

**VINÍCIUS MACHADO MARTINEZ**

**SISTEMA BASEADO EM REGRAS *FUZZY* DO TIPO TAKAGI-  
SUGENO APLICADO A ECOS DE RADARES METEOROLÓGICOS**

Sorocaba  
2016

**VINÍCIUS MACHADO MARTINEZ**

**SISTEMA BASEADO EM REGRAS *FUZZY* DO TIPO TAKAGI-SUGENO APLICADO A ECOS DE RADARES METEOROLÓGICOS**

Dissertação apresentada como requisito para a obtenção do título de Mestre em Ciências Ambientais da Universidade Estadual Paulista "Júlio de Mesquita Filho" na Área de Concentração Diagnóstico, Tratamento e Recuperação Ambiental.

Orientador: Prof<sup>a</sup>. Dra. Sandra Regina Monteiro Masalskiene Roveda

Sorocaba  
2016

PROGRAMA DE PÓS-GRADUAÇÃO em

ciências  
ambientais



Ficha catalográfica elaborada pela Biblioteca da Unesp  
Instituto de Ciência e Tecnologia de Sorocaba

Martinez, Vinícius Machado.

Sistema baseado em regras fuzzy do tipo Takagi-Sugeno aplicado a ecos de radares meteorológicos / Vinícius Machado Martinez, 2016.

99 f.: il.

Orientador: Sandra Regina Monteiro Masalskiene Roveda.

Dissertação (Mestrado) – Universidade Estadual Paulista "Júlio de Mesquita Filho". Instituto de Ciência e Tecnologia (Câmpus de Sorocaba), 2016.

1. Lógica difusa. 2. Radar meteorológico. 3. Sistemas difusos. I. Universidade Estadual Paulista "Júlio de Mesquita Filho". Instituto de Ciência e Tecnologia (Câmpus de Sorocaba). II. Título.

**CERTIFICADO DE APROVAÇÃO**

**TÍTULO DA DISSERTAÇÃO:** Sistema Baseado em Regras Fuzzy do Tipo Takagi- Sugeno Aplicado a Eco Radars Meteorológicos..

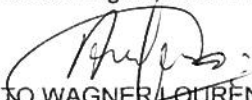
**AUTOR:** VINICIUS MACHADO MARTINEZ

**ORIENTADORA:** SANDRA REGINA M M ROVEDA

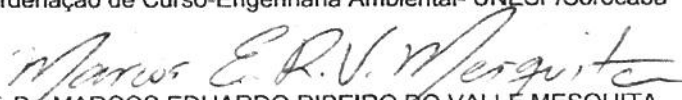
Aprovado como parte das exigências para obtenção do Título de Mestre em CIÊNCIAS AMBIENTAIS, área: Diagnóstico, Tratamento e Recuperação Ambiental, pela Comissão Examinadora:



Profa. Dra. SANDRA REGINA M M ROVEDA  
Coordenação de Curso-Engenharia Ambiental- UNESP/Sorocaba



Prof. Dr. ROBERTO WAGNER LOURENÇO  
Coordenação de Curso-Engenharia Ambiental- UNESP/Sorocaba



Prof. Dr. MARCOS EDUARDO RIBEIRO DO VALLE MESQUITA  
Departamento de Matemática Aplicada- UNICAMP

Sorocaba, 25 de janeiro de 2016

À minha mãe, que em vida carrega nos ombros o amor da entrega ao seus não tão fáceis filhos. Você é tudo na minha vida.

Ao meu tio “Zézinho”, cujo exemplo em vida é de vitória e perseverança.

Ao meu pai, João Sacconi, e ao meu avô, José Machado, cuja morada se faz no plano da eterna saudade. Obrigado por cuidarem de tudo aí de cima.

À minha irmã Viviane, de quem os atritos de personalidade tornam-se ínfimos frente ao amor que partilhamos.

A toda minha família, pelo apoio, incentivo e paciência.

**DEDICO**

## **AGRADECIMENTOS**

À Universidade Estadual Paulista “Júlio de Mesquita Filho” e ao Programa de Pós-Graduação em Ciências Ambientais.

A todo o corpo docente do Programa de Pós-Graduação em Ciências Ambientais, cuja transmissão do conhecimento foi a mais rica de toda a minha vida acadêmica.

A todos os técnicos e funcionários da Unesp/Sorocaba, pelos inúmeros socorros prestados. Sem vocês seria impossível chegar até aqui.

Ao Dr. José Márcio Bassan, grande amigo que, ao longo deste trabalho, contribuiu com todo seu conhecimento computacional, científico e de vida, sem os quais este trabalho seria absolutamente impossível de ser desenvolvido.

Ao IPMet, na pessoa do Prof<sup>o</sup> Dr. Edson Sardella, pelo afastamento e concessão dos dados utilizados nesta pesquisa, confiando no trabalho desenvolvido. Em especial, ao Grupo Operacional do IPMet que acreditam no meu potencial, ao suprir a minha ausência do trabalho quando do afastamento para o mestrado, pelo incentivo aos estudos e pela dedicação profissional.

Aos amigos da Unesp/Bauru Hélio, Fábio e Vinícius Pavani, pela amizade intensa desde a primeira prova da graduação ao incentivo da não desistência nos momentos de fraqueza pessoal. Aos batalhões “Regina’s House” e “Gordaul’s House”, de onde estão as pessoas que fazem a minha caminhada não cessar, com todo o carinho e amizade dedicados a mim.

Ao amigos do Mestrado, em especial ao Adriano, Lucirene, Valteir, Hélio e Fabíola, cuja convivência nesses anos de Sorocaba me fizeram ter maior noção de como a vida acadêmica pode ser, também, descontraída, ainda que de muita responsabilidade.

Aos meus queridos: Prof<sup>o</sup> Dr. José Arnaldo Frutuoso Roveda e em especial a Prof<sup>a</sup> Dra. Sandra Regina Monteiro Masalskiene Roveda, pela recepção, pelo carinho que me acolheram, pela amizade construída, pelos conhecimentos transmitidos como professores e orientadores, pela dedicação no trabalho, pela confiança em mim depositada, pelo incomensurável amadurecimento acadêmico que me proporcionaram, por todos os momentos de descontração e seriedade nesses anos juntos. Vocês se tornaram meu maior espelho nesta jornada, de onde as longas e cansativas viagens semanais de Bauru a Sorocaba se tornaram imensamente prazerosas e inspiradoras. Vocês fizeram toda a diferença nessa missão. Sem vocês, não faria sentido algum continuar sonhando. Minha eterna gratidão.

*"Naquela mesa ele sentava sempre  
E me dizia sempre o que é viver melhor  
Naquela mesa ele contava histórias  
Que hoje na memória eu guardo e sei de cor  
Naquela mesa ele juntava gente  
E contava contente o que fez de manhã  
E nos seus olhos era tanto brilho  
Que mais que seu filho  
Eu fiquei seu fã"*

(Naquela Mesa – Nelson Gonçalves)

*De que me irei ocupar no céu, durante toda a Eternidade, se não me derem  
uma infinidade de problemas de Matemática para resolver?*

(Augustin Louis Cauchy)

# Resumo

O campo de refletividade de ecos observados por radares meteorológicos está sujeito a interferências de fenômenos físicos da atmosfera que podem resultar em interpretações não realísticas do fenômeno observado. Buscando ajustar o campo de refletividade de ecos detectados simultaneamente por dois radares meteorológicos ao longo da distância, este estudo desenvolveu um sistema baseado em regras fuzzy (SBRF), do tipo Takagi-Sugeno de primeira ordem, que combina as variáveis distância (km) e refletividade (dBZ) para expressar a refletividade ajustada de alvos mais distantes de um radar em relação a outro radar mais próximo, de modo que os efeitos das interferências nas medidas dos radares possam ser minimizadas. Os dados utilizados são oriundos de dois radares meteorológicos do IPMet/UNESP, localizados nos municípios de Bauru (22,3583 S; 49,0278 W) e Presidente Prudente (22.1751 S; 51.3743 W), no Brasil, no período de um ano de dados (2010) do produto CAPPI, faixa de 3.5km de altitude. A saída do sistema é nomeada refletividade fuzzy (RF) e é obtida através de um conjunto de nove curvas de regressão linear, cujos coeficientes angulares e lineares foram estimados pelo método dos mínimos quadrados. Dois parâmetros foram utilizados para análise das curvas obtidas: o coeficiente de correlação de Pearson e o coeficiente de determinação. O sistema foi aplicado a 20.514 dados referentes a 18 pixels distribuídos sobre uma faixa de comum cobertura dos radares. O modelo foi avaliado através das estatísticas de erro médio (BIAS), erro quadrático médio (MSE) e pelo teste de Kolmogorov-Smirnov. Os resultados obtidos demonstram a capacidade do sistema em aproximar o campo de refletividade de dois radares que operam sobre uma área de comum cobertura, devendo constituir-se como uma ferramenta alternativa de interpretação no monitoramento de chuvas, nos processos de modelagem ambiental e em sugestões futuras de estimativa de chuva por radar.

**Palavras-chave:** Radar Meteorológico, Lógica Fuzzy, Precipitação, Refletividade, Sistemas baseados em regras fuzzy, método de Takagi-Sugeno.

# Abstract

The reflectivity field of echoes observed by weather radars is subjected to the interference of physical phenomena of the atmosphere that can result in unrealistic interpretations on its characteristics. Aiming to adjust the reflectivity field of echoes simultaneously detected by two weather radars over a distance, this study developed a Takagi-Sugeno fuzzy rule-based system, whose input variables are the distance(km) and the reflectivity(dBZ) of the echoes, in order to obtain the adjusted reflectivity of echoes more distant from a radar in relation to another closer radar that is considered to be less susceptible to interference and, therefore, more realistic. The data used are from two weather radars of IPMet/UNESP, located in the municipalities of Bauru (22.3583° S; 49.0278° W) and Presidente Prudente (22.1751° S; 51.3743° W), Brazil, which collected data of the CAPPI product in the period of one year (2010), with a sampling altitude range of 3.5 km. The system output is named “Fuzzy Reflectivity” (FR), obtained through the fuzzy approach of a set of nine linear regression curves, whose angular and linear coefficients were estimated by the method of least squares. Two parameters were used for the analysis of the curves obtained: the Pearson correlation coefficient and the coefficient of determination. The system was applied to 20,514 data related to 18 pixels spread over a range of common coverage of the radars. We evaluated the system performance by means of statistical parameters: average error (bias), mean square error (MSE) and Kolmogorov-Smirnov test. The results obtained demonstrate the system ability to refine the modeling of the issue in question in relation to the traditional statistical approaches, properly adjusting the reflectivity field of the echoes observed by two radars that operate over an area of common coverage and serving as an alternative interpretation tool in the monitoring of rains, in processes of environmental modeling and in future suggestions of rain estimate by radar.

**Keywords:** Fuzzy Modeling, Takagi-Sugeno method, Meteorology, Weather Radar.

# Lista de ilustrações

Figura 1 – Princípio Básico de Funcionamento de um Radar Meteorológico . . . . .	24
Figura 2 – Sistema Radar - Diagrama de Blocos . . . . .	24
Figura 3 – Trajetória dos feixes entre o alimentador (F) e a superfície refletora . . . . .	25
Figura 4 – Volume iluminado pelo pulso do radar . . . . .	27
Figura 5 – Lóbulos principal e secundários . . . . .	27
Figura 6 – Variação da altura do feixe em função de R e $\theta$ . . . . .	28
Figura 7 – Aumento da altitude do feixe ao longo da distância . . . . .	28
Figura 8 – Propagação Anômala - Desvio na trajetória do feixe eletromagnético . . . . .	31
Figura 9 – Fenômeno da Banda Brilhante próximo à isoterma de zero grau . . . . .	33
Figura 10 – Ilustração das tarefas PPI e CAPPI . . . . .	34
Figura 11 – Esquema para um sistema de controle humano na tarefa de lavar roupa . . . . .	46
Figura 12 – Módulos que compõem um Sistema de Inferência <i>Fuzzy</i> . . . . .	46
Figura 13 – Conjuntos <i>fuzzy</i> para as variáveis do problema . . . . .	48
Figura 14 – Superfície <i>fuzzy</i> resultante da base de regras . . . . .	49
Figura 15 – Processador do tipo Mamdani . . . . .	49
Figura 16 – Conjuntos <i>fuzzy</i> para as variáveis do problema . . . . .	51
Figura 17 – Superfície <i>fuzzy</i> resultante da base de regras . . . . .	52
Figura 18 – Processador do tipo Takagi-Sugeno . . . . .	52
Figura 19 – Método Dual-Radar . . . . .	54
Figura 20 – Interação entre os feixes dos radares meteorológicos de Bauru e Presidente Prudente . . . . .	55
Figura 21 – Áreas de abrangência dos radares meteorológicos de Bauru e Prudente na matriz do TITAN . . . . .	57
Figura 22 – Composição de 21a e 21b - <i>Merged</i> de Bauru e Prudente . . . . .	57
Figura 23 – Área de estudo: Intersecção entre as matrizes de Bauru e Prudente . . . . .	58
Figura 24 – Eco observado na área de intersecção dos radares (Faixa 3.5km do produto CAPPI) . . . . .	58
Figura 25 – Altitude da amostra - 2km . . . . .	59
Figura 26 – Altitude da amostra - 2.75km . . . . .	59
Figura 27 – Altitude da amostra - 3.5km . . . . .	59
Figura 28 – Conjuntos <i>Fuzzy</i> para as variáveis de entrada . . . . .	61
Figura 29 – Pontos utilizados para determinar as curvas de regressão . . . . .	62
Figura 30 – Comparação entre os Radares Meteorológicos - Pontos D1 a D4 . . . . .	73
Figura 31 – Comparação entre os Radares Meteorológicos - Pontos D5 a D8 . . . . .	74
Figura 32 – Ponto M . . . . .	75
Figura 33 – Superfície <i>Fuzzy</i> gerada pela base de regras . . . . .	75

Figura 34 – ECDF para P10 . . . . .	81
Figura 35 – ECDF para P30 . . . . .	81
Figura 36 – ECDF para P50 . . . . .	82
Figura 37 – ECDF para P70 . . . . .	82
Figura 38 – ECDF para P89 . . . . .	83
Figura 39 – ECDF para P105 . . . . .	83
Figura 40 – ECDF para P124 . . . . .	84
Figura 41 – ECDF para P147 . . . . .	84
Figura 42 – ECDF para P166 . . . . .	85
Figura 43 – ECDF para P184 . . . . .	85
Figura 44 – ECDF para P203 . . . . .	86
Figura 45 – ECDF para P223 . . . . .	86
Figura 46 – ECDF para P242 . . . . .	87
Figura 47 – ECDF para P262 . . . . .	87
Figura 48 – ECDF para P281 . . . . .	88
Figura 49 – ECDF para P301 . . . . .	88

# Lista de tabelas

Tabela 1 – Bandas de Trabalho . . . . .	23
Tabela 2 – Aplicações para diferentes bandas de trabalho . . . . .	23
Tabela 3 – Classificação linguística em termos de <i>dBZ</i> . . . . .	30
Tabela 4 – Tabela verdade de $\wedge$ . . . . .	41
Tabela 5 – Tabela verdade de $\vee$ . . . . .	41
Tabela 6 – Tabela verdade de $\longrightarrow$ . . . . .	41
Tabela 7 – Tabela verdade de $\neg$ . . . . .	41
Tabela 8 – t-normas e s-normas . . . . .	44
Tabela 9 – Regras de um sistema de automação na lavagem de roupas . . . . .	45
Tabela 10 – Características Técnicas dos Radares Meteorológicos de Bauru e Presidente Prudente . . . . .	56
Tabela 11 – Estatística de filtragem de pares de dados anômalos . . . . .	63
Tabela 12 – Pixels utilizados para a avaliação do desempenho do modelo mais próximos ao Radar de Presidente Prudente . . . . .	67
Tabela 13 – Pixels utilizados para a avaliação do desempenho do modelo mais próximos ao Radar de Bauru . . . . .	68
Tabela 14 – Coeficientes de determinação e de correlação obtidos . . . . .	72
Tabela 15 – Pontos Otimizados e Pontos Divergentes . . . . .	77
Tabela 16 – Pontos Otimizados e Pontos Divergentes . . . . .	77
Tabela 17 – Análise dos Resultados: Erro Sistemático (BIAS) . . . . .	78
Tabela 18 – Análise dos Resultados: Erro Sistemático (BIAS) . . . . .	78
Tabela 19 – Análise dos Resultados: Erro Quadrático Médio (MSE) . . . . .	78
Tabela 20 – Análise dos Resultados: Erro Quadrático Médio (MSE) . . . . .	79
Tabela 21 – Análise dos Resultados: Raiz do Erro Quadrático Médio (RMSE) . . . . .	79
Tabela 22 – Análise dos Resultados: Raiz Erro Quadrático Médio (RMSE) . . . . .	80
Tabela 23 – Teste de Kolmogorov-Smirnov antes e depois das simulações do modelo . . . . .	80

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>16</b>
<b>1.1</b>	<b>Objetivos da Pesquisa</b>	<b>18</b>
<b>1.2</b>	<b>Organização do trabalho</b>	<b>20</b>
<b>2</b>	<b>RADAR METEOROLÓGICO</b>	<b>21</b>
<b>2.1</b>	<b>Contexto Histórico</b>	<b>21</b>
<b>2.2</b>	<b>Princípios Físicos de Funcionamento</b>	<b>22</b>
<b>2.3</b>	<b>Componentes de um RADAR</b>	<b>24</b>
2.3.1	Transmissor ( <i>Transmitter</i> )	24
2.3.2	Modulador ( <i>Modulator</i> )	25
2.3.3	Antena ( <i>Antenna</i> )	25
2.3.4	Radome	29
<b>2.4</b>	<b>A Equação do Radar</b>	<b>29</b>
<b>2.5</b>	<b>Propagação Anômala</b>	<b>30</b>
<b>2.6</b>	<b>Banda Brilhante</b>	<b>32</b>
<b>2.7</b>	<b>Coleta de Dados dos Radares Meteorológicos de Bauru e Presidente Prudente</b>	<b>33</b>
2.7.1	Os Produtos <i>Plan Position Indicator</i> e <i>Constant Altitude Plan Position Indicator</i>	33
<b>2.8</b>	<b>Calibração de radares meteorológicos</b>	<b>34</b>
<b>3</b>	<b>CONJUNTOS FUZZY, LÓGICA FUZZY E SISTEMAS DE INFERÊNCIA FUZZY</b>	<b>36</b>
<b>3.1</b>	<b>Teoria dos Conjuntos Fuzzy</b>	<b>36</b>
3.1.1	Fundamentos	36
3.1.2	Definições e Operações	38
3.1.3	Variáveis Linguísticas	39
<b>3.2</b>	<b>Lógica Fuzzy</b>	<b>40</b>
3.2.1	Conectivos fundamentais da Lógica Clássica	40
3.2.2	Conectivos fundamentais da Lógica Fuzzy	43
3.2.3	Propriedades	44
<b>3.3</b>	<b>Sistemas Baseados em Regras Fuzzy</b>	<b>45</b>
3.3.1	Sistema de Inferência Fuzzy	46
3.3.1.1	Fuzzificação	47
3.3.1.2	Base de Regras Fuzzy	47
3.3.1.3	Inferência	47

3.3.1.4	Defuzzificação . . . . .	47
3.3.2	O método de Inferência de Mamdani . . . . .	47
3.3.3	O método de Inferência de Takagi-Sugeno . . . . .	50
<b>4</b>	<b>MATERIAIS E MÉTODOS . . . . .</b>	<b>53</b>
<b>4.1</b>	<b>Caracterização dos dados . . . . .</b>	<b>53</b>
4.1.1	A Técnica de Radares Integrados ( <i>Dual-Radar Method</i> ) . . . . .	53
4.1.2	Matrizes do sistema TITAN . . . . .	56
<b>4.2</b>	<b>Elaboração do Modelo do tipo Takagi-Sugeno de ordem 1 . . . . .</b>	<b>59</b>
4.2.1	Escolha das Variáveis . . . . .	60
4.2.2	Conjuntos <i>Fuzzy</i> para as entradas Distância e Refletividade . . . . .	60
4.2.3	O Método de Inferência de Takagi-Sugeno . . . . .	61
4.2.3.1	Determinação dos parâmetros $\delta$ , $\kappa$ e $\nu$ - O Método dos Mínimos Quadrados . . . . .	62
4.2.4	Dados utilizados para simulação . . . . .	67
<b>4.3</b>	<b>Análise Estatística . . . . .</b>	<b>68</b>
4.3.1	Para as curvas de regressão linear . . . . .	68
4.3.1.1	Coefficiente de correlação de Perason - ( $\rho$ ) . . . . .	68
4.3.1.2	Coefficiente de determinação - ( $R^2$ ) . . . . .	68
4.3.2	Para o desempenho do modelo . . . . .	69
4.3.2.1	BIAS . . . . .	69
4.3.2.2	MSE . . . . .	69
4.3.2.3	RMSE . . . . .	70
4.3.2.4	O teste de Kolmogorov-Smirnov . . . . .	70
<b>5</b>	<b>RESULTADOS E DISCUSSÕES . . . . .</b>	<b>71</b>
<b>5.1</b>	<b>Curvas de Regressão . . . . .</b>	<b>71</b>
<b>5.2</b>	<b>Superfície <i>Fuzzy</i> . . . . .</b>	<b>75</b>
<b>5.3</b>	<b>Estatística dos Resultados . . . . .</b>	<b>76</b>
5.3.1	Pontos Otimizados e Pontos Divergentes . . . . .	76
5.3.1.1	Caso $\theta_o$ = Radar de Presidente Prudente . . . . .	77
5.3.1.2	Caso $\theta_o$ = Radar de Bauru . . . . .	77
5.3.2	BIAS - Erro Médio . . . . .	77
5.3.2.1	Caso $\theta_o$ = Radar de Presidente Prudente . . . . .	77
5.3.2.2	Caso $\theta_o$ = Radar de Bauru . . . . .	78
5.3.3	MSE - Erro Quadrático Médio . . . . .	78
5.3.3.1	Caso $\theta_o$ = Radar de Presidente Prudente . . . . .	78
5.3.3.2	Caso $\theta_o$ = Radar de Bauru . . . . .	79
5.3.4	RMSE - Raiz do Erro Quadrático Médio . . . . .	79
5.3.4.1	Caso $\theta_o$ = Radar de Presidente Prudente . . . . .	79
5.3.4.2	Caso $\theta_o$ = Radar de Bauru . . . . .	79

5.4	Comparação entre as funções de distribuição obtidas pré e pós modelagem <i>fuzzy</i> . . . . .	80
5.5	Análise dos Resultados . . . . .	88
6	CONSIDERAÇÕES FINAIS . . . . .	91
	REFERÊNCIAS . . . . .	93

# 1 Introdução

Dados de precipitação tem sido freqüentemente utilizados na modelagem de processos hidrológicos, em atividades da agricultura, em modelos de previsão do tempo e, também, no monitoramento de tempestades (COLE; MOORE, 2008; MARTENS et al., 2013; KAY et al., 2015; SZCZEŚNIAK; PINIEWSKI, 2015; BASSAN et al., 2015; ZHANG; ZHANG; CHEN, 2015). De maneira geral, o pluviômetro tem sido a fonte mais comum. Entretanto, é necessário um elevado número de equipamentos distribuídos espacialmente para que o perfil da precipitação numa determinada área seja representativa (WILSON; BRANDES, 1979), uma vez que o pluviômetro tem suas medições de caráter pontual, e isso se torna uma limitação para as aplicações desejadas em alguns modelos ambientais.

É de sensível conhecimento os impactos que tempestades severas causam na sociedade em todo o Brasil e no mundo. Podem ocorrer prejuízos na agricultura, na biodiversidade, na saúde da população e na geração de energia. Eventos extremos de chuvas aumentam o risco de escorregamento podendo afetar as populações que moram em morros desmatados e, dentre inúmeros outros consequentes, desencadear enchentes urbanas intensas (GUIDICINI; IWASA, 1976; MARCELINO; NUNES; KOBIYAMA, 2006; FILHO, 2012).

Na esfera dos acidentes geológicos e hidrológicos, Cerri (1993) afirma que os acidentes relacionados a escorregamento constituem a maior causa de mortes no Brasil, ao passo que inundações e enchentes tem maior frequência de registros.

Conhecer o período de chuvas é, portanto, de fundamental importância para o planejamento e execução de tarefas dos mais diversos setores da sociedade, seja na cidade ou no campo. Tal conhecimento reflete na qualidade de atividades como na agricultura, na construção civil, na gestão de recursos hídricos e, também, na emissão de alertas de riscos das Defesas Civas que realizam operações urbanas e sociais nestes períodos.

Particularmente, são inúmeros os estudos que investigam o início da estação chuvosa no sudeste brasileiro. Em Alves et al. (2005) são apresentados os padrões atmosféricos que prevalecem durante o período chuvoso na região sudeste do Brasil, a partir da análise de dados de precipitação, circulação nos baixos níveis da atmosfera, radiação de onda larga e temperatura da superfície do mar, dispostos em uma grade regular através do método de interpolação de Cressman (CRESSMAN, 1959). Neste estudo os resultados sugerem que o período chuvoso na região sudeste se inicia na pênstada 57 (período de 5 dias de chuvas acumuladas), equivalente aos dias de 8 a 12 de outubro, com desvio padrão de  $\pm 2$  pênstadas.

Fenômenos meteorológicos de escala sinótica, como os sistemas frontais, a Zona de

Convergência do Atlântico Sul (ZCAS)(KODAMA, 1992), o *El Niño* (COBB et al., 2003) e a *La Niña* (HOLTON; DMOWSKA; PHILANDER, 1989) têm um papel importante na variabilidade pluviométrica, alguns ligados ao aumento do regime de chuvas e outros à diminuição (KOUSKY; CAVALCANTI, 1984; KOUSKY; KAGANO; CAVALCANTI, 1984; ACEITUNO, 1988; PISCIOTTANO et al., 1994; ROPELEWSKI; HALPERT, 1989; CAVALCANTI, 2012).

Com o advento tecnológico dos Radares Meteorológicos, junto à técnica de previsão do tempo de curtíssimo prazo, denominada *nowcasting* (BROWNING, 1982), é possível realizar a emissão de alertas de tempestades severas em tempo real, o que torna-se de grande valia no estudo e na viabilização de procedimentos que possam ser executados em tempo hábil, prezando pela vida e patrimônio.

O *nowcasting* pode ser entendido como um conjunto de técnicas que combina a descrição das condições do tempo atuais e a extrapola a um momento posterior próximo. Para Browning (1982) esta definição é caracterizada pela extrapolação em um intervalo de até 2 horas, ao passo que Conway (1998) considera tal detalhamento em até 6 horas. Esta técnica têm evidente relevância se considerarmos que, embora haja uma significativa evolução da previsão do tempo numérica convencional, ainda há limitações nos resultados que envolvem as primeiras horas de simulação, na assimilação de grandes quantidades de dados, além de altos custos computacionais (NOVO, 2008).

O IPMet - Centro de Meteorologia de Bauru, unidade da Universidade Estadual Paulista UNESP, localizado em Bauru/SP, tem como objetivos a pesquisa meteorológica voltada à utilização em previsão do tempo para o estado de São Paulo, o monitoramento e quantificação de chuvas ocorrendo nessa mesma região com o uso de radar meteorológico e, além da pesquisa, presta serviços destinados a população do estado, aos meios de comunicação, a agricultores, Polícia Ambiental, Polícia Rodoviária, Corpo de Bombeiros, dentre outros. Destaca-se o trabalho destinado às Defesas Civas do Estado de São Paulo, cujo trabalho consiste em emitir alertas de ocorrência de tempestades severas em tempo real para fins de tomada de decisão, além de oferecer treinamentos para a utilização e interpretação de produtos meteorológicos gerados no instituto, todos possíveis graças à presença de dois radares meteorológicos instalados em Bauru/SP e Presidente Prudente/SP.

Bassan et al. (2015), utilizando dados dos radares meteorológicos do IPMet e estações meteorológicas automáticas de dois municípios, propôs uma equação de correção em solo de precipitação acumulada estimada por radar, como uma ferramenta de apoio à agricultura.

Figueiredo (2005) estudou a pluviometria na região central do Estado de São Paulo através de dados de radar meteorológico.

A meteorologia é, portanto, também uma ciência de notório caráter aplicado, uma

vez que seus objetos de estudo refletem no dia-a-dia do ser humano.

A complexa modelagem de fenômenos atmosféricos, a alta variabilidade de características e as diferentes interações entre eles fazem com que a Meteorologia trabalhe, em determinados campos, com teorias probabilísticas, sendo, por muitas vezes, divergentes entre os profissionais e estudiosos do meio, resultando em diferentes prognósticos.

Atualmente a Teoria dos Conjuntos *Fuzzy* (ZADEH, 1965), introduzida em 1965, por Lotfi Asker Zadeh, professor em Berkeley, Universidade da Califórnia, vem sendo desenvolvida e utilizada como uma ferramenta de grande utilidade na formulação de modelos meteorológicos como em diversos campos da ciência, dentre as quais citamos: a engenharia, agronomia, administração, tecnologia da informação e medicina.

A literatura apresenta diversos estudos que utilizam conceitos da lógica *fuzzy* para modelar fenômenos meteorológicos. Silva, Alves e Campos (2007) utilizaram a Teoria dos Conjuntos *Fuzzy* para otimização de prognósticos de consenso sazonal de chuva no nordeste do Brasil. Particularmente em meteorologia com radar, Berenguer et al. (2006) aplicaram técnicas de lógica *fuzzy* para identificar e filtrar alvos não meteorológicos identificados através de ecos de radar. Marzano et al. (2006) adotam os conceitos da lógica *fuzzy* em radares de dupla polarização para classificar hidrometeoros, estendendo-a de um radar banda S a um radar banda C. Yang, Chen e Qi (2013) propoem uma classificação dos ecos observados por radar meteorológico em convectivos ou estratiformes a partir de um algoritmo de lógica *fuzzy*.

Ao contrário da modelagem clássica, na teoria *fuzzy* são possíveis os valores intermediários, permitindo lidar com as incertezas e imprecisões. Esta pesquisa foi motivada pelo notável potencial dos Sistemas de Inferência *Fuzzy* (GOMIDE; GUDWIN, 1994; ROSS, 2009) na modelagem de fenômenos ambientais e sua aplicabilidade ao estudo de fatores que interferem nas interpretações físicas realísticas dos fenômenos atmosféricos detectados por radares meteorológicos.

## 1.1 Objetivos da Pesquisa

Com o advento tecnológico, Radares meteorológicos tem proporcionado dados com alta resolução espacial e temporal, uma vez que seu princípio de funcionamento se baseia na emissão de ondas eletromagnéticas para atmosfera a partir de uma antena rotativa, cujo raio de abrangência se dá em algumas centenas de quilômetros. A partir da magnitude e da energia retro espalhada pelos ecos, é definido o fator de refletividade  $Z$  (RINEHART, 2004). O radar produz uma medida indireta da taxa de precipitação  $R$  através de diferentes relações empíricas, chamadas de relações  $Z - R$  (MARSHALL; PALMER, 1948; JONES, 1956; ROSENFELD; WOLFF; ATLAS, 1993).

Nas últimas décadas estudos tem buscado otimizar as estimativas de precipitação por radar, aumentando a correlação com os dados observados nos pluviômetros. Algumas das técnicas mais utilizadas são a Krigagem (BERNDT; RABIEI; HABERLANDT, 2014), Regressão linear/correção do bias (YOO et al., 2014; RABIEI; HABERLANDT, 2015), composição condicional (SINCLAIR; PEGRAM, 2005) e inteligência artificial (redes neurais) (BELLERBY et al., 2000). Contudo, um dos grandes desafios no processo de otimização entre as medidas de radar e pluviômetro consiste em minimizar os diversos tipos de interferências que os radares meteorológicos estão sujeitos em suas medições no fator de refletividade  $Z$ , como o trajeto do feixe de ondas eletromagnéticas ao longo da distância, a presença de ecos de terreno, os fenômeno da super/subrefração e a banda brilhante, que podem subestimar sua intensidade em alguns casos e super estimar em outros (BATTAN, 1973; SAUVAGEOT, 1992; RINEHART, 2004; MEISCHNER, 2004).

Neste contexto, diversos estudos baseados em técnicas de filtragem estatística, inteligência artificial e reconhecimento de padrões têm sido propostos com o objetivo de tratar os diversos tipos de interferências.

Moszkowicz, Ciach e Krajewski (1994) propõe um classificador Bayesiano com o objetivo de indentificar a propagação anômala (PA) do feixe e ecos reais de precipiação usando, para isso, alguns critérios como a refletividade máxima, topo de eco, e gradientes horizontais. A diferença máxima entre um determinado pixel e seus vizinhos imediatos foi usada para explicação da ocorrência de ecos que não representavam precipitações.

Haddad et al. (2000) demonstra a capacidade das cadeias de Markov na modelagem do fenômeno de propagação anômala em ecos coletados por um radar banda S no sudoeste da França, em 1996, analisando um parâmetro de autocorrelação como um importante método de detecção de propagação anômala.

Krajewski e Vignal (2001a) utilizam a abordagem das redes neurais artificiais para classificar cerca de 10 000 volume coletados entre 1994 e 1995 pelo radar Tulsa, Oklahoma, WSR- 88D, tendo como critério a comparação com dados de pluviômetros.

Arai, Saka e Seto (2006) propõe uma reconstrução de cortes verticais em eventos de precipitação com dados de radar, baseado em análise wavelet de multi-resolução, identificando os picos de refletividade afim de detectar a altura da banda brilhante.

Islam et al. (2012) utiliza técnicas de inteligência artificial para identificação de fenômenos de propagação anômala, ecos de terreno e demais interferências a partir de dados de radar polarimétrico, tendo como parâmetros de análise o campo de refletividade, refletividade diferencial, coeficiente de correlação de corte, propagação de fase diferencial e velocidade espectral indicando a capacidade das técnicas na identificação, comparando ainda o resultado a abordagens Bayesianas.

Seo, Krajewski e Mishra (2015) estuda o efeito que a interação entre a propa-

gação anômala do feixe de radar (AP) e turbinas eólicas em estimativas da chuva por radar, propondo uma abordagem baseada na capacidade polarimétrica de variáveis como refletividade diferencial, correlação polar, e fase diferencial.

O campo de refletividade é, portanto, de suma importância tanto na estimativa de chuvas por radar, quanto no monitoramento de tempestades severas em tempo real. No estado de São Paulo, dois radares meteorológicos do IPMet, situados nos municípios de Bauru e Presidente Prudente, realizam a vigilância das tempestades e a estimativa de chuvas em superfície (BASSAN et al., 2015). A medida que os ecos se distanciam de um radar, o campo de refletividade tende a perder qualidade nas medições, devido aos fatores de interferências citados.

Este estudo propõe uma abordagem fuzzy, através de um sistema de inferência linear do tipo Takagi-Sugeno, no intuito de otimizar o campo de refletividade de ecos simultaneamente detectados a diferentes distâncias dos radares meteorológicos do IPMet, de maneira a obter maior concordância entre as medições realizadas por ambos os radares.

Cabe destacar que este sistema tem aplicações potencialmente úteis na área de análise e previsão de chuvas possibilitando a utilização de uma ferramenta de apoio à tomada de decisão para as instituições que emitem alertas de condições de tempestades severas em tempo real.

## 1.2 Organização do trabalho

O presente trabalho encontra-se dividido e organizado da seguinte forma:

No capítulo 2 é feita uma revisão bibliográfica a partir de obras clássicas e contemporâneas sobre Radares Meteorológicos, destacando desde seu princípio básico de funcionamento, componentes, características técnicas até as complexas interferências existentes na coleta de informações atmosféricas.

No capítulo 3 são revistos os conceitos fundamentais da Teoria dos Conjuntos *Fuzzy*, da Lógica *Fuzzy* e sua transposição em relação às Teorias Clássicas, evidenciando as potencialidades da modelagem *fuzzy* em ciências de caráter aplicado.

No capítulo 4 são apresentados todos os materiais e métodos utilizados para a elaboração da modelagem *fuzzy* proposta neste trabalho.

No capítulo 5 é realizada uma análise estatística da metodologia utilizada, assim como do desempenho do modelo.

E finalmente, no capítulo 6, as considerações finais e propostas de trabalhos futuros.

## 2 Radar Meteorológico

Um RADAR, acrônimo de *RAdio Detection And Ranging*, é um complexo sistema que usa da técnica de emissão de ondas eletromagnéticas para determinar a existência e explorar características de um determinado alvo. Em especial, radares meteorológicos são radares cuja aplicação se dá a fenômenos meteorológicos, podendo ser útil para determinar sua localização, seu movimento, na estimativa do tipo (chuva, granizo, neve), na previsão de sua severidade, além de previsão de comportamentos futuros (RINEHART, 2004).

Sauvageot (1992) evidencia vantagens do uso de radares em Meteorologia tais como:

- Possibilidade de realizar a teledetecção atmosférica ainda que a algumas centenas de quilômetros do alvo;
- O sinal de retorno ao radar independe da luz solar ou de qualquer reemissão dos alvos;
- Realizar medidas em 3 dimensões e em consideráveis volumes;
- As resoluções temporais e espaciais atendem à demanda de diversas aplicações cotidianas ligadas ou não à Meteorologia;
- A não perturbação do meio pelo qual as ondas são conduzidas, o que entende-se por radiação eletromagnética não ionizante.

### 2.1 Contexto Histórico

Não há um consentimento sobre um único personagem ou uma única nação que seja considerada a criadora da tecnologia de radares. O que se tem admitido é o fato de que esta tecnologia é resultante de um acúmulo de conhecimentos desenvolvidos por diversas nações de todo o mundo, tendo seu desenvolvimento impulsionado durante a Segunda Guerra Mundial (1939), onde foram utilizados no monitoramento de ataques inimigos pelos ingleses, uma vez que era possível determinar com relativa precisão a distância, velocidade e direção dos possíveis ataques, capacitando-os na emissão de alertas à população. Alemanha, Itália e Japão, denominadas potências do eixo, também debruçaram sobre a tecnologia de radar, entretanto com o objetivo de aperfeiçoar a precisão de seu equipamento bélico, melhorando o direcionamento em relação aos alvos. Durante a Guerra Fria, Estados Unidos e União Soviética usaram largamente esta tecnologia em função de seus conflitos.

Durante todo o seu desenvolvimento, alguns personagens tiveram notória contribuição, dos quais destacam-se:

**James Maxwell(1865)** Criou a Teoria de Propagação das Ondas Eletromagnéticas;

**Heinrich Hertz(1886)** Demonstrou, através das equações de Maxwell, as leis de reflexão das ondas de rádio;

**Guglielmo Marconi(1895)** Fez a junção entre as teorias de Maxwell e Hertz conseguindo realizar a primeira transmissão de telegrafia sem fio;

**Padre Landell de Moura (1899)** Brasileiro que conseguiu realizar a transmissão de voz a uma distância superior a 7km;

**Christian Hulsmeyer(1903)** Observou que as ondas de rádio eram refletidas por navios, patenteando a descoberta e, posteriormente, montando uma equipe destinada à ajudar nas navegações, evitando colisões dos navios;

**Watson Watt(1935)** Elaborou formas de avisar pilotos sobre a presença de tormentas.

## 2.2 Princípios Físicos de Funcionamento

Dos conhecimentos da ondulatória clássica, na Física, é evidenciado a relação entre duas grandezas das radiações eletromagnéticas: *frequência* e *comprimento de onda*. Por frequência  $f$  entende-se o número de ciclos de movimento produzido por um campo em um intervalo de tempo, cuja unidade de medida é dada em Hertz ( $Hz$ ). O comprimento de onda  $\lambda$  é a distância entre valores repetidos sucessivos num padrão de onda, cuja unidade de medida é metros ( $m$ ). A Equação 2.1 exhibe a relação entre  $f$  e  $\lambda$  (RINEHART, 2004).

$$c = \lambda f \tag{2.1}$$

Diferentes comprimentos de ondas utilizados por diferentes tipos de radares são referenciados por letras maiúsculas, tais como L, S, C, X, K, que dão a característica conhecida por *banda de trabalho*. As letras que indicam tal característica estão ligadas aos códigos de segurança usados em guerras e, portanto, sem conotação científica (FIGUEIREDO, 2005).

Hutchinson et al. (2000) e Rinehart (2004) apresentam a descrição da designação das bandas de trabalho e as respectivas frequências e comprimentos de onda utilizados, conforme descrito na Tabela 1.

As principais aplicações de uso de cada banda de trabalho, conforme descrito em Raghavan (2003), estão apresentadas na Tabela 2.

Semelhante ao sistema de ecolocalização de alguns seres vivos, a dinâmica de funcionamento de um radar meteorológico inicia-se na transmissão de pulsos de energia eletromagnética em intervalos de tempo regulares, concentrados em um feixe de uma antena rotativa. Os alvos iluminados pelo feixe do radar absorvem parte desta energia e

Tabela 1 – Bandas de Trabalho

<b>Designação de Banda</b>	$f$ [GHz]	$\lambda$ [cm]
VHF	0,03 † 0,3	1000 † 100
UHF	0,3 † 1	100 † 30
L	1 † 2	30 † 15
S	2 † 4	15 † 7,5
C	4 † 8	7,5 † 3,75
X	8 † 12,5	3,75 † 2,4
Ku	12,5 † 18	2,4 † 1,67
K	18 † 26,5	1,67 † 1,13
Ka	26,5 † 40	1,13 † 0,75

Fonte: Adaptada de Hutchinson et al. (2000)

Tabela 2 – Aplicações para diferentes bandas de trabalho


<b>Banda</b>	<b>Principais aplicações</b>
VHF e UHF	Observação de fenômenos de ar claro na troposfera e na estratosfera, perfis de vento, turbulência, estrutura de índice de refração.
L	Céu claro e fenômenos de precipitação.
S	Medição de precipitações, observação de ciclones tropicais, tempestades severas locais, a propagação de ondas de rádio.
C	Uso na aviação, medição de precipitações, observação de ciclones tropicais, tempestades severas locais, a propagação de ondas de rádio.
X	Deteção de temporais e frentes de rajadas, propagação de ondas de rádio, uso em aeronaves.
Ku e Ka	Física das nuvens, tetômetro, sensoriamento remoto, radar de abertura sintética para estudos marinhos, medição de precipitação de atenuação, observação de tornados

Fonte: Adaptada de Raghavan (2003)

irradiam-nas em diversas direções. A fração da energia que retorna ao radar é medida pelo receptor (Figura 1) e, assim, verificando-se o intervalo de tempo  $t$  entre a emissão e o retorno do eco, é possível determinar a distância  $r$  do alvo, uma vez que a velocidade de propagação das ondas é aproximadamente a velocidade da luz  $c$ . A equação 2.2 pode ser utilizada para determinar a distância  $r$  do alvo iluminado (SAUVAGEOT, 1992; RAGHAVAN, 2003; RINEHART, 2004; MEISCHNER, 2004).

$$r = \frac{ct}{2} \quad (2.2)$$

Figura 1 – Princípio Básico de Funcionamento de um Radar Meteorológico

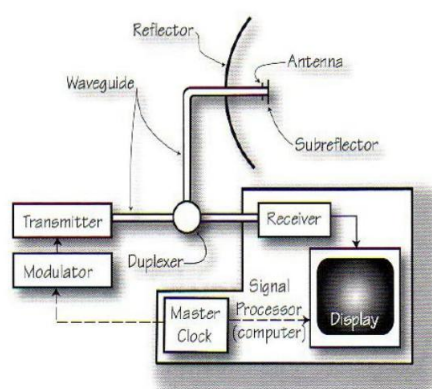


Fonte: <http://www.windows2universe.org/> (adaptada)

## 2.3 Componentes de um RADAR

Pode-se considerar que o sistema de radar é o resultado da união de um conjunto de técnicas e diversos outros subsistemas que, em sincronia, operam para determinada finalidade. A Figura 2 exibe um radar em diagrama de blocos.

Figura 2 – Sistema Radar - Diagrama de Blocos



Fonte: Rinehart (2004)

### 2.3.1 Transmissor (*Transmitter*)

O ponto de partida do processo de emissão de radiação eletromagnética, neste sistema, se dá através do transmissor. Este componente é responsável por gerar os sinais de alta frequência que viajam pela atmosfera. Segundo Rinehart (2004), há basicamente 3 tipos de transmissores mais importantes para finalidades meteorológicas: O *Magnetron*, *Klystron* e *Solid-State* (estado sólido). Neste trabalho detalhamos o transmissor do tipo *Magnetron*, presente nos radares meteorológicos utilizados nesta pesquisa.

- *Magnetron*: Criada por John Randall e Henry Boot, em 1939, consiste em uma válvula que gera um circuito oscilante, através de uma bateria, uma bobina e um

capacitor que passa por processos sucessivos de carga e descarga. Os elétrons vão do cátodo ao ânodo em espiral, fazendo com que o campo elétrico gere os sinais de microondas que, por sua vez, são captados por uma sonda e transmitidos para o guia de ondas.

### 2.3.2 Modulador (*Modulator*)

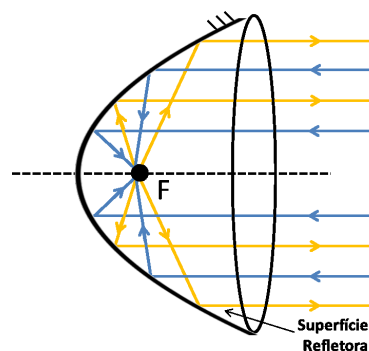
O modulador é o dispositivo que controla a dinâmica do transmissor, alternando seu ligamento/desligamento, de forma a obter o formato adequado dos pulsos de onda. Em outras palavras, este dispositivo controla o momento de funcionamento do transmissor e sua duração. Os pulsos eletromagnéticos são transmitidos durante determinado intervalo de tempo em uma dada frequência de repetição de pulso, o que entende-se por *PRF* (Pulse Repetition Frequency). Segundo Queiroz (2009), os radares convencionais operam com PRF de 150 a 300 *Hz* enquanto radares Doppler (capazes de determinar a velocidade radial de deslocamento dos alvos) operam entre 700 e 3000 *Hz*.

### 2.3.3 Antena (*Antenna*)

A antena, do tipo parabólica, é fixada a um pedestal e ligada a sensores de posicionamento que, de acordo com o movimento de seu eixo de rotação, determinam a direção de propagação do sinal transmitido e recebido pelo sistema. Referencia-se horizontalmente a posição da antena pelo norte geográfico ( $0^\circ = \text{Norte}$ ,  $90^\circ = \text{Leste}$ ,  $180^\circ = \text{Sul}$  e  $270^\circ = \text{Oeste}$ ), sendo este ângulo de posição chamado de *ângulo azimutal*. Na componente vertical a referência se dá do plano tangente à superfície terrestre ( $0^\circ$ ) ao zênite ( $90^\circ$ ), sendo esta referência chamada de *ângulo de elevação* da antena.

No foco da superfície parabólica situa-se o *alimentador*, dispositivo responsável pela conexão entre a linha de transmissão, o *guia de onda*, e a superfície refletora. Dos conhecimentos físicos de óptica, o sinal oriundo no foco se propaga na direção paralela ao eixo da parábola e todos os sinais de retorno, por sua vez, concentram-se no alimentador (Figura 3).

Figura 3 – Trajetória dos feixes entre o alimentador (F) e a superfície refletora



Tal capacidade de concentração da energia é denominada o *ganho*  $G$  da antena, expressa em decibéis ( $dB$ ). Esta grandeza representa a relação entre a potência recebida de um ponto específico do espaço com o valor ideal deste mesmo ponto segundo uma antena isotrópica, podendo ser expressa através da Equação 2.3.

$$G = 10 \log \frac{4\pi A}{\lambda^2}, \quad (2.3)$$

Onde:

- $G$ : Ganho da antena [dB];

- $A$ : Área do refletor [ $m^2$ ];

- $\lambda$ : Comprimento de onda [m].

Tridimensionalmente, a antena parabólica determina um feixe que tem a forma aproximada de um cone ao longo de sua trajetória. O ângulo  $\theta_v$  de abertura do vértice é o que define a largura do feixe e pode ser obtido, em graus, em função do comprimento de onda  $\lambda$  e do diâmetro da antena  $D_a$  (parabólica circular, iluminada no foco) através da Equação 2.4 (DOVIAK; ZRNIC, 1993).

$$\theta_v = \frac{72,76\lambda}{D_a} \quad (2.4)$$


A medida que  $r$  aumenta, o volume iluminado pela antena  $V_i$  aumenta na ordem de  $r^2$  (quadrado da distância). Alvos detectados neste volume serão tratados como um único. Assim sendo  $V_i$  representa a resolução volumétrica do radar (SAUVAGEOT, 1992; RINEHART, 2004). Obtem-se  $V_i$  através da Equação 2.5.

$$V_i = \frac{\pi r^2 \theta_0 \phi_0 h}{16 \ln 2} \quad (2.5)$$

Sendo  $\theta_0$  e  $\phi_0$  os ângulos na horizontal e vertical, respectivamente, de -3dB (onde metade da potência sinal está concentrada) e  $h$  a largura do pulso correspondente ao tempo de duração transmitido ao volume, conforme ilustrado pela Figura 4.

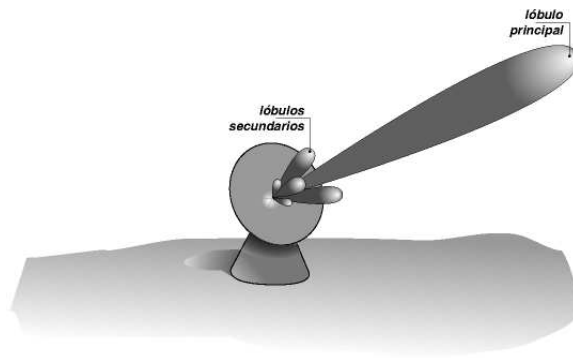
O eixo central, denominado *lóbulo principal*, é o local onde o ganho da antena é máximo, entretanto existem interferências ao redor desta região, o que é conhecido por *lóbulos secundários*. Estas interferências são, geralmente, as responsáveis por gerarem ruídos próximos ao radar, quando a elevação da antena é baixa. Isso ocorre devido ao fato de que parte dos sinais transmitidos direcionam-se na direção dos lóbulos secundários, que produzem ecos de terreno tais como as edificações e a vegetação. A Figura 5 ilustra a radiação nos lóbulos principal e secundário.

Figura 4 – Volume iluminado pelo pulso do radar



Fonte: (QUEIROZ, 2009).

Figura 5 – Lóbulos principal e secundários



Fonte: <http://www.crahi.upc.edu/curs/graficos/lobulos.gif>

A altura do feixe do radar sofre variações em função da sua distância percorrida, uma vez que o feixe tem sua propagação em trajetória aproximadamente linear, não acompanhando a trajetória da superfície terrestre (SAUVAGEOT, 1992; RINEHART, 2004; FIGUEIREDO, 2005; BASSAN et al., 2015).

A altura  $H$  do feixe de ondas eletromagnéticas pode ser determinada aproximadamente por:

$$H = r \operatorname{sen} \theta + \frac{r^2}{2r_e} \quad (2.6)$$

Onde:

$H$ : Altura do feixe [km];

$R$ : Distância percorrida [km];


$\theta$ : Ângulo de inclinação da Antena em relação ao plano tangente à superfície terrestre;

$r_e$ : Raio da Terra (aproximadamente 6371 km).

A figura 6 mostra a trajetória da altura do feixe de ondas eletromagnéticas do


radar meteorológico de Bauru, em função da distância percorrida e o ângulo de elevação da antena.

Figura 6 – Variação da altura do feixe em função de R e  $\theta$ .



Próximo ao radar, o feixe de ondas eletromagnéticas tem baixa altitude, fazendo com que seja possível observar fenômenos meteorológicos mais próximos da superfície. Em contrapartida, a medida em que o feixe se distancia do radar sua altitude também aumenta, podendo ultrapassar núcleos de precipitação intensos mais próximos da superfície. Costuma-se dizer que, neste caso, a longas distancias, o feixe do radar somente é capaz de coletar informações do "topo das tempestades", onde os valores de refletividade não condizem, necessariamente, com a realidade do fenômeno meteorológico em superfície, super estimando-o em alguns casos (caso o feixe passe por um volume com presença de granizo) e subestimando em outros (quanto o núcleo mais intenso da tempestade está em altitudes menores que a do feixe). A Figura 7 ilustra a situação descrita.

Figura 7 – Aumento da altitude do feixe ao longo da distância



Fonte: <http://www.srh.noaa.gov/images/bmx/radar/radarsfc.jpg>

### 2.3.4 Radome

Instalada no topo de uma torre com altura na ordem de 10 a 15 metros, a superfície da antena fica exposta e sujeita à uma alta resistência do vento, assim como ao demais elementos comuns às variações do tempo. Estes fatores geram fragilidades ao sistema mecânico responsável pela movimentação, além da integridade dos materiais como um todo. Neste sentido, utiliza-se um domo esférico, chamado Radome (do inglês *radar dome*) para o isolamento da antena, protegendo-a destes agentes do tempo e, também, garantindo uma velocidade de rotação constante. Usualmente, o Radome é fabricado em fibra de vidro, garantindo uma quase total transparência à energia eletromagnética, com atenuação de até 2dB (SAUVAGEOT, 1992).

## 2.4 A Equação do Radar

A partir de potência da energia que retorna ao radar (refletividade do alvo), torna-se possível estimar informações sobre a natureza dos alvos detectados. Neste sentido, a *Equação do Radar* têm papel fundamental na relação entre a potência recebida e a secção transversal retro-espalhada do alvo (RINEHART, 2004). As considerações seguintes podem ser encontradas em inúmeras obras clássicas, tais como (BATTAN, 1973; SKOLINK, 1990; SAUVAGEOT, 1992; DOVIK; ZRNIC, 1993; RAGHAVAN, 2003; RINEHART, 2004; MEISCHNER, 2004).

A refletividade  $Z$  do alvo é estimada a partir da energia de retorno  $P_R$  que, por sua vez, têm dependência nas características técnicas da antena, das condições de propagação, da distância dos alvos e a magnitude do alvo em relação a sua refletividade  $Z$ . A equação do radar é dada por:

$$P_R(r) = \frac{\pi^2 P_T G^2 G_R \Theta^2 c \tau |K|^2 Z}{2^{10} \ln(2) \lambda^2 r^2 L_{atm}^2 L_{MF}} \quad (2.7)$$

Onde:

$P_T$  Potência de Pico transmitido pela antena;

$G$  Ganho total da antena;

$G_R$  Ganho total do receptor (considerando perdas no caminho);

$\Theta$  Largura do feixe de 3dB;

$|K|$  Constante Dielétrica (0,93 para chuva e 0,2 para gelo e neve);

$\lambda$  Comprimento de onda transmitido;

$L_{atm}$  Atenuação atmosférica entre a antena e o alvo;

$L_{MF}$  Perdas oriundas de filtros;

$\tau$  Comprimento do pulso transmitido.

A refletividade  $Z$  é medida em  $mm^6m^{-3}$ , representando o espalhamento da secção transversal de todos os hidrometeoros presente em um volume de  $1m^3$ , em proporção à sexta potência do diâmetro das gotas. Este fato decorre do conhecido fenômeno de espalhamento de Rayleigh. Assim, a refletividade é obtida por:

$$Z = \int_0^{\infty} D^6 N_v(D) dD \quad (2.8)$$

Onde:  $D$  e  $N_v(D)$  são funções do diâmetro e distribuição das gotas no volume amostrado (DUTTA et al., 2011).

No sentido de trabalhar com valores de ordem conveniente é adotada a unidade  $dBZ$ , que representa uma escala logarítmica de  $Z$ , conforme a Equação 2.9.

$$dBZ = 10 \log Z \quad (2.9)$$

Desta maneira, se em um volume amostrado a refletividade é da ordem de  $10^5 mm^6 m^{-3}$ , por exemplo, sua refletividade  $Z$  será de  $50dBZ$ .

A Tabela 3 exibe uma classificação linguística da intensidade dos ecos detectados por radar em função da sua refletividade, tendo sido apresentada por Falconer (1984).

Tabela 3 – Classificação linguística em termos de  $dBZ$

dBZ	Intensidade do Eco
<30	Fraca
30-41	Moderada
41-46	Forte
46-50	Muito Forte
50-57	Intensa
>57	Extrema

Fonte: Adaptada de Falconer (1984)

## 2.5 Propagação Anômala

Assim como ocorre com feixe de luz, segundo a Lei de Snell, condições atmosféricas como diferenças de densidades causadas pela variação da temperatura, umidade e pressão, fazem com que a propagação do feixe de ondas eletromagnéticas sofra desvio em seu percurso. Este fenômeno é conhecido como *Propagação Anômala - PA* (RINEHART, 2004).


O fenômeno natural da inversão térmica, por exemplo, faz com que o feixe seja desviado de sua trajetória padrão e direcionado para a superfície terrestre, o que é chamado

de *super refração*, comumente observados no período da noite e nas primeiras horas do período da manhã.

Embora com maior raridade de ocorrência, o feixe também pode sofrer desvio para maiores altitudes (ao invés de direcionado a superfície). Este fenômeno é conhecido como *sub refração*.

Como consequência desses dois tipos de PA, pode ocorrer o aprisionamento do feixe na faixa para o qual foi desviado, impedindo-o de retornar ao seu trajeto normal. Este tipo de PA é chamado de *Duto*. Os diferentes tipos de Propagação Anômala estão ilustrados na Figura 8.

Figura 8 – Propagação Anômala - Desvio na trajetória do feixe eletromagnético



Fonte: [http://www.srh.noaa.gov/jetstream/doppler/beam\\_max.htm](http://www.srh.noaa.gov/jetstream/doppler/beam_max.htm)

Qualquer que seja o tipo de PA ocorrida, o fato é que a coleta de informações dos ecos por radar sofre interferências sendo, portanto, necessário procedimentos de identificação e filtragem de fenômenos de propagação anômala e de ecos de terreno.

Um dos primeiros trabalhos que destacou a importância do tratamento deste fenômeno pode ser consultado em Browning (1978).

Atualmente a literatura que trata de identificação, classificação, tratamento e filtragem de PA é bastante vasta, de maneira que, neste trabalho, foram revisados alguns trabalhos relevantes da problemática.

Moszkowicz, Ciach e Krajewski (1994) propôs um classificador Bayesiano com o objetivo de identificar PA e ecos reais de precipitação usando, para isso, alguns critérios tais como a refletividade máxima, top de eco, e gradientes horizontais. A diferença máxima entre um determinado pixel e seus vizinhos imediatos foi usada para explicar a ocorrência de ecos que não representam precipitações.

Steiner e Smith (2002) utilizaram um classificador do tipo árvore de decisão para detecção de PA, sendo consideradas as variáveis extensão vertical dos ecos de radar, sua

variabilidade espacial e o gradiente de intensidade do eco.

Ryzhkov e Zrnic (1998) demonstram que o coeficiente de correlação entre os sinais de retroespalhamento polarizados horizontalmente e verticalmente, a variabilidade local da diferença de fase total podem ser bons identificadores de dados contaminados por PA, estudando, ainda, a estimativa de chuvas em ecos com presenças de PA.

Krajewski e Vignal (2001b) utilizam a abordagem das redes neurais artificiais para classificação de cerca de 10 000 volume coletados entre 1994 e 1995 pelo radar Tulsa, Oklahoma, WSR- 88D, tendo como critério a comparação simples com dados de pluviômetros.

Mesnard e Sauvageot (2010) analisa a climatologia de ecos contaminados por PA, coletados por um radar banda S na costa sudoeste da França, evidenciando a forte correlação com as características orográficas e topográficas da região.

No IPMet, a filtragem adotada levou em conta os campos de refletividade e vento radial, através da análise de suas respectivas matrizes de dados, desconsiderados quaisquer valores de refletividade inferiores a 15 dBZ. Foram analisados o gradiente do campo refletividade e a ocorrência da velocidade radial nas posições circunvizinhas ao ponto analisado e os resultados indicam que o filtro é capaz de identificar grande parte da PA sem interferir significativamente em áreas de precipitação (IPMet/ UNESP, 1998)

## 2.6 Banda Brilhante

O fenômeno conhecido por Banda Brilhante (BB) consiste em uma camada de alta refletividade formada devido ao derretimento do gelo (SAUVAGEOT, 1992; RAGHAVAN, 2003; RINEHART, 2004; MEISCHNER, 2004).

Em altitudes acima da linha isoterma de zero graus, o gelo cai com uma velocidade mais lenta e quando atinge essa isoterma entra em processo de fusão.


Neste momento, o gelo ainda está com temperatura menor do que a temperatura de congelamento, acarretando no início de seu derretimento de fora para dentro. Consequentemente, forma-se um revestimento de água sobre o gelo, ainda permanecendo em formato grande e irregular.

Logo, um radar que detecta este gelo interpreta-o como se fosse uma grande gota de água, aumentando o valor da refletividade lida pelo radar.

A banda brilhante, portanto, pode causar significativos erros no cálculo da taxa de precipitação, uma vez que para tal usa-se o fator de refletividade do eco observado. A Figura 9 ilustra este fenômeno.

O tratamento do fenômeno da banda brilhante pode ser consultado em uma gama

Figura 9 – Fenômeno da Banda Brilhante próximo à isoterma de zero grau



Fonte:

[http://wx.db.erau.edu/faculty/mullerb/Wx365/Bright\\_band/bright\\_band.html](http://wx.db.erau.edu/faculty/mullerb/Wx365/Bright_band/bright_band.html)

de estudos dentre os quais citamos Austin e Bemis (1950), Smith (1986), Huggel, Schmid e Waldvogel (1996), Smyth e Illingworth (1998), Sánchez-Diezma, Zawadzki e Sempere-Torres (2000) podem ser consultados para maiores esclarecimentos.

## 2.7 Coleta de Dados dos Radares Meteorológicos de Bauru e Presidente Prudente

### 2.7.1 Os Produtos *Plan Position Indicator* e *Constant Altitude Plan Position Indicator*

As informações sobre os alvos presentes na atmosfera são coletadas e registradas em função do ângulo azimutal e do ângulo de elevação. Os radares meteorológicos do IPMet operam de maneira ininterrupta, executando tarefas programadas de coleta de dados meteorológicos. Em situações onde não há presença de alvos meteorológicos, a cada hora, uma tarefa de coleta de dados meteorológicos é acionada, cujo ângulo de elevação é fixado, com capacidade de alcance de um raio de 450 km do radar. Esta tarefa é chamada de *Plan Position Indicator* (PPI) (??FIGUEIREDO, 2005; BASSAN et al., 2015).

Por ser operada em apenas um ângulo de elevação, a tarefa PPI não permite estimativa volumétrica da chuva.

Para se obter dados volumétricos de chuva, a tarefa denominada *Constant Altitude Plan Position Indicator* (CAPPI) é escalonada.

A tarefa CAPPI, por sua vez, possui um raio de abrangência de apenas 240km. Entretanto, ela é capaz de realizar uma varredura rica em informações tridimensionais das chuvas localizadas neste raio de cobertura, uma vez que a tarefa CAPPI opera com 16


ângulos de elevação. A partir do momento que a tarefa CAPPI é escalonada, gera-se um produto a cada 7,5min, totalizando 8 varreduras por hora.

Após todas as varreduras, projeta-se partes dos dados de refletividade coletados em um plano horizontal, através de interpolação, localizado em altitude constante.

O IPMet adota, como altitude constante, o plano de 3,5km. Esta escolha se baseia, entre muitos fatores, na experiência de que nesta altitude os produtos CAPPI parecem estar menos contaminados por ecos de terrenos e demais inteferências.

As tarefas PPI e CAPPI podem ser observadas na Figura 10.

Figura 10 – Ilustração das tarefas PPI e CAPPI



Fonte: Bassan et al. (2015)

## 2.8 Calibração de radares meteorológicos

O crescente uso de radares meteorológicos em aplicações cotidianas possibilitou a compreensão do fato de que embora fossem geradas informações de alta resolução espacial e temporal, diversos fatores interferem nas medições realizadas, como a atenuação pelo radome (GORGUCCI et al., 2013), a presença de cristais de gelo nos ecos, as relações entre reletividade e taxa de precipitação (AUSTIN, 1987), subestimando-as em alguns casos e superestimando em outros (RABIEI; HABERLANDT, 2015). Desta maneira, torna-se necessário que sejam desenvolvidos métodos a fim de minimizar o efeito destes fatores (MOREAU; TESTUD; BOUAR, 2009; PEDERSEN; JENSEN; MADSEN, 2010; THORND AHL; RASMUSSEN, 2012; RABIEI; HABERLANDT, 2015).

Rabiei e Haberlandt (2015) consideram a grande variabilidade e discordância entre os valores de precipitação encontrados em pixels pelo radar e o respectivos valores observados na rede de pluviômetros. Neste estudo é proposto um mapeamento quantil do

erro sistemático (bias), análises de variogramas e semi-variogramas, com o objetivo de melhor ajustar os dados. Os resultados indicam que há maior variação entre a qualidade dos dados de radar no verão e inverno, sendo o verão de menor qualidade e o inverno maior qualidade.

Pedersen, Jensen e Madsen (2010) realiza um estudo em um período de 5 meses de dados de um radar banda X que opera para fins hidrológicos na Dinamarca, e uma rede de estações em uma área de 500x500m, propondo um método linear de calibração do radar ao invés de lei exponencial entre refletividade e precipitação utilizada convencionalmente em dados de radares. Os resultados indicam que é possível ocorrer redução nas incompatibilidades em um fator de até 50% através desta metodologia.

Thorndahl e Rasmussen (2012) analisam 3 métodos lineares para estimação de um parâmetro, denominado parâmetro de calibração, de forma a otimizar dados de um radar banda X e os dados de pluviômetros no período de Julho de 2008 a Maio de 2010. Os resultados indicam que similaridade entre os 3 métodos nos volumes de precipitação, entretanto maior divergência em pico de intensidade das chuvas.

## 3 Conjuntos *Fuzzy*, Lógica *Fuzzy* e Sistemas de Inferência *Fuzzy*

A humanidade tem buscado, ao longo de sua existência, desenvolver sua capacidade de entendimento, tratamento e manipulação de complexos fenômenos naturais baseados em informações subjetivas, imprecisas ou aproximadas. Do ponto de vista da Modelagem Matemática, a subjetividade observada na linguagem natural está presente desde a formulação de problemas simples do cotidiano, assim como em complexos campos da ciência tais como na Medicina (no entendimento da evolução do câncer, por exemplo), na Meteorologia (na modelagem de fenômenos atmosféricos), na Economia (no entendimento oscilatório do mercado), nas Ciências Ambientais (no estudo de Impacto Ambiental), dentre outras.

Termos linguísticos tais como "*muito*", "*pouco*", "*levemente*", "*extremamente*", "*em torno de*", "*alto*", "*baixo*", "*forte*", "*fraco*" são exemplos (dentre uma infinidade) de sentenças subjetivas na modelagem de um problema.

Neste sentido, em seu trabalho pioneiro denominado *Fuzzy Sets* (ZADEH, 1965), Lotfi Askar Zadeh propôs a chamada Teoria dos Conjuntos *Fuzzy* com o objetivo de possibilitar, através de um aparato matemático, a sistematização de termos imprecisos ou vagos na modelagem de problemas das mais diversas áreas do conhecimento.

Posteriormente, a chamada *Lógica Fuzzy* decorreu dos conceitos da Teoria dos Conjuntos *Fuzzy* de maneira a tornar os conceitos da Lógica Clássica casos particulares.

Este capítulo apresenta os principais conceitos da Teoria dos Conjuntos *Fuzzy* e da Lógica *Fuzzy*, assim como de mecanismos de inferência capazes de lidar com o chamado raciocínio aproximado, destacando a transposição da teoria/lógica clássica para seu âmbito difuso.

### 3.1 Teoria dos Conjuntos *Fuzzy*

#### 3.1.1 Fundamentos

Na teoria clássica de conjuntos, é de interesse o estudo da relação entre um dado elemento  $x$  e um conjunto  $A$  de um universo  $X$ , de maneira a dizer se o elemento  $x$  *pertence* ou *não pertence* ao conjunto  $A$ . Esta relação é traduzida através de uma *função característica* (GOMIDE; GUDWIN, 1994; BARROS; BASSANEZI, 2006).

**Definição 1.** *Seja  $A \subset X$  e  $x$  um elemento do universo  $X$ . Uma função característica*

$f_A: X \rightarrow A$  de um elemento  $x$  em um conjunto  $A$  é definida por:

$$f_A(x) = \begin{cases} 1, & \text{se } x \in A, \\ 0, & \text{se } x \notin A. \end{cases}$$

Esta função traduz o *Princípio do Terceiro Excluído* que, em proposições lógicas, afirma que ela ou é verdadeira ou é falsa (FEITOSA, 2005).

Zadeh, entretanto, notou que existem uma infinidade de relativismos e dubiedades da linguagem que podem não concordar com o princípio do terceiro excluído. Em outras palavras seria possível encontrar situações pela qual julgamos que, de certa maneira, um elemento pode apresentar maior similaridade com um conjunto do que outros elementos. Com o objetivo de dar melhor tratamento matemático para fenômenos desse tipo, propôs uma caracterização mais ampla da função característica, de modo a ser capaz de assumir infinitos valores no intervalo  $[0, 1]$ . Assim sendo, se na Teoria Clássica dos conjuntos uma pessoa de 1,8m de altura tem valor de pertinência 0 em relação ao "conjunto das pessoas baixas", na Teoria dos Conjuntos *Fuzzy* ela poderá ter grau de pertinência 0,3 uma vez que pode-se considerar que pessoas com 1,8m é relativamente baixa em relação a uma pessoa de 2m de altura.

Desta maneira, podemos definir um *Conjunto Fuzzy* através da nova concepção da função característica, como segue.

**Definição 2.** *Seja  $A \subset X$  e  $x$  um elemento do universo  $X$ . Um Conjunto Fuzzy  $A$  é definido por todos os pares ordenados  $(x, \mu_A(x))$  onde  $\mu_A(x): X \rightarrow [0, 1]$  é a função de pertinência de um elemento  $x$  em um conjunto  $A$ . Dizemos que  $\mu_A(x)$  é o grau de pertinência do elemento  $x$  em relação ao conjunto  $A$ . Assim:*

$$A = \{(x, \mu_A(x)) \mid x \in X\}$$

Podemos, portanto, concluir que o grau de pertinência  $\mu_A(x)$  traduz o nível de compatibilidade de  $x$  com a propriedade  $P$  que caracteriza o conjunto  $A$ , sendo  $\mu_A(x)=1$  se há uma completa compatibilidade entre  $x$  e  $P$ , e  $\mu_A(x)=0$  caso não haja compatibilidade alguma entre  $x$  e  $P$ .

Evidentemente poderá haver um número elevado de elementos em um universo  $X$  de modo que  $\mu_A(x)=0$  sendo, portanto, desnecessária sua escrita em  $A$ . Assim, define-se o *Suporte* de  $A$  no universo  $X$ .

**Definição 3.** *O Suporte de um conjunto fuzzy  $A$ ,  $\text{sup } A$ , é formado por todos os elementos  $x \in X$  tais que  $\mu_A(x) > 0$ .*

$$\text{sup } A = \{x \in X \mid \mu_A(x) > 0\}$$

Se um conjunto *fuzzy*  $A$  é tal que  $\text{sup } A$  possui um único elemento  $\delta$  tal que  $\mu_A(\delta) = 1$  dizemos que  $A$  é um conjunto *unitário* ou, ainda, *singleton*.

### 3.1.2 Definições e Operações

Nesta seção, serão introduzidas algumas definições e operações da teoria dos conjuntos *fuzzy*, analogamente ao que se faz na teoria clássica. Dados dois conjuntos  $A \subset X$  e  $B \subset X$  definimos:

**Definição 4.** Um conjunto *fuzzy*  $A$  é vazio se e somente se todo elemento  $x$  do universo  $X$  tem pertinência  $\mu_A(x) = 0$ .

$$A = \emptyset \iff \forall x \in X, \mu_A(x) = 0$$

**Definição 5.** O conjunto *fuzzy*  $A^c$  é o complemento de  $A$  se os elementos  $x$  do universo  $X$  são tais que  $\mu_{A^c}(x) = 1 - \mu_A(x)$ . Assim:

$$A^c = \{(x, 1 - \mu_A(x)) \mid x \in X\}$$

**Definição 6.** Os conjuntos *fuzzy*  $A$  e  $B$  são iguais se todos os elementos  $x$  do universo  $X$  têm o mesmo grau de pertinência em relação aos conjuntos  $A$  e  $B$ .

$$A = B \iff \mu_A(x) = \mu_B(x) \forall x \in X$$

**Definição 7.** O conjunto  $A$  é subconjunto de  $B$  se para todos os elementos  $x$  do universo  $X$  o grau de pertinência  $\mu_A(x)$  é menor ou igual ao grau de pertinência  $\mu_B(x)$

$$A \subset B \iff \mu_A(x) \leq \mu_B(x), \forall x \in X$$

As operações entre conjuntos *fuzzy* são realizadas a partir de funções do tipo *norma triangular* (t-norma) e *co-norma triangular* (s-norma). Definidas como segue:

**Definição 8.** Uma t-norma é uma aplicação  $\Delta : [0, 1] \times [0, 1] \rightarrow [0, 1]$  tal que,  $\forall x, y, z, w \in [0, 1]$  verificam-se:

- (i) *Comutatividade*:  $x \triangle y = y \triangle x$
- (ii) *Associatividade*:  $(x \triangle y) \triangle z = x \triangle (y \triangle z)$
- (iii) *Monotonicidade*:  $x \triangle w \leq y \triangle z$ , se  $x \leq y, w \leq z$
- (iv) *Identidade*:  $x \triangle 1 = x$

**Definição 9.** Uma *s-norma* (ou *t-conorma*) é uma aplicação  $\nabla : [0, 1] \times [0, 1] \rightarrow [0, 1]$  tal que,  $\forall x, y, z, w \in [0, 1]$  verificam-se:

- (i) *Comutatividade*:  $x \nabla y = y \nabla x$
- (ii) *Associatividade*:  $(x \nabla y) \nabla z = x \nabla (y \nabla z)$
- (iii) *Monotonicidade*:  $x \nabla w \leq y \nabla z$ , se  $x \leq y, w \leq z$
- (iv) *Identidade*:  $x \nabla 0 = x$

### 3.1.3 Variáveis Linguísticas

O conceito de variáveis linguísticas desempenha um papel importante na Teoria dos Conjuntos *fuzzy*. Em contraponto à ideia de que uma variável, em geral, é descrita por um número as variáveis linguísticas apresentam-se como variáveis cujos valores são nomes de conjuntos *fuzzy* (GOMIDE; GUDWIN, 1994).

Intuitivamente, como sugere Barros e Bassanezi (2006), uma variável linguística é um substantivo, enquanto seus valores são adjetivos, representados por conjuntos *fuzzy*. Por exemplo, para a estatura de uma determinada pessoa podemos valorá-la através dos termos linguísticos Baixa, Mediana e Alta. Neste caso, "altura" é a variável linguística e seus valores são dados pelos atributos "Baixa, Mediana e Alta".

De um modo geral, essas variáveis permitem uma caracterização aproximada de vários fenômenos por meio de uma descrição linguística.

Formalmente, assim como descrito por Gomide e Gudwin (1994), uma variável linguística é caracterizada por uma quintupla  $(X, T(X), U, G, M)$ , onde:

$X$ : Nome da variável;

$T(X)$ : Conjunto de termos de  $X$  (valores linguísticos de  $X$ );

$U$ : Universo de discurso;

$G$ : Regra Sintática para gerar os valores de  $X$  como uma composição de termos  $T(X)$ , conectivos lógicos, modificadores e delimitadores;

$M$ : Regra semântica, para associar a cada valor gerado por  $G$  um conjunto *fuzzy* em  $U$ .

## 3.2 Lógica Fuzzy

É vasto da literatura o uso do termo "Lógica Fuzzy" tratado, basicamente, de duas maneiras: a primeira de forma a representar e manipular informações inexatas com o propósito de tomar decisões, lançando mão da teoria dos conjuntos *fuzzy*, de suas funções de pertinência e suas álgebras em geral; a segunda diz respeito à extensão da lógica clássica (BARROS; BASSANEZI, 2006). Raciocínios do tipo:

"Todo homem é mortal;

Socrates é homem;

Logo, Sócrates é mortal"

são ditos Silogismos, estrutura objetiva fundamental pela qual a Lógica Clássica permeia.

Assim como esclarece Barros e Bassanezi (2006):

*"...embora as premissas e conclusões obtidas através da lógica fuzzy sejam subjetivas, isso não significa nenhum tipo de retrocesso de modo a se debater novamente com aquelas questões de interpretações pré-aristotélicas. A lógica fuzzy é de fato uma lógica (área do conhecimento que estuda consequências) com suas metodologias próprias (...). Ela não lida com questões ambíguas. As incertezas com as quais ela lida são do tipo monotônicas no sentido que quanto menos incertas forem as premissas, menos incertas serão as conclusões. Nesse sentido, intuitivamente, podemos dizer que a lógica clássica é uma espécie de limite da lógica fuzzy quando as incertezas tendem a zero."*

### 3.2.1 Conectivos fundamentais da Lógica Clássica

Os conectivos "e", "ou", "não" e "implicação" são os objetos iniciais nos estudos em lógica matemática. Estes conectivos estão presentes em sentenças lógicas do tipo:

"Se  $a$  está em  $A$  e  $b$  está em  $B$ , **então**  $c$  está em  $C$  **ou**  $d$  não está em  $D$ ".

Estuda-se os valores lógicos dos conectivos através das chamadas "Tabelas Verdade".

Assim, por exemplo, a sentença:

*"a está em  $A$  e  $b$  está em  $B$ "*

é verdadeira apenas se for verdade que  $a$  está em  $A$  e também que  $b$  está em  $B$ . Esta sentença expressa uma consequência para o conectivo "e".

Na lógica clássica, adota-se valor lógico 1 para sentenças ditas verdadeiras e 0 para sentenças ditas falsas. Pensando sobre a transposição para o caso *fuzzy*, usa-se a notação  $\wedge$  (mínimo) para a conjunção **e**; usa-se a notação  $\vee$  (máximo) para o conectivo **ou**;  $\neg$  para a **negação** e  $\longrightarrow$  para a **implicação**.

Assim, dadas as proposições  $p$  e  $q$ , as tabelas verdades para os conectivos são:

Tabela 4 – Tabela verdade de  $\wedge$

$p$	$q$	$p \wedge q$
1	1	1
1	0	0
0	1	0
0	0	0

Tabela 5 – Tabela verdade de  $\vee$

$p$	$q$	$p \vee q$
1	1	1
1	0	1
0	1	1
0	0	0

Tabela 6 – Tabela verdade de  $\longrightarrow$

$p$	$q$	$p \longrightarrow q$
1	1	1
1	0	0
0	1	1
0	0	1

Tabela 7 – Tabela verdade de  $\neg$

$p$	$\neg p$
1	0
0	1

Os valores dos conectivos coincidem com as respectivas tabelas verdades, fato que justifica as notação de  $\wedge$  para **e** e  $\vee$  para **ou**. De fato:

- Conectivo **e**:  $\wedge$ .

$$\begin{aligned} \wedge: \{0, 1\} \times \{0, 1\} &\rightarrow \{0, 1\} \\ (p, q) &\mapsto \wedge(p, q) = p \wedge q = \min\{p, q\}. \end{aligned}$$

O que resulta em:

$$\begin{aligned} \wedge(1, 1) &= 1 \wedge 1 = 1; \\ \wedge(1, 0) &= 1 \wedge 0 = 0; \\ \wedge(0, 1) &= 0 \wedge 1 = 0; \\ \wedge(0, 0) &= 0 \wedge 0 = 0; \end{aligned}$$

- Conectivo *ou*:  $\vee$ .

$$\begin{aligned} \vee: \{0, 1\} \times \{0, 1\} &\rightarrow \{0, 1\} \\ (p, q) &\mapsto \vee(p, q) = p \vee q = \max\{p, q\}. \end{aligned}$$

O que resulta em:

$$\begin{aligned} \vee(1, 1) &= 1 \vee 1 = 1; \\ \vee(1, 0) &= 1 \vee 0 = 1; \\ \vee(0, 1) &= 0 \vee 1 = 1; \\ \vee(0, 0) &= 0 \vee 0 = 0; \end{aligned}$$

- Conectivo *implicação*:  $\longrightarrow$ .

$$\longrightarrow: \{0, 1\} \times \{0, 1\} \rightarrow \{0, 1\}$$

Este conectivo pode ser definido em função dos dois conectivos anteriormente apresentado e, assim, obter as seguintes sentenças que reproduzem a tabela verdade da implicação:

$$1) (p \longrightarrow q) = (\neg p) \vee q;$$

$$2) (p \longrightarrow q) = (\neg p) \vee (p \wedge q);$$

$$3) (p \longrightarrow q) = \max\{x \in \{0, 1\} : p \wedge x \leq q\};$$

De fato:

$$\longrightarrow (1,1) = 1 \longrightarrow 1 = (\neg 1) \vee 1 = 1 ;$$

$$\longrightarrow (1,0) = 0 \longrightarrow 0 = (\neg 1) \vee 0 = 0 ;$$

$$\longrightarrow (0,1) = 1 \longrightarrow 1 = (\neg 0) \vee 1 = 1 ;$$

$$\longrightarrow (0,0) = 0 \longrightarrow 0 = (\neg 0) \vee 0 = 0 ;$$

Observamos que, para o caso da Lógica Clássica, as sentenças somente podem ser valoradas de acordo com o valor lógico atribuído às premissas que a compõem. Desta forma, o valor lógico da sentença coincide com o valor lógico da composição das premissas, dadas pela função característica em seu formato clássico, 0 ou 1.

Veremos que este fato, fundamentalmente, é diferenciado na lógica *fuzzy*.

### 3.2.2 Conectivos fundamentais da Lógica *Fuzzy*

Dados os conjuntos *fuzzy*  $A$  e  $B$ , as *s-normas* são utilizadas para definir a união de dois conjuntos  $A \cup B$  e as *t-normas* são, usualmente, utilizadas para definir a intersecção de dois conjuntos *fuzzy*  $A \cap B$ .

Assim, podemos definir as operações de união e intersecção de conjuntos *fuzzy*:

**Definição 10.** A união de dois conjuntos *fuzzy*  $A$  e  $B$ , pela *s-norma*  $\nabla$  é tal que:

$$A \cup B = \{(x, \mu_A(x)) \nabla \mu_B(x) \mid x \in X\}$$

Ou ainda:

$$\mu_{A \cup B}(x) = \mu_A(x) \nabla \mu_B(x), \forall x \in X$$

**Definição 11.** A intersecção de dois conjuntos *fuzzy*  $A$  e  $B$ , pela *t-norma*  $\Delta$  é tal que:

$$A \cap B = \{(x, \mu_A(x)) \Delta \mu_B(x) \mid x \in X\}$$

Ou ainda:

$$\mu_{A \cap B}(x) = \mu_A(x) \Delta \mu_B(x), \forall x \in X$$

A *s-norma* e a *t-norma* de Zadeh são definidas, respectivamente pelos operadores máximo ( $\vee$ ) e mínimo ( $\wedge$ ). Neste caso temos que:

$$\mu_{A \cup B}(x) = \mu_A(x) \vee \mu_B(x) = \max\{\mu_A(x), \mu_B(x)\}$$

$$\mu_{A \cap B}(x) = \mu_A(x) \wedge \mu_B(x) = \min\{\mu_A(x), \mu_B(x)\}$$

Há uma esforço por parte dos matemáticos em desenvolver s-normas e t-normas para a modelagem de problema utilizando os conceitos da teoria dos conjuntos *fuzzy*. A Tabela 8 exhibe algumas *t-normas* e *s-normas* (GUPTA; QI, 1991):

Tabela 8 – t-normas e s-normas

t-norma	s-norma	Definição
$\min(a, b)$	$\max(a, b)$	Zadeh (ZADEH, 1973).
$\max(a + b - 1, 0)$	$\min(a + b, 1)$	Łukasiewicz (GILES, 1976).
$ab$	$a + b - ab$	Probabilística (BANDLER; KOHOUT, 1980).
$\frac{ab}{\max\{a, b, \alpha\}}, \alpha \in [0, 1]$	$1 - \frac{(1-a)(1-b)}{\max\{1-a, 1-b, \alpha\}}$	Dubois & Prade (DUBOIS; PRADE, 1980).
$\frac{ab}{\gamma + (1-\gamma)(a+ab)}, \gamma \geq 0$	$\frac{a+b-(2-\gamma)ab}{1-(1-\gamma)ab}, \gamma \geq 0$	Hamacher (WEBER, 1983).
$\max(0, \frac{a+b+\lambda ab-1}{1+\lambda})$	$\min(1, a + b - \frac{\lambda ab}{1+\lambda})$	Eber (WEBER, 1983).
$\max(0, 1 - ((1-a)^p + (1-b)^p)^{\frac{1}{p}})$	$\min((a^p + b^p)^{\frac{1}{p}}, 1)$	Yager (YAGER, 1980).

### 3.2.3 Propriedades

Nesta seção, são apresentadas algumas propriedades interessantes dos conjuntos *fuzzy* em analogia às conhecidas para conjuntos clássicos.

**Teorema 1.** *Sejam,  $A, B$  e  $C$  conjuntos fuzzy de um universo  $X$  dotados da t-norma do mínimo  $\wedge$  e da s-norma do máximo  $\vee$ . Verificam-se as seguintes propriedades:*

- **Involução:**  $(A^c)^c = A$

**Demonstração:**

Por definição,  $\mu_{(A^c)^c}(x) = 1 - \mu_{A^c}(x)$  **(I)**.

Mas  $\mu_{A^c}(x) = 1 - \mu_A(x)$  **(II)**.

De **(I)** e **(II)** segue que  $\mu_{(A^c)^c}(x) = \mu_A(x) \forall x \in X$  e, portanto,  $(A^c)^c = A$

■

- **Idempotência:**  $A \cap A = A$  e  $A \cup A = A$ .

**Demonstração:**

Pela definição de Intersecção de conjuntos fuzzy, temos:  $\mu_{A \cap A}(x) = \mu_A(x) \wedge \mu_A(x) = \min\{\mu_A(x), \mu_A(x)\} = \mu_A(x)$ . Assim:

$$\mu_{A \cap A}(x) = \mu_A(x) \iff A \cap A = A$$

A demonstração de  $A \cup A = A$  é análoga. ■

- **Comutatividade:**  $A \cap B = B \cap A$  e  $A \cup B = B \cup A$ .

**Demonstração:**  $\mu_{A \cap B}(x) = \mu_A(x) \wedge \mu_B(x)$ . Mas  $\wedge$  é uma t-norma, e, portanto, vale a comutatividade. Assim:

$$\mu_{A \cap B}(x) = \mu_A(x) \wedge \mu_B(x) = \mu_B(x) \wedge \mu_A(x) = \mu_{B \cap A}(x), \forall x \in X.$$

A demonstração de  $A \cup B = B \cup A$  é análoga. ■

- **Associatividade:**  $(A \cap B) \cap C = A \cap (B \cap C)$  e  $(A \cup B) \cup C = A \cup (B \cup C)$ .

**Demonstração:** Da definição de interseção e da associatividade de  $\wedge$ , segue que:

$$\mu_{(A \cap B) \cap C}(x) = (\mu_A(x) \wedge \mu_B(x)) \wedge \mu_C(x) = \mu_A(x) \wedge (\mu_B(x) \wedge \mu_C(x)) = \mu_{A \cap (B \cap C)}(x)$$

A demonstração de  $(A \cup B) \cup C = A \cup (B \cup C)$  é análoga. ■

### 3.3 Sistemas Baseados em Regras Fuzzy

Valeremo-nos do exemplo presente em Barros e Bassanezi (2006) para a apresentação dos Sistemas Baseados em Regras Fuzzy (SBRF).

Suponha que, uma pessoa que deseja realizar a lavagem de suas roupas adote esquema de procedimentos exposto pela Figura 11.

Poderíamos adotar, por exemplo, as regras expostas pela Tabela 9.

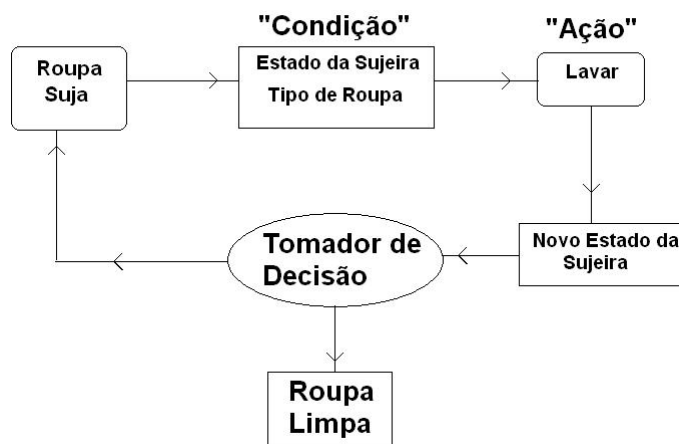
Tabela 9 – Regras de um sistema de automação na lavagem de roupas

Regra	Estrutura Lógica
$R_1$	Se a roupa é "grossa" e a sujeira é "difícil", então lava-se "muito tempo"
$R_2$	Se a roupa é "grossa" e a sujeira é "fácil", então lava-se "em tempo médio"
$R_3$	Se a roupa é "fina" e a sujeira é "fácil", então lava-se "pouco tempo"

Fonte: Adaptada de Barros e Bassanezi (2006)

Neste exemplo, as tarefas são conduzidas por meio de termos expressos em linguagem natural que, de alguma maneira, relacionam-se com as variáveis de interesse. Neste ponto, é fundamental o papel das variáveis linguísticas.

Figura 11 – Esquema para um sistema de controle humano na tarefa de lavar roupa



Fonte: Adaptada de Barros e Bassanezi (2006)

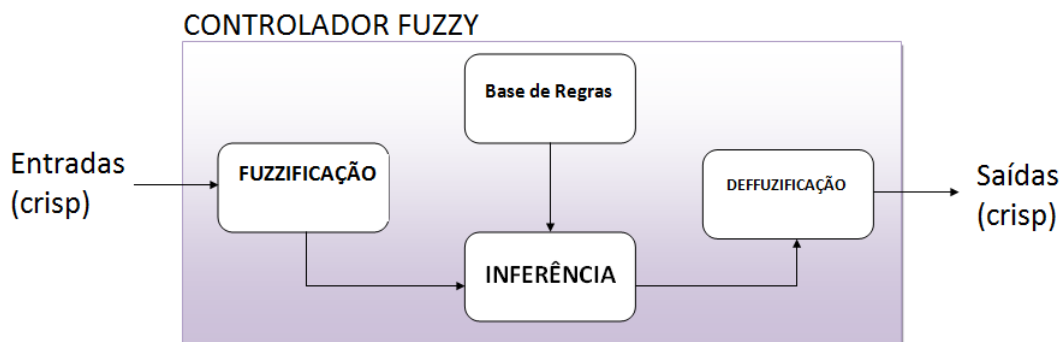
A combinação de todos os termos linguísticos junto às variáveis relacionadas compõe o que chamamos de **Base de Regras Fuzzy** e, a partir dessa base de regras é que se obtêm as relações que produzirão as saídas (respostas, ações) para cada entrada (estado, condição).

Especialmente, se a entrada e a saída são do tipo condição e a ação, respectivamente, o SBRF é chamado de Controlador *Fuzzy*.

### 3.3.1 Sistema de Inferência Fuzzy

Um Sistema de Inferência *Fuzzy* é composto de alguns módulos fundamentais, são eles: Módulo de Fuzzificação, Base de Regras, Módulo de Inferência e Módulo de Defuzzificação. A Figura 12 ilustra a composição geral de um Controlador *Fuzzy*.

Figura 12 – Módulos que compõem um Sistema de Inferência *Fuzzy*



### 3.3.1.1 Fuzzificação

Neste módulo as entradas do sistema são modeladas por conjuntos *fuzzy* e seus respectivos domínios, sendo de fundamental importância a intervenção do especialista do fenômeno que está a se estudar. As funções de pertinência são definidas e as entradas crisp são fuzzificadas por essas funções.

### 3.3.1.2 Base de Regras Fuzzy

É neste módulo que se diz a maneira como as variáveis são relacionadas, isto pode ser feito a partir da opinião de um especialista, por ajuste de curvas, interpolações dentre inúmeras outras metodologias (BARROS; BASSANEZI, 2006).

### 3.3.1.3 Inferência

Nesta fase, cada proposição é transposta em termos matemáticos através dos conceitos da Lógica *Fuzzy*. Neste módulo define-se as t-normas e s-normas a serem utilizadas para se obter as relações que modelam a base de regras.

### 3.3.1.4 Defuzzificação

Este é o processo pelo qual as entradas crisp, convertidas em conjuntos *fuzzy* no processo de fuzzificação, novamente são convertidas para o formato crisp, gerando, portanto, uma saída real.

Comumente utiliza-se no processo de defuzzificação, dentre inúmeros outros, o **Método do Centro de Gravidade**, cujo exemplo de aplicação encontra-se na próxima seção para melhor compreensão.

## 3.3.2 O método de Inferência de Mamdani

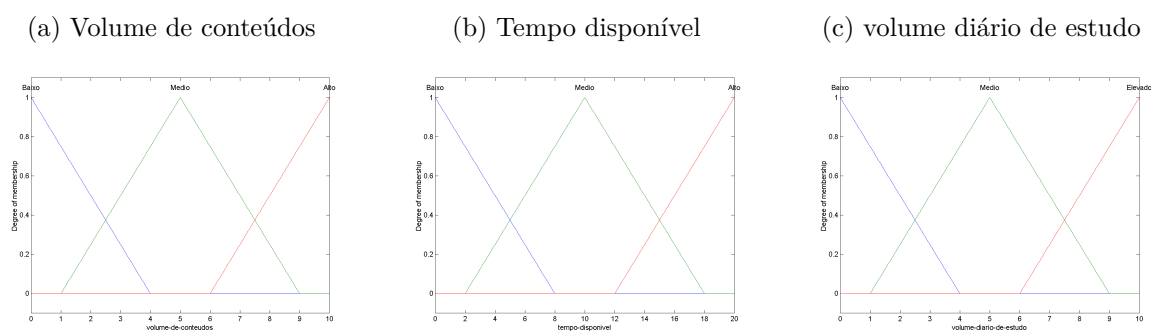
Proposto por Mamdani (1974), este método de inferência vale-se da t-norma do mínimo ( $\wedge$ ) para o conectivo **e** e da s-norma do máximo ( $\vee$ ) para o conectivo **ou**.

No processo de inferência, os antecedentes de cada regra da base de regras são avaliados por meio da operação de intersecção, ou seja, pela t-norma  $\wedge$ . Assim, é gerado um grau de pertinência na ativação de cada regra. Por fim, todas as regras que possuírem graus de pertinência maiores que zero irão contribuir para a determinação da saída. No processamento dos consequents, os graus de pertinência de ativação das regras vão limitar os valores máximos dos conjuntos difusos de saída gerados pelas regras. Em outras palavras, depois de avaliação dos antecedentes pela t-norma do mínimo, é realizada entre os graus de pertinência gerados a operação da s-norma  $\vee$ . Este processo é comumente chamado de *max-min*. Por fim, utiliza-se o respectivo conjunto fuzzy de saída, ou converte-se o resultante fuzzy em crisp.

Para exemplificar um problema modelado pelo método de Mamdani, considere o seguinte problema: Suponha que um aluno deseja organizar sua rotina de estudos em função das provas que deverá realizar. Para isso, o estudante analisa o volume de conteúdos a ser estudado e o tempo disponível até a data da prova, de maneira a decidir o quanto estudará por dia. Neste sentido, duas variáveis de entrada são consideradas: *volume de conteúdos* e *tempo disponível*. A variável de saída é chamada de *volume diário de estudo*.

Os conjuntos *fuzzy* associados ao problema estão ilustrados na Figura 13.

Figura 13 – Conjuntos *fuzzy* para as variáveis do problema




O estudante, baseado em suas experiências anteriores, construiu a seguinte base de regras:

- R1** Se o *volume de conteúdos* é **alto** e o *tempo disponível* é **alto**, então o *volume diário de estudo* é **baixo**;
- R2** Se o *volume de conteúdos* é **alto** e o *tempo disponível* é **médio**, então o *volume diário de estudo* é **médio**
- R3** Se o *volume de conteúdos* é **alto** e o *tempo disponível* é **baixo**, então o *volume diário de estudo* é **elevado**
- R4** Se o *volume de conteúdos* é **médio** e o *tempo disponível* é **alto**, então o *volume diário de estudo* é **baixo**
- R5** Se o *volume de conteúdos* é **médio** e o *tempo disponível* é **médio**, então o *volume diário de estudo* é **médio**
- R6** Se o *volume de conteúdos* é **médio** e o *tempo disponível* é **baixo**, então o *volume diário de estudo* é **elevado**
- R7** Se o *volume de conteúdos* é **baixo** e o *tempo disponível* é **alto**, então o *volume diário de estudo* é **baixo**
- R8** Se o *volume de conteúdos* é **baixo** e o *tempo disponível* é **médio**, então o *volume diário de estudo* é **baixo**

**R9** Se o *volume de conteúdos* é **baixo** e o *tempo disponível* é **baixo**, então o *volume diário de estudo* é **médio**

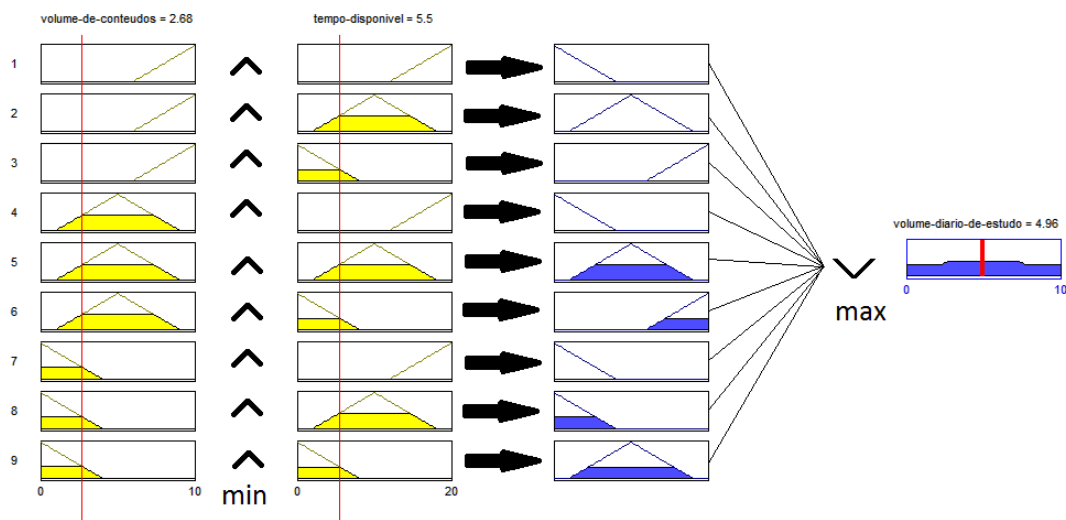
Note que, neste exemplo, o *volume de conteúdos* recebe 3 modificadores linguísticos: baixo, médio e alto. O *tempo disponível* recebe 3 modificadores: baixo, médio e alto o *volume diário de estudo* recebe 3 modificadores: baixo, médio e elevado. A superfície *fuzzy* resultante da base de regras que modela este problema é exibida na Figura 14.

Figura 14 – Superfície *fuzzy* resultante da base de regras



Cada um dos conjuntos *fuzzy*, neste caso do tipo triangular, descreve funções de pertinência e, ao receber as variáveis de entrada, verificam qual o grau de pertinência nos conjuntos e, conseqüentemente, na ativação das regras através da t-norma do mínimo. Em seguida, todos os graus de ativação da regra são operados pela s-norma do máximo e, por fim, defuzzificados pelo método do centro de gravidade. A Figura 15 exhibe o processamento do método de Mamdani.

Figura 15 – Processador do tipo Mamdani



### 3.3.3 O método de Inferência de Takagi-Sugeno

O método de inferência fuzzy introduzido por Takagi-Sugeno ou TSK (TAKAGI; SUGENO, 1985; SUGENO; KANG, 1988) consiste em uma estrutura de inferência baseada na teoria dos conjuntos fuzzy de modo a produzir os consequentes de maneira paramétrica, tendo grande potencial como modelo de aproximação de sistemas que podem ser representados em partes ou totalmente pelas relações das variáveis de entrada. As etapas principais consistem na *fuzzificação* das variáveis de entrada, avaliação, processamento e por fim a geração das saídas. Este método utiliza uma base de regras condicionais, ou seja, do tipo SE-ENTÃO. Contudo, o processo para gerar os consequentes é realizado através de funções paramétricas que relacionam as variáveis de entrada. Uma regra genérica que representa o método de Takagi-Sugeno pode ser dada pela Equação 3.1.

$$\text{if } x_1 = A_i \text{ and } x_2 = A_j \text{ and } \dots \text{ and } x_p = A_m \text{ then } y = \phi(x_1, x_2, \dots, x_p) \quad (3.1)$$

Onde  $x_i$  e  $A_i$ ,  $i, m \in \mathbb{N} \mid 1 \leq i \leq m$ , são as entradas e as partições dos conjuntos fuzzy que modelam as variáveis de entrada, respectivamente, e  $y$  é a saída produzida pelo sistema através da função  $\phi$ .

No processo de fuzzificação das variáveis de entrada, os antecedentes das regras são processados através de uma t-norma<sup>1</sup> entre os graus de pertinência  $\mu$  das variáveis em relação a cada uma das partições dos conjuntos fuzzy que modelam as entradas, gerando um grau de ativação de cada regra. Assim, para a  $k$ -ésima regra da base é atribuído um grau de disparo  $D^{(k)}$ . Desta forma, considerando a t-norma  $T$ , a Equação 3.2 indica a obtenção de  $D^{(k)}$ .

$$D^{(k)} = T[\mu_{A_1}^k(x_1), \mu_{A_2}^k(x_2), \dots, \mu_{A_m}^k(x_p)] \quad (3.2)$$

A saída é determinada pela soma das saídas das regras ponderadas pelos valores de ativação  $D^{(k)}$ , conforme a Equação 3.3.

$$y = \frac{\sum_{i=1}^k D^{(i)} \phi_i(x_1, x_2, \dots, x_m)}{\sum_{i=1}^k D^{(i)}} \quad (3.3)$$


<sup>1</sup> Operador binário usado na abordagem de espaços métricos probabilísticos e na lógica fuzzy, como uma generalização do conceito de inteseção de conjuntos da lógica clássica

Observe que, neste modelo, a saída é dada por uma função real. Usualmente esta função é um polinômio mas pode ser qualquer função real que descreva a saída do sistema definida pelos antecedentes (ROSS, 2009).


Um exemplo de modelagem pelo método de Takagi-Sugeno pode ser dado por: Considere  $x$  e  $y$  dois números reais, ambos pertencentes ao intervalo  $[-10, 10]$ , pelos quais deseja-se gerar pontos do espaço da forma  $z = ax + by + c$ . Os números  $x$  e  $y$  são caracterizados pelos modificadores "*próximo de -10*" ou "*distante de -10*". A Figura 16 exhibe os conjuntos fuzzy (do tipo sino) para as variáveis em questão.

Figura 16 – Conjuntos *fuzzy* para as variáveis do problema

(a) Volume de conteúdos



(b) Tempo disponível



Considere as seguintes regras para a geração de planos:

**R1** Se  $x$  é próximo de -10 e  $y$  é próximo de -10, então  $z = 3x - 2y + 1$

**R2** Se  $x$  é próximo de -10 e  $y$  é distante de -10, então  $z = 3x + 2y - 1$

**R3** Se  $x$  é distante de -10 e  $y$  é próximo de -10, então  $z = -3x + 2y - 1$

**R4** Se  $x$  é distante de -10 e  $y$  é distante de -10, então  $z = -3x + 2y + 1$

A superfície gerada pela base de regras está ilustrada na Figura 17

A Figura 18 exhibe as regras que são ativadas e a saída considerada pelo método.

Figura 17 – Suerfície *fuzzy* resultante da base de regras





Figura 18 – Processador do tipo Takagi-Sugeno



## 4 Materiais e Métodos

### 4.1 Caracterização dos dados

Os dados utilizados neste estudo foram coletados dos radares meteorológicos doppler do Instituto de Pesquisas Meteorológicas – IPMet, unidade complementar da Universidade Estadual Paulista UNESP, localizado em Bauru/SP, instalados em Bauru/SP e Presidente Prudente/SP.

Este Instituto tem como objetivos a pesquisa meteorológica voltada à utilização em previsão do tempo para o Estado de São Paulo, o monitoramento e quantificação de chuvas ocorrendo nessa mesma região, com o uso de radar meteorológico. O instituto presta serviços a diversos setores da sociedade, como a população do estado, meios de comunicação, agricultores e usinas. Dentre os setores atendidos, destaca-se o trabalho destinado às Defesas Civas do Estado de São Paulo, cujo trabalho consiste em emitir alertas de ocorrência de tempestades severas para fins de tomada de decisão, além de oferecer treinamentos para a utilização e interpretação de produtos meteorológicos gerados no instituto, todos possíveis graças à presença de dois radares meteorológicos administrados pelo instituto, instalados em Bauru/SP e Presidente Prudente/SP.

Para determinar a área de estudo foi adotada a técnica dos radares integrados e o tratamento gráfico dos dados foi realizado por meio do sistema TITAN. Estes procedimentos são descritos nas seções seguintes.

#### 4.1.1 A Técnica de Radares Integrados (*Dual-Radar Method*)

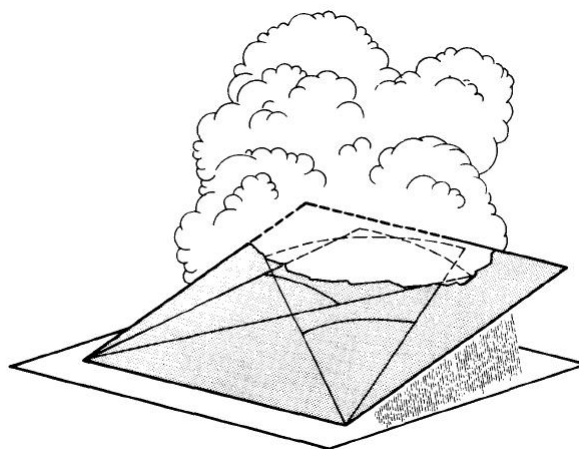
Esta técnica consiste no uso de 2 radares meteorológicos doppler que operam sobre uma área de comum abrangência, chamada área de intersecção e, a partir da análise pontual, são feitos os devidos estudos e comparações sobre as características dos ecos alí observados por cada equipamento. Em outras palavras, esta técnica busca integrar dois radares meteorológicos de maneira a otimizar as características de um mesmo eco observado a partir de dois pontos distintos, conforme ilustrado pela Figura 19.

Os primeiros usos de dados integrados foram propostos nos trabalhos de Lhermitte

(1970) e posteriormente aprimorados por Miller e Strauch (1974). A integração por múltiplos tipos de sensores têm se mostrado uma metodologia potencial na melhoria da estimativa de chuvas e na interpretação do campo de refletividade de ecos detectados por radares meteorológicos. Neste sentido, o uso de dados integrados em uma rede de radares é de fundamental importância para se otimizar, por exemplo, o problema de limitação geométrica do volume de cobertura, na composição da informação sobre a estrutura vertical, e nos diversos problemas de interferências nas medidas produzidas por radar (LAKSHMANAN et al., 2006)

Na criação de uma grade tridimensional com informações de múltiplos radares, alguns métodos têm sido freqüentemente utilizados, como o método de mapeamento do vizinho mais próximo, a interpolação bilinear e a ponderação do campo de refletividade como uma função exponencial da distância (TRAPP; III, 2000; ASKELSON; AUBAGNAC; STRAKA, 2000; ZHANG; HOWARD; GOURLEY, 2005). Contudo, dentre uma extensa gama de complexos aspectos, fatores como a não-sincronia da rede de radares e os diferentes métodos de varredura tornam-se grandes desafios na chamada técnica de análise objetiva, que consiste na utilização de dados de volume completo para a composição do mosaico de integração (CHARBA; LIANG, 2005), podendo surtir efeitos como localização inadequada das áreas espacializadas, assim como a incompatibilidade temporal dos pontos considerados, implicando em uma mistura negligenciada dos ecos.

Figura 19 – Método Dual-Radar



Fonte: Miller e Strauch (1974).

Nos estudos pioneiros de Lhermitte (1970) e Miller e Strauch (1974) esta técnica foi utilizada de forma que as observações, realizadas por 2 radares doppler, sobre velocidade


radial das partículas presentes em precipitações, juntamente analisadas as equações de conservação de massa e estimativas médias da velocidade de queda, possibilitaram realizar um rico detalhamento da estrutura dos campos de vento que ocorrem no interior de tempestades, assim como em condições de neve.

Citando os problemas que ocorrem nas interpretações físicas de alvos mais distantes dos radares, Blahak (2005) utiliza da técnica de radares integrados como uma alternativa ao estudo da relação entre refletividade e a taxa de precipitação, comumente estudada a partir de relações Z-R por Marshall e Palmer (1948).

Além de estar presente em estudos cujo objetivo se dá em questões de caráter aplicado, como na agricultura e na engenharia urbana, esta técnica também é utilizada de maneira a estudar os efeitos atenuantes dos equipamentos eletrônicos, as interferências nas medições e na avaliação de parâmetros para eventos de precipitação, como detalhado em Srivastava e Tian (1996), Kozu e Nakamura (1991).

Para este estudo foram considerados pontos da área de comum cobertura dos radares meteorológicos de Bauru e Presidente Prudente, determinados a partir da técnica dos radares integrados, cujo mapa de intersecção dos feixes pode ser observado na Figura 20.

Figura 20 – Interação entre os feixes dos radares meteorológicos de Bauru e Presidente Prudente



A Tabela 10 descreve as características técnicas dos radares meteorológicos de Bauru e Presidente Prudente.

Tabela 10 – Características Técnicas dos Radares Meteorológicos de Bauru e Presidente Prudente

Banda	S
Frequência	2.8GHz
Comprimento de onda	10,7cm
Potência	600kW
Faixa de amostragem	3,5 km
Diâmetro da antena	4 m
Largura do feixe	2°
Pulso Longo	PRF 250Hz - 9°/s - 1 elevação - SURVEILLANCE (58s)
Pulso Curto	PRF 620Hz - 20°/s - 16 elevações - VOLSCAN (5m40s)

#### 4.1.2 Matrizes do sistema TITAN

Desenvolvido por Dixon e Wiener (1993), no *National Center for Atmospheric Research* - NCAR, o software *Thunderstorm Identification, Tracking, Analysis, and Now-casting* (TITAN) é mundialmente utilizado em centros de previsão do tempo, pesquisas meteorológicas e atmosféricas.

Este complexo sistema de aplicação específica de identificação e previsão de tempestades de chuvas usando dados de radares meteorológicos, vem sendo aprimorado durante as últimas 2 décadas, possibilita a agregação de diversos tipos de dados, realiza processamentos, gera produtos personalizados e possibilita ao usuário realizar estudos e acompanhamentos iniciais em ambiente gráfico.

O sistema é ainda capaz de assimilar dados de trajetória de aviões, descargas elétricas, satélites, modelos numéricos e estações meteorológicas; tratar ecos de terreno e propagações anômalas; estimar precipitação acumulada espacialmente; dentre uma infinidade de aplicações.

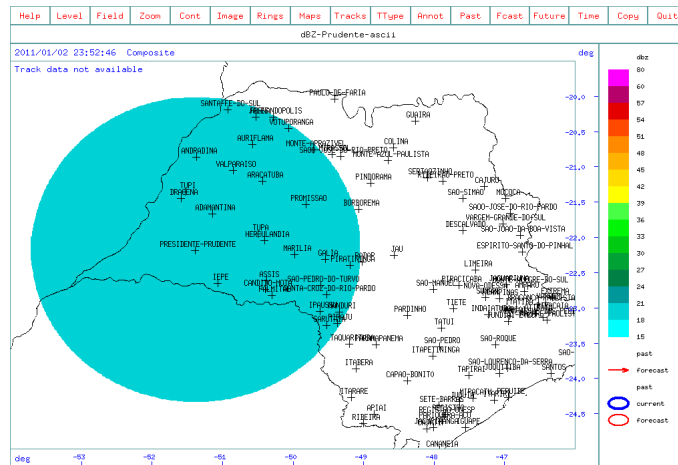
No Brasil, o IPMet - Centro de Meteorologia de Bauru foi pioneiro no uso deste sistema, tendo seu projeto de implantação desenvolvido por Kokitsu (2005).

O produto CAPPI, escalonado a cada 7,5 minutos em cada radar, é composto em uma grade cuja resolução espacial é de 750m. Para cada varredura completa das 16 elevações das antenas, é gerada uma matriz de 677 linhas e 1000 colunas.

Para determinar a área de estudo deste trabalho foi utilizada a técnica Dual-Radar, tendo como matriz resultante a intersecção entre as matrizes de Bauru (Figura 21b) e Presidente Prudente (Figura 21a), apresentada na Figura 23

Figura 21 – Áreas de abrangência dos radares meteorológicos de Bauru e Prudente na matriz do TITAN

(a) Matriz do Radar de Prudente



(b) Matriz do Radar de Bauru

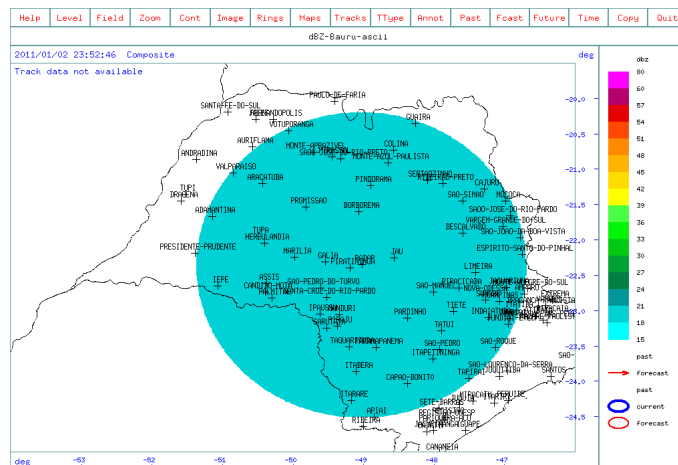
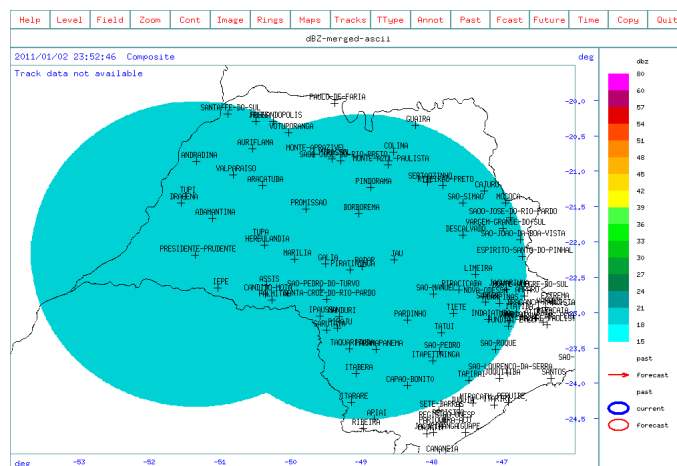
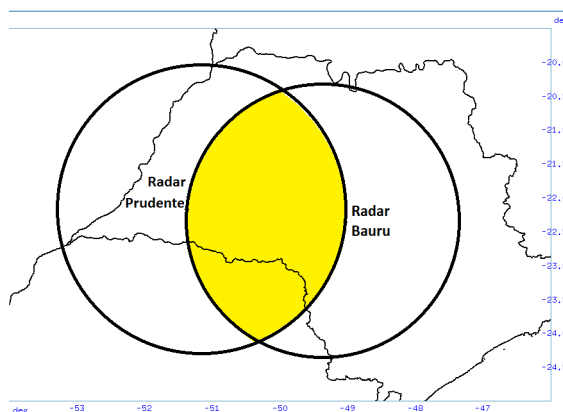


Figura 22 – Composição de 21a e 21b - *Merged* de Bauru e Prudente



Para a composição (*merged*) das matrizes, o TITAN pode ser parametrizado de maneira a escolher o máximo valor de refletividade, assim como o mínimo valor ou a média,

Figura 23 – Área de estudo: Intersecção entre as matrizes de Bauru e Prudente



entre as matrizes de Bauru e Prudente. No IPMet o parâmetro escolhido é do tipo Máximo. Em outras palavras, se em determinado pixel da matriz de Bauru o valor de refletividade é, por exemplo, 45dBZ e na matriz de Prudente este valor é de 48dBZ, o pixel resultante na matriz composta terá valor de MÁXIMO  $\{45, 48\} = 48dBZ$ . Este fato reforça a ideia da existência de diferença de caracterização de um mesmo eco pelos radares, ainda que sejam equipamentos idênticos. Para evidenciar tal fato, foi selecionado um eco presente na área de intersecção, no dia 01/02/2015 (Figura 24), observado isoladamente por cada matriz e, em seguida, o campo composto apresentado nas altitudes de 2km , 2.75km e 3.5km, conforme descrito nas Figuras 25c, 26ce 27c, respectivamente.

Figura 24 – Eco observado na área de intersecção dos radares (Faixa 3.5km do produto CAPPI)

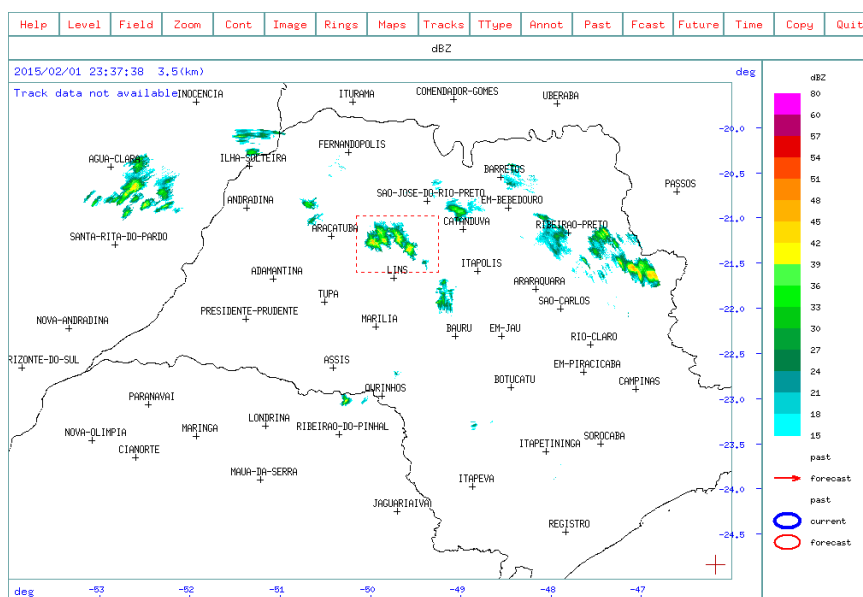


Figura 25 – Altitude da amostra - 2km

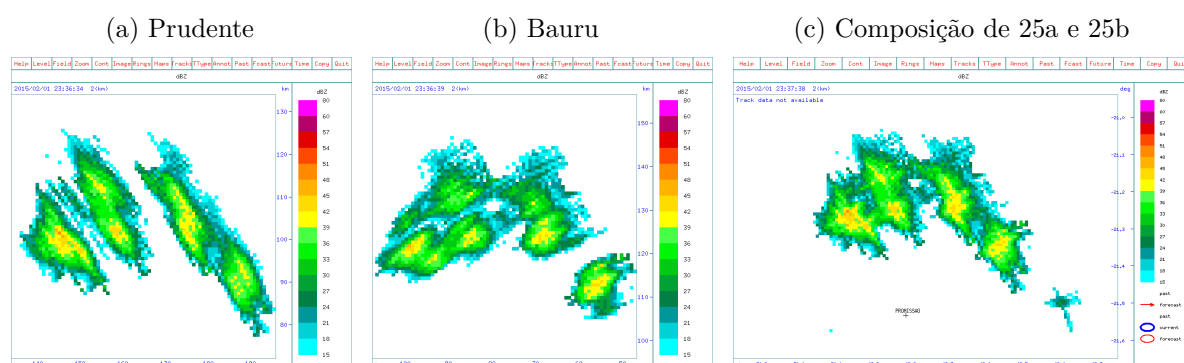


Figura 26 – Altitude da amostra - 2.75km


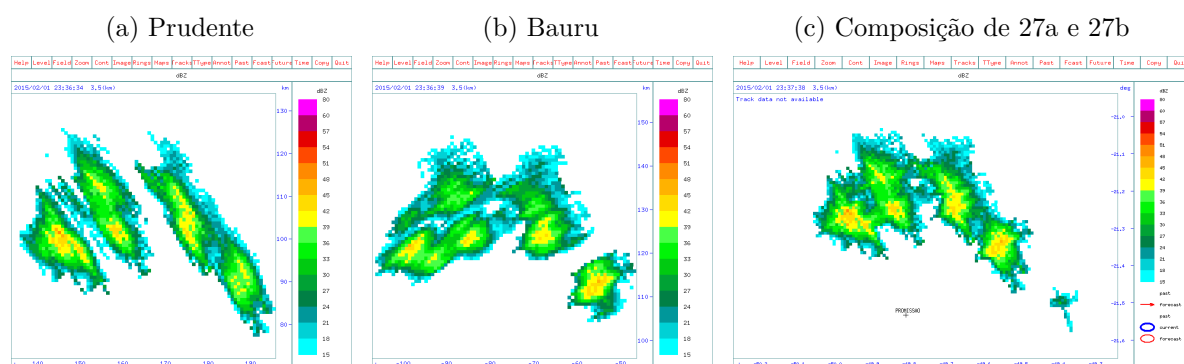


Figura 27 – Altitude da amostra - 3.5km



## 4.2 Elaboração do Modelo do tipo Takagi-Sugeno de ordem 1

Nesta seção, é apresentado o desenvolvimento de um Sistema Baseado em Regras *Fuzzy* (SBRF) do tipo Takagi-Sugeno (TAKAGI; SUGENO, 1985), que combinar duas variáveis particulares dos ecos detectados e, ao final, analisar sua capacidade de otimização da classificação linguística proposta por Falconer (1984).

### 4.2.1 Escolha das Variáveis

De acordo com a Equação 2.6 o feixe de ondas eletromagnéticas afasta-se da superfície à medida que distancia-se do radar. É esperado, portanto, que quanto maior a distância, menor se de a ocorrência de detecção de alvos em baixas altitudes, ou seja, espera-se que o radar não consiga identificar fenômenos meteorológicos mais próximos ao solo. De modo geral, o efeito da curvatura da Terra pode influenciar nas classificações de intensidades reais dos alvos detectados a longas distâncias causando uma incompatibilidade linguística entre o fenômeno e sua adjetivação.

É sabido que para se obter informações da magnitude das tempestades identificadas pelo radar é preciso considerar diversos fatores relativos às características dos processos físicos que controlam a ocorrência e podem influenciar na interpretação das imagens (FRENCH; ANDRIEU; KRAJEWSKI, 1995).

Para o modelo aqui proposto são consideradas a distância e a refletividade como variáveis de entrada, por meio das quais o sistema deverá aproximar a refletividade de alvos mais distantes de um radar para a refletividade ideal observada segundo um radar mais próximo ao eco.

A escolha pela variável *distância* justifica-se, portanto, pelo fato que as caracterizações dos alvos detectados por radares sofrem inteferências ao longo da distância, ou seja, a medida que o feixe distancia-se do radar sua trajetória vertical é aumentada e, portanto, a identificação de alvos em maiores altitudes pode não condizer com a realidade do fenômeno observado em níveis da atmosfera mais próximos ao solo.

### 4.2.2 Conjuntos *Fuzzy* para as entradas Distância e Refletividade

Baseou-se a elaboração dos conjuntos *fuzzy* para a caracterização da variável *Refletividade* a partir da classificação proposta por Falconer (1984), admitindo o tratamento *fuzzy* dos intervalos de transição entre os modificadores linguísticos *Baixa*, *Moderada*, *Forte*, *Muito Forte*, *Intensa* e *Extrema*. Também foi incluso o conjunto *Desprezível* para caracterizar os ecos cujo valores são menores que 15dBZ. A justificativa para este fato é de que fenômenos com refletividade inferiores a 15dBZ podem não ser detectados ou, ainda, pouco significativos.

As funções de pertinência da variável *Refletividade* são do tipo *Trapezoidal* e estão ilustradas na Figura 28a. Matematicamente, a função de pertinência é dada por:

$$f_R(x) = \begin{cases} \frac{x-a}{b-a}, & \text{se } a \leq x < b, \\ 1, & \text{se } b \leq x < c, \\ \frac{d-x}{d-c}, & \text{se } c \leq x < d, \\ 0, & \text{se } x \geq d \end{cases}$$

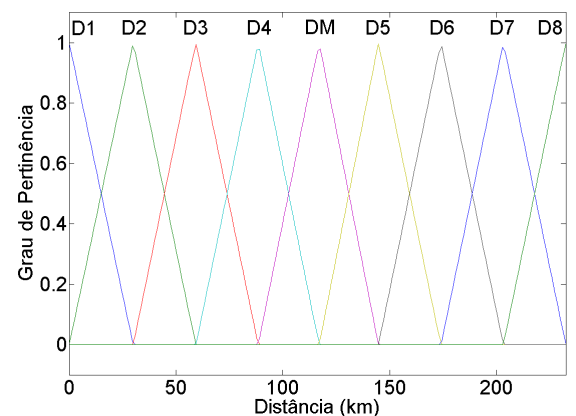
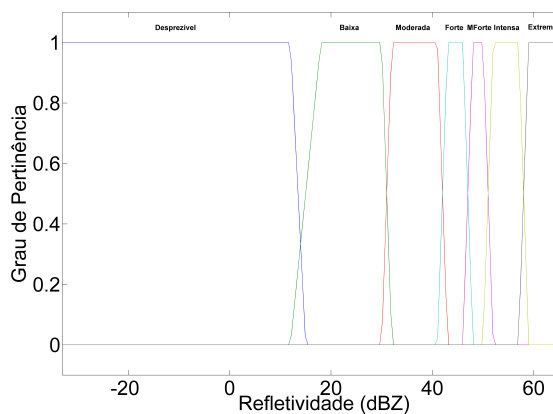
Para a variável *Distância* as funções de pertinência são do tipo *Triangular*, determinando 9 conjuntos que representam as faixas de distância, de acordo com os 9 pontos delimitadores, conforme ilustra a Figura 28b. Matematicamente:

$$f_D(x) = \begin{cases} 0, & \text{se } x < a, \\ \frac{x-a}{u-a}, & \text{se } a \leq x \leq u, \\ \frac{x-b}{u-b}, & \text{se } u \leq x \leq b, \\ 0, & \text{se } x > b \end{cases}$$

Figura 28 – Conjuntos *Fuzzy* para as variáveis de entrada

(a) Refletividade

(b) Distância



### 4.2.3 O Método de Inferência de Takagi-Sugeno

Dado um eco  $E(R, D)$  observado isoladamente por um Radar, sua *Intensidade Fuzzy*  $z$  será determinada utilizando a inferência de Takagi-Sugeno na tentativa de ajustar

o campo de refletividade à realidade física do fenômeno.

A estrutura do sistema do método de Takagi-Sugeno é tal que:

$$\text{Se } r_i \text{ é } R \text{ e } d_i \text{ é } D, \text{ então } z_i(r_i, d_i) = \delta_i r_i + \kappa_i d_i + \nu_i.$$

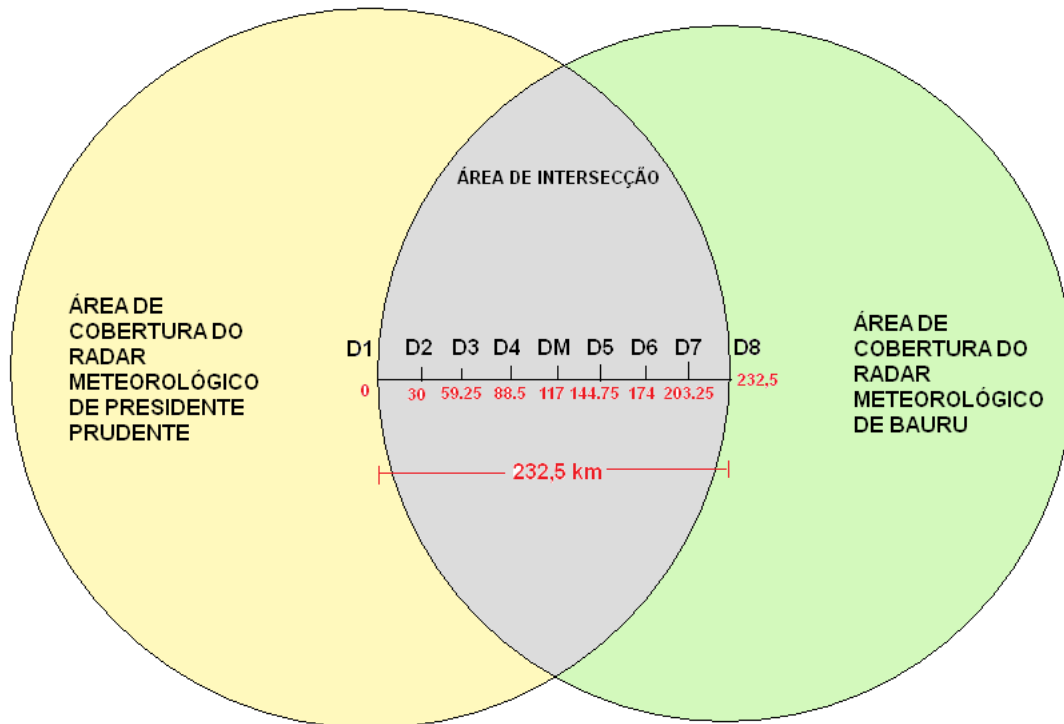
Com  $r_i \in R$  a Refletividade,  $d_i \in D$  a Distância e  $z_i(r_i, d_i)$  a *Intensidade Fuzzy*.

#### 4.2.3.1 Determinação dos parâmetros $\delta$ , $\kappa$ e $\nu$ - O Método dos Mínimos Quadrados

Optou-se por obter  $z_i(r_i, d_i)$  para cada uma das 9 faixas, isoladamente. Desta maneira, a função  $z_i(r_i, d_i)$  terá sempre  $\kappa = 0$ , ou seja, não irá depender dos valores  $d_i$ .

Para determinar os parâmetros  $\delta_i$  e  $\nu_i$ , foram analisados dados do produto CAPPI(3.5km) dos radares meteorológicos de Bauru e Presidente Prudente do ano de 2010 em 9 pontos (pixels) pertencentes a cada uma das faixas  $D1, D2, D3, D4, DM, D5, D6, D7$  e  $D8$ , no sentido de comparar a diferença entre o campo de refletividade de um mesmo eco observado pelos radares. A figura 29 ilustra os pontos analisados.

Figura 29 – Pontos utilizados para determinar as curvas de regressão



Fonte: O Autor.

Após comparação pixel a pixel segundo cada radar, foi escolhido um filtro estatístico para eliminar pares de dados ( Dado a ser Corrigido  $x_i$  (oriundo do radar mais distante do eco); Dado real  $y_i$  (oriundo do radar mais próximo do eco)) anômalos que poderiam influenciar no cálculo dos parâmetros  $\delta_i$  e  $\nu_i$ . Adotou-se o seguinte filtro:

$$|x_i - y_i| > \sum_{i=1}^n \frac{x_i - y_i}{n} + 2\sigma \Rightarrow \text{Descarta} - se(x_i, y_i) \quad (4.1)$$

Onde  $\sigma$  representa o desvio padrão das  $n$  diferenças  $x_i - y_i$ .

Para o ponto *DM* o limiar utilizado foi de  $3\sigma$  uma vez que nesta região os dados parecem estar melhor correlacionados e, portanto, com menor frequência de pares anômalos.

Este filtro é utilizado para que os parâmetros possam ser estimados com o mínimo de interferência entre os pares de dados considerados casos anômalos, ou seja, cuja diferença entre suas magnitudes destoa significativamente das diferenças dos demais pares de dados analisados.

Com o filtro utilizado, foram eliminados 12,41% dos dados da amostra. A Tabela 11 exibe a descrição detalhada sobre o efeito do filtro adotado para cada um dos pontos *D1*, *D2*, *D3*, *D4*, *DM*, *D5*, *D6*, *D7* e *D8*.

Tabela 11 – Estatística de filtragem de pares de dados anômalos

Ponto	Sem Filtro	Com Filtro	Eliminados	Redução(%)
<b>D1</b>	707	641	66	9,34
<b>D2</b>	1067	934	133	12,46
<b>D3</b>	1458	1269	189	12,96
<b>D4</b>	1773	1676	97	5,47
<b>DM</b>	1551	1541	10	0,64
<b>D5</b>	1548	1261	287	18,54
<b>D6</b>	1239	967	272	21,95
<b>D7</b>	932	714	218	23,39
<b>D8</b>	488	418	70	14,34
<b>TOTAL</b>	<b>10763</b>	<b>9421</b>	<b>1342</b>	<b>12,47</b>

Em seguida, utilizou-se o Método dos Mínimos Quadrados para estimar uma curva de regressão linear entre os dados dos radares de Bauru e Presidente Prudente.

O Método dos Mínimos Quadrados (HELENE, 2006; WILKS, 2011; GUJARATI; PORTER, 2011) tem sua fundamentação consolidada na Teoria de Otimização Matemática,

sendo inúmeras as obras da literatura que contemplam sua descrição, princípios e exemplos de aplicações.

Este método busca estimar o melhor ajuste para um conjunto de dados minimizando a soma dos quadrados das diferenças entre o valor estimado e os dados observados (reais). Essa diferença é chamada de resíduo (Erro).

Formalmente, o Método dos Mínimos Quadrados (MQ) busca estimar valores para uma variável  $y$  a partir de um conjunto de valores da variável  $x$  que acredita-se estar relacionada a  $y$ . A relação das variáveis é expressa pela curva de regressão:

$$y = \alpha + \beta x + \varepsilon \quad (4.2)$$

Onde:  $\alpha$ : Parâmetro constante;

$\beta$ : Coeficiente da variável  $x$ ;

$\varepsilon$ : Erro que não é explicada pelo modelo de regressão.

Desta forma, em uma base de dados com  $n$  valores observados de  $x$  e  $y$ , procurou-se estimar os parâmetros  $\alpha$ ,  $\beta$  de maneira que se tenha  $y = \alpha + \beta x + \varepsilon$ . É importante observar que esses parâmetros são estimativas, uma vez que são influenciados pela existência de resíduos.

Logo, este método consiste em determinar:

$$y_i = \alpha + \beta x_i + \varepsilon_i \quad (4.3)$$

Onde  $y_i$  e  $x_i$  representa cada uma das  $n$  observações do banco de dados, ou seja,  $1 \leq i \leq n$ .

O princípio deste método se dá na tentativa de minimizar a soma dos quadrados dos resíduos  $\varepsilon_i$ . Ou seja:

$$MQ \longrightarrow \text{minimizar} \sum_{i=1}^n \varepsilon_i^2 \quad (4.4)$$

Isolando  $\varepsilon_i$  na Equação 4.3, segue que:

$$\varepsilon_i = y_i - \alpha - \beta x_i \quad (4.5)$$

Assim, das Equações 4.5 e 4.4, obtém-se:

$$MQ \longrightarrow^{minimizar} F(\alpha, \beta) = \sum_{i=1}^n (y_i - \alpha - \beta x_i)^2 \quad (4.6)$$

A ideia dessa técnica se fundamenta pelo fato de que minimizando a soma do quadrado dos resíduos, encontraremos  $\alpha$  e  $\beta$  que trarão a menor diferença entre a previsão de  $y$  obtida por meio de  $x$  e o valor de  $y$  observado.

Dos conhecimentos do Cálculo Diferencial, o processo para se minimizar  $F(\alpha, \beta)$  dá-se por meio do cálculo das derivadas parciais em relação à  $\alpha$  e  $\beta$ , igualando-as a 0.

$$\frac{\partial F}{\partial \alpha} = -2 \sum_{i=1}^n (y_i - \alpha - \beta x_i) = 0 \quad (4.7)$$

$$\frac{\partial F}{\partial \beta} = -2 \sum_{i=1}^n x_i (y_i - \alpha - \beta x_i) = 0 \quad (4.8)$$

Distribuindo e dividindo a Equação 4.7 por  $2n$  segue que:

$$\frac{-2 \sum_{i=1}^n y_i}{2n} + \frac{2 \sum_{i=1}^n \alpha}{2n} + \frac{2 \sum_{i=1}^n \beta x_i}{2n} = \frac{0}{2n}$$

$$\frac{-\sum_{i=1}^n y_i}{n} + \frac{\sum_{i=1}^n \alpha}{n} + \frac{\sum_{i=1}^n \beta x_i}{n} = 0$$

$$-\bar{y} + \alpha + \beta \bar{x} = 0$$

$$\alpha = \bar{y} - \beta \bar{x} \quad (4.9)$$

Onde:

$\bar{x}$  é a média da amostra de  $x$ ;

$\bar{y}$  é a média da amostra de  $y$ .

Agora, substituindo 4.9 em 4.8, segue que:

$$\begin{aligned}
 -2 \sum_{i=1}^n x_i (y_i - \bar{y} + \beta \bar{x} - \beta x_i) &= 0 \\
 \sum_{i=1}^n [x_i (y_i - \bar{y}) + x_i \beta (\bar{x} - x_i)] &= 0 \\
 \sum_{i=1}^n x_i (y_i - \bar{y}) + \beta \sum_{i=1}^n x_i (\bar{x} - x_i) &= 0 \\
 \beta &= \frac{\sum_{i=1}^n x_i (y_i - \bar{y})}{\sum_{i=1}^n x_i (\bar{x} - x_i)} \tag{4.10}
 \end{aligned}$$

Desta forma, os parâmetros  $\alpha$  e  $\beta$  estimados correspondem, respectivamente, aos parâmetros  $\delta_i$  e  $\nu_i$  esperados pelo modelo *fuzzy* para a formulação de cada uma das  $z_i(r_i, d_i)$ .

A faixa que contém os 9 pontos utilizados para o cálculo dos parâmetros das curvas de ajustes possui 310 pixels com resolução de 0,75km x 0,75km, perfazendo o total de 232,5km. Os 9 pontos (pixels) foram determinados adotando o ponto mais próximo do Radar de Presidente Prudente como a origem, ou seja, o ponto D1 equivale a distância 0km e o ponto D8 equivale a 232,5km. Como o número de pixels é par, considerou-se que o pixel que representa o centro desta linha é o pixel de número 156 e, portanto, a faixa DM equivale à 117km.

Do ponto D1 ao ponto D2 percorre-se 30km (40 pixels).

Do ponto D2 ao ponto D3 percorre-se 29,25km (39 pixels).

Do ponto D3 ao ponto D4 percorre-se 29,25km (39 pixels).

Do ponto D4 ao ponto DM percorre-se 28,5km (38 pixels).

Do ponto DM ao ponto D5 percorre-se 27,75km (37 pixels).

Do ponto D5 ao ponto D6 percorre-se 29,25km (39 pixels).

Do ponto D6 ao ponto D7 percorre-se 29,25km (39 pixels).

Do ponto D7 ao ponto D8 percorres-e 29,25km (39 pixels).

#### 4.2.4 Dados utilizados para simulação

Para a análise do desempenho do modelo foram selecionados 2 pixels em cada uma das 8 faixas de distância, totalizando 16 pixels. Cada pixel foi avaliado no total de 1 ano da tarefa CAPPI, faixa de amostragem 3,5km. Nomeou-se cada pixel de acordo com sua posição em relação ao pixel mais próximo do radar de Presidente Prudente (Pixel P1). Assim, por exemplo, o pixel 10 é nomeado P10.

A Tabela 12 exhibe os 8 pixels analisados mais próximos ao Radar de Presidente Prudente(cujos dados são considerados os reais), as respectivas distâncias e a quantidade de dados cuja refletividade é maior ou igual a 15 *dBZ* em ambos os radares.

Tabela 12 – Pixels utilizados para a avaliação do desempenho do modelo mais próximos ao Radar de Presidente Prudente

<b>Pixel</b>	<b>Distância (km)</b>	<b>Dados</b>
<b>P10</b>	7,5	801
<b>P30</b>	22,5	981
<b>P50</b>	37,5	1276
<b>P70</b>	52,5	1474
<b>P89</b>	66,75	1500
<b>P105</b>	78,75	1497
<b>P124</b>	93	1724
<b>P147</b>	110,25	1601
<b>TOTAL</b>	-	<b>10854</b>

A Tabela 13 exhibe os 8 pixels analisados mais próximos ao Radar de Bauru (cujos dados são considerados os reais), as respectivas distâncias e a quantidade de dados cuja refletividade é maior ou igual a 15*dBZ* em ambos os radares.

Tabela 13 – Pixels utilizados para a avaliação do desempenho do modelo mais próximos ao Radar de Bauru

Pixel	Distância (km)	Dados
<b>P166</b>	124,5	1619
<b>P184</b>	138	1509
<b>P203</b>	152,25	1524
<b>P223</b>	167,25	1441
<b>P242</b>	181,5	1150
<b>P262</b>	196,5	1026
<b>P281</b>	210,75	807
<b>P301</b>	225,75	584
<b>TOTAL</b>	-	<b>9660</b>

## 4.3 Análise Estatística

### 4.3.1 Para as curvas de regressão linear

#### 4.3.1.1 Coeficiente de correlação de Perason - ( $\rho$ )

O coeficiente de correlação de Perason  $\rho$  é determinado por:

$$\rho = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (4.11)$$

Este parâmetro traduz o nível de correlação linear e direção entre dois conjuntos de dados. No caso em que  $\rho > 0$ , isso indica que o sentido de crescimento (ou decrescimento) de um conjunto de dados é mantido no outro conjunto de dados. Se  $\rho < 0$ , isso indica que o sentido de crescimento (ou decrescimento) de um conjunto de dados é inverso ao sentido do outro conjunto. Se  $\rho = 1$  isso significa que existe perfeita correlação positiva entre os conjuntos. Se  $\rho = -1$  isso significa que existe perfeita correlação negativa entre os conjuntos.

#### 4.3.1.2 Coeficiente de determinação - ( $R^2$ )

Obtido a partir do quadrado do coeficiente de pearson, o coeficiente de determinação  $R^2$  é uma medida de ajustamento de um modelo estatístico linear de dados empíricos em relação aos valores reais observados. O  $R^2$  varia entre 0 e 1, indicando o percentual de quanto o modelo de regressão consegue explicar os valores observados. Quanto maior o  $R^2$ , mais explicativo é o modelo.

### 4.3.2 Para o desempenho do modelo

Após o processamento dos dados pelo modelo, foram utilizados os parâmetros estatísticos *Erro Médio* (BIAS), *Erro Quadrático Médio* (MSE), e a *Raiz Quadrada do Erro Quadrático Médio* (RMSE) para verificar a capacidade de otimização do modelo nos 16 pixels. Foram computados, também, a quantidade de dados que o modelo foi capaz de aproximar em relação aos dados reais, assim como os que divergiram (afastaram-se).

#### 4.3.2.1 BIAS

O BIAS, também conhecido por Erro Sistemático, é o parâmetro estatístico que mede a tendência do modelo subestimar ou super-estimar os dados reais observados.

O BIAS é definido de acordo com a Equação 4.12.

$$BIAS = \sum_{i=1}^n \frac{\theta_e - \theta_o}{n} \quad (4.12)$$

Onde:

$\theta_e$  é o dado estimado pelo modelo;

$\theta_o$  é o dado real observado pelo radar mais próximo do pixel.

#### 4.3.2.2 MSE

O BIAS não traduz o comportamento dos erros individuais, não sendo, portanto, uma medida de acurácia da simulação. Segundo Hallak e Filho (2011), os erros individuais positivos e negativos de mesma magnitude interferem no BIAS, uma vez que no somatório podem se anular.

Neste sentido, um parâmetro frequentemente utilizado para avaliação da acurácia é o chamado Erro Médio Quadrático, cuja sigla em inglês é MSE (Mean Square Error). Conforme descrito em (WILKS, 2011), o MSE é definido como:

$$MSE = \sum_{i=1}^n \frac{(\theta_e - \theta_o)^2}{n} \quad (4.13)$$

### 4.3.2.3 RMSE

Para complementação da compreensão da acurácia, utilizamos o parâmetro denominado Raiz do Erro Quadrático Médio, sigla em inglês RMSE (Root Mean Square Error). Este parâmetro se faz de grande valia uma vez seus resultados apresentam a mesma dimensão da variável analisada. O RMSE é definido conforme a Equação 4.14.

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(\theta_e - \theta_o)^2}{n}} \quad (4.14)$$

### 4.3.2.4 O teste de Kolmogorov-Smirnov

Utilizou-se o teste de Kolmogorov-Smirnov (WILKS, 2011) para verificar a capacidade do modelo em diminuir a maior diferença absoluta ( $K$ ) entre as funções de distribuição de probabilidade dos conjuntos de dados pré/pós processamento ao conjunto dos dados reais observados. O parâmetro  $K$  pode ser obtido conforme a Equação 23.

$$K = \sup |F(x) - G(y)| \quad (4.15)$$

Onde  $F(x)$  e  $G(y)$  são as correspondentes funções de distribuição empírica dos conjuntos de dados  $X$  e  $Y$ .

Dados dois conjuntos de dados  $X$  e  $Y$ , o teste de Kolmogorov-Smirnov pode ser utilizado para avaliar as hipóteses:

$H_0$  : Os conjuntos seguem uma distribuição normal;

$H_1$  : Os conjuntos não seguem uma distribuição normal;

Entretanto, devido ao fato de que o teste de Kolmogorov-Smirnov observa a máxima diferença absoluta entre a função de distribuição acumulada dos dados (parâmetro  $K$ ), este teste também possibilita verificar se duas curvas de distribuição aproximam-se ou afastam-se a partir de uma proposta de ajuste de curvas.

Utilizou-se o parâmetro  $K$  no sentido de verificar se a distribuição de probabilidade dos conjuntos de dados utilizados nesta pesquisa tendem a se aproximar.

## 5 Resultados e Discussões

### 5.1 Curvas de Regressão

As curvas de regressão linear para os pontos 1,2,3,4 encontradas foram, respectivamente:

$$(D1) : y = 0.6454x + 9.194 \quad (5.1)$$

$$(D2) : y = 0.7304x + 7.866 \quad (5.2)$$

$$(D3) : y = 0.8818x + 4.134 \quad (5.3)$$

$$(D4) : y = 0.866x + 3.537 \quad (5.4)$$

A Figura 30 exhibe a comparação dos ecos observados por cada radar meteorológico no período de análise nos pontos 1 a 4, no qual considera-se que o dado real é representado pelos ecos observados pelo Radar de Presidente Prudente, devido à sua maior proximidade a esses pontos.

As curvas de regressão linear para os pontos D5,D6,D7,D8 encontradas foram, respectivamente:

$$(D5) : y = 0.9335x + 2.6821 \quad (5.5)$$

$$(D6) : y = 0.866x + 4.6414 \quad (5.6)$$

$$(D7) : y = 0.8218x + 6.0268 \quad (5.7)$$

$$(D8) : y = 0.5345x + 12.7268 \quad (5.8)$$

A Figura 31 exibe a comparação dos ecos observados por cada radar meteorológico no período de análise nos pontos 5 a 8, no qual considera-se que o dado real é representado pelos ecos observados pelo Radar de Bauru, devido à sua maior proximidade a esses pontos.

A Figura 32 exibe a comparação dos ecos observados pelos radares no ponto *DM* adotado como o ponto central entre os radares, embora esteja 1 pixel mais próximo do radar de Bauru.

Nestas condições, a curva de regressão encontrada foi:

$$(DM) : y = 0.9261x + 2.556 \quad (5.9)$$

A Tabela 14 exibe os resultados obtidos para os coeficientes de determinação e de correlação de perason para cada uma das equações obtidas.

Tabela 14 – Coeficientes de determinação e de correlação obtidos

Ponto	Curva obtida	$\rho$	$R^2$
<b>D1</b>	$y = 0.6454x + 9.194$	0.5596	0.3132
<b>D2</b>	$y = 0.7304x + 7.866$	0.6745	0.4549
<b>D3</b>	$y = 0.8818x + 4.134$	0.8534	0.7284
<b>D4</b>	$y = 0.866x + 3.537$	0.8784	0.7716
<b>DM</b>	$y = 0.9261x + 2.556$	0.8832	0.78
<b>D5</b>	$y = 0.9335x + 2.6821$	0.9252	0.856
<b>D6</b>	$y = 0.866x + 4.6414$	0.8225	0.6764
<b>D7</b>	$y = 0.8218x + 6.0268$	0.7654	0.5858
<b>D8</b>	$y = 0.5345x + 12.7268$	0.5151	0.2653

Nota-se que a medida que os pontos se aproximam da faixa central de distância, os coeficientes de determinação e o de correlação de Pearson tendem a crescer, ou seja, os dados tendem a estar melhor correlacionados e explicados pelas equações encontradas. O Ponto D8 apresentou a menor correlação entre os dados dos radares meteorológicos, apresentando  $\rho = 0.5151$  e  $R^2 = 0.2653$ . Em contrapartida, o ponto D5 apresentou a maior correlação com  $\rho = 0.9252$  e  $R^2 = 0.856$ . Estes resultados uma vez mais evidenciam a importância da variável distância na correlação entre dados dos radares meteorológicos, uma vez que com o aumento da distância entre os ecos e radar, mais influências os radares sofrem no processo de coleta das informações, podendo acarretar interpretações não realísticas do fenômeno observado.

Figura 30 – Comparação entre os Radares Meteorológicos - Pontos D1 a D4

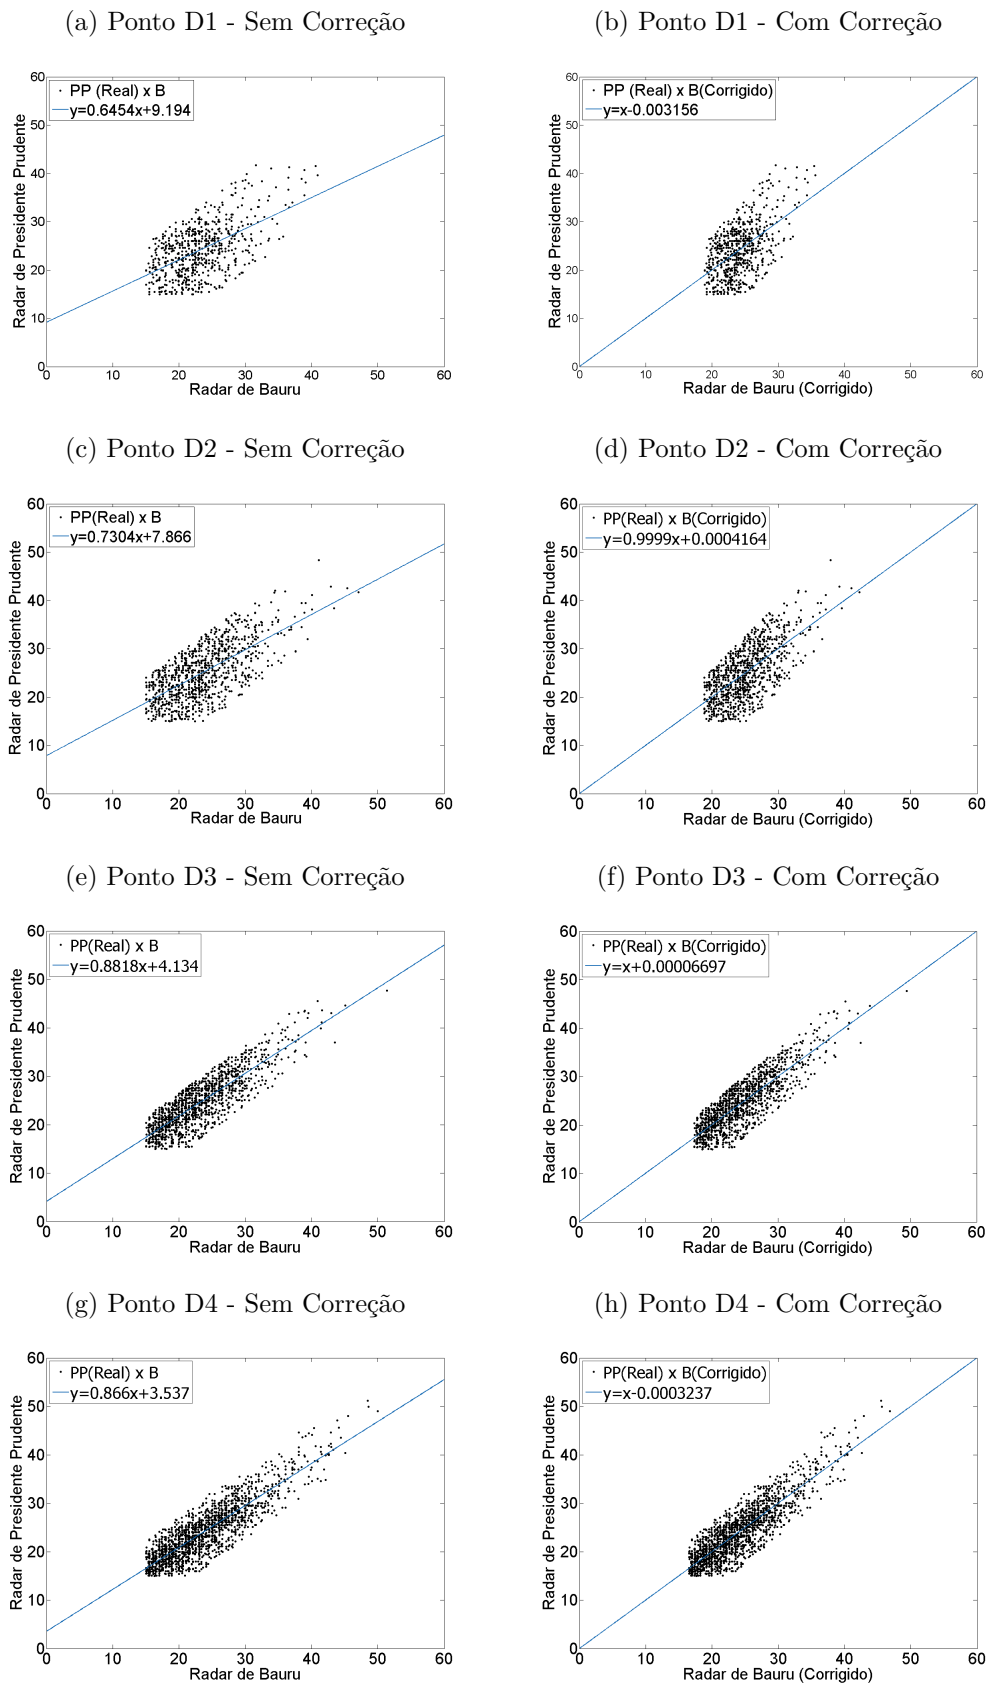


Figura 31 – Comparação entre os Radares Meteorológicos - Pontos D5 a D8

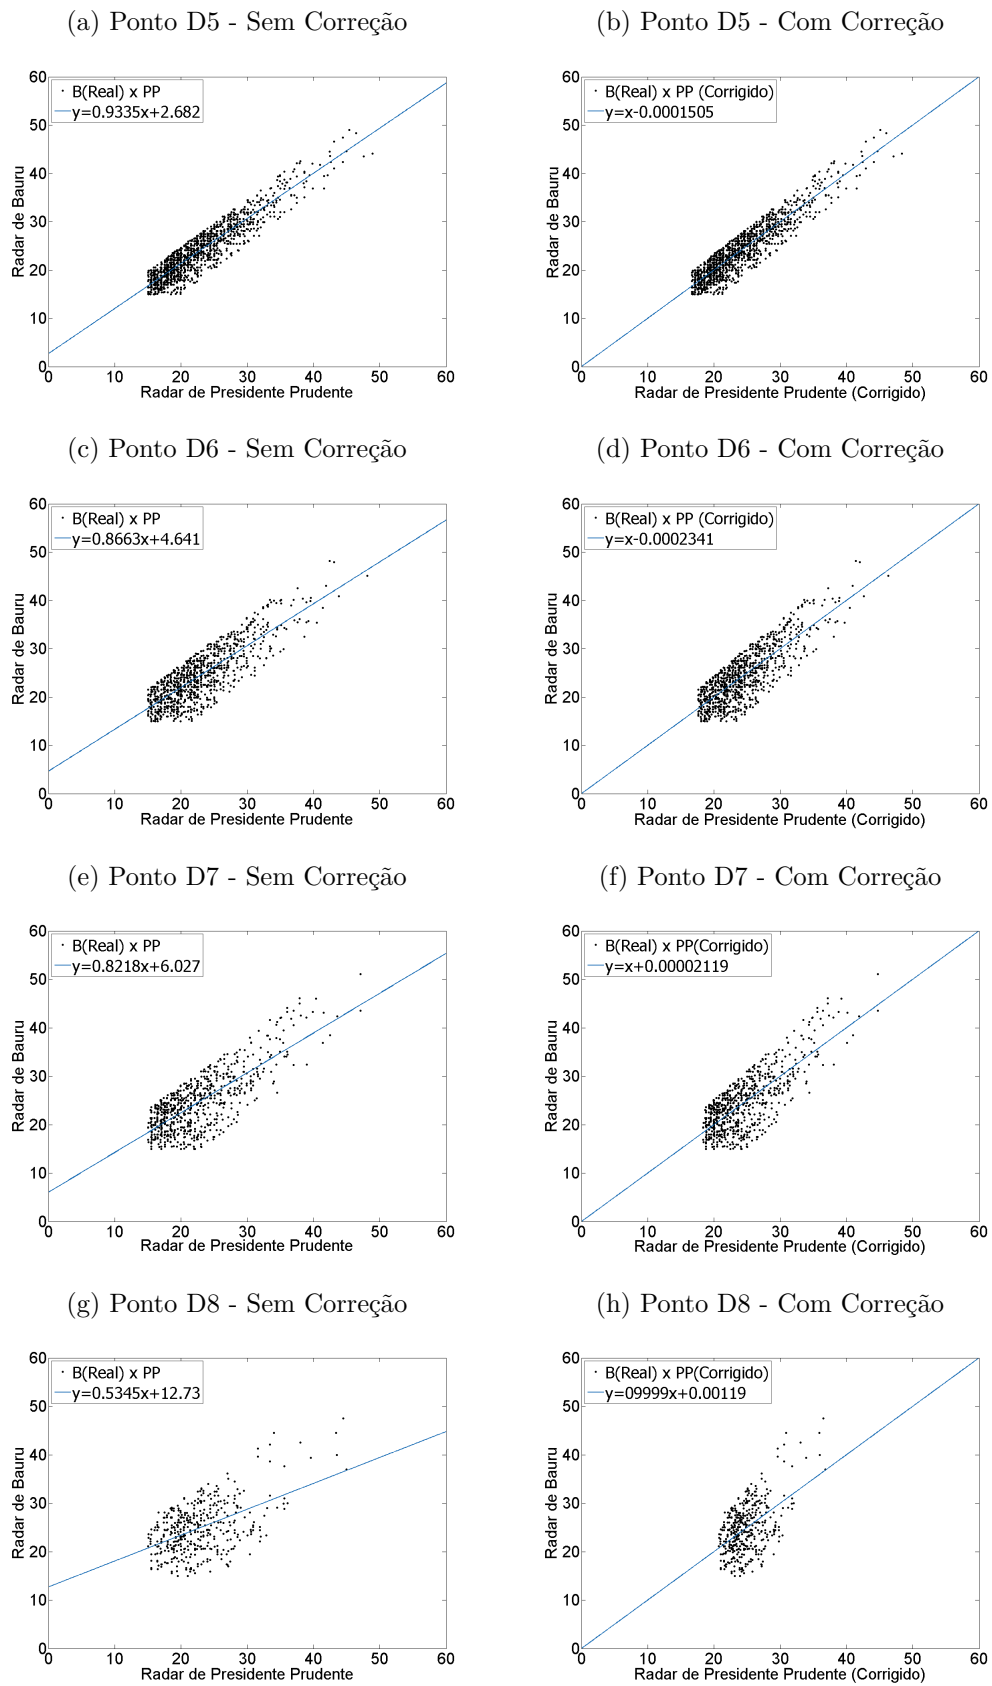




Figura 32 – Ponto M



## 5.2 Superfície *Fuzzy*

A partir das curvas de regressão linear obtidas, a base de regras do sistema aqui proposto foi gerada de maneira a combinar todos os subconjuntos *fuzzy* da variável *distância* com todos os subconjuntos *fuzzy* da variável refletividade. Como são 9 subconjuntos para a variável distância e 7 subconjuntos para a variável refletividade, foram geradas 63 regras.

A superfície *fuzzy* obtida pela base de regras esta representada pela Figura 33.

Figura 33 – Superfície *Fuzzy* gerada pela base de regras

## 5.3 Estatística dos Resultados

### 5.3.1 Pontos Otimizados e Pontos Divergentes

Inicialmente, foram contabilizados os casos em que o modelo foi capaz de otimizar os dados iniciais aos dados reais observados.

Os pontos que foram aproximados aos dados reais foram denominados como Pontos Otimizados (PO). Os pontos que foram afastados dos dados reais foram denominados Pontos Divergentes (PD).

Assim, a classificação se deu através de:

$$|\theta_e - \theta_o| < |\theta_i - \theta_o| \rightarrow \text{PontoOtimizado}$$

$$|\theta_e - \theta_o| > |\theta_i - \theta_o| \rightarrow \text{PontoDivergente}$$

Onde:

$\theta_i$ : Dado inicial antes do processamento;

$\theta_e$ : Dado estimado pelo modelo;

$\theta_o$ : Dado real observado;

Não ocorreu casos em que mantiveram-se as diferenças pré-processamento dos dados.

Nos Pixels P10, P30, P50, P70, P89, P105, P124 e P147 os dados adotados como reais são os dados oriundos do radar de Presidente Prudente, devido a maior proximidade. Portanto, é o caso em que os dados do Radar de Bauru são ajustados de acordo com a realidade apresentada pelos dados do Radar de Prudente. Logo  $\theta_o = \text{Radar de Presidente Prudente}$ .

Nos Pixels P166, P184, P203, P223, P242, P262, P281 e P301 os dados adotados como reais são os dados oriundos do radar de Bauru, devido a maior proximidade. Portanto, é o caso em que os dados do Radar de Presidente Prudente são ajustados de acordo com a realidade apresentada pelos dados do Radar de Bauru. Logo  $\theta_o = \text{Radar de Bauru}$ .

### 5.3.1.1 Caso $\theta_o = \text{Radar de Presidente Prudente}$

A Tabela 15 exibe os resultados das simulações dos Pixels P10, P30, P50, P70, P89, P105, P124 e P147 em relação ao percentual de Pontos Otimizados e dos Pontos Divergentes.

Tabela 15 – Pontos Otimizados e Pontos Divergentes

<b>Pixel</b>	<b>Distância(km)</b>	<b>Pontos Otimizados (%)</b>	<b>Pontos Divergentes (%)</b>
<b>P10</b>	7,50	61,3	38,7
<b>P30</b>	22,50	63,2	36,8
<b>P50</b>	37,50	50,16	49,84
<b>P70</b>	52,50	60,61	39,39
<b>P89</b>	66,75	61,07	38,93
<b>P105</b>	78,75	58,65	41,35
<b>P124</b>	93,00	54,12	45,88
<b>P147</b>	110,25	60,09	39,91

### 5.3.1.2 Caso $\theta_o = \text{Radar de Bauru}$

A Tabela 16 exibe os resultados das simulações dos Pixels P10, P30, P50, P70, P89, P105, P124 e P147 em relação ao percentual de Pontos Otimizados e dos Pontos Divergentes.

Tabela 16 – Pontos Otimizados e Pontos Divergentes

<b>Pixel</b>	<b>Distância(km)</b>	<b>Pontos Otimizados (%)</b>	<b>Pontos Divergentes (%)</b>
<b>P166</b>	124,5	55,78	44,22
<b>P184</b>	138	60,57	39,43
<b>P203</b>	152,25	69,09	30,91
<b>P223</b>	167,25	63,71	36,29
<b>P242</b>	181,5	66,26	33,74
<b>P262</b>	196,5	67,45	32,55
<b>P281</b>	210,75	65,55	34,45
<b>P301</b>	225,75	65,58	34,42

## 5.3.2 BIAS - Erro Médio

### 5.3.2.1 Caso $\theta_o = \text{Radar de Presidente Prudente}$

A Tabela 17 exibe os resultados das simulações dos Pixels P10, P30, P50, P70, P89, P105, P124 e P147 para os parâmetro estatístico BIAS.

Tabela 17 – Análise dos Resultados: Erro Sistemático (BIAS)

Pixel	Distância(km)	BIAS (Sem Correção)	Bias (Com Correção)
P10	7,50	-1,99	-0,89
P30	22,50	-2,52	-1,16
P50	37,50	-1,98	-0,42
P70	52,50	-1,61	-0,19
P89	66,75	-0,89	0,19
P105	78,75	-0,99	-0,28
P124	93,00	0,29	0,38
P147	110,25	0,94	0,38

### 5.3.2.2 Caso $\theta_o$ = Radar de Bauru

A Tabela 18 exibe os resultados das simulações dos Pixels P166, P184, P203, P223, P242, P262, P281 e P301 para os parâmetro estatístico BIAS.

Tabela 18 – Análise dos Resultados: Erro Sistemático (BIAS)

Pixel	Distância(km)	BIAS (Sem Correção)	BIAS (Com Correção)
P166	124,5	-0,94	-0,03
P184	138	-1,17	-0,49
P203	152,25	-2,28	-1
P223	167,25	-1,99	-0,48
P242	181,5	-2,99	-1,3
P262	196,5	-2,93	-0,95
P281	210,75	-3,47	-1,39
P301	225,75	-3,71	-1,39

### 5.3.3 MSE - Erro Quadrático Médio

#### 5.3.3.1 Caso $\theta_o$ = Radar de Presidente Prudente

A Tabela 19 exibe os resultados das simulações dos Pixels P10, P30, P50, P70, P89, P105, P124 e P147 para os parâmetro estatístico MSE.

Tabela 19 – Análise dos Resultados: Erro Quadrático Médio (MSE)

Pixel	Distância(km)	MSE (Sem correção)	MSE (Com Correção)
P10	7,50	41,63	33,26
P30	22,50	42,77	32,6
P50	37,50	34,25	25,25
P70	52,50	23,2	18,9
P89	66,75	15,42	13,36
P105	78,75	18,20	16,07
P124	93,00	12,82	11,39
P147	110,25	9,06	7,48

5.3.3.2 Caso  $\theta_o = \text{Radar de Bauru}$ 

A Tabela 20 exibe os resultados das simulações dos Pixels P10, P30, P50, P70, P89, P105, P124 e P147 para os parâmetro estatístico MSE.

Tabela 20 – Análise dos Resultados: Erro Quadrático Médio (MSE)

Pixel	Distância(km)	MSE (Sem correção)	MSE (Com Correção)
<b>P166</b>	124,5	12,04	10,83
<b>P184</b>	138	14,19	12,43
<b>P203</b>	152,25	20,11	15,20
<b>P223</b>	167,25	23,95	18,79
<b>P242</b>	181,5	38	28,29
<b>P262</b>	196,5	38,9	27,97
<b>P281</b>	210,75	55,69	40,58
<b>P301</b>	225,75	54,31	36,38

## 5.3.4 RMSE - Raiz do Erro Quadrático Médio

5.3.4.1 Caso  $\theta_o = \text{Radar de Presidente Prudente}$ 

A Tabela 21 exibe os resultados das simulações dos Pixels P10, P30, P50, P70, P89, P105, P124 e P147 para os parâmetro estatístico RMSE.

Tabela 21 – Análise dos Resultados: Raiz do Erro Quadrático Médio (RMSE)

Pixel	Distância(km)	RMSE (Sem correção)	RMSE (Com Correção)
<b>P10</b>	7,50	6,45	5,77
<b>P30</b>	22,50	6,54	5,71
<b>P50</b>	37,50	5,85	5,03
<b>P70</b>	52,50	4,82	4,35
<b>P89</b>	66,75	3,93	3,65
<b>P105</b>	78,75	4,27	4,01
<b>P124</b>	93,00	3,58	3,37
<b>P147</b>	110,25	3,01	2,73

5.3.4.2 Caso  $\theta_o = \text{Radar de Bauru}$ 

A Tabela 22 exibe os resultados das simulações dos Pixels P10, P30, P50, P70, P89, P105, P124 e P147 para os parâmetro estatístico RMSE.

Tabela 22 – Análise dos Resultados: Raiz Erro Quadrático Médio (RMSE)

Pixel	Distância(km)	RMSE (Sem correção)	RMSE (Com Correção)
<b>P166</b>	124,5	3,47	3,29
<b>P184</b>	138	3,77	3,53
<b>P203</b>	152,25	4,48	3,9
<b>P223</b>	167,25	4,89	4,33
<b>P242</b>	181,5	6,16	5,32
<b>P262</b>	196,5	6,24	5,29
<b>P281</b>	210,75	7,46	6,37
<b>P301</b>	225,75	7,37	6,03

#### 5.4 Comparação entre as funções de distribuição obtidas pré e pós modelagem *fuzzy*

O teste estatístico de Kolmogorov-Smirnov estima um parâmetro  $K$  que traduz a maior distância entre dois conjuntos de dados, segundo suas funções de distribuição de probabilidades. De maneira simplificada, a medida que dois conjuntos de dados tendem a ter valores próximos,  $K$  tende a zero.

Desta forma, a Tabela 23 exibe os parâmetros  $K_a$  e  $K_d$  obtidos antes e depois simulação para os 16 pontos utilizados respectivamente, no sentido de verificar a capacidade em minimizar  $K$ .

Tabela 23 – Teste de Kolmogorov-Smirnov antes e depois das simulações do modelo

Pixel	$K_a$	$K_b$
<b>P10</b>	0.17853	0.17353
<b>P30</b>	0.20183	0.18247
<b>P50</b>	0.18809	0.13636
<b>P70</b>	0.12347	0.097015
<b>P89</b>	0.094	0.072667
<b>P105</b>	0.082832	0.077488
<b>P124</b>	0.028422	0.078306
<b>P147</b>	0.078076	0.087445
<b>P166</b>	0.069179	0.065473
<b>P184</b>	0.09609	0.076872
<b>P203</b>	0.19751	0.10499
<b>P223</b>	0.18043	0.097155
<b>P242</b>	0.24783	0.14261
<b>P262</b>	0.24659	0.12378
<b>P281</b>	0.25527	0.16109
<b>P301</b>	0.30651	0.21233

As curvas de distribuição empírica, classicamente tratada com seu termo em inglês

*Empirical Cumulative Distribution Function*, obtidas após a modelagem dos pontos P10 a P147 (dados do radar de Prudente adotados como reais) estão ilustradas nas Figuras 34, 35, 36, 37, 38,39, 40 e 41.

Figura 34 – ECDF para P10




Figura 35 – ECDF para P30




Figura 36 – ECDF para P50





Figura 37 – ECDF para P70



Para a modelagem dos pontos P166 a P301 (dados do radar de Bauru adotados como reais), as comparações das curvas estão ilustradas nas Figuras 42, 43, 44, 45, 46, 47, 48 e 49.

Figura 38 – ECDF para P89




Figura 39 – ECDF para P105




Figura 40 – ECDF para P124




Figura 41 – ECDF para P147

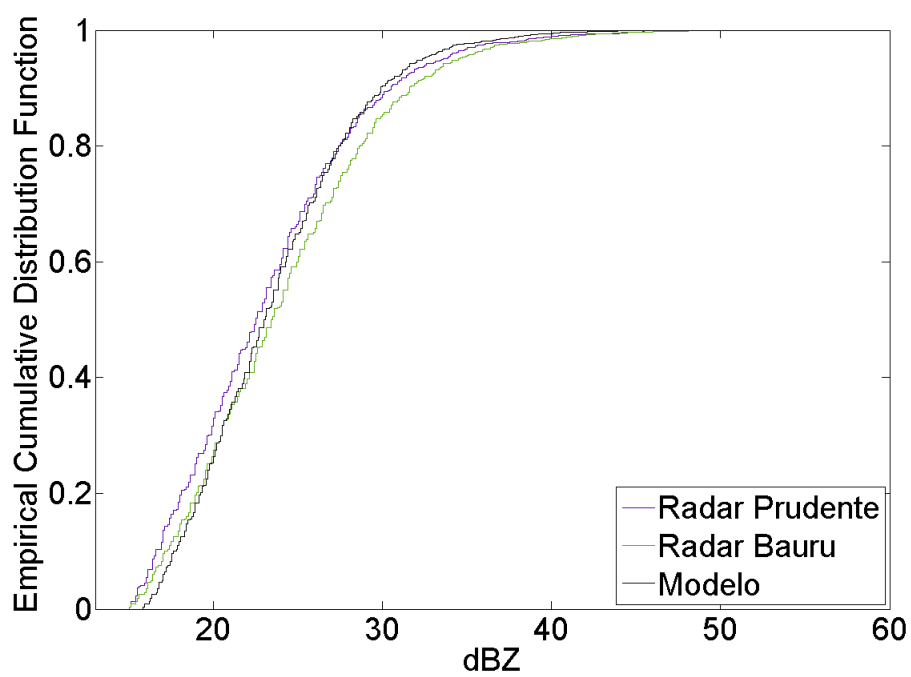


Figura 42 – ECDF para P166




Figura 43 – ECDF para P184




Figura 44 – ECDF para P203




Figura 45 – ECDF para P223




Figura 46 – ECDF para P242




Figura 47 – ECDF para P262




Figura 48 – ECDF para P281





Figura 49 – ECDF para P301



## 5.5 Análise dos Resultados

Os coeficientes de determinação  $R^2$  e de correlação de Perason  $\rho$  possibilitaram verificar a tendência de existir variação na correlação dos dados obtidos pelos radares me-

teorológicos a medida que a variável distância oscila, assim como evidenciar a dificuldade na modelagem destes fenômenos. Nota-se, ainda, a capacidade de explicação das variáveis através das equações obtidas na maioria dos casos estudados.

Ainda que os resultados das Tabelas 15 e 16 demonstrem que o modelo foi capaz de gerar mais pontos otimizados do que dados divergentes, é preciso examinar o comportamento do modelo para o conjunto de dados de uma maneira geral, uma vez que a força do processo de aproximação de pontos gerado pelo modelo pode ser menor que sua força em afastá-los, ou seja, pode-se obter um número de dados aproximados maiores que o número de dados afastados porém, a maneira com que os dados são otimizados não superam a maneira que os dados são afastados, sendo assim, para o conjunto de dados geral, um mau resultado (ainda que com mais pontos otimizados do que divergentes). Desta maneira, é necessário analisar o desempenho dos parâmetros estatísticos propostos no Capítulo 4.

Nota-se, na Tabela 17 que nos pixels P10, P30, P50, P70, P89, P105 e P147 o modelo foi capaz de diminuir o erro sistemático (BIAS) do conjunto de dados analisados.

Nota-se, ainda, nos pixels P10, P30, P50, P70, P89 e P105 os valores do BIAS (sem correção) negativos. Estes resultados mostram a tendência do Radar de Bauru Super-Estimar o campo de refletividade na região onde o Radar de Presidente Prudente é considerado o dado real, fato que pode estar relacionado aos fenômenos de Propagação Anômala, Banda Brilhante e trajetória do feixe de ondas eletromagnéticas, apresentados no Capítulo 2.

O pixel P124 apresentou ligeiro aumento no BIAS. Contudo, não é possível afirmar que neste pixel o modelo apresentou mau desempenho sendo, portanto, necessário analisar os demais parâmetros estatísticos de acurácia.

Na Tabela 19, os resultados obtidos para o Erro Quadrático Médio demonstram a capacidade do modelo em diminuir, em todos os pontos simulados, a diferença quadrática entre os dados estimados e os dados observados, ainda que no pixel P124 tenha apresentado ligeiro aumento no BIAS.

Na Tabela 18, nota-se que em todos os pixels o modelo foi capaz de diminuir o erro sistemático (BIAS) do conjunto de dados analisados.

Em todos os pixels os valores do BIAS (sem correção) são negativos. Novamente

demonstrando, analogamente ao Radar de Bauru, a tendência do Radar de Presidente Prudente Super-Estimar o campo de refletividade na região onde o Radar de Bauru é considerado o dado real.

Conforme a Tabela 20, os resultados obtidos para o Erro Quadrático Médio demonstram a capacidade do modelo de diminuir a diferença quadrática entre os dados observados e os ajustados pelo modelo.

Por fim, a Tabela 23 demonstra a capacidade do modelo em aproximar a distribuição dos conjuntos de dados analisados, indicando o potencial desta metodologia no processo de otimização das possíveis interferências encontradas em dados de radares meteorológicos.

## 6 Considerações Finais

O presente trabalho buscou evidenciar a importância da Meteorologia como ciência de caráter aplicado, a complexa modelagem de fenômenos meteorológicos e a grande utilidade dos Radares Meteorológicos na monitoramento de eventos extremos de precipitação, discutindo o efeito da distância do feixe de ondas eletromagnéticas na coleta de informações da atmosfera.

Neste estudo, é proposta uma abordagem de modelagem baseada na teoria dos conjuntos fuzzy, na lógica fuzzy e nos sistemas de inferência fuzzy para o ajuste do campo de refletividade de ecos detectados por radar, discutindo o efeito da distância nas medidas realizadas por dois radares que operam em uma área de comum cobertura.

Devido à inúmeras interferências nas medições, ao raciocínio aproximado e a grande variabilidade dos dados, um modelo fuzzy do tipo Takagi-Sugeno foi utilizado como uma potencial metodologia, capaz de vincular de certa maneira as subjetividades do problema nas quais as metodologias estatísticas clássicas têm limitações ou dificuldades de abordar, implicando, assim, numa real contribuição para que as interpretações medidas do campo de refletividade possam ser feitas de maneira otimizada e refinada.

A importância deste sistema se dá, ainda, no sentido da possibilidade de gerar uma metodologia alternativa de extrapolação do padrão de ajuste modelado nesta pesquisa para as demais áreas de cobertura dos radares, podendo ser útil na quantificação de chuvas de maneira espacial além do monitoramento de tempestades em áreas que não possuem radares integrados ou ainda poucos pontos com pluviômetros.

Destacamos, por fim, o grande potencial de modelagem e re-modelagem da metodologia empregada, uma vez que possibilita incorporar recursivamente subjetividades aos conjuntos fuzzy que descrevem as variáveis de entrada de maneira elementar, como a quantidade de conjuntos fuzzy e suas partições, assim como o número de regras, mostrando-se uma metodologia flexível de re-estruturação a medida que o conhecimento da problemática avança.

Como sugestão de trabalhos futuros, temos a possibilidade de considerar, além dos

dados oriundos de radar, dados observados em superfície (Pluviômetros/ Rede de Estações Meteorológicas), no sentido de estudar a correlação entre esses dados.

Outra possibilidade seria a abordagem das Redes Neurais Artificiais como classificadores dos ecos detectados por radar, realizando os devidos estudos das problemáticas que aqui fizemos, como uma ferramenta de suporte a tomada de decisão de alertas de tempestade severa.

## Referências

- ACEITUNO, P. On the functioning of the southern oscillation in the south american sector. part i: Surface climate. *Monthly Weather Review*, v. 116, n. 3, p. 505–524, 1988.
- ALVES, L. M. et al. Início da estação chuvosa na região sudeste do brasil: Parte 1-estudos observacionais. *INPE ePrint: sid.inpe.br/ePrint@80/2005/05.09.18.30 v1 2005-05-10*, 2005.
- ARAI, K.; SAKA, M.; SETO, K. Bright band height assignment with precipitation radar data based on multi-resolution analysis (mra) of wavelet analysis. *Advances in Space Research*, Elsevier, v. 37, n. 12, p. 2197–2201, 2006.
- ASKELSON, M. A.; AUBAGNAC, J.-P.; STRAKA, J. M. An adaptation of the barnes filter applied to the objective analysis of radar data. *Monthly weather review*, v. 128, n. 9, p. 3050–3082, 2000.
- AUSTIN, P. M. Relation between measured radar reflectivity and surface rainfall. *Monthly Weather Review*, v. 115, n. 5, p. 1053–1070, 1987.
- AUSTIN, P. M.; BEMIS, A. C. A quantitative study of the “bright band” in radar precipitation echoes. *Journal of Meteorology*, v. 7, n. 2, p. 145–151, 1950.
- BANDLER, W.; KOHOUT, L. Fuzzy power sets and fuzzy implication operators. *Fuzzy Sets and Systems*, Elsevier, v. 4, n. 1, p. 13–30, 1980.
- BARROS, L. C.; BASSANEZI, R. C. *Tópicos de lógica fuzzy e biomatemática*. [S.l.]: Unicamp-Imecc, 2006.
- BASSAN, J. M. et al. Application of weather radar cappi data to verify nwp rainfall accumulation data. *Meteorology and Atmospheric Physics*, Springer, v. 127, n. 6, p. 725–743, 2015.
- BATTAN, L. J. Radar observation of the atmosphere. 1973.
- BELLERBY, T. et al. Rainfall estimation from a combination of trmm precipitation radar and goes multispectral satellite imagery through the use of an artificial neural network. *Journal of applied Meteorology*, v. 39, n. 12, p. 2115–2128, 2000.
- BERENGUER, M. et al. A fuzzy logic technique for identifying nonprecipitating echoes in radar scans. *Journal of Atmospheric and Oceanic Technology*, v. 23, n. 9, p. 1157–1180, 2006.
- BERNDT, C.; RABIEI, E.; HABERLANDT, U. Geostatistical merging of rain gauge and radar data for high temporal resolutions and various station density scenarios. *Journal of Hydrology*, Elsevier, v. 508, p. 88–101, 2014.
- BLAHAK, U. Analysis of the extinction effect on precipitation measurements with c-band radar by means of simulation and measurement; analyse des extinktionseffektes bei niederschlagsmessungen mit einem c-band radar anhand von simulation und messung. Karlsruhe Univ.(TH)(Germany). Fakultæt fuer Physik; Karlsruhe Univ.(TH)(Germany). Inst. fuer Meteorologie und Klimaforschung, 2005.

- BROWNING, K. Meteorological applications of radar. *Reports on progress in physics*, IOP Publishing, v. 41, n. 5, p. 761, 1978.
- BROWNING, K. A. *Nowcasting*. [S.l.]: Academic Press New York, 1982.
- CAVALCANTI, I. F. A. Large scale and synoptic features associated with extreme precipitation over south america: A review and case studies for the first decade of the 21st century. *Atmospheric Research*, Elsevier, v. 118, p. 27–40, 2012.
- CERRI, L. E. S. Riscos geológicos associados a escorregamentos: uma proposta para a prevenção de acidentes. *Rio Claro*, 1993.
- CHARBA, J.; LIANG, F. Quality control of gridded national radar reflectivity data. In: *21st Conference on Weather Analysis and Forecasting/17th Conference on Numerical Weather Prediction*. [S.l.: s.n.], 2005.
- COBB, K. M. et al. El nino/southern oscillation and tropical pacific climate during the last millennium. *Nature*, Nature Publishing Group, v. 424, n. 6946, p. 271–276, 2003.
- COLE, S. J.; MOORE, R. J. Hydrological modelling using raingauge-and radar-based estimators of areal rainfall. *Journal of Hydrology*, Elsevier, v. 358, n. 3, p. 159–181, 2008.
- CONWAY, B. An overview of nowcasting techniques. In: *SAF Training Workshop—Nowcasting and Very Short Range Forecasting*. [S.l.: s.n.], 1998.
- CRESSMAN, G. P. An operational objective analysis system. *Monthly Weather Review*, v. 87, n. 10, p. 367–374, 1959.
- DIXON, M.; WIENER, G. Titan: Thunderstorm identification, tracking, analysis, and nowcasting—a radar-based methodology. *Journal of Atmospheric and Oceanic Technology*, v. 10, n. 6, p. 785–797, 1993.
- DOVIAK, R. J.; ZRNIC, D. S. *Doppler Radar & Weather Observations*. [S.l.]: Academic press, 1993.
- DUBOIS, D.; PRADE, H. New results about properties and semantics of fuzzy set-theoretic operators. In: *Fuzzy Sets*. [S.l.]: Springer, 1980. p. 59–75.
- DUTTA, D. et al. An artificial neural network based approach for estimation of rain intensity from spectral moments of a doppler weather radar. *Advances in Space Research*, Elsevier, v. 47, n. 11, p. 1949–1957, 2011.
- FALCONER, P. D. A radar-based climatology of thunderstorm days across new york state. *Journal of climate and applied meteorology*, v. 23, n. 7, p. 1115–1120, 1984.
- FEITOSA, H. d. A. *Um prelúdio à lógica*. [S.l.]: Unesp, 2005.
- FIGUEIREDO, J. C. Pluviometria para a região central do estado de São Paulo utilizando ecos de radar meteorológico. *Energ. Agric., Botucatu*, vol. 22, n.4, 2007, p.79-97, 2005.
- FILHO, A. R. Os deslizamentos de encostas nas favelas em áreas de risco da “suíça brasileira”(the landslides of hillsides in the slum quarters in the areas of risk of “brazilian switzerland”). *Acta Geográfica*, v. 6, n. 11, p. 23–34, 2012.

- FRENCH, M. N.; ANDRIEU, H.; KRAJEWSKI, W. F. Uncertainty in vertically integrated liquid water content due to radar reflectivity observation error. *Journal of Atmospheric and Oceanic Technology*, v. 12, n. 2, p. 404–409, 1995.
- GILES, R. Łukasiewicz logic and fuzzy set theory. *International Journal of Man-Machine Studies*, Elsevier, v. 8, n. 3, p. 313–327, 1976.
- GOMIDE, F. A. C.; GUDWIN, R. R. Modelagem, controle, sistemas e lógica fuzzy. *SBA Controle e Automação*, v. 4, n. 3, p. 97–115, 1994.
- GORGUCCI, E. et al. The influence of antenna radome on weather radar calibration and its real-time assessment. *Journal of Atmospheric and Oceanic Technology*, v. 30, n. 4, p. 676–689, 2013.
- GUIDICINI, G.; IWASA, O. Y. *Ensaio de correlação entre pluviosidade e escorregamentos em meio tropical úmido*. [S.l.]: IPT, 1976.
- GUJARATI, D. N.; PORTER, D. C. *Econometria Básica-5*. [S.l.]: McGraw Hill Brasil, 2011.
- GUPTA, M.; QI, J. Theory of t-norms and fuzzy inference methods. *Fuzzy sets and systems*, Elsevier, v. 40, n. 3, p. 431–450, 1991.
- HADDAD, B. et al. Modeling anomalous radar propagation using first-order two-state markov chains. *Atmospheric research*, Elsevier, v. 52, n. 4, p. 283–292, 2000.
- HALLAK, R.; FILHO, A. J. A. P. Metodologia para análise de desempenho de simulações de sistemas convectivos na região metropolitana de são paulo com o modelo arps: sensibilidade a variações com os esquemas de advecção e assimilação de dados. *Revista Brasileira de Meteorologia*, scielo, v. 26, p. 591 – 608, 12 2011. ISSN 0102-7786. Disponível em: <[http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S0102-77862011000400009&nrm=iso](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0102-77862011000400009&nrm=iso)>.
- HELENE, O. *Metodos dos Minimos Quadrados*. [S.l.]: Editora Livraria da Fisica, 2006.
- HOLTON, J. R.; DMOWSKA, R.; PHILANDER, S. G. *El Niño, La Niña, and the southern oscillation*. [S.l.]: Academic press, 1989. v. 46.
- HUGGEL, A.; SCHMID, W.; WALDVOGEL, A. Raindrop size distributions and the radar bright band. *Journal of Applied Meteorology*, v. 35, n. 10, p. 1688–1701, 1996.
- HUTCHINSON, C. et al. *The ARRL handbook for radio amateurs*. [S.l.]: Amer Radio Relay League, 2000.
- ISLAM, T. et al. Artificial intelligence techniques for clutter identification with polarimetric radar signatures. *Atmospheric Research*, Elsevier, v. 109, p. 95–113, 2012.
- JONES, D. M. *Rainfall drop size-distribution and radar reflectivity*. [S.l.]: Defense Technical Information Center, 1956.
- KAY, A. et al. Use of very high resolution climate model data for hydrological modelling: baseline performance and future flood changes. *Climatic Change*, Springer, v. 133, n. 2, p. 193–208, 2015.

- KODAMA, Y.-M. Large-scale common features of subtropical precipitation zones (the baiu frontal zone, the spcz, and the sacz). part i: Characteristics of subtropical frontal zones. *J. Meteor. Soc. Japan*, v. 70, p. 813–836, 1992.
- KOKITSU, J. *Transferência de Tecnologias para Aplicação direta ao Monitoramento e Nowcasting Usando os Radares Meteorológicos Doppler do IPMet-UNESP*. [S.l.]: Relatório Técnico (Bolsa de Participação em Curso ou Estágio Técnico no Exterior, Período: 01/09/2005 a 01/10/2005), FAPESP Processo, 2005.
- KOUSKY, V.; CAVALCANTI, I. Eventos oscilação sul-el niño: características, evolução e anomalias de precipitação. *Ciência e Cultura*, v. 36, n. 11, p. 1888–1899, 1984.
- KOUSKY, V. E.; KAGANO, M. T.; CAVALCANTI, I. F. A review of the southern oscillation: oceanic-atmospheric circulation changes and related rainfall anomalies. *Tellus A*, Wiley Online Library, v. 36, n. 5, p. 490–504, 1984.
- KOZU, T.; NAKAMURA, K. Rainfall parameter estimation from dual-radar measurements combining reflectivity profile and path-integrated attenuation. *Journal of Atmospheric and Oceanic Technology*, v. 8, n. 2, p. 259–270, 1991.
- KRAJEWSKI, W. F.; VIGNAL, B. Evaluation of anomalous propagation echo detection in wsr-88d data: A large sample case study. *Journal of Atmospheric and Oceanic Technology*, v. 18, n. 5, p. 807–814, 2001.
- KRAJEWSKI, W. F.; VIGNAL, B. Evaluation of anomalous propagation echo detection in wsr-88d data: A large sample case study. *Journal of Atmospheric and Oceanic Technology*, v. 18, n. 5, p. 807–814, 2001.
- LAKSHMANAN, V. et al. A real-time, three-dimensional, rapidly updating, heterogeneous radar merger technique for reflectivity, velocity, and derived products. *Weather and Forecasting*, v. 21, n. 5, p. 802–823, 2006.
- LHERMITTE, R. M. Dual-doppler radar observations of convective storm circulation. In: *14th Conference on radar meteorology (preprints)*. [S.l.: s.n.], 1970. p. 139–144.
- MAMDANI, E. H. Application of fuzzy algorithms for control of simple dynamic plant. In: *IET. Proceedings of the Institution of Electrical Engineers*. [S.l.], 1974. v. 121, n. 12, p. 1585–1588.
- MARCELINO, E. V.; NUNES, L. H.; KOBİYAMA, M. Mapeamento de risco de desastres naturais do estado de santa catarina. *Caminhos de Geografia*, v. 7, n. 17, 2006.
- MARSHALL, J. S.; PALMER, W. M. K. The distribution of raindrops with size. *Journal of meteorology*, v. 5, n. 4, p. 165–166, 1948.
- MARTENS, B. et al. Merging weather radar observations with ground-based measurements of rainfall using an adaptive multiquadric surface fitting algorithm. *Journal of Hydrology*, Elsevier, v. 500, p. 84–96, 2013.
- MARZANO, F. et al. Hydrometeor classification from dual-polarized weather radar: extending fuzzy logic from s-band to c-band data. *Advances in Geosciences*, v. 7, p. 109–114, 2006.

- MEISCHNER, P. *Weather radar: principles and advanced applications*. [S.l.]: Springer Science & Business Media, 2004.
- MESNARD, F.; SAUVAGEOT, H. Climatology of anomalous propagation radar echoes in a coastal area. *Journal of Applied Meteorology and Climatology*, v. 49, n. 11, p. 2285–2300, 2010.
- MILLER, L.; STRAUCH, R. A dual doppler radar method for the determination of wind velocities within precipitating weather systems. *Remote Sensing of Environment*, Elsevier, v. 3, n. 4, p. 219–235, 1974.
- MOREAU, E.; TESTUD, J.; BOUAR, E. L. Rainfall spatial variability observed by x-band weather radar and its implication for the accuracy of rainfall estimates. *Advances in water resources*, Elsevier, v. 32, n. 7, p. 1011–1019, 2009.
- MOSZKOWICZ, S.; CIACH, G. J.; KRAJEWSKI, W. F. Statistical detection of anomalous propagation in radar reflectivity patterns. *Journal of Atmospheric and Oceanic Technology*, v. 11, n. 4, p. 1026–1034, 1994.
- NOVO, S. Pronóstico inmediato de tormentas convectivas por radar-una actualización. *Revista Brasileira de Meteorologia*, SciELO Brasil, v. 23, p. 41–50, 2008.
- PEDERSEN, L.; JENSEN, N. E.; MADSEN, H. Calibration of local area weather radar—identifying significant factors affecting the calibration. *Atmospheric Research*, Elsevier, v. 97, n. 1, p. 129–143, 2010.
- PISCIOTTANO, G. et al. El niño-southern oscillation impact on rainfall in uruguay. *Journal of Climate*, v. 7, n. 8, p. 1286–1302, 1994.
- QUEIROZ, A. P. d. *Monitoramento e Previsão Imediata de Tempestades Severas Usando dados de Radar*. Tese (Dissertação de Mestrado) — Instituto Nacional de Pesquisas Espaciais, 2009.
- RABIEI, E.; HABERLANDT, U. Applying bias correction for merging rain gauge and radar data. *Journal of Hydrology*, Elsevier, 2015.
- RAGHAVAN, S. *Radar meteorology*. [S.l.]: Springer, 2003.
- RINEHART, R. E. *Radar for meteorologists*. [S.l.]: University of North Dakota, Office of the President, 2004.
- ROPELEWSKI, C. F.; HALPERT, M. Precipitation patterns associated with the high index phase of the southern oscillation. *Journal of climate*, v. 2, n. 3, p. 268–284, 1989.
- ROSENFELD, D.; WOLFF, D. B.; ATLAS, D. General probability-matched relations between radar reflectivity and rain rate. *Journal of applied meteorology*, v. 32, n. 1, p. 50–72, 1993.
- ROSS, T. J. *Fuzzy logic with engineering applications*. [S.l.]: John Wiley & Sons, 2009.
- RYZHKOV, A. V.; ZRNIC, D. S. Polarimetric rainfall estimation in the presence of anomalous propagation. *Journal of Atmospheric and Oceanic Technology*, v. 15, n. 6, p. 1320–1330, 1998.

- SÁNCHEZ-DIEZMA, R.; ZAWADZKI, I.; SEMPERE-TORRES, D. Identification of the bright band through the analysis of volumetric radar data. *Journal of Geophysical Research: Atmospheres (1984–2012)*, Wiley Online Library, v. 105, n. D2, p. 2225–2236, 2000.
- SAUVAGEOT, H. *Radar meteorology*. [S.l.]: Artech House Publishers, 1992.
- SEO, B.-C.; KRAJEWSKI, W. F.; MISHRA, K. V. Using the new dual-polarimetric capability of wsr-88d to eliminate anomalous propagation and wind turbine effects in radar-rainfall. *Atmospheric Research*, Elsevier, v. 153, p. 296–309, 2015.
- SILVA, E. M.; ALVES, J. M. B.; CAMPOS, J. N. B. Uma aplicação de conjuntos difusos na otimização do prognóstico de consenso sazonal de chuva no nordeste do brasil. *Revista Brasileira de Meteorologia*, SciELO Brasil, v. 22, n. 1, p. 83–93, 2007.
- SINCLAIR, S.; PEGRAM, G. Combining radar and rain gauge rainfall estimates using conditional merging. *Atmospheric Science Letters*, Wiley Online Library, v. 6, n. 1, p. 19–22, 2005.
- SKOLINK, M. *Radar Handbook, Chapter 18.37–18.46*. [S.l.]: McGraw-Hill Publishing Co, 1990.
- SMITH, C. J. The reduction of errors caused by bright bands in quantitative rainfall measurements made using radar. *Journal of Atmospheric and Oceanic Technology*, v. 3, n. 1, p. 129–141, 1986.
- SMYTH, T.; ILLINGWORTH, A. Radar estimates of rainfall rates at the ground in bright band and non-bright band events. *Quarterly Journal of the Royal Meteorological Society*, Wiley Online Library, v. 124, n. 551, p. 2417–2434, 1998.
- SRIVASTAVA, R.; TIAN, L. Measurement of attenuation by a dual-radar method: Concept and error analysis. *Journal of Atmospheric and Oceanic Technology*, v. 13, n. 5, p. 937–947, 1996.
- STEINER, M.; SMITH, J. A. Use of three-dimensional reflectivity structure for automated detection and removal of nonprecipitating echoes in radar data. *Journal of Atmospheric and Oceanic Technology*, v. 19, n. 5, p. 673–686, 2002.
- SUGENO, M.; KANG, G. Structure identification of fuzzy model. *Fuzzy sets and systems*, Elsevier, v. 28, n. 1, p. 15–33, 1988.
- SZCZEŚNIAK, M.; PINIEWSKI, M. Improvement of hydrological simulations by applying daily precipitation interpolation schemes in meso-scale catchments. *Water*, Multidisciplinary Digital Publishing Institute, v. 7, n. 2, p. 747–779, 2015.
- TAKAGI, T.; SUGENO, M. Fuzzy identification of systems and its applications to modeling and control. *Systems, Man and Cybernetics, IEEE Transactions on*, IEEE, n. 1, p. 116–132, 1985.
- THORND AHL, S.; RASMUSSEN, M. R. Marine x-band weather radar data calibration. *Atmospheric Research*, Elsevier, v. 103, p. 33–44, 2012.
- TRAPP, R. J.; III, C. A. D. Radar data objective analysis. *Journal of Atmospheric and Oceanic Technology*, v. 17, n. 2, p. 105–120, 2000.

- WEBER, S. A general concept of fuzzy connectives, negations and implications based on t-norms and t-conorms. *Fuzzy sets and systems*, Elsevier, v. 11, n. 1, p. 103–113, 1983.
- WILKS, D. S. *Statistical methods in the atmospheric sciences*. [S.l.]: Academic press, 2011. v. 100.
- WILSON, J. W.; BRANDES, E. A. Radar measurement of rainfall—a summary. *Bulletin of the American Meteorological Society*, v. 60, n. 9, p. 1048–1058, 1979.
- YAGER, R. R. On a general class of fuzzy connectives. *Fuzzy sets and Systems*, Elsevier, v. 4, n. 3, p. 235–242, 1980.
- YANG, Y.; CHEN, X.; QI, Y. Classification of convective/stratiform echoes in radar reflectivity observations using a fuzzy logic algorithm. *Journal of Geophysical Research: Atmospheres*, Wiley Online Library, v. 118, n. 4, p. 1896–1905, 2013.
- YOO, C. et al. Interpretation of mean-field bias correction of radar rain rate using the concept of linear regression. *Hydrological Processes*, Wiley Online Library, v. 28, n. 19, p. 5081–5092, 2014.
- ZADEH, L. A. Fuzzy sets. *Information and control*, Elsevier, v. 8, n. 3, p. 338–353, 1965.
- ZADEH, L. A. Outline of a new approach to the analysis of complex systems and decision processes. *Systems, Man and Cybernetics, IEEE Transactions on*, IEEE, n. 1, p. 28–44, 1973.
- ZHANG, J.; HOWARD, K.; GOURLEY, J. Constructing three-dimensional multiple-radar reflectivity mosaics: Examples of convective storms and stratiform rain echoes. *Journal of Atmospheric and Oceanic Technology*, v. 22, n. 1, p. 30–42, 2005.
- ZHANG, P.; ZHANG, J.; CHEN, M. Economic impacts of climate change on chinese agriculture: The importance of relative humidity and other climatic variables. *Available at SSRN*, 2015.