

UNIVERSIDADE FEDERAL DE PELOTAS
Instituto de Física e Matemática
Programa de Pós-Graduação em Modelagem Matemática



Dissertação

**Redes Neurais Convolucionais Recorrentes Aplicadas a Previsão
Meteorológica de Curto Prazo Através de Imagens de Radar**

Felipe Copceski Rossatto

Pelotas, 2023

Felipe Copceski Rossatto

**Redes Neurais Convolucionais Recorrentes Aplicadas a Previsão
Meteorológica de Curto Prazo Através de Imagens de Radar**

Dissertação apresentada ao Programa de Pós-Graduação em Modelagem Matemática do Instituto de Física e Matemática da Universidade Federal de Pelotas, como requisito parcial à obtenção do título de Mestre em Modelagem Matemática.

Orientador: Prof. Dr. Fabrício Pereira Härter
Coorientador: Prof. Dr. Élcio Hideiti Shiguemori
Colaborador: Prof. Dr. Leonardo Calvetti

Pelotas, 2023

Universidade Federal de Pelotas / Sistema de Bibliotecas
Catalogação na Publicação

R823r Rossatto, Felipe Copceski

Redes neurais convolucionais recorrentes aplicadas a
previsão meteorológica de curto prazo através de imagens
de radar / Felipe Copceski Rossatto ; Fabrício Pereira
Härter, orientador ; Elcio Hideiti Shiguemori, coorientador.
— Pelotas, 2023.

160 f. : il.

Dissertação (Mestrado) — Modelagem Matemática,
Instituto de Física e Matemática, Universidade Federal de
Pelotas, 2023.

1. Redes neurais. 2. Meteorologia. 3. Nowcasting. 4.
Radar. I. Härter, Fabrício Pereira, orient. II. Shiguemori,
Elcio Hideiti, coorient. III. Título.

CDD : 551.6353

Felipe Copceski Rossatto

**Redes Neurais Convolucionais Recorrentes Aplicadas a Previsão
Meteorológica de Curto Prazo Através de Imagens de Radar**

Dissertação aprovada, como requisito parcial, para obtenção do grau de Mestre em Modelagem Matemática, Programa de Pós-Graduação em Modelagem Matemática, Instituto de Física e Matemática, Universidade Federal de Pelotas.

Data da Defesa: 04 de setembro de 2023

Banca Examinadora:

Prof. Dr. Fabrício Pereira Härter (orientador).

Doutor em Computação Aplicada pelo Instituto Nacional de Pesquisas Espaciais.

Prof. Dr. Elcio Hideiti Shiguemori (coorientador).

Doutor em Computação Aplicada pelo Instituto Nacional de Pesquisas Espaciais.

Prof. Dra. Rita de Cássia Marques Alves.

Doutora em Meteorologia pela Universidade de São Paulo.

Prof. Dr. Leonardo Calvetti.

Doutor em Meteorologia pela Universidade de São Paulo.

Prof. Dr. Régis Sperotto de Quadros.

Doutor em Matemática Aplicada pela *Technische Universität Darmstadt* - Alemanha.

Nem todos os que vagueiam estão perdidos.
— J. R. R. TOLKIEN

RESUMO

ROSSATTO, Felipe Copceski. **Redes Neurais Convolucionais Recorrentes Aplicadas a Previsão Meteorológica de Curto Prazo Através de Imagens de Radar.** Orientador: Fabrício Pereira Härter. 2023. 160 f. Exame de Qualificação (Mestrado em Modelagem Matemática) - Programa de Pos-Graduação em Modelagem Matemática, Instituto de Física e Matemática, Universidade Federal de Pelotas, Pelotas, 2023.

Neste trabalho, propõe-se um modelo baseado em Redes Neurais Convolucionais Recorrentes (*RNCR*), para previsão meteorológica de curto prazo (*nowcasting*). Esta abordagem é uma alternativa a técnicas tradicionais de extrapolação estatística. Para isso, foi utilizada uma *RNCR* supervisionada de aprendizagem preditiva conhecida como *PredRNN++*. Foram utilizados dados (imagens) de quatro radares localizados no sul do Brasil, disponíveis para acesso gratuito no site do *INPE* (Instituto Nacional de Pesquisas Espaciais), como entrada e saída da rede. Na saída, o alvo ou professor, são imagens de 6 a 120 minutos à frente no tempo, em relação a entrada, ou seja, o que se deseja prever. Para se verificar a qualidade da previsão gerada pela *PredRNN++*, além de uma análise empírica das imagens previstas, utilizam-se as métricas estatísticas *RMSE*, *SSIM* e *MAE* explorando um evento extremo, ocorrido no sul do Brasil, em 12 de junho de 2018. A rede mostrou-se uma alternativa viável para previsão de *nowcasting*, uma vez que reproduz a intensidade e a localização dos sistemas emulados.

Palavras-chave: Redes Neurais. Meteorologia. Nowcasting. Radar.

ABSTRACT

ROSSATTO, Felipe Copceski. **Recurrent Convolutional Neural Networks Applied to Short-Term Weather Forecasting Through Radar Images..** Advisor: Fabrício Pereira Härter. 2023. 160 f. Qualifying Exam (Master's in Mathematical Modeling) - Postgraduate Program in Mathematical Modeling, Institute of Physics and Mathematics, Federal University of Pelotas, Pelotas, 2023.

In this study, a model based on Recurrent Convolutional Neural Networks (RCNN) is proposed for short-term meteorological forecasting (nowcasting). This approach presents an alternative to traditional statistical extrapolation techniques. The chosen methodology involves the implementation of a supervised predictive learning RCNN model known as PredRNN++. The model is trained and evaluated using data in the form of images captured by four radars situated in the southern region of Brazil. These radar images are made freely accessible via the website of the National Institute for Space Research (INPE). The images serve as both input and output for the neural network. For the output, the model aims to predict images ranging from 6 to 120 minutes ahead in time, relative to the provided input images. The forecasted images are compared against the actual observations to assess the accuracy of the PredRNN++ model. This evaluation process involves empirical analysis of the predicted images, along with the application of statistical metrics such as Root Mean Square Error (RMSE), Structural Similarity Index (SSIM), and Mean Absolute Error (MAE). The assessment focuses on an extreme weather event that occurred in the southern region of Brazil on June 12, 2018. The outcomes of the study indicate that the PredRNN++ model demonstrates promise as a viable alternative for nowcasting predictions. This is attributed to its ability to effectively replicate the intensity and spatial distribution of the emulated meteorological systems.

Keywords: Neural Networks. Meteorology. Nowcasting. Radar.

LISTA DE FIGURAS

Figura 1	Exemplo da aplicação do <i>kernel</i> de convolução em dados de entrada. Fonte: Rahul Kadam/Medium.	24
Figura 2	Estrutura da Rede PredRNN++. Fonte: Wang et al. (2018)	27
Figura 3	Estrutura do <i>GHU</i> . Fonte: Wang et al. (2018)	28
Figura 4	Diagrama apresentando os processos metodológicos.	30
Figura 5	Interface para download dos dados da plataforma SIGMA.	32
Figura 6	Área de cobertura do radar de Canguçu. Fonte: Google Maps.	33
Figura 7	Área de cobertura do radar de Chapecó. Fonte: <i>Google Maps</i>	34
Figura 8	Área de cobertura do radar de Morro da Igreja. Fonte: <i>Google Maps</i>	35
Figura 9	Área de cobertura do radar de Santiago. Fonte: Google Maps.	36
Figura 10	Exemplo de imagens baixadas diretamente do SIGMA.	37
Figura 11	Resultados do treinamento com 100, 500 e 1000 épocas.	44
Figura 12	Resultados do treinamento com 3000, 5000 e 7000 épocas.	44
Figura 13	Resultados do treinamento com 9000 e 10000 épocas.	45
Figura 14	Torre danificada.	48
Figura 15	Imagens de satélite nos horários 00h15, 00h30 e 00h45 do dia 12 de junho de 2018.	49
Figura 16	Carta em Superfície no dia 11/06/2018 às 18h00 e no dia 12/06/2018 às 12h00 e às 12h06.	49
Figura 17	Carta em Altitude no dia 11/06/2018 às 18h00 e no dia 12/06/2018 às 12h00 e às 12h06.	49
Figura 18	Imagens do radar de Chapecó-SC entre 23h02 e 23h56 do dia 11/06/2018.	52
Figura 19	Previsão para o dia 12/06/2018 às 00h02 e às 00h08.	53
Figura 20	Previsão para o dia 12/06/2018 às 00h14 e às 00h20.	54
Figura 21	Previsão para o dia 12/06/2018 às 00h26 e às 00h32.	55
Figura 22	Previsão para o dia 12/06/2018 à 00h38 e à 00h44.	56
Figura 23	Previsão para o dia 12/06/2018 à 00h50 e à 00h56.	57
Figura 24	Imagens do radar de Chapecó-SC entre 00h02 e 00h56 do dia 12/06/2018.	59
Figura 25	Previsão para o dia 12/06/2018 à 01h02 e à 01h08	60
Figura 26	Previsão para o dia 12/06/2018 à 01h14 e à 01h20.	61
Figura 27	Previsão para o dia 12/06/2018 à 01h26 e à 01h32.	62
Figura 28	Previsão para o dia 12/06/2018 à 01h38 e à 01h44.	63
Figura 29	Previsão para o dia 12/06/2018 à 01h50 e à 01h56.	64

Figura 30	Imagens do radar de Chapecó-SC entre 01h02 e 01h56 do dia 12/06/2018.	66
Figura 31	Previsão para o dia 12/06/2018 às 02h02 e às 02h08.	67
Figura 32	Previsão para o dia 12/06/2018 às 02h14 e às 02h20.	68
Figura 33	Previsão para o dia 12/06/2018 às 02h26 e às 02h32.	69
Figura 34	Previsão para o dia 12/06/2018 às 02h38 e às 02h44.	70
Figura 35	Previsão para o dia 12/06/2018 às 02h50 e 02h56.	71
Figura 36	Imagens do radar de Chapecó-SC entre às 02h02 e às 02h56.	73
Figura 37	Previsão para o dia 12/06/2018 às 03h02 e às 03h08.	74
Figura 38	Previsão para o dia 12/06/2018 às 03h14 e às 03h20.	75
Figura 39	Previsão para o dia 12/06/2018 às 03h26 e às 03h32.	76
Figura 40	Previsão para o dia 12/06/2018 às 03h38 e às 03h44.	77
Figura 41	Previsão para o dia 12/06/2018 às 03h50 e às 03h56.	78
Figura 42	Imagens do radar de Chapecó-SC entre 21h20 e 23h14 do dia 11/06/2018.	81
Figura 43	Previsão para o dia 11/06/2018 às 23h20 e às 23h26.	82
Figura 44	Previsão para o dia 11/06/2018 às 23h32 e às 23h38.	83
Figura 45	Previsão para o dia 11/06/2018 às 23h44 e às 23h50.	84
Figura 46	Previsão para o dia 11/06/2018 e dia 12/06/2018 às 23h56 e às 00h02.	85
Figura 47	Previsão para o dia 12/06/2018 às 00h08 e às 00h14.	86
Figura 48	Previsão para o dia 12/06/2018 às 00h20 e às 00h26.	87
Figura 49	Previsão para o dia 12/06/2018 às 00h32 e às 00h38.	88
Figura 50	Previsão para o dia 12/06/2018 às 00h44 e às 00h50.	89
Figura 51	Previsão para o dia 12/06/2018 às 00h56 e às 01h02.	90
Figura 52	Previsão para o dia 12/06/2018 às 01h08 e às 01h14.	91
Figura 53	Entrada do dia 14/08/2020 entre 15h10 e 16h04.	101
Figura 54	Previsão das 16h10 e 16h16.	102
Figura 55	Previsão das 16h22 e 16h28.	103
Figura 56	Previsão das 16h34 e 16h40.	104
Figura 57	Previsão das 16h46 e 16h52.	105
Figura 58	Previsão das 16h58 e 17h04.	106
Figura 59	Entrada do dia 14/08/2020 entre 17h10 e 18h04.	107
Figura 60	Previsão das 18h10 e 18h16.	108
Figura 61	Previsão das 18h22 e 18h28.	109
Figura 62	Previsão das 18h34 e 18h40.	110
Figura 63	Previsão das 18h46 e 18h52.	111
Figura 64	Previsão das 18h58 e 19h04.	112
Figura 65	Entrada do dia 03/06/2020 entre 19h11 e 20h05.	113
Figura 66	Previsão das 20h11 e 20h17.	114
Figura 67	Previsão das 20h23 e 20h29.	115
Figura 68	Previsão das 20h35 e 20h41.	116
Figura 69	Previsão das 20h47 e 20h53.	117
Figura 70	Previsão das 20h59 e 21h05.	118
Figura 71	Entrada do dia 03/06/2020 entre 21h11 e 22h05.	119
Figura 72	Previsão das 22h11 e 22h17.	120
Figura 73	Previsão das 22h23 e 22h29.	121
Figura 74	Previsão das 22h35 e 22h41.	122

Figura 75	Previsão das 22h47 e 22h53.	123
Figura 76	Previsão das 22h59 e 23h05.	124
Figura 77	Entrada do dia 03/02/2021 entre 18h46 e 19h40.	125
Figura 78	Previsão das 19h46 e 19h52.	126
Figura 79	Previsão das 19h58 e 20h04.	127
Figura 80	Previsão das 20h10 e 20h16.	128
Figura 81	Previsão das 20h22 e 20h28.	129
Figura 82	Previsão das 20h34 e 20h40.	130
Figura 83	Entrada do dia 03/02/2021 entre 21h16 e 22h10.	131
Figura 84	Previsão das 22h16 e 22h22.	132
Figura 85	Previsão das 22h28 e 22h34.	133
Figura 86	Previsão das 22h40 e 22h46.	134
Figura 87	Previsão das 22h52 e 22h58.	135
Figura 88	Previsão das 23h04 e 23h10.	136
Figura 89	Entrada do dia 21/04/2022 entre 12h26 e 13h20.	137
Figura 90	Previsão das 13h26 e 13h32.	138
Figura 91	Previsão das 13h38 e 13h44.	139
Figura 92	Previsão das 13h50 e 13h56.	140
Figura 93	Previsão das 14h02 e 14h08.	141
Figura 94	Previsão das 14h14 e 14h20.	142
Figura 95	Entrada do dia 21/04/2022 entre 14h41 e 15h35.	143
Figura 96	Previsão das 15h41 e 15h47.	144
Figura 97	Previsão das 15h53 e 15h59.	145
Figura 98	Previsão das 16h05 e 16h11.	146
Figura 99	Previsão das 16h17 e 16h23.	147
Figura 100	Previsão das 16h29 e 16h35.	148
Figura 101	Entrada do dia 17/08/2020 entre 19h24 e 20h18.	149
Figura 102	Previsão das 20h24 e 20h30.	150
Figura 103	Previsão das 20h36 e 20h42.	151
Figura 104	Previsão das 20h48 e 20h54.	152
Figura 105	Previsão das 21h00 e 21h06.	153
Figura 106	Previsão das 21h12 e 21h18.	154
Figura 107	Entrada do dia 17/08/2020 entre 21h24 e 22h18.	155
Figura 108	Previsão das 22h24 e 22h30.	156
Figura 109	Previsão das 22h36 e 22h42.	157
Figura 110	Previsão das 22h48 e 22h54.	158
Figura 111	Previsão das 23h00 e 23h06.	159
Figura 112	Previsão das 23h12 e 23h18.	160

LISTA DE TABELAS

Tabela 1	Métricas durante o treinamento.	45
Tabela 2	Métricas entre 00h02 e 00h56.	58
Tabela 3	Métricas entre 01h02 e 01h56.	65
Tabela 4	Métricas entre 02h02 e 02h56.	72
Tabela 5	Métricas entre 03h02 e 03h56.	79
Tabela 6	Métricas entre 23h20 e 01h14 para a previsão de 20 imagens. . . .	92

LISTA DE ABREVIATURAS E SIGLAS

Adam	Adaptive Moment Estimation
BN	Rede Bayesiana (Bayesian Network)
CNN	Redes Neurais Convolucionais (Convolutional neural network)
ConvLSTM	Convolutional Long Short Term Memory
CPTEC	Centro de Previsão de Tempo e Estudos Climáticos
CrevNet	Conditionally Reversible Network
dBZ	Decibéis de Z
E3D	Eidetic 3D
GPU	Unidade Gráfica de Processamento
IA	Inteligências Artificial
INPE	Instituto Nacional de Pesquisas Espaciais
LSTM	Long Short Term Memory
LT	Linha de Transmissão
MAE	Mean Absolute Error (Média do erro absoluto)
MLP	Multi Layer Perceptron (Perceptron de Múltiplas Camadas)
MNIST	Modified National Institute of Standards and Technology database
MsPred	Multi-Scale Hierarchical Video Prediction
NWP	Previsão numérica do tempo (Numerical weather prediction)
PhyDNet	Disentangling Physical Dynamics Network
PredRNN	Predictive Recurrent neural network
RGB	Sistema de cores (do inglês: red, green, blue)
RMSE	Root-mean-square error (Raiz quadrada do erro médio)
RNA	Redes Neurais Artificiais
RNCR	Redes Neurais Convolucionais Recorrentes
RNN	Redes Neurais Recorrentes (Recurrent neural network)
RS	Estado do Rio Grande do Sul

SA	Self-Attention
SC	Estado de Santa Catarina
SSIM	Structural similarity index measure (Medida do índice de similaridade estrutural)
TrajGRU	Trajectory Gated Recurrent Unit

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Objetivos do trabalho	17
1.2	Trabalhos Relacionados	17
1.3	Estrutura e organização do trabalho	20
2	REDES NEURAS ARTIFICIAIS	21
2.1	Redes Neurais Recorrentes	21
2.2	A Rede <i>LSTM</i> - <i>Long Short Term Memory</i>	22
2.3	Redes Neurais Convolucionais	23
2.4	<i>ConvLSTM</i>	25
2.5	Rede Neural Recorrente Preditiva	26
2.6	A importância dos dados	29
3	METODOLOGIA	30
3.1	Descrição e obtenção dos dados	31
3.2	Localização dos Radares Utilizados neste Trabalho	33
3.3	Pré-processamento dos dados	36
3.4	Glossário sobre alguns termos utilizados em Redes Neurais	38
3.5	Treinamento de uma Rede Neural	39
3.6	Métricas de Avaliação	40
4	RESULTADOS E DISCUSSÕES	42
4.1	Treinamento da Rede	42
4.2	Experimento	47
4.2.1	Caso de 12/06/2018 - Tornado nos estados RS/SC - Dados do Radar de Chapecó	47
4.2.2	Ambiente em Escala Sinótica na Madrugada do dia 12/06/2018	48
4.3	Horizonte de previsão aumentado para 120 minutos	80
5	CONCLUSÃO	93
	REFERÊNCIAS	95
	APÊNDICE A PREVISÃO DIA - 14/08/2020 - RADAR CHAPECÓ	101
	APÊNDICE B PREVISÃO DIA - 03/06/2020 - RADAR CHAPECÓ	113
	APÊNDICE C PREVISÃO DIA - 03/02/2021 - RADAR CHAPECÓ	125
	APÊNDICE D PREVISÃO DIA - 21/04/2022 - RADAR CHAPECÓ	137

1 INTRODUÇÃO

Desde os primórdios da nossa civilização, os estudos meteorológicos sempre estiveram presentes e exerceram um papel importante na sociedade. Na atualidade, com as mudanças climáticas que o planeta vem passando, é esperado um aumento muito grande na frequência e na intensidade de sistemas meteorológicos de grande escala. Esses sistemas podem gerar tempestades severas, furacões, tornados, ciclones, entre outros desastres naturais e são capazes de causar danos em grande magnitude (ZILLI et al., 2017). Os danos podem ser ambientais, em infraestrutura das cidades e até mesmo apresentar grandes riscos a vida humana (VUUREN; CARTER, 2014).

Modelos numéricos de equações primitivas, utilizados na Previsão Numérica de Tempo (*NWP*)¹, atingem um *skill correlation*² superior a 97% na previsão de determinadas variáveis meteorológicas, na escala de fenômenos de milhares de quilômetros, que perduram por dias, tais como as frentes frias, entretanto, apesar da melhora contínua na precisão, a *NWP* nunca será exata (SUN et al., 2014).

Para previsões localizadas, em escala de poucos quilômetros e até 3 horas, conhecidas como *Nowcasting*, os modelos numéricos não apresentam uma precisão tão elevada, em comparação com a previsão de tempo na escala de dias (BROWNING; COLLIER, 1989).

Diante do exposto, visando buscar uma alternativa a *NWP*, na última década vem se desenvolvendo estudos na área de *Machine Learning (ML)* aplicados ao *nowcasting*. Analisando-se o estado da arte na área, dentre várias técnicas, o que vem apresentando resultados bastante satisfatórios são as Redes Neurais Convolucionais Recorrentes (*RNCR*), que fazem uso de aprendizagem espaço temporal para a previsão de uma determinada sequência de imagens (OLIU; SELVA; ESCALERA, 2018). Basicamente, uma rede com aprendizagem espaço temporal tem a capacidade de analisar sequências de dados, extraíndo características e gerando previsões.

A grande diferença e principal ponto positivo das *RNCR* se dá no tipo de dados que são usados. Enquanto os modelos numéricos de previsão de tempo são inicia-

¹Do inglês - *Numerical weather prediction*

²A correlação de habilidades (*skill correlation*, em inglês) na meteorologia, refere-se à medida de quão bem um modelo de previsão meteorológica representa as características do tempo real.

lizados com dados de diferentes fontes, uma *RNCR* pode gerar previsões utilizando apenas imagens, diminuindo o tempo e custo computacional necessário para essa tarefa (SCHULTZ et al., 2021). Ademais, devido a natureza da previsão sequencial desses modelos, eles são ideais para o *nowcasting*, atingindo ótimos resultados para esse tipo de problema.

1.1 Objetivos do trabalho

Considerando o que foi mencionado, o objetivo principal deste trabalho é analisar as contribuições e aplicabilidade de técnicas de inteligência artificial, mais especificamente Redes Neurais Convolucionais Recorrentes, no campo da meteorologia, como uma alternativa aos modelos clássicos de previsão numérica de chuva para curto prazo (*nowcasting*), relacionando imagens de refletividade capturadas por diversos radares dispostos no Brasil.

O principal motivo para a escolha deste tema, foi acreditar que as técnicas mais recentes de inteligência artificial apresentam um potencial computacional imenso nos estudos dos processos atmosféricos e, conseqüentemente, possam vir a ser, se não uma alternativa, um aliado interessante a previsão do tempo.

Os objetivos específicos do trabalho são:

- Verificar dentre a literatura qual rede neural se aplica melhor para o tipo de problema proposto;
- Treinar uma Rede Neural utilizando apenas dados de imagens, que consiga realizar uma previsão de curto prazo para todos os radares treinados, com baixa complexidade computacional;
- Realizar simulações em eventos meteorológicos de diferentes escalas;
- Desenvolver e disponibilizar um banco de dados de radares brasileiros para a utilização em pesquisas futuras, auxiliando na fomentação da área de pesquisa de Redes Neurais aplicadas a meteorologia.

1.2 Trabalhos Relacionados

No final da década de 1990 e início dos anos 2000, surgiram em maior volume, pesquisas científicas em revistas indexadas, sobre a aplicação de Inteligência Artificial (*IA*) a ciências atmosféricas. Kuligowski; Barros (1998) apresentaram um modelo estatístico que combinava a Previsão Numérica de Tempo (*NWP*) e técnicas de *IA* para realizar previsão de 6 horas de precipitação líquida em áreas específicas dos Estados Unidos.

Os modelos utilizados nesse trabalho são comparados com outras quatro metodologias de previsão meteorológica e apresentaram melhores resultados. Porém, os

autores enfatizam que a deficiência na quantidade e qualidade dos dados e alta demanda computacional, são um entrave a aplicação.

Liu; Lee (1999) analisaram a capacidade de uma Rede Neural baseada no algoritmo de retro propagação do erro (*backpropagation*) realizar previsões de chuva de curto prazo, utilizando dados de múltiplas estações meteorológica na região de Hong Kong. Através dos testes realizados, os autores concluíram que a metodologia proposta apresentou bons resultados, porém inferiores aos obtidos por técnicas tradicionais. Além disso, não captou satisfatoriamente o sinal em escala sazonal. Os autores destacam que dados em maior quantidade e melhor qualidade gerariam resultados mais precisos.

Em *Bayesian Network for probabilistic weather prediction*, de Cofino et al. (2002), foi apresentado um modelo chamado de *Bayesian Network (BNs)* otimizado para a previsão de dados em uma série temporal. O modelo utiliza grafos acíclicos para capturar as dependências espaciais e temporais de diferentes estações meteorológicas de diversos locais da Península Ibérica. Os autores concluem que os primeiros resultados da pesquisa são promissores, podendo auxiliar a previsão operacional.

Maqsood; Khan; Abraham (2003) demonstrou a aplicabilidade do modelo de *Hopfield* na previsão de temperatura, velocidade do vento e umidade relativa do ar sobre o Canadá. Os autores compararam o modelo de *Hopfield* com outros três modelos de previsão e constatam que as melhores previsões são geradas quando os modelos são combinados.

No artigo de Pinson; Kariniotakis (2003) foi desenvolvido um modelo neural para a previsão de vento em locais da Irlanda, com o intuito de estimar a quantidade de energia gerada por parques eólicos num horizonte de 10 horas e 48 horas. O modelo proposto apresentou resultados promissores, sendo capaz de estimar a energia gerada com um acerto de 86,22%.

No trabalho "*Intelligent weather forecast*", de Lai et al. (2004) foi proposto um modelo para a previsão de temperatura e chuva em região costeira da China, baseado no modelo neural de De vries; Principe (1992). Os autores obtiveram um acerto de 82,23% com dados de oito estações. Entretanto, concluem que a precisão aumenta com o aumento na quantidade de dados utilizados no teinamento de rede neural.

Hayati; Shirvany (2007) e Shank et al. (2008) treinaram um Perceptron de Múltiplas Camadas (*MLP*) com dados de estações meteorológicas locais e obtiveram bons resultados para a previsão de temperatura em cidades do Irã e dos Estados Unidos.

Quanto aplicação de redes neurais a previsão de tempo, pode-se ainda citar trabalhos com resultados promissores como (GHANBARZADEH et al., 2009), (ABDULKADER, 2009), (TAN et al., 2008), (KURT; OKTAY, 2010). Entretanto, o final dos anos 2000, foi um período de letargia, quanto a inovações metodológicas de redes neurais artificiais.

Apesar da literatura mostrar um crescente aumento de aplicações de RNA à previsão de tempo e clima, os responsáveis pela grande mudança na área de inteligência artificial aplicada a meteorologia são os trabalhos de Shi et al. (2015) e Shi et al. (2017). Nesses dois trabalhos, um grupo de meteorologistas de Hong Kong deu início a uma abordagem metodológica que fazia uso de imagens de radares meteorológicos para a previsão de chuva em curto período de tempo. No trabalho de 2015 foi introduzido a rede *ConvLSTM* e no de 2017 a *TrajGRU*. Essas duas arquiteturas de Redes Neurais, principalmente a *ConvLSTM*, serviram como base de todas as outras que vieram a seguir, com a *ConvLSTM* se tornando o pilar do desenvolvimento da área.

O ponto chave da utilização dessa abordagem utilizando imagens de radares se dá na estrutura que as mesmas possuem. Uma sequência de leituras de um radar pode gerar imagens com transformações e variações complexas, à medida que evolui com as interações. Essas leituras, embora sejam diferentes conforme as interações, tem uma certa coerência e seguem uma sequência lógica nas formações dos sistemas meteorológicos. Os trabalhos Shi et al. (2015) e Shi et al. (2017) apresentaram resultados que superam métodos tradicionais de *nowcasting*, alcançando uma melhor precisão nessa previsão de curto prazo.

A capacidade de previsão de uma nova imagem de um fenômeno físico pode encontrar fundamentação científica na área chamada de *Video Prediction* (Previsão de vídeo)(MATHIEU; COUPRIE; LECUN, 2016), onde o objetivo é desenvolver redes preditivas que tenham a capacidade de extrair as correlações espaço-temporais de uma sequência de dados (nesse caso, imagens ou vídeos) a fim de prever quais serão os próximos elementos da sequência referida.

Em Mathieu; Couprie; Lecun (2016), os autores fazem uso de uma estrutura de múltiplas escalas, na qual a rede neural aprende a prever os *frames* futuros em diferentes níveis de detalhe. Isso permite que a rede capture informações temporais em diferentes resoluções espaciais, o que é importante para a previsão de eventos complexos e de longo prazo em vídeos.

Os resultados mostraram que a abordagem proposta pelos autores é capaz de gerar previsões de vídeo mais realistas e de melhor qualidade em comparação com métodos anteriores baseados em erros numéricos. Além disso, o modelo proposto também se mostrou eficaz na captura de eventos complexos e de longo prazo.

Para esse trabalho, o foco será em modelos de Redes Neurais Recorrentes (da sigla em inglês, RNN), que são especificamente desenvolvidas para a previsão espaço-temporal de dados dispostos em uma sequência. Na literatura, encontramos inúmeros casos de sucesso de utilização da *RNNs* em tarefas de previsão de vídeo, por exemplo: (SHI et al., 2015), (WANG et al., 2017), (WANG et al., 2018), (WANG; CASALINO; KHULLAR, 2019), (YU et al., 2019), (LIN et al., 2020), (WANG et al., 2022) e (VILLAR-CORRALES et al., 2022).

1.3 Estrutura e organização do trabalho

Este trabalho está organizado em cinco capítulos, referências bibliográficas e apêndices. Além da introdução, que já foi apresentada, os demais capítulos serão descritos a seguir.

- No Capítulo 2 está contida a fundamentação teórica a respeito das Redes Neurais Artificiais, apresentando os principais tópicos utilizados nessa pesquisa.
- O Capítulo 3 traz a metodologia utilizada para a realização dos objetivos propostos. Nesse capítulo, é apresentada a importância de se ter dados de boa qualidade quando se utiliza Redes Neurais Artificiais e se apresenta todos os processos desde a coleta até processamento dos dados da pesquisa. Por fim, são citados como são feitos os processos de treinamento, previsão e avaliação dos resultados gerados pela Rede Neural.
- O Capítulo 4 contém os resultados dos experimentos realizados no trabalho.
- Por fim, no Capítulo 5 apresentam-se as conclusões e planos futuros para continuidade desta pesquisa.

2 REDES NEURAIIS ARTIFICIAIS

Nesse capítulo serão introduzidos alguns conceitos das Redes Neurais Artificiais, necessários no decorrer do trabalho e para o entendimento da metodologia proposta. Inicialmente terá uma breve introdução sobre as Redes Recorrentes, Redes Neurais Convolucionais e as arquiteturas de Redes Neurais utilizadas nesta pesquisa.

2.1 Redes Neurais Recorrentes

As Redes Neurais Recorrentes (do inglês - *Recurrent Neural Network* - *RNN*) são redes designadas, principalmente para resolver problemas que fazem uso de dados sequenciais dispostos no tempo, como preço de ações, áudio, textos e, usando o exemplo desta pesquisa, previsão de um fenômeno físico, através de imagens de refletividade de radar meteorológico. A importante característica desse tipo de rede, é ter conexões ao longo de sequências temporais entre suas células em uma mesma camada da rede.

Exemplificando, numa *RNN* uma célula recebe um item de uma sequência de dados como entrada, realiza os cálculos, computa a saída e passa a informação (estado) para a próxima célula que irá processar o próximo item da sequência de dados, sempre levando em consideração o que foi processado na célula anterior.

Conforme o treinamento de uma *RNN* é realizado, podem ocorrer problemas de estabilidade, gerados pela entrada de novos dados, inviabilizando a minimização da função custo. Essa instabilidade é chamada de *vanishing* ou *exploding gradient problem*, que numa tradução livre podemos chamar de problema de desaparecimento ou explosão de gradiente. Intuitivamente, quando temos um gradiente diminuindo muito rapidamente (se aproximando de zero), ocorre o problema de desaparecimento, por outro lado a explosão de gradiente ocorre devido ao aumento descontrolado do mesmo. Quando ocorre qualquer um desses problemas a *RNN* perde a capacidade de aprendizagem temporal (PASCANU; MIKOLOV; BENGIO, 2013).

Para contornar esses problemas na minimização da função custo, Hochreiter; Schmidhuber (1997) propuseram uma modificação das *RNN* chamada de *Long Short-*

Term Memory (LSTM) que será detalhada a seguir.

2.2 A Rede LSTM - Long Short Term Memory

A LSTM é um dos tipos de estruturas de RNN com grande difusão dentro da literatura. Esse tipo de estrutura expande a RNN adicionando mais um tipo de estado a rede, agora além da célula temporal, a RNN passa a ter células ocultas em cada camada. A LSTM ainda conta com estruturas chamadas de portas (*gates*) que permitem o modelo aprender quais informações devem ser guardadas e quais podem ser descartadas das células, fazendo com que o problema de explosão ou desaparecimento de gradiente seja contornado Hochreiter (1998), permitindo o treinamento da rede por longos períodos de tempo e utilizando maiores sequências de dados (GREFF et al., 2016).

Todo o processo da LSTM pode ser representado pelas seguintes equações:

$$\begin{aligned}
 i_t &= \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i) \\
 f_t &= \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f) \\
 c_t &= f_t \odot c_{t-1} + i_t \odot \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \\
 o_t &= \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o) \\
 h_t &= o_t \odot \tanh(c_t)
 \end{aligned} \tag{1}$$

No conjunto de equações 1, σ representa a função sigmoide, W_* e b_* são os parâmetros de aprendizagem do modelo, x_t é o ponto temporal da sequência de entrada no tempo t , h_{t-1} e c_{t-1} são os estados anteriores da camada oculta e da célula e o \odot representa o produto de *Hadamard*.

Primeiramente, os valores das portas de entrada i_t e de esquecimento f_t são calculadas aplicando a função sigmoide a uma soma ponderada entre a entrada atual e o estado da camada oculta anterior. Continuando, o estado da célula c_t é atualizado de acordo com as portas, estados anteriores da rede e a entrada de dados temporal. A porta de saída conta com uma função sigmoide aplicada a uma soma ponderada entre os dados de entrada, o estado oculto e o estado da célula. O estado oculto é calculado através do produto de *Hadamard* entre os elementos do estado da célula e a porta de saída (GREFF et al., 2016).

2.3 Redes Neurais Convolucionais

As redes neurais convolucionais (CNNs – do inglês *Convolutional neural networks*), propostas por Lecun et al. (1989) são um tipo de rede neural desenvolvida para processar dados que seguem um formato de grade (matrizes) por exemplo, uma série temporal de dados, que podemos chamar de uma matriz 1-D ou uma imagem, que é formada por uma matriz de pixels 2-D (altura e largura).

O conceito principal das redes convolucionais está fundamentado em um tipo especial de operação linear matemática, chamada de convolução. Podemos dizer que as redes convolucionais são redes neurais básicas que utilizam a operação de convolução em pelo menos uma de suas camadas ao invés de utilizar apenas multiplicações de matrizes como as outras redes.

A operação de convolução resulta, através de duas funções dadas, uma terceira função que descreve a soma do produto das funções dadas ao longo de uma região implícita pela superposição em função do deslocamento existente entre as duas funções. Podemos descrever a convolução entre uma função f e uma função g como $f * g$, onde o $*$ indica a operação de convolução. A convolução para funções contínuas é representada pela equação 2:

$$(f * g)(x) = h(x) = \int_{-\infty}^{\infty} f(u)g(x - u)du \quad (2)$$

Onde x é a variável independente e u o deslocamento. Como as redes neurais tem como entrada dados matriciais, a operação da convolução também pode ser escrita em forma matricial, como ilustra a equação 3:

$$f * g = fg = h \quad (3)$$

Para esse caso, o f é um operador matricial que transforma a matriz ou vetor g em outro vetor h .

Quando falamos em termos de aplicações de Redes Neurais Artificiais, podemos dizer que a convolução é o ato de utilizar um *kernel* para extrair determinadas características de uma imagem de entrada. O *kernel* de convolução é uma matriz quadrada de tamanho especificado que percorre a imagem de entrada aplicando a operação de convolução nos pixels da mesma, transformando a saída até a forma desejada.




Figura 1 – Exemplo da aplicação do *kernel* de convolução em dados de entrada. Fonte: Rahul Kadam/Medium.

A figura 1 demonstra visualmente como o *kernel* é utilizado. Temos os valores numéricos de uma imagem qualquer na entrada (*input*), o *kernel* será aplicado em todos esses valores, percorrendo a matriz de entrada em toda a sua dimensão e gerando a saída (*output*) com os valores desejados.

O livro “*Deep Learning Architectures: A Mathematical Approach*” de Galin (2020), apresenta um exemplo de como a operação de convolução funciona matematicamente nas redes neurais quando aplicadas a uma imagem. Consideramos para o exemplo uma imagem colorida (no formato *RGB*) representada na forma de uma matriz de dimensões $L \times C \times 3$, onde L é o número de linhas e C é o número das colunas de pixels da imagem. O 3 representa que a imagem é colorida, ou seja, possui três canais de cores.

$$\begin{pmatrix} 2 & 1 & 1 \\ 4 & 3 & 5 \\ 7 & 6 & 0 \end{pmatrix} \text{Entrada} \begin{pmatrix} 1 & -1 \\ 2 & 1 \end{pmatrix} \text{Kernel} \quad (4)$$

A equação 4 demonstra as duas matrizes que usaremos nesse exemplo. O *kernel* de convolução é sobreposto na matriz e movido horizontalmente e verticalmente, em todas as posições possíveis. Em cada posição somamos os produtos das entradas do *kernel* e as entradas da matriz e os resultados geram a saída. A sobreposição do *kernel* começa no canto superior esquerdo da imagem e desliza um pixel para a direita. Então a operação continua para a linha inferior, da forma que ilustra a equação 5:

$$\begin{aligned}
(1.2) - (1.1) + (2.4) + (1.3) &= 12 \\
(1.1) - (1.1) + (2.3) + (1.5) &= 11 \\
(1.4) - (1.3) + (2.7) + (1.6) &= 21 \\
(1.3) - (1.5) + (2.6) + (1.0) &= 10
\end{aligned} \tag{5}$$

Usando o operador de convolução $*$, as operações realizadas na equação 5 são apresentadas na equação 6:

$$\begin{pmatrix} 2 & 1 & 1 \\ 4 & 3 & 5 \\ 7 & 6 & 0 \end{pmatrix} * \begin{pmatrix} 1 & -1 \\ 2 & 1 \end{pmatrix} = \begin{pmatrix} 12 & 11 \\ 21 & 10 \end{pmatrix} \tag{6}$$

Nesse exemplo apresentado, uma parte específica de uma imagem de tamanho 3x3 foi convolucionada com um *kernel* 2x2, essa operação também pode ser chamada de *feature map*, que pode ser traduzido como "mapa de recurso", afinal essa operação, como já foi citado anteriormente, tem a capacidade de retirar diversos recursos e características das imagens de entrada, dependendo do *kernel* usado e sua posição.

2.4 ConvLSTM

Embora as *LSTM* tenham resolvido o problema do gradiente, quando se considera aprendizagem espaço temporal com mais de uma dimensão (tempo e forma), como por exemplo dados de mapas, nuvens e radares, a rede apresenta dificuldade na fase de aprendizagem. Ou seja, tem alto custo computacional com baixa precisão.

Para contornar esse problema, (SHI et al., 2015) propôs a *LSTM* Convolucional (*ConvLSTM*), rede que mantém a estrutura da *LSTM* mas troca as operações lineares da rede por operações convolucionais. A *ConvLSTM* pode ser representada pela equação 7:

$$\begin{aligned}
i_t &= \sigma(W_{xi} * X_t + W_{hi} * H_{t-1} + W_{ci} \odot C_{t-1} + b_i) \\
f_t &= \sigma(W_{xf} * X_t + W_{hf} * H_{t-1} + W_{cf} \odot C_{t-1} + b_f) \\
C_t &= f_t \odot C_{t-1} + i_t \odot \tanh(W_{xc} * X_t + W_{hc} * H_{t-1} + b_c) \\
i_o &= \sigma(W_{xo} * X_t + W_{ho} * H_{t-1} + W_{co} \odot C_{t-1} + b_o) \\
H_t &= o_t \odot \tanh(C_t)
\end{aligned} \tag{7}$$

Na equação 7, $*$ representa a operação convolucional 2D, X_t a entrada da rede, H_t e C_t o estado oculto e estado da célula, respectivamente.

Na literatura, a *ConvLSTM* se mostrou superior a *LSTM* na solução de problemas que envolvam mais do que uma dimensão. Finn; Goodfellow; Levine (2016), mostra que a *ConvLSTM* consegue realizar previsões de vídeos com melhores resultados do que redes sem convolução. No trabalho de Shi et al. (2015), foi demonstrado que a rede recorrente com convolução apresenta resultados promissores quando aplicada a previsão de fenômenos atmosféricos.

2.5 Rede Neural Recorrente Preditiva

A Rede Neural Preditiva (*PredRNN*) foi proposta inicialmente por Wang et al. (2017) e tem sua arquitetura desenvolvida e otimizada especificamente para aprendizagem preditiva de dados espaço temporais. Além da original, a *PredRNN* possuiu mais duas atualizações, Wang et al. (2018) e Wang et al. (2022).

Embora tanto a *PredRNN++* quanto a *PredRNN-V2* sejam estado da arte na área de aprendizagem preditiva, inicialmente, neste estágio do trabalho, será utilizada a *PredRNN++*, pois mesmo sendo uma arquitetura mais antiga em relação a *PredRNN-V2*, Wang et al. (2022) demonstra que a *PredRNN++* apresenta resultados melhores com dados de radares meteorológicos, semelhantes aos usados nesse trabalho. No futuro, a *PredRNN-V2* sera testada, com o objetivo de comparar a performance da mesma com a *PredRNN++*, utilizando o *dataset* de radares brasileiros. A figura 2 representa a estrutura da rede *PredRNN++*.

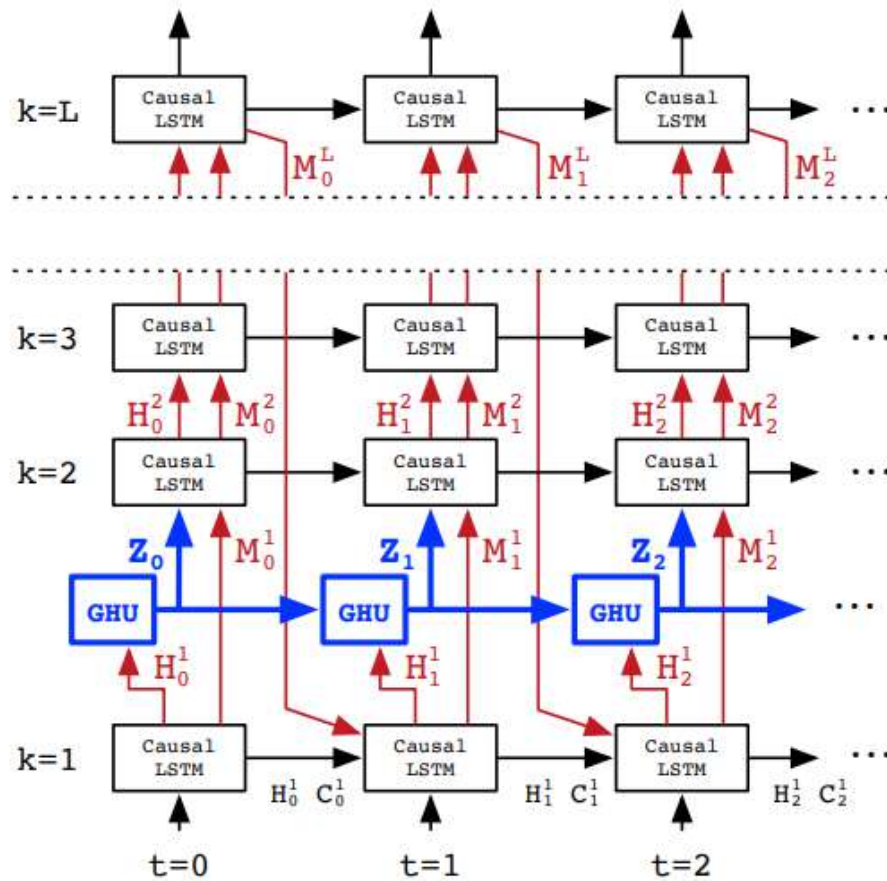


Figura 2 – Estrutura da Rede PredRNN++. Fonte: Wang et al. (2018)

Na estrutura da *PredRNN++* demonstrada na figura 2 é introduzida uma nova célula *RNN* chamada de *CausalLSTM*. Essa nova célula expande a *ConvLSTM* mostrada anteriormente, adicionando um estado de memória espacial C_t^k , além da memória temporal M_t^k . Também aumentou o número de combinações não-lineares da rede. A célula *CausalLSTM* é representada pelas seguintes equações:

$$\begin{pmatrix} g_t \\ i_t \\ f_t \end{pmatrix} = \begin{pmatrix} \tanh \\ \sigma \\ \sigma \end{pmatrix} W_1 * [X_t, H_{t-1}^k, C_{t-1}^k]$$

$$C_t^k = f_t \odot C_{t-1}^k + i_t \odot g_t$$

$$\begin{pmatrix} g'_t \\ i'_t \\ f'_t \end{pmatrix} = \begin{pmatrix} \tanh \\ \sigma \\ \sigma \end{pmatrix} W_2 * [X_t, C_t^k, M_t^{t-1}] \quad (8)$$

$$M_t^k = f'_t \odot \tanh(W_3 * M_t^{k-1}) + i'_t \odot g'_t$$

$$o_t = \tanh(W_4 * [X_t, C_t^k, M_t^k])$$

$$H_t^k = o_t \odot \tanh(W_5 * [C_t^k, M_t^k])$$

Onde $*$ representa a operação de convolução da rede, \odot indica o produto de Hadamard e o σ é a aplicação da função de ativação sigmóide. Os W_{1-5} são os filtros convolucionais da rede, H_t^k é a saída final determinada pelos estados das duas memórias M_t^k e C_t^k .

A *PredRNN++* também possui em sua estrutura uma célula chamada de *gradient highway unit (GHU)*. A estrutura de uma célula *GHU* está ilustrada na figura 3.

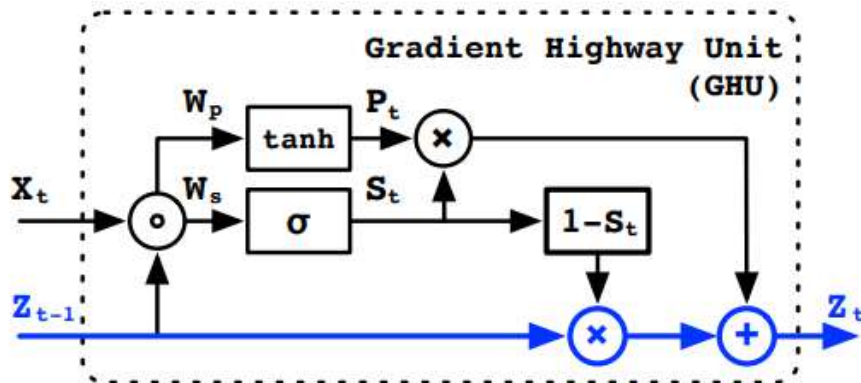


Figura 3 – Estrutura do *GHU*. Fonte: Wang et al. (2018)

O *GHU* pode ser representado matematicamente pela equação 9.

$$P_t = \tanh(W_{px} * X_t + W_{pz} * Z_{t-1})$$

$$S_t = \sigma(W_{sx} * X_t + W_{sz} * Z_{t-1})$$

$$Z_t = S_t \odot P_t + (1 - S_t) \odot Z_{t-1} \quad (9)$$

Onde S_t é chamado de *switch gate* e tem a função de habilitar uma aprendizagem adaptativa entre as entradas da rede P_t e os estados da rede nas camadas ocultas Z_t . A combinação das equações 8 e 9 representam a *PredRNN++* completa.

Outro ponto importante da *PredRNN++*, é que a rede compartilha a memória espacial entre diferentes camadas e diferentes posições da sequência de dados de entrada, isso gera uma capacidade muito maior de previsão temporal do que a *ConvLSTM*.

Um ponto relevante a ser mencionado é que para uma Rede Neural (ou qualquer outra aplicação de Aprendizado de Máquina) ter um funcionamento em sua máxima excelência, dados de boa qualidade são imprescindíveis. A seção 2.6 trata sobre esse assunto.

2.6 A importância dos dados

É consenso na literatura sobre Aprendizado de Máquina (*Machine Learning (ML)*), que a qualidade dos dados utilizados em uma pesquisa é o fator principal para a produção de bons resultados. No artigo “*Limits on Learning Machine Accuracy Imposed by Data Quality*” de Cortes; Jackel; Chiang (1994), o autor destacou que a limitação da capacidade de aprendizagem dos modelos de ML se dá pela insuficiência e baixa qualidade dos dados utilizados.

Estudos recentes como os de Jain et al. (2020), Gupta et al. (2021) e Chen et al. (2021), evidenciam que os grandes avanços da área de aprendizagem de máquina nos últimos anos, devem-se ao esforço coletivo da academia em construir banco de dados de qualidade, para que a arquitetura dos modelos pudesse evoluir continuamente.

A base de dados de radar no Brasil, domínio de interesse neste trabalho, é bastante limitado, pois há poucos radares em funcionamento pleno no território nacional. Tratando-se de dados brutos, não há dados disponíveis, por isso destaca-se a importância de se aplicar uma metodologia que utilize imagens ao invés de dados brutos. Na linha da pesquisa aqui apresentada, destaca-se o trabalho de Bonnet; Evsukoff; Morales rodriguez (2020), no qual os autores fazem uso de Redes Neurais e imagens de radares para *nowcasting* na cidade de São Paulo – SP.

Diante disso, além de avaliar a capacidade de previsão meteorológica de Redes Neurais Artificiais, esse trabalho busca elaborar e disponibilizar bancos de dados de imagens de radares do Brasil, para que possam ser usados em futuras pesquisas, como novas arquiteturas de aprendizagem de máquina, auxiliando no desenvolvimento desta aplicação.

3 METODOLOGIA

Neste capítulo são apresentados os processos metodológicos que foram seguidos para a resolução do problema proposto para esse trabalho. O diagrama grafado na Figura 4 exibe a ordem de etapas efetuadas para a obtenção dos resultados desejados, iniciando pela obtenção e pré-processamento dos dados utilizados, treinamento, teste e avaliação da Rede Neural, bem como o processo para gerar as previsões com a mesma.

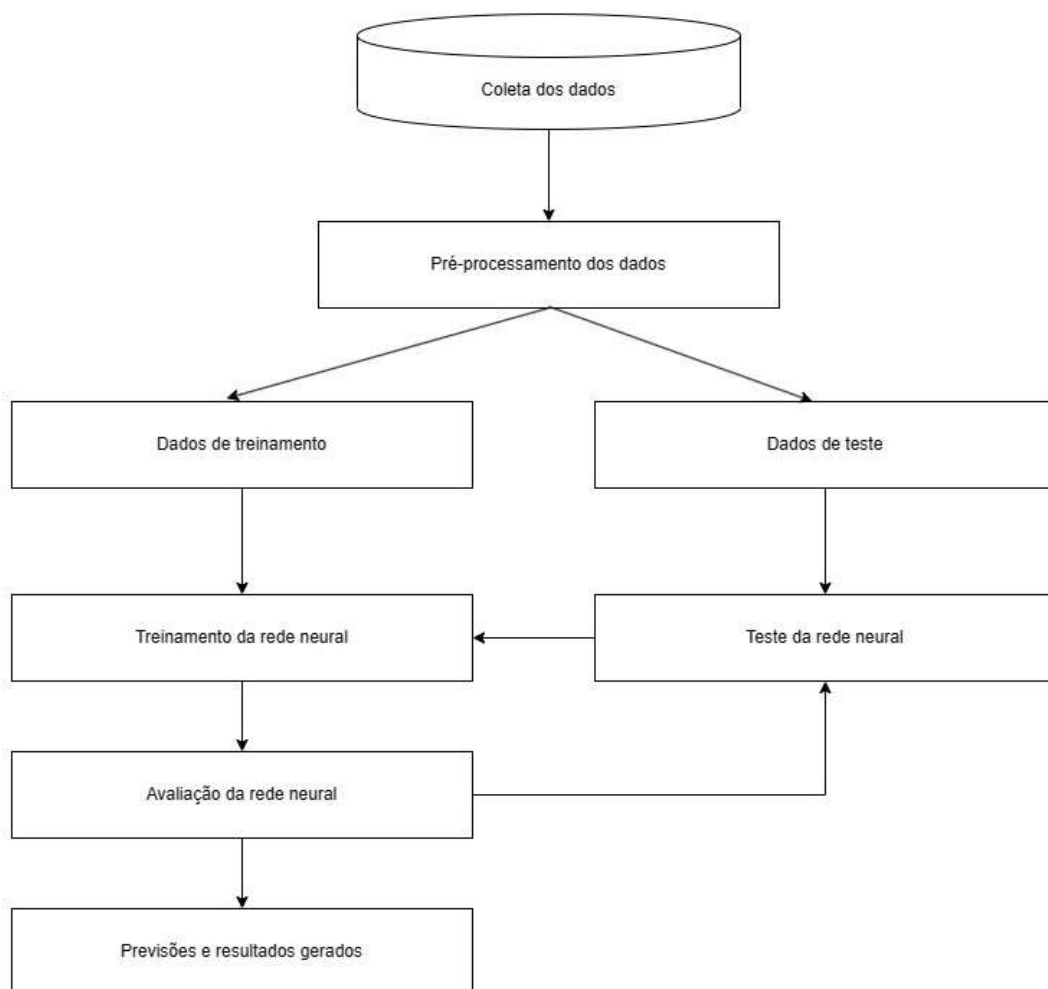


Figura 4 – Diagrama apresentando os processos metodológicos.

3.1 Descrição e obtenção dos dados

Todos os dados utilizados nessa pesquisa foram obtidos através do sistema SIGMA, mantido pelo Centro de Previsão de Tempo e Estudos Climáticos (CPTEC), que faz parte do Instituto Nacional de Pesquisas Espaciais (INPE). O sistema com as imagens de radares pode ser acessado pelo seguinte link: <<http://sigma.cptec.inpe.br>>.

O SIGMA disponibiliza vários produtos de meteorologia gratuitamente, como imagens de satélites, dados de descargas elétricas, dados de vento, dados de radiação, classificação de nuvens e as imagens de radares, que serão utilizadas nesse trabalho. A parte de radares do SIGMA é dividida por regiões do Brasil e além de conter as imagens de refletividade utilizadas nesse trabalho, contém medições de vento.

Utiliza-se quatro radares disponíveis no SIGMA da região sul do país. Esses radares estão dispostos nas cidades de Canguçu – RS, Chapecó – SC, Morro da Igreja – SC e Santiago – RS. Após a realização de experimentos com esses radares e a validação da performance da Rede Neural, pretende-se expandir a pesquisa para as demais regiões do Brasil.

Para a realização dos *downloads* dos dados dentro da plataforma SIGMA, deve-se selecionar o radar desejado, selecionar o dia e os horários das leituras, como ilustra a figura 5. O processo de obtenção de dados é um tanto trabalhoso, porque a plataforma não disponibiliza um recurso de *download* de arquivos por períodos.

CAPPI Chapecó - SC

Data: Selecionar todas Tam. Estimado: 61.0 Kb

<input type="checkbox"/> 13:26	<input type="checkbox"/> 13:36	<input type="checkbox"/> 13:41	<input type="checkbox"/> 13:51	<input type="checkbox"/> 13:56	<input type="checkbox"/> 14:01	<input type="checkbox"/> 14:06	<input type="checkbox"/> 14:11
<input type="checkbox"/> 14:16	<input type="checkbox"/> 14:21	<input type="checkbox"/> 14:26	<input type="checkbox"/> 14:31	<input type="checkbox"/> 14:36	<input type="checkbox"/> 14:41	<input type="checkbox"/> 14:46	<input type="checkbox"/> 14:51
<input type="checkbox"/> 14:56	<input type="checkbox"/> 15:01	<input type="checkbox"/> 15:06	<input type="checkbox"/> 15:11	<input type="checkbox"/> 15:16	<input type="checkbox"/> 15:21	<input type="checkbox"/> 15:26	<input type="checkbox"/> 15:31
<input type="checkbox"/> 15:36	<input type="checkbox"/> 15:41	<input type="checkbox"/> 15:46	<input type="checkbox"/> 15:51	<input type="checkbox"/> 15:56	<input type="checkbox"/> 16:01	<input type="checkbox"/> 16:11	<input type="checkbox"/> 16:21
<input type="checkbox"/> 16:31	<input type="checkbox"/> 16:41	<input type="checkbox"/> 16:51	<input type="checkbox"/> 17:01	<input type="checkbox"/> 17:11	<input type="checkbox"/> 17:21	<input type="checkbox"/> 17:31	<input type="checkbox"/> 17:41
<input type="checkbox"/> 17:51	<input type="checkbox"/> 18:01	<input type="checkbox"/> 18:06	<input type="checkbox"/> 18:11	<input type="checkbox"/> 18:21	<input type="checkbox"/> 18:31	<input type="checkbox"/> 18:41	<input type="checkbox"/> 18:51
<input type="checkbox"/> 19:01	<input type="checkbox"/> 19:11	<input type="checkbox"/> 19:21	<input type="checkbox"/> 19:31	<input type="checkbox"/> 19:41	<input type="checkbox"/> 19:51	<input type="checkbox"/> 20:01	<input type="checkbox"/> 20:11
<input type="checkbox"/> 20:21	<input type="checkbox"/> 20:31	<input type="checkbox"/> 20:41	<input type="checkbox"/> 20:51	<input type="checkbox"/> 21:01	<input type="checkbox"/> 21:06	<input type="checkbox"/> 21:11	<input type="checkbox"/> 21:16
<input type="checkbox"/> 21:21	<input type="checkbox"/> 21:26	<input type="checkbox"/> 21:31	<input type="checkbox"/> 21:36	<input type="checkbox"/> 21:41	<input type="checkbox"/> 21:46	<input type="checkbox"/> 21:51	<input type="checkbox"/> 21:56
<input type="checkbox"/> 22:01	<input type="checkbox"/> 22:06	<input type="checkbox"/> 22:11	<input type="checkbox"/> 22:16	<input type="checkbox"/> 22:21	<input type="checkbox"/> 22:26	<input type="checkbox"/> 22:31	<input type="checkbox"/> 22:36
<input type="checkbox"/> 22:41	<input type="checkbox"/> 22:46	<input type="checkbox"/> 22:51	<input type="checkbox"/> 22:56	<input type="checkbox"/> 23:01	<input type="checkbox"/> 23:06	<input type="checkbox"/> 23:11	<input type="checkbox"/> 23:16
<input type="checkbox"/> 23:21	<input type="checkbox"/> 23:26	<input type="checkbox"/> 23:31	<input type="checkbox"/> 23:36	<input type="checkbox"/> 23:41	<input type="checkbox"/> 23:46	<input type="checkbox"/> 23:51	<input type="checkbox"/> 23:56

* Imagens em horário GMT.

[Download](#)

Figura 5 – Interface para download dos dados da plataforma SIGMA.

Como regra geral, foram selecionadas para *download* 20.000 imagens de cada um dos radares, entre os anos de 2018 e 2022, buscando-se a uma grande variedade de sistemas meteorológicos. Todo o processamento dos dados e criação dos bancos para a utilização na Rede Neural é demonstrado na seção 3.3.

É importante mencionar que os radares apresentam seus dados na escala de *dBZ*. O *dBZ* é uma unidade de medida utilizada em radares meteorológicos para expressar a intensidade do eco do sinal de retorno que é refletido por uma nuvem ou precipitação. Essa unidade é uma abreviação para "decibéis de Z", sendo "Z" uma constante que representa a seção transversal de retroespalhamento do alvo.

3.2 Localização dos Radares Utilizados neste Trabalho

As imagens dos quatro radares do sul do Brasil utilizados, apresentam uma altitude fixa de 3 km e um alcance de raio 250 km.

A figura 6 ilustra a cobertura do radar de Canguçu - RS – Disposto em: $31^{\circ}24'05.4''S$ $52^{\circ}41'47.5''W$.

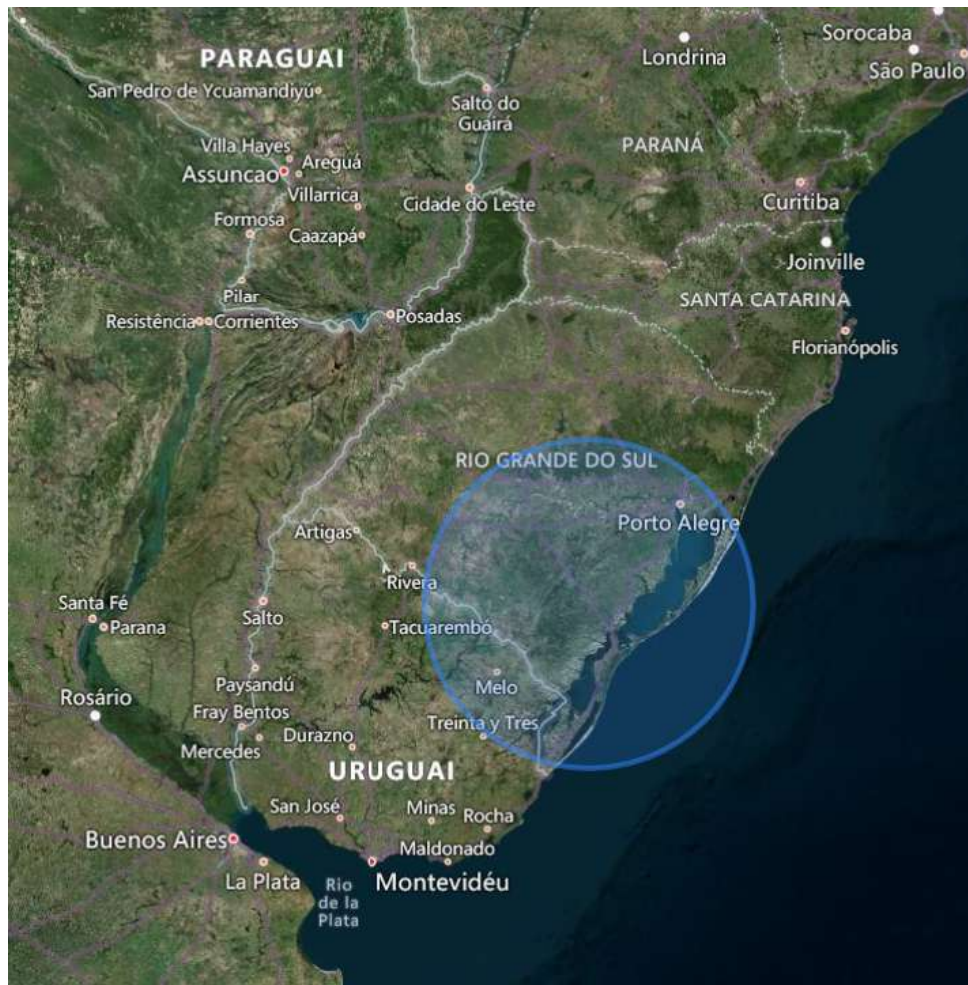


Figura 6 – Área de cobertura do radar de Canguçu. Fonte: Google Maps.

A figura 7 ilustra a cobertura do radar de Chapecó – SC – Disposto em: $27^{\circ}02'55.3''\text{S } 52^{\circ}36'13.3''\text{W}$.



Figura 7 – Área de cobertura do radar de Chapecó. Fonte: *Google Maps*.

A figura 8 ilustra a cobertura do radar de Morro da Igreja – SC – Disposto em: $28^{\circ}07'32.7''S$ $49^{\circ}28'29.5''W$.




Figura 8 – Área de cobertura do radar de Morro da Igreja. Fonte: *Google Maps*.

Por fim, a figura 9 ilustra a cobertura do radar de Santiago – RS – Disposto em: $29^{\circ}13'16.7''S$ $54^{\circ}55'37.6''W$.

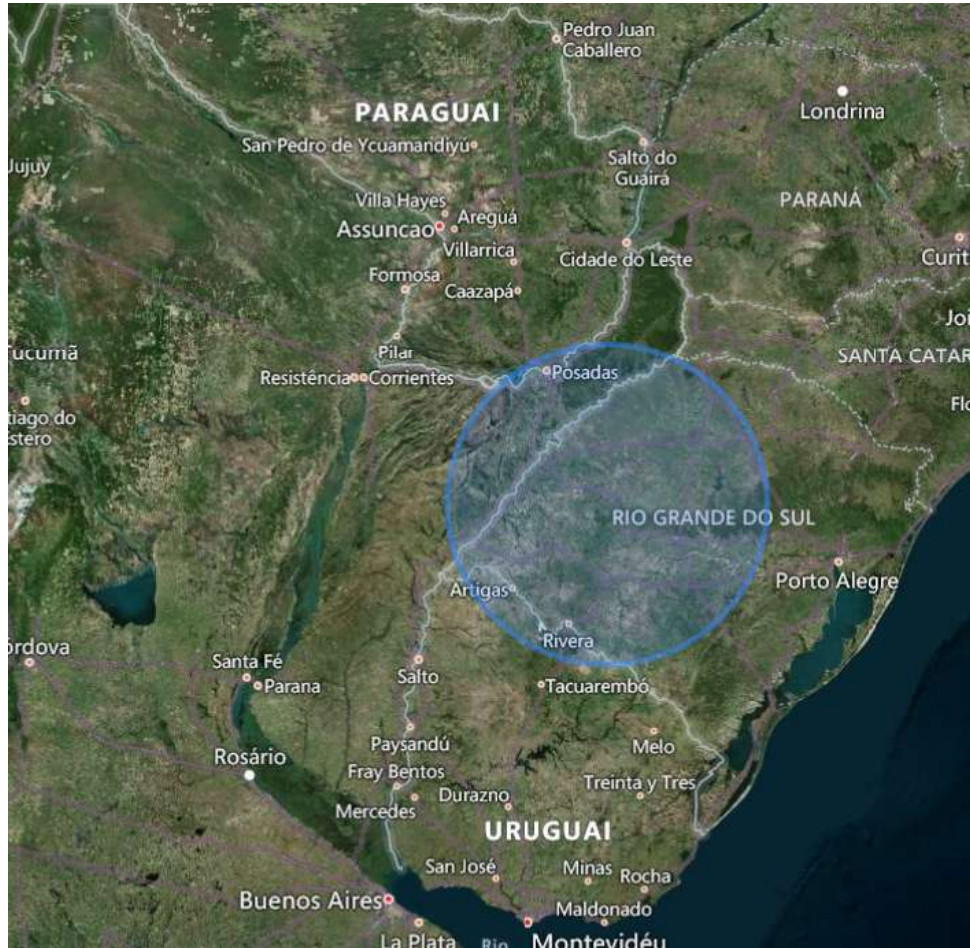


Figura 9 – Área de cobertura do radar de Santiago. Fonte: Google Maps.

3.3 Pré-processamento dos dados

Como já citado, foram selecionadas 20.000 imagens de cada um dos radares. A Figura 10 mostra um exemplo do radar da cidade de Chapecó – SC (todos seguem um padrão) de como são essas imagens quando obtidas diretamente do SIGMA, sem qualquer tipo de processamento.




Figura 10 – Exemplo de imagens baixadas diretamente do SIGMA.

Para que as imagens de radar pudessem se adequar a arquitetura de treinamento de uma Rede Neural, foi tomado como base uma versão específica do dataset *MNIST* (LECUN, 1998) preparado para aprendizagem temporal, usado no trabalho “*Unsupervised Learning of Video Representations using LSTMs*” de (SRIVASTAVA; MANSIMOV; SALAKHUDINOV, 2015).

O dataset *MNIST* contém 10.000 seqüências de imagens de números se movendo em um determinado período de tempo. Esse período de tempo compreende uma seqüência de 20 imagens, todas com o mesmo tamanho, bidimensional com 64x64 bits, ou seja, não possuem cores, estão em escala de cinza. Os dados desse *dataset* são apresentados as Redes Neurais no formato de um vetor de 4 dimensões [20,10000,64,64], onde o 20 representa o tamanho da seqüência de dados, 10.000 a quantidade de seqüências e 64x64 representa o tamanho de cada imagem.

Esse formato de *dataset* foi escolhido para essa pesquisa porque muitas Redes Neurais realizam previsões em seqüências de imagens treinadas e validadas com o *MNIST* ou com dados customizados no mesmo formato. Podemos citar como exemplo a PredRNN (WANG et al., 2017), PredRNN++ (WANG et al., 2018), PredRNNv2 (WANG et al., 2022), ConvLSTM (SHI et al., 2015), MSPred (VILLAR-CORRALES et al., 2022), CrevNet (YU et al., 2019), PhyDNet (MURALIDHAR et al., 2020), entre várias outras.

Para adequar os dados dessa pesquisa ao formato referenciado, as 20.000 imagens de cada radar foram divididas em 1.000 seqüências de 20 imagens cada, resultando em um vetor no formato [20, 1000, 64, 64]. Como em grande parte dos radares as leituras de refletividade são registradas de 6 em 6 minutos, cada seqüência de dados representa um intervalo de 120 minutos no tempo.

Além disso, como as imagens do SIGMA são disponibilizadas em um tamanho de 500x500 e em formato colorido (três dimensões – *RGB*), antes de serem dispostas em seqüências, foram redimensionadas para o tamanho 64x64 e transformadas em imagens de duas dimensões, convertendo-as de coloridas para escala de cinza.

Todos esse processamentos realizados nos dados foram efetuados em linguagem

de programação *Python*, sendo que todos os códigos bem como as explicações detalhadas de como utilizá-los estão disponíveis em um repositório no *GitHub* do autor e pode ser acessado através do seguinte link: <<https://github.com/rossattofc/Brazil-Radar-Nowcasting>>. No repositório também é disponibilizado os dados pré processados de todos os radares utilizados nesse trabalho, facilitando assim futuras pesquisas meteorológicas no Brasil.

3.4 Glossário sobre alguns termos utilizados em Redes Neurais

Antes de tratar sobre a Rede Neural propriamente dita, se faz necessário apresentar alguns termos e conceitos que serão abordados no decorrer desse trabalho.

Épocas (*epochs* - em inglês): Uma época se refere a uma passagem completa do conjunto de treinamento por todo o Modelo Neural que se está treinando.

Otimizador Adam: O otimizador *Adam* (*Adaptive Moment Estimation*) é um algoritmo de otimização utilizado em treinamento de redes neurais e outros problemas de aprendizado de máquina. Ele é projetado para ajustar os pesos das conexões entre os neurônios de forma eficiente, permitindo que a rede neural aprenda os padrões nos dados de treinamento.

Pesos: Os pesos de uma rede neural são parâmetros ajustáveis que determinam a força e a direção das conexões entre os neurônios em diferentes camadas da rede. Essas conexões são representadas por sinapses artificiais, que são análogas às conexões sinápticas no cérebro humano. Os pesos são fundamentais para o funcionamento e o aprendizado da rede neural, pois influenciam a saída gerada pela rede para um dado conjunto de entradas.

Taxa de aprendizagem: A taxa de aprendizagem controla o quão rápido ou devagar os pesos da rede neural são atualizados em direção a um mínimo local (ou máximo, em problemas de maximização) da função de perda.

Batch Size: O *batch size* (tamanho do lote, em português) em uma rede neural refere-se ao número de exemplos de treinamento que são usados em uma única iteração do algoritmo de treinamento. Em outras palavras, é o número de dados de treinamento que são processados em paralelo antes de atualizar os pesos da rede neural.

Função de ativação: Tem a função de determinar a saída de um neurônio em resposta aos dados entrada que foram recebidos. Ela introduz a não-linearidade nas saídas dos neurônios, permitindo que a rede neural aprenda e modele relações complexas nos dados.

3.5 Treinamento de uma Rede Neural

Após a coleta e pré processamento dos dados, o próximo passo é o treinamento da rede neural. É nessa etapa que a rede começa a "aprender" a mapear e relacionar os dados da entrada com a saída desejada. Em outras palavras, esse é o processo pelo qual a rede neural ajusta seus pesos e parâmetros internos para otimizar seu desempenho em uma tarefa específica.

O objetivo do treinamento é fazer com que a rede neural seja capaz de generalizar padrões e relações dos dados de treinamento para dados que não pertenceram ao conjunto de treinamento, permitindo que ela faça previsões ou classificações precisas em novos exemplos.

As principais etapas do treinamento de uma rede neural, como cita Beale; Hagan; Demuth (2010), podem ser descritas como:

Inicialização: Os pesos e parâmetros da rede neural são inicializados com valores aleatórios ou com algum método de inicialização específico.

Forward Pass¹: Nessa etapa a rede neural é alimentada com os dados de treinamento, passando por cada uma das camadas da mesma. Conforme os dados "avançam" pelas camadas ocultas da rede neural, eles são transformados através de operações matemáticas definidas pela função de ativação e pelos outros parâmetros da rede.

Cálculo do erro: É realizado o cálculo do erro comparando a saída da rede neural e os dados reais, com o objetivo de estimar a diferença entre a saída prevista e a saída desejada. É na etapa do cálculo do erro que os dados de testes são utilizados pela rede neural para estimar como está a performance do modelo.

Os dados de testes e de treinamento são diferentes e são definidos antes do treinamento iniciar, através de uma divisão entre o *dataset* completo. Essa divisão é feita para fins de avaliação e validação do modelo, garantindo que ele seja capaz de generalizar bem para dados não apresentados anteriormente.

Propagação do erro: O erro da etapa anterior é propagado para a rede neural atrás de um algoritmo de retropropagação (*backpropagation*). Esse algoritmo ajusta os pesos e parâmetros da rede em direção ao mínimo global da função de perda, buscando reduzir o erro geral da rede.

Otimização dos pesos da rede: Depois da retropropagação os pesos da rede neural são atualizados através de um algoritmo de otimização que varia de rede para rede, um dos mais difundidos é o Gradiente Descendente (*Gradient Descent*).

Todos os passos anteriores são repetidos várias vezes para todos os dados apresentados a rede neural. Cada vez que todos os dados passam por essas etapas, uma época de treinamento é completa. O número de épocas varia de acordo com o

¹ Traduzindo para português seria algo como "alimentação para frente", pois os dados avançam entre as camadas da rede neural.

problema a ser resolvido e o tipo dos dados que estão sendo utilizados.

Por fim, todo o processo de treinamento é repetido várias vezes até que a rede neural apresente um desempenho desejável para o problema que se está resolvendo. Esse desempenho pode ser medido através da diminuição do erro do treinamento, utilização de métricas avaliativas para comparar os valores previstos e os valores esperados e também através de análises empíricas sobre os resultados.

3.6 Métricas de Avaliação

Um dos pontos mais importantes quando tratamos de modelos preditivos é como iremos avaliar a qualidade da previsão gerada. Para esse trabalho, serão utilizadas três medidas de regressão para realizar essa avaliação.

Essas medidas de regressão realizam cálculos do erro entre a imagem real e a imagem prevista pela rede. Essas métricas específicas foram escolhidas por serem amplamente utilizadas na literatura de previsão de imagens por Redes Neurais Artificiais (SCHULTZ et al., 2021).

1 – *RMSE* (Raiz Quadrada do Erro Médio Quadrático) – Essa é uma das medidas mais utilizadas em qualquer problema de regressão estatística (HYNDMAN; KOEHLER, 2006). A *RMSE* realiza o cálculo considerando o quadrado da diferença entre o valor previsto e o valor observado. Os resultados são de 0 a 1 e quando mais próximo de 0, melhor é a qualidade da previsão. A *RMSE* pode ser representada pela seguinte equação:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (d_i - f_i)^2} \quad (10)$$

Onde d_i e f_i são a verdade terrestre e os valores previstos e n a quantidade de amostras.

2 – *SSIM* (Índice de similaridade estrutural) – É uma medida de avaliação de imagens proposta inicialmente por (WANG et al., 2004). O *SSIM* busca analisar a diferença entre duas imagens se baseando na percepção que o olho humano tem das mesmas. Compara-se a estrutura de duas imagens, no caso a imagem prevista e a imagem observada, quanto ao brilho, contraste e estrutura das mesmas. Os resultados variam entre -1 e 1 e quando mais próximo de 1, maior é a similaridade entre as duas amostras.

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1) + (2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (11)$$

A equação 11 calcula o *SSIM* entre duas imagens x e y , onde μ_x e μ_y representam as médias dos valores dos *pixels* das imagens x e y respectivamente. σ_x^2 e σ_y^2 são as variâncias das respectivas variáveis e σ_{xy} a covariância entre x e y . C_1 e C_2 são duas variáveis utilizadas para estabilizar a divisão.

3 – *MAE* (Média do Erro Absoluto) - O *MAE*, como o nome indica, calcula o erro absoluto de um conjunto de dados. É uma métrica básica utilizada em problemas de previsão, pois proporciona uma visão geral da diferença numérica entre o que foi previsto perante a verdade terrestre. O *MAE* é representado pela Equação 12.

$$MAE = \frac{1}{n} \sum_{i=1}^n |d_i - f_i| \quad (12)$$

Onde n é o número de amostras e d_i e f_i são os valores da verdade terrestre e os valores previstos, respectivamente. Essa métrica não tem um limiar máximo, mas quanto menores são os valores (mais próximo de zero), melhor é a previsão.

4 RESULTADOS E DISCUSSÕES

Neste capítulo é descrito o experimento realizado no trabalho, selecionado por representar um evento ocorrido no sul do Brasil, que por sua vez ocasionou perdas, especialmente no setor elétrico. Destaca-se a dificuldade na obtenção de dados para a precisa classificação do sistema na escala de *nowcasting*. O algoritmo proposto neste trabalho tem sido aplicado a outros casos, entretanto a dificuldade em se obter dados de radar, devido a baixa cobertura de radares na Região Sul do Brasil, associada as falhas típicas de operacionalidade, limitam os estudos de caso. Todavia, foi possível explorar o caso clássico ocorrido no dia 12/06/2018, apresentado a seguir.

4.1 Treinamento da Rede

Como já citado, a rede escolhida para esse trabalho é a *PredRNN++* e nesse tópico são detalhados os passos e parâmetros utilizados no treinamento. Os treinamentos foram realizados com os dados no formato citado na seção 3.3 e para cada um dos radares foi realizado um treinamento separado, com os mesmos parâmetros.

Partindo do formato de dados exemplificados na seção 3.3, os treinamentos foram realizados com 1000 sequências contendo 20 imagens cada. Utilizou-se validação cruzada, os dados foram divididos na proporção 80/20 ou seja, 800 sequências para treinamento da rede e 200 sequências para teste. Dentro de uma sequência, as 10 primeiras imagens são os dados históricos do radar e as outras 10 são a verdade terrestre, que buscamos prever.

A rede foi treinada por 10.000 épocas para cada um dos *datasets*, apresentando uma média de 1,66 minutos para cada uma das épocas, isso resultou em aproximadamente 277 horas de treinamento por radar e um tempo total de 1108 horas no geral. O treinamento foi realizado em um computador das seguintes configurações:

Processador: AMD Ryzen 3 2200g 3.7GHz

Memória RAM: 16GB DDR4 2666MHz

Placa de vídeo (GPU): GEFORCE GTX 1080 Ti 4GB GDDR5 128 Bits

Sistema: Windows 10

Além disso, em todo o código (ver *Github*) foi utilizado a API¹ *CUDA* da *NVIDIA*. A API *CUDA*² permite aos desenvolvedores tirar proveito do poder de processamento paralelo das *GPUs* para acelerar várias tarefas computacionais, incluindo simulações científicas e aprendizado de máquina.

A arquitetura padrão da *PredRNN++* foi mantida para o treinamento. Foram utilizadas 4 camadas da célula *CAUSAL LSTM*, com 128, 64, 64, 64 canais³ e uma célula *GHU* no topo da rede com 128 canais. Além disso, foi utilizado um filtro convolucional em cada uma das camadas, o otimizador *Adam* em suas configurações padrões do *PyTorch*, uma taxa de aprendizagem de 10^{-3} , um *batch size* de 8 e a função de ativação \tanh .

A função \tanh (Tangente Hiperbólica) é uma das mais difundidas na área de redes neurais artificiais (ABDELOUAHAB; PELCAT; BERRY, 2017). Ela é uma função não linear que retorna resultados no intervalo entre -1 e 1 e pode ser definida como:

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (13)$$

Onde e representa a base do logaritmo natural. A função de ativação \tanh é vantajosa em redes neurais porque é diferenciável e introduz não-linearidades, permitindo que a rede aprenda relações mais complexas entre os dados de entrada e as saídas.

Ainda sobre o treinamento, as Figuras 11, 12 e 13 demonstram a evolução da qualidade da previsão da rede conforme as épocas de treinamento são apresentadas a rede. Já a Tabela 1 demonstra os resultados das métricas avaliativas conforme as épocas avançam. Os valores apresentados na tabela são valores globais, ou seja, a média de cada métrica para cada uma das épocas. Para a ativação da rede buscando a demonstração das épocas, foi utilizado uma sequência aleatória do *dataset* de radares.

¹API significa "Application Programming Interface"(Interface de Programação de Aplicativos, em português). É um conjunto de regras e protocolos que permitem que diferentes softwares se comuniquem e interajam entre si.

²CUDA - do inglês - Compute Unified Device Architecture) é uma interface de programação de aplicativos desenvolvida pela *NVIDIA* para permitir a programação de GPUs (Graphics Processing Units) da *NVIDIA* para tarefas de computação de propósito geral.

³Em uma célula recorrente, como a *LSTM*, *CAUSAL LSTM* ou a *GHU*, os "canais" se referem às diferentes unidades independentes que processam informações em paralelo. Cada canal tem sua própria memória e parâmetros associados.

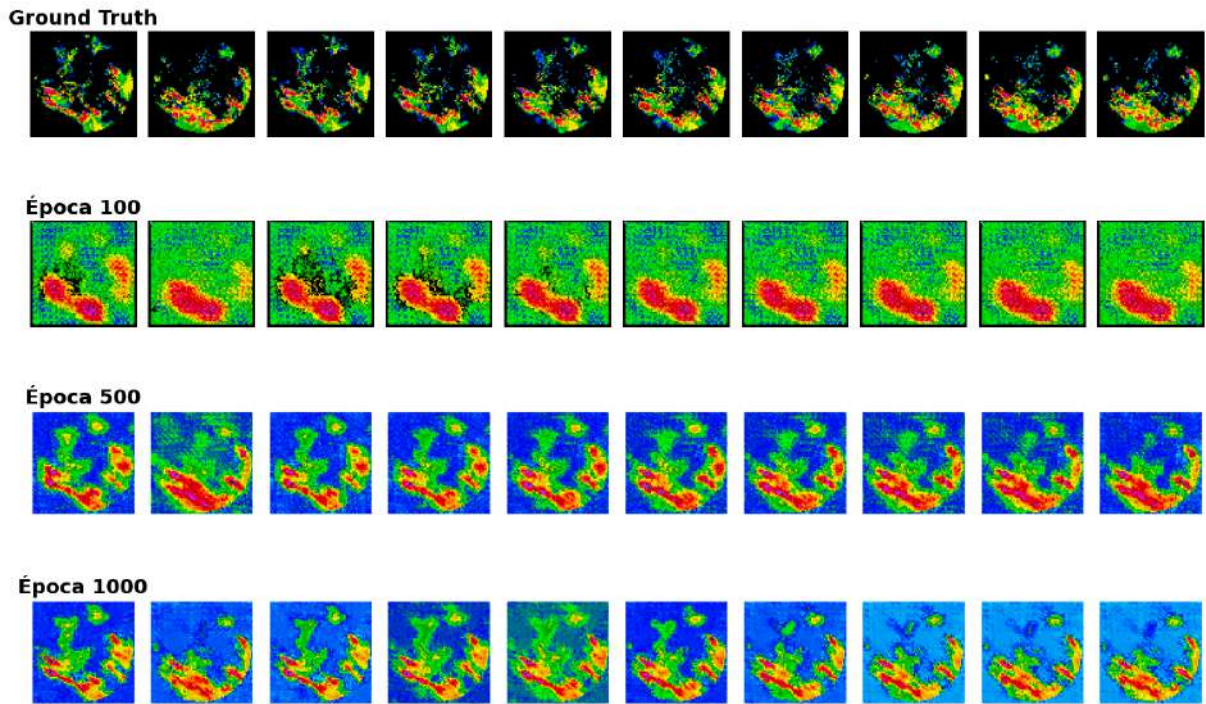


Figura 11 – Resultados do treinamento com 100, 500 e 1000 épocas.




Figura 12 – Resultados do treinamento com 3000, 5000 e 7000 épocas.




Figura 13 – Resultados do treinamento com 9000 e 10000 épocas.

Tabela 1 – Métricas durante o treinamento.

Época	RMSE	SSIM	MAE
100	31,30944	0,55093	48,12770
500	35,73444	0,50797	61,53530
1000	36,30185	0,49890	55,19013
3000	23,06605	0,76265	36,96029
5000	19,62519	0,81459	29,91783
7000	15,72346	0,86138	23,44246
9000	14,93970	0,86661	22,62350
10000	14,00514	0,87962	22,14639

Na Figura 11 pode ser observado que nas primeiras 100 épocas de treinamento a rede neural começa a identificar a forma do sistema meteorológico contido na verdade terrestre (*ground truth*), mas ainda está bem longe do formato e da intensidade. Entre as épocas 500 e 1000, o sistema começa a tomar forma, porém ainda bem longe da verdade terrestre. Vale observar que o fundo das imagens previstas nestas épocas são totalmente diferente do fundo preto das imagens originais contidas na verdade terrestre.

Na Figura 12 é demonstrado que a partir da época 3000 a previsão da rede dá um grande salto de qualidade em comparação a época 1000. Quase todas as imagens previstas apresentam o fundo preto das imagens originais, o formato do sistema meteorológico está mais semelhante e a intensidade (representada pelas cores) está começando a se estabilizar. A melhora da previsão segue nas épocas 5000 e 7000, com a época 7000 apresentando as cores de fundo da verdade terrestre com excelente precisão.

Já na Figura 13, nas épocas 9000 e 10000 a melhora começa a se tornar menos visível, tendo apenas alguns pequenos ajustes. As épocas 90000 e 100000 já demonstram uma semelhança muito grande entre a previsão e a verdade terrestre, tanto no formato quanto na intensidade do sistema.

Quando analisa-se as métricas contidas na Tabela 1, nota-se que entre as épocas 100 e 1000, a rede neural ainda está se ajustando ao dados e apresenta grande instabilidade e diferença perante a verdade terrestre. A estabilização começa a partir da época 3000, onde as três métricas melhoram consideravelmente.

A partir da época 5000 a rede neural já apresenta um resultado muito bom, com um *SSIM* demonstrando que a imagem prevista está aproximadamente 81% igual a verdade terrestre. Nas épocas subsequentes, as métricas se estabilizam e atingem uma precisão ótima, com valores muito próximos da verdade terrestre.

Vale ressaltar que essa qualidade de previsão deve ser considerada apenas para os dados utilizados nesse trabalho, que são dados dos quatro radares dispostos no sul do Brasil. Não encontramos na literatura (até o momento) outros trabalhos utilizando esses dados para comparar. Para outros dados, sejam eles de radares ou não, o tempo de treinamento e o valor das métricas será diferente, podendo ser melhores ou piores. Apenas como referência, o trabalho original de (WANG et al., 2018) trás um *SSIM* de 0,898 para o *dataset MNIST*.

Também destaca-se que, embora o tempo de treinamento da Rede Neural tenha sido relativamente alto, ultrapassando 1000 horas, após o mesmo ter sido finalizado, a *PredRNN++* consegue gerar uma previsão (no formato mostrado em 4.2) em menos de 30 segundos.

A agilidade na produção das previsões é uma característica distintiva que destaca a capacidade da *PredRNN++* em lidar com tarefas complexas de previsão em um intervalo de tempo notavelmente curto. Em contraste, os modelos numéricos convencionais frequentemente demandam minutos, se não horas, para executar a mesma tarefa de geração de previsões (WEDI, 2014). Essa discrepância substancial no tempo de processamento coloca a *PredRNN++* em uma posição vantajosa, tornando-a uma opção atrativa para cenários em que a velocidade de obtenção das previsões é crucial, como em aplicações de monitoramento em tempo real ou tomada de decisões ágeis baseadas em previsões precisas.

4.2 Experimento

4.2.1 Caso de 12/06/2018 - Tornado nos estados RS/SC - Dados do Radar de Chapecó

Na madrugada do dia 12/06/2018, no município de Água Santa-RS, foram registrados danos em três torres que integram a Linha de Transmissão (LT) Itá-Nova Santa Rita, responsável pela geração de 525 kV de energia. Mais precisamente, duas torres foram completamente destruídas e uma foi severamente danificada. O Centro de operação do sistema da Eletrosul registrou a ocorrência às 00h40, do dia 12/06/2018. A empresa mobilizou mais de 80 técnicos para a recuperação da LT, que foi concluída no dia 17/06/2018, com energização liberada pelo Operador Nacional do Sistema Elétrico às 22h13. A Figura 14 ilustra como ficou uma das torres de transmissão após o evento ocorrido na madrugada do dia 12/06/2018 em Água Santa-RS.




Figura 14 – Torre danificada.

4.2.2 Ambiente em Escala Sinótica na Madrugada do dia 12/06/2018

No intuito de apresentar uma visão geral da situação atmosférica no período do evento em questão, na escala sinótica, apresenta-se na Figura 15 imagens do satélite GOES-16, no Canal Infravermelho Termal às 00h15, 00h30 e 00h45 do dia 12 de junho de 2018.

As imagens mostram nuvens altas com topo frio no litoral do RS, sugerindo a ação de uma frente cobrindo todo o estado. No realce, as cores escuras destacam o topo das nuvens mais altas e mais frias, donde subentendesse a existência de nuvens do tipo *Cumulus Nimbus*. A sequência mostra que o sistema amplifica-se e se desloca em direção ao Oceano Atlântico.

Nas imagens a seguir, observa-se o produto GPT, gerado pelo Centro de Previsão de Tempo e Estudos Climáticos do Instituto Nacional de Pesquisas Espaciais (CPTEC-INPE). As Cartas de Superfície são grafadas na Figura 16 e as de altitude são grafadas na Figura 17.




Figura 15 – Imagens de satélite nos horários 00h15, 00h30 e 00h45 do dia 12 de junho de 2018.




Figura 16 – Carta em Superfície no dia 11/06/2018 às 18h00 e no dia 12/06/2018 às 12h00 e às 12h06.




Figura 17 – Carta em Altitude no dia 11/06/2018 às 18h00 e no dia 12/06/2018 às 12h00 e às 12h06.

Os campos grafados nas Figuras 16 e 17 mostram uma típica onda de *Rossby* se propagando de sudoeste para noroeste, ou seja, uma frente fria. Este sistema é composto por uma região de separação entre duas massas de ar com temperatura e densidade diferente, onde a massa de ar frio projeta-se sobre a área de massa de ar quente. Em altos níveis há um cavado baroclínico, onde há conversão de energia potencial do estado básico para energia cinética do estado perturbado da onda. Este sistema, causa queda de temperatura, ventos fortes e precipitação pelo domínio por onde se propaga. Ou seja, em escala sinótica, temos uma típica configuração de instabilidade baroclínica associada a sistema frontal (HOLTON, 1973; BLUESTEIN, 1992). Contudo, questiona-se porque apenas a região de Água Santa teve ventos com intensidade superior a 300 km/h e se é possível prever ou encontrar assinaturas de fenômenos em menor escala que causem eventos extremos.

A ciência não tem resposta completa e definitiva para estas questões, mas necessita que tenhamos ferramentas que auxiliem os cientistas e previsores se anteciparem a estes eventos, como uma rede de observações em alta resolução, tanto em superfície como em altitude, de medidas diretas, como estações de superfície e sondagens, como de medidas indiretas, tais como refletividade de radares e radiâncias de satélites em alta resolução.

Uma forma de amenizar a falta de dados e a baixa cobertura de radares, em específico na Região Sul do Brasil, é utilizada neste trabalho, ou seja, Redes Neurais Artificiais para prever a propagação e intensidade de sistemas que causam eventos extremos na escala de *nowcasting*.

Desse modo, com o intuito de avaliar a capacidade da metodologia por RNA na previsão de *nowcasting*, treinou-se a *PredRNN* com os dados descritos em 3.1 e ativou-se para 60 minutos, da gênese a oclusão do sistema estudado (4 vezes de 1 hora), ou seja, explora-se a capacidade do modelo neural na previsão de 1h; com dados de entrada do dia 11/06/2018 às 23h02 até às 03h56 do dia 12/06/2018.

Destaca-se que é intuitivo crer que o sistema já deve ter se formado para ser acompanhado. A rede não considera processos físicos de formação e dissipação e sim movimento de translação e rotação.

4.2.2.1 *Previsão para o domínio da região de Chapecó-SC entre 00h02 e 00h56 do dia 12/06/2018*

Ao analisar os resultados, é importante conhecer a relação entre decibéis (*dBZ*) e precipitação, bem como discriminar a quantidade de precipitação. Portanto, considera-se que 10 *dBZ* equivale a precipitação de aproximadamente 0,1 mm/h, onde a maioria das nuvens não são precipitáveis; que 20 *dBZ* equivale a aproximadamente 0,5 mm/h (chuvisco); que 30 *dBZ* equivale a aproximadamente 3 mm/h (chuva fraca); 40 *dBZ* equivale a aproximadamente 12 mm/h (chuva moderada); 50

dBZ equivale a 60 mm/h (chuva forte, tempestade, possibilidade de granizo) e 60 *dBZ* equivale a aproximadamente 300 mm/h (chuva extremamente forte).

A partir deste ponto do texto, analisa-se os resultados na escala espaço-temporal do *nowcasting*. A primeira questão a ser considerada é qual sistema causou o dano detectado. É comum a imprensa e populares⁴, classificarem tal evento como tornádico. Portanto, vale destacar, que embora tenha havido um considerável aumento no registro de número de tornados no Brasil nos últimos anos, é provável que a ocorrência destes fenômenos seja sub notificada, principalmente quando ocorrem em regiões desabitadas e a noite, pois não existe no país, um sistema oficial de avaliação de danos causados por ventos (Lopes e Nascimento, 2020). Tornados tem resolução espaçotemporal da ordem de minutos e da ordem de centenas de metros, de forma que a observação da vegetação, como árvores contorcidas, são um bom indicativo da passagem de um tornado em determinada região.

De maneira menos subjetiva, utilizam-se imagens de satélites ambientais de órbita baixa na detecção de rastros deixados por tornados, ventos intensos e até a ocorrência de granizo. Entretanto, radares de dupla polarização são a ferramenta mais importante na detecção e classificação de tornados (WU; WEI; LI, 2022).

Na madrugada do dia 12/06/2018, tudo indica que houve a ocorrência de um célula tornádica na Região de Água Santa-RS, estabelecido numa linha de instabilidade que acompanhou a frente fria que passou pela Região Sul do Brasil no período.

Na Figura 18, imagens do radar de Chapecó-SC entre 23h02 e 23h56 do dia 11/06/2018, observa-se a presença de refletividade em toda a área de cobertura do radar, entretanto os valores mais altos, representando células convectivas mais profundas, localizam-se a sudoeste do radar. Esses pixels, com refletividade superiores a 40 *dBZ*, formam uma linha de instabilidade, onde pode ter ocorrido o tornado.

⁴Aqui nos referimos a todas as pessoas que não tenham conhecimento científico sobre o tema

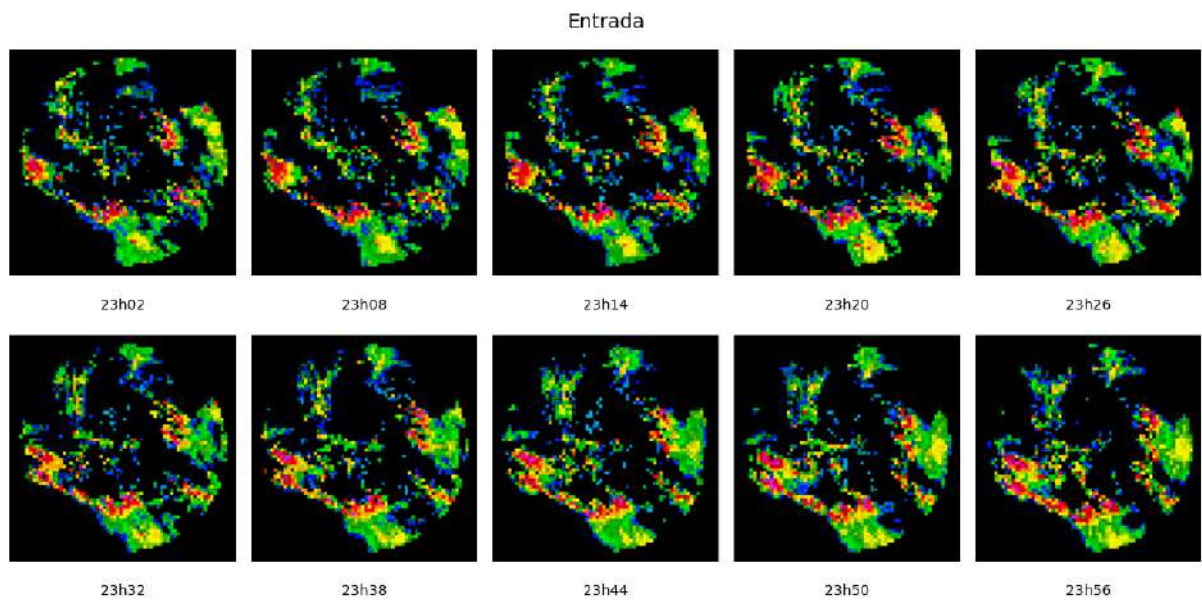


Figura 18 – Imagens do radar de Chapecó-SC entre 23h02 e 23h56 do dia 11/06/2018.

Entre as Figuras 19 e 23 observa-se a trajetória e posição do sistema em um intervalo de 54 minutos. Verifica-se também, que a capacidade preditiva do modelo é evidenciada pelo fato de que as previsões geradas reproduzem quase que fielmente o que foi observado na verdade terrestre. Essa notável congruência entre as previsões e a verdade terrestre é crucial para estabelecer a confiabilidade e a validade do modelo de previsão adotado.

Além da posição, as previsões também demonstram a capacidade do modelo em identificar tanto as regiões com maiores refletividades quanto aquelas com menores refletividades. Essa habilidade de distinguir as variações nas intensidades é fundamental para compreender a distribuição e a magnitude das características do sistema meteorológico em análise. A precisão com que o modelo neural consegue identificar essas diferenças e alocá-las nas respectivas localizações é uma demonstração da eficácia do modelo em capturar as características do sistema, contribuindo para uma previsão mais precisa e confiável.

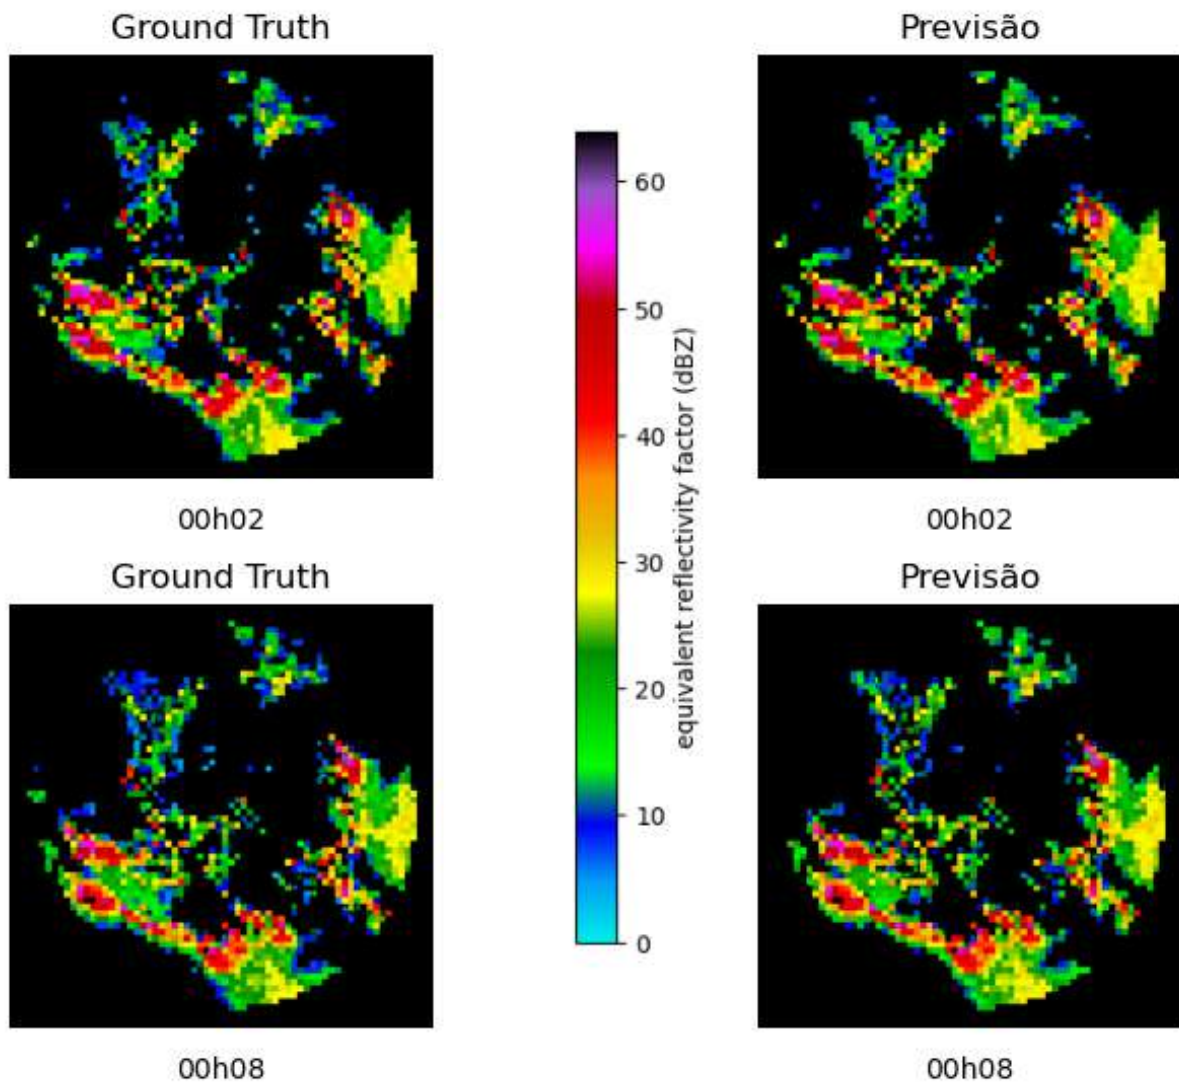


Figura 19 – Previsão para o dia 12/06/2018 às 00h02 e às 00h08.

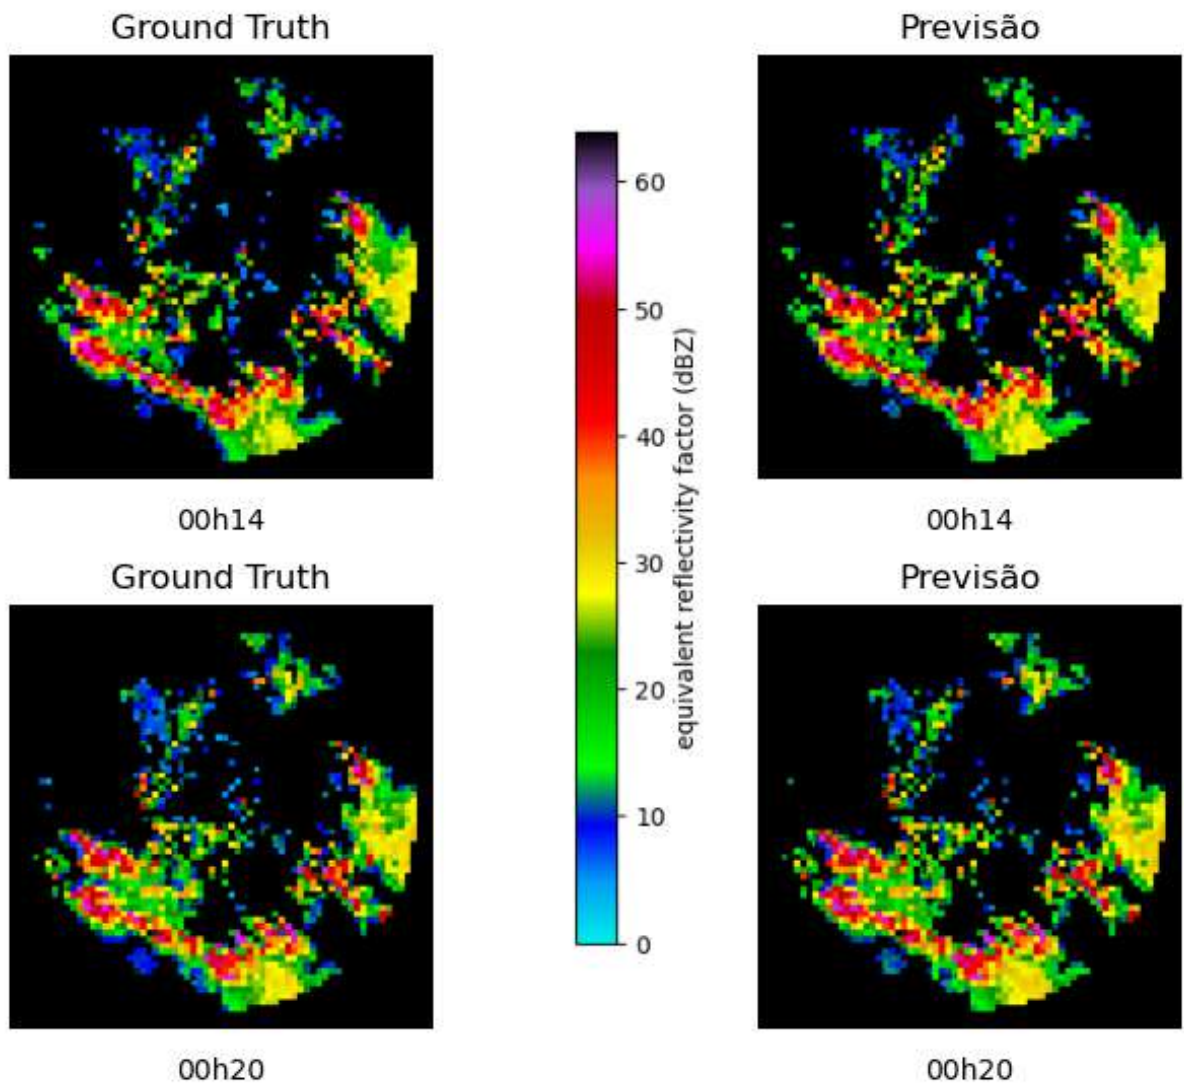


Figura 20 – Previsão para o dia 12/06/2018 às 00h14 e às 00h20.

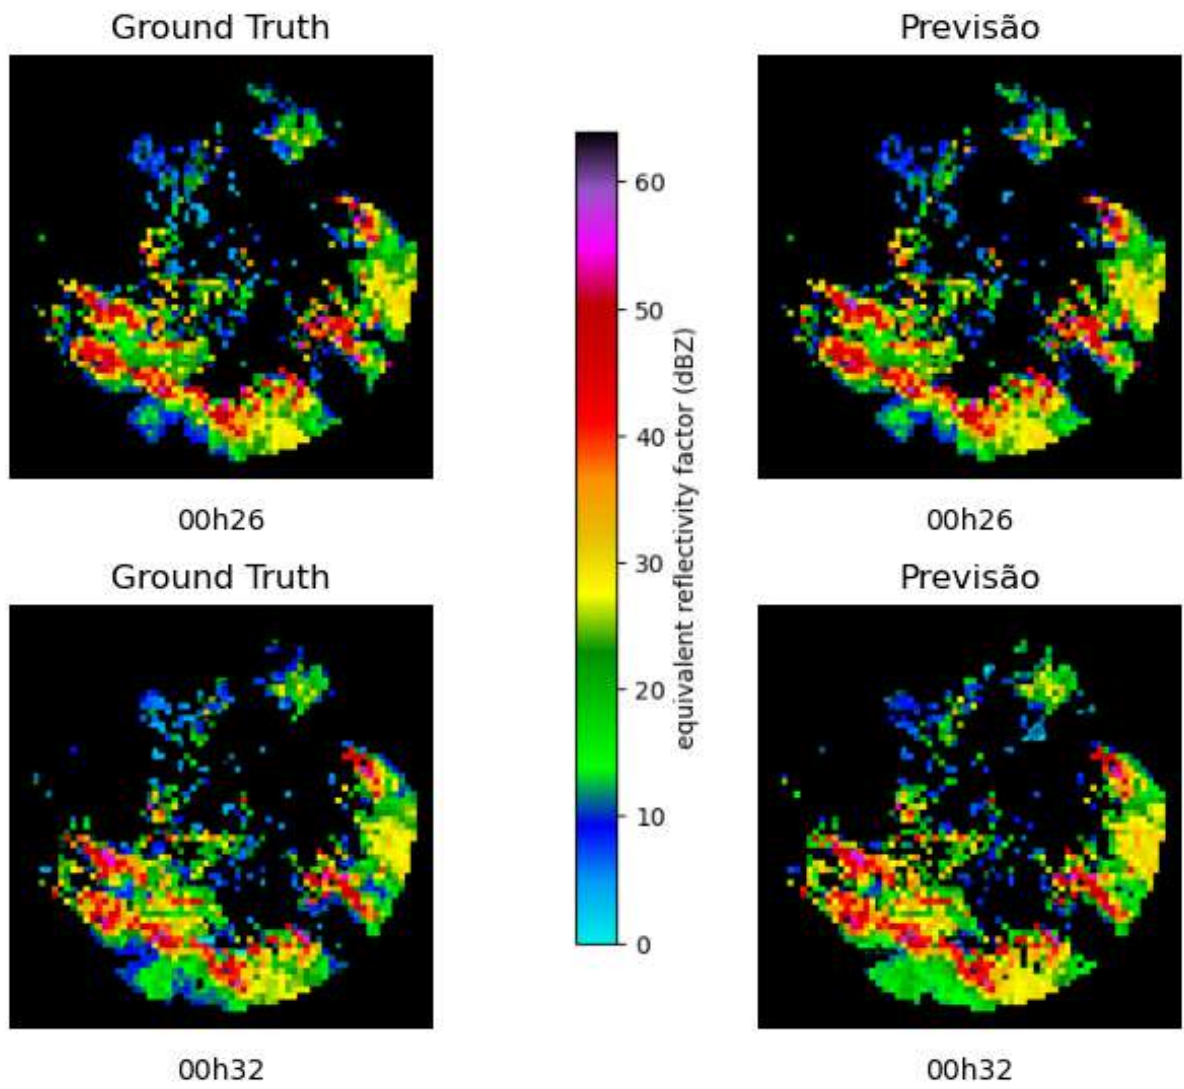


Figura 21 – Previsão para o dia 12/06/2018 às 00h26 e às 00h32.

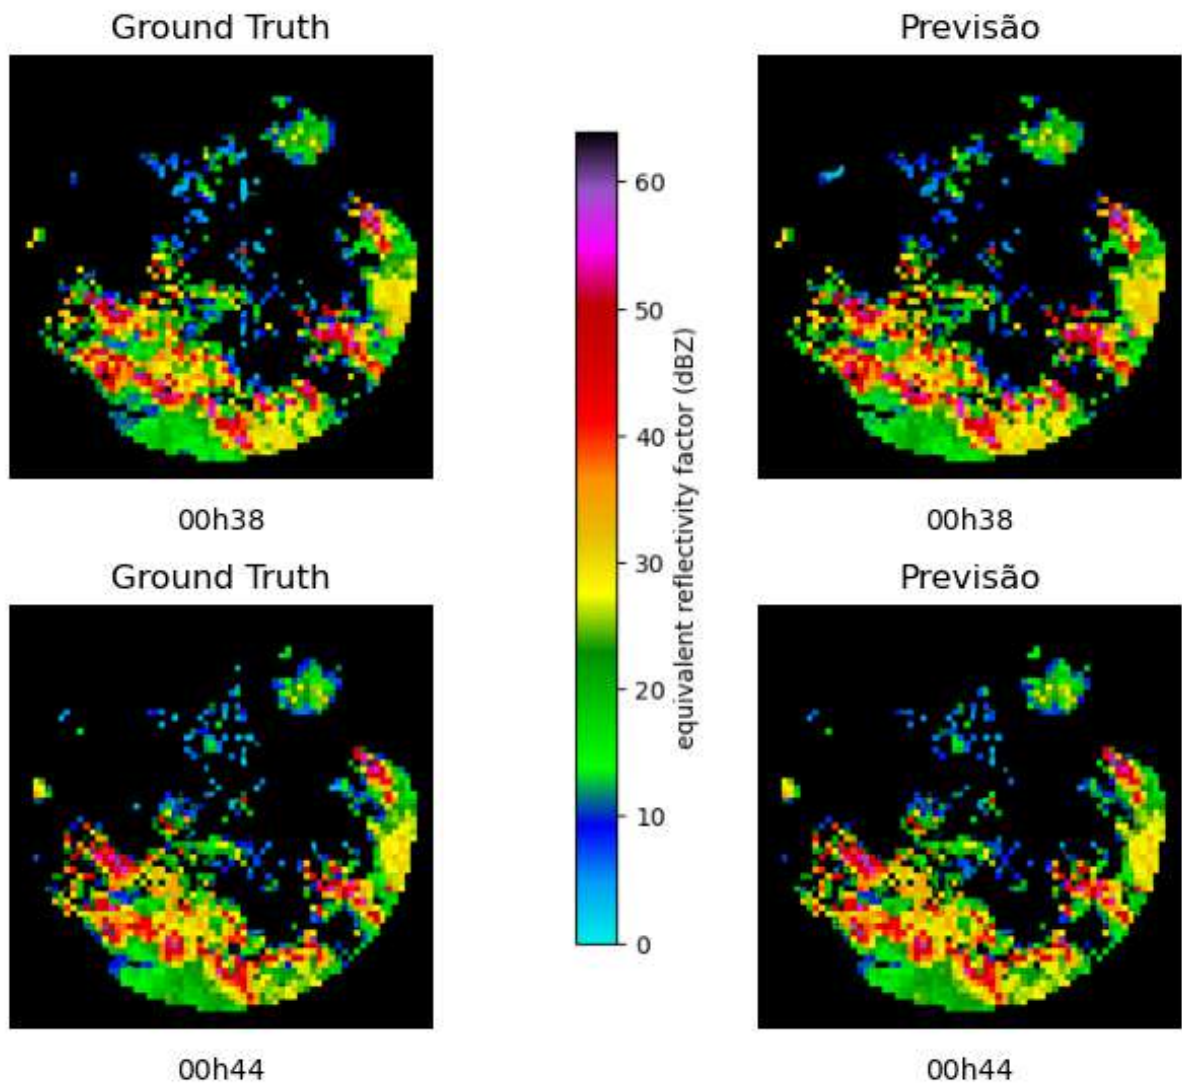


Figura 22 – Previsão para o dia 12/06/2018 à 00h38 e à 00h44.

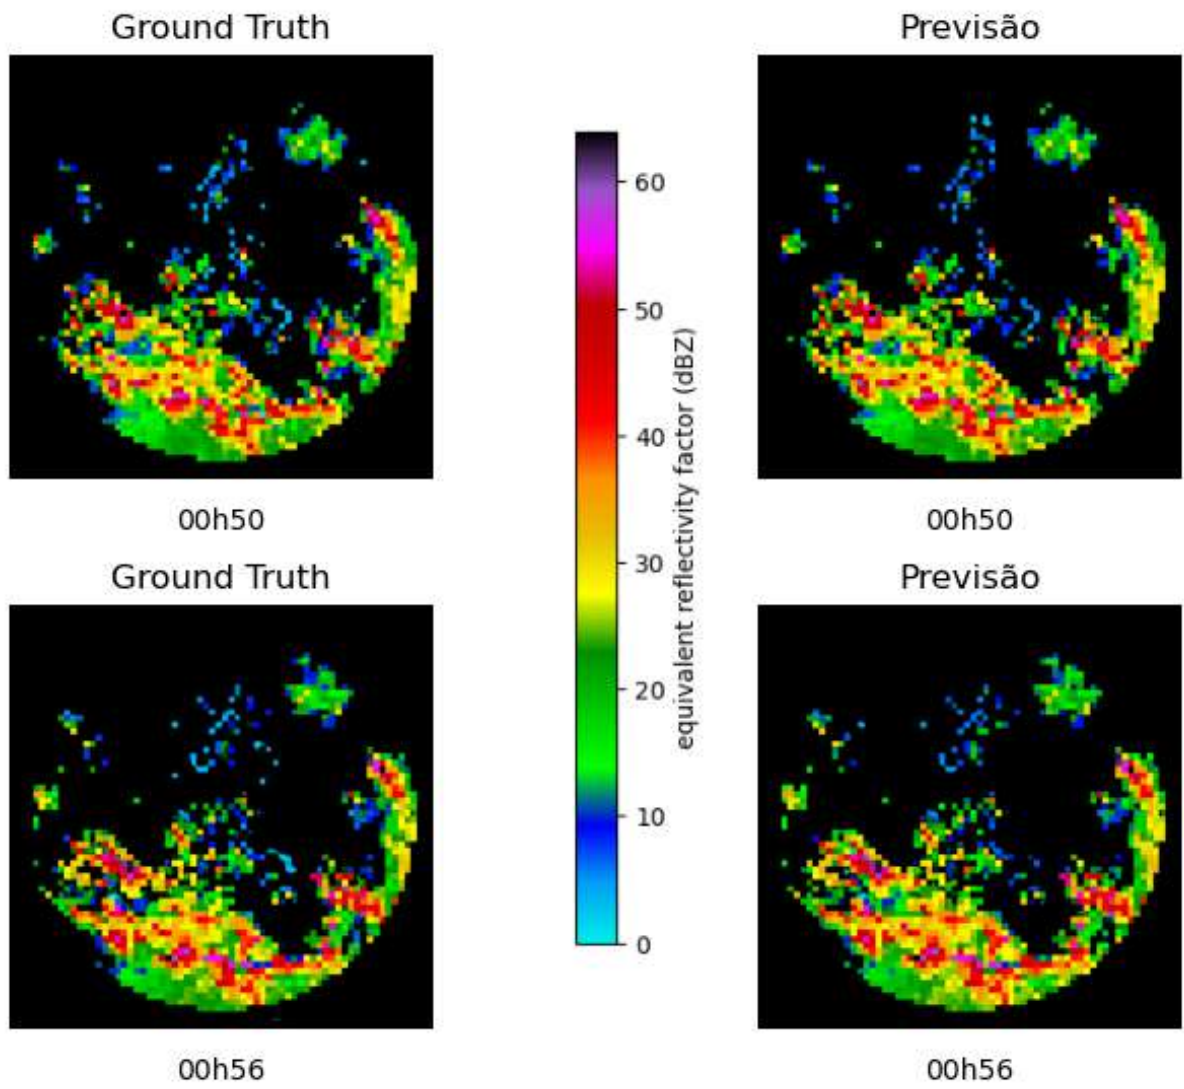


Figura 23 – Previsão para o dia 12/06/2018 à 00h50 e à 00h56.

A Tabela 2 mostra que tanto o *RMSE* como o *MAE* aumentaram um pouco com o horizonte de previsão, com pequenas oscilações no período. Em teoria, quando pensando a longo prazo, esse comportamento sugere uma tendência geral de maior discrepância entre as previsões geradas pelo modelo e os valores reais conforme o período de previsão se afasta do momento presente.

Porém, quando observa-se os resultados do *SSIM*, a alta similaridade de 88% revela que o modelo está capturando de maneira notável os padrões e as características presentes nos dados reais. Isso sugere que, apesar das flutuações nos indicadores de erro mencionados anteriormente, o modelo está conseguindo preservar e refletir de maneira significativa as informações cruciais necessárias para gerar previsões coerentes com o que se está buscando.

Tabela 2 – Métricas entre 00h02 e 00h56.

Horário	RMSE	SSIM	MAE
00h02	12,97092	0,88736	21,46726
00h08	13,89034	0,87895	22,08349
00h14	13,57018	0,88225	21,84790
00h20	13,26058	0,88474	21,79353
00h26	12,83015	0,88791	21,61334
00h32	15,78007	0,86003	23,67804
00h38	13,41088	0,88346	21,19067
00h44	12,61092	0,88971	22,47739
00h50	12,62077	0,88989	20,52912
00h56	13,30041	0,88507	22,25039

4.2.2.2 *Previsão para o domínio da região de Chapecó-SC entre 01h02 e 01h56 do dia 12/06/2018*

Na Figura 24, imagens do radar de Chapecó-SC entre 00h02 e à 00h56 do dia 12/06/2018, o sistema ainda esta ativo, entretanto a presença da segunda linha de estabilidade é marcante.

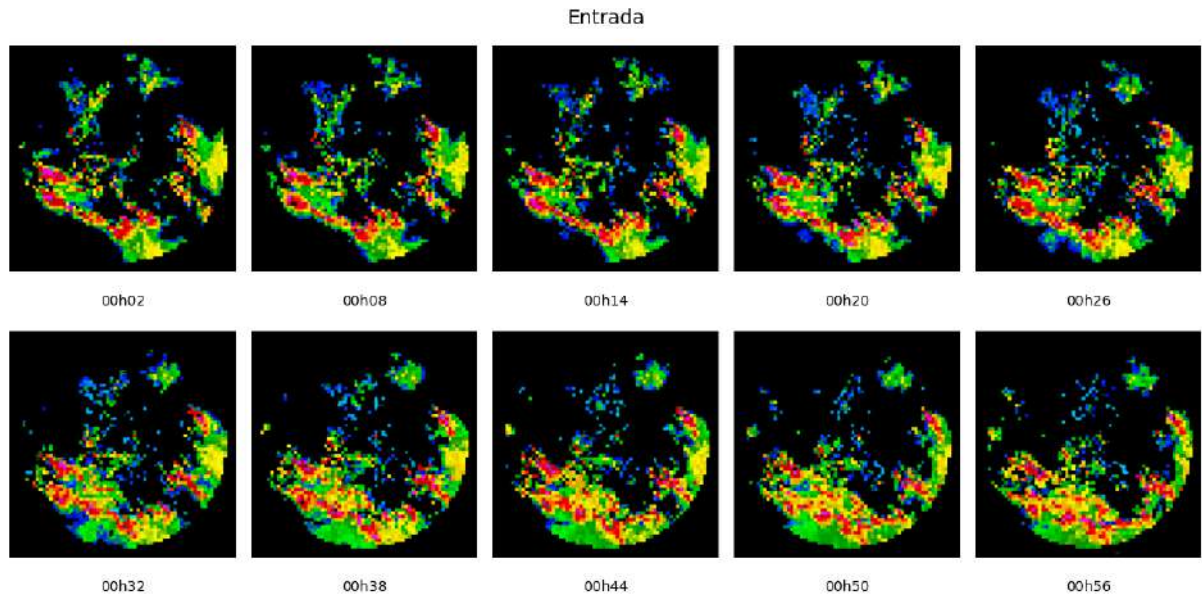


Figura 24 – Imagens do radar de Chapecó-SC entre 00h02 e 00h56 do dia 12/06/2018.

Entre as Figuras 26 e 29 observa-se que o Modelo Neural continua com uma ótima acurácia em prever, não somente a localização e forma do sistema estudado, mas também os vários níveis de intensidade do mesmo, resultando em uma reprodução visual muito fiel com a verdade observada.

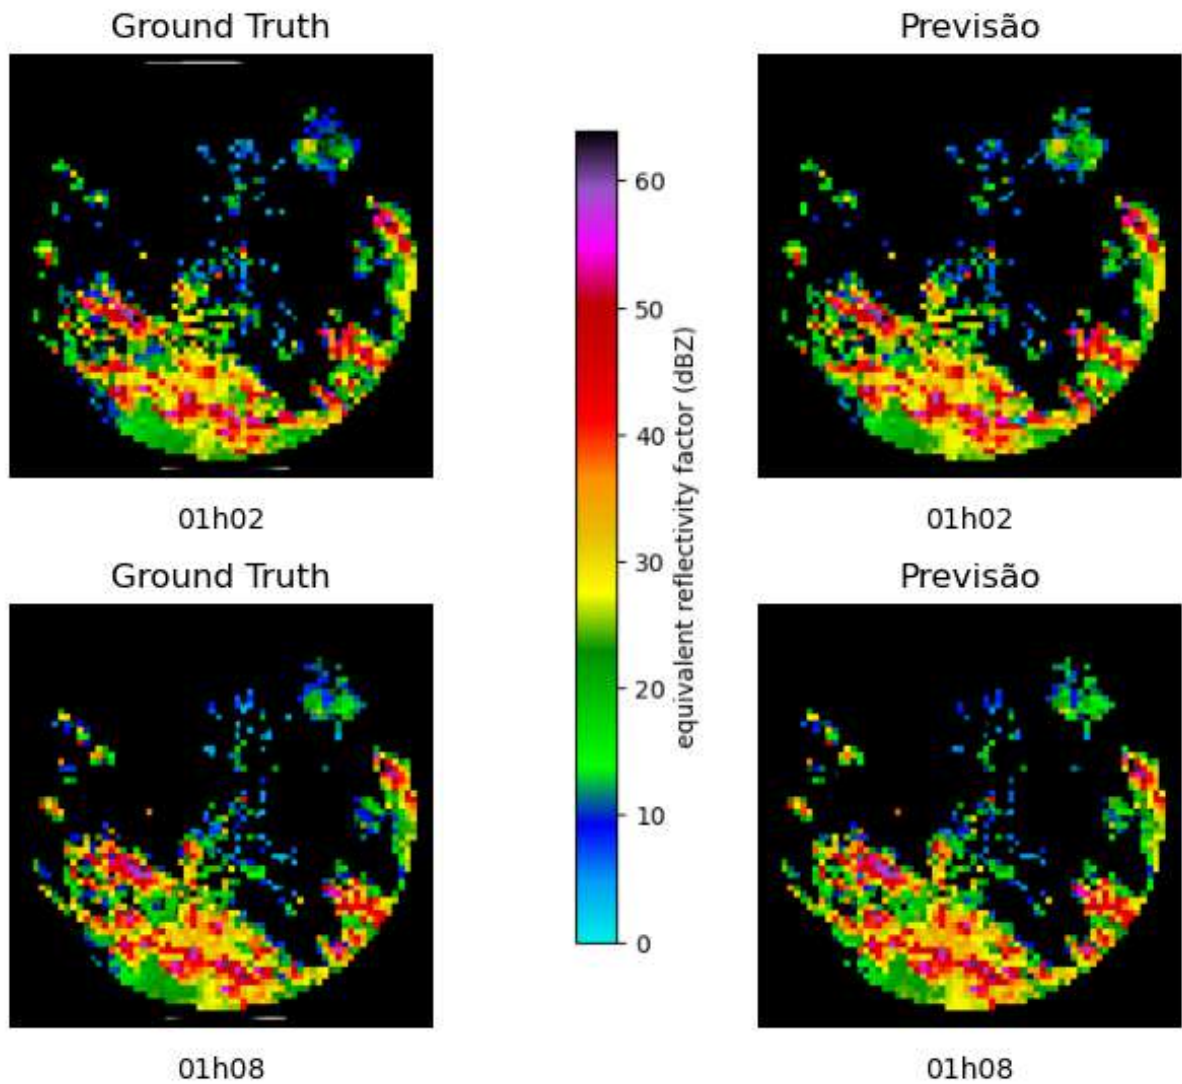


Figura 25 – Previsão para o dia 12/06/2018 à 01h02 e à 01h08

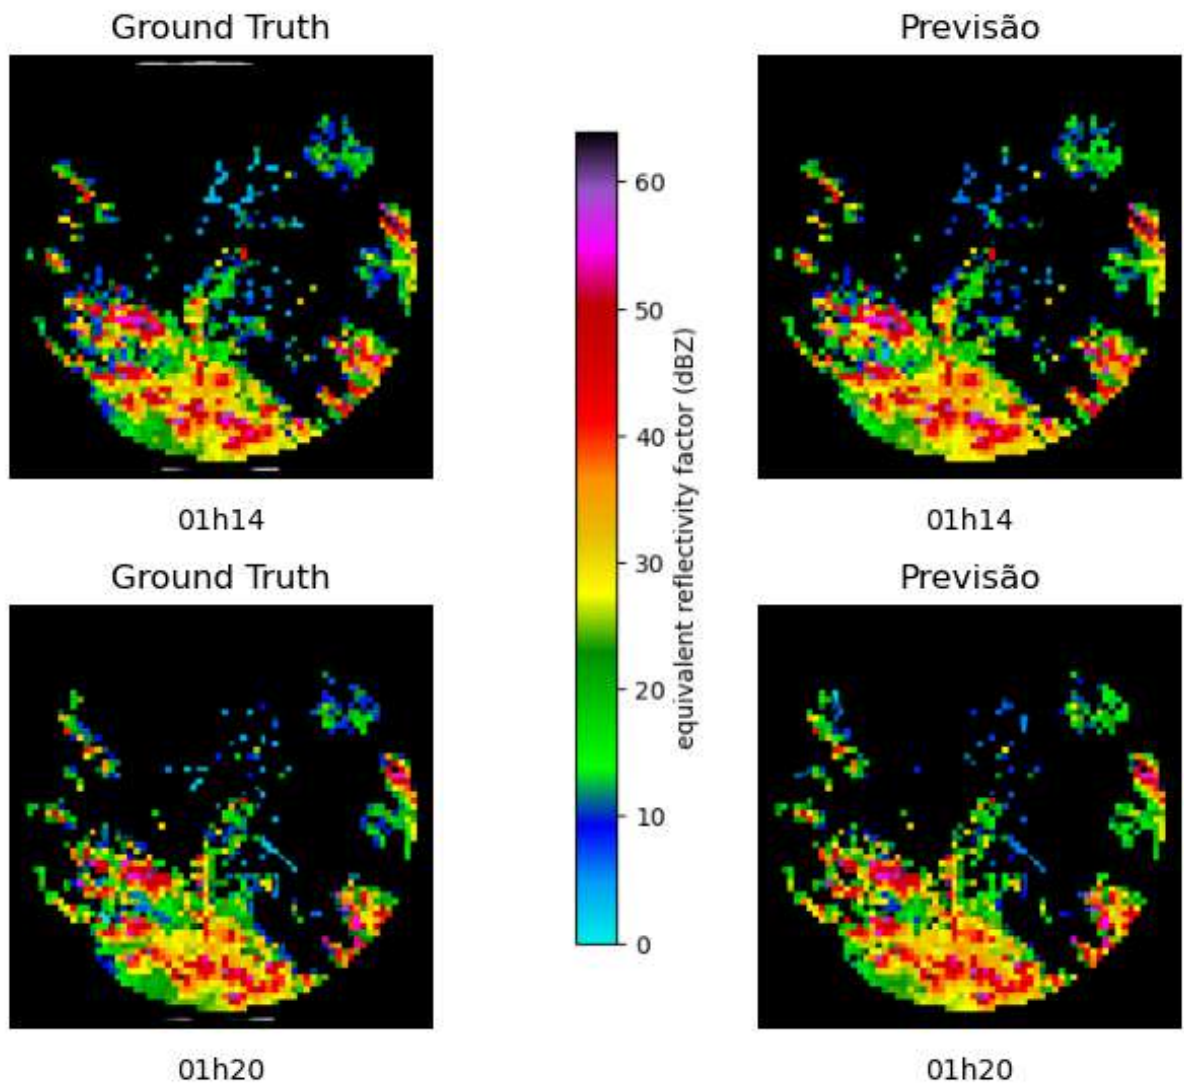


Figura 26 – Previsão para o dia 12/06/2018 à 01h14 e à 01h20.

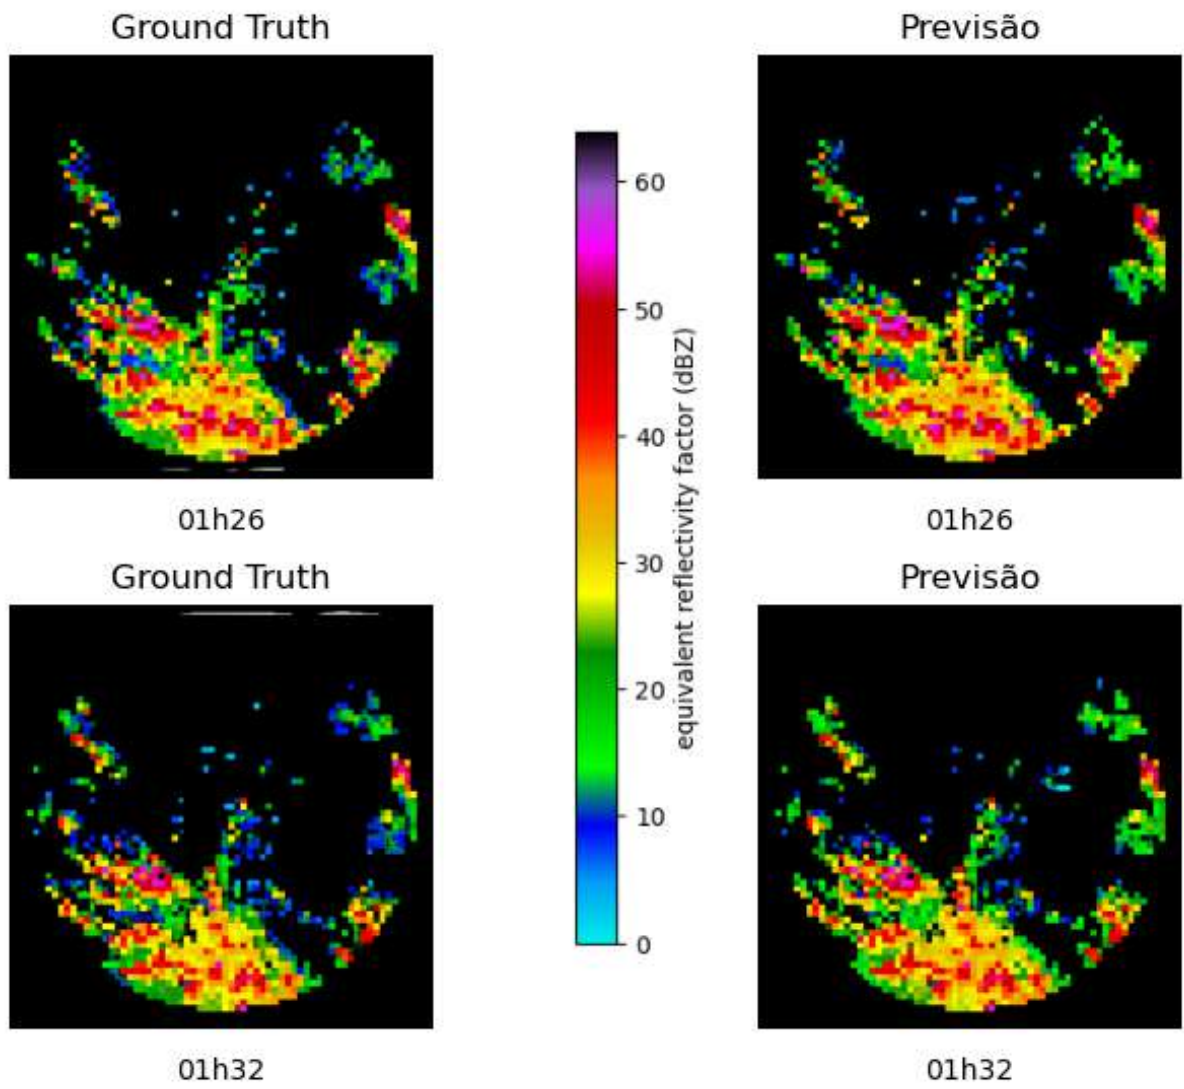


Figura 27 – Previsão para o dia 12/06/2018 à 01h26 e à 01h32.

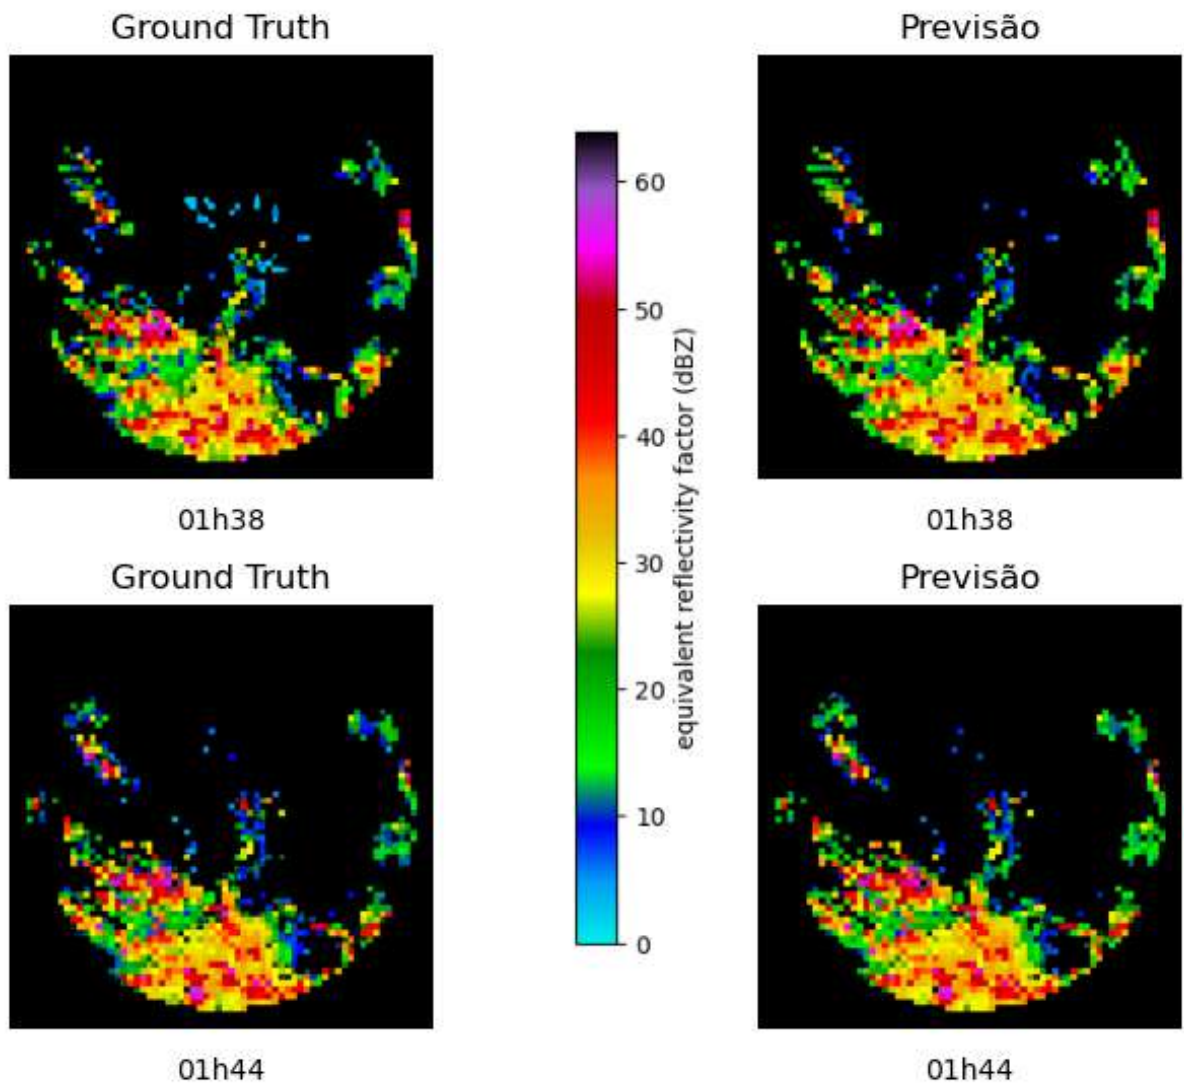


Figura 28 – Previsão para o dia 12/06/2018 à 01h38 e à 01h44.

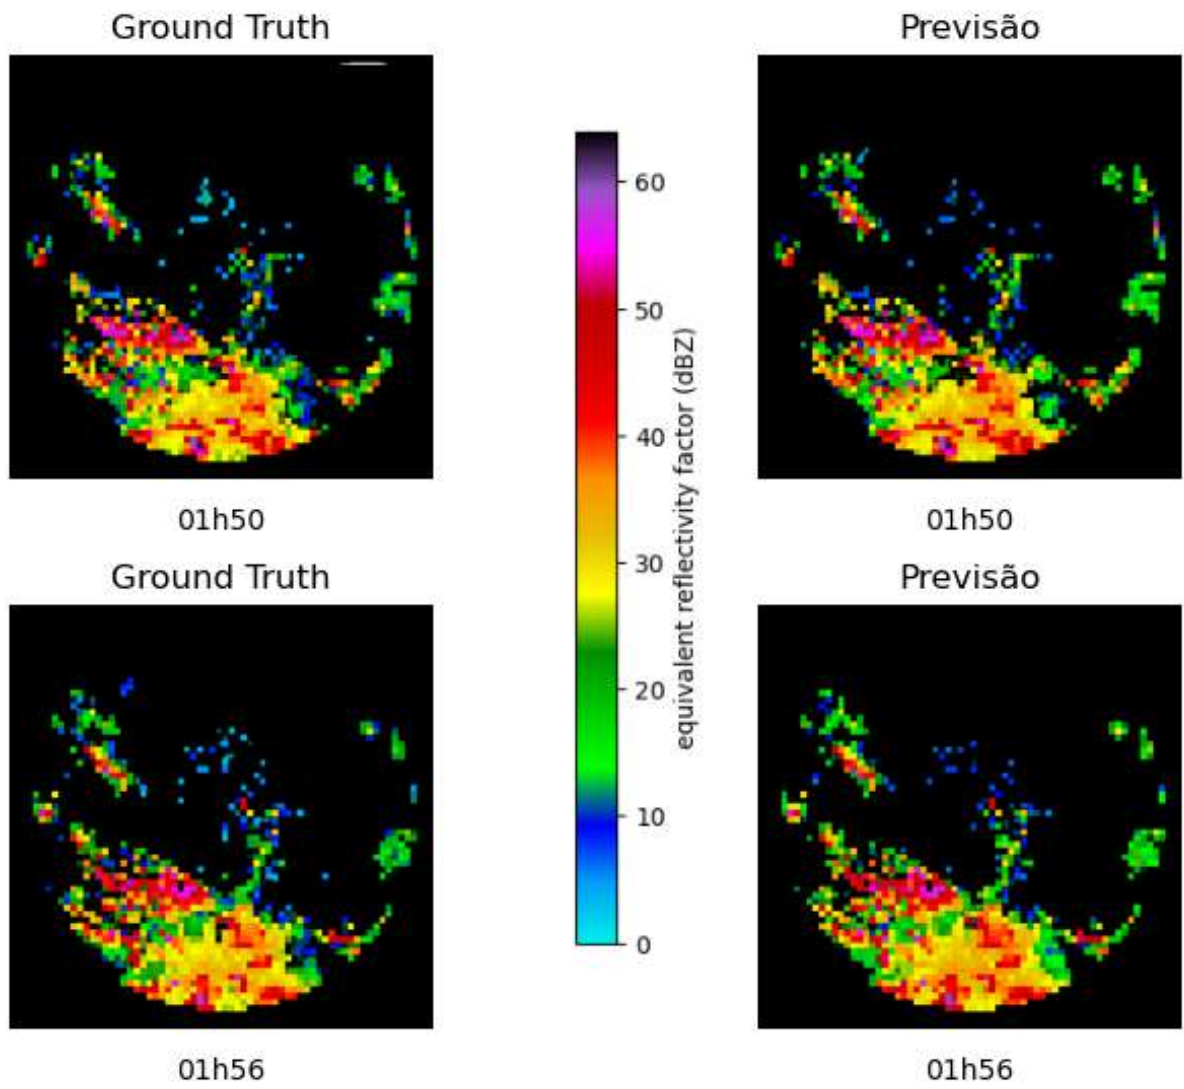


Figura 29 – Previsão para o dia 12/06/2018 à 01h50 e à 01h56.

Tabela 3 – Métricas entre 01h02 e 01h56.

Horário	RMSE	SSIM	MAE
01h02	13,52034	0,88278	21,9971
01h08	13,04095	0,88647	21,5225
01h14	14,10028	0,87684	22,0324
01h20	14,87017	0,87007	21,2735
01h26	14,58071	0,87317	22,8742
01h32	14,91060	0,86901	21,8854
01h38	13,85078	0,88070	20,8620
01h44	13,05048	0,88653	20,7215
01h50	13,61079	0,88159	20,84084
01h56	13,94063	0,87954	20,32897

Os dados apresentados na Tabela 3 também respaldam a continuação da qualidade de previsão do modelo. Os erros associados às previsões revelam-se relativamente pequenos quando comparados à magnitude das características do sistema em análise. Essa coerência entre as previsões geradas pelo modelo e os valores reais observados é uma indicação sólida da capacidade do Modelo Neural em aprender e representar a complexidade do sistema meteorológico em questão.

4.2.2.3 *Previsão para o domínio da região de Chapecó-SC entre 02h02 e 02h56 do dia 12/06/2018*

Na Figura 30 são apresentadas imagens do radar de Chapecó-SC entre 01h02 e às 01h56 do dia 12/06/2018. Nesse momento, pode ser observado que as linhas de estabilidade se desorganizaram, sendo que há células de convecção profunda distribuídas no domínio do radar aproximando-se da antena.

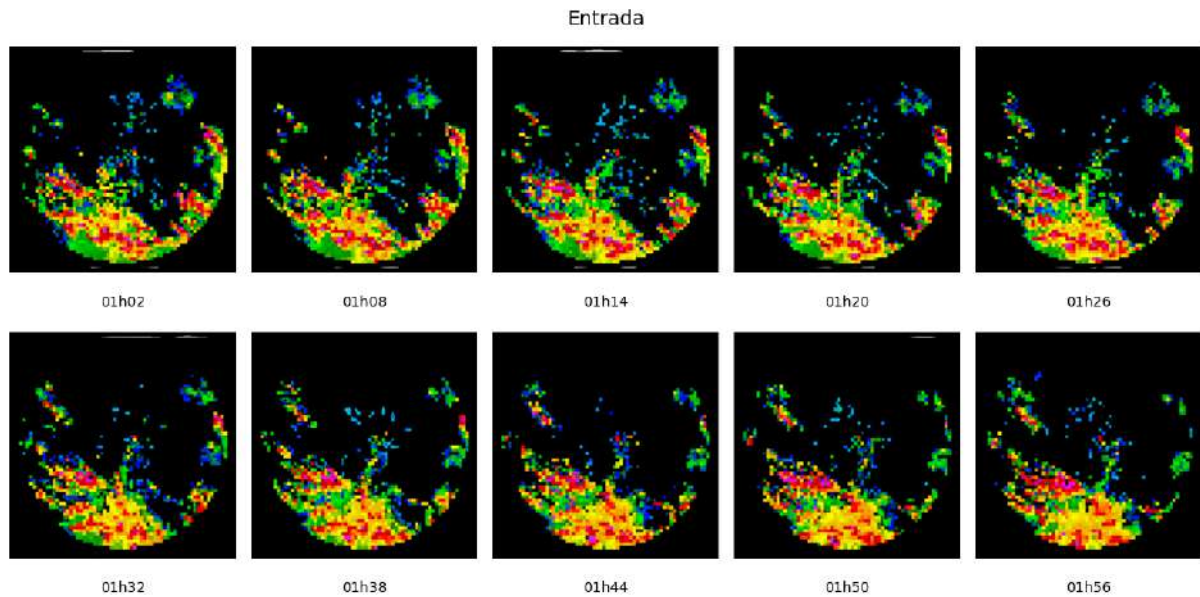


Figura 30 – Imagens do radar de Chapecó-SC entre entre 01h02 e 01h56 do dia 12/06/2018.

Quando examina-se com profundidade o intervalo compreendido pelas Figuras 31 e 35, se reforça a ótima precisão obtida pelo Modelo Neural. A habilidade do modelo em identificar de maneira confiável as características essenciais do sistema se manifesta de maneira muito boa nessa sequência de imagens. As informações visuais contidas nessas figuras continuam a ilustrar o Modelo Neural como uma ferramenta altamente competente na representação dos dados observados na verdade terrestre.

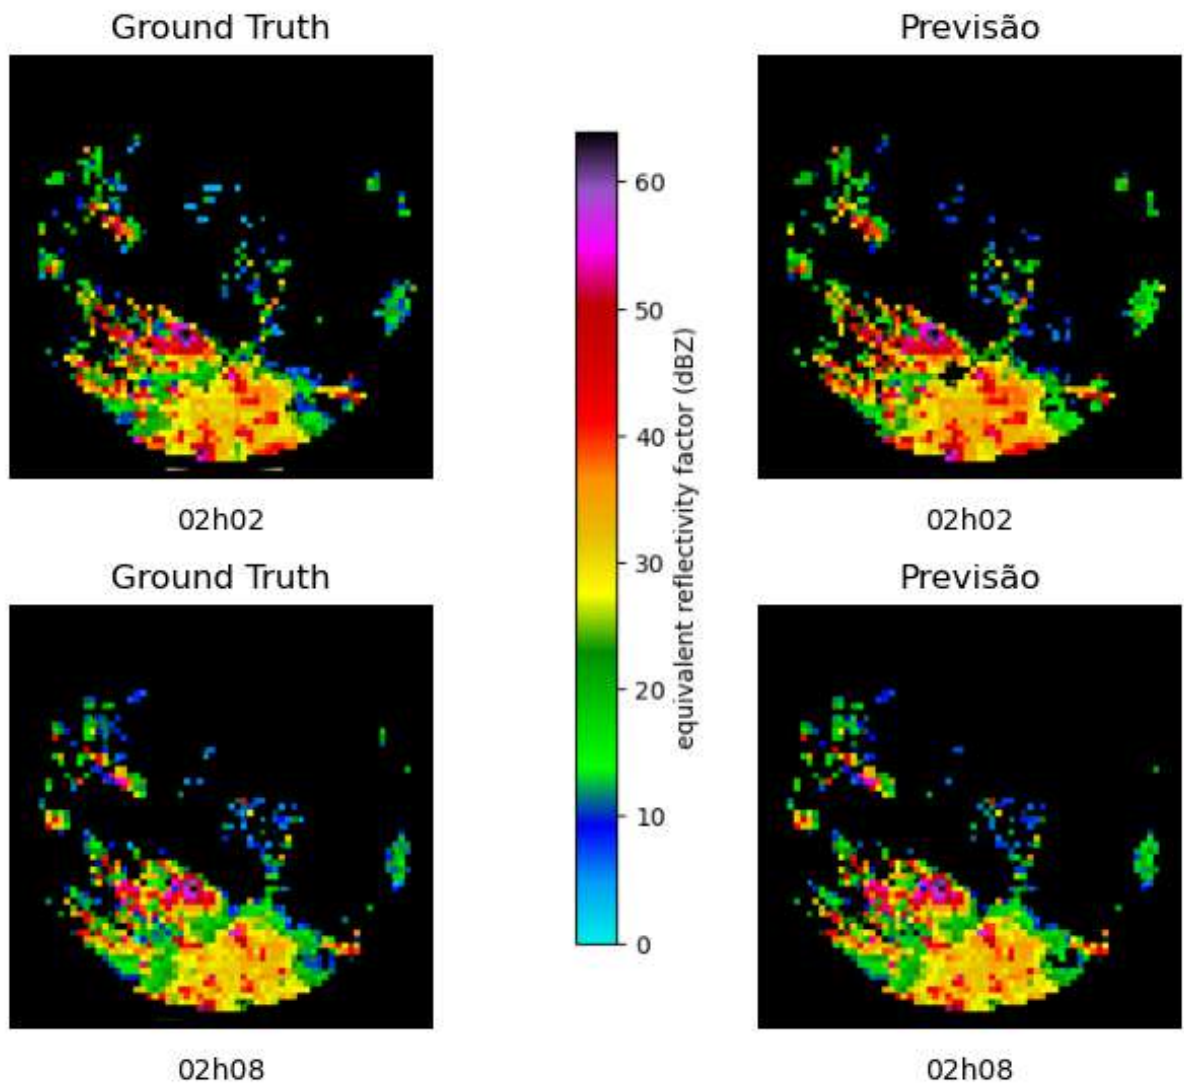


Figura 31 – Previsão para o dia 12/06/2018 às 02h02 e às 02h08.

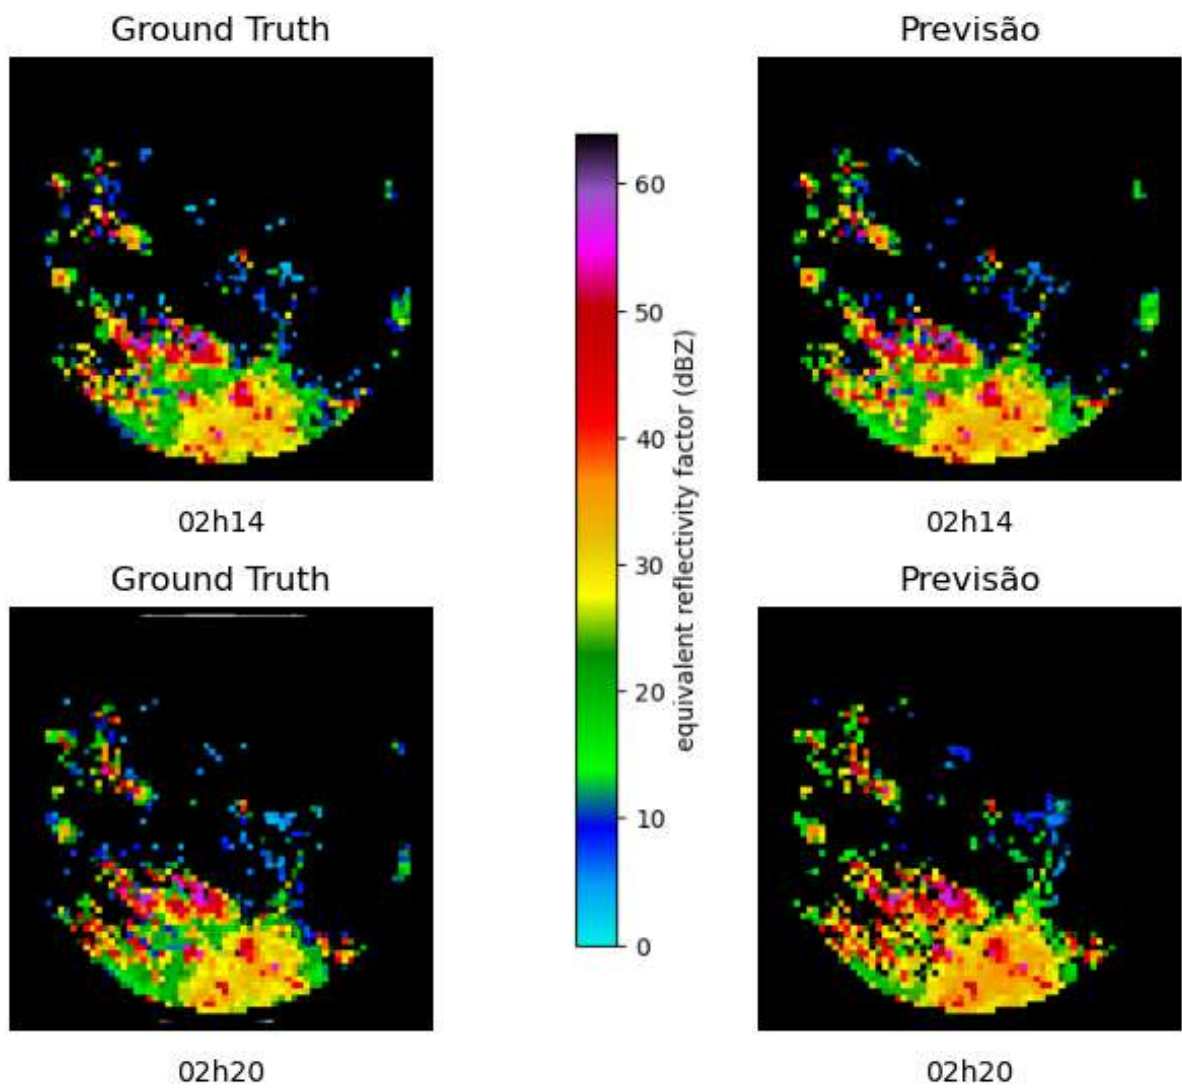


Figura 32 – Previsão para o dia 12/06/2018 às 02h14 e às 02h20.

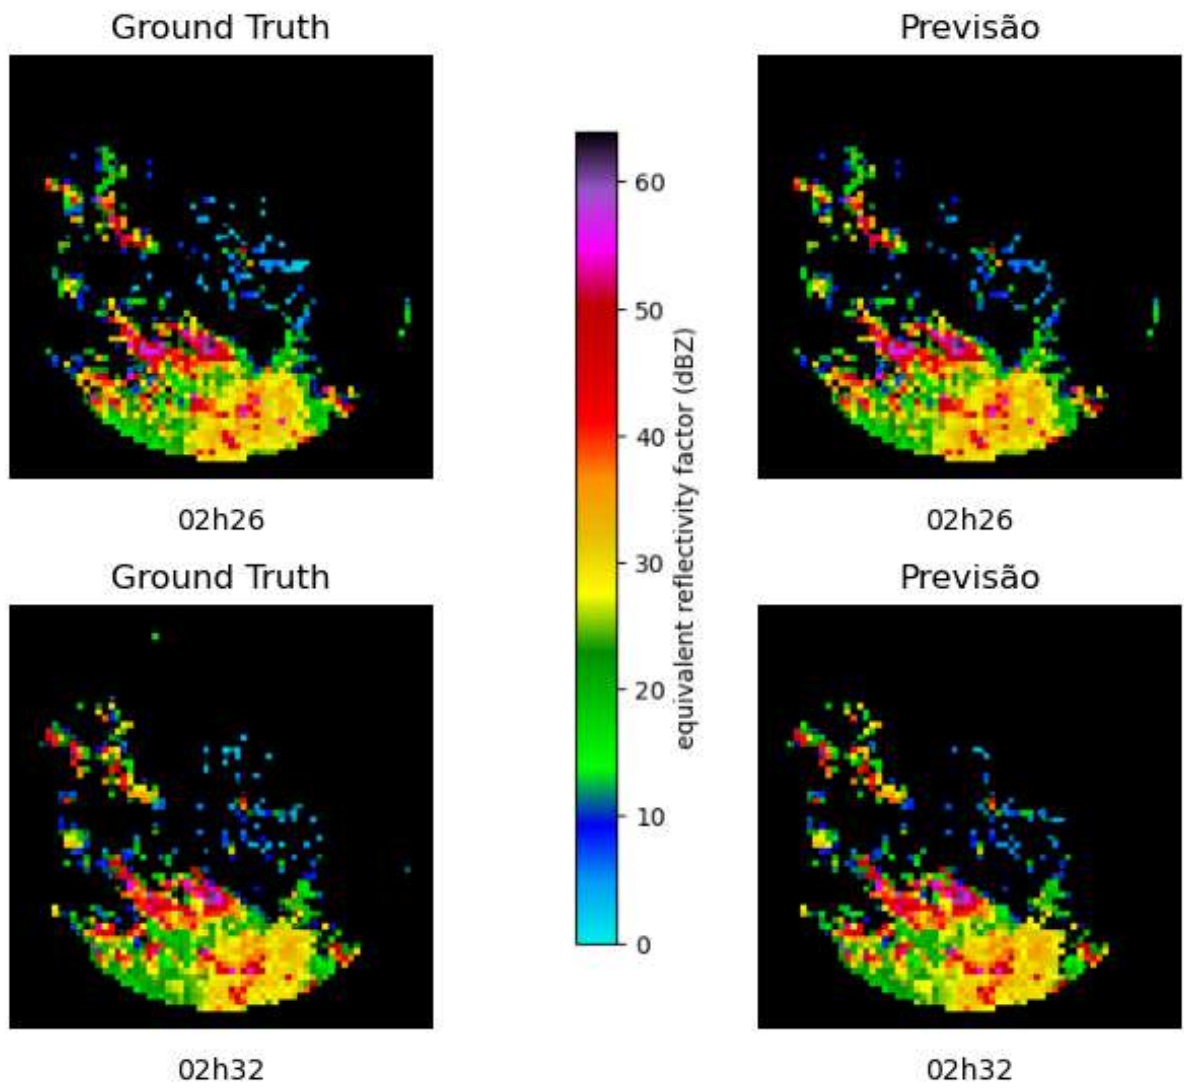


Figura 33 – Previsão para o dia 12/06/2018 às 02h26 e às 02h32.

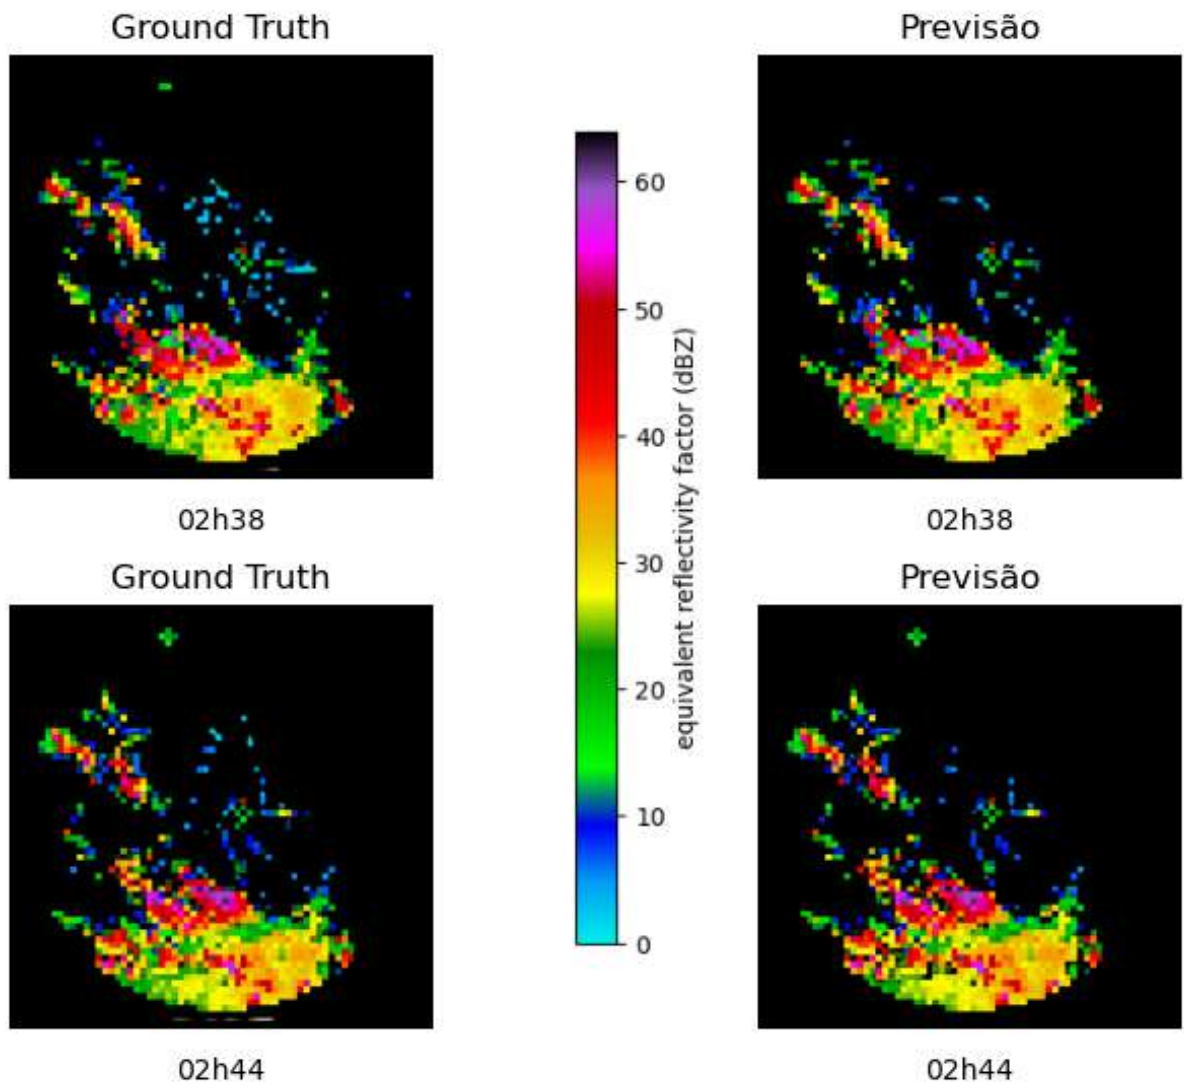


Figura 34 – Previsão para o dia 12/06/2018 às 02h38 e às 02h44.

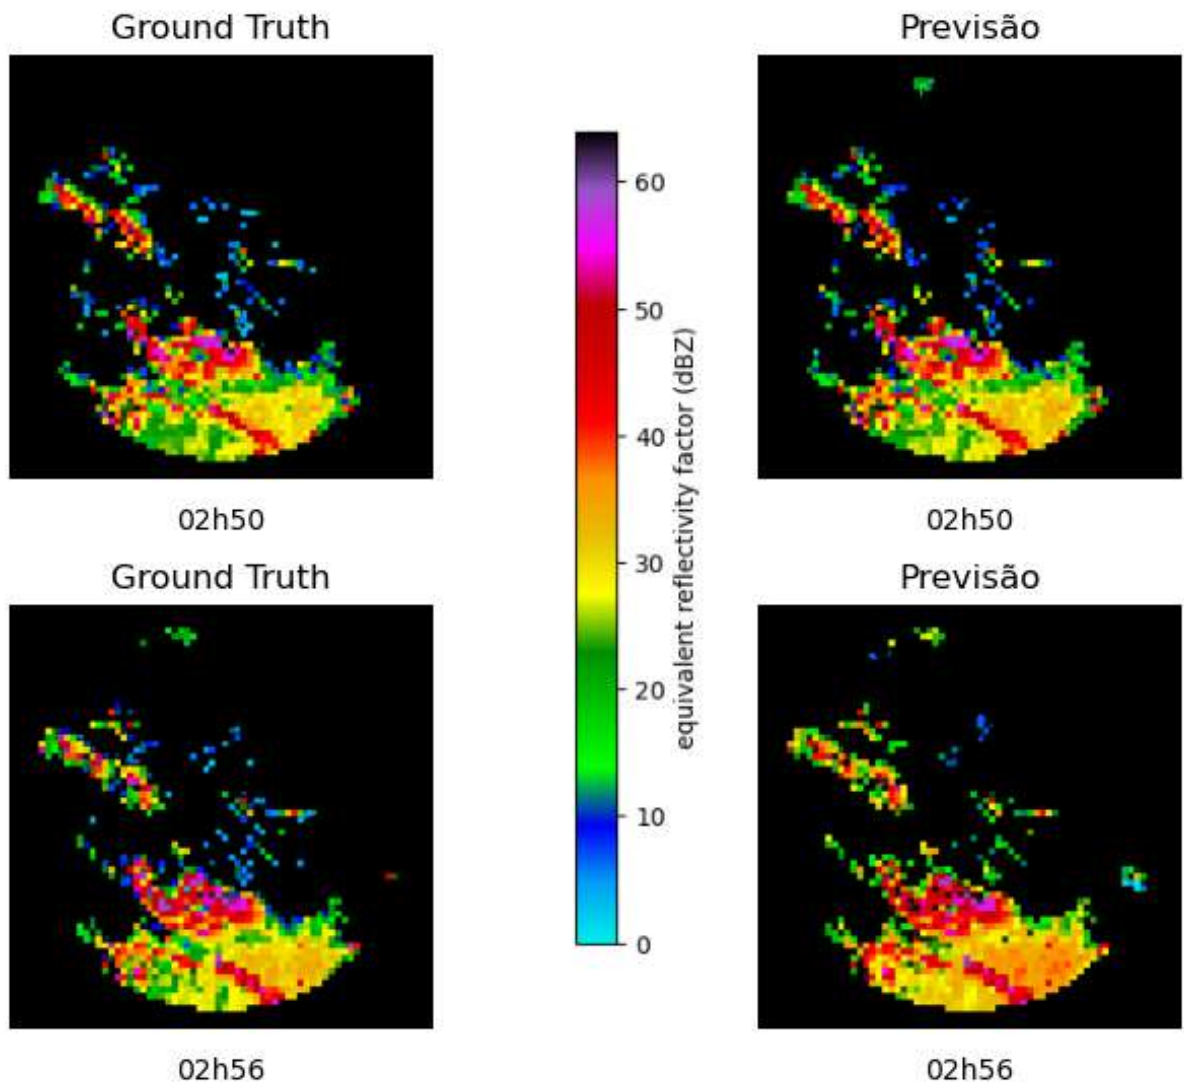


Figura 35 – Previsão para o dia 12/06/2018 às 02h50 e 02h56.

Tabela 4 – Métricas entre 02h02 e 02h56.

Horário	RMSE	SSIM	MAE
02h02	14,39014	0,87526	20,64813
02h08	12,43389	0,89125	18,00123
02h14	13,79503	0,88110	20,2910
02h20	16,53102	0,85365	22,2797
02h26	12,37876	0,89158	18,56445
02h32	12,63045	0,88983	18,44449
02h38	12,90621	0,88707	19,65196
02h44	12,18933	0,89234	18,96536
02h50	12,76207	0,88934	19,05172
02h56	15,96798	0,86363	21,43082

A Tabela 4 demonstra que os erros permanecem na mesma ordem de magnitude em comparação com os valores observados nas duas horas anteriores, entretanto oscilam bastante, sendo que o *MAE* parece ser tão sensível ao *outliers*⁵ quanto o *RMSE*.

Apesar disso, os valores do *SSIM* continuam evidenciando a alta congruência entre as previsões do modelo e a verdade terrestre. Essa persistente similaridade é um indicativo robusto de que o Modelo Neural está capturando aspectos cruciais do sistema meteorológico, mesmo em face de flutuações nos outros indicadores de erro.

⁵*Outliers* são valores atípicos ou discrepantes em relação aos demais dados de uma determinada variável meteorológica em uma região e período de tempo.

4.2.2.4 Previsão para o domínio da região de Chapecó-SC entre 03h02 e 03h56 do dia 12/06/2018

Na Figura 36, imagens do radar de Chapecó-SC entre 02h02 e às 02h56 do dia 12/06/2018, observa-se que a linha de instabilidade não está bem configurada, mas permanecem os pixels com refletividade superior a 40 dBZ, sugerindo a existência de núcleos significativos de células convectivas.

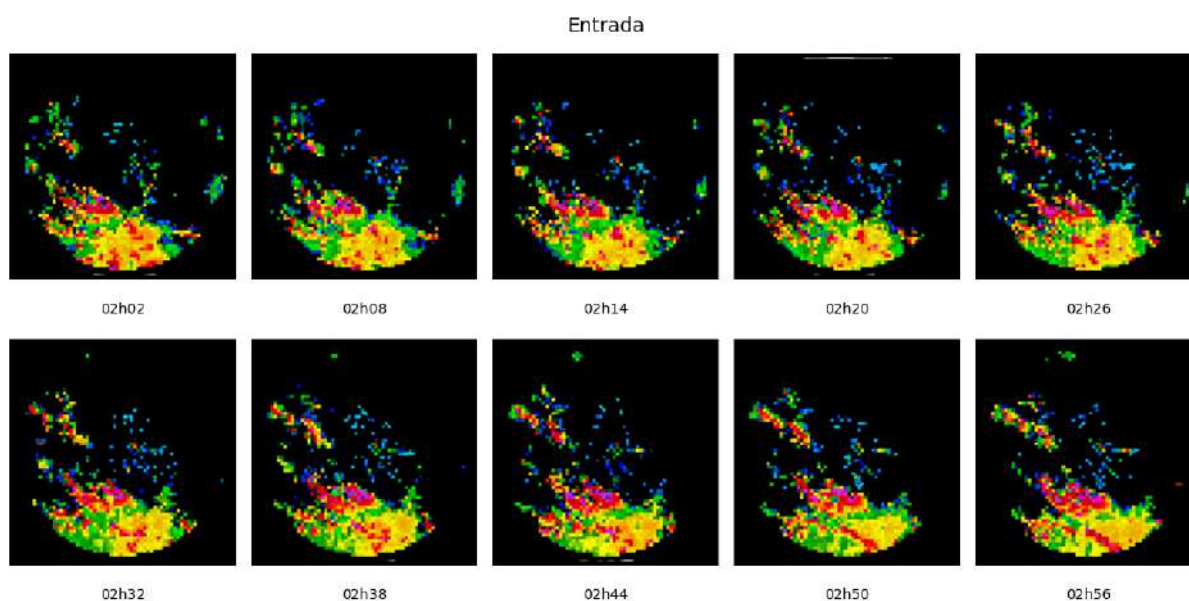


Figura 36 – Imagens do radar de Chapecó-SC entre às 02h02 e às 02h56.

Entre as Figuras 37 e 41 surge um núcleo de maior refletividade no sistema, que se manifesta com uma intensidade considerável de precipitação, variando de moderada a forte, principalmente na região sul e nas proximidades da antena do radar. A notável correspondência entre as observações visuais e os resultados do modelo neural reforça a precisão consistente das previsões geradas. Especificamente, o modelo confirma de maneira convincente sua habilidade de realizar previsões com acurácia notável para um horizonte de 1 hora, a partir do momento de gênese do sistema.

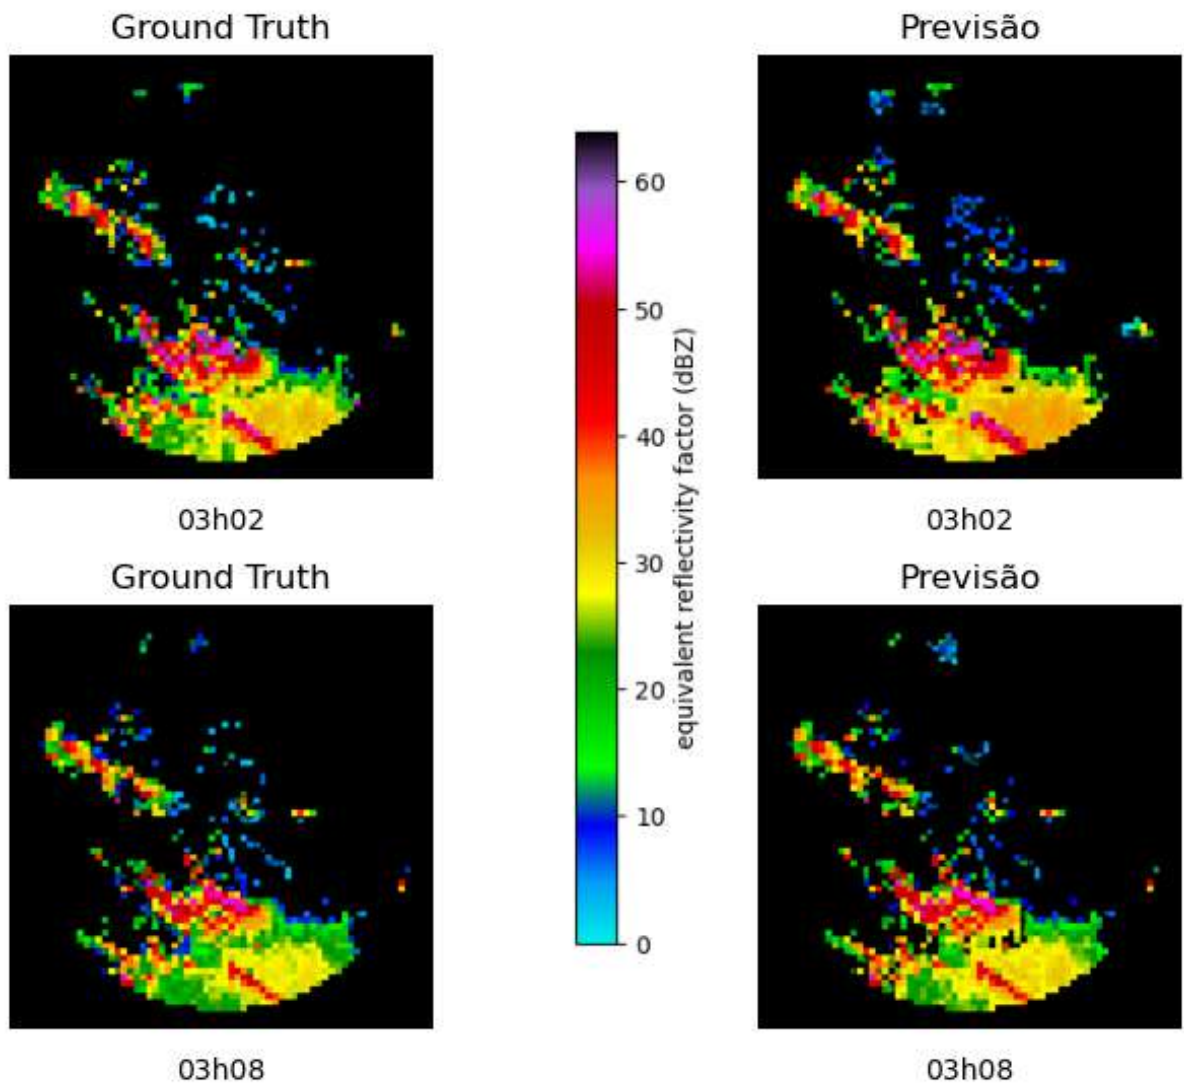


Figura 37 – Previsão para o dia 12/06/2018 às 03h02 e às 03h08.




Figura 38 – Previsão para o dia 12/06/2018 às 03h14 e às 03h20.

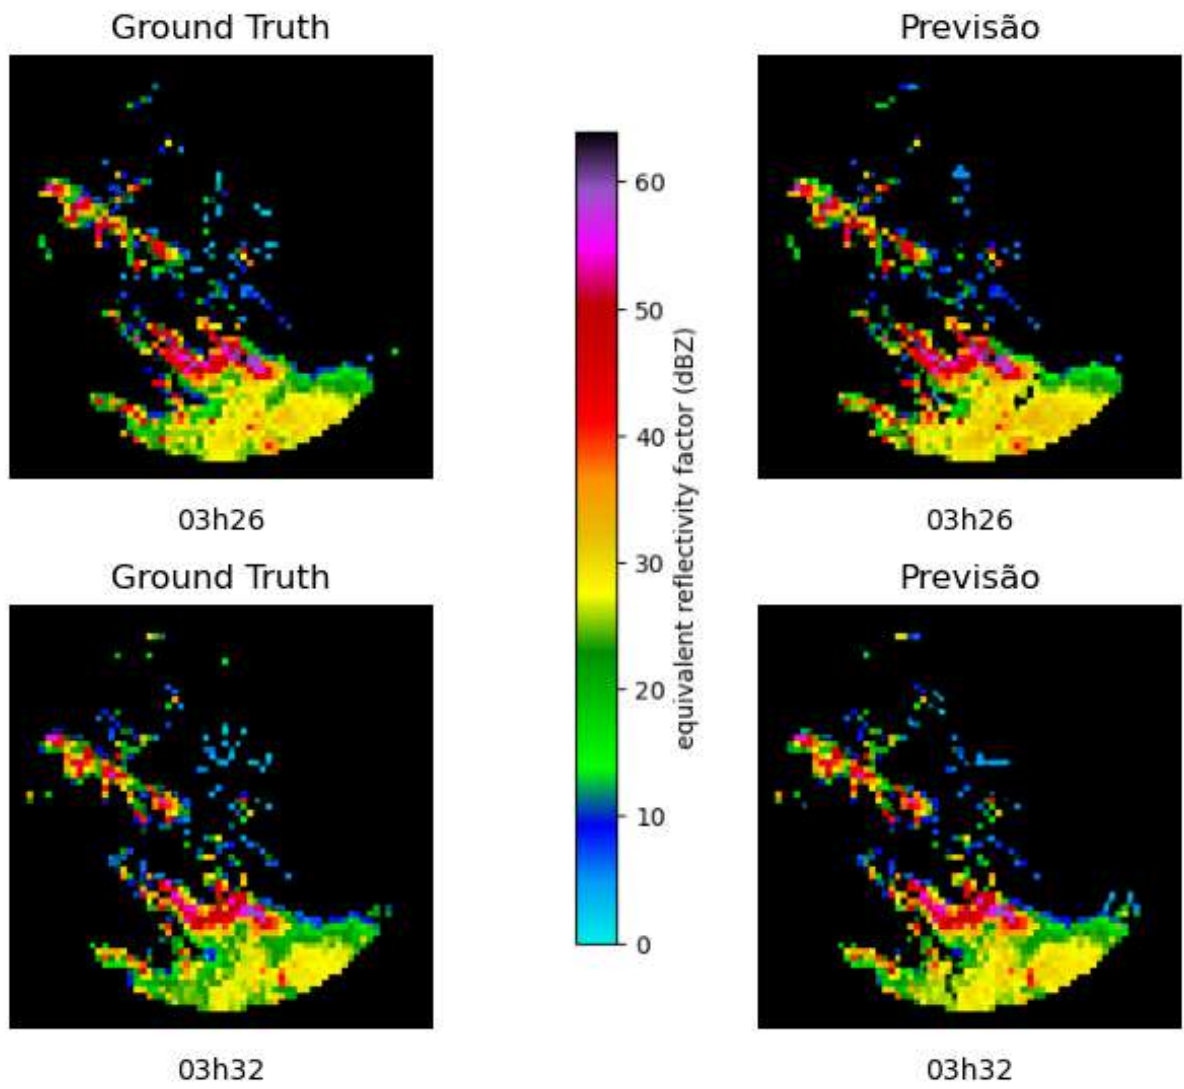


Figura 39 – Previsão para o dia 12/06/2018 às 03h26 e às 03h32.

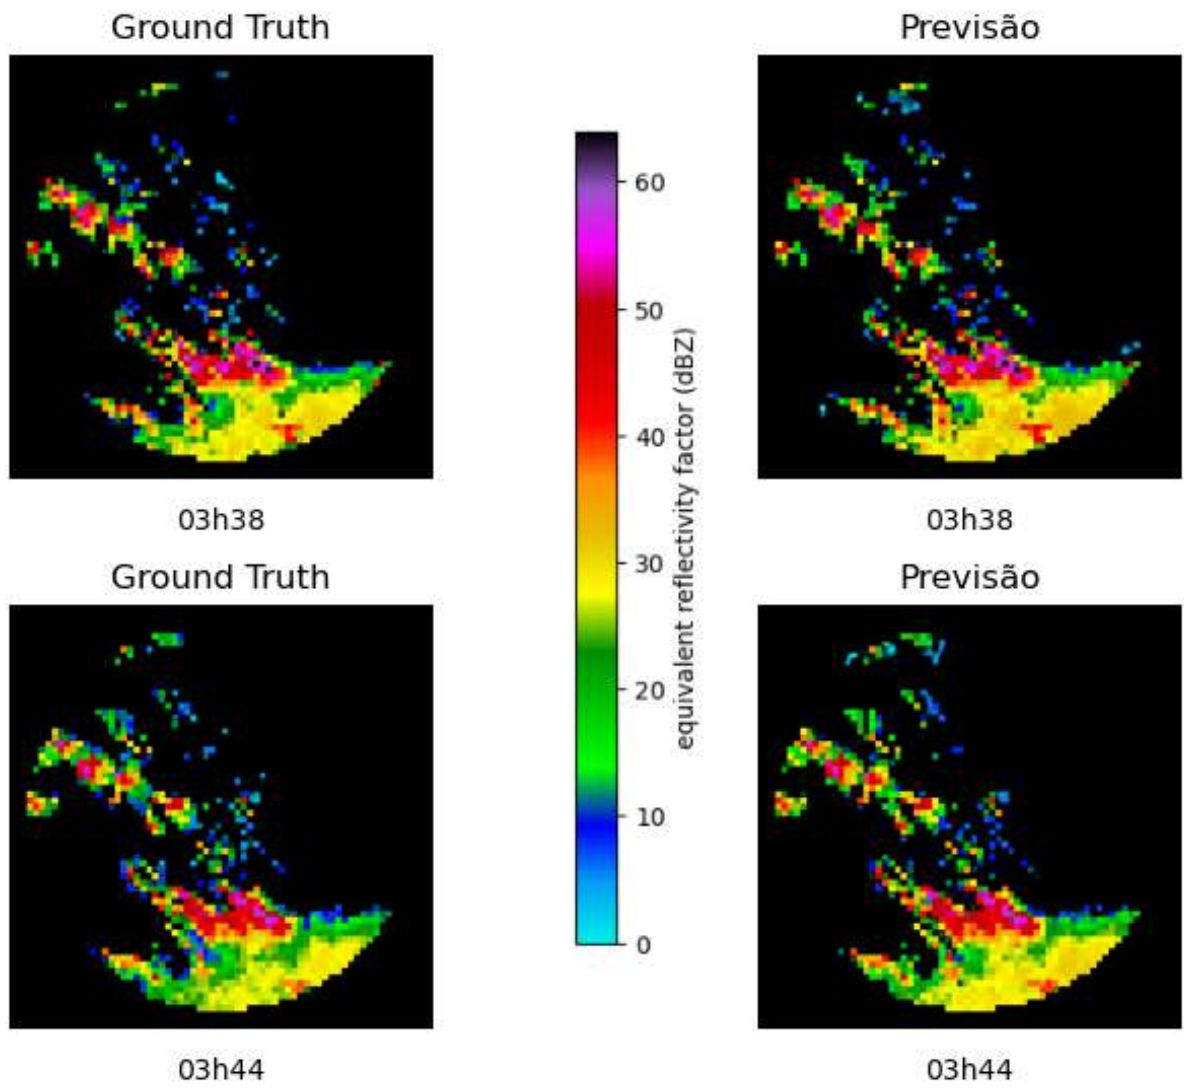


Figura 40 – Previsão para o dia 12/06/2018 às 03h38 e às 03h44.

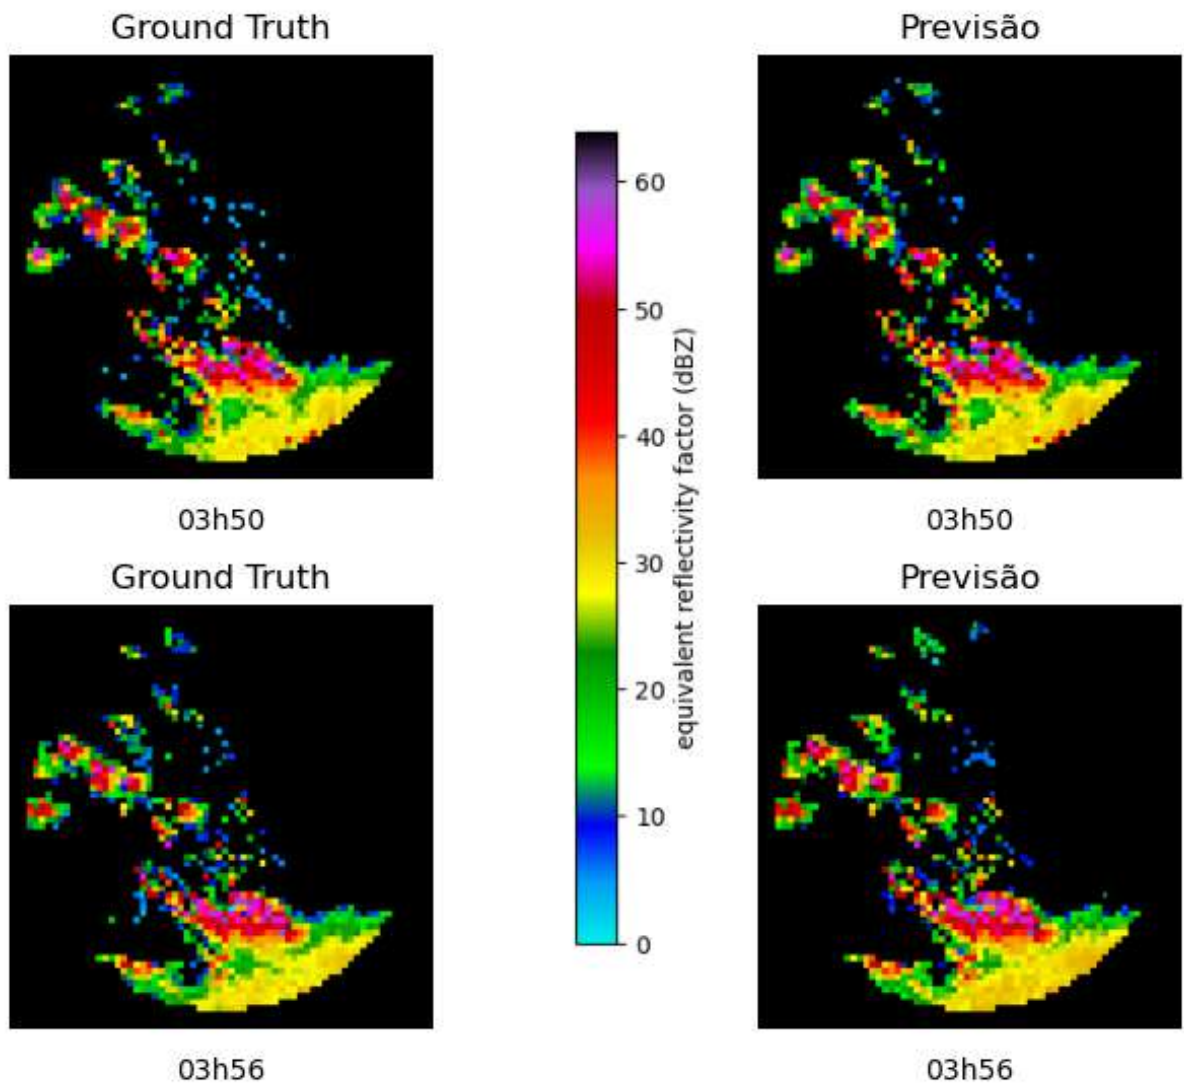


Figura 41 – Previsão para o dia 12/06/2018 às 03h50 e às 03h56.

Tabela 5 – Métricas entre 03h02 e 03h56.

Horário	RMSE	SSIM	MAE
03h02	15,38004	0,86830	20,2442
03h08	13,63203	0,88250	19,78822
03h14	14,65815	0,87501	21,0617
03h20	13,81097	0,88143	19,55957
03h26	13,32601	0,88579	20,98579
03h32	13,29928	0,88535	19,82172
03h38	13,60506	0,88224	18,71355
03h44	14,02310	0,87950	20,9835
03h50	12,96742	0,88728	19,43241
03h56	14,02159	0,87896	20,4681

Na análise dos erros, demonstrada na Tabela 5, destaca-se novamente o baixo *RMSE*, que é uma indicação sólida da capacidade do modelo em manter baixos os erros globais nas previsões. No entanto, torna-se evidente mais uma vez que o *RMSE* e o *MAE* são sensíveis aos *outliers*. A sensibilidade e as variações atípicas dessas duas métricas reforçam a importância de uma análise mais empírica das previsões para obter uma compreensão completa do desempenho do modelo.

Vale a pena notar que os valores do *SSIM* continuam a fornecer uma avaliação positiva do desempenho do modelo. Com uma similaridade superior a 87% em relação à verdade terrestre, as previsões geradas pelo modelo neural mantêm uma qualidade visual e estrutural que se alinha de forma notável com as observações reais.

4.3 Horizonte de previsão aumentado para 120 minutos

Para além da previsão convencional, que implica na entrada de uma sequência de 10 imagens à rede neural visando a previsão das subsequentes 10 imagens, como, da forma que foi apresentada na seção 4.2, também se conduziram experimentos para um horizonte preditivo mais amplo, abrangendo um período total de 120 minutos no futuro.

Nesse contexto, foi adotada a metodologia prévia, em que x imagens foram apresentadas para a rede neural e foram previstas as próximas x imagens da sequência. Levando em consideração o intervalo de 6 minutos nas leituras do radar, um horizonte de previsão de 120 minutos é representado por 20 imagens de radares.

Para viabilizar essa extensão, houve necessidade de modificar a estrutura do conjunto de dados apresentado na seção 3.3, em que o formato original do vetor [20, 1000, 64, 64] foi modificado para [40, 500, 64, 64], representando 500 conjuntos sequenciais, cada qual composto por 40 imagens. Dessas, 20 imagens correspondem à entrada da rede, enquanto as 20 imagens subsequentes constituem a referência verdadeira. Nota-se que tal ampliação do tamanho das sequências (de 20 para 40) resultou na correspondente redução no número global de sequências (de 1000 para 500). O processo de divisão entre as fases de treinamento e validação se estabeleceu como 400/100, ou seja, 400 sequências foram alocadas para treinamento e 100 sequências para validação.

Na realização desse experimento, o treinamento da rede seguiu o mesmo padrão apresentado em 4.1, com exceção da alteração no formato do *dataset* citado no parágrafo anterior. O tempo de treinamento também não se alterou, mantendo uma média de aproximadamente 270 horas para 10 mil épocas de treinamento.

Por fim, para verificar a capacidade preditiva da rede em 120 minutos no futuro, foram realizados testes com o caso apresentado em 4.2.1. Os resultados serão apresentados a seguir, primeiramente com a entrada da rede (20 imagens do passado) seguidas da verdade terrestre e as respectivas previsões (20 imagens do futuro).




Figura 42 – Imagens do radar de Chapecó-SC entre 21h20 e 23h14 do dia 11/06/2018.

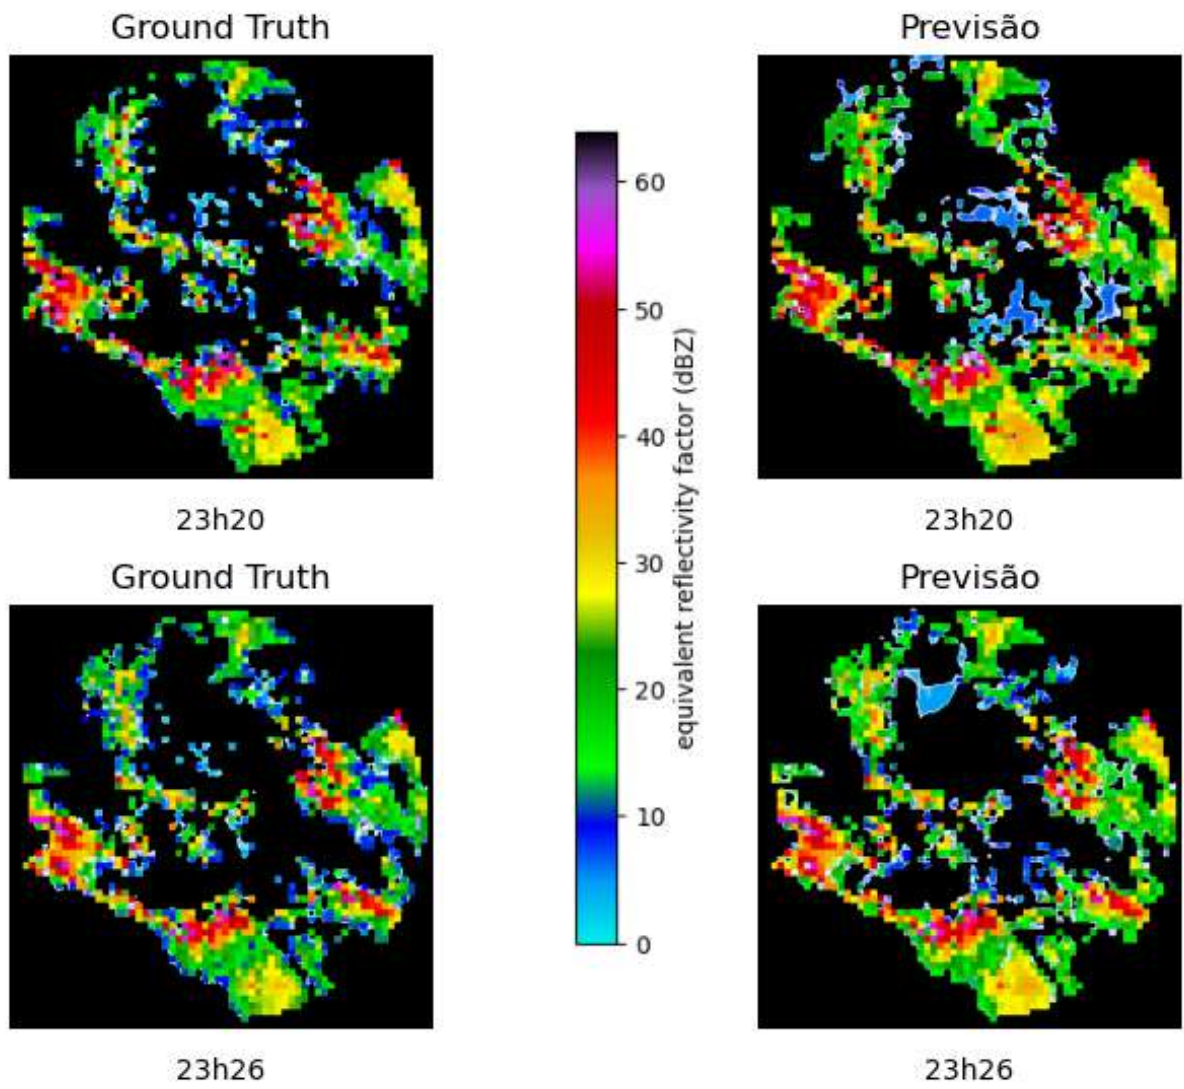


Figura 43 – Previsão para o dia 11/06/2018 às 23h20 e às 23h26.

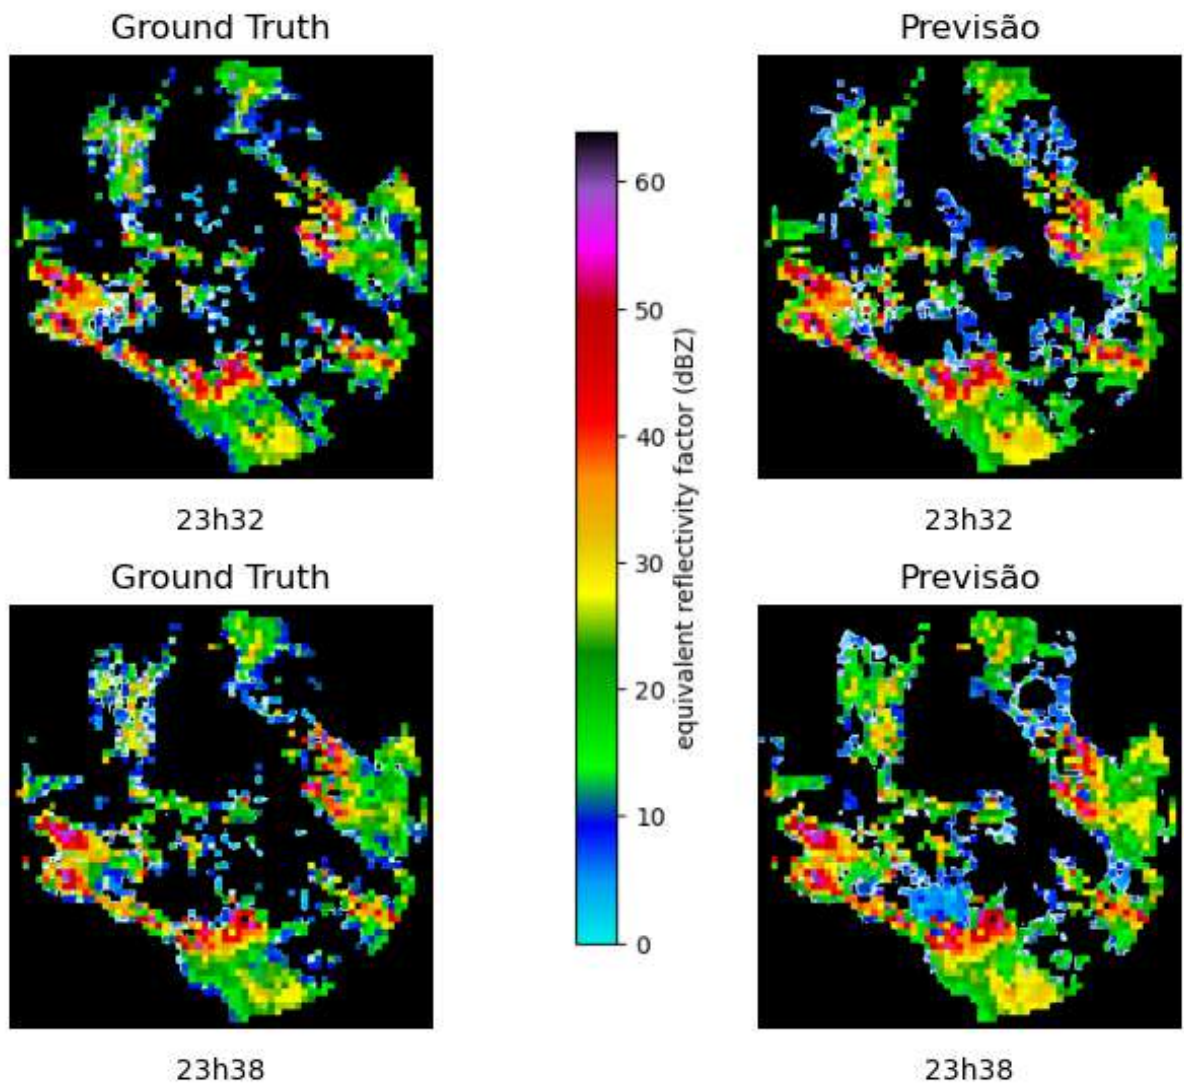


Figura 44 – Previsão para o dia 11/06/2018 às 23h32 e às 23h38.

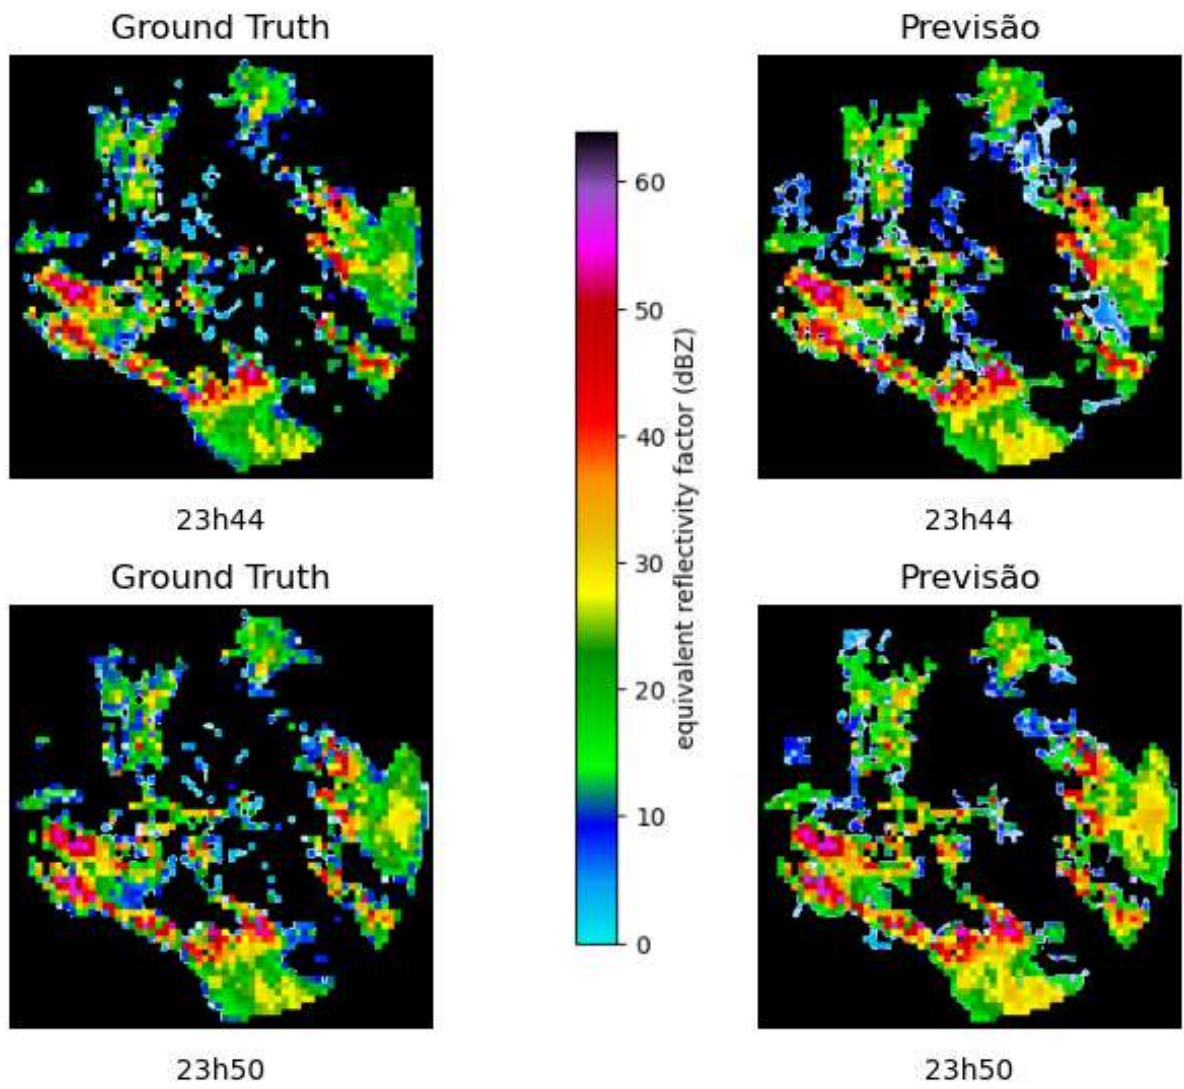


Figura 45 – Previsão para o dia 11/06/2018 às 23h44 e às 23h50.

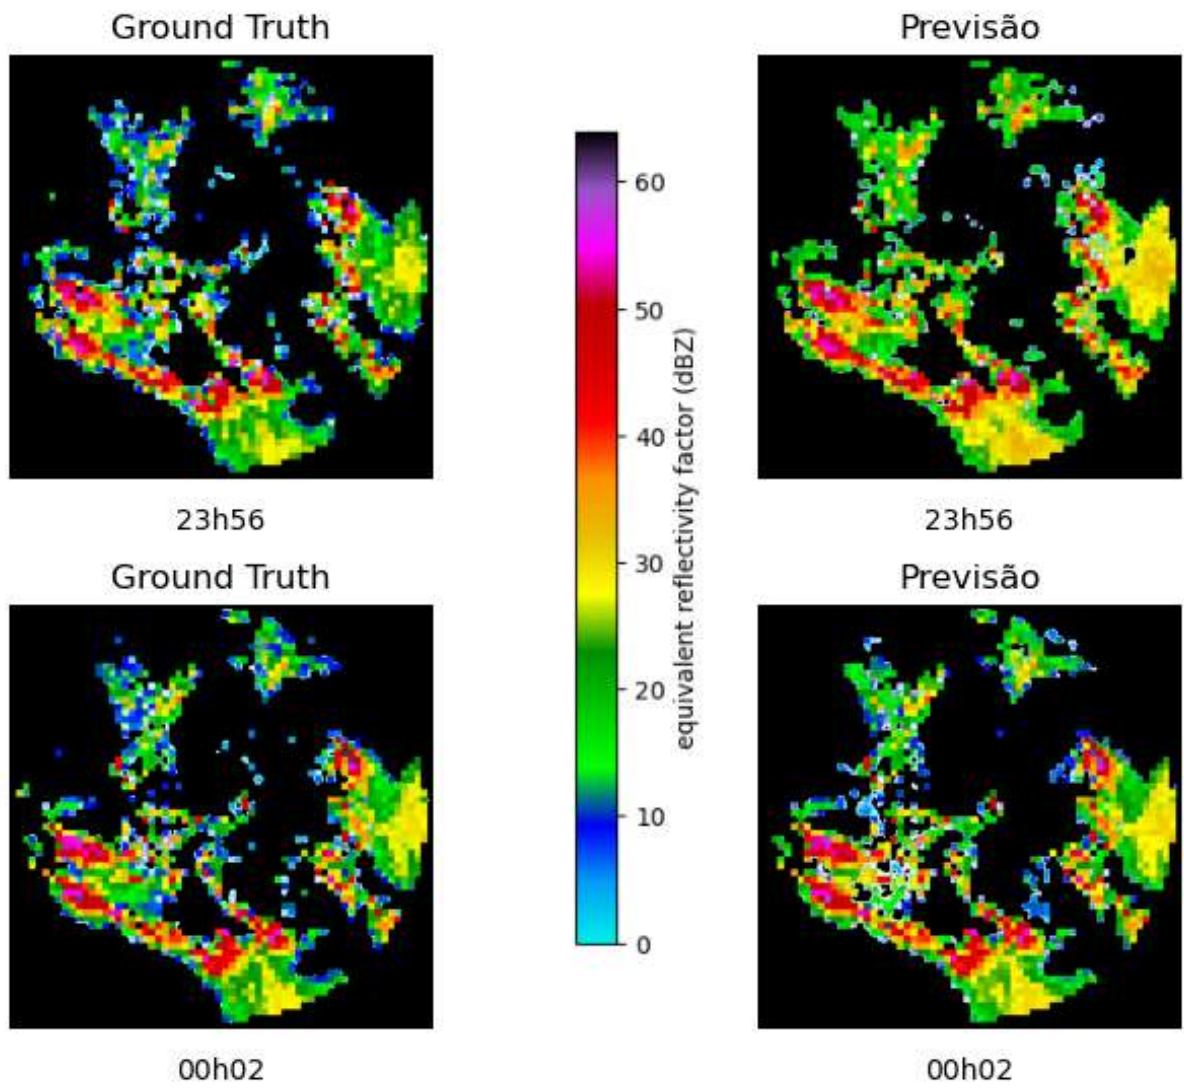


Figura 46 – Previsão para o dia 11/06/2018 e dia 12/06/2018 às 23h56 e às 00h02.

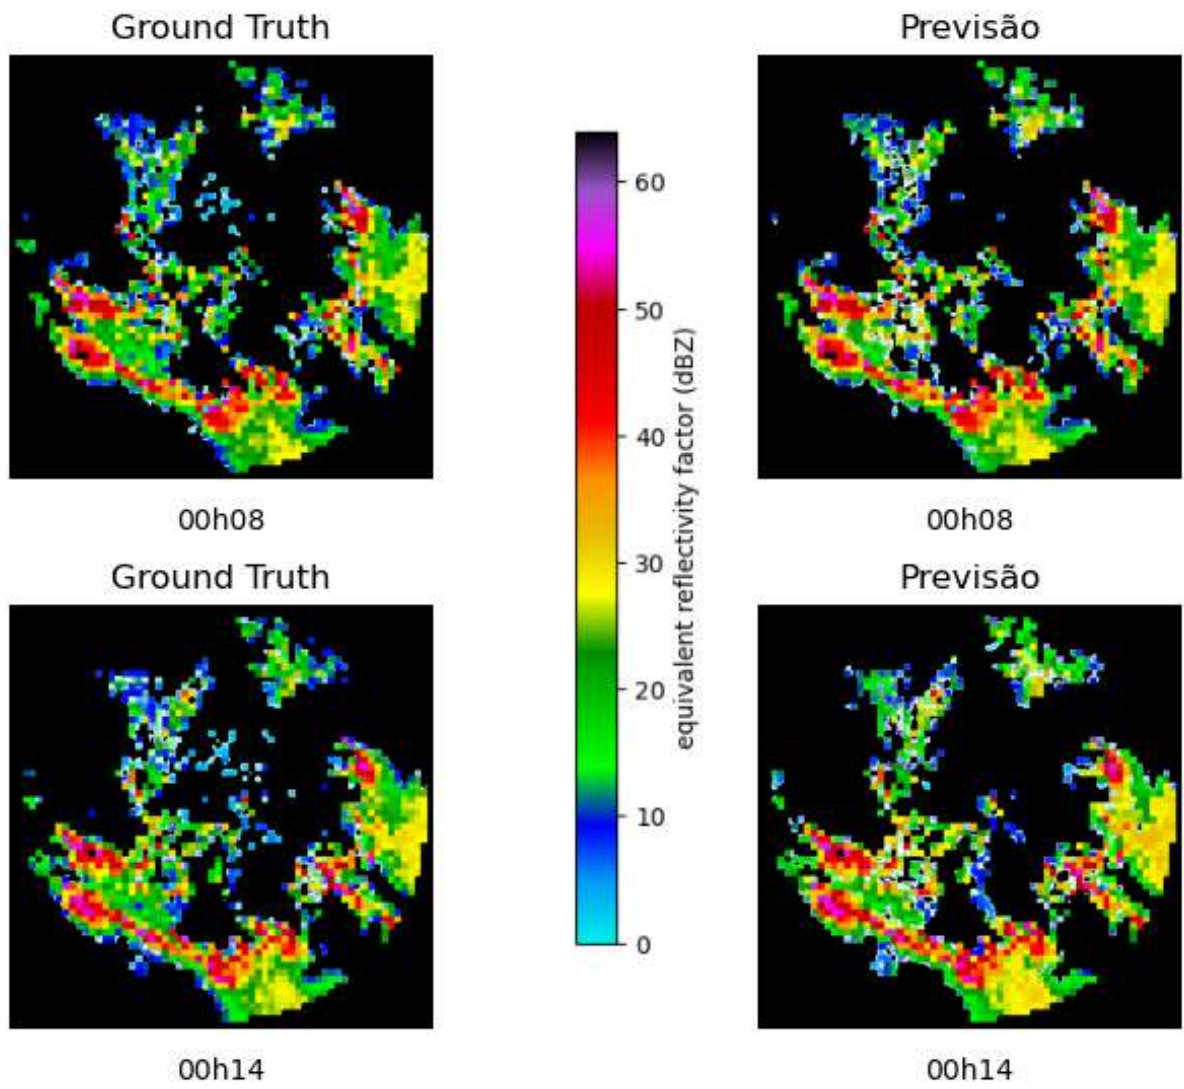


Figura 47 – Previsão para o dia 12/06/2018 às 00h08 e às 00h14.

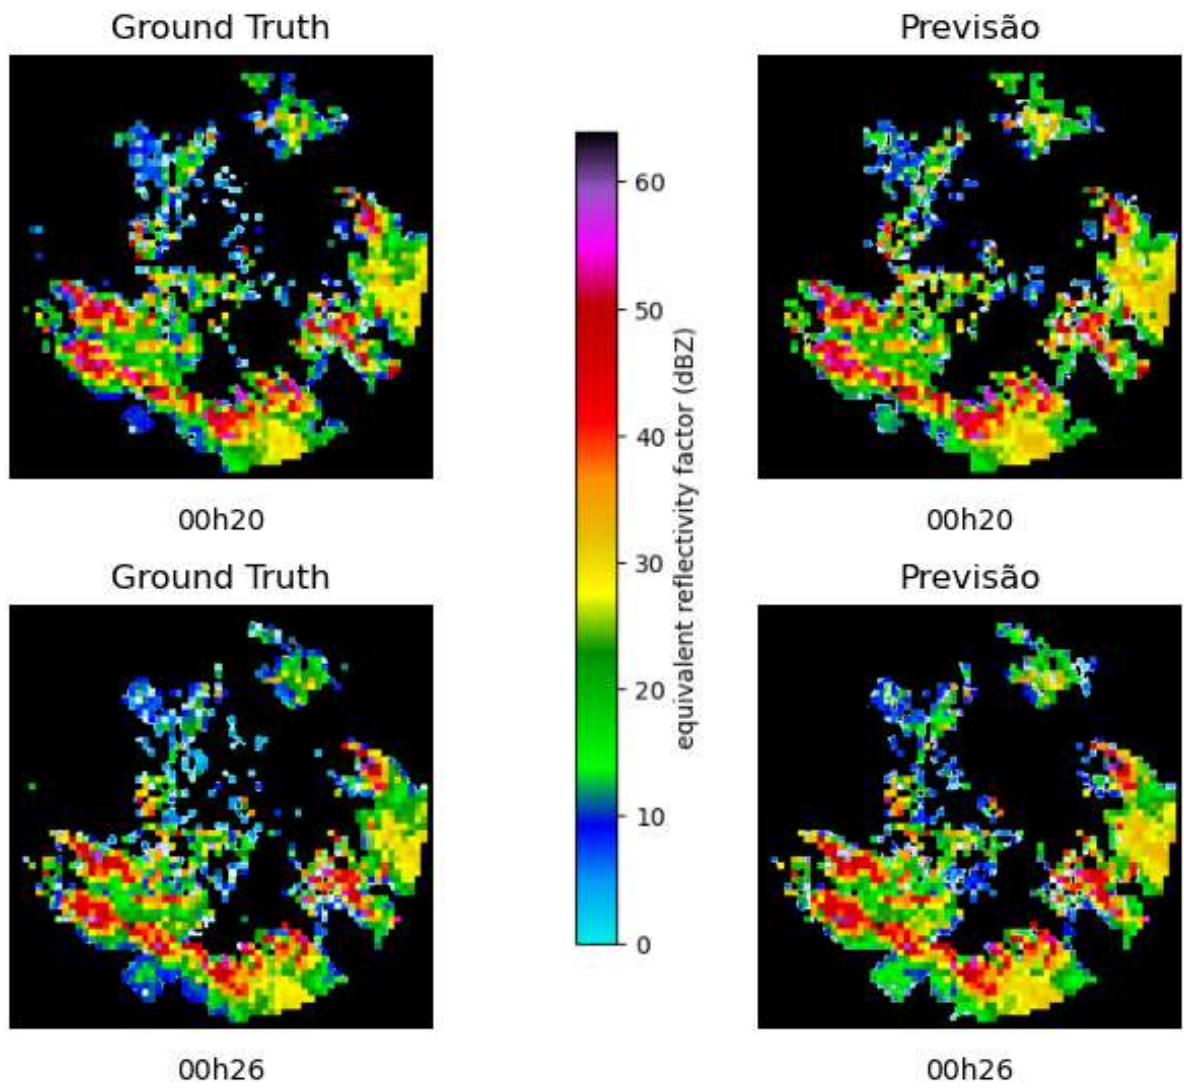


Figura 48 – Previsão para o dia 12/06/2018 às 00h20 e às 00h26.

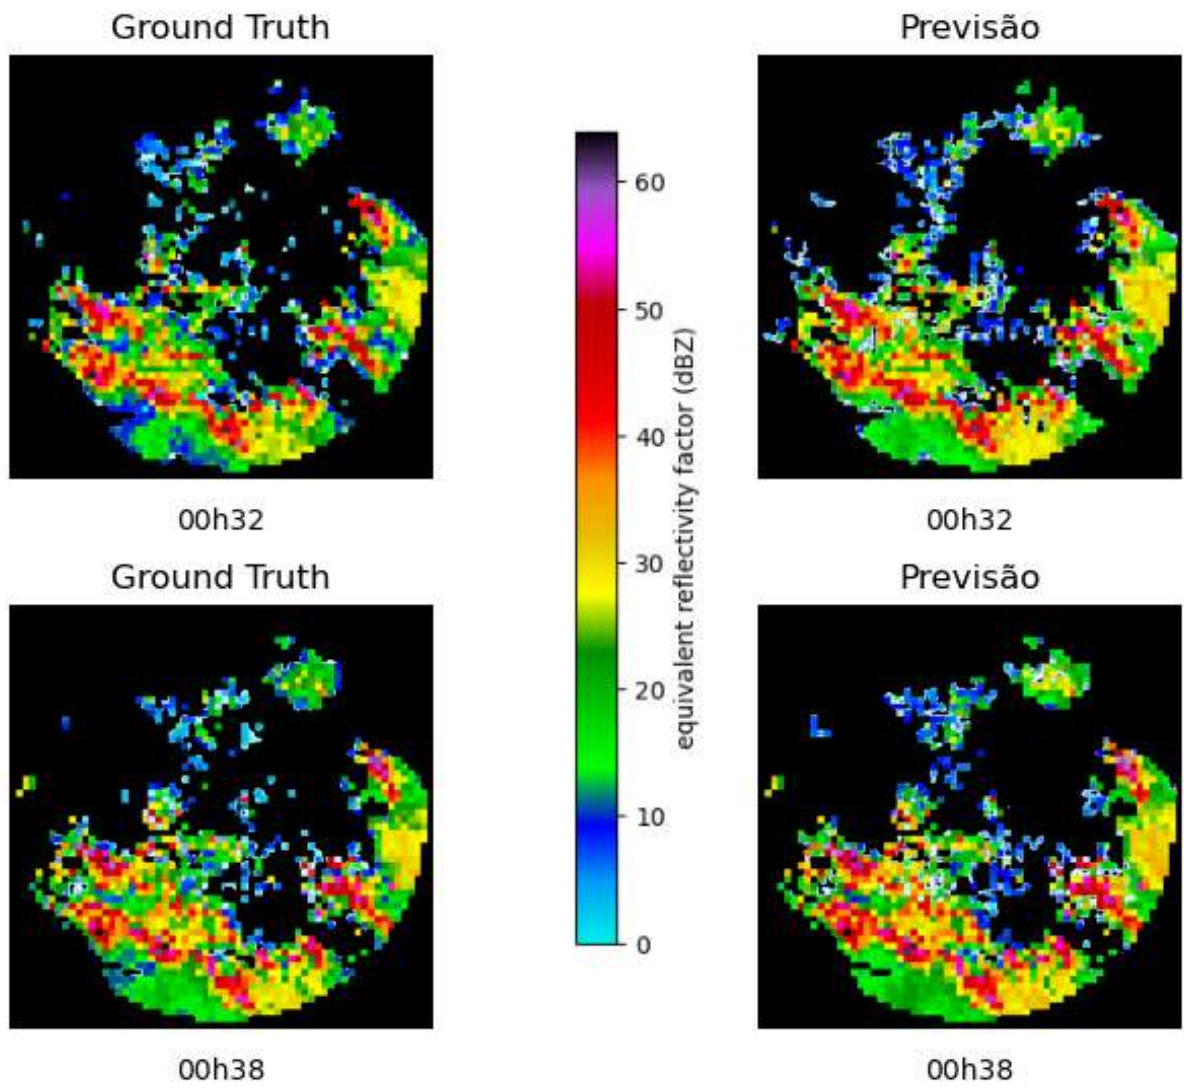


Figura 49 – Previsão para o dia 12/06/2018 às 00h32 e às 00h38.

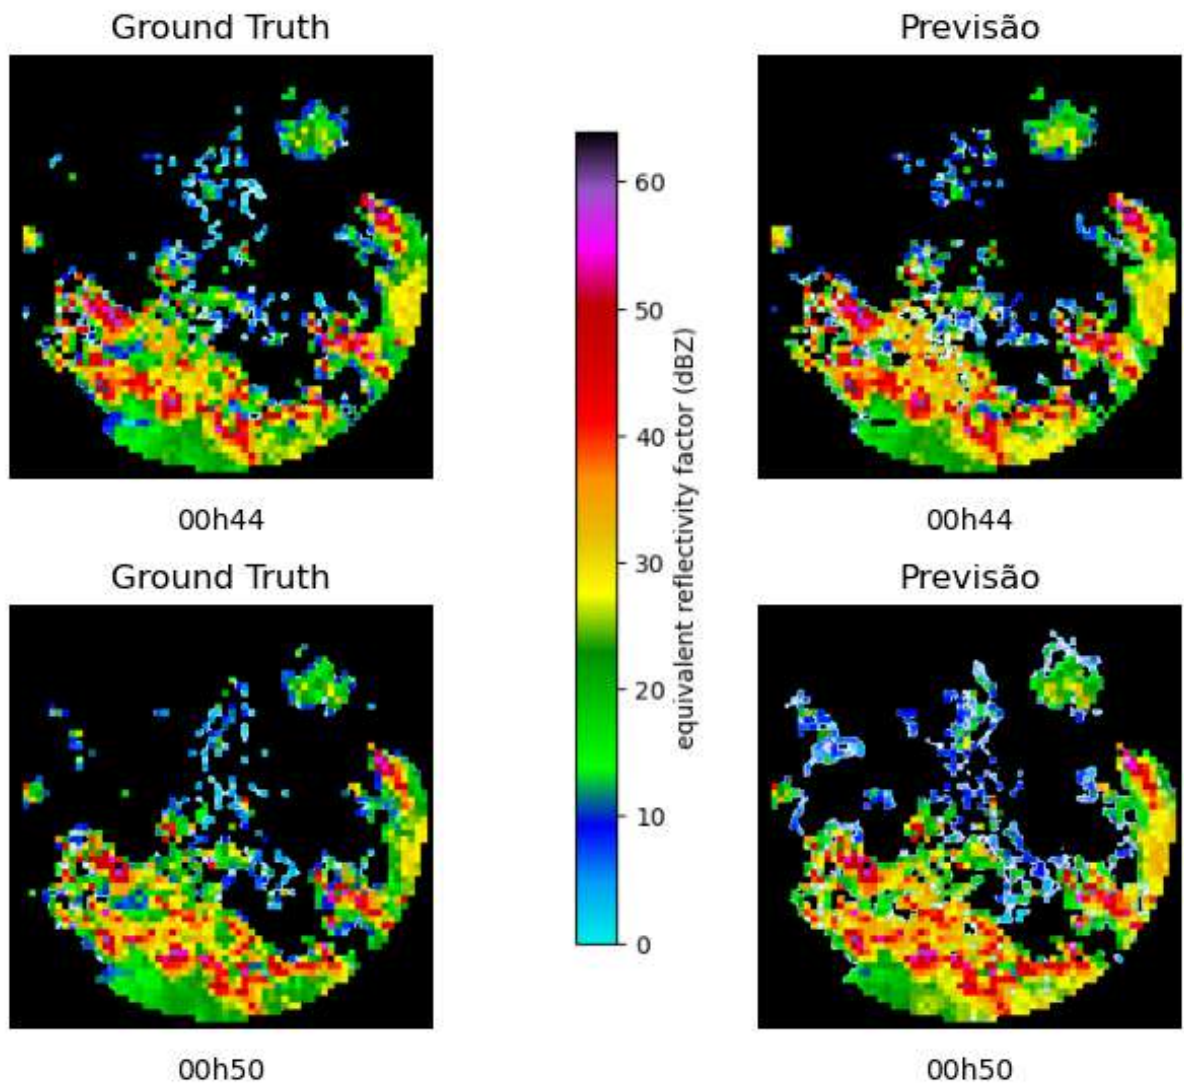


Figura 50 – Previsão para o dia 12/06/2018 às 00h44 e às 00h50.

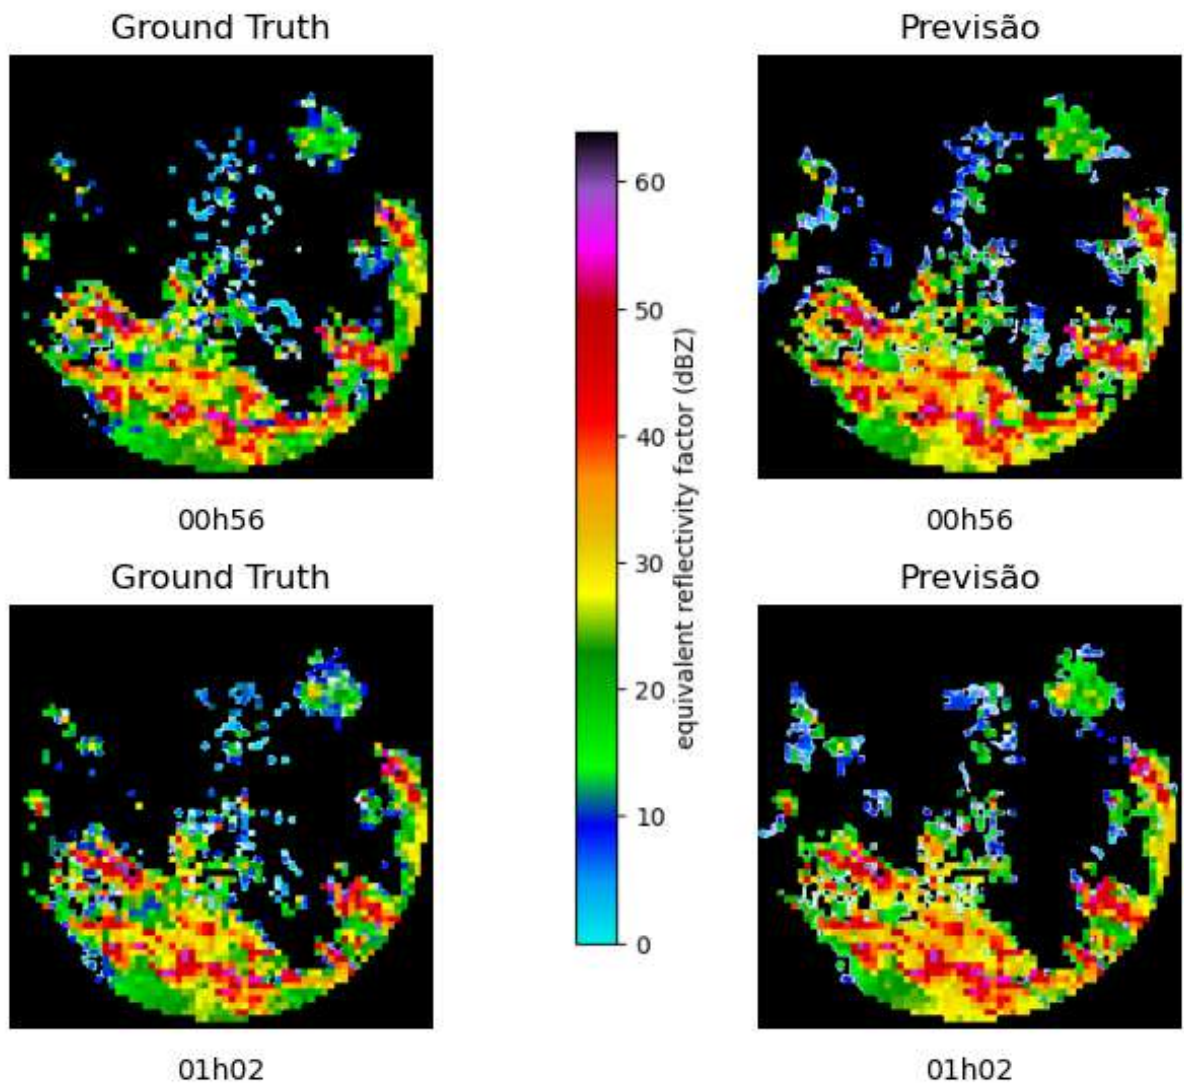


Figura 51 – Previsão para o dia 12/06/2018 às 00h56 e às 01h02.

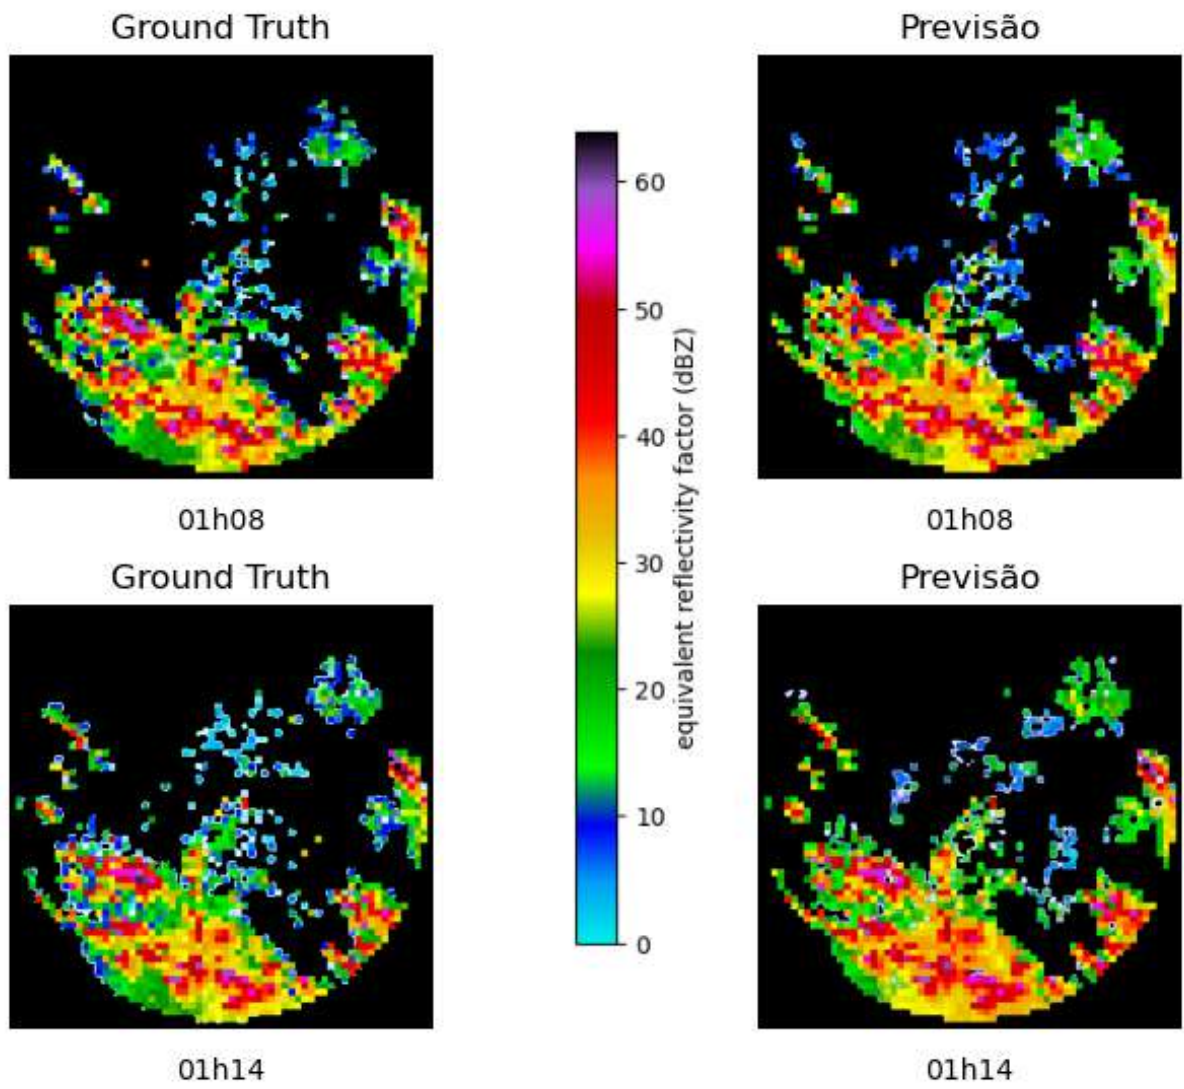


Figura 52 – Previsão para o dia 12/06/2018 às 01h08 e às 01h14.

Tabela 6 – Métricas entre 23h20 e 01h14 para a previsão de 20 imagens.

Horário	RMSE	SSIM	MAE
23h20	23,04037	0,78090	32,7166
23h26	21,54820	0,79893	31,7250
23h32	22,06109	0,79059	32,8051
23h38	22,77504	0,78711	32,0356
23h44	22,71255	0,78424	32,8949
23h50	22,24708	0,79331	32,5961
23h56	22,21013	0,79842	31,6551
00h02	22,31956	0,84370	28,8577
00h08	17,56402	0,85352	27,3456
00h14	19,61621	0,82958	29,1907
00h20	18,94002	0,83683	28,3729
00h26	18,93475	0,83863	28,5496
00h32	20,62198	0,81643	30,1383
00h38	18,77807	0,84155	28,0327
00h44	18,71613	0,84295	27,4730
00h50	21,25042	0,79294	22,4622
00h56	21,63365	0,80698	21,1271
01h02	21,31901	0,81069	20,9189
01h08	18,87124	0,83771	27,8185
01h14	22,29899	0,79568	31,9000

Analisando os resultados das métricas descritos na Tabela 6, chega-se a conclusão que, embora a previsão para 120 minutos tenha apresentado uma precisão interessante, com um *SSIM* global de aproximadamente 81% de semelhança com a verdade terrestre, tanto o *RMSE* quanto o *MAE* demonstram estar mais sensíveis (comparando com a previsão de 60 minutos) aos *outliers* dos sistemas meteorológicos apresentados.

Outro ponto interessante a ser considerado é que mesmo com as métricas tendo apresentado valores relativamente piores em comparação a previsão de 60 minutos, é possível verificar entre as Figuras 43 e 52 que a rede neural conseguiu estimar o formato do sistema meteorológico com grande maestria, pecando apenas nos níveis de intensidade, que podem ser notados através de algumas diferenças de cores entre a imagem prevista e a verdade terrestre.

Por fim, acredita-se que os resultados inferiores obtidos para a previsão de 120 minutos se deram por causa da pequena quantidade de dados dos radares utilizados no treinamento. Mesmo que o número de imagens não tenha se alterado, o número de sequências utilizadas para treinar a rede diminuiu pela metade (de 1000 para 500). Com menos sequências, considera-se que acabou diminuindo a capacidade de generalização e conseqüentemente de previsão da rede neural.

5 CONCLUSÃO

A previsão meteorológica é de extrema importância para todos os segmentos da sociedade, do transporte marítimo/aéreo até a agricultura, passando pelo setor energético. Portanto, a melhoria contínua na capacidade de prever fenômenos meteorológicos extremos, como tempestades, inundações e ventos fortes, desempenha um papel crucial na prevenção de perdas materiais e, mais importante ainda, na proteção de vidas humanas contra os impactos desses eventos.

Em vista disso, nesta dissertação foram verificadas as possibilidades da utilização de um modelo de *Deep Learning*, mais especificamente uma Rede Neural Convolutiva Recorrente, para a previsão meteorológica de curto prazo (*nowcasting*) utilizando imagens de radares meteorológicos como dados de entrada.

Para tal, foi treinada e ativada uma rede neural chamada *PredRNN++*, com dados de quatro radares dispostos no sul do Brasil. Após o treinamento e ativação, foram realizados testes em um horizonte de previsão de 60 e 120 minutos. A avaliação da rede se deu através de três métricas (*SSIM*, *MAE* e *RMSE*), que calculam as semelhanças entre as imagens previstas e a verdade terrestre.

Embora se tenha tido algumas dificuldades referente a quantidade de dados disponíveis, acredita-se que os resultados obtidos foram bons, com precisão de aproximadamente 90% para a previsão de 60 minutos e 80% para a previsão de 120 minutos. Analisando empiricamente, a *PredRNN++* foi capaz de prever com exímia acurácia o formato dos sistemas meteorológicos nos dois horizontes de previsão e também apresentou uma grande assertividade na intensidade dos eventos para a previsão de 60 minutos.

Para trabalhos futuros, o foco se voltará para a melhoria das previsões de horizontes mais estendidos, notadamente as de 120 minutos. Expandir o alcance temporal das previsões (*lead time*) para até 3 horas surge como um objetivo-chave. Essa extensão se mostra crucial para a contribuição na mitigação de danos causados por eventos extremos, desempenhando um papel especialmente importante em setores sensíveis como o de energia elétrica. A capacidade de antecipar com maior precisão e antecedência a ocorrência desses eventos permitirá a adoção de medidas preventivas e a

otimização dos recursos disponíveis.

Também se almeja investigar como a *PredRNN++* se comporta utilizando imagens de satélites combinadas com imagens de radares. Essa abordagem visa superar a limitação da falta de dados ao aproveitar a disponibilidade relativamente abundante de imagens de satélites. A integração dessas duas fontes de informações poderia aprimorar significativamente a qualidade das previsões, oferecendo uma visão mais completa e detalhada das condições meteorológicas. Isso se torna especialmente valioso para regiões como o Brasil, onde a obtenção de dados meteorológicos abundantes e precisos, principalmente de radares meteorológicos, se mostrou bem desafiadora.

Por fim, também em uma pesquisa futura, se busca realizar uma investigação mais aprofundada no domínio da previsão de vídeo, um campo em rápida evolução dentro da academia. Essa pesquisa envolverá a comparação da *PredRNN++* com redes neurais mais recentes, visando identificar o modelo mais adequado para a previsão de *nowcasting* no contexto brasileiro. Acredita-se que a integração das mais recentes inovações na área de Redes Neurais com a meteorologia pode levar a avanços significativos na precisão e capacidade preditiva de qualquer forma de evento meteorológico, contribuindo ainda mais para a eficácia da previsão em tempo real.

REFERÊNCIAS

- ABDELOUAHAB, K.; PELCAT, M.; BERRY, F. Why TanH is a Hardware Friendly Activation Function for CNNs. **Proceedings of the 11th International Conference on Distributed Smart Cameras**, New York, NY, USA, p.199–201, 2017.
- ABDUL-KADER, H. Neural networks training based on differential evolution algorithm compared with other architectures for weather forecasting³⁴. **International Journal of Computer Science and Network Security**, v.9, n.3, p.92–99, 2009.
- BEALE, M. H.; HAGAN, M. T.; DEMUTH, H. B. Neural network toolbox 7. **User's Guide, MathWorks**, Natick, MA, USA, v.2, 2010.
- BLUESTEIN, H. B. **Synoptic-dynamic Meteorology in Midlatitudes**: Observations and theory of weather systems. New York, NY, USA: Taylor & Francis, 1992. v.2.
- BONNET, S. M.; EVSUKOFF, A.; MORALES RODRIGUEZ, C. A. Precipitation nowcasting with weather radar images and deep learning in são paulo, brasil. **Atmosphere**, v.11, n.11, p.1157, 2020.
- BROWNING, K.; COLLIER, C. Nowcasting of precipitation systems. **Reviews of Geophysics**, v.27, n.3, p.345–370, 1989.
- CALIN, O. **Deep learning architectures**. Switzerland: Springer, 2020.
- CHEN, R. J. et al. Synthetic data in machine learning for medicine and healthcare. **Nature Biomedical Engineering**, v.5, n.6, p.493–497, 2021.
- COFINO, A. S.; CANO, R.; SORDO, C.; GUTIERREZ, J. M. Bayesian Networks for Probabilistic Weather Prediction. **Proceedings of the 15th European Conference on Artificial Intelligence**, NLD, p.695–699, 2002.
- CORTES, C.; JACKEL, L. D.; CHIANG, W.-P. Limits on learning machine accuracy imposed by data quality. **Advances in Neural Information Processing Systems**, v.7, 1994.

DE VRIES, B.; PRINCIPE, J. C. The gamma model—A new neural model for temporal processing. **Neural networks**, v.5, n.4, p.565–576, 1992.

FINN, C.; GOODFELLOW, I.; LEVINE, S. Unsupervised learning for physical interaction through video prediction. **Advances in neural information processing systems**, v.29, 2016.

GHANBARZADEH, A.; NOGHREHABADI, A.; ASSAREH, E.; BEHRANG, M. Solar radiation forecasting based on meteorological data using artificial neural networks. **2009 7th IEEE international conference on industrial informatics**, p.227–231, 2009.

GREFF, K. et al. LSTM: A search space odyssey. **IEEE transactions on neural networks and learning systems**, v.28, n.10, p.2222–2232, 2016.

GUPTA, N. et al. Data quality for machine learning tasks. **Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining**, p.4040–4041, 2021.

HAYATI, M.; SHIRVANY, Y. Artificial neural network approach for short term load forecasting for Illam region. **World Academy of Science, Engineering and Technology**, v.28, p.280–284, 2007.

HOCHREITER, S. The vanishing gradient problem during learning recurrent neural nets and problem solutions. **International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems**, v.6, n.02, p.107–116, 1998.

HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. **Neural computation**, v.9, n.8, p.1735–1780, 1997.

HOLTON, J. R. An introduction to dynamic meteorology. **American Journal of Physics**, v.41, n.5, p.752–754, 1973.

HYNDMAN, R. J.; KOEHLER, A. B. Another look at measures of forecast accuracy. **International journal of forecasting**, v.22, n.4, p.679–688, 2006.

JAIN, P. et al. A review of machine learning applications in wildfire science and management. **Environmental Reviews**, v.28, n.4, p.478–505, 2020.

KULIGOWSKI, R. J.; BARROS, A. P. Localized precipitation forecasts from a numerical weather prediction model using artificial neural networks. **Weather and forecasting**, v.13, n.4, p.1194–1204, 1998.

KURT, A.; OKTAY, A. B. Forecasting air pollutant indicator levels with geographic models 3 days in advance using neural networks. **Expert Systems with Applications**, v.37, n.12, p.7986–7992, 2010.

LAI, L. L. et al. Intelligent weather forecast. **Proceedings of 2004 International Conference on Machine Learning and Cybernetics (IEEE Cat. No. 04EX826)**, v.7, p.4216–4221, 2004.

LECUN, Y. The MNIST database of handwritten digits. [http://yann. lecun. com/exdb/mnist/](http://yann.lecun.com/exdb/mnist/), 1998.

LECUN, Y. et al. Backpropagation applied to handwritten zip code recognition. **Neural computation**, v.1, n.4, p.541–551, 1989.

LIN, Z. et al. Self-attention convlstm for spatiotemporal prediction. **Proceedings of the AAAI Conference on Artificial Intelligence**, v.34, n.07, p.11531–11538, 2020.

LIU, J. N.; LEE, R. S. Rainfall forecasting from multiple point sources using neural networks. **IEEE SMC'99 Conference Proceedings. 1999 IEEE International Conference on Systems, Man, and Cybernetics (Cat. No. 99CH37028)**, v.3, p.429–434, 1999.

MAQSOOD, I.; KHAN, M. R.; ABRAHAM, A. Weather forecasting models using ensembles of neural networks. In: **Intelligent Systems Design and Applications**.]: Springer, 2003. p.33–42.

MATHIEU, M.; COUPRIE, C.; LECUN, Y. **Deep multi-scale video prediction beyond mean square error**.

MURALIDHAR, N. et al. Phynet: Physics guided neural networks for particle drag force prediction in assembly. **Proceedings of the 2020 SIAM International Conference on Data Mining**, p.559–567, 2020.

OLIU, M.; SELVA, J.; ESCALERA, S. Folded recurrent neural networks for future video prediction. **Proceedings of the European Conference on Computer Vision (ECCV)**, p.716–731, 2018.

PASCANU, R.; MIKOLOV, T.; BENGIO, Y. On the difficulty of training recurrent neural networks. **International conference on machine learning**, p.1310–1318, 2013.

PINSON, P.; KARINIOTAKIS, G. Wind power forecasting using fuzzy neural networks enhanced with on-line prediction risk assessment. **2003 IEEE Bologna Power Tech Conference Proceedings**, v.2, p.8–pp, 2003.

SCHULTZ, M. G. et al. Can deep learning beat numerical weather prediction? **Philosophical Transactions of the Royal Society A**, v.379, n.2194, p.20200097, 2021.

SHANK, D. B.; MCCLENDON, R. W.; PAZ, J.; HOOGENBOOM, G. Ensemble artificial neural networks for prediction of dew point temperature. **Applied Artificial Intelligence**, v.22, n.6, p.523–542, 2008.

SHI, X. et al. **Convolutional LSTM Network**: A Machine Learning Approach for Precipitation Nowcasting.

SHI, X. et al. Deep learning for precipitation nowcasting: A benchmark and a new model. **Advances in neural information processing systems**, v.30, 2017.

SRIVASTAVA, N.; MANSIMOV, E.; SALAKHUDINOV, R. Unsupervised learning of video representations using lstms. **International conference on machine learning**, p.843–852, 2015.

SUN, J. et al. Use of NWP for nowcasting convective precipitation: Recent progress and challenges. **Bulletin of the American Meteorological Society**, v.95, n.3, p.409–426, 2014.

TAN, T. Z. et al. Rainfall intensity prediction by a spatial-temporal ensemble. **2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence)**, p.1721–1727, 2008.

VILLAR-CORRALES, A. et al. MSPred: Video Prediction at Multiple Spatio-Temporal Scales with Hierarchical Recurrent Networks. **arXiv preprint arXiv:2203.09303**, 2022.

VUUREN, D. P. van; CARTER, T. R. Climate and socio-economic scenarios for climate change research and assessment: reconciling the new with the old. **Climatic change**, v.122, p.415–429, 2014.

WANG, F.; CASALINO, L. P.; KHULLAR, D. Deep learning in medicine—promise, progress, and challenges. **JAMA internal medicine**, v.179, n.3, p.293–294, 2019.

WANG, Y. et al. Predrnn: Recurrent neural networks for predictive learning using spatiotemporal lstms. **Advances in neural information processing systems**, v.30, 2017.

WANG, Y. et al. Predrnn++: Towards a resolution of the deep-in-time dilemma in spatiotemporal predictive learning. **International Conference on Machine Learning**, p.5123–5132, 2018.

WANG, Y. et al. Predrnn: A recurrent neural network for spatiotemporal predictive learning. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, 2022.

WANG, Z.; BOVIK, A. C.; SHEIKH, H. R.; SIMONCELLI, E. P. Image quality assessment: from error visibility to structural similarity. **IEEE transactions on image processing**, v.13, n.4, p.600–612, 2004.

WEDI, N. P. Increasing horizontal resolution in numerical weather prediction and climate simulations: illusion or panacea? **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences**, v.372, n.2018, p.20130289, 2014.

WU, B.; WEI, M.; LI, Y. Dual-Polarization Radar Observations of the Evolution of a Supercell Tornado and Analysis of the Echo Mechanisms. **Atmosphere**, v.13, n.5, p.797, 2022.

YU, W.; LU, Y.; EASTERBROOK, S.; FIDLER, S. Crevnet: Conditionally reversible video prediction. **arXiv preprint arXiv:1910.11577**, 2019.

ZILLI, M. T.; CARVALHO, L. M.; LIEBMANN, B.; SILVA DIAS, M. A. A comprehensive analysis of trends in extreme precipitation over southeastern coast of Brazil. **International Journal of Climatology**, v.37, n.5, p.2269–2279, 2017.

Apêndices

APÊNDICE A – Previsão dia - 14/08/2020 - Radar Chapecó

Entrada




Figura 53 – Entrada do dia 14/08/2020 entre 15h10 e 16h04.

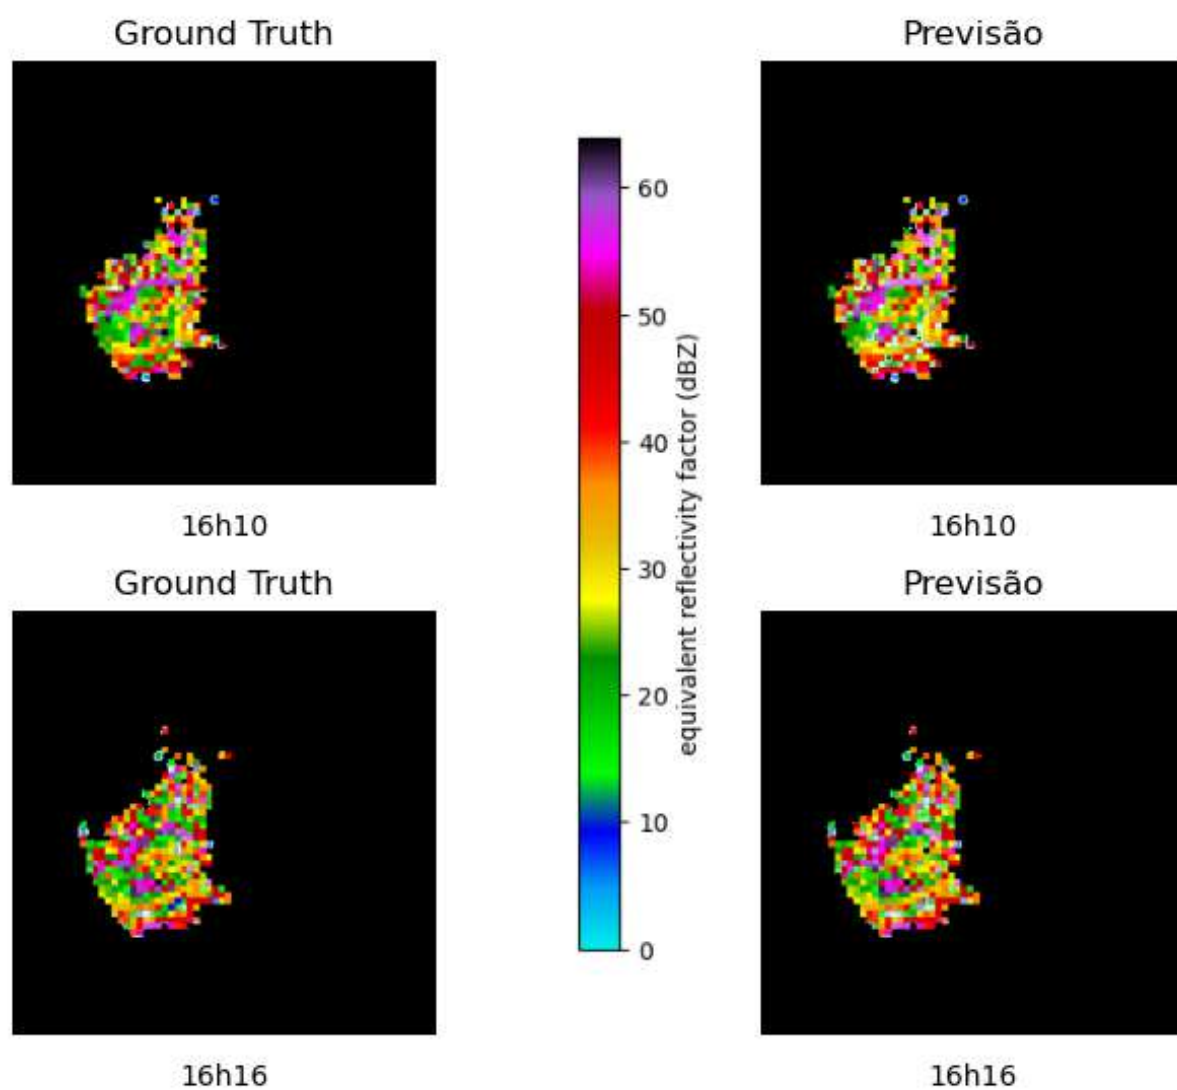


Figura 54 – Previsão das 16h10 e 16h16.




Figura 55 – Previsão das 16h22 e 16h28.




Figura 56 – Previsão das 16h34 e 16h40.




Figura 57 – Previsão das 16h46 e 16h52.




Figura 58 – Previsão das 16h58 e 17h04.

Entrada




Figura 59 – Entrada do dia 14/08/2020 entre 17h10 e 18h04.

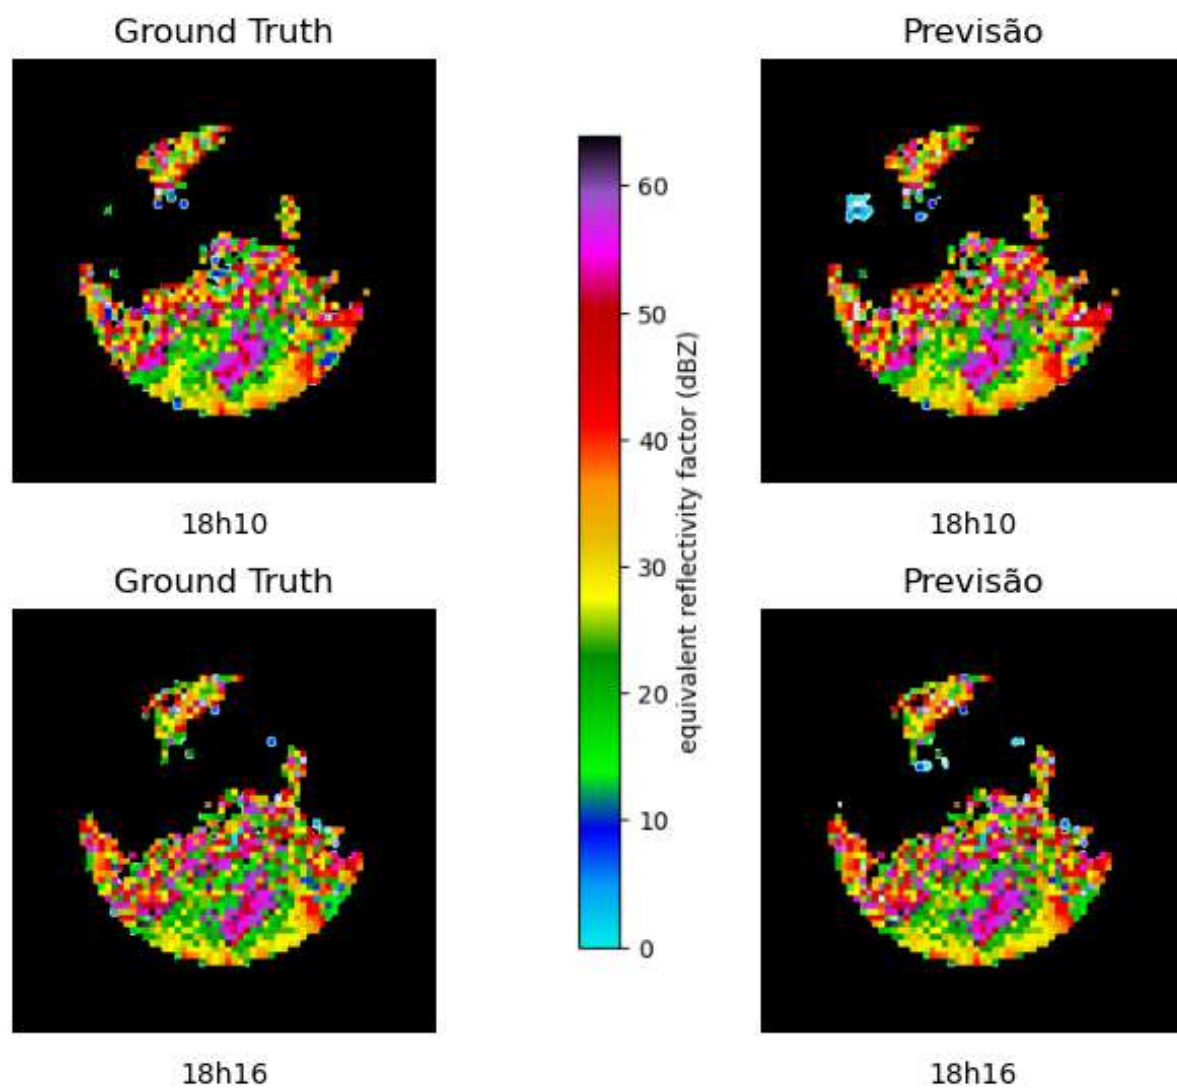


Figura 60 – Previsão das 18h10 e 18h16.

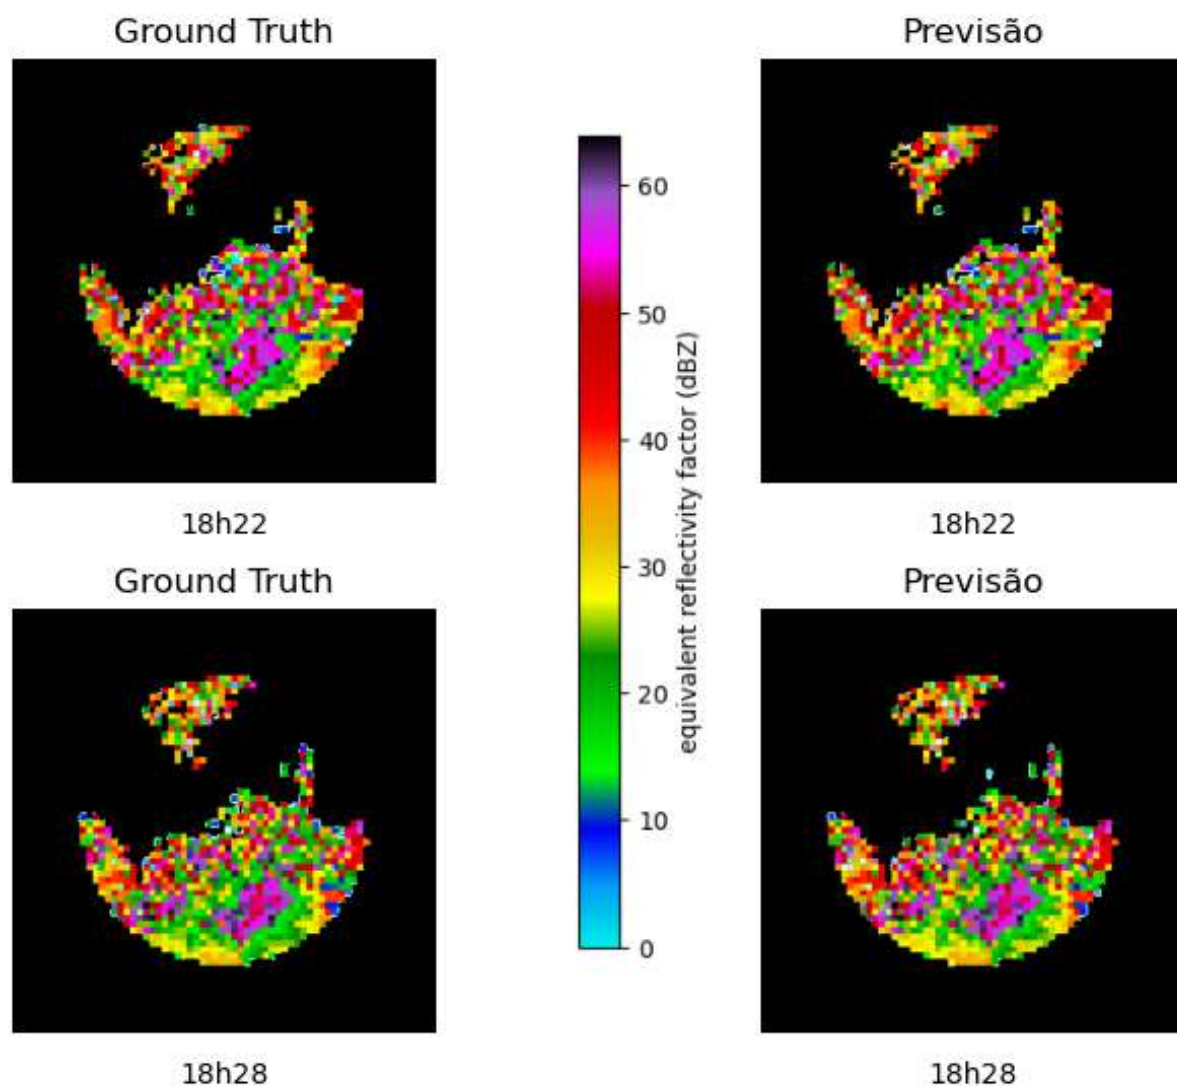


Figura 61 – Previsão das 18h22 e 18h28.

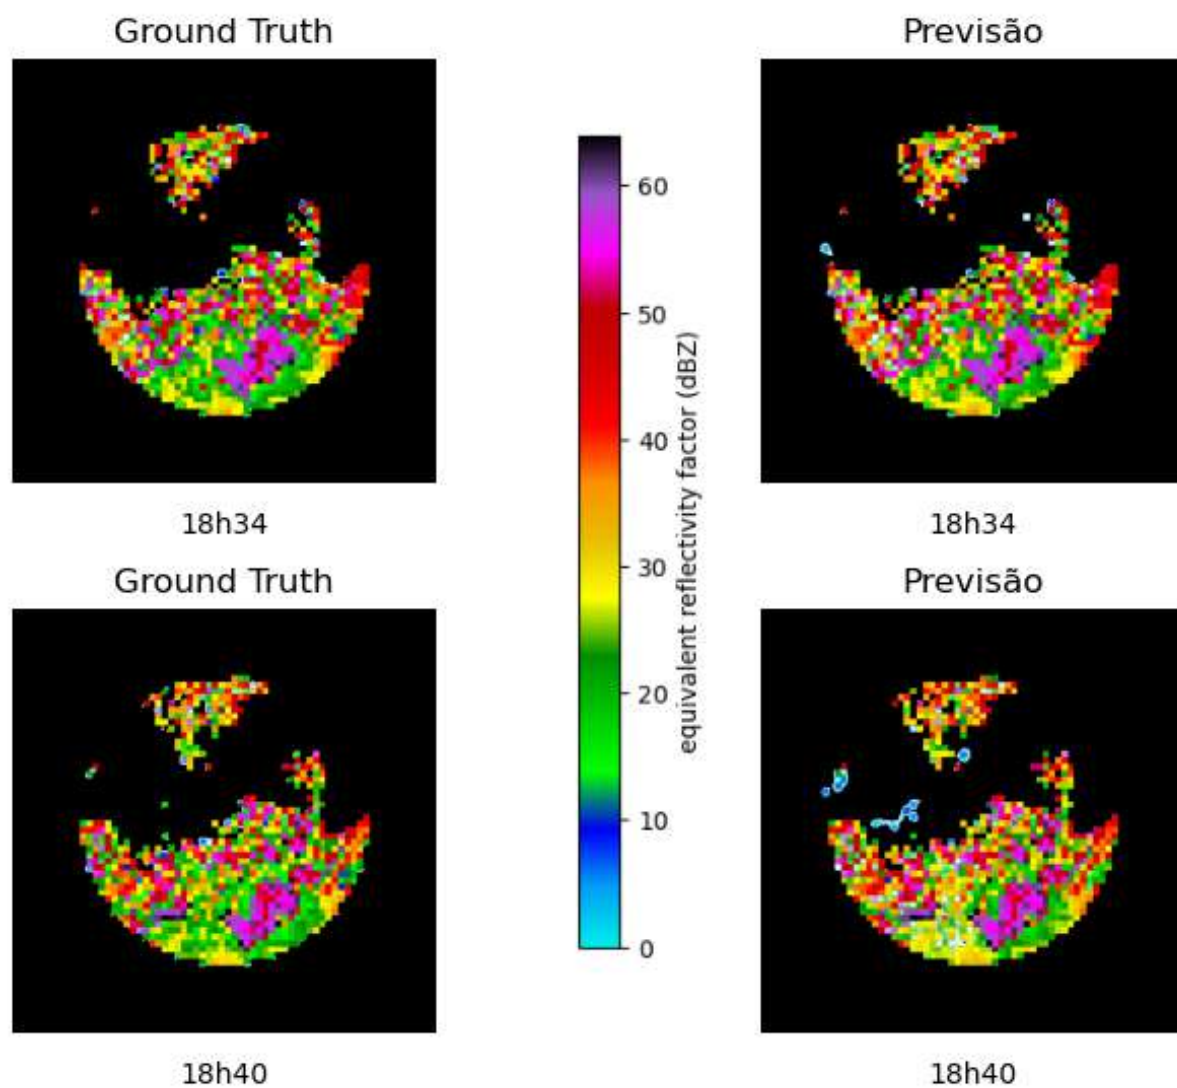


Figura 62 – Previsão das 18h34 e 18h40.

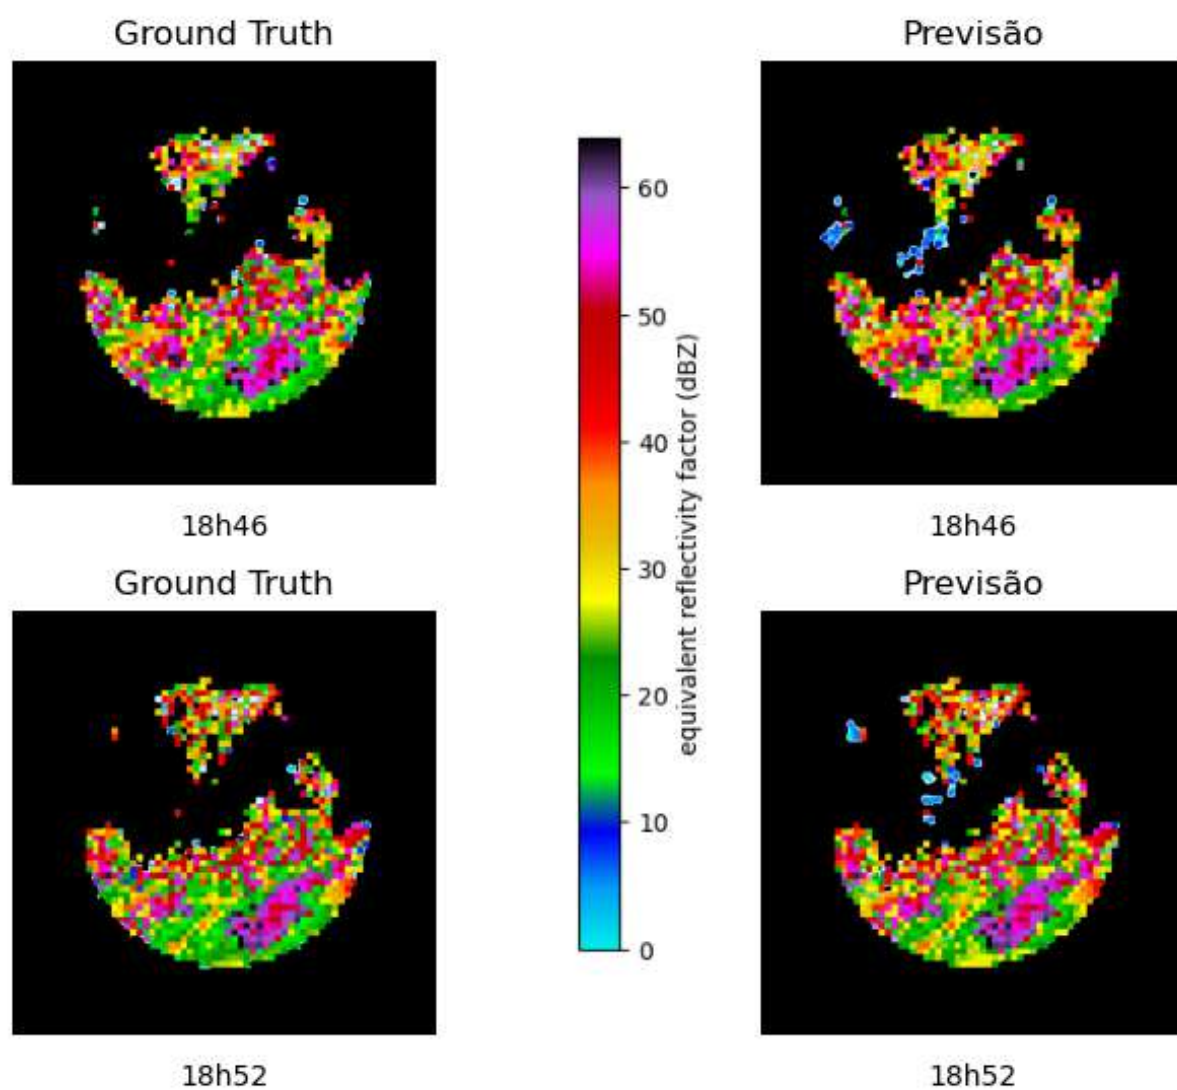


Figura 63 – Previsão das 18h46 e 18h52.

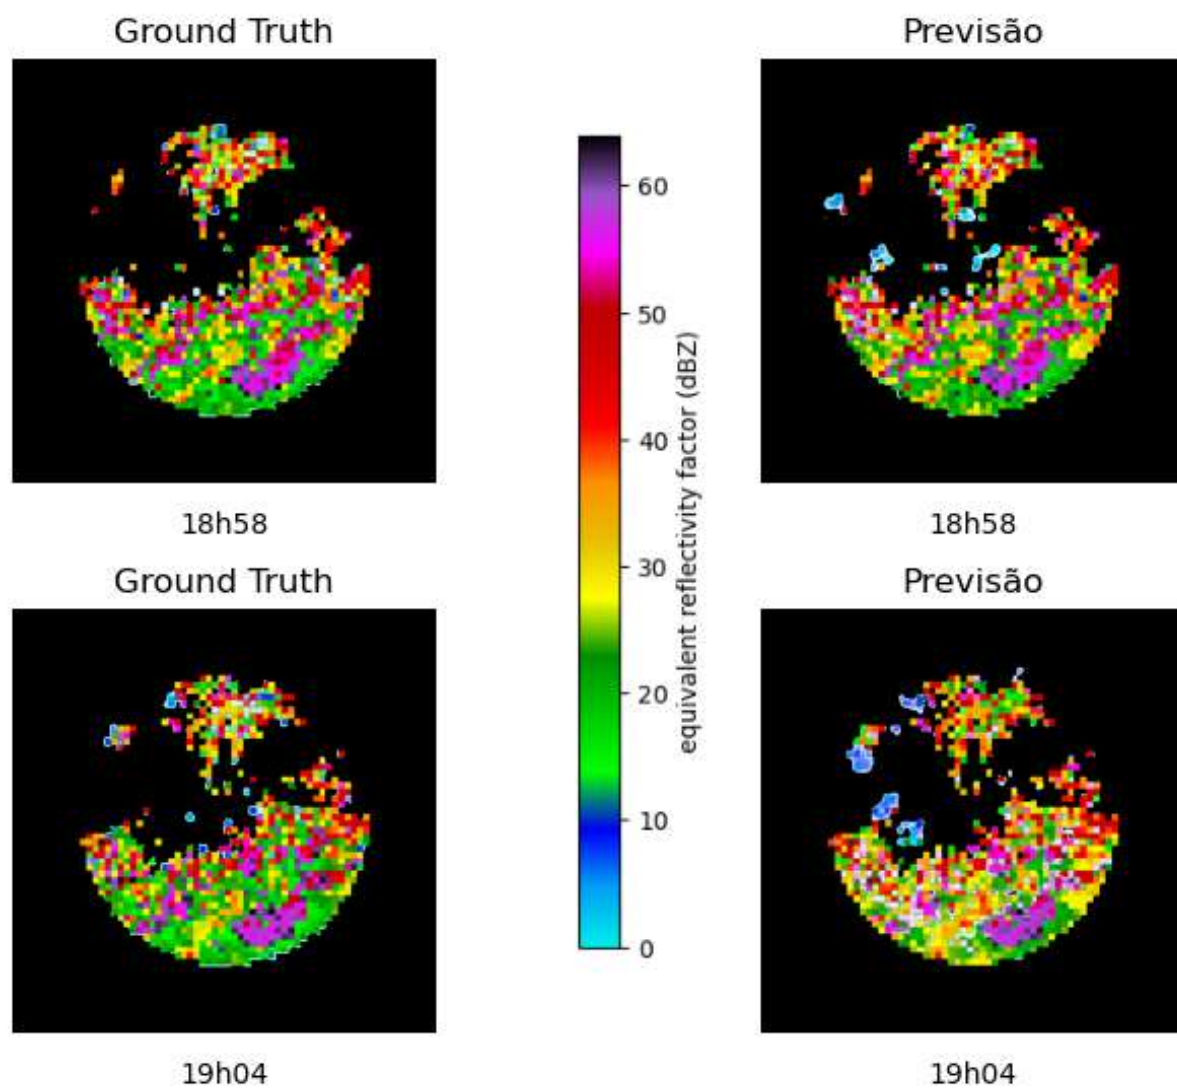


Figura 64 – Previsão das 18h58 e 19h04.

APÊNDICE B – Previsão dia - 03/06/2020 - Radar Chapecó




Figura 65 – Entrada do dia 03/06/2020 entre 19h11 e 20h05.




Figura 66 – Previsão das 20h11 e 20h17.

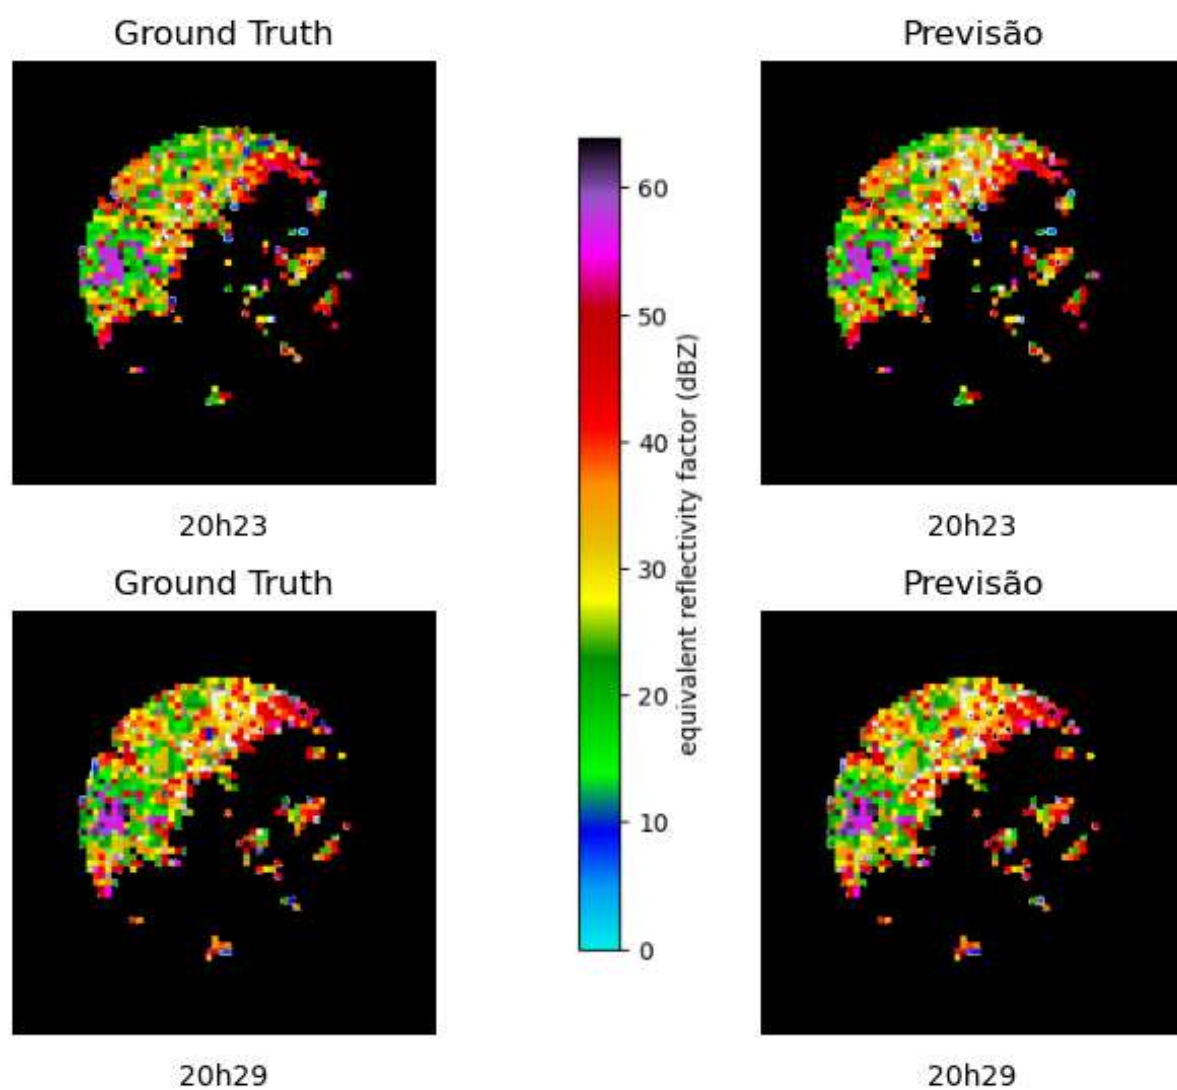


Figura 67 – Previsão das 20h23 e 20h29.

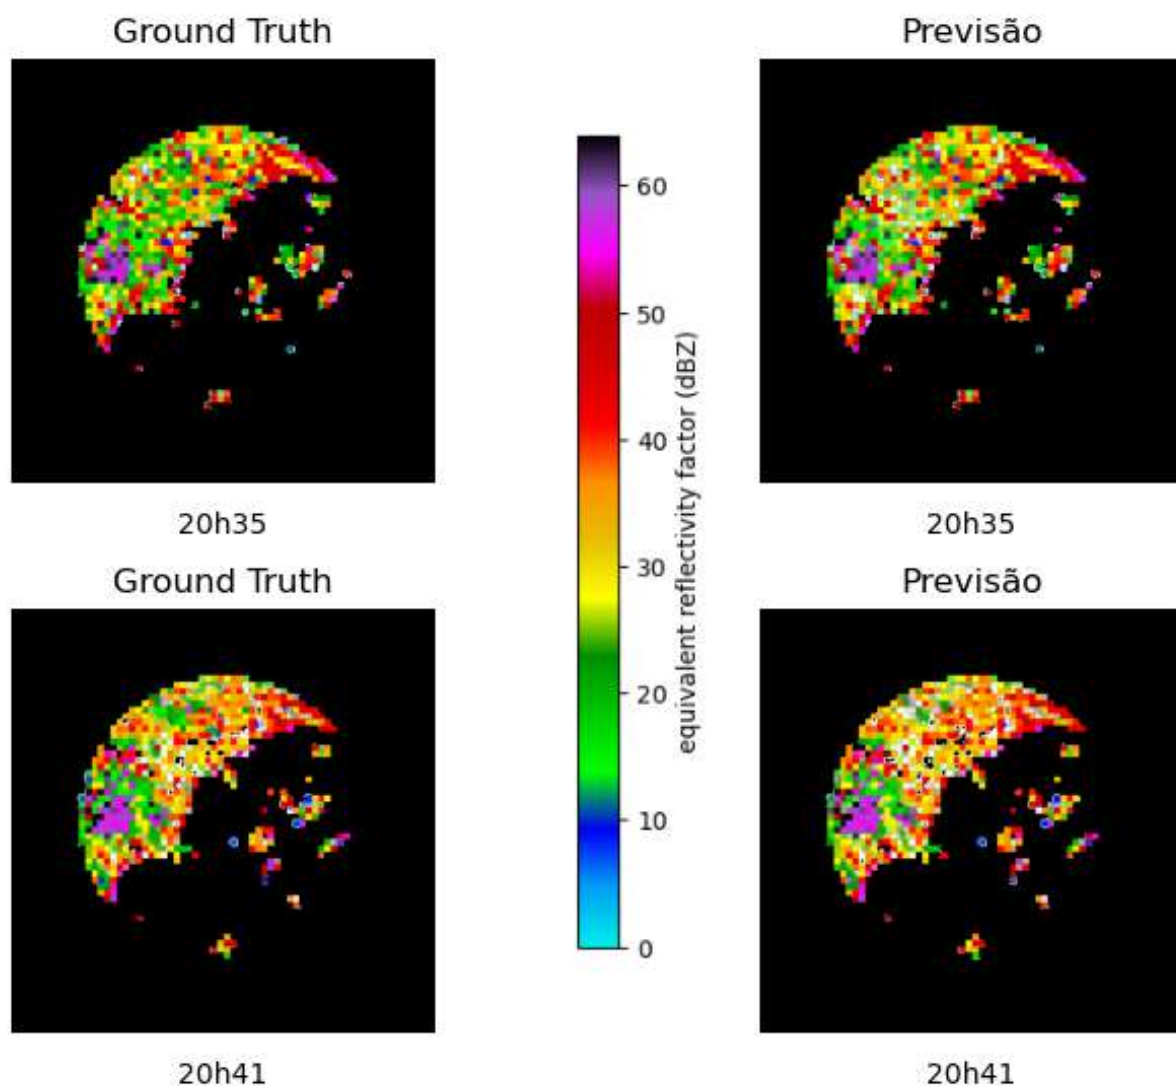


Figura 68 – Previsão das 20h35 e 20h41.

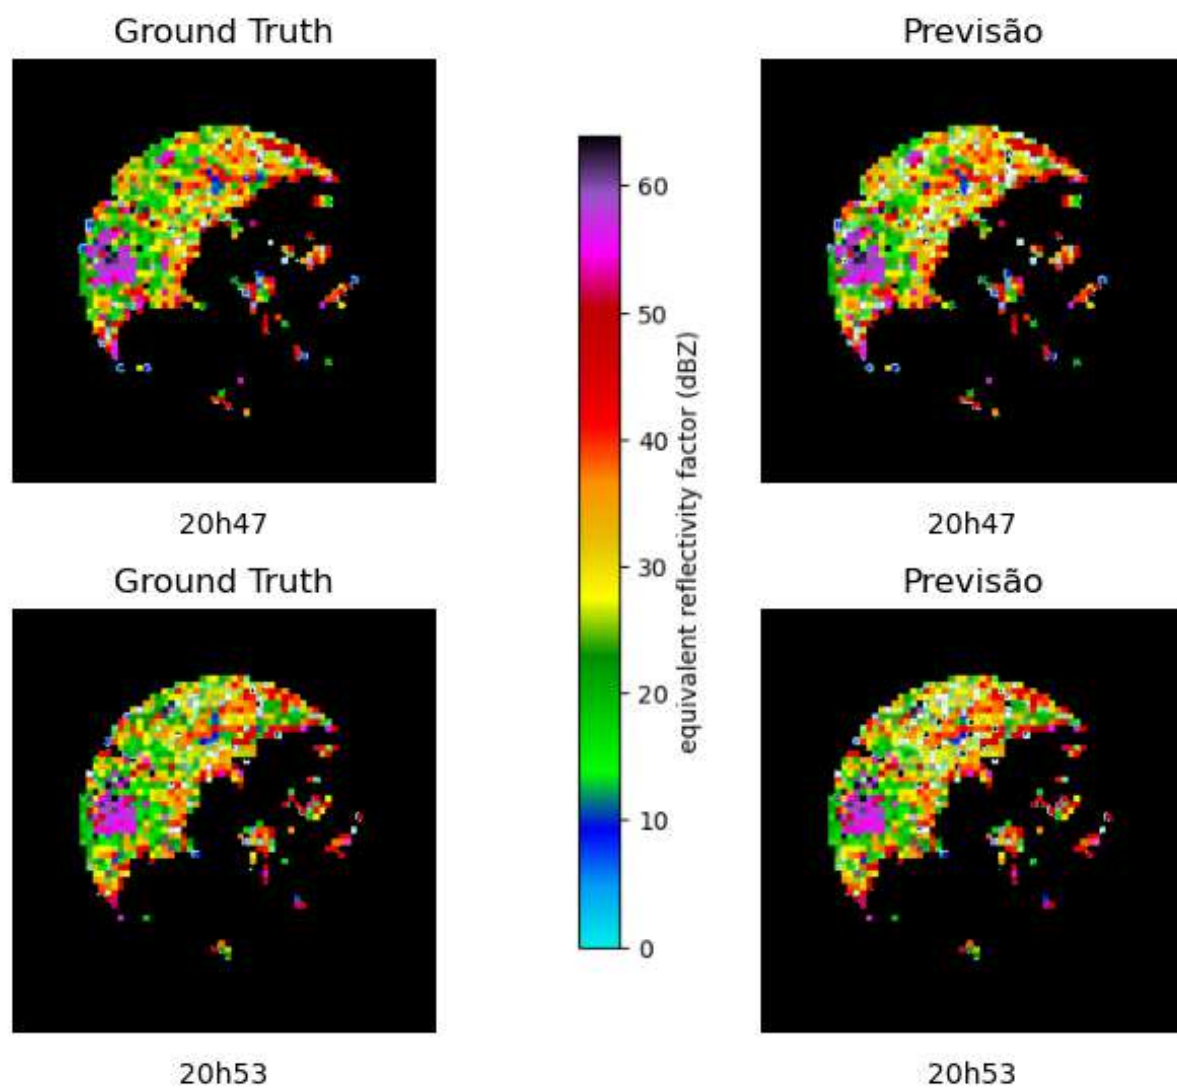


Figura 69 – Previsão das 20h47 e 20h53.

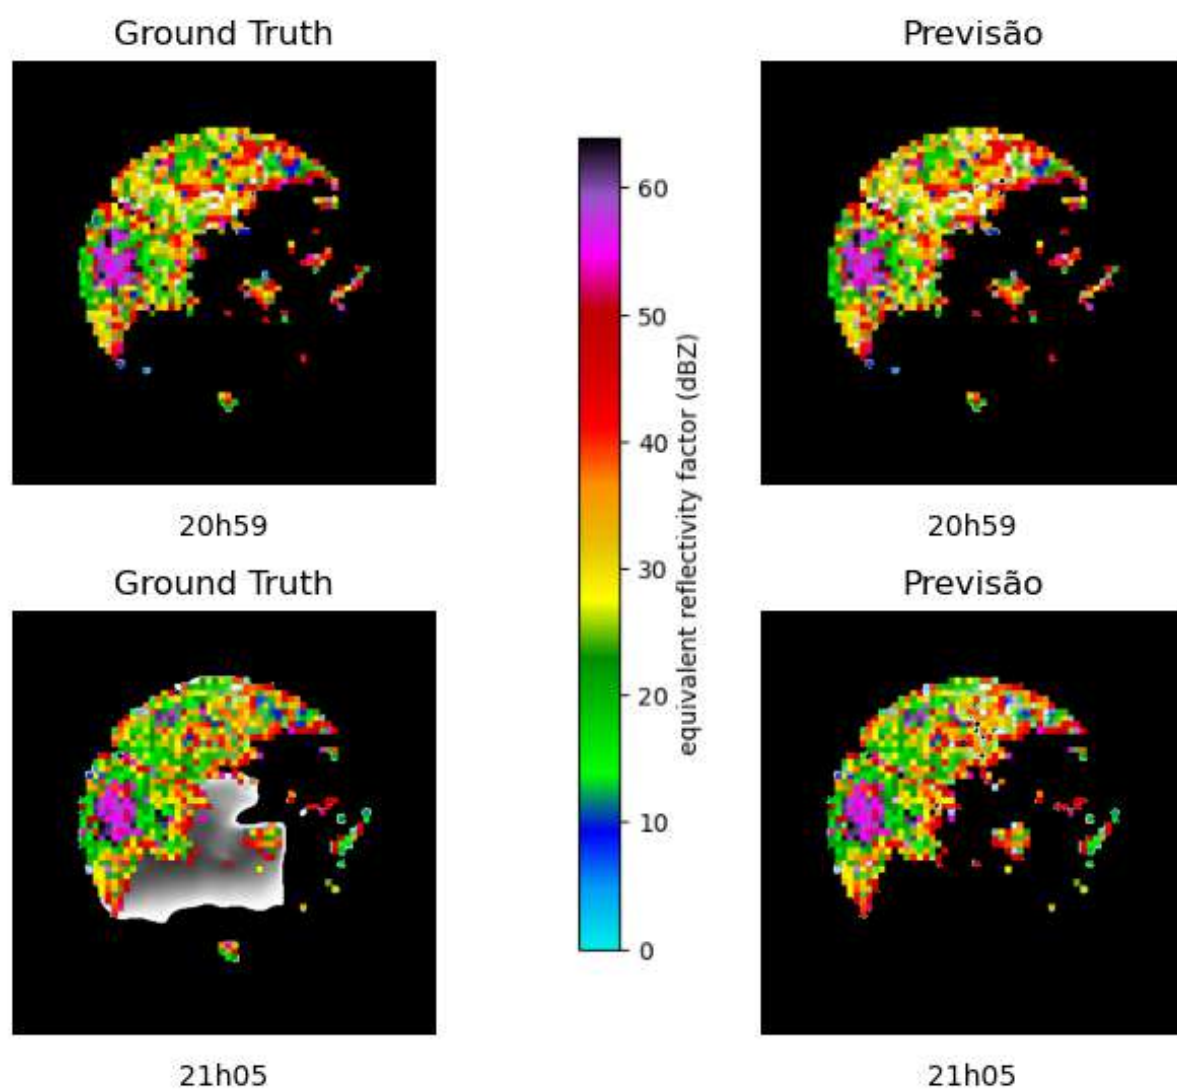


Figura 70 – Previsão das 20h59 e 21h05.

Entrada




Figura 71 – Entrada do dia 03/06/2020 entre 21h11 e 22h05.




Figura 72 – Previsão das 22h11 e 22h17.

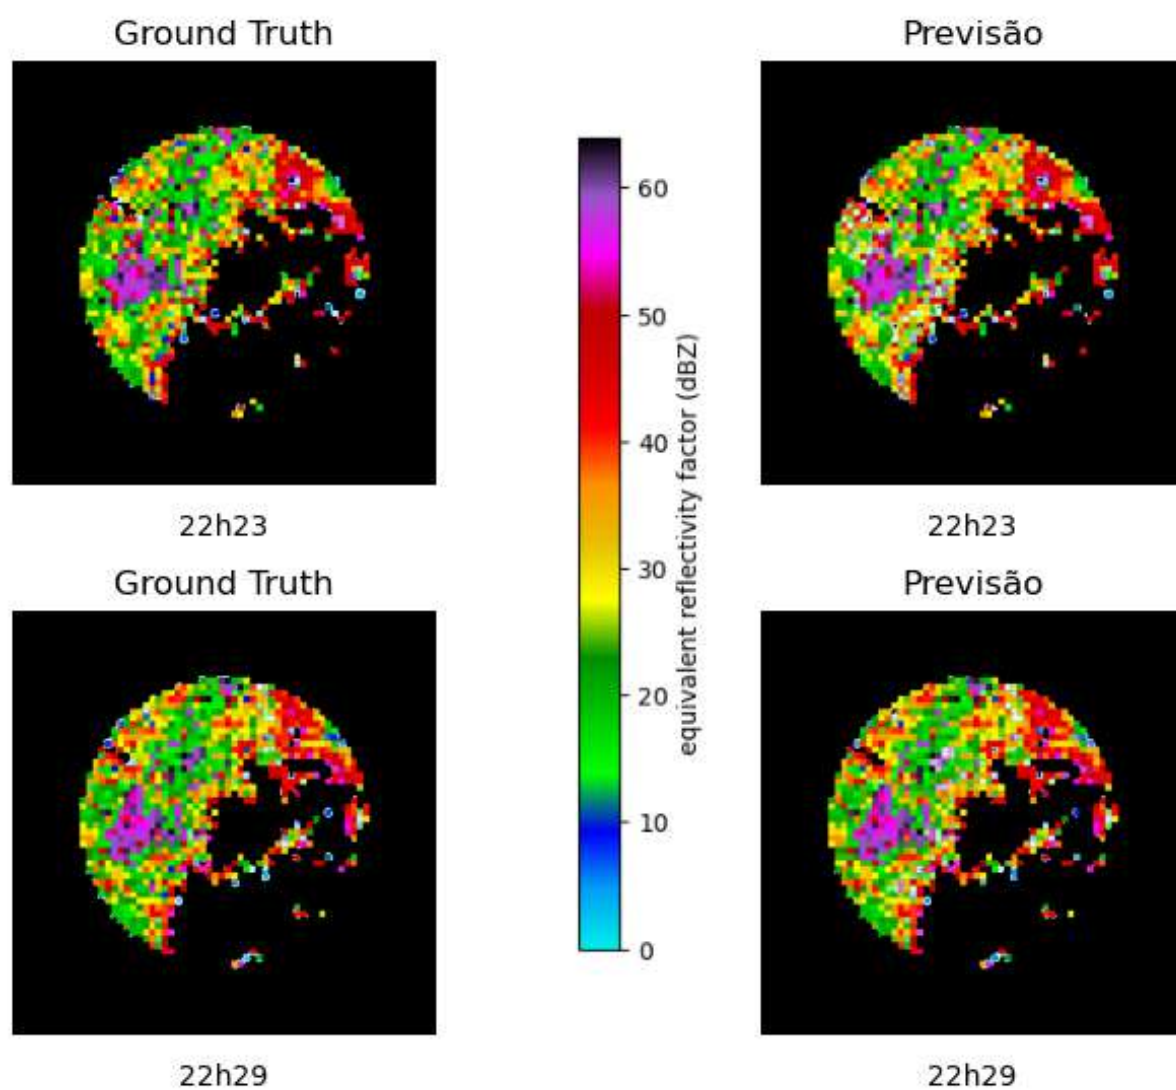


Figura 73 – Previsão das 22h23 e 22h29.

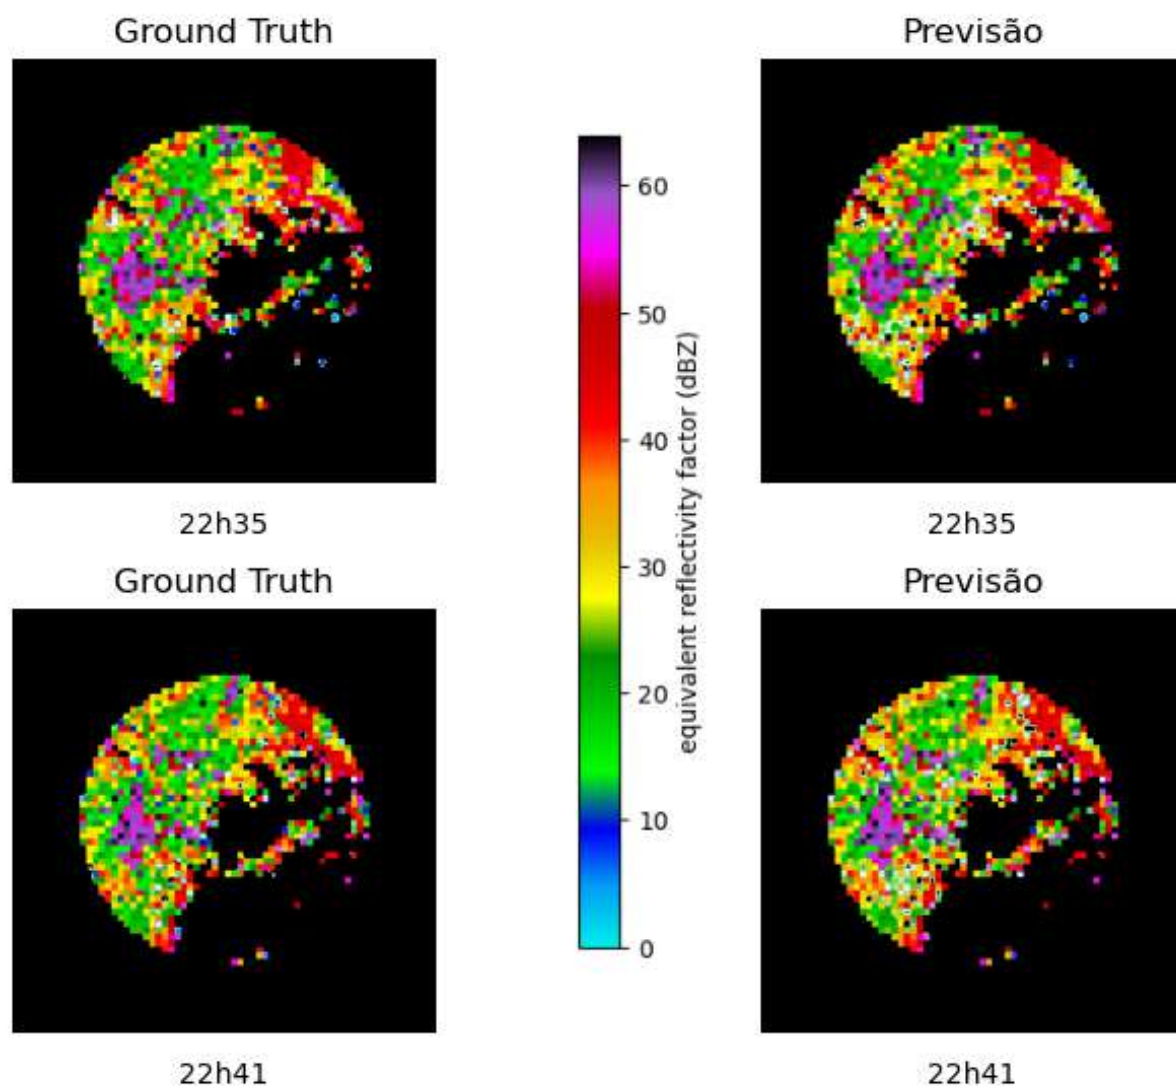


Figura 74 – Previsão das 22h35 e 22h41.

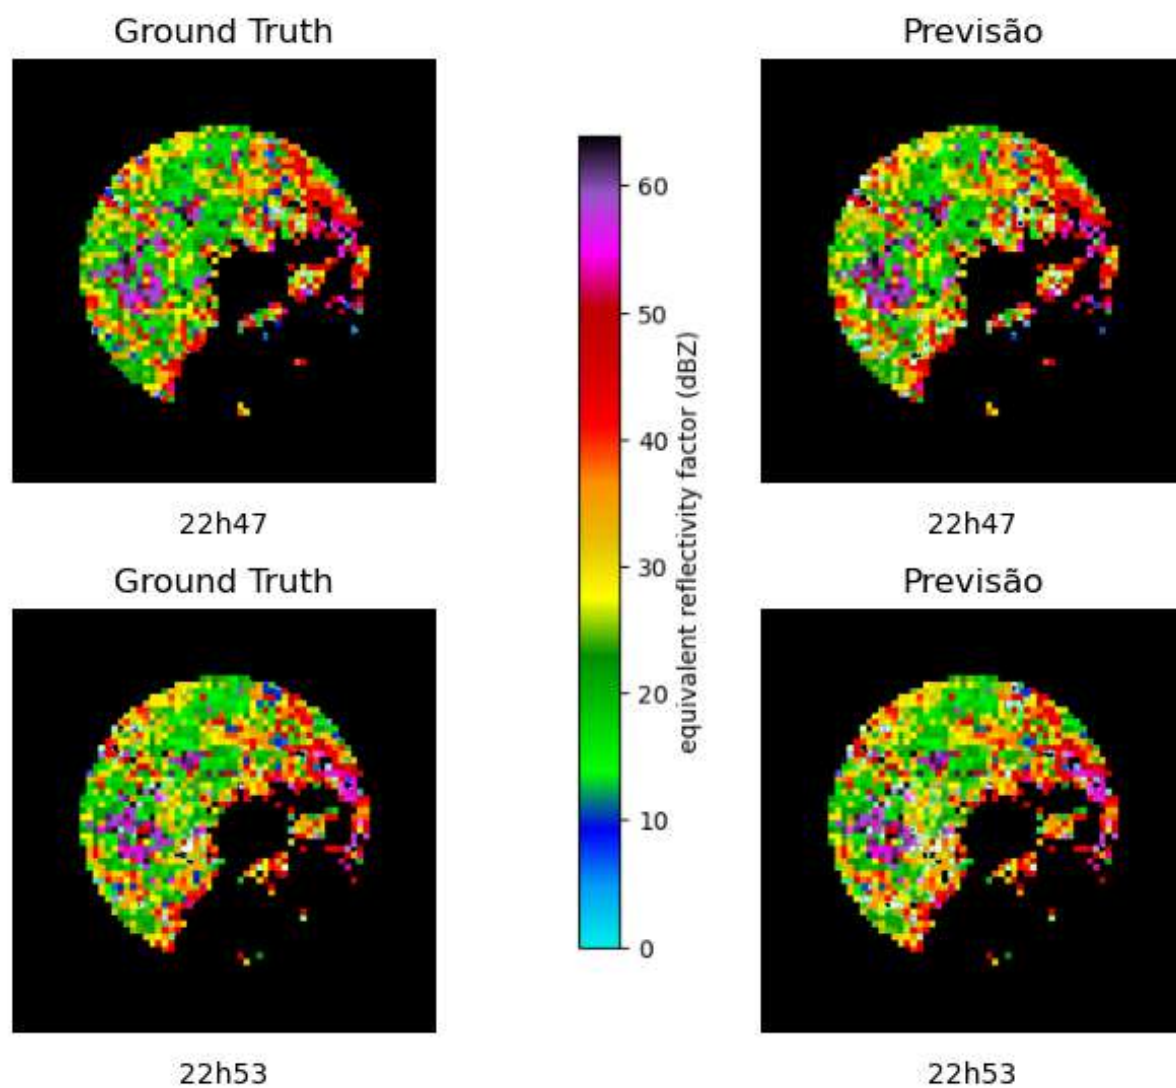


Figura 75 – Previsão das 22h47 e 22h53.

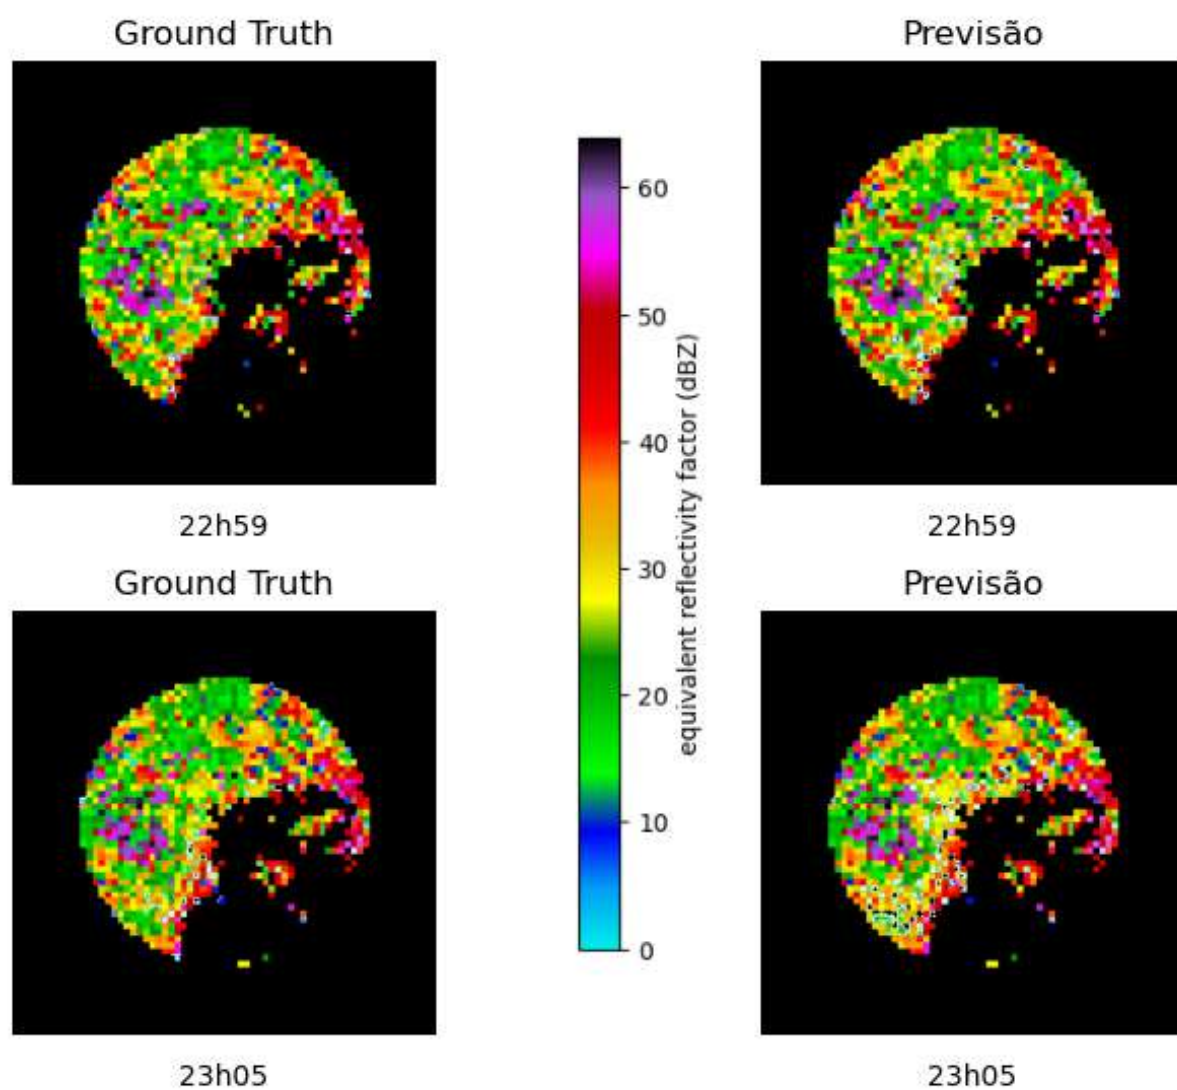


Figura 76 – Previsão das 22h59 e 23h05.

APÊNDICE C – Previsão dia - 03/02/2021 - Radar Chapecó




Figura 77 – Entrada do dia 03/02/2021 entre 18h46 e 19h40.

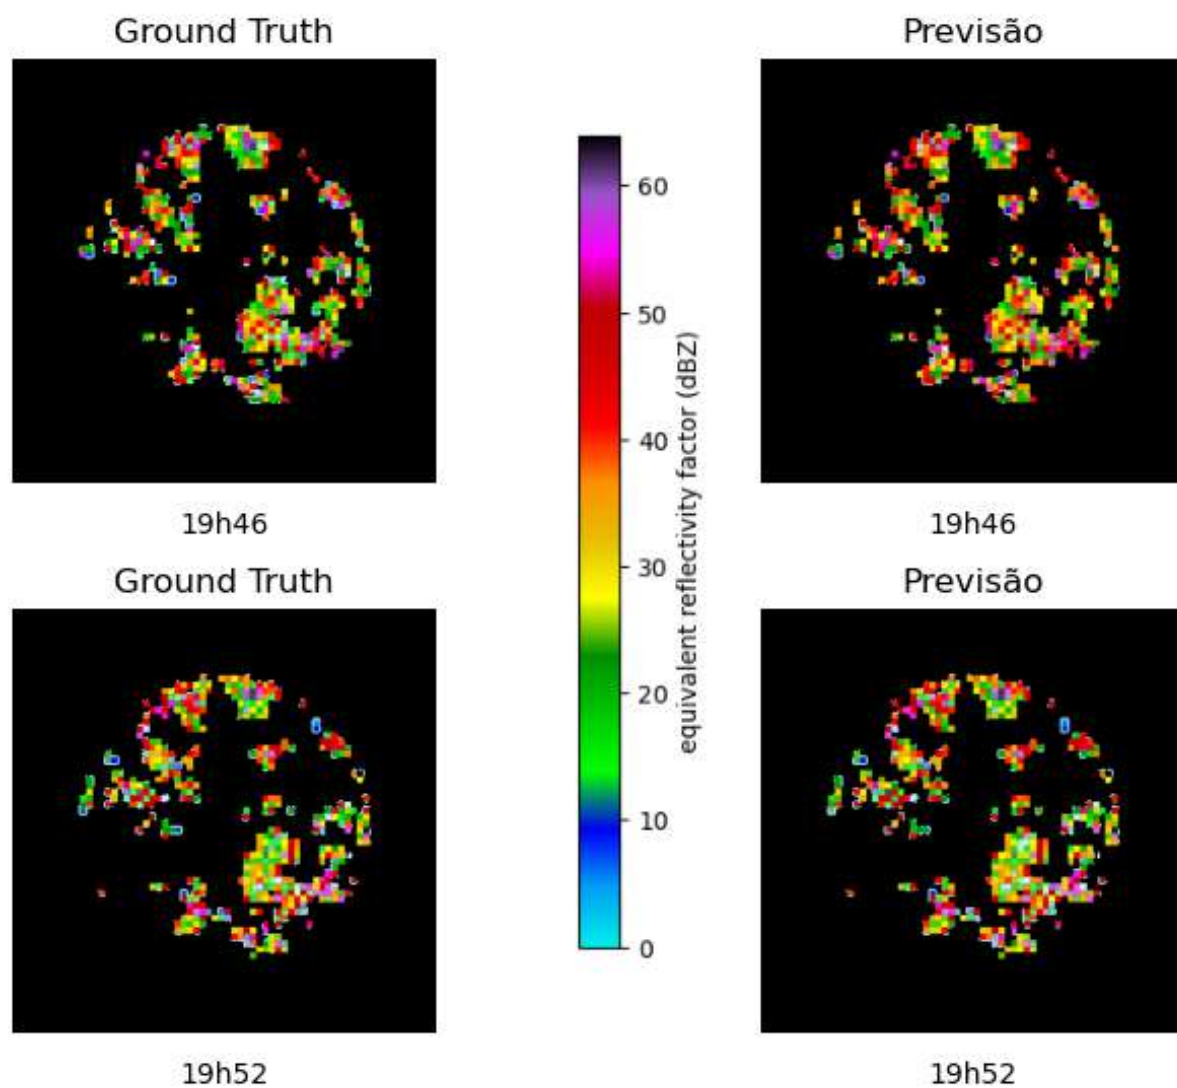


Figura 78 – Previsão das 19h46 e 19h52.

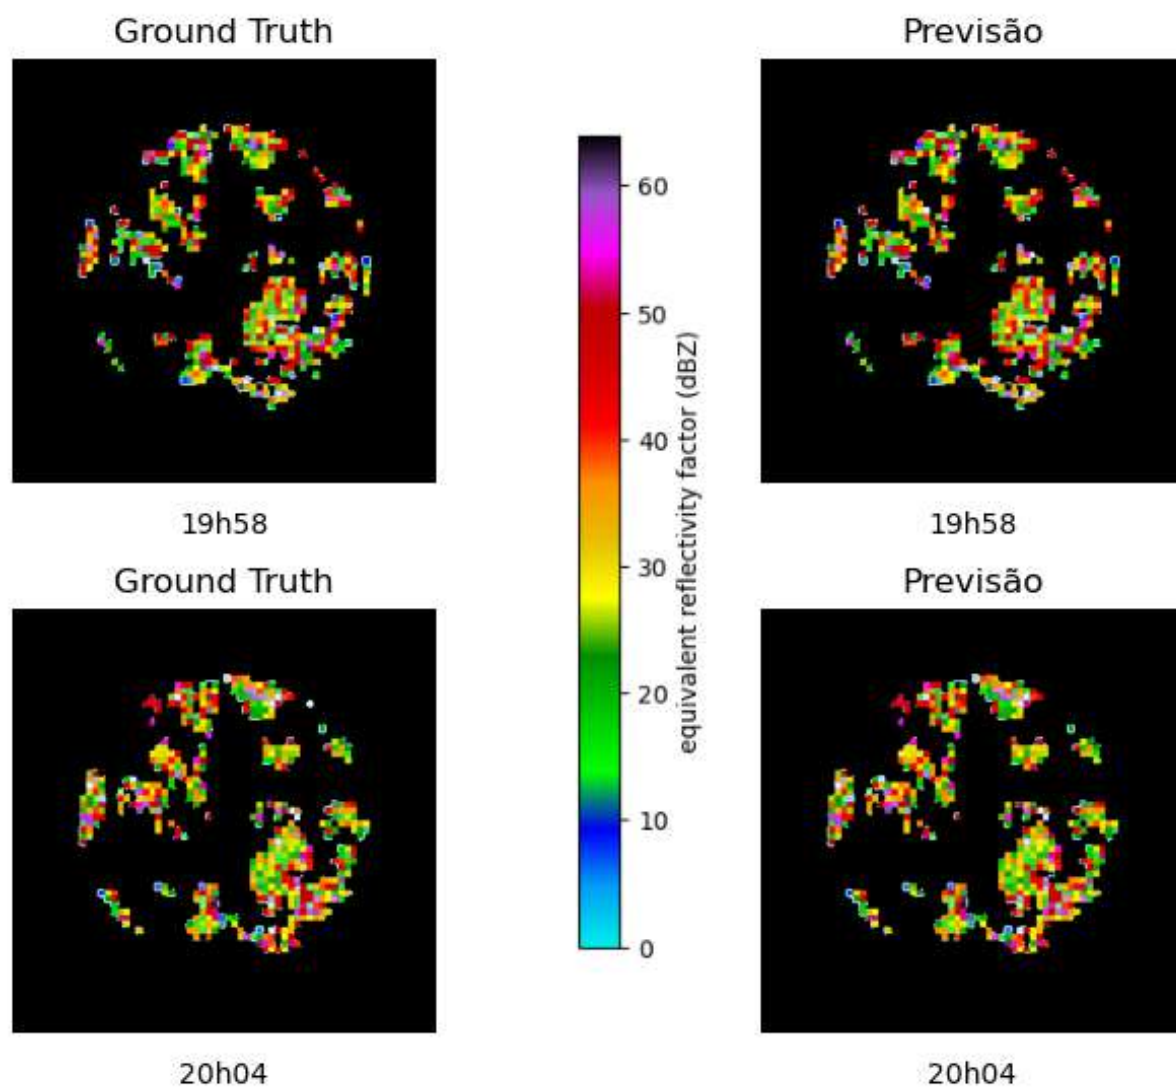


Figura 79 – Previsão das 19h58 e 20h04.

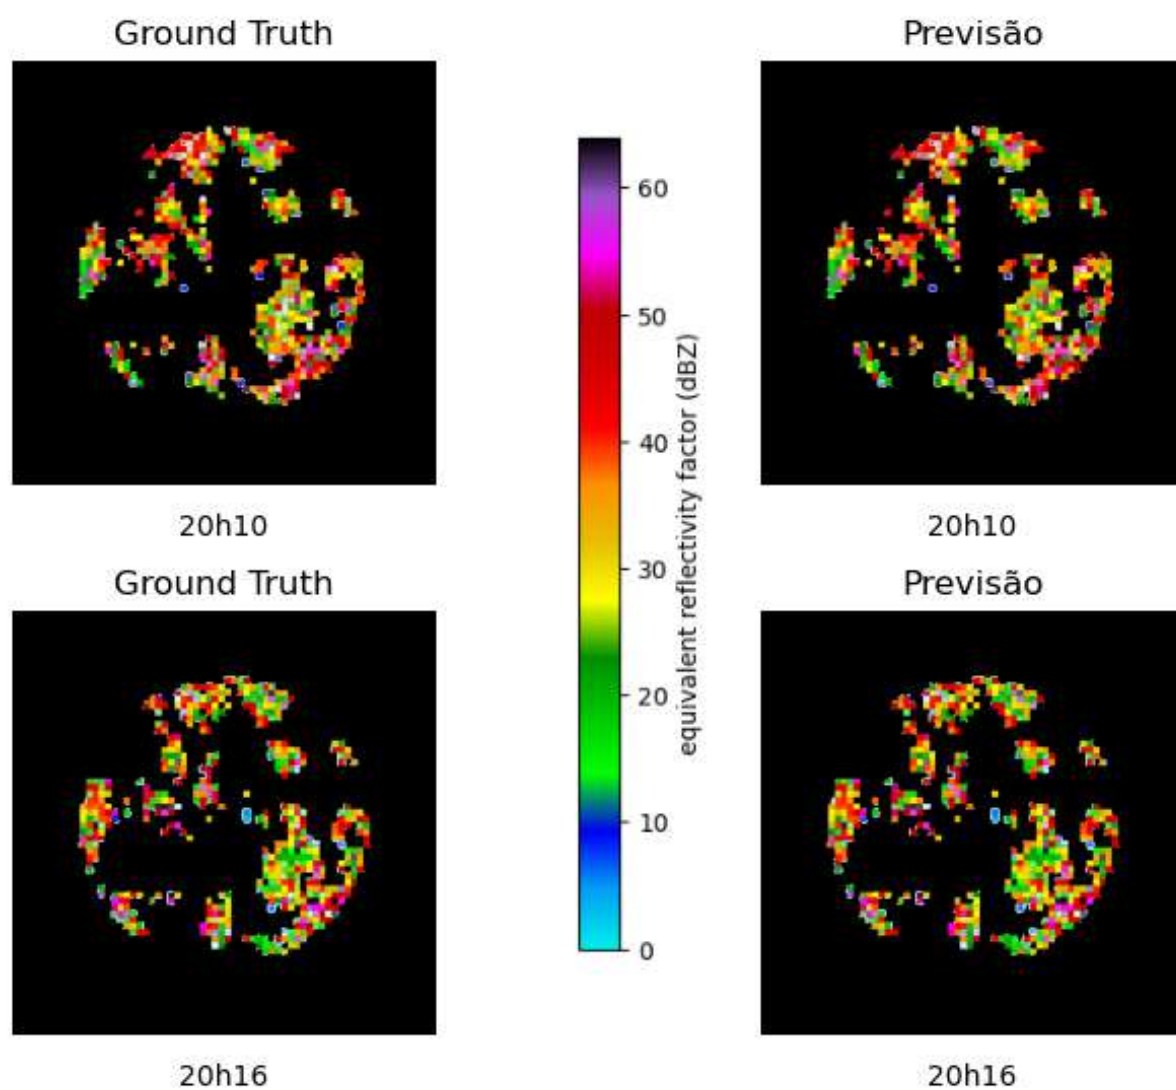


Figura 80 – Previsão das 20h10 e 20h16.

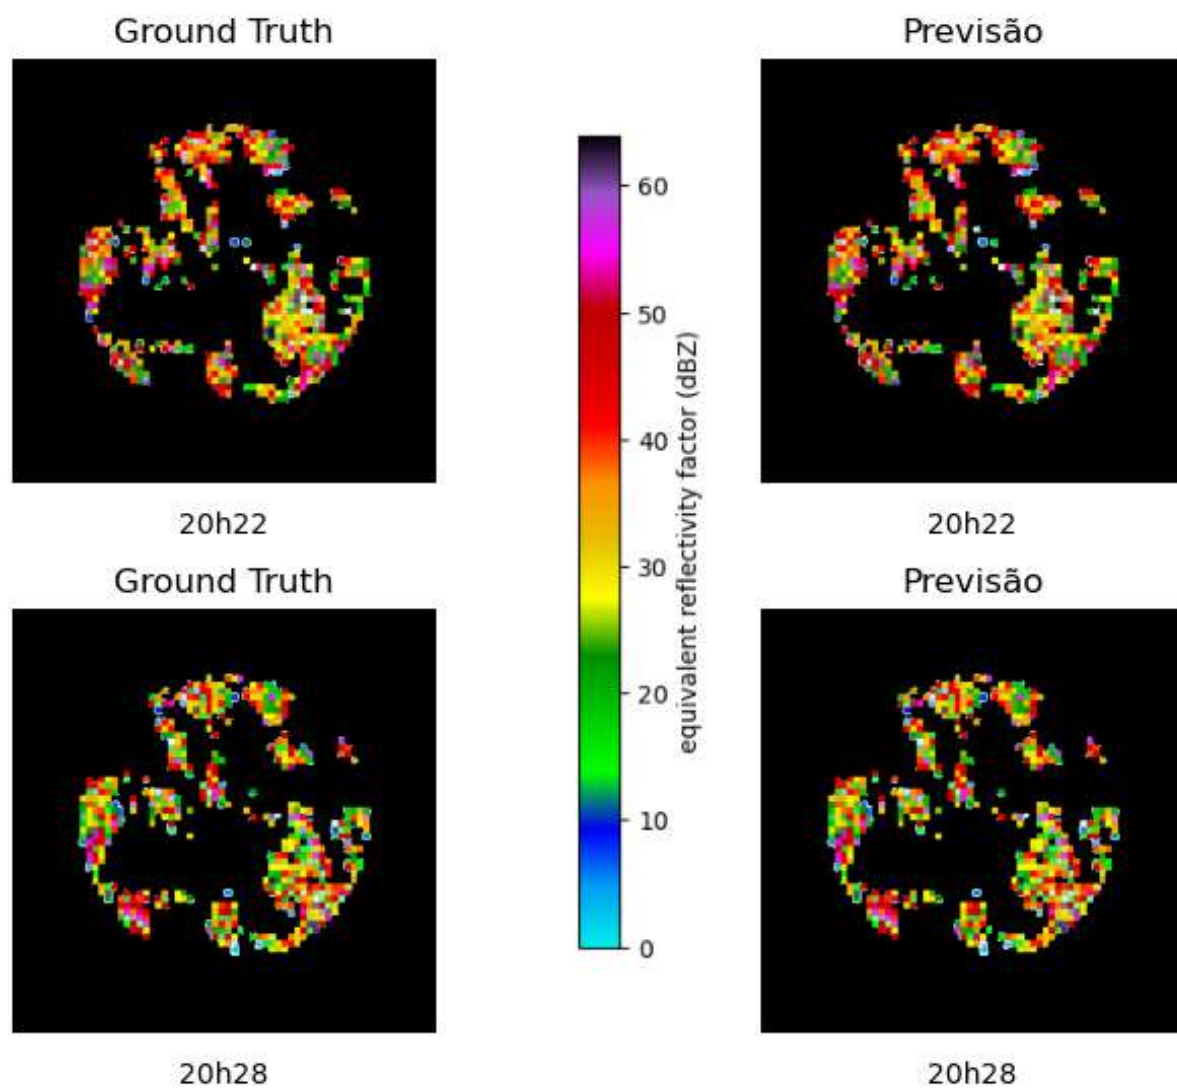


Figura 81 – Previsão das 20h22 e 20h28.

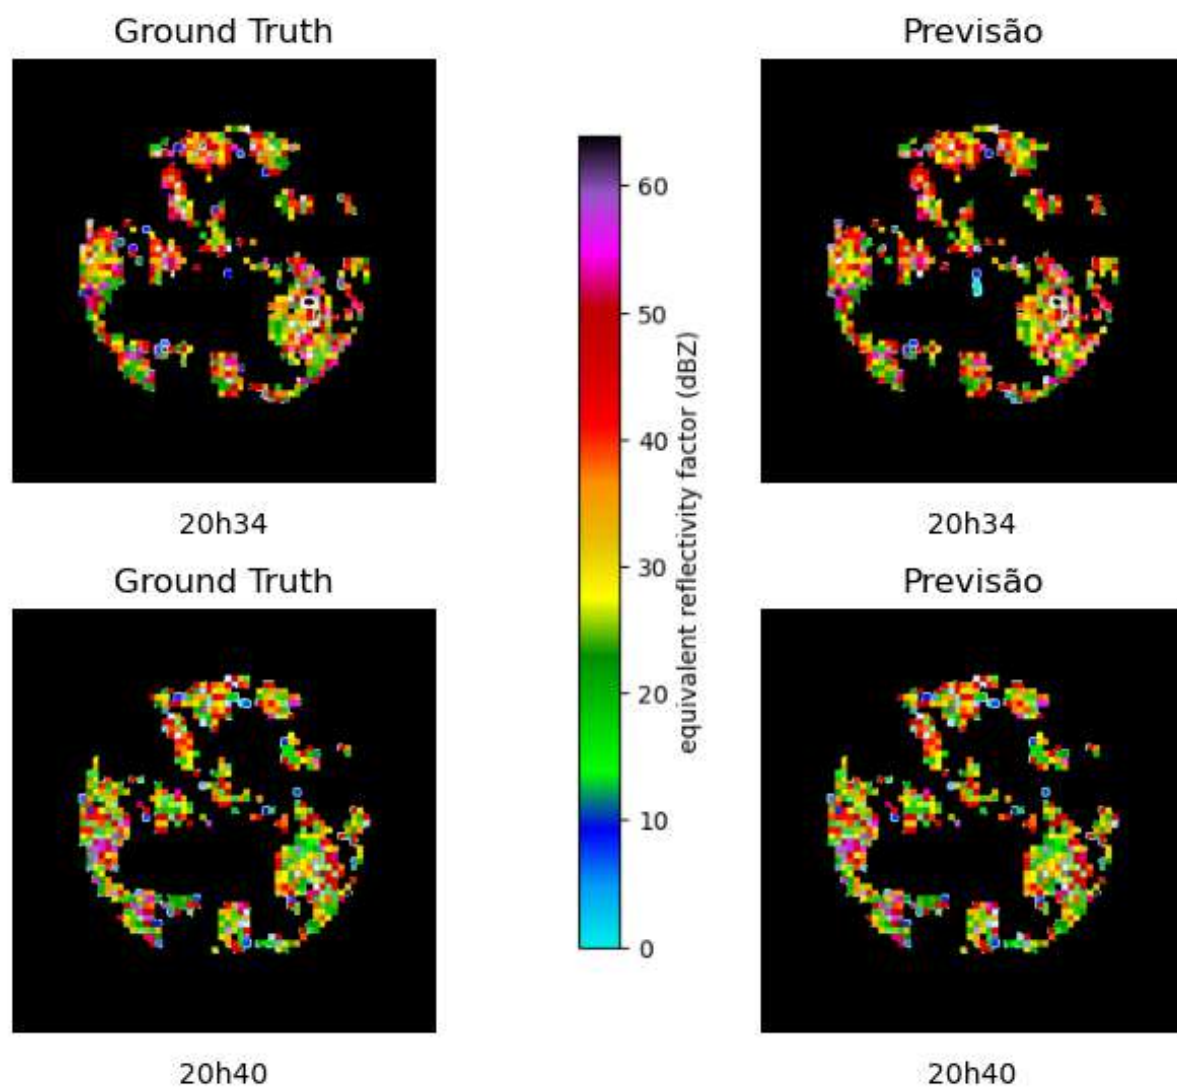


Figura 82 – Previsão das 20h34 e 20h40.

Entrada




Figura 83 – Entrada do dia 03/02/2021 entre 21h16 e 22h10.

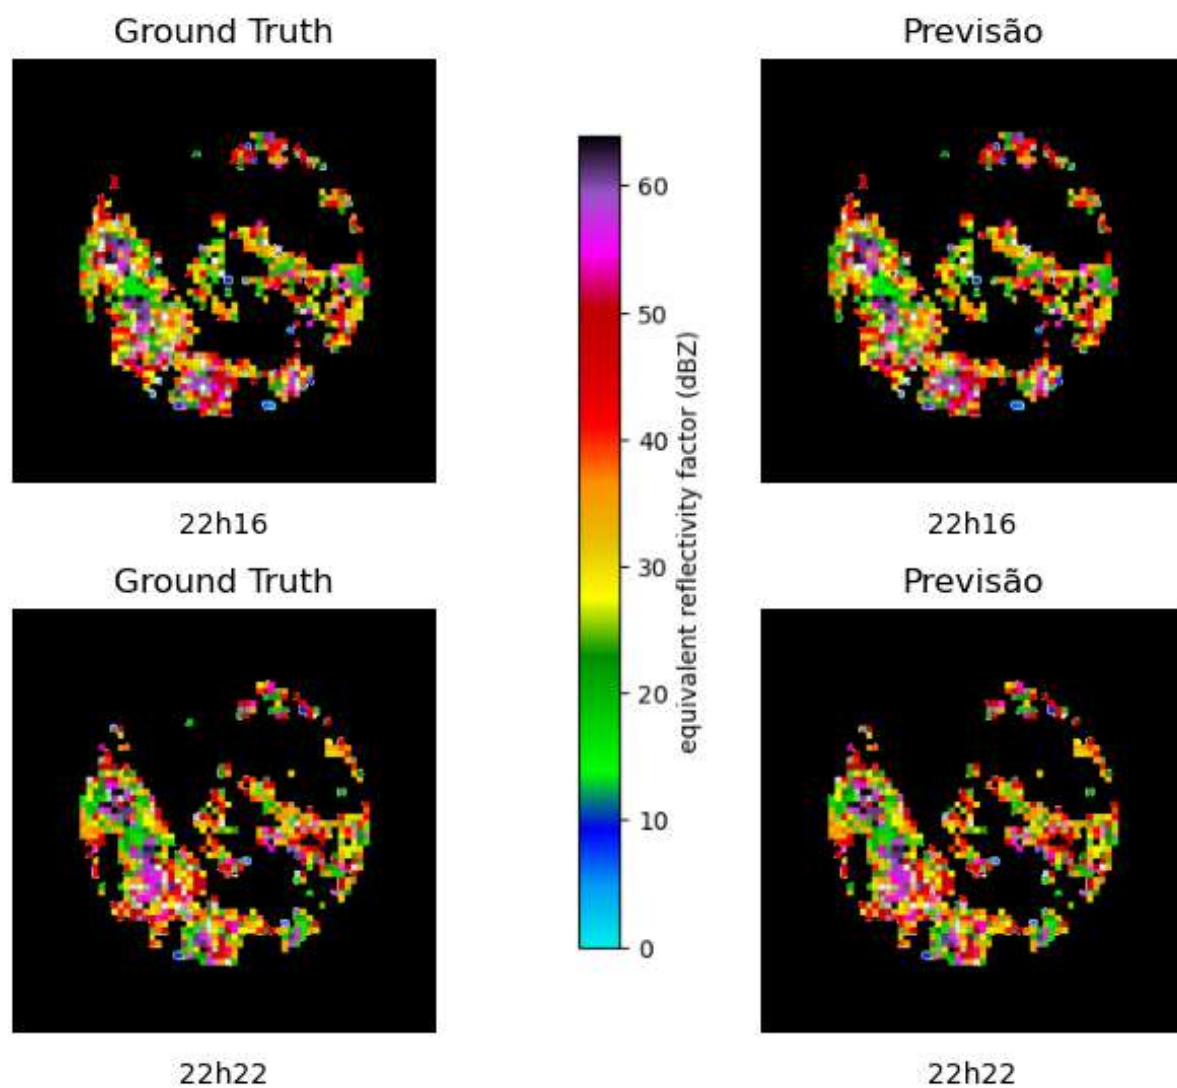


Figura 84 – Previsão das 22h16 e 22h22.

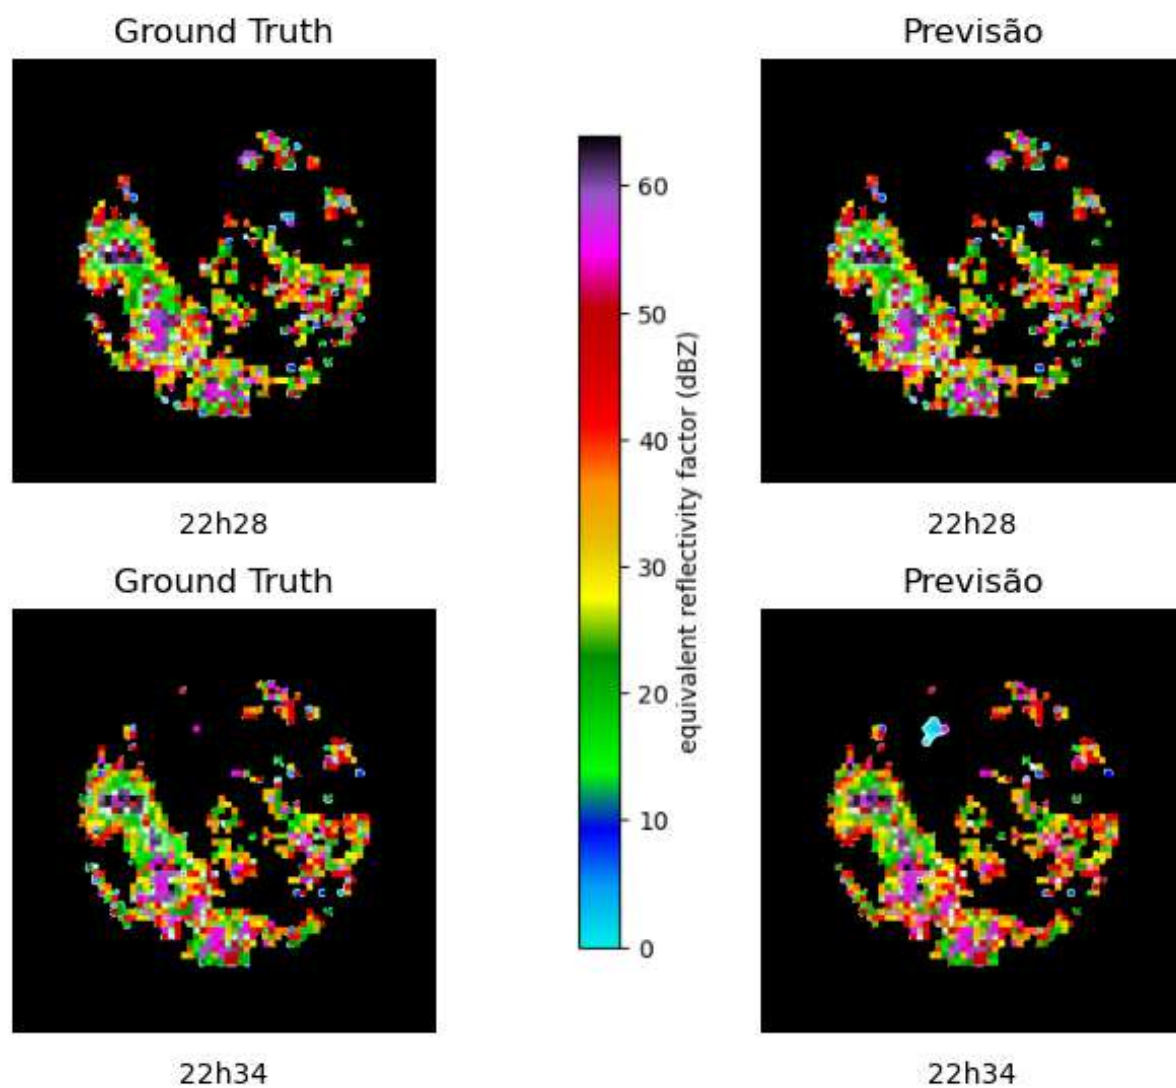


Figura 85 – Previsão das 22h28 e 22h34.

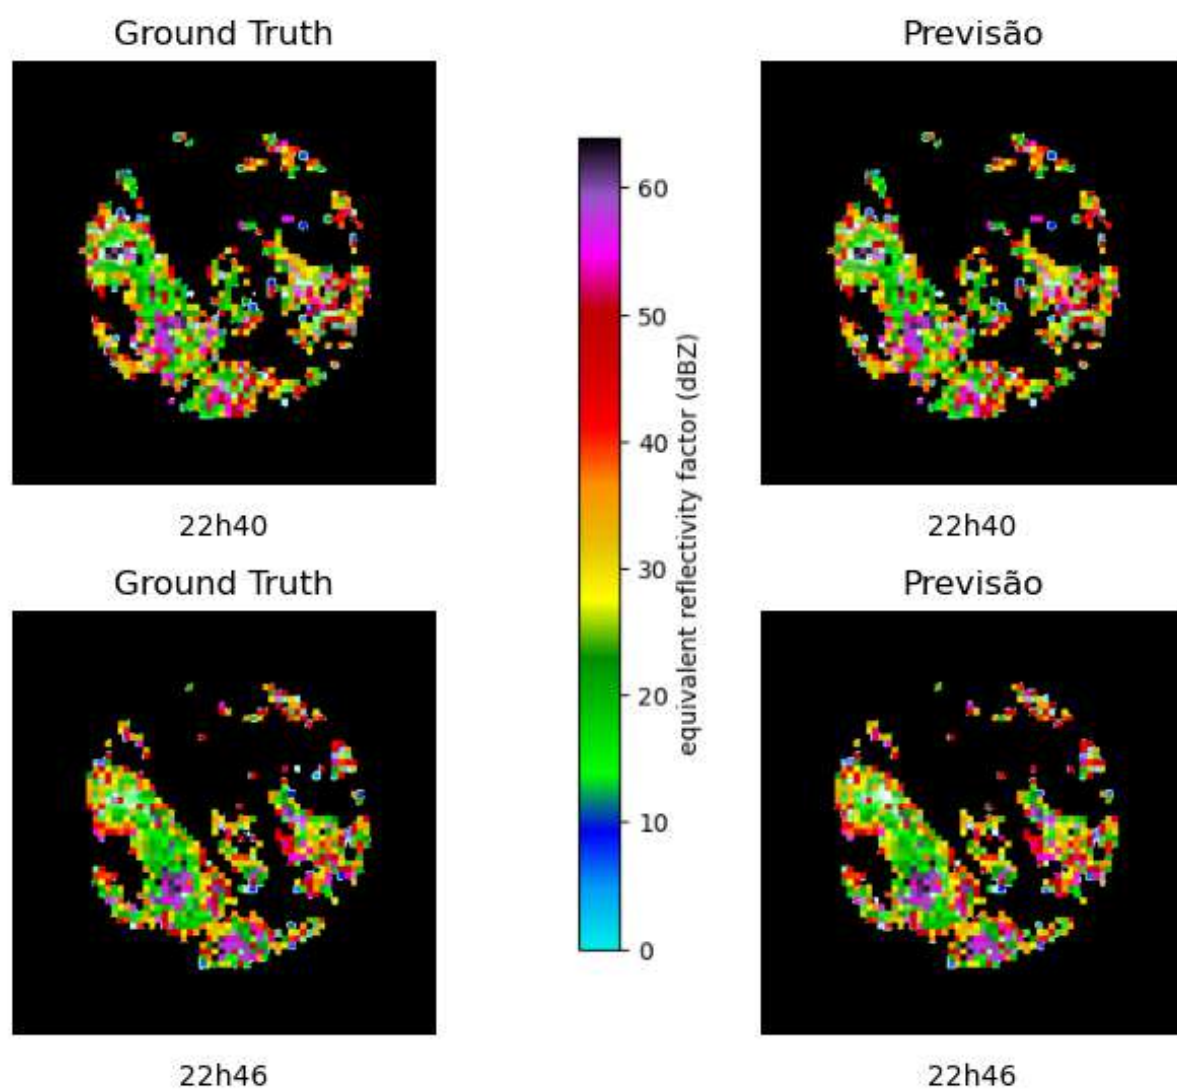


Figura 86 – Previsão das 22h40 e 22h46.

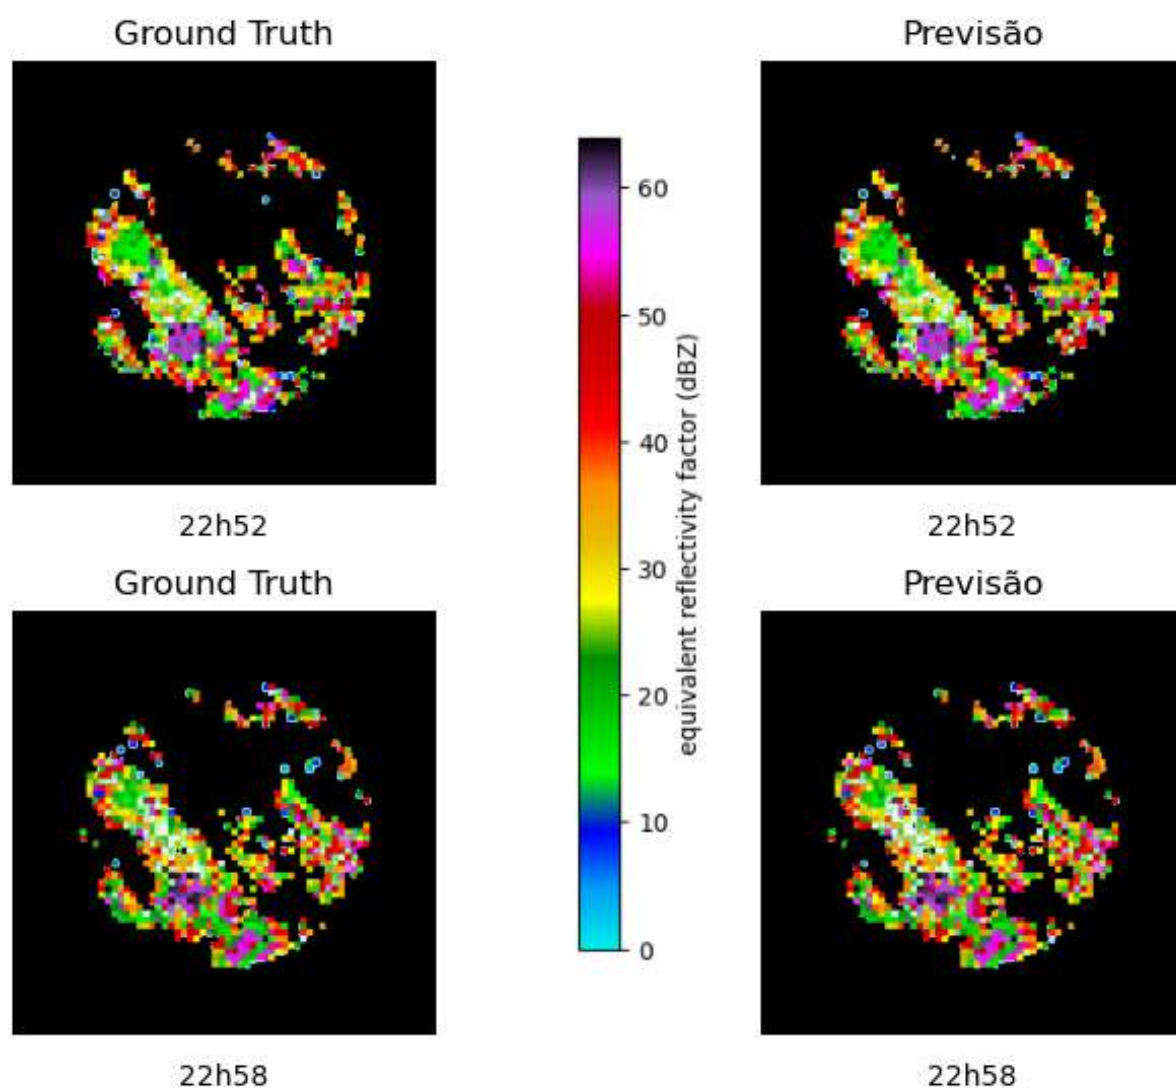


Figura 87 – Previsão das 22h52 e 22h58.

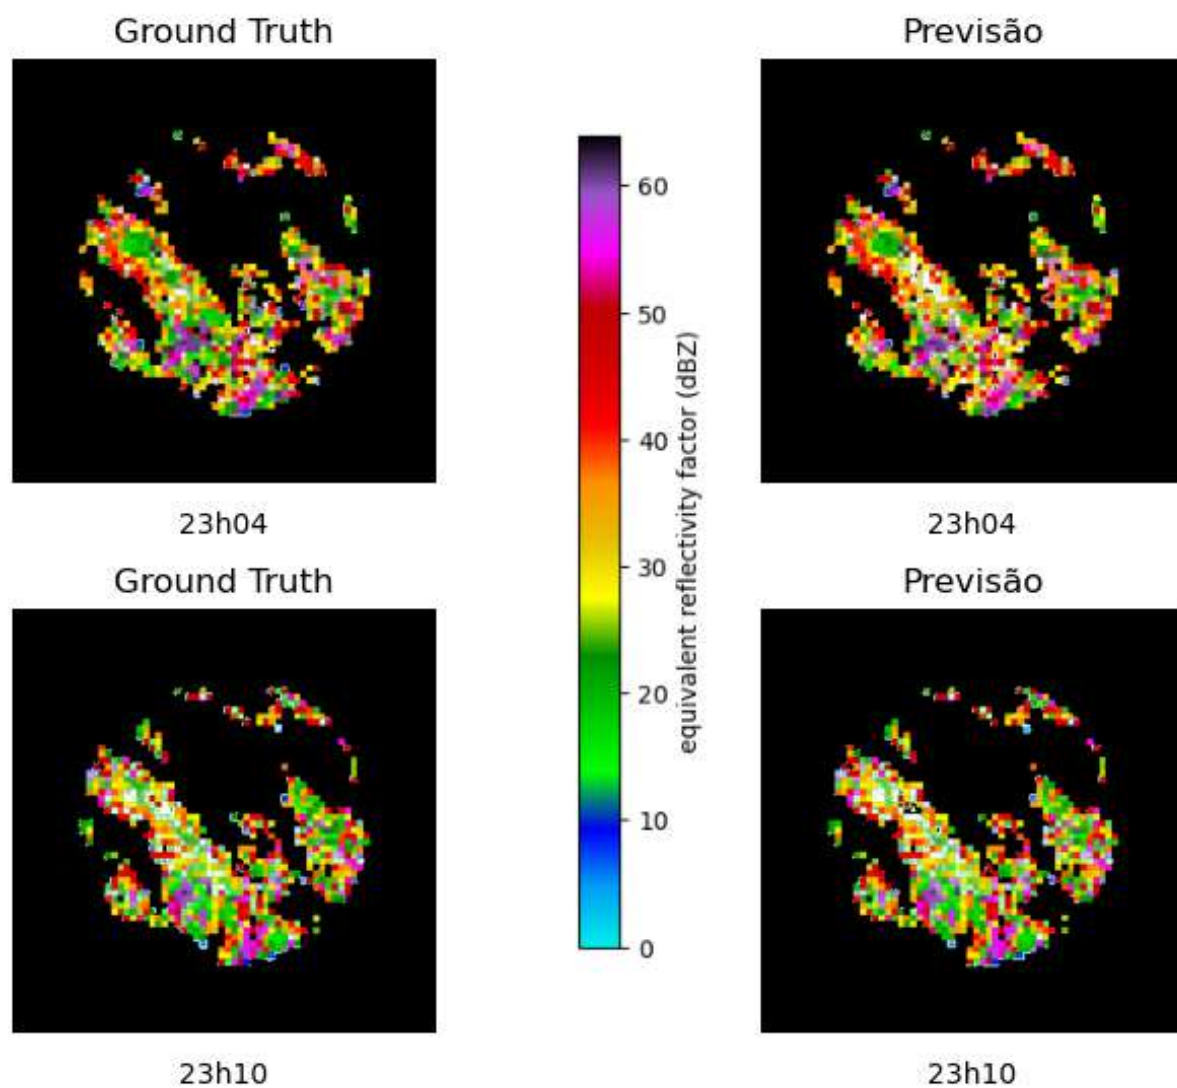


Figura 88 – Previsão das 23h04 e 23h10.

APÊNDICE D – Previsão dia - 21/04/2022 - Radar Chapecó




Figura 89 – Entrada do dia 21/04/2022 entre 12h26 e 13h20.

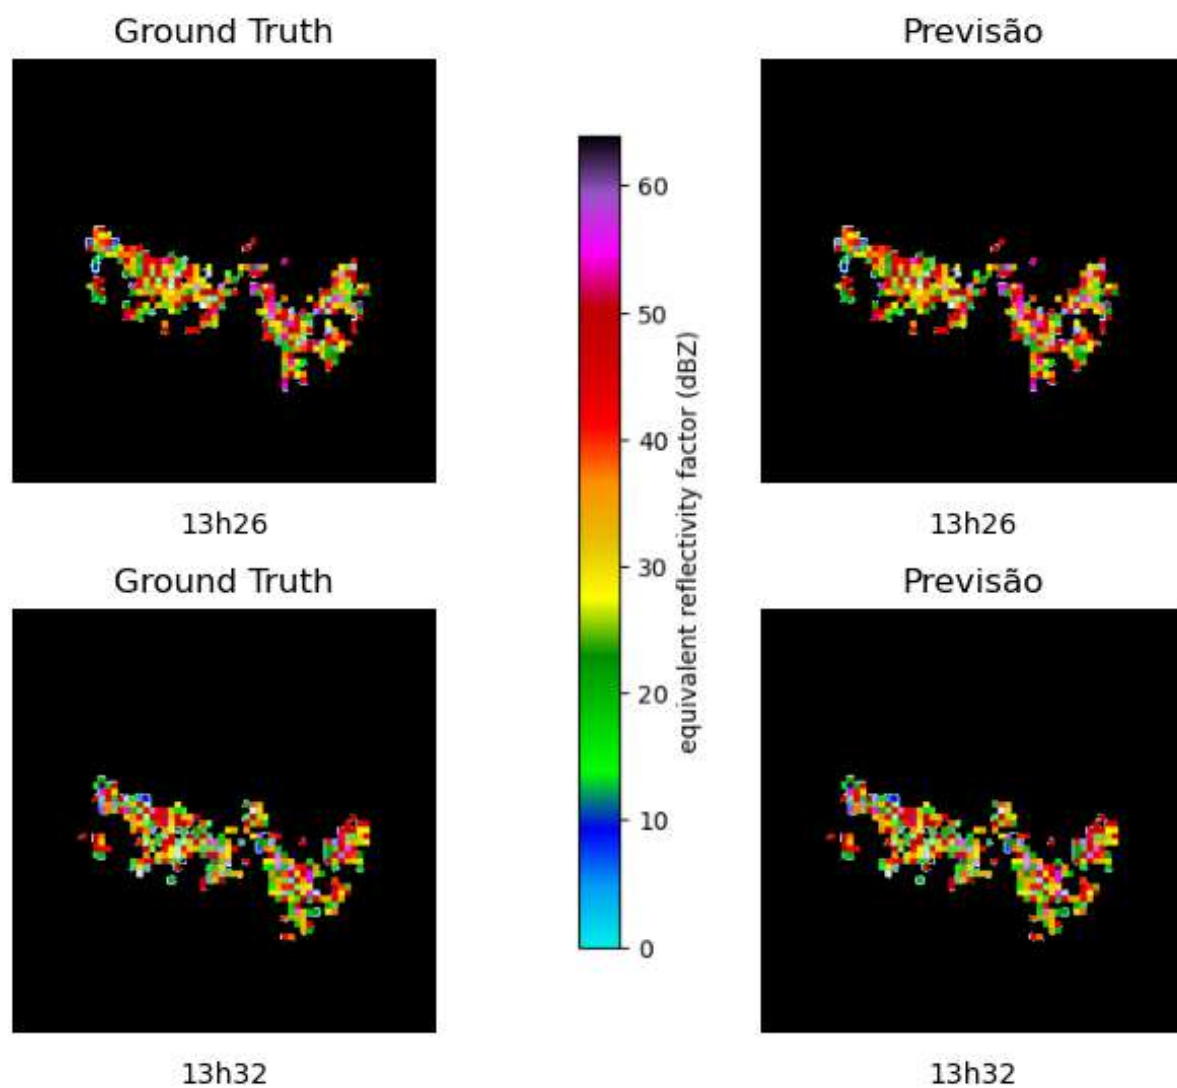


Figura 90 – Previsão das 13h26 e 13h32.

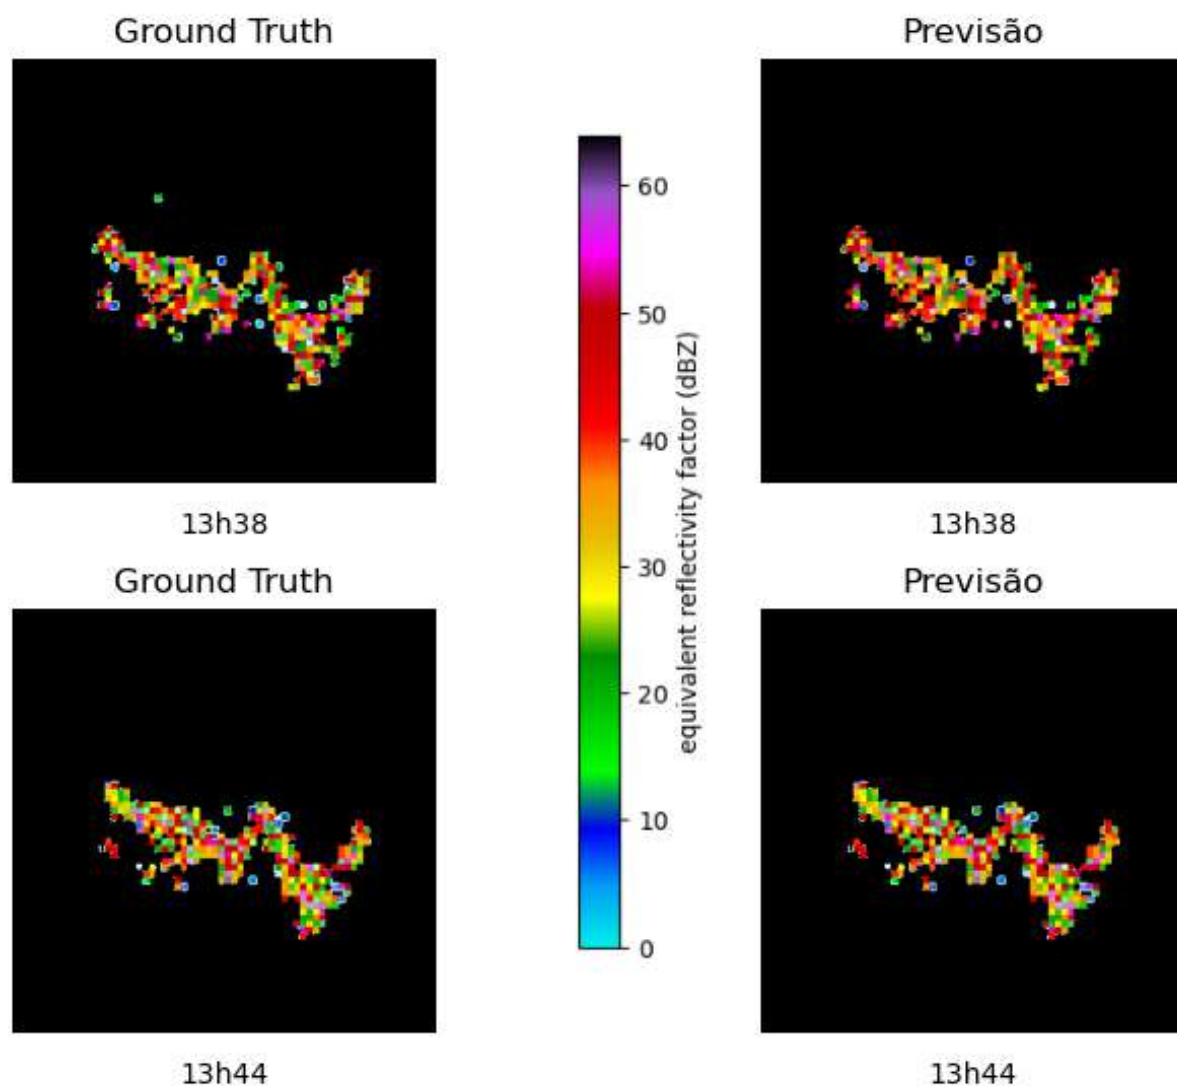


Figura 91 – Previsão das 13h38 e 13h44.

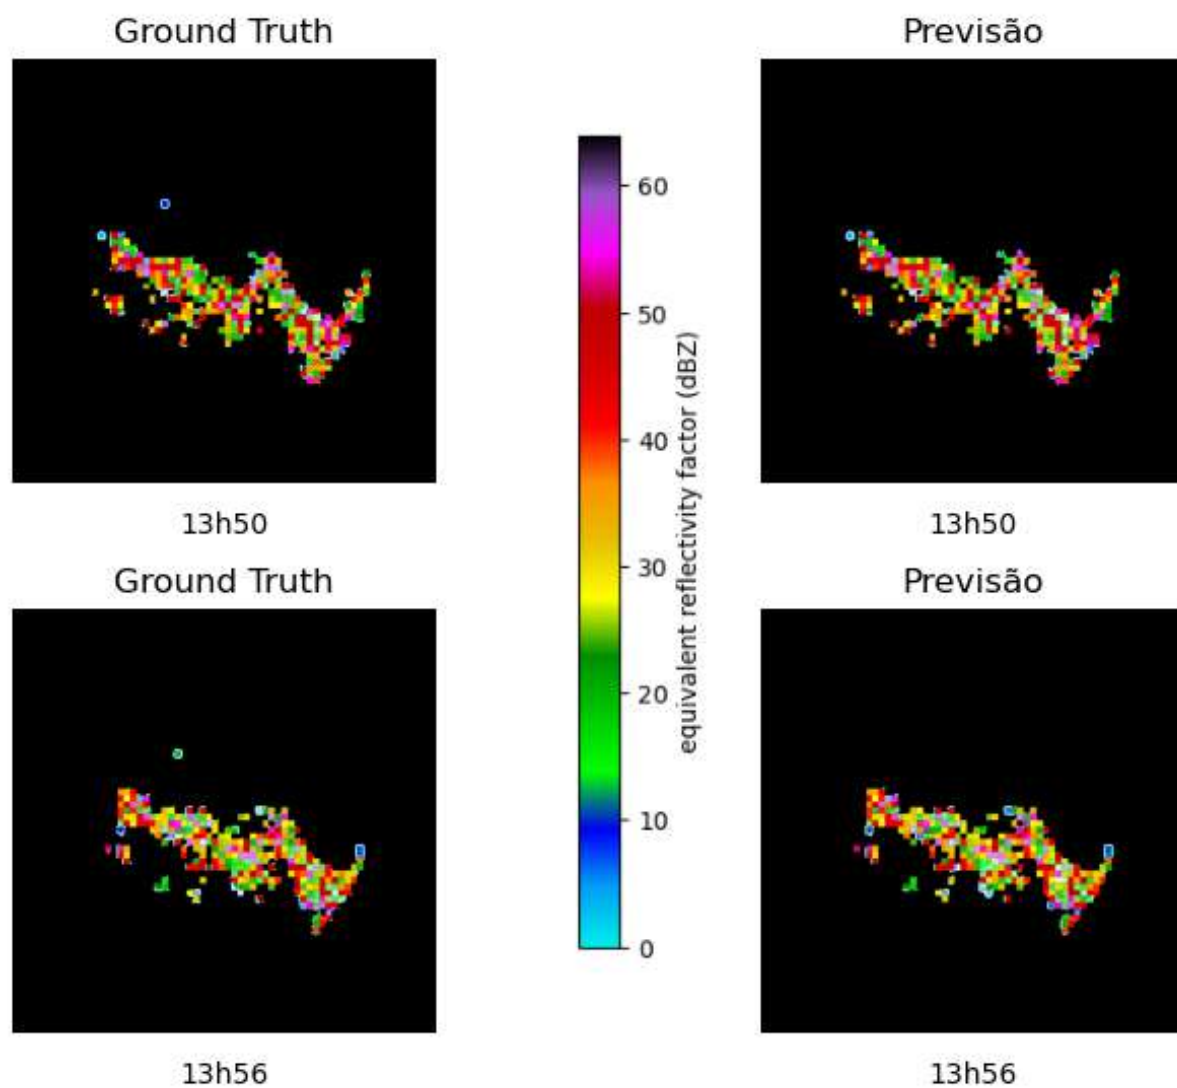


Figura 92 – Previsão das 13h50 e 13h56.

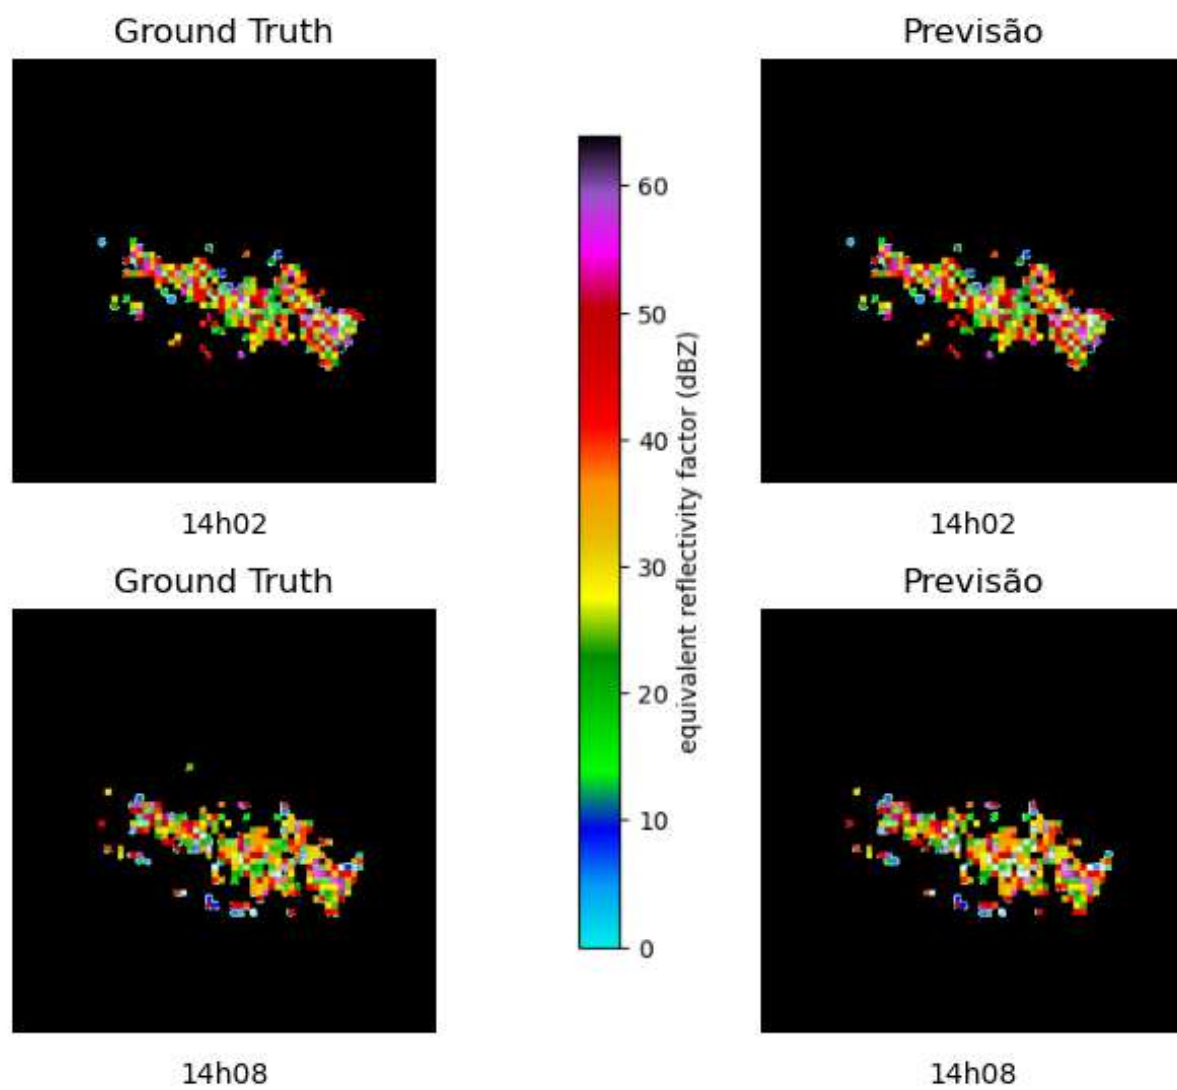


Figura 93 – Previsão das 14h02 e 14h08.




Figura 94 – Previsão das 14h14 e 14h20.

Entrada




Figura 95 – Entrada do dia 21/04/2022 entre 14h41 e 15h35.

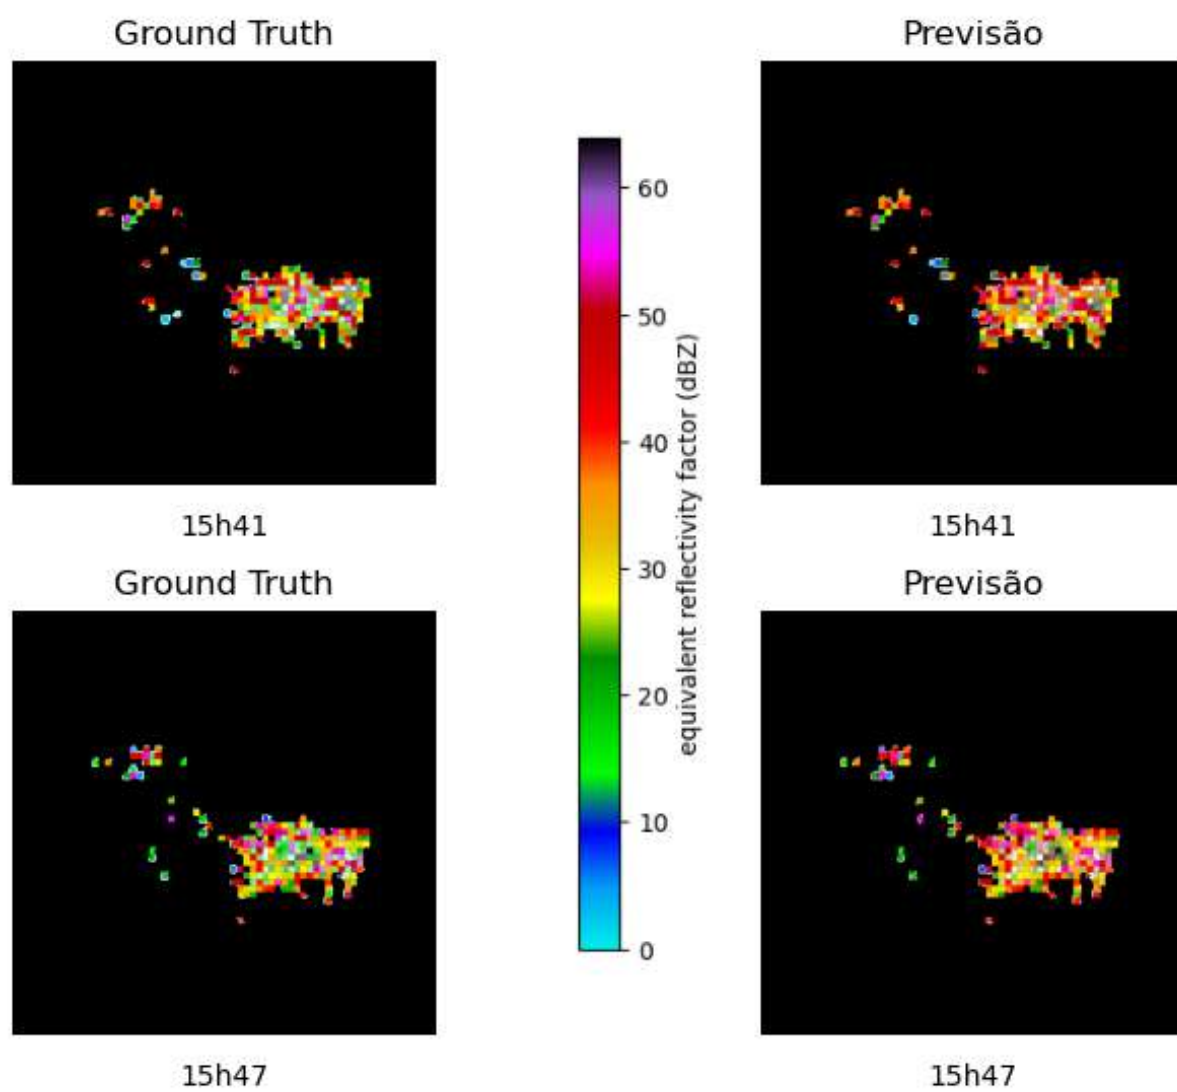


Figura 96 – Previsão das 15h41 e 15h47.

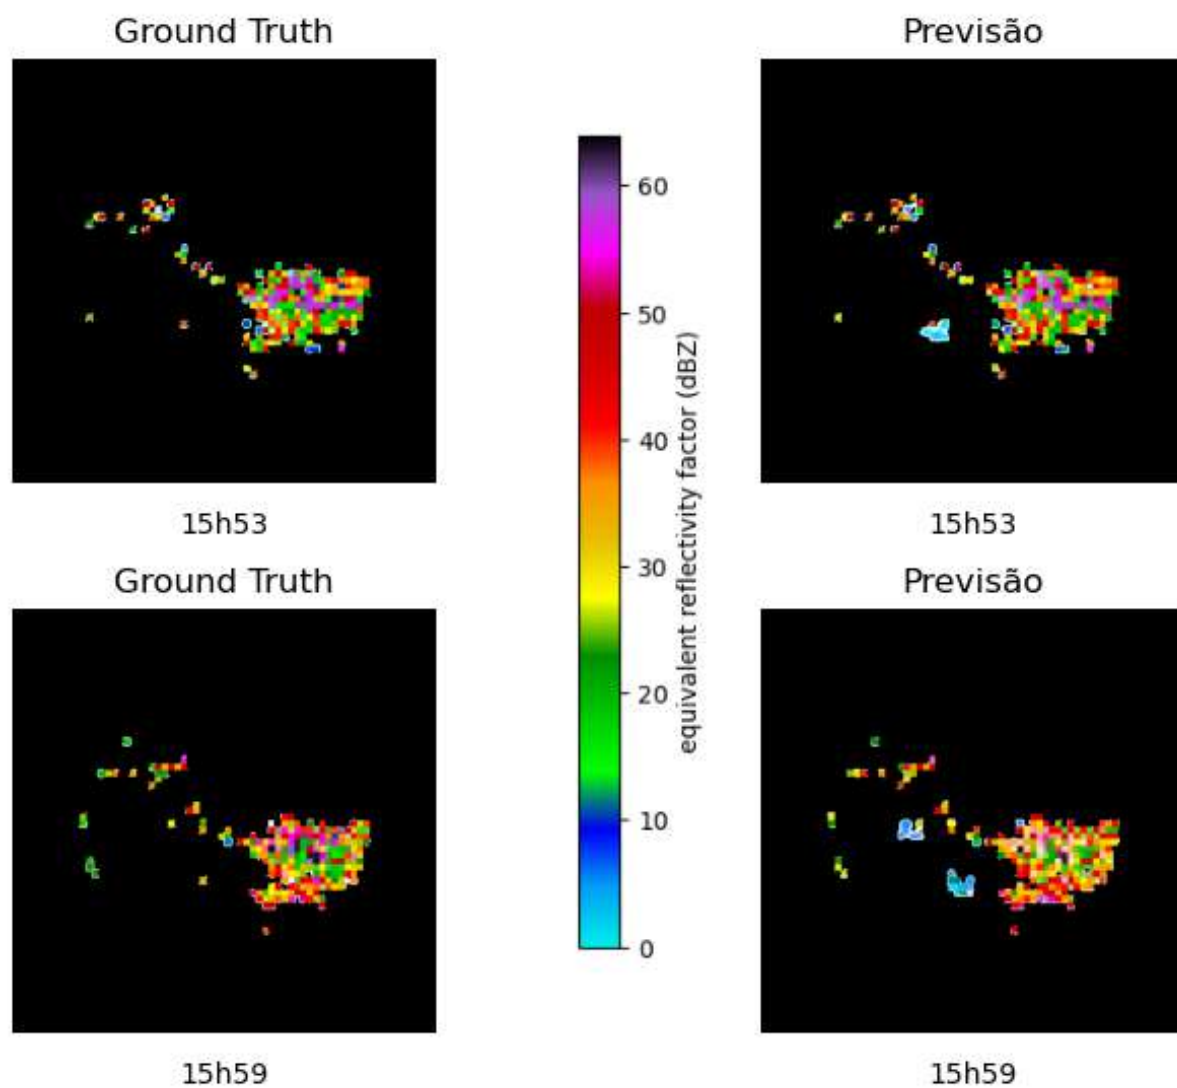


Figura 97 – Previsão das 15h53 e 15h59.

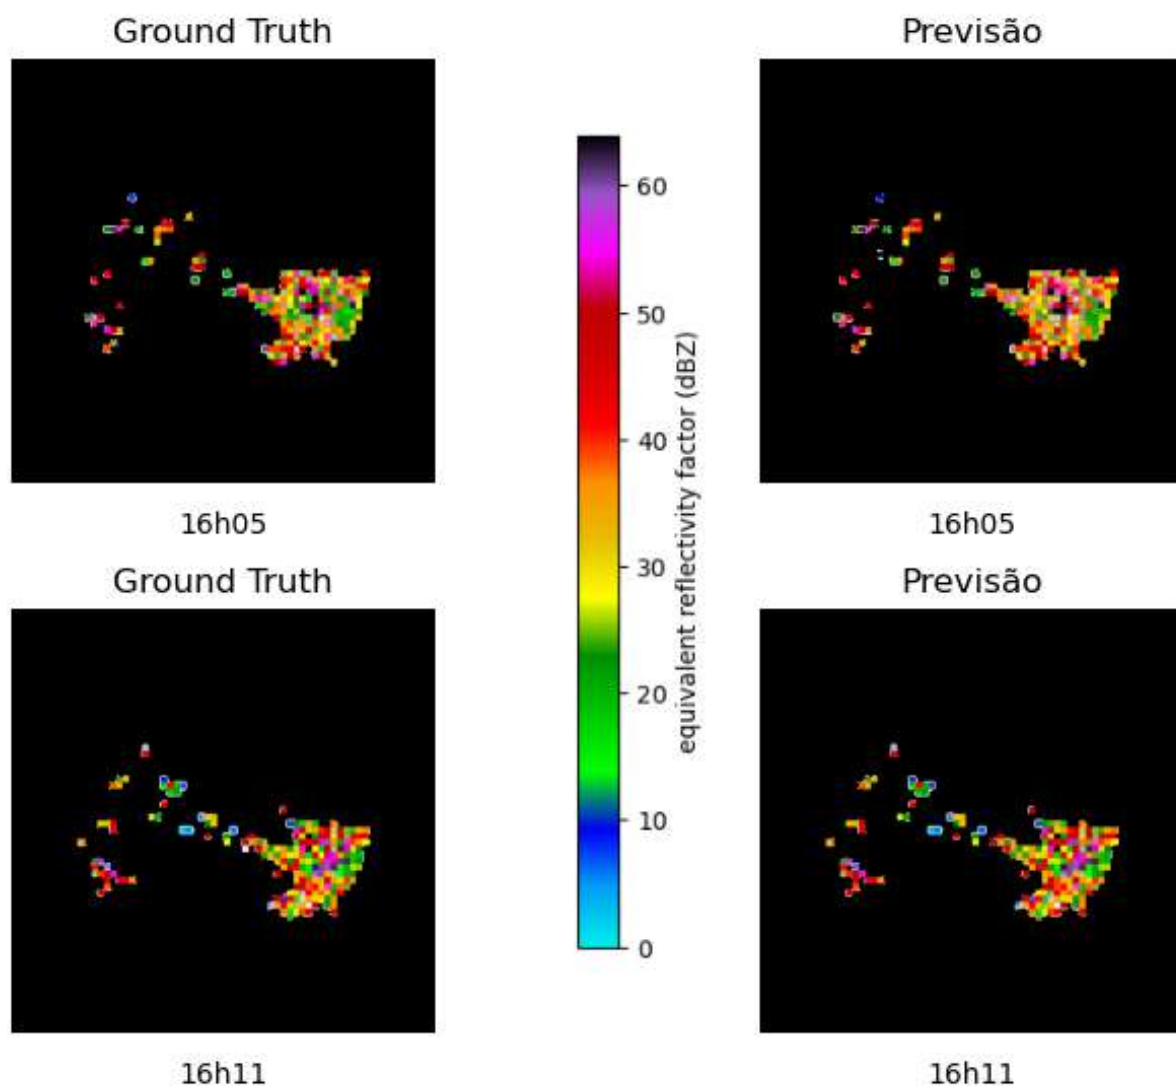


Figura 98 – Previsão das 16h05 e 16h11.

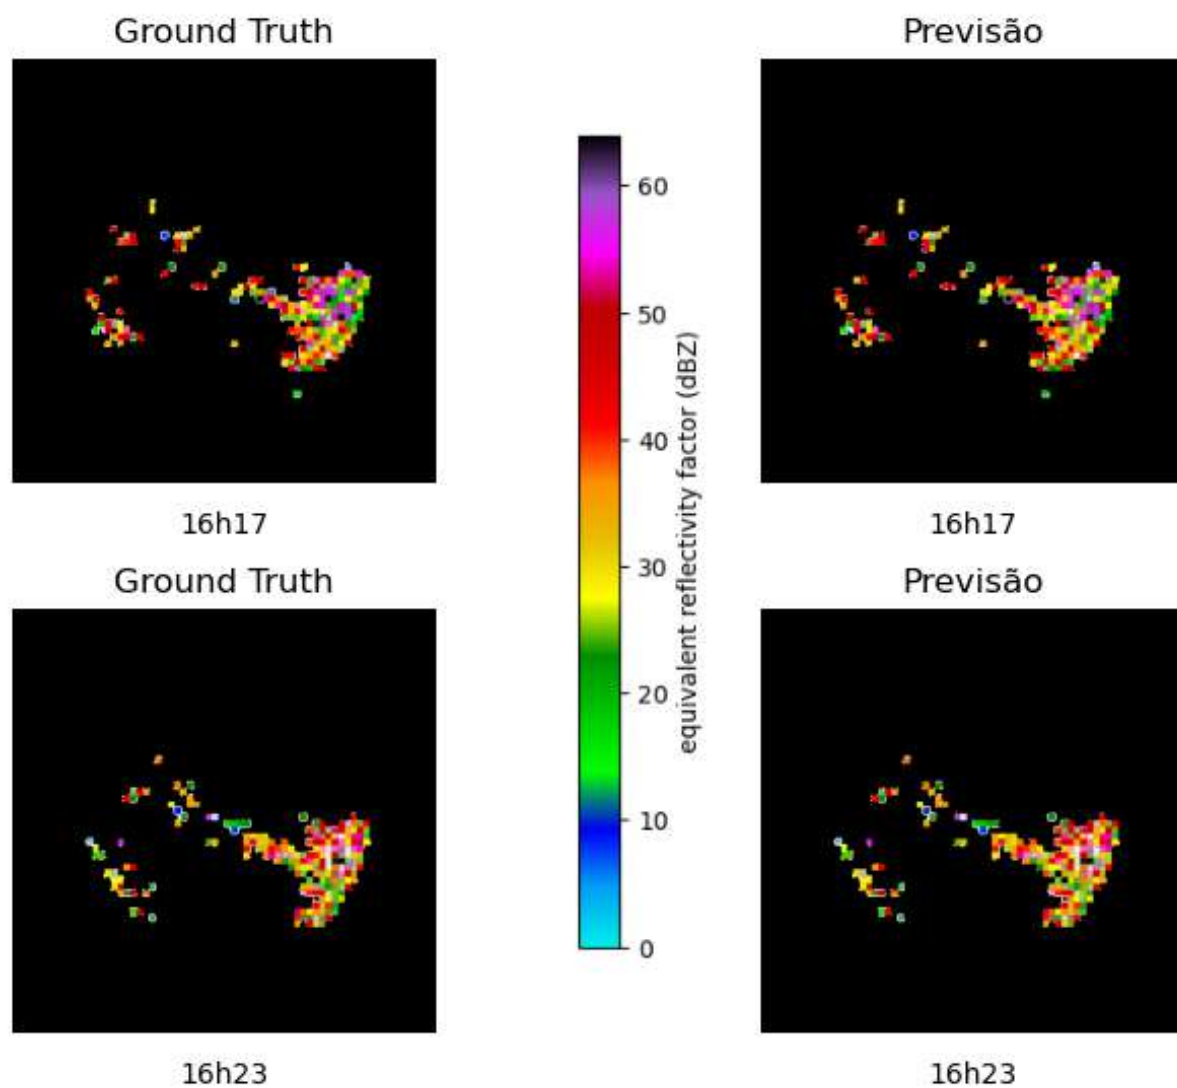


Figura 99 – Previsão das 16h17 e 16h23.

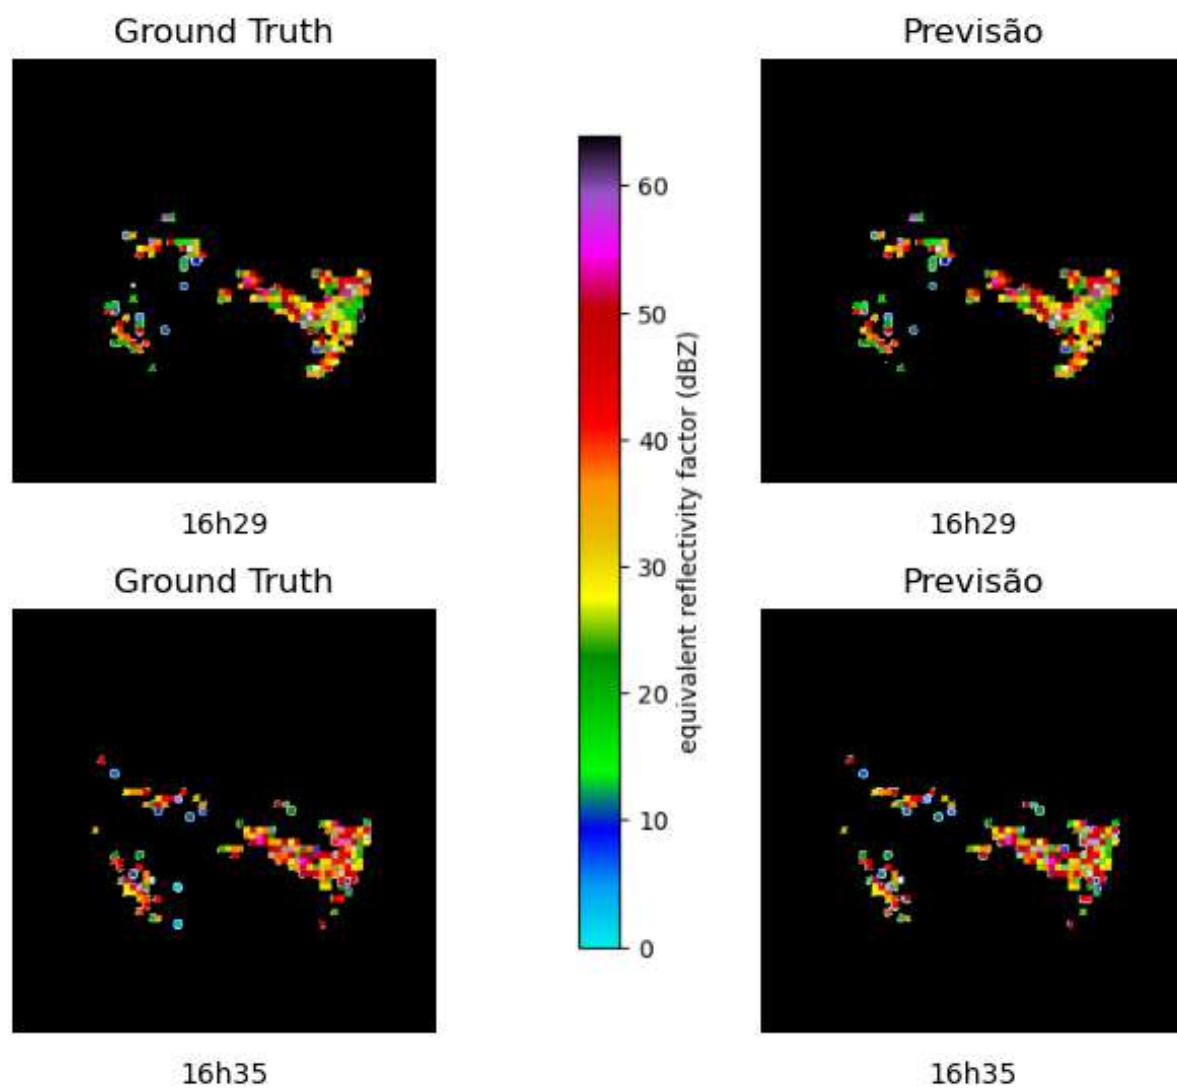


Figura 100 – Previsão das 16h29 e 16h35.

APÊNDICE E – Previsão dia - 17/08/2020 - Radar Morro da Igreja

Entrada




Figura 101 – Entrada do dia 17/08/2020 entre 19h24 e 20h18.




Figura 102 – Previsão das 20h24 e 20h30.




Figura 103 – Previsão das 20h36 e 20h42.




Figura 104 – Previsão das 20h48 e 20h54.




Figura 105 – Previsão das 21h00 e 21h06.




Figura 106 – Previsão das 21h12 e 21h18.

Entrada




Figura 107 – Entrada do dia 17/08/2020 entre 21h24 e 22h18.




Figura 108 – Previsão das 22h24 e 22h30.




Figura 109 – Previsão das 22h36 e 22h42.




Figura 110 – Previsão das 22h48 e 22h54.

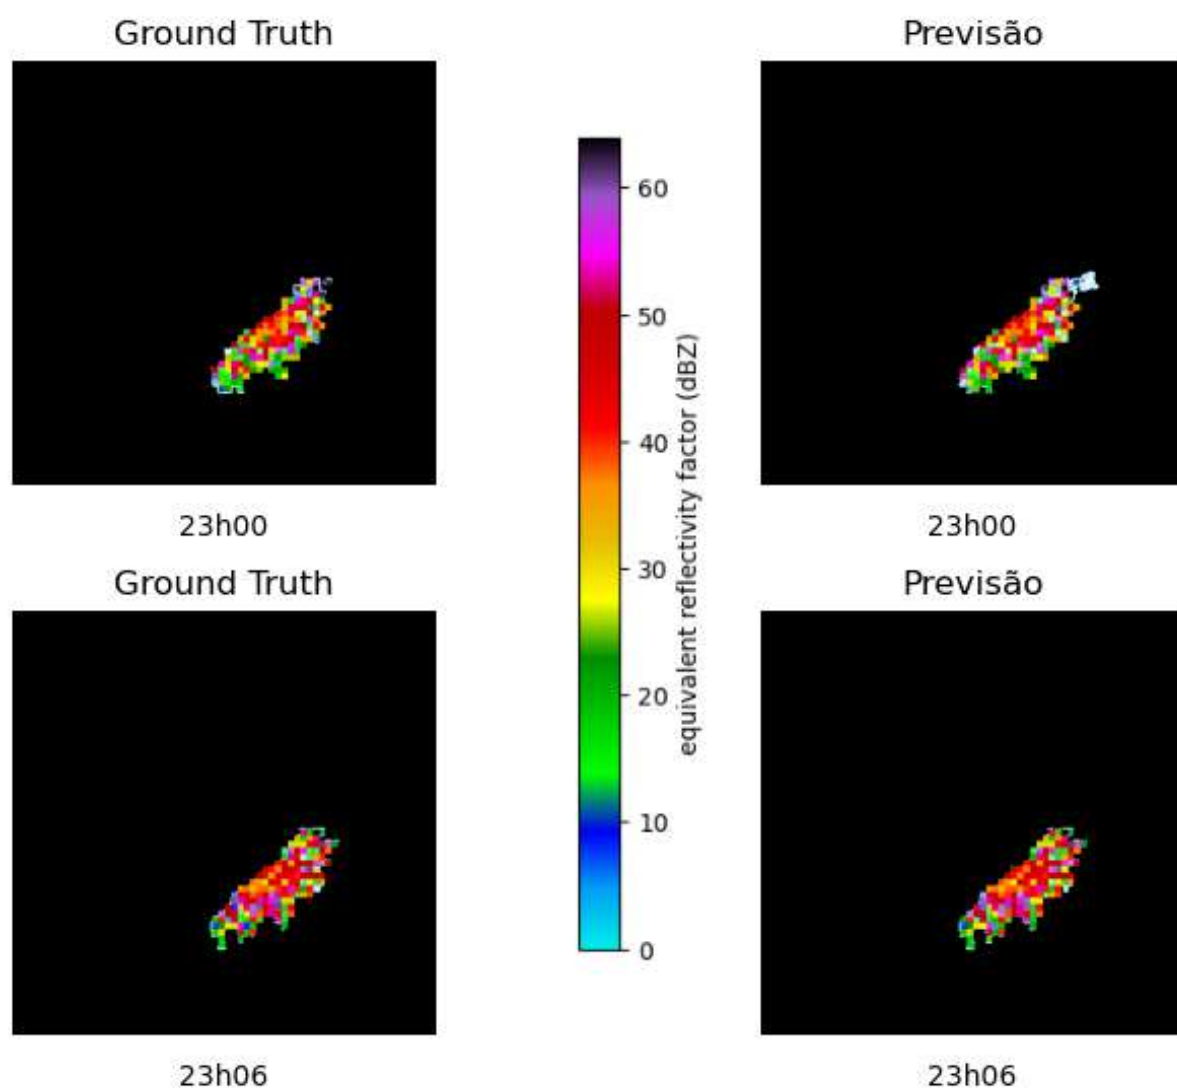


Figura 111 – Previsão das 23h00 e 23h06.




Figura 112 – Previsão das 23h12 e 23h18.