

UNIVERSIDADE DE PASSO FUNDO
INSTITUTO DE CIÊNCIAS EXATAS E GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM
COMPUTAÇÃO APLICADA

**Análise do impacto da utilização da
previsão do tempo corrigida pelo método
Model Output Calibration em modelos de
doenças da maçã**

Vanessa Lago Machado

Passo Fundo

2017

UNIVERSIDADE DE PASSO FUNDO
INSTITUTO DE CIÊNCIAS EXATAS E GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO APLICADA

**ANÁLISE DO IMPACTO DA
UTILIZAÇÃO DA PREVISÃO DO
TEMPO CORRIGIDA PELO MÉTODO
MODEL OUTPUT CALIBRATION EM
MODELOS DE DOENÇAS DA MAÇÃ**

Vanessa Lago Machado

Dissertação apresentada como requisito parcial
à obtenção do grau de Mestre em Computação
Aplicada na Universidade de Passo Fundo.

Orientador: Prof. Dr. Carlos Amaral Hölbig

Passo Fundo

2017

CIP – Catalogação na Publicação

M149a Machado, Vanessa Lago
Análise do impacto da utilização da previsão do tempo corrigida pelo método Model Output Calibration em modelos de doenças da maçã / Vanessa Lago Machado. – 2017.
67 f. : il. color. ; 30 cm.

Orientador: Prof. Dr. Carlos Amaral Hölbig.
Dissertação (Mestrado em Computação Aplicada) –
Universidade de Passo Fundo, 2017.

1. Simulação (Computadores) 2. Previsão numérica do tempo (Meteorologia). 3. Maçã - Doenças 4. Estatística matemática. I. Hölbig, Carlos Amaral, orientador. II. Título.

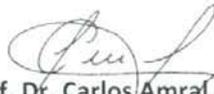
CDU: 004.414.23

Catalogação: Bibliotecário Luís Diego Dias de S. da Silva – CRB 10/2241

**ATA DE DEFESA DO
TRABALHO DE CONCLUSÃO DE CURSO DA ACADÊMICA**

Vanessa Lago Machado

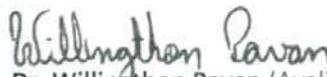
Aos **vinte e dois** dias do mês de **fevereiro** do ano dois mil e **dezessete**, às **quatorze** horas, realizou-se, no Instituto de Ciências Exatas e Geociências, prédio B5, da Universidade de Passo Fundo, a sessão pública de defesa do Trabalho de Conclusão de Curso "**Análise do impacto da utilização da previsão do tempo corrigida pelo método *Model Output Calibration* em modelos de doenças da maçã**", de autoria de **Vanessa Lago Machado**, acadêmica do Curso de Mestrado em Computação Aplicada do Programa de Pós-Graduação em Computação Aplicada – PPGCA/UPF. Segundo as informações prestadas pelo Conselho de Pós-Graduação e constantes nos arquivos da Secretaria do PPGCA, a aluna preencheu os requisitos necessários para submeter seu trabalho à avaliação. A banca examinadora foi composta pelos doutores **Carlos Amaral Hölbig (UPF) – orientador e presidente**, **Jorge Luis Gomes (CPTec/INPE)** e **Willingthon Pavan (UPF)**. Concluídos os trabalhos de apresentação e arguição, a banca examinadora considerou o(a) candidato(a) **APROVADO**. Foi concedido o prazo de até quarenta e cinco (45) dias, conforme Regimento do PPGCA, para o(a) acadêmico(a) apresentar ao Conselho de Pós-Graduação o trabalho em sua redação definitiva, a fim de que sejam feitos os encaminhamentos necessários à emissão do Diploma de Mestre em Computação Aplicada. Para constar, foi lavrada a presente ata, que vai assinada pelos membros da banca examinadora e pela Coordenação do PPGCA.



Prof. Dr. Carlos Amrãl Hölbig
Presidente da Banca Examinadora (Orientador)



Prof. Dr. Jorge Luis Gomes (Avaliador Externo)



Prof. Dr. Willingthon Pavan (Avaliador 2)



Prof. Dr. Carlos Amrãl Hölbig
Coordenador do PPGCA

Dedico este trabalho a Deus por sempre iluminar e acompanhar meu caminho, e a meus pais, Mário (*in memoriam*) e Sônia, que dedicaram suas vidas à criação dos filhos. Hoje, dedico minha vida e cada vitória a eles.

AGRADECIMENTOS

Primeiro gostaria de agradecer a Deus por sempre iluminar meu caminho mostrando que tudo tem seu tempo determinado.

Agradeço aos meus pais, Mário (*in memoriam*) e Sônia, por suas batalhas constantes pelo estudo e criação dos filhos. Agradeço meu esposo Marcos, pela paciência e apoio durante todo o percurso.

Agradeço a todos os professores do programa de Computação Aplicada (PPGCA) da UPF, em especial a meu orientador, Carlos A. Hölbig, por todo apoio e confiança a mim concebida. Agradeço também ao professor Willingthon Pavan, por todo apoio e fornecimento de dados para aplicação do estudo de caso.

Agradeço, também, ao INPE, em especial Jorge Luís Gomes e Chou Sin Chan, pelo fornecimento de dados e auxílio durante a pesquisa, tornando possível este trabalho.

“Descobrir consiste em olhar o que todo mundo
está vendo e pensar uma coisa diferente.”

(Roger Von Oech)

ANÁLISE DO IMPACTO DA UTILIZAÇÃO DA PREVISÃO DO TEMPO CORRIGIDA PELO MÉTODO MODEL OUTPUT CALIBRATION EM MODELOS DE DOENÇAS DA MAÇÃ

RESUMO

Os modelos de simulação servem, em geral, como ferramentas para auxiliar as diferentes áreas na previsão de resultados e, conseqüentemente, para uma tomada de decisão. Porém, muitas vezes, as simulações apresentam resultados que não refletem a realidade. Dentre as possíveis causas, encontram-se a qualidade dos dados de entrada, os quais podem conter imprecisões quando tratam-se de previsões. No caso dos modelos que simulam doenças na cultura da maçã, uma das fontes de dados é o gerado por modelos de previsão do tempo, os quais estão sujeitos a essas imprecisões. Ainda, verificou-se que esses dados de previsão do tempo podem ser aperfeiçoados (corrigidos) por meio de métodos estatísticos. Assim, percebeu-se que a melhora na qualidade desses dados poderia proporcionar uma conseqüente melhora no resultado final das simulações dos modelos de doenças. A fim de analisar o impacto da correção dos dados de entrada dos modelos de simulação, este trabalho utilizou o uso de seis modelos de doenças da cultura da maçã aplicados à cidade de Vacaria (RS), que utilizam entre os seus dados de entrada a previsão numérica do tempo (PNT) gerada pelo modelo regional Eta 15km do CPTEC/INPE. Assim, foi possível verificar a melhora na acurácia dos mesmos, comparando os dados previstos e os corrigidos em relação aos dados observados. Para realizar tal correção, utilizou-se o método estatístico Model Output Calibration (MOC) aplicado sobre as variáveis de temperatura e de umidade relativa. Os resultados da aplicação do MOC apresentaram uma correção satisfatória dos dados de PNT gerados para a cidade de Vacaria. Na avaliação dos resultados gerados pelos modelos epidemiológicos que preveem a ocorrência de algumas doenças na cultura da maçã, pôde-se observar que os resultados demonstraram-se satisfatórios, possibilitando auxiliar nas tomadas de decisões dos produtores e pesquisadores envolvidos com essa cultura.

Palavras-Chave: Correção estatística, Model Output Calibration, modelos de simulação, modelo Eta, previsão numérica do tempo.

IMPACT ANALYSIS OF THE USE OF THE FORECAST CORRECTED BY THE MODEL OUTPUT CALIBRATION ON MODELS OF APPLE DISEASES

ABSTRACT

Simulation models generally serve as tools to assist the different areas in predicting results and, consequently, in decision making. However, the simulations often present results that do not reflect reality. Among the possible causes are the quality of the input data, which may contain inaccuracies when it comes to forecasts. In the case of models that simulate diseases in apple culture, one of the data sources is those generated by weather forecast models, which are subject to these inaccuracies. An improvement in the quality of these data could lead to a consequent improvement in the final outcome of the disease model simulations as it has been found that these weather forecast data can be improved or corrected by statistical methods. This work aimed at the use of some models of diseases of the apple crop applied to the city of Vacaria (RS) that use among their input data the numerical weather prediction (NWP) generated by the regional model Eta 15km of CPTEC/INPE. The analysis of the impact on the final result of the simulation using the original Eta model prediction data in relation to these data corrected by a statistical model was the main objective of the study. In order to perform such correction or calibration the statistical method of model output calibration (MOC) applied on temperature and relative humidity variables was used. The results application of the MOC presented a satisfactory correction of the forecast generated for the city of Vacaria. And in the evaluation of the results generated by the epidemiological models that predict the occurrence of some diseases in the apple crop, the results of such analysis have proved to be satisfactory, making it possible to assist in the decision making of the producers and researchers involved with this crop.

Keywords: Statistic correction, Eta model, Model Output Calibration, numerical weather forecast, simulation models.

LISTA DE FIGURAS

Figura 1.	Modelo em ponto de grade.	18
Figura 2.	Fases do modelo de PNT.	19
Figura 3.	Sistema de Observação Global.	20
Figura 4.	Malha E Arakawa, em que H representa a variável de massa e V representa as componentes horizontais do vento	21
Figura 5.	Coordenadas verticais σ e η	21
Figura 6.	Diferenças entre o mundo real e o mundo simulado por modelos de previsão.	22
Figura 7.	Fluxo de calibração com MOC.	30
Figura 8.	Arquitetura do sistema projetado para coletar e armazenar dados meteorológicos reais e previstos para executar os modelos de simulação de previsão do risco de doenças no cultivo das maçãs.	37
Figura 9.	Fluxo da aplicação dos modelos de simulações relacionados as enfermidades do cultivo da maçã.	37
Figura 10.	Forma de coleta de dados.	39
Figura 11.	Ciclo diurno médio da temperatura do ar a 2m da atmosfera para cada um dos meses do período de teste	41
Figura 12.	Comparação da temperatura do ar com e sem ajuste sobre a correção realizada pelo MOC para a cidade de Vacaria durante o período de 1º a 15 de setembro de 2015.	42
Figura 13.	Ciclo diurno médio da umidade relativa do ar, dados mensais	43
Figura 14.	Comparação da umidade relativa do ar com e sem ajuste sobre a correção realizada pelo MOC para a cidade de Vacaria durante o período de 08 a 15 de setembro de 2015	44
Figura 15.	Análise geral da Mancha Foliar de Gala sob ambos os cenários (C2 e C3) em relação a diferença de horas das ocorrências identificadas em C1, sendo que na execução de C1 obteve 44 ocorrências.	47
Figura 16.	Análise individual da Mancha Foliar de Gala sob cada um dos cenários em relação as ocorrências de C1, sendo que na execução de C1 obteve 44 ocorrências.	48
Figura 17.	Análise geral da Podridão Branca sob ambos os cenários (C2 e C3) em relação a diferença de horas das ocorrências identificadas em C1, sendo que na execução de C1 obteve 45 ocorrências.	49
Figura 18.	Análise individual da Podridão Branca sob cada um dos cenários em relação as ocorrências de C1, sendo que na execução de C1 obteve 45 ocorrências.	50

Figura 19.	Análise geral da Podridão Olho de Boi (variedade da maçã Fuji) sob ambos os cenários (C2 e C3) em relação a diferença de horas das ocorrências identificadas em C1, sendo que na execução de C1 obteve 63 ocorrências.	51
Figura 20.	Análise individual da Podridão Olho de Boi (variedade da maçã Fuji) sob cada um dos cenários em relação as ocorrências de C1, sendo que na execução de C1 obteve 63 ocorrências.	52
Figura 21.	Análise geral da Podridão Olho de Boi (variedade da maçã Gala) sob ambos os cenários (C2 e C3) em relação a diferença de horas das ocorrências identificadas em C1, sendo que na execução de C1 obteve 35 ocorrências.	54
Figura 22.	Análise individual da Podridão Olho de Boi (variedade da maçã Gala) sob cada um dos cenários em relação as ocorrências de C1, sendo que na execução de C1 obteve 35 ocorrências.	54
Figura 23.	Análise geral da Podridão Olho de Boi (variedade da maçã Pink Lady) sob ambos os cenários (C2 e C3) em relação a diferença de horas das ocorrências identificadas em C1, sendo que na execução de C1 obteve 53 ocorrências.	56
Figura 24.	Análise individual da Podridão Olho de Boi (variedade da maçã Pink Lady) sob cada um dos cenários em relação as ocorrências de C1, sendo que na execução de C1 obteve 53 ocorrências.	56

LISTA DE TABELAS

Tabela 1.	Comparação entre os métodos de correção estatística	28
Tabela 2.	Média Diária da temperatura do ar (°C) observada, prevista pelo modelo Eta, corrigida pelo MOC e a correspondência das medidas estatísticas básicas do erro (BIAS, MAE e RMSE) para a cidade de Vacaria, nos meses do período de teste (Setembro de 2015 a Junho de 2016).	41
Tabela 3.	Média Diária da Umidade relativa do ar (%) observada, prevista pelo modelo Eta, corrigida pelo MOC e a correspondência das medidas estatísticas básicas do erro (BIAS, MAE e RMSE) para a cidade de Vacaria, nos meses do período de teste (Setembro de 2015 a Junho de 2016).	43
Tabela 4.	Skill Score dos erros BIAS, MAE e RMSE para a média diária da previsão de temperatura do ar e umidade relativa para o período do estudo de caso, para a cidade de Vacaria	45
Tabela 5.	Análise mensal da previsão de ocorrências da doença Mancha Foliar de Gala	48
Tabela 6.	Análise mensal da previsão de ocorrências da doença Podridão Branca	50
Tabela 7.	Análise mensal da previsão de ocorrências da doença Podridão 'Olho de Boi', variedade de maçã Fuji.	52
Tabela 8.	Análise mensal da previsão de ocorrências da doença Podridão 'Olho de Boi', variedade de maçã Gala	55
Tabela 9.	Análise mensal da previsão de ocorrências da doença Podridão 'Olho de Boi', variedade de maçã Pink Lady	57
Tabela 10.	Análise geral da previsão de ocorrências de enfermidades no cultivo de maçã	57
Tabela 11.	Análise da concentração da diferença de horas da identificação da ocorrência de enfermidades no cultivo da maçã em C2 e C3 em relação ao cenário com dados observados (C1).	58
Tabela 12.	Análise da tendência da identificação da ocorrência de enfermidades no cultivo da maçã em C2 e C3 em relação ao cenário com dados observados (C1). . . .	58

SUMÁRIO

1	INTRODUÇÃO	14
2	OBJETIVOS	16
2.1	OBJETIVO GERAL	16
2.2	OBJETIVOS ESPECÍFICOS	16
3	REVISÃO BIBLIOGRÁFICA: MODELOS DE SIMULAÇÃO	17
3.1	PREVISÃO NUMÉRICA DO TEMPO	17
3.1.1	Modelo Eta	20
3.2	MODELOS EPIDEMIOLÓGICOS APLICADOS A ÁREA AGRÍCOLA	22
3.2.1	Enfermidades da Cultura da Maçã	23
3.3	FORMAS DE CORREÇÃO ESTATÍSTICA	24
3.3.1	Kalman-Filter	24
3.3.2	Método da Analogia	25
3.3.3	Regressão Linear Multivariada	25
3.4	MÉTODOS DE CORREÇÃO ESTATÍSTICA DOS MODELOS DE PNT	26
3.4.1	Perfect Prognosis Method (PPM)	26
3.4.2	Model Output Statistics (MOS)	26
3.4.3	Extended Kalman Filter (EKF)	27
3.4.4	Model Outputing Calibration (MOC)	27
3.4.5	Comparação entre os Métodos	27
3.5	MODEL OUTPUT CALIBRATION (MOC)	28
3.5.1	Seleção de Preditores	30
3.5.2	Características	31
3.5.3	Aplicações do MOC sob modelos de circulação	31
4	METODOLOGIA	34
4.1	ANÁLISE DOS DADOS DE PNT	34
4.2	ESTUDO DE CASO	35
4.2.1	Sisalert: Sistema de monitoramento e alertas das doenças presentes na cultura da Maçã	36
4.2.2	Cenário do Estudo de Caso	38
4.2.2.1	Ajustes dos dados	38

4.2.2.2	Conjunto de dados para as simulações	39
5	ANÁLISE DA CORREÇÃO DOS DADOS DE PNT PARA VACARIA - RS	40
5.1	CORREÇÃO DA VARIÁVEL TEMPERATURA	40
5.2	CORREÇÃO DA VARIÁVEL UMIDADE RELATIVA	42
6	RESULTADOS ENCONTRADOS	46
6.1	MODELO DA MANCHA FOLIAR DA VARIEDADE DE MAÇÃ GALA	46
6.2	MODELO DA PODRIDÃO BRANCA	48
6.3	MODELO DA PODRIDÃO OLHO DE BOI, VARIEDADE DE MAÇÃ FUJI	51
6.4	MODELO DA PODRIDÃO OLHO DE BOI, VARIEDADE DA MAÇÃ GALA	53
6.5	MODELO DA PODRIDÃO OLHO DE BOI, VARIEDADE DE MAÇÃ PINK LADY	55
6.6	CONSTATAÇÕES E PERCEPÇÕES GERAIS	57
7	CONSIDERAÇÕES FINAIS	59
7.1	DISSEMINAÇÃO DO CONHECIMENTO	60
7.2	TRABALHOS FUTUROS	60
	REFERÊNCIAS	62

1. INTRODUÇÃO

Concomitante à evolução tecnológica, verificou-se o avanço das técnicas de estimativa de dados, como modelos de previsão, os quais, em geral, são utilizados como ferramentas nas tomadas de decisões. Percebe-se, com isso, que essas simulações representam, cada vez mais, situações próximas da realidade. Entretanto, os resultados gerados apresentam, na verdade, uma simplificação do problema e, por isso, estão sujeitos a incertezas ou imprecisões. Essas imprecisões, que impactam em seu resultado final, podem ser ocasionadas pela própria estrutura e organização do modelo de simulação ou por fatores externos a ele, como por exemplo, pela qualidade de seus dados de entrada.

Esses dados de entrada, muitas vezes, são gerados por outros modelos de simulação, visto que o objetivo é prever informações. Como exemplo disso, verifica-se que muitos modelos de simulação utilizam a previsão numérica do tempo (PNT) como dados de entrada, assim como é o caso de modelos agrícolas (de culturas e de doenças) ou de geração de energia.

Como exemplo desses dados de entrada, pode-se citar os modelos de circulação, os quais demonstram "de forma qualitativa e quantitativa, o funcionamento do sistema climático terrestre" [1], e são utilizados como ferramentas nas tomadas de decisões. Dentre esses modelos encontram-se os modelos de PNT.

Ao se referir a modelos de PNT, muitos fatores podem influenciar os dados das previsões, como: a densidade dos dados, o método de assimilação de dados, o modelo numérico, a topografia da região, o regime meteorológico (verão ou inverno), etc. Além disso, existem algumas dificuldades nos trópicos que também implicam em incertezas sobre os resultados dos dados gerados, como a dificuldade de representar os processos físicos que ocorrem, como por exemplo, turbulência, convecção, radiação, etc.

Considerando que as variáveis de PNT estão sujeitas a interferências devido às ocorrências de mudanças no estado do tempo que o modelo não conseguiu capturar, e tendo em vista a grande influência desses dados sobre outros modelos de simulação, como, por exemplo, nos modelos agrícolas, os resultados dos modelos derivados desses dados podem ser superestimados ou subestimados, não refletindo a realidade.

Muitos modelos de simulação na área agrícola utilizam como variáveis de entrada os dados de PNT, com o objetivo de prever o crescimento e ocorrência de doenças nas diferentes culturas. Ainda, ao prever uma doença de determinada cultura, muitas vezes os dados possuem grande índice de imprecisão, visto que uma informação incorreta gerada pelo modelo pode resultar em uma perda parcial ou total do cultivo.

Devido a esses fatos torna-se necessário o uso de ferramentas que possibilitem prever cenários que reflitam a realidade apresentada, sendo que uma das alternativas possíveis é a de melhorar os dados providos dos modelos de circulação, factível por meio da aplicação de técnicas de correção estatística. Assim, considerando os fatores apresentados, percebe-se que a melhora dos dados

dos modelos de PNT, por meio da correção estatística, pode contribuir de forma significativa para a melhora nos cenários previstos por modelos derivados.

Tendo em vista a falta de informações sobre o grau de incertezas nos modelos de circulação, o presente trabalho possui como objetivo analisar o impacto do uso da previsão do tempo corrigida em modelos de simulação de doenças na cultura da maçã, aplicados à cidade de Vacaria (RS).

Assim, um estudo de caso foi aplicado sobre a previsão da ocorrência de seis doenças na cultura da maçã e a análise de três cenários que utilizam como condição inicial do modelo de previsão de doenças os diferentes dados de PNT, sendo eles: os dados observados, obtidos por meio de estações automáticas; dados previstos pelo modelo regional de PNT Eta, em grades de 15Km; e, dados gerados pelo Eta com a correção por meio do método Model Output Calibration (MOC).

Com base nos problemas expostos, e para a melhor compreensão das informações, o presente trabalho encontra-se organizado da seguinte forma: no capítulo 2 são descritos os objetivos deste trabalho (geral e específicos); no capítulo 3 apresenta-se o referencial teórico, que contextualiza os conceitos de modelos de simulação, os modelos atmosféricos, os modelos epidemiológicos aplicados a área agrícola, as formas e os métodos de correção estatística de modelos de simulação, além de um detalhamento do método de correção estatística MOC; no capítulo 4 é detalhada a metodologia utilizada para avaliação da correção dos dados de PNT, assim como a definição do estudo de caso, seus ajustes e forma de execução para análise; no capítulo 5 são detalhados os resultados da correção dos dados de PNT para a cidade de Vacaria; no capítulo 6 são apresentados os resultados gerados pelas análises do estudo de caso; e, no capítulo 7, são abordadas as considerações finais, bem como a disseminação do conhecimento e os trabalhos futuros que podem ser originados por esta pesquisa.

2. OBJETIVOS

2.1 OBJETIVO GERAL

Analisar o impacto do uso da previsão do tempo corrigida em modelos de simulação de doenças da cultura da maçã aplicados à cidade de Vacaria (RS).

2.2 OBJETIVOS ESPECÍFICOS

- Corrigir o resultado gerado pelo modelo de simulação da previsão numérica do tempo Eta para a cidade de Vacaria (RS);
- Utilizar os dados de previsão corrigidos como variáveis de entrada nos modelos de simulação de seis doenças na cultura da maçã;
- Analisar o impacto dos resultados obtidos nos modelos de simulação com a utilização da correção dos dados do Eta em comparação com dados originais gerados pelo Eta, sem correção.

3. REVISÃO BIBLIOGRÁFICA: MODELOS DE SIMULAÇÃO

Modelos de simulação podem ser definidos como uma abstração da realidade, aproximando-se do comportamento real, o qual permite entender sua funcionalidade ou até mesmo prever determinadas possibilidades, ou seja, por meio desses modelos de simulação tornam-se possíveis estudos sobre dados que ainda não existem, permitindo tomar decisões necessárias antes que as mudanças físicas ocorram realmente.

O termo simulação pode ser classificado em duas categorias: simulação computacional e simulação não computacional [2]. A simulação computacional, como o nome sugere, trata-se da simulação que possui uma determinada complexidade e, conseqüentemente, sua execução na forma não computacional torna-se inviável.

A simulação computacional pode ser classificada em três categorias básicas: simulação de "Monte Carlo", a qual utiliza valores aleatórios para simulação de sistemas físicos e matemáticos, no qual o tempo é simplesmente uma variável do modelo; simulação contínua, a qual considera a mudança de estado do sistema ao longo do tempo, considerando que o estado do sistema varia continuamente no tempo; e simulação discreta, a qual considera, também, a mudança do estado do sistema ao longo do tempo, porém considerando que as mudanças do estado do sistema ocorrem em momentos discretos no tempo, considerando a ocorrência de eventos [2]. Neste trabalho será utilizado a simulação computacional de eventos discretos.

3.1 PREVISÃO NUMÉRICA DO TEMPO

De acordo com o INPE [3], modelos atmosféricos podem ser definidos como modelos capazes de reproduzir condições e características da atmosfera por meio de equações matemáticas, como campos de vento, temperatura, pressão, precipitação, etc. Nesses modelos a atmosfera recebe influência do oceano e da superfície terrestre, no qual os modelos "usam leis físicas básicas para simular ou prever condições futuras da atmosfera" [3]. Estes modelos são conhecidos como modelos de previsão numérica do tempo (PNT), usados para experimentos e previsão de tempo e clima.

Por volta de 1904, Vihelm Bjerknes propôs um sistema de sete equações primitivas representadas por mapas sinóticos [4]. De acordo com Tomé [5], em 1919 Bjerknes sugeriu que a previsão do tempo fosse vista como um problema de condições iniciais, assim, sabendo o estado atual da atmosfera e as equações matemáticas que governam o movimento, seria possível prever movimentos atmosféricos de grande escala daquele ponto em diante.

Em 1922 Lewis Fry Richardson desenvolveu o primeiro sistema de PNT, com base na solução proposta por Bjerknes, porém a resolução das equações matemáticas necessárias mostrou-se irrealista, pois uma previsão de apenas 8 horas levaria 6 semanas para ser completada. Assim, somente com o surgimento do primeiro computador (ENIAC), a técnica tornou-se viável [6].

Para que os modelos de PNT tornem-se exequíveis, existem dois tipos de modelos: modelos em ponto de grade, os quais utilizam diferenças finitas; e, modelos espectrais, os quais usam funções harmônicas esféricas. Ambos os tipos de modelos representam a atmosfera baseados na resolução horizontal e nos níveis verticais, em que a resolução horizontal refere-se à distância entre dois pontos de grade ou a distância da menor onda (modelos espectrais), e os níveis verticais referem-se à distribuição dos níveis na vertical [3].

Neste trabalho será abordado o modelo em ponto de grade (Figura 1), o qual é definido por caixas de grades horizontais e níveis verticais. Assim, pressupõem-se que a atmosfera seja homogênea em cada uma dessas caixas, sendo necessário conhecer os dados de um ponto por caixa [7].

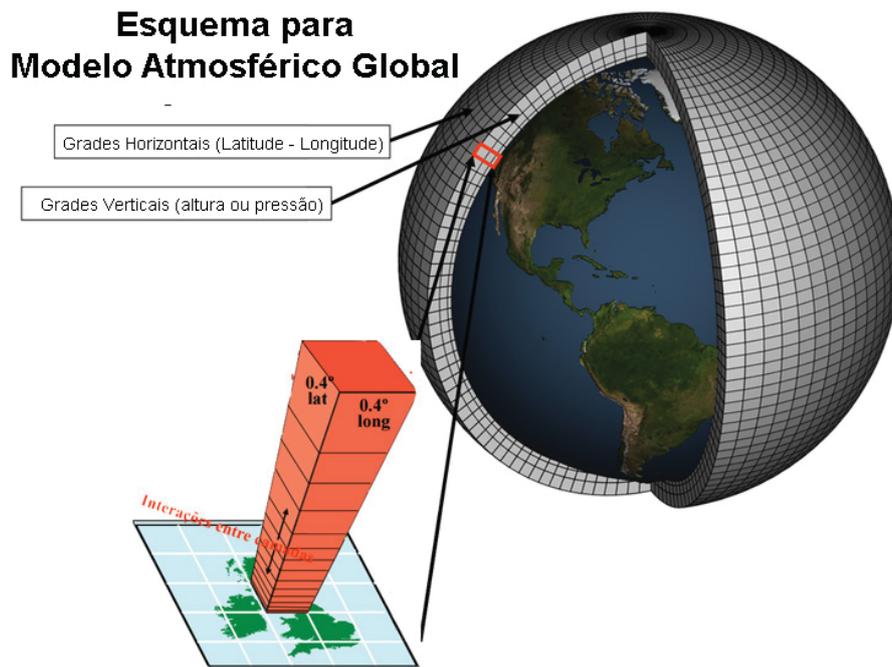


Figura 1. Modelo em ponto de grade.
Fonte: Adaptações de Chou [7] e UNIST [8].

Os modelos de PNT dividem-se em modelos globais e regionais (de área limitada), sendo que os modelos globais referem-se a equações relacionadas sobre todo o globo terrestre, conhecidos também como modelos climáticos globais ou modelo geral de circulação [8]. Esses modelos utilizam dados relacionados a fenômenos que ocorrem em todo o globo, sem considerar peculiaridades de cada região, o que os diferem dos modelos regionais [9].

O modelo regional possui "aplicação semelhante aos modelos globais, mas com resolução maior sobre uma área limitada de interesse" [7], ou seja, o modelo de área limitada se propõe a complementar e a aumentar o detalhamento do modelo global sobre uma área de interesse [4]. Ainda, de acordo com Chou [7], existe um submodelo dos modelos regionais, modelo de mesoescala, o qual "acrescenta detalhes aos padrões de escala sinótica previsto no modelo regional". Como exemplo do modelo mesoescala, é possível citar o modelo Brazilian developments on the *Regional Atmospheric Modelling System* (BRAMS), baseado no modelo *Regional Atmospheric Modelling System* (RAMS) [10].

Os modelos de área limitada (regionais ou mesoescala) utilizam condições de contorno derivadas de um modelo de área maior, normalmente derivados da previsão de um modelo global [11]. A condição de contorno "objetiva minimizar a reflexão de informações indesejáveis para dentro do domínio do modelo." [12].

Para resolução das operacionalidades dos modelos de PNT, são necessárias algumas fases (Figura 2), dentre as quais verifica-se que as fases que antecedem a execução do modelo tratam-se da obtenção dos dados observados para cada área e a primeira aproximação (*First Guess*), nesse caso previsão de 6 ou 12 horas do modelo. Assim, com base nessas informações, é realizada a assimilação dos dados, em que gera uma análise sobre um domínio que cobre a área de execução do modelo em que ocorre a verificação da acurácia dos dados e interpolação das observações, fornecendo assim a condição inicial do modelo. Na fase do modelo numérico ocorre a modelagem da previsão, levando em consideração a condição inicial e as condições de contorno lateral. Por fim, as fases que procedem a execução do modelo, conhecidas como pós-processamento, tratam da binarização dos dados para armazenamento e utilização (tal fato encontra-se ilustrado na Figura 2).

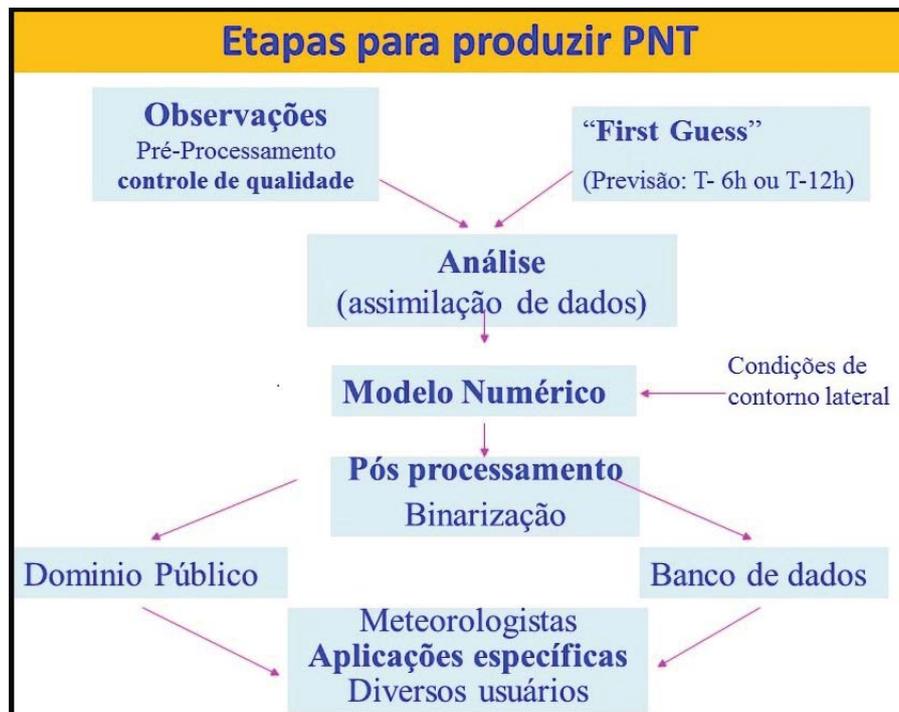


Figura 2. Fases do modelo de PNT.
Fonte: INPE [4].

Os dados observados são derivados de diversos instrumentos e diferentes ambientes. As principais fontes de derivação desses dados são: estações meteorológicas, estações de superfície, aeroportos, navios, aviões, satélites e radares. Formando, assim, um sistema de observação global, conforme ilustrado na Figura 3.

Em conformidade com University Corporation for Atmospheric Research [13], esses instrumentos encontram-se divididos em 3 classes principais: Classe 1, na qual se encontram instrumentos que analisam a medição em um determinado ponto específico, logo, estes ocupam um pequeno vo-

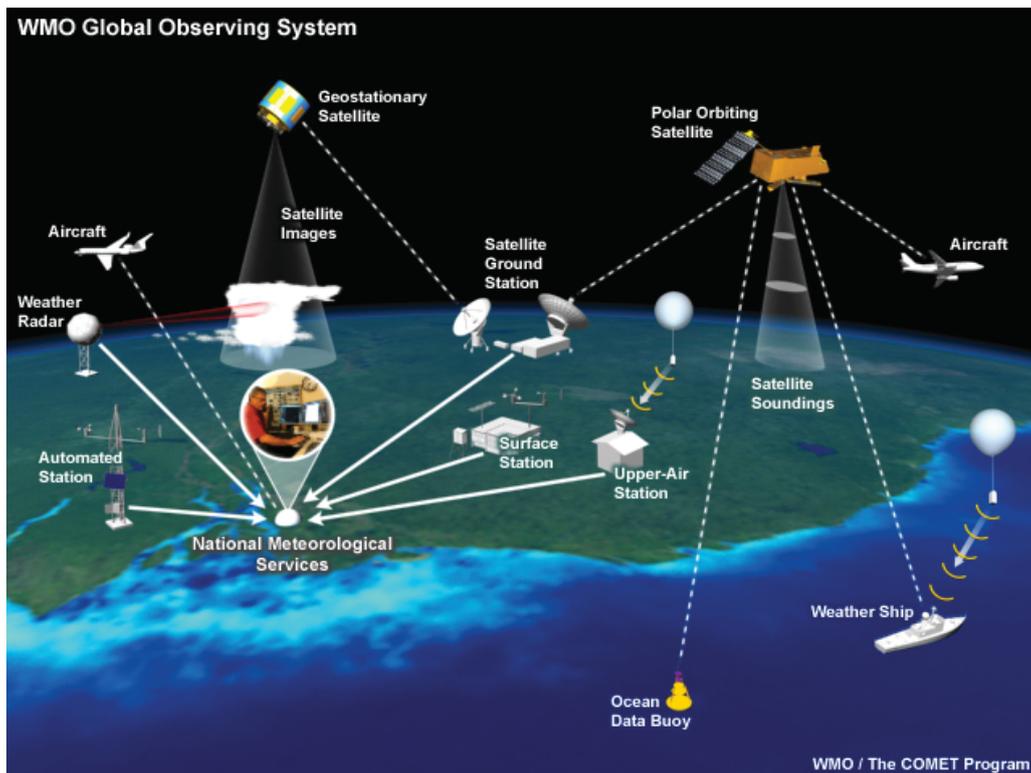


Figura 3. Sistema de Observação Global.

Fonte: University Corporation for Atmospheric Research [13].

lume (ex: estações de superfície); Classe 2 são os instrumentos que realizam medida de uma determinada área (ex: instrumentos como satélites e radar); e a Classe 3 são os instrumentos que medem variáveis não pontuais, como velocidade do vento (ex: satélite).

Para fins desta pesquisa, o modelo de PNT utilizado foi o modelo Eta, o qual encontra-se descrito na próxima seção.

3.1.1 Modelo Eta

O modelo Eta possui como objetivo a previsão de fenômenos atmosféricos usado para pesquisas e decisões operacionais. Sua estrutura é formada por grades horizontais (estruturas de grade do tipo E de Arakawa, conforme Figura 4) e coordenadas verticais η .

Em relação às coordenadas verticais do modelo Eta, é utilizada a coordenada η (eta), o que justifica sua nomenclatura e sua estrutura possui 38 camadas verticais, em que a maior resolução encontra-se nos níveis mais baixos, a qual diminui na proporção que a altura aumenta [14].

A coordenada η trata-se de uma extensão da coordenada σ , na qual a coordenada σ segue a superfície do terreno e a coordenada η transforma essas áreas em superfícies que são aproximadamente horizontais (Figura 5) [4].

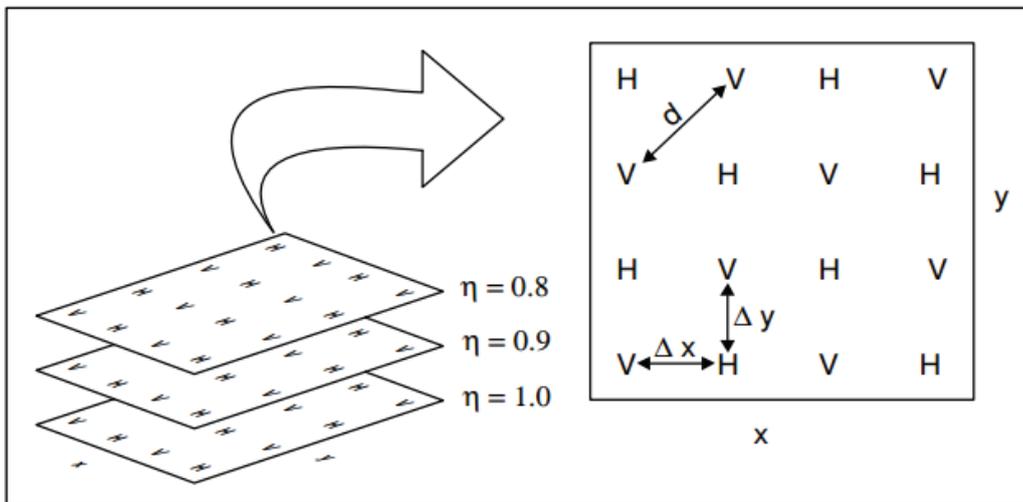


Figura 4. Malha E Arakawa, em que H representa a variável de massa e V representa as componentes horizontais do vento .

Fonte: INPE [4]

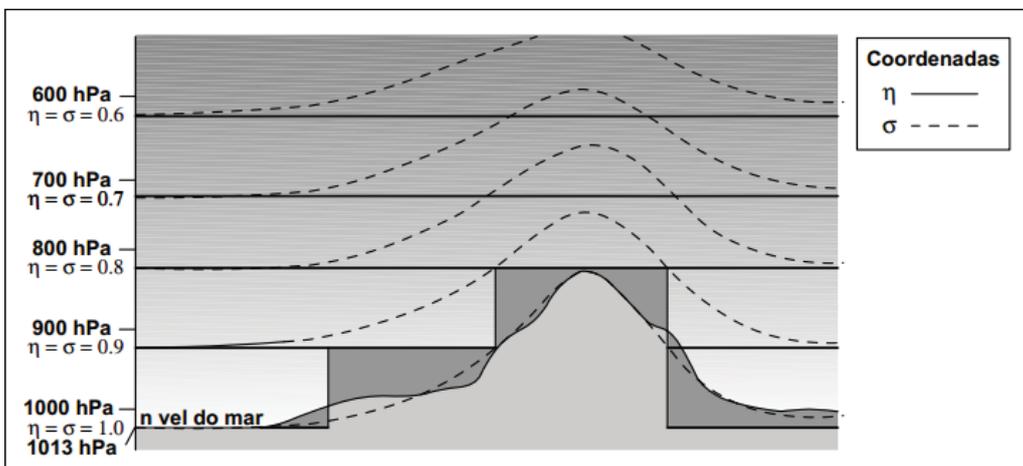


Figura 5. Coordenadas verticais σ e η .

Fonte: INPE [4]

Assim, o modelo Eta permanece aproximadamente horizontal em áreas montanhosas, tornando-se adequado para estudos de regiões de topografia íngreme, como por exemplo, a cordilheira dos Andes [15].

Seu desenvolvimento iniciou por volta da década de 1970 por Mesinger e Janjic [16], tornando-se oficialmente operacional em 1993. Atualmente, possui diversas versões, sendo amplamente utilizado em diversos países [17].

No Brasil, o modelo Eta é utilizado no Centro de Previsão de Tempo e Estudos Climáticos (CPTEC) do Instituto Nacional de Pesquisas Espaciais (INPE) em forma operacional, abrangendo a América do Sul. De acordo com Chou et Al.[15], o modelo é utilizado operacionalmente pelo INPE desde 1997 para previsões meteorológicas e para previsões do estado do tempo desde 2002.

Como o modelo Eta utilizado no Brasil trata-se de um modelo regional, suas condições iniciais são obtidas por meio de uma análise estatística, na qual a estimativa inicial é ajustada de acordo com

as observações do horário da análise. "Nos contornos laterais, o modelo é atualizado a cada 6 horas com as previsões do modelo global" [14].

As variáveis prognósticas do modelo, variáveis de saída, são: temperatura do ar, componentes zonal e meridional do vento, umidade específica, pressão à superfície e energia cinética turbulenta [17]. Assim, o modelo propõe-se a prever fenômenos atmosféricos de forma mais detalhada, quando associado a essas variáveis, como no caso de tempestades, nevoeiros, etc.

Como tais variáveis não possuem uma linearidade, podendo variar com uma frequência maior em grades por espaços de tempo, devido às mudanças do estado do tempo envolvidas, tal previsão é melhor definida quando ocorrida em um curto espaço de tempo. A previsão gerada pelo modelo regional Eta estende-se em até 120 horas, sendo fornecida duas vezes ao dia para o modelo regular de grade de 40km e de 15km. Possui, também, modelos de mesoescala com grades de 5km e 1km.

Contudo, sabe-se que os modelos de simulação podem conter imprecisões, ainda mais quando estes tratam-se de modelos que representam ações da natureza. Como exemplo, pode-se citar os modelos de previsão de temperatura, os quais, de acordo com Mao et Al. [18], são conhecidos por conterem erros devido a sua representação grosseira do modelo topográfico e um modelo físico deficiente. A Figura 6 demonstra essas diferenças entre mundo real (lado esquerdo) derivado de dados observados, e o mundo simulado por modelos de previsão (lado direito) derivado de modelos de ponto de grade.

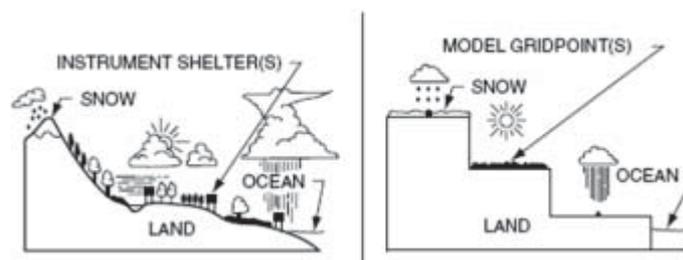


Figura 6. Diferenças entre o mundo real e o mundo simulado por modelos de previsão.

Fonte: Wilks [19].

Essas diferenças ocorrem devido a utilização de modelo de ponto de grade, considerando um ponto único por grade. Assim, o modelo pressupõe que os dados do estado do tempo se comportam de maneira homogênea dentro de cada caixa de grade [7]. Ainda que os modelos de simulação sejam melhorados, os modelos de previsão do tempo estão longe de serem perfeitos [18].

3.2 MODELOS EPIDEMIOLÓGICOS APLICADOS A ÁREA AGRÍCOLA

Existem diversos modelos de simulação relacionados à área agrícola que utilizam como variáveis de entrada os dados de PNT, nos quais os modelos de crescimento de cultura tratam do crescimento das plantas em relação ao ambiente [20, 21]; e os modelos epidemiológicos tratam da previsão de doenças em plantas [22, 23, 24].

Para Santos et al. [25], a utilização de modelos de simulação (previsão) para detecção de enfermidades em diversas culturas vem mostrando resultados promissores, pois auxiliam na racionalização do uso de agrotóxicos e na melhora da eficiência do controle químico, permitindo, assim, que as pulverizações sejam realizadas somente quando existem condições favoráveis para o surgimento das doenças. Para isso, avisos são emitidos pelos sistemas de previsão, os quais auxiliam produtores na tomada de decisão, resultando em produções mais saudáveis ao consumidor e auxiliando o meio ambiente na redução da utilização dos agrotóxicos.

Conforme Spolti [26], "a cultura da macieira no Brasil ocupa uma área de 35 mil hectares, concentrada nos estados do sul do país. Apesar do alto patamar técnico atingido, a cultura sofre o ataque e perdas por inúmeras doenças".

3.2.1 Enfermidades da Cultura da Maçã

Dentre as enfermidades ocorridas no cultivo da maçã, conforme Santos et al. [25], a sarna da macieira, causada pelo fungo *Venturia inaequalis* (Cooke) Winter, é o principal problema dos produtores de maçã, principalmente em regiões de primavera fria e úmida.

Os prejuízos causados pela sarna manifestam-se por meio da queda precoce das folhas e flores, assim como infecções nos frutos provocam rachaduras, deformações, ou mesmo sua queda prematura, causando depreciação comercial destes ([27] apud [25]). Bleicher et al. [28] detalham os prejuízos causados pela sarna, verificando-se que em casos de infecção severa, é comum o encarquilhamento e a queda prematura das folhas. Quando a mesma infecção severa atinge o pedúnculo pode causar a queda prematura dos frutos.

Juntamente com a sarna, a mancha foliar de macieiras 'gala' é, também, uma das doenças mais preocupantes no cultivo e produção de maçã no sul do Brasil. Essa doença é causada pelos agentes *Colletotrichum gloeosporioides*, *Colletotrichum acutatum* e *Colletotrichum spp.* De acordo com Sanhueza et al. [29], "os prejuízos dessa doença são grandes e na ausência de controle, o produtor pode sofrer perda da produção do ano e reduzir a do ano seguinte".

O controle destas enfermidades é realizado por meio da utilização de fungicidas, sendo que, na região de Vacaria, são realizadas aplicações a partir do final de agosto até o início de dezembro [25].

De acordo com Machardy ([30], apud Santos et al. [25]), o uso de fungicidas é um sucesso, mas parte das pulverizações poderiam ser eliminadas sem o risco de desenvolvimento da sarna durante os períodos em que as condições de umidade e temperatura não são favoráveis à infecção, pois, em conformidade com Denardi et al. [31], com a redução do uso dos fungicidas, torna-se possível a redução dos custos da produção, além da proteção do produtor, da saúde do consumidor e da preservação do meio ambiente.

Assim, a inter-relação entre intervalos de molhamento foliar, temperatura e aumento de sarna foram formalizados por Mills [32], conforme uma tabela conhecida como Tabela de Mills, a qual mostra a quantidade de horas de molhamento foliar necessárias para infecção leve, moderada e severa nos pomares. Essa tabela representa um marco para os sistemas de alerta para esses níveis de infecção,

pois com ela foi possível a criação de estações de avisos, os quais auxiliam produtores no controle dessa enfermidade ([33] apud [25]).

Dentre as infecções que causam podridão na maçã, encontram-se a podridão branca (*Botryosphaeria dothidea*) e a podridão 'Olho de boi' (*Cryptosporiopsis perennans*). Sanhueza et al. [34] esclarecem que a podridão branca é uma das doenças com controle mais difícil, pois, embora a infecção ocorra no fruto jovem, os sintomas só ocorrem próximo do período de colheita. Assim, faz-se necessário um controle relacionado às condições climáticas a fim de evitar a infecção. Em decorrência disso, Sanhueza et al. [34] alertam que "verões chuvosos e com temperaturas amenas" são propensos à doença. Inclusive, Sanhueza et al. [35] especificam ainda mais as condições, na qual longos períodos de molhamento e temperaturas médias entre 15°C e 22°C podem causar perdas elevadas nos cultivares.

Tendo em vista os problemas enfrentados pelas doenças que afetam o cultivo da maçã e seu consequente prejuízo quando não tomadas as devidas providências, além da necessidade de reduzir os agrotóxicos para otimização da produtividade, surgiram então os modelos de simulação que auxiliam na previsão dessas doenças, mostrando avisos quando existem condições favoráveis à infecção.

Porém, tendo em vista que os dados de PNT podem possuir imprecisões, e a fim de melhorar esses modelos, torna-se necessário encontrar algumas alternativas. Nesse sentido, é possível a utilização de modelos de ponto de grade em mesoescala em determinadas regiões, alternativa possível para regiões de topologia íngreme, como regiões montanhosas, e já adotada pelo modelo Eta em algumas regiões.

Outra alternativa é a correção estatística, ou calibração, desses modelos de PNT, a qual é possível por meio da aplicação de algum método de calibração, promovendo assim sua otimização.

3.3 FORMAS DE CORREÇÃO ESTATÍSTICA

Existem diversas formas de realizar a correção dos dados de previsão, por meio da interpretação estatística da saída dos modelos numéricos de previsão do tempo, com posterior análise e correção dos dados. Algumas das formas encontram-se descritas a seguir.

3.3.1 Kalman-Filter

Desenvolvido por Rudolf Emil Kalman em 1960 [36], a teoria possuiu em sua criação um contexto do programa espacial americano que levaria a Apollo 11 à Lua em 1969, a qual consiste em minimizar os erros existentes nas previsões numéricas. Para isso, o método utiliza o erro existente em previsões anteriores e pressupõem que este seja recorrente [37]. Ele é construído sobre a análise da comparação das observações com a respectiva previsão do modelo, verificando assim a recorrência do erro sistemático. Assim, algumas equações são aplicadas a fim de compensar esses erros recur-

sivamente. A grande vantagem desse método, é de que não requer uma grande base de dados para sua aplicação [38, 39].

Para utilização em modelos de PNT, é comum utilizar alguma técnica de Rede Neural Artificial (RNA) em conjunto (como pode ser visto em [40], [41], [42]), pois estas possuem capacidade de aprendizado e resposta, possíveis através do reconhecimento de padrões de funções e modelo preditivo. Assim, "Uma vez treinada a rede neural o esforço computacional é menor em relação ao filtro de Kalman, o que torna a rede neural mais apta para lidar com grande volume de dados." [40]. Ainda, sua aplicação sob modelos de PNT em sua forma padrão possui carga computacional inaceitável, assim é utilizado simplificações da teoria de Kalman-filter para assimilação dos dados de forma computacionalmente eficiente [41].

3.3.2 Método da Analogia

O método da Analogia utiliza-se de dados históricos para verificar se a situação atual possui situações semelhantes no passado, e, se houver, essas serão conhecidas como análogos. Desse modo, pressupõem-se que o desenvolvimento dos processos atmosféricos no futuro devem ser os mesmos dos análogos encontrados [37].

3.3.3 Regressão Linear Multivariada

Regressão Linear Multivariada, ou regressão linear múltipla, é a forma mais utilizada pelos métodos de correção. O principal objetivo desse formato é modelar e investigar a relação entre os dados previstos e os potenciais preditores. Assim, na equação para regressão linear multivariada, Equação(1), há uma relação de k variáveis preditoras [43].

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k \quad (1)$$

Os parâmetros $\beta_0, \beta_1, \beta_2, \dots, \beta_k$ são os coeficientes de regressão, no qual β_0 representa o intercepto da linha no eixo da ordenada, e $\beta_1, \beta_2, \dots, \beta_k$ representam a angulação da linha de regressão, ou seja, a inclinação da reta. Para estimar os parâmetros do modelo são utilizados alguns métodos, como: Método dos Mínimos Quadrados, Método Bayesiano e Método Bootstrap.

O método mais utilizado é o Método dos Mínimos Quadrados, Equação(2), utilizado quando ($n > k$), sendo que n é o número de observações e k o número de variáveis preditoras, fato muito comum em modelos numéricos de previsão do tempo. Esse método estima os parâmetros de regressão de forma a minimizar as somas quadráticas dos resíduos [43], em que os resíduos (ϵ_i) são resultados da diferença entre y e y_i .

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + \epsilon_i \quad (2)$$

na qual $i = 1, 2, \dots, n$.

3.4 MÉTODOS DE CORREÇÃO ESTATÍSTICA DOS MODELOS DE PNT

O processo de validação e calibração diferenciam-se pela escolha dos parâmetros. Assim, a seleção de parâmetros utilizados para calibração dos dados pode não ser relevante na validação do modelo. Logo, a seleção dos parâmetros utilizados para calibração dos dados é uma questão técnica, na qual cada método estatístico trata de uma maneira própria. Os principais métodos de correção dos modelos de simulação encontram-se descritos a seguir.

3.4.1 Perfect Prognosis Method (PPM)

Perfect Prognosis Method, também conhecido como *Perfect Prog*, é um método estatístico para correção de dados de PNT desenvolvido por Klein et al. [44] em 1959. Para isso, o método realiza regressão linear multivariada. Dentre as utilizações desse modelo, é possível citar Rajeevan et al. [45], no qual foi utilizado o método PPM para previsão de trovoadas e relâmpagos, em que mostrou-se positivo, obtendo uma precisão razoável. Esse método desenvolve equações prognósticas com base em relações estatísticas entre os elementos meteorológicos observados, como preditantes, e variáveis de saída da análise diagnóstica do modelo numérico, como preditores, as quais são, posteriormente, aplicadas a saída do modelo bruto. Com base nessas melhorias realizadas sobre o modelo bruto, o modelo era, até então, considerado perfeito, o que justifica o nome dado ao método em questão. Contudo, existem duas deficiências que limitam o sucesso desse método, sendo a primeira o fato de não levar em conta os erros sistemáticos do modelo numérico, e a segunda é devido ao fato de não levar em consideração as alterações do estado da atmosfera no decorrer do tempo.

3.4.2 Model Output Statistics (MOS)

Model Output Statistics trata-se do método estatístico de correção disponibilizado por Glahn e Lowry [46] em 1972, já sendo utilizado pela National Weather Service desde 1970. Ele consiste em determinar uma relação estatística entre os dados observados, como preditando, e as variáveis do modelo numérico em algumas predições do tempo. Nesse modelo os erros sistemáticos podem ser levados em conta. Porém, estudos mostraram que são necessários dois anos de dados arquivados para execução do modelo, a fim de obter uma equação MOS eficiente, segundo Jacks et al. [47]. Esse fato gera uma deficiência no modelo, pois o MOS não oferece possibilidade de desenvolver grande base de dados, visto que os modelos numéricos são continuamente alterados e para a execução do MOS faz-se necessário que, durante o período de arquivamento dos dados, a configuração do modelo mantenha-se congelada. Tal deficiência é contornada com a utilização de equações prognósticas por regiões. Pesquisas realizadas por Maini [48] e por Mazban et al. [49] apontam que em uma compara-

ção relacionando MOS e PPM, o MOS mostra um desempenho melhor quando refere-se a variância do erro encontrado entre a previsão e o dado observado. Contudo, o MOS ainda aponta dificuldades pelo tamanho limitado de dados necessários.

3.4.3 Extended Kalman Filter (EKF)

Traduzido como Filtro de Kalman Estendido, trata-se de uma versão do filtro de Kalman aplicado quando o processo a ser estimado é não-linear, no qual, para isso, a covariância do erro da previsão é obtida linearizando o modelo sobre uma trajetória não linear entre a previsão do tempo anterior com a previsão corrente. Possui como característica que "apenas o estado estimado a partir da etapa de tempo anterior e a atual medição são necessários para calcular a estimativa para o estado atual" [50]. Ainda, para obtenção de uma estimativa satisfatória do estado da atmosfera e do erro da covariância, o EKF pode necessitar de um período transitório inicial de uma semana ou mais. Assim, esse método apresenta uma vantagem em relação aos métodos de regressão linear PPM e MOS, pois estes necessitam de uma grande quantidade de dados como período de treinamento. No entanto, quando os dados representam um ambiente instável, em que as observações não são suficientemente frequentes, é possível que a linearização se torne imprecisa e, conseqüentemente, o EKF pode apresentar resultados insatisfatórios, afastando-se da real ocorrência dos fatos [51] apud [52].

Dentre suas aplicações sob modelos de circulação, Carvalho [50] realizou uma aplicação do método EKF para correção da temperatura prevista pelo Precip-BR - sistema de previsão de clima regional desenvolvido pelo Hadley Center na Inglaterra e adaptado para as condições brasileiras pelo INPE - o qual mostrou-se positivo, apresentando "em média, índice de melhoria acima de 12,5%".

3.4.4 Model Outputting Calibration (MOC)

Model Outputting Calibration, desenvolvido por Mao et al. [18] em 1998, trata-se de um método de correção estatística baseada em regressão linear multivariada, assim como PPM e MOS, em que sua grande diferença quando relacionado a estes é seu curto prazo de armazenamento de previsão e observações necessárias para realização da correção do modelo estatístico. Detalhes sobre o MOC são abordados na seção 3.5.

3.4.5 Comparação entre os Métodos

Para análise dos métodos de correção estatística citados anteriormente (PPM, MOS, EKF e MOC) algumas características principais devem ser levadas em consideração, visto que a avaliação depende do contexto ao qual serão aplicados.

Considerando que o contexto de utilização do método de correção estatística será sob modelos de PNT e, avaliando as características de cada um dos métodos apresentados, como pode ser

visto na Tabela 1, verifica-se que em relação aos métodos que consideram as alterações do estado da atmosfera, MOS e MOC, mostram-se positivos.

Contudo, o método MOS possui um tempo de treinamento de aproximadamente dois anos, o que se mostra inviável para modelos de circulação, pois estes possuem variações constantes. Ainda, considerando o critério de tempo, o EKF possui o menor tempo necessário para treinamento, porém, como visto anteriormente, em estruturas com variações constantes, como é o caso dos modelos de PNT, este pode resultar em dados insatisfatórios.

Tabela 1. Comparação entre os métodos de correção estatística

Características/ Métodos	Considera as alterações do estado da atmosfera	Tempo de treinamento	Método de correção estatística
PPM	não	-	Regressão Linear Multivariada
MOS	sim	~2 anos	Regressão Linear Multivariada
EKF	não	>1 semana	Kalman Filter
MOC	sim	2 a 4 semanas	Regressão Linear Multivariada

Assim, a utilização do MOC sugere ser positiva, pois ele considera as alterações do estado da atmosfera e seu tempo de treinamento é relativamente curto.

3.5 MODEL OUTPUT CALIBRATION (MOC)

A maioria dos métodos que realizam correção estatística de modelos de simulação propõem-se em determinar o valor de uma variável específica, determinada *a priori*. O método de correção MOC, desenvolvido por Mao et al. [18], tem como princípio a existência de erro na previsão, o qual pode ter sido influenciado por outras variáveis da saída do modelo de simulação. Assim, o MOC propõe-se a encontrar o erro da previsão por meio da aplicação de regressão linear multivariada para correção do modelo de simulação. Trata-se de um modelo de correção simples, o qual é adequado para variáveis com comportamento linear, pois, de acordo com Chou et al. [53], o MOC é baseado em um modelo linear, logo variáveis com comportamento não linear não são corretamente representadas, ou seja, variáveis que representam a ocorrência ou não-ocorrência dos fatos, tais como precipitação ou nebulosidade.

Dentre as vantagens desse método está o curto período de previsões e observações necessárias (de 2 a 4 semanas) como treinamento para execução da correção. Assim, o algoritmo é usado para estimar o ajuste necessário para o modelo, prevendo erros e fazendo um refinamento dos predi-

cados. Logo, obtêm-se como resultado da correção aplicada com MOC, o erro da previsão em relação a uma determinada variável, conforme Equação (3).

$$\Delta T_{(ij)}(k) = T_{(ij)}(k) - T_{(ij)}^*(k) \quad (3)$$

onde: $T_{(ij)}(k)$ representa uma série de previsões; (k) representa uma série de valores da variável T em diferentes tempos ($k = 1, 2, 3, \dots, N$). Nesse exemplo a variável utilizada como exemplo refere-se a temperatura; (i, j) refere-se ao ponto da grade no qual está sendo verificado os valores, ou seja, a localização; e $T_{(ij)}^*(k)$ refere-se a série de dados observados. Logo, com o valor previsto em determinado período para determinado lugar, subtraído do valor observado, no mesmo período e lugar, obtêm-se então o erro da previsão.

Assim, assume-se que $\Delta T_{(ij)}(k)$ (erro da previsão) está intrinsecamente associado com vários parâmetros e variáveis de saída do modelo. Logo $\Delta T_{(ij)}(k)$ pode ser uma função de $X_{ij,l}(k)$, em que esta representa a l -ésima quantidade de variáveis obtidas ou derivadas de uma recente saída do modelo no mesmo ponto da grade (i, j) , na qual o erro previsto está correlacionado com a quantidade L de saídas do modelo. Como exemplo, Chou [53] apresenta que na correção estatística da previsão de temperatura existem diversas variáveis associadas, tais como as próximas ao solo (umidade do solo e temperatura da superfície).

Com base nestes dados, é possível construir um modelo de regressão linear multivariada, com o qual é possível obter o erro da previsão do modelo, conforme Equação (4).

$$\Delta T_{(ij)}(k) = \Lambda_o + \sum_{l=1}^L \Lambda_l X_{ij,l}(k) \quad (4)$$

onde $k = 1, 2, \dots, N$ e $l = 1, 2, \dots, L$.

Os coeficientes Λ_o e Λ_l podem ser definidos por meio da análise da regressão linear multivariada. O $\Delta T_{(ij)}(k)$ é o preditando das equações, ou seja, a variável dependente, e $X_{ij,l}(k)$ são as variáveis de saída do modelo que representa os preditores.

A calibração é aplicada após a correção, $N + 1$, sendo que N é o tamanho da série para cálculo dos coeficientes de regressão, obtendo-se, desse modo, a previsão refinada $T_{moc}(k)$, segundo equação (5).

$$T_{moc}(k) = T_{(ij)}(k) - \Delta T_{(ij)}(k) \quad (5)$$

onde $T_{(ij)}(k)$ representa a previsão do modelo corrente e $\Delta T_{(ij)}(k)$ representa o erro no mesmo ponto da grade. O fluxo do procedimento para obtenção da previsão calibrada pode ser visto na Figura 7.

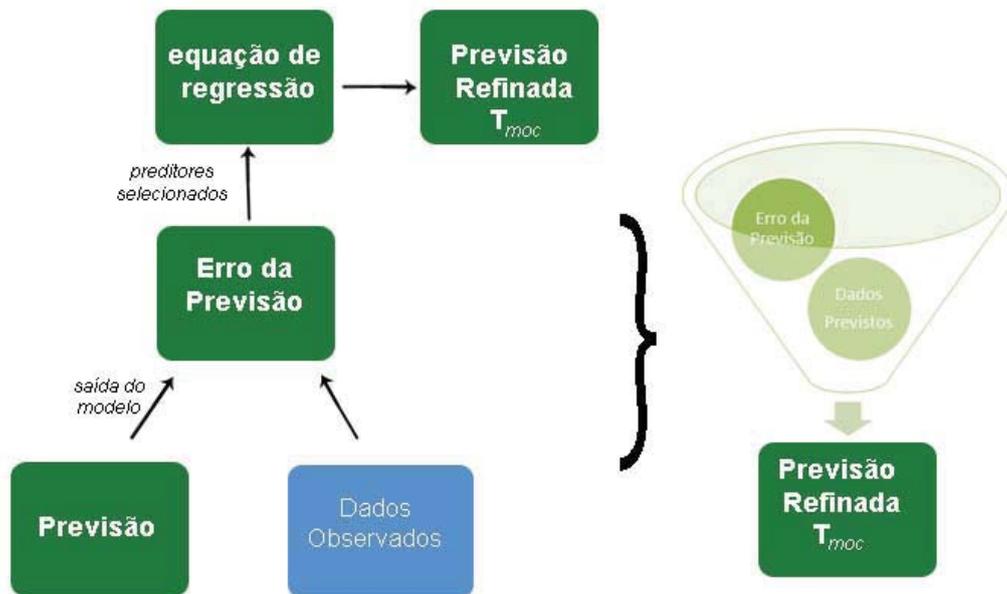


Figura 7. Fluxo de calibração com MOC.

Fonte: Do autor.

3.5.1 Seleção de Preditores

De acordo com Mao et al. [18], a seleção de preditores no MOC ocorre a cada novo ciclo da previsão com base em um conjunto de variáveis candidatas, ou seja, a cada nova rodada da correção os preditores são selecionados (Equação (4)), diferente do MOS em que os preditores são definidos *a priori*. Conseqüentemente, o número de preditores selecionados (L_c), diretos ou derivados, deve ser menor que o número de variáveis candidatas (L).

A seleção dos preditores é realizada com base na correlação entre o erro da previsão e as variáveis previstas pelo modelo (R). Assim, as variáveis que apresentam uma correlação maior que um valor crítico, um valor de corte (R_c), são selecionadas como preditoras [53].

Para isso, a aplicação apresentada por Chou [53] realizou a seleção dos preditores em um modelo com a seguinte configuração: o conjunto de dados consistia de 72 variáveis como candidatas a preditoras em um período de treinamento de 28 dias e correção aplicada no período de 30 dias. Nessa aplicação o R_c encontrado foi entre 0.6 e 0.8, e limitado o número de preditores a 5, podendo ser utilizado 6 em alguns casos. Os preditores são recalculados para cada previsão. Assim, as variáveis selecionadas com maior frequência sugerem quais são os processos do modelo que estão influenciando no erro da previsão.

Dentre os métodos utilizados para esta seleção, Ferreira [54] utiliza o método *Stepwise* que constrói iterativamente uma sequência de modelos de regressão pela adição ou remoção de variáveis, aplicada em cada etapa do processo. A adição e remoção das variáveis ocorre por meio de um teste de F , comparando um modelo com seu submodelo, no qual é realizado uma análise de variância a fim de verificar se ao menos uma variável de controle $X_{ij,l}(k)$ é estatisticamente significativa para o modelo.

3.5.2 Características

A fim de determinar as características específicas de um determinado objeto, é necessário basear-se em outros objetos do mesmo segmento para realizar uma comparação, permitindo assim que suas vantagens e desvantagens sejam definidas. Assim, com o objetivo de definir as vantagens e desvantagens do MOC, é necessário compará-lo a outros modelos de correção estatísticas dos modelos de simulação. Logo, Ferreira [43] realizou um estudo comparativo entre os modelos estatísticos MOS e MOC, aplicando os métodos de correção ao modelo de previsão do tempo BRAMS em oito localidades.

Após este estudo pode-se constatar que, para o modelo de previsão BRAMS, o método MOS trouxe melhores resultados de correção para as variáveis temperatura da superfície, umidade relativa do ar em superfície e pressão à superfície. Contudo, ambos os métodos apresentaram melhoras nos dados da previsão, e o MOC apresentou bons resultados para as variáveis de umidade relativa do ar em superfície e pressão à superfície, para correção no período de 24h.

Ainda que alguns resultados obtiveram uma correção pouco melhor com o método MOS, MOC se mostrou mais vantajoso pois necessita de um curto período de dados (previstos e observados) para ajustar a correção.

Contudo, Mao et al. [18] evidenciam que MOC não foi criado com intuito de substituição ao MOS, mas sim como um complemento, visto que os métodos são aplicados em modelos de previsão diferentes, dependendo da necessidade de correção de cada modelo.

Devido ao fato do MOC necessitar de um curto período de dados para realização do ajuste da correção, é possível realizar ajustes em modelos independente de mudanças ambientais do modelo de previsão, tornando-se uma ótima ferramenta para modelos de previsão regionais.

Além disso, Mao et al. [18] apresentam outras vantagens da utilização do MOC: é uma técnica simples, flexível e eficiente; baseia-se nas condições climáticas mais recentes; a seleção de preditores ocorre de forma objetiva e, de certa forma, ideal, pois após os preditandos e variáveis candidatas serem especificados, o resto do processo ocorre de forma objetiva e iterativa; o algoritmo utilizado para correção estatística do modelo de previsão é flexível e fácil de implementar para qualquer modelo, pois a equação é atualizada em cada ciclo da previsão e é menos sensível a mudanças ou reconfigurações do modelo; a informação dos resultados da seleção dos preditores pode ser utilizada em diagnósticos e sintonização do modelo físico, pois com o uso dessa seleção é possível verificar as variáveis que estão influenciando no erro da previsão.

3.5.3 Aplicações do MOC sob modelos de circulação

Em 1998, junto com a definição do modelo MOC, Mao et. al [18] publicaram uma aplicação deste para o período de 27 de junho a 30 de julho de 1997, a qual foi utilizada para correção da variável temperatura para seis centros urbanos do Tennessee Valley (EUA), em que a média dos erros BIAS, MAE e RMSE, das seis localidades, para o erro da previsão eram -5.9 , 6.2 , e 6.7 °F respectivamente.

Após a correção aplicando o MOC, a média dos erros foram -1.8 , 3.0 e 3.7 °F, respectivamente. Ainda, a redução dos erros de previsão variou de 58% a 98% para o erro sistemático Bias, de 40% a 52% para o MAE, e 33% a 46% para RMSE.

Em 2002 Tozzi e Silva [55] publicaram um artigo sobre a aplicação da correção estatística MOC sobre o modelo de PNT Eta, para a variável temperatura do ar para as cidades de Porto Alegre, Cuiabá e Belo Horizonte, a qual foi aplicada sobre o mês de abril de 2000, para a previsão das horas 6h e 18h, com o intuito de verificar como o modelo se comportaria em diferentes regiões do país. Neste trabalho pode-se verificar uma melhora entre 6.847% para a cidade de Cuiabá para a previsão das 18 horas, e 64.031% para a cidade de Belo Horizonte para a previsão das 6 horas, com uma média de melhora de 29.8% . Todas as localidades apresentaram melhoras na correção sobre a previsão.

Em 2005 Oliveira [56] realizou a aplicação do MOC para a variável vento do modelo Eta na grade de 40Km para a cidade de Florianópolis durante o período de janeiro, fevereiro e março de 2005, na qual foi possível constatar uma melhora em relação a previsão e uma redução do erro contido nesta, podendo verificar a forte correlação entre os dados observados e os dados corrigidos. A partir deste trabalho foi possível identificar que a eficiência da calibração está relacionada ao limiar de correlação, a qual é determinada de acordo com as características de cada região e período, assim as variáveis preditoras são escolhidas de forma mais adequada e obtendo um melhor resultado.

Em 2007 Chou et al. [53] publicaram um artigo sobre a aplicação do MOC para refinamento da previsão horária de temperatura para o modelo de PNT Eta, com grades na resolução de 40km , a qual foi aplicada sobre a região do Nordeste brasileiro para o período de setembro de 2003, em que para o erro RMSE houve uma redução na ordem de 43% , e para os erros sistemáticos BIAS houve uma melhora na ordem de $|0.4|^\circ\text{C}$.

Em 2011 Ferreira [43] realizou uma comparação utilizando os modelos de correção estatística MOS e MOC, para isso estas foram aplicadas para correção das variáveis temperatura da superfície, umidade relativa do ar, pressão à superfície e chuva acumulada em 1h para algumas estações do Rio Grande do Sul, as quais consistem em 8 estações espalhadas pelo estado. Ainda, este trabalho foi aplicado sobre o modelo de PNT BRAMS. Com este trabalho pode-se verificar que a correção da chuva acumulada em 1h não mostrou melhoras, devido ao fato de tratar-se de uma variável discreta; para o erro MAE na correção sobre a previsão do período de 24h a variável pressão à superfície apresentou resultados muito satisfatórios, com melhoras de 7.59% a 86% ; a correção da variável umidade relativa apresentou uma melhora entre 3.26% e 21.43% , contudo em uma das localidades (Santa Rosa) não houve melhora para essa variável; e para a variável temperatura, houve uma melhora de 7.99% a 29.55% , contudo uma das regiões também não apresentou melhora (Bagé). Para as previsões nos períodos de 48h e 72h o MOC não apresentou resultados positivos.

Em 2015 Hölbig et al. [57] aplicaram a correção estatística MOC sob as variáveis temperatura e umidade relativa a dois metros da superfície para 36 cidades utilizadas em uma aplicação da área de energia, a qual foi aplicada para o modelo de PNT Eta na grade de resolução de 15Km durante o período de fevereiro de 2015. Nessa aplicação houve ocasiões em que a correção não gerou resultados positivos, possuindo valores com erros maiores do que a previsão, porém, na maioria dos casos a

correção mostrou-se positiva. Para a variável temperatura, "em geral subestimaram as observações, principalmente nos horários da madrugada. Por outro lado, a umidade relativa foi geralmente superestimada durante o período noturno e subestimada durante o período diurno" [57]. Assim, por meio da aplicação do MOC houve uma redução significativa sobre os erros sistemáticos, os erros MAE e RMSE também mostraram redução nos erros, porém com porcentagem menor. Logo, a partir desse breve histórico foi possível identificar que, na maioria dos casos, houve viabilidade na correção para as variáveis de comportamento linear obtendo, ainda, um sucesso maior para as primeiras 24h.

4. METODOLOGIA

Este capítulo visa definir a utilização do estudo de caso, assim como as formas de avaliação utilizadas para análise do ganho da utilização dos dados corrigidos de PNT aplicados a outros modelos derivados.

4.1 ANÁLISE DOS DADOS DE PNT

Para avaliar se as calibrações dos modelos de previsão apresentam um resultado satisfatório, obtendo um ganho significativo na relação entre o valor previsto e o valor observado, conforme Mao et al. [18], são utilizadas três medidas estatísticas básicas do erro: o erro médio (BIAS), erro absoluto médio (MAE - em inglês *mean absolute error*) e a raiz quadrada do erro quadrático médio (RMSE - em inglês *root mean square error*). Por meio dessas medidas é possível determinar a qualidade da previsão e de sua calibração.

Ainda, para determinar o ganho que se obteve com a calibração utiliza-se o cálculo do *Skill Score* (SS). Com base nessas informações é possível determinar pontos fracos e fortes do sistema. Estas medidas encontram-se descritas a seguir.

O erro médio (BIAS), ou erro sistemático, tem por objetivo trazer informações do desempenho do modelo a longo prazo. A Equação (6) resulta no desvio médio do modelo em relação à variável, onde quanto mais próximo de ZERO for o resultado de BIAS, melhor é o resultado.

$$BIAS = \frac{1}{M_{total}} \sum_{i=1}^{M_{total}} (T_i - T_i^*) \quad (6)$$

Na Equação (6), M_{total} é a quantidade total de previsões corrigidas. T_i é o i-ésimo valor corrigido pelo MOC e T_i^* é o i-ésimo valor observado correspondente. T_i poderá indicar o valor não corrigido, obtido pelo modelo de previsão, quando o cálculo do erro médio for realizado para o valor previsto e não para o corrigido. Contudo, como o resultado poderá ser positivo ou negativo, este não indica precisão da previsão.

O erro médio absoluto (MAE), Eq. (7), tende a mostrar o erro médio absoluto da diferença entre os dados previstos ou corrigidos (T_i), e os dados observados (T_i^*), sendo seu resultado um valor não-negativo. Assim como o BIAS, o resultado do MAE é melhor quanto mais próximo de ZERO.

$$MAE = \frac{1}{M_{total}} \sum_{i=1}^{M_{total}} |T_i - T_i^*| \quad (7)$$

O RMSE, raiz quadrada do erro quadrático médio, Equação (8), tem como resultado a diferença individual entre os dados previstos ou corrigidos (T_i) e os dados observados (T_i^*). O resultado do RMSE é um valor não-negativo, assim como o MAE. Porém, o RMSE é mais sensível a grandes erros, pois, conforme Ferreira, Varone e Alvez [54], elevando a diferença ao quadrado, força tratar igualmente resultados negativos e positivos.

$$RMSE = \sqrt{\frac{1}{M_{total}} \sum_{i=1}^{M_{total}} (T_i - T_i^*)^2} \quad (8)$$

Essas três medidas estatísticas básicas do erro obtêm seu resultado na mesma unidade dos dados utilizados nos testes. Por exemplo, quando é testado o erro da previsão da temperatura em graus Celsius ($^{\circ}\text{C}$), os erros também serão apresentados em $^{\circ}\text{C}$. Porém, muitas vezes, é necessário saber qual o ganho que se obteve com a calibração realizada. Esse ganho se mostra mais significativo quando apresentado em porcentagem. Para isso há o cálculo do *Skill Score* (SS), Equação (9), o qual reflete justamente a porcentagem de melhora do modelo calibrado sobre o não calibrado.

$$SS = \left(\frac{E_{previsao} - E_{MOC}}{E_{previsao}} \right) \times 100\% \quad (9)$$

Na Equação (9) $E_{previsao}$ trata do erro obtido com o modelo da previsão, conseqüentemente E_{MOC} é o erro do modelo calibrado com MOC. Ambos os erros referem-se ao erro obtido com uma das três medidas estatísticas de erro: BIAS, MAE e RMSE, ou seja, esse índice (SS) pode ser calculado para cada um dos erros mencionados anteriormente.

4.2 ESTUDO DE CASO

Considerando que as variáveis de um modelo de PNT estão sujeitas a interferências devido as ocorrências de mudanças do estado do tempo que o modelo não conseguiu capturar, e tendo em vista a grande influência desses dados sobre outros modelos de simulação (modelos derivados), como modelos agrícolas, por exemplo, os resultados desses modelos podem ser superestimados ou subestimados, não refletindo a realidade. Buscou-se, então, um modelo de simulação que utilize como condição inicial algumas variáveis do modelo Eta, tendo como finalidade analisar se a calibração dessas variáveis contribui de forma significativa para a melhora nos cenários previstos por estes modelos derivados.

De acordo com Murthy [21], o cultivo de determinada cultura pode ser definido como o crescimento de determinada espécie de planta em uma área pré-definida, tendo como principal objetivo os fins econômicos. Desse modo, optou-se em aplicar a análise sobre um modelo epidemiológico, representando, assim, a simulação de algumas enfermidades relacionadas a uma cultura.

O estudo de caso foi aplicado sobre a ocorrência de seis doenças na cultura da maçã, sendo elas: podridão branca, mancha foliar da gala, sarna e podridão 'olho de boi' das variedades gala, fuji

e pink lady. Este estudo foi realizado durante o período de 01 de setembro de 2015 a 30 de junho de 2016 para a região de Vacaria, no estado do Rio Grande do Sul.

Para avaliar se houve melhora com a utilização dos dados calibrados, foram analisados três cenários: o resultado do modelo de simulação com a observação dos dados do estado do tempo (assumidos como ocorrência da doença), o resultado do modelo de simulação original (com os dados de PNT derivados da previsão do modelo Eta), e o modelo de simulação com os dados de PNT corrigidos.

Em trabalhos relacionados ao tema desta pesquisa, encontrou-se na literatura a pesquisa realizada por Marchiori [58], na qual foi efetuada uma análise sobre o rendimento da cultura da soja de acordo com a estimativa de evapotranspiração do modelo de PNT BRAMS em que são comparados os cenários do rendimento da cultura da soja com os dados observados e com os dados previstos pelo BRAMS, porém nessa pesquisa não é utilizada a correção estatística sobre os modelos de PNT.

4.2.1 Sisalert: Sistema de monitoramento e alertas das doenças presentes na cultura da Maçã

Os modelos de simulação utilizados como estudo de caso fazem parte de um sistema web para previsão das epidemias, utilizado na plataforma Sisalert (<http://sisalert.com.br/>), a qual refere-se a "uma plataforma multi-modelo que coleta dados meteorológicos obtidos de estações meteorológicas automáticas e de prognósticos de tempo de curto prazo que processa as informações por diversos modelos epidemiológicos, simples ou complexos, para a simulação e alertas de risco de epidemias e distribui a informação de risco para os usuários" [59]. Essa ferramenta é utilizada como apoio à análise e decisão por pesquisadores e produtores da indústria do trigo e maçã [60].

Os modelos de simulação relacionados às enfermidades do cultivo da maçã foram desenvolvidos por pesquisadores da Embrapa, da Universidade de Passo Fundo (UPF) e da Associação Gaúcha de Produtos de Maçã [60]. Assim, o modelo epidemiológico da sarna na cultura da maçã trata-se de adaptações da tabela de Mills. Já os demais modelos foram desenvolvidos a partir de modificações do sistema utilizado na região de São Joaquim, Santa Catarina [61].

O sistema foi desenvolvido sob a arquitetura *Model View Control* (MVC), no qual: a camada de modelo trabalha com a lógica de negócio; a camada visão é responsável pela interação com o usuário através de páginas web; e a camada controle determina o fluxo geral da aplicação. Como pode ser visto na Figura 8, a camada de controle realiza conexão com o banco de dados por meio da camada de modelo, processando o modelo de simulação a cada 15 minutos e todos os eventos gerados (registro de epidemias) são armazenados no banco de dados. Após a execução do modelo são emitidos avisos de alerta via e-mail e mensagens de texto para os usuários cadastrados. O usuário também pode visualizar as mensagens via sistema Web.

Os dados meteorológicos são provenientes de estações automáticas coletados em intervalos de 15 minutos. Os dados destas estações são: "a pluviosidade (*mm*), temperatura (mínima, máxima e média, °C), umidade relativa do ar (%) e horas de molhamento foliar (*h*)" [26]. Em conformidade com Pavan et al. [60], o sistema realiza a coleta dos dados de sete estações meteorológicas automáticas

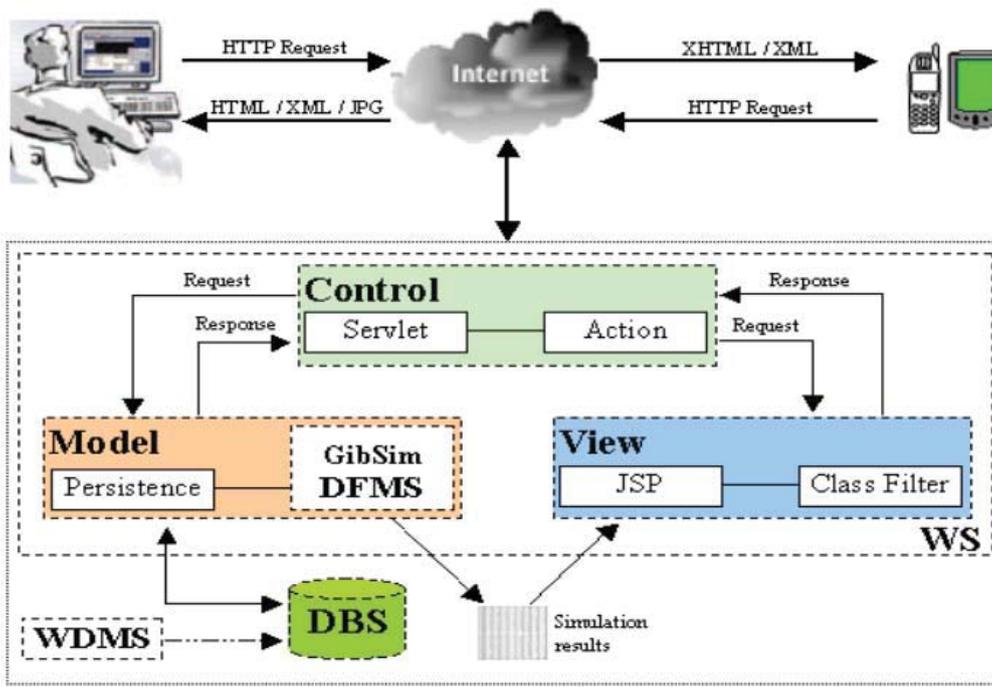


Figura 8. Arquitetura do sistema projetado para coletar e armazenar dados meteorológicos reais e previstos para executar os modelos de simulação de previsão do risco de doenças no cultivo das maçãs.

Fonte: Pavan et al. [60].

da Associação Gaúcha de Produtos de Maçã, as quais realizam a transmissão dessas informações a um concentrador, no qual os dados são analisados, processados e transmitidos para a base de dados do servidor (PostgreSQL). Os dados de previsão são provenientes do INPE, modelo Eta, na resolução de grades de 15 km x 15 km, obtidos via protocolo FTP e que são, também, armazenados no banco de dados, como pode ser visto na Figura 9.

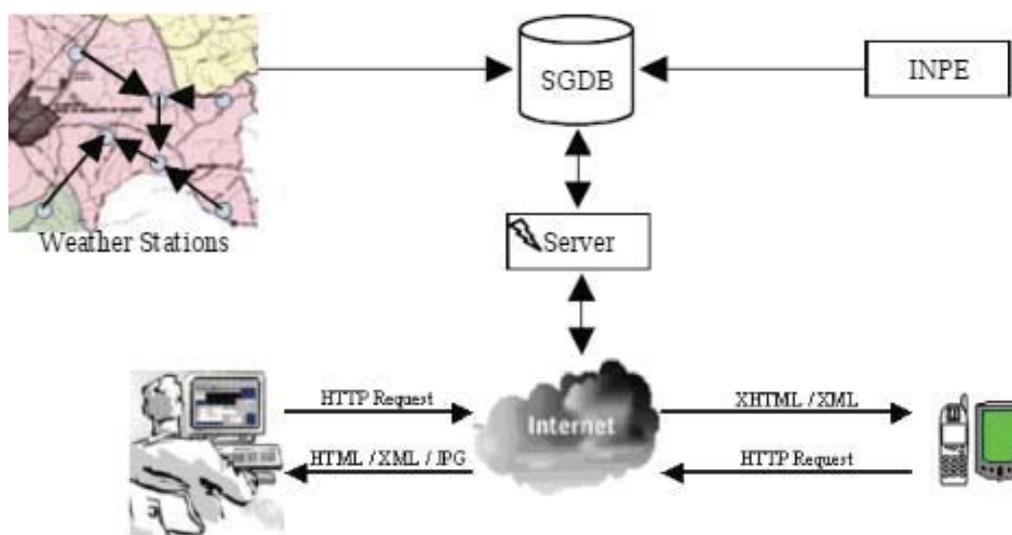


Figura 9. Fluxo da aplicação dos modelos de simulações relacionados as enfermidades do cultivo da maçã.

Fonte: Pavan et al. [60].

Com base nessas informações, o sistema produz um índice de risco de infecção diária baseado na combinação histórica da previsão do tempo dos últimos sete dias.

O sistema foi desenvolvido na linguagem de programação Java, no qual, para as camadas de Modelo e Controle foi utilizado a arquitetura Java *Standard Edition* (JSE) e para a camada de visão foi utilizado a arquitetura Java *Enterprise Edition* (JEE).

4.2.2 Cenário do Estudo de Caso

Para execução do estudo de caso, foi realizada a atualização do modelo de simulação para linguagem de programação R¹, somente das camadas Modelo e Controle. Para a análise realizada neste trabalho as variáveis de entrada (dados meteorológicos) do modelo de simulação de cada uma das enfermidades estão relacionadas com cada um dos cenários envolvidos, em que: para o primeiro cenário (C1) os dados utilizados são os dados observados, dados provenientes da estação meteorológica A880 do Instituto Nacional de Meteorologia (INMET)²; o segundo cenário (C2) trata-se dos dados previstos pelo modelo Eta, na resolução de grades 15 km x 15 km; e o terceiro cenário (C3) são os dados de previsão corrigidos através do MOC. Assim, tornou-se possível a análise dos resultados obtidos pelo modelo em cada um dos cenários.

4.2.2.1 Ajustes dos dados

Tendo em vista que o modelo de simulação original realiza leitura dos dados meteorológicos a cada 15 minutos, foi necessário adaptar o sistema, pois, nos três cenários avaliados, os dados meteorológicos utilizados são dados horários, devido aos dados obtidos de observação do INMET e de previsão gerados pelo Eta.

Os dados meteorológicos utilizados no modelo são: temperatura, umidade relativa, precipitação e radiação solar, além do dado referente ao molhamento foliar da planta, todos em dados horários. Contudo, houve alguns casos de necessidade de cálculos específicos para determinação do valor de algumas variáveis, pois existem alguns dados faltantes em alguns dos cenários, no qual: no C1 os dados observados disponibilizados pelo INMET não contêm informação do molhamento foliar; para os dados previstos e corrigidos foi necessário calcular, além do molhamento foliar, também a temperatura em ponto de orvalho, necessária para o cálculo do molhamento foliar.

Para o cálculo do molhamento foliar utilizou-se o método Dew Point Depression (DPD). Esse método trata da diferença entre a temperatura do ar e a temperatura em ponto de orvalho. Assim, o método consiste em estimar se houve molhamento de acordo com o tempo em que a depressão em ponto de orvalho permaneceu entre dois limites na diferença das temperaturas, sendo que o menor valor representa o começo do molhamento e o maior valor representa o começo da secagem. Os

¹<https://www.r-project.org/>

²<http://www.inmet.gov.br/portal/>

valores utilizados para estes limites foram de 2°C para o surgimento e 3.8°C para secagem ([62] apud [63]).

Ainda, para o cálculo da temperatura em ponto de orvalho utilizou-se a função desenvolvida por McNoldy [64], conforme Equação 10. Nesta as variáveis T e RH representam, respectivamente, temperatura do ar e umidade relativa, já as constantes possuem seus valores definidos como $a = 17.625$ e $b = 243.04$.

$$T_d = \frac{b[\ln(\frac{RH}{100}) + \frac{aT}{b+T}]}{a - \ln(\frac{RH}{100}) - \frac{aT}{b+T}} \quad (10)$$

4.2.2.2 Conjunto de dados para as simulações

Para a coleta de dados, testou-se diversas hipóteses em relação a obtenção dos dados, tornando possível que a análise realizada apresentasse resultados fidedignos. Para isso, os dados obtidos com C1 foram resultados da execução contínua do modelo de simulação para o período de teste, a fim de verificar todos os casos de ocorrências das doenças para o período. Como o intuito deste trabalho é avaliar qual cenário mais se aproxima do C1, a coleta de dados de C2 e C3 (Figura 10, situação 1) foi realizada da seguinte forma: para cada ocorrência de C1 foi executada a simulação da doença com a previsão meteorológica para sete dias, utilizando a previsão dada para o terceiro dia anterior a ocorrência em C1 (sendo três dias anteriores a cada ocorrência em C1, e três dias posteriores, somando-se sete dias de previsão, contando com o dia da ocorrência).

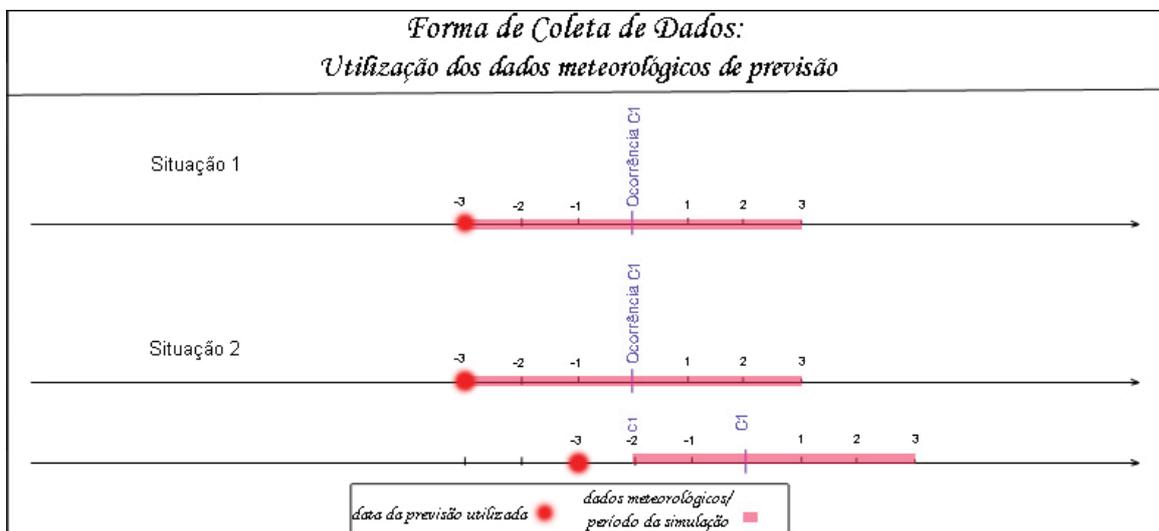


Figura 10. Forma de coleta de dados.

Fonte: Autor.

Assim, quando há mais de uma ocorrência em C1 próximas, que possam estar nesse intervalo de três dias anterior, a previsão utilizada segue a mesma lógica de dados. Contudo, os dados meteorológicos utilizados para simulação de C2 e C3 iniciam a partir da última ocorrência, evitando, desse modo, que informações possam interferir na análise. Tal situação pode ser vista na Figura 10, situação 2.

5. ANÁLISE DA CORREÇÃO DOS DADOS DE PNT PARA VACARIA - RS

Neste capítulo são analisados os resultados obtidos com a aplicação do MOC, na correção da temperatura e da umidade relativa, sobre o modelo Eta na resolução de 15Km, referente ao período de setembro de 2015 a junho de 2016 para a cidade de Vacaria (RS). As coordenadas do ponto de grade do Eta utilizadas foram -28.51 (latitude) e -50.93 (longitude). Os dados observados foram obtidos da estação do INMET A880 localizada em Vacaria nas coordenadas -28.51 (latitude) e -50.88 (longitude).

5.1 CORREÇÃO DA VARIÁVEL TEMPERATURA

A variável temperatura, utilizada como condição inicial dos modelos de doenças do cultivo da maçã, refere-se a temperatura do ar a dois metros da atmosfera obtida como previsão das medidas horárias para o ponto de grade localizado na área da cidade de Vacaria. Foi realizada a comparação entre a temperatura do ar observada, prevista (pelo Eta) e a corrigida (pelo MOC), para o período do estudo de caso. Na Figura 11 é representada a média diária para a temperatura durante os meses de setembro de 2015 a junho de 2016, sendo que as curvas em azuis referem-se às medidas observadas na estação do INMET; as curvas em vermelho referem-se às medidas previstas pelo modelo Eta e as curvas em verdes referem-se aos dados do Eta refinados pelo MOC.

Com base nessa análise é possível identificar o período de maior instabilidade dos resultados da previsão, no qual durante o período de setembro a dezembro de 2015, houve um grau de instabilidade grande em relação a temperatura entre os horários de 09:00 e 21:00, em que as medidas da previsão foram subestimadas em relação a observação dos dados, podendo se verificar, também, que durante esse período a média diária dos dados corrigidos apresenta uma melhora significativa, pois aproxima-se aos dados observados. Na Tabela 2, é possível comparar os dados observados, previstos e corrigidos da variável de temperatura para cada um dos meses do período do estudo de caso.

Contudo, ainda que a média diária da temperatura tenha apresentado resultados positivos, observou-se que havia casos isolados onde a correção feita pelo MOC não apresentava resultados promissores, como pode ser visto na Figura 12, dados sem ajustes, no qual esses casos são evidenciados pelos círculos em amarelo. Dessa forma, verifica-se que esses casos ocorriam tanto na correção da temperatura quanto da umidade relativa, além disso, tal fato ocorria quando alguma mudança significativa em relação ao estado do tempo acontecia, como pode ser visto na Figura 12. Visando contornar esse problema, foi necessário realizar um ajuste sobre a correção com o uso do MOC.

Para a implementação de tal ajuste foi necessário realizar a verificação da média do desvio padrão e o erro médio da correção com MOC dos últimos 21 dias, no qual para cada dado horário é verificado se a correção se mantém dentro do desvio padrão médio em comparação com o dado observado, caso contrário é aplicado a correção com base no erro médio.

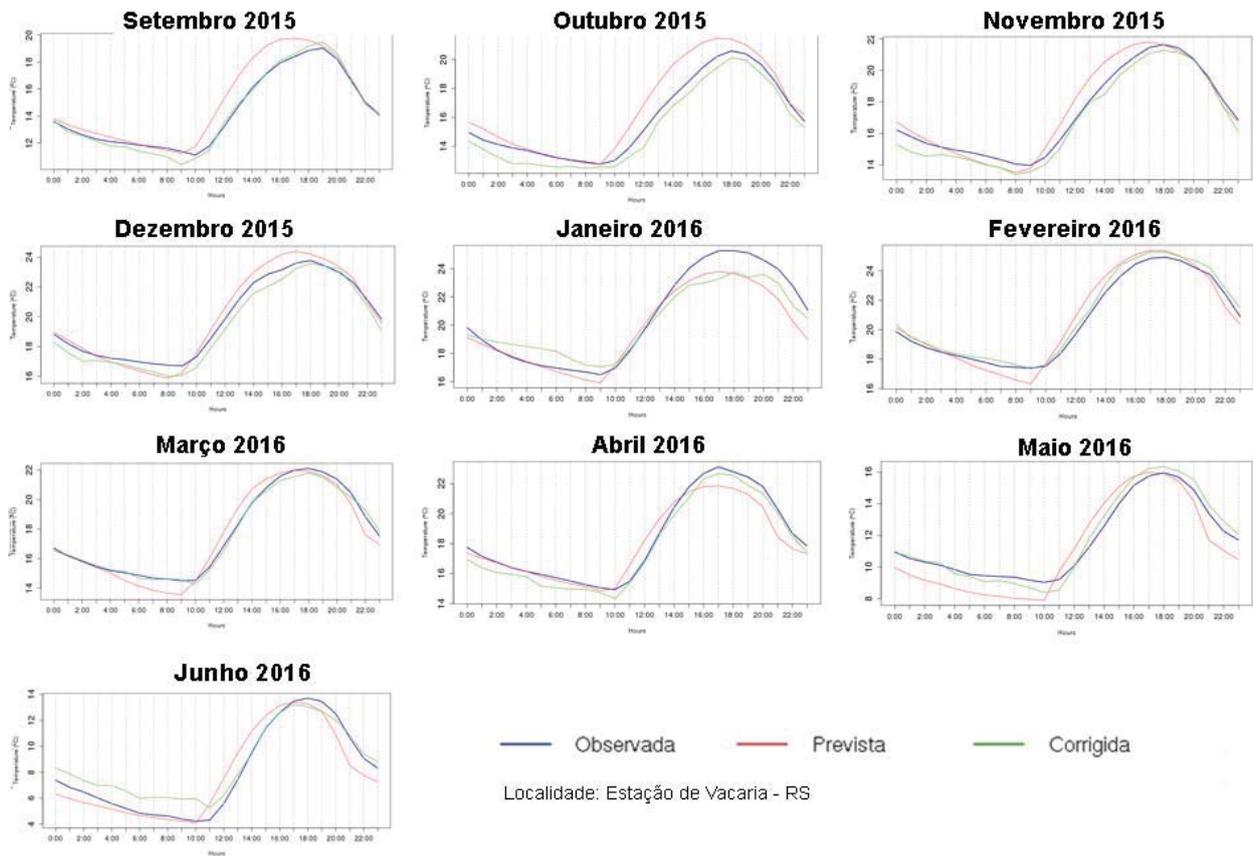


Figura 11. Ciclo diurno médio da temperatura do ar a 2m da atmosfera para cada um dos meses do período de teste

Fonte: Do autor

Tabela 2. Média Diária da temperatura do ar (°C) observada, prevista pelo modelo Eta, corrigida pelo MOC e a correspondência das medidas estatísticas básicas do erro (BIAS, MAE e RMSE) para a cidade de Vacaria, nos meses do período de teste (Setembro de 2015 a Junho de 2016).

Período	Obs	Eta	MOC	Eta			MOC		
				BIAS	MAE	RMSE	BIAS	MAE	RMSE
Set. 2015	14.35	15.05	14.26	0.70	1.81	2.31	-0.09	2.09	2.64
Out. 2015	15.92	16.70	15.27	0.78	1.68	2.35	-0.65	1.88	2.33
Nov. 2015	17.25	17.49	16.78	0.25	1.57	2.09	-0.47	1.74	2.16
Dez. 2015	19.83	19.99	19.33	0.16	1.38	1.80	-0.49	1.60	1.98
Jan. 2016	20.51	19.78	20.22	-0.73	2.17	2.88	-0.29	2.19	2.96
Fev. 2016	20.66	20.79	20.99	0.13	1.37	1.77	0.34	1.28	1.73
Mar. 2016	17.69	17.55	17.59	-0.14	1.21	1.53	-0.10	1.25	1.56
Abr. 2016	18.31	18.02	17.86	-0.29	1.56	1.90	-0.45	1.55	1.90
Mai. 2016	11.65	11.17	11.76	0.11	1.53	1.93	-0.48	1.46	1.79
Jun. 2016	8.01	7.84	8.62	-0.17	1.58	1.94	0.60	1.60	1.96
Set. 15 ~ Jun. 16	16.41	16.43	16.26	0.02	1.58	2.07	-0.15	1.67	2.16

Conforme ilustrado na Figura 12 pode-se constatar que os círculos em amarelos evidenciam alguns dos casos com ocorrência do problema, em que é possível perceber que no dia 02 de setembro a temperatura corrigida com o MOC apresentava instabilidade e dados irrealistas, problema amenizado

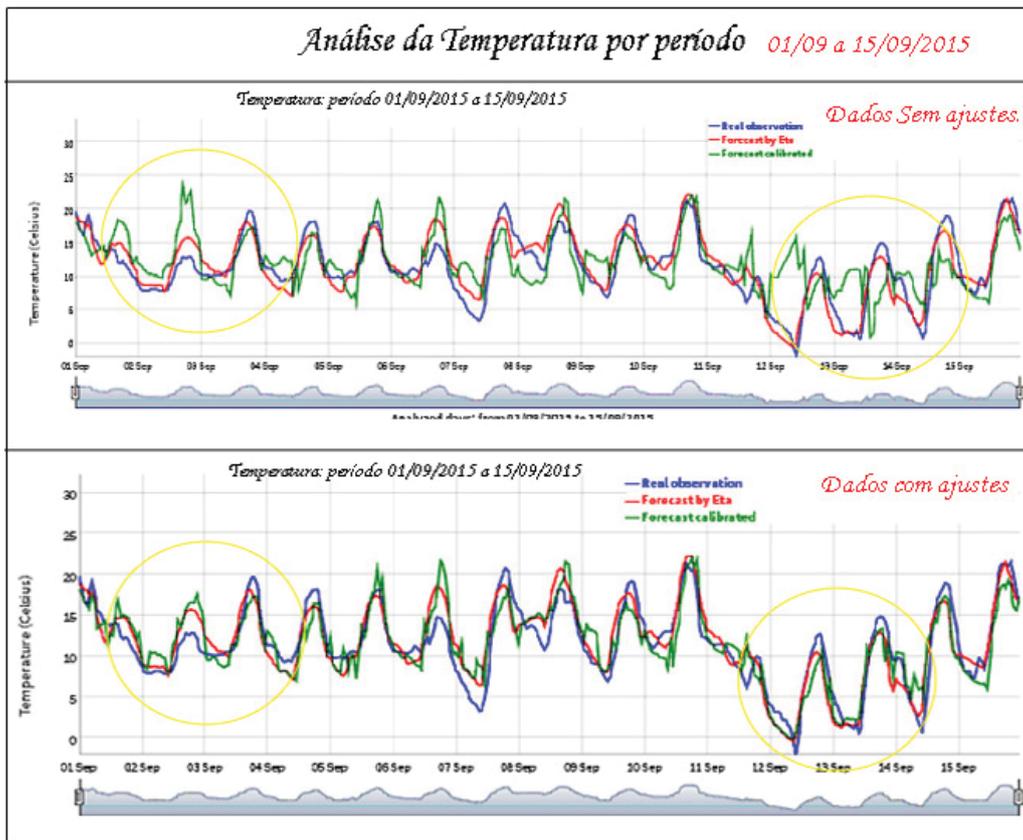


Figura 12. Comparação da temperatura do ar com e sem ajuste sobre a correção realizada pelo MOC para a cidade de Vacaria durante o período de 1º a 15 de setembro de 2015.

Fonte: Do autor

com o ajuste da correção. Outra situação pode ser vista nos dias 12 e 13 de setembro, em que a correção apresentou dados irrealistas e não manteve a tendência dos dados, o que foi regulado com o ajuste. Consta-se que houve uma melhora significativa nos dados corrigidos após seu ajuste, mantendo-se próximos à real observação.

5.2 CORREÇÃO DA VARIÁVEL UMIDADE RELATIVA

A observação da umidade relativa do ar foi, também, comparada com os dados gerados por meio da previsão do modelo Eta e a correção desta variável pelo MOC, para o período do estudo de caso. Para esta comparação, na Figura 13 é representada a análise da média diária para umidade relativa, podendo ser analisada mês a mês, onde as curvas em azul referem-se as medidas observadas na estação meteorológica, as curvas em vermelho referem-se as medidas previstas pelo modelo Eta e as curvas em verde referem-se aos dados refinados pelo MOC, todos para a região de Vacaria-RS.

Desse modo, foi possível identificar os períodos do dia em que a previsão acaba subestimando ou superestimando os dados, assim, percebe-se que entre os horários de 00:00 e 09:00, os dados em geral são superestimados pela previsão, e entre os horários de 10:00 e 19:00, os dados em geral são subestimados pela previsão. Como pode ser visto na Figura 13, os dados previstos acompanham a linearidade dos dados observados, contudo, percebe-se que existe uma instabilidade

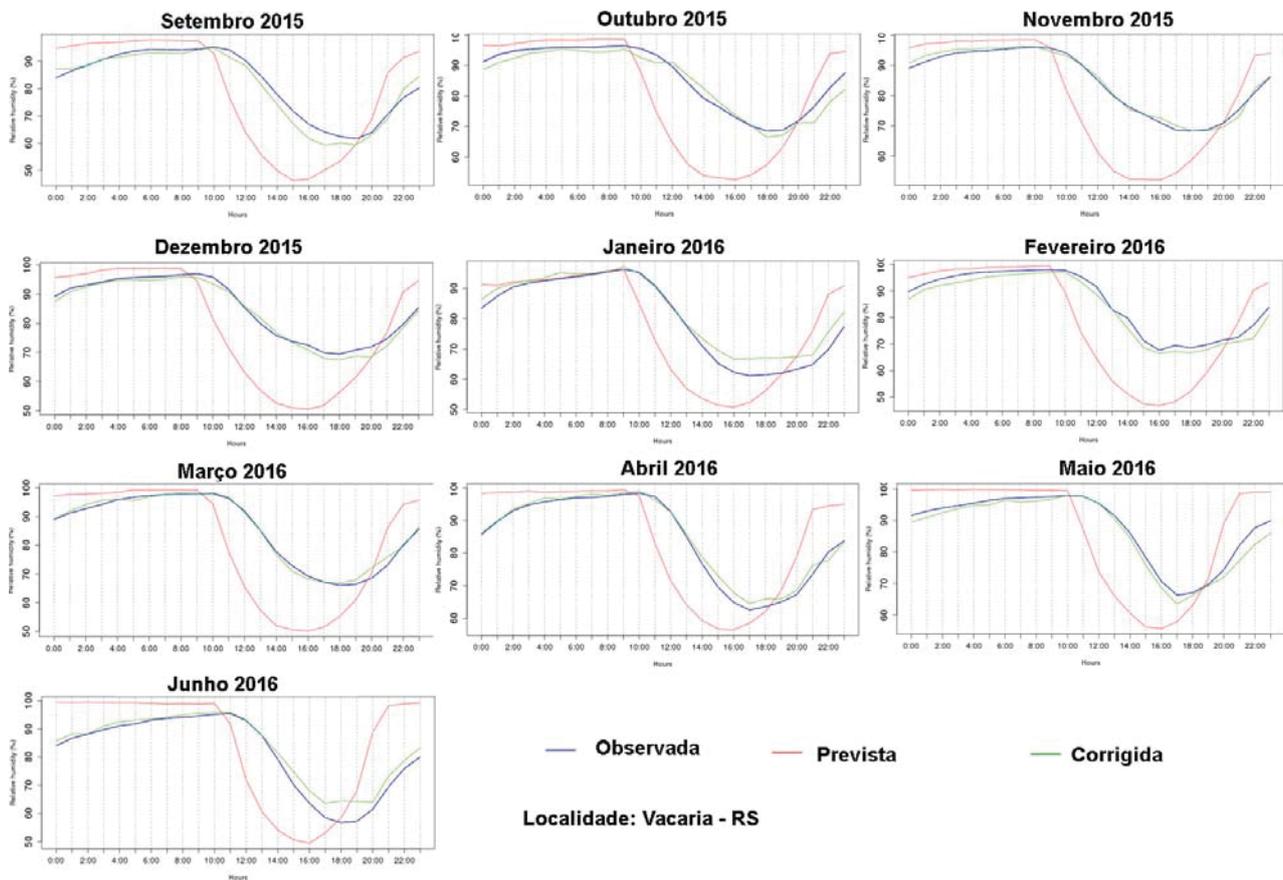


Figura 13. Ciclo diurno médio da umidade relativa do ar, dados mensais
Fonte: Do autor

na previsão, pois os dados previstos de umidade relativa possuem uma tendência a antecipar sua ocorrência. Na Tabela 3 é possível comparar os dados observados, previstos e corrigidos da variável de umidade relativa para cada um dos meses do período do estudo de caso.

Tabela 3. Média Diária da Umidade relativa do ar (%) observada, prevista pelo modelo Eta, corrigida pelo MOC e a correspondência das medidas estatísticas básicas do erro (BIAS, MAE e RMSE) para a cidade de Vacaria, nos meses do período de teste (Setembro de 2015 a Junho de 2016).

Período	Obs	Eta	MOC	Eta			MOC		
				BIAS	MAE	RMSE	BIAS	MAE	RMSE
Set. 2015	82.45	79.41	80.20	-3.04	13.51	18.71	-2.25	10.73	14.34
Out. 2015	86.23	80.92	85.24	-5.30	11.58	16.30	-0.98	7.98	10.88
Nov. 2015	84.58	79.95	85.10	-4.62	11.69	15.59	0.52	7.27	9.66
Dez. 2015	85.06	79.25	84.54	-5.81	12.08	16.23	-0.53	7.07	9.89
Jan. 2016	80.28	77.54	81.77	-2.74	15.10	19.20	1.50	10.89	15.15
Fev. 2016	85.70	79.15	83.67	-6.55	12.68	17.58	-2.02	7.02	10.83
Mar. 2016	85.38	81.16	86.68	-4.23	11.52	15.69	1.30	5.91	8.28
Abr. 2016	84.42	84.54	85.55	0.12	10.39	14.45	1.12	7.68	10.59
Mai. 2016	87.86	86.44	86.24	-1.42	10.77	15.37	-1.61	7.67	10.48
Jun. 2016	81.29	84.80	83.88	3.51	14.23	19.74	2.59	9.93	13.38
Set. 15 ~ Jun. 16	84.33	81.32	84.30	-3.01	12.35	16.96	-0.03	8.21	11.54

Em relação à correção dos dados realizados pelo MOC para a umidade relativa, pode-se constatar que essa aproxima-se dos dados observados, apresentando uma melhora significativa quando comparada à previsão realizada pelo Eta. Para esses dados foi necessária, também, a realização do ajuste com base na média do desvio padrão e erro da previsão, conforme detalhado anteriormente.

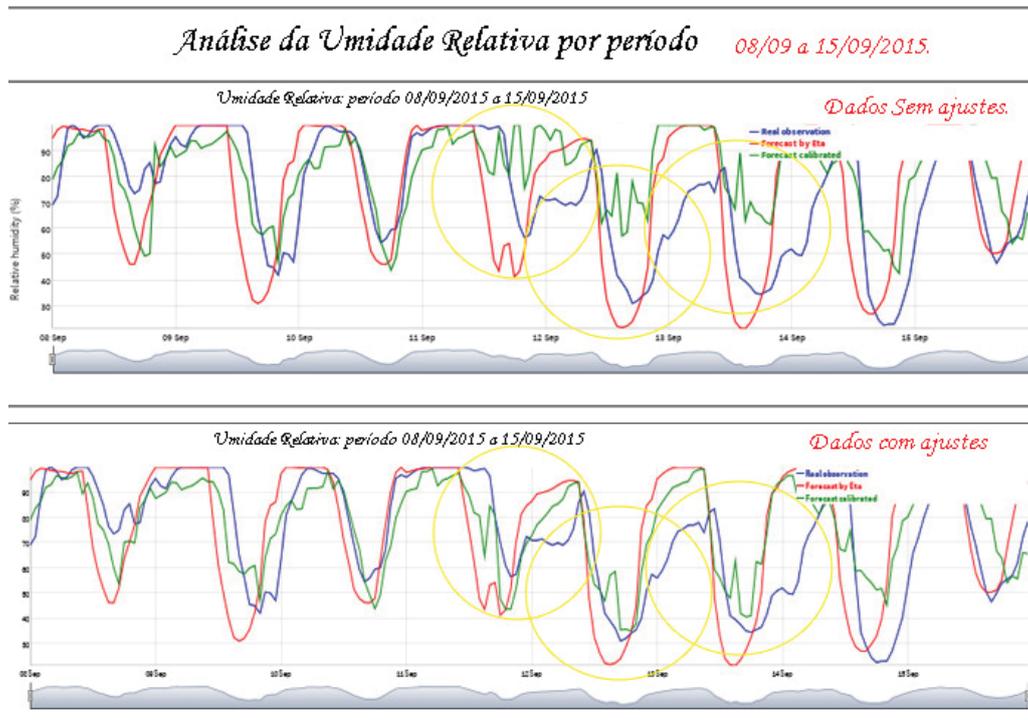


Figura 14. Comparação da umidade relativa do ar com e sem ajuste sobre a correção realizada pelo MOC para a cidade de Vacaria durante o período de 08 a 15 de setembro de 2015

Fonte: Do autor

Após o ajuste dos dados de correção foi possível analisá-los, no qual, conforme Figura 14, os círculos em amarelos evidenciam alguns dos casos da identificação de problemas em relação a correção com o MOC, tornando possível comparar os dados com a correção original e após o ajuste dos dados. Na Figura 14, verifica-se que nos dias 11 a 13 de setembro de 2015 a correção sem ajustes apresentava problemas e, em alguns casos, não acompanhava a linearidade dos dados, o que foi amenizado com a realização do ajuste da correção. Assim, constatou-se que, embora o problema não tenha deixado de existir, os dados após o ajuste apresentaram uma melhora quando comparado ao dado observado. Ainda, foi possível constatar que esses casos onde a correção apresenta dados irrelevantes, ou seja, que não seguem a tendência da ocorrência dos dados, tratam-se de casos isolados, não se tratando de situações rotineiras, desse modo identificou-se essas situações em alguns períodos do mês de setembro de 2015, janeiro e junho de 2016.

Para a avaliação dos resultados, foram analisadas as três medidas estatísticas básicas do erro. Assim, na Tabela 4 são apresentados os valores do índice de Skill Score, a fim de verificar a performance da correção. Nesta tabela pode-se verificar o ganho obtido com a aplicação do MOC, no qual observou-se que, em geral, o uso do MOC para correção dos dados de previsão gerados pelo modelo Eta demonstra bons resultados. É possível constatar que para a correção da variável da

umidade relativa, os dados apresentaram resultados ainda melhores, demonstrando o potencial de uso do MOC.

Tabela 4. Skill Score dos erros BIAS, MAE e RMSE para a média diária da previsão de temperatura do ar e umidade relativa para o período do estudo de caso, para a cidade de Vacaria

Período	SS MOC Temperatura			SS MOC Umidade Relativa		
	BIAS (%)	MAE (%)	RMSE (%)	BIAS (%)	MAE (%)	RMSE (%)
Set. 2015	112.57	-15.47	-14.29	25.99	20.58	23.36
Out. 2015	183.33	-11.90	0.85	81.51	31.09	33.25
Nov. 2015	288.00	-10.83	-3.35	111.26	37.81	38.04
Dez. 2015	406.25	-15.94	-10.00	90.88	41.47	39.06
Jan. 2016	60.27	-0.92	-2.78	154.74	27.88	21.09
Fev. 2016	-161.54	6.57	2.26	69.16	44.64	38.40
Mar. 2016	28.57	-3.31	-1.96	130.73	48.70	47.23
Abr. 2016	-55.17	0.64	0.00	-833.33	26.08	26.71
Mai. 2016	122.92	-4.79	-7.82	-13.38	28.78	31.82
Jun. 2016	425.00	-1.27	-1.03	26.21	30.22	32.22
Set. 15 ~ Jun. 16	850.00	-5.70	-4.35	99.00	33.52	31.96

6. RESULTADOS ENCONTRADOS

Neste capítulo são analisados os resultados obtidos com o estudo de caso, a fim de verificar o impacto da correção dos dados de PNT sobre cinco modelos de enfermidades no cultivo da maçã, sendo elas: mancha foliar da gala, podridão branca e podridão 'olho de boi' das variedades gala, fuji e pink lady. A enfermidade da sarna sob a cultura da maçã não consta dentre as análises, pois a execução de C1 não constatou nenhuma ocorrência.

Assim, para que a visualização dos dados fosse possível, foi necessária a realização de alguns ajustes em relação aos gráficos, na qual, para facilitar a comparação dos dados, foram utilizadas as cores laranja para representar o C3, e azul para o C2. Os gráficos possuem como intuito analisar a quantidade em horas da diferença em relação ao C1. Para identificar as ocorrências obtidas no C1 foi utilizada uma linha vertical na hora Zero. Ainda, para melhor visualização, os dados foram agrupados de 10 em 10 horas, a fim de estruturar as barras do histograma.

Além disso, para a visualização dos dados corrigidos e/ou previstos, quando a execução do modelo de simulação desses não resultaram em ocorrência de doença, a diferença em horas em relação a C1 foi ajustada para o valor 100.

6.1 MODELO DA MANCHA FOLIAR DA VARIEDADE DE MAÇÃ GALA

O modelo de simulação da doença Mancha foliar de Gala, causada pelos agentes *Colletotrichum gloeosporioides*, *Colletotrichum acutatum* e *Colletotrichum spp*, utiliza como variáveis de estado do tempo a precipitação, a temperatura e o molhamento foliar. Desse modo, pela execução do modelo dessa doença, de hora em hora, com essas variáveis, é calculado a média da temperatura do dia, a quantidade de horas sem chuva, a quantidade de horas onde houve período de molhamento e a quantidade de dias de chuva. Após a análise desses acúmulos, de acordo com os dados horários de cada variável, é analisado se houve período favorável a doença, sendo considerado para isso um período com mais de dois dias de chuva, quando o momento atual não está chovendo e a média de temperatura é maior ou igual a 15°C. Assim, a cada período favorável, uma ocorrência é gerada e uma nova análise é iniciada.

Como apresentado na Figura 15, foi possível averiguar que houve diversos períodos em que os diferentes cenários (previsto e corrigido) não identificaram ocorrência da doença. Das 44 ocorrências obtidas pelo uso dos dados observados, 27 não foram encontradas com o uso dos dados corrigidos pelo MOC (pelo C3), e 33 não foram encontradas com o uso dos dados previstos pelo ETA (pelo C2). Com isso, foi possível identificar que o C2 identificou as ocorrências em 25% dos casos, enquanto o C3 identificou 38,64% dessas.

Analisando ambos os cenários C2 e C3, observa-se que a concentração da diferença de horas relacionadas a C1 ocorre entre 20 horas anteriores e 20 horas posteriores a ocorrência da doença, sendo que as ocorrências identificadas pelo cenário C2 para esse período representam 36,36%, e para

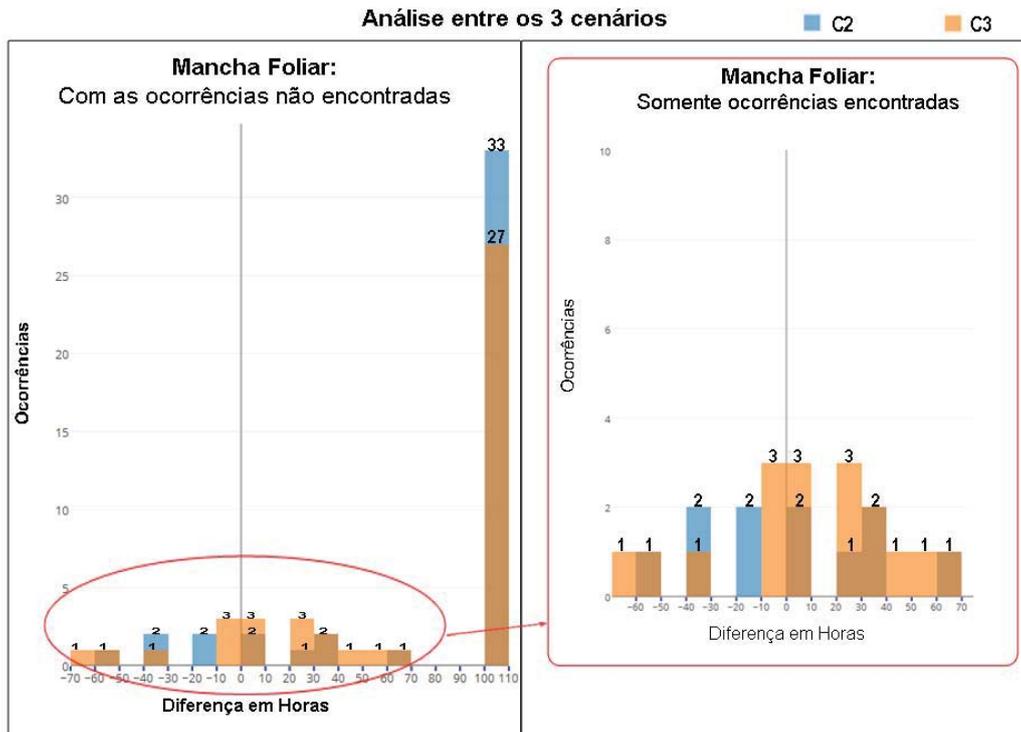


Figura 15. Análise geral da Mancha Foliar de Gala sob ambos os cenários (C2 e C3) em relação a diferença de horas das ocorrências identificadas em C1, sendo que na execução de C1 obteve 44 ocorrências.

Fonte: Do autor

o C3 representam 35,29%. Já, em relação aos cenários que conseguiram identificar com exatidão a ocorrência, dentre as identificadas, o C2 não obteve exatidão em nenhuma delas, enquanto C3 as identificou em 5,88%.

Os dados de cada cenário foram analisados separadamente, conforme Figura 16, possibilitando verificar que o C3 possui uma tendência maior para atrasar a identificação da hora da ocorrência, quando comparada a ocorrência identificada pelo C1, que nesse caso foi de 64,71% das ocorrências. Já em relação ao C2 há, também, uma leve tendência (54,55% das ocorrências) a atrasar a identificação das ocorrências, porém, nesse caso, os dados não possuem grande concentração.

Analisando os dados mensalmente, conforme Tabela 5, somente durante um dos meses (novembro de 2015), os dados do C2 mostraram-se superiores à utilização do MOC. Durante quatro meses do período (dezembro de 2015 e, janeiro, abril e maio de 2016) os dados de ambos os cenários identificaram a mesma quantidade de ocorrências e durante quatro meses do período (setembro e outubro de 2015 e, fevereiro e março de 2015) o resultado obtido através do C3 mostrou-se superior ao C2, apresentando melhorias significativas. Ainda, durante o mês de junho de 2016, não houve ocorrência com o C1, portanto, os dados não foram analisados para esse período.

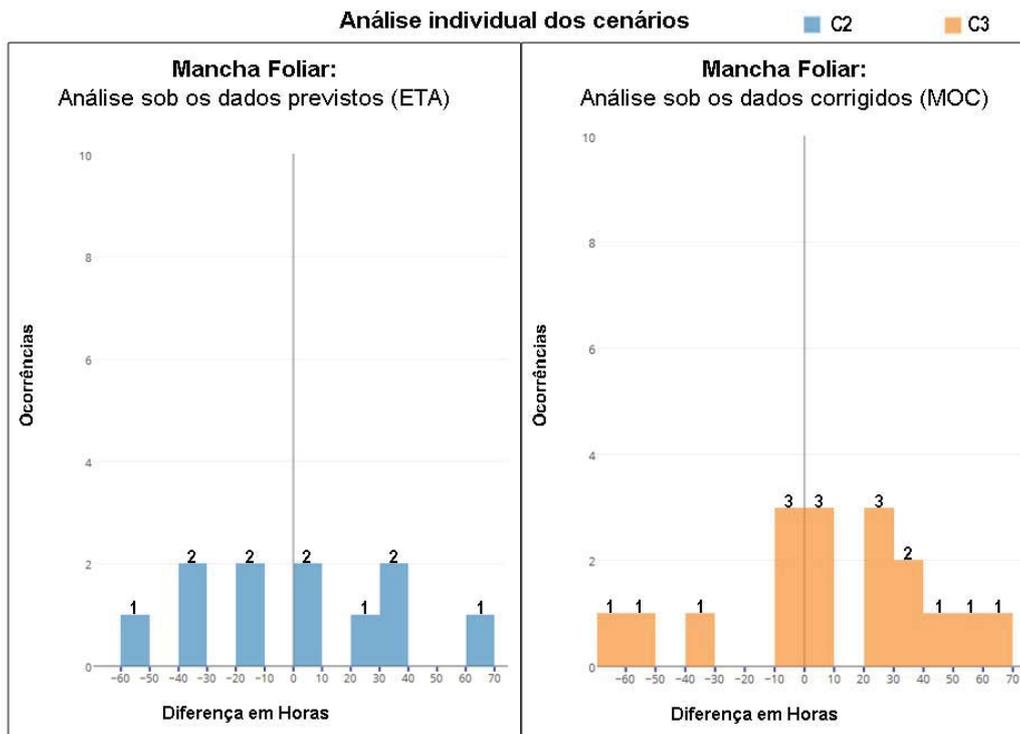


Figura 16. Análise individual da Mancha Foliar de Gala sob cada um dos cenários em relação as ocorrências de C1, sendo que na execução de C1 obteve 44 ocorrências.

Fonte: Do autor

Tabela 5. Análise mensal da previsão de ocorrências da doença Mancha Foliar de Gala

Período X Cenário	Quantidade de Ocorrências			%	
	C1	C2	C3	C2 ~ C1	C3 ~ C1
Set. 2015	6	1	3	16,67%	50,00%
Out. 2015	5	1	2	20,00%	40,00%
Nov. 2015	6	2	1	33,33%	16,67%
Dez. 2015	6	2	2	33,33%	33,33%
Jan. 2016	4	2	2	50,00%	50,00%
Fev. 2016	6	0	1	0,00%	16,67%
Mar. 2016	6	1	4	16,67%	66,67%
Abr. 2016	4	2	2	50,00%	50,00%
Mai. 2016	1	0	0	0,00%	0,00%
Jun. 2016	0	0	0	-	-
Set. 2015 ~ Jun. 2016	44	11	17	25,00%	38,64%

6.2 MODELO DA PODRIDÃO BRANCA

A simulação da enfermidade podridão branca (*Botryosphaeria dothidea*) possui como fatores de influência a precipitação, a temperatura do ar, o molhamento foliar e a umidade relativa do ar, todos em dados horários. Desse modo, a partir dessa coleta de dados é iniciada a análise, na qual é calculada a quantidade de chuva acumulada e a quantidade de horas com molhamento, caso contrário é acumulado à quantidade de horas sem chuva. Além desses dados é calculada a média de tempera-

tura. Assim, quando essas informações acumulam-se formando um período favorável a enfermidade da podridão branca, uma ocorrência é gerada e uma nova análise se inicia.

Em relação à identificação das ocorrências da podridão branca, a qual identificou 45 ocorrências para o período de teste em C1, o cenário que mostrou melhores resultados para essa doença foi o C3, o qual atingiu um sucesso de 73,33% das ocorrências, já o C2 apresentou um sucesso de 64,44%. Contudo, ao analisar o cenário que conseguiu identificar com exatidão a hora da ocorrência, dentre as ocorrências identificadas por cada cenário, C2 apresentou melhores resultados, visto que atingiu um sucesso em 10,34% dos casos, enquanto C3 obteve sucesso em apenas 2,22% desses.

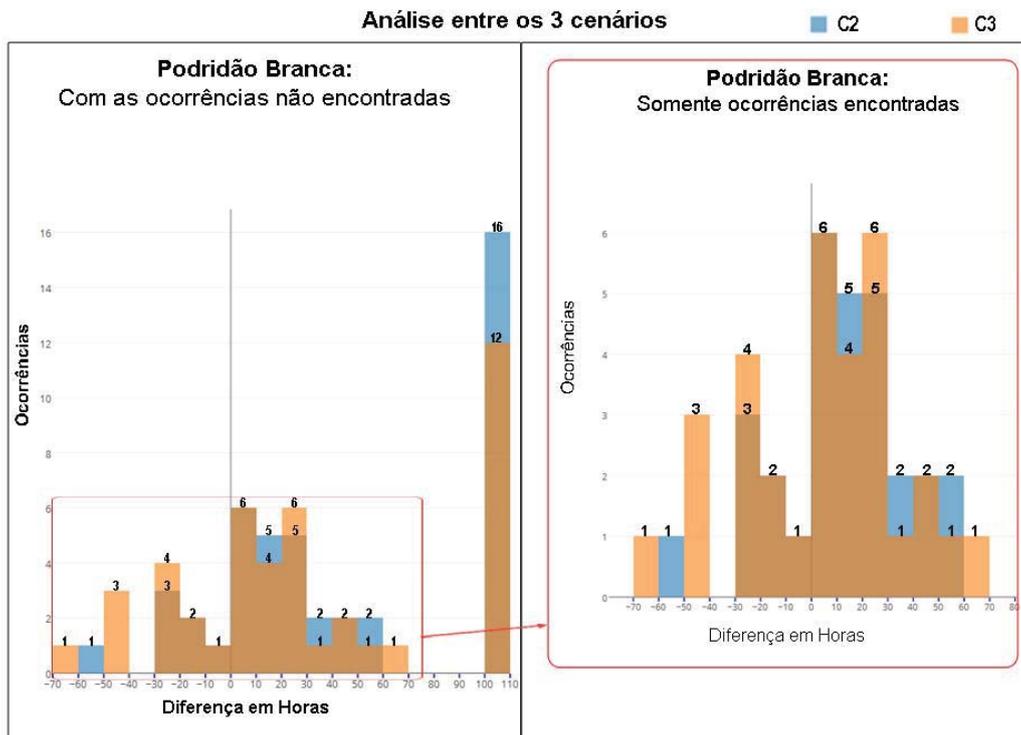


Figura 17. Análise geral da Podridão Branca sob ambos os cenários (C2 e C3) em relação a diferença de horas das ocorrências identificadas em C1, sendo que na execução de C1 obteve 45 ocorrências.

Fonte: Do autor

Evidencia-se que a concentração da diferença de horas em relação a C1 ocorre entre a exata hora da ocorrência e 30 horas posteriores, sendo que ambos os cenários identificaram a mesma quantidade de ocorrências, representando 55,17% das ocorrências identificadas por C2 e 48,48% das identificadas por C3, conforme apresentado na Figura 17.

Investigando cada um dos cenários, conforme Figura 18, e tendo em vista o período de concentração dos dados, constatou-se que ambos os cenários possuem tendência a atrasar a identificação da hora da ocorrência, identificando-as posterior à hora de C1, onde 65,52% das ocorrências de C2 são atrasadas e 60,61% das ocorrências de C3.

Sob um diagnóstico mensal, como pode ser visto na Tabela 6, foi possível identificar que durante quatro meses do período (setembro de 2015, e janeiro, fevereiro e abril de 2016) ambos os cenários identificaram a mesma quantidade de ocorrências. Durante quatro meses (outubro, novembro

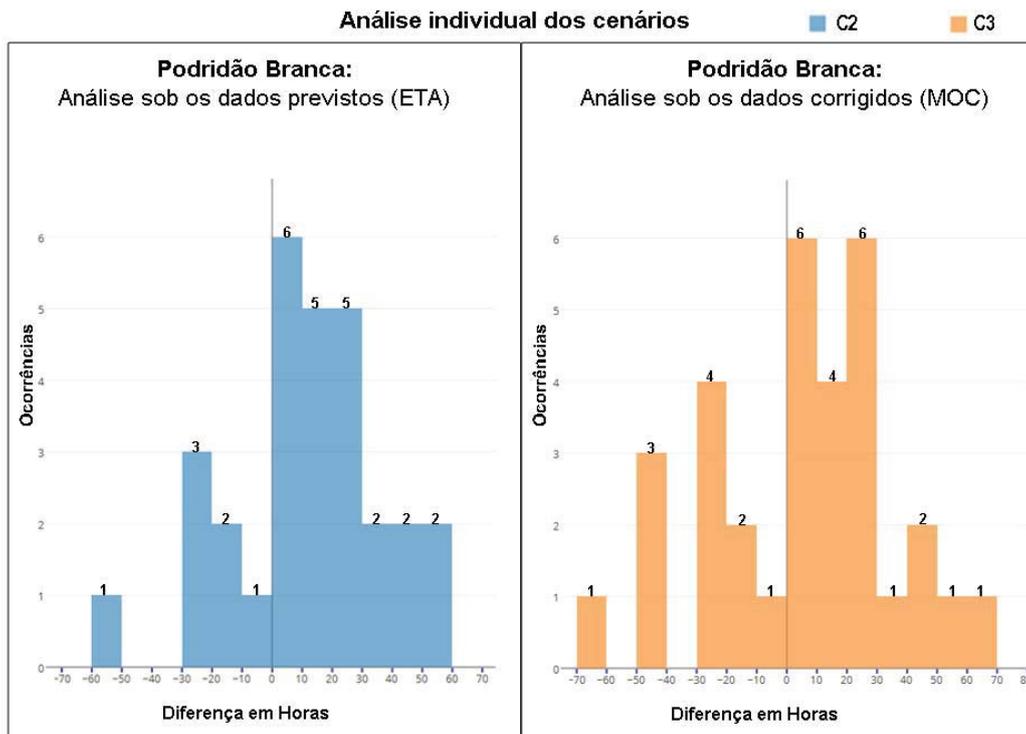


Figura 18. Análise individual da Podridão Branca sob cada um dos cenários em relação as ocorrências de C1, sendo que na execução de C1 obteve 45 ocorrências.

Fonte: Do autor

Tabela 6. Análise mensal da previsão de ocorrências da doença Podridão Branca

Período X Cenário	Quantidade de Ocorrências			%	
	C1	C2	C3	C2 ~ C1	C3 ~ C1
Set. 2015	3	2	2	66,67%	66,67%
Out. 2015	3	1	2	33,33%	66,67%
Nov. 2015	5	4	5	80,00%	100,00%
Dez. 2015	13	9	10	69,23%	76,92%
Jan. 2016	4	1	1	25,00%	25,00%
Fev. 2016	11	8	8	72,73%	72,73%
Mar. 2016	3	1	2	33,33%	66,67%
Abr. 2016	3	3	3	100,00%	100,00%
Mai. 2016	0	0	0	-	-
Jun. 2016	0	0	0	-	-
Set. 2015 ~ Jun. 2016	45	29	33	64,44%	73,33%

e dezembro de 2015, e março de 2016), o cenário C3 atingiu melhores resultados quando comparados a C2. E durante os meses de maio e junho de 2016 não houve ocorrências em C1, assim não houve teste para esse período. Com base nesses dados, e analisando os dados individuais e mensais para a doença da podridão branca sob o cultivo da maçã, foi possível constatar que C3 mostrou atingir melhores resultados.

6.3 MODELO DA PODRIDÃO OLHO DE BOI, VARIEDADE DE MAÇÃ FUJI

Para a previsão da enfermidade *Cryptosporiopsis perennans*, popularmente conhecida como podridão 'Olho de Boi' sob a variedade de maçã Fuji, os elementos influentes utilizados como variáveis de entrada do modelo de simulação são a precipitação, a temperatura do ar, o molhamento foliar e a umidade relativa do ar, todos em dados horários. Com base em algumas verificações das variáveis de entrada, o modelo realiza alguns cálculos para verificar se houve ou não chuva no período, e, se for o caso, a quantidade de horas de molhamento, ou a quantidade de horas sem chuva, e, ainda, é calculado a média de temperatura desse período. O modelo analisa os dados e quando há condições favoráveis para a doença, com base no acúmulo de horas de molhamento e a média de temperatura, a ocorrência da doença pode ser prevista como severa ou moderada. Após a identificação de uma ocorrência uma nova análise é iniciada.

O modelo de simulação com os dados observados para o período de análise identificou 63 ocorrências, nas quais C3 identificou 80,95% e C2 identificou 76,19%. Além disso, a fim de verificar o cenário que identificou com exatidão a hora da ocorrência em relação a C1, constatou-se que C2 obteve sucesso em 8,33%, enquanto C3 identificou 3,17% dessas.

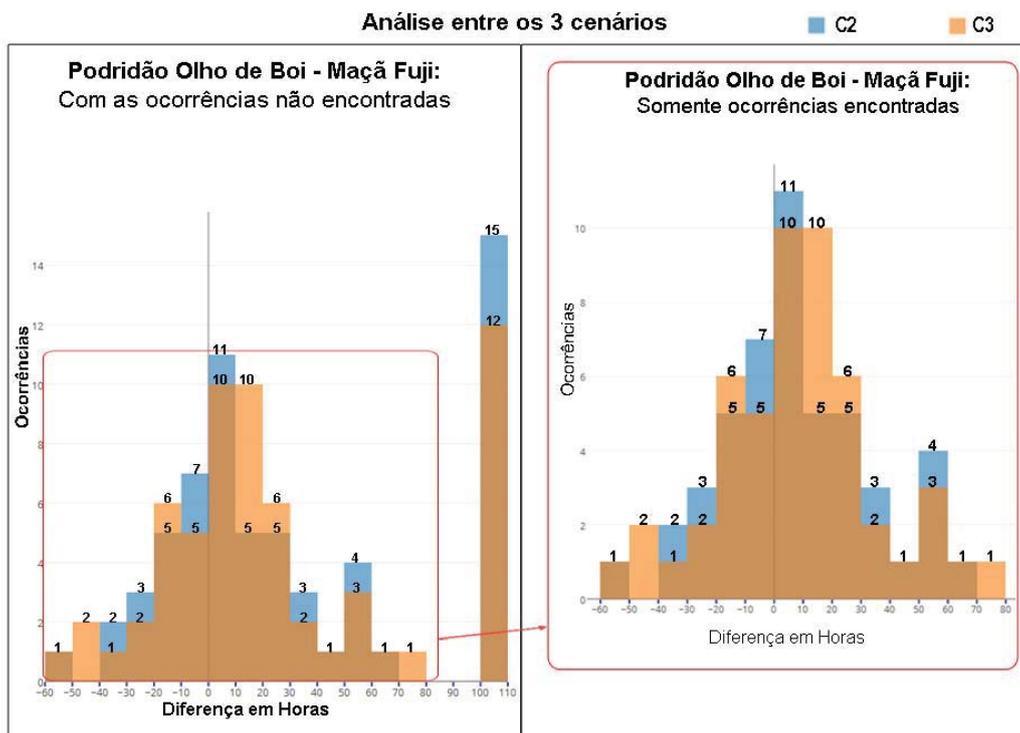


Figura 19. Análise geral da Podridão Olho de Boi (variedade da maçã Fuji) sob ambos os cenários (C2 e C3) em relação a diferença de horas das ocorrências identificadas em C1, sendo que na execução de C1 obteve 63 ocorrências.

Fonte: Do autor

Observa-se, ainda, que a maior concentração das ocorrências em ambos os cenários, como visto na Figura 19, ocorreu entre 10 horas anteriores e 20 horas posteriores a ocorrência em C1, em que C3 identificou 49,02% de suas ocorrências nesse período e C2 47,92% de suas ocorrências.

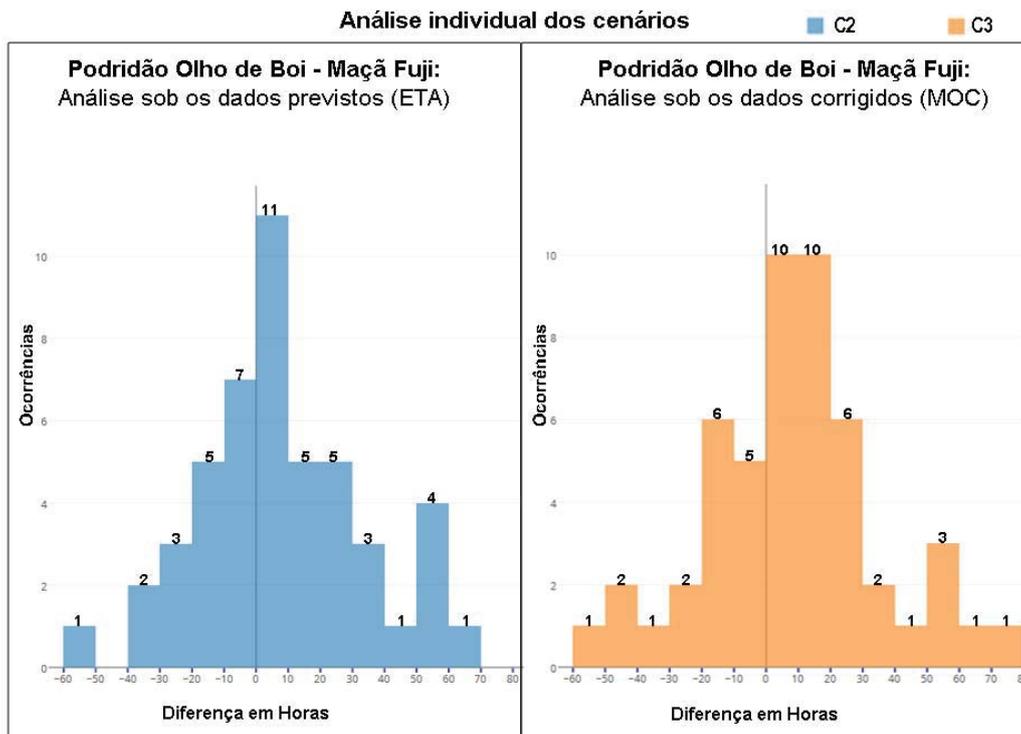


Figura 20. Análise individual da Podridão Olho de Boi (variedade da maçã Fuji) sob cada um dos cenários em relação as ocorrências de C1, sendo que na execução de C1 obteve 63 ocorrências.

Fonte: Do autor

Baseado na Figura 20 é possível verificar a tendência de cada um dos cenários, constatando-se que ambos tendem a atrasar a hora da identificação da ocorrência, identificando-a posterior a hora ocorrida em C1, representando 62,75% das ocorrências identificadas de C3 e 54,17% das identificadas por C2.

Tabela 7. Análise mensal da previsão de ocorrências da doença Podridão 'Olho de Boi', variedade de maçã Fuji

Período X Cenário	Quantidade de Ocorrências			%	
	C1	C2	C3	C2 ~ C1	C3 ~ C1
Set. 2015	11	9	9	81,82%	81,82%
Out. 2015	7	5	6	71,43%	85,71%
Nov. 2015	8	6	7	75,00%	87,50%
Dez. 2015	11	8	8	72,73%	72,73%
Jan. 2016	6	3	5	50,00%	83,33%
Fev. 2016	10	8	8	80,00%	80,00%
Mar. 2016	5	4	4	80,00%	80,00%
Abr. 2016	5	5	4	100,00%	80,00%
Mai. 2016	0	0	0	-	-
Jun. 2016	0	0	0	-	-
Set. 2015 ~ Jun. 2016	63	48	51	76,19%	80,95%

Realizando uma análise mensal sobre os dados, conforme Tabela 7, foi possível constatar que durante quatro meses do período (setembro e dezembro de 2015, e fevereiro e março de 2016) ambos os cenários obtiveram o mesmo sucesso de identificação dos dados. Durante três meses do período (outubro e novembro de 2015, e janeiro de 2016), o cenário C3 apresentou melhoras significativas em relação a C2, e durante um mês do período (abril de 2016) C2 se mostrou mais eficiente. Já durante os meses de maio e junho de 2016, não houve ocorrências em C1, assim, para esse período não houve análise dos dados. Com isso, é possível verificar que, em geral, C3 se mostrou mais eficaz para identificar as ocorrências da enfermidade podridão 'Olho de Boi' sob o cultivar de maçã Fuji.

6.4 MODELO DA PODRIDÃO OLHO DE BOI, VARIEDADE DA MAÇÃ GALA

O modelo de simulação da enfermidade podridão 'Olho de Boi' sob a variedade de maçã Gala, assim como o modelo de previsão da podridão 'Olho de Boi' sob a variedade de maçã Fuji, possui como variáveis de entrada a precipitação, a temperatura do ar, o molhamento foliar e a umidade relativa do ar, todos em dados horários. Para essa previsão também é analisado se houve ou não chuva no período, e com base nessa informação é acumulado a quantidade de horas de molhamento, ou, caso contrário, é acumulado à quantidade de horas sem chuva, e ainda é calculado a média de temperatura do período. Com base no acúmulo de horas de molhamento e a média de temperatura é analisado quando há condições favoráveis para a doença, gerando uma ocorrência (a qual pode ser severa ou moderada) e uma nova análise é iniciada.

Durante o período do estudo de caso a previsão com C1 identificou 35 ocorrências de podridão 'Olho de Boi' para os cultivares de maçã Gala, dessas, C2 obteve sucesso em 80% dos casos, e C3 atingiu 85,71% desses casos, como pode ser visto na Figura 21. Já em relação à identificação exata da hora da ocorrência, C2 pode precisar 7,14% dentre suas ocorrências identificadas, e C3 obteve exatidão em 5,71% de suas ocorrências identificadas.

Como pode ser visto na Figura 21, as ocorrências em ambos os cenários concentram-se entre 10 horas anteriores e 30 horas posteriores a hora da ocorrência em C1, sendo que dentre as ocorrências identificadas, C3 constatou 56,67% nesse período, e em C2 esse período representa 67,86%.

Durante essa análise foi possível constatar a tendência que os dados obtiveram em cada um dos cenários, conforme Figura 22, na qual C2 apresenta uma tendência a atrasar a hora da identificação da ocorrência, representando 53,57% de suas ocorrências identificadas. Já C3 possui uma leve tendência a adiantar os dados, representando 50% de suas ocorrências.

Com base nos dados das ocorrências do período foi possível realizar uma análise mensal dos dados (Tabela 8), sendo que durante oito meses desse período (setembro e dezembro de 2015, e os meses de janeiro a junho de 2016), ambos os cenários conseguiram identificar a mesma quantidade de ocorrências, e durante dois meses (outubro e novembro de 2015), C3 apresentou maior eficácia na identificação das ocorrências. Assim, verifica-se que, em geral, C3 apresentou melhores resultados para identificar as ocorrências da enfermidade 'Olho de Boi' sob o cultivar de maçã Gala.

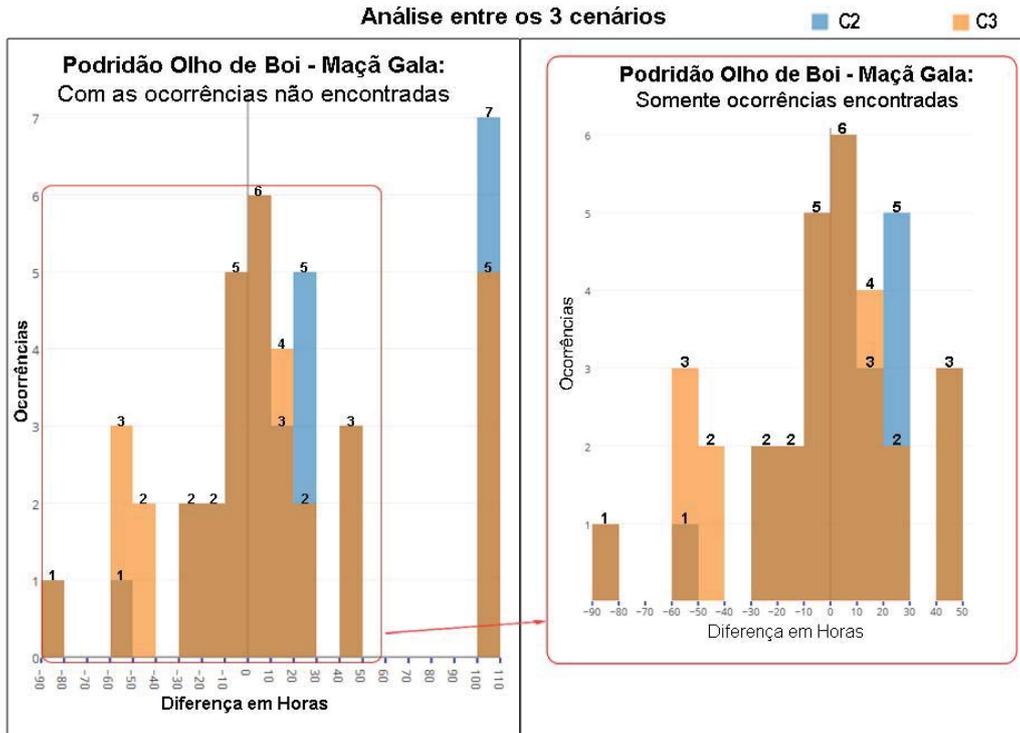


Figura 21. Análise geral da Podridão Olho de Boi (variedade da maçã Gala) sob ambos os cenários (C2 e C3) em relação a diferença de horas das ocorrências identificadas em C1, sendo que na execução de C1 obteve 35 ocorrências.

Fonte: Do autor

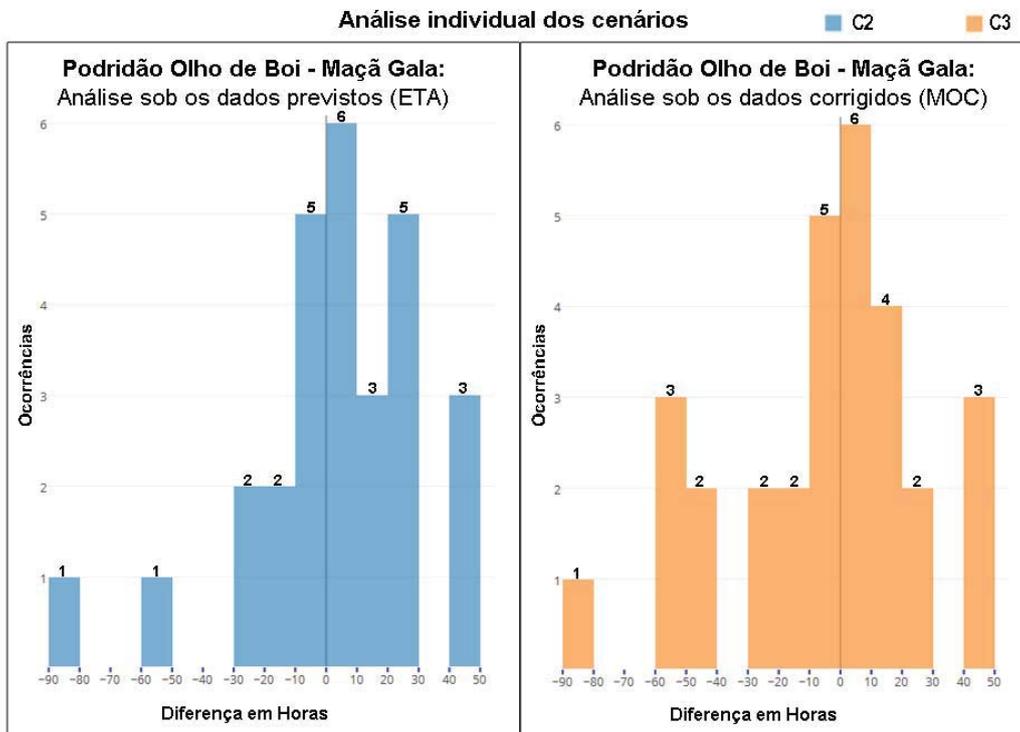


Figura 22. Análise individual da Podridão Olho de Boi (variedade da maçã Gala) sob cada um dos cenários em relação as ocorrências de C1, sendo que na execução de C1 obteve 35 ocorrências.

Fonte: Do autor

Tabela 8. Análise mensal da previsão de ocorrências da doença Podridão 'Olho de Boi', variedade de maçã Gala

Período X Cenário	Quantidade de Ocorrências			%	
	C1	C2	C3	C2 ~ C1	C3 ~ C1
Set. 2015	7	7	7	100,00%	100,00%
Out. 2015	10	8	9	80,00%	90,00%
Nov. 2015	6	5	6	83,33%	100,00%
Dez. 2015	2	1	1	50,00%	50,00%
Jan. 2016	1	0	0	0,00%	0,00%
Fev. 2016	1	0	0	0,00%	0,00%
Mar. 2016	3	2	2	66,67%	66,67%
Abr. 2016	5	5	4	100,00%	100,00%
Mai. 2016	0	0	0	-	-
Jun. 2016	0	0	0	-	-
Set. 2015 ~ Jun. 2016	35	28	30	80,00%	85,71%

6.5 MODELO DA PODRIDÃO OLHO DE BOI, VARIEDADE DE MAÇÃ PINK LADY

Para a previsão da enfermidade podridão 'Olho de boi' sobre os cultivares da variedade de maçã Pink Lady, os dados de comparação e a metodologia utilizada segue o mesmo padrão que os modelos de previsão das enfermidades de podridão 'Olho de boi' sob as variedades de maçã Fuji e Gala, modificando somente as análises finais em que são comparadas as condições favoráveis a doença, podendo essa ser, também, moderada ou severa.

Com base na exploração de dados, evidenciados na Figura 23, foi possível analisar que entre as 53 ocorrências obtidas pelo C1, foram identificadas 79,25% das ocorrências em C2, e 81,13% foram identificadas em C3. Já em relação à identificação exata da hora da ocorrência, com base nas ocorrências identificadas por cada um dos cenários, percebe-se que ambos os cenários apresentaram uma taxa pequena de representação dessas, em que 4,76% das ocorrências identificadas por C2 apresentaram esta exatidão, e 1,89% das ocorrências identificadas por C3.

Verifica-se que os dados possuem uma maior concentração entre a hora exata da ocorrência e 30 horas posteriores, em que 45,24% das ocorrências identificadas por C2 referem-se a esse período, e 46,51% das ocorrências identificadas por C3.

Ainda, é possível constatar que, conforme Figura 24, ambos os cenários possuem uma leve tendência a atrasar o horário da ocorrência da enfermidade, sendo que 52,38% das ocorrências identificadas por C2 referem-se a ocorrências posteriores a identificadas por C1. Já em C3 esses casos referem-se a 58,14% de suas ocorrências identificadas.

Com base na análise mensal (Tabela 9), foi possível verificar que durante sete meses do período do estudo de caso (setembro, novembro e dezembro de 2015, e janeiro, fevereiro, março e junho de 2016), ambos os cenários identificaram a mesma quantidade de ocorrências que C1. Para um mês do período (maio de 2015), C2 mostrou resultados positivos, identificando 100% das ocorrências,

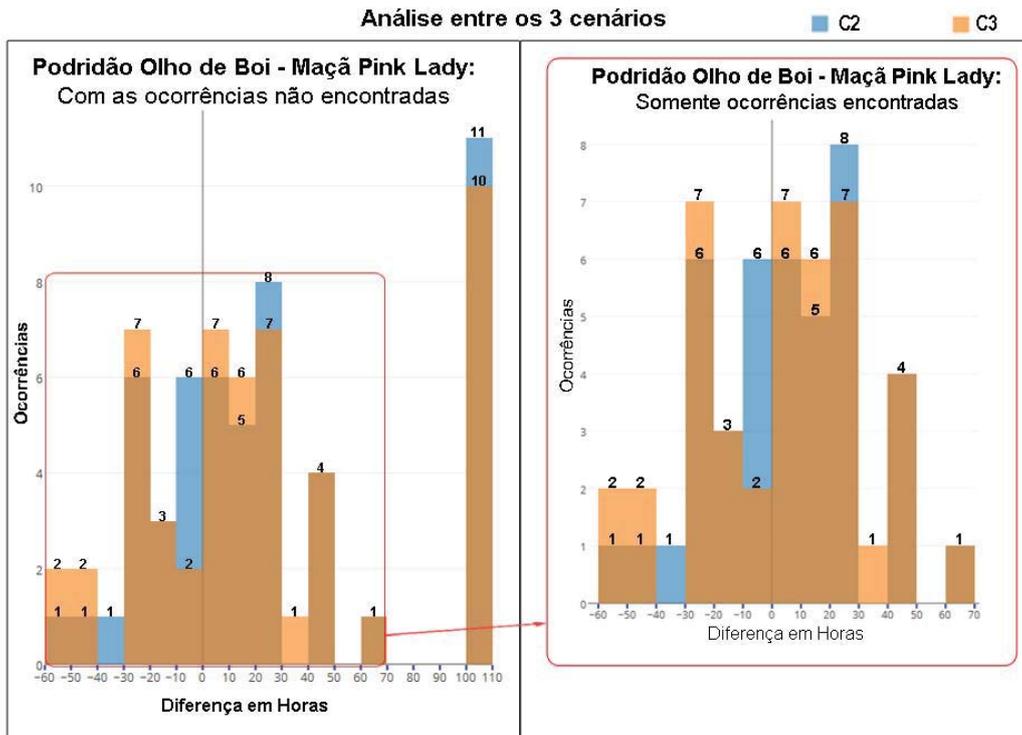


Figura 23. Análise geral da Podridão Olho de Boi (variedade da maçã Pink Lady) sob ambos os cenários (C2 e C3) em relação a diferença de horas das ocorrências identificadas em C1, sendo que na execução de C1 obteve 53 ocorrências.

Fonte: Do autor

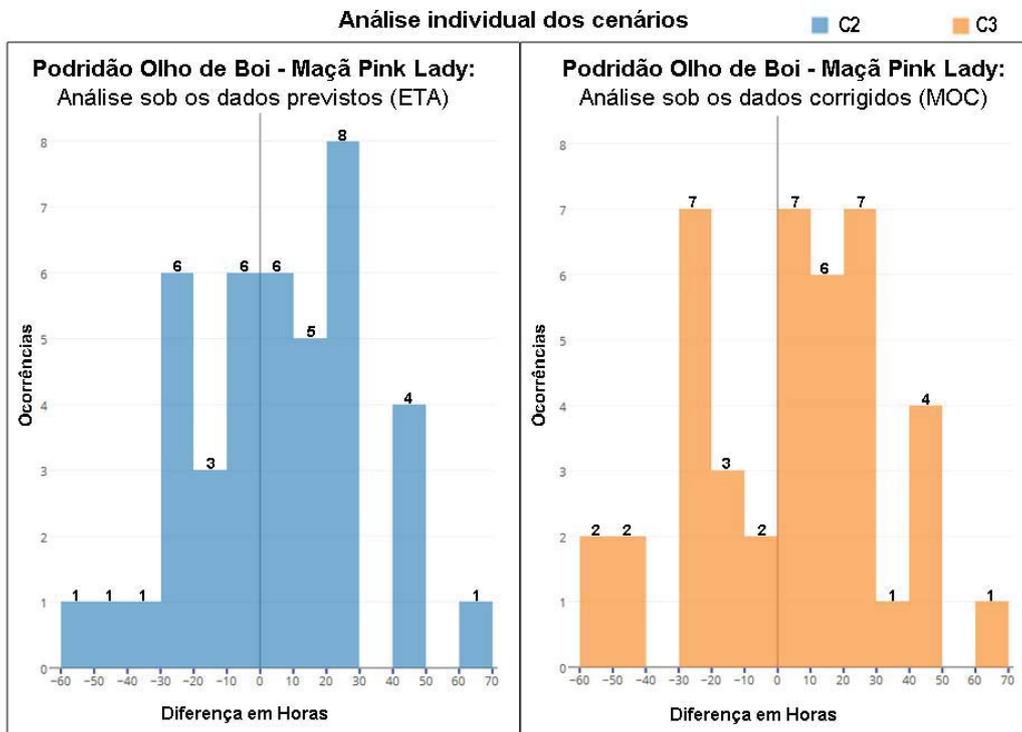


Figura 24. Análise individual da Podridão Olho de Boi (variedade da maçã Pink Lady) sob cada um dos cenários em relação as ocorrências de C1, sendo que na execução de C1 obteve 53 ocorrências.

Fonte: Do autor

Tabela 9. Análise mensal da previsão de ocorrências da doença Podridão 'Olho de Boi', variedade de maçã Pink Lady

Período X Cenário	Quantidade de Ocorrências			%	
	C1	C2	C3	C2 ~ C1	C3 ~ C1
Set. 2015	6	6	6	100,00%	100,00%
Out. 2015	12	10	11	83,33%	91,67%
Nov. 2015	6	6	6	100,00%	100,00%
Dez. 2015	7	6	6	85,71%	85,71%
Jan. 2016	4	1	1	25,00%	25,00%
Fev. 2016	7	5	5	71,43%	71,43%
Mar. 2016	4	2	2	50,00%	50,00%
Abr. 2016	3	2	3	66,67%	100,00%
Mai. 2016	3	3	2	100,00%	66,67%
Jun. 2016	1	1	1	100,00%	100,00%
Set. 2015 ~ Jun. 2016	53	42	43	79,25%	81,13%

enquanto C3 identificou 66,67% dessas. Durante dois meses (outubro de 2015 e abril de 2016), C3 apresentou os melhores resultados, identificando 91,67% das ocorrências de outubro, enquanto C2 identificou 83,33% dessas, e em abril C3 identificou 100% das ocorrências, enquanto C2 identificou 66,67% dessas.

6.6 CONSTATAÇÕES E PERCEPÇÕES GERAIS

A partir da investigação individual de cada enfermidade foi possível identificar o cenário que melhor representou suas ocorrências. Assim, o refinamento obtido pelo MOC (C3) sugere uma melhoria na previsão dessas enfermidades, como pode-se constatar na Tabela 10, na qual para todas as enfermidades os resultados com C3 foram superiores.

Tabela 10. Análise geral da previsão de ocorrências de enfermidades no cultivo de maçã

Enfermidades X Cenário	Qtde. ocorrências			%	
	C1	C2	C3	C2 ~ C1	C3 ~ C1
Mancha Foliar de Gala	44	11	17	25,00%	38,64%
Podridão Branca	45	29	33	64,44%	73,33%
Podridão Olho de Boi - Maçã Fuji	63	48	51	76,19%	80,95%
Podridão Olho de Boi - Maçã Gala	35	28	30	80,00%	85,71%
Podridão Olho de Boi - Maçã Pink Lady	53	42	43	79,25%	81,13%

Na Tabela 11 são apresentados os dados da concentração da diferença de horas das enfermidades nos cenários C2 e C3 em relação às ocorrências de enfermidades com dados observados (C1), sendo que, em geral elas são previstas entre 20 horas anteriores e 30 posteriores a sua ocorrência.

Nesse mesmo contexto, pode-se verificar que a tendência de C3, na maioria das doenças, é de atrasar a hora da identificação das ocorrências apresentando a previsão da hora da ocorrência posterior a identificação de C1, como pode ser visto na Tabela 12.

Tabela 11. Análise da concentração da diferença de horas da identificação da ocorrência de enfermidades no cultivo da maçã em C2 e C3 em relação ao cenário com dados observados (C1).

Enfermidade	Concentração da diferença de horas
Mancha Foliar	-20 a +20
Podridão Branca	0 a +30
Podridão 'Olho de Boi' - Maçã Fuji	-10 a +20
Podridão 'Olho de Boi' - Maçã Gala	-10 a +30
Podridão 'Olho de Boi' - Maçã Pink Lady	0 a +30

Tabela 12. Análise da tendência da identificação da ocorrência de enfermidades no cultivo da maçã em C2 e C3 em relação ao cenário com dados observados (C1).

Enfermidade	Tendência	
	C2 ~ C1	C3 ~ C1
Mancha Foliar	atrasar	atrasar
Podridão Branca	atrasar	atrasar
Podridão 'Olho de Boi' - Maçã Fuji	atrasar	atrasar
Podridão 'Olho de Boi' - Maçã Gala	atrasar	adiantar
Podridão 'Olho de Boi' - Maçã Pink Lady	atrasar	atrasar

7. CONSIDERAÇÕES FINAIS

Os modelos de simulação geram dados relevantes para o auxílio nas tomadas de decisões. Muitas vezes essas decisões são de suma importância dentro da área em que se encontram e ao se realizar uma ação incorreta, ou fora do tempo hábil, podem gerar dados negativamente impactantes. Em decorrência disso, verificou-se que dados de PNT muitas vezes possuem imprecisões e, devido a isso, percebe-se a necessidade de melhorar a sua qualidade numérica.

Com base nessas situações, foi possível observar que modelos de simulação derivados dos dados de PNT, quando esses tratam-se dos dados refinados, podem gerar dados com maior precisão. Assim, com a finalidade de analisar esse impacto, utilizou-se como estudo de caso seis modelos de previsão de algumas doenças na cultura da maçã em execução na plataforma Sisalert, sendo elas: a podridão branca, a mancha foliar da gala, a sarna e a podridão 'olho de boi' das variedades de maçã gala, fuji e pink lady. Este estudo de caso foi aplicado para a região de Vacaria-RS.

Com a finalidade de analisar se houve impacto no modelo de simulação, utilizado como estudo de caso, quando utilizado como dados de condição inicial do modelo os dados de PNT refinados, cada modelo epidemiológico foi executado em três cenários distintos, sendo que cada cenário representou dados de PNT obtidos de diferentes formas: dados observados, obtidos de uma estação meteorológica; dados previstos, gerados pelo modelo Eta, na configuração de grades de 15 Km; e, esses dados gerados pelo Eta corrigidos pelo MOC para as variáveis de temperatura do ar a 2 metros da atmosfera e umidade relativa do ar.

Destaca-se que para o período do estudo de caso não havia registro dos dados de ocorrência das doenças. Assim, assumiu-se como resultado das ocorrências a execução do modelo de simulação com os dados observados da estação do INMET, os quais foram utilizados como base de comparação.

Com isso, foi possível identificar a melhora dos dados climáticos quando corrigidos, e também verificou-se que havia alguns problemas pontuais em relação aos dados de PNT previstos, podendo esses serem resultados da mudança de regime meteorológico, ou mesmo das grandes mudanças de temperaturas, fato que deve-se também ao clima da região utilizada como estudo de caso. Para solucionar esses casos pontuais, foi realizado um ajuste sobre os dados, o qual consiste em uma análise da média do desvio padrão e o erro médio da correção com o MOC dos últimos 21 dias, comparando se cada dado corrigido se mantém dentro do desvio padrão médio, comparando-o com o dado observado. Caso contrário é aplicada a correção com base no erro médio.

Após a análise dos dados, foi possível identificar que das cinco doenças que obtiveram dados para análise, todas apresentaram resultados melhores quando o modelo foi executado utilizando os dados de PNT corrigidos como condição inicial. Além de verificar que os dados corrigidos propõem resultados melhores para a previsão das doenças, é possível constatar, ainda, que a correção trata-se somente dos dados de umidade relativa do ar e temperatura, e que a melhora da correção mostra-se significativamente maior para a umidade relativa, a qual não é utilizada como condição inicial de todos os modelos de previsão de doenças, como é o caso da Mancha Foliar de Gala. Nesse caso a variável

de umidade relativa do ar foi utilizada somente como dado para cálculo da temperatura em ponto de orvalho.

Sabe-se que, em geral, os modelos de simulação apresentam resultados de uma simplificação da realidade, portanto esses podem influenciar negativamente nas tomadas de decisões. A partir disso, com os resultados deste trabalho obteve-se uma melhora nos resultados dos modelos de simulação das enfermidades no cultivo da maçã, gerando dados mais próximos da realidade apresentada.

Por fim, com este trabalho, buscou-se verificar o impacto da utilização de dados refinados como condição inicial de modelos de simulação e, assim, constatou-se que tal abordagem pode auxiliar as diferentes áreas em suas tomadas de decisões, além de auxiliar pesquisadores interessados no benefício de tal enfoque.

7.1 DISSEMINAÇÃO DO CONHECIMENTO

Com a finalidade de auxiliar os pesquisadores interessados na área, foram realizadas algumas publicações relacionadas ao trabalho, as quais encontram-se elencadas abaixo:

- Publicação e apresentação do artigo intitulado "Correção estatística do resultado da previsão do tempo aplicando a técnica Model Output Calibration (MOC)" no III Workshop-Escola de Informática Teórica (WEIT) 2015.
- Publicação e Apresentação de resumo trabalho intitulado "Correção estatística da previsão do tempo aplicando o Model Output Calibration (MOC)" na II Semana do Conhecimento, 2015. Evento organizado pela Universidade de Passo Fundo.
- Publicação do artigo intitulado "Aplicação do método Model Output Calibration para a correção estatística do resultado da previsão do tempo" no XXXVI Congresso Nacional de Matemática Aplicada e Computacional, 2016.
- Publicação do trabalho intitulado "Statistical Correction of the Result of Weather Forecast by Applying the Model Output Calibration" na revista Electronic Notes in Theoretical Computer Science, v. 324, p. 79-90, 2016.

7.2 TRABALHOS FUTUROS

Dentre os problemas enfrentados no decorrer do trabalho, estava justamente o de encontrar um modelo de simulação para ser o estudo de caso, um modelo que utilizasse as variáveis corrigidas pelo MOC e que fosse possível realizar as comparações. Assim, percebeu-se que, após as análises, um dos modelos de simulação de algumas doenças (Mancha foliar de Gala) não utilizava uma das variáveis como condição inicial do modelo, sendo que foram corrigidas somente as variáveis de temperatura e umidade relativa. Percebeu-se, com isso, a necessidade de corrigir as demais variáveis

utilizadas como condição inicial desses modelos (como é o caso do molhamento foliar), o que mostra a possibilidade de gerar uma melhora ainda mais significativa sobre os modelos.

Verificou-se, ainda, que ocorreram algumas situações pontuais onde a correção da previsão não conseguia se manter com a mesma tendência que os dados observados, o que pressupõem que se deva ao clima da região e as grandes alterações no estado do tempo. Logo, como trabalho futuro, em parceria com os pesquisadores do CPTEC/INPE, deve-se pensar em uma forma de adaptação sobre o algoritmo do MOC, para que ele se adapte a essas situações.

Além disso, a correção realizada pelo MOC ocorre somente para a previsão da hora 24 a 47, ou seja, do dia seguinte, e para os demais dias previstos é replicado o erro do dia corrigido. Assim, verifica-se a necessidade de correção das demais horas da previsão.

Por fim, outro trabalho futuro refere-se à aplicação da correção em outros modelos de simulação da área agrícola, como modelos de crescimento de plantas e de enfermidades aplicado a outras culturas como a do trigo, a do morango e a da videira.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] FRANÇA, J. R. A. et al. Simulação de um modelo de circulação geral com grade em zoom centrada no estado do Rio de Janeiro, Brasil. In: *XI Congresso Brasileiro de Meteorologia*. [S.l.: s.n.], 2000.
- [2] CHWIF, L.; MEDINA, A. C. *Modelagem e Simulação de Eventos Discretos*. LEONARDO CHWIF. 320 p. Disponível em: <<https://books.google.com/books?id=VOHV4tEZakoC&pgis=1>>. Acesso em: 05 Mai. 2015.
- [3] ESPACIAL, I. N. de P. *Laboratório de modelagem atmosférica (LMA)*. 2015. Disponível em: <<http://lma.cptec.inpe.br/>>. Acesso em: 20 Mar. 2017.
- [4] ESPACIAL, I. N. de P. *Diretório de arquivos do V Workshop do modelo Eta*. Disponível em: <<ftp://ftp1.cptec.inpe.br/etamd/Workshop/WorkEtaV>>. Acesso em: 02 Jun. 2015.
- [5] TOMÉ, R. F. D. *Previsão do tempo com modelos de mesoscala: Casos de estudo com o modelo MM5 nos Açores*. Tese (Doutorado) — Faculdade de Ciências, Universidade de Lisboa, Especialização em Meteorologia, São José dos Campos, 2004. Disponível em: <<https://goo.gl/y97JuX>>. Acesso em: 20 Nov. 2015.
- [6] NUNES, A. *Inicialização física em modelos de previsão de tempo e estudo de seus efeitos na partição de energia em modos verticais e horizontais nos trópicos e na América do Sul*. Tese (Doutorado), 2002. Disponível em: <<https://goo.gl/TXSbek>>. Acesso em: 12 Abr. 2015.
- [7] CHOU, S. C. *Modelagem Numérica (Introdução a PNT)*. 2010. Disponível em: <<https://goo.gl/tL7GPZ>>. Acesso em: 10 Jun. 2015.
- [8] UNIST Climate Environment Modeling Laboratory (UCEM): Global Climate Model. 2013. Disponível em: <<http://climate.unist.ac.kr/research/globalClimateModel.sko>>. Acesso em: 23 Apr. 2016.
- [9] CIÊNCIAS, U. I. F. de. *Previsão Numérica*. 2015. Disponível em: <<http://www.ipmet.unesp.br>>. Acesso em: 11 Jun. 2015.
- [10] FREITAS, S. R. et al. The Coupled Aerosol and Tracer Transport model to the Brazilian developments on the Regional Atmospheric Modeling System (CATT-BRAMS) – Part 1: Model description and evaluation. *Atmospheric Chemistry and Physics*, Copernicus GmbH, v. 9, n. 8, p. 2843–2861, abr. 2009. Disponível em: <<http://www.atmos-chem-phys.net/9/2843/2009/acp-9-2843-2009.html>>. Acesso em: 11 Set. 2015.
- [11] MESINGER, F. Limited Area Modeling: Beginnings, state of the art, outlook. In: . [s.n.]. Disponível em: <<ftp://ftp1.cptec.inpe.br/etamd/Publications/Mesinger2001.potsdam.symp.book.pdf>>.
- [12] CAVALCANTI, E. P. Métodos de Modelagem Numérica. Disponível em: <http://www.dca.ufcg.edu.br/mna/MNA_modulo_02.pdf>.

- [13] RESEARCH, U. C. for A. *Introduction to Tropical Meteorology, Ch. 9: Observation, Analysis, and Prediction*. 2011. Disponível em: <<https://goo.gl/WGSV94>>. Acesso em: 15 Jun. 2015.
- [14] CHOU, S. C. *MODELO REGIONAL ETA*. Disponível em: <<https://goo.gl/mU0sJ6>>. Acesso em: 02 Jun. 2015.
- [15] CHOU, S. C. et al. Evaluation of the Eta Simulations Nested in Three Global Climate Models. *American Journal of Climate Change*, Scientific Research Publishing, v. 03, n. 05, p. 438–454, dez. 2014. Disponível em: <<http://www.scirp.org/journal/PaperInformation.aspx?PaperID=52877&#abstract>>. Acesso em: 17 Mai. 2015.
- [16] MESINGER, F.; JANJIC, Z. I. Noise due to time-dependent boundary conditions in limited area models. *The GARP Programme on Numerical Experimentation*, v. 4, p. 31–32, 1974.
- [17] INPE. *Eta Model*. 1995–2006. Disponível em: <<http://etamodel.cptec.inpe.br>>. Acesso em: 23 Mar. 2015.
- [18] MAO, Q. et al. An optimal model output calibration algorithm suitable for objective temperature forecasting. *American Meteorological Society*, v. 14, p. 190–202, 1999.
- [19] WILKS, D. S. *Statistical Methods in the Atmospheric Sciences*. Academic Press. 676 p. Disponível em: <<https://books.google.com/books?id=IJuCVtQ0ySIC&pgis=1>>. Acesso em: 12 Mar. 2015.
- [20] AL., G. et. Crop simulation models as tools in computer laboratory and classroom-based education. *Journal of Natural Resources and Life Sciences Education*, p. 48–54, 2002.
- [21] MURTHY, V. R. K. Crop growth modeling and its applications in agricultural meteorology. *Satellite remote sensing and GIS applications in agricultural meteorology*, p. 235, 2004. Disponível em: <<http://www.wamis.org/agm/pubs/agm8/Paper-12.pdf>>. Acesso em: 16 Set. 2015.
- [22] PAVAN, W. *Técnicas de Engenharia de Software de Software Aplicadas a Modelagem e Simulação de Doenças e Plantas*. Dissertação (Mestrado) — Universidade de Passo Fundo, doutorado em Agronomia, Passo Fundo, 2007.
- [23] YANG, X. B.; DOWLER, W. M.; TSCHANZ, A. T. A Simulation Model for Assessing Soybean Rust Epidemics. *Journal of Phytopathology*, v. 133, n. 3, p. 187–200, nov. 1991. Disponível em: <<http://doi.wiley.com/10.1111/j.1439-0434.1991.tb00153.x>>. Acesso em: 6 Mar. 2016.
- [24] SUTHERST, R. A computerised system for matching climates in ecology. *Agriculture, Ecosystems & Environment*, v. 13, n. 3-4, p. 281–299, jul. 1985. Disponível em: <<http://www.sciencedirect.com/science/article/pii/0167880985900167>>. Acesso em: 9 Abr. 2016.
- [25] SANTOS, M. C. dos; FURTADO, E. L.; SANHUEZA, R. M. V. Controle da sarna da macieira com utilização da tabela de mills, na região de Vacaria-RS. *Summa Phytopathologica*, v. 31, p. 254–260, 2005.

- [26] SPOLTI, P. *Epidemiologia e controle de fuligem e sujeira de mosca em macieiras (Malus x domestica Borkh.) no Sul do Brasil*. Tese (Doutorado) — Universidade Federal do Rio Grande do Sul, 2009.
- [27] BONETI, J.; KATSURAYAMA, Y.; SANHUEZA, R. *Manejo da sarna na Produção Integrada de Maçã*. [S.l.]: Embrapa Uva e Vinho, 2001.
- [28] BLEICHER, J. et al. Doenças da macieira e outras pomáceas. *Kimati, H.; Amorim, L. Bergamin Filho, A., Camargo, LEA*, p. 473–474, 1997.
- [29] SANHUEZA, R. M. V. et al. *Manejo das doenças de verão na Produção Integrada de Maçã*. Bento Gonçalves: Embrapa Uva e Vinho, 2002. Disponível em: <<http://www.cnpuv.embrapa.br/publica/circular/cir036.pdf>>. Acesso em: 13 Set. 2016.
- [30] MACHARDY, W. simple, quick technique for determining apple scab infection periods. *Plant disease reporter*, Rep 63, p. 199 – 204, 1979.
- [31] DENARDI, F.; BERTON, O.; SPENGLER, M. M. Resistência genética à podridão amarga em maçãs, determinada pela taxa de desenvolvimento da doença em frutos com e sem ferimentos. *Revista Brasileira de Fruticultura*, sciELO, v. 25, p. 494 – 497, Dec 2003. Disponível em: <<https://goo.gl/l5yUSV>>. Acesso em: 16 Set. 2016.
- [32] MILLS, W. Efficient use of sulfur dusts and sprays during rain to control apple scab. *New York Agricultural Experiment Station, Ithaca Extension Bulletin*, 630, p. 4–7, 1944.
- [33] MACHARDY, W. simple, quick technique for determining apple scab infection periods. *Plant disease reporter*, Rep 63, p. 199 – 204, 1979.
- [34] SANHUEZA, R. M. V. et al. *Características e Controle das Doenças de Verão na Produção Integrada de Maçã*. MANEJO da Macieira no sistema de Produção Integrada de Frutas. 21. ed. Bento Gonçalves, SC: Embrapa Uva e Vinho, 2006. 51 – 60 p. Disponível em: <<https://goo.gl/SV9e5L>>. Acesso em: 5 Ago. 2016.
- [35] SANHUEZA, R. M. V. et al. *Características e controle da podridão “olho de boi” nas maçãs do sul do Brasil*. Bento Gonçalves: Embrapa Uva e Vinho, 2006. Disponível em: <<http://ainfo.cnptia.embrapa.br/digital/bitstream/item/55164/1/cir066.pdf>>. Acesso em: 29 Set. 2016.
- [36] KALMAN, R. A New Approach to Linear Filtering and Prediction Problems. *Transactions of the ASME – Journal of Basic Engineering*, n. 82 (Series D), p. 35 – 45, 1960.
- [37] KIM, I.; QUADRO, M. d.; MARENGO, J. Sobre interpretação estatística da saída do modelo numérico. In: *Anais do X Congresso Brasileira de Meteorologia, Brasília*. [S.l.]: SBMET, 1998. p. 26–30.

- [38] LIBONATI, R.; TRIGO, I.; DACAMARA, C. Aplicação do filtro de Kalman na correção das previsões de temperatura a 2 metros do ECMWF. In: *Anais do XIII Congresso Brasileiro de Meteorologia*. [S.l.: s.n.], 2004.
- [39] CARVALHO, J. R. P. de; ASSAD, E. D.; PINTO, H. S. Kalman filter and correction of the temperatures estimated by {PRECIS} model. *Atmospheric Research*, v. 102, n. 1–2, p. 218 – 226, 2011. ISSN 0169-8095. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0169809511002389>>. Acesso em: 16 Mai. 2015.
- [40] ANOCHI, J. A. *Previsão climática de precipitação por redes neurais autoconfiguradas*. Tese (Doutorado) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, Doutorado em Computação Aplicada, São José dos Campos, 2015.
- [41] CINTRA, R.; De Campos Velho, H.; TODLING, R. Redes Neurais Artificiais na Melhoria de Desempenho de Métodos de Assimilação de Dados: Filtro de Kalman. *TEMA - Tendências em Matemática Aplicada e Computacional*, v. 11, n. 1, mar 2010. Disponível em: <<https://goo.gl/qXPPQp>>. Acesso em: 11 Set. 2015.
- [42] FURTADO, H.; VELHO, H. de C.; MACAU, E. Assimilação de dados com redes neurais artificiais em equações diferenciais. In: *Anais do DINCON*. [S.l.: s.n.], 2011. p. 595–598.
- [43] FERREIRA, S. P. *Estudo comparativo entre o modelo dinâmico BRAMS e os modelos estatísticos MOS e MOC*. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Sul, mestrado em sensoriamento remoto, Porto Alegre, 2011.
- [44] KLEIN, B.; LEWIS, M.; ENGER, I. Objective prediction of 5 day mean temperature during winter. *Journal of Meteorology*, v. 16, p. 672–682, 1959.
- [45] RAJEEVAN, M. et al. Development of a perfect prognosis probabilistic model for prediction of lightning over south-east india. *Journal of Earth System Science*, v. 121, n. 2, p. 355–371, 2012. Disponível em: <<http://dx.doi.org/10.1007/s12040-012-0173-y>>. Acesso em: 23 Out. 2015.
- [46] GLAHN, H. R.; LOWRY, D. A. The use of model output statistics (MOS) in objective weather forecasting. *J. Appl. Meteor*, v. 11, p. 1203–1211, 1972.
- [47] JACKS, E. J. B. et al. New ngm-based mos guidance for maximum/minimum temperature, probability of precipitation, cloud amount, and sea surface wind. *Wea. Forecasting*, v. 5, p. 128–138, 1990.
- [48] MAINI, P. Forecasting maximum and minimum temperatures by statistical interpretation of numerical weather prediction model output. *Weather and forecasting*, v. 18, p. 938–952, 2003.
- [49] MARZBAN CAREN; SANDGATHE, S. K. E. MOS, Perfect Prog, and Reanalysis. *Monthly Weather Review*, v. 134, p. 657–663, 2006.

- [50] CARVALHO, J. R. P. de. Uso do Filtro de Kalman para correção de temperatura estimada pelo Precipitação no período 2000-2010. dec 2011. Disponível em: <<https://goo.gl/mSZG8x>>. Acesso em: 11 Jun. 2015.
- [51] MILLER, R. N.; GHIL, M.; GAUTHIEZ, F. Advanced Data Assimilation in Strongly Nonlinear Dynamical Systems. *Journal of the Atmospheric Sciences*, v. 51, n. 8, p. 1037–1056, apr 1994. Disponível em: <<https://goo.gl/3Vv1Yz>>. Acesso em: 2 Nov. 2015.
- [52] KALNAY, E. *Atmospheric modeling, data assimilation and predictability*. [S.l.]: Cambridge University Press, 2003.
- [53] CHOU, S. C. et al. Refinamento estatístico das previsões horárias de temperatura a 2m do modelo Eta em estações do nordeste do Brasil. 2007. 287-296 p. Disponível em: <<http://doi.org/10.1590/S0102-77862007000300001>>. Acesso em: 24 Ago. 2015.
- [54] FERREIRA, S. P.; VARONE, F.; ALVEZ, R. d. C. M. Uso do trmm para a correção estatística da chuva prevista pelo modelo brams. *IV Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação*, p. 01–09, 2012.
- [55] TOZZY, L. R. L.; SILVA, M. G. A. J. d. Calibragem estatística das previsões de temperatura do modelo Eta. In: XII CONGRESSO BRASILEIRO DE METEOROLOGIA. Foz do Iguaçu, 2002. Disponível em: <<https://goo.gl/9yLq0h>>. Acesso em: 21 Jul. 2015.
- [56] EVANGELISTA, E. de F. D. Refinamento das previsões de intensidade do vento do modelo eta. In: SEMINÁRIO DE INICIAÇÃO CIENTÍFICA DO INPE (SICINPE), 2005, SÃO JOSÉ. 2005. Disponível em: <<http://urlib.net/sid.inpe.br/iris@1916/2005/09.27.12.21>>. Acesso em: 30 Mai. 2016.
- [57] HOLBIG, C. A. et al. Correção estatística das previsões de temperatura e umidade relativa a 2 metros do Modelo Eta-15km para aprimorar as estimativas de carga do sistema elétrico. In: XVI CONGRESSO BRASILEIRO DE ENERGIA. [s.n.], 2015. Disponível em: <<https://goo.gl/d5HVcO>>. Acesso em: 22 Abr. 2016.
- [58] MARCHIORI, L. A. da C. Avaliação da estimativa da evapotranspiração obtida através do modelo BRAMS visando o uso em modelo de estimativa de rendimento da soja no Rio Grande do Sul. 2006. Disponível em: <<http://www.lume.ufrgs.br/handle/10183/21629>>. Acesso em: 17 Mai. 2016.
- [59] SISALERT. *Sobre o portal Sisalert*. Disponível em: <<http://dev.sisalert.com.br/novosisalert>>. Acesso em: 10 Ago. 2016.
- [60] PAVAN, W. et al. Web-based system to true-forecast disease epidemics–sisalert. In: AMERICAN SOCIETY OF AGRICULTURAL AND BIOLOGICAL ENGINEERS. *Computers in Agriculture and Natural Resources, 23-25 July 2006, Orlando Florida*. [S.l.], 2006. p. 655.
- [61] SANHUEZA, R. M. V.; PAVAN, W. Controle de doenças da macieira utilizando sistema de alerta Sisalert no Rio Grande do Sul. *Fitopatologia Brasileira*, v. 29, p. 84, 2004.

- [62] RAO, P.; GILLESPIE, T.; SCHAAFSMA, A. Estimating wetness duration on maize ears from meteorological observations. *Canadian Journal of Soil Science*, NRC Research Press, v. 78, n. 1, p. 149–154, 1998.
- [63] MONTONE, V. O. et al. Evaluation of leaf wetness duration models for operational use in strawberry disease-warning systems in four us states. *International Journal of Biometeorology*, Springer, p. 1–14, 2016.
- [64] MCNOLDY, B. *Calculate Temperature, Dewpoint, or Relative Humidity*. Disponível em: <<http://andrew.rsmas.miami.edu/bmcnoldy/Humidity.html>>. Acesso em: 21 Out. 2016.