

**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE TECNOLOGIA E RECURSOS NATURAIS
UNIDADE ACADÊMICA DE CIÊNCIAS ATMOSFÉRICAS**

**PROGRAMA DE PÓS-GRADUAÇÃO EM
METEOROLOGIA**



TESE DE DOUTORADO

Fabício Daniel dos Santos Silva

**Cenários Climáticos Atuais e Futuros da Produtividade
do Algodão Herbáceo no Nordeste do Brasil**

Campina Grande, Dezembro de 2014



UNIVERSIDADE FEDERAL DE CAMPINA GRANDE

PROGRAMA DE PÓS-GRADUAÇÃO EM METEOROLOGIA

UNIDADE ACADÊMICA DE CIÊNCIAS ATMOSFÉRICAS

CENTRO DE TECNOLOGIA E RECURSOS NATURAIS

**CENÁRIOS CLIMÁTICOS ATUAIS E FUTUROS DA
PRODUTIVIDADE DO ALGODÃO HERBÁCEO NO NORDESTE DO
BRASIL**

FABRÍCIO DANIEL DOS SANTOS SILVA

CAMPINA GRANDE - PB

Dezembro de 2014

**CENÁRIOS CLIMÁTICOS ATUAIS E FUTUROS DA PRODUTIVIDADE DO
ALGODÃO HERBÁCEO NO NORDESTE DO BRASIL**

FABRÍCIO DANIEL DOS SANTOS SILVA

Tese apresentada ao Programa de Pós-Graduação em Meteorologia da Universidade Federal de Campina Grande em cumprimento às exigências do Regulamento do Curso para a obtenção do título de Doutor em Meteorologia.

Área de concentração: **Meteorologia de Meso e Grande Escalas**

Sub-área: **Climatologia**

Orientador: Prof. Dr. Pedro Vieira de Azevedo

CAMPINA GRANDE - PB

Dezembro de 2014

FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA CENTRAL DA UFCG

S586c Silva, Fabrício Daniel dos Santos.

Cenários climáticos atuais e futuros da produtividade do algodão herbáceo no nordeste do Brasil / Fabrício Daniel dos Santos Silva. – Campina Grande, 2014.

105 f. : Color.

Tese (Doutorado em Meteorologia) – Universidade Federal de Campina Grande, Centro de Tecnologia e Recursos Naturais.

"Orientação: Prof. Dr. Pedro Vieira de Azevedo".
Referências.

1. Modelo Agrometeorológico. 2. Cenários Climáticos Futuros. 3. Produtividade do Algodão. I. Pedro Vieira de Azevedo. II. Título.


CDU 551.509:633.051(043)


FABRÍCIO DANIEL DOS SANTOS SILVA

CENÁRIOS CLIMÁTICOS ATUAIS E FUTUROS DA PRODUTIVIDADE DO
ALGODÃO HERBÁCEO NO NORDESTE DO BRASIL

TESE APROVADA EM 05/12/2014

BANCA EXAMINADORA


Prof. Dr. PEDRO VIEIRA DE AZEVEDO
Unidade Acadêmica de Ciências Atmosféricas
Universidade Federal de Campina Grande


Prof. Dr. CARLOS ANTONIO COSTA DOS SANTOS
Unidade Acadêmica de Ciências Atmosféricas
Universidade Federal de Campina Grande


Prof. Dr. VICENTE DE PAULO RODRIGUES DA SILVA
Unidade Acadêmica de Ciências Atmosféricas
Universidade Federal de Campina Grande


Profª. Dra. WERÔNICA MEIRA DE SOUZA
Unidade Acadêmica de Garanhuns
Universidade Federal Rural de Pernambuco


Dra. DANIELLE BARROS FERREIRA
Instituto Nacional de Meteorologia

DEDICATÓRIA

À Deus, que não apenas nos criou, mas nos deu o dom de aprender. Sem isto, não chegaríamos a nenhum lugar.

À meus pais, Olivaldo e Ivone, que na humildade, me incentivaram a vencer na vida com honestidade, sem pensar em outro caminho que não o estudo.

À minha família, que acreditou sempre em mim.

Ao meu amor, Rafaela, que me acompanha desde 2011 nesta jornada, me ensinando e ajudando muito.

AGRADECIMENTOS

À Deus, À meus pais, irmão e irmãs, sobrinhos e sobrinhas, cunhados e cunhada, por integrarem a base de tudo na vida de um ser humano: a família.

À Rafaela, pelo companheirismo e amor durante estes últimos quatro anos.

Aos professores do Departamento de Meteorologia da UFCG, que acreditaram neste projeto de levar mais qualificação aos funcionários do INMET, e se dispuseram a compartilhar de seus conhecimentos conosco.

À Divanete, pelo seu sempre excelente trabalho, e simpatia.

Ao professor e amigo Pedro Vieira de Azevedo, por aceitar me orientar mais uma vez. Primeiro na Graduação, agora no Doutorado.

Ao INMET, na pessoa de seu Diretor, Antonio Divino Moura, pela iniciativa do acordo de cooperação entre o Departamento de Meteorologia da UFCG e o INMET, que propiciou a formação de Mestres e Doutores.

À Lauro Fortes, coordenador do setor de pesquisa e desenvolvimento do INMET, onde trabalho, pelo incentivo.

Aos grandes amigos do INMET, Mozar, Luiz, Danielle, Márcia, Edmundo, Sidney, Kléber, Alan, Adeilda, por tornarem o ambiente de trabalho sempre prazeroso, divertido, e com muitas idéias criativas em prol da ciência meteorológica.

Aos colegas do Serviço Meteorológico Nacional, da Argentina, pelos ensinamentos com o programa de controle de qualidade.

Ao amigo Gabriel Sarmanho, pelas dicas com o pacote estatístico *MICE*, da linguagem de programação R.

Ao colega Pablo Borges de Amorim, da Universidade de Dresden, Alemanha, pelo compartilhamento de idéias em torno do *downscaling* estatístico.

Ao colega José Eduardo Monteiro, da Embrapa Informática Agropecuária, pelos ensinamentos com o modelo agrometeorológico.

À José Manuel Gutiérrez Llorente, do Instituto de Física de Cantabria, Espanha, por abrir as portas do projeto *ENSEMBLES Downscaling Portal*, que foi importantíssimo para a conclusão das pesquisas.

A todos, meu muito obrigado.

RESUMO

Este trabalho teve como objetivo principal gerar cenários climáticos futuros, e avaliar os impactos na produtividade do algodão herbáceo através de um modelo agrometeorológico, quando comparada com a produtividade atual observada. Um downscaling estatístico foi empregado para obter as series futuras das variáveis meteorológicas necessárias para o calculo da produtividade, obtido com um modelo agrometeorológico devidamente calibrada para a realidade do algodão na região semi-arida do Nordeste brasileiro. As series temporais das variáveis meteorológicas tiveram suas falhas devidamente preenchidas e passaram por um rigoroso sistema de controle de qualidade. As projeções futuras calculadas para os cenários climáticos A1B e A2, dos modelos ECHAM5-OM e HadGEM2-ES foram unanimes em apontar redução significativa das chuvas e aumento das temperaturas. A evapotranspiração, conseqüentemente, também apresenta tendência de aumento para o horizonte futuro estudado, de 2020 a 2080. Como impacto para a cultura do algodão, prevê-se, para 23 municípios estudados do semiárido nordestino, redução significativa da produtividade, que pode ser reduzida a aproximadamente metade da produtividade atual observada.

Palavras-chave: Modelo agrometeorológico, cenários climáticos futuros, produtividade do algodão.

ABSTRACT

This paper had as its primary objective the generation of future climatic scenarios and the evaluation of impacts over the productivity of upland cotton through an agrometeorological model, when compared to the current productivity observed. A statistical downscaling was used to obtain the future series of meteorological variables needed for the calculation of productivity, obtained with an agrometeorological model appropriately calibrated for the reality of cotton in the semi-arid region of Northeast Brazil. The time series of the meteorological variables had their flaws properly completed and went through a rigorous quality control system. The future projections calculated for the climatic scenarios A1B and A2, of the models ECHAM5-OM and HadGEM2-ES were unanimous in pointing out the significant reduction in rainfall and temperature rising. The evapotranspiration, consequently, also presents an upward trend for the future horizon studied, from 2020 to 2080. As impact for the cotton crop, it is foreseen, for the 23 studied municipalities of the northeast semi-arid, a significant reduction in productivity, which can be reduced to approximately half of the current observed productivity.

Keywords: Agrometeorological model, future climate scenarios, cotton yield.

SUMÁRIO

	Pg.
1. INTRODUÇÃO.....	1
1.1 OBJETIVOS.....	2
1.1.1 OBJETIVO GERAL.....	2
1.1.2 OBJETIVOS ESPECÍFICOS.....	3
2. REVISÃO BIBLIOGRÁFICA.....	4
2.1 - CLIMA E CULTIVO DO ALGODÃO NA REGIÃO NORDESTE DO BRASIL.....	4
2.2 - MODELOS AGROMETEOROLÓGICOS.....	9
2.3 - MODELOS CLIMÁTICOS GLOBAIS E CENÁRIOS DE MUDANÇAS CLIMÁTICAS.....	10
2.4 - <i>DOWNSCALING</i> ESTATÍSTICO.....	12
3. MATERIAL E MÉTODOS.....	15
3.1 - DADOS DE PRODUTIVIDADE, METEOROLÓGICOS E ÁREA DE ESTUDO.....	15
3.2 - PREENCHIMENTO DE FALHAS EM DADOS METEOROLÓGICOS.....	17
3.4 - SISTEMA DE CONTROLE DE QUALIDADE EM DADOS METEOROLÓGICOS.....	21
3.4 - MODELO AGROMETEOROLÓGICO DE PENALIZAÇÃO POR DEFICIÊNCIA HÍDRICA.....	23
3.4.1 - CALIBRAÇÃO DO MODELO AGROMETEOROLÓGICO.....	27
3.5 - <i>DOWNSCALING</i> ESTATÍSTICO DA PRECIPITAÇÃO, TEMPERATURAS MÁXIMAS E TEMPERATURAS MÍNIMAS.....	28
3.5.1 - SELEÇÃO DOS PREDITORES.....	30
3.5.2 - SELEÇÃO DOS PREDITANDOS.....	32
3.5.3.1 - ESTATÍSTICA DESCRITIVA.....	36
3.5.3.2 - MEDIDAS DE PRECISÃO.....	37
3.5.3.3 - SIMILARIDADE DAS DISTRIBUIÇÕES.....	39
3.6 - REFINAMENTO ESTATÍSTICO PARA <i>DOWNSCALING</i> DA PRESSÃO ATMOSFÉRICA, UMIDADE RELATIVA E VELOCIDADE DO VENTO À	40

SUPERFÍCIE.....	
4. RESULTADOS E DISCUSSÕES.....	43
4.1 - TRATAMENTO ESTATÍSTICO DOS DADOS: PREENCHIMENTO DE FALHAS.....	43
4.2 - TRATAMENTO ESTATÍSTICO DOS DADOS: CONTROLE DE QUALIDADE.....	47
4.3 - CALIBRAÇÃO E VALIDAÇÃO DO MODELO AGROMETEOROLÓGICO PARA ESTIMATIVA DA PRODUTIVIDADE DO ALGODÃO HERBÁCEO.....	50
4.4 - CALIBRAÇÃO E VALIDAÇÃO DO MÉTODO DE <i>DOWNSCALING</i> ESTATÍSTICO PARA PRECIPITAÇÃO, TEMPERATURAS MÁXIMAS E MÍNIMAS.....	57
4.5 - <i>DOWNSCALING</i> ESTATÍSTICO DA PRECIPITAÇÃO, TEMPERATURAS MÁXIMAS E MÍNIMAS DIÁRIAS.....	68
4.5.1 - RESULTADOS DOS MODELOS PARA O PERÍODO DE CALIBRAÇÃO.....	68
4.6 - CENÁRIOS FUTUROS DA PRECIPITAÇÃO, TEMPERATURAS MÁXIMAS E MÍNIMAS DIÁRIAS.....	74
4.7 - CENÁRIOS FUTUROS DA EVAPOTRANSPIRAÇÃO POTENCIAL.....	79
4.8 - CENÁRIOS FUTUROS DA PRODUTIVIDADE DO ALGODÃO.....	84
5. CONCLUSÕES.....	91
6. REFERÊNCIAS BIBLIOGRÁFICAS.....	92

LISTA DE FIGURAS

- Figura 1:** Distribuição geográfica das 96 estações meteorológicas convencionais do INMET na região Nordeste (a), e das 23 localizadas em municípios produtores de algodão (b). Sobre os pontos de estação, seu respectivo código da Organização Meteorológica Mundial (OMM).....16
- Figura 2:** Principais passos utilizados na imputação múltipla.....19
- Figura 3:** Fluxograma do SCQ, desde a extração de uma série do banco de dados, a aplicação dos testes, até a verificação ou correção dos dados duvidosos.....23
- Figura 4:** Grade e preditores utilizados para a precipitação da região Nordeste.....31
- Figura 5:** Janela de criação de um preditando para um determinado experimento. No exemplo, para a precipitação, da região Nordeste.....32
- Figura 6:** Resultado do teste de limites variáveis para os percentis de 1% e 99%, para as variáveis umidade relativa e temperatura média. Pontos em vermelho indicam valores que extrapolaram os limiares.....49
- Figura 7:** Resultado do teste de consistência entre variáveis relacionando temperaturas médias, com temperaturas máximas e mínimas diárias. Os valores suspeitos de temperaturas médias são identificados por pontos em vermelho.....50
- Figura 8:** Produtividade média do algodão herbáceo (kg/há) em cada município, entre 2001-2011, fornecida pelo IBGE.....51
- Figura 9:** Produtividades observadas e simuladas do algodão herbáceo nas cidades de Carinhanha (a e b) e Crateús (c e d), antes e depois da calibração do modelo agrometeorológico.....53
- Figura 10:** Produtividades médias do algodão herbáceo (kg/há) em cada município, entre 2001-2011, observadas e estimadas pelo modelo agrometeorológico.....56
- Figura 11:** Para cada estação, funções densidade de probabilidade e valores do PDFscore à esquerda, diagramas de dispersão e valores de r no centro, e distribuições Q-Q plot à direita, para as precipitações observadas e previstas acumuladas (mm) em 10 dias para o período 1991-2000.....65

Figura 12: Funções densidade de probabilidade e valores do PDFscore à esquerda, diagramas de dispersão e valores de r no centro, e distribuições Q-Q plot à direita, das temperaturas máximas observadas e previstas agregadas em 10 dias para o período 1991-2000, para as estações de Água Branca e Monteiro.....**67**

Figura 13: Funções densidade de probabilidade e valores do PDFscore à esquerda, diagramas de dispersão e valores de r no centro, e distribuições Q-Q plot à direita, das temperaturas mínimas observadas e previstas agregadas em 10 dias para o período 1991-2000, para as estações de Senhor do Bonfim e Vitória da Conquista.....**67**

Figura 14: Climatologia da precipitação do período 1961-1990, com dados observados (linha azul), modelos ECHAM5-OM (linha vermelha) e HadGEM2-ES (linha verde), para as 23 estações.....**70**

Figura 15: (a) Médias anuais 1961-1990 da precipitação (mm) obtidas das observações (linha azul), ECHAM5-OM (linha vermelha) e HadGEM2-ES (linha verde), e (b) Diferenças médias anuais entre os modelos e observação.....**71**

Figura 16: Climatologia da temperatura máxima do período 1961-1990, com dados observados (linha azul), modelos ECHAM5-OM (linha vermelha) e HadGEM2-ES (linha verde), para 4 estações.....**72**

Figura 17: (a) Médias anuais 1961-1990 da temperatura máxima (°C) obtidas das observações (linha azul), ECHAM5-OM (linha vermelha) e HadGEM2-ES (linha verde), e (b) Diferenças médias anuais entre os modelos e observação.....**73**

Figura 18: Climatologia da temperatura mínima do período 1961-1990, com dados observados (linha azul), modelos ECHAM5-OM (linha vermelha) e HadGEM2-ES (linha verde), para 4 estações.....**73**

Figura 19: (a) Médias anuais 1961-1990 da temperatura mínima (°C) obtidas das observações (linha azul), ECHAM5-OM (linha vermelha) e HadGEM2-ES (linha verde), e (b) Diferenças médias anuais entre os modelos e observação.....**74**

Figura 20: Diferenças médias anuais da precipitação para 2020-2080 dos modelos ECHAM5-OM (a) e HadGEM2-ES (b) com as médias 1961-1990. O mesmo para temperaturas máximas (c e d) e temperaturas mínimas (e e f). Todos os resultados para o cenário A1B.....**76**

Figura 21: Diferenças médias anuais da precipitação para 2020-2080 do modelo ECHAM5-OM com as médias 1961-1990 para precipitação (a), temperaturas máximas (b) e temperaturas mínimas (c). Todos os resultados para o cenário A2.....**78**

Figura 22: Evolução da ETP diária, em mm/dia, entre 2020 e 2080 para os cenários A1B dos modelos ECHAM5-OM e HadGEM2-ES, e para o cenário A2 do modelo ECHAM5-OM, para a estação de Barra (BA). A linha preta corresponde ao valor médio diário da ETP em 1961-1990, e a linha vermelha corresponde a linha de tendência do período 2020-2080.....	83
Figura 23: Mesmo da Figura 22, mas para a estação de Monteiro (PB).....	83
Figura 24: Mesmo da Figura 22, mas para a estação de Patos (PB).....	84
Figura 25: Mesmo da Figura 22, mas para a estação de Sobral (CE).....	84
Figura 26: Estimativa percentual da perda de produtividade do algodão herbáceo para 2020-2080 dos cenários A1B dos modelos ECHAM5-OM (linha vermelha) e HadGEM2-ES (linha azul), e do cenário A2 do modelo ECHAM5-OM (linha verde). A produtividade média observada do período 2001-2011 é mostrada na linha preta horizontal dos gráficos, para as 23 estações.....	89
Figura 27: Produtividades médias do algodão herbáceo (Kg/ha) em cada município, entre 2020 e 2080, projetadas para os cenários A1B e A2 do modelo ECHAM5-OM, e A1B do modelo HadGEM2-ES, comparadas com a produtividade média anual observada no período 2001-2011.....	90

LISTA DE TABELAS

Tabela 1. Duração média de cada estágio de desenvolvimento do algodoeiro.....	6
Tabela 2. Valores médios de evapotranspiração diária para cada fase de desenvolvimento do algodoeiro.....	8
Tabela 3. Coeficiente de cultivo para cada fase de desenvolvimento do algodoeiro.....	8
Tabela 4. Estado, código, nome, latitude, longitude e altitude das 23 estações meteorológicas do INMET da região Nordeste onde existe a produção de algodão.....	17
Tabela 5. Ilustração de dados de precipitação a serem imputados, representados por NA, referentes à estação de Ouricuri (código OMM: 82753) - Pernambuco (a), e dados com as falhas preenchidas (b). Os dados originais (coluna Orig) estão ao lado das séries gradeadas mais próximas, ou conjunto de preditores (G-01; G-02; G-03 e G-04). As falhas preenchidas aparecem destacadas em vermelho.....	20
Tabela 6. Descrição das variáveis, níveis de altura e unidades do conjunto de parâmetros disponíveis para seleção de preditores.....	31
Tabela 7. Coeficiente de correlação estatística, ou coeficiente de correlação de Pearson. Fonte: Devore (2006).....	38
Tabela 8. Percentual de dados faltantes, por variável e por estação. Destacados em cinza os percentuais acima de 50%.....	44
Tabela 9. Valores de r e do RMSE para as variáveis TMed, UR, PAt e VMV, para cada estação, válidos para um intervalo de 10 dias de acumulação entre valores observados e imputados. Valores de r acima de 0,60 estão destacados em cinza.....	46
Tabela 10. Valores de r e do RMSE para as variáveis PREC e INS, válidos para um intervalo de 10 dias de acumulação entre valores observados e imputados. Valores de r acima de 0,60 estão destacados em cinza.....	47
Tabela 11. Registros de valores suspeitos encontrados pelo SCQ relativo ao Teste de Limites Fixos, para PAt (em hPa) e INS (em horas por dia).....	48
Tabela 12. Exemplos de valores suspeitos de temperaturas médias encontrados pelo Teste de Limites Variáveis. Em azul valor diário abaixo do percentil de 1% e em vermelho acima do percentil 99%.....	49

Tabela 13. Produtividade média observada e simulada, erro médio absoluto (EMA) e relativo (EMR), coeficiente de produtividade máxima tecnológica (Δp), fator de déficit hídrico ajustado (ky^*) e correlação (r) entre simulações e observações. Valores de r acima de 0,60 estão destacados em cinza.....	55
Tabela 14. Taxa de precipitação observada e prevista (TP-Obs) e (TP-Prev), médias observadas e previstas (Média-Obs) e (Média-Prev), desvio padrão observado e previsto (σ -Obs) e (σ -Prev), taxas de acerto e de alarmes falsos (TA) e (TAF), e razão das variâncias (RV). Médias estatísticas obtidas para dados diários de precipitação no período 1991-2000.....	59
Tabela 15. Médias observadas e previstas (Média-Obs) e (Média-Prev), desvio padrão observado e previsto (σ -Obs) e (σ -Prev), e correlações (r), para temperaturas máximas agregadas em 10dias. Valores de r acima de 0,60 estão destacados em cinza.....	66
Tabela 16. Médias observadas e previstas (Média-Obs) e (Média-Prev), desvio padrão observado e previsto (σ -Obs) e (σ -Prev), e correlações (r), para temperaturas mínimas agregadas em 10dias. Valores de r acima de 0,60 estão destacados em cinza.....	66
Tabela 17. Correlações entre observações e previsões do modelo ECHAM5-OM, cenário A1B, entre 2001 e 2012, das variáveis Umidade Relativa (UR), Pressão Atmosférica (PA _t), Velocidade Média do Vento (VMV) e Insolação (INS). Valores de r acima de 0,6 estão destacados em cinza.....	80
Tabela 18. Correlações entre observações e previsões do modelo HadGEM2-ES, cenário A1B, entre 2001 e 2012, das variáveis Umidade Relativa (UR), Pressão Atmosférica (PA _t), Velocidade Média do Vento (VMV) e Insolação (INS). Valores de r acima de 0,6 estão destacados em cinza.....	81
Tabela 19. Correlações entre observações e previsões do modelo ECHAM5-OM, cenário A2, entre 2001 e 2012, das variáveis Umidade Relativa (UR), Pressão Atmosférica (PA _t), Velocidade Média do Vento (VMV) e Insolação (INS). Valores de r acima de 0,6 estão destacados em cinza.....	82
Tabela 20. Correlações entre ETPs observadas e previstas pelos modelos ECHAM5-OM, cenários A1B e A2, e HadGEM2-ES para o cenário A1B, entre 2001 e 2012. Valores de r acima de 0,6 estão destacados em cinza.....	82
Tabela 21. Penalização média obtida com dados observados no período 2001-2011 <i>versus</i> valores médios da penalização obtida com os cenários A1B e A2 do modelo ECHAM5-OM, e com o cenário A1B do modelo HadGEM2-ES, para o período 2020-2080.....	86

LISTA DE SIGLAS E ABREVIATURAS

ARM	Armazenamento de água no solo
ARMant	Armazenamento anterior
ARMc	Armazenamento crítico
CAD	Capacidade de Água Disponível
CONAB	Companhia Nacional de Abastecimento
CPC	Climate Prediction Center
CSIRO-Mk2	Commonwealth Scientific and Industrial Research Organization
DE	Downscaling Estatístico
DV	Desenvolvimento Vegetativo
ECHAM5-OM	Modelo climático global desenvolvido pelo Max Planck Institute for Meteorology da Alemanha
EMA	Erro Médio Absoluto
ERA-40	ECMWF re-analises
ETm	Evapotranspiração máxima (mm.dia-1)
ETo	Evapotranspiração de referência (mm.dia-1)
ETP	Evapotranspiração Potencial (mm.dia-1)
ETPc	Evapotranspiração Potencial da cultura (mm.dia-1)
ETRc	Evapotranspiração Real da cultura (mm.dia-1)
ETR	Evapotranspiração Real (mm)
FAO	Food and Agriculture Organization
FDP	Função Densidade de Probabilidade
FOE	Funções Ortogonais Empíricas
HadCM3	Hadley Centre Coupled Model, versão 3
HadGEM2-ES	Modelo climático global desenvolvido pelo Met Office Hadley Centre do Reino Unido
IBGE	Instituto Brasileiro de Geografia e Estatística

INMET	Instituto Nacional de Meteorologia
INS	Insolação (horas.dia-1)
IPCC	Intergovernmental Panel on Climate Change
kc	Coefficiente da cultura (adimensional)
ks	Coefficiente de umidade para o solo (adimensional)
ky	Coefficiente de penalização hídrica (adimensional)
ky*	Coefficiente de penalização hídrica ajustada (adimensional)
MCG	Modelo Climático Global
MDE	Método de Downscaling Estatístico
MICE	Multivariate Imputation by Chained Equations
NCAR	National Center for Atmospheric Research
NCEP	National Center for Environmental Predictions
OMM	Organização Meteorológica Mundial
PA _t	Pressão Atmosférica (hPa)
PMM	Predictive Mean Matching
PMT	Produtividade Máxima Tecnológica
PNM	Pressão ao Nível médio do Mar
PR	Produtividade Real
PREC	Precipitação (mm)
PRO	Produtividade Real Observada
RMSE	Raiz do Erro Médio Quadrático
RV	Razão das Variâncias
SCQ	Sistema de Controle de Qualidade
SDSM	Statistical DownScaling Model
SIDRA	Sistema IBGE de Recuperação Automática
SRES	Special Report Emissions Scenarios
TA	Taxa de Acertos

TAF	Taxa de Alarmes Falsos
TMax	Temperatura máxima (°C)
TMed	Temperatura média (°C)
TMin	Temperatura Mínima (°C)
TP	Taxa de Precipitação
TPA	Tendência da Produtividade Anual
UR	Umidade Relativa (%)
VMV	Velocidade Média do Vento (m.seg-1)
ZCIT	Zona de Convergência Intertropical

LISTA DE SÍMBOLOS

CO ₂	Dióxido de carbono
<i>r</i>	Correlação (adimensional)
<i>e_a</i>	Pressão de vapor atual (kPa)
<i>e_s</i>	Pressão de vapor de saturação (kPa)
<i>l_{bda}</i>	Calor latente de vaporização (MJ.Kg-1)
<i>delta</i>	Declividade da curva de pressão de vapor (kPa.°C-1)
<i>f_i</i>	Constante psicrométrica (kPa.°C-1)
<i>d_r</i>	Inverso da distância relativa da Terra ao Sol (rad)
<i>s_i</i>	Declinação solar (rad)
<i>W_s</i>	Ângulo do pôr do sol (rad)
<i>R_a</i>	Radiação extraterrestre diária (MJ.m-2.dia-1)
<i>R_{so}</i>	Radiação solar para um dia sem nuvens (MJ.m-2.dia-1)
<i>R_s</i>	Radiação solar (MJ.m-2.dia-1)
<i>N</i>	Horas de brilho solar (h)
<i>R_{nl}</i>	Radiação de ondas longas (MJ.m-2.dia-1)
<i>R_{ns}</i>	Radiação de ondas curtas (MJ.m-2.dia-1)
<i>R_n</i>	Saldo de radiação na superfície (MJ. m-2. dia-1)
<i>G</i>	Densidade de Fluxo de Calor no Solo (MJ.m-2.dia-1)
<i>V_{vel2m}</i>	Velocidade do vento a 2 metros de altura (m.seg-1)
°C	Graus Celsius
mm	Milímetros
<i>Y_d</i>	Penalização final
<i>p</i>	Fator de disponibilidade
<i>Δp</i>	Coefficiente de produtividade máxima tecnológica

1. INTRODUÇÃO

O clima da terra é regulado por diversos elementos e processos que envolvem o fluxo de radiação solar, a atmosfera e a superfície terrestre. O maior regulador do clima da Terra é a radiação solar. A quantidade de radiação solar que chega a cada segundo em cada metro quadrado da superfície da Terra gera uma permanente dinâmica entre a atmosfera e a crosta terrestre, que é sentida por meio do clima. O clima evolui ao longo do tempo sob a influência de três fatores centrais: sua própria dinâmica interna, os forçamentos externos naturais, como erupções vulcânicas e variações solares, e os forçamentos antrópicos, devido às atividades humanas, como a emissão de gases de efeito estufa por meio da queima de combustíveis fósseis, e pelo desmatamento. No sistema climático, todos estes elementos estão interligados e o desequilíbrio de uma parte influencia no equilíbrio dos demais.

Para determinar a influência antrópica no clima atual, um enorme número de observações experimentais de vários parâmetros ambientais foi compilado pela equipe do Painel Intergovernamental sobre Mudanças Climáticas (IPCC), que investigou as alterações climáticas em curso no planeta. As variações na temperatura média, nos padrões de precipitação pluvial, na área coberta por neve, no nível do mar e em muitos outros parâmetros ambientais foram analisadas detalhadamente. As conclusões indicam que, dentro de um índice de confiabilidade de 95%, o clima de nosso planeta está efetivamente sendo alterado (IPCC, 2013).

Diversos estudos, principalmente a partir das últimas décadas após o surgimento do IPCC, em 1988, vêm tentando demonstrar que as mudanças nos padrões climáticos já são evidentes em todo o planeta (FRICH *et al.*, 2002), e não serão apenas um “privilegio” guardado e já amplamente modelado para o futuro. A maior parte dos estudos sobre mudanças climáticas em séries de dados observados mostra a dificuldade de se encontrar tendências consistentes, e significativas, ao se analisar dados de precipitação, enquanto foram encontradas tendências de aumento muitas vezes significativas em índices relativos aos dados de temperatura, nas mais diversas regiões do globo (KÜRBIS *et al.*, 2009; GOMEZ, 1999).

Trabalhos recentes procuram mostrar que o planeta vem passando por uma situação de aquecimento, e não diferentemente o continente sul-americano (SOLMAN *et al.*, 2008; MARENGO *et al.*, 2007). Hayloch *et al.* (2006) estudaram dados diários de temperatura máxima e mínima para estações localizadas em oito países da América do Sul, e concluíram que as tendências de aumento mais importantes foram encontradas nas séries de temperaturas

mínimas, com uma tendência de aumento de noites quentes durante o verão. As estações que apresentaram estas tendências mais significativas estavam localizadas na porção centro-leste da América do Sul.

Em particular para a região Nordeste do Brasil, estudos recentes (MARENGO *et al.*, 2009) mostram que existe uma tendência predominantemente positiva no aumento das temperaturas, principalmente das temperaturas mínimas, diminuindo a amplitude térmica diária, o que deve provocar diretamente um aumento da evapotranspiração potencial (ETP) desta região, e que esta tendência continua para diferentes cenários futuros de mudanças climáticas. No caso do Nordeste, que tem a maior parte de sua área inserida no clima semiárido, o aumento na ETP associado a já conhecida alta variabilidade espaço-temporal da precipitação, pode prejudicar ainda mais as atividades agrícolas, notadamente as de sequeiro, como no caso do cultivo do algodão herbáceo.

O algodão é produzido por mais de sessenta países, onde China, Índia, Estados Unidos, Paquistão e Brasil são os maiores produtores da fibra, sendo o Brasil o terceiro maior exportador mundial. No Brasil, atualmente os Estados do Mato Grosso e Bahia são responsáveis por mais de 82% da produção nacional. Este fator mostra que a região Nordeste do Brasil apresenta condições climáticas favoráveis à cotonicultura, haja vista que o algodão necessita de temperaturas ambientais na faixa de 18 a 30°C, elevadas radiação solar e insolação. Acrescente-se a isto, a existência de cultivares de ciclo (da emergência a primeira colheita) curto (100 - 120 dias) e médio (130 - 150 dias), que consomem entre 450 e 700 mm de água e apresentam potencial de rendimento superior a 3.000 kg/ha de algodão em caroço (AZEVEDO e SILVA, 2007).

A cultura do algodão herbáceo já foi a mais importante e rentável prática agrícola do Nordeste brasileiro, que já chegou a plantar mais de um milhão de hectares, como na safra 1984/85. Pragas e adversidades climáticas sempre foram fatores limitantes da produção. Com o avanço no controle das pragas, o fator climático torna-se o mais importante ator para o sucesso ou fracasso das safras, tendo em vista que a maior parte da produção é sob regime de sequeiro.

Diante das discussões climáticas atuais, com projeções futuras para a região muitas vezes preocupantes, faz-se necessário um estudo aprofundado de como determinados cenários futuros de mudanças climáticas poderão impactar o sistema produtivo.

Desta forma, trazer para o nível local dos municípios produtores de algodão no Nordeste, onde o Estado da Bahia é o segundo maior produtor nacional, as projeções climáticas futuras, por meio de uma moderna técnica de *downscaling* estatístico, e estimar a produtividade desta cultura no horizonte de 2020 a 2080, será o foco desta pesquisa.

Nesse contexto, a presente pesquisa foi desenvolvida no sentido de alcançar os seguintes objetivos:

1.1 - OBJETIVOS

1.1.1 - OBJETIVO GERAL

Gerar cenários climáticos futuros, e avaliar os impactos na produtividade do algodão herbáceo através de um modelo agrometeorológico, comparando com a produtividade atual observada.

1.1.2 - OBJETIVOS ESPECÍFICOS

1. Validar o método estatístico *MICE* para o preenchimento de dados diários faltantes;
2. Validar um modelo agrometeorológico de penalização por déficit hídrico aplicado à cultura do algodão herbáceo;
3. Gerar um *downscaling* estatístico da precipitação e ETP para estações meteorológicas do Nordeste brasileiro, a partir de previsões de modelos climáticos globais, para dois diferentes cenários futuros de emissão de CO₂: cenários A1B e A2.
4. Gerar cenários futuros de produtividade para o algodão herbáceo no Nordeste do Brasil.

2. REVISÃO BIBLIOGRÁFICA

2.1 - CLIMA E CULTIVO DO ALGODÃO NA REGIÃO NORDESTE DO BRASIL

Na região Nordeste do Brasil, a economia agrícola é seriamente afetada por adversidades climáticas, principalmente associadas às secas frequentes (SILVA *et al.*, 2012). Silva *et al.* (2013), mostraram que, recentemente, a região passou por um longo período de seca associado a intensidade do fenômeno oceânico-atmosférico conhecido como Dipolo do Atlântico. Aliado ao fator clima, práticas agrícolas ultrapassadas e falta de crédito agrícola geram ainda mais problemas no que tange a produtividade agrícola da região (SILVA, 1994), já que esta é fortemente baseada na agricultura de subsistência.

O conhecimento do regime de chuvas, associado à umidade retirada no solo é de fundamental importância para a definição do início, duração e término da estação chuvosa de determinada região. Tal conhecimento permite a determinação da estação de cultivo e época mais apropriada à semeadura e a elaboração do calendário agrícola, principalmente para culturas de sequeiro, como o algodão.

No entanto, mais de 60% das áreas mundiais cultivadas com algodão são irrigadas. A cotonicultura está concentrada basicamente em sete países: China, Estados Unidos, Índia, Paquistão, Uzbequistão, Brasil e Turquia, os quais respondem por 77%, em média, do volume mundial (TOYAMA e NOGUEIRA, 2000). No Brasil, a maior parte da produção é por regime de sequeiro, e o algodão não consta entre as cinco principais culturas irrigadas, que são a cana-de-açúcar (1,7 milhão de hectares); arroz em casca (1,1 milhão de hectares); soja (624 mil hectares); milho em grão (559 mil hectares) e o feijão de cor (195 mil hectares) (Fonte: Ministério da Integração Nacional, 2013).

Nas regiões semiáridas do Nordeste do Brasil, o algodão é cultivado, predominantemente, em condições de sequeiro e a variabilidade meteorológica, especialmente o regime de chuvas, constitui-se no principal fator limitante das safras (PRATES *et al.*, 1986). Nestes casos, a estação de cultivo deve coincidir com a estação chuvosa, a qual nem sempre é adequada e suficientemente longa para suprir as necessidades hídricas da cultura em todos os seus subperíodos de desenvolvimento (AZEVEDO e MACIEL, 1993; AZEVEDO *et al.*, 2004). Nessas áreas do semiárido nordestino, a atividade agrícola é dependente da precipitação pluviométrica (cultivos de sequeiro), resultando em incertezas na produção, em

que, segundo Chaves *et al.* (1982), 89% da precipitação pluviométrica anual concentram-se em uma estação chuvosa de 06 (seis) meses, sendo março e abril os meses mais chuvosos.

Além da grande variabilidade sazonal, ocorrem também grandes flutuações interanuais no semiárido, que provocam fenômenos extremos como secas severas ou enchentes. No Nordeste, os eventos de chuva estão associados a mecanismos dinâmicos de grande escala, entre os quais: Zona de Convergência Intertropical (ZCIT) (HASTENRATH, 1984; MOURA e SHUKLA, 1981), penetração de sistemas oriundos de latitudes médias austrais (KOUSKY, 1979), Vórtices Ciclônicos de Altos Níveis (VCANs) (KOUSKY e GAN, 1981) e a Oscilação de Madden-Julian (KOUSKY e KAYANO, 1994).

De acordo com a distribuição de chuvas ocasionadas pelos diversos sistemas atuantes na região, a época de semeadura deve ajustar-se da melhor maneira dentro da estação chuvosa, de forma a evitar déficit de umidade no solo para a germinação, excesso de umidade nos subperíodos de abertura dos capulhos e da colheita do algodão em caroço, o que poderá aumentar substancialmente a produtividade do algodoeiro (FALLIERI e SILVA, 1968; LACA-BUENDIA *et al.*, 1997).

No Brasil, a cotonicultura retomou sua trajetória de recuperação a partir da safra 1996/97, saltando de 305,8 mil toneladas de pluma, produzidas nesta safra para 1.602,5 mil toneladas, na safra 2007/08 (CONAB, 2009). Esta retomada do crescimento está fundamentada na expansão da área de cultivo para novas regiões, notadamente os cerrados do Centro-Oeste e Bahia, e na adoção de novas tecnologias, como lavouras extensas, mecanização total da cultura e uso intensivo de insumos agrícolas.

Das 52 espécies catalogadas no gênero *Gossypium*, pertencente à família *Malvaceae*, na qual o algodoeiro está inserido, apenas quatro são cultivadas comercialmente, ou seja, *G. hirsutum*, *G. barbadense*, *G. herbaceum* e *G. arboreum*. Destas, *G. hirsutum* é a principal espécie, ocupando quase a totalidade das áreas produtoras do mundo. Esta espécie se diferenciou em raças e, no Brasil, assim como no mundo, o algodão herbáceo (*Gossypium hirsutum* L. raça *latifolium* Hutch.) é o mais importante. No Brasil, o algodoeiro herbáceo (mocó) ou perene (*Gossypium hirsutum* L. raça *Marie galante* Hutch.), de grande importância até a década de 80, encontra-se, atualmente, restrito a pequenas áreas do semiárido do Nordeste.

De acordo com o tempo necessário para que 90% dos frutos estejam abertos, os cultivares podem ser classificadas em três grupos de maturação: precoces (120 a 130 dias), médias (140 a 160 dias) e tardias (acima de 170 dias). Em média, o algodoeiro anual inicia seu florescimento com cerca de 50 dias, estendendo-se até 120 dias ou mais, com o pico da curva de florescimento ao redor de 70 a 80 dias, e o pegamento das flores é maior até 30 a 40 dias de florescimento, quando as condições da planta e do ambiente são determinantes.

O algodoeiro é estruturalmente complexo, devido ao hábito de crescimento indeterminado, ao padrão de desenvolvimento dos ramos simpodiais e ao padrão de florescimento. Isso torna relativamente difícil a sistematização do desenvolvimento desta espécie (MAUNEY, 1966). A transição entre os processos de desenvolvimento (estabelecimento de plantas e raízes, área foliar e estabelecimento do dossel, florescimento e maturação) não é claramente distinguível. Deste modo, é considerável o efeito que o ambiente exerce, não apenas sobre o desenvolvimento vegetativo dessa planta, como também nos componentes da produção (massa de capulhos, massa de sementes e porcentagem de fibras) e na qualidade da fibra.

Apesar de complexo, o ciclo de vida do algodoeiro pode ser resumidamente demonstrado na Tabela 1, em cinco estágios: germinação e emergência da plântula, emergência ao primeiro botão floral, primeiro botão floral a abertura da primeira flor, primeira flor ao primeiro capulho, primeiro capulho e colheita (maturação e deiscência).

Tabela 1. Duração média de cada estágio de desenvolvimento do algodoeiro.

Estágio	Duração (dias)
Germinação - Emergência	5 a 10
Emergência - Primeiro Botão Floral	30 a 35
Primeiro Botão Floral - Primeira Flor	20 a 25
Primeira Flor - Primeiro Capulho	50 a 55
Primeiro Capulho - Colheita	45 a 50

Fonte: Monteiro, J. E. B. A (2009).

O algodoeiro é uma planta de hábito perene, arbustivo, nativo de regiões tropicais e subtropicais com baixa pluviosidade. As formas anuais surgiram quando a planta foi levada para maiores latitudes, onde as formas perenes não tiveram condições de sobreviver devido ao frio.

Nos dias atuais, o cultivo do algodoeiro é viável entre as latitudes 42°N e 30°S, em áreas que apresentem, durante o ciclo da cultura, cerca de 180 a 200 dias livres de geadas, temperaturas médias superiores a 20°C, precipitações entre 500 e 1500 mm, e alta insolação. Para a qualidade da fibra, o equilíbrio entre o crescimento vegetativo e reprodutivo é fundamental, e este equilíbrio é diretamente influenciado pelas condições do ambiente (temperatura, insolação, umidade e fertilidade do solo) e de manejo (densidade das plantas, espaçamento entre linhas, nutrientes e reguladores de crescimento).

Os solos mais propícios ao cultivo do algodoeiro são os mais profundos, de textura média, ricos em matéria orgânica, permeáveis, bem drenados e férteis. No entanto, com as devidas correções, o algodoeiro adapta-se facilmente em condições não tão favoráveis (GARCIA-LORCA e ORTEGA, 1991).

As necessidades hídricas do algodoeiro variam com os estágios fenológicos. A quantidade de água necessária para atender as necessidades hídricas do algodoeiro pode variar entre 500 e 1500 mm, dependendo do clima e da duração do período total de crescimento. Para cultivares de ciclo médio (140 a 160 dias), a quantidade de água necessária para completar o ciclo pode variar entre 500 e 700 mm, quantidade de água que, em média, ocorre no semiárido nordestino.

Assim, para o algodoeiro, não é suficiente apenas a quantidade de água, o mais importante é que a distribuição desta água seja adequada para atender as demandas específicas em cada estágio fenológico. Para o algodoeiro, a fase mais crítica e sensível ao estresse hídrico está entre o florescimento e a frutificação. Um déficit hídrico capaz de reduzir 50% da evapotranspiração, pode significar redução na produtividade da ordem de 28 a 45% (DOORENBOS e KASSAM, 1979). A Tabela 2 mostra valores médios de evapotranspiração diária para cada fase de desenvolvimento da planta.

A necessidade de água representada pela evapotranspiração máxima (ET_m), em relação a evapotranspiração de referência (ET_o), é estimada para cada etapa do desenvolvimento das plantas utilizando-se o respectivo coeficiente de cultivo (*kc*), através da

equação: $ET_m = kc \times ET_o$. Na Tabela 3 encontram-se os valores de kc para cada fase de desenvolvimento da cultura.

Tabela 2. Valores médios de evapotranspiração diária para cada fase de desenvolvimento do algodoeiro.

Estágio de desenvolvimento	Necessidade hídrica diária (mm)
Semeadura	Maior que zero
Desenvolvimento vegetativo	1 a 2
Primeiro Botão Floral	2 a 4
Fase reprodutiva	3 a 8
Pico de florescimento	8
Primeiro capulho	8 a 4
Fase de maturação	4

Fonte: Freeland Jr. *et al.* (2006).

Tabela 3. Coeficiente de cultivo para cada fase de desenvolvimento do algodoeiro.

Período inicial (15 a 25 dias)	Desenvolvimento vegetativo	Gemas e floração	Maturação dos capulhos	Final de ciclo e colheita
0,4	0,7	1,05	0,8	0,65

Fonte: Doorenbos *et al.* (1979).

Com relação à temperatura, a faixa ideal da temperatura do ar é de 20°C a 30°C, embora o seu cultivo seja viável em regiões com temperaturas do ar variando entre 18°C e 40°C (REDDY *et al.*, 1991), e a maioria dos cultivares requer mais de 150 dias com temperaturas acima de 15°C, para produzir satisfatoriamente (FREELAND *et al.*, 2006). A faixa de temperatura do solo considerada ótima para a germinação e emergência do algodoeiro, é de 25°C a 30°C.

2.2 - MODELOS AGROMETEOROLÓGICOS

Os modelos agrometeorológicos são utilizados para caracterizar os efeitos climáticos sobre a produtividade das culturas. Isto faz-se necessário, pois a agricultura é uma das atividades econômicas e sociais mais afetadas pelas condições meteorológicas. Excessos ou déficits de precipitação, ondas de calor ou frio, geadas, ventanias e granizo são bons exemplos de fatores limitantes das safras.

São modelos agrometeorológicos consagrados na literatura os modelos de Pedro Junior *et al.*, (1984), Camargo *et al.*, (1986), Meyer (1990), Berlato e Molion (1993), Camargo (1993) e Matzenauer (1994). As condições térmicas e pluviométricas são as mais importantes para a produtividade das culturas, algumas respondem mais diretamente as necessidades hídricas, outras as necessidades térmicas, que afetam o processo fotossintético, que se torna ainda mais limitado em situações de deficiência hídrica, aumentando o potencial de quebra de rendimento das culturas (HANKS e RASMUSSEN, 1982).

O modelo agrometeorológico, utilizado em vários estudos, para estimar a produtividade agrícola das culturas é o proposto por Doorenbos e Kassam (1979). Este modelo procura explicar o efeito das variáveis meteorológicas, precipitação e ETP, na produtividade da cultura, relacionando a perda de rendimento de culturas com o déficit hídrico, sendo comumente utilizado para gerar estimativas de perdas.

Os efeitos do clima na produtividade do milho no Rio Grande do Sul, em diferentes locais do Estado e para diferentes épocas de plantio, usando o modelo de produtividade de Doorenbos e Kassam (1979), foram estudados por Dourado Neto *et al.*, (2004). Usando os princípios deste modelo, Assad *et al.*, (2007) elaboraram um sistema para prever as safras da cultura da soja, em cada região brasileira, com os melhores resultados sendo obtidos para o Rio Grande do Sul, Santa Catarina, Mato Grosso do Sul, Maranhão, Piauí e Bahia.

Este modelo também foi utilizado por Rosa *et al.*, (2010) para estimar a produtividade da cultura do café para o sul e sudoeste do Estado de Minas Gerais, usando como dados de entrada para o modelo imagens do sensor MODIS e saídas do modelo de previsão de tempo ETA. Para a região da zona da mata de Minas Gerais, estimativas de produtividade do café arábica foram estimadas por este mesmo modelo, por Silva *et al.*, (2011).

Santos *et al.*, (2011) estudaram a produtividade do milho em mesorregiões do Estado de Minas Gerais sob condições futuras de mudanças climáticas usando o cenário de emissões

A1B, chegando a conclusão de que a produtividade cairá principalmente devido a diminuição da oferta de água por chuva, mantidas as condições tecnológicas atuais.

Na Grécia, Kotsopoulos *et al.* (2004), usaram este modelo para otimizar o uso de irrigação em campos experimentais de algodão, quando a oferta de água de chuva e o aumento da ETP passaram a ameaçar a produtividade, principalmente na fase de crescimento da planta.

Rajic e Rajic (2005) observaram que a região agrícola mais produtiva da Sérvia era afetada no verão por alta temperatura do ar, baixa umidade relativa, ocasionando elevada ETP das culturas, e estas condições tem sido frequentemente associadas a baixas taxas de precipitação, acarretando em baixas produtividades.

Marin *et al.* (2000) utilizaram o modelo de Doorenbos e Kassam (1979) para estimar a perda potencial de rendimento da cultura do girassol em três localidades do Estado de São Paulo, para 36 épocas de semeadura. Como resultado obteve as melhores épocas de plantio de acordo com o menor risco de quebras de rendimento, oferecidas pelo modelo.

Ferreira e Rao (2011) quantificaram a influência da variabilidade das chuvas e temperaturas na produção de soja da região sul do Brasil, utilizando três diferentes adaptações do modelo conceitual de Doorenbos e Kassam (1979). Verificaram que os rendimentos da soja são mais afetados pelas temperaturas de verão, e pelas chuvas no início e pico de desenvolvimento das plantações e, o mais importante, que no Paraná as plantações de soja são mais sensíveis às variações da chuva, enquanto no Rio Grande do Sul, às variações da temperatura.

2.3 - MODELOS CLIMÁTICOS GLOBAIS E CENÁRIOS DE MUDANÇAS CLIMÁTICAS

A circulação geral da atmosfera é usada para definir um estado de referência para a atmosfera, conhecido como estado básico. As circulações atmosféricas são provocadas pela conservação de massa e pelas forças de pressão e empuxo da superfície, observadas por um referencial em rotação. Do ponto de vista climático, ou médio, a estrutura básica da circulação geral da atmosfera se mantém relativamente constante. No entanto, estas circulações, ano a ano, ou em escalas de tempo menores, variam substancialmente devido a fenômenos de escala menor no espaço e no tempo. Estas variações são sobrepostas ao estado básico da atmosfera, em forma de ondas, respondendo a diferentes fontes de energia.

Um Modelo Climático Global (MCG) procura representar matematicamente o sistema climático baseado nas propriedades físicas de seus componentes, mas em geral ainda deixam de representar características importantes em escala sub-grade, como nuvens e topografia, devido a sua resolução espacial grosseira (em média, da ordem de 250 km na horizontal, com 20 níveis na vertical). Os MCG's atuais são acoplados com modelos oceânicos, contemplando ainda processos biogeoquímicos. Desta forma, apesar de caracterizar bem as condições climáticas globais, pecam em caracterizar bem características climáticas regionais, principalmente em áreas com coberturas vegetais e topografias complexas, e regiões litorâneas (WMO, 2002).

Desde a criação do IPCC (*Intergovernmental Panel on Climate Change*), em 1988, os MCG's evoluíram muito (VANNITSEM e CHOME, 2005) e passaram a gerar previsões climáticas futuras incorporando informações de estimativas de gases de efeito estufa. Tais previsões, ou como são mais conhecidos, cenários futuros, são prognósticos das condições futuras do clima sob determinados padrões de emissões de gases de efeito estufa, como a duplicação do gás carbônico, monóxido de carbono, óxido nitroso, dióxido de enxofre, metano, entre outros gases (MITCHELL e HULME, 1999).

Alguns autores consideram que estes cenários são consistentes com a tendência mundial de consumo de combustíveis fósseis. Logo, são representações confiáveis de como se comportará o clima global futuramente (JONES *et al.*, 2004). Portanto, para a construção dos cenários de mudanças climáticas, uma série de idéias ou suposições, tendem a ser coerentes fisicamente com a estrutura natural representada pelos MCG's, sendo incorporadas nos modelos.

Os cenários de mudanças climáticas, oriundos de modelos climáticos, usando como forçantes gases de efeito estufa e aerossóis, foram divulgados pelo *Special Report Emissions Scenarios* (SRES), do IPCC (NAKICENOVIC *et al.*, 2000). Os cenários são divididos em quatro grandes famílias, conhecidos como cenários A1, A2, B1 e B2. O conjunto de informações que gerou estes cenários cobre uma vasta gama das principais forças demográficas, econômicas e tecnológicas de condução das futuras emissões de gases de efeito estufa e de enxofre.

O cenário A1 representa um futuro de crescimento econômico muito rápido, de baixo crescimento populacional e rápida introdução de tecnologias mais eficientes. Há convergência cultural e econômica com a redução substancial das diferenças regionais na renda *per capita*. O cenário A1 se desdobra em três direções alternativas da mudança tecnológica no sistema de

energia: o uso intensivo de combustíveis fósseis (A1FI), fontes não fósseis (A1T) ou um equilíbrio entre as fontes (A1B) (SRES, 2010).

O cenário A2 retrata um mundo mais heterogêneo. O tema subjacente é o de reforçar as identidades culturais regionais, com altos índices de população e menos interesse em rápido crescimento econômico (SRES, 2010).

O cenário B1 representa um mundo convergente, com um pico de população mundial em meados do século, em rápida evolução das estruturas econômicas em direção a uma economia de serviços e informação, a redução da intensidade material e a introdução de tecnologias limpas e eficientes. Uma ênfase especial é dada às soluções globais para a economia sustentável, social e ambiental, incluindo uma maior equidade, mas sem iniciativas climáticas (SRES, 2010).

O cenário B2 retrata um mundo que enfatiza soluções locais para a economia sustentável, social e ambiental. É um mundo heterogêneo, com mudanças tecnológicas menos rápidas e mais diversas do que nos cenários A1 e B1 (SRES, 2010).

2.4 - *DOWNSCALING* ESTATÍSTICO

O *Downscaling* Estatístico (DE) é uma técnica de pós-processamento das saídas dos MCG's, que nada mais é que uma metodologia de diminuição da escala espacial do modelo. Ela também é conhecida como uma ferramenta de interpolação de variáveis em escala espacial para a escala pontual (sobre uma estação meteorológica). Esta técnica foi desenvolvida pela necessidade de se ter uma informação mais detalhada no tempo e no espaço dos produtos de previsão numéricas de tempo e clima (HEWINTON e CRANE, 1996; WILBY e WIGLEY, 1997; HALL *et al.*,1999). A informação em larga escala pode vir de observações meteorológicas sistemáticas ou de saídas de modelos climáticos. Esta técnica tem o atrativo de permitir detalhar e avaliar o risco climático para assuntos específicos em escala regional, usando, em geral, métodos determinísticos (regressão linear múltipla, funções de transferência e/ou redes neurais) que assumem uma relação entre as variáveis de larga escala ao clima local, como a precipitação e a temperatura (WILBY *et al.*, 2004).

A disseminação do DE foi percebida como uma forma eficiente de diminuir a distância entre o acesso a informações mais regionalizadas de mudanças climáticas e a sofisticação para gerar tais informações. Desta forma, modelos de *downscaling* dinâmico que

eram restritos a especialistas e instituições de pesquisa, hoje dividem espaço com os modelos de *downscaling* estatístico (*Statistical DownScaling Model*-SDSM), comprovadamente uma técnica robusta e computacionalmente simples que permite a produção de séries temporais de mudanças climáticas em locais onde existam dados diários suficientes para calibração do modelo, bem como saídas de MCG's para o século 21. Também os SDSM's podem ser utilizados como geradores de tempo estocástico ou para preenchimento de lacunas em dados meteorológicos (GIRVETZ *et al.*, 2009).

Métodos de DE foram empregados para examinar mudanças futuras da temperatura na Irlanda do Norte, em uma grade de resolução espacial específica (MULLAN *et al.*, 2012), empregando a saída de três MCG's e dois cenários de emissões para redução de escala das temperaturas máximas e mínimas em nove estações climatológicas. Neste estudo foi utilizada uma ferramenta de suporte à tomada de decisões para avaliar impactos de mudanças climáticas locais chamada de *O Statistical DownScaling Model*, versão 4.2 (SDSM v4.2). Esta ferramenta especial produz estes cenários (WILBY e DAWSON, 2007), aplicando técnicas estatísticas robustas de redução de escalas. O SDSM facilita o rápido desenvolvimento de múltiplos cenários, a baixo custo, em locais particulares de interesse, que precisam conter apenas dados diários de variáveis meteorológicas e análises de um MCG sob o clima presente e previsões para um clima futuro (WILBY *et al.*, 2002).

O SDSM é, frequentemente, descrito como um sistema híbrido, entre uma aproximação baseada em regressões e um gerador de tempo, pois padrões de circulação diária em grande escala e variáveis de mistura atmosférica são utilizadas para condicionar parâmetros geradores de tempo em determinados locais (WILBY e HARRIS, 2006). A filosofia subjacente do SDSM invoca o estabelecimento de regressões múltiplas entre os preditandos em escala local (como a precipitação e as temperaturas máximas e mínimas diárias) e os preditores de grande escala (como a pressão média ao nível do mar e a vortacidade em superfície (WILBY e DAWSON, 2007)). As relações estabelecidas são, então, aplicadas à circulação simulada por MCG, a fim de gerar projeções do clima local, motivadas pela suposição de que os MCG's são mais eficientes em simular a circulação atmosférica em grande escala do que em simular variáveis climáticas de superfície (MURPHY, 2000).

Para uma região determinada do Uruguai, Bettolli *et al.*, (2010), utilizaram o SDSM, versão 3.1, para analisar a variabilidade do rendimento da pastagem e a variabilidade climática, utilizando como período de referência 1961-1990, e os cenários A2 e B2 de

mudanças climáticas, fornecidos pelos MCG's HadCM3 e CSIRO-Mk2. Para os cenários estudados, aumentos previstos nas temperaturas mínimas e máximas reduziram a probabilidade de ocorrência de temperaturas abaixo do limite mínimo considerado para o pasto (10°C), e aumentariam a probabilidade de estresse térmico durante o verão. A precipitação apresentaria aumentos que poderiam aumentar a incidência do excesso de água no inverno, enquanto os incrementos projetados para o verão não compensariam a demanda hídrica atmosférica para temperaturas mais altas.

Para a cultura do milho, o estudo de Babel e Turyatunga (2014), empregando o SDSM versão 4.2, com dados climáticos futuros de baixa resolução obtidas a partir do modelo de circulação geral HadCM3 dos cenários A2 e B2, mostrou os impactos na produtividade do milho na zona agroecológica ocidental de Uganda. Nesta região, espera-se um aumento da temperatura média anual entre 0,69 - 2,46°C e 0,66 - 1,78°C, respectivamente, nos três períodos futuros das décadas de 2020, 2050 e 2080, em relação ao período de referência 1961-1990, enquanto que para a precipitação média anual espera-se diminuição entre 4,7 - 16,4% e 4,7 - 11,8%, sob os cenários A2 e B2 do SRES. A precipitação média mensal deverá diminuir para a maioria dos meses, mas deve aumentar nos meses de outubro, novembro e dezembro em ambos os cenários. Os resultados do modelo de culturas utilizados mostraram que na safra de março a maio, a produção de milho vai diminuir entre 9,6 - 43,3% e 10,5 - 28,4% sob os cenários A2 e B2, respectivamente, em relação ao período de referência nos três períodos futuros. No entanto, na safra de setembro a novembro, a produção de milho deverá aumentar entre 8,1 - 9,6% e 8,6 - 10,2% sob os cenários A2 e B2, respectivamente.

3. MATERIAL E MÉTODOS

3.1 - DADOS DE PRODUTIVIDADE, METEOROLÓGICOS E ÁREA DE ESTUDO

O Instituto Nacional de Meteorologia (INMET) possui 96 estações meteorológicas convencionais localizadas na região Nordeste, que medem Precipitação (Prec), e as demais variáveis necessárias ao cálculo da evapotranspiração potencial (ETP): Temperaturas Máximas (TMax), Mínimas (TMin) e Médias (TMed), Umidade Relativa do ar (UR), Insolação (Ins), Pressão Atmosférica (PA_t), e Velocidade Média do Vento (VMV) a 10 metros de altura, conforme Figura 1a.

Os dados de produtividade do algodão herbáceo para a região Nordeste são disponibilizados pelo Instituto Brasileiro de Geografia e Estatística (IBGE), através de seu Sistema IBGE de Recuperação Automática (SIDRA). Pelo SIDRA, foi possível obter dados da produtividade média da produção, em quilogramas por hectare, das lavouras temporárias do algodão herbáceo, entre 2001 e 2011, em 23 cidades onde coincidiu haver estações meteorológicas do INMET. A seleção dos municípios foi feita visualmente, comparando a lista de cidades produtoras de algodão informadas pelo IBGE com as cidades do Nordeste onde estão localizadas estações meteorológicas convencionais do INMET.

Os dados de produtividade fornecidos pelo IBGE não informam o ciclo da cultura nem a variedade plantada, desta forma, tomaremos esta informação como sendo a produtividade média obtida para determinado município considerando um ciclo médio para o algodão de 150 dias. Logo, para a realização desta pesquisa, foram utilizadas apenas as 23 localidades, conforme mostrado na Figura 1b. Os municípios estão relacionados na Tabela 4.

O período inicial estipulado para início de cada série foi 01 de janeiro de 1961, até 31 de dezembro de 2012. Para este período, os dados passaram por dois procedimentos essenciais: preenchimento de falhas de dados faltantes e controle de qualidade. Cada um destes procedimentos será melhor explicado a seguir.




Figura 1: Distribuição geográfica das 96 estações meteorológicas convencionais do INMET na região Nordeste (a), e das 23 localizadas em municípios produtores de algodão (b). Sobre os pontos de estação, seu respectivo código da Organização Meteorológica Mundial (OMM).

A Tabela 4 mostra as informações básicas das 23 estações, como código OMM, Estado à qual pertence, nome do município, coordenadas geográficas e altitude.

Tabela 4. Estado, código, nome, latitude, longitude e altitude das 23 estações meteorológicas do INMET da região Nordeste onde existe a produção de algodão.

Estado	Código da Estação	Nome da Estação	Latitude (°)	Longitude (°)	Altitude (m)
Alagoas	82989	Água Branca	-9,28	-37,90	605,3
Bahia	83088	Senhor do Bonfim	-10,47	-40,18	558,2
Bahia	83179	Barra	-11,08	-43,17	401,6
Bahia	83236	Barreiras	-12,15	-45,00	439,3
Bahia	83242	Lençóis	-12,57	-41,38	438,7
Bahia	83286	Correntina	-13,33	-44,62	549,5
Bahia	83288	Bom Jesus da Lapa	-13,27	-43,42	440,0
Bahia	83339	Caetitê	-14,07	-42,48	882,5
Bahia	83344	Vitória da Conquista	-14,88	-40,80	874,8
Bahia	83408	Carinhanha	-14,28	-43,77	450,2
Ceará	82392	Sobral	-3,73	-40,33	109,6
Ceará	82493	Jaguaruana	-4,78	-37,77	11,7
Ceará	82583	Crateús	-5,17	-40,67	296,8
Ceará	82586	Quixeramobim	-5,17	-39,28	79,5
Ceará	82588	Morada Nova	-5,12	-38,37	43,6

Ceará	82683	Tauá	-6,00	-40,42	398,8
Ceará	82686	Iguatú	-6,37	-39,30	217,7
Piauí	82882	Paulistana	-8,13	-41,13	374,2
Pernambuco	82753	Ouricuri	-7,90	-40,05	459,3
Rio Grande do Norte	82590	Apodí	-5,62	-37,82	150,0
Paraíba	82791	Patos	-7,02	-37,27	249,1
Paraíba	82792	Monteiro	-7,88	-37,07	603,7
Maranhão	82768	Balsas	-7,53	-46,03	259,4

3.2 - PREENCHIMENTO DE FALHAS EM DADOS METEOROLÓGICOS

Em Meteorologia e Climatologia, diversos produtos operacionais de monitoramento em tempo e clima dependem de uma boa rede de observações em superfície, que não apresentem ou tenham o menor número possível de falhas. Como exemplo, as séries de dados pluviométricos completos servem tanto para caracterizar a climatologia média das chuvas de uma região, como para a determinação do volume de água necessário para culturas irrigadas, como também para estudos de mudanças, tendências e extremos climáticos (SALVADOR, 2010). Lucio *et al.*, (2007) observou que, frequentemente, dados de recordes climatológicos de localidades onde não há observações meteorológicas, tem que ser calculados via interpolações temporais de observações em estações vizinhas.

Para preenchimento de falhas em dados diários de variáveis meteorológicas foi utilizada a técnica conhecida como *MICE* (*Multivariate Imputation by Chained Equations*). Esta é uma técnica de imputação múltipla que tem uma série de vantagens sobre outros métodos para tratar dados faltantes em séries temporais (SCHAFFER e GRAHAM, 2002).

Vários são os campos de aplicação da técnica *MICE* (VAN BUUREN e GROOTHUIS-OUDSHOORN, 2011), principalmente a dados da área de saúde pública. Nesta pesquisa, ela será adaptada para preenchimento de dados faltosos em séries temporais de variáveis meteorológicas.

Com o *MICE*, para preencher dados faltantes são criados vários conjuntos de dados completos, baseados em regressões lineares, regressões logísticas, modelos multinomiais log-lineares, ou regressões de Poisson para cada variável, como seja

apropriado, e os dados ausentes são imputados com base nos valores observados e suas relações com os dados de cada conjunto, envolvendo a criação de várias previsões para cada valor em falta, sendo, finalmente, usados os dados do conjunto que produziu menos incertezas e menores erros, entre estes e a série de dados observada (GREENLAND e FINKLE, 1995).

A técnica *MICE* faz uso de duas abordagens para imputação multivariada de dados ausentes em séries temporais: a modelagem conjunta e a modelagem subordinada às especificações (VAN BUUREN e GROOTHUIS-OUDSHOORN, 2011). O *MICE* é desenvolvido em linguagem R, para versões maiores que a 2.10, e disponibilizado em forma de pacote. Uma descrição básica de sua abordagem é descrita a seguir.

Seja Y_j com $(j=1,\dots,p)$, um conjunto de p variáveis incompletas, onde $Y=(Y_1,\dots,Y_p)$. As porções observadas e faltantes de Y_j são denotadas por Y_j^{obs} e Y_j^{falhas} , respectivamente, então $Y^{obs}=(Y_1^{obs},\dots,Y_p^{obs})$ e $Y^{falhas}=(Y_1^{falhas},\dots,Y_p^{falhas})$, representam os dados observados e em falta de Y . O número de imputações deve ser sempre igual a $m \geq 1$. O conjunto de dados imputados h_{th} é dado por $Y^{(h)}$ onde $h=1,\dots,m$. Seja agora $Y_{-j}=(Y_1,\dots,Y_{j-1}, Y_{j+1},\dots,Y_p)$ a coleção de variáveis $p-1$ em Y com exceção de Y_j . Seja Q a quantidade de dados faltantes a modelar. Na prática Q é frequentemente um vetor multivariado representando qualquer modelo a ser gerado para a modelagem dos dados faltantes.

A Figura 2 ilustra os três passos principais na imputação múltipla: imputação, análise e agrupamento. O *software* armazena os resultados de cada etapa em classes específicas denominadas *mids*, *mira* e *mipo*, explicados em detalhes a seguir.

O lado mais à esquerda na Figura 2 indica que a análise começa com um conjunto de dados observados Y_{obs} . O problema é que não se pode estimar Q de Y_{obs} sem fazer suposições irreais sobre os dados não observados. Logo, dados faltantes são gerados aleatoriamente ao conjunto de Y_{obs} , e várias versões de uma imputação múltipla são geradas, com valores plausíveis, de acordo com a natureza da variável, extraídos de uma distribuição especificamente modelada para cada entrada de valor para um respectivo dado faltante.

No *MICE*, esta tarefa é feita pela função `mice()`. A Figura 2 retrata $m=3$ dados imputados $Y_{(1)},\dots,Y_{(3)}$. Os três conjuntos imputados são idênticos aos conjuntos de dados

de entradas não faltantes, que diferenciam, logicamente, dos dados imputados. A magnitude destas diferenças reflete a incerteza sobre os valores a ser imputados.




Figura 2: Principais passos utilizados na imputação múltipla.

O segundo passo é estimar Q em cada conjunto de dados imputados, da mesma forma como em um conjunto de dados sem falhas. Isso se torna fácil já que todos os conjuntos estão completos. O modelo aplicado para $Y^{(1)}, \dots, Y^{(m)}$ é geralmente idêntico. As estimativas $Q^{(1)}, \dots, Q^{(m)}$ são diferentes umas das outras.

O terceiro e último passo é reunir as m estimativas $Q^{(1)}, \dots, Q^{(m)}$ em uma única estimativa Q_{med} e estimar sua variância. Para quantidades Q que são normalmente distribuídas, pode-se calcular a média sobre $Q^{(1)}, \dots, Q^{(m)}$ e somar com a variância de Q_{med} , de acordo com o método descrito em RUBIN (1987). O ideal é aplicar esta metodologia a uma coluna de dados que apresente falhas, ao lado de colunas com dados similares que não apresentem falhas, chamados de preditores, pois a relação estabelecida entre os conjuntos de dados tenderá a melhorar as estimativas dos conjuntos de dados a ser imputados da coluna que apresenta dados faltantes (COSTA *et al.*, 2012)

Na adaptação da técnica *MICE* para preenchimentos de falhas de precipitação, foram usados como conjuntos de preditores, séries da análise gradeada de precipitação do *Climate Prediction Center* do *National Oceanic and Atmospheric Administration* (CPC/NOAA) (CHEN *et al.*, 2008, SILVA *et al.*, 2007), baseadas no método de interpolação ótima de Gandin (1965), com resolução espacial de $0,5^\circ \times 0,5^\circ$. Para as outras variáveis, foram usadas como variáveis predictoras, séries das análises gradeadas fornecidas

pelo NCEP/NCAR (*National Center for Environmental Prediction/ National Center for Atmospheric Research*), com resolução de 1,0° x 1,0° (SHEFFIELD *et al.*, 2006).

Nas séries temporais que possuem dados faltosos, as falhas são caracterizadas por “NA”, sendo usado o número de imputações múltiplas padrão do pacote *MICE*, versão 2.12 (m=5 iterações), do *software* estatístico livre R. As imputações são geradas de acordo com o método padrão, que é, para dados numéricos, o método PMM - *Predictive Mean Matching*. Usando dados de precipitação para exemplificar o procedimento, a série original com falhas da estação meteorológica é colocada lado a lado dos quatro pontos de grade mais próximos da localidade, em uma matriz exemplificada na Tabela 5.

Tabela 5. Ilustração de dados de precipitação a serem imputados, representados por NA, referentes à estação de Ouricuri (código OMM: 82753) - Pernambuco (a), e dados com as falhas preenchidas (b). Os dados originais (coluna Orig) estão ao lado das séries gradeadas mais próximas, ou conjunto de preditores (G-01; G-02; G-03 e G-04). As falhas preenchidas aparecem destacadas em vermelho.

(a)								(b)							
Ano	Mês	Dia	Orig	G-01	G-02	G-03	G-04	Ano	Mês	Dia	Orig	G-01	G-02	G-03	G-04
1980	12	15	0	3,2	3,8	2,7	7,9	1980	12	15	0	3,2	3,8	2,7	7,9
1980	12	16	0	1,9	0,7	3,2	0,4	1980	12	16	0	1,9	0,7	3,2	0,4
1980	12	17	NA	8,3	5,5	3,3	3,7	1980	12	17	5,2	8,3	5,5	3,3	3,7
1980	12	18	15,9	14,7	5,5	19,1	5,1	1980	12	18	15,9	14,7	5,5	19,1	5,1
1980	12	19	6,8	3,9	1,4	9,6	1,7	1980	12	19	6,8	3,9	1,4	9,6	1,7
1980	12	20	NA	12,3	4,4	14,1	5,8	1980	12	20	12,6	12,3	4,4	14,1	5,8
1980	12	21	0	0,1	0	0,2	0,2	1980	12	21	0	0,1	0	0,2	0,2
1980	12	22	0	6,2	3,1	4,9	0,8	1980	12	22	0	6,2	3,1	4,9	0,8

Após a imputação dos dados faltantes, foram identificadas nas séries originais ao menos 05 anos com dados medidos sem falhas na série original, e então falhas foram geradas artificialmente para estes anos e o método foi novamente empregado, a fim de comparar dados realmente observados com a imputação gerada, para avaliar a habilidade do método. Estatísticas como correlações (*r*) e a raiz do erro quadrático médio (REQM) foram calculadas para estes períodos de verificação para validação da metodologia.

3.3 - SISTEMA DE CONTROLE DE QUALIDADE EM DADOS METEOROLÓGICOS

Todos os sistemas de monitoramento do clima e conjuntos de dados climáticos exigem a melhoria da qualidade dos dados, continuidade e homogeneidade. Isso vale para praticamente todas as aplicações climatológicas, mas torna-se uma necessidade essencial em termos da capacidade de medir, detectar ou atribuir mudanças climáticas. Para dados diários, onde a acessibilidade ainda é muito restrita, Sistemas de Controle de Qualidade (SCQ), particularmente rigorosos, são essenciais (WMO, 2003; CAMARGO e HUBBARD, 1999). Os dados não devem ser considerados como satisfatórios para arquivamento permanente até que tenham sido submetidos a um nível adequado de controle de qualidade.

Um bom SCQ deve combinar dois fatores: pessoas e máquinas. Um *software* de qualidade de dados deve fornecer uma lista de dados suspeitos, mas as decisões finais sobre a correção ou atualização do arquivo digital devem ser do pessoal competente que estará analisando tais relatórios. No entanto, a massa de dados disponíveis nos Serviços Meteorológicos Nacionais (particularmente no INMET) só aumenta, por exemplo, com a inserção de dados provenientes de estações meteorológicas automáticas de alta resolução. No entanto, a contrapartida geralmente está associada a restrições de pessoal e na qualidade da verificação automática.

Um SCQ não deve ser uma ferramenta perfeita, que acusa um possível erro e automaticamente o dado é retirado da série. Algumas técnicas de SCQ, com forte componente estocástica, podem levar a uma alta probabilidade de rejeição de boas observações (GUTTMAN, 1990; MEEK, 1994). Um SCQ deve disponibilizar ao tomador de decisão, saídas gráficas facilmente compreensíveis e resumos contendo a lista de dados suspeitos, que são excelentes ferramentas para exames visuais que podem ser de grande ajuda, uma vez que a mente humana é especialmente hábil em identificar padrões espaciais.

Alguns testes de consistência são um importante conjunto de verificações de possíveis erros, pois devem explorar a inter-relação temporal e espacial dos dados climatológicos. Os três principais meios de verificações de consistência são os internos, os temporais, e os espaciais:

- os testes de consistência interna exprimem as relações físicas entre os diferentes elementos climatológicos. Em alguns casos são testes lógicos do tipo: se determinado elemento encontra-se em algum intervalo, outro deverá estar contido, também, em outro determinado intervalo (GANDIN, 1988).

- testes de consistência temporal são baseados na persistência no tempo de elementos climatológicos. Certos limiares de mudanças selecionadas dependem da variável em questão, do período do ano e da região climática a que pertence os elementos da série tempoal (EISCHEID *et al.*, 1995).

- testes de consistência espacial exploram a suave variação no espaço das variáveis climatológicas. Geralmente este tipo de teste envolve a estimativa de um determinado elemento com base nas observações vizinhas em uma mesma região climática (HUBBARD *et al.*, 2005). O limite de diferenças aceitas dependerá do tipo de variável, da região climática e da distancia entre as estações. Logo, a eficácia deste tipo de teste vai depender da disponibilidade de estações vizinhas (YOU *et al.*, 2007).

O SCQ aplicado neste estudo é baseado em uma série de testes, denominados Grupos de Testes. O fluxograma mostrado na Figura 3 detalha o passo a passo de cada etapa à qual todos os registros de dados são analisados. Todas as colunas com informações são cuidadosamente estudadas, desde a coluna que contém o código de identificação da OMM da estação, a coluna que contém as datas da coleta dos dados, e os respectivos valores das variáveis meteorológicas. Uma etapa importante é a confecção de um arquivo chamado metadados, que contém as informações básicas da estação: o código de identificação da OMM, o nome da estação, a longitude e a latitude em graus, minutos e segundos, assim como em décimos de graus, a altitude, o País e Estado a qual pertence, a data de início e fim de suas operações, a Instituição a qual pertence e o tipo da estação, se convencional ou automática. No pré-processamento do SCQ, estas informações contidas nos metadados são lidas e servem de base para alguns dos testes gerais, mostrados na Figura 3.




Figura 3: Fluxograma do SCQ, desde a extração de uma série do banco de dados, a aplicação dos testes, até a verificação ou correção dos dados duvidosos.

3.4 - MODELO AGROMETEOROLÓGICO DE PENALIZAÇÃO POR DEFICIÊNCIA HÍDRICA

O modelo de simulação para produtividade das culturas utilizado segue a base teórica proposta por Doorenbos e Kassan (1979), que estabelece relações entre perdas de produtividade e deficiência hídrica no decorrer das fases fenológicas da cultura. Este modelo é composto por dois módulos: um que estima a produtividade potencial da safra ou

produtividade máxima, e outra que estima o decréscimo do potencial de produtividade em função do déficit hídrico.

A penalização final é calculada conforme o modelo de Doorenbos e Kassam (1979), e acumulada a cada passo de tempo (diário, decendial ou mensal). Esse modelo é função da Evapotranspiração Potencial da Cultura (ETP_c), da Evapotranspiração Real da Cultura (ETR_c) e do coeficiente de penalização por déficit hídrico (ky), mostrados na equação 1.

$$Yd = \left(1 - \frac{ETR_c}{ETP_c}\right) \times ky \times 100 \quad \text{Equação (1)}$$

em que Yd = penalizacao final, ETR_c = Evapotranspiração Real da Cultura, ETP_c = Evapotranspiração Potencial da Cultura e ky = coeficiente de penalização por déficit hídrico.

No entanto, antes de chegar à etapa final para o cálculo da penalização por déficit hídrico, estágios anteriores tem que ser expostos, e são mostrados na sequencia das equacoes 2 a 7. Nos cálculos, o desenvolvimento da cultura do algodão é tabelado para um ciclo da cultura de 150 dias. Este ciclo contém os coeficientes da cultura (kc) e de penalização hídrica (ky), com valores diários. O cálculo da evapotranspiração da cultura (ETC) depende de um valor para o kc , e a evapotranspiração real da cultura (ETR_c) depende de um coeficiente de umidade para o solo, o ks , calculado conforme o manual de irrigação de Salassier Bernardo *et al* (2008), abaixo.

$$ETC = ETP \times kc \quad \text{Equação (2)}$$

$$ETR_c = ks \times ETP \times kc \quad \text{Equação (3)}$$

$$ks = \frac{\text{Log}(ARM + 1)}{\text{Log}(ARM_c)} \quad \text{Equação (4)}$$

$$CAD = \frac{kc}{kc_{max}} \times CAD_{max} \quad \text{Equação (5)}$$

$$ARM = ARM_{ant} - ETR_c + Precipitação \quad \text{Equação (6)}$$

$$ARM_c = (1 - p) \times CAD \quad \text{Equação (7)}$$

em que: ETP = evapotranspiração; ETP_c = evapotranspiração da cultura; CAD = capacidade de campo; ARM = armazenamento de água no solo; ARM_c = armazenamento

crítico (a partir do qual a planta perde produtividade); ARM_{ant} = armazenamento anterior; p = fator de disponibilidade, tabelado pela *Food and Agriculture Organization of the United Nations* (FAO); ks = coeficiente de umidade; kc = coeficiente de cultura; kc_{max} = máximo coeficiente de cultura. O ARM nunca pode ser maior do que a CAD .

Diante da formulação acima mostrada, algumas definições são necessárias. A CAD pode ser definida como a quantidade máxima de água que o solo pode armazenar na profundidade explorada pelo sistema radicular da planta, variando ao longo do ciclo das culturas em função das características físicas do solo, nas diferentes profundidades, e devido ao crescimento do sistema radicular até atingir a profundidade efetiva. Para a cultura do algodão, a profundidade do sistema radicular pode chegar, em média, a 60 cm.

A ETP é a mudança de estado da água da fase líquida para a gasosa, no caso de solos parcialmente vegetados (BERLATO e MOLION, 1981). A ETP foi definida por Thornthwaite (1948) como a quantidade de água utilizada por uma extensa área vegetada, em crescimento ativo, sob condições ótimas de umidade do solo. Já Penman (1956) definiu ETP como “a quantidade de água utilizada na unidade de tempo por uma cultura de porte baixo e verde, cobrindo totalmente a superfície, com altura uniforme e sem deficiência hídrica”. Independente das definições, em 1990 a FAO recomendou o método de Penman-Monteith como padrão na estimativa da ETP.

Este método, denominado PM-FAO-1956, foi selecionado por apresentar resultados que muito se aproximam da evapotranspiração da grama em diferentes localidades, por representar as condições físicas presentes no processo e por incorporar tanto parâmetros fisiológicos como aerodinâmicos. Para estimativas da ETP por este método, são necessários dados de temperatura do ar, umidade relativa, radiação e velocidade do vento, diários, semanais, decendiais ou mensais. A ETP é obtida pela equação 8 a seguir.

- Cálculo da evapotranspiração potencial (mm/dia):

$$ETP = \frac{\left(\frac{1}{\lambda} \times \Delta \times (R_n - G) + f \times \frac{900}{(T_{med} + 273) \times V_{vel2m} \times (e_s - e_a)} \right)}{(\Delta + f \times (1 + 0,34 \times V_{vel2m}))}$$

Equação (8)

A ETP obtida pela Equação (8) relaciona-se com a evapotranspiração da cultura (ETPc) através de um coeficiente de cultivo (kc), obtidos experimentalmente. No início de

desenvolvimento de uma cultura o k_c é baixo, atingindo valores maiores à medida que a planta atinge a fase de maior demanda de água. Estes valores de k_c , para diversas culturas, podem ser obtidos na literatura (DOORENBOS e KASSAM, 2000). Para o algodão, no primeiro estágio, da emergência até 10% do desenvolvimento vegetativo (DV), os valores do k_c são em torno de 0,40 - 0,50; no segundo estágio, entre 10% do DV até 80% do DV, o k_c varia de 0,70 - 0,80, no terceiro estágio, entre 80% do DV até 100% do DV, com frutos formados, o k_c varia de 1,05 - 1,25; No quarto estágio, de maturação, o k_c varia de 0,80 - 0,90, e no quinto estágio, de colheita, o k_c varia de 0,65 - 0,70.

O conceito de ETPc foi introduzido por Doorenbos e Pruitt (1997), como sendo a evapotranspiração de uma cultura agrônômica livre de doenças, desenvolvendo-se em uma área cultivada de um ou mais hectares, sob condições otimizadas de solo, incluindo água e fertilidade. Em condições de campo, especialmente na agricultura de sequeiro, na maioria dos casos ocorre restrição de água. Desta forma, o termo evapotranspiração real da cultura (ETRc) foi introduzido para representar a quantidade de água realmente utilizada por uma cultura agrícola, com ou sem restrição de água.

O déficit hídrico passa então a ser analisado como um dos principais fatores limitantes a produtividade agrícola, influenciando todos os aspectos relacionados ao desenvolvimento vegetal, diminuindo a fotossíntese pela redução da área foliar e afetando vários outros processos, além de alterar o ambiente físico das culturas (FONTANA *et al.*, 1992). Seus efeitos dependem da sua intensidade, duração, época de ocorrência e da interação com outros fatores que interferem no rendimento das culturas (CUNHA e BERGAMASCHI, 1999).

Doorenbos e Kassam (2000) expressaram a sensibilidade das culturas ao déficit hídrico através de um fator de sensibilidade (k_y) correlacionando a queda de rendimento com o déficit de evapotranspiração relativa. Este valor indica que havendo déficit de água no solo a cultura responde negativamente diminuindo o seu rendimento. A maioria das culturas em termos de rendimento reage diferentemente ao déficit hídrico em função da fase de desenvolvimento. Desta forma, o déficit hídrico ocorrido em uma ou mais fases está associado a uma redução percentual na produtividade máxima, sendo o rendimento relativo dado pela relação entre este rendimento máximo e o déficit de evapotranspiração em cada fase de desenvolvimento.

3.4.1 - CALIBRAÇÃO DO MODELO AGROMETEOROLÓGICO

O modelo agrometeorológico proposto foi calibrado para o período 2001-2011, utilizando-se, para isso, dados de produtividade do algodão herbáceo, em kg/ha, para a área plantada de 23 municípios localizados na região semiárida do Nordeste do Brasil, de acordo com as épocas de semeadura indicadas pela Companhia Nacional de Abastecimento (CONAB), do Governo Federal.

O primeiro passo foi obter, dos dados de produtividade, a produtividade máxima chamada de Produtividade Máxima Tecnológica (PMT), estimada a partir de um ajuste estatístico baseado na série de dados das Produtividades Reais Observadas (PRO). Uma equação linear de primeiro grau ($Y=ax+b$), dos dados observados *versus* o tempo (ano) deve ser obtida, onde a linha reta indica a tendência da produtividade ao longo dos anos (TPA). Os desvios ao longo da linha de tendência são causados por fatores climáticos, de disponibilidade hídrica e de manejo da cultura. A segunda etapa consiste na determinação de um fator de correção que, quando multiplicado pela tendência da produtividade observada (TPA), elevaria os valores de produtividade em uma situação sem restrição de água. Esse fator de correção foi nomeado coeficiente de produtividade máxima tecnológica (Δp). Logo, a PMT foi calculada para cada ano "n", em função da produtividade real ajustada multiplicada por Δp : $PMT = TPA \times \Delta p$.

Desta forma, Δp foi ajustado de uma regressão linear sem tendência e consiste em um dos parâmetros calibrados no modelo, de acordo com o método indicado a seguir. Os valores dos coeficientes de cultura (kc) e de déficit hídrico (ky), apresentados por DOOREMBOS e KASSAM (2000) para o algodão herbáceo, de acordo com suas fases fenológicas, foram adaptados para a escala diária, facilitando sua posterior obtenção para a escala decenal.

A Produtividade Real (PR) foi estimada a partir da relação entre o déficit relativo de água [$1 - (ETR_c/ETP_c)$], e as perdas de produtividade relativa, ponderada pelo fator de déficit hídrico (ky), para cada fase fenológica:

$$Y_d = \frac{PR}{PMT} = \left[1 - \left(\frac{ETR_c}{ETP_c} \right) \right] \times ky \times 100 \quad \text{Equação (9)}$$

Neste modelo, uma alteração importante é encontrar, para qualquer estação meteorológica, de acordo com a sua classe de produtividade (baixa, média ou alta), um

parâmetro empírico denominado "fator de déficit hídrico ajustado", ou " k_y^* ", que resulta em maior ou menor resposta ao estresse hídrico. Outra diferença é a utilização da PMT. Com tais mudanças, o modelo final apresentará a seguinte equação:

$$\frac{PR}{PMT} = \left[1 - \left(\frac{ETR_c}{ETP_c} \right) \right] \times k_y \times k_y^* \times 100 \quad \text{Equação (10)}$$

Em que, nesta equação, a PMT é usada como referencia inicial para começar o procedimento de cálculo das perdas, para cada estação.

O processo de parametrização consiste no ajuste do coeficiente de produtividade máxima tecnológica (Δp), e do " k_y^* ", a fim de maximizar a correlação entre as produtividades reais observadas e estimadas, e também para minimizar o erro médio absoluto (EMA) entre eles. Neste processo, k_y^* começa com valor igual a 1, sendo acrescido ou reduzido de acordo com o ganho ou perda na correlação e no EMA entre as produtividades observadas e estimadas. O EMA é caracterizado pela média do módulo dos erros absolutos das estimativas, sendo dado por:

$$EMA = \frac{1}{n} \sum_{i=1}^n |Pe_i - Po_i| \quad \text{Equação (11)}$$

Onde Pe_i é a produtividade final estimada em um ano i e Po_i é a produtividade real observada pelo IBGE no ano i , e n é o numero de comparações.

No modelo da Equacao (26), a ETRc é calculada pelo balanço hídrico sequencial, onde são computados as mudanças diárias na umidade do solo, de acordo com o método de Thornthwaite (1948).

3.5 - DOWNSCALING ESTATÍSTICO DA PRECIPITAÇÃO, TEMPERATURAS MÁXIMAS E TEMPERATURAS MÍNIMAS

O *downscaling* estatístico é um campo da ciência que permite adaptar a baixa resolução (tipicamente 250 km) dos cenários de mudanças climáticas globais fornecidas pelos MCGs para escala regional ou local. Estes métodos ligam as saídas em larga escala dos MCGs (como a altura geopotencial em 500 mb) com observações históricas locais (variáveis de superfície como a precipitação ou temperatura) na região de interesse

(TIMBAL *et al.*, 2003; HAYLOCK *et al.*, 2006; HEWITSON e CRANE, 2006; TIMBAL e JONES, 2008; BENESTAD, 2010; BRANDS *et al.*, 2011a; BRANDS *et al.*, 2011b; GUTZLER e ROBBINS, 2011).

Diferentes métodos de *downscaling* estatístico (MDEs) têm sido propostos para inferir tais relações (MARAUN *et al.*, 2010). Para qualquer método que venha a ser utilizado, as saídas de reanálises para um período representativo, geralmente os últimos 30 anos, são utilizados como preditores, enquanto as observações históricas locais são utilizadas como preditandos para o período de treinamento de um MDE. Uma vez que a configuração ideal do modelo é encontrada usando estes dados (quase) observados, este modelo é aplicado à saída de um MCG para obter projeções futuras em diferentes cenários de alterações climáticas (WILBY e DAWSON, 2013).

A forma mais comum de obter a relação estatística, ou empírica, desenvolvida a partir da relação quantitativa entre preditores e preditandos, pode ser entendida como: $R = F(L)$, onde R representaria o preditando (a variável climática regional, ou local, por exemplo, precipitação, temperatura ou evapotranspiração obtidas de uma determinada estação meteorológica), e F uma função determinística/estocástica condicionada por L, obtida a partir da relação empírica obtida da respectiva grade associada ao MCG utilizado. Os MDEs combinam as informações dos MCGs as reanálises das observações das variáveis de grande escala, a fim de inferir os modelos de transferência estatística apropriados. Portanto, dois ingredientes básicos dos MDEs são os conjuntos de dados de reanálises e as observações, que são necessários para definir e calibrar o/os MDE(s) que será(ão) usados posteriormente para gerar cenários futuros.

A habilidade dos MDEs depende da variável, época e região de interesse. Assim, para cada aplicação e estudo de um caso particular, um conjunto de métodos de *downscaling* estatístico precisa ser testado e validado para alcançar o máximo de habilidade e uma representação adequada de incertezas. Assim, a validação se torna a principal componente de um MDE.

Cada experimento deve conter todas as informações necessárias para o processo de redução de escala: um conjunto único de preditores, os preditandos e um MDE. Para definir um experimento as três etapas sequenciais devem ser adotadas:

- 1. Preditores:** Definição da região geográfica e preditores a serem utilizados.
- 2. Preditandos:** Definição de um ou vários predictandos a serem processados.
- 3. Método de Redução de Escala:** Definição e validação de um ou vários MDE para ser aplicado no experimento.

Uma vez que a cadeia Preditores → Preditandos → Método de redução de escala tenha sido concluída, os MDEs estarão prontos para ser utilizados e aplicados a qualquer um dos MCGs disponíveis. Para a elaboração dos resultados de *downscaling* estatístico das variáveis precipitação, temperaturas máximas e mínimas desta pesquisa, serão utilizadas as funcionalidades fornecidas pelo *ENSEMBLES Downscaling Portal*, desenvolvido pelo Grupo Santander Meteorologia (<http://www.meteo.unican.es>) com a assistência técnica do Predictia (<http://www.predicta.es>) como parte das atividades do projeto *ENSEMBLES* financiado pela União Europeia (2004-2009, ver <http://ensembles-eu.metoffice.com>).

3.5.1 - SELEÇÃO DOS PREDITORES

Entre as funcionalidades do portal, os dados de reanálises do projeto ERA40 (UPPALA *et al.*, 2005) e do NCEP/NCAR (KALNAY *et al.*, 1996; BRANDS *et al.*, 2012), estão disponíveis em uma grade comum $2,5^\circ \times 2,5^\circ$, que é a mesma resolução de grade dos quatro diferentes MCGs que estão disponíveis para serem trabalhados, tanto para o período de controle (1961-2000) quanto para cenários futuros (A1B e A2, para 2001-2100). Para a variável precipitação, a Figura 4 mostra a grade utilizada projetada sobre a região Nordeste, com as respectivas variáveis predictoras: componente meridional da velocidade média do vento no nível de 850 hPa, componente zonal da velocidade média do vento no nível de 850 hPa, umidade específica no nível de 850 hPa, pressão ao nível médio do mar, geopotencial em 500 hPa e temperatura no nível de 850 hPa, preditores oriundos das reanálises do projeto ERA40, para o período de 01 de janeiro de 1961 a 31 de dezembro de 2000.

Para as variáveis temperaturas máximas e mínimas, foram selecionadas as respectivas variáveis predictoras: umidade específica no nível de 850 hPa, pressão ao nível médio do mar, geopotencial em 500 hPa e temperatura no nível de 850 hPa, preditores oriundos das reanálises do NCEP/NCAR, para o período de 01 de janeiro de 1961 a 31 de dezembro de 2000.



Figura 4: Grade e preditores utilizados para a precipitação da região Nordeste.

Os dados de reanálise são derivados de modelos numéricos que reproduzem estados atmosféricos passados que são consistentes com as observações. Vários produtos de reanálise estão disponíveis (FLATO *et al.*, 2013; COLLINS *et al.*, 2013; HARTMANN *et al.*, 2013).

A Tabela 6 mostra as variáveis de grande escala disponíveis, tanto do projeto ERA40 quanto do NCEP/NCAR, para seleção dos preditandos, que devem coincidir com variáveis simuladas pelos MCGs (WILBY e WIGLEY, 2000; FOWLER *et al.*, 2007; TEUTSCHBEIN *et al.*, 2011).

Tabela 6. Descrição das variáveis, níveis de altura e unidades do conjunto de parâmetros disponíveis para seleção de preditores.

Variável (Código)	Níveis Atmosféricos (hPa)	Unidades
Geopotencial (Z)	1000, 850, 700, 500, 300	$m^2 s^{-2}$
Componente Meridional do Vento (V)	850, 700, 500, 300	$m s^{-1}$
Componente Zonal do Vento (U)	850, 700, 500, 300	$m s^{-1}$
Temperatura (T)	850, 700, 500, 300	K
Umidade Específica (q)	850, 700, 500, 300	$kg kg^{-1}$
Pressão ao Nível Médio do Mar (MSLP)	superfície	Pa
Temperatura a 2m (2T)	superfície	K

3.5.2 - SELEÇÃO DOS PREDITANDOS

Foram inseridas no portal dados observados de precipitação, temperaturas máximas e mínimas das 23 estações meteorológicas pertencentes ao INMET na região Nordeste do Brasil, que coincidem com regiões de produção de algodão verificadas de acordo com o IBGE. Estas três variáveis são os predictandos, as quais devem passar pelo processo de calibração com os preditores que foram selecionados, a partir dos dados de reanálises, de forma independente entre si. A Figura 5 mostra a localização espacial das estações, as quais podem ser trabalhadas em grupos de até cinco estações para, em seguida, ser escolhido o método de *downscaling* estatístico, o respectivo MCG e o respectivo cenário a ser trabalhado na geração das futuras séries de precipitação, temperaturas máximas e mínimas.




Figura 5: Janela de criação de um predictando para um determinado experimento. No exemplo, para a precipitação da região Nordeste.

3.5.3 - SELEÇÃO DO MÉTODO DE *DOWNSCALING* ESTATÍSTICO

Como já mencionado, o passo inicial de um MDE é encontrar uma relação empírica (um modelo estatístico) entre as variáveis de grande escala das reanálises (preditores) e as variáveis observadas em pequena escala (predictandos), utilizando dados em um período histórico comum, neste caso, de 1961 a 2000. Em seguida, o modelo estatístico resultante é aplicado aos dados a partir de diferentes simulações de mudanças climáticas de MCGs, sob diferentes cenários a fim de obter a projeção futura local.

Geralmente, as diferentes metodologias de *downscaling* estatístico são classificadas em três classes (GUTIERREZ *et al.*, 2013):

- **Weather Typing (Análogos)**, baseado em vizinhos próximos ou em uma pré-classificação da reanálise em um número finito de tipos de tempo obtidos de acordo com sua semelhança sinótica, onde um algoritmo de previsão é obtido para a geração das séries temporais.
- **Funções de Transferência (Regressões)**, baseado em modelos de regressão lineares ou não lineares (por exemplo, redes neurais ou modelos lineares generalizados), para inferir as relações entre preditandos e os preditores de grande escala. Estes modelos são chamados “geradores”, no sentido em que as projeções são derivadas de um modelo.
- **Geradores de Tempo (Weather Generators)**, que simulam estocasticamente valores climatológicos diários com base nas projeções médias mensais disponíveis ou em procedimentos de reamostragem ou simulações aplicadas aos dados diários. Estas técnicas são métodos de desagregação temporais.

Para esta pesquisa, dois cenários de mudanças climáticas, A1B e A2, foram utilizados para a geração das séries de precipitação, temperaturas máximas e mínimas para o período 2001-2080. Os MCGs utilizados são o ECHAM5-OM, do *Max Planck Institute for Meteorology*, da Alemanha (MARSLAND *et al.*, 2003; RADDATZ *et al.*, 2007), e o HadGEM2-ES, do *Meteorological Office Hadley Centre*, do Reino Unido (BELLOUIN *et al.*, 2007; COLLINS *et al.*, 2008).

O ECHAM5-OM consiste do acoplamento de um MCG atmosférico (ECHAM5) e de uma componente oceano-gelo marinho. O ECHAM5 é a quinta geração do MCG ECHAM, evoluindo originalmente do modelo de previsão de tempo espectral do Centro Europeu de Previsão de Tempo a Médio Prazo (ECMWF). Seu módulo oceânico é um modelo de equações primitivas (Grade-C, coordenadas-Z, superfície livre), com os pressupostos hidrostáticos e de Boussinesq. Ele inclui um modelo de gelo marinho dinâmico/termodinâmico com uma reologia plástico-viscosa e um esquema de camada limite inferior para o fluxo ao longo de topografia íngreme. Suas variáveis prognósticas atmosféricas são a vorticidade, divergência, temperatura, pressão, vapor d'água, água líquida de nuvens e gelo de nuvens. Sua resolução espacial é de 63 níveis de resolução horizontal e 31 níveis de resolução vertical. Resolução oceânica de 1,5°, com 40 níveis.

O HadGEM2-ES é um modelo acoplado do sistema terrestre utilizado pelo Met Office Hadley Centre para simulações ao longo do século. Este foi o primeiro modelo do Hadley Centre a incluir os componentes padrões do sistema terrestre. Este módulo é utilizado por um grande número de instituições no mundo, tanto para previsão do tempo operacional quanto para pesquisas climáticas. Este modelo compreende um MCG atmosférico com 96 níveis de resolução horizontal e 38 níveis de resolução vertical, e um MCG oceânico com resolução horizontal de 1° (aumentando até 0,33° no equador) e 40 níveis verticais. Os principais componentes do sistema terrestre incluídos são os ciclos do carbono terrestre e oceânico, e a química troposférica. Um modelo dinâmico de vegetação terrestre está presente, simulando a cobertura e balanço do carbono para cinco tipos de vegetação (árvores folhosas, árvores pouco folhosas, raras C3, gramíneas C4 e arbustos). A biologia e a química dos carbonatos oceânicos são representados, incluindo a limitação do crescimento do plancton por macro e micro nutrientes.

O MDE escolhido para a geração das séries dos respectivos cenários foi o método dos análogos. Este método tem sido aplicado essencialmente no campo da previsão do tempo (LORENZ, 1969; KRUIZINGA e MURPHY, 1983), e na previsão do clima a curto prazo (BARNETT e PREISENDORFER, 1978; VAN DEN DOOL, 1994). Para fins de redução de escala, este método ainda é pouco aplicado (ZORITA *et al.*, 1995; CUBASCH *et al.*, 1996; BIAU *et al.*, 1999, ZORITA e STORCH, 1999), embora a sua metodologia seja simples. A circulação atmosférica em grande escala simulada por um MCG é comparada com cada uma das observações históricas, e o padrão mais semelhante com as observações é escolhido como seu análogo. O clima local observado simultaneamente é, então, associado ao padrão de grande escala simulado.

Um problema relevante associado a este método é a necessidade de observações suficientemente longas, para que um análogo razoável da circulação de grande escala possa sempre ser encontrado. Este problema com as observações de superfície foi sanado usando o procedimento de preenchimento de falhas explicado na seção 3.3.

Devido ao número de graus de liberdade da circulação atmosférica de grande escala, foi mostrado que para fins de previsão, a nível global (VAN DEN DOOL, 1994), seriam necessários vários milhares de anos de simulações com um MCG, e de dados de reanálises, para obter padrões análogos com as situações sinóticas observadas. No entanto, muitos destes graus de liberdade representam apenas ruídos, que podem ser previamente

filtrados, por exemplo, por um padrão de funções ortogonais empíricas (FOE). Outra vantagem é que, para aplicações em *downscaling*, a área de interesse não é global, geralmente se trata de uma fração continental ou oceânica.

Além disso, para fins de *downscaling*, o método de análogos não é usado em um esquema de previsão, mas sim como um meio para especificar um estado local coerente com um estado simultâneo de grande escala. Tudo isto reduz o número de graus de liberdade do problema, e os estados análogos então se tornam úteis na maior parte das aplicações de *downscaling*. Nesta forma ligeiramente modificada, as anomalias da circulação atmosférica, por exemplo, representadas por (f) do campo da Pressão ao Nível do Mar (PNM), são descritos por poucos padrões principais de FOE:

$$f(i, t) = \sum_{k=1}^n xk_t gk_t + \epsilon_t \quad \text{Equação (12)}$$

Onde i é um índice de ponto de grade, t é o tempo, gk é o padrão de ordem k da EOF, $xk(t)$ é a amplitude deste padrão no tempo t , n representa o número de padrões de EOF retidos, e ϵ é a parte da variabilidade não descrita pelos principais padrões n , considerado pequeno. Os análogos são pesquisados apenas dentro do espaço gerado por estas n EOF padrões.

Realisticamente, este método pode ser mais bem ilustrado no seguinte exemplo. Supõe-se que estamos interessados na precipitação do trimestre fevereiro-março-abril sobre a região Nordeste, para um número de estações meteorológicas distribuídas irregularmente. Supõe-se que a precipitação desta região é controlada, em maior parte, pela variabilidade atmosférica gerada pelo fenômeno conhecido como Dipolo do Atlântico. A variável em grande escala será o campo da PNM, que para este fim oferece algumas vantagens em comparação com dados de altura geopotencial, por exemplo. Primeiro, existem séries longas e homogêneas desta variável que permitem configurar o modelo estatístico em um período, e verificá-lo em outro período para um conjunto de dados independentes. Em segundo lugar, em experimentos de mudanças climáticas com um MCG, a altura geopotencial tende a ser muito mais afetada pelo aquecimento global, mas essas alterações podem estar relacionadas a mudanças na densidade atmosférica média e não necessariamente às mudanças da circulação atmosférica. Portanto, utilizando-se as alturas geopotenciais como o campo de grande escala para associar padrões análogos a precipitação deste trimestre, sobre a região Nordeste, pode-se incorrer no risco de se incluir

um sinal que não é fisicamente relacionado com a circulação atmosférica e, portanto, com a variável local. O campo da PNM, por outro lado, é muito menos afetado. Geralmente, as cinco componentes principais das FOEs do campo de PNM, ao serem mantidas, podem chegar a descrever de 75 a 85% da variabilidade observada nas chuvas diárias (ZORITA e STORCH, 1999).

O método dos análogos será validado usando a abordagem dos períodos de treinamento e dos testes. O período histórico comum para preditores (reanálises) e preditandos (observações), é dividido em treinamento (75% dos dados) e testes (25% dos dados). A fase de treinamento é calibrada utilizando os dados de treinamento, enquanto que a fase de testes é validada entre as simulações feitas para este período e as observações correspondentes. Os dados dos testes não são utilizados na fase de calibração, desta forma os coeficientes obtidos para o método dos análogos na fase de calibração podem ser extrapolados para novos conjuntos de dados provenientes dos cenários dos modelos para o horizonte 2001-2080.

A validação é feita tanto em nível diário quanto em uma base decendial. Em ambos os casos, estatísticas básicas são calculadas para duas diferentes escalas de tempo, diária e decendial. Principalmente no caso da precipitação, uma variável de caráter duplo, discreta/continua, melhores desempenhos normalmente serão observados a nível decendial. A seguir serão detalhados os três tipos de medidas de desempenho que permitirão avaliar o *downscaling* estatístico entre observações e simulações pelo método dos análogos, a estatística descritiva, medidas de acurácia e de distribuição de similaridades, para precipitação e temperaturas.

3.5.3.1 - ESTATÍSTICA DESCRITIVA

São as estatísticas básicas oriundas das observações e das simulações.

TP: Taxa de Precipitação (apenas para a precipitação). Este índice mede a frequência de dias úmidos e é calculada dividindo-se o número de dias chuvosos (N_{chu}), pelo tamanho da amostra (N), expressa em %. Considerou-se como evento chuvoso qualquer valor acima de 0,1mm por dia.

$$TP = \frac{N_{chu}}{N} \times 100\% \quad \text{Equação (13)}$$

Média: A média aritmética diária. Mede a tendência central em uma amostra. É calculada pela soma de todos os pontos dos dados (x_i , $i = 1, \dots, n$), dividido pelo tamanho N da amostra.

$$M = \frac{1}{N} \sum_{i=1}^N x_i \quad \text{Equação (14)}$$

Desvio Padrão: Esta medida mostra o quão grande pode ser, ou não, a variação em torno da média, definida como a raiz quadrada da variância. É uma medida muito influenciada por valores discrepantes. Uma vantagem desta medida é a de que, ao contrário da variância, é expressa na mesma unidade dos dados. Em graus Celsius para temperatura, em milímetros para a chuva, etc.

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2} \quad \text{Equação (15)}$$

3.5.3.2 - MEDIDAS DE PRECISÃO

A precisão é um dos principais aspectos que devem ser analisados quando se olha para a qualidade de uma simulação/previsão, uma vez que mede o grau de concordância entre as previsões e as séries históricas. Alguns dos resultados são apresentados em unidades de alguma estatística descritiva, o que permite uma comparação direta entre as estações.

TA: Taxa de Acertos (Hit Rate). É a probabilidade de ocorrência (o) de dias com chuva que foram corretamente previstos (p). Esta pontuação varia entre $[0,1]$ sendo 1 a pontuação perfeita.

$$TA = P(p = 1 | o = 1) \quad \text{Equação (16)}$$

TAF: Taxa de Alarmes Falsos (False Alar Rate). É a probabilidade de não ocorrência que foram incorretamente previstos. Esta pontuação varia em $[0,1]$ sendo 0 a pontuação perfeita.

$$TAF = P(p = 1 | o = 0) \quad \text{Equação (17)}$$

Os escores TA e TAF são calculados apenas para a precipitação diária. Não são calculados para a precipitação acumulada em 10 dias, pois esta variável passa a ser considerada contínua, e estes dois escores são calculados conjuntamente para avaliar a precipitação como variável discreta.

r: Coeficiente de correlação de Pearson mede a força da relação linear entre observações e previsões (Equação 18). Varia entre [-1,1]. Pontuação perfeita: 1. O coeficiente de correlação de Pearson entre duas variáveis (observações(o) e previsões(p)) é definida como a covariância das duas variáveis (Cov (o, p)) dividida pelo produto de seus desvios-padrão.

$$r_{o,p} = \frac{Cov(o,p)}{\sigma_o} = \frac{\sum_{t=1}^N (o_t - \bar{o})(p_t - \bar{p})}{\sqrt{\sum_{t=1}^N (o_t - \bar{o})^2} \sqrt{\sum_{t=1}^N (p_t - \bar{p})^2}} \quad \text{Equação (18)}$$

Será utilizado como forma de auxiliar a análise estatística do coeficiente de correlação, a tabela abaixo, onde se apresenta uma interpretação detalhada do coeficiente de correlação de Pearson.

Tabela 7. Coeficiente de correlação estatística, ou coeficiente de correlação de Pearson. Fonte: Devore (2006)

Intervalos	Definição
0,00 a 0,19	Correlação bem fraca
0,20 a 0,39	Correlação fraca
0,40 a 0,69	Correlação moderada
0,70 a 0,89	Correlação forte
0,90 a 1,00	Correlação muito forte

Para garantir que o valor de *r* realmente exprima a concordância entre observações e simulações, usar-se-á o teste paramétrico t-Student (Huang e Paes, 2009; Menezes, 2010) para avaliar o grau de relação entre as variáveis em questão. Uma premissa para o uso do teste é que o tamanho da amostra, N, da qual obtém-se o valor do coeficiente de correlação, *r*, seja igual ou superior a 6, então o valor de t é dado por:

$$t = \frac{r}{\sqrt{(1-r^2)/(N-2)}} \quad \text{Equação (19)}$$

A equação (19) é uma distribuição para t com N-2 graus de liberdade. A aplicação desta fórmula para qualquer valor de r e de N vai testar a hipótese nula de que o valor observado vem de uma população em que não existe correlação significativa entre os dados. Uma vez obtido o valor de t, pode-se extrair o coeficiente de correlação crítico (r_c), que é um valor para a qual se aceita ou não a hipótese estatística que existe correlação entre os dados simulados e observados, r_c é dado por:

$$r_c = \sqrt{\frac{t^2}{(N-2) + t^2}} \quad \text{Equação (20)}$$

3.5.3.3 - SIMILARIDADE DAS DISTRIBUIÇÕES

A análise da semelhança das distribuições descreve a qualidade de uma previsão/simulação, particularmente em escalas temporais onde não se pode averiguar a correspondência serial entre previsões e simulações, exatamente como no caso de projeções de mudanças climáticas. Desta forma, estes índices medem a similaridade em termos climatológicos. A similaridade da distribuição deve ser cuidadosamente examinada, especialmente para estudos de mudanças climáticas. Aqui, três índices serão avaliados:

RV: Razão de Variâncias. Esta pontuação mede a relação entre as variações das previsões e das observações. Varia entre $[0, \infty)$. Pontuação perfeita: 1.

$$RV = \frac{\sigma_p^2}{\sigma_o^2} \quad \text{Equação (21)}$$

PDFscore: O PDFscore mede a sobreposição entre as funções de densidade de probabilidade empíricas observadas e previstas. Varia no intervalo $[0,1]$. Pontuação perfeita: 1. Este índice é calculado como em Perkins e McAneney (2007):

$$PDFscore = \sum_{i=1}^{100} (PDF_{pt} - PDF_{ot}) \quad \text{Equação (22)}$$

Onde PDF_{fi} é a densidade de probabilidade das previsões e o PDF_{oi} é a densidade de probabilidade das observações, para 200 classes definidas para toda a gama de observações e previsões. A densidade de probabilidade para cada classe é estimada por um filtro de Kernel em uma abordagem não paramétrica para encaixe das densidades. Todas as densidades são comparadas para cada classe, por um parâmetro de largura otimizado para distribuições normais.

O PDFscore é pouco sensível a falhas nas caudas das distribuições. No caso da precipitação diária, devido à alta densidade de probabilidade de classes localizadas próximas a zero, este índice é calculado apenas para a parte contínua das distribuições, considerando-se exclusivamente os dias com chuva observada e prevista.

Q-Q Plot: O gráfico quantil-quantil plot ou q-q plot é utilizado para determinar se dois conjuntos de dados pertencem a mesma distribuição de probabilidades. Em tais gráficos os pontos são formados pelos quantis amostrais e se no resultado os pontos alinham-se numa reta de inclinação 1, as distribuições das duas amostras podem ser consideradas as mesmas.

3.6 - REFINAMENTO ESTATÍSTICO PARA *DOWNSCALING* DA PRESSÃO ATMOSFÉRICA, UMIDADE RELATIVA E VELOCIDADE DO VENTO À SUPERFÍCIE

Os MDEs conhecidos, seus *softwares* e metodologias, são comumente preparados para dados de precipitação, temperaturas máximas e mínimas. Faz-se também necessário nesta pesquisa, adotar uma metodologia para redução de escala de outras variáveis importantes para o cálculo da ETP pelo método de Penman-Monteith, que são a PAt, a UR e a VMV. Tais dados são disponibilizados a nível mensal, em arquivos no formato NETCDF, pelo Centro de Distribuição de Dados do IPCC, em pontos de grade para diversos modelos, para o período de janeiro de 2000 a dezembro de 2100. Tais dados podem ser acessados no link: (http://www.ipcc-data.org/sim/gcm_monthly/SRES_AR4/index.html).

Foram extraídas as seguintes variáveis dos modelos ECHAM5-OM e HadGEM2-ES: PAt ao nível do mar, UR no nível de 850hPa (ur_850), e as componentes zonal (u_sup)

e meridional do vento a superfície (v_{sup}), para os respectivos pontos de grade mais próximos de cada uma das 23 estações meteorológicas.

O período em comum entre observações e saídas dos modelos, janeiro de 2001 a dezembro de 2012, foi usado para um refinamento estatístico que permita trazer as estimativas dos modelos para o mesmo nível local das observações.

Para exemplificar esta metodologia, consideremos que $ur_{850}(t)$ é a série temporal das previsões de uma caixa de grade do modelo ECHAM5-OM da UR no nível de 850 hPa e $ur_{obs}(t)$ é a série temporal da UR observada em determinada estação, localizada dentro desta mesma caixa de grade. O erro da previsão da umidade relativa será definido como:

$$\Delta UR_t = UR_{850_t} - UR_{obs_t} \quad \text{Equação (23)}$$

Neste caso, para cada $t = 1, 2, 3, \dots, N$, uma série de diferenças é obtida, permitindo uma correção, para cada mês, de um erro médio obtido, ou viés (BIAS), dado por:

$$BIAS = \frac{1}{N} \sum_{i=1}^N \Delta UR_t \quad \text{Equação (24)}$$

onde N é o número total de previsões corrigidas em relação às observações, para cada mês.

Os valores modelados em cada mês para a variável são corrigidos pela compensação das médias das diferenças com as observações em cada mês. A nova série modelada para um ponto de estação corresponde agora com mais fidedignidade aos valores observados no período de validação, e este viés de correção é aplicado então a todo o restante da série de UR do modelo, até o ano de 2080. A mesma metodologia é aplicada as séries de PAt ao nível médio do mar. Como os modelos não estimam diretamente a velocidade média do vento a superfície, mas sim suas componentes zonal e meridional, a velocidade média é estimada pela equação (39), e em seguida a mesma metodologia de redução das diferenças pelo BIAS é aplicada.

$$V_{sup} = (u_{sup}^{-2} + v_{sup}^{-2})^{0.5} \quad \text{Equação (25)}$$

Por fim, têm-se os valores mensais modelados destas variáveis para o período 2001 a 2080. Desta forma, para o cálculo dos cenários futuros da ETP para 2020-2080, assume-se que para estas variáveis, os três decêndios terão o valor mensal, que é uma aproximação bastante razoável para três variáveis de natureza contínua.

A última variável necessária ao cálculo da ETP e que não possui nenhum tipo de saída de MCG é a insolação. Neste caso, de posse dos dados acumulados decendialmente para TMax e TMin, e conseqüentemente TMed, e agora de posse de estimativas decendiais da Pat, UR e VMV, pode-se criar séries de insolação utilizando a técnica *MICE* explicada no item 3.3. Para tanto, as observações do período 1961-2000 de cada estação são agregadas aos valores modelados a partir de 2001, restando apenas à insolação como dado faltante a ser gerado, pela relação direta com as demais variáveis. O reconhecimento de padrões associados a estas médias relativas ao período de 1961 a 2000 são essenciais para a estimativa dos valores decendiais.

Para o processo de validação deste procedimento, como o objetivo final é o cálculo da ETP, calcular-se-á o coeficiente de correlação (r) e a raiz do erro quadrático médio (REQM) dado pela equação (40), entre a ETP observada e estimada no período de validação desta metodologia, entre 2001-2012. O coeficiente de correlação já foi explicado na seção anterior, o RMSE mede a magnitude média dos erros da previsão, sua pontuação varia entre $[0, \infty)$ e é dado por:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (p_i - o_i)^2} \quad \text{Equação (26)}$$

em que N é o número total de elementos da amostra, p =previsões e o =observações em cada momento i .

4. RESULTADOS E DISCUSSÕES

4.1 - TRATAMENTO ESTATÍSTICO DOS DADOS: PREENCHIMENTO DE FALHAS

Um grave problema identificado em relação aos dados observados, em todas as variáveis, foi a grande quantidade de valores faltantes. Nesta seção serão mostrados os resultados obtidos para as variáveis: precipitação, temperatura média, pressão atmosférica, umidade relativa, velocidade média do vento e insolação, usando a técnica estatística para preenchimento de falhas *MICE*. e discussões.

Esta técnica foi utilizada nas 23 estações meteorológicas do INMET onde coincidiu haver dados de produtividade para o algodão herbáceo disponibilizados pelo IBGE, na região Nordeste. Estas estações tiveram todas as suas falhas, de 1961 a 2012, preenchidas. Após a imputação dos dados faltantes, foram identificadas nas séries originais ao menos 05 anos com dados medidos sem falhas na série original, e então falhas foram geradas artificialmente para estes anos e o método foi novamente empregado, a fim de comparar dados realmente observados com a imputação gerada. As medidas estatísticas usadas para avaliar a destreza do método foram o coeficiente de correlação (r) e a raiz do erro quadrático médio (REQM).

O período de 1961 a 2012 compreende um total de 18993 registros, para cada variável, por estação. A Tabela 8 mostra a porcentagem total de dados faltantes entre 1961 e 2012 para as variáveis analisadas. Este percentual é muito elevado em cada estação, o que poderia comprometer consideravelmente os resultados da pesquisa. A estação que apresentou o maior número de falhas em relação ao número total de registros foi Água Branca (AL), com 54,3% do total de dados faltantes, enquanto Morada Nova (CE) apresentou o menor percentual, 17,7%. Em relação a uma variável específica, o recorde de falhas é da umidade relativa: Correntina (BA) apresentou 64,1% dos dados faltantes, enquanto o menor percentual foi da precipitação observada em Morada Nova (CE), 13,9% de dados faltantes.

Tabela 8. Percentual de dados faltantes, por variável e por estação. Destacados em cinza os percentuais acima de 50%.

Estação	Prec (mm)	Tmed (°C)	UR (%)	PAt (hPa)	VMV(m/s)	Insol (horas)
	% de Falhas					
Água Branca (AL)	51,7	56,5	57,3	54,5	53,7	52,2
Paulistana (PI)	48,2	56,3	55,4	55,6	55,3	48,4
Balsas (MA)	33,9	45,4	43,8	40,2	41,8	36,6
Apodi (RN)	30,2	45,2	42,5	39,9	31,6	31,7
Patos (PB)	49,5	54,1	54,1	52,6	49,6	49,6
Monteiro (PB)	27,1	28,3	28,2	27,3	27,2	27,2
Ouricuri (PI)	48,3	59,0	62,2	54,1	48,4	48,4
Crateús (CE)	28,9	39,2	36,0	34,4	29,3	29,3
Iguatu (CE)	27,6	36,6	36,2	35,1	38,3	29,1
Jaguaruana (CE)	41,2	52,8	49,6	48,4	41,3	41,8
Morada Nova (CE)	13,9	23,9	20,9	16,5	15,6	15,6
Quixeramobim (CE)	24,1	37,9	30,6	29,4	24,3	24,3
Sobral (CE)	24,2	38,9	36,1	34,0	24,3	24,3
Tauá (CE)	33,3	48,0	41,6	40,3	33,4	33,4
Barra (BA)	47,0	50,4	47,4	48,8	47,7	47,5
Barreiras (BA)	19,6	26,6	32,1	32,5	19,6	36,5
B. J. da Lapa (BA)	36,4	37,4	37,0	36,1	36,9	38,7
Caetitê (BA)	22,1	30,8	22,0	24,2	31,0	23,8
Carinhanha (BA)	48,9	50,0	54,5	50,1	51,0	49
Correntina (BA)	50,5	55,1	64,1	51,1	53,4	51,7
Lençóis (BA)	22,9	33,5	29,4	28,9	23,3	40,9
S. do Bonfim (BA)	48,8	54,6	53,3	49,8	48,8	49,3
V. da Conquista (BA)	46,2	53,7	46,2	46,0	48,7	47,2

Como as falhas podem ocorrer em qualquer parte dos dados, o algoritmo de imputação atribui a uma coluna de dados incompletos valores sintéticos “plausíveis” de acordo com as demais colunas dos preditores, onde cada dado desta coluna quando coincide com a falha a ser tratada, tem seu próprio conjunto de equações baseadas em indicadores específicos. Desta forma, o método “conserva” os dados originais no arquivo de saída mesmo levando-os em consideração na geração de dados sintéticos.

Depois de processada a técnica e dos valores faltantes serem preenchidos, a metodologia foi repetida para validação, onde cinco anos de dados observados foram escolhidos e tiveram seus valores retirados, a fim de serem novamente imputados para posterior comparação. Para concordar com a resolução temporal dos dados usados no

modelo agrometeorológico, que é de 10 dias (chuva acumulada em 10 dias e a média das demais variáveis em 10 dias), serão mostrados os valores obtidos para r e para o RMSE para as variáveis agregadas a cada 10 dias. Na Tabela 9 são mostrados os valores destes parâmetros estatísticos para as variáveis TMed, UR, PAt e VMV.

Observa-se na Tabela 9, os altos valores de r , principalmente para a TMed, UR e PAt, que evidenciam o grau de destreza entre os dados observados e preenchidos, com a maior parte das estações apresentando valores de r maiores do que 0,60 (destacados em cinza na tabela, que correspondem a valores considerados moderados). Para o tamanho da amostra, ou seja, $N=180$ decêndios em cinco anos de validação, o teste de significância estatística aponta como valor de correlação crítica: $r_c=0,29$. Qualquer valor de r acima de 0,29 é estatisticamente significativo ao nível de 99% de confiança.

Os menores valores de r ocorrem para a VMV em 10 dias, com duas estações não apresentando significância estatística, Barreiras e Lençóis, na Bahia. Analisando o parâmetro REQM, observa-se que, para a magnitude dos valores das variáveis, os menores erros entre preenchimento e observações ocorrem para a TMed, VMV e PAt, e os maiores para a UR. De acordo com estas análises os valores de r e do REQM das estações mostram que o método de preenchimento é eficaz e gera valores confiáveis, permitindo aceitar seus resultados, que são coerentes para cada variável, complementando desta forma as falhas nas séries.

Tabela 9. Valores de r e do RMSE para as variáveis TMed, UR, Pat e VMV, para cada estação, validos para um intervalo de 10 dias de acumulação entre valores observados e imputados. Valores de r acima de 0,60 estão destacados em cinza.

Estação	TMed (°C)		UR (%)		PAt (hPa)		VMV (m/s)	
	r	REQM	r	REQM	r	REQM	r	REQM
Água Branca (AL)	0,88*	0,82	0,74*	7,13	0,85*	1,16	0,49*	0,83
Paulistana (PI)	0,76*	1,04	0,84*	7,76	0,80*	1,32	0,88*	0,61
Balsas (MA)	0,68*	0,89	0,78*	10,78	0,88*	0,61	0,51*	0,49
Apodi (RN)	0,81*	0,78	0,80*	8,14	0,76*	2,70	0,46*	1,29
Patos (PB)	0,76*	1,04	0,76*	8,28	0,79*	1,82	0,79*	0,74
Monteiro (PB)	0,87*	0,85	0,76*	8,47	0,90*	0,75	0,62*	0,80
Ouricuri (PI)	0,85*	1,06	0,86*	7,69	0,74*	1,43	0,76*	0,74
Crateús (CE)	0,88*	0,84	0,85*	7,67	0,67*	1,45	0,65*	0,89
Iguatu (CE)	0,88*	0,77	0,79*	8,91	0,75*	1,46	0,71*	0,83
Jaguaruana (CE)	0,60*	1,36	0,90*	4,59	0,93*	0,91	0,70*	1,02
Morada Nova (CE)	0,89*	0,70	0,87*	7,58	0,84*	0,90	0,71*	0,86
Quixeramobim (CE)	0,89*	0,83	0,83*	8,11	0,63*	2,01	0,60*	1,35

Sobral (CE)	0,78*	0,63	0,82*	7,78	0,63*	1,69	0,38*	1,40
Tauá (CE)	0,60*	1,52	0,74*	10,11	0,54*	1,83	0,57*	0,97
Barra (BA)	0,45*	1,53	0,83*	7,63	0,93*	0,77	0,49*	0,75
Barreiras (BA)	0,82*	1,14	0,76*	8,98	0,49*	3,14	0,24	0,71
B. J. da Lapa (BA)	0,76*	1,12	0,54*	12,08	0,94*	0,75	0,40*	0,67
Caetití (BA)	0,89*	0,80	0,76*	8,26	0,77*	1,47	0,53*	0,95
Carinhanha (BA)	0,87*	0,92	0,76*	11,49	0,66*	2,45	0,53*	0,50
Correntina (BA)	0,85*	0,96	0,84*	10,44	0,49*	4,44	0,57*	0,53
Lençóis (BA)	0,89*	0,78	0,59*	7,20	0,79*	1,63	0,24	0,65
S. do Bonfim (BA)	0,89*	1,00	0,73*	8,20	0,88*	1,16	0,65*	0,79
V. da Conquista (BA)	0,94*	0,75	0,57*	6,95	0,74*	2,34	0,46*	0,56

*Valores estatisticamente significantes ao nível de 99% de confiança.

Por terem passado por um processo de preenchimento de falhas diferente com relação aos preditores, os resultados da validação da técnica de preenchimento para a PREC e para a INS são mostrados na Tabela 9. A diferença da PREC foi o espaçamento de grade dos preditores usados, provenientes da análise gradeada do CPC com resolução de $0,5^\circ \times 0,5^\circ$, mais refinada que para as demais variáveis, cujos preditores foram oriundos de uma análise gradeada do NCEP/NCAR de $1,0^\circ \times 1,0^\circ$. Para a INS, a diferença é que foram usados como preditores os valores das demais variáveis já preenchidas.

Para os resultados apresentados na Tabela 10, uma importante observação é a correlação obtida em todas as estações da comparação entre dados observados e preenchidos, todas maiores que 0,6. A PREC é, entre as variáveis, uma das mais importantes para a simulação de produtividade em um modelo agrometeorológico. Para a INS, os valores de r foram mais baixos, e significativos estatisticamente para a quase totalidade das estações, com exceção de Paulistana, no Piauí, que apresentou valor de r igual a 0,16, e Agua Branca, com r igual a 0,27, menores que o r_c considerado para significância estatística. Os valores do RMSE ficaram dentro do esperado para as variáveis.

Tabela 10. Valores de r e do REQM para as variáveis PREC e INS, validos para um intervalo de 10 dias de acumulação entre valores observados e imputados. Valores de r acima de 0,60 estão destacados em cinza.

Estação	PREC (mm)		INS (horas)	
	r	REQM	r	REQM
Água Branca (AL)	0,66*	27,5	0,27	1,47
Paulistana (PI)	0,78*	20,0	0,16	3,12
Balsas (MA)	0,65*	36,5	0,57*	1,57
Apodi (RN)	0,68*	22,6	0,67*	1,40
Patos (PB)	0,75*	33,2	0,49*	2,56

Monteiro (PB)	0,66*	23,3	0,81*	1,31
Ouricuri (PI)	0,73*	29,3	0,76*	1,47
Crateús (CE)	0,93*	14,6	0,43*	2,36
Iguatu (CE)	0,76*	27,5	0,41*	1,73
Jaguaruana (CE)	0,81*	21,9	0,37*	2,88
Morada Nova (CE)	0,62*	27,0	0,65*	1,32
Quixeramobim (CE)	0,89*	11,8	0,60*	1,32
Sobral (CE)	0,89*	18,5	0,66*	1,42
Tauá (CE)	0,80*	19,5	0,72*	1,16
Barra (BA)	0,83*	17,8	0,76*	1,26
Barreiras (BA)	0,84*	21,4	0,64*	1,39
B. J. da Lapa (BA)	0,93*	14,1	0,66*	1,65
Caetité (BA)	0,84*	20,0	0,87*	1,33
Carinhanha (BA)	0,82*	25,7	0,30*	1,82
Correntina (BA)	0,86*	22,5	0,50*	1,60
Lençóis (BA)	0,78*	30,4	0,60*	1,27
S. do Bonfim (BA)	0,63*	22,9	0,45*	1,56
V. da Conquista (BA)	0,88*	15,9	0,48*	1,93

*Valores estatisticamente significantes ao nível de 99% de confiança.

O uso adequado da técnica estatística MICE mostrou-se bastante eficiente no preenchimento de falhas em series temporais de dados diários de variáveis meteorológicas, mesmo no caso de longos períodos de dados faltantes, apresentando elevados valores dos coeficientes de correlação na grande maioria das estações, assim como de elevada significância estatística.

4.2 - TRATAMENTO ESTATÍSTICO DOS DADOS: CONTROLE DE QUALIDADE

Após a correção do primeiro problema, o preenchimento de falhas dos faltantes, um segundo problema precisou ser avaliado, os valores suspeitos, exigindo para tal um controle de qualidade, para que enfim seja possível trabalhar com series completas e de alta confiabilidade. Nesta seção serão mostrados alguns resultados referentes a um SCQ baseado em uma série de testes, denominados Grupos de Testes, os quais obedecem a um fluxograma, como foi mostrado na Figura 3. Os resultados de alguns testes são mostrados para a estação de Sobral (CE). Esta estação teve os dados diários analisados de 1961 a 2012, onde a porcentagem de falhas preenchidas foi de aproximadamente 30% do total de dados diários.

O grupo de testes de limites fixos é utilizado para as temperaturas, precipitação, umidade relativa e a insolação. O teste consiste em estabelecer limites fixos para cada variável, um limite inferior e superior para valores aceitáveis. O resultado deste teste dependerá do rigor imposto por quem está aplicando o SCQ, assim como pelo grau de conhecimento sobre a estação que está sendo trabalhada. Em Sobral, entre 1961 e 2012, o menor valor de temperatura mínima observada e o maior valor de temperatura máxima observada foram, respectivamente, 17,1°C e 39,8°C. Estes foram os limites escolhidos para verificar se havia nos registros valores inferiores ou superiores a estes para as temperaturas mínimas, máximas e médias. O resultado mostrou não haver problemas de valores além destes limites, em todo o período 1961-2012. Para outras variáveis foram detectados erros. A Tabela 11 mostra dois valores suspeitos encontrados para a PAt, com limites fixos entre 994,1 e 1009,5 hPa, e a INS, com limites fixos entre 0 e 12 horas.

Tabela 11. Registros de valores suspeitos encontrados pelo SCQ relativo ao Teste de Limites Fixos, para PAt (em hPa) e INS (em horas/dia).

Ano	Mês	Dia	Pressão
			Atmosférica (hPa)
1979	1	5	987,9
2002	6	23	971
Ano	Mês	Dia	Insolação (horas)
1998	4	26	23,2
1998	4	28	24,8

Os testes de limites variáveis identificam resíduos “extremos” em relação a um ciclo sazonal ajustado para a variável considerada. Como limites para identificar resíduos extremos se definem dois limiares de percentis (um inferior e um superior), por exemplo, 0,01 (ou seja, o percentil 1%) e 0,99 (ou seja, o percentil 99%). Os percentis extremos podem ser calculados de duas formas, para cada mês, ou com todos os dados. Registros menores que o percentil inferior e maiores que o percentil superior são considerados extremos. Para as temperaturas médias do mês de janeiro em Sobral, por exemplo, os percentis de 1% e 99% são respectivamente os valores 23,8°C e 30,6°C. Logo, valores que ultrapassem estes limiares serão considerados extremos, e suspeitos, sendo reportados em uma saída impressa para que estes valores sejam analisados, como exemplifica a Tabela 12.

Tabela 12. Exemplos de valores suspeitos de temperaturas médias encontrados pelo teste de limites variáveis. Em azul valor diário abaixo do percentil de 1% e em vermelho acima do percentil de 99%.

Ano	Mês	Dia	TMed (°C)
1986	1	12	23,3
2011	1	10	22,1
2011	1	20	22,9
1983	1	16	31,5
1983	1	24	31,2

A Figura 6 mostra os resultados gráficos do teste de limites variáveis, em um gráfico do tipo *box-plot*, para as variáveis umidade relativa e temperatura média, onde os pontos em vermelho fazem referencia aos valores que ultrapassaram estes limites variáveis referentes aos percentis de 1% e 99%.

Nos testes de consistência entre variáveis, a relação entre as temperaturas mínimas, médias e máximas é analisada. Este teste parte da condição de que as temperaturas mínimas não devem ser maiores que as temperaturas máximas, e também de que as temperaturas médias devem estar entre as temperaturas mínimas e máximas diárias. Os valores de temperaturas médias maiores que as temperaturas máximas e os valores de temperaturas médias menores que as temperaturas mínimas aparecem destacados em vermelho, mostrados na Figura 7.




Figura 6: Resultado do teste de limites variáveis para os percentis de 1% e 99%, para as variáveis umidade relativa e temperatura média. Pontos em vermelho indicam valores que extrapolaram os limiares.




Figura 7: Resultado do teste de consistência entre variáveis relacionando temperaturas médias, com temperaturas máximas e mínimas diárias. Os valores suspeitos de temperaturas médias são identificados por pontos em vermelho.

Os testes do SCQ apontaram dados suspeitos em todas as variáveis das estações, muitos foram corrigidos, outros verificados e aceitos. No total, 1457 registros foram corrigidos entre as 23 estações meteorológicas usadas nesta pesquisa.

4.3 - CALIBRAÇÃO E VALIDAÇÃO DO MODELO AGROMETEOROLÓGICO PARA ESTIMATIVA DA PRODUTIVIDADE DO ALGODÃO HERBÁCEO

De acordo com os dados de produtividade anual do algodão herbáceo disponibilizados pelo IBGE, entre 2001 e 2011, existe grande variabilidade entre os 23 municípios pesquisados. A produtividade média anual nestes 11 anos varia de 259 kg/ha em Água Branca (AL), até 3652 kg/ha em Bom Jesus da Lapa (BA), ambas as cidades localizadas no semi-árido nordestino. A maioria dos municípios apresenta produtividades médias inferiores a 1000 kg/ha. A Figura 8 mostra esta variação, ou seja, as produtividades médias em cada município segundo o cenário climático atual a que esta submetida a cultura.





Figura 8: Produtividade média do algodão herbáceo (Kg/ha) em cada município, entre 2001 e 2011, fornecido pelo IBGE.

Esta variabilidade reflete como dois importantes fatores influenciam a produtividade do algodão entre os municípios: o grau de vulnerabilidade ao estresse hídrico e a influência tecnológica. Por isso, foram calculados o coeficiente de rendimento máximo tecnológico (Δp) e o fator de déficit hídrico ajustado (ky^*) para cada município, durante o processo de calibração do modelo de produtividade. Estes parâmetros permitiram simular, com mais precisão, a produtividade em cada ano.

Primeiro, é obtida uma estimativa da produtividade, para cada município, sem levar em consideração o rendimento máximo tecnológico (Δp) e o fator de déficit hídrico ajustado (ky^*), pela formulação clássica proposta por DOORENBOS e KASSAM (1994), cuja penalização depende apenas da relação entre ETR_c e ETP_c . Em seguida, ao se calcular a produtividade potencial tecnológica, com a correção das tendências de rendimento ao longo do tempo, a precisão das estimativas tanto dos baixos quanto dos altos rendimentos é melhorada e podem-se aproximar os valores de perda percentual da produtividade aos valores observados pelo IBGE, calibrando o modelo e encontrando os valores de Δp e ky^* . Em alguns casos, onde o fator de estresse hídrico não se torna muito relevante, o valor de ky^* continua igual a 1.

Para exemplificar a importância destes parâmetros na simulação da produtividade, os gráficos da Figuras 9 mostram as curvas, entre 2001 e 2011, da estimativa de produtividade versus a produtividade observada nos municípios de Carinhanha (BA), antes (a) e depois (b) do processo de calibração, e em Crateús (CE), antes (c) e depois (d) do processo de calibração.






Figura 9: Produtividades observadas e simuladas do algodão herbáceo nas cidades de Carinhanha (a e b) e Crateús (c e d), antes e depois da calibração do modelo agrometeorológico.

A Tabela 13 mostra os valores da produtividade média prevista e observada, os valores do Δp e do ky^* encontrados para cada município a fim de obter a maior correlação e o menor erro absoluto possível. Analisando os valores de r , percebe-se que os ajustes impostos ao modelo para estimativa da produtividade foram bem sucedidos. Para o tamanho da amostra, ou seja, $N=11$ anos de comparações, o teste de significância

estatística aponta como valor de correlação crítica: $r_c=0,92$. Qualquer valor de r maior ou igual a 0,92 é estatisticamente significativo ao nível de 99% de confiança. Como este valor é muito alto e difícil de alcançar para apenas $N=11$ comparações, adota-se o nível de significância de 95%, cujo $r_c=0,78$. Dos 23 locais estudados, 6 apresentaram correlações estatisticamente significantes, mais da metade (13 estações) apresentaram valores de r entre 0,6 e 0,8, ou fortes correlações, e em cinco os valores de r ficaram entre 0,8 e 1,0, indicando ótimas correlações. Nenhuma estação apresentou r inferior a 0,2, duas estações apresentaram r entre 0,2 e 0,4 e por fim quatro estações apresentaram r entre 0,4 e 0,6, ou correlações moderadas.

Analisando as estações de Barra e Lençóis (BA), que apresentaram baixas correlações, entre 0,2 e 0,4, observa-se que as mesmas também apresentaram os maiores erros relativos, ano a ano, culminando em um erro médio relativo de 55,1% em Lençóis e de 32,7% em Barra. Isso significa que entre 2001 e 2011, a produtividade estimada pelo modelo apresentou diferenças significativas das observadas nestas cidades, muitas vezes em sentidos opostos, caracterizando as baixas correlações. Esses erros sistemáticos poderiam ser amenizados por meio de uma re-calibração do modelo agrometeorológico, mas, para tanto, necessitaríamos de séries de produtividades observadas bem maior do que a que se foi possível trabalhar, permitindo uma melhor análise da variabilidade inter-anual destas produtividades. Diante deste pequeno número de casos em que o modelo não se saiu bem em suas estimativas, pode-se inferir que as fontes de erros podem estar relacionadas com eventuais alterações das práticas agrícolas e de gestão, que incluem os genótipos utilizados, manejo do solo, adubação, doenças e surtos de pragas, etc. Estes são fatores não computados pelo modelo, devido à impossibilidade de examiná-los, sistematicamente, nas amplas áreas a serem consideradas. Portanto, variações imprevisíveis podem ocorrer e prejudicar o desempenho do modelo.

Em contrapartida, 16 das 23 estações apresentaram correlações superiores a 0,6. Nestes casos, foram observados os menores erros relativos entre os valores modelados e observados. Analisando os casos onde a correlação foi igual ou superior a 0,80, nas localidades de Carinhanha (BA), Crateús, Jaguaruana e Sobral (CE), o erro médio absoluto ficou em torno de ± 150 kg/ha, ou um erro médio relativo inferior a 15%, entre rendimentos estimados e observados.

Tabela 13. Produtividade média observada e simulada, erro médio absoluto (EMA) e relativo (EMR), coeficiente de produtividade máxima tecnológica (Δp), fator de déficit hídrico ajustado (ky^*), e correlação (r) entre simulações e observações. Valores de r acima de 0,60 estão destacados em cinza.

Estação	Produtividade Média Observada (Kg/ha)	Produtividade Média Simulada(Kg/ha)	EMA(Kg/ha)	EMR(%)	Δp	Ky^*	r
Água Branca (AL)	259	288	41	15,7	1,25	1,00	0,63
Apodi (RN)	664	716	76	10,4	1,27	0,58	0,68
Balsas (MA)	3292	3405	193	5,3	1,20	1,00	0,63
Barra (BA)	754	808	267	32,7	1,71	0,96	0,37
Barreiras (BA)	3548	3721	324	9,1	1,22	0,53	0,78*
B. J. da Lapa (BA)	3652	3959	582	15,9	1,32	0,53	0,69
Caetite (BA)	1528	1585	229	15	1,59	1,00	0,65
Carinhanha (BA)	2074	2024	224	10,8	1,30	0,61	0,92**
Correntina (BA)	3601	3675	270	7,5	1,18	0,42	0,57
Lencois (BA)	716	972	395	55,1	1,95	1,00	0,22
Monteiro (PB)	647	686	112	17,3	1,30	0,47	0,56
Ouricuri(PE)	661	640	41	6,2	1,23	0,46	0,75
Patos (PB)	781	750	231	29,6	1,54	1,00	0,54
S. do Bonfim (BA)	428	436	15	3,4	1,07	0,17	0,79*
V. Conquista (BA)	756	948	308	40,8	1,82	1,00	0,44
Crateus (CE)	881	783	109	12,4	1,28	0,92	0,89*
Jaguaruana (CE)	970	1015	111	11,4	1,52	1,00	0,84*
Iguatu (CE)	1448	1540	250	17,2	1,46	1,00	0,78*
Taua (CE)	746	726	190	25,5	1,54	1,00	0,63
Sobral (CE)	806	824	99	12,3	1,28	0,92	0,80*
Quixeramobim (CE)	909	900	124	13,7	1,45	0,91	0,60
Morada Nova (CE)	1099	1075	115	10,4	1,22	0,56	0,73
Paulistana (PI)	312	359	111	35,7	1,90	0,99	0,75

*Valores estatisticamente significantes ao nível de 95% de confiança; **Valores estatisticamente significantes ao nível de 99% de confiança.

Por fim, a Figura 10 mostra a produtividade média observada versus a produtividade média simulada em cada município. Vale salientar que o cálculo da produtividade para cada município é função inicialmente do cálculo da penalização por déficit hídrico, que indica o percentual de perda da produtividade em três datas estabelecidas e determinadas pelo Governo Federal para a semeadura no campo, correspondentes ao calendário agrícola. Para cada uma das três datas, é calculada a penalização, assumindo-se que, em média, 25% da produção é plantada na primeira data, 50% da produção é plantada na segunda data e 25% da produção é plantada na terceira data.




Figura 10: Produtividades médias do algodão herbáceo (kg/ha) em cada município, entre 2001 e 2011, observadas e estimadas pelo modelo agrometeorológico.

A calibração do modelo agrometeorológico permitiu estimar a produtividade do algodão, em cada uma das 23 estações entre 2001 e 2011, com boa concordância em relação as produtividades observadas pelo IBGE. A variabilidade anual, que acarretou em baixos coeficientes de correlação para algumas estações, incorre de um problema comum em qualquer tipo de modelagem, que é a capacidade de simular extremos. Desta forma, a média dos 11 anos de observações e simulações, para cada estação, mostrou a habilidade do modelo em simular os valores médios de produtividade, tanto nos municípios de produtividade muito baixa (abaixo de 750 kg/ha), nos de médias produtividades (750 a 2000 kg/ha) e nos de alta produtividade (superiores a 2000 kg/ha)

4.4 - CALIBRAÇÃO E VALIDAÇÃO DO MÉTODO DE *DOWNSCALING* ESTATÍSTICO (MDE) PARA PRECIPITACAO, TEMPERATURAS MAXIMAS E MINIMAS.

No processo de calibração e sua posterior validação, os resultados independem do MCG a ser utilizado para geração de cenários futuros, uma vez que se busca estudar a relação entre os preditores escolhidos das reanálises, com as variáveis de superfície.

O MDE estatístico usado foi o método dos análogos. No processo de calibração, o desejável é que o MDE empregado gere valores determinísticos que comprovem sua habilidade em explicar a variabilidade do preditando. Além disso, devido a não estacionariedade do clima, é importante verificar a capacidade do MDE em simular/prever as variáveis para um período independente. Na calibração do MDE foram usados 75% dos dados, entre 1961 e 2000. Desta forma, a relação preditor-preditando foi considerada para os 25% dos dados restantes, ou seja, para 1991-2000. As séries sintéticas de precipitação, temperaturas máximas e mínimas geradas para este período foram analisadas diariamente e agregadas a cada 10 dias, e comparadas às observações.

A validação tem seu alicerce em medidas estatísticas específicas: descritivas (taxa de precipitação, média e desvio padrão para precipitação e temperaturas); medidas de precisão (taxas de acerto e de alarme falso para precipitação, e coeficiente de correlação para precipitação e temperaturas); medidas de similaridade (razão das variâncias, PDFscore e Q-Q Plot para precipitação e temperaturas).

Para a precipitação foram usados como preditores as variáveis pressão ao nível médio do mar, umidade específica no nível de 850 hPa, a altura geopotencial no nível de 500 hPa, a temperatura em 850 hPa, e as componentes zonal e meridional do vento no nível de 850 hPa. Tais variáveis são provenientes das reanálises do projeto ERA40, no período 1961-2000.

A Tabela 14 mostra, para a precipitação observada e prevista diária, os valores da Taxa de Precipitação (TP-Obs e TP-Prev), Médias (Média-Obs e Média-Prev), Desvio padrão (σ -Obs e σ -Prev), Taxa de Acertos (TA), Taxa de Alarmes Falsos (TAF) e Razão das Variâncias (RV). Os parâmetros estatísticos obtidos mostram que existe alta concordância entre os valores diários observados e previstos da TP, que é a razão entre número de dias de chuva em relação ao número de dias do período e da Média diária de

precipitação. Os desvios padrões das duas amostras também apresentaram valores bem próximos, resultando em valores de RV muito próximos a 1, valor perfeito para este parâmetro que serve para medir o grau de homogeneidade entre as distribuições de duas populações, neste caso os dados observados e previstos. Os valores de TA variaram de 0,27 em Monteiro a 0,51 em Sobral, ou seja, em Monteiro 27% das previsões de ocorrência de chuva realmente ocorreram, enquanto em Sobral o índice de acerto das previsões foi de 51%. Para esta medida de destreza, quanto mais próximo de 1 (100%), melhor o índice. Os valores de TAF variaram de 0,11 em Barra e Carinhanha, até 0,36 em Lençóis, ou seja, em Barra e Carinhanha apenas 11% das previsões de ocorrência de chuvas não aconteceram, enquanto em Lençóis, 36% das previsões de chuva não ocorreram.

Dada a dificuldade em se prever a ocorrência da precipitação em nível diário, pode-se considerar que o método dos análogos gerou resultados satisfatórios para o período de validação, principalmente observando-se a concordância entre os valores da taxa de precipitação, média e desvio padrão da distribuição de chuvas previstas em relação às observações. Dentre os índices, o que apresentou o menor desempenho foi TA, mas isto pode ser explicado pelo limite de chuva diário considerado para o cálculo dos índices, iguais ou maiores que 0,1mm. Testes mostraram que quando este limite é estabelecido, por exemplo, para ocorrências maiores ou iguais a 1mm, existe forte tendência de melhora da taxa de acerto da precipitação diária.

Tabela 14. Taxa de precipitação observada e prevista (TP-Obs) e (TP-Prev), médias observadas e previstas (Média-Obs) e (Média-Prev), desvio padrão observado e previsto (σ -Obs) e (σ -Prev), taxas de acerto e de alarmes falsos (TA) e (TAF), e razão das variancias (RV). Medias estatísticas obtidas para dados diários de precipitação no período 1991-2000.

Estação	TP-Obs(mm)	TP-Prev(mm)	Média-Obs(mm)	Média-Prev(mm)	σ -Obs	σ -Prev	TA	TAF	RV
Sobral	27,3	27,1	2,6	2,3	7,8	7,1	0,51	0,18	0,83
Crateús	25,0	23,8	2,3	2,0	8,0	7,0	0,42	0,18	0,78
Quixeramobim	27,1	26,7	2,2	2,0	7,3	6,6	0,42	0,21	0,82
Tauá	21,7	20,1	1,7	1,4	6,9	6,2	0,36	0,16	0,81
Iguatú	25,4	24,7	2,8	2,5	9,5	8,8	0,41	0,19	0,87
Jaguaruana	24,3	24,1	2,3	2,3	8,2	8,0	0,41	0,19	0,97
Morada Nova	23,9	24,1	2,2	1,9	7,6	6,8	0,45	0,18	0,81
Apodi	22,3	22,3	2,1	2,0	7,6	7,3	0,40	0,17	0,91
Patos	19,8	19,0	1,9	1,7	7,4	6,8	0,32	0,16	0,83
Monteiro	18,4	18,1	1,7	1,7	7,2	6,8	0,27	0,16	0,90
Ouricuri	22,0	20,5	1,6	1,4	6,3	5,7	0,30	0,18	0,81

Paulistana	18,6	17,8	1,8	1,7	7,0	7,2	0,30	0,15	1,03
Água Branca	35,9	36,1	2,9	2,9	8,1	8,3	0,42	0,33	1,04
S. do Bonfim	34,4	33,0	2,5	2,4	8,2	8,0	0,47	0,26	0,95
Balsas	26,0	23,5	2,9	2,5	9,2	8,8	0,38	0,18	0,90
Barra	17,3	16,2	2,0	1,8	8,2	7,5	0,40	0,11	0,84
Barreiras	27,0	25,6	3,0	2,8	9,7	9,7	0,48	0,17	1,00
Correntina	21,2	20,6	2,8	2,5	9,3	8,8	0,49	0,13	0,91
B. J. da Lapa	20,0	18,6	2,4	2,2	8,6	8,6	0,42	0,13	0,99
Carinhanha	18,0	16,7	2,4	2,2	8,8	8,7	0,42	0,11	0,99
Lençóis	42,7	41,5	3,6	3,4	11,0	10,4	0,49	0,36	0,90
Caetite	25,8	25,7	2,4	2,3	7,9	7,6	0,42	0,20	0,92
V. da Conquista	31,6	31,2	2,3	2,1	7,5	6,9	0,42	0,26	0,83


A Figura 11 mostra para a precipitação, agora agregada de 10 dias, três gráficos para cada estação com diferentes parâmetros estatísticos calculados. O gráfico à esquerda mostra a função densidade de probabilidade (FDP) dos dados observados e previstos, a fim de analisar a similaridade das distribuições e inferir sobre a qualidade das previsões. Dentro do gráfico há o valor do PDFscore calculado, que serve para medir justamente o grau de superposição entre funções de densidade de probabilidade empíricas observadas e previstas, e quanto mais próximo de 1 mais bem ajustadas são as funções. No centro, há um diagrama de dispersão entre valores previstos e observados, em seu interior pode-se observar o valor de r . À direita, um gráfico Q-Q plot dos percentis previstos e observados que sugere o grau de normalidade dos percentis estimados. Se a configuração dos pontos no gráfico se aproxima de uma reta a suposição de normalidade é sustentável, podendo ser colocada sob suspeita se a maior parte dos pontos se desviarem do comportamento linear.


Em todos os gráficos da Figura 11 percebe-se a concordância entre as FDPs das previsões e observações, tanto pelo comportamento das curvas quanto pelos valores calculados do PDFscore, cujo valor mais baixo foi 0,79 em Jaguaruana e Sobral, e o mais alto 0,95, em Paulistana, Ouricuri, Iguatu, Carinhanha e Balsas. Vale ressaltar que no período de calibração, Jaguaruana e Sobral apresentaram os maiores desvios médios mensais pelos modelos em relação às médias observadas. Dos diagramas de dispersão, pode-se observar que a maior parte dos valores acumulados situa-se numa faixa de até 100mm. A habilidade de prever melhor ou não os extremos reflete significativamente nos valores de r , mesmo que os demais gráficos e medidas indiquem confiança para se usar os dados previstos. Neste período de validação (1991-2000), agregados de 10 dias correspondem a 360 decêndios. Para este tamanho $n=360$, as correlações apresentam


significância estatística ao nível de 99% de confiança se forem maiores que 0,21. Das 23 estações, em 15 os valores de r foram superiores a 0,50, com 4 delas apresentando r acima de 0,70. Em apenas 5 estações, os valores de r foram abaixo de 0,40, em Agua Branca ($r = 0,32$), Lençóis ($r = 0,38$), Monteiro e Vitória da Conquista ($r = 0,39$) e Balsas ($r=0,34$), mesmo assim, superiores ao valor limite de 0,29, podendo-se afirmar que todas as previsões apresentam significância estatística em relação as observações.


Os gráficos Q-Q plot de todas as estações mostram que os percentis empíricos calculados para as observações e previsões geram retas muito próximas da reta diagonal que indica uma distribuição quantílica perfeita. Em muitos casos, os valores extremos aparecem destacados e devido a ineficácia de suas previsões, ditam o desvio das retas empíricas, mas sem colocar sob suspeita a hipótese de normalidade das distribuições dos percentis calculados.


Constata-se que através dos parâmetros estatísticos mostrados na Tabela 14 e dos gráficos da Figura 11, para todas as estações, que o método dos análogos representa bem a distribuição diária da precipitação e principalmente, da precipitação agregada em 10 dias, gerando confiabilidade para o uso dos cenários futuros por cada um dos modelos, quando serão finalmente usados para o cálculo das estimativas de produtividade do algodão herbáceo para o horizonte 2021-2080.














Figura 11: Para cada estação, funções densidade de probabilidade e valores do PDFscore à esquerda, diagramas de dispersão e valores de r no centro, e distribuições Q-Q plot a direita, para as precipitações observadas e previstas acumuladas (mm) em 10 dias para o período 1991-2000.

Para as temperaturas máximas e mínimas, foram usadas como preditores as mesmas variáveis da precipitação, com exceção das componentes zonal e meridional do vento. Diferentes da precipitação são mostrados nas Tabelas 15 e 16 apenas as médias observadas e previstas, os desvios padrões e a correlação para 10 dias de valores agregados. Como pode ser observado pelos valores de r , os resultados oriundos do método dos análogos para o período de validação mostrou um maior potencial preditivo para estas variáveis. As Figuras 12 e 13 mostram para temperaturas máximas e mínimas, a título de exemplo para duas estações, as quais apresentaram os maiores valores de correlação entre simulações e observações, as funções densidade de probabilidade e valores do PDFscore à esquerda, diagramas de dispersão e valores de r no centro, e distribuições Q-Q plot a direita, para as temperaturas observadas e previstas agregadas em 10 dias para o período 1991-2000.

Tabela 15. Médias observadas e previstas (Média-Obs) e (Média-Prev), desvio padrão observado e previsto (σ -Obs) e (σ -Prev), e correlações (r), para temperaturas máximas agregadas em 10dias. Valores de r acima de 0,6 estão destacados em cinza.

Estação	Média-Obs (°C)	Média-Prev (°C)	σ -Obs	σ -Prev	r
Sobral	33,8	33,6	2,1	1,7	0,75*
Crateús	32,9	32,9	2,0	1,5	0,77*
Quixeramobim	32,8	32,7	1,9	1,4	0,73*
Tauá	32,1	32,0	1,7	1,3	0,70*
Iguatú	32,8	32,7	2,0	1,5	0,71*
Jaguaruana	33,0	33,0	1,3	1,0	0,62*
Morada Nova	34,0	33,8	1,9	1,5	0,69*
Apodi	34,0	33,9	1,8	1,4	0,68*
Patos	33,5	33,4	1,6	1,2	0,74*

Monteiro	30,7	30,7	2,0	1,6	0,80*
Ouricuri	31,4	31,3	1,9	1,5	0,68*
Balsas	32,0	32,0	1,7	1,5	0,75*
Paulistana	32,4	32,2	1,7	1,3	0,63*
Água Branca	28,3	28,3	2,5	2,3	0,81*
S. do Bonfim	29,2	29,1	2,1	1,8	0,81*
Barra	32,5	32,5	1,4	1,0	0,52*
Barreiras	32,1	32,1	1,9	1,4	0,72*
Correntina	30,8	30,8	1,6	1,2	0,37*
B. J. da Lapa	32,1	32,0	1,8	1,3	0,60*
Carinhanha	31,7	31,7	1,7	1,3	0,62*
Lençóis	29,0	28,8	2,0	1,5	0,65*
Caetité	27,1	27,0	1,9	1,3	0,39*
V. da Conquista	25,6	25,6	2,0	1,8	0,80*

*Valores estatisticamente significantes ao nível de 99% de confiança.

Tabela 16. Médias observadas e previstas (Média-Obs) e (Média-Prev), desvio padrão observado e previsto (σ -Obs) e (σ -Prev), e correlações (r), para temperaturas mínimas agregadas em 10dias. Valores de r acima de 0,6 estão destacados em cinza.

Estação	Média-Obs (°C)	Média-Prev (°C)	σ-Obs	σ-Prev	r
Sobral	22,2	22,3	1,1	0,7	0,46*
Crateús	21,7	21,7	1,3	1,0	0,61*
Quixeramobim	22,8	22,7	1,0	0,8	0,66*
Tauá	21,3	21,3	1,5	1,1	0,62*
Iguatú	22,1	22,0	1,1	0,9	0,55*
Jaguaruana	22,7	22,6	1,0	0,9	0,69*
Morada Nova	22,3	22,2	1,1	0,9	0,63*
Apodi	23,1	23,0	1,2	0,8	0,46*
Patos	21,7	21,7	1,2	0,9	0,68*
Monteiro	18,2	18,1	1,9	1,7	0,78*
Ouricuri	20,6	20,5	1,4	1,2	0,69*
Balsas	21,6	21,5	1,1	1,0	0,50*
Paulistana	21,5	21,3	1,3	1,0	0,55*
Água Branca	19,0	19,0	1,1	1,0	0,75*
S. do Bonfim	19,6	19,5	1,2	1,1	0,81*
Barra	19,5	19,4	1,7	1,4	0,69*
Barreiras	18,4	18,3	2,5	2,1	0,81*
Correntina	18,0	17,8	2,4	2,2	0,77*
B. J. da Lapa	19,2	19,1	1,8	1,6	0,76*
Carinhanha	19,3	19,1	2,1	1,9	0,77*
Lençóis	19,5	19,5	1,5	1,3	0,73*
Caetité	16,6	16,7	1,9	1,4	0,72*
V. da Conquista	16,1	16,1	1,6	1,4	0,84*

*Valores estatisticamente significantes ao nível de 99% de confiança.




Figura 12: Mesmo que a Figura 11, mas para as temperaturas máximas observadas e previstas agregadas em 10 dias para o período 1991-2000, para as estações de Água Branca (AL) e Monteiro (PB).




Figura 13: Mesmo que a Figura 12, mas para as temperaturas mínimas observadas e previstas agregadas em 10 dias para o período 1991-2000, para as estações de Senhor do Bonfim (BA) e Vitória da Conquista (BA).

4.5 - DOWNSCALING ESTATÍSTICO DA PRECIPITAÇÃO, TEMPERATURAS MÁXIMAS E MÍNIMAS DIÁRIAS

Após a seleção dos preditores, os quais devem ser variáveis de grande escala que tenham conceitualmente ligação física com as variáveis de superfície, ou seja, forçantes físicas robustas que imponham respostas ao clima local, pode-se verificar o desempenho dos modelos em simular o clima para um período de referência, que deve coincidir com o período de calibração do MDE: 1961-1990.


4.5.1 - RESULTADO DOS MODELOS PARA O PERÍODO DE CALIBRAÇÃO

Nesta seção são avaliados os resultados obtidos para o período de calibração, ou de referência (1961-1990), com os modelos HadGEM2-ES e ECHAM5-OM, usando o método dos análogos, tanto para a precipitação quanto para as temperaturas máximas e mínimas diárias.

É importante verificar a capacidade dos modelos usados em simular o comportamento climatológico das variáveis. Foram calculadas, a partir dos dados diários gerados pelos modelos, as respectivas médias mensais para os 30 anos do período de calibração, permitindo compará-las com as médias climatológicas das observações.

Para a precipitação, os gráficos da Figura 14 mostram, para as 23 estações analisadas, que a normal climatológica observada versus as médias climatológicas mensais obtidas com os modelos são bastante coincidentes, o que reflete a habilidade dos dois modelos em caracterizar os meses secos e chuvosos. Com relação aos valores médios obtidos pelos modelos, principalmente para as estações localizadas mais ao norte da região Nordeste, pertencentes aos Estados do Ceará, Paraíba, Maranhão, Rio Grande do Norte e Pernambuco, os dois modelos subestimaram a precipitação dos meses mais chuvosos, notadamente março e abril. Para estas localidades, este viés seco concorda com os resultados obtidos por ALVES *et al*, 2005, que em seu estudo mostraram que a versão ECHAM4.5 subestimava a precipitação da quadra chuvosa do norte da região Nordeste: fevereiro a maio, o mesmo ocorrendo, em maior magnitude, com o modelo HadGEM2-ES. Nas estações localizadas na Bahia e Alagoas, os modelos também subestimaram a precipitação dos meses mais chuvosos, entre outubro e dezembro, em menor grau, e superestimaram entre janeiro e março, praticamente compensando o déficit do período

anterior. Os meses secos, de modo geral, foram melhor caracterizados pelos modelos, com valores médios simulados muito próximos dos observados.






Figura 14: Climatologia da precipitação do período 1961-1990, com dados observados (linha azul), modelos ECHAM5-OM (linha vermelha) e HadGEM2-ES (linha verde), para as 23 estações.

A Figura 15a mostra a média anual da precipitação observada no período 1961-1990 com as médias anuais simuladas pelos modelos no mesmo período, onde nota-se que os modelos simularam, na maioria das estações, menos chuva do que a observada no período. A Figura 15b mostra apenas estas diferenças nas médias anuais em cada estação, evidenciando que o modelo ECHAM5-OM subestimou menos a precipitação do que o modelo HadGEM2-ES, apresentando desta forma, melhores resultados em relação as observações, apesar da maior diferença ter sido observada pela estimativa deste modelo na estação de Sobral, no Ceará. Como já comentado, a falta de destreza em simular bem os eventos associados a ZCIT de fevereiro a maio acarretaram em desvios anuais mais pronunciados nas estações localizadas ao norte da região Nordeste.




Figura 15: (a) Médias anuais 1961-1990 da precipitação (mm) obtidas das observações (linha azul), ECHAM5-OM (linha vermelha) e HadGEM2-ES (linha verde), e (b) Diferenças médias anuais entre os modelos e observação.

Para as temperaturas máximas, a Figura 16 mostra, a título de exemplo, a normal climatológica observada versus as medias climatológicas mensais obtidas com os modelos para quatro estações, que, assim como para a precipitação, foram coincidentes, refletindo a habilidade dos modelos em simular bem a temperatura máxima a superfície. A Figura 17a mostra a comparação das médias anuais e a Figura 17b mostra os respectivos desvios, para cada uma das 24 estações. Como se pode observar, os modelos apresentaram leve tendência de superestimar as temperaturas máximas, com destaque para o modelo HadGEM2-ES. No entanto, os desvios médios anuais não chagam a ultrapassar 0,4°C em relação a média observada. Este fator deve estar diretamente associado a escassez da chuva simulada principalmente entre fevereiro e maio, acarretando em menor nebulosidade

gerada pelo modelo e maior incidência de radiação a superfície, retendo energia próxima a superfície e aumentando a temperatura.

O mesmo acontece com as temperaturas mínimas, muito bem simuladas pelos modelos por meio do método dos análogos, que para esta variável apresentaram comportamento ainda mais similar com as observações. A Figura 18 mostra, como exemplo, a normal climatológica observada versus as medias climatológicas mensais obtidas com os modelos para quatro estações. A Figura 19a mostra a comparação das médias anuais e a Figura 19b mostra os respectivos desvios, para cada uma das 24 estações. Observa-se que os modelos foram ainda mais eficientes em simular as TMin, pois os desvios de TMin foram baixíssimos se comparados aos de TMax, que foram baixos. Outra característica da simulação desta variável foi que, entre as estações, o comportamento foi aleatório, com praticamente metade das estações apresentando pequena superestimativa e a outra metade apresentando pequena subestimativa.




Figura 16: Climatologia da temperatura máxima do período 1961-1990, com dados observados (linha azul), modelos ECHAM5-OM (linha vermelha) e HadGEM2-ES (linha verde), para 4 estações.




Figura 17: (a) Médias anuais 1961-1990 da temperatura máxima (°C) obtidas das observações (linha azul), ECHAM5-OM (linha vermelha) e HadGEM2-ES (linha verde), e (b) Diferenças médias anuais entre os modelos e observação.




Figura 18: Climatologia da temperatura mínima do período 1961-1990, com dados observados (linha azul), modelos ECHAM5-OM (linha vermelha) e HadGEM2-ES (linha verde), para 4 estações.




Figura 19: (a) Médias anuais 1961-1990 da temperatura mínima (°C) obtidas das observações (linha azul), ECHAM5-OM (linha vermelha) e HadGEM2-ES (linha verde), e (b) Diferenças médias anuais entre os modelos e observação.

Os resultados mostraram que os modelos subestimaram a precipitação no norte da região Nordeste, enquanto as temperaturas de modo geral foram muito bem simuladas, quando comparadas as observações. Nas estações da Bahia e Alagoas, a precipitação foi melhor simulada, pois estas estações não sofrem influencia da ZCIT, que tende a não ser bem simulada pelos modelos, entre fevereiro e maio.


4.6 - CENÁRIOS FUTUROS DA PRECIPITAÇÃO, TEMPERATURAS MÁXIMAS E MÍNIMAS DIÁRIAS

Após a seleção dos preditores, calibração e validação do método dos análogos, e verificação da destreza dos modelos em simular o ciclo climático anual, os cenários futuros podem enfim ser gerados a partir dos MCGs, uma vez que se torna essencial conhecer suas incertezas a fim de alcançar representações confiáveis do clima futuro.

Todas as incertezas estão associadas aos cenários socioeconômicos, emissões de gases de efeito estufa, estrutura e parametrizações dos modelos, e ao próprio método de regionalização empregado. Os resultados estão apresentados em termos das alterações de longo prazo, entre a média anual obtida das variáveis para cada modelo e cenário, ou seja, em termos das diferenças absolutas das médias do período 2020-2080, e o respectivo período de referência: 1961-1990.

Para o cenário A1B, a Figura 20 mostra as diferenças obtidas dos modelos ECHAM5-OM e HadGEM2-ES para a precipitação (a e b), temperaturas máximas (c e d) e temperaturas mínimas (e e f). Em termos médios das 23 estações estudadas, o modelo ECHAM5-OM para o cenário A1B prevê uma redução média de -29,88% da precipitação, e aumentos de 1,3°C para temperaturas máximas, e 1,4°C para temperaturas mínimas, até o final de 2080. O modelo HadGEM2-ES prevê uma redução média de -46,87% da precipitação, e aumentos de 1,5°C para temperaturas máximas, e 1,3°C para temperaturas mínimas, até o final de 2080. Comparando estes valores aos obtidos do quarto relatório do IPCC (2007), para o cenário A1B, a previsão para a região Nordeste seria de aumento das temperaturas entre 1 a 3°C, com redução de até 20% do volume das chuvas. Tais resultados do IPCC são provenientes do *ENSEMBLE* (médias) de vários modelos, entre os quais os dois aqui discutidos.

Os resultados para precipitação mostram que o modelo ECHAM5-OM apresenta menos déficit de precipitação na área norte da região Nordeste, inclusive com duas estações do Ceará, Crateús e Quixeramobim, com diferenças positivas em relação ao período 1961-1990. Isso não acontece no modelo HadGEM2-ES, com precipitações no norte do Nordeste variando entre 200mm e 600mm a menos do que em relação a 1961-1990. No restante da região, principalmente para o Estado da Bahia, os dois modelos apontam déficits significativos







Figura 20: Diferenças médias anuais da precipitação para 2020-2080, dos modelos ECHAM5-OM (a) e HadGEM2-ES (b) com as médias 1961-1990. O mesmo para temperaturas máximas (c) e (d), e temperaturas mínimas, (e) e (f). Todos os resultados para o cenário A1B.

Para o cenário A2, foi possível trabalhar apenas com o modelo ECHAM5-OM. O modelo HadGEM2-ES não disponibiliza saídas para este cenário, apenas para os cenários A1 e A1B, e cenários B1 e B2, não explorados na pesquisa.

A Figura 21 mostra os resultados obtidos com o modelo ECHAM5-OM para a precipitação (a), temperaturas máximas (b) e temperaturas mínimas (c). Os resultados mostram que este cenário indica, em média das 23 estações, uma redução de -26,40% da precipitação, e aumentos de 1,2°C para temperaturas máximas, e 1,3°C para temperaturas mínimas, até o final de 2080.

Tais valores, um pouco mais brandos que os obtidos para o cenário A1B, contradizem do que poderia ser esperado de acordo com o relatório do IPCC (2007), que aponta o cenário A2 mais agressivo que o cenário A1B, com maiores déficits de precipitação e maior elevação das temperaturas. Pode-se perceber que os resultados dos dois cenários, A1B e A2 do modelo ECHAM5-OM, são muito parecidos.






Figura 21: Diferenças médias anuais da precipitação para 2020-2080, do modelo ECHAM5-OM com as médias 1961-1990, para a precipitação (a), temperaturas máximas (b) e temperaturas mínimas (c). Todos os resultados para o cenário A2.

Um estudo de ASSAD *et al*, (2012), avaliou a redução das áreas de baixo risco climático para o cultivo do algodão herbáceo no Brasil, ante as mudanças climáticas dos cenários A2 e B2, entre 2010 e 2040. O Nordeste foi a região que apresentou maior redução, em torno de 15% em 30 anos, das áreas aptas ao cultivo, sob o cenário A2.

Os resultados aqui gerados indicam, para o horizonte de 2020 a 2080, redução significativa das chuvas, principalmente no centro-sul da região Nordeste, envolvendo toda a Bahia, que hoje responde por grande parte da produção nacional. O aumento da temperatura na maior parte das estações se situa entre 0°C e 2°C, enquanto a precipitação projetada em algumas estações do oeste baiano, por exemplo, poderá ter decréscimo de 400 a 800mm do seu total anual.

Esta projeção, se confirmada, devere impactar negativamente o cultivo do algodão na região, pois a faixa de temperaturas ótimas para o desenvolvimento do algodão, entre 18°C e 30°C, poderá ser ultrapassada e a quantidade ótima de precipitação, entre 500 e 1500mm, poderá não ser atingida em muitas safras.

4.7 – CENÁRIOS FUTUROS DA EVAPOTRANSPIRAÇÃO POTENCIAL

Após a obtenção das séries modeladas para o período 2020-2080 da TMed, TMax, TMin e PREC, foram obtidos os dados de UR, PAt e VMV a partir de um refinamento estatístico que possibilita aproximar valores modelados dos pontos de grade mais próximos da localização das estações. A INS, por não ser uma variável contemplada em saídas de MCG, foi conseguida a partir da relação existente entre as demais variáveis, usando a técnica estatística de imputação multivariada *MICE*.

Os resultados para os cenários A1B e A2, do modelo ECHAM5-OM e A1B do modelo HadGEM2-ES, são mostrados nas Tabelas 17 e 18 para os cenários A1B, e na Tabela 19 para o cenário A2. As tabelas mostram os valores de r encontrados entre os dados observados e previstos para o período 2001-2012, a nível mensal. Para esta validação, o tamanho da amostra é $N=144$ meses, para este valor o coeficiente de correlação é estatisticamente significativo ao nível de 99% de confiança se for maior ou igual a 0,32. Tais resultados mostram que a PAt foi a variável que apresentou a melhor relação com as observações, com um valor médio de r igual a 0,78, seguida da UR com valor médio de r igual a 0,69. A VMV apresentou um valor médio de r igual 0,54 e a INS apresentou um valor médio de r igual 0,50. Tais valores indicam que o refinamento estatístico forneceu bons resultados para as variáveis.

De posse destas variáveis, e da TMed, TMax e TMin, foi possível calcular, pelo método de *Penman-Monteith*, a ETP para o período 2020-2080. A validação da ETP é obtida para o período 2001-2012, mostrada na Tabela 20, entre valores observados e previstos nos dois cenários e para os dois modelos, a nível decendial, pois o modelo agrometeorológico usa esta escala de tempo para estimativa da produtividade, ou da penalização percentual.

No cenário A1B do modelo ECHAM5-OM, 14 das 23 estações apresentaram valores de r superiores a 0,6, enquanto que para os cenários A2 do modelo ECHAM5-OM e A1B do modelo HadGEM2-ES, 16 das 23 estações apresentaram valores de r superiores a 0,6.

Tabela 17. Correlações entre observações e previsões do modelo ECHAM5-OM, cenário A1B, entre 2001 e 2012, das variáveis Umidade Relativa (UR), Pressão Atmosférica (PAT), Velocidade Média do Vento (VMV) e Insolação (INS). Valores de r acima de 0,6 estão destacados em cinza.

Correlação entre observações e previsões (2001-2012)				
Modelo ECHAM5-OM , Cenário A1B				
Estação	UR (r)	PAt (r)	VMV (r)	INS (r)
Água Branca	0,68*	0,85*	0,65*	0,55*
Apodi	0,72*	0,79*	0,56*	0,50*
Balsas	0,86*	0,70*	0,18	0,76*
Barra	0,67*	0,83*	0,48*	0,32*
Barreiras	0,80*	0,73*	0,37*	0,44*
B. J. da lapa	0,73*	0,80*	0,26	0,37*
Caetitê	0,46*	0,81*	0,61*	0,24
Carinhanha	0,68*	0,80*	0,54*	0,42*
Correntina	0,70*	0,74*	0,37*	0,41*
Crateús	0,87*	0,72*	0,67*	0,71*
Iguatu	0,88*	0,81*	0,73*	0,64*
Jaguaruana	0,78*	0,77*	0,77*	0,67*
Lençóis	0,56*	0,86*	0,30*	0,14
Monteiro	0,68*	0,77*	0,73*	0,54*
Morada Nova	0,60*	0,74*	0,51*	0,55*
Ouricuri	0,78*	0,81*	0,53*	0,60*
Patos	0,73*	0,76*	0,79*	0,59*
Paulistana	0,76*	0,85*	0,75*	0,53*
Quixeramobim	0,63*	0,51*	0,80*	0,49*
S. do Bonfim	0,70*	0,79*	0,61*	0,40*
Sobral	0,82*	0,74*	0,53*	0,74*
Tauá	0,84*	0,79*	0,37*	0,68*
V. da Conquista	0,32*	0,80*	0,24	0,16

*Valores estatisticamente significantes ao nível de 99% de confiança.

Tabela 18. Correlações entre observações e previsões do modelo HadGEM2-ES, cenário A1B, entre 2001 e 2012, das variáveis Umidade Relativa (UR), Pressão Atmosférica (PAT), Velocidade Média do Vento (VMV) e Insolação (INS). Valores de r acima de 0,6 estão destacados em cinza.

Correlação entre observações e previsões (2001-2012)				
Modelo HadGEM2-ES , Cenário A1B				
Estação	UR (r)	PAt (r)	VMV (r)	INS (r)
Água Branca	0,52*	0,86*	0,63*	0,49*
Apodi	0,66*	0,79*	0,46*	0,55*
Balsas	0,89*	0,77*	0,07	0,73*
Barra	0,56*	0,84*	0,63*	0,22
Barreiras	0,78*	0,78*	0,44*	0,45*

B. J. da lapa	0,72*	0,83*	0,25	0,27
Caetité	0,50*	0,84*	0,60*	0,25
Carinhanha	0,66*	0,84*	0,58*	0,45*
Correntina	0,66*	0,70*	0,40*	0,42*
Crateús	0,86*	0,76*	0,76*	0,70*
Iguatu	0,87*	0,83*	0,72*	0,53*
Jaguaruana	0,71*	0,79*	0,76*	0,66*
Lençóis	0,44*	0,86*	0,34*	0,28
Monteiro	0,68*	0,79*	0,65*	0,55*
Morada Nova	0,44*	0,81*	0,57*	0,45*
Ouricuri	0,78*	0,84*	0,51*	0,62*
Patos	0,68*	0,79*	0,71*	0,51*
Paulistana	0,74*	0,85*	0,77*	0,52*
Quixeramobim	0,57*	0,47*	0,81*	0,66*
S. do Bonfim	0,51*	0,81*	0,57*	0,35*
Sobral	0,81*	0,76*	0,70*	0,71*
Tauá	0,81*	0,85*	0,27	0,67*
V. da Conquista	0,26	0,78*	0,19	0,20

*Valores estatisticamente significantes ao nível de 99% de confiança.

Tabela 19. Correlações entre observações e previsões do modelo ECHAM5-OM, cenário A2, entre 2001 e 2012, das variáveis Umidade Relativa (UR), Pressão Atmosférica (PAT), Velocidade Média do Vento (VMV) e Insolação (INS). Valores de r acima de 0,6 estão destacados em cinza.

Correlação entre observações e previsões (2001-2012)				
Modelo ECHAM5-OM , Cenário A2				
Estação	UR (r)	PAT (r)	VMV (r)	INS (r)
Água Branca	0,70*	0,88*	0,61*	0,51*
Apodi	0,75*	0,80*	0,61*	0,48*
Balsas	0,89*	0,68*	0,21	0,77*
Barra	0,71*	0,82*	0,53*	0,37*
Barreiras	0,81*	0,69*	0,32*	0,45*
B. J. da lapa	0,73*	0,82*	0,18	0,41*
Caetité	0,53*	0,82*	0,62*	0,37*
Carinhanha	0,74*	0,79*	0,49*	0,57*
Correntina	0,64*	0,66*	0,27	0,48*
Crateús	0,87*	0,69*	0,73*	0,68*
Iguatu	0,89*	0,80*	0,75*	0,61*
Jaguaruana	0,76*	0,79*	0,77*	0,71*
Lençóis	0,50*	0,87*	0,22	0,16
Monteiro	0,67*	0,74*	0,72*	0,49*
Morada Nova	0,63*	0,81*	0,57*	0,48*
Ouricuri	0,80*	0,82*	0,53*	0,55*
Patos	0,75*	0,81*	0,79*	0,52*

Paulistana	0,77*	0,81*	0,75*	0,51*
Quixeramobim	0,57*	0,36*	0,72*	0,63*
S. do Bonfim	0,65*	0,79*	0,65*	0,34*
Sobral	0,81*	0,72*	0,55*	0,69*
Tauá	0,85*	0,82*	0,39*	0,69*
V. da Conquista	0,31	0,82*	0,37*	0,21

*Valores estatisticamente significantes ao nível de 99% de confiança.

Tabela 20. Correlações entre ETPs observadas e previstas pelos modelos ECHAM5-OM, cenários A1B e A2, e HadGEM2-ES para o cenário A1B, entre 2001 e 2012. Valores de r acima de 0,6 estão destacados em cinza.

Correlação ETO modelada e observada (2001-2012)			
Modelo	ECHAM5-OM	ECHAM5-OM	HadGEM2-ES
Estação	Cenário A1B	Cenário A2	Cenário A1B
Água Branca	0,50*	0,63*	0,48*
Apodi	0,61*	0,64*	0,59*
Balsas	0,70*	0,74*	0,81*
Barra	0,52*	0,60*	0,62*
Barreiras	0,62*	0,66*	0,67*
B. J. da lapa	0,61*	0,62*	0,65*
Caetité	0,31	0,40*	0,38*
Carinhanha	0,59*	0,63*	0,62*
Correntina	0,63*	0,65*	0,64*
Crateús	0,76*	0,76*	0,79*
Iguatu	0,76*	0,76*	0,76*
Jaguaruana	0,67*	0,65*	0,67*
Lençóis	0,33*	0,25	0,34*
Monteiro	0,60*	0,55*	0,60*
Morada Nova	0,50*	0,53*	0,40*
Ouricuri	0,61*	0,63*	0,64*
Patos	0,63*	0,64*	0,61*
Paulistana	0,68*	0,68*	0,68*
Quixeramobim	0,45*	0,60*	0,65*
S. do Bonfim	0,13	0,08	0,08
Sobral	0,64*	0,63*	0,74*
Tauá	0,66*	0,69*	0,68*
V. da Conquista	0,14	0,16	0,16

*Valores estatisticamente significantes ao nível de 99% de confiança.

Como resultado principalmente do aumento das temperaturas, foi observada uma tendência de aumento da ETP, para os dois cenários dos dois modelos, entre 2020 a 2080. Resultados das estimativas diárias para quatro estações são mostradas nas Figuras 22 a 25 para Barra (BA), Monteiro (PB), Patos (PB) e Sobral (CE). Nos gráficos, os valores diários

estimados para o período futuro são confrontados com a media diária dos dados observados entre 1961 e 1990, permitindo observar a elevação dos valores de ETP.




Figura 22: Evolução da ETP diária, em mm/dia, entre 2020 e 2080 para os cenários A1B dos modelos ECHAM5-OM e HadGEM2-ES, e para o cenário A2 do modelo ECHAM5-OM, para a estação de Barra (BA). A linha preta corresponde ao valor médio diário da ETP em 1961-1990, e a linha vermelha corresponde a linha de tendência do período 2020-2080.




Figura 23: Mesmo da Figura 22, mas para a estação de Monteiro (PB).




Figura 24: Mesmo da Figura 22, mas para a estação de Patos (PB).




Figura 25: Mesmo da Figura 22, mas para a estação de Sobral (CE).

4.8 - CENÁRIOS FUTUROS DA PRODUTIVIDADE DO ALGODÃO

Todo o processo de geração de cenários futuros das variáveis meteorológicas relativas a 23 estações meteorológicas do INMET teve como objetivo final, não apenas avaliar o grau de mudanças futuras destas variáveis, mas gerar cenários futuros da

produtividade do algodão herbáceo na região semiárida do Nordeste sob diferentes cenários de mudanças climáticas.

Para cada município, foi calculada a penalização, ou percentual de perda de produtividade, no período de 2001 a 2011 com dados meteorológicos observados, permitindo calibrar um modelo agrometeorológico que possibilita estimar tanto a penalização da cultura por déficit hídrico, como também transformar esta penalização em estimativa da produção, em kg/ha. Foi observado que o modelo foi bem calibrado e apresentou valores médios do período 2001-2011 muito próximos dos valores observados pelo IBGE (ver Figura 10).

A variabilidade entre os 23 municípios ficou explícita, mostrando diferentes níveis de resposta da produção em relação às condições climáticas. Desta forma, de posse dos cenários futuros da PREC e da ETP, principais dados de entrada para rodar o modelo agrometeorológico, foi possível estimar a penalização futura, para diferentes cenários de dois MCGs.

A Tabela 21 mostra a penalização estimada para o período 2020-2080 para os cenários A1B e A2 do modelo ECHAM5-OM, e A1B do HadGEM2-ES, comparada à penalização média calculada com dados observados do período 2001-2011. Os resultados mostram o aumento da penalização por déficit hídrico, projetada pelos cenários futuros para o algodão.

Tabela 21. Penalização média obtida com dados observados no período 2001-2011 *versus* valores médios da penalização obtida com os cenários A1B e A2 do modelo ECHAM5-OM, e com o cenário A1B do modelo HadGEM2-ES, para o período 2020-2080.


Estação	Penalização Média Observada (%) de 2001-2011	Penalização Modelo ECHAM5-OM (%)	Penalização Modelo HadGEM2-ES (%)	Penalização Modelo ECHAM5-OM (%)
		Cenário A1B: 2020-2080	Cenário A1B: 2020-2080	Cenário A2: 2020-2080
Água Branca	18,0	33,7	43,7	32,6
Apodi	29,7	48,7	53,5	47,9
Balsas	18,7	42,4	46,3	42,3
Barra	42,7	51,9	47,5	49,4
Barreiras	29,2	44,5	47,0	43,8
B. J. da lapa	35,8	48,2	51,2	47,0


Caetité	38,9	47,5	47,8	45,5
Carinhanha	39,1	48,1	44,5	40,5
Correntina	32,7	42,5	40,1	41,7
Crateús	35,8	35,1	48,1	36,2
Iguatu	31,7	42,4	50,9	41,1
Jaguaruana	33,5	40,6	40,5	53,4
Lençóis	35,4	45,1	49,9	43,2
Monteiro	37,4	55,4	60,3	54,9
Morada Nova	33,5	41,2	53,4	42,0
Ouricuri	43,5	53,9	58,6	53,2
Patos	24,1	55,1	57,8	53,8
Paulistana	41,6	54,3	58,1	52,8
Quixeramobim	31,9	40,2	50,8	41,8
S. do Bonfim	36,6	50,0	54,5	47,5
Sobral	24,1	34,0	45,8	34,3
Tauá	39,6	49,1	56,1	48,0
V. da Conquista	35,1	45,0	46,3	43,9

A Figura 26 mostra, para as 23 estações analisadas, a tendência de aumento do percentual de perda da cultura do algodão entre 2020 e 2080, para os diferentes cenários dos modelos, ou seja, principalmente com a diminuição da precipitação projetada para o futuro e do aumento da ETP, há uma tendência significativa de que esta cultura, se mantidas as condições atuais tecnológicas, tenha maior probabilidade de queda em sua produtividade. A linha horizontal em cada gráfico representa a penalização média observada em cada município de 2001 a 2011. Os resultados da Figura 26 indicam uma interessante característica, que é uma perceptível tendência de aumento mais significativa a partir de 2050, podendo-se destacar mais facilmente isto em Monteiro e Patos (PB), Ouricuri (PE), Paulistana (PI), e Lençóis, Senhor do Bonfim, Correntina e Vitória da Conquista (BA).

Em Balsas (MA), Água Branca (AL), Apodí (RN), Iguatu e Tauá (CE), e Barra, Barreiras, Bom Jesus da Lapa e Caetité (BA), percebe-se uma tendência constante do aumento das penalizações desde 2020. Já nas cidades cearenses de Crateús, Jaguaruana, Morada Nova, Quixeramobim e Sobral, notam-se uma elevação do patamar médio das penalizações, mas sem uma tendência marcadamente constante desde 2020 ou mais acentuada a partir de 2050. Nota-se ainda, que para a maior parte dos municípios, as maiores taxas de aumento das penalizações provêm do cenário A1B do modelo

HadGEM2-ES. Salientando que este foi, entre os cenários e os modelos, o que apresentou a maior redução da precipitação entre 2020 e 2080.








Figura 26: Estimativa percentual da perda de produtividade do algodão herbáceo para 2020-2080 dos cenários A1B dos modelos ECHAM5-OM (linha vermelha) e HadGEM2-ES (linha azul), e do cenário A2 do modelo ECHAM5-OM (linha verde). A produtividade média observada do período 2001-2011 é mostrada na linha preta horizontal dos gráficos, para as 23 estações.

Uma aproximação final para avaliar a perda de produtividade do algodão herbáceo na região Nordeste é mostrada na Figura 27. Nesta figura são projetadas a produtividade média anual do período 2020-2080 dos dois cenários climáticos obtidos com o modelo ECHAM5-OM e do cenário climático obtido com o modelo HadGEM2-ES, em kg/ha. Para chegar a este resultado, foram tomadas as produtividades médias obtidas com dados observados do período 2001-2011, mostradas na Figura 8, e estimadas as dos modelos com base nesta média observada e na penalização média estimada pelos mesmos para 2020-2080. O resultado mostra claramente que a perda de produtividade se acentua quanto mais produtivo seja o município.




Figura 27: Produtividades médias do algodão herbáceo (Kg/ha) em cada município, entre 2020 e 2080, projetadas para os cenários A1B e A2 do modelo ECHAM5-OM, e A1B do modelo HadGEM2-ES, comparadas com a produtividade média anual observada no período 2001-2011.

5. CONCLUSÕES

A técnica *MICE* se mostrou muito eficiente para o preenchimento das falhas em séries temporais de variáveis meteorológicas. O SCQ usado deve ser indicado para tratamento de séries temporais de variáveis meteorológicas. É baseado em rigorosos testes e permite corrigir muitos erros.

As projeções futuras dos cenários dos modelos foram praticamente unânimes em indicar redução significativa das taxas de precipitação, e aumento moderado das temperaturas máximas e mínimas.

Para 2020 a 2080, em média, o modelo ECHAM5-OM prevê redução de 29,88% da precipitação, com aumentos de 1,3°C das temperaturas máximas e 1,4°C das temperaturas mínimas, para o cenário A1B.

O modelo HadGEM2-ES prevê, em média, redução de 46,87% da precipitação, e aumento de 1,5°C das temperaturas máximas e 1,3°C das temperaturas mínimas, para o cenário A1B.

O modelo ECHAM5-OM prevê redução de 26,40% da precipitação, com aumentos de 1,2°C das temperaturas máximas e 1,3°C das temperaturas mínimas, para o cenário A2.

Prevê-se, para 2020 a 2080, uma redução significativa da produtividade do algodão nos 23 municípios estudados, de acordo com os dados gerados com os cenários climáticos futuros A1B e A2, dos modelos ECHAM5-OM e HadGEM2-ES. Este resultado é fruto direto da diminuição da precipitação prevista para o período, assim como do aumento da ETP.

Tal redução se mostra mais importante quanto maior a produtividade do município. Os municípios com produtividade em torno de 3500 kg/ha poderão ter suas produtividades reduzidas a 1700 kg/ha, aproximadamente, Municípios com produtividade média de 1500 kg/ha poderão ter suas produtividades reduzidas a 750 kg/ha, aproximadamente, enquanto municípios com produtividade em torno de 750 kg/ha poderão ter suas produtividades reduzidas a 300 kg/ha, aproximadamente. Isso mostra que os cenários são de redução de aproximadamente metade da produtividade atual.

6. REFERENCIAS BIBLIOGRÁFICAS

ALVES, J. M. B.; CAMPOS, J. N. B.; FILHO, F. A. S.; MONCUNNIL, D. F.; SILVA, E. M.; BARBOSA, W. L.; FERREIRA, A. G.; SUN, L.; MOURA, A. D. Uma avaliação preliminar de simulações climáticas de um modelo regional espectral aninhado em um modelo global (ECHAM 4.5) sobre o setor norte da região Nordeste do Brasil (1971-2000). **Revista Brasileira de Meteorologia**, v.20, n.2, p.191-206, 2005.

ASSAD, E. D.; MARIN, F. R.; EVANGELISTA, S. R.; PILAU, F. G.; FARIAS, J. R. B.; PINTO, H. S.; JUNIO, J. Z. Sistema de previsão para da safra de soja para o Brasil. **Pesquisa Agropecuária Brasileira**, Brasília-DF, v.42, n.5, p. 615-625, 2007.

AZEVEDO, P. V.; MACIEL, G. F. Estação de cultivo e época de semeadura para o algodão herbáceo na região de Sousa-PB. **Revista Brasileira de Agrometeorologia**, Santa Maria-RS, v.1, n.1, p. 81-85, 1993.

AZEVEDO, P. V.; SILVA, F. D. S.; BEZERRA, J. R. C. Zoneamento da época de semeadura para o algodoeiro no Estado da Paraíba. **Revista Brasileira de Agrometeorologia**, Piracicaba-SP, v.12, n.2, p. 379-386, 2004.

AZEVEDO, P. V. de; SILVA, F. D. S. Risco climático para o cultivo do algodoeiro na região Nordeste do Brasil. **Revista Brasileira de Meteorologia**, v.22, p.408-416, 2007.

BABEL, M. S.; TURİYATUNGA, E. Evaluation of climate change impacts and adaptation measures for maize cultivation in the western Uganda agro-ecological zone. **Theoretical and Applied Climatology**, doi: 10.1007/s00704-01401097-z, 2014.

BARNETT, T.; PREISENDORFER, R. Multifield analog prediction of short-term climate fluctuations using a climate state vector. **Journal of Atmospheric Sciences**, v. 35, p. 1771-1787, 1978.

BELLOUIN N.; BOUCHER, O.; HAYWOOD, J.; JOHNSON, C.; JONES, A.; RAE, J.; WOODWARD, S. Improved representation of aerosols for HadGEM2. Meteorological Office Hadley Centre, **Technical Note 73**, March 2007.

BENESTAD, R. E. Downscaling precipitation extremes. **Theoretical and Applied Climatology**, v. 100 (1-2), p. 1-21, 2010.

BERLATO, M. A.; MOLION, L. C. B. Evaporação e evapotranspiração. Porto Alegre: **IPAGRO**, 95p, 1981. (IPAGRO. Boletim Técnico, 7).

BERLATO, M. A.; MOLION, L. C. B. Modelo de relação entre rendimento de grãos da soja e déficit hídrico. **In: Congresso Brasileiro de Agrometeorologia**, Porto Alegre-RS, p.144, 1993.

BETTOLLI, M. L.; CARMEN, M. A. A.; BRASESCO, G. C.; RUDORFF, F.; ORTIZ, A. M.; ARROYO, J.; ARMOA, Y. J. Pastura natural de salto (Uruguay): Relacion con la variabilidad climatica y analisis de contextos futuros de cambio climatico. **Revista Brasileira de Meteorologia**, Brasília-DF, v. 25, p. 248-259, 2010.

BIAU, G.; ZORITA, E.; VON STORCH, H.; WACKERNAGEL, H. Estimation of precipitation by kriging in the EOF space of the sea level pressure field. **Journal of Climate**, v. 12, p. 1070-1085, 1999.

BRANDS, S.; HERRERA, S.; SAN-MARTIN, D.; GUTIERREZ, J. M. Validation of the ensembles global climate models over southwestern Europe using probability density functions, from a downscaling perspective. **Climate Research**, v. 48(2-3), p. 145–161, 2011a.

BRANDS, S.; TABOADA, J. J.; COFINO, A. S.; SAUTER, T.; SCHNEIDER, C. Statistical downscaling of daily temperatures in the Iberian Peninsula from global climate models: validation and future scenarios. **Climate Research**, v.48(2-3), p. 163–176, 2011b.

BRANDS, S.; GUTIERREZ, J. M.; HERRERA, S. On the Use of Reanalysis Data for Downscaling. **Journal of Climate**, v.25, p. 2517-2526, 2012.

CAMARGO, M. B. P; BRUNINI, O.; MIRANDA, M. A. C. Modelo agrometeorológico para estimativa da produtividade para a cultura da soja no Estado de São Paulo. **Bragantina**, Campinas-SP, v. 45, n. 2, p. 279-292, 1986.

CAMARGO, M. B. P. Determination of the water balance components and drought sensitivity indices for a sorghum crop. Lincoln/USA, 126p. **Doctoral Dissertation**, University of Nebraska, 1993.

CAMARGO, M. B. P.; HUBBARD, K. G. Spatial and temporal variability of daily weather variables in sub-humid and semi-arid areas of the U.S. High Plains. **Agricultural and Forest Meteorology**, v. 93, p. 141-148, 1999.

CHAVES, I. B.; FREIRE, O.; AMORIM NETO, M. S. Característica da precipitação e riscos de erosão na região tropical semiárida brasileira. **Pesquisa Agropecuária Brasileira**, Brasília-DF, v. 20, n. 9, p. 991-998, 1982.

CHEN, M.; SHI, W.; XIE, P.; SILVA, V. B. S.; KOUSKY, V. E.; WAYNE HIGGINS, R.; JANOWIAK, J. E. Assessing objective techniques for gauge-based analyses of global daily precipitation. **Journal of Geophysical Research: Atmospheres**, v. 113, D04110, doi:10.1029/2007JD009132, 2008.

COLLINS, M.; KNUTTI, R.; ARBLASTER, J.; DUFRESNE, J. L.; FICHEFET, T.; FRIEDLINGSTEIN, P.; GAO, X.; GUTOWSKI, W. J.; JOHNS, T.; KRINNER, G.; SHONGWE, M.; TEBALDI, C.; WEAVER, A. J.; WEHNER, M. Long-term climate change: Projections, commitments and irreversibility. **In Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change**, 2013.

COLLINS, W. J.; BELLOUIN, N.; DOUTRIAUX-BOUCHER, M.; GEDNEY, N.; HINTON, T. C.; JONES, D.; LIDDICOAT, S.; MARTIN, G.; OCONNOR, F.; RAE, J.; SENIOR, C.; TOTTERDELL, I.; WOODWARD, S. Evaluation of the HadGEM2 model. Meteorological Office Hadley Centre, **Technical Note 74**, 2008.

COMPANHIA NACIONAL DE ABASTECIMENTO, 2008. Disponível em: <<http://www.conab.gov.br> />. Acesso em: 21 jan. 2009.

COSTA, R. L.; SILVA, F. D. D.; SARMANHO, G. F.; LUCIO, P. S. Imputação Multivariada de Dados Diários de Precipitação e Análise de Índices de Extremos Climáticos. *Revista Brasileira de Geografia Física*, v. 5, n.3, p. 661-675, 2012.

CUBASCH, U.; VON STORCH, H.; WASZKEWITZ, J. ZORITA, E. Estimates of climate changes in southern Europe using different downscaling techniques. **Climate Research**, v. 7, p. 129-149, 1996.

CUNHA, G. R.; BERGAMASCHI, H. Efeitos da disponibilidade hídrica sobre o rendimento das culturas. In: BERGAMASCHI, H. (Coord). Agrometeorologia aplicada a irrigação, 2.ed. Porto Alegre: **Editora Universidade/UFRGS - capítulo 6**, p. 85-87, 1999.

DEVORE, J. L. Probabilidade e estatística para engenharia e ciência. São Paulo: **Thomson Pioneira**, p. 706, 2006.

DOORENBOS, J; PRUITT, W. O. Necessidades hídricas das culturas. Tradução de GHEYI, H. R.; METRI, J. E. C.; DAMASCENO, F. A. V. Campina Grande: UFPB (**Estudos FAO: Irrigação e Drenagem, 24**), 1997.

DOORENBOS, J; KASSAM, A. H. Efeito da água no rendimento das culturas. Tradução de GHEYI, H. R.; SOUSA, A. A.; DAMASCENO, J. F. 2. ed. Campina Grande: UFPB, 2000, 221p. (**Estudos FAO: Irrigação e Drenagem, 33**).

DOORENBOS, J; KASSAM, A. H. Yield response to water. Roma, Irrigation and Drainage Paper 33, **FAO**, 179p, 1979.

DOURADO NETO, D.; DARIO, G. J. A.; JUNIOR, P. A. V.; MANFRON, P. A.; MARTIN, T. N.; BONNECARRÉRE, R. A. G.; CRESPO, P. E. N. Aplicação e influência do fitorregulador no crescimento das plantas de milho. **Revista da Faculdade de Zootecnia, Veterinária e Agronomia**, v.11, n.1, p.93-102, 2004.

EISCHEID, J. K.; BAKER, C. B.; KARL, T.; DIAZ, H. F. The quality control of long-term climatological data using objective data analysis. **Journal of Applied Meteorology**, v. 34, p. 2787-2795, 1995.

FALLIERI, J.; SILVA, A. Ensaio de épocas de plantio do algodoeiro na Estação Experimental de Sete Lagoas, MG. **IPEACO**, 9p, 1968.

FERREIRA, D. B.; RAO, V. B. Recent climate variability and its impacts on soybean yields in Southern Brazil. **Theoretical and Applied Climatology**, v. 105, p. 83-97, 2011.

FLATO, G.; MAROTZKE, J.; ABIODUN, B.; BRACONNOT, P.; CHOU, S.C.; COLLINS, W.; COX, P.; DRIQUECH, F.; EMORI, S.; EYRING, V.; FOREST, C.; GLECKLER, P.; GUILYARDI, E.; JAKOB, C.; KATTSOV, V.; REASON, C.; RUMMUKAINEN, M. Evaluation of climate models. **In Climate Change 2013: The**

Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change, 2013.

FONTANA, D. C.; BERLATO, M. A.; BARGAMASCHI, H. Alterações micrometeorológicas na cultura da soja submetida a diferentes regimes hídricos. **Pesquisa Agropecuaria Brasileira**, v. 27, n. 5, p.661-669, 1992.

FOWLER, H. J.; BLENKINSOP, S.; TEBALDI, C. Linking climate change modelling to impacts studies: Recent advances in downscaling techniques for hydrological modelling. **International Journal of Climatology**, v. 27, p. 1547-1578, 2007.

FREELAND, T. B.; PETTIGREW, B.; THAXTON, P.; ANDREWS, G. L. Agrometeorology and cotton productions. Washington, Dc: United States Department of Agriculture. **Agricultural Research Service**, 17p, 2006.

FRICH, P.; ALEXANDER, L. V.; DELLA-MARTA, P.; GLEASON, G.; HAYLOCK, M.; KLEIN TANK, A. M. G.; PETERSON, T. Observed coherent changes in climatic extremes during the second half of the century. **Climate Research**, v. 19, p.193-212, 2002.

GANDIN, L. S. Objective Analysis of Meteorological Fields. **Israel Program for Scientific Translation**, Jerusalem, 242 pp, 1965.

GANDIN, L. S. Complex quality control of meteorological observations. **Monthly Weather Review**, v. 116, p. 1137-1156, 1988.

GARCIA-LORCA, D. R.; ORTEGA, J. M. C. El Algodon. Madrid: Mundi-Prensa, 242p, 1991.

GIRVETZ, E. H.; ZGANJAR, C.; RABER, G. T.; MAURER, E. P.; KAREIVA, P.; LAWLER, J. J. Applied Climate-Change Analysis: The Climate Wizard Tool. **Plos One**, v. 4, n. 12, 19p, 2009

GOMEZ, R. A. Q. Trends of Maximum and Minimum Temperatures in Northern South America. **Journal of Climate**, v.16, p. 2104-2112, 1999.

GREENLAND, S.; FINKLE, W. D. A Critical Look at Methods for Handling Missing Covariates in Epidemiologic Regression Analyses. **American Journal of Epidemiology**, v. 142, n. 12, p. 1255-1264, 1995.

GUTIÉRREZ, J. M.; SAN-MARTIN, D.; BRANDS, S.; MANZANAS, R.; HERRERA, S. Reassessing statistical downscaling techniques for their robust application under climate change conditions. **Journal of Climate**. v. 26, p. 171-188, 2013.

GUTTMAN, N. V.; QUAYLE, R. G. A review of cooperative temperature data validation. **Journal of Atmospheric and Oceanic Technology**. v. 7, p. 334-339, 1990.

GUTZLER, D. S.; ROBBINS, T. O. Climate variability and projected change in the western United States: regional downscaling and drought statistics. **Climate Dynamics**, v. 37 (5-6), p. 835–849, 2011.

HALL, T.; BROOKS, H.; DOSWELL, C. Precipitation forecasting using a neural network. **Weather and Forecasting**, v. 14, p. 338-345, 1999.

HANKS, R. J.; RASMUSSEN, V. P. Predicting crop production as related to plant water stress. In: BRADY, N. C., ed. Crop production and plant water stress. **Advances in Agronomy**, Madison, v. 35, p. 193-215, 1982.

HARTMANN, D. L.; KLEIN-TANK, A. M. G.; RUSTICUCCI, M.; ALEXANDER, L. V.; BRONNIMANN, S.; CHARABI, Y.; DENTENER, F. J.; DLUGOKENCKY, E. J.; EASTERLING, D. R.; KAPLAN, A.; SODEN, B. J.; THORNE, P. W.; WILD, M.; ZHAI, P. M. Observations: Atmosphere and Surface. **In The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change**, p. 159-254, 2013.

HASTENRATH, S. Interannual variability and annual cycle: mechanisms of circulation and climate in the tropical Atlantic. **Monthly Weather Review**, v. 112, p. 1097-1107, 1984.

HAYLOCK, M. R.; PETERSON, T. C.; ALVES, L. M.; AMBRIZZI, T.; ANUNCIAÇÃO, Y. M. T.; BAEZ, J.; BARROS, V. R.; BERLATO, M. A.; BIDEGAIN, M.; CORONEL, G.; CORRADI, V.; GARCIA, V. J.; GRIMM, A. M.; KAROLY, D.; MARENGO, J. A.; MARINO, M. B.; MONCUNILL, D. F.; NECHET, D.; QUINTANA, J.; REBELLO, E.; RUSTICUCCI, M.; SANTOS, J. L.; TREBEJO, I.; VINCENT, L. A. Trends in Total and Extreme South American Rainfall in 1960–2000 and Links with Sea Surface Temperature. **Journal of Climate**, v. 19, p. 1490 - 1512, 2006.

HEWITSON B. C.; CRANE, R. G. Climate downscaling: techniques and application. **Climate Research**, v. 7, n. 29, p. 85-95, 1996.

HEWITSON, B. C.; CRANE, R. G. Consensus between GCM climate change projections with empirical downscaling: precipitation downscaling over South Africa. **International Journal of Climatology**, v. 26, p. 1315-1337, 2006.

HUBBARD, K. G.; GODDARD, S.; SORENSEN, W. D.; WELLS, N.; OSUGI, T. T. Performance of Quality Assurance Procedure for an Applied Climate Information System. **Journal of Atmospheric and Oceanic Technology**, v. 22, p. 105-112, 2005.

HUANG, G.; PAES, A. T. Posso usar o teste t-Student quando preciso comparar três ou mais grupo? **Einstein: Educação Continuada em Saúde**, v. 7, n. 2, p. 63-64, 2009.

INTERGOVERNAMENTAL PANEL ON CLIMATE CHANGE – IPCC. Climate Change - The physical science basis. Contribution of working group I to the fourth assessment Report of the IPCC. **Cambridge University**. Press, Cambridge, 2007.

IPCC. Working Group I Contribution to the IPCC Fifth Assessment Report (AR5), Climate Change 2013: The Physical Science Basis. **Intergovernmental Panel on Climate Change**, Geneva, Switzerland, 2013.

JONES, R. G.; NOGUER, M.; HASSEL, D. C.; HUDSON, D.; WILSON, S. S.; JENKINS, G. J.; MITCHELL, J. F. B. Generating high resolution climate change scenarios using PRECIS. **Meteorological Office Hadley Centre**. Exeter, UK, 40p. 2004.

KALNAY, E., and Coauthors. The NCEP/NCAR 40-Year Reanalysis Project. *Bulletin of the American Meteorological Society*, v.77(3), p.437–471, 1996.

KOUSKY, V. E. Frontal influences on Northeast Brazil. **Monthly Weather Review**, v. 107, p. 1140-1153, 1979.

KOUSKY, V. E.; GAN, M. A. Upper Tropospheric Cyclonic Vortices in the Tropical South Atlantic. **Tellus**, v.33, p. 538-551, 1981.

KOUSKY, V. E.; KAYANO, M. T. Principal modes of outgoing longwave radiation and 250 mb circulation for the South American sector. **Journal of Climate**, v. 7, p. 1131-1143, 1994.

KOTSOPOULOS, S.; KALFOUNTZOS, D.; ALEXIOU, I. Water depths and cotton yields under sprinkler, surface trickle and subsurface trickle irrigation. **Protection and Restoration of the Environment VII**, Mykonos-Greece, 2004.

KRUIZINGA, S.; MURPHY, A H. Use of an Analogue Procedure to Formulate Objective Probabilistic Temperature Forecasts in the Netherlands. **Monthly Weather Review**, v. 111, p. 2244-2254, 1983.

KÜRBIS, K.; MUDELSEE, M.; TETZLAFF.; BRÁZDIL, R. Trends in extremes of temperature, dew point, and precipitation from long instrumental series from central Europe. **Theoretical Applied of Climatology**, 98: 187-195, 2009.

LACA-BUENDIA, J. P.; OLIVEIRA, P.; PIRES, G. A. D.; SILVA FILHO. P. V. Estudo de época de plantio x cultivares de algodão herbáceo (*Gossypium hirsutum* L. var. *latifolium* Hutch) nas principais regiões algodoeiras de Minas Gerais. EPAMIB (Belo Horizonte, MG). **Projeto Algodão**, Relatório 1980/92. p. 594-596, 1997.

LORENZ, E. N. Atmospheric predictability as revealed by naturally occurring analogues. **Journal of the Atmospheric Sciences**, v. 26, p. 636-646, 1969.

LUCIO, P. S.; CONDE, F. C.; CAVALCANTI, I. F. Spatiotemporal monthly rainfall reconstruction via Artificial Neural Network. Case study: south of Brazil. **Advances in Geosciences**, v. 10, p. 67-76, 2007.

MARAUN, D.; WETTERHALL, F.; IRESON, A. M.; CHANDLER, R. E.; KENDON, E. J.; WIDMANN, M.; BRIENEN, S.; RUST, H. W.; SAUTER, T.; THEMEL, M.; VENEMA, V. K. C.; CHUN, K. P.; GOODESS, C. M., JONES, R. G.; ONOF, C.; VRAC, M.; THIELE-EICH, I. Precipitation downscaling under climate change: recent developments to bridge the gap between dynamical models and the end user. **Reviews of Geophysics**, v.48, p. 1-38, 2010.

MARENGO, J. A.; ALVES, L.; VALVERDE, M.; ROCHA, R.; LABORBE, R. Eventos extremos em cenários regionalizados de clima no Brasil e América do Sul para o Século XXI: Projeções de clima futuro usando três modelos regionais. **Relatório 5**, MINISTERIO DO MEIO AMBIENTE - MMA, SECRETARIA DE BIODIVERSIDADE E FLORESTAS - SBF, DIRETORIA DE CONSERVACAO DA BIODIVERSIDADE - DCBio Mudanças Climáticas Globais e Efeitos sobre a Biodiversidade - Sub projeto:

Caracterização do clima atual e definição das alterações climáticas para o território brasileiro ao longo do Século XXI. Brasília, Fevereiro de 2007.

MARENGO, J. A.; JONES, R.; ALVES, L. M.; VALVERDE, M. C. Future change of temperature and precipitation extremes in South America as derived from the PRECIS regional climate modeling system. **International Journal of Climatology**, v. 29, p. 2241-2255, 2009.

MARSLAND, S. J.; HAAK, H.; JUNGCLAUS, J. H.; LATIF, M.; ROESKE, F. The Max-Planck-Institute global ocean/sea ice model with orthogonal curvilinear coordinates. **Ocean Modelling**, v. 5, p. 91-127, 2003.

MARIN, F. R.; SENTELHAS, P. C.; UNGARO, M. R. G. Perda de rendimento potencial da cultura do girassol por deficiência hídrica, no Estado de São Paulo. **Scientia Agrícola**, v.57, n.1, p.1-6, 2000.

MATZENAUER, R. Modelos agrometeorológicos para estimativa do rendimento de milho em função da disponibilidade hídrica no Estado do Rio Grande do Sul. Porto Alegre, 1994. 172p. **Tese (Doutorado)** - UFRGS, 1994.

MAUNEY, J. R. Floral initiation in upland cotton *Gossypium hirsutum* L. in response to temperatures. **Journal of Experimental Botany**, Oxford, v. 17, p. 452-459, 1966.

MEEK, D. W.; HATFIELD, J. L. Data quality checking for single station meteorological databases. **Agricultural and Forest Meteorology**, v. 69, p. 85-109, 1994.

MENEZES, H. E. A. Influência da Zona de Convergência Secundária do Atlântico Sul sobre a ocorrência de precipitação no leste do Nordeste brasileiro. **Tese de Doutorado - UFCG**, Campina Grande-PB, 103p. 2010.

MEYER, S. J. The development of a crop specific drought index for corn. Lincoln/USA, 165p. **Doctoral Dissertation**, University of Nebraska, 1990.

MINISTÉRIO DA INTEGRAÇÃO NACIONAL, 2013. Disponível em: Retrato da irrigação no Brasil, <<http://www.integracao.gov.br/>>. Acesso em: 01 nov. 2013.

MITCHELL, T. D.; HULME, M. Predicting regional climate change: living with uncertainty. **Progress in Physical Geography**, v.23, n. 1, p.57- 78, 1999.

MONTEIRO, J. E. B. A. Agrometeorologia dos Cultivos - o fator meteorológico na produção agrícola. 1. ed. Brasília-DF, **INMET-MAPA**, 2009.

MOURA, A. D.; SHUKLA, J. On the dynamics of droughts in northeast Brazil: Observations, theory and numerical experiments with a general circulation model. **Journal of the Atmospheric Science**, v. 38, p. 2653-2675, 1981.

MULLAN, D.J.; FAVIS-MORTLOCK, D.T.; FEALY, R. Addressing key limitations associated with modelling soil erosion under the impacts of future climate change. **Agricultural and Forest Meteorology**, v. 156, p. 18-30, 2012.

MURPHY, J. Predictions of climate change over Europe using statistical and dynamical downscaling techniques. **International Journal of Climatology**, v. 20, p. 489-501, 2000.

NAKICENOVIC, N.; ALCAMO, J.; DAVIS, G.; DE VRIES, B.; FENHANN, J.; GAFFIN, S.; GREGORY, K.; GRÜBLER, A.; JUNG, T. Y.; KRAM, T.; LA ROVERE, E. L.; MICHAELIS, L.; MORI, S.; MORITA, T.; PEPPER, W.; PITCHER, H.; PRICE, L.; RAIHI, K.; ROEHL, A.; ROGNER, H. H.; SANKOVSKI, A.; SCHLESINGER, M.; SHUKLA, P.; SMITH, S.; SWART, R.; VAN ROOIJEN, S.; VICTOR, N.; DADI, Z. IPCC: Special Report on Emissions Scenarios, **Cambridge University Press**, Cambridge, United Kingdom and New York, NY, USA, 2000.

PEDRO JUNIOR, M. J.; CAMARGO, M. B. P.; BRUNINI, O.; ALFONSI, R. R.; ORTOLANI, A. A.; MIRANDA, M. A. C. Teste de um modelo para estimativa da produção da soja. **In: Congresso Brasileiro de Agrometeorologia**, Anais da Sociedade Brasileira de Agrometeorologia, Campinas-SP, p.11-17, 1984.

PENMAN, H. L. Evaporation: Introduction survey. **Netherlands Journal of Agricultural Science**. v.4, n. 1, p.9- 29, 1956.

PRATES, J. E.; SEDYAMA, G. C.; VIEIRA, H. A. Clima e produção agrícola. **Informe Agropecuário**, Belo Horizonte-MG, v. 12, n. 138, p. 18 - 22, 1986.

PERKINS, S. E.; PITMAN, A. J.; HOLBROOK, N. J.; McANENEY, J. Evaluation of the AR4 climate models? simulated daily maximum temperature, minimum temperature and precipitation over Australia using Probability Density Functions. **Journal of Climate**, v. 20, p. 4356-4376, 2007.

RADDATZ T. J.; REICK, C. H.; KNORR , W.; KATTGE, J.; ROECKNER, E.; SCHNUR, R.; SCHNITZLER, K.-G.; WETZEL, P.; JUNGCLAUS, J. Will the tropical land biosphere dominate the climate-carbon cycle feedback during the twenty first century? **Climate Dynamics**, v. 29, p. 565-574, 2007.

RAJIC, M.; RAJIC, M. Influence of climate change to water deficit. **Proceedings of the 9th International Conference on Environmental Science and Technology**, Rhodes-Island-Greece, 2005.

REDDY, V. R.; BAKER, D. N.; HODGES, H. F. Temperature effect on cotton canopy growth, photosynthesis and respiration. **Agronomy Journal**. v. 83, p. 699–704, 1991.

ROSA, V. G. C.; MOREIRA. M. A.; RUDOFF, B. F. T.; ADAMI. M. Estimativa da produtividade de café com base em um modelo agrometeorológico espectral. **Pesquisa agropecuária brasileira.**, Brasília, v.45, n.12, p.1478-1488, 2010

RUBIN, D. B. Multiple Imputation for Nonresponse in Surveys. **John Wiley & Sons**, New York., 1987

SALASSIER, B.; SOARES, A. A.; MANTOVANI, E. C. Manual de Irrigação. **Editora UFV**, 625p, 8.ed, 2008.

SALVADOR, M. A.; SANTOS, L. S. F. C. Análise da Precipitação na Cidade de São Paulo no Período 1961-2009. **Revista Brasileira de Climatologia**, v. 7, p. 8-19, 2010.

SANTOS, R. S.; COSTA, L. C.; SEDYIAMA, G. C.; LEAL, B. G.; OLIVEIRA, R. A.; JUSTINO, F. B. Avaliação da relação seca/produtividade agrícola em cenários de mudanças climáticas. **Revista Brasileira de Meteorologia**, v. 26, n. 2, p. 313-321, 2011.

SCHAFFER, J. L.; GRAHAM, J. W. Missing data: our view of the state of the art. **Psychological Methods**, v.7, n.2, p.147 - 177, 2002.

SILVA, V. B. S.; KOUSKY, V. E.; SHI, W.; HIGGINS, R. W. An improved gridded historical daily precipitation analysis for Brazil. **Journal of Hydrometeorology**, v.8, p. 847-861, 2007.

SILVA, S. A.; LIMA, J. S. S; OLIVEIRA, R. B. Modelo agrometeorológico na estimativa da produtividade de duas variedades de café arábica considerando a variabilidade espacial. **Irriga**, Botucatu, v. 16, n. 1, p. 1-10, 2011.

SILVA, V. B. S.; KOUSKY, V. E.; SILVA, F. D. S.; SALVADOR, M. A.; ARAVEQUIA, J. A. The 2012 severe drought over Northeast Brazil. **Special Supplement to the Bulletin of the American Meteorological Society**, v. 94, No. 8, August 2013.

SILVA, V. B. S.; KOUSKY, V. E. The South American Monsoon System: Climatology and Variability, **Modern Climatology**, Dr Shih-Yu Wang (Ed.), ISBN: 978-953-51-0095-9, InTech, Available from: <http://www.intechopen.com/books/modern-climatology/the-south-american-monsoon-system-climatology-and-variability>, 2012.

SILVA, B. B. Estresse hídrico em algodoeiro herbáceo irrigado evidenciado pela termometria infravermelha. **DCA\CCTUFPPB**, Campina Grande-PB, 139p., 1994. (Tese de doutorado).

SHEFFIELD, J.; G. GOTETI.; WOOD, E. F. Development of a 50-yr high-resolution global dataset of meteorological forcings for land surface modeling. **Journal of Climate**, v.19, n.13, p.3088 - 3111, 2006.

SOLMAN, S. A., NUÑEZ, M. N., CABRÉ, M. F. Regional climate change experiments over southern South America. I: present climate. **Climate Dynamics**, v.30, n.5, p. 533-552, 2008.

SRES - Emissions Scenarios: A Special Report of IPCC Working Group III. **Published for the Intergovernmental Panel on Climate Change**, ISBN: 92-9169-113-5, 2010.

TEUTSCHBEIN, C., WETTERHALL, F.; SEIBERT, J. Evaluation of different downscaling techniques for hydrological climate-change impact studies at the catchment scale. **Climate Dynamics**, v. 37(9-10), p. 2087-2105, 2011.

TIMBAL, B.; DUFOUR, A.; MCAVANEY, B. An estimate of future climate change for western France using a statistical downscaling technique. **Climate Dynamics**, v. 20, p. 807-823, 2003.

TIMBAL, B.; JONES, D. A. Future projections of winter rainfall in southeast Australia using a statistical downscaling technique. **Climatic Change**, V. 86(1), P.165-187, 2008.

THORNTWAITE, G. W. An approach toward a rational classification of climate. **Geographycal Review**, New York, v.38, n.1, p.55-94. 1948.

TOYAMA, K. N.; NOGUEIRA JUNIOR, S. Demanda internacional do algodão. Relatório de Pesquisa ABIT/SINDITEXTIL. **Carta abit**, SP, 2000.

UPPALA, S., et al. The era-40 re-analysis. **Quarterly Journal of The Royal Meteorological Society**, v. 131 (612, PartB), p. 2961–3012, 2005.

VANNITSEM, S.; CHOMÉ, F. One-way nested regional climate simulations and domain size. **Journal of Climate**, v. 18, p. 229-233, 2005.

VAN BUUREN, S.; GROOTHUIS-OUDSHOORN, K. MICE: Multivariate Imputation by Chained Equations in R. **Journal of Statistical Software**, v. 45, n.3, p. 1-67, 2011.

VAN DEN DOOL, H. Searching for analogs, how long must we wait? **Tellus**, 46A, p. 314-324, 1994.

WILBY, R. L.; WIGLEY, T. M. L. Downscaling general circulation model output: a review of methods and limitations. **Progress in Physical Geography**, v. 21, n.4, p. 530-548, 1997.

WILBY, R. L. WIGLEY, T. M. L. Downscaling general circulation model output: A reappraisal of methods and limitations. In *Climate Prediction and Agriculture. Proceedings of the START/WMO International Workshop*, Washington, DC, pp. 39-68, 2000.

WILBY, R. L.; CHARLES, S. P.; ZORITA, E.; TIMBAL, B.; WHETTON, P.; MEARNES, L. O. Guidelines for use of climate scenarios developed from statistical downscaling methods. Available at: http://ipcc-ddc.cru.uea.ac.uk/guidelines/dgm_no2_v1_09_2004.pdf, 2004.

WILBY, R. L.; DAWSON, C. W. SDSM 4.1 - A decision support tool for the assessment of regional climate change impacts. **Environment Agency of England and Wales**, Nottingham, 2004.

WILBY, R. L.; DAWSON, C. W.; BARROW, E. M. SDSM - A decision support tool for the assessment of regional climate change impacts. **Environmental Modelling and Software**, v. 17, p. 147-159, 2002.

WILBY, R. L.; HARRIS, I. SDSM - A framework for assessing uncertainties in climate change impacts: low flow scenarios for the River Thames, UK. **Water Resources Research**, v. 42:W02419.1-W02419.10, 2006.

WILBY, R. L., DAWSON, C. W. User manual for SDSM 4.2, 2007

WILBY, R. L.; DAWSON, C. W. The Statistical DownScaling Model (SDSM): Insights from one decade of application. **International Journal of Climatology**, v. 33, p. 1707-1719, 2013.

WMO. Atmospheric RCMs: A multipurpose tool? Report of the joint WGNE/WGCM ad hoc panel on Regional. **Climate Modelling**, Geneva, Switzerland, 2002.

WMO. Guidelines on Climate Observation Networks and Systems. **WMO Technical Document**, Geneva, Switzerland, 2003.

YOU, J. K.; HUBBARD, G.; GODDARD, S. Comparison of methods for spatially estimating station temperatures in a quality control system. **International Journal of Climatology**, v. 28, p. 777-787, DOI: joc.1571, 2007.

ZORITA, E.; HUGHES, J. P.; LETTENMAIER, D. P.; VON STORCH, H. Stochastic characterization of regional circulation patterns for climate model diagnosis and estimation of local precipitation. **Journal of Climate**, v.8, p.1023-1042, 1995.

ZORITA, E.; VON STORCH, H. The analog method as a simple statistical downscaling technique: Comparison with more complicated methods. **Journal of Climate**, v. 12(n. 8, Part 2), p. 2474-2489, 1999.