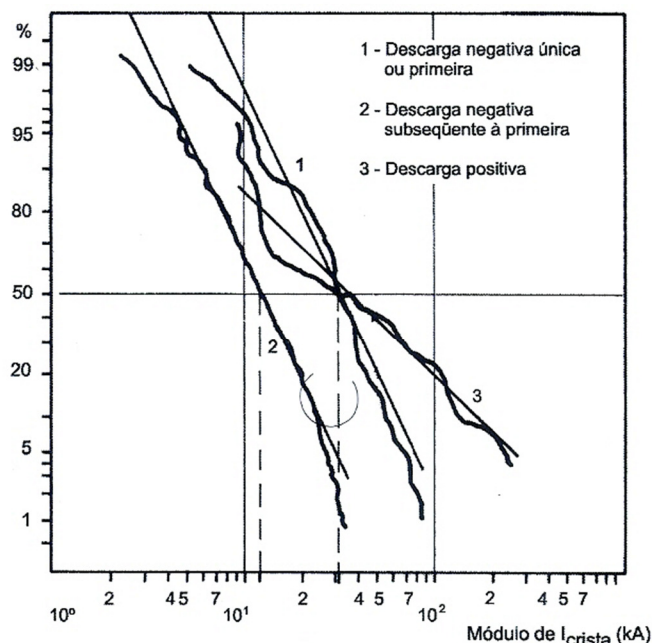
2.7.1 CORRENTE DE PICO

Segundo Visacro Filho (2010, p.82):

A amplitude da corrente de descarga, referida como valor de pico ou de crista de onda de corrente, corresponde ao valor máximo alcançado pela corrente. Usualmente, as ondas da primeira corrente de descarga negativa apresentam dois picos, sendo o segundo superior ao primeiro, na maioria das vezes.

A Figura 15 mostra as curvas de distribuição acumulada de amplitude de corrente para os três tipos de descarga. Pela Figura 15, observa-se que os valores medianos da amplitude das ondas de corrente das descargas positivas (Figura 15 (3)) estão próximos do valor mediano da amplitude da onda de descarga negativa única (ou primeira descarga negativa) (Figura 15 (1)), sendo este valor em torno de 30 kA. O valor mediano da amplitude da onda de corrente das descargas negativas subsequentes se aproxima de 12 kA.

Figura 15- Valores acumulados de corrente de pico: (1) Descarga negativa única ou primeira, (2) descarga negativa subsequente à primeira e (3) descarga positiva.



Fonte: Berger, Anderson e Kröninger (1975)

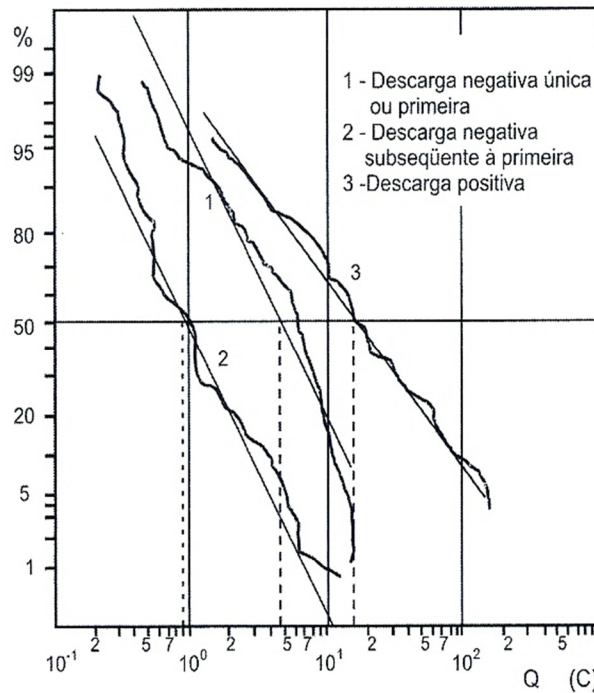
2.7.2 CARGA TRANSFERIDA POR DESCARGA

A carga elétrica transferida para à terra pela corrente de uma descarga de retorno (ou *stroke*), pode ser determinada pela integração no tempo da corrente de retorno de uma onda de descarga. Assim, através da medição desse parâmetro pode-se avaliar através do canal precursor da descarga em direção ao solo, a quantidade de carga elétrica acumulada durante esse percurso.

A Figura 16 ilustra para os três tipos de descarga, segundo as medições de Berger, Anderson e Kröninger (1975), a distribuição de probabilidade acumulada da carga elétrica envolvida na fase impulsiva da corrente de retorno. Pela Figura 16, nota-se que a descarga positiva (Figura 16 (3)) transfere uma quantidade de carga muito maior quando comparada a

descarga negativa única e a descarga negativa subsequente. A descarga negativa única transfere uma quantidade de carga maior em relação à descarga negativa subsequente. Os valores medianos da carga elétrica transferida pela positiva, descarga negativa subsequente e negativa única são respectivamente, 16 C, 4,5 C e 0,95 C.

Figura 16 - Valores de probabilidade acumulados da carga de um impulso da descarga: (1) Descarga negativa única ou primeira, (2) descarga negativa subsequente à primeira e (3) descarga positiva.




Fonte: Berger, Anderson e Kröninger (1975)

2.7.3 TEMPO DE FRENTE DE ONDA

De acordo com Visacro Filho (2005, p.86): “o tempo de frente de onda da corrente de descarga corresponde ao intervalo de tempo decorrido entre o início da onda impulsiva até o alcance do primeiro pico de onda”.

A Figura 17 mostra os valores medianos dos tempos de frente de onda para os três tipos de descargas. Pela Figura 17 nota-se que a descarga positiva apresenta menor tempo de frente de onda, enquanto a descarga negativa subsequente apresenta maior tempo de frente de onda. Como a descarga negativa subsequente já encontra condições favoráveis à sua ocorrência, devido à baixa ionização do canal após a primeira descarga, isto acaba lhe favorecendo uma maior rapidez no alcance do valor de pico de onda.

Figura 17 - Valores de probabilidade acumulados de tempo de frente de onda: (1) Descarga negativa única ou primeira, (2) descarga negativa subsequente à primeira e (3) descarga positiva.



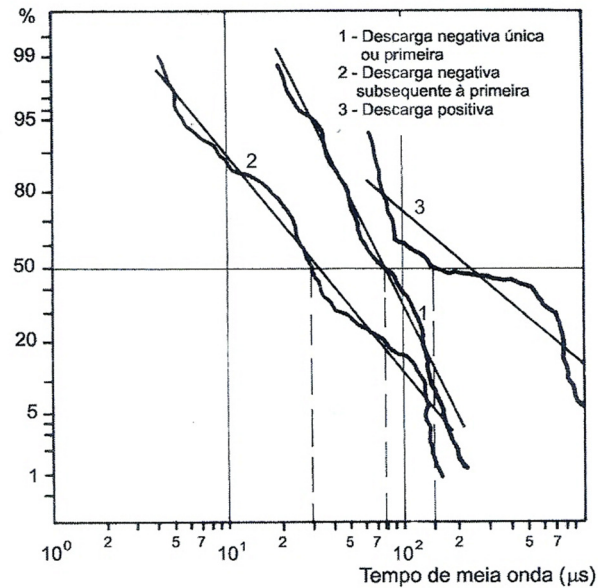
Fonte: Berger, Anderson e Kröniger (1975)

2.7.4 TEMPO DE MEIA ONDA

De acordo com Visacro Filho (2005, p.89): “O tempo de meia onda é conceituado como o tempo decorrido entre o início da onda impulsiva e o instante em que a corrente, após ter ultrapassado o valor de pico (maior pico), tem sua intensidade reduzida para 50% deste valor”.

Na Figura 18 observam-se os valores cumulativos do tempo de meia onda, onde a descarga positiva apresenta menor tempo de meia onda, enquanto a descarga negativa subsequente apresenta maior tempo de meia onda. Segundo Berger, Anderson e Kröniger (1975) os valores medianos para o tempo de meia onda para as descargas positivas, primeira negativa e negativas subsequente são respectivamente, 230 ms, 75 ms e 32 ms.

Figura 18 - Valores de probabilidade acumulados de tempo de meia onda: (1) Descarga negativa única ou primeira, (2) descarga negativa subsequente à primeira e (3) descarga positiva.

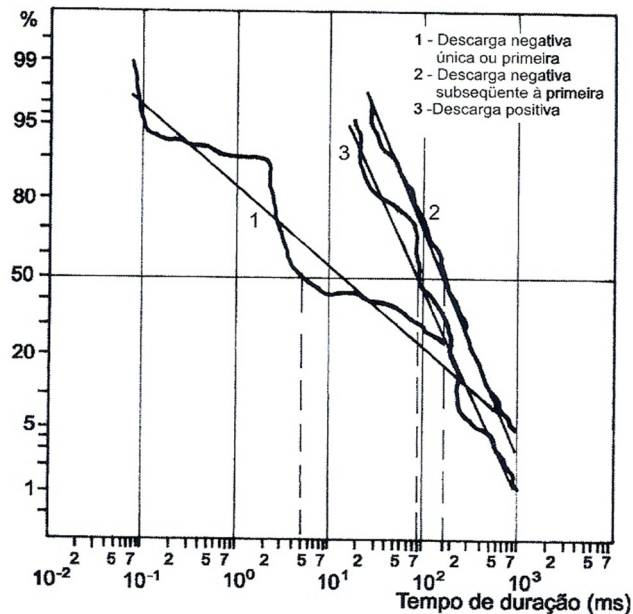


Fonte: Berger, Anderson e Kröninger. (1975)

2.7.5 TEMPO DE DURAÇÃO TOTAL DE DESCARGA

Em Visacro Filho (2005) o tempo de duração total de descarga é definido como: “o intervalo decorrido entre o início da onda impulsiva de corrente e seu término, quando a mesma se anula”. A Figura 19 mostra os valores cumulativos do tempo de duração total de descarga para os três tipos de descargas. Os valores medianos para as descargas subsequentes, descarga positiva e descarga única são respectivamente, 180 ms, 85 ms, 13 ms.

Figura 19 - Valores de probabilidade acumulados do tempo de duração total da descarga: (1) Descarga negativa única ou primeira, (2) descarga negativa subsequente à primeira e (3) descarga positiva.



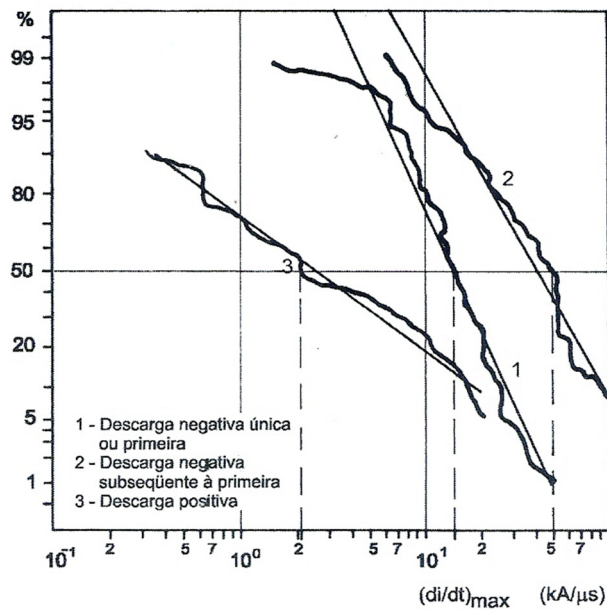
Fonte: Berger, Anderson e Kröninger. (1975)

2.7.6 DERIVADA MÁXIMA

A derivada máxima corresponde a maior taxa de variação da corrente de retorno (di/dt). A Figura 20 apresenta os valores cumulativos da derivada máxima de corrente para os três tipos de descargas. Pela Figura 20, observa-se que as descargas negativas subsequentes (Figura 20 (2)) apresentam maiores taxas de variação da corrente de retorno, enquanto as descargas positivas (Figura 20 (3)) apresentam as menores taxas de variação da corrente de retorno.

Berger, Anderson e Kröninger (1975) obteve os valores medianos de 40 kA/ μ s, 12 kA/ μ s e 2,5 kA/ μ s, respectivamente para as descargas subsequentes negativas, primeira descarga e descarga negativa única.

Figura 20 - Valores de probabilidade acumulados de derivada máxima: (1) Descarga negativa única ou primeira, (2) descarga negativa subsequente à primeira e (3) descarga positiva.



Fonte: Berger, Anderson e Kröninger. (1975)

2.7.7 ENERGIA POR UNIDADE DE RESISTÊNCIA

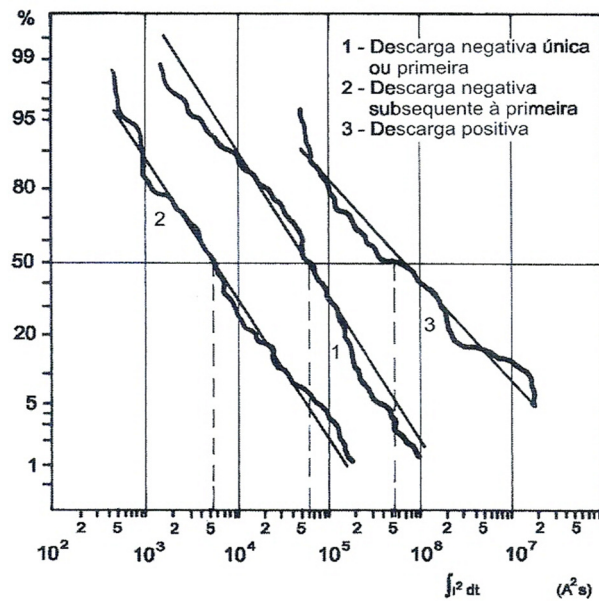
A energia por unidade de resistência (W), corresponde à integração do quadrado da corrente durante o intervalo de duração da corrente de retorno (VISACRO FILHO, 2005). Sendo obtida:

$$W = \int_0^T [i(t)]^2 dt \quad (2.1)$$

A Figura 21 apresenta os valores acumulados de energia por unidade de resistência para os três tipos de descargas. As descargas positivas (Figura 21 (3)) apresentam valores de W maiores quando comparado às outras descargas (Figura 21 (1) e (2)), enquanto as descargas negativas subsequentes (Figura 21 (2)) apresentam os menores valores de W .

Berger, Anderson e Kröninger (1975) obteve os valores medianos de $6,5 \times 10^5 A^2 s$, $5,5 \times 10^4 A^2 s$ e $6 \times 10^3 A^2 s$, respectivamente para as descargas positiva, negativa única e negativa subsequentes.

Figura 21 - Valores de probabilidade acumulados de energia por unidade de resistência: (1) Descarga negativa única ou primeira, (2) descarga negativa subsequente à primeira e (3) descarga positiva.



Fonte: Berger, Anderson e Kröninger. (1975)

2.8 MEDIÇÃO E SISTEMAS DE LOCALIZAÇÃO DE DESCARGAS ATMOSFÉRICAS

Nesta seção serão apresentados conceitos sobre medição direta e indireta das descargas atmosféricas, além dos processos envolvidos na localização de sua ocorrência. As técnicas de medições de parâmetros físicos de descargas atmosféricas contribuem para quantificar a severidade de sua ocorrência, auxiliando no desenvolvimento de sistemas de segurança e proteção. Os sistemas de localização de descargas atmosféricas permitem conhecer características físicas, geográficas e sazonais das descargas atmosféricas.

2.8.1 MEDIÇÃO DIRETA DE PARÂMETROS DESCARGA ATMOSFÉRICA


As técnicas de medições diretas de raios representam uma maior garantia na quantificação da intensidade da corrente elétrica dos raios. Para este tipo de medição são utilizados transdutores especiais, como os “*shunts*”, bobinas de *Rogowski* e de *Pearson*. Este tipo de medição pode ser realizado de duas formas:

- Medição de raios naturais
- Medição de raios induzidos

2.8.1.1 Medição de raios naturais

Esta técnica de medição de raios naturais se baseia na utilização de elevadas torres “instrumentadas” que são instaladas em estações fixas posicionadas no alto de montanhas. A Figura 22 ilustra um esquema de uma torre de medição. Essa torre possui um dispositivo transdutor que recebe o sinal do raio que incide em seu topo. Essa medição é transmitida para abrigos blindados que registram os parâmetros físicos das descargas. A blindagem do abrigo permite evitar as interferências eletromagnéticas nos equipamentos de medição e registro, e também como sistema de proteção do ambiente.

Figura 22 - Esquema de uma torre de medição de raios naturais.



Fonte: Visacro Filho (2005)

2.8.1.2 Medição de raios induzidos

Essa técnica de medição consiste no lançamento de foguetes que transportam um fio condutor entre a nuvem de tempestade e o solo (estação receptora) para induzir a formação de descargas artificiais (chamados de raios trigados). O princípio básico deste método consiste na criação de um canal precursor acima do solo com grande probabilidade de criar canais disruptivos que se conectam ao canal precursor de uma descarga atmosférica, criando as condições para o fluxo de corrente de retorno pelo canal. Assim, originando uma descarga atmosférica induzida.

Antes da formação do canal precursor de uma descarga, o campo elétrico entre a nuvem de tempestade e o solo é extremamente alto, podendo chegar de 4 a 20 kV/m (VISACRO

FILHO, 2005). Nesse momento o foguete é lançado em alta velocidade em direção a nuvem de tempestade, atingindo uma altura superior a 600 m. Uma vez havendo a conexão entre o canal precursor criado e o canal precursor da descarga, fica assim configurado a descarga induzida.

2.8.2 MEDIÇÃO INDIRETA DE PARÂMETROS DE DESCARGA ATMOSFÉRICA

Esta técnica se fundamenta na detecção dos resultados indiretos acarretados pela ocorrência da descarga atmosférica, como, por exemplo: luminoso, eletromagnético, sonoro e térmico.

A medição indireta de raio é utilizada para caracterizar a atividade média de raios em um determinado local, ao invés de caracterizar os raios individualmente. Assim, as técnicas de medições indiretas de parâmetros de descargas atmosféricas podem ser realizadas de duas formas:

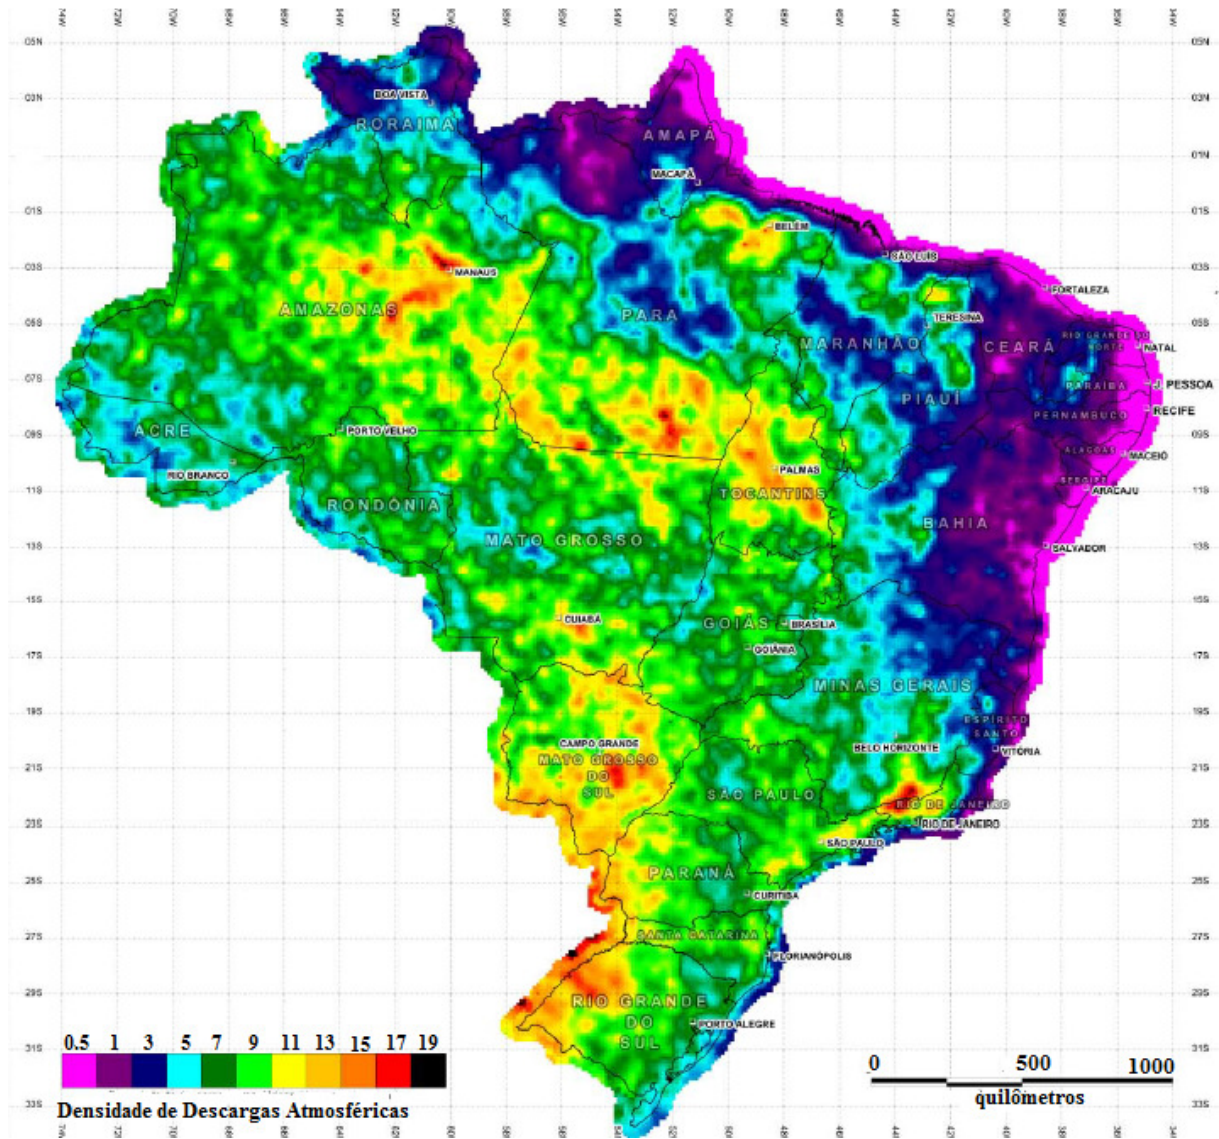
- Dias de tempestades
- Contadores de descargas

2.8.2.1 Dias de tempestades

O número anual de tempestades ou índice ceráunico corresponde a um dia do calendário local durante o qual um trovão é ouvido, pelo menos uma vez em determinado local (RAKOV; UMAN, 2003). Essa faixa prática de audição pode se estender de 15 km até no máximo 25 km (RAKOV; UMAN, 2003). O nível ceráunico refere-se ao número de dias de tempestades com raios por ano, em uma região.

A distribuição espacial dos valores médios da densidade do número de descargas para à terra é apresentada na forma de mapas ceráunicos. Estes mapas representam os números de registrados obtidos durante anos em diversas localidades do mundo. A Figura 23 exhibe o mapa da densidade de raios do Brasil (descargas /km²/ano).

Figura 23 – Mapa da Densidade de Raios do Brasil.



Fonte: Associação Brasileira da Normas Técnicas (2015)

A densidade do número de descargas para à terra (N_g) pode ser calculada através de fórmulas empíricas que utilizam o nível cerâmico (T_d) como parâmetro. Tais formulações diferem bastante de uma região para outra. Sendo que no Brasil, a ABNT (Associação Brasileira de Normas Técnicas, 2015) faz a recomendação da seguinte fórmula para avaliar o risco de exposição à descarga atmosférica:

$$N_g \approx 0,01T_d \quad [km^2 / ano] \quad (2.2)$$

2.8.2.2 Contadores de raios

Contadores de raios são dispositivos desenvolvidos com o objetivo de detectar o campo elétrico (ou magnético) de uma descarga nuvem-solo e contá-las. Esse instrumento é constituído de uma antena que registra o campo elétrico provocado pelo raio. O campo elétrico gerado engloba uma faixa de frequência do espectro eletromagnético que se estende desde centenas de Hertz (Hz) até dezenas de Kiloherz (kHz). Sendo assim, toda vez que o campo elétrico excede um limite, é acionado um contador eletromecânico que faz o registro de ocorrência do raio em uma determinada localidade.

A densidade de descarga (N_g) pode ser estimada a partir da seguinte equação (RAKOV; UMAN, 2003):

$$N_g = (K.Y_g) / (\pi R_g^2) \quad (2.3)$$

Onde:

K = número de descargas registradas


Y_g = Fator de correção

R_g = raio de detecção

O fator de correção Y_g tem como meta corrigir eventuais registros de ocorrências de descargas intra-nuvem ou entre nuvens, isto é, descargas que não atingem o solo. O raio R_g circunscreve a região da terra onde é detectada a descarga nuvem-solo. De acordo com Carvalho, Diniz e Cherchiglia (1992) valores de Y_g e R_g obtidos através de experimentos foram respectivamente, 0,93 e 20 km.

Na Figura 24 tem-se um exemplo de um mapa de densidade de raios obtido através de 11 anos de dados de raios, contabilizados através de contadores de raios, sendo esse registro feito no território do estado de Minas Gerais. Para isso, foram utilizados 60 contadores de raios e atualmente está rede de contadores encontra-se desativada (DIAS; MESQUITA; VISACRATO, 2009).

Figura 24 - Mapa de densidade de raios nuvem-solo para o estado de Minas Gerais.




Fonte: Dias, Mesquita e Visacrato (2009)

2.8.3 SISTEMA DE LOCALIZAÇÃO DE DESCARGAS ATMOSFÉRICAS

Os recentes avanços em pesquisas científicas ligadas as descargas atmosféricas estão relacionadas à utilização de sistemas de localização de descargas atmosféricas. Usualmente chamados de LLS (do inglês, *Lightning Location Systems*).

LLS são usados em muitos países para a obtenção do ponto de incidência do raio nuvem-solo (SONNADARA et al., 2014). Estes representam uma ferramenta mais evoluída da análise da incidência das descargas atmosféricas. Tais sistemas se baseiam na medição de propagação do campo eletromagnético produzido pelo raio (HUNT et al., 2016). De acordo com Rakov e Uman (2003), os raios emitem campo elétrico na faixa de frequência variando de 1 Hz a 300 MHz, isto é, com baixa frequência (LF – *Low Frequency*) e alta frequência (VHF - *Very High Frequency*), com pico de espectro de frequência próximo de 5 a 10 kHz para distâncias superiores a 50 km. Enquanto os relâmpagos intra-nuvem por serem processos de ruptura, emitem uma radiação eletromagnética em alta frequência, denominada de VHF (*Very High Frequency*), no qual varia de 100 a 800 MHz (VHF a UHF-*Ultra High Frequency*) (KRIDER, 1996). A Figura 25 exhibe os principais sistemas de detecção de raios, como suas respectivas faixas de frequência no campo eletromagnético.

Figura 25 - Tipos de sistemas de localização de descargas atmosféricas pela faixa de frequência.

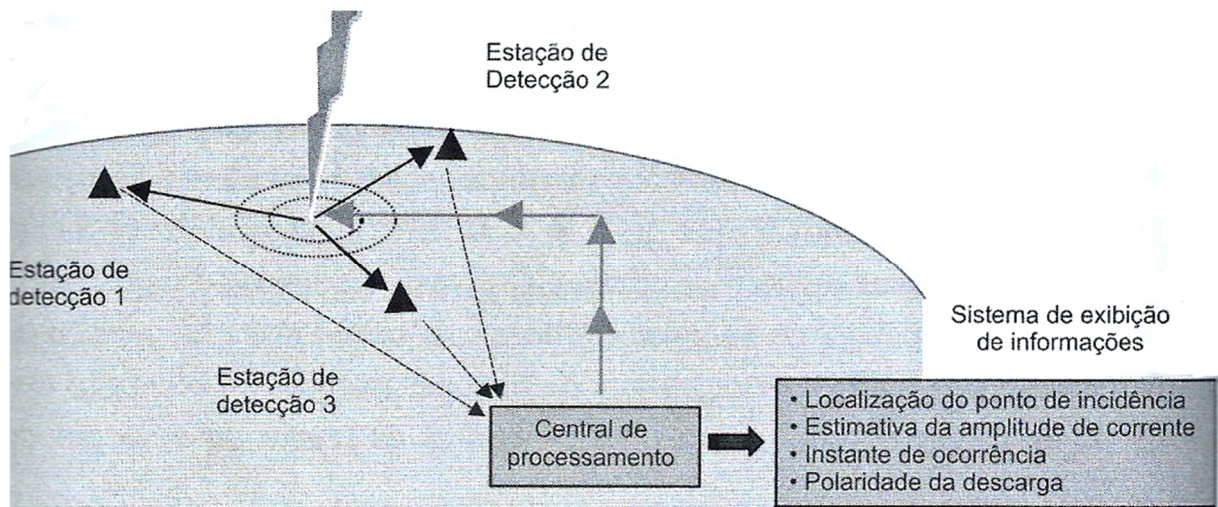


Fonte: Cummins e Murphy (2009)

Sendo assim, através da medição da frequência por sensores é possível determinar a posição geográfica de ocorrência (latitude e longitude), instante de ocorrência, polaridade do raio e dentre outros. Segundo Naccarato (2006) cada raio possui uma característica diferente relacionada à emissão da radiação eletromagnética, permitindo assim determinar a sua polaridade.

A Figura 26 mostra um esquema simplificado de um sistema de detecção de raios, onde pode-se verificar a espacialização das estações de detecções cobrindo diferentes pontos. Cada estação é equipada com sensores especiais que medem o espectro de frequência do campo eletromagnético emitido pela corrente de retorno através do canal da descarga. Além das estações remotas, há também uma central de processamento que permite a localização do ponto de incidência, estimativa da amplitude de corrente, instante de ocorrência e polaridade da descarga.

Figura 26 - Esquema de um sistema de localização.




Fonte: Visacrato Filho (2005)

As estações de detecções ficam dispostas, em geral, a distância entre 100 a 400 km (sensores que operam na frequência LF). Para uma melhor eficácia de detecção, as estações são posicionadas em configurações geométricas para delimitar uma região de cobertura satisfatória. Quando o raio incide em uma determinada localização, seu campo eletromagnético se propaga a partir deste ponto. De modo que, sensores posicionados em distâncias remotas do ponto de incidência, detectam a descarga em diferentes instantes de tempo e com intensidade de correntes diferentes. Há diferentes meios de localização de descarga atmosférica nuvem-solo, como: técnica de indicação de direção (DF), técnica da diferença no tempo de chegada (TOA) e técnica de interferometria. Essas técnicas serão discutidas a seguir.

2.8.3.1 Técnica de indicação de direção (DF)

A técnica de indicação de direção consiste basicamente na medição do ângulo azimute da descarga em relação ao norte geográfico através de triangulação (SOARES, 2014). Com dois sensores torna-se possível detectar o ponto de localização da emissão do campo eletromagnético, mediante a interseção das retas que correspondem à direção de incidência da descarga. Entretanto, segundo Visacro Filho (2005), utilizam-se três sensores, s_1 , s_2 e s_3 , conforme Figura 27, para evitar a indeterminação na medição, caso um raio incida sobre a linha base (linha pontilhada – Figura 27). Pela Figura 27, os pontos L12, L13 e L23 indicam a posição detectada pelos sensores s_1 , s_2 e s_3 . Assim algoritmos especiais são utilizados para estimar essa posição.

Figura 27 - Determinação do ponto de localização da descarga atmosférica pela técnica de indicação de direção.



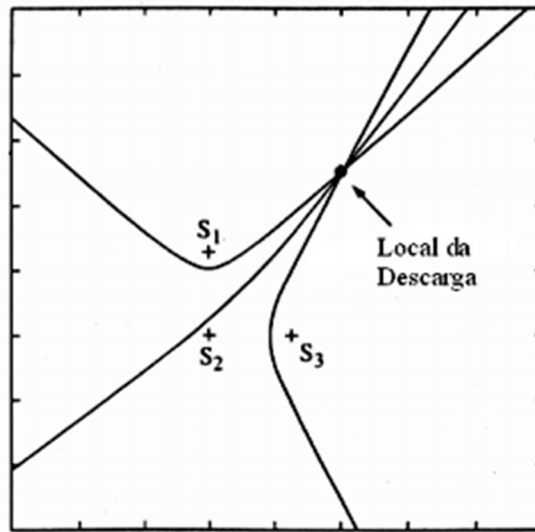
Fonte: Naccarato (2001)

2.8.3.2 Técnica da diferença no tempo de chegada (TOA)

A técnica da diferença no tempo de chegada consiste no registo do tempo e o horário da chegada da energia eletromagnética emitida pela descarga (SOARES, 2014). Para isso, são instaladas antenas em conjunto que detectam o horário de chegada da onda eletromagnética. Essa detecção é calculada através da diferença temporal relativa entre os horários de chegada registado por cada sensor que devem estar sincronizados entre si.

Cada sensor descreve uma curva hiperbólica que define a possível localização do ponto de incidência da descarga. A interseção das hipérbolas relativa à diferença no tempo de chegada da onda em cada sensor, indica o ponto de incidência. A Figura 28 mostra a localização do ponto de incidência através da interseção das hipérbolas geradas pelas estações receptoras (s_1 , s_2 e s_3), localizadas remotamente do local de descarga.

Figura 28 - Determinação do ponto de localização da descarga atmosférica pela técnica da diferença no tempo de chegada.




Fonte: Naccarato (2001)

2.8.3.3 Técnica interferométrica

A técnica interferométrica se baseia nas diferenças de fases da onda eletromagnética medida por antenas posicionadas em triangulação. Dessa forma, cada antena mede a onda em uma fase diferente (VISACRO FILHO, 2005). A partir dessas diferenças é possível determinar a direção de chegada da onda eletromagnética emitida pelo raio. A Figura 29 exibe um esquema simplificado de localização do ponto de ocorrência através de dois sensores. Nota-se que o método de angulação para localizar a descarga, se assemelha ao método de direção de chegada.

Figura 29 - Determinação do ponto de ocorrência de uma descarga atmosférica pela técnica interferométrica.



Fonte: Visacrato Filho (2005)

CAPÍTULO III

3 INDICADORES DE INSTABILIDADE ATMOSFÉRICA

3.1 INTRODUÇÃO

Nesta seção serão abordados conceitos básicos sobre a atmosfera terrestre e estabilidade atmosférica. Tais conceitos permitem o entendimento do emprego de índices de instabilidade atmosférica como meio clássico de previsão de tempestades severas com raios. Valores de alguns índices de instabilidade atmosférica foram calculados a partir dos dados de sondagem atmosférica por satélite, com o objetivo de validar uma metodologia de previsão de raios, nesta tese. Dessa forma, cabe uma breve explicação sobre os processos envolvidos para a obtenção dos índices de instabilidade atmosférica. Tradicionalmente, radiossondas lançadas na atmosfera terrestre, são utilizadas como meios de obtenção de índices e parâmetros termodinâmicos da atmosférica.

3.2 COMPOSIÇÃO DA ATMOSFERA TERRESTRE

Segundo Silva (2006):

A atmosfera terrestre é o conjunto de gases, vapor d'água e partículas, constituindo o que se chama de ar, que envolve a superfície da Terra. Não existe um limite superior para atmosfera, no sentido físico, verificando-se apenas uma progressiva rarefação do ar com a altitude. No âmbito da Meteorologia, geralmente se considera que a atmosfera terrestre possui cerca de 80 a 100 km de espessura. Deve-se ter em mente que essa camada, predominantemente gasosa, é muito delgada quando comparada com o raio médio do planeta. De fato, representa apenas cerca de 1,6% desse raio. A porção mais importante da atmosfera, sob o ponto de vista meteorológica, porém não atinge 20 km de altitude, o que representa apenas 0,3% do raio do planeta.

A composição da atmosfera terrestre é bastante variável. Existem, na atmosfera um grupo de gases que apresentam uma concentração aproximadamente constante, até cerca de 90 km de altitude. São os chamados gases permanentes ou não variáveis, sendo formados, principalmente por: Nitrogênio (N_2), Oxigênio (O_2), Argônio (Ar), Neônio (Ne), Hélio (He), Metano (CH_4), Criptônio (Kr), Hidrogênio (H_2) e Xenônio (Xe). Há também, os chamados gases variáveis, como: vapor d'água (H_2O), Dióxido de carbono (CO_2), Ozônio (O_3), Dióxido de enxofre (SO_2) e Dióxido de nitrogênio (NO_2). Dentre os gases variáveis, o N_2 encontra-se em maior quantidade na atmosfera (78,084 % por volume), enquanto o Xe apresenta-se em menor concentração ($0,087 \times 10^{-4}$ % por volume). Dentre os gases variáveis, o vapor d'água


encontra-se em maior quantidade na atmosfera (0 a 7 % por volume) e o NO_2 é o menor (0 a 0,000002 % por volume) (VIANELLO; ALVES, 2000).

O vapor d'água presente na atmosfera é um elemento essencial para o surgimento de inúmeros fenômenos meteorológicos, como nuvens, precipitação e descargas atmosféricas. Sendo um veículo para o transporte de calor na atmosfera, conduzindo-o sob a forma de calor latente e liberando-o como calor sensível. Esse transporte é importante, vertical e horizontalmente, em análises de parâmetros termodinâmicos da atmosfera, como temperatura, etc.

3.3 ESTRUTURA VERTICAL DA ATMOSFERA TERRESTRE

Considerando o gradiente vertical de temperatura, a atmosfera terrestre pode ser dividida verticalmente em quatro camadas principais: troposfera, estratosfera, mesosfera e termosfera. Há também, três regiões de transições entre as camadas principais: tropopausa, estratopausa e mesopausa. Ressalta-se que não há uma separação física entre as camadas e cada camada apresenta características próprias. A Figura 30 ilustra a composição da atmosfera terrestre até 100 km, destacando-se a variação da temperatura em $^{\circ}\text{C}$ (linha vermelha) e pressão atmosférica em mb.

Figura 30 - Composição da atmosfera terrestre.



Fonte: Silva (2006)

A troposfera situa-se adjacente à superfície terrestre, sendo por ela aquecida. Do ponto de vista meteorológico, é considerada a camada mais importante, devido aos inúmeros fenômenos atmosféricos que acontecem nessa região. Atinge uma altitude aproximadamente de 15 – 18 km. Essa camada se caracteriza por intensos eventos convectivos, concentrando a maior quantidade de gases e vapor d'água. Nessa camada a temperatura cai rapidamente com a altitude, cerca de 6,5°C por km (SILVA, 2006).

A tropopausa é a região de transição entre a troposfera e estratosfera, se caracterizando pela tendência de isoterma, isto é, por manter o gradiente vertical de temperatura constante. Nas médias latitudes, a temperatura da tropopausa varia de -50 a -55°C, com uma espessura de aproximadamente de 3 km.

A estratosfera se estende além da tropopausa, a uma altitude de aproximadamente 50 km. Essa camada se caracteriza pelo crescimento da temperatura, atingindo no topo, valores máximos próximos de 0°C. Há uma altura de aproximadamente 30 km, esse crescimento torna-se mais suave. Atribui-se a grande quantidade de O₃ presente nessa camada, a absorção da radiação ultravioleta, acarretando assim no aumento da temperatura. Essa camada se caracteriza pela ausência de movimentos verticais, devido seu perfil estável de temperatura.

A estratopausa é a região de transição entre a estratosfera e a mesosfera. Caracteriza-se pela isoterma e decrescimento da quantidade de O₂. Sua espessura média é entorno de 3 a 5 km.

A mesosfera se estende de 50 a 80 km de altitude, aproximadamente. Apresenta uma variação negativa da temperatura, atingindo uma temperatura de aproximadamente de -95° C em seu topo. O vapor d'água e CO₂, a partir de 60 km de altitude, são praticamente ausentes. A região de transição entre a mesosfera e a termosfera é conhecida como mesopausa. A mesopausa, também, se caracteriza pela isoterma, com limites entre 80 e 90 km.

A termosfera é a última camada da atmosfera terrestre, se estendendo de 90 km até em direção ao espaço. Sendo seu limite considerado de 1.000 km. Caracteriza-se pelo aumento médio de temperatura com a altitude e pela rarefação local.

3.4 ESTABILIDADE ATMOSFÉRICA

O termo “estado de estabilidade” é definido como a estabilidade da atmosfera em equilíbrio hidrostático em relação a deslocamentos verticais da massa de ar, geralmente considerando o método da parcela (PIPIER, 1988). Se caracterizando pela ausência ou inibição de movimentos atmosféricos ascendentes. Quando prevalecem os movimentos verticais atmosféricos, há uma condição de instabilidade. Se o estado da atmosfera é instável

com grande umidade, há grandes possibilidades de ocorrências de trovoadas. Dessa forma, Vujović et al. (2015) afirma que a condição de instabilidade, aliada à umidade relativa, cisalhamento do vento e uma fonte de energia para iniciar a convecção são pré-condições para a formação das tempestades com raios.

A condição de estabilidade ou não é avaliada através da diferença de temperatura do ar no interior da parcela em relação ao ar no ambiente externo (atmosfera), quando se considera a ascensão de um volume de ar não saturado, segundo uma razão adiabática seca em relação à variação da temperatura observada na atmosfera. Se a temperatura da parcela de ar for maior que a temperatura do meio, conseqüentemente haverá um deslocamento da parcela de ar que receberá um empuxo vertical para cima, ocasionada mudança em sua temperatura, gerando uma condição de instabilidade atmosférica. Se a temperatura da parcela for menor que a temperatura do meio, haverá um deslocamento da parcela de ar que receberá um empuxo vertical para baixo, gerando uma condição de estabilidade atmosférica.

A Figura 31 exemplifica, resumidamente, as condições de estabilidade ou instabilidade atmosférica, considerando o método da parcela. Observa-se pela Figura 31, que quando se tem uma instabilidade, há uma predominância de correntes ascendentes de massa de ar, gerando fortes correntes de convecção entre as massas de ar ascendente (menor densidade) e descendente (maior densidade). Na situação de estabilidade há uma predominância de correntes descendentes de ar (densidade maior), não gerando convecção entre as diferenças de temperaturas das massas de ar inferior e superior.

Figura 31 - Consideração de estados de estabilidade ou instabilidade da atmosfera, considerando o método da parcela.



Fonte: Fundamentos da Meteorologia (2014)

O conhecimento do estado de estabilidade da atmosfera ou não em uma região, permite avaliar se as condições dessa localidade em produzir intensas atividades convectiva, levarão a formação de nuvens de tempestades. Como já mencionado anteriormente, a condição de instabilidade da atmosfera é a responsável pelo surgimento das nuvens de tempestades. Estudos científicos ao longo dos anos foram desenvolvidos com o intuito de prever tempestades. Com isso, foram definidos alguns índices termodinâmicos, obtidos através de radiossondagem convencional, para avaliar a habilidade da atmosfera em desenvolver severas condições de tempo meteorológico.

3.5 INDICADORES DE INSTABILIDADE ATMOSFÉRICA

Para se avaliar o grau de instabilidade da atmosfera com o propósito de realizar previsão de tempestades severas, foram propostos diversos indicadores de instabilidade atmosférica que auxiliam nos estudos meteorológicos (PIPIER, 1988). Diversos estudos, como Manzato (2007), Ali et al. (2011), Kaltenböck, Diendorfer e Dotzek (2009) utilizaram indicadores de instabilidade, derivados de radiossondagens, para prever condições de tempestades severas em suas localidades de estudos.

De acordo com o Glossário de Meteorologia da Sociedade Americana de Meteorologia (AMERICAN METEOROLOGY SOCIETY, 2017) “um índice de instabilidade é qualquer quantidade que estime o potencial da atmosfera para atividade convectiva e que possa ser prontamente avaliado a partir de dados obtidos por sondagens operacionais”. Dessa forma, os valores que estes índices de estabilidade assumem no momento da sondagem dão uma noção do estado de estabilidade da atmosfera, através de critérios termodinâmicos da atmosfera e dinâmicos do vento. Com isso, pode-se obter um indicativo da condição de tempo meteorológico em um determinado local.

Alguns índices admitem como fatores de instabilidade a diferença da condição de temperatura, umidade, as características do vento, como direção e velocidade, em diferentes níveis de pressão atmosférica. Além desses critérios, existem índices de estabilidade consideram conhecimentos da energia da força dos movimentos das massas de ar para avaliar a ocorrência de convecção (SÁ, 2011).

Na literatura existem diversos tipos de índices de instabilidade que podem ser calculados para avaliar o potencial de instabilidade atmosférica. Assim, cita-se: Índice Showalter (*Showalter index*) (SHOWALTER, 1953); Índice K (*K-index*) (GEORGE, 1960); Índice de Levantamento (*Lifted index*) (GALWAY, 1953); Índice Cross Totals (*Cross totals index*) (MILLER, 1967); Índice Total Totals (*Total totals index*) (MILLER, 1967); Índice SWEAT

(*SWEAT index*) (BINDER, 1970); Inibição Convectiva (*Convective Inhibition - CINE*); Energia Potencial Convectiva Disponível (*Convective Available Potential Energy - CAPE*) (MONCRIEFF; MILLER, 1976), Água precipitável, etc.

A seguir alguns indicadores de instabilidade atmosférica serão descritos. Essa explicação, torna-se necessária, pois, no capítulo 6 (MATERIAIS e MÉTODOS), será abordado um processo de validação desta tese de doutorado, o qual foi realizado comparando os resultados obtidos com uma metodologia tradicional existente na literatura científica. Algumas metodologias tradicionais de previsão de raios, se baseiam na utilização de indicadores de instabilidade, provenientes de dados de radiossondagem, como temperatura do ar, umidade, temperatura do ponto de orvalho e dentre outros. Assim, no capítulo 6 será abordado o cálculo de alguns índices de instabilidade a partir de dados satelitais para a região de estudo.

3.5.1 ÍNDICE SHOWALTER (*Showalter index*)

Este índice é dado em função de apenas três parâmetros: temperatura do ar e temperatura do ponto de orvalho no nível de pressão de 850 hPa e temperatura do ar em 500 hPa. Dessa forma, este índice avalia a instabilidade da parcela de ar no nível de 850mb.

O índice Showalter é calculado pela subtração entre a temperatura do ar no nível de 500 hPa e a temperatura de uma parcela de ar que subiu adiabaticamente seca, do nível de 850 hPa até atingir o nível de 500 hPa, conforme a Equação 3.1:

$$I_{showalter} = T_{500} - T_{parcela} \quad 3.1$$

Onde:

T_{500} = temperatura do ambiente (em °C) no nível de 500 hPa;

$T_{parcela}$ = temperatura de uma parcela levantada (em °C) de 850 hPa a 500 hPa.

Quanto mais negativo for o valor deste índice, maior será a probabilidade de ocorrências de tempestades. Showalter (1953) encontrou que para $I_{showalter} \leq +3$, há forte evidências de indicadores de raios e tempestades e para $I_{showalter} \leq -3$, há forte probabilidade de convecção severa.

3.5.2 ÍNDICE DE LEVANTAMENTO (*Lifted index* - LI)

Este índice proposto é uma modificação do Índice Showalter para avaliar a instabilidade de uma parcela de ar nos níveis da baixa troposfera (GALWAY, 1956). Este índice é definido pela Equação 3.2 a seguir:

$$LI = T_{500} - T_{p500} \quad 3.2$$

Onde:

T_{500} = temperatura do ambiente (em °C) no nível de 500 hPa;

T_{p500} = temperatura de uma parcela levantada (em °C) de 500 m acima da superfície até o nível 500 hPa.

Valores negativos de LI indicam situações de instabilidade. Miller (1967) adota o valor de $LI = -2$, como sendo um valor indicativo para ocorrência de tempestades severas. Quando mais negativo for esse índice, maiores são as chances de trovoadas.

3.5.3 ÍNDICE SWEAT

É um índice que utiliza diversas variáveis para determinar a probabilidade de tempo severo. Sendo essas variáveis dadas pela equação 3.3 a seguir:

$$I_{SWEAT} = 12T_{d850} + 20(TT - 49) + 2f_{850} + f_{500} + 125(S + 0,2) \quad 3.3$$

Onde:

T_{d850} = temperatura do ponto de orvalho (em °C) no nível de 850 hPa;

TT = valor do índice Total Totals;

f_{850} = velocidade do vento em nós no nível de pressão de 500 hPa;

f_{500} = velocidade do vento em nós no nível de pressão de 500 hPa;

S = é a função da diferença de direção entre o vento de 500 hPa e o de 850 hPa.

Valores altos de I_{SWEAT} são indicativos de tempo severo. Sendo que na literatura valores entre 300-400 indicam possibilidade tempo severo.

3.5.4 ÍNDICE K (K index)

É um índice utilizado para avaliar o potencial convectivo para formação de tempestades. É dado pela Equação 3.4 a seguir:

$$IK = (T_{850} - T_{500}) + T_{d850} - (T_{700} - T_{d700}) \quad 3.4$$

Onde:

T_{850} = temperatura do ar (em °C) no nível de pressão de 850 hPa;

T_{500} = temperatura do ar (em °C) no nível de pressão de 500 hPa;

T_{d850} = temperatura do ponto de orvalho (em °C) no nível de pressão de 850 hPa;

T_{700} = temperatura do ar (em °C) no nível de pressão de 700 hPa;

T_{d700} = temperatura do ponto de orvalho (em °C) no nível de pressão de 700 hPa.

Quanto maior for este índice, maiores serão as chances de tempestades. Valores de K superiores a 20, já sinalizam a formação de tempestade com probabilidade de 20% - 40%, e para valores de K maiores de 40 indicam probabilidade próxima de 100% de chance de ocorrer tempestades severas.

3.5.5 ÍNDICE TOTAL TOTALS (*Total Totals Index* - TTI)

É um índice utilizado para avaliar a força de uma tempestade. Este índice é uma combinação entre o Índice Vertical Totals (*Vertical Totals Index* - VTI) e o Índice Cross Totals (*Cross Totals Index* - CTI). O Índice Vertical Totals é dado pela Equação 3.5, enquanto o Índice Cross Totals é dado pela Equação 3.6 a seguir:

$$VTI = T_{850} - T_{500} \quad 3.5$$

Onde:

T_{850} = temperatura (em °C) no nível de pressão 850 hPa;

T_{500} = temperatura (em °C) no nível de pressão 500 hPa;

$$CTI = T_{d850} - T_{500} \quad 3.6$$

Onde:

T_{d850} = temperatura do ponto de orvalho (em °C) no nível de pressão 850 hPa;

T_{500} = temperatura (em °C) no nível de pressão 500 hPa;

Logo o Índice Vertical Totals é dado pela junção entre a Equação 3.5 e 3.6, resultando em:

$$TTI = VTI + CTI \quad 3.7$$

Quanto maiores forem os valores de *TTI* mais a atmosfera estará instável. Para valores de *TTI* acima de 43 há uma forte possibilidade de ocorrência de tempestades com raios (MILLER,1967).

3.5.6 ÁGUA PRECIPITÁVEL

Corresponde a informação da quantidade água disponível na atmosfera (sondagem em mm), não sendo equiparada às precipitações que ocasionam as chuvas tradicionais (processos físicos). Uma quantidade de água precipitável elevada, aliada a um ambiente com elevados valores de CAPE, reúne condições atmosféricas favoráveis para ocorrência de trovoadas.

3.5.7 ENERGIA POTENCIAL CONVECTIVA DISPONÍVEL (*Convective Available Potential Energy - CAPE*)

Corresponde à área positiva de uma sondagem no diagrama termodinâmico, que indica a quantidade de energia disponível para convecção. Sendo obtida pela Equação 3.8 a seguir:

$$CAPE = g \int_{NCE}^{NE} \left(\frac{\theta_e(z) - \theta_{es}(z)}{\theta_{es}(z)} \right) dz \quad 3.8$$

Onde:

NCE = é o nível de convecção espontânea que corresponde ao momento em que a parcela de ar começa a ascender de forma espontânea. O NCE é o limite inferior da integral que determina a área da CAPE.

NE = é o nível de equilíbrio que corresponde à igualdade entre a temperatura do ambiente e a temperatura de uma parcela de ar ascendente. O NE é o limite superior da integral e representa o topo da nuvem.

θ_e = é a temperatura potencial equivalente da parcela de ar que corresponde a temperatura potencial de uma parcela de ar teria se todo o vapor d'água fosse condensado e o calor latente liberado para aquecer a parcela.

θ_{es} = temperatura potencial equivalente saturada do ambiente que corresponde a temperatura potencial alcançada por uma parcela de ar saturada se todo o vapor d'água disponível fosse condensado ou removido do sistema.

A Tabela 2 representa os valores de CAPE obtidos pela Equação 3.8 e as condições de estabilidade associadas por esses valores.

Tabela 2 - Valores de CAPE

| CAPE (J/Kg) | Condições associadas |
|--------------------------------|----------------------|
| $500 \leq \text{CAPE} < 1000$ | Convecção fraca |
| $1000 \leq \text{CAPE} < 2500$ | Convecção moderada |
| $\text{CAPE} \geq 2500$ | Convecção forte |

Fonte: Bluestein (1993)

Segundo (MOTA; TAVARES, 2012, p.209) “a CAPE é a medida da integral na vertical da flutuabilidade da parcela entre os níveis de convecção espontânea (NCE) e nível de equilíbrio (NE)”. Com isso, quando há uma diferença entre a temperatura potencial equivalente da parcela de ar θ_e e a temperatura potencial equivalente saturada do ambiente θ_{es} , a área definida da Equação 3.8 existirá e será positiva. Isto significa que se a parcela de ar deslocada estiver mais quente que o ambiente, haverá uma força de empuxo direcionando para cima.

3.5.8 ENERGIA DE INIBIÇÃO DA CONVECÇÃO (*Convective Inhibition Energy* - CINE)

É representada pela área negativa de um diagrama de termodinâmico que corresponde à área entre o perfil de temperatura e a temperatura de uma parcela de ar levantada até o nível NCE. Isto representa a quantidade de energia necessária para levantar a parcela de ar até o NCE. O cálculo da CINE é dada pela Equação 3.9 a baixo:

$$CINE = g \int_{NS}^{NCE} \left(\frac{\theta_e(z) - \theta_{es}(z)}{\theta_{es}(z)} \right) dz \quad 3.9$$

Onde:

NS = Nível da superfície;

NCE = Nível de convecção espontânea;

θ_e = Temperatura potencial equivalente da parcela de ar;


θ_{es} = Temperatura potencial equivalente saturada do ambiente.

A área negativa da CINE representa a possibilidade de convecção severa, sendo que quanto maior o valor de CINE, menor será a possibilidade de formação de chuvas.

A Figura 32 ilustra respectivamente a área negativa (CINE) e a área positiva (CAPE), traçadas a partir da superfície, através dos parâmetros NCE, NE, θ_e , θ_{es} , θ (temperatura potencial), θ_{ep} (curva da temperatura potencial equivalente constante). A CAPE e a CINE representam a energias necessárias para haver a convecção atmosférica, levando a instabilidade. Dessa forma, valores altos de CAPE (positivos), associados a valores baixos de CINE

(negativos), indicam condições de instabilidade da atmosfera, favorecendo a formação de tempestades em uma região.

Figura 32 - Área da CAPE (positiva em vermelho) e Área da CINE (negativa em azul).



Fonte: Mota (2007)

3.6 CONSIDERAÇÕES FINAIS

Este capítulo abordou alguns conceitos básicos de estabilidade e índices de instabilidade atmosférica. No capítulo 4, será explanado os principais conceitos envolvendo as sondagens atmosféricas. As sondagens atmosféricas são importantes para obtenção dos índices de instabilidades que foram apresentados neste capítulo.

CAPÍTULO IV

4 SONDAGEM ATMOSFÉRICA

4.1 INTRODUÇÃO

Uma sondagem atmosférica corresponde a uma medição dinâmica e termodinâmica da atmosfera terrestre com o propósito de obter informações relacionadas à distribuição vertical da pressão atmosférica, temperatura, umidade e vento (direção e velocidade), estudando assim as propriedades físicas da atmosfera (SILVA, 2006). Outros parâmetros também podem ser obtidos indiretamente através da sondagem atmosférica, como índices de instabilidade atmosférica, bem como desenvolver modelos de previsão de descargas atmosféricas. Assim, dados de sondagens permitem estudos acerca das condições meteorológicas da atmosfera terrestre, como ocorrências de chuvas (CARDOSO, 2007), previsão de raios (WANG et al., 2014) e fortes eventos convectivos, como os tornados (PIPIER, 1988).

As sondagens atmosféricas podem ser realizadas por aparelhos denominados de radiossonda ou através de satélites meteorológicos. Essa tese de doutorado fez uso de dados de sondagens satelitais. Dessa forma, este capítulo descreverá conceitos básicos relacionados à sondagem atmosférica por satélite e as chamadas radiossondagens convencionais. Abordar-se-á os satélites da série NOAA, com seus equipamentos sondadores embarcados e as principais características destes, além de explicar o funcionamento da estação de recepção de sondagem atmosférica por satélite do SIPAM, com sede em Belém - PA.

4.2 SISTEMA MUNDIAL DE OBSERVAÇÃO (SMO)

O SMO é o responsável pelas inúmeras observações meteorológicas no mundo. As observações são realizadas por estações espalhadas por diversos países membros da Organização Meteorológica Mundial (OMM), obedecendo normas e critérios técnicos (VIANELLO; ALVES, 2012). Há diversas fontes de coleta de dados como: satélites meteorológicos, radares, estações meteorológicas, plataformas automáticas de coletas de dados continentais e marítimas, etc. (VIANELLO; ALVES, 2012). Existem também estações marítimas fixas, como navios-plataformas e, boias fixas e de deriva. A Figura 33 ilustra o esquema de funcionamento do sistema de observação mundial das condições atmosférica terrestre.


Figura 33 - Sistema mundial de observação meteorológica.



Fonte: Adaptado (Ferreira, 2004)

As estações de superfícies permitem a coleta, processamento de dados meteorológicos de superfície e altitude em uma determinada localidade. Os satélites meteorológicos se apresentam como uma alternativa mais eficiente de cobertura e obtenção de dados observacionais da Terra, devido as grandes lacunas no espaço que podem cobrir. Existem basicamente dois tipos de satélites: os de órbita polar e os de órbita geoestacionária. A Figura 34 exibe os satélites de órbita polar e órbita geoestacionária.

Figura 34 - Órbitas dos satélites polar e geoestacionário ao redor do planeta Terra.




Fonte: Viannelo e Alves (2012)

Os satélites de órbita polar (Figura 35) estão posicionados ao redor do planeta Terra entre 800 e 1.400 km de altura, com uma visão de polo a polo (norte-sul). Possuem uma órbita de inclinação em torno de 99° em relação a linha do equador, fornecendo imagens da Terra em faixas nominais de aproximadamente 3.000 km, cobrindo-a duas vezes por dia. Enquanto os

satélites geoestacionários encontram-se a 36.000 km, estando posicionados em órbita equatorial, fornecendo imagens 24 horas (TERASCAN ® SYSTEM TRAINING GUIDE, 2011).

Figura 35 - Órbita de satélites polares.



Fonte: TERASCAN ® SYSTEM TRAINING GUIDE (2011)

Todas as informações obtidas pelos satélites de órbita polar e geoestacionários são enviadas às estações receptoras ao redor do mundo. O Brasil recebe informações de vários satélites meteorológicos, como NOAA, NASA/MSFC, GOES, AQUA, TERRA, FENG YUN, MTSAT/JMA, METEOSAT e dentre outros (FERREIRA, 2004).

4.3 RADIOSSONDAGEM – ESTAÇÃO DE OBSERVAÇÃO DE ALTITUDE

A radiossondagem é uma forma de realização de sondagem atmosférica, onde se obtém parâmetros meteorológicos atmosféricos em uma determinada localidade.

Cardoso (2007, p.27) define radiossonda como:

É um tipo de sondagem da atmosfera em que um conjunto de equipamentos é transportado da superfície para a atmosfera superior por meio de um balão. O conjunto de equipamentos é constituído por sensores de temperatura, umidade e pressão, juntamente com um rádio transmissor, utilizado para efetuar medidas de vento, além de uma bateria que alimenta o sistema.

Enquanto Munta (2009, p. 5) define radiossonda como: “um conjunto de instrumentos e sensores que medem basicamente a temperatura do ar, umidade relativa e pressão atmosférica, enquanto elevada na atmosfera até alturas da ordem de 30 km, por um balão inflamado com gás

hélio”. A Figura 36 exhibe modelos de equipamentos de radiossondagem. A radiossonda é um equipamento transmissor, dotado de sensores de pressão, temperatura e umidade, possuindo também antena de GPS (*Global Position System*) que permite medir o deslocamento da sonda e estimar direção e velocidade do vento, em pequenos intervalos de tempo. Todo o conjunto pesa em torno de 1 kg.

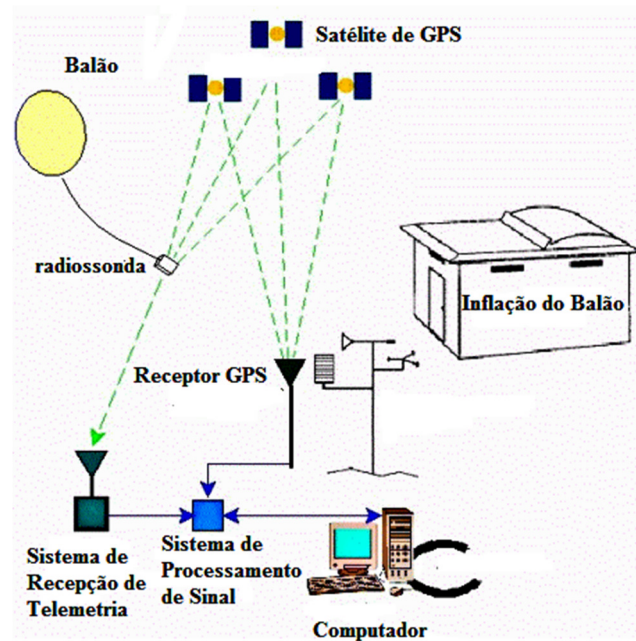
Figura 36 - Radiossondas.



Fonte: (Silva, 2006)

A Figura 37 exhibe um esquema simplificado da realização de uma sondagem atmosférica através de radiossonda. O equipamento (radiossonda) é preso ao balão que ascende a partir da superfície terrestre. Durante esse processo, a radiossonda registra e transmite as medidas em diferentes alturas a cima da superfície da Terra. Estes dados são enviados, minuto a minuto, para um sistema de recepção de telemetria para em seguida serem processados e armazenados em computador. O deslocamento do balão é realizado pelo vento, assim, a radiossonda não ascende verticalmente na atmosfera. Normalmente a radiossonda cai com auxílio de paraquedas, podendo ser reaproveitada para futuras sondagens. Há casos em que a radiossonda é descartável, sendo utilizada uma única vez.


Figura 37 - Esquema simplificado do mecanismo de radiossondagem.



Fonte: Adaptado de WEATHER (2012)

Em geral, uma radiossonda é elevada até alturas de 30 km (SILVA, 2006), sendo que seu limite é determinado pela ruptura do balão. Radiossondas são lançadas uma ou duas vezes, durante o dia, às 12:00 UTC (*Universal Time Coordinate*) e 00:00 UTC, a partir de estações de observações de altitude espalhadas pelo globo terrestre (Figura 38). Esses horários são definidos como horário padrão mundial pela OMM (Organização Meteorológica Mundial), isto significa que todos os países realizam suas radiossondagens no mesmo instante.

Figura 38 - Estações de radiossondagem ao redor do mundo.



Fonte: Huricannes (2017)


Segundo a OMM os níveis de pressão atmosférica obrigatórios em uma sondagem atmosférica são: 1000 hPa, 925 hPa, 850 hPa, 700 hPa, 500 hPa, 400 hPa, 300 hPa, 250 hPa, 200 hPa, 150 hPa, 100 hPa, 70 hPa, 50 hPa, 30 hPa, 20 hPa e 10 hPa.

Para sondagens na alta estratosfera e na mesosfera, utilizam-se balões estratosféricos ou foguetes, chegando a alturas de 160 km ou mais. Estes balões podem permanecer vários dias a uma altura de 40 km, suportando cargas maiores que 500 kg (VIANELLO; ALVES, 2012).

Dados de sondagem atmosférica permitem a obtenção do perfil vertical atmosférico de uma região em um determinado horário. Sendo importante para o estudo de possíveis transformações termodinâmicas que o ar atmosférico possa sofrer, isto é, análises das condições de estabilidade atmosférica, além de alimentarem modelos numéricos de previsão de tempo.

A Figura 39 mostra um diagrama Skew-T Log-P, proveniente de uma radiossondagem a partir da estação do aeroporto de Belém (SBBE), estado do Pará. O diagrama mostra a variação da temperatura do ar e temperatura de ponto de orvalho em diferentes níveis de pressão atmosférica. Normalmente, os dados de entrada para construção desses diagramas são os obtidos por meio das sondagens aerológicas, isto é, pressão, temperatura do ar e do ponto de orvalho. Estes diagramas termodinâmicos permitem avaliar, diretamente, as condições atmosféricas.

Figura 39 - Diagrama Skew-T Log-P resultando de uma radissondagem.



De acordo com Vianello e Alves (2012, p.60) a temperatura do ponto de orvalho é definida como:

A temperatura na qual a saturação ocorre quando o ar é resfriado a pressão constante e sem adição ou remoção de vapor d'água. Em outras palavras, é a temperatura na qual a quantidade de vapor atualmente presente na atmosfera estaria em sua máxima concentração, a mesma pressão.

A Figura 40 mostra as localizações das estações meteorológicas de altitude (EMA) no Brasil. Na região norte há 13 EMA, sendo que no estado do Pará, há somente três estações. Sendo uma localizada em Belém – SBBE (Estação Meteorológica de Altitude de Belém), outra em Tiriós - SBTS (Estação Meteorológica de Altitude de Tiriós) e em Santarém – SBSN (Estação Meteorológica de Altitude de Santarém). Dessa forma, nota-se que há uma carência de EMA no estado do Pará e na região amazônica como um todo. Isso dificulta a obtenção de dados observacionais para modelagem numérica e previsão do tempo na região. Além disso, dados que são obtidos por radiossondagem meteorológica, se restringem à área de cobertura que é percorrida pela sonda, com isso deixando uma extensa área descoberta em razão da baixa densidade de EMA. Assim, torna-se necessário dispor de outro mecanismo para a aquisição de dados de sondagem atmosférica para a região, no qual possa auxiliar nas análises das condições meteorológicas atmosféricas, e assim auxiliar, futuras pesquisas científicas na região Amazônica no Brasil.

Figura 40 - Redes de Estações Meteorológicas de Altitude no Brasil.



Fonte: Autor

4.4 SONDAGEM ATMOSFÉRICA POR SATÉLITE DE ÓRBITA POLAR

As EMA possuem indiscutível importância na geração de informações úteis para análise e previsão do tempo, porém, algumas limitações podem ser elencadas quanto à utilização exclusiva de estações meteorológicas de altitude convencionais, como a baixa densidade de cobertura na região Amazônica, o seu elevado custo de operação, visto que o equipamento (radiossonda), normalmente é perdido após cada sondagem, além do risco que apresenta para o operador a manipulação do gás que alimenta o balão que leva a radiossonda. Diante de tais circunstâncias e dificuldades, uma alternativa que se apresenta viável, bastante econômica e que permite maior densidade de cobertura consiste na utilização de sensores do tipo sondadores instalados em plataformas orbitais. Visto que os sensores podem ser instalados em satélites de órbita polar, cuja trajetória dura aproximadamente 100 minutos, uma mesma área pode ser visitada, em média, duas vezes ao dia, por um único satélite. Utilizando-se uma constelação de satélites, o dado pode ser obtido várias vezes ao dia, em diferentes horários.

4.4.1 SATÉLITES NOAA

O primeiro satélite construído para realização de observação meteorológica foi o TIROS 1 (*Television and Infrared Observation Satellite*), em 1960. Elaborado pela Agência Espacial Americana (NASA – em inglês: *National Aeronautics and Space Administration*) e pelo Departamento de Defesa dos Estados Unidos. Devido ao sucesso obtido, a partir deste, novos satélites foram agregados para aumentar o campo de observação ao redor do mundo.

Os satélites da NOAA são controlados pela NASA em cooperação com a Administração Nacional Oceanográfica e Atmosférica (NOAA – em inglês: *National Oceanographic and Atmospheric Administration*). A história dos satélites NOAA iniciou-se na década 1960, através dos satélites da série TIROS. A partir do TIROS-6, esta série de satélite passou a ser denominada de NOAA, permanecendo até os dias atuais.

Durante anos, a série de satélites NOAA vêm contribuindo com informações meteorológicas importantes sobre o planeta Terra, permitindo a obtenção de imagens multiespectrais (captadas por sensores) e medições numéricas de variáveis da superfície e atmosfera terrestre, através de equipamentos sondadores (obtidas por sensores).

Os satélites da série NOAA coletam informações da superfície da Terra em intervalos curtos de tempo, proporcionando a obtenção de informações de cada ponto do planeta, a cada 12 horas. Possuem uma órbita de altitude média em relação à Terra de 850 km.

Atualmente a série de satélites NOAA apresenta 3 satélites operacionais: NOAA-15, NOAA-18 e NOAA-19 (POES, 2017). A Tabela 3 exibe os satélites NOAA que já foram lançados em órbita, com seu ano de lançamento e o estado atual de operação.

Tabela 3- História da série de satélites NOAA.

| Satélite | Lançamento | Estado de Operação |
|----------|------------|--------------------|
| NOAA-1 | 1970 | Inativo |
| NOAA-2 | 1972 | Inativo |
| NOAA-3 | 1973 | Inativo |
| NOAA-4 | 1974 | Inativo |
| NOAA-5 | 1976 | Inativo |
| NOAA-6 | 1979 | Inativo |
| NOAA-7 | 1981 | Inativo |
| NOAA-8 | 1983 | Inativo |
| NOAA-9 | 1984 | Inativo |
| NOAA-10 | 1986 | Inativo |
| NOAA-11 | 1988 | Inativo |
| NOAA-12 | 1991 | Inativo |
| NOAA-13 | 1991 | Inativo |
| NOAA-14 | 1994 | Inativo |
| NOAA-15 | 1998 | Ativo |
| NOAA-16 | 2000 | Inativo |
| NOAA-17 | 2002 | Inativo |
| NOAA-18 | 2005 | Ativo |
| NOAA-19 | 2009 | Ativo |

Fonte: Fonte: (SATVIEW, 2017)

Segundo NOAA (2017) o satélite NOAA-11 saiu de operação em 16 de junho de 2004, enquanto NOAA-12, NOAA-14, NOAA-16 e NOAA-17 saíram de funcionalidade, respectivamente em: 10 de agosto de 2007, 23 de maio de 2007, 09 de junho de 2014 e 10 de abril de 2013.

Os satélites da série NOAA possuem sensores do tipo sondadores como: o ATOVS (*Advanced TIROS Operational Vertical Sounder*) e o TOVS (*TIROS Operational Vertical Sounder*). Estes sensores são capazes de traçar perfis verticais de temperatura ao longo de suas trajetórias. A sondagem vertical obtida através de satélites apresenta características vantajosas para sua utilização operacional, especialmente na Amazônia, não apenas pelo baixo custo

operacional, mas, principalmente, pela densidade de pontos que se pode cobrir (TERASCAN ® SYSTEM TRAINING GUIDE, 2011).

4.4.1.1 Sensores dos Satélites da Série NOAA

Os sensores que compõem os satélites meteorológicos são os principais responsáveis pela realização da sondagem vertical. Ao longo da evolução tecnológica dos satélites, os sensores que os integram, também foram aperfeiçoados com o objetivo de aproximar cada vez mais as suas medições das medições realizadas pelas tradicionais radiossondagens. As radiossondagens possuem grande confiabilidade em suas medições de variáveis atmosféricas e há anos são utilizadas em estudos de parâmetros atmosféricos, como as ocorrências de descargas atmosféricas.

Os principais sensores utilizados na obtenção de dados de sensoriamento remoto das condições meteorológicas atmosféricas, através dos satélites NOAA, são:

- AVHRR/2 (*Advanced Very High Resolution Radiometer*) – sensor de imagem.

Apresenta como características principais:

1. 5 canais:
 - 1.2 . 1 visível (canal 1).
 - 1.2 . 2 infravermelho próximo (canal 2 e 3).
 - 1.2 . 2 infravermelhos termais (canal 4 e 5).

- AVHRR/3 (*Advanced Very High Resolution Radiometer*) – sensor de imagem.

Apresenta como características principais:

1. 6 canais:
 - 1.2 . 1 visível (canal 1).
 - 1.2 . 3 infravermelho próximo (canal 2, 3A e 3B).
 - 1.2 . 2 infravermelhos termais (canal 4 e 5).

Somente o canal 5 é transmitido a qualquer momento. O canal 3A opera durante a passagem do dia e o canal 3B opera durante a passagem da noite.

- TOVS (*TIROS Operational Vertical Sounder*)

Possui os seguintes sensores:

1. HIRS/2 (*High-Resolution Infrared Sounder*)
2. MSU (*Microwave Sounding Unit*)
3. SSU (*Stratospheric Sounding Unit*)

- ATOVS (*Advanced TIROS Operational Vertical Sounder*)

Possui os seguintes sensores, dependendo da série do satélite:

1. HIRS/3 (*High Resolution Infrared Sounder Version 3*) e HIRS/4 (*High Resolution Infrared Sounder Version 4*)
2. AMSU-A (*Microwave Humidity Sounder Unit – A*), AMSU-B (*Microwave Humidity Sounder Unit – B*), AMSU-A1, AMSU-A2 e MHS.

A Tabela 4 exibe os sensores que compõem os instrumentos de sondagem dos satélites da série NOAA.

Tabela 4 - Series de satélites NOAA com seus sondadores.

| | | |
|-------------------|----------------------------|-------------------|
| NOAA-12 e NOAA-14 | NOAA-15, NOAA-16 e NOAA-17 | NOAA-18 e NOAA-19 |
| AVHRR/2 | AVHRR/3 | AVHRR3 |
| HIRS/2 | HIRS/3 | HIRS/4/ |
| MSU e SSU | AMSU-A e AMSU-B | AMSU-A1 e AMSU-A2 |

Fonte: TERASCAN © SYSTEM TRAINING GUIDE (2011)

Devido os dados que foram utilizados ao longo do desenvolvimento desta tese, serem oriundos dos sensores TOVS e ATOVS, será dado ênfase nas explicações sobre estes sensores.

4.4.1.1.1 Sondador TOVS dos satélites NOAA-12 e NOAA-14: MSU, SSU e HIRS/2

O pacote TOVS (*TIROS Operational Vertical Sounder*) que integra os satélites NOAA-12 e NOAA-14, inclui o MSU (*Microwave Sounder Unit*) e HIRS/2 (*High Resolution Infrared Sounder Version 2*) e o SSU (*Stratospheric Sounding Unit*).

O primeiro satélite a utilizar o sensor HIRS foi o Nimbus-6, lançado em 1975. Os dados que foram coletados, por este sensor, mostraram-se bastante promissores. Assim, houve a melhoria da eficiência deste sensor. O HIRS/2 foi a evolução do HIRS, possuindo 20 faixas de canais que permitem medir o perfil vertical das condições de temperatura, a cerca de 40 km. Possui um canal visível (0,69 μm), sete canais de ondas curtas (3,7 a 4,6 μm) e doze canais de ondas longas (6,5 a 15 μm). O HIRS/2 mede temperatura e umidade, além disto, mede também a temperatura da superfície do mar, altura da nuvem, radiação de onda longa, fração de nuvem, estimativa de precipitação, velocidade e direção do vento.

O sensor SSU possui três canais no infravermelho para obter medidas da estratosfera. O MSU mede somente a temperatura através de quatro faixas de canais. Sendo que está medição pode ser realizada através de nuvens. Tem como principal objetivo medir a temperatura em dias nublados. O HIRS mede além da temperatura, a umidade, entretanto, não consegue medir a temperatura através das nuvens.

Os satélites que faziam uso destes sensores, isto é, NOAA-12 e NOAA-14 foram inutilizados. Assim, foram desenvolvidos outros satélites com sensores mais aperfeiçoados para estimar os perfis verticais de temperatura.

4.4.1.1.2 Sensor ATOVS dos satélites NOAA-15, NOAA-16, NOAA-17: AMSU-A, AMSU-B e HIRS/3

O sensor ATOVS foi integrado a partir da série de satélites do NOAA-15. O HIRS/3 possui características semelhantes ao HIRS/2, mas com modernizações em componentes em relação ao seu antecessor. O instrumento HIRS/3 foi aperfeiçoado para aumentar sua vida útil e para produzir níveis de ruídos mais baixos (FERREIRA, 2004).

O sensor AMSU (*Advanced Microwave Sounding Unit*) incorporado aos satélites NOAA, a partir do NOAA-15 até o NOAA-17, substituíram os antigos MSU e SSU. O AMSU possuía um total de 20 canais de micro-ondas. Isto representou uma melhora significativa em relação ao sensor MSU que possuía apenas 4 faixas de canais de micro-ondas. O AMSU permitiu uma melhora na capacidade de traçar o perfil atmosférico, principalmente, na presença de nuvens, além da aquisição de informação do vapor d'água, precipitação e gelo.

AMSU-A é um radiômetro de micro-ondas de 15 canais compostos por duas unidades separadas: AMSU-A1 e AMSU-A2. Juntos, eles fornecem sondagens de temperatura melhoradas (canais 1, 2 e 15 fornecem informações sobre precipitação, concentração de gelo, cobertura de neve e umidade). O módulo AMSU-A1 contém treze canais e o módulo AMSU-A2, dois canais.

AMSU-B é um radiômetro de micro-ondas de 5 canais, com três canais centrados na linha de vapor de água de 183,31 GHz, um canal a 89 GHz e um canal a 150 GHz. Quando combinado com AMSU-A, este instrumento permite a obtenção de perfis verticais de vapor d'água desde a superfície da Terra até uma altura equivalente a 12 km (FERREIRA, 2004).

4.4.1.2 Sensor ATOVS dos satélites NOAA-18, NOAA-19: AMSU-A, MHS e HIRS/4

Os sensores AMSU-A e AMSU-B foram substituídos pelo sensor MHS (*Microwave Humidity Sounder*), a partir do NOAA-18.

O MHS é um radiômetro micro-ondas de 5 canais que varre a superfície da terra em bandas de frequências específicas. Como a umidade na atmosfera (gelo, cobertura de nuvens, chuva e neve) atenua a radiação de micro-ondas emitida da superfície da Terra, é possível, a partir das observações feitas pelo MHS, obter uma imagem detalhada da umidade atmosférica

com os diferentes canais relativos às diferentes altitudes. A temperatura na superfície da Terra também pode ser determinada.

O MHS tem canais na faixa de 89 a 190 GHz. Os canais 157 GHz e 183 GHz fornecem dados de umidade atmosférica. O canal de 89 GHz fornece informações sobre a temperatura e emissividade do sistema (em conjunto com dados AMSU-A) e detecta nuvens de baixa altitude e precipitação. A Tabela 5 exibe os canais MHS com seus comprimentos de ondas e as respectivas resoluções medidas em nadir. Os satélites NOAA-18 e NOAA-19 também carregam o HIRS/4 que substituiu o HIRS/3.

Tabela 5 - Características do sensor MHS.

| Canal MHS | Frequência | Resolução (em nadir) |
|------------------|----------------------|-----------------------------|
| H1 | 89,9GHz | ~15-16 km |
| H2 | 157,0 GHz | ~15-16 km |
| H3 | 183.311 +/- 1.00 GHz | ~15-16 km |
| H4 | 183.311 +/- 3.00 GHz | ~15-16 km |
| H5 | 190.311 GHz | ~15-16 km |

Fonte: TERASCAN © SYSTEM TRAINING GUIDE (2011)


4.4.2 SATÉLITE NOAA-19

O sensor ATOVS integra a plataforma de coleta de dados do NOAA-19, o que permite a realização de sondagem vertical por este satélite. O ATOVS é constituído pelos sensores: *Advanced Microwave Sounding* (AMSU), *High Resolution Infrared Radiation Sounder Version 4* (HIRS/4) e *Microwave Humidity Sounder* (MHS).

O satélite NOAA-19 (Figura 41 - com as respectivas localizações dos sensores) entrou em operação a partir de 02 de fevereiro de 2009, apresenta uma órbita que cruza o equador próximo à região de Belém durante o dia em torno de 17 UTC (14 horas locais) e aproximadamente às 05:00 UTC (02 horas locais). Atualmente, encontra-se em operação.

O satélite NOAA-19 apresenta como características básicas: altitude de 870 km, ângulo de inclinação de 98.7°, taxa de processamento de 0,77 (minuto/mês) e uma trajetória que dura em torno de 102,14 minutos.

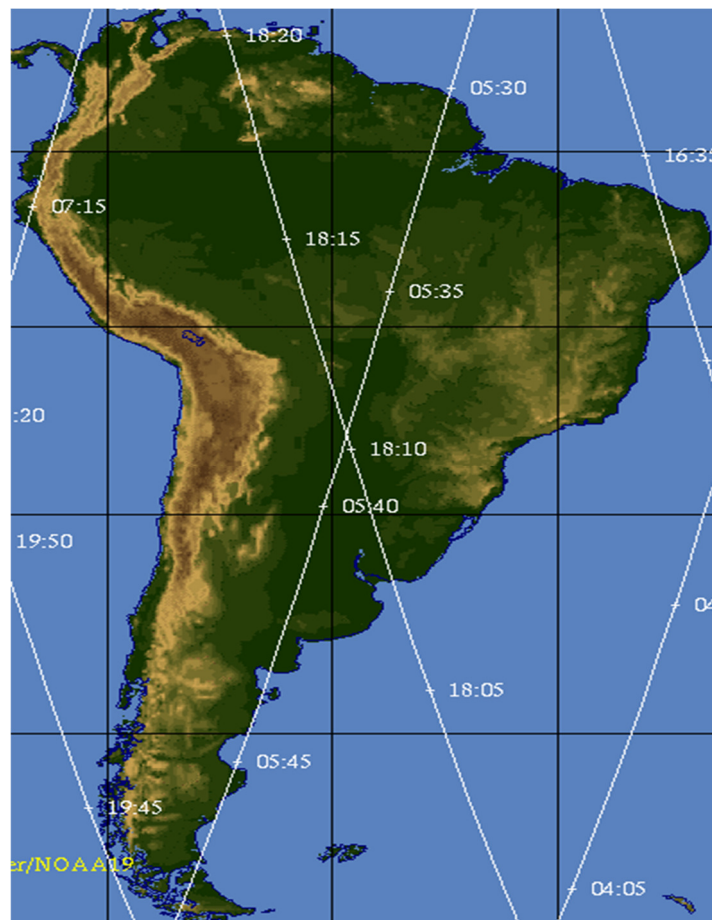
Figura 41 - Sensores a bordo do satélite NOAA-19.



Fonte: NASA (2017)

A Figura 42 apresenta, respectivamente, o percurso sucessivo do satélite meteorológico de órbita polar NOAA-19, com os horários em UTC, sobre a América do Sul.

Figura 42 - Visualização do percurso do satélite NOAA-19 sobre a América do Sul.



Fonte: NOAA (2017)

4.4.3 ESTAÇÃO TERRESTRE DE RECEPÇÃO DE DADOS POR SATÉLITE DO SIPAM-BELÉM-PA

O SIPAM (Sistema de Proteção da Amazônia) possui três estações de recepção de dados de satélites ambientais de órbita polar, incluindo os satélites da série *National Oceanic and Atmospheric Administration* (NOAA 18 e 19), situadas em Porto Velho-RO, Manaus-AM e Belém-PA. Após cada passagem dos satélites sobre a região amazônica, antenas de recepção de sinais de satélite, em cada estação do SIPAM, captam esses dados que são transmitidos para um computador de aquisição e posteriormente para um computador de processamento. Assim, cada estação terrestre do SIPAM pode visualizar e manipular os dados de satélites através do software TERASCAN® v4.0. A Figura 43 exibe a antena rastreamento para recepção dos dados de sondagem atmosférica por satélite da sede do SIPAM - Belém/PA.

Figura 43 - Antena de Recepção de dados de sondagem do NOAA-19 pelo SIPAM.



Fonte: Autor

4.4.3.1 Sistema TERASCAN®.

O TERASCAN é um sistema integrado de *hardware* e *software* concebido para a recepção automatizada de dados de satélites meteorológicos e ambientais, processamento de imagens e sobreposição de dados. Os dados são recuperados em imagens e exibidos em espectros parciais ou variáveis, que podem ser inclusive sobrepostos às próprias imagens. Estes dados são armazenados no formato próprio do TERASCAN, chamado de TDF (*Terascan Data Format*) e visualizado pelo *Terascan viewer* (TERASCAN® SYSTEM TRAINING GUIDE, 2011).

O TERASCAN é um sistema proprietário, desenvolvido pela *Seaspace Corporation* (SEASPACE, 2017), sendo que o SIPAM detém a licença para sua utilização. Este sistema pode receber dados dos seguintes satélites:

- Dados de banda-X de satélites em órbita polar:
 - Dados MODIS dos satélites Terra e Aqua;
 - Dados OCM do Oceansat-1;
 - Dados SAR (somente captura) do Radarsat-1 e ERS-1.
- Dados de banda -L/S de satélites em órbita polar:
 - AVHRR, ATOVS dos satélites NOAA-18 e NOAA-19;
 - Dados AHRPT do satélite MetOp-2;
 - Dados SeaWiFS do OrbView-2;
 - Dados do sensor especial e OLS (SSM/I, SSM/T1 e SSM/T2) dos satélites DMSP;
 - Dados MVISR do FY-1D.
- Dados banda-L de satélites geostacionário.
 - Dados de sondagem e imagem do GOES;
 - Dados de imagem do MTSAT e FY-2;
 - Dados LRIT do GOES, MSG, MTSAT e FY-ED/E;
 - Dados HRIT do MTSAT e MSG;
 - Dados HiRID do FY-2D/E e MTSAT;
 - Dados HRI dos Meteosat;
 - Dados WEFAX dos GOES, Meteosat e MSG.

A seguir é dada uma listagem do *hardware* que compõe o TERASCAN que permite receber e processar os dados de satélite.

- Antena de interceptação de sinais de satélite. Para a recepção de dados de alta resolução a partir de satélites geostacionários, é utilizada uma grande antena de direção fixa de 3,8 m de diâmetro. Para a recepção de dados de alta resolução a partir de satélites em

órbita polar, é utilizada uma antena de rastreamento, cujo tamanho depende da telemetria a ser recebida;


- Receptor para sintonizar a frequência correta do sinal de satélite e separar os dados do sensor (a banda de base) da portadora RF (conhecida como demodulação);
- Sincronizador de bits para regenerar o fluxo de bits contra ruído, convertendo o formato de dados digitais para NRZ-L, se necessário, e extraíndo o *clock*, um pulso de tempo é adicionado ao sinal do satélite para permitir a sincronização do sistema de recepção com o transmissor do satélite;
- Sincronizador de *frames* para dividir o fluxo de bits contínuos em blocos de dados significativos, chamados de *frames*;
- Um computador como estação de trabalho com o *software* TERASCAN para agendar e controlar a recepção de dados, processar os dados em produtos e, exibir e distribuir estes dados de produtos;
- Uma antena de GPS (*Global Positioning System*) para fornecer a posição e o tempo do sistema;
- Fonte de alimentação ininterrupta para proteger o sistema de “surto” de energia, manter o sistema ligado e funcionando em caso de “falta” de energia;
- Interface para navegação de bordo.

O software do TERASCAN é baseado no Sistema Operacional Linux, consistindo:

- Um formato de dados chamado de TDF (*TeraScan Data Format*);
- Mais de 600 funções de linhas de comando para receber e processar os dados de satélites;
- Um conjunto de arquivos de referências e banco de dados;
- Um conjunto de interfaces gráficas de usuário (GUI - *graphical user interfaces*) para manipulação dos dados do TERASCAN.

A Figura 44 apresenta a interface gráfica do Terascan *viewer*, utilizada para visualizar as faixas de varredura dos satélites e as respectivas coordenadas de sondagens (pontos amarelos). Cada ponto em amarelo, corresponde uma coordenada de sondagem adquirida através dos satélites. Pela Figura 44 pode-se notar a dimensão territorial que as sondagens satelitais podem cobrir, assim tornando-se alternativas as radiossondagens convencionais.

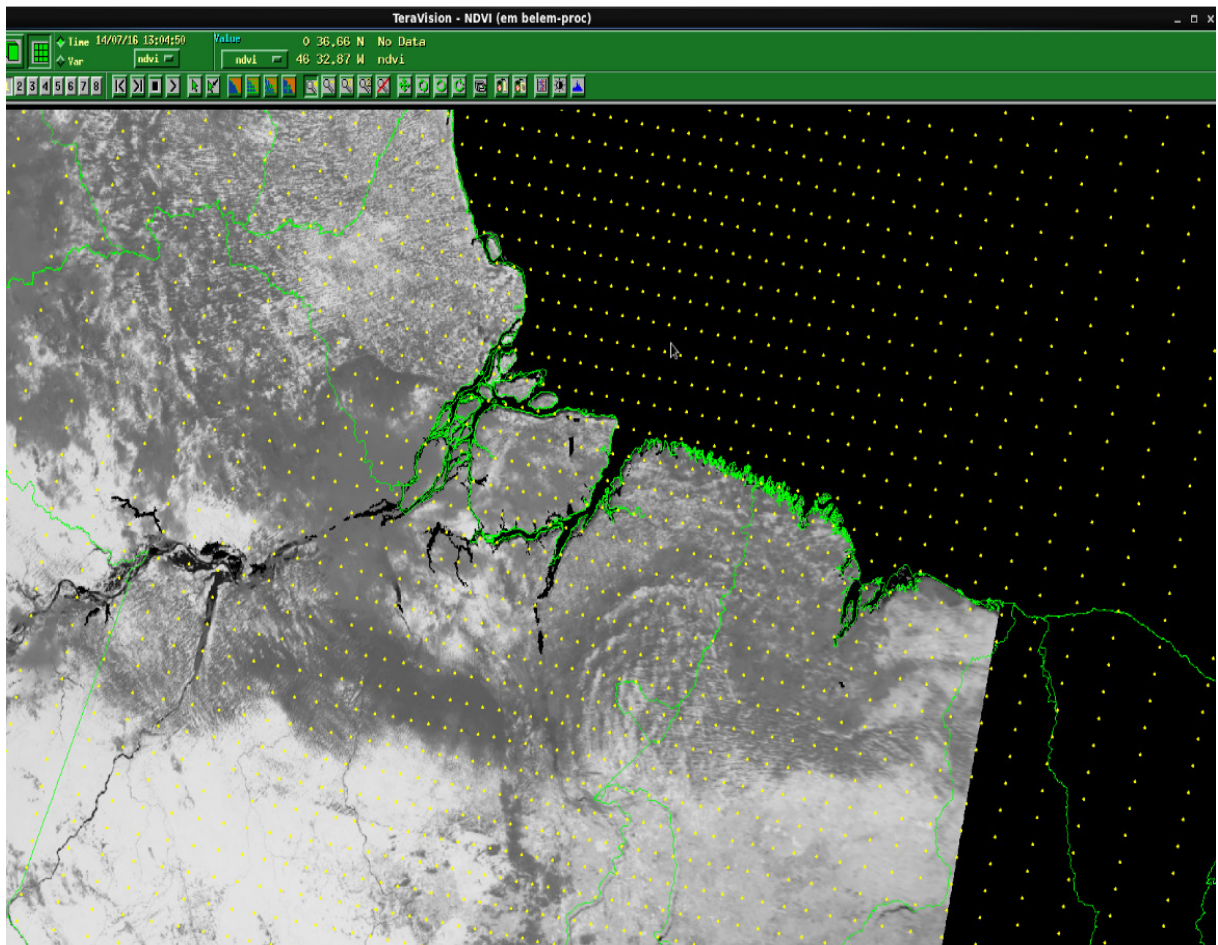
Figura 44 - Interface gráfica do Terascan viewer.



Fonte: Autor

A Figura 45 mostra os pontos de obtenção de sondagem atmosférica, estimada pelo satélite NOAA-19, especificamente pelo estado do Pará, englobando principalmente, a região do Marajó, Belém e nordeste.

Figura 45 - Pontos de obtenção de dados de sondagens pelo NOAA-19.




Fonte: Autor

O TERASCAN recebe os dados oriundos dos sensores ATOVS presentes nos satélites NOAA-18 e NOAA19.

A Figura 46 ilustra o diagrama Skew-T Log P obtido a partir da sondagem do satélite NOAA-19. O diagrama mostra a variação da temperatura do ar e temperatura de ponto de orvalho em diferentes níveis de pressão atmosférica para uma determinada localidade.

Figura 46 - Diagrama Skew-T Log-P resultando da sondagem do satélite NOAA-19.



Fonte: Autor

4.5 CONSIDERAÇÕES FINAIS

Este capítulo abordou conceitos relacionados aos principais mecanismos envolvidos na obtenção de dados observacionais da atmosfera terrestre, como temperatura do ar, temperatura do ponto de orvalho, vento, umidade e dentre outras. Mostrou-se que essas variáveis atmosféricas podem ser medidas, basicamente, por estações de radiossondagens e satélites. Enfatizou-se explicar as principais características dos satélites da série NOAA, em especial os que utilizam os sensores ATOVS. Os dados de perfis verticais de temperatura que foram obtidos a partir dos satélites NOAA, manipulados através do software TERASCAN, foram empregados como variáveis preditivas de entrada para treinamento e validação da RNA. O capítulo 5, descreverá os principais conceitos relacionados as RNA.

CAPÍTULO V

5 REDES NEURAS ARTIFICIAIS

5.1 INTRODUÇÃO

Este capítulo descreverá alguns conceitos básicos relacionados ao método baseado em otimização que foi utilizado para prever a ocorrência ou não de descargas atmosféricas na Região Amazônica.

Segundo Faceli et al. (2015, p.54):

Um algoritmo preditivo é uma função que, dado um conjunto de exemplos rotulados, constrói um estimador. O rótulo ou etiqueta toma valores num domínio conhecido. Se o domínio for um conjunto de valores nominais, tem-se um problema de classificação, também conhecido como aprendizado de conceitos, e o estimador gerado é um classificador. Se o domínio for um conjunto infinito e ordenado de valores, tem-se um problema de regressão, que induz um regressor. Um classificador (ou regressor), por sua vez também é uma função, que, dado um exemplo não rotulado, atribui esse exemplo a uma das possíveis classes (ou a um valor real).

Assim dado um conjunto de observações na forma: $D = \{(x_i, f(x_i)), i = 1, \dots, n\}$, sendo f uma função desconhecida, assim um algoritmo preditivo aprende a aproximar a função desconhecida f a partir de uma função \hat{f} (função de aproximação). Assim \hat{f} permite estimar o valor de f para novas observações de x (FACELI et al., 2015). Assim, de acordo com Faceli et al. (2015), tem-se duas possibilidades para f :

- Classificação: $y_i = f(x_i) \in \{c_1, \dots, c_n\}$, onde $f(x_i)$ assume valores em um conjunto discreto e não ordenado.
- Regressão: $y_i = f(x_i) \in \mathcal{R}$, onde $f(x_i)$ assume valores em um conjunto infinito e ordenado de valores.

Este estudo teve a tarefa de classificar os modelos preditivos em duas classes: 0 (não ocorrência) e 1 (ocorrência), a partir das medições de temperatura do ar e temperatura do ponto de orvalho na atmosfera terrestre, correlacionando essas variáveis com dados históricos de raios. Para realização da predição, optou-se pela utilização de RNA, está se apresenta como uma boa opção na tentativa de modelar um fenômeno atmosférico altamente não linear, como é o caso da formação de uma nuvem de tempestade, sem que haja o domínio do processo físico envolvido em sua formação, apenas fazendo um mapeamento não linear dos dados de entrada e saída de padrões meteorológicos atmosféricos.

5.2 CONCEITO

O cérebro é o órgão responsável pelo controle de todas as atividades dos seres humanos, possibilitando a estes, possuírem diversos sentidos como, por exemplo: controle motor, reconhecer padrões e relacioná-los, usar e armazenar conhecimento, percepção, pensar, refletir, interpretar observações e solucionar diversos tipos problemas do dia-a-dia. Sendo formado por uma grande variedade de células nervosas interligadas que são chamadas de neurônios. Os neurônios são os responsáveis pela propagação das informações dos impulsos nervosos no cérebro, permitindo o processamento de informações complexas, de forma paralela e em um curtíssimo intervalo de tempo.

Este complexo funcionamento do cérebro humano foi motivo de inúmeras pesquisas e trabalhos ao longo dos anos por cientistas. A partir da descoberta das informações sobre a neurofisiologia dos neurônios foi possível criar um modelo matemático computacional que se assemelhasse a organização do cérebro, e que pudesse elucidar novas formas de problemas do cotidiano, no qual os métodos computacionais vigentes se mostravam ineficazes em sua resolução. Com isso, a estrutura individual de cada neurônio, a topologia de suas conexões e o comportamento conjunto desses elementos de processamento natural formou a base para o estudo das Redes Neurais Artificiais (RNA).

Segundo Haykin (2001, p.28): “Uma rede neural é um processador maciçamente paralelo distribuído constituído de processamento simples que têm a propensão natural para armazenar conhecimento experimental e tomá-lo disponível para uso” e se assemelha ao cérebro em dois processos:

1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.
2. Forças de conexões entre neurônios, conhecidas como pesos sinápticos, são utilizados para armazenar o conhecimento adquirido.

Estes processos mostram algumas das principais características das RNA, nos quais, tornam bastante atrativo o uso de RNA na solução de diversos tipos problemas na atualidade, destacando-se:

1. Capacidade de aprender por meio de padrões de entrada/saída, possibilitando a extração de informações de características desconhecidas pela RNA, durante seu processo de treinamento, generalizando esta informação aprendida;
2. Adaptabilidade, através da alteração de seus pesos sinápticos, permitindo adaptar-se a novos tipos de ambientes;

3. Capacidade de representar sistemas com características não-lineares e atuar como mapeadoras universais de funções multivariáveis;

4. Capacidade de auto-organização, no qual a rede atribui um padrão de entrada a uma classe entre um conjunto classes conhecidas.

Em Braga (2007, p.3) define-se uma RNA como sendo “Sistemas paralelos distribuídos compostos por unidades de processamento simples (neurônios artificiais) que calculam determinadas funções matemáticas (normalmente não-lineares). Tais unidades são dispostas em uma ou mais camadas interligadas por um grande número de conexões”.


Pelas duas citações a cima fica evidente que a ideia básica por trás das RNA é imitar o funcionamento do cérebro humano e construir sistemas computacionais capazes de aprender, fazer generalizações e descoberta de conhecimentos.

As primeiras pesquisas acerca das RNA se deram na década de 40, através da descoberta no neurônio artificial por Warren McCulloch e Walter Pitts (McCULLOCH; PITTS, 1943). Desde então, esta área passou por períodos de latência e grandes evidências que consolidaram as RNA com uma poderosa ferramenta computacional em diversas aplicações. Atualmente, utilizam-se as RNA em diversas áreas de pesquisa, como na identificação e controle de sistemas dinâmicos, extração de conhecimento, classificação de padrões, previsão, agrupamento ou *clusterização*, etc. Dentre estas aplicações, alguns tipos de RNA tornam-se bastante atrativas para solucionar determinados problemas específicos, como, por exemplo: Redes *Perceptron de Multicamadas*, Rede de Base Radial, Redes de Kohonen e outras. Cada vez mais novos estudos acerca das RNA vêm sendo desenvolvidos, proporcionando o crescimento cada vez maior desta área de pesquisa.

5.3 NEURÔNIO BIOLÓGICO

O cérebro humano contém cerca de 86 bilhões de neurônios (célula fundamental), todas interligadas (UOL, 2017). Os neurônios são as células mais diferenciadas do organismo, pois, apresentam a maior complexidade estrutural e funcional. A Figura 47 apresenta a estrutura do neurônio biológico humano.

Figura 47 - Neurônio Biológico Humano.




Fonte: Psicológico (2014)

Um neurônio é formado por ramificações filamentosas chamadas de dendritos, que são os terminais de entrada da célula, por um corpo celular, onde ocorre o metabolismo da célula nervosa e pelo axônio que são os terminais de saída da célula.

Os neurônios se comunicam através das sinapses. A sinapse é a região onde dois neurônios entram em contato e é através da qual são transmitidos os impulsos nervosos (corrente elétrica) entre eles. Esta é polarizada e os impulsos nervosos ocorrem através da liberação de substâncias químicas chamadas de neurotransmissores. Um neurotransmissor fica armazenado em vesículas especiais chamadas de vesículas sinápticas. A transmissão dos impulsos nervosos acontece quando os impulsos recebidos por um neurônio A, em determinado momento, são processados e, após atingir um dado limiar de ação, o neurônio A dispara, desencadeando o potencial de ação, que se propaga como onda de despolarização pelo axônio até a sinapse com outro neurônio B; neste local é liberado, então o mediador químico neurotransmissor, que fica armazenado na vesícula sináptica, por um mecanismo chamado de exocitose. Este mediador vai então ocupar os receptores de outro neurônio B, podendo então desencadear uma nova onda de despolarização. Cabe ressaltar que a transmissão dos impulsos é sempre feita do terminal de entrada, ou seja, dos dendritos em direção ao terminal de saída, isto é, para o axônio.

Um neurônio pode criar cerca de 10.000 sinapses, ou seja, até 10.000 conexões com neurônios adjacentes (BASTOS, 2007). Isto mostra a grande capacidade de armazenamento que possui o cérebro humano. A Figura 48, apresenta um esquema do mecanismo de transmissão dos impulsos nervosos no cérebro humano.

Figura 48 - Representação do mecanismo de propagação dos estímulos nervosos pelos neurônios.

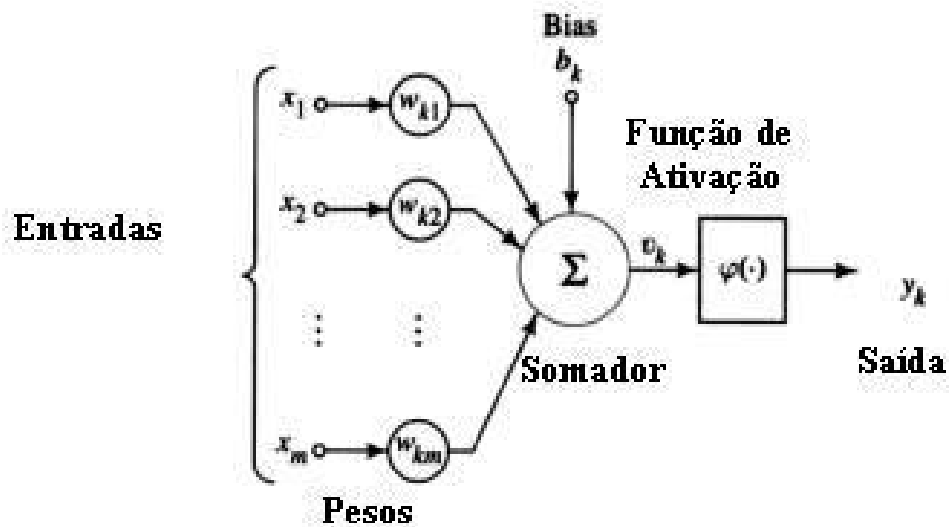


Fonte: NeuroscienceKnowledge (2017)

5.4 NEURÔNIO ARTIFICIAL

O modelo do neurônio artificial, proposto em 1943 pelos pesquisadores McCulloch&Pitts, é inspirado na natureza do neurônio biológico humano. A Figura 49 apresenta o esquema do neurônio artificial.

Figura 49 - Modelo do neurônio artificial.



Fonte: Goldschmit (2014)

Este modelo é composto por três elementos básicos que formam a sua estrutura:

1. **Um conjunto de sinapses ou conexões de entrada:** correspondentes aos terminais de entrada dos dendritos dos neurônios biológicos, onde cada entrada é ponderada por um peso sináptico. Logo, um sinal de entrada x_m na entrada da sinapse w conectada a um neurônio k é multiplicado pelo peso sináptico w_{km} . Para os índices do peso sináptico, o índice k faz referência ao neurônio em questão e o índice m ao terminal de entrada da sinapse a qual o peso se refere.
2. **Uma junção soma:** é responsável pela combinação dos sinais de entrada ponderada pelos seus respectivos pesos sinápticos, ou seja, é o integrador dos sinais que chegam ao neurônio.
3. **Uma função de ativação:** é uma função, geralmente não linear. O intervalo de ativação dos neurônios é confinado ao intervalo unitário $[0, 1]$ ou $[-1, 1]$, restringindo a amplitude de saída do neurônio a um valor finito.

O modelo da Figura 59 resultou na descrição matemática do funcionamento do neurônio de acordo com o par de equações:

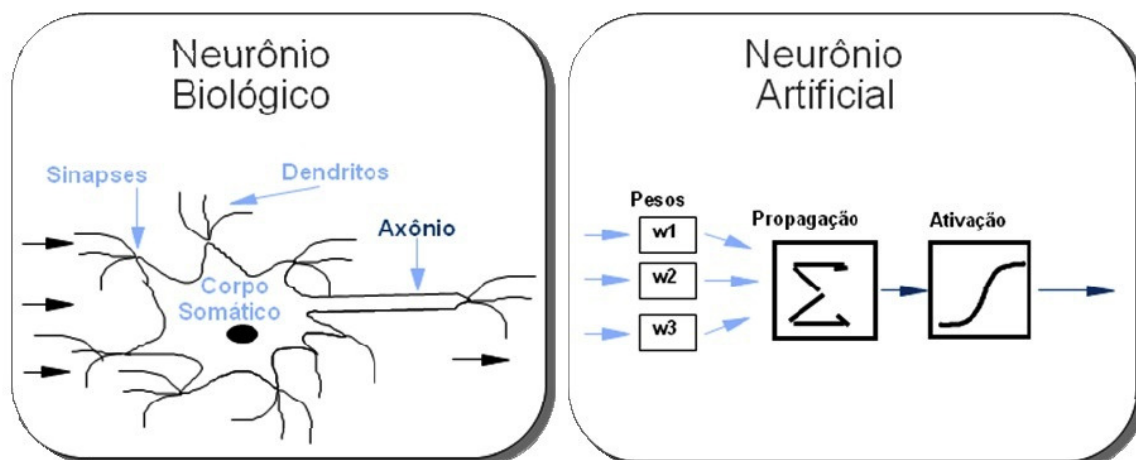
$$v_k = \sum_{m=1}^p w_{km} x_m \quad (5.1)$$

$$y_k = f(v_k + b_k) \quad (5.2)$$

Onde x_0, x_1, \dots, x_p são os sinais apresentados a entrada do neurônio. Cada sinal de entrada é multiplicado respectivamente por w_{k0}, w_{k1}, w_{kp} , que são os pesos sinápticos do neurônio k . Um somatório destes sinais produz um nível de atividade interna dado por v_k (saída linear). Esta saída é submetida a uma função de ativação f que combinado ao valor de bias b_k , formam a saída de ativação do neurônio artificial y_k . O valor de bias tem o papel de aumentar ou diminuir a influência do valor das entradas.

A Figura 50 representa a comparação entre o neurônio biológico humano com o modelo do neurônio artificial. Nota-se a semelhança entre os dois modelos de neurônios, através dos seus terminais de entrada, suas conexões sinápticas e terminais de saída.

Figura 50 - Analogia entre os neurônios naturais e neurônios artificiais.



Fonte: Goldschmidt (2010)

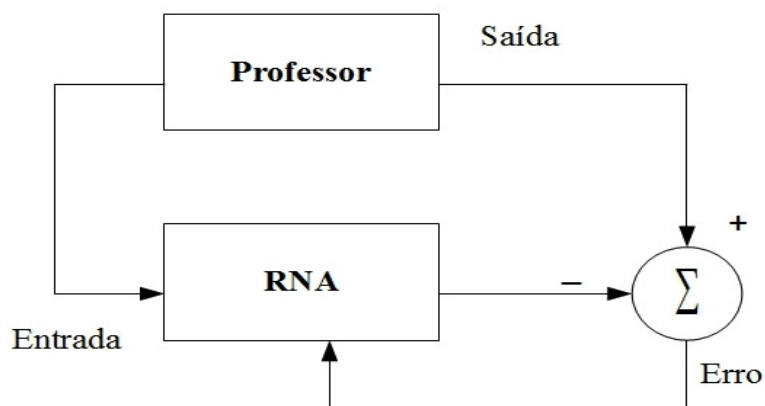
As funções de ativações são geralmente funções do tipo não lineares associadas à saída da unidade de processamento, limitando a saída do neurônio a um determinado valor. As funções de ativações mais comumente utilizadas são: linear, sigmoide, tangente hiperbólica, gaussiana e softmax.

5.5 APRENDIZADO DA RNA

Uma das principais características das RNA é a sua capacidade de aprender através de exemplos ou padrões de entrada/saída. Este aprendizado consiste em ajustar os pesos sinápticos e níveis de bias, estimulando a rede através do ambiente a melhorar o seu desempenho. Existe uma variedade de algoritmos de aprendizagem para promover o treinamento da RNA que se resumem em dois grandes grupos: aprendizado supervisionado e aprendizado não-supervisionado.

5.5.1 APRENDIZADO SUPERVISIONADO

Aprendizado supervisionado ou com professor externo consiste na existência de um supervisor, no qual é o responsável por estimular as entradas da rede por meio de padrões de entrada e observar a saída calculada pela mesma, comparando-a com a saída desejada. Os pesos da rede são ajustados com a finalidade de tornar a saída da rede mais próxima possível da saída desejada, através da minimização de um erro. A Figura 51 ilustra uma representação esquemática do aprendizado supervisionado.

Figura 51 - Esquema de aprendizado Supervisionado.


Fonte: Braga (2007)

Este tipo de aprendizado é aplicado em problemas em que se deseja obter um mapeamento entre os padrões de entrada e saída da rede.

O aprendizado supervisionado pode ser implementado de duas formas: *offline* e *online*. Para um treinamento *offline*, os dados do conjunto de treinamento não mudam e, quando se obtém uma solução para a rede, esta permanece fixa. Em situações que novos dados possam ser adicionados, um novo treinamento deve ser realizado e outra solução é obtida. No aprendizado *online*, os dados estão continuamente mudando, e a rede deve estar em contínuo processo de treinamento (adaptação ao ambiente).

5.5.2 APRENDIZADO NÃO-SUPERVISONADO

Neste tipo de aprendizado não existe a presença do supervisor ou professor como ocorre no aprendizado supervisionado para acompanhar o aprendizado. Neste caso, este tipo de aprendizado usa somente padrões de entrada para treinamento da rede, com isso não se necessita de saídas desejadas e a rede é ajustada de acordo com regularidades estatísticas dos dados de entradas. Um esquema gráfico do aprendizado supervisionado é apresentado na Figura 52.

Figura 52 - Esquema de aprendizado não-supervisionado.

Fonte: Braga (2007)

Este tipo de aprendizado se aplica a problemas que visam a descoberta de características estatísticas relevantes nos dados de entrada, como, por exemplo, a descoberta de agrupamentos e/ou classes.

5.6 ARQUITETURA DAS RNA

O poder computacional de uma RNA está relacionado a forma com que os neurônios artificiais estão interligados. Um conjunto de neurônios artificiais conectados possui maior capacidade na resolução de problemas complexos, em detrimento de neurônios individuais. Com isso a disposição da organização destes neurônios na RNA está intimamente ligada ao problema que será solucionado.

As arquiteturas das redes neurais podem se enquadrar em três configurações possíveis: rede *feedforward*, redes *feedback* e redes auto-organizáveis.


5.6.1 REDE FEEDFORWARD

Uma rede *feedforward* a RNA precisa que suas saídas se conectem somente com as unidades da próxima camada e a propagação de seus estímulos são feitos “para frente”, ou seja, apenas no sentido positivo. Pode ser de uma ou mais camadas de neurônios (múltiplas camadas).

Uma rede *feedforward* de uma camada (Figura 53(a)) apresenta uma estrutura mais simples, consistindo de apenas um nó entre a entrada e a saída. Esta rede pode resolver problemas multivariáveis de múltiplas funções, mas com algumas restrições de complexidade, por apresentar uma estrutura simples.

Uma rede *feedforward* de mais camadas, chamada de RNA multicamadas, se diferencia da rede *feedforward* de apenas uma camada, por possuir uma camada adicional intermediária entre a camada de entrada e camada de saída. A camada intermediária, também, é denominada de camada escondida ou oculta. Essa camada intermediária confere a RNA um alto poder computacional da resolução de diversos de problemas, tornando-a uma aproximadora universal de funções contínuas e não contínuas. Sendo essa capacidade de aproximação relacionada ao número de neurônios ocultos na camada intermediária. A Figura 53 (b) apresenta uma RNA de multicamadas.

Figura 53 -Redes Feedforwards: uma camada (a) e multicamadas (b).



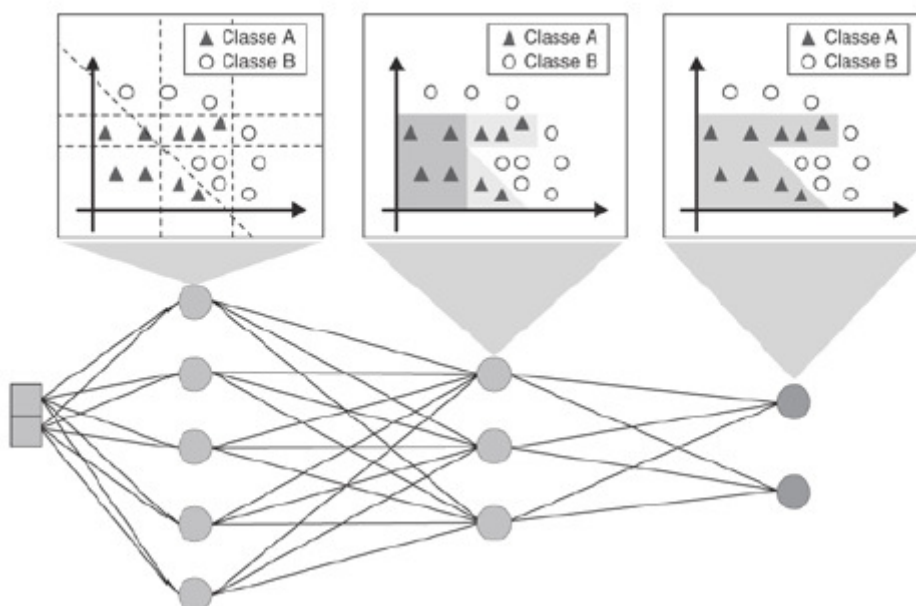
Fonte: Braga (2007)

O comportamento da Figura 53 (b) pode ser descrito por duas transformações sucessivas, uma sendo na camada intermediária e outra na camada de saída, sendo dadas respectivamente: $H(x; w_H)$ e $Y(H(x; w_H); w_S)$, onde w_H e w_S correspondem, respectivamente, aos vetores de pesos da camada intermediária e de saída (BRAGA, 2017).

Segundo Braga (2007) as RNA de multicamadas podem tratar um problema não-linearmente separável do espaço de entrada em um problema linearmente separável na camada de saída, através de operações na camada intermediária. Assim, em problemas de classificação, as RNA de multicamadas podem trabalhar com dados não linearmente separáveis.

Uma RNA multicamadas (MLP, do inglês *multilayer perceptron*) comum apresenta suas camadas completamente conectadas. Os neurônios de uma camada j estão conectados a todos os neurônios da camada $j+1$. A Figura 54 ilustra uma MLP comum para um problema de predição de classes (A e B). Nesta é possível observar o papel de cada neurônio na fronteira de decisão que irá permitir a RNA classificar novos exemplos.

Figura 54 - MLP aplicada a um problema de classificação.



Fonte: Faceli et al. (2015)

Assim pela Figura 54 tem-se (FACELI et al., 2015):

- Na primeira camada ou camada de entrada, o espaço de entrada é dividido em duas partes. Os neurônios dessa camada aprendem uma função que define um hiperplano dessa divisão.
- Os neurônios da camada seguinte (camada intermediária) combinam um grupo de hiperplanos definidos pela camada anterior, formando regiões convexas.
- Os neurônios da camada de saída combinam subconjunto das regiões convexas em regiões de formato arbitrário.

Cada neurônio da camada de saída está associado a uma das classes presente no conjunto de dados. Para o treinamento da RNA, um vetor de resposta desejado $y = [y_1, y_2, \dots, y_n]^t$ para cada objeto, onde n é o número de neurônios na camada de saída (número de classes), tem valor 1 associado à classe do objeto e 0 nas demais posições. O erro é obtido comparando-se o vetor de saída dos neurônios da camada de saída e o vetor de valores desejados para essas saídas.

Segundo Faceli et al. (2015):

Um erro de classificação ocorre quando o neurônio de uma outra classe é o que produz o valor de saída mais elevado. Quando nenhum neurônio produz um valor elevado ou valor elevado é produzido por mais de um neurônio, a rede não tem condições de prever a classe do objeto.


5.6.2 REDE FEEDBACK

Uma rede em que suas saídas, em determinado instante, não dependem apenas de suas entradas, mas também do seu valor atual, pois, possuem uma realimentação da saída dos neurônios para outros neurônios da rede. São chamadas redes recorrentes e podem ser: rede com recorrência entre saídas e camada intermediária e redes recorrentes auto-associativas.

Uma rede neural *feedback* do tipo recorrência entre saídas e camada intermediária se caracteriza por apresentar um laço de realimentação entre a camada de saída e camada intermediária, como pode-se ver na Figura 55 (a). É muito utilizada em problemas que envolvem previsões de eventos futuros.

Uma rede neural *feedback* recorrente auto-associativa (Figura 55 (b)) possui todas suas ligações na forma cíclica. As suas saídas ligam-se as entradas, com isso a resposta da rede sempre depende do seu estado anterior, formando uma auto-associação entre os neurônios da rede. Possui aplicação em problemas de recuperação ou “regeneração” de um padrão de entradas.

Figura 55 - Redes Feedbacks: rede com recorrência entre saídas e camada intermediária (a) e rede com recorrência auto-associativa (b).




Fonte: Braga (2007)

5.6.3 REDES AUTO-ORGANIZÁVEIS

As redes auto-organizáveis se distinguem pela disposição topológica da camada de saída que está organizada em forma de uma “grade”, onde cada grupo de neurônios da grade é responsável por responder a uma classe de estímulos. Possui aplicação, principalmente, em problemas de *clusterização* e compressão de dados. A Figura 56 apresenta o arranjo topológico dos neurônios em uma rede neural auto-organizável.

Figura 56 - Rede neural auto-organizável.



Fonte: Braga (2007)

5.7 ALGORITMO BACKPROPAGATION

O algoritmo de aprendizado das RNA de multicamada mais utilizado é o *backpropagation*, apresentando modificações, como o algoritmo Levenberg-Marquardt (HAGAN; MENHAJ, 1994). Ambos algoritmos serão descritos a seguir.

5.7.1 FORMULAÇÃO TEÓRICA


Provê um aprendizado supervisionado as redes neurais MLP. Baseia-se no aprendizado por correção de erro, onde se busca achar, iterativamente a mínima diferença entre as saídas desejadas e as saídas obtidas pela rede neural, segundo um erro mínimo.

Este algoritmo consiste basicamente em dois passos, conforme as Figuras 57 e 58, um passo direto chamado de propagação e um passo reverso chamado de retropropagação.

Na propagação é aplicado um padrão como estímulo à entrada da RNA e seu efeito se propaga camada por camada até produzir uma saída gerada como resposta a excitação sofrida. Este padrão de saída é então comparado com a saída desejada, e um sinal de erro é calculado para cada elemento da saída. Na etapa de propagação os pesos sinápticos permanecem todos fixos.

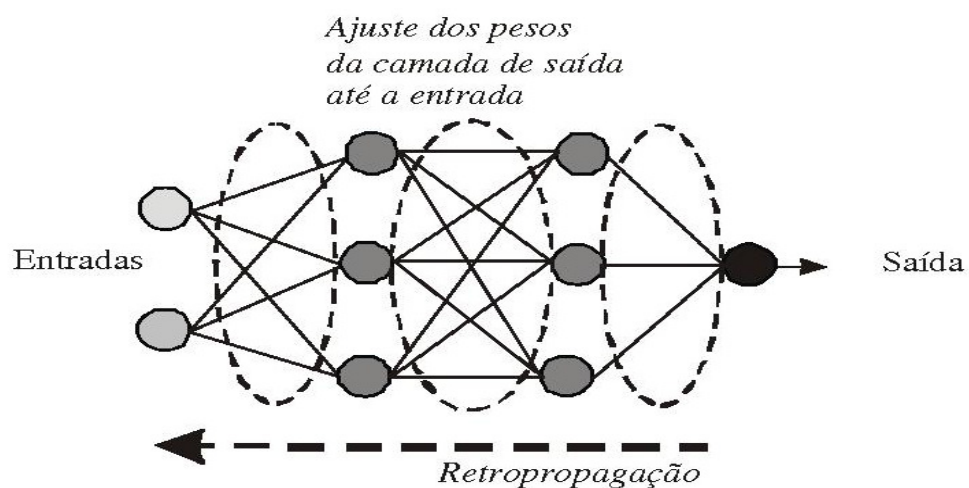
Na retropropagação o sinal de erro gerado é então propagado da camada de saída em direção às camadas intermediárias da rede MLP. Porém, cada elemento da camada intermediária recebe apenas uma porção do sinal de erro total equivalente à contribuição relativa de cada elemento que formam a saída original. Este processo se repete até quando, cada elemento da rede receber um sinal de erro referente a sua contribuição relativa ao erro total. Neste momento, os pesos sinápticos baseados no sinal de erro recebido serão ajustados para cada elemento, fazendo a rede convergir para um estado no qual a resposta desejada se equivalha o mais próximo possível a resposta obtida.

Figura 57 - Etapa de propagação do algoritmo *backpropagation*.



Fonte: Alves (2009)

Figura 58 - Etapa de retropropagação do algoritmo *backpropagation*.




Fonte: Alves (2009)

5.7.2 FORMULAÇÃO MATEMÁTICA

O algoritmo *backpropagation* pode ser descrito em cinco etapas, apresentadas a seguir, e que podem ser acompanhadas pela Figura 59 (HAYKIN, 2001):

Figura 59 - Grafo de fluxo de um neurônio para análise do algoritmo *Backpropagation*.



Fonte: Haykin (2011)

1. **Inicialização:** valores aleatórios são arbitrados aos pesos sinápticos e níveis de bias, em uma distribuição uniforme, cuja média deverá ser zero.
2. **Apresentação dos exemplos de treinamento:** para os exemplos apresentados em uma época (conjunto de treinamento), a rede realiza a propagação do sinal e a retropropagação do erro, corrigindo os pesos sinápticos e níveis de bias.
3. **Propagação dos sinais:** um vetor de sinais $x(n)$ é aplicado a entrada da rede. Então calcula-se o campo local induzido e o sinal de saída para todos os neurônios, começando da camada de entrada até a camada de saída, onde se obtém o vetor de sinais funcionais da rede $y(n)$. Em seguida, calcula-se o erro $e_j(n)$ para cada neurônio da camada de saída, pela comparação $y(n)$ com o vetor de sinais de saída desejado $d(n)$. Com isso, calcula-se o erro instantâneo e com este erro, o erro médio global, para teste de finalização. O erro $e_j(n)$ é dado por:

$$e_j(n) = d_j(n) - y_j(n) \quad (5.1)$$

Em que:

- $y_j(n)$ é a resposta calculada para o neurônio j ;
- $d_j(n)$ é a resposta desejada para o neurônio j .

O sinal de erro global e instantâneo da rede, para os neurônios j da camada de saída, em uma interação n , é definido por:

$$E(n) = \frac{1}{2} \sum_{j=1}^J e_j^2(n) \quad (5.2)$$

Para todo um conjunto de treinamento em N interações o erro médio é dado por:

$$\bar{E}(n) = \frac{1}{N} \sum_{n=1}^N E(n) \quad (5.3)$$

4. Retropragação dos sinais de erro: calculam-se os gradientes locais para todos os neurônios da camada de saída, dado pela equação 5.4:

$$\delta_j = -e_j(n) \varphi'_j(V_j(n)) \quad (5.4)$$

A regra delta é dada pela equação abaixo:

$$\Delta W_{ij} = -\eta \frac{\partial E_n}{\partial W_{ij}} \quad (5.5)$$

Onde η = Taxa de aprendizado

Em seguida, calculam-se os ajustes para os pesos da camada de saída, bem como os de bias, os quais devem ser somados aos valores atuais. Esta correção é dada pela aplicação da regra delta, com o objetivo de minimizar o erro médio dado pela Equação 5.3. Substituindo-se a Equação 5.4 em 5.5, obtém-se:

$$\Delta W_{ij} = -\eta \frac{\partial E(n)}{\partial W_{ij}} = \eta e_j(n) \varphi'_j(V_j(n)) y_i(n) = -\eta \delta_j(n) y_i(n) \quad (5.6)$$

$$\Delta b_{ij} = -\eta \frac{\partial E(n)}{\partial b_{ij}} = \Delta b_j \eta e_j(n) \varphi'_j(V_j(n)) y_i(n) = -\eta \delta_j(n) y_i(n) \quad (5.7)$$

O próximo passo é o cálculo do gradiente local para os neurônios da penúltima camada (camada oculta), dada pela Equação 5.8:

$$\delta_i(n) = \varphi'_i(v_i(n)) \sum_{j=1}^j (\delta_j(n) W_{ij}(n)) \quad (5.8)$$

Então, calcula-se o ajuste para todos os pesos da camada intermediária, bem como os de bias, os quais devem ser somados aos valores atuais. Portanto substituindo a Equação 5.8 em 5.5, tem-se:

$$\delta_i(n) = -\eta \varphi'_i(V_i(n)) y_k(n) \sum_{j=1}^j (\delta_j(n) W_{ij}(n)) = -\eta \delta_i y_k(n) \quad (5.9)$$

$$\Delta b_i = -\eta \varphi'_i(V_i(n)) y_k(n) \sum_{j=1}^j (\delta_j(n) W_{ij}(n)) = -\eta \delta_i y_k(n) \quad (5.10)$$

O mesmo processo continua de forma idêntica para as demais camadas ocultas.

4. Interação: novas épocas de treinamentos são apresentadas à rede de forma aleatória até que o critério de parada seja satisfeito. Os ciclos de apresentação dos dados de treinamento e ajustes de pesos são realizados de forma iterativa até que se estabeleça algum critério de parada. Os principais tipos de critério de parada são: número máximo de épocas de treinamento e a taxa mínima de erro.

5.7.3 ALGORITMO LEVENBERG-MARQUARDT

O *backpropagation* é um algoritmo de treinamento baseado no método de gradiente descendente, enquanto o algoritmo Levenberg-Marquardt é uma aproximação do método de Newton (HAGAN; MENHAJ, 1994).

De acordo com Braga (2007) “o algoritmo Levenberg-Marquardt melhora o método de Gauss-Newton por meio da utilização de uma taxa de aprendizado variável”. Enquanto o método *backpropagation* é um algoritmo de treinamento baseado no método de gradiente descendente.

Os pesos da RNA através desse algoritmo são atualizados através da Equação 5.11:

$$\Delta w_{ij} = -[\nabla^2 E(w_{ij}(t) + \eta I)]^{-1} \nabla E(w_{ij}(t)) \quad (5.11)$$

Onde $\nabla^2 E(w_{ij}(t))$ é a matriz Hessiana e $\nabla E_{ji}(t)$ é o gradiente.

O parâmetro η é multiplicado por um fator β quando um passo (ajuste) resulta no aumento de $E(w_{ij}(t))$. Quando um passo reduz o valor de $E(w_{ij}(t))$, a taxa de aprendizagem η é dividida por β . Em Hagan e Menhaj (1994), os autores fizeram experimentos com $\eta = 0,01$ e $\beta = 10$. Hagan e Menhaj (1994) afirma que quando o valor de η é grande, o algoritmo se torna o gradiente descendente e quando o valor de η é baixo, o algoritmo se torna o método de Gauss-Newton.

5.8 AVALIAÇÃO DE MODELOS PREDITIVOS

Entre algumas métricas de desempenho usualmente empregada para avaliar um classificador, tem-se: a matriz de confusão, gráfico ROC e área sob a curva ROC (AUC).

5.8.1 MATRIZ DE CONFUSÃO

A avaliação das RNA neste trabalho foi realizada através da taxa de acertos de classificação obtida através de uma matriz de confusão entre a classe prevista (classe de saída) e a classe verdadeira (classe real ou observação). Na matriz, cada coluna representa um

resultado previsto, enquanto cada linha representa o resultado real. A Tabela 6 mostra uma matriz de confusão para avaliar os modelos de classificação realizados neste estudo (FAWCETT, 2006).

Tabela 6 - Matriz de confusão para avaliação dos modelos de classificação.

| CLASSE REAL | CLASSE PREDITA | |
|-------------|----------------|----|
| | | VP |
| | FP | VN |
| | P | N |

Para um problema de apenas duas classes, como será apresentado neste trabalho, pode-se denotar uma classe como sendo positiva e outra como negativa. A partir da matriz de confusão da Tabela 6, obtém-se:

- VP corresponde ao número de verdadeiro positivo, isto é, é o número de elementos classificados corretamente como positivos pelo classificador.
- VN corresponde ao número de verdadeiros negativos, isto é, é o número de elementos classificados corretamente como negativos pelo classificador.
- FP corresponde ao número de falso positivo, isto é, é o número de elementos que pertencem à classe negativa, mas que foram classificados erradamente como pertencentes a classe positiva.
- FN corresponde ao número de falso negativo, isto é, é o número de elementos que pertencem à classe positiva, mas que foram classificados erradamente como pertencentes a classe negativa.
- P e N correspondem, respectivamente, a total de elementos positivos e total de elementos negativos.

A partir da Tabela 6 também são expostas possíveis métricas de análises de desempenho do classificador: taxa de VP, taxa de FP, taxa de FN, taxa de VN e a acurácia de classificação, conforme as equações 5.11, 5.12, 5.13, 5.14 e 5.15, a seguir:

$$\text{Taxa de VP} = \left(\frac{VP}{P} \right) \times 100 \quad (5.11)$$

$$\text{Taxa de FP} = \left(\frac{FP}{N} \right) \times 100 \quad (5.12)$$

$$\text{Taxa de FN} = \left(\frac{FN}{P} \right) \times 100 \quad (5.13)$$

$$\text{Taxa de VP} = \left(\frac{VN}{N} \right) \times 100 \quad (5.14)$$

$$\text{acurácia} = \left(\frac{VP + VN}{N + P} \right) \times 100 \quad (5.15)$$


5.6.2 GRÁFICO ROC E ÁREA SOB A CURVA (AUC)

As análises dos resultados também foram feitas através das curvas do gráfico ROC (Curvas de Características de Operação do Receptor). O gráfico ROC permite visualizar o desempenho de um classificador (FAWCETT, 2006). No gráfico ROC a taxa de verdadeiros positivos de um classificador é registrada sobre o eixo Y, enquanto a taxa de falsos positivos é registrada sobre o eixo X. A Figura 60 ilustra o exemplo de um gráfico ROC com três pontos.

Pelo gráfico ROC da Figura 60, tem-se:

- A linha tracejada na diagonal representa classificadores que realizam previsões aleatórias. Assim, qualquer classificador abaixo dessa linha pode ser considerado pior que o aleatório.
- O ponto (0,1) representa classificadores ideais. Desse modo em termos comparativos entre classificadores, quanto mais à noroeste (taxa de VP é maior e/ou taxa de FP é menor) da linha horizontal do espaço ROC, melhor é o desempenho do classificador (VAN ERKEL; PATTYNAMA, 1998). Esse ponto é chamado de céu ROC, pois, todos os exemplos positivos e negativos são classificados corretamente.
- O ponto (1,0) representa o “inferno ROC”, o ponto (1,1) representa as classificações sempre positivas e o ponto (0,0) representa as classificações sempre como negativas.

Figura 60 - Espaço ROC.



Fonte: Faceli et al. (2015)

Outra forma de avaliar a qualidade de um classificador é através do cálculo da área sob a curva (AUC) do espaço bidimensional ROC (VAN LOOY et al., 2006; VAN ERKEL; PATTYNAMA, 1998; FAWCETT, 2006), a qual constitui uma forma aceitável de comparação geral entre desempenhos de classificadores (WOODS; BOWYER, 1997). Um classificador ideal possui $AUC=1$, isto acontece quando o classificador consegue separar perfeitamente as classes. Para Van Looy et al. (2006) o cálculo da AUC é avaliado como uma medida de qualidade mais sofisticada do que a acurácia geral obtida pelo classificador. Desse modo, obtiveram-se AUC nos casos de estudo desta tese para confirmar a precisão dos resultados obtidos.

5.9 CONSIDERAÇÕES FINAIS

Neste capítulo foi apresentada a técnica de inteligência computacional empregada, neste estudo, para identificar padrões de tempestades de raios. Assim, este trabalho buscou avaliar se a RNA conseguiria identificar padrões atmosféricos que podem evoluir ou não para ocorrência de tempestades com raios. Portanto, no capítulo 6, será descrito o método científico que corroborou com essa hipótese.

CAPÍTULO VI

6 MATERIAS E MÉTODOS

6.1 INTRODUÇÃO

Nesta seção serão descritos os procedimentos metodológicos adotados no desenvolvimento desta pesquisa que consistiu em aplicar redes neurais artificiais e dados de sondagem atmosférica por satélite para propor novo (os) modelo (s) para previsão de raios para a região Amazônica. Para atender este objetivo, inicialmente foram levantados dados de sondagem atmosférica através do satélite NOAA-16, com intuito de analisar estatisticamente, os dados de sondagens verticais obtidos pela passagem deste satélite na região Amazônica. É fundamental que os dados obtidos por sensores orbitais possuam representatividade e fidelidade em suas medições, semelhante ao que se tem através das radiossondagens convencionais.

Dessa forma, Alves et al. (2015) desenvolveram um estudo comparativo entre os dados de sondagem do satélite NOAA-16 e os de radiossondagem convencional. Os dados de radiossondagem empregados estão disponíveis no website da Universidade de Wyoming (UNIVERSITY OF WYOMING, 2017), enquanto os dados dos perfis verticais provenientes do NOAA-16, foram obtidos da estação de recepção do SIPAM CR-BE. Essa comparação foi realizada para a cidade de Belém-PA, com coordenadas 1,38° S e 48, 48° W.

A análise realizada empregou dados diários de sondagens efetuadas às 12:00 UTC, empregando como variáveis meteorológicas testadas, a temperatura do ar e temperatura do ponto de orvalho, a partir dos níveis de pressão atmosférica comuns entre as duas fontes de radiossondagem. O horário de 12:00 UTC é equivalente ao lançamento da radiossonda ao nível mundial, o que coincidiu com a órbita do satélite NOAA-16, na região.

Empregado um teste de hipótese não paramétrico de Wilcoxon-Mann-Whitney, Alves et al. (2015) constataram que as variáveis meteorológicas, temperatura do ar e temperatura do ponto de orvalho, obtidas por meio de radiossondagem tradicional e através do satélite NOAA-16, apresentavam semelhanças estatísticas para a região de Belém-PA. Dessa forma, a validação dos dados de sondagem realizada para o satélite NOAA-16, que encerrou suas operações em junho de 2014, contribui para utilização de dados de outros satélites, com o sensor ATOVS mais aperfeiçoado, como foi o caso do emprego de dados de sondagem do satélite NOAA-19, nesta tese. Bem como expandir a utilização dos dados para outras regiões da Amazônia.

Após o mecanismo de validação local dos dados de sondagem do satélite NOAA, deu-se o emprego à utilização de dados de sondagem atmosférica por satélite para reconhecer padrões atmosféricos relacionados as ocorrências de raios. Destaca-se, novamente, que a característica de originalidades deste estudo científico, se baseia, principalmente em adotar dados de sondagem atmosférica por satélite para prever descargas atmosféricas na região amazônica. Propondo assim, uma nova abordagem de previsão de raios, contribuindo com estudos de previsões de raios em regiões que não dispõem de EMA, principalmente na região amazônica, onde há uma enorme carência destas estações.

Este capítulo descreve inicialmente a área de obtenção dos dados de sondagens através do NOAA-19, realizando-se em seguida uma descrição dos dados para a área de estudo. Apresenta-se, também, o processo de tratamento dos dados realizado através da análise de componentes principais e normalização. Essas etapas iniciais de pré-processamento, descrição geral, foram empregadas em duas abordagens de predição de descargas atmosféricas.

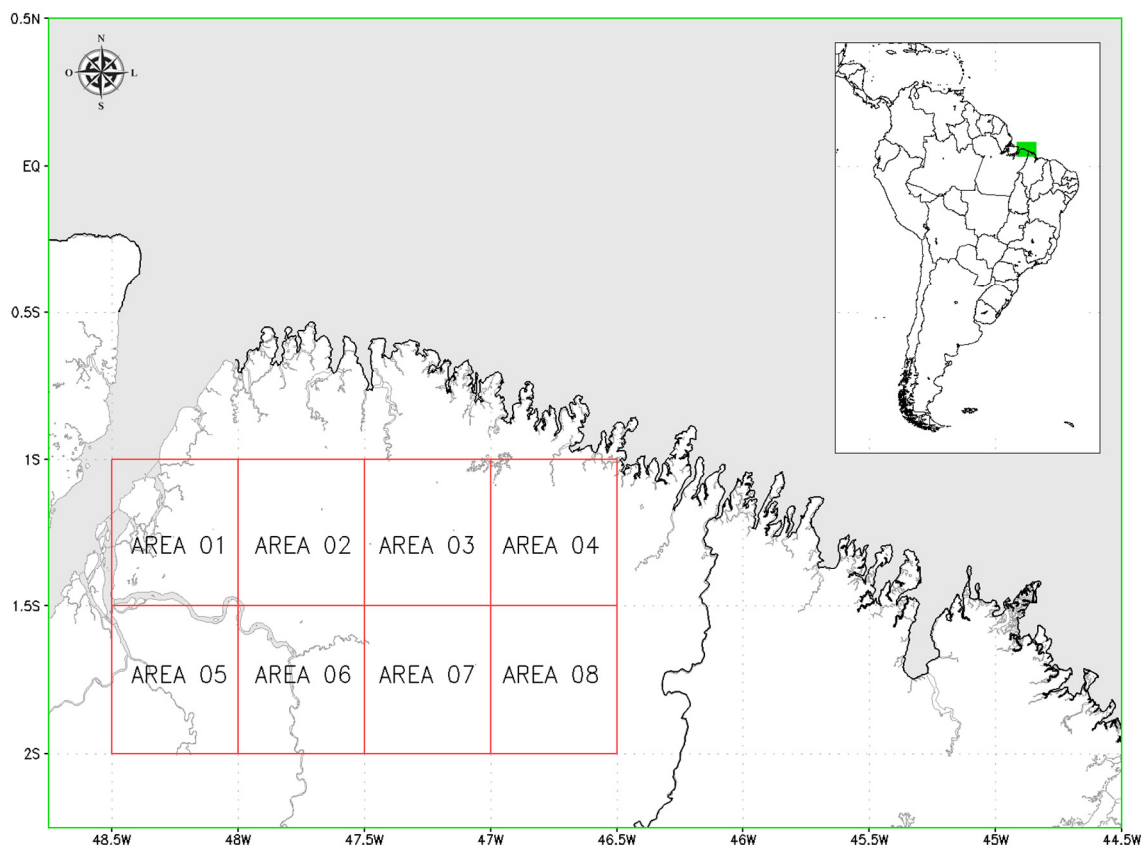
Todas as abordagens utilizaram RNA como técnica preditora, sendo uma descrita, conforme em Alves et al. (2017), na Seção 6.6. Uma outra abordagem de predição de descargas atmosféricas (Seção 6.7), também, é apresentada, diferenciando-se de Alves et al. (2015), pela forma como os dados são apresentados a RNA e pelo aumento da base de dados para simulação.

6.2 ÁREA DE ESTUDO

O estado do Pará é uma região extremamente grande territorialmente. Assim, a região de estudo de emprego desta metodologia de previsão de raios, compreende a seleção de oito áreas localizadas no nordeste do estado do Pará, no Brasil, conforme ilustrado na Figura 61, abrangendo as latitudes 01° S e 02° S e longitudes de 046,5° W e 048,5° W.

O estudo englobou uma área total de 24.961,861 km². Dentre as oito áreas selecionadas para aplicação da metodologia destinada à previsão de raios, apenas em um ponto (Belém), situado na área 01, ocorre sondagem convencional regular, caracterizando as demais áreas como região sem cobertura. Além disto, esta área de estudo apresenta elevados índices de incidência de descargas atmosféricas (PINTO; PINTO JUNIOR, 2003).

Figura 61 - Área de estudo.



Fonte: Autor

6.3 DESCRIÇÃO DOS DADOS

Para todas as oito áreas, exibidas na Figura 61, foram obtidas as coordenadas geográficas de centroide, conforme mostrado na Tabela 7. Um centroide corresponde as coordenadas de centro de cada área de estudo. Essas localizações geográficas serviram de referência para coleta dos dados de sondagem por satélite na estação do SIPAM CR-BE. Assim, para cada centroide de área foram obtidas medidas de sondagens. Com isso, para cada dia, foram obtidas 8 medidas de sondagens para as coordenadas geográficas mostradas na Tabela 7.

Tabela 7 - Coordenadas geográficas dos centroides de cada área.

| Área | Coordenadas geográficas | |
|------|-------------------------|-----------|
| | Latitude | Longitude |
| A1 | 01,25°S | 048,25°W |
| A2 | 01,25°S | 047,75°W |
| A3 | 01,25°S | 047,25°W |
| A4 | 01,25°S | 046,75°W |


| | | |
|----|---------|----------|
| A5 | 01,75°S | 048,25°W |
| A6 | 01,75°S | 047,75°W |
| A7 | 01,75°S | 047,25°W |
| A8 | 01,75°S | 046,75°W |

Para este estudo, foram utilizados os dados de sondagem do satélite NOAA-19, manipulados através do software TERASCAN[®] e dados coletados do número de eventos de descargas atmosféricas, disponíveis no website da rede de detecção de descargas atmosféricas a longa distância (Sferic Timing and Ranging Network – STARNET).

Os parâmetros atmosféricos obtidos foi temperatura do ar e temperatura de ponto de orvalho em 30 níveis de pressão atmosférica em cada centroide de área, conforme Figura 62 (temperatura do ar em vermelho e temperatura do ponto de orvalho em azul), que mostra uma sondagem realizada para a área 01, no dia 13 de junho de 2014.

Esta tese se destaca, primeiramente, por usar apenas essas duas variáveis meteorológicas, oriundas de sondagens satelitais, e não de radiossondagens regulares. Segundo, a partir dessas duas variáveis são obtidos diretamente ou indiretamente valores dos índices de instabilidade atmosféricos, como exemplo: CAPE, CINE, K e TT, como podem ser vistos ao lado direito do diagrama Skew-T Log-P (Figura 62).

Figura 62 - Diagrama Skew-T Log-P mostrando o perfil vertical da temperatura do ar (linha em vermelho) e temperatura do ponto de orvalho (linha azul). Índices de instabilidade atmosférica: K (Índice K), TT (Índice Total Totals), APrec (Água Precipitável), CAPE.

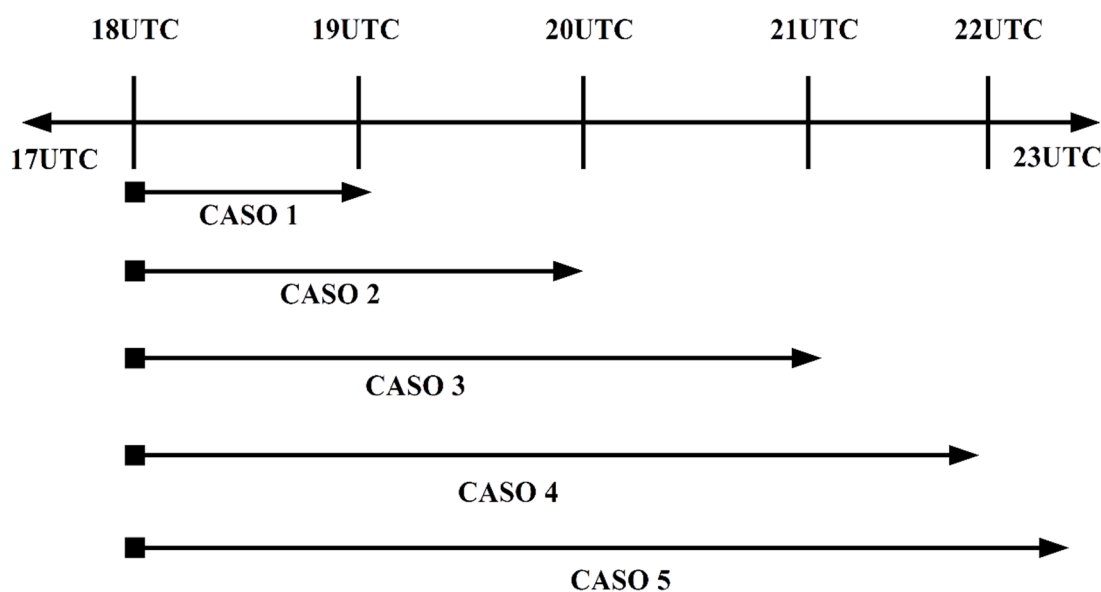


Fonte: Autor

O horário de referência para obtenção dos dados de satélite foi às 17UTC. Assim, apenas sondagens realizadas às 14h00 no horário local foram utilizadas, devido ao interesse de realizar as previsões pelos horários da tarde e noite. Esses horários reúnem as condições atmosféricas mais propícias para o surgimento de nuvens Cb. Os horários de incidência de raios foram limitados de 18:00 UTC às 23:00UTC (15h00 às 20h00).

Neste sentido, a previsão foi realizada com uma hora de antecedência, em relação ao horário de 18UTC, considerando-se cinco casos de período de validade para os modelos de previsões, conforme mostrado na Figura 63. Os casos considerados de previsão são: caso 1 (uma hora), caso 2 (duas horas), caso 3 (três horas), caso 4 (quatro horas) e o caso 5 (5 horas), sendo que estes períodos de tempos são cumulativos, isto é, cada caso posterior acumula o período de tempo do caso anterior. Assim, o caso 2 engloba o caso 1, o caso 3 engloba os casos 1 e 2, o caso 4 engloba os casos 1, 2 e 3, o caso 5 engloba os casos 1, 2, 3, e 4.

Figura 63 - Casos de previsão de raios.



Fonte: Autor

O estudo busca avaliar, principalmente, se as condições de estabilidade atmosférica em função do perfil vertical de temperatura do ambiente (temperatura do ar e temperatura do ponto de orvalho) obtidas por meio de sondagem do satélite NOAA-19, estarão ou não propícias para a ocorrência de tempestades de raios para os casos analisados na Figura 63.

6.4 SELEÇÃO DOS DADOS

Como existe uma relação monotônica entre pressão e altura em cada coluna vertical da atmosfera, usualmente a meteorologia utiliza a pressão como coordenada vertical para simplificar as equações utilizadas na solução dos problemas da termodinâmica. Para um ponto situado em uma determinada altura, quanto maior o valor da coordenada de pressão, mais próximo da superfície encontra-se o ponto. Neste caso, a unidade normalmente aplicada para pressão atmosférica é o hecto pascal (hPa).

Os parâmetros atmosféricos obtidos a partir da sondagem do NOAA-19, temperatura do ar e temperatura do ponto de orvalho, referem-se aos seguintes níveis de pressão atmosférica: 10 hPa, 15 hPa, 20 hPa, 25 hPa, 30 hPa, 50 hPa, 60 hPa, 70 hPa, 85 hPa, 100 hPa, 115 hPa, 135 hPa, 150 hPa, 200 hPa, 250 hPa, 300 hPa, 350 hPa, 400 hPa, 430 hPa, 475 hPa, 500 hPa, 570 hPa, 620 hPa, 670 hPa, 700 hPa, 780 hPa, 850 hPa, 920hPa, 950hPa e 1000hPa. Resultando ao todo em 60 níveis de pressão atmosférica, sendo 30 níveis para temperatura do ar e outros 30 para a temperatura do ponto de orvalho.

Os referidos níveis de pressão passaram por um processo de redução de variáveis através de análise de componentes principais, com menor perda possível de informação. De acordo com Faceli et al. (2015) a análise de componentes principais (PCA, do inglês – *Principal Component Analysis*) é uma técnica que correlaciona estatisticamente dados, promovendo uma redução da dimensionalidade dos dados originais, a partir da eliminação de redundâncias. O objetivo dessa técnica é encontrar combinações lineares, de p variáveis aleatórias X_1, X_2, \dots, X_p , denominadas de componentes principais Z_1, Z_2, \dots, Z_n .

Cada componente principal será resultante de parcelas proporcionais das p variáveis aleatórias. A equação 6.1 descreve as componentes principais.

$$Z_i = \sum_{j=1}^p a_{ij}X_j = a_{i1}X_1 + a_{i2}X_2 + \dots + a_{ip}X_p \quad (6.1)$$

Onde:

i = índice da componente principal;

j = índice da variável aleatória, sendo $j = 1, 2, \dots, p$;


Z_i = componente principal i ;

a_{ij} = constante relativa a variável aleatória j e componente principal i ;

X_j = variável aleatória j .


As Figuras 64 e 65 mostram, respectivamente as características das distribuições de variabilidades dos dados de temperatura do ar e ponto do orvalho para os 30 níveis de pressão atmosférica. Para a camada compreendida entre 850 hPa e 150 hPa, houve baixa dispersão quanto aos dados de temperatura do ar, enquanto a temperatura do ponto de orvalho apresentou menor dispersão para os níveis mais elevados da atmosfera, entre 135 hPa e 10 hPa.

Figura 64 - Variabilidade para temperatura do ar.



Fonte: Autor

Figura 65 - Variabilidade para temperatura do ponto de orvalho.



Fonte: Autor


Das 30 componentes principais relativas às variáveis de temperatura do ar, verificou-se que as três primeiras componentes representavam aproximadamente 78% da variância total explicada. Assim, os quinze diferentes níveis de pressão cuja variável temperatura do ar apresentou os melhores coeficientes na combinação linear das respectivas componentes principais foram: 10 hPa, 15 hPa, 20 hPa, 25 hPa, 30 hPa, 50 hPa, 60 hPa, 70 hPa, 85 hPa, 100 hPa, 115 hPa, 850 hPa, 920 hPa, 950 hPa e 1000 hPa. Em tais níveis de pressão houve maior variabilidade da temperatura do ar (Figura 64), sendo, portanto, definidos como variáveis de entrada (temperatura do ar) para o treinamento das RNA.

Enquanto das 30 componentes principais das variáveis da temperatura do ponto de orvalho, a primeira componente representou aproximadamente 81% da variância total explicada. Com isso, dezessete variáveis relacionadas à temperatura do ponto de orvalho apresentaram consideráveis valores numéricos dos respectivos coeficientes na combinação linear destes componentes principais, que foram: 150 hPa, 200 hPa, 250 hPa, 300 hPa, 350 hPa, 400 hPa, 430 hPa, 475 hPa, 500 hPa, 570 hPa, 620 hPa, 670 hPa, 700 hPa, 780 hPa, 850 hPa, 920 hPa e 1000 hPa que correspondem às variáveis de maior variabilidade, conforme


ilustrado na Figura 65. Portanto, estes níveis compuseram a variável de entrada temperatura do ponto de orvalho utilizada nos treinamentos das RNA.

As Figuras 66 e 67 mostram as variáveis explicadas pelas componentes principais para: temperatura do ar, até a nona componente principal e temperatura do ponto do orvalho, até a terceira componente principal.

Figura 66 - Componentes Principais: temperatura do ar.



Fonte: Autor

Figura 67 - Componentes Principais: temperatura do ponto de orvalho.

Fonte: Autor

6.5 NORMALIZAÇÃO DOS DADOS

Após o processo de seleção dos dados realizou-se a sua normalização, com o objetivo reduzir as discrepâncias entre os valores das variáveis de entrada. A Equação 6.2 descreve o método de normalização utilizado:

$$value_{normalized} = \frac{value_{original} - \min A}{\max A - \min A} \quad (6.2)$$

Essa normalização transformou os valores originais das variáveis de entrada em valores compreendidos no intervalo [0, 1].

6.6 PREVISÃO DE DESCARGAS ATMOSFÉRICAS PARA TODAS AS ÁREAS DE ESTUDO

Para esta abordagem, foram coletados dados de sondagem através do satélite NOAA-19, relativos aos meses de junho a dezembro de 2014, assim como também dados de eventos de raios. Dessa forma, resultando em 608 exemplos extraídos para o conjunto de dados. Esse valor corresponde ao total de dias válidos para as oito áreas de estudo. Outros dias não incluídos, deu-se ao não registro de medição de sondagem pelo NOAA-19, nas regiões de estudo. Para

todos os casos de estudo (Figura 63) foram desenvolvidos cinco modelos de RNA, através de vários testes de desempenhos para os cinco períodos distintos de validade.

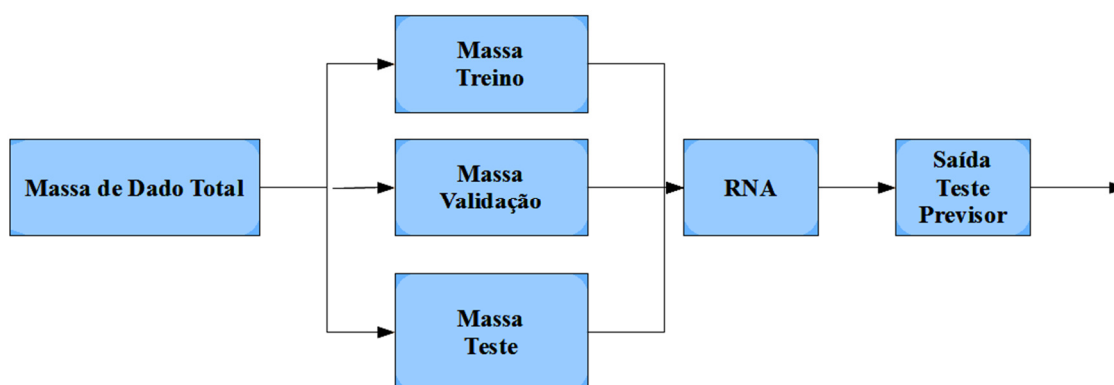
Os 608 exemplos de dados de sondagens foram divididos aleatoriamente, conforme Figura 68, em: dados de treinamento para modificação dos pesos da RNA e ajustes de acordo com seu erro; dados de validação para estimar a capacidade de generalização da RNA; e dados de teste para testar a generalização da RNA. Com isso, os resultados dos dados de testes foram utilizados como as acurácias globais dos modelos. As RNA foram treinadas com 426 padrões ($\approx 70\%$) e foram usados 91 padrões para validação ($\approx 15\%$) e 91 para teste ($\approx 15\%$). A Figura 68 pode ser resumida pelo seguinte algoritmo:

Entrada: uma massa de dados total é apresentada a RNA.

Saída: acurácia de predição.

1. Apresentação da massa total de dados;
2. Divisão da massa total de forma aleatória em: massa para treino, massa de validação e massa de teste;
3. Apresentação do conjunto de dados de treino à RNA;
4. Apresentação do conjunto de dados de validação à RNA ainda durante o treinamento;
5. Apresentação do conjunto de teste, após a RNA treinada e generalizada;
6. Obtenção dos acertos e erros de classificações da saída de teste do previsor;
7. A partir dos acertos e erros, obter a matriz de confusão da acurácia de predição.

Figura 68 - Divisão aleatória dos dados em treino, validação e teste.



Fonte: Autor

Em cada caso de previsão analisado, variou-se nos treinamentos das RNA, o número de neurônios na camada oculta, com o objetivo de avaliar os desempenhos das RNA para os períodos de validade das previsões analisadas.

As propriedades dos desenvolvimentos das RNA empregadas nesta proposta são resumidas na Tabela 8.


Tabela 8- Propriedades de desenvolvimento das RNA.

| Propriedades das RNA | Propriedades |
|--|---------------------|
| Algoritmo de treinamento | Levenberg-Marquardt |
| Função de transferência da camada oculta | Sigmóide |
| Função de transferência da camada de saída | Softmax |
| Número de neurônios na camada oculta | 1-30 |
| Taxa de momento | 0.001 |
| Padrões de treinamento | 426 |
| Padrões de validação | 91 |
| Padrões de teste | 91 |

6.4.1 MODELO DE TREINAMENTO DA REDE NEURAL

Dois tipos de dados foram utilizados nesta proposta, os dados meteorológicos selecionados (temperatura do ar e temperatura do ponto de orvalho) como entrada e dados históricos de raio como saída alvo, conforme Figura 69. Cada aplicação da rede neural utilizada nos cinco casos de estudos, recebe os dados de entrada, denotado por P, e de saída alvo como t.

Figura 69 - Modelo de treinamento da RNA.



Fonte: Autor

A característica da matriz de entrada da RNA é dada por:

$$P = [D, I, t]$$

Onde:

D = dados de temperatura do ar (° C)

I = dados de temperatura do ponto de orvalho (° C)

t = vetor histórico de raios.

A matriz D é dada por:

$$D = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \dots & \dots & \dots & \dots \\ x_{m1} & x_{m2} & \dots & x_{mn} \end{bmatrix}$$

Onde:

n = número de padrões de entrada.

m = número de variáveis de entrada da temperatura do ar (° C).

[m × n] é o tamanho da matriz D.

No caso da matriz D, tem-se [608 × 15], devido ao processo de redução de variáveis por meio da análise de componentes principais.

E a matriz I é dado por:

$$I = \begin{bmatrix} y_{11} & y_{12} & \dots & y_{1n} \\ y_{21} & y_{22} & \dots & y_{2n} \\ \dots & \dots & \dots & \dots \\ y_{m1} & y_{m2} & \dots & y_{mn} \end{bmatrix}$$

Onde:

n = número de padrões de entrada.

m = é o número de variáveis de entrada da temperatura do ponto de orvalho (° C).

[m × n] é o tamanho da matriz I.

No caso da matriz I, tem-se [608 × 17], devido ao processo de redução de variáveis por meio da análise de componentes principais.

A saída alvo, denotado por t, é dada pelo seguinte vetor:

$$t = \begin{bmatrix} c_1 \\ c_2 \\ \vdots \\ c_n \end{bmatrix}$$

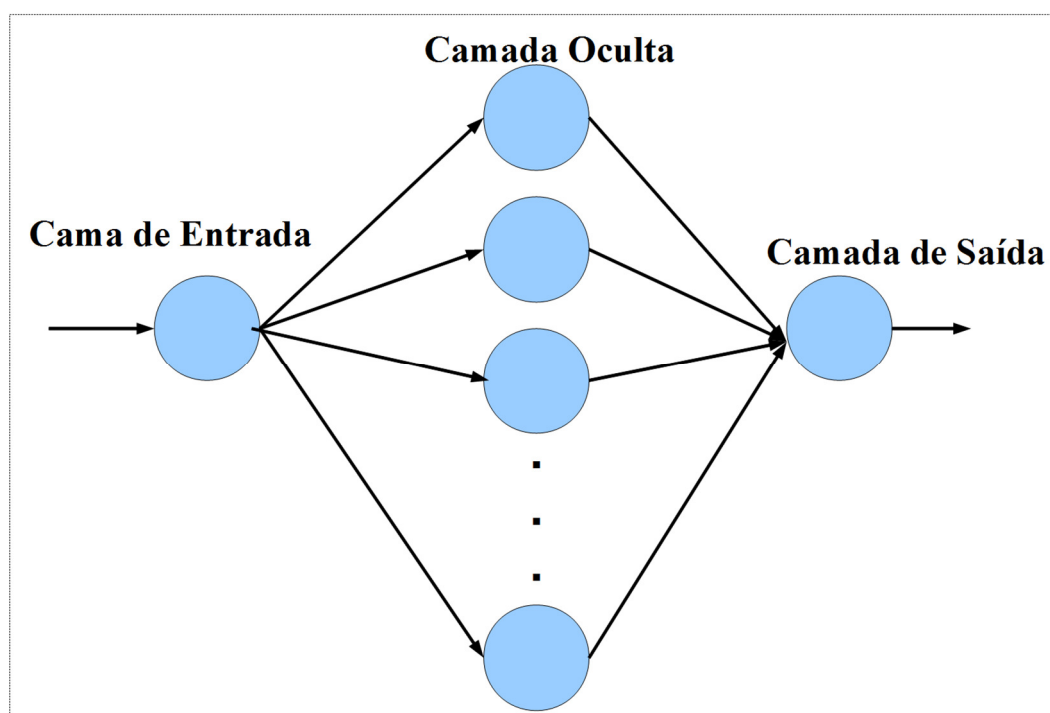
Onde

C_n é dado por “0” ou “1”. A matriz t tem-se [608 x 1].

Para cada caso de previsão, visualizado na Figura 63, adotou-se que: “0” corresponde a não ocorrência de raio e “1” como houve raio. Neste sentido, utilizou-se RNA para reconhecimento de padrões para classificar os atributos preditivos de treinamento de cinco RNA, em um conjunto de duas categorias: não ocorrência de raio ou ocorrência de raio.

Uma técnica de classificação pode ser utilizada como uma modelagem preditiva, quando um classificador é utilizado para identificar a que classe pertence um novo exemplo (TAN et al., 2005). A Figura 70 exhibe o esquema do modelo de RNA utilizada para prever os eventos meteorológicos deste estudo.

Figura 70 - Modelo da RNA.



Fonte: Autor

O modelo adotado consistiu em uma RNA *feed-forward* com três camadas: a primeira sendo a camada de entrada (vetor P de entrada); a segunda é uma camada oculta (dada pelos números de neurônios ocultos); e terceira é a camada de saída que representa a saída do predictor de raios (0 ou 1). Foi utilizada a função de ativação sigmóide na camada oculta, exibida na Equação 6.2. A natureza não linear da função sigmoide é essencial para o desempenho da RNA que deve representar as características não lineares presentes no conjunto de dados de entrada.

$$f(z) = \frac{1}{1 + e^{-z}} \quad (6.2)$$

A função de ativação da camada de saída utilizada foi a função softmax, exibida na Equação 6.3. Esta função de ativação é implementada na camada de saída da RNA com a finalidade de classificar os padrões preditivos.

$$f(z) = \frac{e^{(z_i)}}{\sum_{m=1}^k e^{(z_m)}} \quad (6.3)$$

Onde k representa o número de classes da camada de saída.

O treinamento da RNA foi realizado através do algoritmo Levenberg-Marquardt *backpropagation* que permite um treinamento mais rápido para uma RNA *feed-forward* em comparação a outros métodos de treinamento (FUN; HAGAN, 1996).

6.4.2 MÉTRICAS DE AVALIAÇÃO E VALIDAÇÃO DOS CASOS DE PREVISÃO DE RAIOS

A avaliação de desempenho dos melhores modelos de RNA, para os todos casos de estudo, consistiu na obtenção das matrizes de confusão. Assim, os resultados foram apresentados em matrizes de confusão para avaliar a taxa de acerto dos classificadores (acurácia).

As análises dos resultados também foram feitas através das curvas do gráfico ROC (Curvas de Características de Operação do Receptor). O gráfico ROC permitiu visualizar o desempenho dos classificadores. Outra forma de avaliação utilizada foi a obtenção das áreas sobre a curva (AUC) do gráfico ROC. Desse modo, obtiveram-se AUC em cada caso de estudo para confirmar a precisão dos resultados obtidos.

Com a tentativa de evitar o *overfitting* da RNA, ou seja, uma má generalização da RNA através da incorporação de ruídos presentes nos dados de entrada, utilizou-se três conjuntos de dados, sendo treinamento, validação e teste, para ajustar os melhores modelos de previsões. Então, o critério de parada da RNA consistiu em evitar que a RNA pudesse se ajustar excessivamente ao conjunto de treinamento e validação, através da utilização de um conjunto de dados de teste.

Este método proposto de previsão de descargas atmosféricas foi validado, através da comparação com metodologias tradicionais estabelecidas de previsão de descargas atmosféricas. Nesse sentido, um dos principais métodos estabelecidos de previsão de descargas atmosféricas é o uso de índices de instabilidade atmosférica. Estes indicam o potencial para a formação de nuvens de tempestades (CB) que são as responsáveis pela formação das descargas atmosféricas. A utilização destes índices de instabilidade e parâmetros termodinâmicos se

baseia em estudos que demonstram uma relação entre tempestades severas e formação de descargas atmosféricas (MACGORMAN; RUST, 1998).

A validação desta proposta foi realizada, individualmente, para as oito áreas de estudo. Para cada área obtiveram-se os valores dos índices de instabilidade: Índice K (IK), Índice Total Totals (ITT) e CAPE, correspondentes aos dados utilizados nesta proposta de estudo. Sendo assim, realizando-se uma validação comparativa na mesma data e horário entre o modelo proposto (MP) e os métodos tradicionais.

Foi avaliado se os valores dos índices obtidos levaram a ocorrência ou não de tempestades com raios nos cinco casos de estudos de previsões realizados, em cada área. Essas comparações dos valores dos índices foram feitas através da base de dados de raios da STARNET (MORALES et al., 2011). Então, avaliou-se acurácia de acerto (%) do IK, ITT e CAPE. As Figuras 71, 72, 73, 74, 75, 76, 77 e 78 mostram o comportamento do índice IK para as áreas 1, 2, 3, 4, 5, 6, 7 e 8, respectivamente, ver apêndice A.

As Figuras 79, 80, 81, 82, 83, 84, 85 e 86 mostram o comportamento do Índice Total Totals (ITT) para as áreas 1, 2, 3, 4, 5, 6, 7 e 8, respectivamente, ver apêndice B. Enquanto as Figuras 87, 88, 89, 90, 91, 92, 93 e 94 mostram o comportamento da CAPE para as áreas 1, 2, 3, 4, 5, 6, 7 e 8, respectivamente, ver apêndice C

Para cada índice de instabilidade (IK, ITT e CAPE) calculado a partir dos dados de sondagem do NOAA-19, para todas as oito áreas de estudo. Foram adotados os seguintes valores limítrofes, como sendo condições favoráveis à ocorrência de tempestades com raios:

- $IK = 31$;
- $ITT = 48$;
- $CAPE = 2500$.

Esses valores adotados para a região amazônica foram baseados na referência literária de cada índice. As Figuras 95, 96 e 97 mostram, como exemplo, apenas para as áreas 7, 5 e 1, o comportamento dos índices K, ITT e CAPE, com os valores limites para cada um dos índices de instabilidade. Assim, a linha em vermelho corresponde ao valor mínimo necessário para ocorrência de tempestades. Esse valor mínimo de tempestades foi denotado como “1” para ocorrência e “0” para não ocorrência.

Figura 71 - Comportamento do Índice K e valor limite (linha em vermelho) para ocorrência ou não de tempestades de raios.




Figura 72 - Comportamento do Índice Total Totals e valor limite (linha em vermelho) para ocorrência ou não de tempestades de raios.


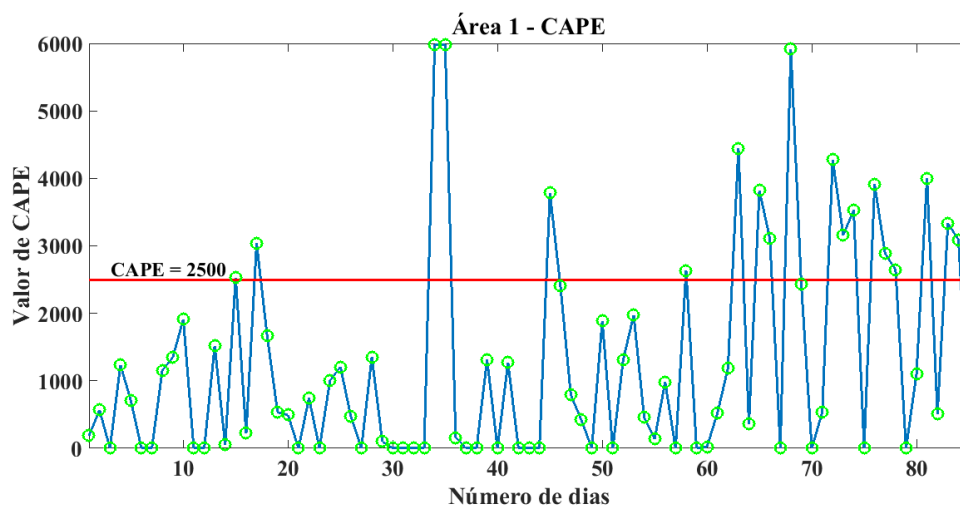


Figura 73 - Comportamento da CAPE e valor limite (linha em vermelho) para ocorrência ou não de tempestades de raios.



Fonte: Autor

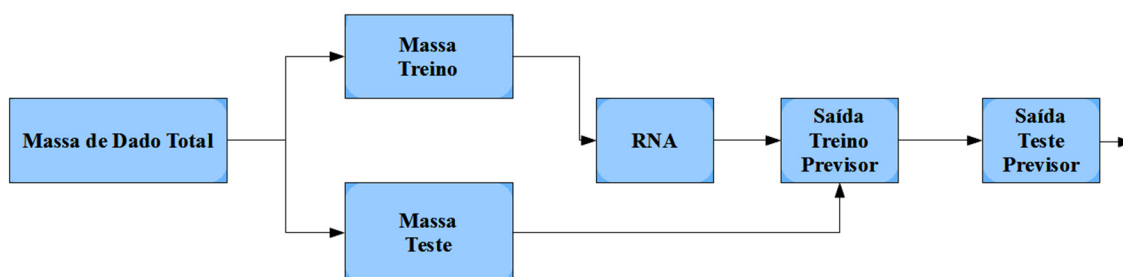
Os resultados obtidos com o algoritmo Levenberg-Marquardt *backpropagation* (trainlm) foram comparados com outros dois algoritmos de treinamento testados: *Scaled Conjugate Gradient backpropagation* (traincsg) e *Gradient Descent backpropagation* (traingd).

6.7 PREVISÃO DE DESCARGAS ATMÓSFERICAS POR ÁREA DE ESTUDO

Esta abordagem de previsores de raios se caracteriza, principalmente, por:

1. Aumento da base de dados de sondagem atmosférica por satélite, em comparação com massa de dados de junho a dezembro de 2014 (608 padrões), exposta na Seção 6.6, onde para as oito áreas de estudo, foram incluídas sondagens dos meses de janeiro, fevereiro, março e abril de 2015. Assim, obtendo-se uma nova massa de dados de perfis verticais de temperatura (temperatura do ar e temperatura do ponto de orvalho). Além, da inclusão de novos dados de raios reprocessados pela STARNET, para o mesmo período de 2015, isto é, totalizando 880 padrões (dias válidos), excluindo-se os dias sem sondagem por satélite.
2. Separação não aleatória de uma massa de dados para treinamento e outra para teste, a partir da massa de dados total (Figura 98). Logo, para os 880 padrões, 704 padrões ($\approx 80\%$) foram escolhidos para treinar e outros 176 padrões ($\approx 20\%$) foram apresentados a RNA depois de treinada para teste. A apresentação de uma massa de teste não aleatória, desconhecida pela RNA, consistiu em avaliar os valores preditos de raios em relação às situações reais de ocorrência (“1”) ou não ocorrência (“0”). Assim, compondo a validação do modelo.

Figura 74 - Divisão não aleatória em dados de treino e validação.



Fonte: Autor

- Essa abordagem foi realizada por área de estudo. Logo foram realizadas previsões para cada área, individualmente.

A Figura 98 pode ser resumida pelo seguinte algoritmo:

Entrada: uma massa de dados total é apresentada a RNA.

Saída: acurácia de predição.

- Apresentação da massa total de dados;
- Divisão da massa total de forma não aleatória em: massa para treino e massa de teste;
- Apresentação do conjunto de dados de treino à RNA;
- Apresentação do conjunto de teste, após a RNA treinada;
- Obtenção dos acertos e erros de classificações da saída de teste do previsor;
- A partir dos acertos e erros, obter a matriz de confusão da acurácia de predição.

A Tabela 9 ilustra, como exemplo, as situações possíveis que podem acontecer entre uma situação real (observado) e o valor de saída do teste da RNA (previsto) após ser treinada, em cada área de estudo.

Tabela 9 - Cenários de previsões por áreas de estudo em relação as situações observadas.

| | DATA | | | | | | | |
|----------|--------|--------|--------|--------|--------|--------|--------|--------|
| | Área 1 | Área 2 | Área 3 | Área 4 | Área 5 | Área 6 | Área 7 | Área 8 |
| Real | 0 | 0 | 1 | 1 | 1 | 1 | 0 | 0 |
| Previsto | 0 | 0 | 0 | 0 | 1 | 1 | 1 | 1 |

Pela Tabela 9 quatro situações são possíveis:

- **Situação 1:** quando o valor observado não registrou ocorrência de raio e o valor previsto também não registrou a ocorrência, observa-se essa situação nas Áreas 1 e 2;

- **Situação 2:** Quando o valor observado registrou a ocorrência de raio e o valor predito não registrou a ocorrência, observa-se essa situação nas Áreas 3 e 4.
- **Situação 3:** Quando o valor observado registrou a ocorrência de raio e o valor predito também registrou a ocorrência, observa-se essa situação nas Áreas 5 e 6.
- **Situação 4:** Quando o valor observado não registrou a ocorrência de raio e o valor predito registrou a ocorrência de raios, observa-se essa situação nas Áreas (7 e 8).

Das quatro situações listadas acima, as situações 1 e 3 são consideradas satisfatórias, pois, caracterizam cenários reais no qual a RNA conseguiu prever corretamente as possibilidades de ocorrência ou não de raios. As situações 2 e 5 caracterizam situações não satisfatórias, ou seja, a RNA não conseguiu prever adequadamente as ocasiões 0 e 1.

Para a construção deste preditor de descargas atmosféricas foram adotados os seguintes parâmetros:

- Aplicado no caso 5 de estudo (5 horas);
- Utilizou-se os mesmos níveis de pressão atmosférica que foram selecionados através da análise de componentes principais para temperatura do ar e temperatura do ponto de orvalho, processo descrito na seção 6.4, resultando em [880 x 15] para temperatura do ar e [880 x 17] para temperatura do ponto de orvalho, sendo o vetor histórico de raios de tamanho [880 x 1];
- Normalização dos dados (seção 6.5);
- Modelo de treinamento da Figura 69;
- Propriedades para o desenvolvimento da RNA (Tabela 8), com exceção dos padrões de treinamento, validação e teste
- Modelo da RNA da Figura 70.

O modelo de predição satisfatório foi obtido variando-se o número de neurônios ocultos na camada intermediária. Os resultados foram avaliados por uma matriz de confusão dos dados de teste da RNA.

6.8 CONSIDERAÇÕES FINAIS

Neste capítulo mostrou-se a descrição detalhada do método científico empregado no desenvolvimento desta tese. Assim, no capítulo 7, serão exibidos os resultados obtidos através do emprego deste método científico que levou a alcançar o objetivo principal desta tese.

CAPÍTULO VII

7 RESULTADOS

7.1 INTRODUÇÃO

Este capítulo apresenta os resultados obtidos através da nova metodologia de previsão de descargas atmosféricas para a região amazônica, no qual foram utilizados dados de sondagem atmosférica do satélite NOAA-19 e dados históricos de raios da STARNET, conjuntamente com emprego de RNA. Inicialmente, apresentam-se os resultados obtidos com a abordagem de predição de descargas atmosféricas para todas as áreas de estudo, também é exposto o mecanismo de validação desta proposta, através de indicadores de instabilidade atmosférica que foram calculados a partir dos dados do satélite NOAA-19. Em seguida, apresenta-se a outra abordagem de predição de descargas atmosféricas obtida por área de estudo. Essa abordagem consiste em apenas realizar o treinamento da RNA, em separado, para posteriormente apresentar-lhe um conjunto de dados de teste e avaliar a sua eficiência de predição para dados reais de teste, realizando assim também a validação do modelo de predição.

7.2 RESULTADOS DA PREVISÃO DE DESCARGAS ATMÓSFERICAS PARA TODAS AS ÁREAS DE ESTUDO

Foram realizados diversos testes para encontrar a quantidade de neurônios ocultos que representassem o melhor modelo de predição de descargas atmosféricas para cada caso de estudo. As configurações avaliadas foram de 1-30 neurônios ocultos na camada intermediária.

A Tabela 10 apresenta a melhor topologia de NNO (número de neurônios ocultos na camada escondida) obtida para cada RNA, nos cinco casos analisados nesta proposta de previsão de raio. Ressalta-se que foi considerado como resultado satisfatório de predição, o valor da acurácia da matriz de confusão de teste obtida pela RNA, em cada caso.

Tabela 10 - Resultados obtidos para os casos 1, 2, 3 4 e 5.

| | NNO | ACURÁCIA (%) |
|---------------|------------|---------------------|
| Caso 1 | 28 | 72,5 |
| Caso 2 | 1 | 75,8 |
| Caso 3 | 11 | 74,7 |
| Caso 4 | 16 | 86,8 |
| Caso 5 | 21 | 95,6 |

Fonte: Autor

A Tabela 10 mostra a acurácia global de teste da RNA para cada caso de predição alcançada por todas as configurações possíveis do número de neurônios ocultos na camada intermediária. Percebe-se que o caso 5 foi o que apresentou a melhor acurácia de teste (%) em relação a todos os outros casos e o caso 1 apresentou menor acurácia de teste (%). Assim as melhores taxas de acurácia de teste (%) foram, respectivamente para caso 5, caso 4, caso 2, caso 3 e caso 5: 95,6% com 21 neurônios ocultos, 86,8% com 16 neurônios ocultos, 75,8% com 1 neurônio oculto, 74,7% com 11 neurônios ocultos e 72,5% com 20 neurônios ocultos. Assim, verifica-se que alguns casos foram necessários mais NNO para se alcançar uma acurácia preditiva acima de 70%, como no caso 1, e outros foram necessários uma quantidade mínima de NNO, como no caso 2.

Nota-se, também, pela Tabela 10 que o caso 1, 2 e 3 apresentaram resultados preditivos próximos, enquanto o caso 4 e 5 houve maior crescimento da acurácia de predição. Portanto, pelos resultados das acurácias dos casos 4 e 5, compreende-se que a RNA com o aumento do tempo da janela de previsão, isto é, 4 e 5 horas, foi progressivamente melhorando seu desempenho, obtendo assim o melhor resultado no caso 5. Dessa forma, a RNA conseguiu um melhor reconhecimento de padrões de tempestades de raios nesse caso.

A Tabela 11 exhibe a matriz de confusão de teste obtida neste estudo, a partir dos resultados da Tabela 10. A classe positiva (+) e negativa (-) desta matriz de confusão correspondem, respectivamente: 0 (ausência de raio) e 1 (houve raio). Assim, 0 representa uma condição de tempo “bom” e 1 representa uma condição de tempo “ruim”.

Tabela 11 - Matrix de confusão e acurácia.

| | CASO 1 | | CASO 2 | | CASO 3 | |
|----------|-------------------------|----------|-------------------------|----------|-------------------------|----------|
| | 0 | 1 | 0 | 1 | 0 | 1 |
| 0 | 52,7% | 16,5% | 46,2% | 14,3% | 54,9% | 17,6% |
| 1 | 11% | 19,8% | 9,9% | 29,7% | 7,7% | 19,8% |
| | Acurácia (72,5%) | | Acurácia (75,8%) | | Acurácia (74,7%) | |
| | CASO 4 | | CASO 5 | | | |
| 0 | 79,1% | 6,6% | 92,3% | 3,3% | | |
| 1 | 6,6% | 7,7% | 1,1% | 3,3% | | |
| | Acurácia (86,8%) | | Acurácia (95,6%) | | | |


Fonte: Autor

No caso 1, a RNA obteve uma boa distribuição das taxas de VP=52,7% e VN=19,8%. Entretanto, obteve altas taxas de FP=11% e FN=16,5%, resultando assim na menor acurácia global de teste (72,5%) deste estudo. O caso 2 apresentou taxas satisfatórias de VP=46,2% e VN=29,7%, e menores taxas de FP=9,9% e FN=14,3%, em relação ao caso 1, resultando, com isso, no aumento de sua acurácia (75,8%) de teste da RNA. O caso 3, assim como o caso 1 e 2, obtiveram-se boas distribuições das taxas de VP=54,9% e VN=19,8%, uma baixa taxa FP=7,7% em relação ao caso 1, mas apresentou uma maior taxa de FN=17,6%, assim resultando na quarta melhor acurácia (74,7%) de teste da RNA.

Pelo caso 4 e caso 5 enfatiza-se, novamente, uma melhora do modelo de predição com o aumento do tempo de predição, havendo assim um melhor relacionamento entre os perfis verticais de temperatura com a ocorrência ou não de raios. Em ambos os casos, houve poucas classes classificadas erroneamente, no caso 4, as taxas de FP e FN foram, respectivamente: 6,6% e 6,6%, enquanto no caso 5, essas taxas foram ainda menores, sendo: FP=1,1% e FN=3,3%. Com isso, o caso 5 foi o que apresentou o melhor resultado de predição de descargas atmosféricas baseada em perfis verticais de temperatura provenientes do satélite NOAA-19.

A Figura 99 apresenta o gráfico ROC comparativo dos melhores resultados obtidos pela RNA, na tarefa de previsão de descargas atmosféricas, nos casos 1, 2, 3, 4 e 5, conforme visualizado na Tabela 11. Pela Figura 99, observa-se que todos os classificadores apresentaram resultados melhores em comparação ao pior classificador que realiza predições aleatórias (linha em cinza). Qualquer classificador abaixo dessa linha então é considerado pior que o aleatório.

Figura 75 - Gráfico ROC para os melhores resultados dos casos 1, 2, 3, 4 e 5.



Fonte: Autor

Pela Figura 99 nota-se que o caso 5 foi o que apresentou maior taxa de verdadeiros positivos e menor taxa de falsos positivos, estando bem próximo ao eixo Y (lado esquerdo), isto é, mais próximo ao ponto (0,1), indicando que este teve o melhor desempenho dentre todos os outros casos, conforme observado na Tabela 11. Os casos 1, 2 e 3 apresentaram curvas próximas. Enquanto o caso 4 apresentou melhor precisão em relação aos casos 1, 2 e 3, pois, sua curva ficou acima e à esquerda das curvas destes três casos.

Percebe-se pela Figura 99, que em alguns pontos as curvas de cada caso se interceptam, neste caso pode haver regiões em que um caso possa se melhor que o outro. Dessa forma, comparou-se, também, o desempenho de cada classificador em termos de uma única medida extraída de cada curva, a área abaixo da curva (AUC) ROC. A Tabela 12 exhibe os valores pontuais da AUC obtida nos casos estudados.

Tabela 12 - Resultados da AUC obtida a partir da ROC.

| | CASO 1 | CASO 2 | CASO 3 | CASO 4 | CASO 5 |
|------------|---------------|---------------|---------------|---------------|---------------|
| AUC | 0,794 | 0,813 | 0,793 | 0,864 | 0,871 |

Fonte: Autor

A Tabela 12 mostra que todos os casos tiveram valores de AUC bem superiores ao valor 0,5. O valor de AUC = 0,5 corresponde a incapacidade do classificador em prever ou não prever descargas atmosféricas. Portanto, em todos os casos foram obtidos resultados de AUC considerados satisfatórios. O caso 5 apresentou maior valor de AUC = 0,871 (mais próximo de 1) e, confirmando que este apresentou o melhor desempenho dentre todos os casos analisados. O caso 4 apresentou AUC=0,864, reforçando ser o classificador que obteve o segundo melhor desempenho de predição, seguindo pelo caso 2 que apresentou AUC=0,813. O caso 1, embora tenha apresentado uma menor acurácia (72,5%) de predição em relação ao caso 3 (74,75%), mas apresentou um pequeno aumento de AUC, comparado ao caso 2. Nesse caso, pode-se considerar que não houve diferenças significativas de desempenho entre eles.

Portanto, dos cinco casos aplicados neste estudo, o caso 5 foi de fato o modelo de previsão que melhor se ajustou às condições atmosféricas locais. Isso não exclui a impossibilidade de utilização dos demais modelos, porém, estes apresentam uma menor confiabilidade em seus resultados. Os resultados corroboram quanto à importância da utilização de dados de sondagem por satélite para previsão de descargas atmosféricas na região Amazônica. Dessa forma, pode-se considerar que a maior eficiência de previsão de raio obtida é de um período de validade de tempo de 5 horas, enquanto as piores eficiências seriam de 1 hora e 3 horas.


7.2.1 VALIDAÇÃO DA PROPOSTA

Nesta seção serão mostrados os resultados comparativos entre a metodologia proposta (MP) e os índices de instabilidade: CAPE, KI e ITT, calculados para cada área. Os valores destes índices compõem a metodologia tradicional (MT) de previsão de descargas atmosféricas. Ressalta-se que o modelo geral proposto em cada caso de estudo, pode ser empregado em cada área de estudo, ou seja, é válido em todas as áreas. Isso decorre da composição do modelo geral de previsão de cada caso, ter considerado as condições atmosféricas individuais de cada área de estudo.

7.2.1.1 Área 1


As Figuras 100, 101, 102, 103 e 104 mostram as acurácias obtidas pelos índices de instabilidade CAPE, IK, ITT e pelo modelo proposto, respectivamente para os casos 1, 2, 3, 4 e 5, considerando a área 1 de estudo. Dentre a metodologia tradicional, o ITT apresentou o melhor desempenho, tendo em média, uma acurácia de 59,20%, enquanto o IK e CAPE tiveram, respectivamente, as acurácias médias de 56,06% e 55,26%. Comparando as acurácias individuais obtidas pela metodologia tradicional e a metodologia proposta para cada caso de estudo, na área 1, nota-se que em todos os casos analisados, o modelo proposto apresentou melhor resultado. Assim, validando a proposta para a área 1.

Figura 76 - Comparação entre as acurácias de predição entre MP e MT para Caso 1 aplicado na Área 1.




Fonte: Autor

Figura 77 - Comparação entre as acurácias de predição entre MP e MT para Caso 2 aplicado na Área 1.




Fonte: Autor

Figura 78 - Comparação entre as acurácias de predição entre MP e MT para Caso 3 aplicado na Área 1.




Fonte: Autor

Figura 79 - Comparação entre as acurácias de predição entre MP e MT para Caso 4 aplicado na Área 1.



Fonte: Autor

Figura 80 - Comparação entre as acurácias de predição entre MP e MT para Caso 5 aplicado na Área 1.




Fonte: Autor

7.2.1.2 Área 2


As Figuras 105, 106, 107, 108 e 109 mostram as acurácias obtidas pelos índices de instabilidade CAPE, IK, ITT e pelo modelo proposto, respectivamente para os casos 1, 2, 3, 4 e 5, considerando a área 2 de estudo. Dentre a metodologia tradicional, o ITT e IK apresentaram, aproximadamente, mesmo desempenho, tendo em média, acurácias de 60,27%, enquanto a CAPE teve uma acurácia média de 60%. Comparando as acurácias obtidas pela metodologia tradicional e a metodologia proposta em cada caso de estudo, na área 2, nota-se que em todos os casos analisados, o modelo proposto apresentou melhor resultado. Assim, validando a proposta para a área 2.

Figura 81 - Comparação entre as acurácias de predição entre MP e MT para Caso 1 aplicado na Área 2.




Fonte: Autor

Figura 82 - Comparação entre as acurácias de predição entre MP e MT para Caso 2 aplicado na Área 2.




Fonte: Autor

Figura 83 - Comparação entre as acurácias de predição entre MP e MT para Caso 3 aplicado na Área 2.




Fonte: Autor

Figura 84 - Comparação entre as acurácias de predição entre MP e MT para Caso 4 aplicado na Área 2.



Fonte: Autor

Figura 85 - Comparação entre as acurácias de predição entre MP e MT para Caso 5 aplicado na Área 2.




Fonte: Autor

7.2.1.3 Área 3


As Figuras 110, 111, 112, 113 e 114 mostram as acurácias obtidas pelos índices de instabilidade CAPE, IK, ITT e pelo modelo proposto, respectivamente para os casos 1, 2, 3, 4 e 5, considerando a área 3 de estudo. Dentre a metodologia tradicional, o IK apresentou o melhor desempenho, tendo em média, uma acurácia de 57,63%, enquanto o ITT e CAPE tiveram, respectivamente, as acurácias médias de 57,36% e 56,58%. Comparando as acurácias obtidas pela metodologia tradicional e a metodologia proposta em casa caso de estudo, na área 3, nota-se que em todos os casos analisados, o modelo proposto apresentou melhor resultado. Assim, validando a proposta para a área 3.

Figura 86 - Comparação entre as acurácias de predição entre MP e MT para Caso 1 aplicado na Área 3.




Fonte: Autor

Figura 87 - Comparação entre as acurácias de predição entre MP e MT para Caso 2 aplicado na Área 3.




Fonte: Autor

Figura 88 - Comparação entre as acurácias de predição entre MP e MT para Caso 3 aplicado na Área 3.




Fonte: Autor

Figura 89 - Comparação entre as acurácias de predição entre MP e MT para Caso 4 aplicado na Área 3.



Fonte: Autor

Figura 90 - Comparação entre as acurácias de predição entre MP e MT para Caso 5 aplicado na Área 3.




Fonte: Autor


7.2.1.4 Área 4

As Figuras 115, 116, 117, 118 e 119 mostram as acurácias obtidas pelos índices de instabilidade CAPE, IK, ITT e pelo modelo proposto, respectivamente para os casos 1, 2, 3, 4 e 5, considerando a área 4 de estudo. Dentre a metodologia tradicional, a CAPE apresentou o melhor desempenho, tendo em média, uma acurácia de 59,74%, enquanto IK e ITT tiveram, respectivamente, as acurácias médias de 59,47% e 58,42%. Comparando as acurácias obtidas pela metodologia tradicional e a metodologia proposta em cada caso de estudo, na área 4, nota-se que em todos os casos analisados, o modelo proposto apresentou melhor resultado. Assim, validando a proposta para a área 4.


Figura 91 - Comparação entre as acurácias de predição entre MP e MT para Caso 1 aplicado na Área 4.



Fonte: Autor


Figura 92 - Comparação entre as acurácias de predição entre MP e MT para Caso 2 aplicado na Área 4.

Fonte: Autor

Figura 93 - Comparação entre as acurácias de predição entre MP e MT para Caso 3 aplicado na Área 4.


Fonte: Autor

Figura 94 - Comparação entre as acurácias de predição entre MP e MT para Caso 4 aplicado na Área 4.



Fonte: Autor

Figura 95 - Comparação entre as acurácias de predição entre MP e MT para Caso 5 aplicado na Área 4.




Fonte: Autor

7.2.1.5 Área 5


As Figuras 120, 121, 122, 123 e 124 mostram as acurácias obtidas pelos índices de instabilidade CAPE, IK, ITT e pelo modelo proposto, respectivamente para os casos 1, 2, 3, 4 e 5, considerando a área 5 de estudo. Dentre a metodologia tradicional, o ITT apresentou o melhor desempenho, tendo em média, um acurácia de 59,68%, enquanto a CAPE e IK tiveram, respectivamente, as acurácias médias de 57,89% e 55,52%. Comparando as acurácias obtidas pela metodologia tradicional e a metodologia proposta em cada caso de estudo, na área 5, nota-se que em todos os casos analisados, o modelo proposto apresentou melhor resultado. Assim, validando a proposta para a área 5.

Figura 96 - Comparação entre as acurácias de predição entre MP e MT para Caso 1 aplicado na Área 5.




Fonte: Autor

Figura 97 - Comparação entre as acurácias de predição entre MP e MT para Caso 2 aplicado na Área 5.




Fonte: Autor


Figura 98 - Comparação entre as acurácias de predição entre MP e MT para Caso 3 aplicado na Área 5.



Fonte: Autor

Figura 99 - Comparação entre as acurácias de predição entre MP e MT para Caso 4 aplicado na Área 5.

Fonte: Autor


Figura 100 - Comparação entre as acurácias de predição entre MP e MT para Caso 5 aplicado na Área 5.

Fonte: Autor


7.2.1.6 Área 6

As Figuras 125, 126, 127, 128 e 129 mostram as acurácias obtidas pelos índices de instabilidade CAPE, IK, ITT e pelo modelo proposto, respectivamente para os casos 1, 2, 3, 4 e 5, considerando a área 6 de estudo. Dentre a metodologia tradicional, a CAPE apresentou o melhor desempenho, tendo em média, uma acurácia de 61,05%, enquanto IK e ITT tiveram, respectivamente, as acurácias médias de 56,57% e 56,05%. Comparando as acurácias obtidas pela metodologia tradicional e a metodologia proposta em cada caso de estudo, na área 6, nota-se que em todos os casos analisados, o modelo proposto apresentou melhor resultado. Assim, validando a proposta para a área 6.


Figura 101 - Comparação entre as acurácias de predição entre MP e MT para Caso 1 aplicado na Área 6.



Fonte: Autor


Figura 102 - Comparação entre as acurácias de predição entre MP e MT para Caso 2 aplicado na Área 6.

Fonte: Autor

Figura 103 - Comparação entre as acurácias de predição entre MP e MT para Caso 3 aplicado na Área 6.


Fonte: Autor

Figura 104 - Comparação entre as acurácias de predição entre MP e MT para Caso 4 aplicado na Área 6.



Fonte: Autor

Figura 105 - Comparação entre as acurácias de predição entre MP e MT para Caso 5 aplicado na Área 6.




Fonte: Autor

7.2.1.7 Área 7


As Figuras 130, 131, 132, 133 e 134 mostram as acurácias obtidas pelos índices de instabilidade CAPE, IK, ITT e pelo modelo proposto, respectivamente para os casos 1, 2, 3, 4 e 5, considerando a área 7 de estudo. Dentre a metodologia tradicional, a CAPE apresentou o melhor desempenho, tendo em média, uma acurácia de 63,68%, enquanto o IK e ITT tiveram, respectivamente, as acurácias médias de 56,84% e 55,26%. Comparando as acurácias obtidas pela metodologia tradicional e a metodologia proposta em casa caso de estudo, na área 7, nota-se que em todos os casos analisados, o modelo proposto apresentou melhor resultado. Assim, validando a proposta para a área 7.

Figura 106 - Comparação entre as acurácias de predição entre MP e MT para Caso 1 aplicado na Área 7.




Fonte: Autor

Figura 107 - Comparação entre as acurácias de predição entre MP e MT para Caso 2 aplicado na Área 7.




Fonte: Autor


Figura 108 - Comparação entre as acurácias de predição entre MP e MT para Caso 3 aplicado na Área 7.



Fonte: Autor

Figura 109 - Comparação entre as acurácias de predição entre MP e MT para Caso 4 aplicado na Área 7.

Fonte: Autor


Figura 110 - Comparação entre as acurácias de predição entre MP e MT para Caso 5 aplicado na Área 7.

Fonte: Autor


7.2.1.8 Área 8

As Figuras 135, 136, 137, 138 e 139 mostram as acurácias obtidas pelos índices de instabilidade CAPE, IK, ITT e pelo modelo proposto, respectivamente para os casos 1, 2, 3, 4 e 5, considerando a área 8 de estudo. Dentre a metodologia tradicional, a CAPE apresentou o melhor desempenho, tendo em média, uma acurácia de 61,58%, enquanto IK e ITT tiveram, respectivamente, as acurácias médias de 56,57% e 57,36%. Comparando as acurácias obtidas pela metodologia tradicional e a metodologia proposta em cada caso de estudo, na área 8, nota-se que em todos os casos analisados, o modelo proposto apresentou melhor resultado. Assim, validando a proposta para a área 8.


Figura 111 - Comparação entre as acurácias de predição entre MP e MT para Caso 1 aplicado na Área 8.




Fonte: Autor

Figura 112 - Comparação entre as acurácias de predição entre MP e MT para Caso 2 aplicado na Área 8.


Fonte: Autor

Figura 113 - Comparação entre as acurácias de predição entre MP e MT para Caso 3 aplicado na Área 8.

Fonte: Autor

Figura 114 - Comparação entre as acurácias de predição entre MP e MT para Caso 4 aplicado na Área 8.

Fonte: Autor

Figura 115 - Comparação entre as acurácias de predição entre MP e MT para Caso 5 aplicado na Área 8.

Fonte: Autor

7.2.2 COMPARAÇÃO ENTRE ALGORITMOS DE TREINAMENTO DA RNA

Tabela 13 exibe os resultados obtidos da comparação entre algoritmo Levenberg-Marquardt *backpropagation* (trainlm), *Scaled Conjugate Gradient backpropagation* (traincsg) e o *Gradient Descent backpropagation* (traingd).

Tabela 13 - Acurácia de comparação entre algoritmo de treinamento da RNA.

| | Caso 1 | | Caso 2 | |
|---------------------------------|---------------|--------------|---------------|--------------|
| Algoritmo de Treinamento | NN0 | Acurácia (%) | NN0 | Acurácia (%) |
| trainlm | 28 | 72,5 | 1 | 75,8 |
| traincsg | 4 | 71,8 | 3 | 73,6 |
| traingd | 17 | 69,2 | 1 | 75,8 |
| | Caso 3 | | Caso 4 | |
| Algoritmo de Treinamento | NN0 | Acurácia (%) | NN0 | Acurácia (%) |
| trainlm | 11 | 74,7 | 16 | 86,8 |
| traincsg | 21 | 73,7 | 16 | 85,7 |
| traingd | 3 | 73,7 | 4 | 84,6 |
| | Caso 5 | | | |
| Algoritmo de Treinamento | NN0 | Acurácia (%) | | |
| trainlm | 21 | 95,6 | | |
| traincsg | 17 | 93,4 | | |
| traingd | 26 | 93,4 | | |

Fonte: Autor

Pela Tabela 13, percebe-se que o algoritmo trainlm obteve o melhor desempenho em todos os casos de previsões analisados, enquanto o traingd apresentou pior resultado nos casos 1 e 4, com 17 e 4 neurônios ocultos (NNO), respectivamente. Nos casos 3 e 5, o traingd e o traincsg apresentaram acurácias semelhantes, sendo de 73,7% no caso 3 e de 93,4% no caso 5. No caso 3, o traincsg precisou de mais NNO (NNO=21) para obter a acurácia de 73,7% em relação ao traingd e no caso 5 precisou de menos NNO (NNO=17) para obter acurácia de 93,4% em relação ao traingd. No caso 2 o algoritmo traingd apresentou uma acurácia superior ao traincsg. Portanto, fica evidente o emprego do algoritmo trainlm neste estudo de previsão de descargas atmosféricas, devido este ter apresentado os melhores resultados.

7.3 PREVISÃO DE DESCARGAS ATMOSFÉRICAS POR ÁREA DE ESTUDO

O critério de parada desta proposta foi realizar o treinamento da RNA até se encontrar a melhor taxa de acurácia. A melhor topologia da RNA encontrada foi com 20 neurônios ocultos na camada intermediária, resultando em uma acurácia de 80,1%. Ressalta-se que os resultados obtidos são oriundos do caso 5, pois, foi este que apresentou melhor desempenho em relação aos outros casos de estudo.

Particularmente, nesta abordagem, adotou-se a seguinte representação para as classes de previsões de raios:

- VP corresponde a situação onde houve raio e o previsor acertou esse evento;
- VN corresponde a situação onde não houve raio e o previsor acertou esse evento;
- FP corresponde a situação onde não houve raio e o previsor previu que houve;
- FN corresponde a situação onde houve raio e o previsor previu como não houve raio.

7.3.1 AVALIAÇÃO DA VALIDAÇÃO DOS DADOS GERAIS DE TESTE

A Tabela 14 exibe matriz de confusão total das oito áreas, obtida para os dados de testes apresentados a RNA após treinamento. Obteve-se uma acurácia global de 80,04%. Isso corrobora que se obteve uma generalização satisfatória para o modelo de previsão de descargas atmosféricas.

Tabela 14 - Matriz de confusão geral de teste.

| | | PREVISTO | |
|------|---|--------------------------|--------|
| | | 1 | 0 |
| REAL | 1 | 10,18% | 7,78% |
| | 0 | 10,18% | 71,86% |
| | | Acurácia (82,04%) | |

Fonte: Autor

Pela Tabela 14, nota-se que não há desbalanceamento entre as classes, isto é, o modelo conseguiu separar as classes 0 (não ocorrência de raios, sendo negativa) e 1 (ocorrência de raios, sendo positiva). Obteve-se uma taxa VP=10,18% e uma taxa de FP=10,18%, uma taxa de VN=71,86% e taxa de FN=7,78%.

7.3.2 VALIDAÇÃO – 13/06/2014

A tabela 15 mostra o resultado do teste de previsão apresentado a RNA para o dia 13/06/2014. Nota-se que na área 1, área 2, área 5, área 6 e área 7, o modelo conseguiu prever corretamente os eventos observados. Enquanto, na área 4 e 8, o previsor gerou um resultado falso positivo e na área 3, um resultado falso negativo.

Tabela 15 - Predição para o dia 13/06/2014.

| | | DATA (13/06/2014) | | | | | | | |
|-----------|--|-------------------|--------|--------|--------|--------|--------|--------|--------|
| | | ÁREA 1 | ÁREA 2 | ÁREA 3 | ÁREA 4 | ÁREA 5 | ÁREA 6 | ÁREA 7 | ÁREA 8 |
| OBSERVADO | | 0 | 1 | 1 | 0 | 0 | 0 | 0 | 0 |
| PREVISTO | | 0 | 1 | 0 | 1 | 0 | 0 | 0 | 1 |

Fonte: Autor

7.3.3 VALIDAÇÃO – 05/07/2014

A Tabela 16 mostra o resultado do teste de previsão apresentado a RNA para o dia 05/07/2014. Percebe-se que todo evento observado onde não houve raio, foram adequadamente previstos nas áreas 1, 2, 3, 4, 5 e 8. O modelo gerou um evento falso negativo na área 6.

Tabela 16 - Predição para o dia 05/07/2014.

| | | DATA (05/07/2014) | | | | | | | |
|-----------|--|-------------------|--------|--------|--------|--------|--------|--------|--------|
| | | ÁREA 1 | ÁREA 2 | ÁREA 3 | ÁREA 4 | ÁREA 5 | ÁREA 6 | ÁREA 7 | ÁREA 8 |
| OBSERVADO | | 0 | 0 | 0 | 0 | 0 | 1 | 0 | 0 |
| PREVISTO | | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |

Fonte: Autor

7.3.4 VALIDAÇÃO – 10/07/2014

A Tabela 17 mostra o resultado do teste de previsão apresentado a RNA para o dia 10/07/2014. Todos os eventos observados onde houveram raios foram corretamente previstos nas áreas 1, 2, 5 e 6. O modelo apresentou eventos falsos positivos nas áreas 3, 4, 7 e 8.

Tabela 17 - Predição para o dia 10/07/2014.

| | | DATA (10/07/2014) | | | | | | | |
|----------|--|-------------------|--------|--------|--------|--------|--------|--------|--------|
| | | ÁREA 1 | ÁREA 2 | ÁREA 3 | ÁREA 4 | ÁREA 5 | ÁREA 6 | ÁREA 7 | ÁREA 8 |
| REAL | | 1 | 1 | 0 | 0 | 1 | 1 | 0 | 0 |
| PREVISTO | | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 |

Fonte: Autor

7.3.5 VALIDAÇÃO – 01/08/2014

A Tabela 18 mostra o resultado do teste de previsão apresentado a RNA para o dia 01/08/2014. Para esta data houve apenas evento falso negativo na área 2, todos os outros eventos em que não houveram raios, como nas áreas 1, 3, 4, 5, 6, 7 e 8, foram corretamente previstos pelo modelo.

Tabela 18 - Predição para o dia 01/08/2014.

| | | DATA (01/08/2014) | | | | | | | |
|----------|--|-------------------|--------|--------|--------|--------|--------|--------|--------|
| | | ÁREA 1 | ÁREA 2 | ÁREA 3 | ÁREA 4 | ÁREA 5 | ÁREA 6 | ÁREA 7 | ÁREA 8 |
| REAL | | 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| PREVISTO | | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |

Fonte: Autor

7.3.6 VALIDAÇÃO – 25/08/2014

A Tabela 19 mostra o resultado do teste de previsão apresentado a RNA para o dia 25/08/2014. Observa-se que houveram apenas eventos verdadeiros positivos, nas áreas 3 e 4. Nas áreas 1, 2, 5, 6, 7 e 8, o modelo gerou eventos falsos positivos.

Tabela 19 - Predição para o dia 25/08/2014.

| | | DATA (25/08/2014) | | | | | | | |
|----------|--|-------------------|--------|--------|--------|--------|--------|--------|--------|
| | | ÁREA 1 | ÁREA 2 | ÁREA 3 | ÁREA 4 | ÁREA 5 | ÁREA 6 | ÁREA 7 | ÁREA 8 |
| REAL | | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| PREVISTO | | 1 | 1 | 0 | 0 | 1 | 1 | 1 | 1 |

Fonte: Autor

7.3.7 VALIDAÇÃO – 11/09/2014

Para o dia 11/09/2014 apresentado a RNA, todos os casos reais onde não acontecerem raios, foram corretamente previstos, tendo-se 100% de acerto de eventos verdadeiros positivos nesse dia. A Tabela 20 exibe a validação para o dia 11/09/2014.

Tabela 20 - Predição para o dia 11/09/2014.

| | | DATA (11/09/2014) | | | | | | | |
|----------|--|-------------------|--------|--------|--------|--------|--------|--------|--------|
| | | ÁREA 1 | ÁREA 2 | ÁREA 3 | ÁREA 4 | ÁREA 5 | ÁREA 6 | ÁREA 7 | ÁREA 8 |
| REAL | | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| PREVISTO | | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |

Fonte: Autor

7.3.8 VALIDAÇÃO – 23/09/2014

Para o dia 23/09/2015, o modelo apresentou um evento falso negativo na área 5, em todas as outras áreas, o modelo conseguiu prever corretamente todas as situações em que não houve raio. A Tabela 21 mostra a validação do modelo de predição para o dia 23/09/2014.

Tabela 21 - Predição para o dia 11/09/2014.

| DATA (23/09/2014) | | | | | | | | |
|-------------------|--------|--------|--------|--------|--------|--------|--------|--------|
| | ÁREA 1 | ÁREA 2 | ÁREA 3 | ÁREA 4 | ÁREA 5 | ÁREA 6 | ÁREA 7 | ÁREA 8 |
| REAL | 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 |
| PREVISTO | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |

Fonte: Autor

7.3.9 VALIDAÇÃO – 10/10/2014

Para o dia 10/10/2014 ocorreram eventos falsos positivos nas áreas 3, 4 e 8. Nas áreas 1, 2, 5, 6 e 7 todos os eventos foram caracterizados como verdadeiros positivos. A Tabela 22 mostra a validação do modelo de predição para o dia 10/10/2014.

Tabela 22 - Predição para o dia 10/10/2014.

| DATA (10/10/2014) | | | | | | | | |
|-------------------|--------|--------|--------|--------|--------|--------|--------|--------|
| | ÁREA 1 | ÁREA 2 | ÁREA 3 | ÁREA 4 | ÁREA 5 | ÁREA 6 | ÁREA 7 | ÁREA 8 |
| REAL | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| PREVISTO | 0 | 0 | 1 | 1 | 0 | 0 | 0 | 1 |

Fonte: Autor

7.3.10 VALIDAÇÃO – 17/10/2014

A Tabela 23 mostra que para o dia 17/10/2014, o modelo apresentou um evento classificado como falso negativo, sendo este ocorrido na área 7. Em todas as outras áreas restantes, todos os eventos de não ocorrência de raios foram previstos corretamente.

Tabela 23 - Predição para o dia 17/10/2014.

| DATA (17/10/2014) | | | | | | | | |
|-------------------|--------|--------|--------|--------|--------|--------|--------|--------|
| | ÁREA 1 | ÁREA 2 | ÁREA 3 | ÁREA 4 | ÁREA 5 | ÁREA 6 | ÁREA 7 | ÁREA 8 |
| REAL | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 0 |
| PREVISTO | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |

Fonte: Autor

7.3.11 VALIDAÇÃO – 04/11/2014

Para o dia 04/11/2014 todos os eventos observados sem raios, em todas as áreas, foram previstos perfeitamente, conforme Tabela 24.

Tabela 24 - Predição para o dia 04/11/2014.

| DATA (04/11/2014) | | | | | | | | |
|-------------------|--------|--------|--------|--------|--------|--------|--------|--------|
| | ÁREA 1 | ÁREA 2 | ÁREA 3 | ÁREA 4 | ÁREA 5 | ÁREA 6 | ÁREA 7 | ÁREA 8 |
| REAL | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| PREVISTO | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |

Fonte: Autor

7.3.12 VALIDAÇÃO – 26/11/2014

Para o dia 26/11/2014 aconteceram eventos falsos negativos na área 5 e área 6. Nas áreas 1, 2, 3, 4 e 7 ocorreram eventos verdadeiros positivos, enquanto na área 8 ocorreu evento verdadeiro negativo. A Tabela 25 mostra os resultados de validação da RNA, considerando o dia 26/11/2014.

Tabela 25 - Predição para o dia 26/11/2014.

| DATA (26/11/2014) | | | | | | | | |
|-------------------|--------|--------|--------|--------|--------|--------|--------|--------|
| | ÁREA 1 | ÁREA 2 | ÁREA 3 | ÁREA 4 | ÁREA 5 | ÁREA 6 | ÁREA 7 | ÁREA 8 |
| REAL | 0 | 0 | 0 | 0 | 1 | 1 | 0 | 1 |
| PREVISTO | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 |

Fonte: Autor

7.3.13 VALIDAÇÃO – 02/12/2014

Pela Tabela 26, observa-se que para o dia 02/12/2014, não se observou ocorrência de raios em nenhuma área, sendo que o modelo conseguiu prever essa situação impecavelmente.

Tabela 26 - Predição para o dia 02/12/2014.

| DATA (02/12/2014) | | | | | | | | |
|-------------------|--------|--------|--------|--------|--------|--------|--------|--------|
| | ÁREA 1 | ÁREA 2 | ÁREA 3 | ÁREA 4 | ÁREA 5 | ÁREA 6 | ÁREA 7 | ÁREA 8 |
| REAL | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| PREVISTO | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |

Fonte: Autor

7.3.14 VALIDAÇÃO – 03/12/2014

Pela Tabela 27, nota-se que nas áreas 1, 2, 5 e 8 ocorreram raios no dia 02/12/2014, e o modelo conseguiu prever corretamente essas situações. Nas áreas 4 e 7, o modelo também conseguiu prever a não ocorrência de raio. Na área 3 ocorreu evento falso positivo.

Tabela 27 - Predição para o dia 03/12/2014.

| | | DATA (03/12/2014) | | | | | | | |
|----------|--|-------------------|--------|--------|--------|--------|--------|--------|--------|
| | | ÁREA 1 | ÁREA 2 | ÁREA 3 | ÁREA 4 | ÁREA 5 | ÁREA 6 | ÁREA 7 | ÁREA 8 |
| REAL | | 1 | 1 | 0 | 0 | 1 | 1 | 0 | 1 |
| PREVISTO | | 1 | 1 | 1 | 0 | 1 | 1 | 0 | 1 |

Fonte: Autor

7.3.15 VALIDAÇÃO – 07/01/2015

A Tabela 28 apresenta que para o dia 07/01/2015, houve a ocorrência de raio na área 1, sendo essa ocorrência prevista corretamente. Nas áreas 2, 3, 4, 7 e 8 não houve a incidência de raios, situações, também previstas corretamente. Nas áreas 5 e 6 ocorreram eventos falsos negativos.

Tabela 28 - Predição para o dia 07/01/2015.

| | | DATA (07/01/2015) | | | | | | | |
|----------|--|-------------------|--------|--------|--------|--------|--------|--------|--------|
| | | ÁREA 1 | ÁREA 2 | ÁREA 3 | ÁREA 4 | ÁREA 5 | ÁREA 6 | ÁREA 7 | ÁREA 8 |
| REAL | | 1 | 0 | 0 | 0 | 1 | 1 | 0 | 0 |
| PREVISTO | | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |

Fonte: Autor

7.3.16 VALIDAÇÃO – 20/01/2015

A Tabela 29 mostra que para o dia 20/01/2015 não se observou ocorrência de raios em nenhuma área, situação está prevista corretamente em todas as áreas.

Tabela 29 - Predição para o dia 20/01/2015.

| | | DATA (20/01/2015) | | | | | | | |
|----------|--|-------------------|--------|--------|--------|--------|--------|--------|--------|
| | | ÁREA 1 | ÁREA 2 | ÁREA 3 | ÁREA 4 | ÁREA 5 | ÁREA 6 | ÁREA 7 | ÁREA 8 |
| REAL | | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| PREVISTO | | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |

Fonte: Autor

7.3.17 VALIDAÇÃO – 11/02/2015

Para o dia 11/02/2014 (Tabela 30) ocorreu evento falso negativo na área 1, em todas as outras áreas, o modelo conseguiu prever os casos de não ocorrência de raios.

Tabela 30 - Predição para o dia 11/02/2015.

| DATA (11/02/2015) | | | | | | | | |
|-------------------|--------|--------|--------|--------|--------|--------|--------|--------|
| | ÁREA 1 | ÁREA 2 | ÁREA 3 | ÁREA 4 | ÁREA 5 | ÁREA 6 | ÁREA 7 | ÁREA 8 |
| REAL | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| PREVISTO | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |

Fonte: Autor

7.3.18 VALIDAÇÃO – 23/02/2015

Para o dia 23/02/2014 (Tabela 31) ocorreu evento falso negativo na área 8, em todas as outras áreas, o modelo conseguiu prever os casos de não ocorrência de raios.

Tabela 31 - Predição para o dia 23/02/2015.

| DATA (23/02/2015) | | | | | | | | |
|-------------------|--------|--------|--------|--------|--------|--------|--------|--------|
| | ÁREA 1 | ÁREA 2 | ÁREA 3 | ÁREA 4 | ÁREA 5 | ÁREA 6 | ÁREA 7 | ÁREA 8 |
| REAL | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 |
| PREVISTO | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |

Fonte: Autor

7.3.19 VALIDAÇÃO – 21/03/2015

A Tabela 32 exibe que nas áreas 1, 5, 6 e 7 houveram sucessos nas previsões de acontecimentos de ocorrências de raios pelo modelo. Nas áreas 3 e 8 ocorreram eventos falsos positivos, enquanto na área 4, a não ocorrência de raio observada, foi prevista corretamente.

Tabela 32 - Predição para o dia 21/03/2015.

| DATA (21/03/2015) | | | | | | | | |
|-------------------|--------|--------|--------|--------|--------|--------|--------|--------|
| | ÁREA 1 | ÁREA 2 | ÁREA 3 | ÁREA 4 | ÁREA 5 | ÁREA 6 | ÁREA 7 | ÁREA 8 |
| REAL | 1 | 0 | 0 | 0 | 1 | 1 | 1 | 0 |
| PREVISTO | 1 | 0 | 1 | 0 | 1 | 1 | 1 | 1 |

Fonte: Autor

7.3.20 VALIDAÇÃO – 06/04/2015

A Tabela 33 mostra que para o dia 06/04/2015, todos os fatos observados de não ocorrência de raios, conseguiram ser previstos com sucesso.

Tabela 33 - Predição para o dia 06/04/2015.

| DATA (06/04/2015) | | | | | | | | |
|-------------------|--------|--------|--------|--------|--------|--------|--------|--------|
| | ÁREA 1 | ÁREA 2 | ÁREA 3 | ÁREA 4 | ÁREA 5 | ÁREA 6 | ÁREA 7 | ÁREA 8 |
| REAL | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| PREVISTO | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |

Fonte: Autor

7.3.21 VALIDAÇÃO– 28/04/2015

A Tabela 34 mostra que para o dia 28/04/2015, todos os fatos observados de não ocorrência de raios, conseguiram ser previstos com sucesso.

Tabela 34 - Predição para o dia 28/04/2015.

| DATA (28/04/2015) | | | | | | | | |
|-------------------|--------|--------|--------|--------|--------|--------|--------|--------|
| | ÁREA 1 | ÁREA 2 | ÁREA 3 | ÁREA 4 | ÁREA 5 | ÁREA 6 | ÁREA 7 | ÁREA 8 |
| REAL | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| PREVISTO | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |

Fonte: Autor

7.3.22 AVALIAÇÃO DA VALIDAÇÃO POR ÁREA

A Tabela 35 exibe a matriz de confusão dos dados de teste da área 1. Obteve-se uma acurácia global de 90,48%. Para esta área conseguiram-se desempenhos satisfatórios para as taxas de VP e VN, sendo respectivamente 23,81% e 66,67%. As taxas de FN e PF foram respectivamente 4,76% e 4,76%, ficando abaixo das taxas de VP e VN.

Tabela 35 - Matriz de confusão da Área 1

| | | PREVISTO | |
|------|---|-------------------|--------|
| | | 1 | 0 |
| REAL | 1 | 23,81% | 4,76% |
| | 0 | 4,76% | 66,67% |
| | | Acurácia (90,48%) | |

Fonte: Autor

A Tabela 36 mostra a matriz de confusão dos dados de teste da área 2. Obteve-se uma acurácia global de 85,71%. As taxas de VP e VN foram, respectivamente, 14,29% e 71,43%, sendo superiores as taxas de FP e FN que foram, respectivamente, 4,76% e 9,52%. Assim, obteve desempenhos satisfatórios para a área 2.

Tabela 36 - Matriz de confusão da Área 2.

| | | PREVISTO | |
|------|---|--------------------------|--------|
| | | 1 | 0 |
| REAL | 1 | 14,29% | 9,52% |
| | 0 | 4,76% | 71,43% |
| | | Acurácia (85,71%) | |

Fonte: Autor

A Tabela 37 mostra a matriz de confusão dos dados de teste da área 3. Na área 3 não se observou ocorrências de raios, com isso a taxa de VP=0%. Obteve-se uma taxa de VN=76,19%. As taxas de FP=19,05% e FN=4,76% ficaram abaixo da taxa de VN. A acurácia global foi de 76.19%.

Tabela 37 - Matriz de confusão da Área 3.

| | | PREVISTO | |
|------|---|--------------------------|--------|
| | | 1 | 0 |
| REAL | 1 | 0,00% | 4,76% |
| | 0 | 19,05% | 76,19% |
| | | Acurácia (76,19%) | |

Fonte: Autor

A Tabela 38 mostra a matriz de confusão dos dados de teste da área 4. Na área 4 não se observou a ocorrência de raios, assim teve-se uma taxa VP=0%, também não houveram casos de FN. A taxa de VN=85,71% foi superior à taxa de FP=14,29%. A acurácia global foi de 85,71%.

Tabela 38 - Matriz de confusão da Área 4.

| | | PREVISTO | |
|------|---|--------------------------|--------|
| | | 1 | 0 |
| REAL | 1 | 0,00% | 0,00% |
| | 0 | 14,29% | 85,71% |
| | | Acurácia (85,71%) | |

Fonte: Autor

A Tabela 39 mostra a matriz de confusão dos dados de teste da área 5. Percebe-se que 66,66% dos casos foram preditos corretamente como VN e 14,29% foram preditos corretamente como VP. Os erros preditos de FN e FP foram, respectivamente de 14,29% e 4,76%. A acurácia global foi de 80,95%.

Tabela 39 - Matriz de confusão da Área 5.

| | | PREVISTO | |
|--------------------------|---|----------|--------|
| | | 1 | 0 |
| REAL | 1 | 14,29% | 14,29% |
| | 0 | 4,76% | 66,66% |
| Acurácia (80,95%) | | | |

Fonte: Autor

A Tabela 40 mostra a matriz de confusão dos dados de teste da área 6. Alcançou-se uma acurácia global de 80,95%. As taxas de VP e VN foram, respectivamente de 14,29% e 66,66%, sendo ao todo superiores as taxas de FP e FN que foram, respectivamente, 4,76% e 14,29%.

Tabela 40 - Matriz de confusão da Área 6.

| | | PREVISTO | |
|--------------------------|---|----------|--------|
| | | 1 | 0 |
| REAL | 1 | 14,29% | 14,29% |
| | 0 | 4,76% | 66,66% |
| Acurácia (80,95%) | | | |

Fonte: Autor

A Tabela 41 mostra a matriz de confusão dos dados de teste da área 7. Alcançou-se uma acurácia global de 85,71%. Obtiveram-se altas taxas de VN (80,05%) e baixas taxas de FN (4,76%), enquanto a taxa de VP (4,76%) foi um pouco superior a taxa de FP (9,53%).

Tabela 41 - Matriz de confusão da Área 7.

| | | PREVISTO | |
|--------------------------|---|----------|--------|
| | | 1 | 0 |
| REAL | 1 | 4,76% | 4,76% |
| | 0 | 9,53% | 80,95% |
| Acurácia (85,71%) | | | |

Fonte: Autor

Pela Tabela 42, observa-se que a área 8 foi onde o modelo apresentou menor desempenho em relação as outras áreas, teve uma acurácia global de 66,66%. Isso deve-se ao fato de ter ocorrido uma maior taxa de FP (23,81%), o que acabou provocando um maior erro de predição. Entretanto, obteve-se uma alta taxa de VN (57,15%) em relação a uma menor taxa de FN (9,52%), a taxa de VP foi 9,52%.

Tabela 42 - Matriz de confusão da Área 8.

| | | PREVISTO | |
|--------------------------|---|----------|--------|
| | | 1 | 0 |
| REAL | 1 | 9,52% | 9,52% |
| | 0 | 23,81% | 57,15% |
| Acurácia (66,66%) | | | |

Fonte: Autor

CAPÍTULO VIII

8 CONCLUSÃO

8.1 CONSIDERAÇÕES FINAIS

Uma nova abordagem para previsão de raios baseada em dados de sondagens atmosféricas satelitais foi apresentada nesta tese, aplicando-se RNA com a tarefa de classificar as modelagens preditivas. Sendo que esta proposta compreendeu o emprego de duas estratégias, uma (considerando) uma previsão global para as áreas de estudo, onde os dados foram separados aleatoriamente em dados em treinamento, validação e teste, onde essa separação ficou incumbida pelo algoritmo utilizado para treinar, validar e testar a RNA, sendo que do total de dados utilizados, 70% foram utilizados para treinar, 15% para validar e 15% para testar. A outra estratégia consistiu na previsão de descargas atmosféricas por área de estudo, onde os dados foram separados de forma aleatória para treinar e testar a RNA, onde essa separação foi realizada na montagem da base de dados e não pelo algoritmo, sendo que 80% do total dos dados foram utilizados para treinamento e 20% apresentados a RNA após treinada.

Considerando-se a primeira estratégia e analisando-se somente as acurácias das matrizes de confusão de teste obtidas para cada caso de estudo, o caso 5 foi o que apresentou melhor resultado, obtendo-se uma acurácia de 95,6%, seguido pelos casos 4, 2, 3 e 1 com as respectivas acurácias globais de teste: 86,8%, 75,8%, 74,7% e 72,5%. Isso demonstra que a RNA conseguiu um melhor reconhecimento de padrão de ocorrências de raios para uma janela de previsão de 5 horas e uma menor eficiência para uma janela de previsão de uma hora.

Analisando-se os gráficos ROC de cada caso de estudo para a primeira proposta, nota-se que o caso 5 apresentou melhor desempenho, confirmando a melhor acurácia global obtida para este caso de estudo. Isso significa que se obteve altas taxas de verdadeiros positivos para baixas taxas de falso positivos. A curva ROC gerada para o caso 4, também confirmou para este caso, como sendo o que teve a segunda maior acurácia. Agora, observando-se as curvas ROC dos casos 1, 2 e 3, nota-se uma maior aproximação e interseção entre elas. As próprias acurácias alcançadas por estes três casos, no qual ficaram próximas, explica a proximidade maior entre as curvas ROC. Dessa forma, foi obtida a AUC para cada caso de estudo para avaliar quais previsores, realmente, tiveram os melhores desempenhos.

A AUC calculada para os casos 5 e 4, sendo respectivamente de 0,871 e 0,864, comprovaram que estes dois casos foram os que tiveram os melhores desempenhos na tarefa de

predição de descargas atmosféricas. Dessa forma, conclui-se que a RNA conseguiu ajustar-se melhor a um tempo de predição de raios de 4 e 5 horas. Os valores de AUC para os casos 1, 2 e 3 foram, respectivamente, 0,794, 0,813 e 0,793, mostrando que houve uma pequena diferença de desempenho entre esses três casos. Pela AUC do caso 2, este teve o terceiro melhor desempenho. Observou-se, também, que embora o caso 3 tenha apresenta um valor de acurácia maior que o caso 1, entretanto, o valor de AUC do caso 1 teve um pequeno aumento em relação ao caso 3. Assim, conclui-se que os casos 1 e 3 então tiveram desempenhos praticamente semelhantes.

De uma forma geral, a RNA não teve maior desempenho para janelas de predição de 1, 2 e 3 horas, pois, apresentou uma taxa maior de erro de classificação. Isso não quer dizer que os modelos de predição não possam ser utilizados, mas haverá uma maior dificuldade em avaliar a ocorrência ou não de raios nesses horários.

Como esta tese propôs uma nova metodologia de previsão de descargas atmosféricas, foi necessário comparar os resultados da metodologia proposta com uma metodologia tradicional estabelecida na literatura. Dessa forma, foram obtidos os seguintes índices de instabilidade: IK, ITT Totals e CAPE para oito áreas de estudo, para compor a metodologia clássica. Os resultados comparativos para as oito áreas em cada caso de estudo, mostraram a eficiência da metodologia proposta. Para todos os casos analisados nas oito áreas, a metodologia proposta teve acurácias superiores em relação aos índices de instabilidades, validando-se assim essa proposta de estudo.

A segunda estratégia de previsão de descargas atmosféricas apresentada nesta tese teve o propósito de mostrar um produto de predição. Assim, aumentou-se a base de dados, com intuito aumentar a confiabilidade desta tática. A proposta é permitir analisar em situações reais, diariamente, a ocorrência ou não de raios a partir de dados do satélite. A acurácia global da matriz de confusão obtida de todos os dados de teste, mostrou que a RNA foi capaz de identificar as classes chamadas de: VP (Verdadeiro Positivo), FP (Falso Positivo), VN (Verdadeiro Negativo) e FN (Falso Negativo). Obteve-se uma acurácia global de teste de 82,04%, isto significa que, na prática a RNA conseguiu boas taxas de VP e VN para os dados utilizados, isto é, RNA conseguiu um bom desempenho em predizer as situações de não ocorrência e ocorrência de raios para situações que ela desconhecia. Assim, testou-se o poder de generalização da RNA, tendo esta alcançada resultados considerados satisfatórios.

Analisando-se, individualmente, cada dia que foi utilizado como dados de testes, notou-se que em relação as situações de observação de ocorrência ou não de raio, para as oito áreas, o modelo não classificou todos os exemplos na classe positiva (0) ou negativa (1), mas sim

conseguiu um balanceamento entre as classes de maneira satisfatória, para os dados que foram utilizados. O modelo conseguiu prever situações de ocorrência ou não de raios nas oito áreas, bem como, também mostrou situações em que ele previu que teve raio, mas não teve raio e previu que não teve raio, mas teve raio. Duas situações que demonstram o erro do previsor.

A matriz de confusão de teste obtida para cada área, mostrou que a área 1 foi a que apresentou o melhor desempenho, isto, na prática significa que se conseguiu bons acertos de VP e VN. As áreas 2, 4, 5, 6 e 7 tiveram desempenhos superiores a 80%, enquanto a área 3 teve 76,19%, o menor desempenho foi obtido para área 8, onde teve um erro maior na taxa de VP.

De uma forma geral, as melhores acurácias obtidas para os modelos de previsões neste estudo demonstram que a RNA é uma ferramenta extremamente poderosa em tarefas de reconhecimento de padrões. Esta conseguiu demonstrar, a ocorrência de altas taxas de acertos de eventos considerados como verdadeiros positivos, bem como taxas de acertos de eventos considerados como verdadeiros negativos.

Os modelos de previsões foram baseados na utilização de apenas duas variáveis meteorológicas obtidas por sondagem de satélite: temperatura do ar e temperatura do ponto de orvalho. Entretanto, esses dois parâmetros foram suficientes para a RNA reconhecer padrões fortemente correlacionados com os dados históricos de raios. Visto que essas duas medições são a base para derivação de alguns índices e parâmetros termodinâmicos de sondagens convencionais, indiretamente, os modelos conseguiram incorporar as condições de instabilidade que podem levar à formação de nuvens de tempestades de raios.

Os resultados encontrados sugerem o potencial para expansão das previsões de raios com alcance em toda a Amazônia Legal, uma vez que a região tem uma enorme carência de estações de radiossondagens. As aplicações de tais informações são inúmeras, abrangendo desde a proteção de vidas humanas à proteção e gerenciamento de sistemas diversos como telecomunicações, transmissão de energia, operações aéreas, ferroviárias e rodoviárias, entre muitas outras.

Uma base de dados maior certamente contribuirá para aperfeiçoar as técnicas e obter resultados mais promissores no futuro. Da mesma forma que a melhor cobertura de uma rede de detecção de raios também é fundamental para reduzir os ruídos e aprimorar o desempenho dos algoritmos de aprendizagem que vão modelar o fenômeno.

8.2 PROPOSTAS DE TRABALHOS FUTUROS

Como sugestão para trabalhos futuros, como intuito de dar continuidade a esta tese, recomendam-se as seguintes pesquisas:

- Empregar outras técnicas de inteligência computacional, como por exemplo: Vizinhos mais Próximos, KNN, Naive Bayes e Árvore de Decisão, para comparar os resultados alcançados com a RNA. A RNA é um método que se baseia em otimização, Vizinhos mais Próximos e KNN são métodos baseados em distâncias, enquanto o Naive Bayes é um método probabilístico e Árvore de Decisão é um método baseado em procura. Assim, será avaliado qual será o melhor método de predição a ser empregado.
- Expansão da quantidade de entrada de dados de temperatura do ar, temperatura do ponto de orvalho e dados históricos de raios da STARNET para treinamento do algoritmo.
- Esta tese utilizou apenas duas possibilidades de previsão: “0” como não ocorrência de raios e “1” como ocorrência de raios, correlacionando os dados de temperatura do ar e temperatura do ponto de orvalho. Assim, pretende-se aumentar as possibilidades de previsão de raios, com as seguintes condições: “sem”, “pouco”, “médio” e “muito”.
- Obter para os dados do NOAA-19, os seguintes índices de instabilidade e parâmetros termodinâmicos: CAPE, CINE, IK, ITT, IL e Água Precipitável, para verificar a possibilidade de formação de tempestades severas conjuntamente com raios. Os valores destes índices serão utilizados como atributos preditivos como entrada em uma técnica de inteligência computacional.
- Os modelos propostos se basearam na utilização da base histórica de raios reprocessados da STARNET. Assim, pretende-se utilizar uma base histórica de raios de outra instituição e comparar os resultados com os da STARNET.
- Realizar o treinamento de uma única RNA para prever os 5 casos (saídas).

REFERÊNCIAS

- AGÊNCIA BRASIL, Agência. **Brasil registra média de 78 milhões de raios por ano.** 2017. Disponível em: <<http://agenciabrasil.ebc.com.br/>>. Acesso em: 03 nov. 2017.
- AKINYEMI, M.I. et al. Lightning a Fundamental of Atmospheric Electricity. **Ieri Procedia**, [s.l.], v. 9, p.47-52, 2014. Elsevier BV. <http://dx.doi.org/10.1016/j.ieri.2014.09.039>.
- ALI, A.F. et al. Thunderstorm forecasting by using artificial neural network. **2011 5th International Power Engineering and Optimization Conference**, Shah Alam, Selangor, Malaysia, p.1-6, jun. 2011. IEEE. <http://dx.doi.org/10.1109/peoco.2011.5970391>.
- ALVES, Elton Rafael et al. Lightning prediction using satellite atmospheric sounding data and feed-forward artificial neural network. **Journal of Intelligent & Fuzzy Systems**, [s.l.], v. 33, n. 1, p.79-92, 22 jun. 2017. IOS Press. <http://dx.doi.org/10.3233/jifs-161152>.
- ALVES, Elton Rafael et al.: Estudo comparativo entre radiossondagens convencionais e sondagens do satélite NOAA-16. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 7º, 2015, João Pessoa. **Simpósio**. João Pessoa-PB: Inpe, 2015. p. 1 - 8.
- ALVES, Elton Rafael. **Controle Neural Inverso para um Servomotor.** 2008. TCC (Graduação) - Curso de Engenharia da Computação, Instituto de Tecnologia, Universidade Federal do Pará, Belém-Pa, 2009.
- AMERICAN Meteorology Society: Glossary of Meteorology.** 2017. Disponível em: <http://glossary.ametsoc.org/wiki/Stability_index>. Acesso em: 06 nov. 2017.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 5419-2: Proteção contra descargas atmosféricas Parte 2: Gerenciamento de Risco.** Rio de Janeiro, 2015. 116 p.
- BASTOS, Eduardo Nunes Ferreiras. **Uma rede neural auto-organizável construtiva para aprendizado perpétuo de padrões espaço-temporais.** 2007. 137 f. Dissertação (Mestrado) - Curso de Ciência da Computação, Programa de Pós-graduação em Computação, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2007.
- BERGER, K.; ANDERSON, R. B.; Kröninger, H. Parameters of lightning flashes. **Electra**, no. 41, pp. 23–37, July, 1975.
- BIDNER, A. The Air Force Global Weather Central severe weather threat (SWEAT) index -A preliminary report. Air Weather Service Aerospace Science Review. AWS RP 105-2, No.70-3, 2-5. 1970.
- BLUESTEIN, H. B. Observations and theory of weather systems. In: **Synoptic - dynamic meteorology in midlatitudes.** Oxford: Oxford University Press, 1993, v. 2, 595p.
- BRAGA, A. P.; CARVALHO, A. P.L.F.; LUDEMIR, T.B. **Redes Neurais: Teoria e aplicações.** 2. ed. Rio de Janeiro: LTC, 2017.

BYERS, Horace R.; BRAHAM, Roscoe R. THUNDERSTORM STRUCTURE AND CIRCULATION. **Journal of Meteorology**, [s.l.], v. 5, n. 3, p.71-86, jun. 1948. American Meteorological Society. [http://dx.doi.org/10.1175/1520-0469\(1948\)0052.0.co;2](http://dx.doi.org/10.1175/1520-0469(1948)0052.0.co;2).

CARDOSO, I.; JR. PINTO, O.; PINTO, I.R.C.; HOLLE, R.L. A new approach to estimate the annual number of global lightning fatalities. Proceedings 14th International Conference on Atmospheric Electricity. Rio de Janeiro, Brasil, p.4, 2011.

CARDOSO, Nélia Kainara Rodrigues. **Relações entre Índices de Instabilidade e as chuvas ocorridas em Porto Alegre,RS,de 1990 a 2005**. 2007. 94 f. Tese (Doutorado) - Curso de Meteorologia, Programa de Pós-graduação em Meteorologia, Universidade Federal de Pelotas, Pelotas, 2007.

CARVALHO, A. M.; DINIZ, J. H.; CHERCHIGLIA, L. C. L. Obtenção de densidade de descargas atmosféricas para a Terra através de contadores de descargas, dias de trovoadas ouvidas e Sistema de Localização de Tempestades – SLT. II Seminário Internacional de Proteção Contra Descargas Atmosféricas, Guaratinguetá, São Paulo, julho de 1992.

COLBY, F. P. Jr. Convective inhibition as a predictor of convection during AVE-SESAME II. *Mon. Wea. Rev.*, 112, 2239-2252, 1984.

CUMMINS, Kenneth L.; MURPHY, Martin J. An Overview of Lightning Locating Systems: History, Techniques, and Data Uses, With an In-Depth Look at the U.S. NLDN. **IEEE Transactions on Electromagnetic Compatibility**, [s.l.], v. 51, n. 3, p.499-518, ago. 2009. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/temc.2009.2023450>.

DIAS, Rosilene N.; MESQUITA, Cláudia R.; VISACRO, Silvério. Aplicações de mapas de densidade de descargas atmosféricas na engenharia de proteção: avaliações e limitações. In: ENCUESTRO REGIONAL IBEROAMERICANO DE CIGRÉ, 13., 2009, Puerto Iguazú. **XIII ERIAC**. Puerto Iguazú -argentina: Cigre, 2009. p. 1 - 7.

DURRE, Imke; VOSE, Russell S.; WUERTZ, David B. Overview of the Integrated Global Radiosonde Archive. **Journal of Climate**, [s.l.], v. 19, n. 1, p.53-68, jan. 2006. American Meteorological Society. <http://dx.doi.org/10.1175/jcli3594.1>.

DWYER, Joseph R.; UMAN, Martin A. The physics of lightning. **Physics Reports**, [s.l.], v. 534, n. 4, p.147-241, jan. 2014. Elsevier BV. <http://dx.doi.org/10.1016/j.physrep.2013.09.004>.

ELAT: Grupo de Eletricidade Atmosférica. Grupo de Eletricidade Atmosférica. 2017. Disponível em: <<http://www.inpe.br/webelat/homepage/>>. Acesso em: 14 dez. 2016.

FAWCETT, Tom. An introduction to ROC analysis. **Pattern Recognition Letters**, [s.l.], v. 27, n. 8, p.861-874, jun. 2006. Elsevier BV. <http://dx.doi.org/10.1016/j.patrec.2005.10.010>.

FACELI, Katti et al. **Inteligência Artificial: Uma abordagem de aprendizagem de máquina**. Rio de Janeiro: LTC, 2015. 378 p.

FERREIRA, Nelson Jesus. **Aplicações ambientais brasileiras dos satélites NOAA e Tiros N**. São Paulo: Oficinas de Texto, 2004.

FRANKEL, D. et al. Use of neural networks to predict lightning at Kennedy Space Center. **Ijcn-91-seattle International Joint Conference on Neural Networks**, [s.l.], p.319-324, 1991. IEEE. <http://dx.doi.org/10.1109/ijcn.1991.155197>.

FUN, Meng-hock; HAGAN, M.t. Levenberg-Marquardt training for modular networks. **Proceedings of International Conference on Neural Networks (icnn'96)**, [s.l.], p.468-473, 1996. IEEE. <http://dx.doi.org/10.1109/icnn.1996.548938>.

Fundamentos de Meteorologia. Belém-Pa, 2014 (Apostila 09 do curso de Faculdade de Meteorologia - Universidade Federal do Pará).

GALWAY, Joseph G. The Lifted Index as a Predictor of Latent Instability. **Bulletin of The American Meteorological Society**, v. 37, p.528-529, 1956.

GEORGE, J. J. Weather forecasting for aeronautics. By J. J. George. New York and London Academic Press, 1960. p.673. **Quarterly Journal Of The Royal Meteorological Society**, [s.l.], v. 87, n. 371, p.120-120, jan. 1961. Wiley-Blackwell. <http://dx.doi.org/10.1002/qj.49708737120>.

GIANNAROS, Theodore M.; KOTRONI, Vassiliki; LAGOVARDOS, Konstantinos. Predicting lightning activity in Greece with the Weather Research and Forecasting (WRF) model. **Atmospheric Research**, [s.l.], v. 156, p.1-13, abr. 2015. Elsevier BV. <http://dx.doi.org/10.1016/j.atmosres.2014.12.009>.

GOLDE, R. H. **Lightning** (Vol. 1). London: Academic Press, 1977.

GOLDSCHIMIDT, R. R. **Uma introdução a Inteligência Computacional: Fundamentos, ferramentas e aplicações**. Rio de Janeiro: IST-RIO, 2010.

HAYKIN, Simon. **Redes Neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001.

HEILMANN, Armando. **Avaliação do sistema de detecção de descargas atmosféricas em VLF - Zeus no Brasil**. 2006. 155 f. Tese (Dissertação) - Curso de Ciências Atmosféricas, Universidade de São Paulo, São Paulo, 2006.

HOLLE, Ronald L. Annual rates of lightning fatalities by country. In: INTERNATIONAL LIGHTNING DETECTION CONFERENCE, 20, 2008, Tucson, Arizona, USA. **Conference**. 2008: Vaisala, 2008. p. 1 - 14.

HOLLE, Ronald L. Some aspects of global lightning impacts. **2014 International Conference on Lightning Protection (iclp)**, Shanghai, China, p.1390-1395, out. 2014. IEEE. <http://dx.doi.org/10.1109/iclp.2014.6973348>.

HUNT, H.G.P.; NIXON, K.J.; NAUDÉ, J.A. Using lightning location system stroke reports to evaluate the probability that an area of interest was struck by lightning. **Electric Power**

Systems Research, [s.l.], v. 153, p.32-37, dez. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.eprs.2016.12.010>.

HURICANNES. **Upper-Air Observations: The Radiosonde**: Science and Society. 2017. Disponível em: <http://www.hurricanescience.org/science/observation/landbased/radiosonde/>. Acesso em: 15 nov. 2017.

JOHARI, Dalina; RAHMAN, Titik Khawa Abdul; MUSIRIN, Ismail. Artificial Neural Network Based Technique for Lightning Prediction. **2007 5th Student Conference on Research and Development**, Selangor, Malaysia, Malaysia, p.1-5, 2007. IEEE. <http://dx.doi.org/10.1109/scored.2007.4451448>.

JUNTIAN, Guo; SHANQIANG, Gu; WANXING, Feng. A lightning motion prediction technology based on spatial clustering method. **2011 7th Asia-pacific International Conference on Lightning**, Chengdu, China, p.1-6, nov. 2011. IEEE. <http://dx.doi.org/10.1109/apl.2011.6110234>.

KALTENBÖCK, Rudolf; DIENDORFER, Gerhard; DOTZEK, Nikolai. Evaluation of thunderstorm indices from ECMWF analyses, lightning data and severe storm reports. **Atmospheric Research**, [s.l.], v. 93, n. 1-3, p.381-396, jul. 2009. Elsevier BV. <http://dx.doi.org/10.1016/j.atmosres.2008.11.005>.

KRIDER, E. P. 75 years of research on the physics of a lightning discharge. In: Fleming, J. R. (ed). **Historical essays on meteorology 1919-1995**. Boston: **American Meteorological Society**, 1996. Cap. 11, p. 321-350.

KRIDER, E. P. 75 years of research on the physics of a lightning discharge. In: Fleming, J. R. (ed). **Historical essays on meteorology 1919-1995**. Boston: American Meteorological Society, 1996. Cap. 11, p. 321-350.

LI, Jun et al. Global Soundings of the Atmosphere from ATOVS Measurements: The Algorithm and Validation. **Journal of Applied Meteorology**, [s.l.], v. 39, n. 8, p.1248-1268, ago. 2000. American Meteorological Society. [http://dx.doi.org/10.1175/1520-0450\(2000\)0392.0.co;2](http://dx.doi.org/10.1175/1520-0450(2000)0392.0.co;2).

LU, Jiazheng et al. Forecast method of lightning activity based on the weather conditions. **2011 7th Asia-pacific International Conference on Lightning**, Chengdu, China, p.1-4, nov. 2011. IEEE. <http://dx.doi.org/10.1109/apl.2011.6110202>.

MACGORMAN, D. R.; RUST, W. D. **The electrical nature of storms**. New York: Oxford, 1998

MANZATO, Agostino. Sounding-derived indices for neural network based short-term thunderstorm and rainfall forecasts. **Atmospheric Research**, [s.l.], v. 83, n. 2-4, p.349-365, fev. 2007. Elsevier BV. <http://dx.doi.org/10.1016/j.atmosres.2005.10.021>.

MCCULLOCH, W. S. S.; PITTS, W. H. A. Logical of the ideas immament in nervous activity. **Bulletib of Mathematical Biophysics**, v.5, p.115-133, 1943.

MILLER, R. C. Notes on analysis and severe storm forecasting procedures of the Air Force Global Weather Central. Tech. Report 200 (Revised), AWS, USAF. [Headquarters, AWS, Scott AFB, IL 62225], 1972.

MONCRIEFF, M. W.; MILLER, M. J. The dynamics and simulation of tropical cumulonimbus and squall lines. **Quart. J. Roy. Meteor. Soc.** 102. 373-3 94, 1976.

MORALES, C. A.; Neves, J.R.; Anselmo, E. Sferics Timing and Ranging Network – Starnet: Evaluation over South America. 2011 **14th International Conference on Atmospheric Electricity**. [S.I], p.1-4, 2011.

MOTA, M. A. S. **Convecção na Amazônia: Variabilidade, efeitos e resposta na circulação de grande escala**. 2007. 194 f. Tese (Doutorado em Meteorologia) – Instituto Nacional de Pesquisas Espaciais. São José dos Campos, 2007.

MOTA, M. A. S; TAVARES, J. P. N. **Condições termodinâmicas de eventos de precipitação extrema em Belém-Pa durante a estação chuvosa**. Revista Brasileira de Meteorologia, v.27, n.2, f.173-206, 2012.

MUNTA, Jaya Ausha. **Relatório Final de Projeto de Iniciação Científica (PIBIC/CNPq/INPE)**. Cachoeira Paulista: DSA-CPTEC-INPE, 2009.

NACCARATO K, P. **Análise das Características dos relâmpagos na região sudeste do Brasil**. 2006. 316p. (INPE-14083-TDI/1069). Tese (Doutorado em Geofísica Espacial). INPE, São José dos Campos, 2006.

NACCARATO, Kleber Pinheiro. **Estudo de relâmpagos no Brasil com base na análise de desempenho do Sistema de Localização de Tempestades**. 2001. 158 f. Dissertação (Mestrado) - Curso de Geofísica Espacial, Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2001.

NASA. **National Aeronautics and Space Administration**. 2017. Disponível em: <<https://pmm.nasa.gov/science-team/resources/noaa19-satellite>>. Acesso em: 10 nov. 2017.

NEUROSCIENCEKNOWLEDGE. **Conhecimento é a fonte**. 2017. Disponível em: <<https://neuroscienceknowledge.wordpress.com/>>. Acesso em: 09 nov. 2017.

NOAA. 2017. Disponível em: <<http://www.ospo.noaa.gov/Operations/POES/decommissioned.html>>. Acesso em: 27 jun. 2017.

NOAA. **National Aeronautics and Space Administration**. 2017. Disponível em: <<http://www.noaa.gov/>>. Acesso em: 10 nov. 2017.

NOAA. **National Oceanic and Atmospheric Administration**. 2017. Disponível em: <<http://www.ospo.noaa.gov/Operations/POES/status.html>>. Acesso em: 08 ago. 2017.

PINTO JUNIOR, Osmar. **A arte da guerra contra os raios**. São Paulo: Oficinas de Textos, 2005.

PINTO JUNIOR, Osmar; PINTO, Iara Regina Cardoso de Almeida. **Relâmpagos**. São Paulo: Brasiliense, 1996.

PINTO JUNIOR, Osmar; PINTO, Iara Regina Cardoso de Almeida. **Tempestades e Relâmpagos no Brasil**. São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 2000. 193 p.

PINTO, I.R.C.A.; PINTO JUNIOR, O. Cloud-to-ground lightning distribution in Brazil. **Journal of Atmospheric and Solar-terrestrial Physics**, [s.l.], v. 65, n. 6, p.733-737, abr. 2003. Elsevier BV. [http://dx.doi.org/10.1016/s1364-6826\(03\)00076-2](http://dx.doi.org/10.1016/s1364-6826(03)00076-2).

PIPIER, R. A review of static stability indices and related thermodynamic parameters. **Illinois State Water Survey Climate and Meteorology Section**, USA, 1988.

POES. **Satellite and Product Operations**. 2017. Disponível em: <<http://www.ospo.noaa.gov/index.html>>. Acesso em: 10 nov. 2017.

POTIER, G. C. et al. **Física dos raios e proteção**. 2ª ed. Porto Alegre: EDIPUCRS, 2010.

PSICOLÓGICO, Portfólio. **Cérebro e as áreas especializadas**. 2017. Disponível em: <<http://portfoliopsi12.blogspot.com.br/2012/04/cerebro.html>>. Acesso em: 22 jul. 2017.

PU, Lu et al. A new method to study on distribution characteristics of cloud-to-ground lightning. **2012 International Conference on High Voltage Engineering and Application**, [s.l.], p.1-4, set. 2012. IEEE. <http://dx.doi.org/10.1109/ichve.2012.6357010>.

RAKOV, V.A., 9, 2007, Foz do Iguaçu. **Lightning phenomenology and parameters important for lightning protection**. Foz do Iguaçu, 2007.

RAKOV, V.A. et al. Direct lightning strikes to the lightning protective system of a residential building: triggered-lightning experiments. **IEEE Transactions on Power Delivery**, [s.l.], v. 17, n. 2, p.575-586, abr. 2002. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/61.997942>.

RAKOV, V.A.; UMAN, M.A. **Lightning: Physics and Effects**. New York: Cambridge University Press, 2003.

REDMET. **Portal da Rede de Meteorologia do Comando da Aeronáutica**. 2014. Disponível em: <<https://www.redmet.aer.mil.br/>>. Acesso em: 21 jul. 2014.

RITENOUR, Amber E. et al. Lightning injury: A review. **Burns**, [s.l.], v. 34, n. 5, p.585-594, ago. 2008. Elsevier BV. <http://dx.doi.org/10.1016/j.burns.2007.11.006>.

RODRIGUES, R. B. **Proteção de sistemas de energia eólica contra descargas atmosféricas**. 2010. 250 f. Tese (Doutorado) - Curso de Engenharia Eletrotécnica, Universidade de Beira do Interior, Covilhã-Portugal, 2010.

SÁ, José Alberto Silva de et al. Recurrent Self-Organizing Map for Severe Weather Patterns Recognition. **Recurrent Neural Networks and Soft Computing**, [s.l.], p.151-174, 30 mar. 2012. InTech. <http://dx.doi.org/10.5772/38823>.

SÁ, José Alberto Silva de. **Descargas atmosféricas na Amazônia: Reconhecimento de padrões e análise dos parâmetros de interesse para o planejamento estratégico dos sistemas de proteção de linhas de transmissão**. 2011. 196 f. Tese (Doutorado) - Curso de Engenharia Elétrica, Universidade Federal do Pará, Belém-PA, 2011.

SATVIEW. **Tracking satellites**. 2017. Disponível em: http://www.satview.org/lista_sat.php?cat=noaa. Acesso em: 10 out. 2017.

SEASPACE. **SEASPACE**. 2017. Disponível em: <https://www.seaspace.com/>. Acesso em: 21 jul. 2017

SHOWALTER, A. K. A stability index for forecasting thunderstorms. **Bull. Amer. Meteor. Soc.** 34. 250– 252, 1953.

SIINGH, Devendraa et al. The atmospheric global electric circuit: An overview. **Atmospheric Research**, [s.l.], v. 84, n. 2, p.91-110, abr. 2007. Elsevier BV. <http://dx.doi.org/10.1016/j.atmosres.2006.05.005>.

SILVA, Mário Adelmo Varejão. **Meteorologia e Climatologia**. Versão Digital 2, Recife-PE, 2006.

SOARES, Felipe da Rocha. **Metodologia de previsão de descargas atmosféricas utilizando dados de Radar, rede de sensores eletromagnéticos e modelagem atmosférica**. 2014. 166 f. Dissertação (Mestrado) – Curso de Pós-Graduação em Meteorologia, Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2014.

SONNADARA, Upul et al. Performance of lightning locating systems in extracting lightning flash characteristics. **Journal of Atmospheric and Solar-terrestrial Physics**, [s.l.], v. 112, p.31-37, maio 2014. Elsevier BV. <http://dx.doi.org/10.1016/j.jastp.2014.02.001>.

STARNET. **Sferics Timing and Ranging Network**. 2017. Disponível em: <http://www.zeus.iag.usp.br/>. Acesso em: 13 jun. 2017.

TAN, P. N.; Steinbach, M.; Kumar, V. **Introduction to data mining**. Boston: Addison-Wesley Longman, 2005.

TERASCAN ® SYSTEM TRAINING GUIDE. **Manual de guia de treinamento do sistema TERASCAN**. SeaSpace Corporation, California: USA, 2011, 548f.

UMAN, M. A. **The lightning discharge**. Orlando: Academic Press, 1987.

UMAN, M.A. Natural lightning. **IEEE Transactions on Industry Applications**, [s.l.], v. 30, n. 3, p.785-790, 1994. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/28.293729>.

UNIVERSITY WYOMING, UNIVERSITY OF WYOMING. 2017. Disponível em: <<http://weather.uwyo.edu/upperair/sounding.html>>. Acesso em: 13 maio 2017.

UOL. **Recontando neurônios**. 2007. Disponível em: <http://www2.uol.com.br/vivermente/noticias/recontando_neuronios.html>. Acesso em: 09 nov. 2017.

VAN ERKEL, Arian R; PATTYNAMA, Peter M.th. Receiver operating characteristic (ROC) analysis: Basic principles and applications in radiology. **European Journal of Radiology**, [s.l.], v. 27, n. 2, p.88-94, maio 1998. Elsevier BV. [http://dx.doi.org/10.1016/s0720-048x\(97\)00157-5](http://dx.doi.org/10.1016/s0720-048x(97)00157-5).

VAN LOOY, Stijn et al. Prediction of dose escalation for rheumatoid arthritis patients under infliximab treatment. **Engineering Applications of Artificial Intelligence**, [s.l.], v. 19, n. 7, p.819-828, out. 2006. Elsevier BV. <http://dx.doi.org/10.1016/j.engappai.2006.05.001>.

VIANELLO, R. L.; ALVES, A. R. **Meteorologia básica e aplicações**. UFV: Viçosa-MG, 2000.

VIANELLO, Rubens Alves; Alves, Adil Rainier. **Meteorologia básica e aplicações**. 2 ed. UFV: Viçosa – MG, 2012.

VISACRO FILHO, S. **Descargas atmosféricas**: Uma abordagem de engenharia. São Paulo: Artlibier, 2005.

VUJOVIĆ, D. et al. Evaluation of the stability indices for the thunderstorm forecasting in the region of Belgrade, Serbia. **Atmospheric Research**, [s.l.], v. 161-162, p.143-152, jul. 2015. Elsevier BV. <http://dx.doi.org/10.1016/j.atmosres.2015.04.005>.

WANG, Jun et al. Lightning potential forecast over Nanjing with denoised sounding-derived indices based on SSA and CS-BP neural network. **Atmospheric Research**, [s.l.], v. 137, p.245-256, fev. 2014. Elsevier BV. <http://dx.doi.org/10.1016/j.atmosres.2013.10.014>

Weather Warning Center. Tech. Report 200, AWS, USAF. Headquarters, AWS, Scott AFB, IL 62225, 1967.

WEATHER, Wildcard. **WILDCARD WEATHER**. 2017. Disponível em: <<https://wildcardweather.com/2012/08/10/radiosondes-weather-balloons-and-their-role-in-forecasting/>>. Acesso em: 25 jul. 2017.

WENG, Leong Yeng et al. Lightning Forecasting Using Ann-BP and Radiosonde. **2010 International Conference on Intelligent Computing and Cognitive Informatics**, [s.l.], p.1-4, jun. 2010. IEEE. <http://dx.doi.org/10.1109/icicci.2010.83>.

WILLIAMS, Earle; MAREEV, Eugene. Recent progress on the global electrical circuit. **Atmospheric Research**, [s.l.], v. 135-136, p.208-227, jan. 2014. Elsevier BV. <http://dx.doi.org/10.1016/j.atmosres.2013.05.015>.

WOODS, K.; BOWYER, K.W. Generating ROC curves for artificial neural networks. **Ieee Transactions on Medical Imaging**, [s.l.], v. 16, n. 3, p.329-337, jun. 1997. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/42.585767>.

ZENG, Qingfeng et al. The application of lightning forecasting based on surface electrostatic field observations and radar data. **Journal of Electrostatics**, [s.l.], v. 71, n. 1, p.6-13, fev. 2013. Elsevier BV. <http://dx.doi.org/10.1016/j.elstat.2012.10.007>.

ZEPKA, G.S.; PINTO, O.; SARAIVA, A.C.V. Lightning forecasting in southeastern Brazil using the WRF model. **Atmospheric Research**, [s.l.], v. 135-136, p.344-362, jan. 2014. Elsevier BV. <http://dx.doi.org/10.1016/j.atmosres.2013.01.008>.

ZEPKA, Gisele dos Santos. **Estudo para o desenvolvimento de um previsor de descargas elétricas atmosféricas aplicado à região costeira do Rio de Janeiro**. 2005. 149 f. Dissertação (Mestrado) - Curso de Pós-graduação em Engenharia Oceânica, Fundação Universidade Federal do Rio Grande, Rio Grande-RS, 2005.


ZEPKA, Gisele dos Santos. **Previsão de descargas atmosféricas usando modelo de mesoescala WRF**. 2011. 178 f. Tese (Doutorado) - Curso de Geofísica Espacial/ciências Atmosféricas), Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2011.

ZEPKA, Gisele S. et al. Lightning forecasting using WRF model over EDP distribution companies areas. **2013 International Symposium on Lightning Protection (XII SIPDA)**, Belo Horizonte-Brazil, p.1-6, out. 2013. IEEE. <http://dx.doi.org/10.1109/sipda.2013.6729239>.

ZHOU, Junchi et al. Numeric lightning prediction based on convective indexes at Yangkou Harbor. **2012 9th International Conference on Fuzzy Systems and Knowledge Discovery**, Sichuan, China, p.1-3, maio 2012. IEEE. <http://dx.doi.org/10.1109/fskd.2012.6234094>


APÊNDICE A – Cálculo do Índice K por área de estudo

Figura 116 - Índice K - Área 1.




Fonte: Autor

Figura 117 - Índice K – Área 2.




Fonte: Autor

Figura 118 - Índice K – Área 3




Fonte: Autor

Figura 119 - Índice K – Área 4.



Fonte: Autor

Figura 120 -Índice K – Área 5.



Fonte: Autor

Figura 121 - Índice K – Área 6.






Figura 122 - Índice K – Área 7.



Fonte: Autor


Figura 123 - Índice K – Área 8.



Fonte: Autor


APÊNDICE B - Cálculo do Índice Total Totals por área de estudo

Figura 124 - Índice Total Totals – Área 1.




Fonte: Autor

Figura 125 - Índice Total Totals – Área 2.




Fonte: Autor

Figura 126 - Índice Total Totals – Área 3.



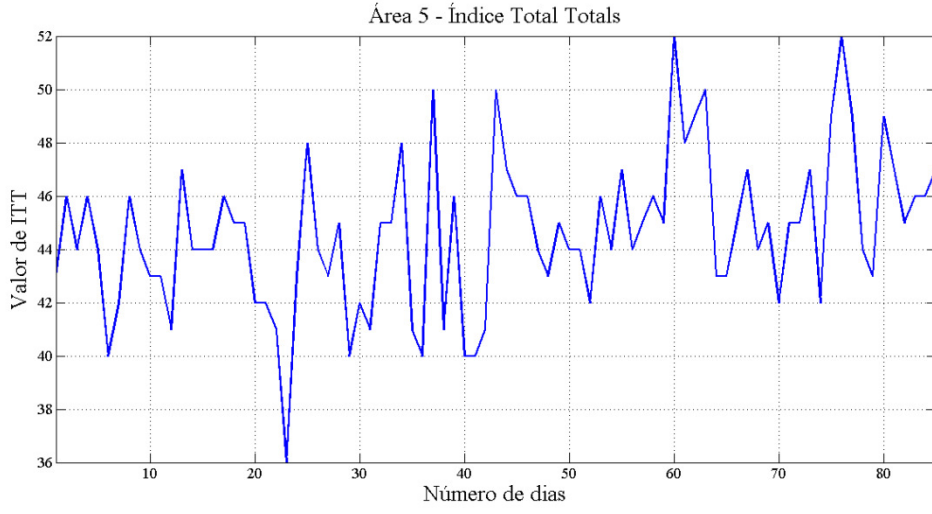
Fonte: Autor

Figura 127 - Índice Total Totals – Área 4.




Fonte: Autor

Figura 128 - Índice Total Totals – Área 5.




Fonte: Autor

Figura 129 - Índice Total Totals – Área 6.




Fonte: Autor

Figura 130 - Índice Total Totals – Área 7.



Fonte: Autor


Figura 131 - Índice Total Totals – Área 8.



Fonte: Autor


APÊNDICE C - Cálculo da CAPE por área de estudo

Figura 132 - Valores de CAPE para Área 1.



Fonte: Autor

Figura 133 - Valores de CAPE para Área 2.



Fonte: Autor





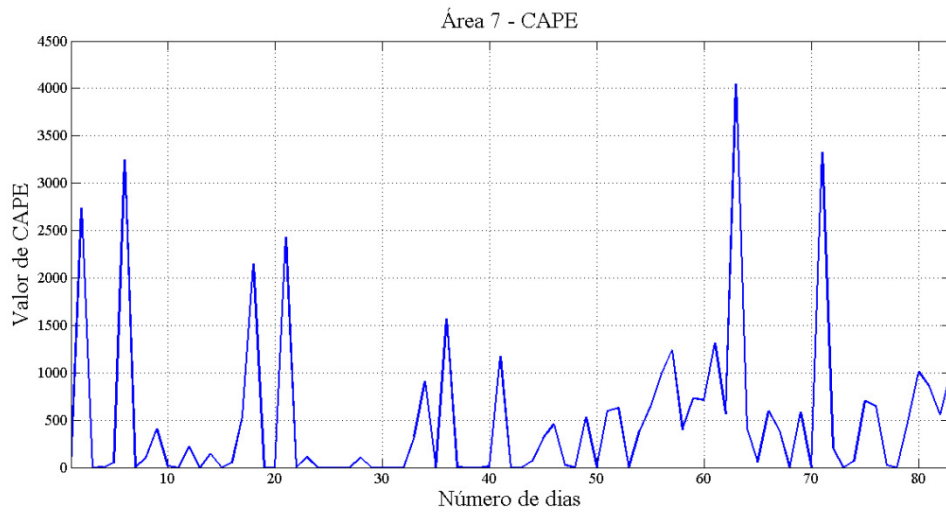

Figura 134 - Valores de CAPE para Área 3.**Fonte:** Autor**Figura 135** - Valores de CAPE para Área 4.**Fonte:** Autor

Figura 136 - Valores de CAPE para Área 5.

Fonte: Autor

Figura 137 - Valores de CAPE para Área 6.

Fonte: Autor

Figura 138 - Valores de CAPE para Área 7.**Fonte:** Autor**Figura 139** - Valores de CAPE para Área 8.**Fonte:** Autor