



UNIVERSIDADE FEDERAL DE ALAGOAS
INSTITUTO DE CIÊNCIAS ATMOSFÉRICAS
PROGRAMA DE PÓS-GRADUAÇÃO EM METEOROLOGIA

**CLIMA E PRODUTIVIDADE DA CANA DE AÇUCAR NO LESTE DO
NORDESTE - PRESENTE E FUTURO**

LÍVIA PILAR MELO DE OLIVEIRA

MACEIÓ - AL

Julho de 2019

LÍVIA PILAR MELO DE OLIVEIRA

**CLIMA E PRODUTIVIDADE DA CANA DE AÇUCAR NO LESTE DO
NORDESTE - PRESENTE E FUTURO**

Área de concentração: **Micrometeorologia e Agrometeorologia**

Prof. Dr. Fabrício Daniel dos Santos Silva

(Orientador)

MACEIÓ - AL

Julho de 2019

Catlogação na fonte
Universidade Federal de Alagoas
Biblioteca Central
Divisão de Tratamento Técnico

Bibliotecária Responsável: Helena Cristina Pimentel do Vale – CRB-4 - 661

O48c Oliveira, Livia Pilar Melo de.

Clima e produtividade da cana-de -çúcar no leste do nordeste : presente e futuro / Livia Pilar Melo de Oliveira. – 2019.

76 f.. : il.

Orientador; Fabrício Daniel dos Santos Silva.

Dissertação (mestrado em Meteorologia) – Universidade Federal de Alagoas. Instituto de Ciências Atmosféricas. Maceió, 2019.

Bibliografia: p. 69-76.

1. Meteorologia agrícola. 2. Climatologia – Brasil, Nordeste. 3. Agrometeorologia. 4. Cana-de-açúcar – Produtividade. I. Título.

CDU: 551.58:631(812/813)



UNIVERSIDADE FEDERAL DE ALAGOAS
INSTITUTO DE CIÊNCIAS ATMOSFÉRICAS
COORDENAÇÃO DE PÓS-GRADUAÇÃO EM METEOROLOGIA

CERTIFICADO DE APRESENTAÇÃO

N.º de ordem: MET-UFAL-MS-162.

“CLIMA E PRODUTIVIDADE DA CANA DE AÇÚCAR NO LESTE DO
NORDESTE - PRESENTE E FUTURO .”

Livia Pilar Melo de Oliveira

Dissertação submetida ao colegiado do Curso de Pós-Graduação em Meteorologia da Universidade Federal de Alagoas - UFAL, como parte dos requisitos necessários à obtenção do grau de Mestre em Meteorologia.

Aprovado pela Banca Examinadora composta por:

Fabício Daniel dos Santos Silva

Prof. Dr. Fabício Daniel dos Santos Silva
(Orientador)

Heliofábio Barros Gomes

Prof. Dr. Heliofábio Barros Gomes
(Membro Interno)

Rafael Lisboa Costa

Dra. Rafael Lisboa Costa
(Membro Interno)

André Luiz de Carvalho

Prof. Dr. André Luiz de Carvalho
(Membro Externo)

Junho/2019

DEDICATÓRIA

Dedico primeiramente à Deus, que nos deu a dádiva da vida e a oportunidade de aprendizado, nos permitindo evoluir.

Aos meus pais, Ivonete e Paulo, que com muito esforço e dificuldades, me propiciaram a oportunidade de estudar e batalhar por conhecimento e evolução como ser humano. Obrigada por todos os ensinamentos morais.

À minha irmã Ivy, que sempre esteve presente ao meu lado.

Aos meus amigos de longa data e colegas de faculdade, obrigada pela parceria.

AGRADECIMENTOS

Agradeço primeiramente à Deus, só eu e Ele sabemos as dificuldades enfrentadas, obstáculos vencidos com muita perseverança e fé, acima de tudo.

Agradeço especialmente para minha mãe, que não me permite fraquejar e desistir em momento algum, sempre me aconselhando e me protegendo com seu amor e cuidados e acima de tudo, me incentivando a evoluir em todos os aspectos.

À minha família em geral, por sempre confiarem em mim.

Aos meus amigos, obrigada pelo companheirismo e amor.

Aos meus colegas de faculdade, obrigada por todos os momentos de parceria, pelos ensinamentos e incentivos.

Aos professores do ICAT, obrigada pelo ensinamento, pelas experiências, incentivo e paciência, acima de tudo.

Ao meu orientador, Fabrício Silva, meu agradecimento especial. Obrigada por aceitar em me orientar, primeiramente. Obrigada por todos ensinamentos, incentivo, auxílio, pela paciência e por sua parceria.

A todos que fizeram parte dessa caminhada de alguma forma, muito obrigada.

RESUMO

A cana de açúcar é a mais importante cultura agrícola do Estado de Alagoas e uma das principais no Nordeste brasileiro, com grande área plantada para a produção de etanol e açúcar. No cultivo da cana de açúcar a previsão a produtividade é realizada na ocasião que antecede a colheita dos canaviais e acontece muito mais de acordo com o conhecimento do executor ao invés de parâmetros estatísticos. Já na estimativa da produção é comum a utilização de modelos agrometeorológicos. O uso destes modelos permite a simulação de cultivos com sistemas de informações geográficas (GIS) e é uma importante ferramenta na avaliação do potencial produtivo. Neste trabalho, o modelo agrometeorológico proposto por Doorenbos e Kassam (1979) foi utilizado com o objetivo simular a produtividade da cultura da cana de açúcar para a região do leste do Nordeste brasileiro, no período de 2021 a 2080, utilizando cenários de mudanças climáticas futuras e confrontando os valores obtidos através das simulações com resultados já conhecidos de produtividade anual disponibilizados pelo IBGE (Instituto Brasileiro de Geografia e Estatística). Para atingir esse objetivo, foi utilizada a técnica de downscaling estatístico da precipitação e da evapotranspiração na região estudada a partir de observações de modelos climáticos globais para os cenários A1B e A2 do quarto relatório do IPCC (Intergovernmental Panel on Climate Change) e para os cenários RCP 4.5 e RCP 8.5 do quinto relatório. A área de estudo se estende entre os estados da Paraíba, Pernambuco e Recife, nas cidades de: João Pessoa, Recife, Maceió e Porto de Pedras, já que em conjunto concentram a maior produção de cana de açúcar da região Nordeste. Com a técnica do Downscaling Estatístico (DE), podemos obter informações de alta resolução para projeções climáticas a partir de MCGs. A calibração do modelo agrometeorológico foi satisfatória e conseguiu simular a produtividade média com valor próximo ao observado pelo IBGE no mesmo período. A destreza do modelo agrometeorológico foi obtida pela correlação de Pearson e pela raiz do erro quadrático médio (REQM). Após a calibração, o modelo foi utilizado para a simulação dos valores de produtividade da cultura para as cidades estudadas, para os cenários futuros. Apesar das simulações confirmarem a tendência da região para o aumento de temperatura e diminuição da precipitação, para todas as cidades e para a maioria dos MCGs e cenários, a projeção é de aumento na produtividade da cana de açúcar. Uma explicação para este resultado reside no fato de que, apesar da redução prevista para os meses mais chuvosos do ano no leste do Nordeste, os cenários projetam maior quantidade de chuvas para os meses mais secos do ano, o que traria uma melhor distribuição temporal ao longo do ano dos eventos de chuvas. Na cidade de Maceió (AL), por exemplo, esse aumento representa um crescimento de 8,81% da produtividade.

Palavras-Chave: Produtividade da cana de açúcar, modelo agrometeorológico, mudanças climáticas.

ABSTRACT

Sugarcane is the most important agricultural crop in the State of Alagoas and one of the main crops in the Brazilian Northeast, with a large area planted to produce ethanol and sugar. In sugarcane cultivation, productivity is predicted at the time that precedes the harvesting of cane fields, and much more happens according to the knowledge of the implementer rather than statistical parameters. In the estimation of production, the use of agrometeorological models is common. The use of these models allows the simulation of crops with geographic information systems (GIS) and is an important tool in the evaluation of productive potential. In this work, the agrometeorological model proposed by Doorenbos and Kassam (1979) was used to simulate the productivity of the sugarcane crop for the eastern region of the Northeast of Brazil, from 2021 to 2080, using future climate change scenarios and comparing the values obtained through the simulations with already known results of annual productivity provided by IBGE (Brazilian Institute of Geography and Statistics). In order to reach this objective, the technique of statistical downscaling of precipitation and evapotranspiration in the studied region was used from observations of global climate models for scenarios A1B and A2 of the fourth report of the Intergovernmental Panel on Climate Change (IPCC) and for scenarios RCP 4.5 and RCP 8.5 of the fifth report. The area of study extends between the states of Paraíba, Pernambuco and Recife, in the cities of: João Pessoa, Recife, Maceió and Porto de Pedras, since together they concentrate the largest sugarcane production in the Northeast region. With the Statistical Downscaling (DE) technique, we can obtain high resolution information for climate projections from MCGs. The calibration of the agrometeorological model was satisfactory and was able to simulate the average yield close to that observed by the IBGE in the same period. The dexterity of the agrometeorological model was obtained by Pearson correlation and root mean square error (REQM). After calibration, the model was used to simulate crop yield values for the cities studied for future scenarios. Although simulations confirm the region's tendency to increase temperature and decrease precipitation, for all cities and most MCGs and scenarios, the projection is for increased sugarcane productivity. One explanation for this result is that, despite the expected reduction in the wettest months of the year in the east of the Northeast, the scenarios project more rainfall for the driest months of the year, which would bring a better temporal distribution to the region. during the year of the rain events. In the city of Maceió (AL), for example, this increase represents an increase of 8.81% in productivity.

Keywords: Sugarcane yield, agrometeorological model, climatic changes

SUMÁRIO

1. INTRODUÇÃO	11
2. OBJETIVOS	13
2.1 OBJETIVO GERAL	13
2.2 OBJETIVOS ESPECÍFICOS	13
3. REVISÃO BIBLIOGRÁFICA	14
3.1 CLIMA E CULTIVO DA CANA DE AÇÚCA	14
3.2 MODELOS AGROMETEOROLÓGICOS	19
3.3 MODELOS CLIMÁTICOS GLOBAIS E CENÁRIOS DE MUDANÇAS CLIMÁTICAS	20
3.4 DOWNSCALING ESTATÍSTICO	23
4. DADOS E METODOLOGIA	24
4.1 ÁREA DE ESTUDO, DADOS METEOROLÓGICOS E DE PRODUTIVIDADE	24
4.2 MODELO DE SIMULAÇÃO DE PRODUTIVIDADE AGRÍCOLA	25
4.3 DOWNSCALING ESTATÍSTICO	27
4.3.1 SELEÇÃO DOS PREDITORES	28
4.3.2 SELEÇÃO DOS PEDITANDOS	29
4.3.3 SELEÇÃO DO MÉTODO DE DOWNSCALING ESTATÍSTICO	30
4.3.4 VALIDAÇÃO DO DOWNSCALING ESTATÍSTICO	31
5. RESULTADOS E DISCUSSÕES	33
5.1 CALIBRAÇÃO DA PRECIPITAÇÃO	33
5.1.2 CALIBRAÇÃO DA TEMPERATURA MÁXIMA	35
5.1.3 CALIBRAÇÃO DA TEMPERATURA MÍNIMA	38
5.2 VALIDAÇÃO DO DOWNSCALING DA PRECIPITAÇÃO	40
5.2.1 VALIDAÇÃO DO DOWNSCALING DA TEMPERATURA MÁXIMA	41
5.2.2 VALIDAÇÃO DO DOWNSCALING DA TEMPERATURA MÍNIMA	42
5.3 CALIBRAÇÃO E VALIDAÇÃO DO MODELO AGROMETEOROLÓGICO	43
5.4 COMPORTAMENTO DA PRECIPITAÇÃO, TEMPERATURA MÉDIA E ETP PARA OS CENÁRIOS FUTUROS DO AR4 CMIP 5	45
5.4.1 JOÃO PESSOA	45
5.4.2 RECIFE	47
5.4.3 PORTO DE PEDRAS	50
5.4.4 MACEIÓ	52
5.5 SIMULAÇÃO DE PRODUTIVIDADE DA CANA DE AÇÚCAR PARA CENÁRIOS FUTUROS	54
5.5.1 JOÃO PESSOA	54
5.5.2 RECIFE	58
5.5.3 PORTO DE PEDRAS	61
5.5.4 MACEIÓ	64
6 CONCLUSÕES	67
7 REFERÊNCIAS BIBLIOGRÁFICAS	69

LISTA DE FIGURAS

Figura 1: Mapeamento da cana de açúcar.....	14
Figura 2: Estágios fenológicos da cana-de-açúcar.....	16
Figura 3: Variação espacial da temperatura do ar, média anual, no Brasil, segundo as exigências térmicas da cana de açúcar	18
Figura 4: Forçante radiativa dos RCPs	22
Figura 5: Distribuição geográfica das estações meteorológicas convencionais de João Pessoa (PB), Recife (PE), Maceió e Porto de Pedras (AL) do INMET na região Nordeste	25
Figura 6: Detalhe dos preditores e grade utilizada para a precipitação da região Nordeste	29
Figura 7: Janela de criação de um preditor para as temperaturas máximas, mínimas e precipitação das estações do INMET	30
Figura 8: Comparação entre a climatologia observada e dos modelos estudados em cada cenário (lado esquerdo) X Comportamento dos dados observados comparados com o ENSEMBLE dos modelos (lado direito), para seus respectivos períodos da variável da precipitação na cidade de João Pessoa.....	33
Figura 9: Comparação entre a climatologia observada e dos modelos estudados em cada cenário (lado esquerdo) X Comportamento dos dados observados comparados com o ENSEMBLE dos modelos (lado direito), para seus respectivos períodos da variável da precipitação na cidade de Recife	34
Figura 10: Comparação entre a climatologia observada e dos modelos estudados em cada cenário (lado esquerdo) X Comportamento dos dados observados comparados com o ENSEMBLE dos modelos (lado direito), para seus respectivos períodos da variável da precipitação na cidade de Porto de Pedras	34
Figura 11: Comparação entre a climatologia observada e dos modelos estudados em cada cenário (lado esquerdo) X Comportamento dos dados observados comparados com o ENSEMBLE dos modelos (lado direito), para seus respectivos períodos da variável da precipitação na cidade de Maceió	35

Figura 12: Comparação entre a climatologia observada e dos modelos estudados em cada cenário (lado esquerdo) X Comportamento dos dados observados comparados com o ENSEMBLE dos modelos (lado direito), para seus respectivos períodos da variável da temperatura máxima na cidade de João Pessoa	36
Figura 13: Comparação entre a climatologia observada e dos modelos estudados em cada cenário (lado esquerdo) X Comportamento dos dados observados comparados com o ENSEMBLE dos modelos (lado direito), para seus respectivos períodos da variável da temperatura máxima na cidade de Recife	36
Figura 14: Comparação entre a climatologia observada e dos modelos estudados em cada cenário (lado esquerdo) X Comportamento dos dados observados comparados com o ENSEMBLE dos modelos (lado direito), para seus respectivos períodos da variável da temperatura máxima na cidade de Porto de Pedras	37
Figura 15: Comparação entre a climatologia observada e dos modelos estudados em cada cenário (lado esquerdo) X Comportamento dos dados observados comparados com o ENSEMBLE dos modelos (lado direito), para seus respectivos períodos da variável da temperatura máxima na cidade de Maceió	37
Figura 16: Comparação entre a climatologia observada e dos modelos estudados em cada cenário (lado esquerdo) X Comportamento dos dados observados comparados com o ENSEMBLE dos modelos (lado direito), para seus respectivos períodos da variável da temperatura mínima na cidade de João Pessoa	38
Figura 17: Comparação entre a climatologia observada e dos modelos estudados em cada cenário (lado esquerdo) X Comportamento dos dados observados comparados com o ENSEMBLE dos modelos (lado direito), para seus respectivos períodos da variável da temperatura mínima na cidade de Recife	39
Figura 18: Comparação entre a climatologia observada e dos modelos estudados em cada cenário (lado esquerdo) X Comportamento dos dados observados comparados com o ENSEMBLE dos modelos (lado direito), para seus respectivos períodos da variável da temperatura mínima na cidade de Porto de Pedras	39
Figura 19: Comparação entre a climatologia observada e dos modelos estudados em cada cenário (lado esquerdo) X Comportamento dos dados observados comparados com o ENSEMBLE dos modelos (lado direito), para seus respectivos períodos da variável da temperatura mínima na cidade de Maceió	40
Figura 20: Comparação gráfica da produtividade observada pelo IBGE e simulada com o modelo agrometeorológico, para Maceió em 20 anos (1996 a 2015)	44

Figura 21: Comparativo entre valores médios obtidos através do IBGE, modelo agrometeorológico observado e modelo agrometeorológico com cenário de mudança climática	44
Figura 22: Comportamento da precipitação nos cenários A1B e A2 para a cidade de João Pessoa, nas séries temporais estudadas contrastadas com o período de observação	45
Figura 23: Comportamento da temperatura média nos cenários A1B e A2 para a cidade de João Pessoa, nas séries temporais estudadas contrastadas com o período de observação.....	46
Figura 24: Comportamento da ETP nos cenários A1B e A2 para a cidade de João Pessoa, nas séries temporais estudadas contrastadas com o período de observação	46
Figura 25: Comportamento da precipitação nos cenários RCP 4.5 e RCP 8.5 para a cidade de João Pessoa, nas séries temporais estudadas contrastadas com o período de observação.....	46
Figura 26: Comportamento da temperatura média nos cenários RCP 4.5 e RCP 8.5 para a cidade de João Pessoa, nas séries temporais estudadas contrastadas com o período de observação	47
Figura 27: Comportamento da ETP nos cenários RCP 4.5 e RCP 8.5 para a cidade de João Pessoa, nas séries temporais estudadas contrastadas com o período de observação.....	47
Figura 28: Comportamento da precipitação nos cenários A1B e A2 para a cidade de Recife, nas séries temporais estudadas contrastadas com o período de observação	48
Figura 29: Comportamento da temperatura média nos cenários A1B e A2 para a cidade de Recife, nas séries temporais estudadas contrastadas com o período de observação.....	48
Figura 30: Comportamento da ETP nos cenários A1B e A2 para a cidade de Recife, nas séries temporais estudadas contrastadas com o período de observação	48
Figura 31: Comportamento da precipitação nos cenários RCP 4.5 e RCP 8.5 para a cidade de Recife, nas séries temporais estudadas contrastadas com o período de observação	49
Figura 32: Comportamento da temperatura média nos cenários RCP 4.5 e RCP 8.5 para a cidade de Recife, nas séries temporais estudadas contrastadas com o período de observação	49
Figura 33: Comportamento da ETP nos cenários RCP 4.5 e RCP 8.5 para a cidade de Recife, nas séries temporais estudadas contrastadas com o período de observação	49

Figura 34: Comportamento da precipitação nos cenários A1B e A2 para a cidade de Porto de Pedras, nas séries temporais estudadas contrastadas com o período de observação	50
Figura 35: Comportamento da temperatura média nos cenários A1B e A2 para a cidade de Porto de Pedras, nas séries temporais estudadas contrastadas com o período de observação.....	50
Figura 36: Comportamento da ETP nos cenários A1B e A2 para a cidade de Porto de Pedras, nas séries temporais estudadas contrastadas com o período de observação.....	51
Figura 37: Comportamento da precipitação nos cenários RCP 4.5 e RCP 8.5 para a cidade de Porto de Pedras, nas séries temporais estudadas contrastadas com o período de observação	51
Figura 38: Comportamento da temperatura média nos cenários RCP 4.5 e RCP 8.5 para a cidade de Recife, nas séries temporais estudadas contrastadas com o período de observação	51
Figura 39: Comportamento da ETP nos cenários RCP 4.5 e RCP 8.5 para a cidade de Recife, nas séries temporais estudadas contrastadas com o período de observação	52
Figura 40: Comportamento da precipitação nos cenários A1B e A2 para a cidade de Maceió, nas séries temporais estudadas contrastadas com o período de observação	52
Figura 41: Comportamento da temperatura média nos cenários A1B e A2 para a cidade de Maceió, nas séries temporais estudadas contrastadas com o período de observação	53
Figura 42: Comportamento da ETP nos cenários A1B e A2 para a cidade de Maceió, nas séries temporais estudadas contrastadas com o período de observação	53
Figura 43: Comportamento da precipitação nos cenários RCP 4.5 e RCP 8.5 para a cidade de Maceió, nas séries temporais estudadas contrastadas com o período de observação	53
Figura 44: Comportamento da temperatura média nos cenários RCP 4.5 e RCP 8.5 para a cidade de Maceió, nas séries temporais estudadas contrastadas com o período de observação.....	54
Figura 45: Comportamento da ETP nos cenários RCP 4.5 e RCP 8.5 para a cidade de Maceió, nas séries temporais estudadas contrastadas com o período de observação	54
Figura 46: Produtividade média prevista para a cana de açúcar em João Pessoa, no cenário A1B no período de 2021 – 2080	55

Figura 47: Produtividade média prevista para a cana de açúcar em João Pessoa, no cenário A2 no período de 2021 – 2080	56
Figura 48: Produtividade média prevista para a cana de açúcar em João Pessoa, no cenário RCP 4.5 no período de 2021 – 2080	56
Figura 49: Produtividade média prevista para a cana de açúcar em João Pessoa, no cenário RCP 8.5 no período de 2021 – 2080	57
Figura 50: Produtividade média prevista para a cana de açúcar em João Pessoa, para o ENSEMBLE dos modelos de todos os cenários estudados no período de 2021 - 2080	57
Figura 51: Produtividade média prevista para a cana de açúcar em Recife, no cenário A1B no período de 2021 – 2080	58
Figura 52: Produtividade média prevista para a cana de açúcar em Recife, no cenário A2 no período de 2021 – 2080	59
Figura 53: Produtividade média prevista para a cana de açúcar em Recife, no cenário RCP 4.5 no período de 2021 – 2080	59
Figura 54: Produtividade média prevista para a cana de açúcar em Recife, no cenário RCP 8.5 no período de 2021 – 2080	60
Figura 55: Produtividade média prevista para a cana de açúcar em Recife, para o ENSEMBLE dos modelos de todos os cenários estudados no período de 2021 – 2080	60
Figura 56: Produtividade média prevista para a cana de açúcar em Porto de Pedras, no cenário A1B no período de 2021 – 2080	61
Figura 57: Produtividade média prevista para a cana de açúcar em Porto de Pedras, no cenário A2 no período de 2021 – 2080	62
Figura 58: Produtividade média prevista para a cana de açúcar em Porto de Pedras, no cenário RCP 4.5 no período de 2021 – 2080	62
Figura 59: Produtividade média prevista para a cana de açúcar em Porto de Pedras, no cenário RCP 8.5 no período de 2021 – 2080	63
Figura 60: Produtividade média prevista para a cana de açúcar em Porto de Pedras, para o ENSEMBLE dos modelos de todos os cenários estudados no período de 2021 – 2080	63
Figura 61: Produtividade média prevista para a cana de açúcar em Maceió, no cenário A1B no período de 2021 – 2080	64

Figura 62: Produtividade média prevista para a cana de açúcar em Maceió, no cenário A2 no período de 2021 – 2080	65
Figura 63: Produtividade média prevista para a cana de açúcar em Maceió, no cenário RCP 4.5 no período de 2021 – 2080	65
Figura 64: Produtividade média prevista para a cana de açúcar em Maceió, no cenário RCP 8.5 no período de 2021 – 2080	66
Figura 65: Produtividade média prevista para a cana de açúcar em Maceió para o ENSEMBLE dos modelos de todos os cenários estudados no período de 2021 – 2080	66

LISTA DE TABELAS

Tabela 1. Condições hídricas nos períodos de desenvolvimento e colheita da cana de açúcar da safra 2016/17.....	15
Tabela 2. Número de dias em cada fase e no ciclo da cana, coeficiente de cultura (kc) e fator de resposta ao déficit hídrico (ky) usado para estimar Yr	26
Tabela 3. Descrição das variáveis, níveis de altura e unidades do conjunto de parâmetros disponíveis para seleção de preditores.....	28
Tabela 4. Análise do cenário AR4 da variável precipitação para a validação do downscaling ..	40
Tabela 5: Análise do cenário CMIP5 da variável precipitação para a validação do downscaling	40
Tabela 6: Análise do cenário Ar4 da variável temperatura máxima para a validação do downscaling.....	41
Tabela 7: Análise do cenário CMIP5 da variável temperatura máxima para a validação do downscaling	41
Tabela 8: Análise do cenário AR4 da variável temperatura mínima para a validação do downscaling	41
Tabela 9: Análise do cenário CMIP5 da variável temperatura mínima para a validação do downscaling	42
Tabela 10: Valores de produtividade média obtidos no período de 2021 a 2080, com cenário de mudanças climáticas A1B e A2, confrontado com valores observados pelo IBGE no período	

LISTA DE SIGLAS E ABREVIATURA

AR4	Quarto Relatório de Avaliação do Painel Intergovernamental sobre mudanças climáticas
AZM	Modelo da Zona Agrometeorológica
CC	Teor de Água Colhida da Planta
CONAB	Companhia Brasileira de Abastecimento
CMIP5	Quinto Relatório de Avaliação do Painel Intergovernamental sobre mudanças climáticas
Ciaf	Coeficiente de Área Foliar
Cic	Coeficiente de Manutenção da Taxa de Respiração
Cresp	Coeficiente de Respiração
Cwc	Coeficiente de Teor de Água nos Caules
DE	Downscaling Estatístico
ETP	Evapotranspiração
FAO	Organização das Nações Unidas para a Alimentação e Agricultura
FB	Taxa Fotossintética
GIS	Sistema de Informações Geográficas
IBGE	Instituto Brasileiro de Geografia e Estatística
INMET	Instituto Nacional de Meteorologia
INSOL	Insolação
IPCC	Painel Intergovernamental de Mudanças Climáticas
Kc	Coeficiente da cultura
Ky	Coeficiente de penalização hídrica

MCGs	Modelos Climáticos Globais
PBMC	Painel Brasileiro de Mudanças Climáticas
PREC	Precipitação
RCP	Caminhos Representativos de Concentrações
REQM	Erro Quadrático Médio
SIDRA	Sistema IBGE de Recuperação Automática
TM	Temperatura Média
TN	Temperatura Mínima
TX	Temperatura Máxima
Yp	Rendimento Potencial
Yr	Rendimento Real

1. INTRODUÇÃO

A agricultura é a atividade econômica mais dependente das condições climáticas. Hoogenboom (2000) cita que de acordo com Fageria (1992) ao redor do 80% da variabilidade da produção agrícola no mundo devem-se à variabilidade das condições meteorológicas durante o ciclo do cultivo, especialmente para as culturas de sequeiro, já que os agricultores não podem exercer nenhum controle sobre tais fenômenos naturais.

A diversidade de clima e solos em que é cultivada e a escolha da melhor variedade adaptada ao melhor ambiente de produção são aspectos decisivos para conseguir o melhor retorno econômico no ciclo produtivo (UNICA, 2012). Existe diferença entre estimativa e previsão feitas pelos modelos. A estimativa é feita com dados históricos e representa uma condição atual (CARRIERO et al., 2009). Já a previsão é a estimativa feita para o futuro, ou seja, com dados disponíveis atuais simular uma condição futura (CLEMENTS; GALVÃO, 2013).

No cultivo da cana-de-açúcar a previsão da produtividade é realizada na ocasião que antecede a colheita dos canaviais, o método utilizado é baseado na experiência do executor, que percorrendo as áreas e baseando-se em históricos e na sua percepção, realiza a previsão sem parâmetros estatísticos (SCHIMIDT et al., 2001).

Há também como estimar a produção através de modelos agrometeorológicos. O uso de modelos de simulação de cultivos com sistemas de informação (GIS) tornou-se uma importante ferramenta para avaliar o potencial produtivo da cana em diferentes regiões (MONTEIRO, 2013). Segundo Jank (2010), em torno de 18% da energia consumida no Brasil é proveniente do etanol da cana de açúcar, a colocando como a segunda fonte de energia brasileira, atrás apenas dos derivados de petróleo e como a principal fonte de energia renovável do País. Esta eficiência produtiva é devida às ótimas condições climáticas que a cana de açúcar encontra no Brasil, tornando-o o maior produtor mundial desta commodity agrícola.

Neste contexto, Modelos Climáticos Globais (MCGs), vem sendo desenvolvidos e melhorados com o intuito de gerar projeções factíveis do clima futuro, baseado no panorama atual de tendências de emissões de gases de efeito estufa, para cenários que sejam favoráveis à estabilização/redução das emissões, assim como para cenários caóticos onde a população mundial intensificará o uso de combustíveis fósseis, principalmente, sem nenhum esforço de controle. Estes cenários são atualizados para melhorar a compreensão do que pode acontecer com o clima futuro de acordo com a influência antrópica no clima atual, de acordo

com vários parâmetros ambientais compilados pela equipe do Painel Intergovernamental sobre Mudanças Climáticas (IPCC), que investiga as alterações climáticas em curso no planeta (SILVA, 2013). Para a região Nordeste do Brasil, estudos recentes (MARENGO et al., 2009; SALES et al, 2015; NOBREGA et al., 2015; GUIMARÃES et al., 2016) 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. 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, assim como aumentando a demanda por água em cultivos irrigados (SALVIANO et al., 2016).

Esta pesquisa tem como objetivo gerar cenários climáticos futuros e avaliar os impactos na produtividade da cana de açúcar através de um modelo agrometeorológico, para o horizonte 2001-2100, balizados pela comparação com a produtividade anual a partir de dados climatológicos observados e de produção disponibilizados pelo IBGE (Instituto Brasileiro de Geografia e Estatística).

Um estudo detalhado das recentes alterações climáticas na região Nordeste, no tocante as variáveis precipitação e ETP, assim como, de posse de cenários futuros de mudanças climáticas, permitirão analisar o grau de magnitude que estas mudanças afetarão a região Nordeste, possibilitando avaliar o grau de risco associado ao cultivo da cultura da cana de açúcar. Nesse contexto, a presente pesquisa foi desenvolvida no sentido de alcançar os seguintes objetivos:

2 OBJETIVOS

2.1 OBJETIVO GERAL

Gerar cenários climáticos futuros e avaliar os impactos na produtividade da cana de açúcar através de um modelo agrometeorológico, comparando com a produtividade anual observada em um período de referência.

2.2 OBJETIVOS ESPECÍFICOS

1. Validar um modelo agrometeorológico de penalização por déficit hídrico aplicado à cultura da cana de açúcar;
2. Validar o downscaling estatístico da precipitação e ETP para o leste do Nordeste brasileiro, a partir de previsões de modelos climáticos globais, para dois cenários diferentes futuros de emissão de CO₂: A1B e A2 do quarto relatório do IPCC, e rcp8.5 e rcp4.5 do quinto relatório do IPCC;
3. Comparar os resultados da produtividade real observada do período 2001-2015 com a gerada a partir dos cenários de mudanças climáticas.
4. Analisar cenários futuros de produtividade da cana de açúcar no Nordeste do Brasil, período 2021-2080.

3. REVISÃO BIBLIOGRÁFICA

3.1 - CLIMA E CULTIVO DA CANA DE AÇÚCAR NA REGIÃO NORDESTE DO BRASIL

A cana de açúcar encontrou no leste do Nordeste brasileiro condições de solo e climáticas extremamente favoráveis, que juntamente a outros Estados produtores, principalmente do sudeste e centro-oeste, fazem do Brasil o maior produtor desta cultura do mundo, seguida pela Índia, China e Tailândia. Na safra de 2018-2019, o Brasil produziu cerca de 620,44 milhões de toneladas de cana de açúcar, o açúcar atingiu 29,04 milhões de toneladas e o etanol 33,14 bilhões de litros (CONAB,2019).

Os três Estados do Nordeste onde se dá a maior produção da cana de açúcar são em Alagoas, Pernambuco e Paraíba, em áreas que se estendem do litoral até aproximadamente 50 a 150km em direção ao interior destes estados conforme a Figura 1. Nas regiões semiáridas destes Estados a cana de açúcar não é cultivada devido suas exigências edafoclimáticas.

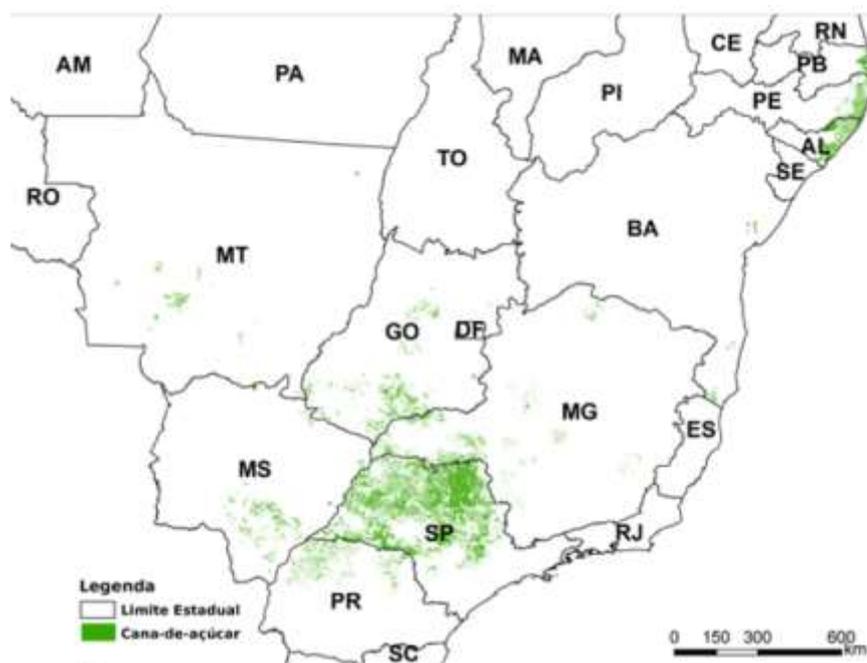


Figura 1: Mapeamento da cana de açúcar. Fonte: Conab (2017).

Assim como na maior parte da região, a economia agrícola no leste do Nordeste também é seriamente afetada por adversidades climáticas, principalmente associadas às

secas frequentes (BARBOSA; KUMAR., 2016). Silva *et al.* (2013), mostraram a influência do oceano atlântico na severa seca do ano de 2012, associada a intensidade do fenômeno oceânico-atmosférico conhecido como Dipolo do Atlântico.

Em diferentes estágios do estresse térmico, quase todos os estágios da vida das plantas são afetados pelo estresse térmico. Os efeitos dos danos causados pelo calor são mais sutis do que os do frio extremo, que matam uma planta instantaneamente. Estresse térmico pode aparecer em muitas formas e podem ser confundidos com outros tipos de estresse. Refinando a distribuição espacial da zona de calor da planta bem como identificar melhor os limiares de tolerância ao calor das plantas permitirá aos agricultores prever com mais precisão quais plantas podem sobreviver aos verões quentes (ZYDI TEQJA et al, 2018).

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), distúrbios ondulatórios dos ventos alísios (GOMES *et al.*, 2015) e a Oscilação de Madden-Julian (KOUSKY e KAYANO, 1994). Esta dinâmica climática modula as variações sazonais e interanuais em todo o Nordeste, desde o semiárido, aos litorais norte e leste do Nordeste, onde o calendário agrícola deve se enquadrar rigorosamente no período climatológico de máxima ocorrência de chuvas a fim de minimizar o risco de perdas das safras agrícolas.

Há duas formas de plantio da cana de açúcar (SEGATO et al., 2006), conhecidas como sistema de cana-de-ano e sistema de cana-de-ano-e-meio. Esta pesquisa será trabalhada para um ciclo de vida 360 dias, relativa a cana-de-ano. Segundo a CONAB, em suas diretrizes de calendário agrícola, nos Estados da Paraíba, Pernambuco e Alagoas, a cana deve ser plantada em meados de setembro, mais precisamente no segundo decêndio do mês (Tabela 1). Isto se dá porque a cana vegeta ativamente por cerca de 8 meses, ocorrendo o processo de maturação nos 4 meses finais. Assim, o canavial apresenta máxima taxa de crescimento entre novembro e abril, em virtude do longo fotoperíodo, da alta temperatura e da maior disponibilidade hídrica. Segundo Segato et al. (2006), em ambos os sistemas de produção, para que o canavial possa aproveitar, ao máximo, as condições favoráveis de fotoperíodo, temperatura e chuva do verão, é importante que o

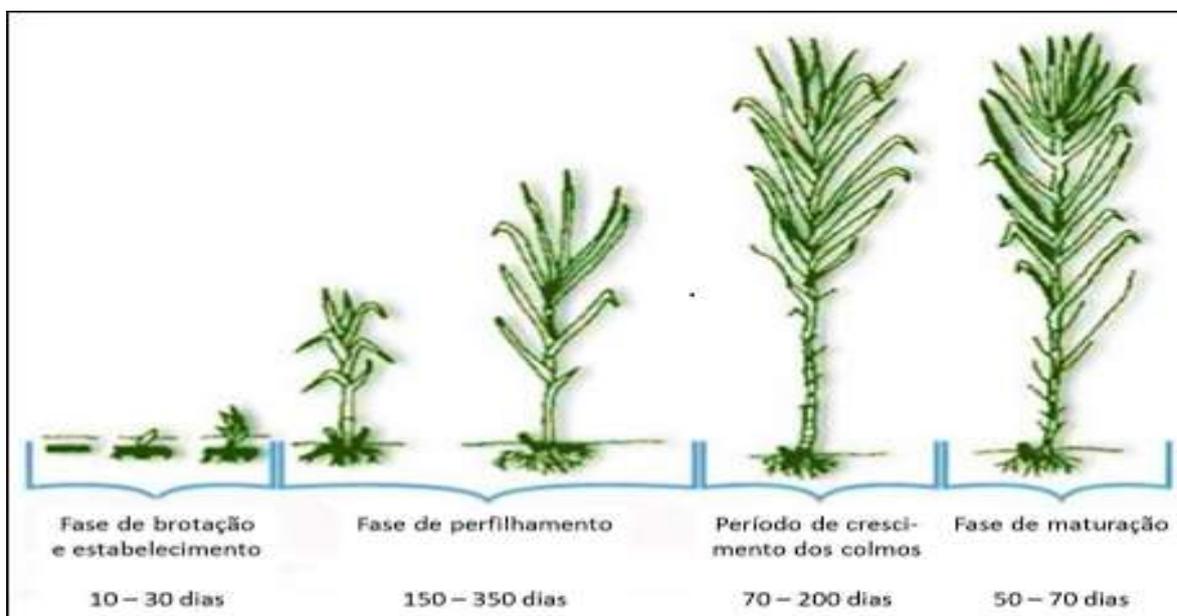
sistema radicular já esteja desenvolvido e que as plantas contem com pelo menos 12 folhas (MONTEIRO, 2009).



Tabela 1: Condições hídricas nos períodos de desenvolvimento e colheita da cana de açúcar da safra 2016/17. Fonte: Conab.

Segundo Câmara (1993), o ciclo da cana de açúcar pode ser dividido em quatro fases características: brotação e emergência, estabelecimento e perfilhamento, crescimento intenso e maturação (Figura 2).

Figura 2: Estágios fenológicos da cana-de-açúcar. Adaptado de Doorembo e Kassan (1979) e Gasho e Shih (1983).



A chuva age indiretamente, afetando o crescimento, o desenvolvimento das culturas e a disponibilidade hídrica dos solos, que tem influência direta na absorção de

água pelas raízes e o status hídrico da cultura (HOOGENBOOM, 2000). Períodos de secas e períodos de excesso de chuvas afetam a produtividade da cultura, comprometendo sua fotossíntese e atividades radiculares e absorção de águas e nutrientes pela planta.

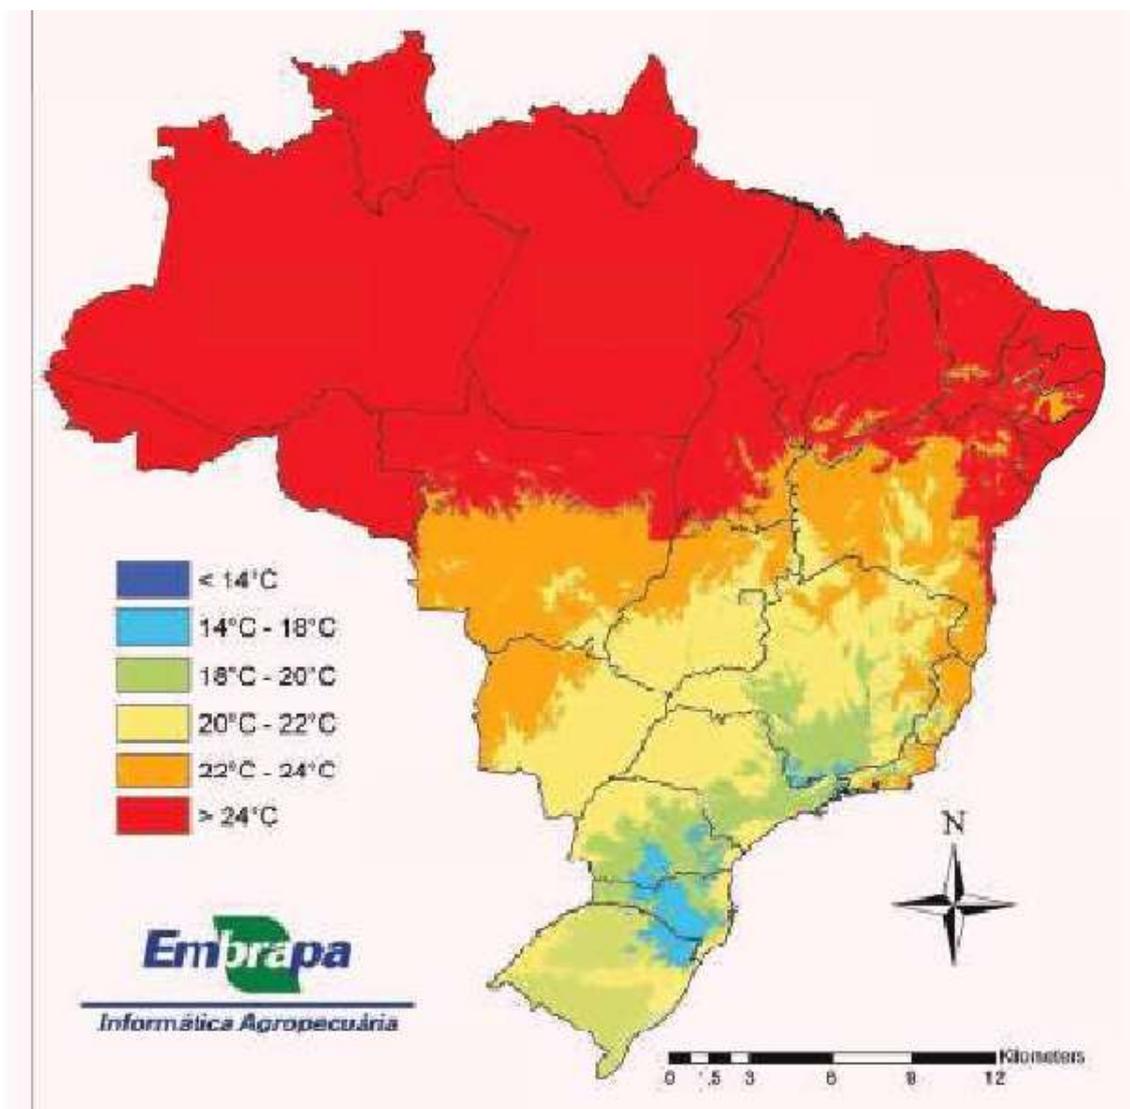
O consumo hídrico médio exigido pela cana de açúcar é em torno de 1500mm ao longo do ciclo da cultura, em meio logicamente a uma grande variabilidade desta exigência para diferentes cultivares (PEREZ, 1988; INMAN-BAMBER e McGLINCHEY, 2003; SANTOS, 2005). De acordo com Santos (2005), o consumo de água da cultura da cana-de-açúcar varia em função do ciclo (cana de ano ou de ano e meio), do estágio de desenvolvimento, das condições climáticas, da água disponível no solo e das variedades.

Com relação a deficiência hídrica, pode-se tomar como valores referenciais os apresentados em Doorembos e Kassan (1979) para o fator de resposta à deficiência hídrica (ky), igual a 0,75 nas fases de emergência e estabelecimento, caindo para 0,5 durante a fase de desenvolvimento da cultura, atingindo apenas 0,1 durante a maturação. Segundo Ramesh (2000), as fases de estabelecimento e desenvolvimento da cultura são as mais sensíveis à deficiência hídrica.

As principais variáveis meteorológicas que afetam a cultura de modo geral, como seu crescimento, desenvolvimento e produtividade são a chuva, temperatura do ar e radiação solar (HOOGENBOOM, 2000; PEREIRA et al., 2002; MAVI E TUPPER, 2004)

A faixa ótima média de temperaturas para a cana é de 23 a 32°C (FAUCONIER e BASSEREAU, 1970), variando de acordo com as diferentes fases fenológicas da cultura. Vários autores convergem em definir que abaixo de 20°C ocorre expressiva queda na taxa de crescimento, crescimento máximo ocorre entre 30 e 34°C, a partir de 35°C a planta apresentará estresse por calor, e interromperá seu crescimento para temperaturas a partir dos 38°C. Esta interrupção do crescimento também ocorrerá se a planta experimentar por determinado tempo temperaturas inferiores a valores entre 16°C e 18°C, (VILLA NOVA, 1977; DOOREMBOS; KASSAN, 1979; MAGALHÃES, 1987; BARBIERI et al., 1979). Na figura 3 temos a variação espacial da temperatura do ar média anual no Brasil, com as exigências térmicas da cana de açúcar.

Figura 3: Variação espacial da temperatura do ar, média anual, no Brasil, segundo as exigências térmicas da cana de açúcar. Fonte: Monteiro, J.E.B.A, 2009. Embrapa.



Em relação a radiação solar, a cana de açúcar atingirá seu máximo desenvolvimento sob condições de abundância desta variável, associadas a elevada disponibilidade de água e temperaturas elevadas. Seu desenvolvimento também é condicionado pelo fotoperíodo, com valores ideais entre 10 e 14 horas (RODRIGUES, 1985).

No Brasil, a atividade da cana de açúcar provavelmente se beneficiará com o aumento da temperatura do ar, dobrando a quantidade de área adequada para o plantio em todo o país. O cultivo dessa cultura será ampliado na região sul, que hoje sofre restrições devido às baixas temperaturas e que terá grande potencial de produção em um futuro próximo (PINTO HS et al, 2008; MARIN FR et al, 2013).

3.2 - MODELOS AGROMETEOROLÓGICOS

Modelos agrometeorológicos são usados para estimar/simular a produtividade das culturas, desempenhando um papel notável no auxílio à compreensão do desenvolvimento vegetal e sua relação com clima e solo, por meio de equações dedicadas a representar o crescimento das plantas. Com o apoio computacional, a modelagem tornou-se uma ferramenta de extrema importância na compreensão do funcionamento dos fenômenos biológicos e físicos no sistema agrícola, dando suporte a solução de problemas que excedem a capacidade de síntese do cérebro humano.

Se baseiam na interação estatística entre variáveis dependentes que serão estimadas (a exemplo da produtividade da cana de açúcar) e variáveis meteorológicas, como: precipitação, evapotranspiração, temperatura média do ar, através de uma regressão linear múltipla (MOREIRA, 2008)

Um modelo agrometeorológico muito 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, relacionando a perda de rendimento de culturas com o déficit hídrico, sendo comumente utilizado para gerar estimativas de perdas. Pereira et al., (2002) destacam que o modelo da FAO foi utilizado em vários locais ao redor do mundo devido as suas principais vantagens, que consistem em sua simplicidade e precisão, quando devidamente calibrado para a cultura e região a ser estudada.

Para a cana-de-açúcar, os modelos mecanicistas mais utilizados são o DSSAT/CANEGRO (Inman-Bamber 1991) e APSIM-Sugarcane (Keating et al. 1999). Esses modelos são altamente complexo e usa vários índices e coeficientes que precisa de calibração para simular todos os processos envolvidos crescimento e desenvolvimento da cana, rendimento e qualidade (MONTEIRO; CENTELHAS, 2014). Uma alternativa a exigência de informações destes modelos é justamente o tipo de modelo proposto por Doorenbos e Kassam (1979), também do tipo mecanístico, capaz de simular um ou mais fenômenos relativos a produtividade das culturas. Este modelo tem dois módulos principais, o modelo de Zona Agroecológica para estimar a produtividade potencial (Y_p), e o modelo de penalização por déficit hídrico para estimar o rendimento real (Y_a).

Por sua simplicidade e precisão, com resultados confiáveis, sua aplicação é largamente empregada em diversas partes do mundo e a uma gama de culturas de ciclo bem definidos. No Brasil, pode-se mencionar Dourado Neto *et al.*, (2004) em estudos para o milho no Rio Grande do Sul, Assad *et al.*, (2007) para previsão da safra de soja em diferentes Estados brasileiros, a citar Rio Grande do Sul, Santa Catarina, Mato Grosso do Sul, Maranhão, Piauí e Bahia. Os efeitos do clima na produtividade do milho no Rio Grande do Sul 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. Rosa *et al.*, (2010) usou este modelo alimentando-o com informações de sensoriamento remoto e modelagem atmosférica para estimar a produtividade do café. Para o cenário de mudanças climáticas A1B do quarto relatório do IPCC, Santos *et al.*, (2011) estimaram a produtividade do milho em diferentes mesorregiões do Estado de Minas Gerais. Além disso, Martin *et al.*, (2007), demonstrou a importância deste modelo para avaliar diferentes estratégias de irrigação. Monteiro e Sentelhas (2014) associaram este modelo a um sistema de informações geográficas para determinar a variabilidade espacial e temporal da produtividade da cana-de-açúcar no sudeste do Brasil.

Gouveia *et al.*, (2009) e Oliveira *et al.*, (2012) mostram que o modelo FAO pode produzir dados confiáveis em comparação com os rendimentos de cana de açúcar observados em nível regional.

3.3 - MODELOS CLIMÁTICOS GLOBAIS E CENÁRIOS DE MUDANÇAS CLIMÁTICAS

Modelos Climáticos Globais (MCGs) buscam simular as condições climáticas baseados nas propriedades físicas dos fluidos principais, atmosfera e oceano, de modo a contemplar de maneira satisfatória as características médias do clima em todo o planeta, para diversas sub-camadas atmosféricas desde a superfície. A demanda computacional destes modelos é extensa pela complexidade das equações matemáticas. Para esta representação do clima global, características importantes de escala sub-grade podem

estar mal representadas, a exemplificar tempestades associadas a nuvens isoladas e efeitos de 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).

Os MCGs evoluíram muito ao longo das últimas décadas (VANNITSEM e CHOME, 2005), passando a incorporar dados relativos as emissões de gases de efeito estufa para atender a demanda do IPCC (*Intergovernmental Panel on Climate Change*) e gerar projeções do clima futuro, em horizontes que podem ultrapassar o final do século XXI (JONES *et al.*, 2004).

Estas projeções futuras são realizadas de acordo com cenários de mudanças climáticas concebidos pelo IPCC no que concerne aos mais prováveis padrões de evolução da humanidade no consumo dos combustíveis fósseis e emissões de gás carbônico, monóxido de carbono, óxido nitroso, dióxido de enxofre, metano, entre outros gases (MITCHELL; HULME, 1999; NAKICENOVIC *et al.*, 2000).

No quarto relatório do IPCC lançado em 2007, os cenários foram divididos em duas grandes famílias, conhecidos como A (A1, A1FI, A1T e A1B) e B (B1 e B2). A família A continha os cenários considerados de realistas a pessimistas, e a família B os cenários otimistas (SRES, 2010). O cenário A1 representa um futuro de rápido crescimento econômico, crescimento populacional lento tendendo a estabilização e introdução de tecnologias mais eficientes para o uso de energia renováveis. Este cenário de dividia em três subcenários: com o uso intensivo de combustíveis fósseis (A1FI), fontes não fósseis (A1T) ou um equilíbrio entre as fontes (A1B), este último considerado o mais provável (SRES, 2010). O cenário A2 retrata um mundo heterogêneo, com alto índice populacional e rápido crescimento econômico, e uso incessante e crescente de combustíveis fósseis (SRES, 2010).

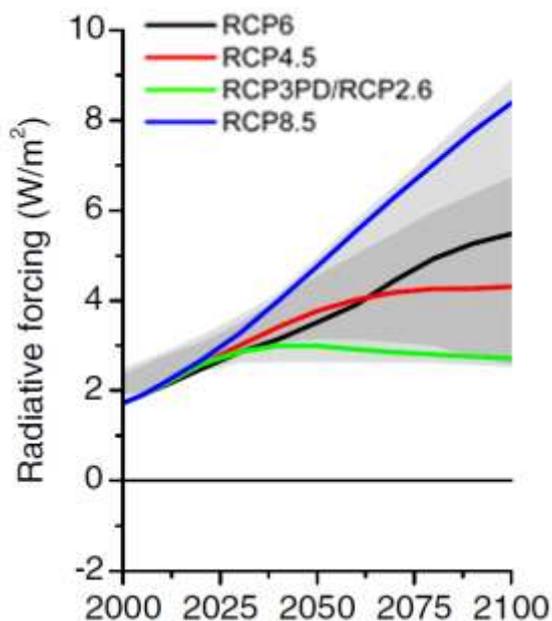
A nova família de cenários foi lançada em 2014 no quinto relatório do IPCC (SYR-AR5, 2014). Os quatro novos cenários são uma evolução dos apresentados no quarto relatório do IPCC por incorporarem aos perfis de emissões forçantes de cunho

político-social baseados em protocolos de acordos firmados por nações relativos a implementação de políticas públicas voltadas a minimizar as emissões de gases de efeito estufa. Os cenários atualizados foram denominados, em português, "caminhos representativos de concentrações", ou RCPs de sua sigla em inglês para Representative Concentration Pathways.

Os cenários são os RCP2.6, RCP4.5, RCP6 e RCP8.5, nomeados desta forma para uma provável faixa de valores de forçamento radiativo no ano 2100 em relação aos valores pré-industriais (+2,6, +4,5, +6,0 e +8,5 W/m², respectivamente). No RCP2.6, ocorreria um pico na forçante radiativa de aproximadamente 3W/m² antes de 2100, que estabiliza e passa a diminuir. O RCP4.5 prevê uma forçante climática que atinge 4.5W/m² até 2050, com posterior estabilização, no RCP6 é mais lento que o do cenário RCP4.5 até 2050, mas contínuo e o ultrapassa até 2100. O pior cenário é o RCP8.5, com contínuo crescimento da forçante radiativa que atingirá o valor de 8.5W/m² até 2100 (RIAHI *et al.*, 2007; RAO e RIAHI., 2006; FUJINO *et al.*, 2006; HIJIOKA *et al.*,2008; SMITH e WIGLEY., 2006; CLARKE *et al.*,2007; WISE *et al.*,2009; van VUUREN *et al.*, 2006, 2007).

A Figura 4 exhibe em detalhes estes prováveis e representativos caminhos da forçante radiativa.

Figura 4: Forçante radiativa dos RCPs. Extraída de van Vuuren et al (2011).



3.4 - *DOWNSCALING* ESTATÍSTICO

O downscaling é um procedimento para levar à escala local informações conhecidas em escalas maiores, ou seja, é um refinamento de uma escala espacial global para uma escala local. Há dois tipos de downscaling, o dinâmico e o estatístico. O downscaling dinâmico requer a execução de modelos climáticos de alta resolução em um subdomínio regional, usando dados observacionais ou saídas de modelos climáticos de baixa resolução como uma condição de contorno, baseiam-se em princípios físicos para reproduzir o clima local, e requerem uso computacional intensivo. O Downscaling Estatístico (DE) é um processo de duas etapas que consiste, primeiro, no desenvolvimento de relações estatísticas entre variáveis climáticas locais (por exemplo, precipitação e temperatura do ar à superfície) e preditores de grande escala (por exemplo, campos de pressão ao nível médio do mar), e em seguida, aplicar estas relações em saídas de MCGs para simular características climáticas locais no presente e futuro (WILBY e WIGLEY, 1997; 2000).

Para Hewitson e Crane (1996), devido a utilização de séries contínuas, existem diferentes sistemas de tempo que podem não ter um desenvolvimento dinâmico, surge então a necessidade de aplicação do downscaling estatístico. É uma técnica de pós processamento das saídas dos MCG's (Modelos Climáticos Globais).

As vantagens de usar técnicas de DE consistem na não exigência de recursos computacionais de alto desempenho, à sua aplicabilidade em qualquer local que tenha um histórico de observações, na fácil obtenção das relações estatísticas entre dados do MCG e dados observados de superfície e rapidez em derivar informações de um MCG para o clima presente e previsões para um clima futuro (WILBY *et al.*, 2002). Também os métodos de DE podem ser utilizados como geradores de tempo estocástico ou para preenchimento de lacunas em dados meteorológicos (GIRVETZ *et al.*, 2009).

O downscaling estatístico se torna uma abordagem realista para desenvolver uma previsão climática para um ponto específico local. São comumente aplicados a projeções dos MCG mas também podem ser aplicados aos Modelos Climáticos Globais (MCR). Geralmente os métodos estatísticos mais utilizados para encontrar as melhores relações entre dados de grande escala do MCG e dados de superfície, abrangem métodos de

regressão entre preditores e preditandos, comparação de padrões análogos, redes neurais artificiais, entre outras (WILBY e HARRIS, 2006; WILBY e DAWSON, 2007).

O Primeiro Relatório de Avaliação Nacional do PBMC (Painel Brasileiro de Mudanças Climáticas) cita que a classificação dos métodos de downscaling estatístico pode ser feita em três categorias:

- Métodos baseados na classificação de padrões de tempo: Variáveis climáticas locais são relacionadas com escala sinótica (Fowler et al., 2007);
- Geradores de tempo: Produzem series temporais sintéticas das variáveis meteorológicas para uma determinada região;
- Modelos de Regressão: Estimam relações quantitativas entre preditores gerados através do MCG e variáveis prognósticas locais utilizando modelos empíricos (Fowler et al., 2007; Mendes et al., 2009). Os preditores podem ser entendidos como saídas de reanálises para um período representativo comumente de 30 anos.

Muitos estudos usando técnicas de DE ganharam impulso após a divulgação dos relatórios do IPCC contendo as projeções futuras do clima derivadas de MCGs. Bettolli *et al.*, (2010) analisou a variabilidade do rendimento agrícola de pastagens no Uruguai a partir dos cenários A2 e B2 fornecidos pelos MCG's HadCM3 e CSIRO-Mk2, chegando a conclusão de uma provável recorrência de eventos de estresse térmico durante o verão até o final do século XXI. O comportamento de índices de extremos climáticos para as próximas décadas também podem ser avaliados a partir de séries temporais locais obtidas de técnicas de DE (NATIVIDADE *et al.*, 2017).

4. DADOS E METODOLOGIA

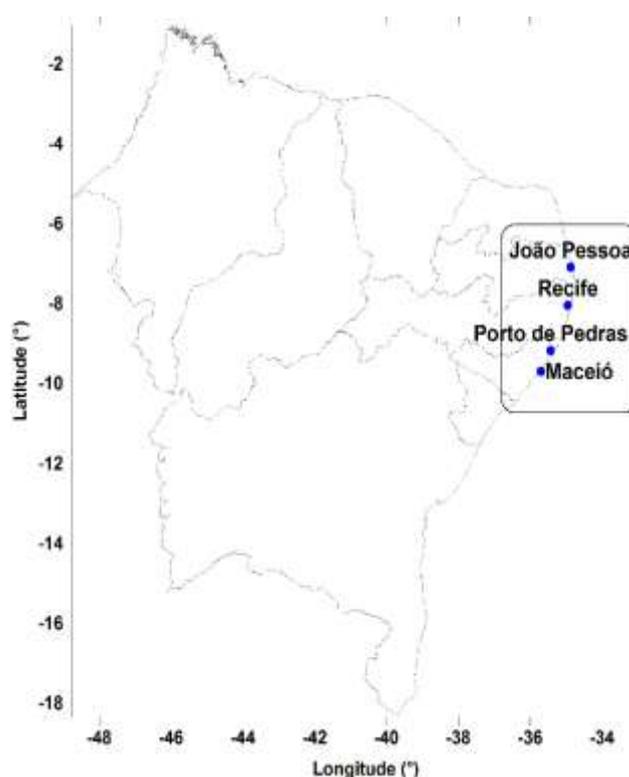
4.1 - ÁREA DE ESTUDO, DADOS METEOROLÓGICOS E DE PRODUTIVIDADE

A área de estudo desta pesquisa estará concentrada no leste do Nordeste, entre os Estados da Paraíba, na cidade de João Pessoa. Pernambuco, com a cidade de Recife e Alagoas, com as cidades de Maceió e Porto de Pedras, que juntos concentram a maior produção de cana de açúcar da região Nordeste (CONAB, 2015), contribuindo com cerca de 9% da produção nacional.

Os dados meteorológicos são provenientes das estações convencionais do INMET (Instituto Nacional de Meteorologia), disponíveis a partir de 01/01/1961 e utilizados deste período até o ano de 2015. Os dados a ser utilizados serão, essencialmente, de Precipitação (Prec), Temperaturas Máximas (TX) e Mínimas (TN), Temperaturas Médias (TM) e Insolação (Insol). A Figura 5 mostra a distribuição destas estações convencionais no Nordeste.

Os dados relativos ao rendimento médio (produtividade) da cana de açúcar em quilogramas por hectare para os municípios dos três Estados focos da pesquisa são provenientes do Sistema IBGE de Recuperação Automática (SIDRA), que disponibiliza diversas informações de caráter socioeconômico, por município, incluindo a agricultura.

Figura 5: Distribuição geográfica das estações meteorológicas convencionais de João Pessoa (PB), Recife (PE), Maceió e Porto de Pedras (AL) do INMET na região Nordeste.



4.2 – MODELO DE SIMULAÇÃO DA PRODUTIVIDADE AGRÍCOLA

O Modelo da Zona Agroecológica (AZM) apresentado por Doorenbos e Kassam (1979) será utilizado para determinar o potencial de rendimento da cana-de-açúcar (Y_p). Os dados climáticos necessários ao modelo são a temperatura média do ar, insolação, precipitação e evapotranspiração potencial. Para a cultura, são necessários o índice

máximo de área foliar (IAF), taxa de respiração de manutenção (Resp), índice de colheita (Harv) e teor de água na parte colhida da planta (CC). A equação geral do modelo Y_p é apresentada abaixo.

$$Y_p = \sum_{i=1}^n (FB \times C_{IAF} \times C_{RESP} \times C_{IC} \times C_{WC}) \quad \text{Equação 1}$$

Onde: Y_p é o rendimento potencial final (Kg ha^{-1}), n é o intervalo de tempo considerado (10 dias, decendial), variando de acordo com o tipo e ciclo da cultura, FB é a taxa fotossintética bruta (produtividade primária bruta) para cada período de 10 dias, expressa como matéria seca de uma safra padrão (Kg ha^{-1}). C_{IAF} é um coeficiente para o índice de área foliar, C_{RESP} é o coeficiente de respiração, C_{IC} é um coeficiente de resposta para manutenção da taxa de respiração, e C_{WC} é um coeficiente do teor de água nos caules. Todos os coeficientes de correção são adimensionais.

A FB é determinada pela soma da produtividade primária bruta em períodos nublados e nos períodos de sol, considerando que a energia disponível para fotossíntese sob cada condição sofre mudanças, afetando a absorção de energia pelas plantas. Os valores destas produtividades primárias sob condições de céu claro e dias nublados e todos seus coeficientes foram determinados seguindo Doorenbos e Kassam (1979) e Pereira et al. (2002). O coeficiente C_{IAF} é determinado por:

$$C_{IAF} = 0,0093 + 0,185 \times IAF_{max} - 0,0175 \times IAF_{max}^2 \quad \text{Equação 2}$$

Para $IAF_{max} \geq 5$; $C_{IAF} = 0,5$, onde IAF_{max} é o IAF máximo da cultura em cada período de 10 dias do ciclo da cultura.

O C_{RESP} é considerado 0,5 durante os períodos de 10 dias, quando a temperatura média (T_{med}) é maior ou igual a 20°C e 0,6 quando $T_{med} < 20^\circ\text{C}$ (Doorenbos e Kassam 1979). O C_{IC} é 0,8, enquanto o C_{WC} é determinado pela seguinte equação (onde U é o teor relativo de água dos caules = 80%):

$$C_{WC} = \left(1 - \frac{U}{100}\right)^{-1} \quad \text{Equação 3}$$

Para estimar o rendimento real (Y_r), consideramos uma relação direta entre a quebra de rendimento relativo ($1 - Y_r/Y_p$) e o déficit relativo de água ($1 - ETr/ETc$). ETc refere-se à evapotranspiração da cultura e ETr é a evapotranspiração real. A ETc foi

calculada dividindo a evapotranspiração de referência (ET_o), estimada pelo método de Hargreaves e Samani (1985), pelo coeficiente de cultura (k_c) para cada fase da cultura durante o ciclo (Tabela 1). A ETr é estimada através do balanço hídrico da cultura usando o método de Thornthwaite e Mather (1955). O fator de resposta da água (k_y), usado no modelo para vincular a quebra de rendimento relativo ao déficit hídrico, foi obtido de Doorenbos e Kassam (1979) e reproduzido na Tabela 2. Estes coeficientes obtidos do balanço hídrico e as demais variáveis permitem o cálculo do Y_r.

$$Y_R = \sum_{i=1}^n \left\{ Y_{Pi} \times \left[1 - k_y \left(1 - \frac{ETr_i}{ETc_i} \right) \right] \right\} \quad \text{Equação 4}$$

Onde: Y_R é o rendimento real (Kg ha⁻¹); i representa as fases fenológicas durante o ciclo da cultura (Tabela 1); Y_{Ri} é o rendimento real da cultura na fase fenológica anterior (Kg ha⁻¹) - no caso da primeira fase fenológica, o rendimento real anterior é igual a Y_p; e ETr e ETc são a evapotranspiração real e máxima da cultura (mm), respectivamente.

Tabela 2: Número de dias em cada fase e no ciclo da cana, coeficiente de cultura (k_c) e fator de resposta ao déficit hídrico (k_y) usado para estimar Y_R.

Fase fenológica (i)	Número de dias	Kc	IAF	Ky
25% coberto	30	0,4	1,5	0,7
25-50%	30	0,7	2	0,7
50-75%	20	1	2,5	0,3
75-100%	50	1,2	3,5	0,3
máximo	175	1,3	3	0,3
senescencia	30	1,1	2,5	0,3
amadurecimento	30	0,8	2	0,1
Dias (total)	365	-	-	-

4.3 – DOWNSCALING ESTATISTICO

O downscaling permite obter informações de alta resolução para projeções climáticas a partir de MCGs de resolução relativamente grosseira. Normalmente, os MCGs têm uma resolução espacial de 150-300 km entre pontos de grade. Para avaliação de impactos locais/regionais em setores como agricultura, saúde e recursos hídricos, estas informações precisam ser reduzidas à escalas de 50 km ou menores, usando para tanto algum método para estimar as informações em menor escala. O downscaling estatístico (DE) primeiro deriva relações estatísticas entre variáveis observadas em pequena escala (estação meteorológica) e grande escala (MCG), usando métodos de análogos (tipificação

da circulação), análises de regressão ou métodos de redes neurais. Os valores futuros das variáveis de larga escala obtidas das projeções dos MCGs (geopotencial, vento zonal e meridional, temperatura, etc) são então usados para derivar relações estatísticas e, assim, um Modelo de Downscaling Estatístico (MDE) proveniente desta relação pode então ser aplicado aos dados de superfície (Wilby e Dawson, 2013).

Inicialmente os MDEs combinam as informações dos MCGs a dados de reanálises das observações das variáveis de superfície, ambos sob a mesma dimensão de grade, a fim de selecionar os melhores preditores. Estes serão os preditores utilizados para calibrar/validar o MDE para as séries temporais de dados observados de precipitação e temperaturas das estações meteorológicas. Uma vez que a cadeia Preditores → Preditandos → MDE tenha sido concluída, o MDE estará pronto para ser utilizado e aplicado 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 *software* desenvolvido pelo Grupo Santander Meteorologia (<http://www.meteo.unican.es>), como parte das atividades do projeto *ENSEMBLES* financiado pela União Europeia (Cofiño et al, 2007).

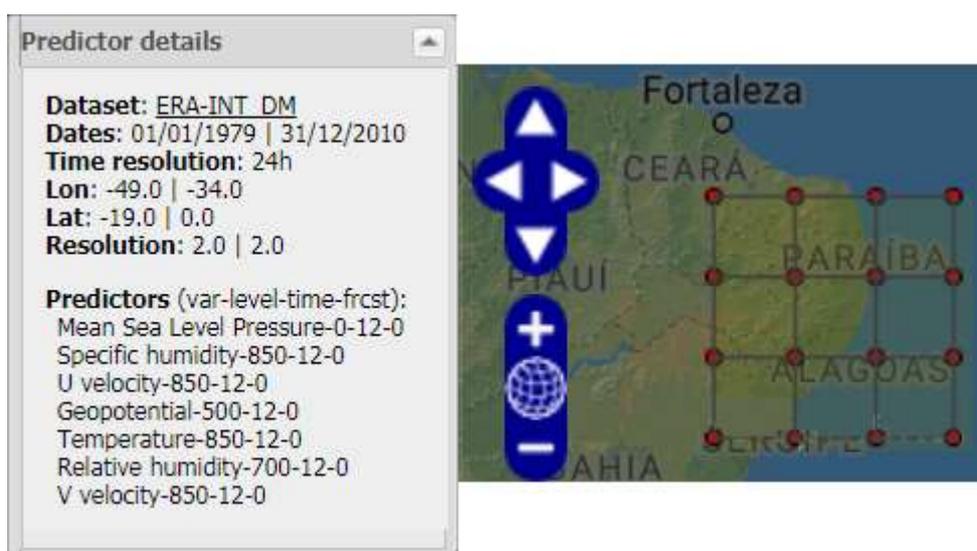
A redução de escala com o MDE consiste em quatro etapas principais: (1) seleção de preditores, (2) calibração de funções de transferência, (3) validação dos resultados do modelo de redução de escala, e (4) geração de cenários (Wilby e Fowler, 2010), descritas a seguir.

4.3.1 SELEÇÃO DOS PREDITORES

Para a calibração do modelo, é preciso escolher um período com o maior número possível de dados observados. Nesta pesquisa trabalhar-se-á com o período de calibração e validação sugerido por Carter et al., (2007), 1961-1990. Os dados de reanálises do projeto ERA40 serão usados para calibração da precipitação e do NCEP/NCAR para as temperaturas máximas e mínimas, em uma grade comum $2,5^\circ \times 2,5^\circ$ para o período de controle 1961-1990 (Flato et al., 2013; Collins et al., 2013; Hartmann et al., 2013). Para a variável precipitação, a Figura 6 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. Para as temperaturas máximas e mínimas, foram selecionadas 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.

Figura 6: Detalhes dos preditores e grade utilizada para a precipitação da região Nordeste.



A Tabela 3 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 3. 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 do Mar (PNM)	superfície	Pa
Temperatura a 2m (2T)	superfície	K

4.3.2 SELEÇÃO DOS PREDITANDOS

Inicialmente, foram trabalhados dados observados de precipitação, temperaturas máximas e mínimas de 97 estações meteorológicas do INMET de toda a região Nordeste do Brasil, não apenas da faixa leste entre os Estados de Paraíba, Pernambuco e Alagoas, a fim de permitir uma visão espacializada das projeções de mudanças climáticas em toda região. A Figura 7 mostra a localização espacial das estações. Após essa etapa, foram selecionadas as estações meteorológicas para obtenção dos dados nas cidades de Maceió, Porto de Pedras, Recife e João Pessoa.

Figura 7: Janela de criação dos predictandos para as temperaturas máximas, mínimas e precipitação das estações do INMET.



4.3.3 SELEÇÃO DO MÉTODO DE DOWNSCALING ESTATÍSTICO

Para geração dos cenários de mudanças climáticas, foi empregado o método dos análogos (Gutierrez et al., 2013). Neste método, padrões análogos são filtrados por funções ortogonais empíricas, especificando um estado local coerente com um estado simultâneo de grande escala. Como exemplo, 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:

$$f(i, t) = \sum_{k=1}^n x_k t_k g_k + \epsilon_t \quad \text{Equação (5)}$$

Onde i é um índice de ponto de grade, t é o tempo, gk é o padrão de ordem k da FOE, $xk(t)$ 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 FOE padrões.

A validação é feita para dados diários e decendiais. O período de calibração do modelo é o climatológico 1961-1990 (75% dos dados), para verificar a habilidade dos modelos em simular os ciclos anuais. A validação é realizada para o período 1991-2000 (25% dos dados), sendo obtidos diversos parâmetros estatísticos que permitem estimar a destreza do MDE em simular o presente e dar confiança para as projeções futuras, tais como: coeficiente de correlação de Pearson (r), PDFscore, razão de variâncias e curvas Q-Q Plot entre simulações e observações. O teste de significância estatística t-student foi empregado para obter o valor crítico de correlação (r_c), valor para a qual se aceita ou não a hipótese estatística que existe correlação entre os dados simulados e observados, a um nível de confiança estatística de no mínimo 95%. r_c é dado por:

$$r_c = \sqrt{\frac{t^2}{(N-2)+t^2}} \quad \text{Equação (6)}$$

4.3.4 VALIDAÇÃO DO DOWNSCALING ESTATÍSTICO

O método de downscaling definido utilizando o portal citado por esse trabalho, é automaticamente validado usando uma abordagem treino/teste. O período histórico comum para preditores (reanálise; essa validação é feita em condições de Prognóstico Perfeito) e preditandos (observações locais) é dividido entre 75% de treino (dos dados) e 25% de teste.

Na fase de treinamento, o método de downscaling é calibrado usando os dados de treinamento (por exemplo: os coeficientes de regressão são ajustados para os dados), enquanto na fase de teste o método é validado nos dados do teste. A precisão e os guias de similaridade mostram diferença de pontuação relacionados à precisão (os padrões são correlação, MAE, RMSE e RMSE normalizado) e a confiabilidade (BIAS, BIAS normalizado, razão de variâncias e Valor p do teste de Kolmogorov-Smirnov) do método.

Os cenários climáticos do AR4 possuem o experimento de controle no período de 1961-2000, onde: 1961-1990 é o período de Calibração e 1991-2000 é o período de validação. Para os cenários do CMIP5 o experimento de controle foi no período de 1979-2010, onde: 1979-2000 é o período de calibração e 2001-2010 o período de validação.

Os coeficientes usados para essa fase de validação do downscaling foram divididos em: Estatística descritiva, medida de precisão e similaridade das distribuições. Na estatística descritiva temos a média e o desvio padrão, que são obtidos através das equações 7 e 8 respectivamente. Na medida de precisão temos o coeficiente de correlação (equação 9) e RMSE (Raiz quadrada do erro médio) na equação 10. E na similaridade das distribuições temos a razão das variâncias (equação 11) e o PDFescore (equação 12).

$$M = \frac{1}{N} \sum_{i=1}^N x_i \quad \text{Equação (7)} \quad \sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2} \quad \text{Equação (8)}$$

$$r_{o,p} = \frac{\text{Cov}(o,p)}{\sigma_{o,p}} \quad \text{Equação (9)} \quad RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad \text{Equação (10)}$$

$$RV = \frac{\sigma_p^2}{\sigma_o^2} \quad \text{Equação (11)} \quad PDFescore = \sum_{i=1}^{200} (PDF_{pi} - PDF_{oi}) \quad \text{Equação (12)}$$

6. RESULTADOS E DISCUSSÕES

5.1 - CALIBRAÇÃO DA PRECIPITAÇÃO

Nesta seção, os resultados da calibração da precipitação serão exibidos sequencialmente para as quatro cidades estudadas, com duas imagens onde se encontram as comparações entre as climatologias observadas e os modelos estudados tanto nos MCGs dos cenários AR4 e CMIP5 e dois gráficos que apresentam o comportamento das observações sobrepostas com o ENSEMBLE dos modelos, para cada série temporal estudada. A ordem das cidades a serem apresentadas será: João Pessoa, Recife, Porto de Pedras e Maceió.

É observado que todos os modelos foram hábeis em representar o ciclo médio anual da precipitação, no entanto, para todas as cidades estudadas houve subestimativa da chuva acumulada média mensal nos meses mais chuvosos e superestimativa nos meses mais secos. Esses comportamentos são visíveis nas figuras a seguir.

Figura 8: Comparação entre a climatologia observada e dos modelos estudados em cada cenário (lado esquerdo) X Comportamento dos dados observados comparados com o ENSEMBLE dos modelos (lado direito), para seus respectivos períodos da variável da precipitação na cidade de João Pessoa.

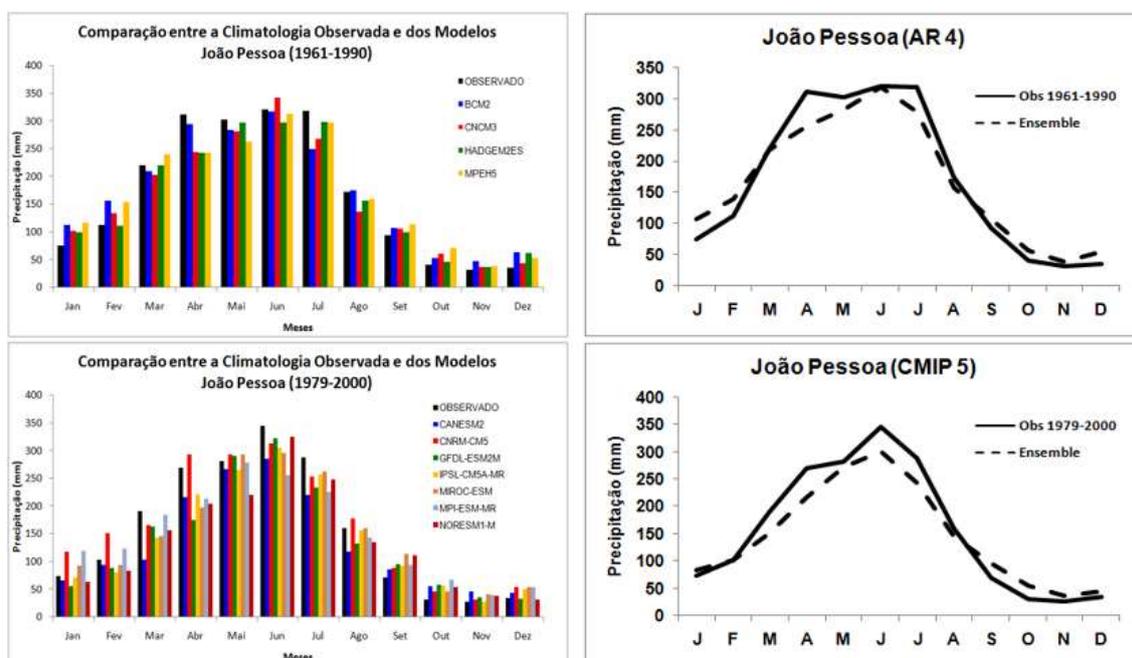


Figura 9: Comparação entre a climatologia observada e dos modelos estudados em cada cenário (lado esquerdo) X Comportamento dos dados observados comparados com o ENSEMBLE dos modelos (lado direito), para seus respectivos períodos da variável da precipitação na cidade de Recife.

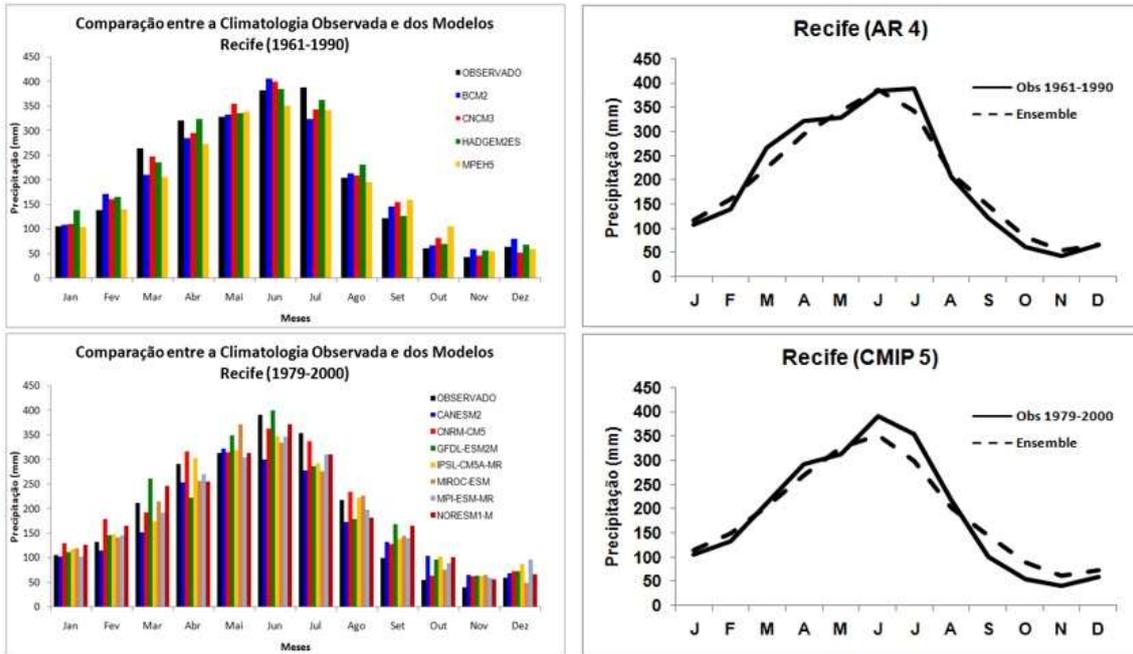


Figura 10: Comparação entre a climatologia observada e dos modelos estudados em cada cenário (lado esquerdo) X Comportamento dos dados observados comparados com o ENSEMBLE dos modelos (lado direito), para seus respectivos períodos da variável da precipitação na cidade de Porto de pedras.

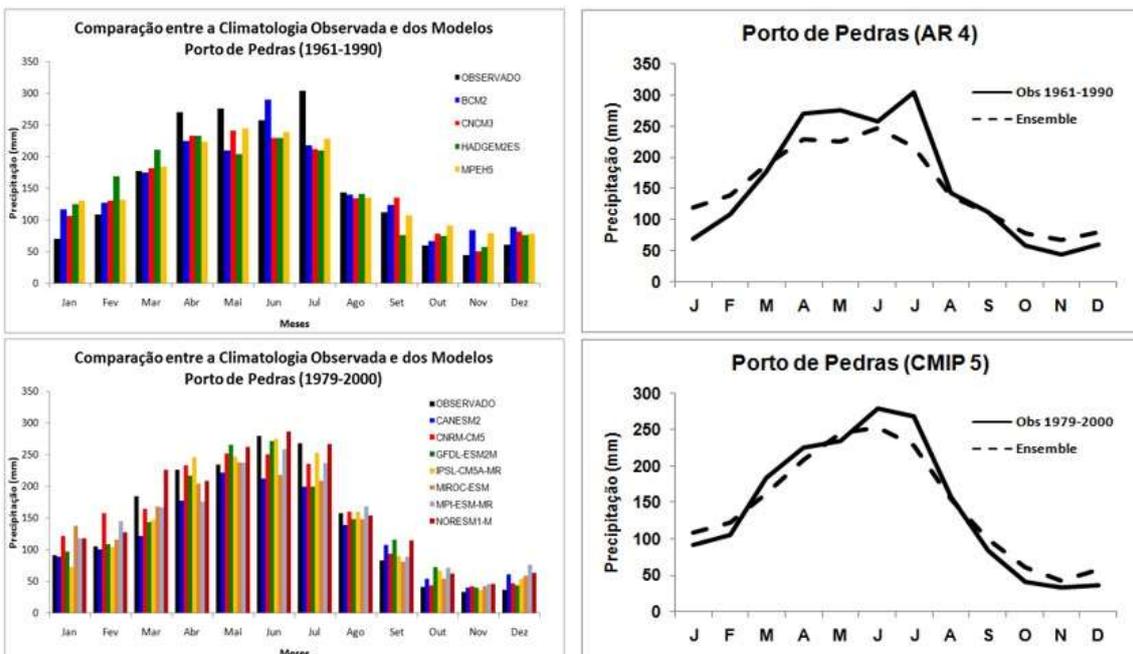
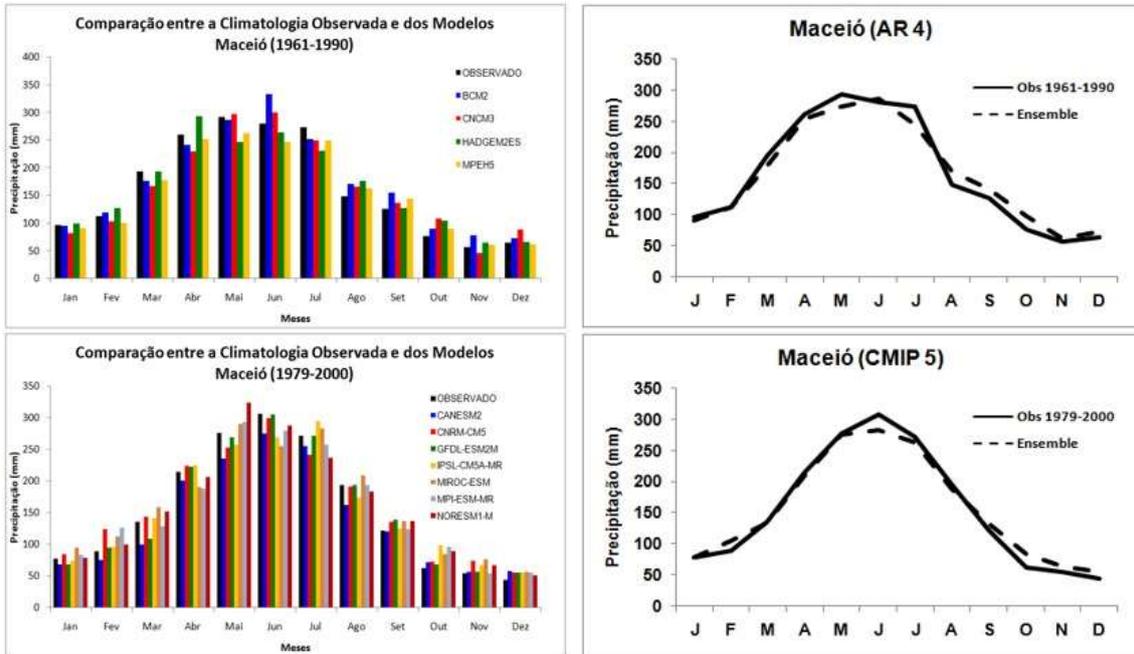


Figura 11: Comparação entre a climatologia observada e dos modelos estudados em cada cenário (lado esquerdo) X Comportamento dos dados observados comparados com o ENSEMBLE dos modelos (lado direito), para seus respectivos períodos da variável da precipitação na cidade de Maceió.



5.1.2 - CALIBRAÇÃO DA TEMPERATURA MÁXIMA

Nesta seção, os resultados da calibração da temperatura máxima serão exibidos sequencialmente para as quatro cidades estudadas, seguindo o mesmo modelo exibido na precipitação onde em duas imagens se encontram as comparações entre as climatologias observadas e os modelos estudados tanto nos MCGs dos cenários AR4 e CMIP5 e dois gráficos que apresentam o comportamento das observações sobrepostas com o ENSEMBLE dos modelos, para cada série temporal estudada. A ordem das cidades a serem apresentadas será a mesma exibida na seção anterior.

De uma maneira geral, houve pouca variação entre a climatologia dos modelos e a climatologia observada. O CMIP 5 apresentou maior destreza com a representação da climatologia observada. Já os modelos do AR4 apresentaram leve tendência para superestimar a temperatura máxima nos meses mais frios.

Figura 12: Comparação entre a climatologia observada e dos modelos estudados em cada cenário (lado esquerdo) X Comportamento dos dados observados comparados com o ENSEMBLE dos modelos (lado direito), para seus respectivos períodos da variável da temperatura máxima na cidade de João Pessoa.

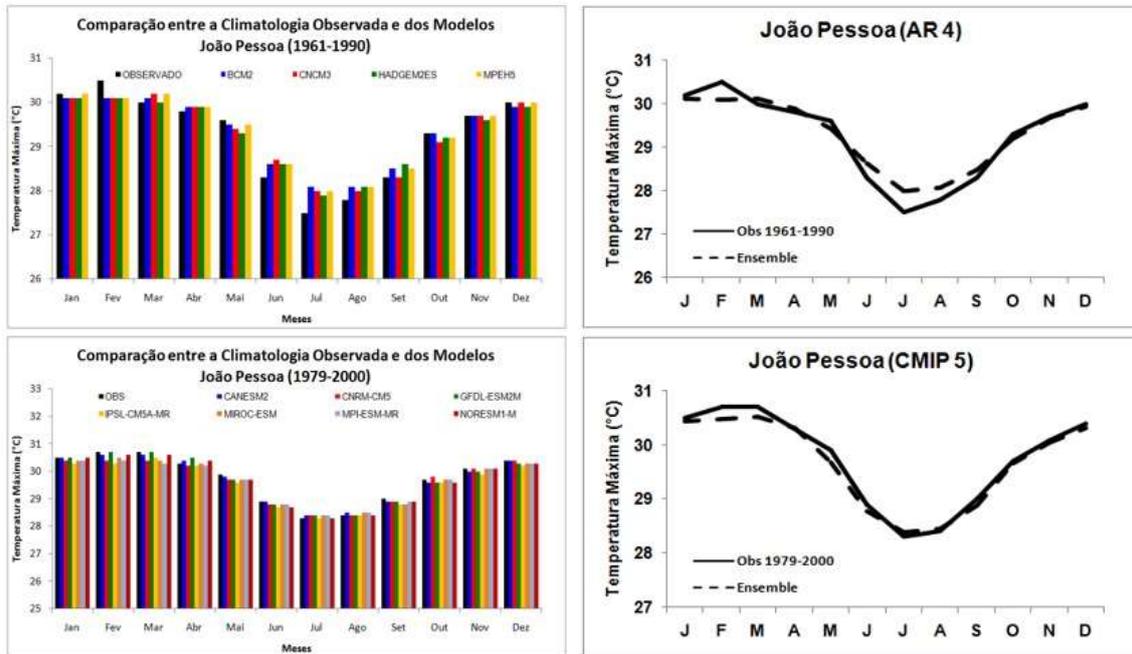


Figura 13: Comparação entre a climatologia observada e dos modelos estudados em cada cenário (lado esquerdo) X Comportamento dos dados observados comparados com o ENSEMBLE dos modelos (lado direito), para seus respectivos períodos da variável da temperatura máxima na cidade de Recife.

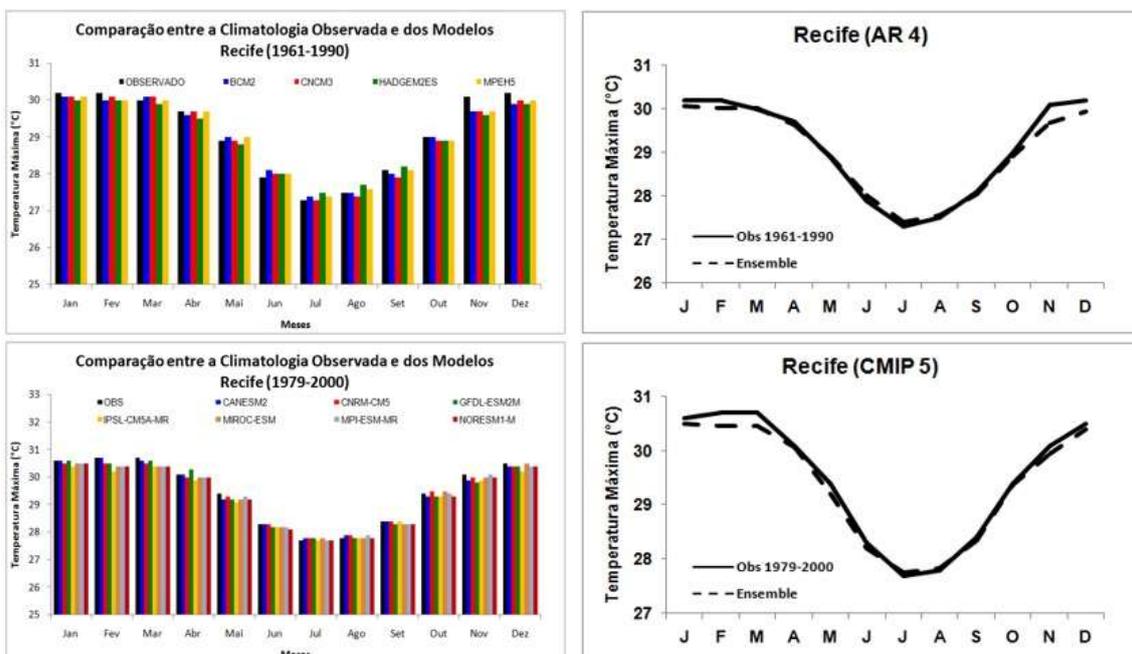


Figura 14: Comparação entre a climatologia observada e dos modelos estudados em cada cenário (lado esquerdo) X Comportamento dos dados observados comparados com o ENSEMBLE dos modelos (lado direito), para seus respectivos períodos da variável da temperatura máxima na cidade de Porto de Pedras.

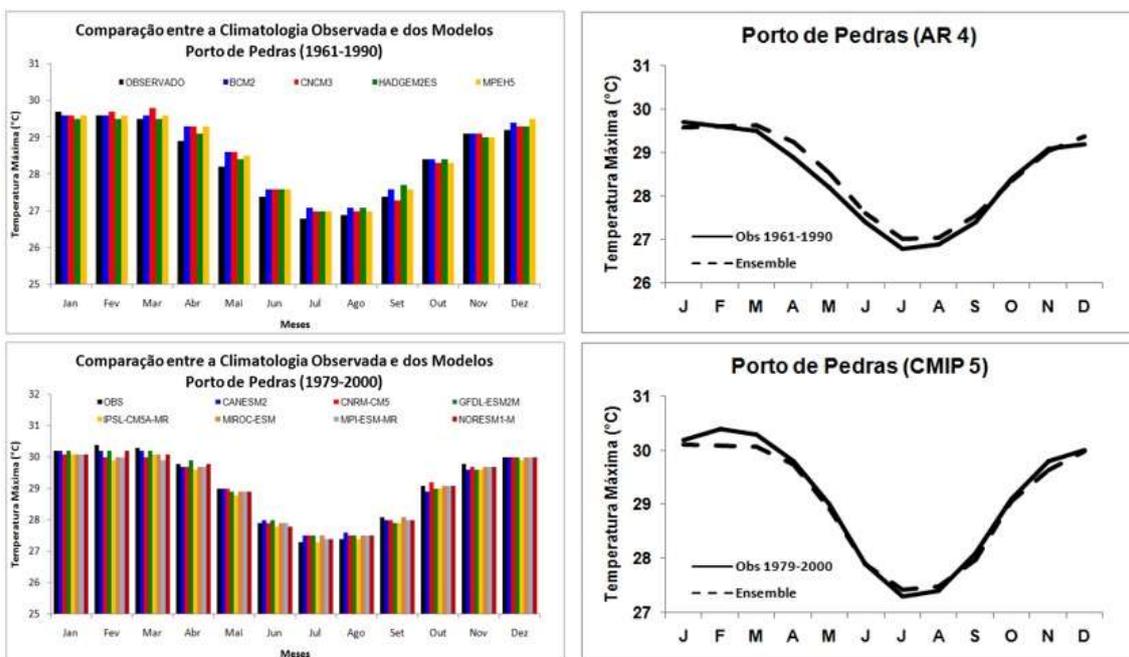
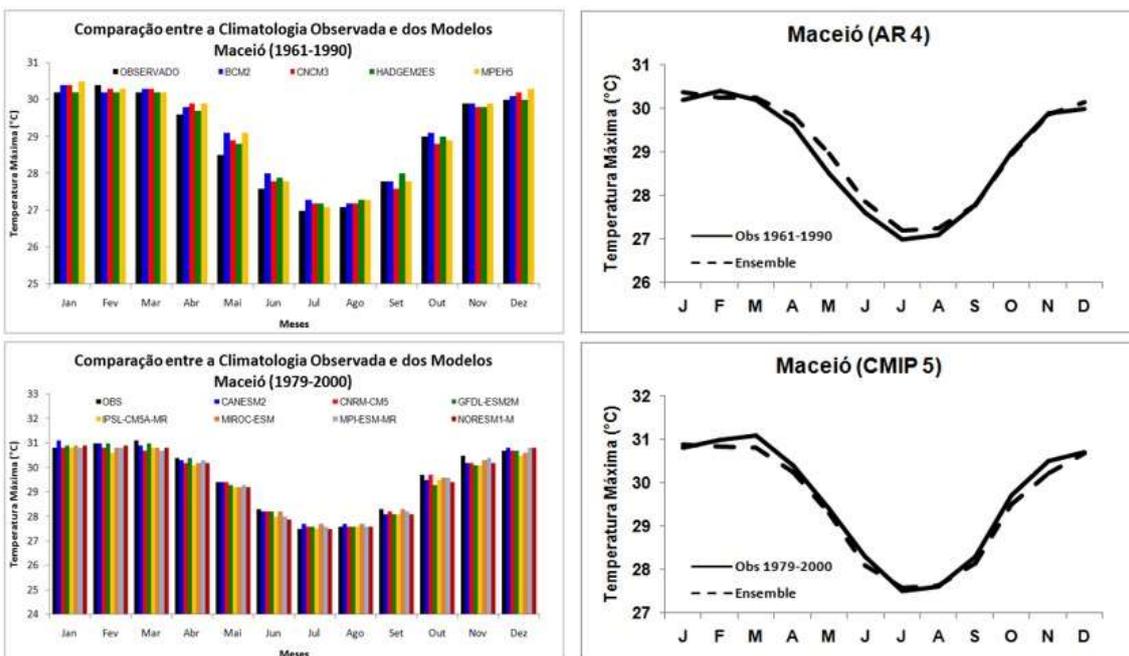


Figura 15: Comparação entre a climatologia observada e dos modelos estudados em cada cenário (lado esquerdo) X Comportamento dos dados observados comparados com o ENSEMBLE dos modelos (lado direito), para seus respectivos períodos da variável da temperatura máxima na cidade de Maceió.



5.1.3 - CALIBRAÇÃO DA TEMPERATURA MÍNIMA

Nesta seção, os resultados da calibração da temperatura mínima seguirão os mesmos modelos apresentados nas duas seções anteriores seguindo também a mesma ordem para as cidades estudadas.

Seguindo o mesmo padrão observado na calibração da temperatura máxima, os modelos do CMIP5 apresentaram também maior destreza em simular a climatologia observada. Os modelos do AR4 superestimaram os valores médios mensais da temperatura mínima nas cidades de João Pessoa, Recife e Porto de Pedras e subestimaram esses valores na cidade de Maceió.

Figura 16: Comparação entre a climatologia observada e dos modelos estudados em cada cenário (lado esquerdo) X Comportamento dos dados observados comparados com o ENSEMBLE dos modelos (lado direito), para seus respectivos períodos da variável da temperatura mínima na cidade de João Pessoa.

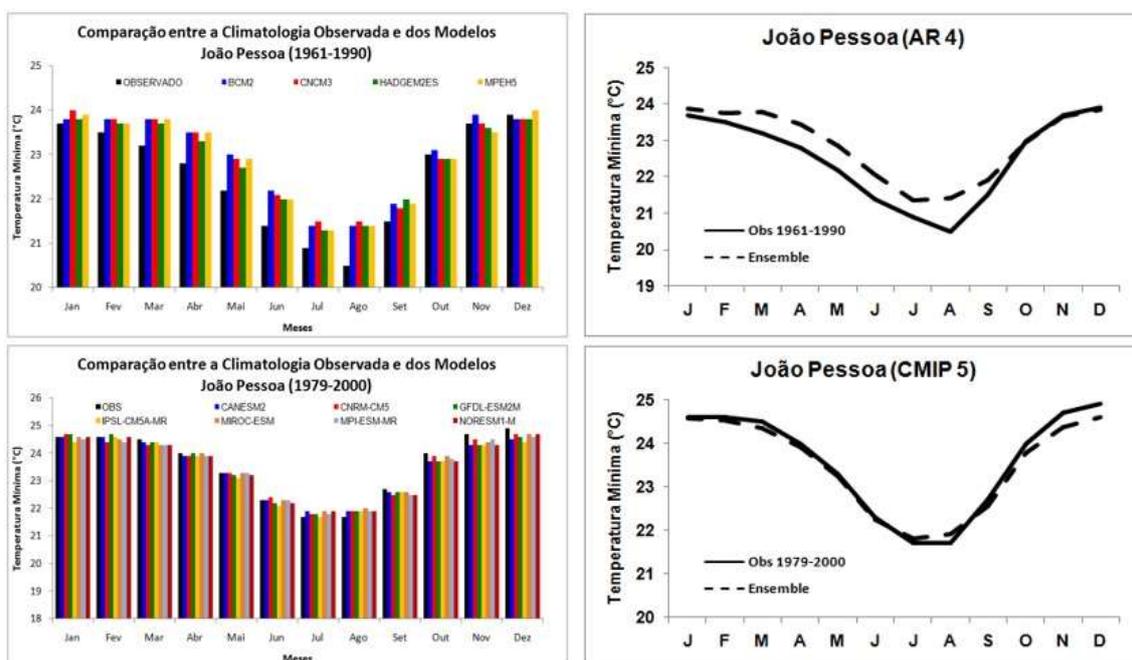


Figura 17: Comparação entre a climatologia observada e dos modelos estudados em cada cenário (lado esquerdo) X Comportamento dos dados observados comparados com o ENSEMBLE dos modelos (lado direito), para seus respectivos períodos da variável da temperatura mínima na cidade de Recife.

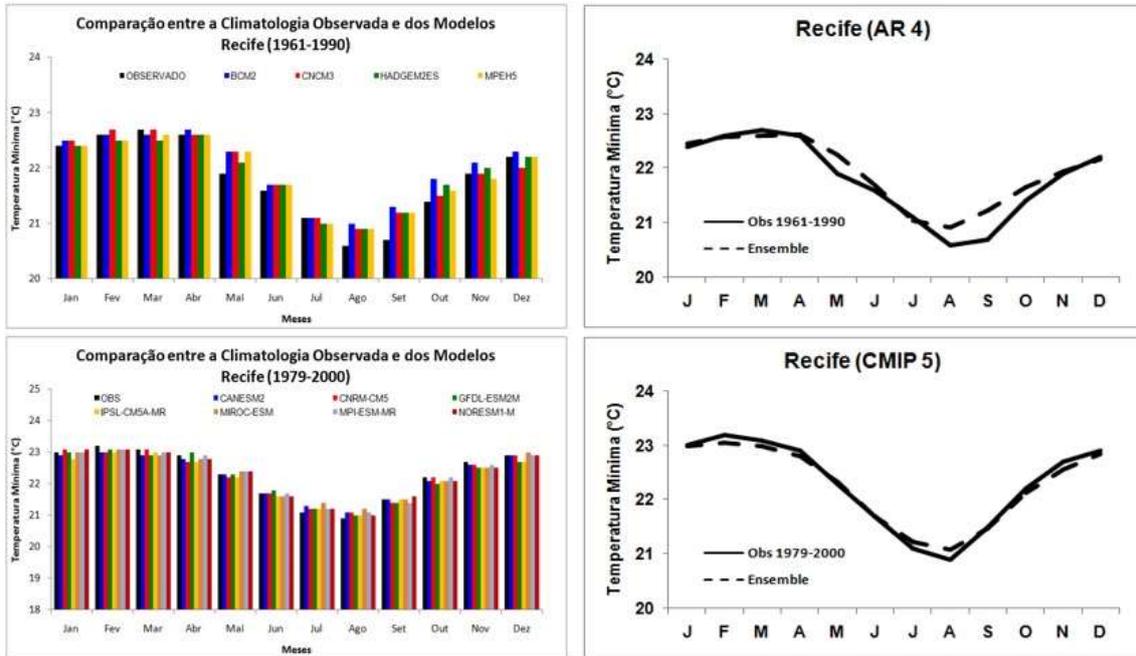


Figura 18: Comparação entre a climatologia observada e dos modelos estudados em cada cenário (lado esquerdo) X Comportamento dos dados observados comparados com o ENSEMBLE dos modelos (lado direito), para seus respectivos períodos da variável da temperatura mínima na cidade de Porto de Pedras.

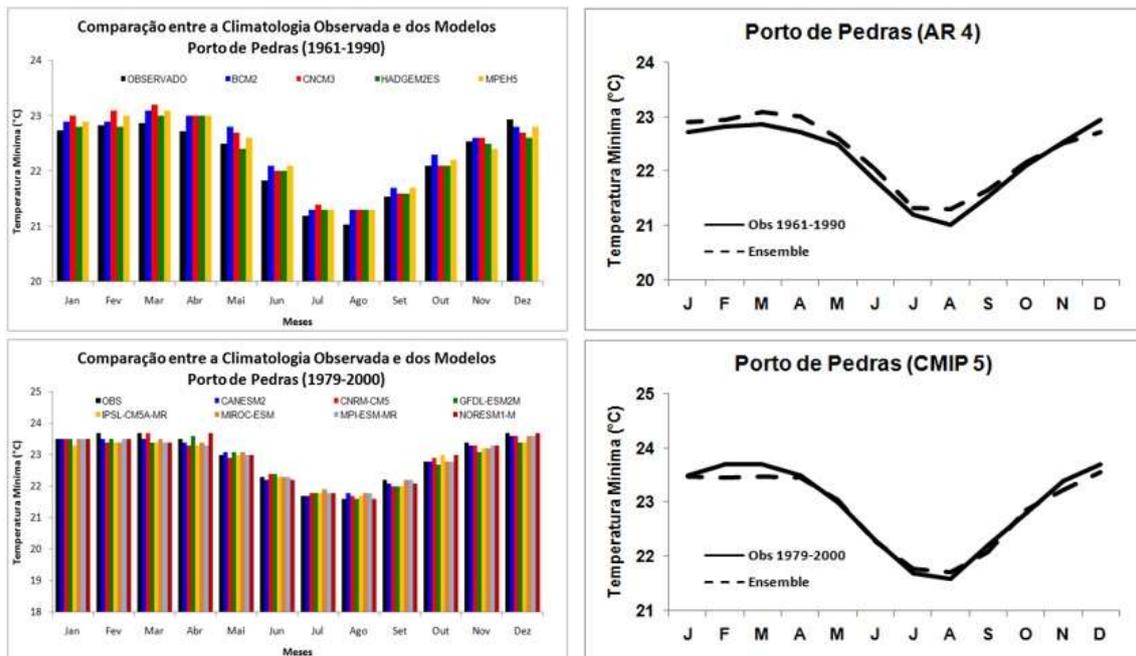
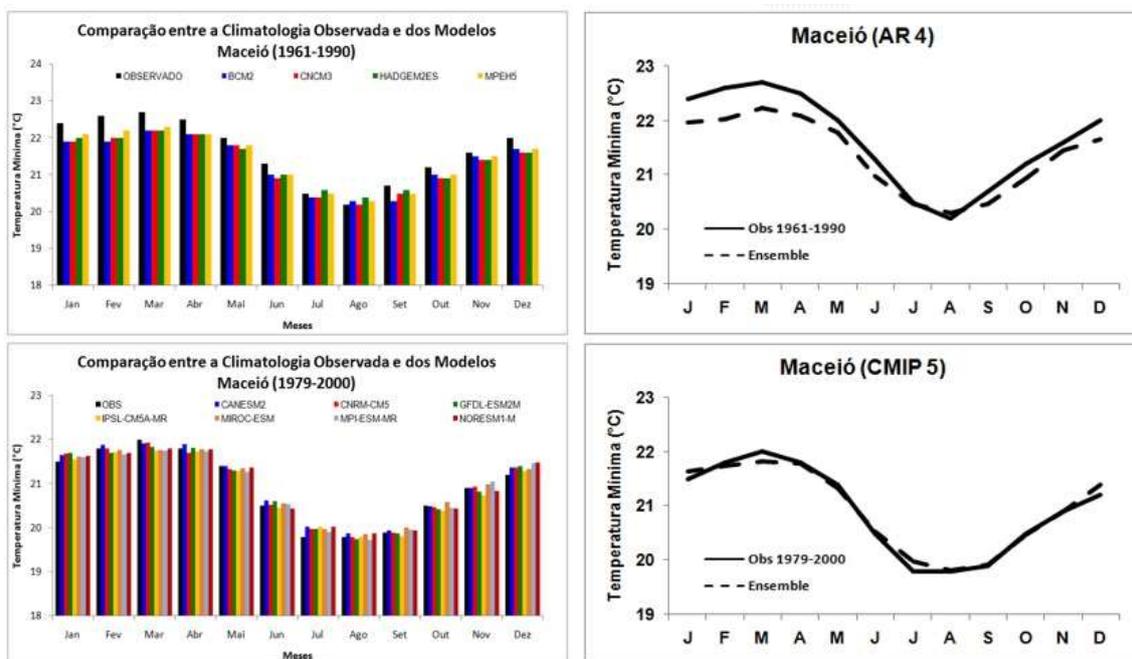


Figura 19: Comparação entre a climatologia observada e dos modelos estudados em cada cenário (lado esquerdo) X Comportamento dos dados observados comparados com o ENSEMBLE dos modelos (lado direito), para seus respectivos períodos da variável da temperatura mínima na cidade de Maceió.



5.2 – VALIDAÇÃO DO DOWNSCALING DA PRECIPITAÇÃO

Nesta seção, os resultados da validação do downscaling da variável precipitação serão exibidos em duas tabelas, onde em cada uma delas estarão dispostas as quatro cidades estudadas e os respectivos coeficientes e médias observados nessa etapa de validação. Na tabela 4 encontram-se os valores de análise dos modelos do cenário AR4 e na tabela 5 estão os valores de análise dos modelos do cenário CMIP5. Os valores de precipitação são acumulados de 10 dias (decendial) e todos os valores de correlações foram estatisticamente significantes ao nível de 95% pelo teste t-student, exposto através da equação 13.

As médias e desvio padrão observadas e simuladas na estatística descritiva para acumulação a cada 10 dias foram levemente melhores para o downscaling estatístico dos modelos do AR4 do que os modelos do CMIP5, mas de uma forma geral, mostram que houve pouca variabilidade entre observações e simulações. As medidas de precisão mostram melhora das simulações do CMIP5 em relação ao AR4, com maiores valores de correlações e menores valores de RMSE. Com as similaridades das distribuições há uma

melhora da razão entre as variâncias do CMIP5 em relação ao AR4 para as cidades de João Pessoa e Recife, enquanto o PDFscore foi levemente superior no CMIP5.

Tabela 4: Análise do cenário AR4 da variável precipitação para a validação do downscaling.

ESTAÇÃO	Média Obs (mm)	Média Sim (mm)	Desvio Padrão Obs (mm)	Desvio Padrão Sim (mm)	R	RMSE (mm)	Razão Var	PDFesc
J. PESSOA	5,3	5,2	6,5	5,6	0,53	6,8	0,76	0,94
RECIFE	6,4	6,3	7,0	6,3	0,56	7,0	0,83	0,93
P. PEDRAS	4,9	4,9	5,0	4,5	0,41	5,6	0,82	0,94
MACEIÓ	5,3	5,3	5,6	5,0	0,45	6,0	0,81	0,94

Tabela 5: Análise do cenário CMIP5 da variável precipitação para a validação do downscaling.

ESTAÇÃO	Média Obs (mm)	Média Sim (mm)	Desvio Padrão Obs (mm)	Desvio Padrão Sim (mm)	R	RMSE (mm)	Razão Var	PDFesc
J. PESSOA	5,1	4,9	6,1	5,6	0,68	5,4	0,86	0,97
RECIFE	6,2	6,1	6,6	6,5	0,67	6,0	0,96	0,96
P. PEDRAS	5,1	4,8	5,7	4,8	0,63	5,2	0,71	0,94
MACEIÓ	4,8	4,6	5,6	5,0	0,56	5,6	0,79	0,95

$$rC = \sqrt{\frac{t^2}{(N-2)+t^2}} \quad \text{Equação (12)}$$

5.2.1 – VALIDAÇÃO DO DOWNSCALING DA TEMPERATURA MÁXIMA

Nesta seção, os resultados da validação do downscaling da variável temperatura máxima serão exibidos em duas tabelas, seguindo o mesmo padrão da seção anterior do downscaling da precipitação. Os valores de correlações também foram estatisticamente significantes ao nível de 95% pelo teste t-student.

Para a variável temperatura máxima, todas as medidas de validação mostraram superioridade no CMIP5 em relação ao AR4, com única exceção na cidade de Porto de Pedras onde os indicadores do AR4 foram levemente superiores aos verificados no CMIP5.

Tabela 6: Análise do cenário AR4 da variável temperatura máxima para a validação do downscaling.

ESTAÇÃO	Média Obs	Média Sim	Desvio Padrão	Desvio Padrão	R	RMSE	Razão	Var	PDFesc
	(°C)	(°C)	Obs (°C)	Sim (°C)		(°C)			
J. PESSOA	29,4	29,4	1,1	0,9	0,79	0,7	0,71	0,90	
RECIFE	29,2	29,1	1,3	1,1	0,85	0,7	0,78	0,89	
P. PEDRAS	28,6	28,7	1,3	1,1	0,82	0,7	0,75	0,90	
MACEIÓ	29,2	29,2	1,5	1,3	0,81	0,9	0,80	0,93	

Tabela 7: Análise do cenário CMIP5 da variável temperatura máxima para a validação do downscaling.

ESTAÇÃO	Média Obs	Média Sim	Desvio Padrão	Desvio Padrão	R	RMSE	Razão	Var	PDFesc
	(°C)	(°C)	Obs (°C)	Sim (°C)		(°C)			
J. PESSOA	29,7	29,7	1,2	1,2	0,80	0,6	0,76	0,90	
RECIFE	29,4	29,4	1,5	1,5	0,86	0,7	0,76	0,89	
P. PEDRAS	29,5	29,5	1,9	1,9	0,82	0,9	0,83	0,93	
MACEIÓ	29,1	29,1	1,5	1,5	0,84	0,7	0,79	0,92	

5.2.2 – VALIDAÇÃO DO DOWNSCALING DA TEMPERATURA MÍNIMA

Nesta seção, os resultados da validação do downscaling da variável temperatura mínima serão exibidos em duas tabelas, seguindo o mesmo padrão das duas seções anteriores. Os valores de correlações também foram estatisticamente significantes ao nível de 95% pelo teste t-student.

Similarmente ao ocorrido na validação da temperatura máxima, todas as medidas de validação mostraram superioridade no CMIP5 em relação ao AR4, com única exceção na cidade de Porto de Pedras onde os indicadores do AR4 foram levemente superiores aos verificados no CMIP5.

Tabela 8: Análise do cenário AR4 da variável temperatura mínima para a validação do downscaling.

ESTAÇÃO	Média Obs	Média Sim	Desvio Padrão	Desvio Padrão	R	RMSE	Razão	Var	PDFesc
	(°C)	(°C)	Obs (°C)	Sim (°C)		(°C)			
J. PESSOA	23,0	23,0	1,4	1,2	0,70	1,0	0,67	0,88	
RECIFE	22,0	22,1	1,1	0,8	0,57	0,9	0,52	0,86	
P. PEDRAS	22,4	22,5	1,1	0,9	0,60	0,9	0,66	0,91	
MACEIÓ	21,5	21,4	1,2	0,9	0,48	1,1	0,62	0,88	

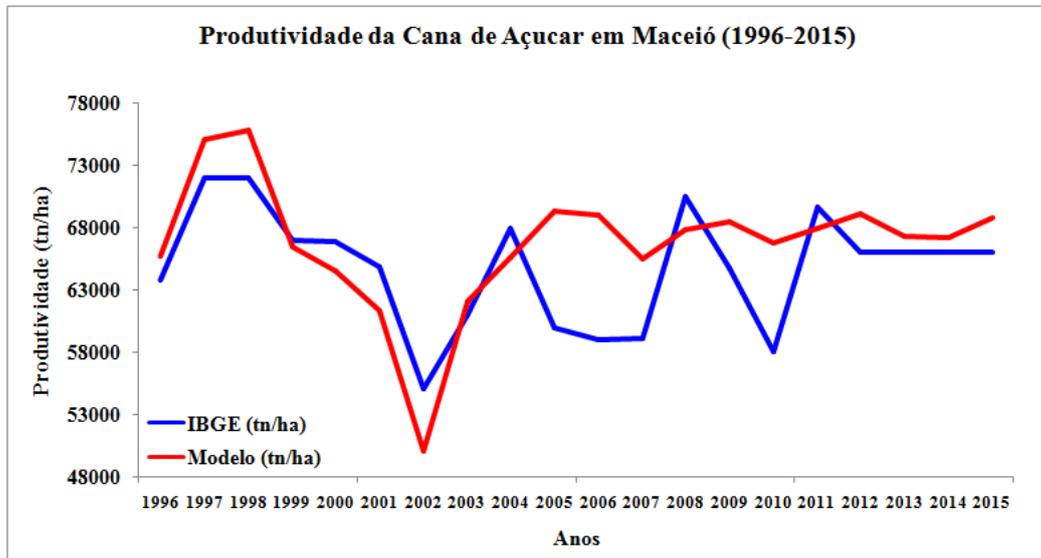
Tabela 9: Análise do cenário CMIP5 da variável temperatura mínima para a validação do downscaling.

ESTAÇÃO	Média Obs	Média Sim	Desvio Padrão	Desvio Padrão	R	RMSE	Razão	Var	PDFesc
	(°C)	(°C)	Obs (°C)	Sim (°C)		(°C)			
J. PESSOA	23,5	23,6	1,4	1,2	0,71	1,0	0,78	0,91	
RECIFE	22,3	22,4	1,0	0,9	0,66	0,8	0,78	0,94	
P. PEDRAS	20,9	20,9	1,2	0,9	0,59	1,0	0,64	0,89	
MACEIÓ	22,9	23,0	1,1	0,9	0,62	0,9	0,78	0,93	

5.3 – CALIBRAÇÃO E VALIDAÇÃO DO MODELO AGROMETEOROLÓGICO

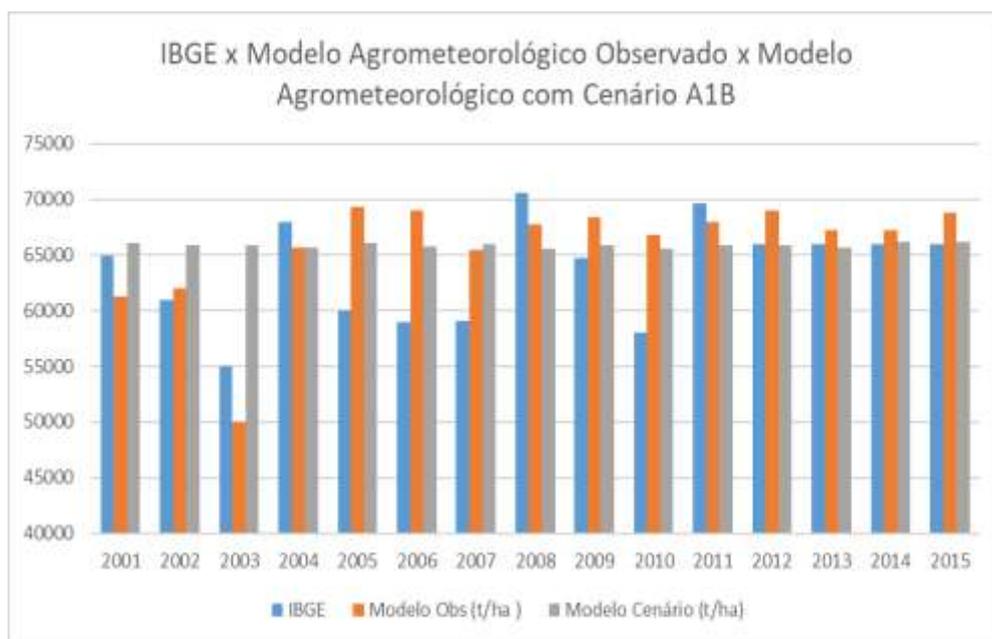
O modelo agrometeorológico utilizado foi calibrado para o período de 1996-2015. A organização dos dados meteorológicos foi dada em uma escala de tempo de 10 dias (decendial), para um ciclo da cultura de 12 meses. A produtividade simulada foi comparada à observada no período pelo IBGE (Figura 20), indicando muito boa concordância entre as simulações e observações na primeira metade dos anos, de 1996 até 2004. Após esta data o modelo tendeu a estimar valores próximos a média do período, no entanto, os dados do IBGE de 2012 a 2015 apresentaram o mesmo valor, o que deixa dúvidas quanto a qualidade dos mesmos, o que pode prejudicar na avaliação da performance do modelo. Apesar disso, o modelo conseguiu simular a produtividade média com valor muito próximo a observada pelo IBGE no período, com médias de 64777 kg/ha para o IBGE e 66703 kg/ha do modelo. A destreza do modelo agrometeorológico foi obtida pela correlação de Pearson ($r = 0,63$), e pela raiz do erro quadrático médio (REQM), igual a 4637 kg/ha.

Figura 20: Comparação gráfica da produtividade observada pelo IBGE e simulada com o modelo agrometeorológico, para Maceió em 20 anos (1996 a 2015).



Ainda para efeito de validação do modelo, já inserindo o cenário de mudança climática A1B, foi possível observar no gráfico da figura 21 o comportamento dos valores de produtividade quando comparados os valores obtidos pelo IBGE, modelo agrometeorológico observado e o modelo agrometeorológico com cenário de mudança climática, no período de 2001 a 2015. De uma maneira geral, não há grandes discrepâncias nos valores de produtividade.

Figura 21: Comparativo entre valores médios obtidos através do IBGE, modelo agrometeorológico observado e modelo agrometeorológico com cenário de mudança climática.



5.4 – COMPORTAMENTO DA PRECIPITAÇÃO, TEMPERATURA MÉDIA E ETP PARA OS CENÁRIOS FUTUROS DO AR4 E CMIP5.

5.4.1 – JOÃO PESSOA

Nesta seção serão exibidos os resultados do comportamento das variáveis utilizadas no modelo agrometeorológico, já nas séries futuras simuladas, que foram divididas em: 2021 – 2050 e 2051 – 2080, confrontadas com a série observada que corresponde ao período de 1961 – 1990. As três variáveis serão exibidas lado a lado nos cenários A1B/A2 e nos cenários RCP4.5/RCP 8.5 para uma melhor visualização de seus comportamentos, ressaltando que os resultados são para o ENSEMBLE dos modelos.

Os cenários A1B e A2 subestimam a precipitação no período chuvoso entre março e agosto na cidade de João Pessoa. No cenário RCP 4.5 apresentou a superestimativa da precipitação no período considerado mais seco, entre setembro e dezembro e no RCP 8.5 esse comportamento é visível na série de 2021 – 2050. A temperatura média, nos cenários A1B e A2 mostram aumentos de 0,5°C entre 2021 – 2050 e de até 2°C entre 2051 – 2080, um comportamento similar foi observado nos RCPs. Em relação a ETP prevê-se aumentos de 20mm nos meses mais quentes nos cenários A1B e A2, já nos RCPs prevê-se redução da ETP nos períodos mais quentes do ano.

Figura 22: Comportamento da precipitação nos cenários A1B e A2 para a cidade de João Pessoa, nas séries temporais estudadas contrastadas com o período de observação.

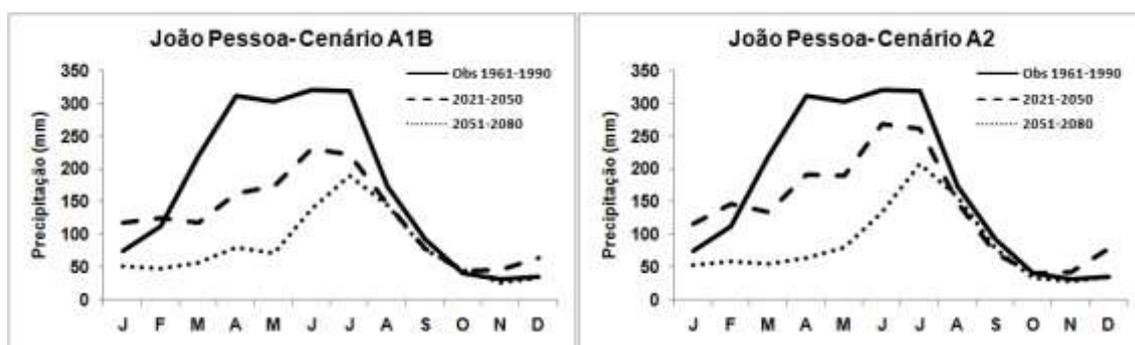


Figura 23: Comportamento da temperatura média nos cenários A1B e A2 para a cidade de João Pessoa, nas séries temporais estudadas contrastadas com o período de observação.

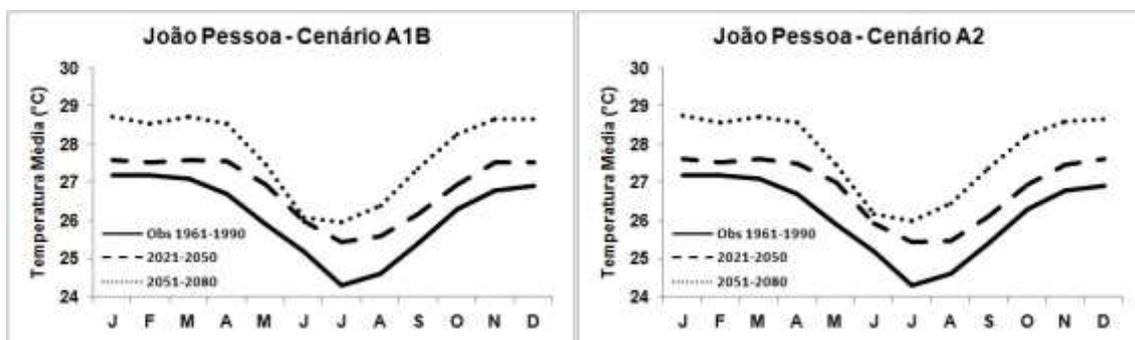


Figura 24: Comportamento da ETP nos cenários A1B e A2 para a cidade de João Pessoa, nas séries temporais estudadas contrastadas com o período de observação.

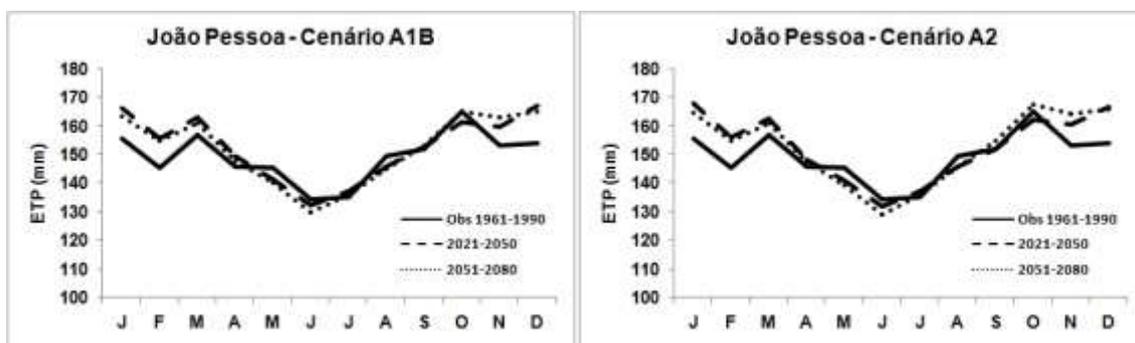


Figura 25: Comportamento da precipitação nos cenários RCP 4.5 e RCP 8.5 para a cidade de João Pessoa, nas séries temporais estudadas contrastadas com o período de observação.

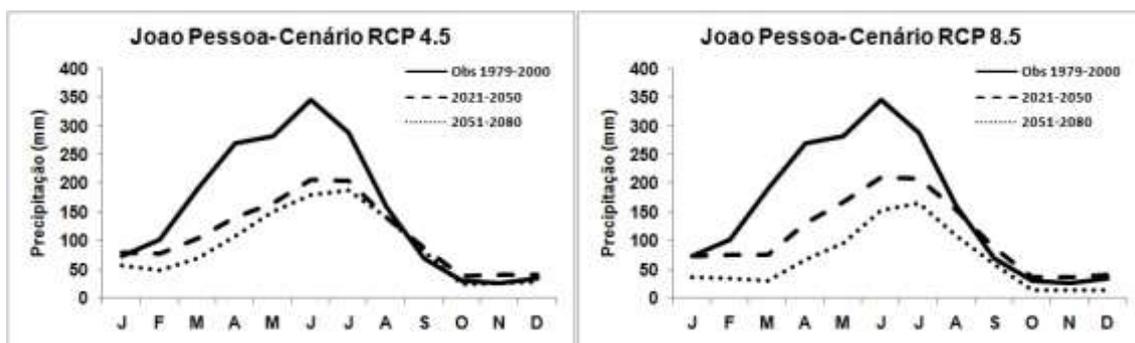


Figura 26: Comportamento da temperatura média nos cenários RCP 4.5 e RCP 8.5 para a cidade de João Pessoa, nas séries temporais estudadas contrastadas com o período de observação.

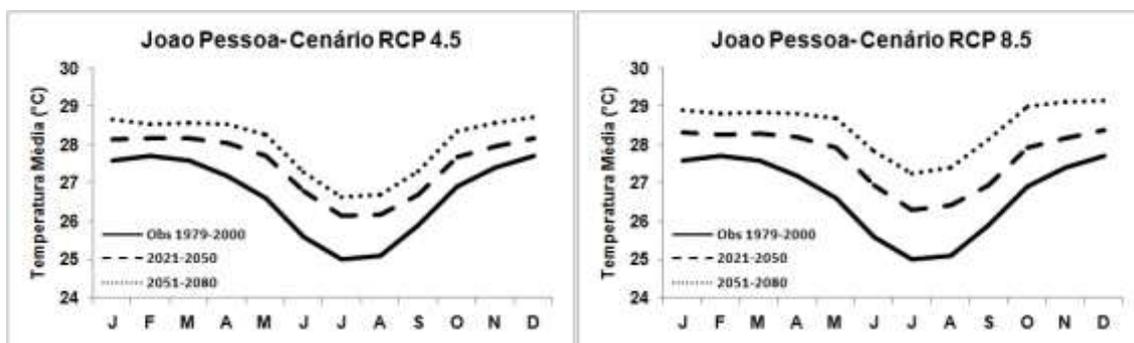
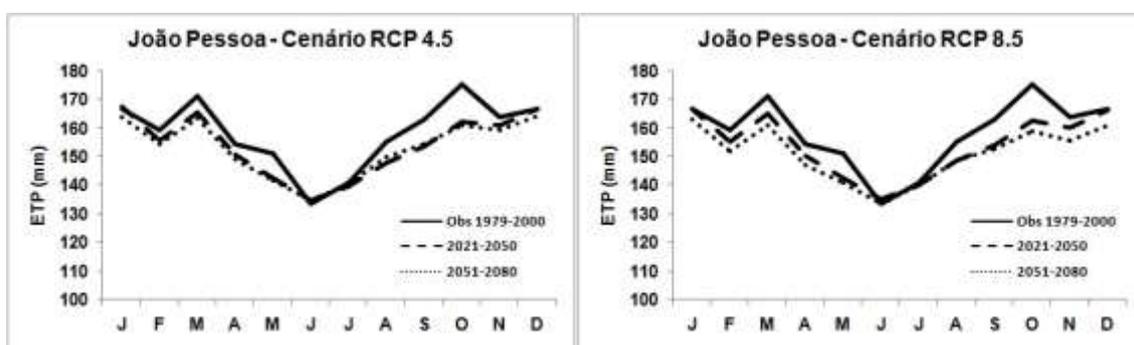


Figura 27: Comportamento da ETP nos cenários RCP 4.5 e RCP 8.5 para a cidade de João Pessoa, nas séries temporais estudadas contrastadas com o período de observação.



5.4.2 – RECIFE

Nesta seção, a exemplo da anterior, serão exibidos os resultados do comportamento das variáveis utilizadas no modelo agrometeorológico, já nas séries futuras simuladas, que foram divididas em: 2021 – 2050 e 2051 – 2080, confrontadas com a série observada que corresponde ao período de 1961 – 1990. As três variáveis serão exibidas lado a lado nos cenários A1B/A2 e nos cenários RCP4.5/RCP 8.5 para uma melhor visualização de seus comportamentos, ressaltando que os resultados são para o ENSEMBLE dos modelos.

Assim como visto na cidade de João Pessoa, os cenários A1B e A2 subestimam a precipitação no período chuvoso entre março e agosto, porém há previsão de aumento das chuvas nos meses de setembro a dezembro, nos mesmo cenários. Nos RCPs, um comportamento similar foi observado. A temperatura média apresenta aumento de 0,5°C entre 2021 – 2050 e de até 2°C entre 2051 – 2080. Os cenários RCPs apresentam a

aumento de até 1,5°C. A evapotranspiração em Recife prevê-se que nos cenários A1B e A2 existam aumento de até 30mm nos meses mais quentes enquanto nos RCPs os valores médios mensais da ETP pouco se alteram em relação a climatologia de referência observada.

Figura 28: Comportamento da precipitação nos cenários A1B e A2 para a cidade de Recife, nas séries temporais estudadas contrastadas com o período de observação.

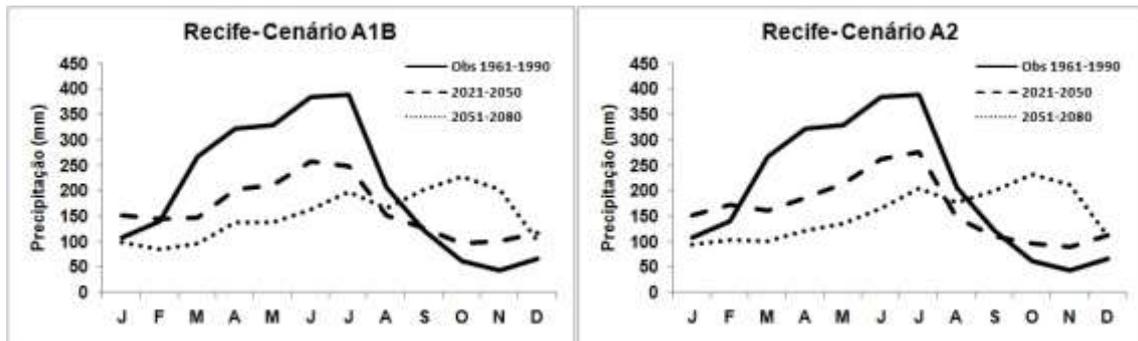


Figura 29: Comportamento da temperatura média nos cenários A1B e A2 para a cidade de Recife, nas séries temporais estudadas contrastadas com o período de observação.

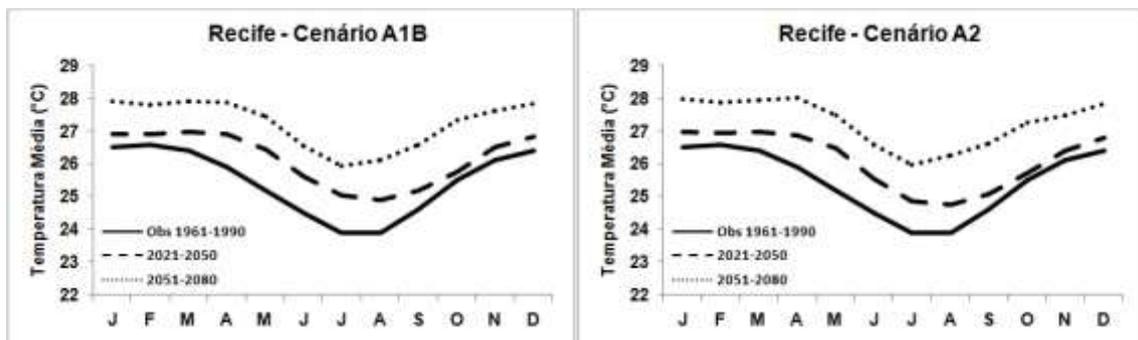


Figura 30: Comportamento da ETP nos cenários A1B e A2 para a cidade de Recife, nas séries temporais estudadas contrastadas com o período de observação.

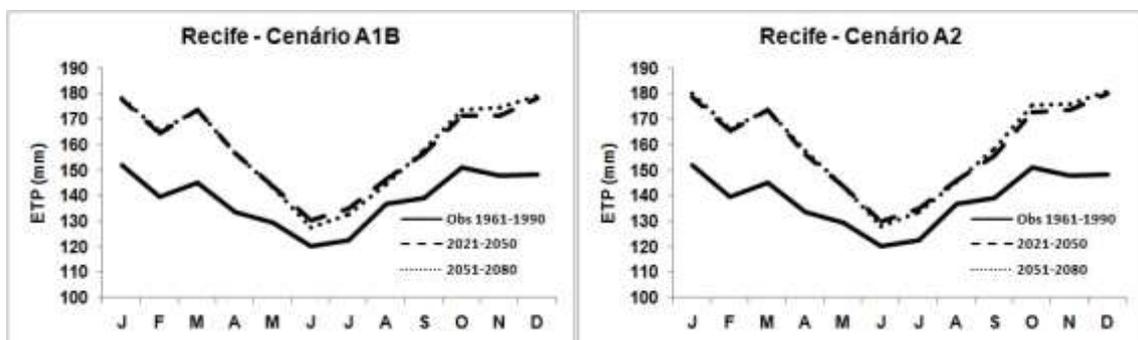


Figura 31: Comportamento da precipitação nos cenários RCP 4.5 e RCP 8.5 para a cidade de Recife, nas séries temporais estudadas contrastadas com o período de observação.

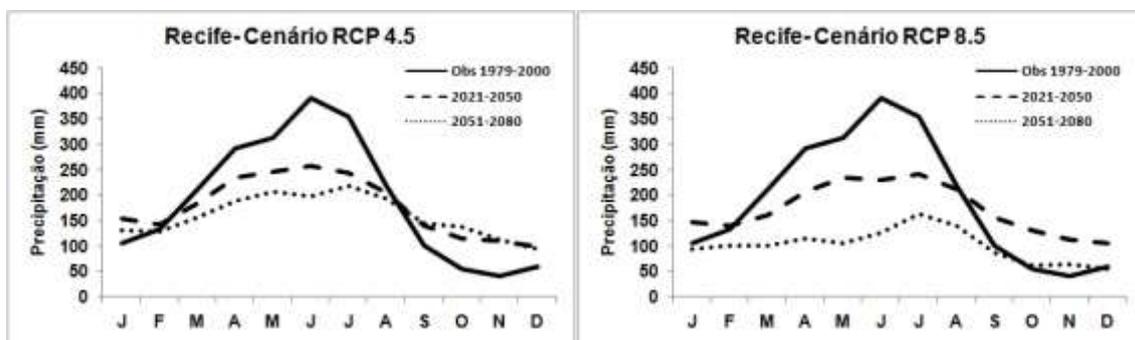


Figura 32: Comportamento da temperatura média nos cenários RCP 4.5 e RCP 8.5 para a cidade de Recife, nas séries temporais estudadas contrastadas com o período de observação.

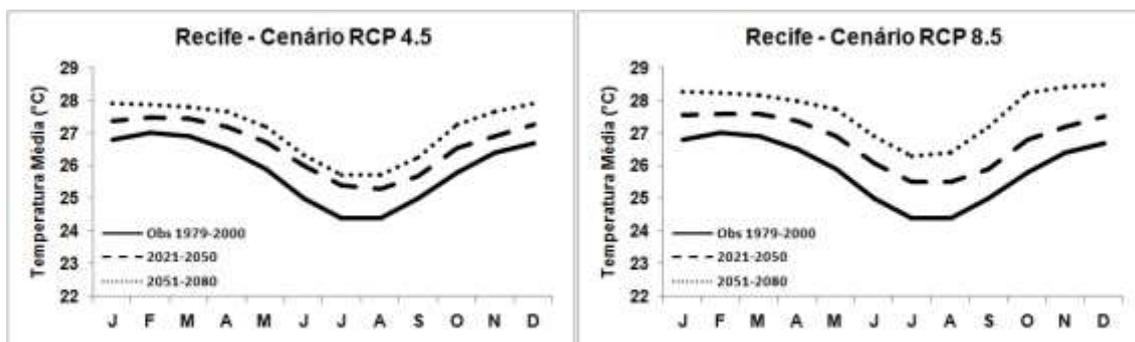
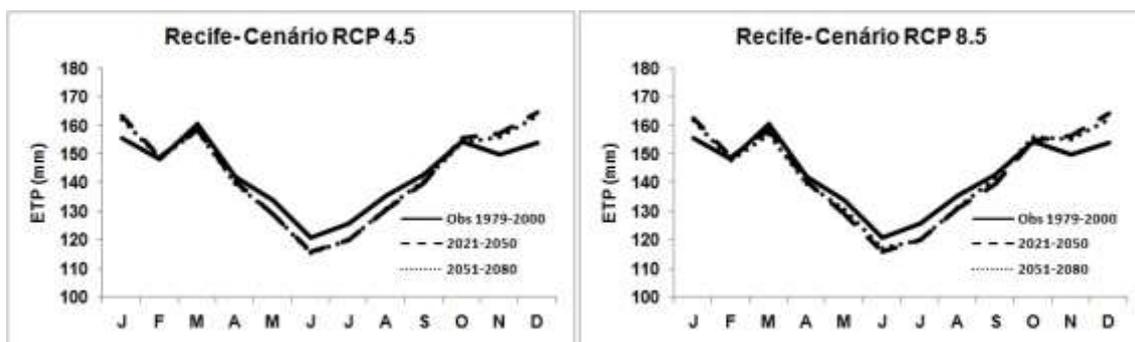


Figura 33: Comportamento da ETP nos cenários RCP 4.5 e RCP 8.5 para a cidade de Recife, nas séries temporais estudadas contrastadas com o período de observação.



5.4.3 – PORTO DE PEDRAS

Nesta seção, a exemplo das duas seções anteriores, serão exibidos os resultados do comportamento das variáveis utilizadas no modelo agrometeorológico, sendo eles exibidos para o ENSEMBLE dos modelos.

Em relação a precipitação, o comportamento observado foi semelhante ao encontrado em Recife. Nos cenários A1B e A2 há previsão de aumento da temperatura média em até 3,5°C entre 2051 – 2080 e de aumento entre 1°C a 2,5°C nos RCPs. Com relação a ETP nos cenários A1B e A2 há redução significativa, de até 70mm nos meses de inverno. Nos cenários RCP essa diminuição é moderada nos meses mais frios do ano, sendo de até 20mm e com um aumento de até 10mm nos meses mais quentes.

Figura 34: Comportamento da precipitação nos cenários A1B e A2 para a cidade de Porto de Pedras, nas séries temporais estudadas contrastadas com o período de observação.

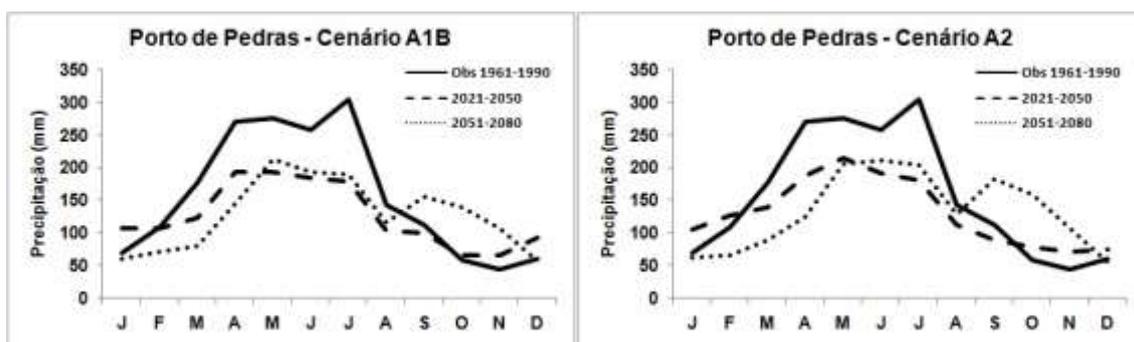


Figura 35: Comportamento da temperatura média nos cenários A1B e A2 para a cidade de Porto de Pedras, nas séries temporais estudadas contrastadas com o período de observação.

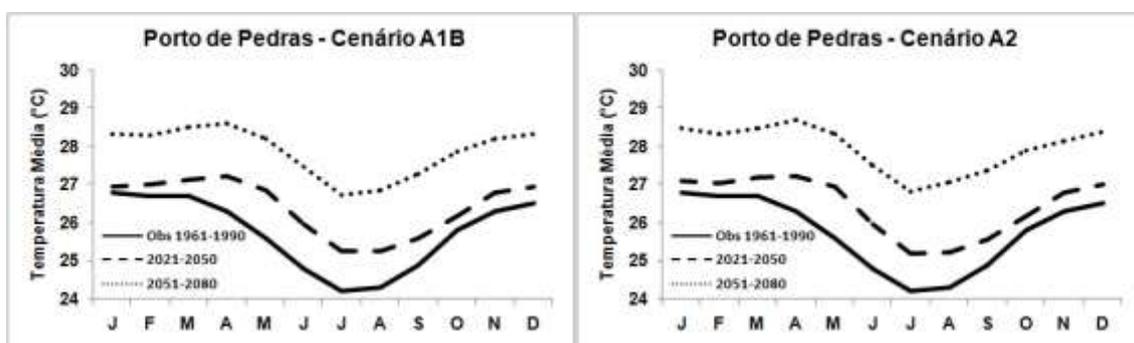


Figura 36: Comportamento da ETP nos cenários A1B e A2 para a cidade de Porto de Pedras, nas séries temporais estudadas contrastadas com o período de observação.

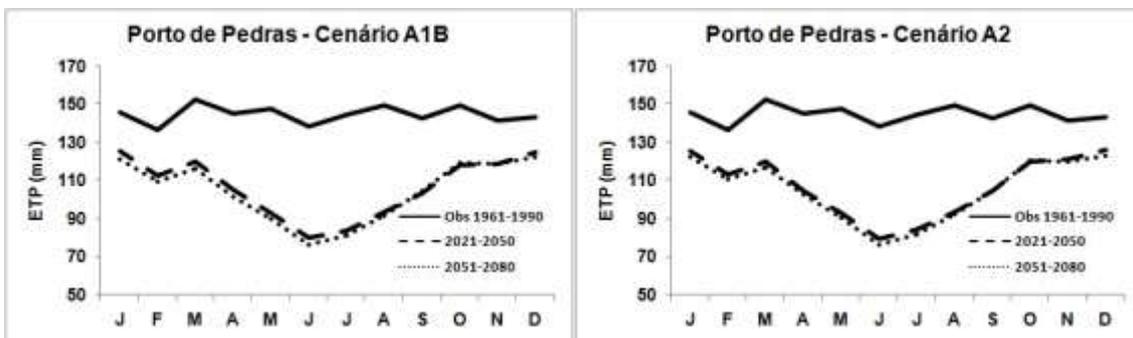


Figura 37: Comportamento da precipitação nos cenários RCP 4.5 e RCP 8.5 para a cidade de Porto de Pedras, nas séries temporais estudadas contrastadas com o período de observação.

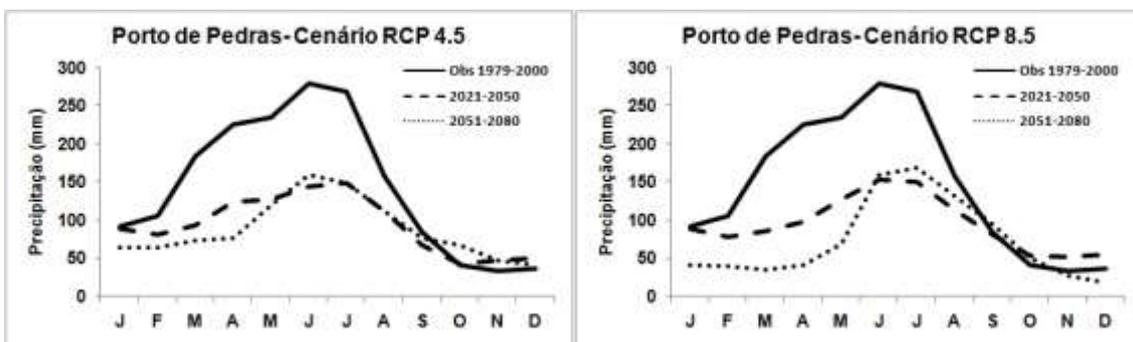


Figura 38: Comportamento da temperatura média nos cenários RCP 4.5 e RCP 8.5 para a cidade de Porto de Pedras, nas séries temporais estudadas contrastadas com o período de observação.

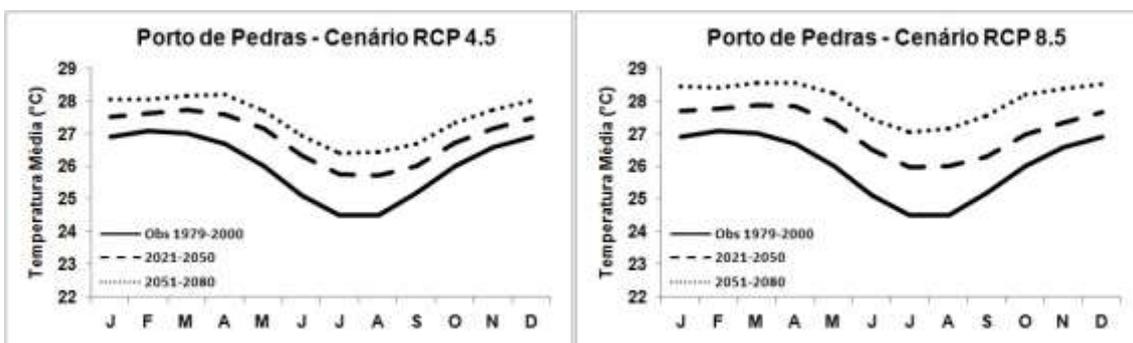
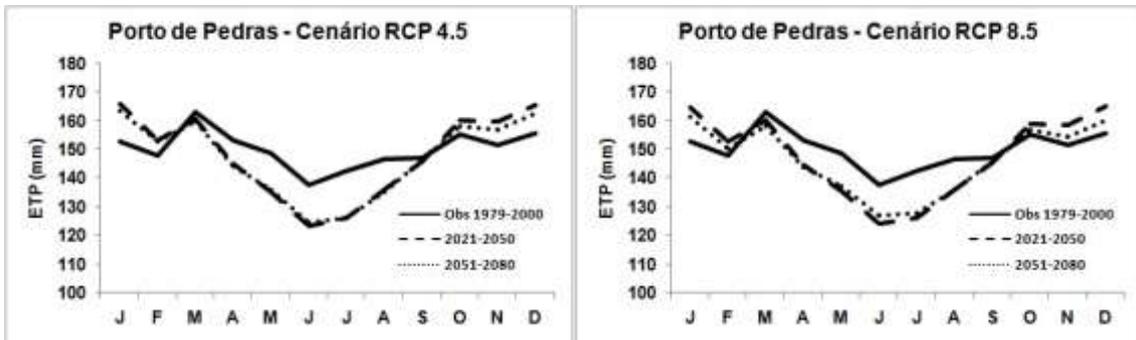


Figura 39: Comportamento da ETP nos cenários RCP 4.5 e RCP 8.5 para a cidade de Porto de Pedras, nas séries temporais estudadas contrastadas com o período de observação.



5.4.4 – MACEIÓ

Nesta seção, a exemplo das três seções anteriores, serão exibidos os resultados do comportamento das variáveis utilizadas no modelo agrometeorológico, sendo eles exibidos para o ENSEMBLE dos modelos.

Assim como Porto de Pedras e Recife, o comportamento da precipitação foi semelhante ao encontrado nessas cidades. A temperatura média apresentou um aumento nos cenários A1B e A2 que varia entre 0,5°C a 2°C, essa mesma média de variação foi encontrada nos RCPs no período de 2051 – 2080. Em relação a ETP, os cenários A1B e A2 preveem um comportamento similar ao de Porto de Pedras, porém nos RCPs prevê-se uma diminuição de até 10mm no inverno com um aumento moderado de até 30mm nos meses mais quentes.

Figura 40: Comportamento da precipitação nos cenários A1B e A2 para a cidade de Maceió, nas séries temporais estudadas contrastadas com o período de observação.

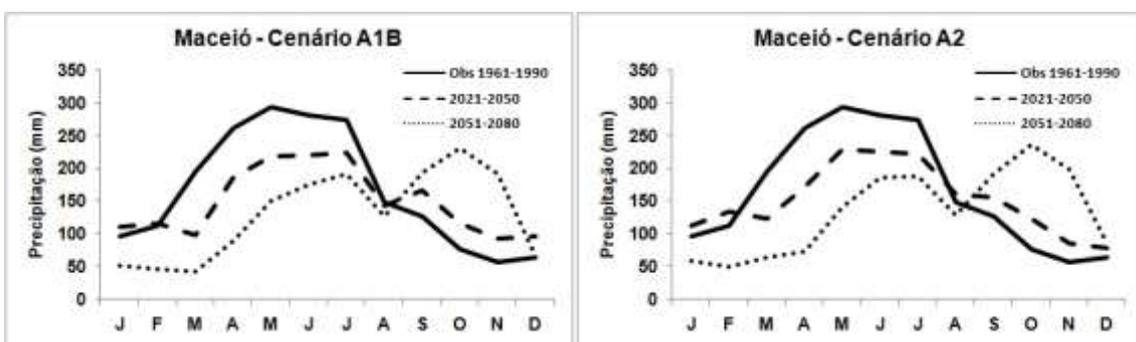


Figura 41: Comportamento da temperatura média nos cenários A1B e A2 para a cidade de Maceió, nas séries temporais estudadas contrastadas com o período de observação.

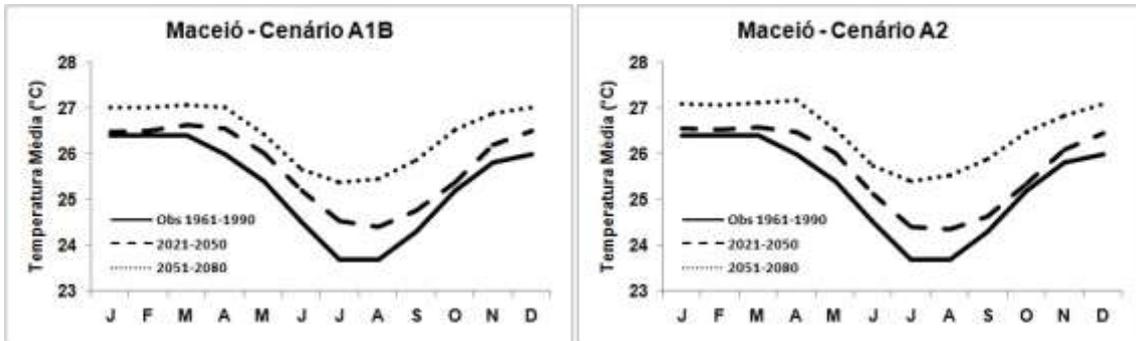


Figura 42: Comportamento da ETP nos cenários A1B e A2 para a cidade de Maceió, nas séries temporais estudadas contrastadas com o período de observação.

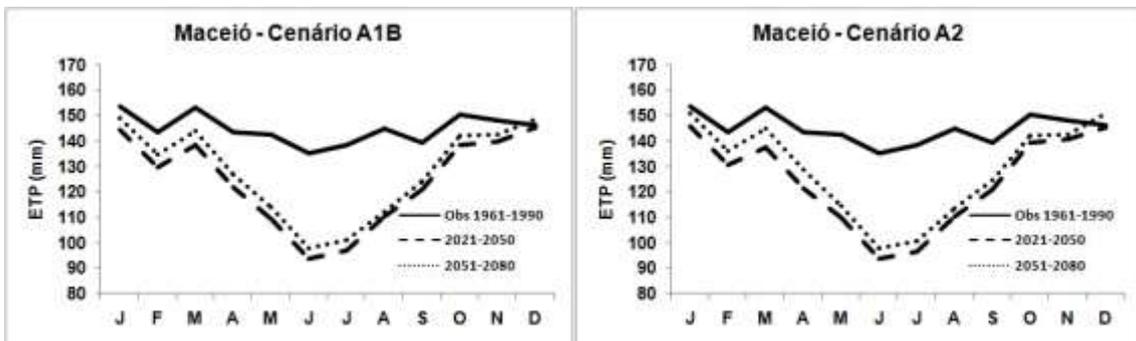


Figura 43: Comportamento da precipitação nos cenários RCP 4.5 e RCP 8.5 para a cidade de Maceió, nas séries temporais estudadas contrastadas com o período de observação.

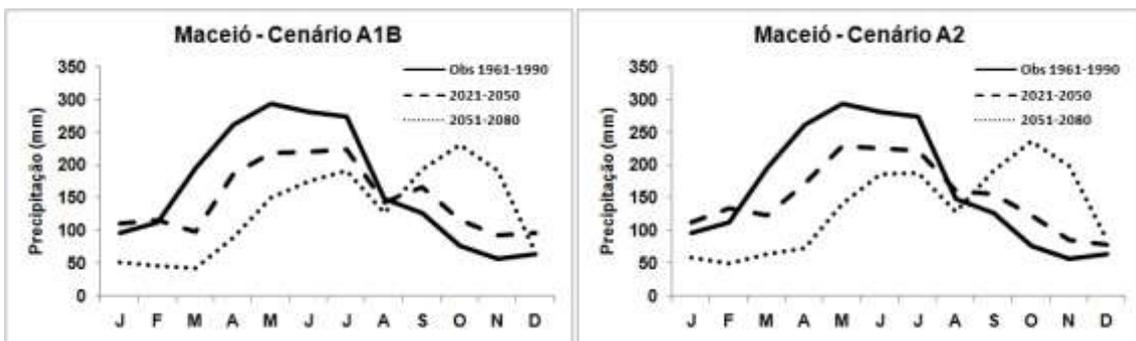


Figura 44: Comportamento da temperatura média nos cenários RCP 4.5 e RCP 8.5 para a cidade de Maceió, nas séries temporais estudadas contrastadas com o período de observação.

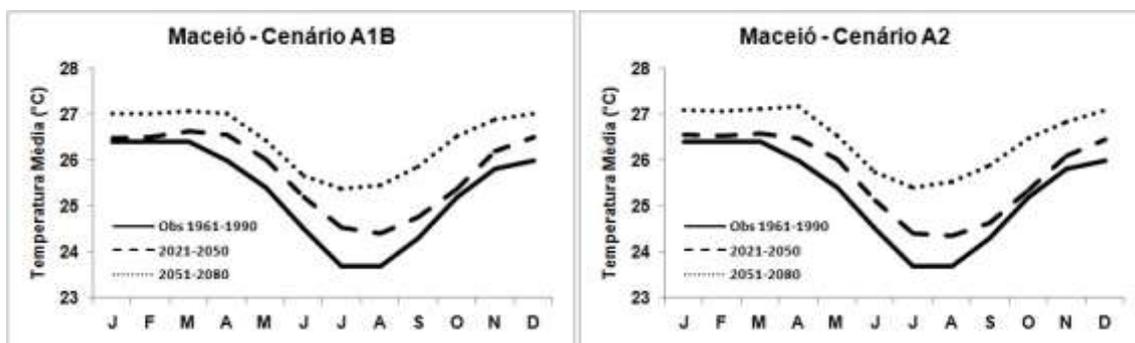
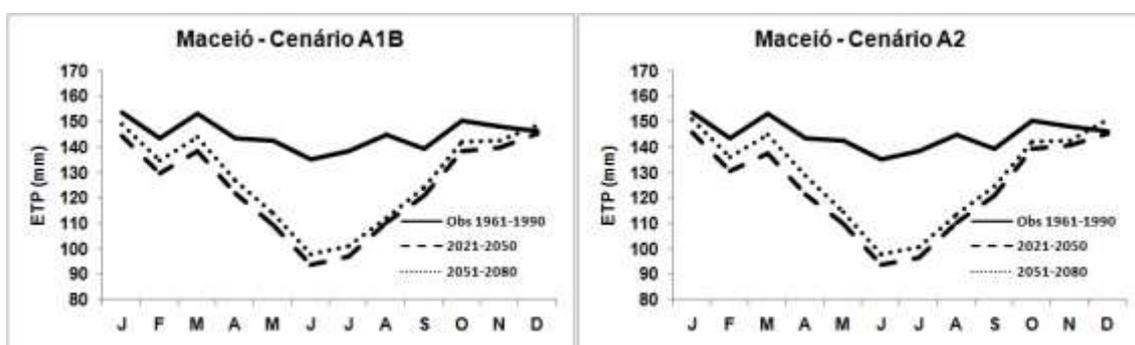


Figura 45: Comportamento da ETP nos cenários RCP 4.5 e RCP 8.5 para a cidade de Maceió, nas séries temporais estudadas contrastadas com o período de observação.



5.5 – SIMULAÇÃO DE PRODUTIVIDADE DA CANA DE AÇÚCAR PARA CENÁRIOS FUTUROS

5.5.1 – JOÃO PESSOA

Nesta seção serão exibidas as simulações de produtividade média da cana de açúcar, processo esse realizado após a etapa de calibração e validação do modelo agrometeorológico e do downscaling estatístico, para o período que corresponde de 2021 a 2080, utilizando os cenários A1B e A2 (AR4) do quarto relatório do IPCC e os cenários RCP 4.5 e RCP 8.5 (CMIP 5), do quinto relatório do IPCC. Os modelos gerados no cenário A1B e A2 foram: BCM2, CNCM3, ECHAM-5OM e HADGEM-2ES. Já nos cenários RCP 4.5 e RCP 8.5 foram: CANESM2, CNRM-CM5, GFDL-ESM2M, IPSL-CM5A-MR, MIROC-ESM, MPI-ESM-MR e NORESM1-M.

As simulações serão exibidas individualmente para uma melhor visibilidade de todos os modelos simulados e o comportamento da produtividade média, expressa em

kg/ha. Por último, encontra-se uma figura onde estão os quatro cenários estudados confrontados de maneira que é possível ver o comportamento das simulações para o ENSEMBLE desses modelos. Em todos os modelos dos cenários A1B e A2 é presente a tendência de aumento da produtividade média da cultura na cidade de João Pessoa. Nos modelos dos cenários RCP 4.5 e RCP 8.5 essa tendência crescente é menos pronunciada. No ENSEMBLE observa-se que os cenários RCPs tendem a estimar uma produtividade maior que a dos modelos dos cenários A1B e A2. Há uma estabilização das estimativas entre cenários e modelos a partir do ano de 2060.

Figura 46: Produtividade média prevista para a Cana de açúcar em João Pessoa, no cenário A1B no período de 2021 – 2080.

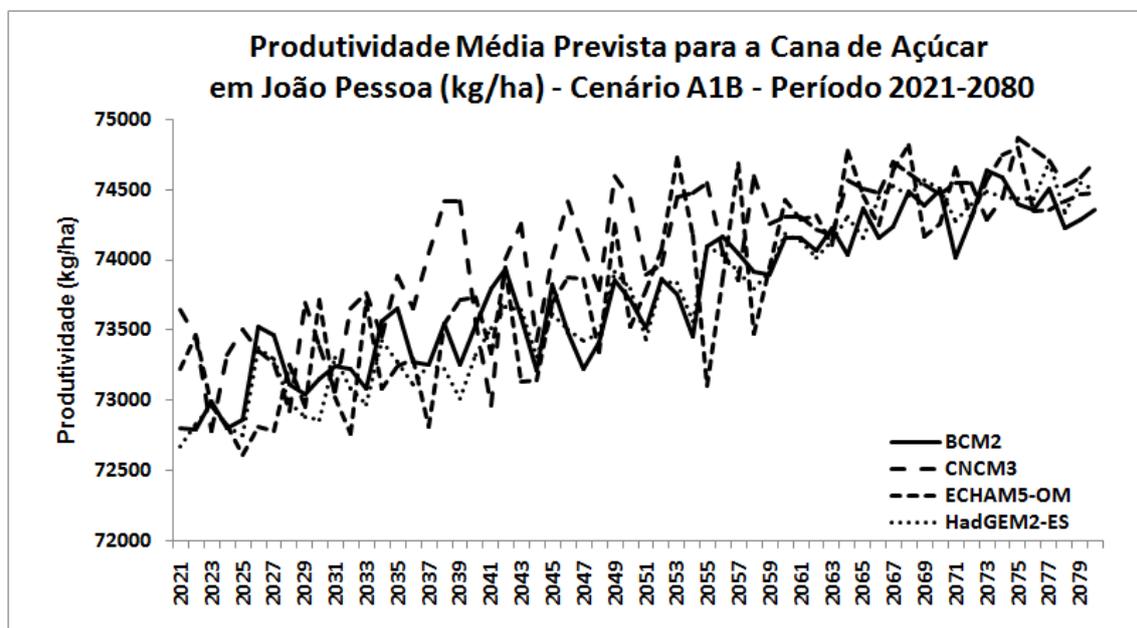


Figura 47: Produtividade média prevista para a Cana de açúcar em João Pessoa, no cenário A2 no período de 2021 – 2080.

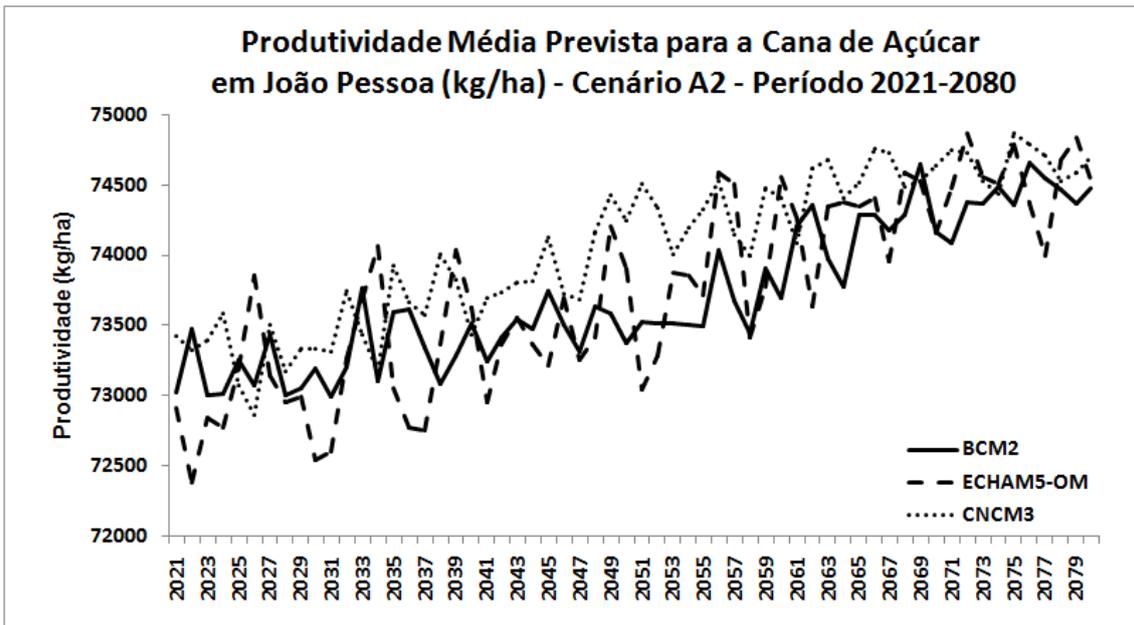


Figura 48: Produtividade média prevista para a Cana de açúcar em João Pessoa, no cenário RCP 4.5 no período de 2021 – 2080.

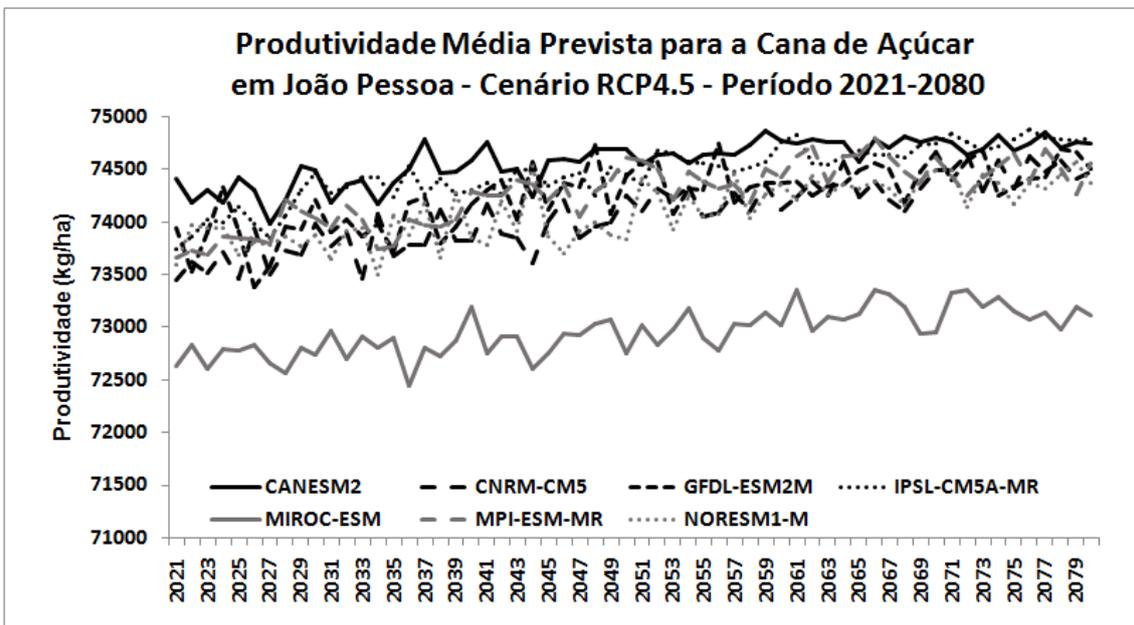


Figura 49: Produtividade média prevista para a Cana de açúcar em João Pessoa, no cenário RCP 8.5 no período de 2021 – 2080.

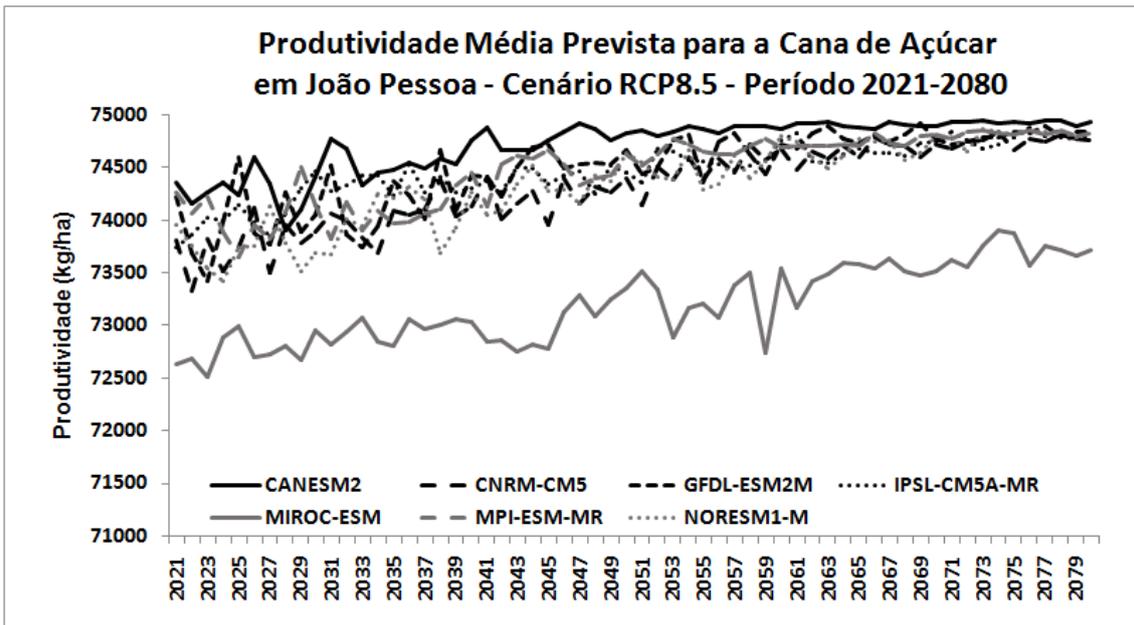
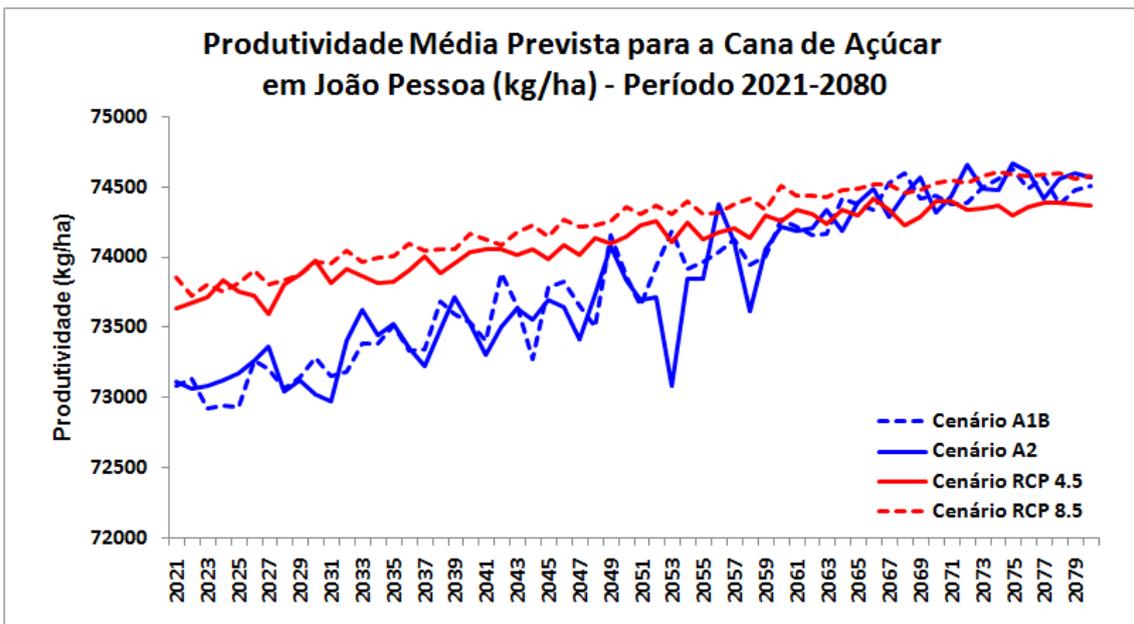


Figura 50: Produtividade média prevista para a Cana de açúcar em João Pessoa, para o ENSEMBLE dos modelos de todos os cenários estudados no período de 2021 – 2080.



5.5.2 – RECIFE

Nesta seção serão exibidas as simulações de produtividade média da cana de açúcar, seguindo o mesmo padrão existente na seção anterior.

As simulações serão exibidas individualmente para uma melhor visibilidade de todos os modelos simulados e o comportamento da produtividade média, expressa em kg/ha. Por último, encontra-se uma figura onde estão os quatro cenários estudados confrontados de maneira que é possível ver o comportamento das simulações para o ENSEMBLE desses modelos. Em Recife é possível observar que as tendências da produtividade são similares a João Pessoa, porém o ENSEMBLE mostra que há maior tendência de aumento da produtividade média nos cenários A1B e A2, diferente de João Pessoa que apresentava essa tendência nos RCPs.

Figura 51: Produtividade média prevista para a Cana de açúcar em Recife, no cenário A1B no período de 2021 – 2080.

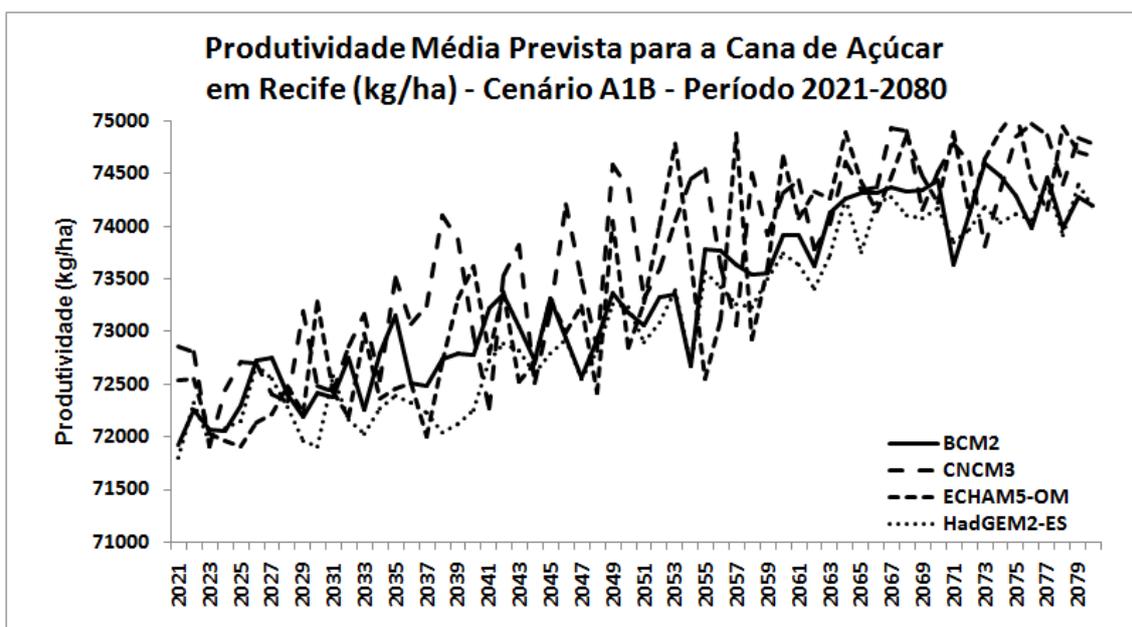


Figura 52: Produtividade média prevista para a Cana de açúcar em Recife, no cenário A2 no período de 2021 – 2080.

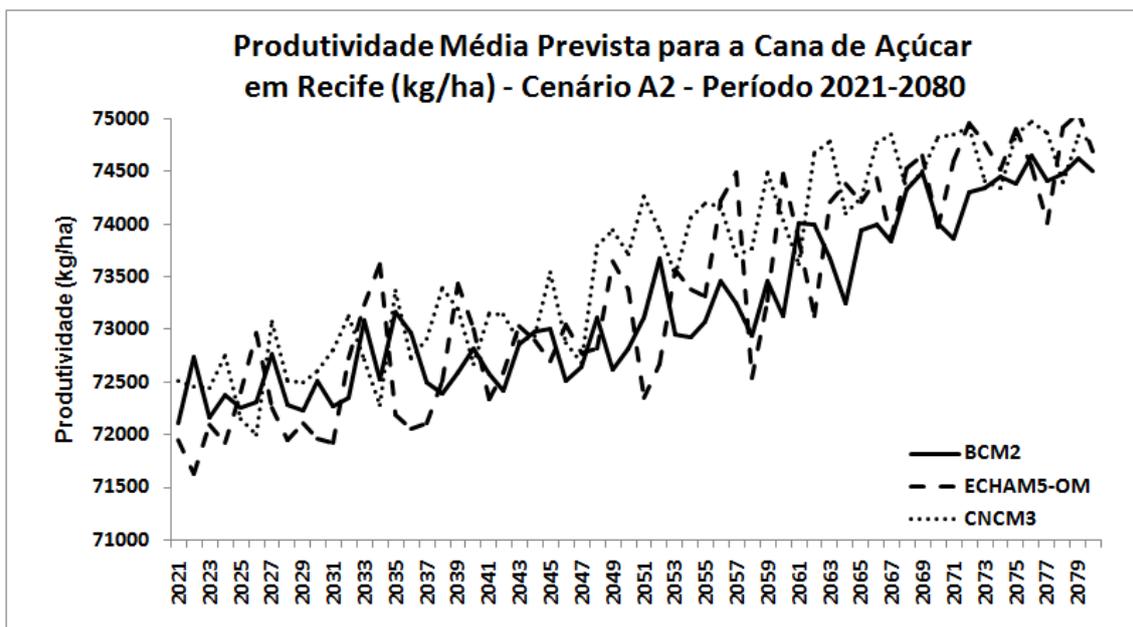


Figura 53: Produtividade média prevista para a Cana de açúcar em Recife, no cenário RCP 4.5 no período de 2021 – 2080.

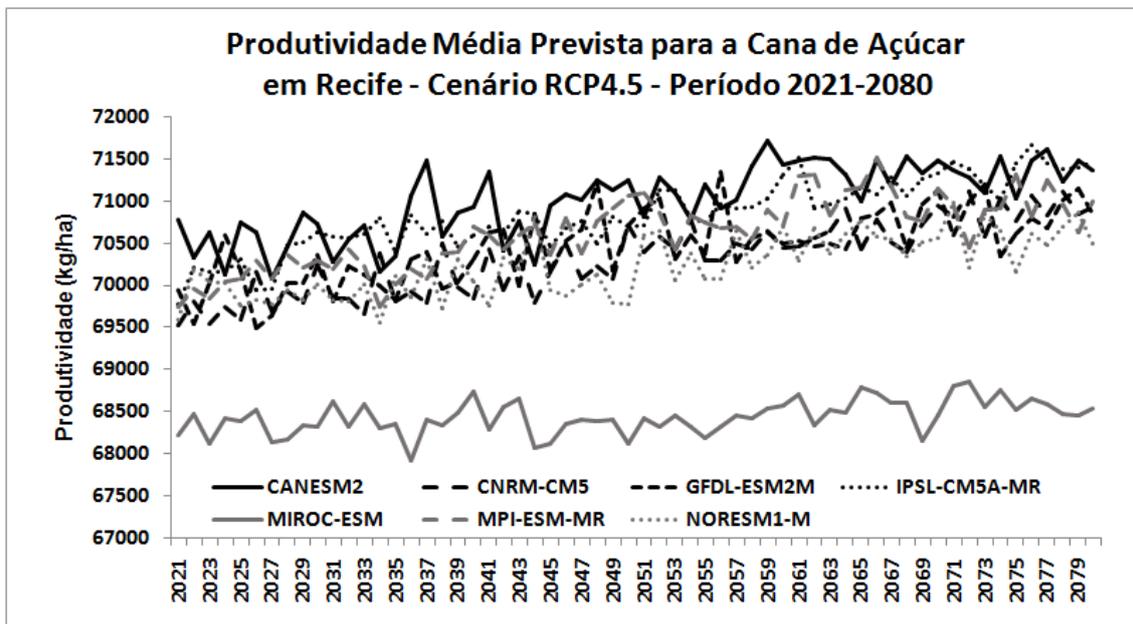


Figura 54: Produtividade média prevista para a Cana de açúcar em Recife, no cenário RCP 8.5 no período de 2021 – 2080.

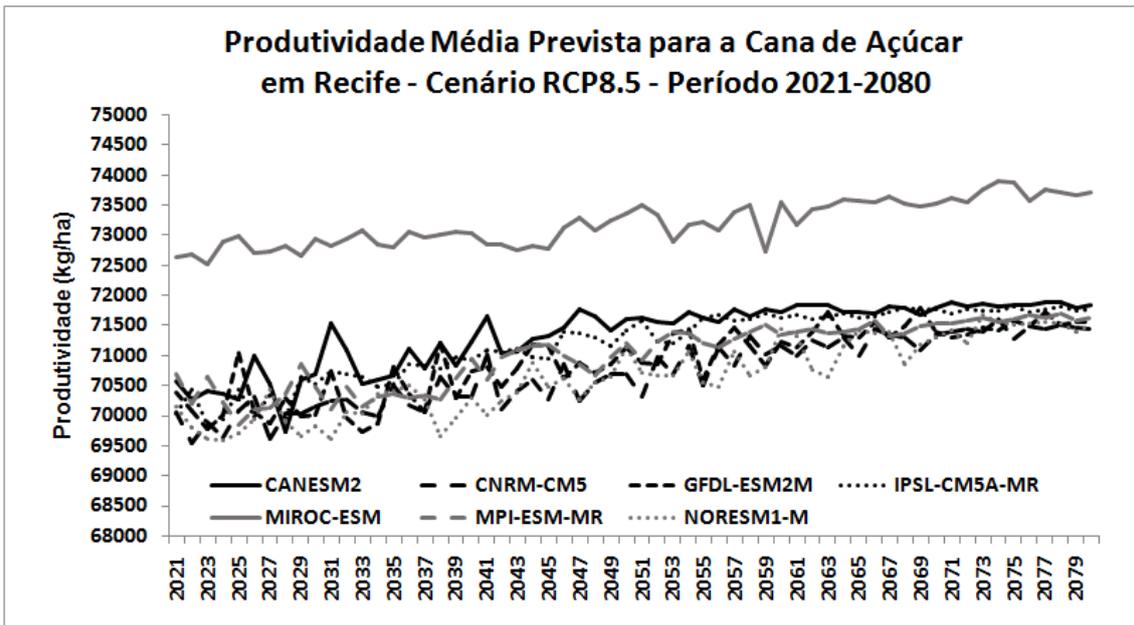
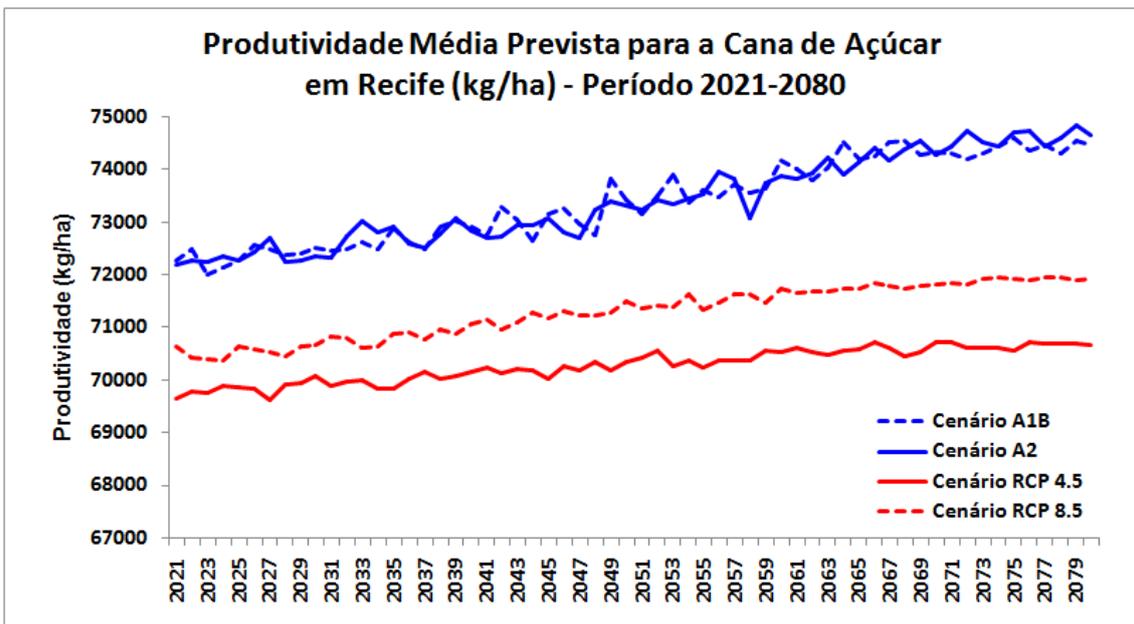


Figura 55: Produtividade média prevista para a Cana de açúcar em Recife, para o ENSEMBLE dos modelos de todos os cenários estudados no período de 2021 – 2080.



5.5.3 – PORTO DE PEDRAS

Nesta seção serão exibidas as simulações de produtividade média da cana de açúcar, seguindo o mesmo padrão existente nas duas seções anteriores.

As simulações serão exibidas individualmente para uma melhor visibilidade de todos os modelos simulados e o comportamento da produtividade média, expressa em kg/ha. Por último, encontra-se uma figura onde estão os quatro cenários estudados confrontados de maneira que é possível ver o comportamento das simulações para o ENSEMBLE desses modelos. No cenário A1B há uma maior variabilidade entre os modelos até o ano de 2050, apesar da tendência crescente observada. Entre 2051 e 2080 todos os resultados convergem para valores próximos da produtividade. O cenário A2 mostra essa tendência crescente em toda a série de forma mais harmônica. Já nos RCPs os modelos apresentam a tendência crescente de produtividade de forma acentuada até o ano de 2050 e de forma mais linear de 2051 – 2080. No ENSEMBLE observa-se que os RCPs superam os valores previstos pelos cenários A1B e A2 até o ano de 2050 e então tem os valores médios superados pelos modelos dos cenários A1B e A2.

Figura 56: Produtividade média prevista para a Cana de açúcar em Porto de Pedras, no cenário A1B no período de 2021 – 2080.

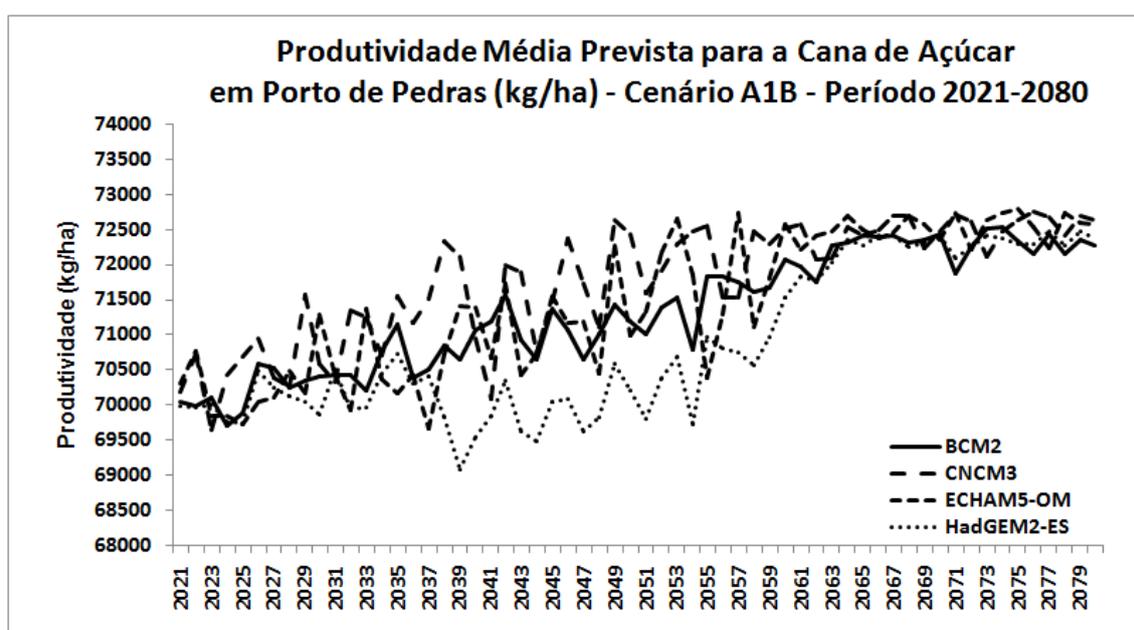


Figura 57: Produtividade média prevista para a Cana de açúcar em Porto de Pedras, no cenário A2 no período de 2021 – 2080.

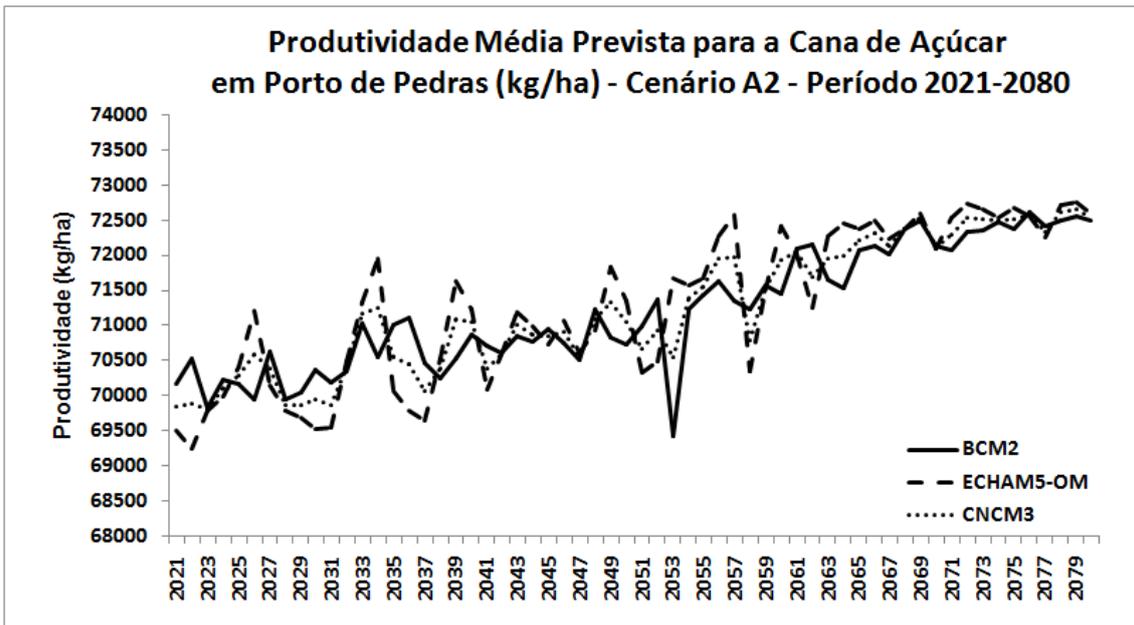


Figura 58: Produtividade média prevista para a Cana de açúcar em Porto de Pedras, no cenário RCP 4.5 no período de 2021 – 2080.

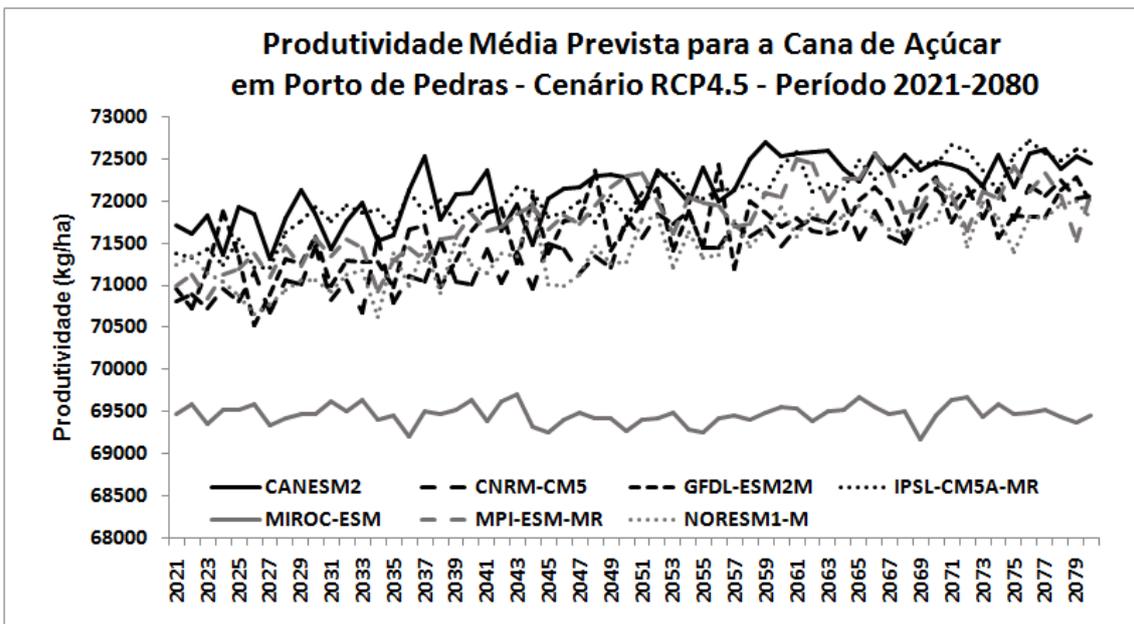


Figura 59: Produtividade média prevista para a Cana de açúcar em Porto de Pedras, no cenário RCP 8.5 no período de 2021 – 2080.

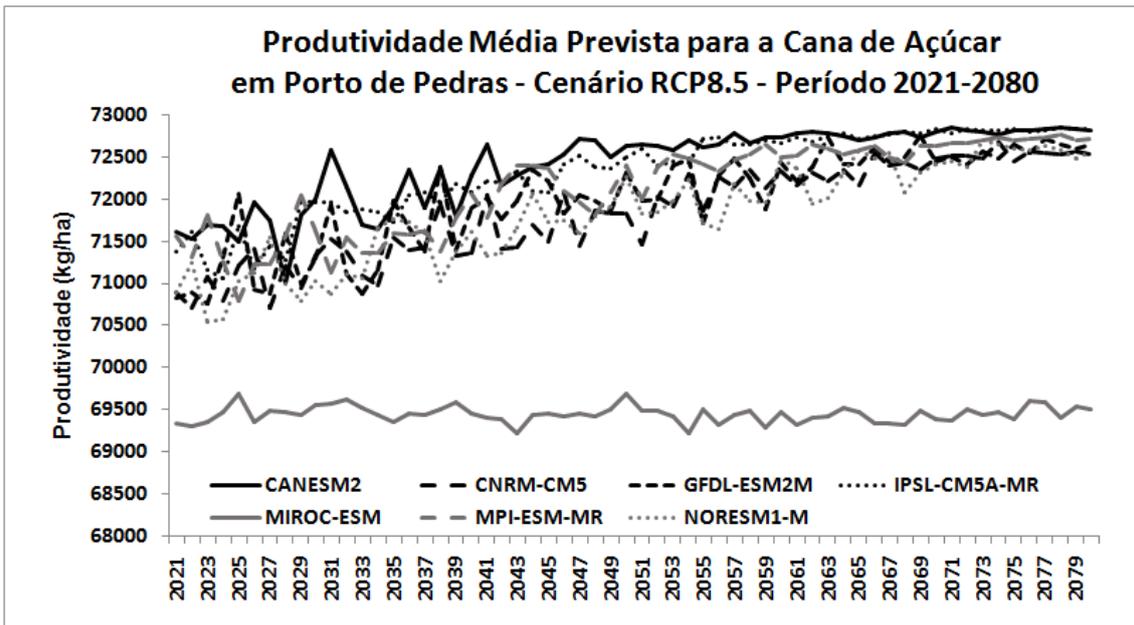
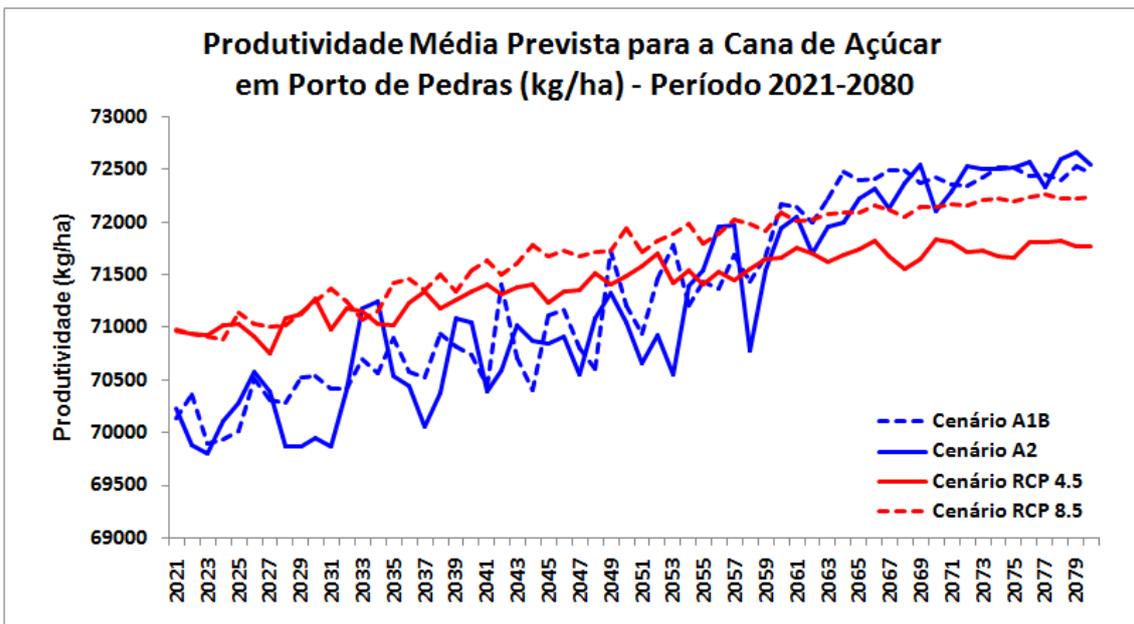


Figura 60: Produtividade média prevista para a Cana de açúcar em Porto de Pedras, para o ENSEMBLE dos modelos de todos os cenários estudados no período de 2021 – 2080.



5.5.4 – MACEIÓ

Nesta seção serão exibidas as simulações de produtividade média da cana de açúcar, seguindo o mesmo padrão existente nas três seções anteriores.

As simulações serão exibidas individualmente para uma melhor visibilidade de todos os modelos simulados e o comportamento da produtividade média, expressa em kg/ha. Por último, encontra-se uma figura onde estão os quatro cenários estudados confrontados de maneira que é possível ver o comportamento das simulações para o ENSEMBLE desses modelos. O comportamento das linhas de produtividade estimados pelos modelos dos cenários A1B e A2 é muito similar ao que foi observado em Recife e também para os RCPs. No entanto, as estimativas de produtividade dos modelos dos RCPs são superiores aos dos modelos dos cenários A1B e A2.

Figura 61: Produtividade média prevista para a Cana de açúcar em Maceió, no cenário A1B no período de 2021 – 2080.

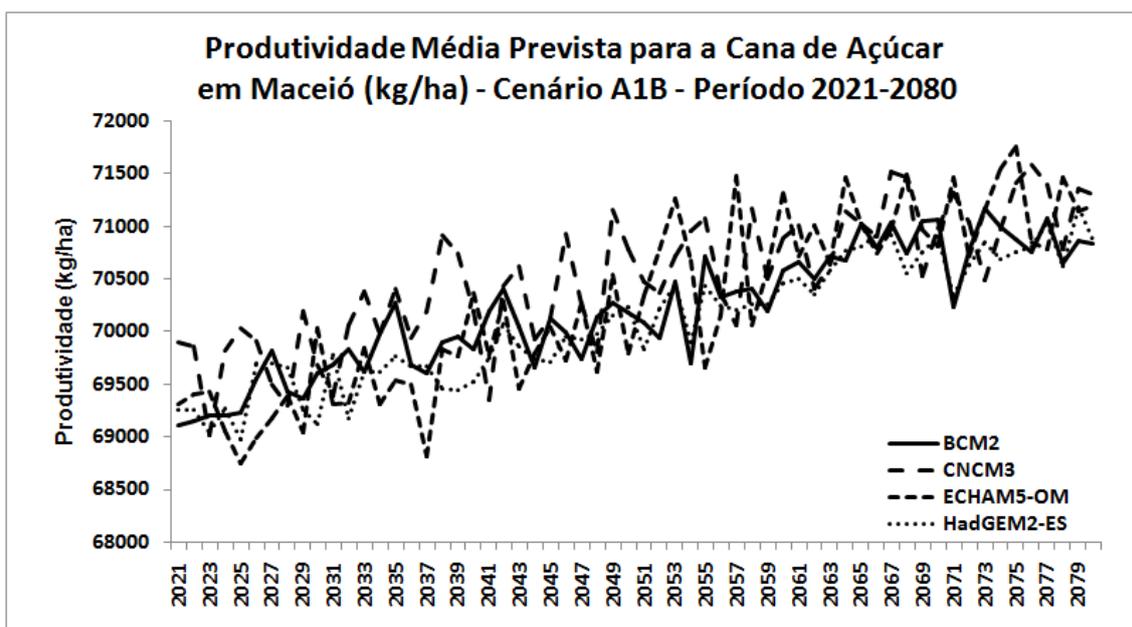


Figura 62: Produtividade média prevista para a Cana de açúcar em Maceió, no cenário A2 no período de 2021 – 2080.

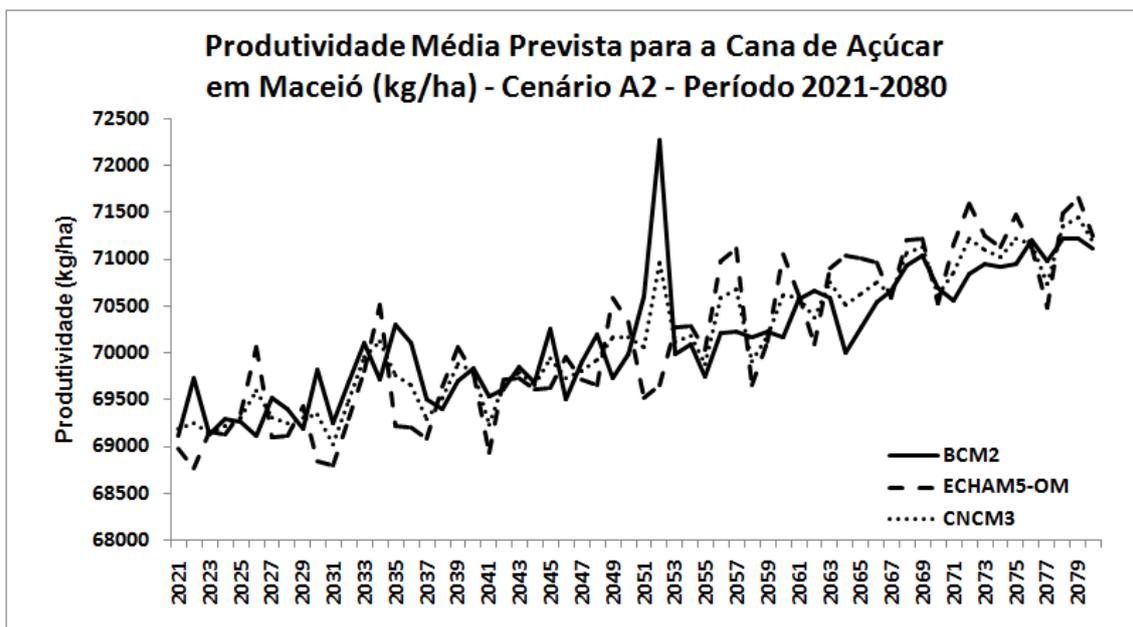


Figura 63: Produtividade média prevista para a Cana de açúcar em Maceió, no cenário RCP 4.5 no período de 2021 – 2080.

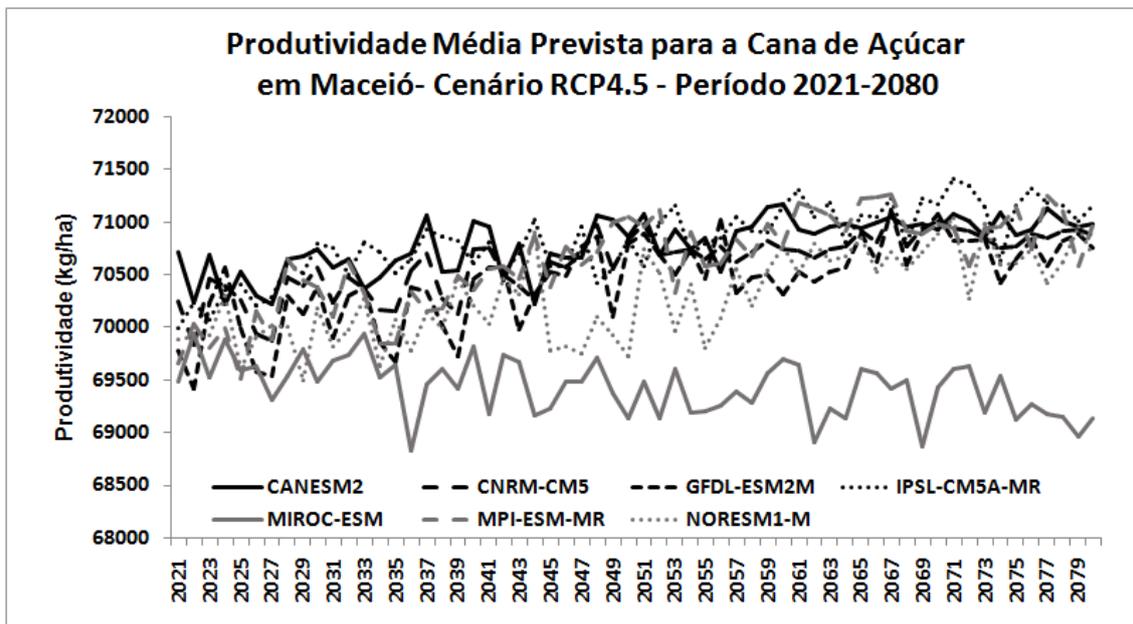


Figura 64: Produtividade média prevista para a Cana de açúcar em Maceió, no cenário RCP 8.5 no período de 2021 – 2080.

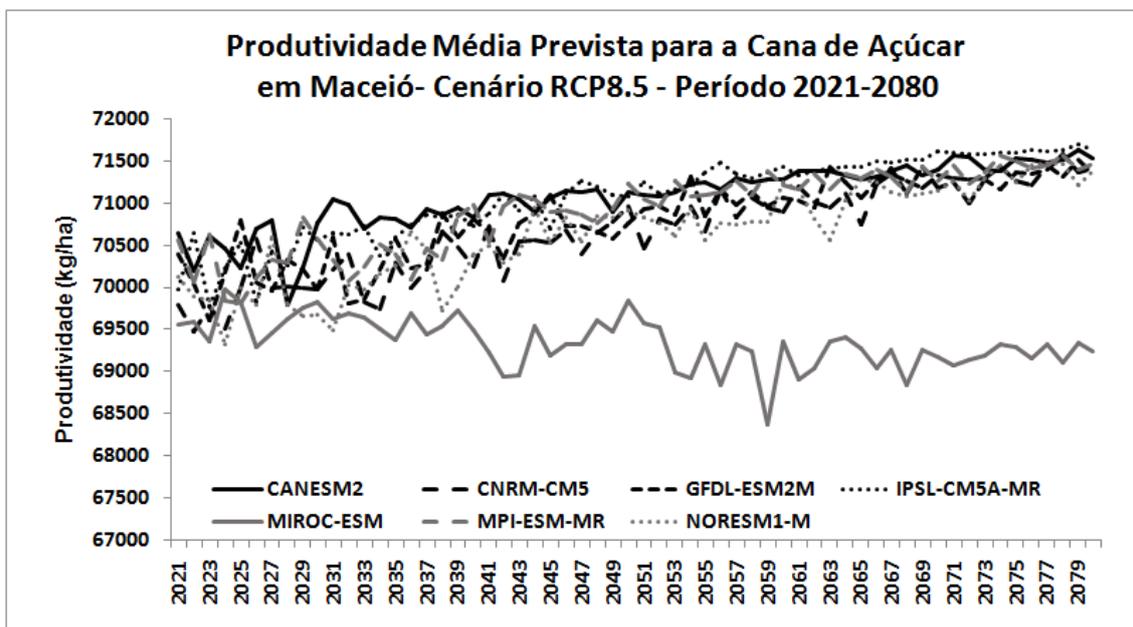
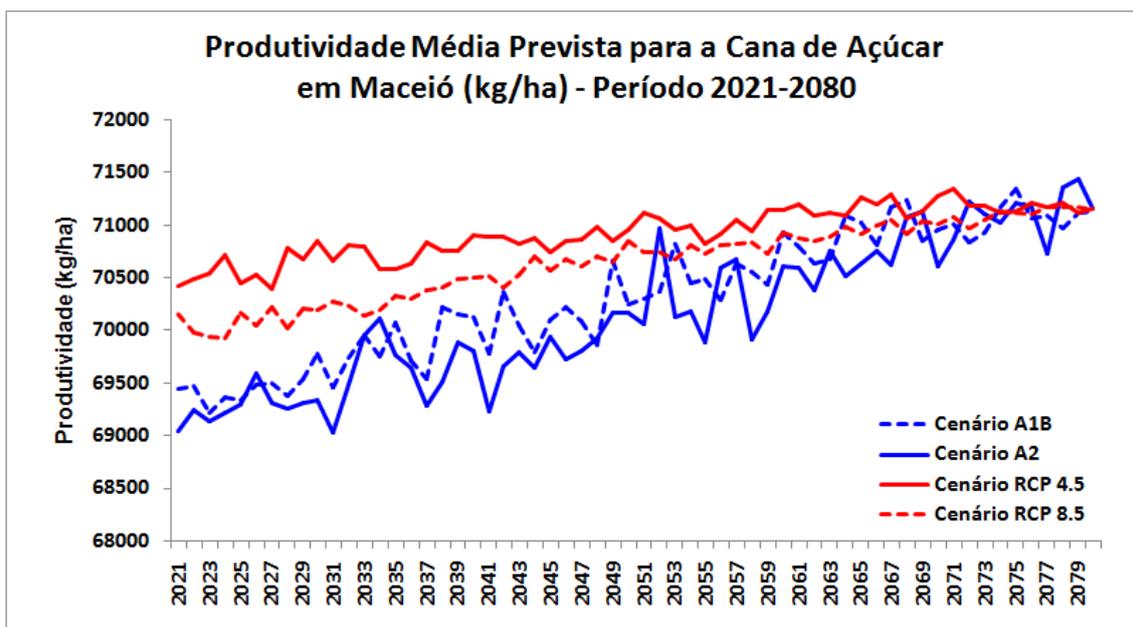


Figura 65: Produtividade média prevista para a Cana de açúcar em Maceió, para o ENSEMBLE dos modelos de todos os cenários estudados no período de 2021 – 2080.



6. CONCLUSÕES

Diante de todos os resultados obtidos, é possível afirmar que referente a calibração dos modelos utilizados para a simulação do clima observado a representação do ciclo médio anual das variáveis foi muito boa, fortalecendo a escolha dos preditores escolhidos para o downscaling estatístico. As medidas de verificação mostraram que o conjunto de preditores escolhidos para o downscaling estatístico tem a capacidade de reproduzir de forma satisfatória as condições observadas.

Em relação aos cenários futuros das variáveis meteorológicas estudadas a precipitação apresentou unanimidade entre os modelos e cenários para a redução no acumulado de chuvas do período chuvoso. Alguns modelos preveem o aumento das chuvas no período seco de setembro a dezembro para as cidades com exceção da cidade de João Pessoa. Os diferentes modelos e cenários também convergem na previsão do aumento das temperaturas médias, sob diferentes graus de intensidade. Com relação a ETP, os resultados são mais variados, com determinados cenários prevendo redução, aumento ou pouca variação em relação à climatologia observada dos valores futuros desta variável.

Após bons resultados nas etapas anteriores, em relação aos cenários futuros de produtividade média da cana de açúcar é possível afirmar que todos os cenários analisados estimam para o futuro aumento da produtividade da cana de açúcar em relação à média de produtividade observada pelo IBGE no período de 1996 a 2015. O aumento da produtividade é similar para todas as cidades, variando de 8 a 15% acima dos valores médios observados no mesmo período de 1996 a 2015. Existe uma variação entre as famílias de cenários, alternando-se entre as cidades no que se refere a quais preveem os maiores incrementos de produtividade para o futuro. O modelo MIROC utilizado na família dos cenários RCPs apresentou sempre valores bem contraditórios em relação aos demais modelos. Sem a influência deste modelo, a diferença observada no ENSEMBLE entre as curvas dos cenários A1B e A2 em relação aos cenários RCPs 4.5 e 8.5 seriam maiores.

A variação entre a produtividade prevista por cada modelo em determinado cenário é diretamente proporcional à previsão das variáveis meteorológicas por cada modelo e cenário. Na contramão do que é esperado em relação a previsão de

produtividade de culturas para o futuro da região Nordeste, estes resultados indicam previsão de aumento da produtividade da cana de açúcar. Para algumas cidades pode-se supor que, mesmo com a diminuição prevista da precipitação no período chuvoso, o aumento da previsão de chuvas entre setembro e dezembro pode equilibrar a relação natural existente hoje entre períodos secos e chuvosos do ano, o que pode beneficiar a cultura. Esse fator combinado com a variabilidade prevista da ETP pode ser um segundo fator positivo para o aumento da produtividade. Estudos desse tipo, por envolverem incertezas, precisam sempre serem aprimorados e atualizados.

7. REFERÊNCIAS BIBLIOGRÁFICAS

Acompanhamento da safra brasileira de cana de açúcar. V.1- Brasília: Conab, 2013-
v. Companhia Nacional de Abastecimento

ASSAD, E.D; Pinto,H.S; Junior,J.z; Ávila, A.M.H. **Impacto das mudanças climáticas no zoneamento agroclimático do café no Brasil.**

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

BARBIERI, V.; VILLA NOVA, N. A. **Climatologia e a cana-de-açúcar.** Araras: PLANALSUCAR – Coordenadoria Regional Sul – COSUL. Climatologia, p.1-22, 1977.

BARBOSA, H.A.; LAKSHMI KUMAR, T.V. Influence of rainfall variability on the vegetation dynamics over Northeastern Brazil. **Journal of Arid Environments**, v. 124, p. 377-387, 2016.

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.

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.

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

CAMARA, G. M. S.; OLIVEIRA E. A. M. **Produção de cana-de-açúcar.** Piracicaba: ESALQ/USP, 1993.

CARRIERO, A.; KAPETANIOS, G.; MARCELINO, M. Forecasting Exchange rates with a large Bayesian VAR. **International Journal of Forecasting**, v.25, p.400,417.

CARTER, M. R.; GREGORICH, E. G. Soil Sampling and Methods of Analysis. 2007.

CLEMENTS, M. P.; GALVÃO, A. B.; Forecasting with vector autoregressive modelo f data vintages, US output growth and inflation. **International Journal of forecasting**, v.29, n4, p.698-714, 2013.

COFIÑO, A. S.; SAN-MARTIN, D.; GUTIÉRREZ, J.M. A web portal for regional projection of weather forecast using GRID middleware. **Santander Meteorology Group**, 2007.

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.

COLLINGS, M.; KNUTTI, R.; ARBLASTER, J.; DUFRESNE, J. L.; FICHEFET, T.; FRIEDLINGSTEIN, O.; 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.

Chou, S.C; Souza, C.R; Gomes, J.L; Evangelista,E.F.D; Osório, C; Cataldi, M. **Refinamento Estatístico das Previsões Horárias de Temperatura a 2 m do Modelo ETA em Estações do Nordeste do Brasil**. Revista Brasileira de Meteorologia, v22, n.3, 287-296, 2007.

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 fitoregulador no crescimento das plantas de milho. **Revista da Faculdade de Zootecnia, Veterinária e Agronomia**, v.11, n.1, p.93-102, 2004.

DOORENBOS, J.; KASSAM, A. H. Yield response to water. Rome: **FAO**, 1979. 139 p. (Irrigation and Drainage Paper, 33).

BOLETIM DA SAFRA DA CANA DE AÇÚCAR. CONAB, 2019.

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; SOUZA, A. A; DAMASCENO, J. F. 2. Ed. Campina Grande: UFPB, 2000. (**Estudos FAO: Irrigação e Drenagem, 33**).

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

Embrapa. **Impactos de mudanças climáticas/variabilidade nos sistemas de produção de trigo e estratégias para a adaptação da cultura no sul do Brasil**.

FAUCONNIER, R.; BASSEREAU, D. **La Carne Sucre**, p.468, 1970.

FAGERIA, N.K. **Maximizing crop yields**. Nacional Rice and Bean Research Center, Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA),1992.

FAO—Food and Agriculture Organization (FAO). FAOSTAT. <http://faostat.org/> (accessed December 21, 2012).

FOWLER, H. J.; WILBY, R. L.; Detecting changes in seasonal precipitation extremes using regional climate model projections: Implications for managing fluvial flood risk. **Water Resources Research, AGU Journal**, 2010.

FLATTO, G.; MAROTZKE, J.; ABIODUN, B.; BRACONNOT, P.; CHOU, S. C.; COLLINS, W.; COX, P.; DRIOUECH, F.; EMORI, S.; EYRING, V.; FOREST, C.; GLECKLER, P.; GUILYARDI, E.; JAKOB, C.; KATSOV, 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.

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.

GOUVÊA, J. R. F.; SENTELHAS, P.C.; GAZZOLA, S. T.; SANTOS, M. C. **Climate changes and technological advances: impacts on sugarcane productivity**. Tropical southern Brazil. *Scientia Agrícola* 66, 593–605.

GUIMARÃES, S. O; COSTA, A. A; JUNIOR, F. C. V; S; SILVA, E. M; SALES, D. C; JUNIOR, L. M. A; SOUZA, S. G. Projeções de mudanças climáticas sobre o nordeste brasileiro dos modelos do CMIP5 e do CORDEX. **Revista Brasileira de Meteorologia**, v.31, n.3, 337-365, 2016.

HARGREAVES, G. H.; SAMANI, Z. A. Reference crop evapotranspiration from temperature. **Applied Engineering in Agriculture**, v. 1, n. 2, 1985.

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.

HOOGENBOOM, G. Contribution of agrometeorology to the simulation of crop production and its applications. **Agricultural and Forest Meteorology**, v. 103, Issues 1-2 June 2000, p. 137-157, 2000.

INMAN-BAMBER, N. G. A growth model for sugarcane based on a simple carbon balance and the CERES-Maize water balance. **South African Journal of Plant and Soil**, Pretoria, v. 8, n. 2, p. 93-99, 1991.

INMAN-BAMBER, N. G.; MCGLINCHEY, M. G. Crop coefficients and water-use estimates for sugarcane based on long-term Bowen ratio energy balance measurements. **Field Crops Research**, Amsterdam, v. 83, n. 2, p. 125-138, 2003.

JANK, M. S. **Etanol e bioeletricidade. A cana-de-açúcar no futuro da matriz energética**. União da Indústria de Cana-de-açúcar (ÚNICA), 2010.

- 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.
- KEATING, B.A.; ROBERTSON, M.J.; MUCHOW, R.C.; HUTH, N.I. Modelling sugarcane production systems. I. Development and performance of the sugarcane module. **Field Crops Research**, v.61, p.253-271, 1999.
- KERSEBAUM, K.C., HECKER, J. M., MIRSCHEL, W., WEGEHENKEL, M. **Modelling water and nutrient dynamics in soil-crop systems: a comparison of simulation models applied on common data sets**, 2007.
- Kousky, V. E. Frontal Influences on Northeast Brazil. **Instituto de Pesquisas Espaciais (INPE), Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPQ)**, 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.
- KORNDÖRFER, G. H.; PEREIRA, H. S.; CAMARGO, M. S. Papel do silício da produção de cana-de-açúcar. **STAB Açúcar e Álcool e Subprodutos**, Piracicaba, v. 21, n. 1, p. 6-9, 2002.
- MAGALHÃES, A. C. N. Ecofisiologia da cana-de-açúcar: aspectos do metabolismo do carbono na planta. In: CASTRO, P. R. C.; FERREIRA, S. O.; TSUIOSHI, Y. **Ecofisiologia da produção agrícola**. Piracicaba: POTAFOS, 1987. 249 p.
- MARENGO, J.A. **Mudanças Climáticas Globais e Regionais: Avaliação do Clima Atual do Brasil e Projeções de Cenários Climáticos do Futuro**. Centro de Previsão de Tempo e Estudos Climáticos/ Instituto Nacional de Pesquisas Espaciais, 2001.
- 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.
- 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, 2013.

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.

MAVI, H. S.; TUPPER, G. J. **Principles and Applications of Climate Studies in Agriculture**, 2004.

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.

MONTEIRO, L. A; SENTELHAS, P. C. Potential and Actual Sugarcane Yields in Southern Brazil as a Function of Climate Conditions and Crop Management. **Sugar Tech**, V.16, issue 3, pp 264-276, 2013.

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.

MOREIRA, L. F. Multicolinearidade em análise de regressão. **12º Encontro Regional de Matemática Aplicada e Computacional**, Foz do Iguaçu. Anais, Unioeste. p.61-75, 2008.

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.; SANKIVSKI, A.; SCHLESINGER, M.; SHUKLA, P.; SMITH, S.; SWART, R.; VAN ROOIJEN, S;; VICTOR, N.; DADI, Z. IPCC: Special Reporto n Emissions Scenarios, **Cambridge University Press**, Cambridge, United Kingdom and New York, USA, 2000.

NOBREGA R. R. A.; FERREIRA, H. F.; FILHO, N., M., G.; FEIJÓ, A.; MENDONÇA, S. V.;LAGGUTH, A. Non-volant mammals from Baturité Ridge, Ceará state, Northeast Brazil. **Check List the jornal of biodiversity data**, v.11, 2015.

OLIVEIRA, A. R.; SANTOS, R. S.; RIBEIRO, A.; ZOLNIER, S.; BARBOSA, M. H. P. Estimativa da produtividade da cana-de-açúcar para as principais regiões produtoras de Minas Gerais usando-se o método ZAE. **Revista Brasileira de Engenharia Agrícola e Ambiental (AGRIAMBI)**, v. 16, n.5, p.549—557, 2012.

PEREIRA, A. R.; ANGELOCCI, L. R.; SENTELHAS, P. C. Agrometeorologia: fundamentos e aplicações práticas, 478. **Guaíba: Agropecuária**, 2002.

PERES, F. C. **Determinação dos coeficientes de cultura (Kc) da cana-de-açúcar: ciclo de cana soca.** 1988. 94 f. Dissertação (Mestrado em Agronomia) – Escola Superior de

Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba.

PINTO, H. S.; ASSAD, E. D. Aquecimento global e cenários futuros da agricultura brasileira. **Embrapa**, 2008.

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.

RAMESH, P. Effect of drought on nutrient utilization, yield and quality of sugarcane (*Saccharum officinarum*) varieties. **Indian Journal of Agronomy**, Nova Delhi, v. 45, n. 2, p. 401-406, 2000.

RODRIGUES, J. D. **Fisiologia da cana-de-açúcar**. Botucatu: Unesp, 1995. 99 p.

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.

SALES, D. C.; COSTA, A. A.; SILVA, E. M.; JUNIOR, F. C. V.; CAVALCANTE, A. M. B.; MEDEIROS, S. S.; MARIN, A. M. P.; GUIMARÃES, S. O.; JUNIOR, L. M. A.; PEREIRA, J. M. R. Projeções de mudanças na precipitação e temperatura no nordeste brasileiro utilizando técnica de downscaling dinâmico. **Revista Brasileira de Meteorologia**, v. 30, n.4, 2015.

SALVIANO, M. F.; GROppo, J. D.; PELEGRINO, G. Q. Análise de tendências em dados de precipitação e temperatura no Brasil. **Revista Brasileira de Meteorologia**, v.31, n.1, p.64-73, 2016.

SAMANI, Z. Estimating Solar Radiation and Evapotranspiration Using Minimum Climatological Data. **Journal of Irrigation and Drainage Engineering**, v. 126, n. 4, 2000.

SANTOS, M. A. L. **Irrigação suplementar da cana-de-açúcar (*Saccharum spp*): um modelo de análise de decisão para o Estado de Alagoas**. 2005. 100 f. Tese (Doutorado em Agronomia – Irrigação e Drenagem)-Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba.

SANTOS, R. S.; COSTA, L. C.; SEDYAMA, 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.

SEGATO, S. V.; PINTO, A. S.; JENDIROBA, E.; NÓBREGA, J. C. M. Atualização em produção da cana-de-açúcar. 2.ed. Piracicaba, **PROL**, 2006. 415p.

SILVA, V. B. S.; KOUSKY, V. E.; SILVA, F. D. S.; SALVADOR, M. A.; ARAVEQUIA, J. A. The 2012 severe drought over Northeast Brazil. **Bulletin of the American Meteorological Society**, v. 94, p. 162, 2013.

SCHMIDT, N.; LIPP, E. K.; LUTHER, M. E.; ROSE, J.B. Determining the effects of El Niño-Southern Oscillation events on coastal water quality. **Estuaries**, v.24, n.4, p.491-497, 2001.

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.

TEQJA, Z.; KOPALI, A. A study of the Impacts of Climate Change Scenarios on the Plant Hardiness Zones of Albania. **Journal of Applied Meteorology and Climatology**, 2018.

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, p.2087-2105.

THORNTHWAITE, C. W., MATHER, J. R. The water balance, 104. Philadelphia: Publications in Climatology, **Drexel Institute of Technology**, 1955.

UNICA. **Dados e cotações estatísticas**. Disponível em: <
<http://www.unica.com.br/dadosCotacao/estatistica/> >. Acesso em: 13 abr. 2012.

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.

VILLA NOVA, N.A.; PEDRO JUNIOR, M. J.; PEREIRA, A. R.; OMETTO, J. C. Estimativa de graus-dia acumulados acima de qualquer temperatura base, em função das temperaturas máxima e mínima. **Caderno de Ciência da Terra**, n.30, p.8, 1972.

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.; 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.

ZYDI T.; LEKAJ, E.; SENES, G.; XHOXHI, O. Evaluation of public parks based on user's preceptions: A comparative study between Tirana and Milan. **Albanian j. agriculture**, 2018.