INSTITUTO DE MATEMATICA E ESTATÍSTICA
UNIVERSIDADE DE SÃO PAULO

PADRÕES DAS MUDANÇAS CLIMÁTICAS EM SIMULAÇÕES NUMÉRICAS DO CLIMA

Aluno: Bruno Ferrero

SÃO PAULO

2017

Padrões das mudanças climáticas em simulações numéricas do clima

Monografia final da disciplina
MAC0499 – Trabalho de Formatura Supervisionado.

Supervisão: Professora Dra. Ilana Wainer - IO-USP

São Paulo
Novembro de 2017

Resumo

A simulação numérica do clima terrestre é certamente um dos problemas de maior demanda computacional. A necessidade da computação de alta performance nesse tipo de aplicação deve-se a enorme quantidade de cálculos envolvidos na resolução das equações que descrevem as diversas variáveis do clima. No presente estudo são utilizados resultados provenientes de simulações climáticas, cujos objetivos são reproduzir o clima global da forma mais realista possível e projetar o clima para os próximos anos (até o ano de 2100). A análise de tais resultados buscou encontrar padrões espaciais e temporais da variável temperatura do oceano que descrevam os sinais da mudança climática nessa variável.

Palavras-chave: simulação numérica, HPC, high performance computing, funções ortogonais empíricas, modelos numéricos do clima.

Sumário

Lista de Figuras **2**

1 Introdução **5**

1.1 A simulação do clima 5

1.2 O clima como um sistema caótico 6

1.3 Objetivos 7

2 O modelo numérico CESM e a simulação LENS **9**

2.1 Modelo oceânico e as equações básicas do fluido 9

2.2 O *"custo"* do problema 11

2.3 Um supercomputador para estudos climáticos 12

3 Metodologia **15**

3.1 Temperatura média global dos oceanos 15

3.2 *Drifts* e tendências 16

3.3 Padrões espaciais: Climatologia 16

3.4 Análise de componentes principais: Funções Ortogonais Empíricas . . . 17

4 Resultados e discussão **20**

4.1 Variabilidade natural e mudança climática 20

4.2 Padrões temporais 22

4.3 Padrões espaciais 26

4.4 Padrões espaço-temporais associados: *Empirical Orthogonal Functions* . . 28

5 Conclusão **32**

Referências **33**

A Tamanhos dos *outputs* **36**

B Softwares e ferramentas **36**

C Apreciação pessoal e crítica **38**

Lista de Figuras

1 Atractor de Lorenz, cada um deles representa a evolução de um sistema dinâmico (equação 1) a partir de dois diferentes pontos de início. 7

2 Esquema das quatro componentes que compõem o modelo climático CESM/NCAR e do acoplador de fluxos, responsável pela troca de energia entre as componentes. Figura retirada de Kay *et al.* (2015). 10

3 Exemplos de resoluções de grade para um domínio global/climático adaptado de Stocker *et al.* (2013). A atual geração de modelos climáticos em conjunto aos recursos computacionais atuais já é capaz de gerar simulações globais em escala de clima com resolução horizontal em torno de 30 km. 13

4 Série temporal de 1800 anos da temperatura média global do oceano (equação 6) para a simulação controle. A curva cinza são médias mensais e a linha azul escura é a série com uso de um filtro do tipo *Hanning* com uma janela de 120 meses. 21

5 Série temporal dos últimos 100 anos da temperatura média global dos oceanos (equação 6) para a simulação controle. A curva cinza representa médias mensais e a linha vermelha representa a tendência do período (0.01°C/século), cujos coeficientes são indicado no título da Figura. . . . 22

6 Série temporal da temperatura média global dos oceanos (equação 6) para a simulação B20TR. As curvas mais claras são médias anuais de cada um dos 34 membros do conjunto LENS e a linha azul escura é média do conjunto. 23

7 Série temporal da temperatura média global da superfície dos oceanos (equação 6) para a simulação B20TR (esquerda) e para a simulação de projeção climática BRCP85 (direita). As curvas mais claras são médias anuais de cada um dos 34 membros do conjunto LENS e a linha escura é média do conjunto. 24

8 Padrões médios climatológicos de verão (esquerda) e de inverno (direita) da temperatura superficial dos oceanos para as simulações B20TR e BRCP85. A escala de cor é a mesma para os 4 mapas e representa os valores de temperatura em °C. 26

9 Curva climatológica da temperatura superficial dos oceanos para diferentes décadas das simulações B20TR e BRCP85. Cada curva (cor) representa uma década. 27
10 Padrões espaciais do primeiro modo da temperatura da superfície do oceano (EOF1) e série temporal dos coeficientes de expansão (componente principal 1 - PC1) do primeiro modo. As séries temporais são adimensionais. Simulação B20TR. 30
11 Padrões espaciais do primeiro modo da temperatura da superfície do oceano (EOF1) e série temporal dos coeficientes de expansão (componente principal 1 - PC1) do primeiro modo. As séries temporais são adimensionais. Simulação BRCP85. 31

1 Introdução

A simulação numérica do clima sempre foi um dos grandes desafios da computação de alto desempenho (*High Performance Computing* - HPC). Em 2015, na maior conferência anual sobre HPC do mundo, a *ACM/IEEE Supercomputing Conference* (SC15), foi lançado o "*#HPC Matters*"[1], com o objetivo de encorajar membros da comunidade científica a compartilhar suas ideias, visões e experiências de como os computadores de alto desempenho são usados para melhorar a vida das pessoas em todo o mundo. Dentre os diversos temas apresentados, muitos relacionavam-se à simulação do tempo e do clima e como essas simulações são utilizadas para prever super tempestades e antever as consequências das mudanças climáticas[2].

1.1 A simulação do clima

Em uma simulação climática, o clima é descrito por modelos matemáticos que utilizam técnicas de *Computational Fluid Dynamics* (CFD) para descrever a física e a interação das diversas componentes do clima, entre elas a atmosfera e o oceano. Tanto a atmosfera quanto o oceano são fluidos e, por sua vez, regidos pelo sistema de equações de *Navier-Stokes*. Tal sistema ainda não possui uma solução analítica completa e é considerado pelo *Clay Mathematics Institute* um dos sete problemas matemáticos do milênio[3]. Contudo, soluções numéricas considerando aproximações adequadas ao fluido de estudo são amplamente utilizadas para suprir a inexistência de uma solução analítica completa do sistema.

No caso dos modelos climáticos, a necessidade do grande poder computacional deve-se fundamentalmente à necessidade de utilizar um sistema de grade que englobe todo o espaço a ser modelado. Quanto maior o número de pontos desta grade maior será a demanda computacional para resolver o problema.

Como mencionado anteriormente, a atmosfera e o oceano são duas das principais componentes do clima. Um modelo climático é um conjunto de dois ou mais modelos que estão acoplados (trocando energia) e cada um destes modelos é responsável por simular uma das componentes do clima. Os modelos climáticos mais simples contam

[1] http://sc15.supercomputing.org/hpc-matters.html [Acessado em Novembro/2017]

[2] https://www.youtube.com/watch?v=QABMJapCIXo[Acessado em Novembro/2017]

[3] http://www.claymath.org/millennium-problems [Acessado em Novembro/2017]

somente com uma componente atmosférica, uma componente oceânica e um acoplador entre esses dois módulos. Já os modelos mais sofisticados contam com diversas componentes, entre elas, criosfera, biosfera, modelos biogeoquímicos, entre outros.

1.2 O clima como um sistema caótico

Uma das principais características do clima é a sua previsibilidade, juntamente com sua estrutura caótica. Esta última decorre da interação das diversas variáveis que compõem o clima e pelo forte mecanismo de *feedback* existente entre elas. Em termos matemáticos, diz-se interações não lineares entre variáveis. Um exemplo simples da interação e *feedback* entre variáveis é o caso da evaporação e da formação de nuvens. Quanto mais quente, maior a taxa de evaporação, que por sua vez favorece a formação de nuvens. No entanto, mais nuvens promoverá uma maior reflectância da radiação solar induzindo um resfriamento do sistema e consequentemente diminuindo a taxa de evaporação.

Um modelo matemático simples que mostra claramente a interação entre variáveis e o mecanismo de *feedback* entre elas foi desenvolvido por Lorenz (1963). Trata-se de um sistema de equações diferenciais ordinárias (usando a notação $\dot{x}$ para representar uma derivada no tempo adimensional) e além da interação entre variáveis, introduz a forte dependência da condição inicial (*Initial value problem*).

$$\begin{aligned} \dot{X} &= -\sigma X + \sigma Y \\ \dot{Y} &= -XZ + rX - Y \\ \dot{Z} &= XY - bZ \end{aligned} \tag{1}$$

Esse sistema simples é capaz de mostrar a evolução de um sistema dinâmico independentemente do ponto de partida. A representação gráfica do sistema de equações acima é o Atractor de Lorenz, mostrado na Figura 1. Nessa Figura observa-se a evolução da trajetória de uma partícula em 10000 iterações (tempo). Claramente, forma-se um padrão, no entanto, com o passar das iterações (quanto mais longe da condição inicial) maior será a divergência.

A simulação do clima, assim como o Atractor de Lorenz, é um problema de interação entre variáveis, *feedback* e fortemente dependente das condições iniciais. Como

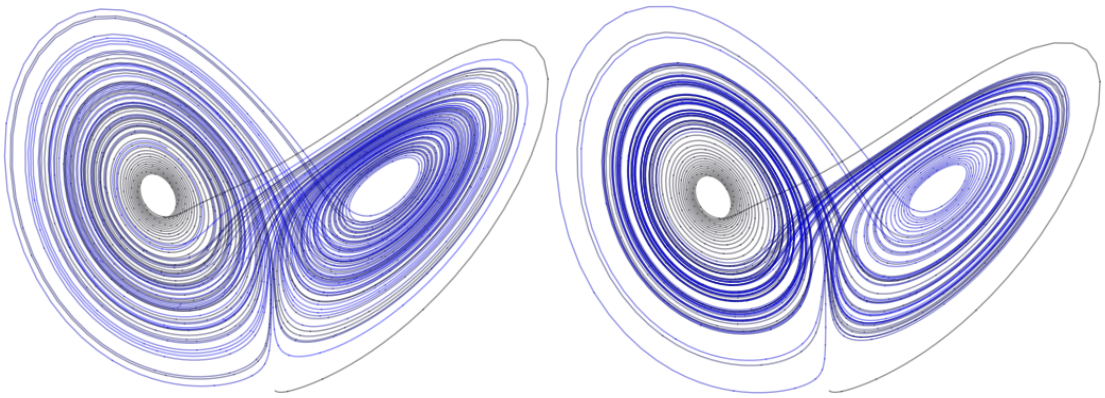

Figura 1: Atractor de Lorenz, cada um deles representa a evolução de um sistema dinâmico (equação 1) a partir de dois diferentes pontos de início.

o propósito da simulação climática é reproduzir e prever o clima é necessário garantir alguma previsibilidade da simulação. Para isso, uma das abordagens utilizadas é a análise por *ensembles* (Kharin & Zwiers, 2002; Kay *et al.*, 2015). Nessa técnica, são geradas diversas simulações para um mesmo modelo, com exatamente a mesma configuração (domínio, grade, período, condições forçantes e condições de contorno), no entanto com pequenas perturbações na condição inicial. O objetivo dessa abordagem é identificar o sinal da variabilidade interna do sistema e garantir robustez na habilidade do modelo em reproduzir uma dinâmica consistente do clima.

1.3 Objetivos

Dentro dessa temática, o objetivo deste estudo é analisar os resultados (*outputs*) de um conjunto de simulações (*ensemble*) produzidas pelo modelo climático denominado *Community Earth System Model* - CESM/NCAR e mostrar a importância da computação de alto desempenho na produção de tais simulações.

Mais especificamente, serão analisados os resultados de temperatura potencial da componente oceânica de 34 simulações com pequenos desvios nas condições iniciais, com um foco em técnicas que ressaltam os padrões espaciais e temporais da mudança climática.

Para atingir tais objetivos estruturou-se o presente texto da seguinte forma.

No capítulo 2 são apresentados com mais detalhes o conceito de modelo climático e de um experimento de simulação do clima, além de uma estimativa do custo computacional de tal simulação. Também serão apresentadas as técnicas e os procedimentos

de análises dos resultados gerados pela simulação numérica (Capítulo 3). No Capítulo 4 são mostradas as análises aplicadas aos resultados provenientes das simulações numéricas acompanhadas de uma discussão dos resultados. E por fim, são apresentadas as conclusões obtidas ao longo desse estudo (Capítulo 5).

2 O modelo numérico CESM e a simulação LENS

Nesse capítulo são apresentados o modelo numérico Community Earth System Model (CESM/NCAR)[4], mais especificamente a componente oceânica denominada *Parallel Ocean Program, version 2* (Danabasoglu *et al.*, 2012), utilizada para gerar os resultados utilizados nesse estudo (Figura 2). Tais resultados estão no contexto do projeto *Large Ensemble Community Project - LENS* (Kay *et al.*, 2015), cujo objetivo é avançar o entendimento da variabilidade e das mudanças climáticas. Para tal, foram gerados os seguintes experimentos:

- **experimento controle:** uma simulação de 1800 anos, considerando apenas um estado climatológico médio (sem forçantes naturais ou atrópicas). O objetivo dessa simulação é obter o estado estável do modelo e a partir desse estado gerar as simulações com as forçantes.

- **experimento B20TR:** são 34 simulações do clima para o período de 1920 até 2006, utilizando a mesma configuração de domínio, grade e forçante. Todas as 34 simulações partem do final de experimento controle, no entanto, cada uma delas parte de um instante diferente, de modo a garantir uma perturbação inicial diferente para cada integração numérica. O principal propósito do experimento/cenário **B20TR** é reproduzir o clima da forma mais realista possível (forçantes naturais e antrópicas - gases estufa).

- **experimento BRCP85:** também consta de 34 simulações, mas para um período futuro, entre 2006 até 2100. Tais simulações partem imediatamente do final das simulações do B20TR. Neste experimento considera-se um cenário severo de mudanças climáticas (*"business as usual"*) e tem como principal característica um aumento gradativo da energia imposta ao sistema de até $8.5 W/m^2$ no final do período de simulação (Riahi *et al.*, 2011).

2.1 Modelo oceânico e as equações básicas do fluido

Dentre os diversos componentes do clima, o oceano é o que responde pela maior quantidade de energia armazenada. Isso acontece devido às propriedades físicas, tais como,

[4] http://www.cesm.ucar.edu/

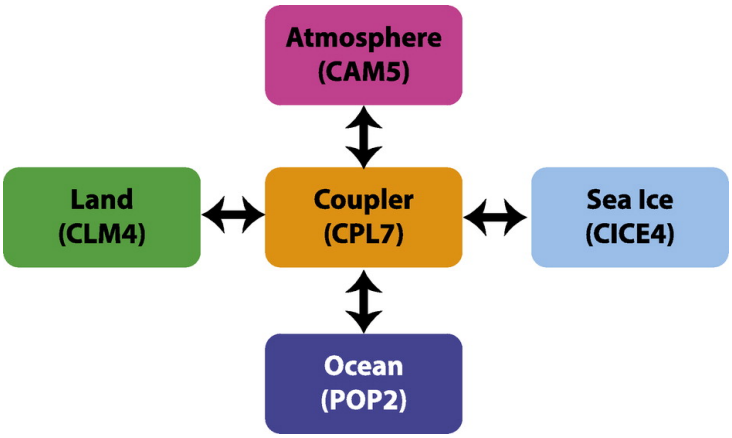

Figura 2: Esquema das quatro componentes que compõem o modelo climático CESM/NCAR e do acoplador de fluxos, responsável pela troca de energia entre as componentes. Figura retirada de Kay et al. (2015).

a maior capacidade térmica da água em relação ao ar (1000 vezes maior, isto é, para aumentar a temperatura de uma parcela de água em 1°C é necessário 1000 vezes mais energia do que seria necessário para aumentar em 1°C uma parcela de ar), e também devido a massa oceânica total ser muito maior do que a massa das demais componentes do clima. Dessa forma, os oceanos atuam como um "regulador" do sistema climático, sendo que mudanças, mesmo que pequenas, em suas propriedades, implicam grandes quantidades de energia sendo rebalanceadas no sistema climático.

Como dito anteriormente, o oceano, assim como a atmosfera, é um fluido, e portanto, regido pelas equações de Navier-Stokes. Uma particularidade do oceano e da atmosfera é que eles são fluidos geofísicos, logo estão suscetíveis às forças geradas pela rotação do planeta Terra (Força de Coriolis) e à força de atração gravitacional.

O sistema de Equações de Navier-Stokes aplicado a um fluido geofísico (no caso, o oceano) recebe o nome de **Equações Primitivas do Movimento**, e juntamente com as aproximações hidrostática e de Boussinesq, podem ser descritas pelas equações a seguir, que estão detalhadas em Griffies (2004):

$$\frac{D\vec{v}_o}{Dt} + f(\vec{k} \times \vec{v}_o) = -\frac{1}{\rho_w}\left[\vec{\nabla}_H (p + \rho_w g\eta) + \vec{F}_H + \vec{F}_V\right] , \tag{2}$$

em que $\vec{v}_o = (u_o, v_o)$ é o vetor velocidade horizontal do oceano, t é o tempo, f é o parâmetro da força de Coriolis, $\vec{k}$ é o vetor unitário normal ao centro da Terra, ρ_w é a densidade de referência constante da água, $\vec{\nabla}_H$ é operador gradiente horizontal, p é a pressão interna, g é a aceleração devido à gravidade e η é a elevação da superfície

livre do oceano. $\vec{F}_H$ e $\vec{F}_V$ são parametrizações para as forças de atrito horizontal e vertical respectivamente. A velocidade vertical é obtida a partir do campo horizontal de velocidade, assumindo a condição de fluido incompressível (equação 3).

$$\frac{\partial w_o}{\partial z} = -\vec{\nabla}_H \cdot \vec{v}_o \tag{3}$$

A temperatura potencial (θ) e a salinidade (S) obedecem as equações de advecção-difusão (equações 4, 5):

$$\frac{\partial \theta}{\partial t} = \vec{\nabla}_H \cdot \left(K \vec{\nabla}_H \theta \right) \tag{4}$$

$$\frac{\partial S}{\partial t} = \vec{\nabla}_H \cdot \left(K \vec{\nabla}_H S \right) \quad , \tag{5}$$

em que K é um tensor utilizado na parametrização horizontal/vertical da difusão.

As equações que descrevem a dinâmica do oceano consideram o espaço e o tempo contínuos. Para traduzir isso para o computador é necessário discretizar o espaço e o tempo. Isso é feito por meio do uso de uma grade de simulação, na qual será resolvida numericamente as Equações Primitivas do Movimento.

Quanto maior o refinamento dessa discretização maior será a demanda computacional envolvida. A escolha do quão bom será esse refinamento será sempre um *trade-off* entre o poder computacional disponível e a escolha do problema a ser resolvido.

2.2 O "*custo*" do problema

Um exemplo de grade usada em um domínio global é apresentado na Figura 3. Nesta figura observa-se também a evolução e o refinamento das grades dos modelos climáticos utilizados para a confecção do 5º Relatório de Avaliação do clima do *Intergovernmental Panel on Climate Change* (IPCC)[5] em 2007.

Na época uma resolução espacial típica (tamanho do elemento de grade) era de cerca de $87,5$ km. Já a atual geração de modelos climáticos conta com uma resolução espacial de aproximadamente 30 km, e o principal fator responsável por tal ganho de resolução é a disponibilidade (tecnológica e preço) de maior poder computacional.

Para se ter uma ideia mais prática do custo computacional envolvido em uma simulação desse tipo, vamos considerar o seguinte exemplo:

[5]Organização científico-política responsável por centralizar o conhecimento acerca das mudanças climáticas

1. Assumir uma grade com resolução horizontal de 55 km;

    - pontos em longitude x e latitude y: **720**^{o} x **180**^{o} (considerando que $1^o \simeq 110$ km);

2. Resolução vertical de 90 metros;

    - considerando um oceano de profundidade máxima de 5400 metros, isso implica 60 camadas de 90 metros;

3. Resolução temporal: 30 minutos;

    - o passo de tempo (*time-step*) do modelo apropriado para uma simulação climática é de 30 min;

4. Número de anos a ser simulado: 100 anos;

    - geralmente em um experimento climático simulam-se 100 anos. Logo, dividindo-se 100 anos em intervalos de 30 minutos: **1753152**

Considerando os números acima, o total de vezes que teremos que resolver uma determinada equação do problema será:

$$720 \times 360 \times 60 \times 1753152 = 45.441.699.840.000$$

Essa é uma aproximação bastante grosseira e além de tudo subestima bastante o número de operações realizadas. Contudo, com números em torno de 45 trilhões já é possível notar que o problema da simulação do clima é de fato um problema que demanda uma alta capacidade de processamento. Com relação à demanda de espaço, armazenar e analisar os resultados de tais simulações também tem sido um grande desafio, principalmente com relação à técnicas estatísticas de análise de grande volumes de dados e de visualização dos mesmos.

2.3 Um supercomputador para estudos climáticos

As simulações do projeto LENS, utilizadas neste estudo, foram integradas durante o ano de 2014 no supercomputador do *National Center for Atmospheric Research* (NCAR),

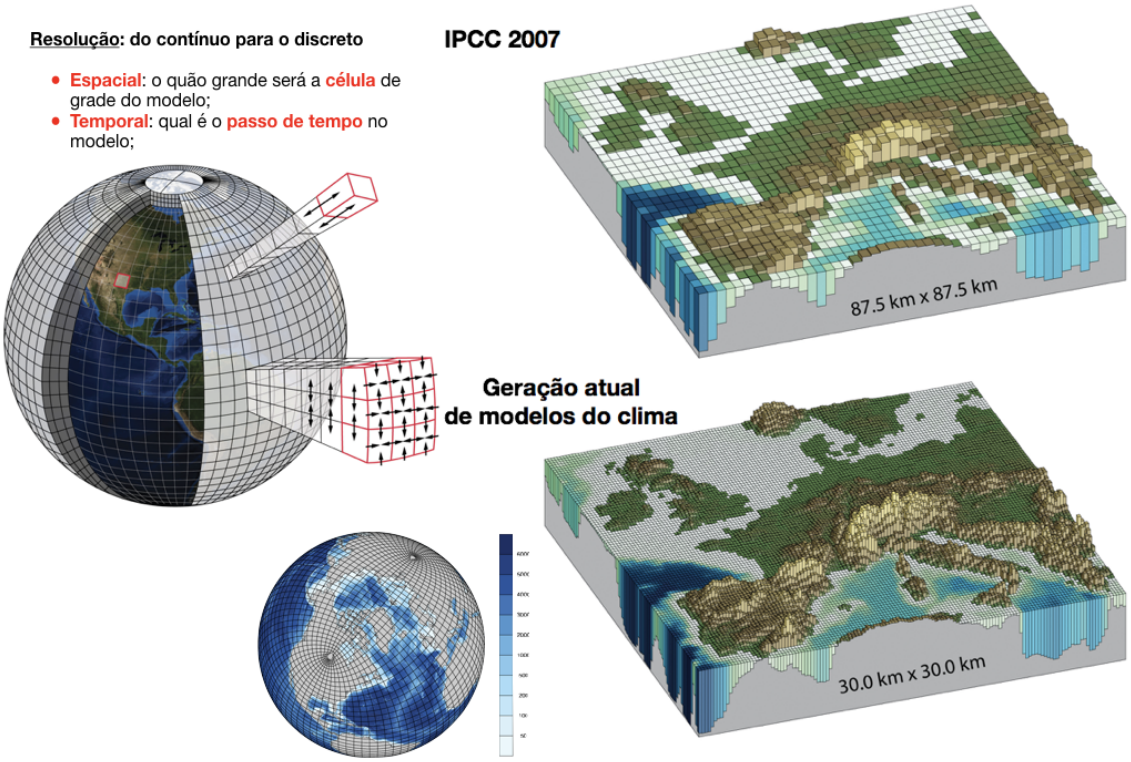

Figura 3: Exemplos de resoluções de grade para um domínio global/climático adaptado de Stocker et al. (2013). A atual geração de modelos climáticos em conjunto aos recursos computacionais atuais já é capaz de gerar simulações globais em escala de clima com resolução horizontal em torno de 30 km.

batizado *Yellowstone*. Na época ele possuía uma performance de pico de 1.5 *petaflops* e ocupava a 29 posição da lista dos TOP500[6].

No começo de 2017 o NCAR lançou o seu mais novo e potente supercomputador dedicado ao uso das ciências climáticas e áreas afins. O supercomputador foi batizado de *Cheyenne* e nos testes iniciais atingiu uma performance de pico de 5.34 *petaflops*. Atualmente ele ocupa a posição 24 [7] entre os **TOP500**. Essa é uma máquina SGI baseada no processador Intel Xeon E5-2697v4.

Uma característica em comum entre a grande maioria dos modelos climáticos é o uso do Fortran (F90) como linguagem dominante nesse tipo de aplicação. Apesar do Fortran ser uma linguagem de programação bastante antiga e considerada "morta"por boa parte da comunidade da ciência da computação, ela ainda é a que atinge uma

[6] https://www.top500.org/system/177827

[7] https://www.top500.org/system/178965

das melhores performances nesse tipo de aplicação em conjunto com as bibliotecas matemáticas otimizadas da Intel (Intel Parallel Studio XE, Intel (2017)).

3 Metodologia

Neste capítulo são apresentados os procedimentos adotados para a obtenção dos resultados e das análises apresentadas no capítulo seguinte.

Uma simulação numérica do clima gera milhares de variáveis como resultado, tais como, temperatura do ar em superfície, intensidade e direção dos ventos, precipitação (chuva), temperatura do mar, salinidade, altura do nível do mar, entre diversas outras. O foco do presente estudo são os resultados gerados pela componente oceânica do CESM/NCAR, e para tanto, foi utilizada a temperatura potencial do oceano como a variável de análise.

Todos os *outputs* da simulação LENS estão disponíveis para acesso por meio do portal de dados do NCAR[8]. Para o presente estudo foram baixados apenas os *outputs* referentes à variável temperatura potencial do oceano para 3 experimentos: o **experimento controle** (1800 anos de simulação), o experimento **B20TR**, (34 simulações do período de 1920 até 2006) e do experimento **BRCP85** (34 simulações do período de 2006 até 2100). O volume de dados baixados e analisados foi por volta de 1.2TB (ver Apêndice A) e para isso foram utilizados os recursos computacionais do Laboratório de Oceanografia Física e Clima da USP[9]. Os arquivos utilizados para armazenar as saídas do modelo seguem o protocolo estabelecido pela *UNIDATA Data Services and Tools for Geoscience*[10] e são baseados no formato binário `NetCDF`. Uma lista dos principais softwares e ferramentas utilizadas para a manipulação e análise de dados utilizados neste trabalho é apresentada no Apêndice B.

3.1 Temperatura média global dos oceanos

Os resultados provenientes da saída direta do modelo encontram-se em matrizes, cujas dimensões são espaços abstratos sem significado físico. No caso da temperatura do oceano (`theta`), temos uma matriz do tipo `theta(t,i,j,k)`, em que `t,i,j,k` são apenas índices abstratos da matriz. Para uma análise física de tais resultados é preciso inicialmente converter tais matrizes em um formato com significado físico, isto é, que cada ponto de dessa matriz tenha um significado físico de espaço e tempo, tal que

[8] https://www.earthsystemgrid.org/

[9] http://oc2.io.usp.br/

[10] https://www.unidata.ucar.edu/software/netcdf/[Acessado em Novembro/2017]

tenhamos $\mathrm{theta}(t, x, y, z)$, em que x, y e z são coordenadas espaciais e t uma coordenada temporal. Basicamente, é necessário fazer uma conversão do espaço matemático para o espaço físico. Essa conversão inicial dos *outputs* foi feita utilizando técnicas de interpolação espacial por meio das ferramentas descritas no Apêndice B.

Após interpolação dos *outputs* para uma grade com significado físico foi calculada a temperatura média global dos oceanos (Θ equação 6) de acordo com Griffies *et al.* (2016).

$$\Theta = \frac{\sum\limits_{x,y,z} \mathrm{theta}\, dA dz}{\sum\limits_{x,y,z} dA dz}\,, \tag{6}$$

em que dA representa a área (metros quadrados) de um elemento de grade e dz a espessura da camada em metros. Com isso, foram elaboradas séries temporais dessa variável para todos os experimentos numéricos.

3.2 *Drifts* e tendências

Para a análise de tendência e desvios internos (*drift*) na simulação foi utilizada uma análise de regressão linear. Dada uma curva y, para se calcular a tendência, buscam-se funções que passem o mais próximo possível dos pontos dados. Os coeficientes dessa função fornecem respostas relativas ao comportamento dos dados em função da variável independente. Para a remoção dos *drifts* foi utilizado um modelo simples do tipo $y = a + bx$. Tal ajuste de reta pode ser calculado via *Método dos Mínimos Quadrados*, obtendo os coeficientes a e b, resolvendo-se o sistema linear 7.

$$\begin{bmatrix} n & \sum\limits_{i=1}^{i=n} x_i \\ \sum\limits_{i=1}^{i=n} x_i & \sum\limits_{i=1}^{i=n} x_i^2 \end{bmatrix} \bullet \begin{bmatrix} a \\ b \end{bmatrix} = \begin{bmatrix} \sum\limits_{i=1}^{i=n} y_i \\ \sum\limits_{i=1}^{i=n} x_i y_i \end{bmatrix}\,, \tag{7}$$

3.3 Padrões espaciais: Climatologia

O cálculo da climatologia é uma das técnicas mais simples e importantes no estudo de séries meteorológicas e climáticas. Tem por objetivo conhecer o comportamento médio de determinado elemento climático em uma região de interesse. Para o cálculo da climatologia mensal, computa-se a média aritmética dos dados de cada mês, durante

todo o período, conforme a equação que se segue:

$$\bar{x}(i) = \frac{1}{n} \sum_{j=0}^{n-1} (x_i + 12_j) \quad , \tag{8}$$

para $i = 1, 2, \ldots, 12$ representando cada um dos 12 meses e para n números de anos envolvidos no cálculo.

3.4 Análise de componentes principais: Funções Ortogonais Empíricas

Em estudos climáticos uma técnica bastante utilizada para se decompor um sinal em sua estrutura espacial e temporal é uma variante da Análise de componentes principais denominada Funções Ortogonais Empíricas (EOF - *Empircal Orthogonal Functions*).

Essa técnica é utilizada para se obter os principais modos espaciais de variabilidade, sua variação no tempo e a quantificação da importância relativa desses padrões (von Storch & Zwiers, 2001; Wainer & Venegas, 2002). Nesse método busca-se encontrar um novo conjunto de variáveis capaz de "capturar" o máximo da variância observada dos dados a partir de uma combinação linear das variáveis originais. O método já foi exaustivamente utilizado em estudos climáticos e descrições mais completas, desde o seu desenvolvimento numérico até sua aplicabilidade são encontradas em von Storch & Zwiers (2001). Em linhas gerais, a EOF serve para reduzir um conjunto de dados com grande número de variáveis para um conjunto menor de novas variáveis que represente uma grande fração da variância contida no conjunto original.

Suponha-se medidas de certa variável (onde a média e a tendência foram retiradas da série) em determinado local $x_1, x_2, \ldots, x_p$, nos tempos $t_1, t_2, \ldots, t_n$, dispostas numa matriz F, de forma que cada coluna tem média zero. Para cada tempo t_j ($j = 1, \ldots, n$) associa-se as medidas de x_i como um campo F.

$$F = \begin{bmatrix} x_{11} & x_{12} & \ldots & x_{1p} \\ x_{21} & x_{22} & \ldots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \ldots & x_{np} \end{bmatrix} \tag{9}$$

Calcula-se, primeiramente, a matriz covariância (R) de F,

$$R = F^t F \tag{10}$$

e, posteriormente, resolve-se o problema dos autovalores

$$RC = C\Sigma \quad , \tag{11}$$

em que, Σ é a matriz diagonal contendo os autovalores σ_i de R. O vetor coluna c_i de C são os autovetores de R correspondentes aos autovalores σ_i. Σ e C têm dimensões $p \times p$.

Para cada autovalor σ_i escolhido, encontra-se o correspondente autovetor c_i, denominado EOF. A primeira EOF é o autovetor associado com o maior autovalor, a segunda EOF é associada com o segundo maior autovalor, subsequentemente, de forma que os menores autovalores são tidos como ruídos. Cada autovalor σ_i, dá uma medida da fração da total variância em R explicada pelo modo. Essa fração é obtida dividindo-se o σ_i pela soma de todos os outros autovalores (o traço de Σ).

A matriz de autovetores C tem a propriedade da ortogonalidade, isto é, $C^tC = CC^t = I$. Isto significa que as EOF's não são correlacionadas sobre o espaço, ou em outras palavras, os autovetores são ortogonais entre si, originando o nome do método Funções Ortogonais Empíricas.

O padrão espacial obtido da EOF representa uma estrutura estacionária. Para determinar como a EOF1, por exemplo, oscila no tempo, calcula-se:

$$a_1 = Fc_1. \tag{12}$$

As n componentes do vetor a_1 são as projeções do autovetor c_1 na matriz covariância F dos dados. Em geral, para cada EOF_j calculada pode-se encontrar um a_j correspondente. O vetor a é denominado coeficiente de expansão. Como as EOFs são ortogonais no espaço, os coeficientes de expansão não são correlacionados no tempo, isto é, as séries temporais também são ortogonais no tempo. Pode-se reconstruir os dados a partir das EOFs e dos coeficientes de expansão como segue:

$$F = \sum_{j=1}^{p} a_j(EOF_j). \tag{13}$$

Os autovalores com suas componentes EOF e os coeficientes de expansão constituem o modo de variabilidade.

Embora sejam bons descritores da variabilidade de um conjunto de dados, os modos obtidos via EOFs não necessariamente conduzem às interpretações dos processos

físicos envolvidos no conjunto original de dados. A influência de diferentes processos físicos pode estar contida em um só modo. Vale ressaltar então que esta técnica representa essencialmente os modos estatísticos envolvidos nos dados.

4 Resultados e discussão

Os resultados apresentados nesse capítulo procuram descrever os padrões espaciais e temporais de variabilidade e tendência da temperatura potencial do oceano para os experimentos B20TR (clima do século XX) e BRCP85 (projeção climática). Para tanto, foram consideradas 3 abordagens de análise. A primeira busca identificar os padrões temporais de temperatura do oceano para todo o globo. A segunda abordagem mostra uma análise do padrão de distribuição de temperatura para uma região específica do hemisfério sul, o oceano Atlântico Sul. E por último, uma abordagem que visa usar um método que combina uma estrutura espacial com uma estrutura temporal de forma a encontrar modos estatísticos que representem um determinado modo espaço-temporal de variabilidade. O modo climático denominado EL-Niño/Oscilação é um típico exemplo de acoplamento de uma estrutura espacial associada a uma estrutura temporal.

4.1 Variabilidade natural e mudança climática

Uma simulação numérica do clima é fortemente dependente da condição inicial. Logo, para que a física e dinâmica do sistema modelado se imponham sobre a condição inicial é necessário um processo de aquecimento (*warm-up*) do modelo. Durante essa fase de aquecimento busca-se um estado estável, no qual o balanço de energia interna do sistema esteja em equilíbrio.

Como um modelo climático está interessado em simular escalas espaciais e temporais mais longas, o tempo de acomodação e estabilização da física interna do modelo é da ordem de milhares de anos. O **experimento controle** tem como objetivo alcançar tal equilíbrio e determinar tendências espúrias, originadas unicamente por uma longa demora no processo de estabilização física do modelo.

A Figura 4 mostra uma série temporal da temperatura média global do oceano (Θ) para o experimento controle. Nessa Figura fica evidenciado o processo de aquecimento e da estabilização física do modelo. Nos primeiros 600 anos de simulação observa-se uma tendência pronunciada de aumento da temperatura. A partir daí a temperatura passa a diminuir atingindo uma aparente estabilidade por volta de 1600 anos de simulação.

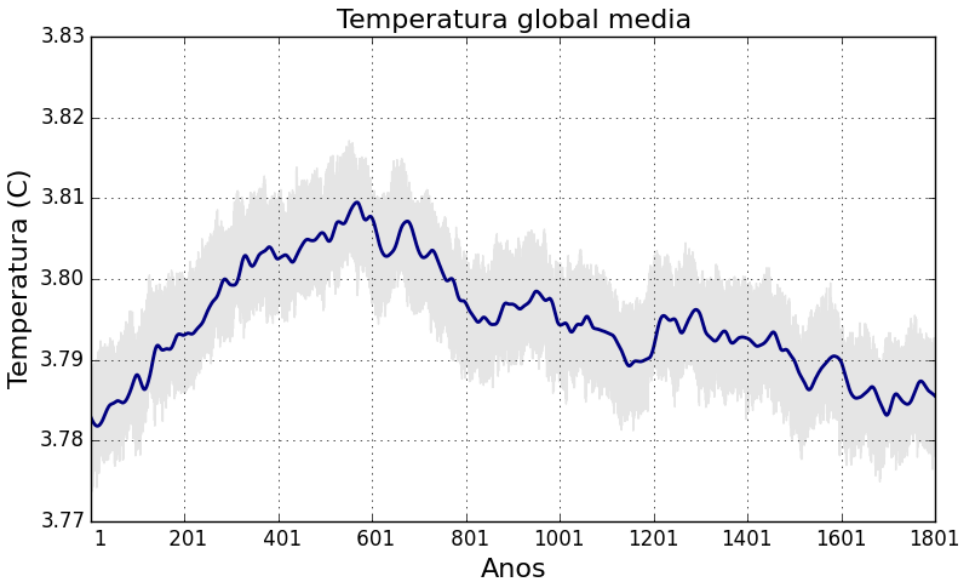

Figura 4: Série temporal de 1800 anos da temperatura média global do oceano (equação 6) para a simulação controle. A curva cinza são médias mensais e a linha azul escura é a série com uso de um filtro do tipo Hanning com uma janela de 120 meses.

Após 1600 anos de simulação, o modelo encontra-se em um estado estável. A Figura 5 mostra o detalhe da série temporal (Figura 4) a partir do ano de simulação 1700 até ano de 1800. Nessa figura a linha vermelha indica a tendência, ajustada por uma reta. Em um estado ótimo essa tendência deveria ser nula, no entanto, sua variação está em torno de $0.01^{o}C$/século. Esse valor refere-se ao desvio natural do modelo (*drift*) e foi removido (subtraído) das séries temporais de temperatura média global do oceano para os experimentos B20TR (clima do século XX) e BRCP85 (projeção climática).

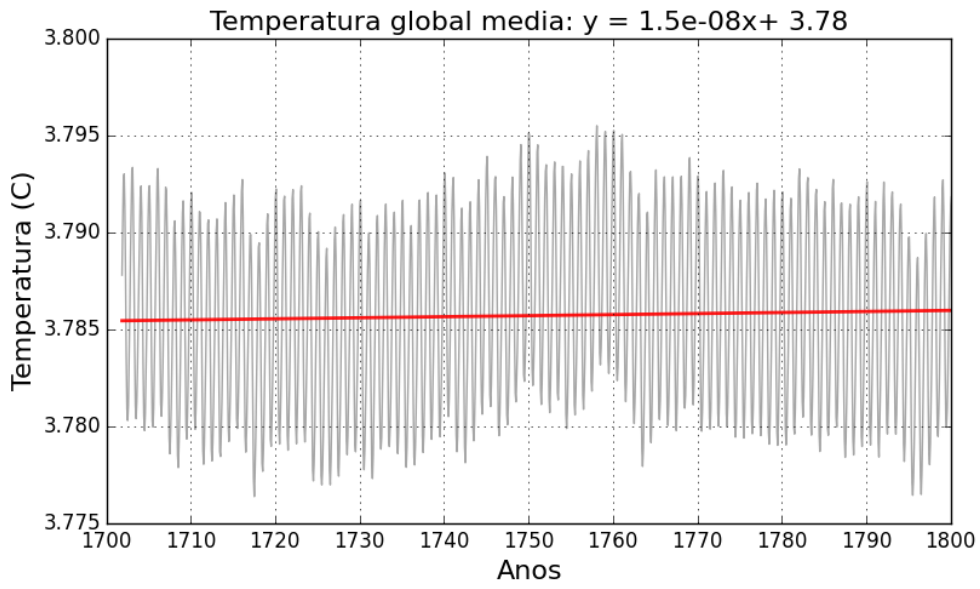

Figura 5: Série temporal dos últimos** 100 **anos da temperatura média global dos oceanos (equação 6) para a simulação controle. A curva cinza representa médias mensais e a linha vermelha representa a tendência do período (** $0.01^{o}C/$**século), cujos coeficientes são indicado no título da Figura.

4.2 Padrões temporais

A série temporal da temperatura média global do oceano para o experimento B20TR (Figura 6, já com o desvio do modelo corrigido) mostra um claro aumento de temperatura ao longo do período de simulação. Nesse gráfico (Figura 6) são mostradas as séries temporais de todas as 34 simulações (linha azul clara) e a média de todas as simulações (linha azul escura). Lembrando que cada uma das 34 simulações inicia em um ponto diferente do experimento controle.

Apesar do comportamento de baixa frequência das simulações ser o mesmo, nota-se diferenças consideráveis na alta frequência. Em alguns períodos (em torno de 1990) a diferença entre simulações chegou a ser 40% em relação a variação total de temperatura em todo o período.

Um outro fator que chama atenção nessa série temporal são as inversões abruptas das tendências de temperatura. São três inversões que se destacam. A primeira em torno de 1964, a segunda em torno de 1982 e a última em 1992. Essas inversões são explicadas pela presença de uma forçante vulcânica realista no experimento B20TR e é justamente nesses períodos de inversões que ocorreram três grande erupções vulcânicas, o Agung (Indonésia) em 1963, o El Chichón (México) em 1982 e o Pinatubo (Filipinas) em 1991 (Church *et al.*, 2011). Quando ocorre uma erupção vulcânica de

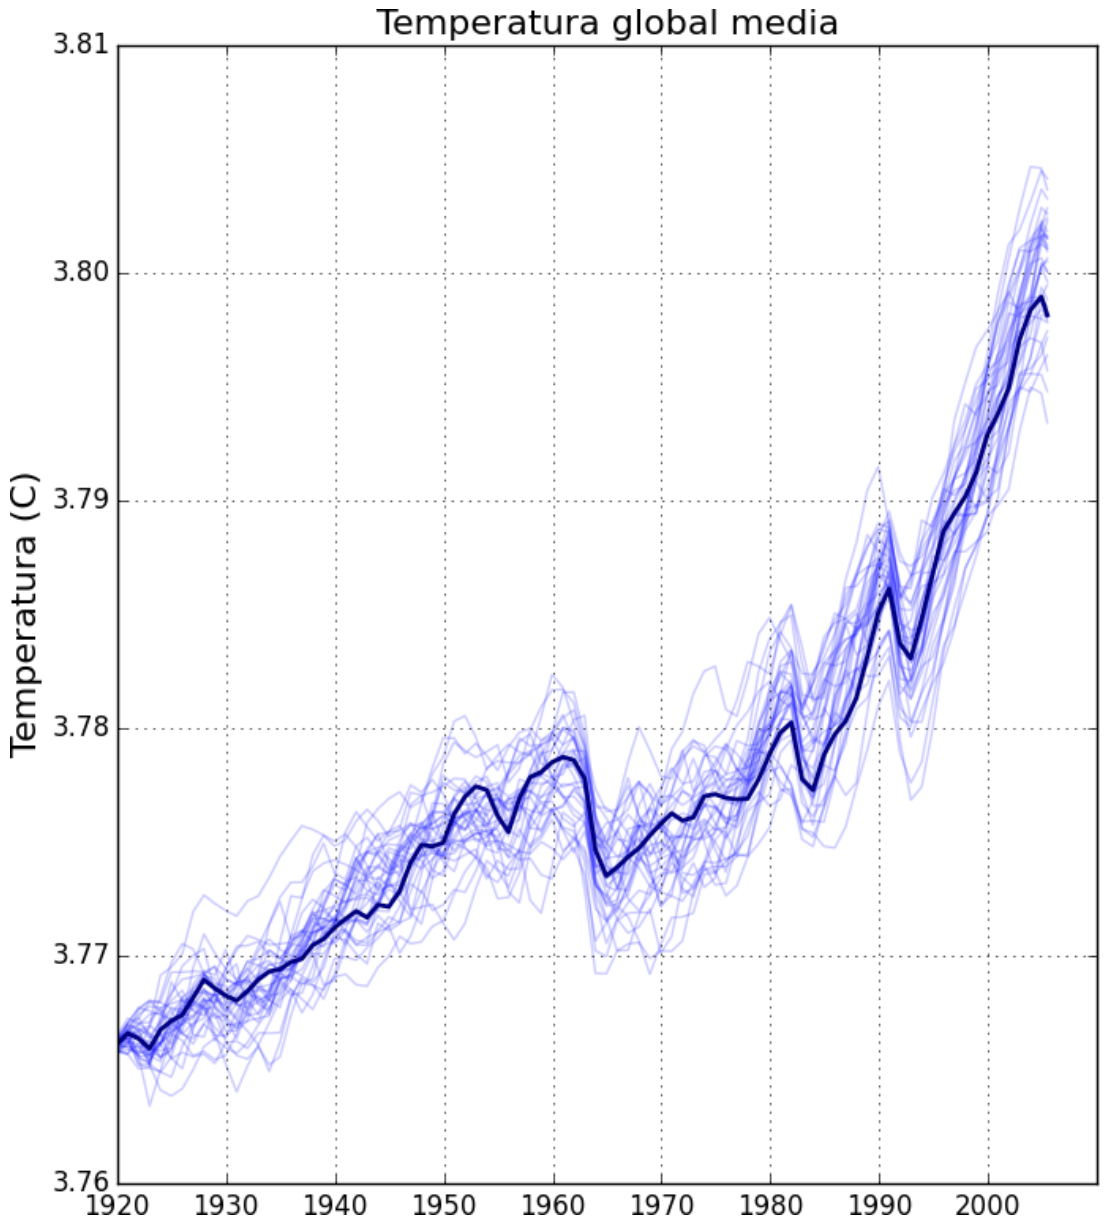

Figura 6: Série temporal da temperatura média global dos oceanos (equação 6) para a simulação B20TR. As curvas mais claras são médias anuais de cada um dos 34 membros do conjunto LENS e a linha azul escura é média do conjunto.

grande porte, muitas partículas são liberadas na atmosfera, que por sua vez refletirá mais a energia solar, fazendo com que o sistema climático absorva menos energia. Esse sinal de resfriamento é captado pelo oceano, refletindo em períodos de diminuição de temperatura do mesmo.

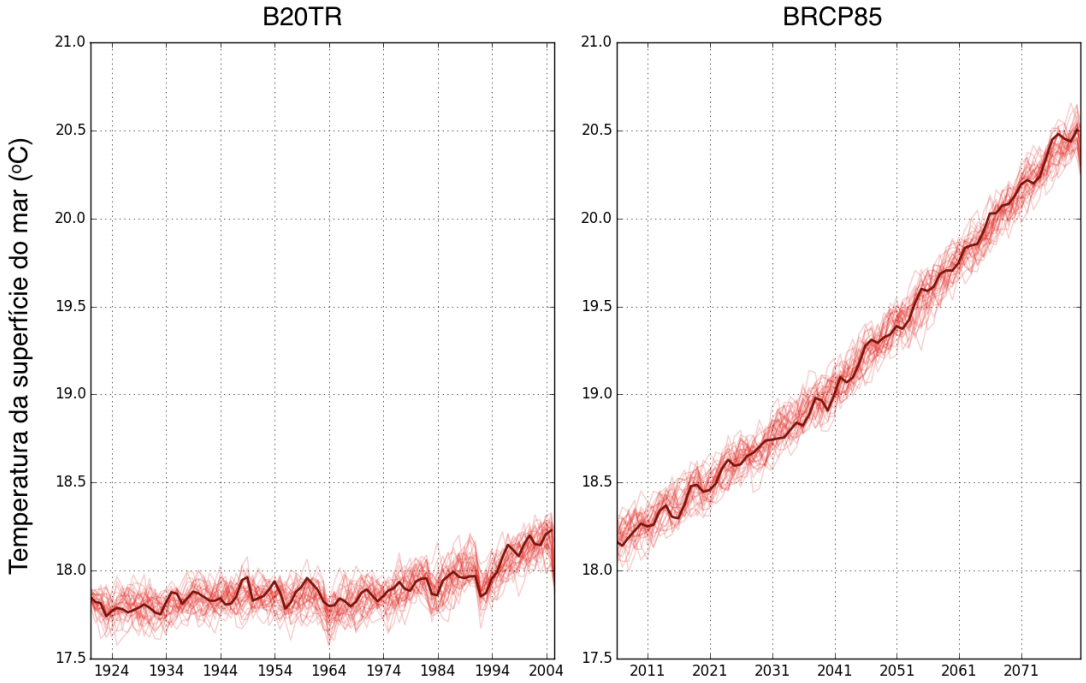

Figura 7: Série temporal da temperatura média global da superfície dos oceanos (equação 6) para a simulação B20TR (esquerda) e para a simulação de projeção climática BRCP85 (direita). As curvas mais claras são médias anuais de cada um dos 34 membros do conjunto LENS e a linha escura é média do conjunto.

A Figura 7 mostra a série temporal da temperatura apenas para a primeira camada do oceano (temperatura superficial do mar). Essa é camada que está em contato direto com a atmosfera, logo é nela que ocorrem as trocas de energia entre as componentes. Portanto, é essa camada que vai responder mais rapidamente a um desequilíbrio energético do sistema.

Novamente são mostradas as séries temporais referentes as 34 simulações do experimento B20TR (painel da esquerda) e também para o experimentos BRCP85. Ambos os experimentos apresentam tendências de aumento de temperatura, sendo que o experimento de projeção futura apresenta uma tendência muito mais pronunciada de aumento de temperatura. Esse resultado mostra claramente o aumento da temperatura do oceano, indicando uma absorção pelo mesmo de boa parte da energia da forçante energética imposta, inerente ao cenário de mudança climática severa (aumento de até

$8.5W/m^2$) imposta pelo experimento BRCP85. Novamente, apesar de haver diferenças entre as 34 simulações, o sinal de tendência de baixa frequência é bastante robusto.

4.3 Padrões espaciais

Ciclo sazonal (estações do ano) é um padrão bastante acentuado na temperatura superficial do mar em regiões não equatoriais. Esse ciclo responde diretamente a quantidade de energia recebida pelo Sol e possui um período equivalente a um ano. As próximas Figuras (8 e 9) mostram o padrão climatológico para a média das 34 simulações de cada um dos experimentos, o B20TR e o BRCP85. As análises desses padrões foram restritas à região que engloba todo o Oceano Atlântico Sul.

A Figura 8 mostra a distribuição espacial de temperatura superficial do oceano de verão e inverno para o Oceano Atlântico Sul. Os painéis da porção superior referem-se ao experimento B20TR e os painéis da parte inferior referem-se ao experimento BRCP85. As diferenças entre verão e inverno são bastante evidentes nos dois experimentos. O verão mostra temperaturas mais altas (cores quentes) atingindo latitudes mais ao sul enquanto no inverno, as temperaturas mais frias avançam em direção ao norte.

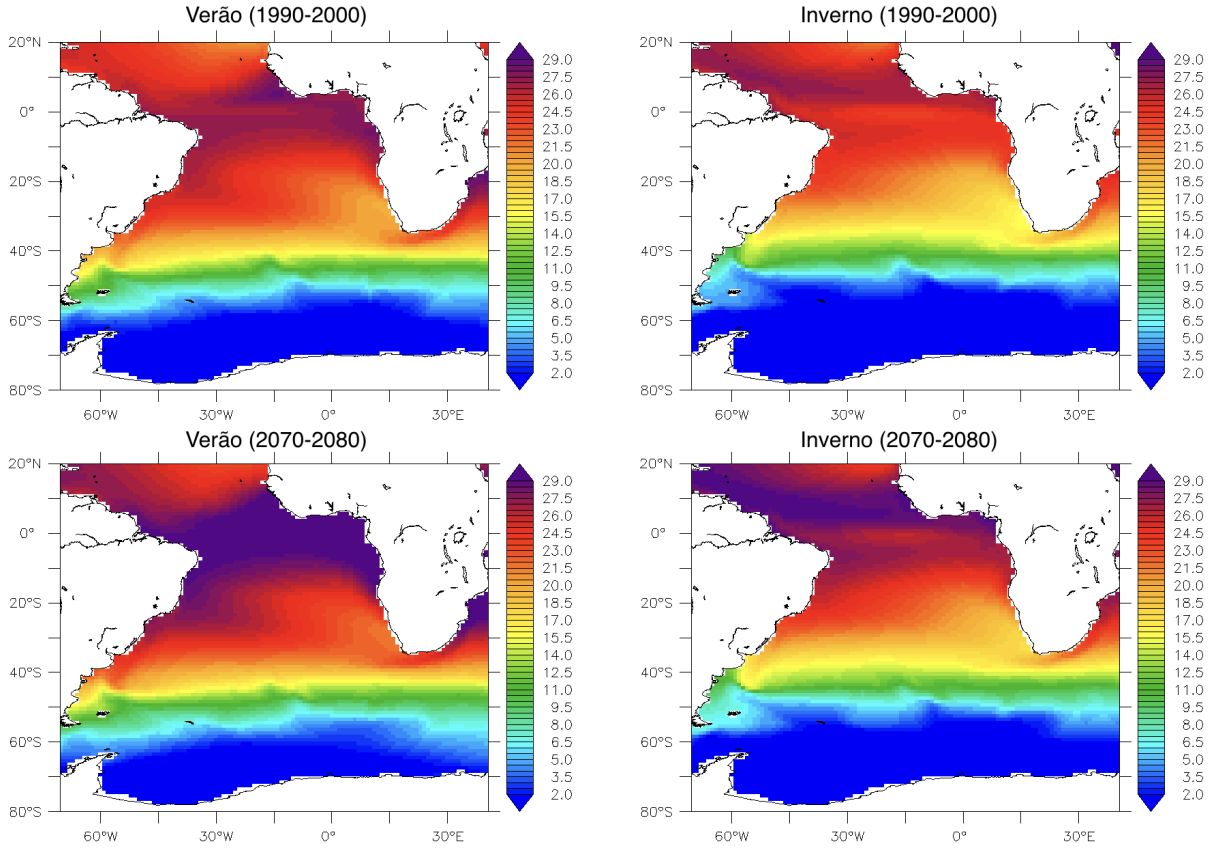

Figura 8: Padrões médios climatológicos de verão (esquerda) e de inverno (direita) da temperatura superficial dos oceanos para as simulações B20TR e BRCP85. A escala de cor é a mesma para os 4 mapas e representa os valores de temperatura em °C.

Com relação a diferença entre os experimentos B20TR e o BRCP85, nota-se temperaturas bastante superiores (chegando até a 3°C) no cenário de projeção climática, principalmente em latitudes tropicais, próximas ao equador.

O ciclo anual climatológico para a região do Atlântico Sul (equação 8) é mostrado na Figura 9. Para cada uma das décadas indicadas na Figura, foi calculado o ciclo climatológico. Observa-se que apesar do aumento de temperatura ao longo das décadas não há varição na amplitude do sinal climatológico. Ou seja, o aumento de temperatura ocorre igualmente em todas as épocas do ano. Uma outra característica é que tanto o máximo quanto o mínimo de temperatura ocorrem sempre no final do verão (Março) e inverno (Setembro) respectivamente.

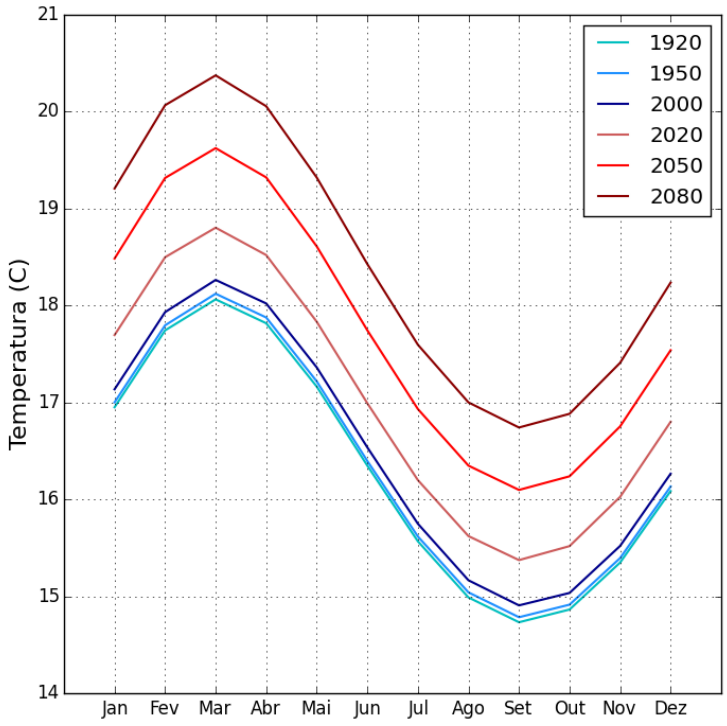

Figura 9: Curva climatológica da temperatura superficial dos oceanos para diferentes décadas das simulações B20TR ***e*** BRCP85***. Cada curva (cor) representa uma década.***

4.4 Padrões espaço-temporais associados: *Empirical Orthogonal Functions*

Um padrão espaço-temporal bastante relevante para o clima é o El-Niño/Oscilação Sul. Esse é um modo de variabilidade natural do Oceano Pacífico que por sua vez é capaz de impactar o clima como um todo, como por exemplo, aumentando o volume de chuvas na região sudeste do Brasil e gerando longos períodos de estiagem nas regiões norte e nordeste do país (Philander, 1990).

Esse padrão de variabilidade está associado a anomalias positivas de temperatura superficial do mar na porção tropical do Oceano Pacífico, principalmente junto à costa do continente Americano, e possui uma periodicidade variando entre 3 e 7 anos. Deser *et al.* (2010) utilizou a técnica de Funções Ortogonais Empíricas (EOF) aplicada a dados de temperatura superficial do oceano provenientes de satélite para a determinar o padrão espaço-temporal do El-Niño/Oscilação Sul. O objetivo dessa análise aplicada a um espaço de anomalias de temperatura é determinar um padrão espaço-temporal que responda pelo máximo de covariância entre a série temporal de anomalia para todos os pares de pontos do espaço.

As Figuras 10 e 11 mostram o resultado da aplicação da técnica de EOF (descrita no Capítulo 3). A análise de EOF foi aplicada aos campos de anomalia da temperatura superficial do oceano (com remoção da tendência, de modo a obtermos uma série temporal estacionária para cada ponto do espaço). A técnica foi aplicada aos dois experimentos, o B20TR e o BRCP85. Em ambos foi utilizada a média das 34 simulações para a obtenção do campo de temperatura.

O resultado da análise para o experimento B20TR (Figura 10) capturou a estrutura espacial do modo de variabilidade El-Niño/Oscilação Sul com anomalias positivas de temperatura para a região tropical do Oceano Pacífico junto à costa da América. A análise mostra também que tal estrutura espacial de anomalias de temperatura indicada na Figura responde por 43% de toda a variabilidade explicada do sistema.

Os valores positivos indicados na série temporal associado ao modo espacial mostrado, apontam o ano de ocorrência de um evento de El-Niño. Quanto mais positiva a anomalia da série temporal, mais intenso o evento de El-Niño.

Em regra, a simulação numérica foi capaz de reproduzir de forma bastante fiel os grandes eventos de El-Niño já registrados, destacando os dois eventos de El-Niño que

ocorreram nos anos de 1982–1983 e 1991–1992[11].

No experimento de projeção climática BRCP85 (Figura 11) observa-se também a presença da estrutura espacial característica do El-Niño com uma variância explicada de 54.9%. Em relação ao experimento para o século XX (B20TR), esse modo passou a ser mais dominante, devido a maior variância explicada. Já a série temporal correspondente ao primeiro modo da EOF mostra ciclos associados a períodos variando entre 3 e 7 anos, típicos da oscilação El-Niño. Essa série também apresentou anomalias positivas mais intensas, indicando possíveis El-Niños mais rigorosos em um cenário de mudança climática abrupta. Com relação a frequência de eventos El-Niño não observa-se nenhuma diferença significativa.

[11] https://www.ncdc.noaa.gov/news/historical-perspective-el-nino[Acessado em Novembro de 2017]

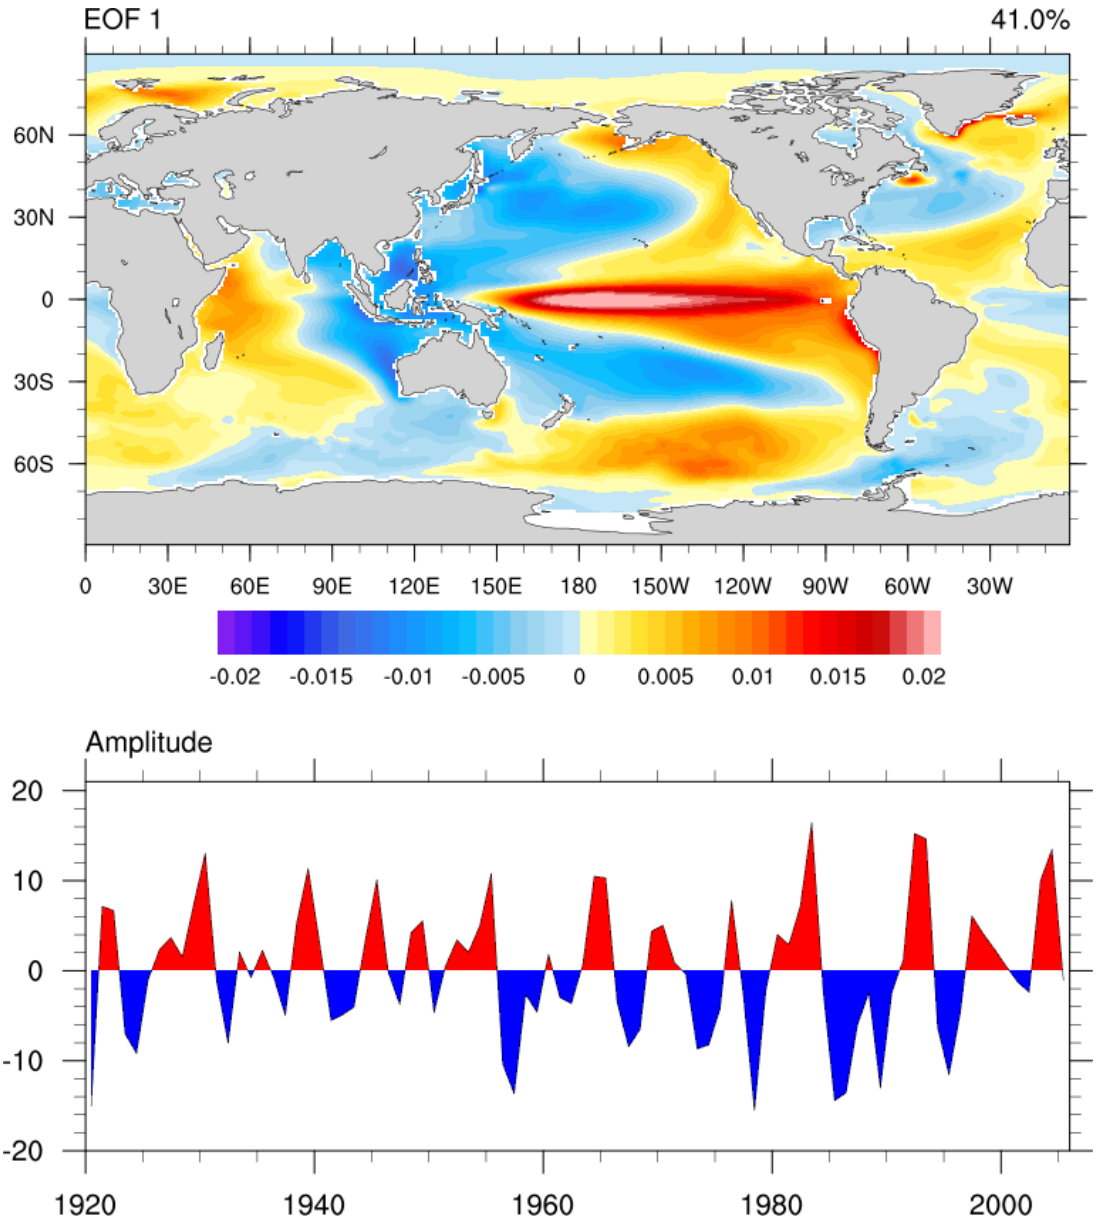

Figura 10: Padrões espaciais do primeiro modo da temperatura da superfície do oceano (EOF1) e série temporal dos coeficientes de expansão (componente principal 1 - PC1) do primeiro modo. As séries temporais são adimensionais. Simulação B20TR.

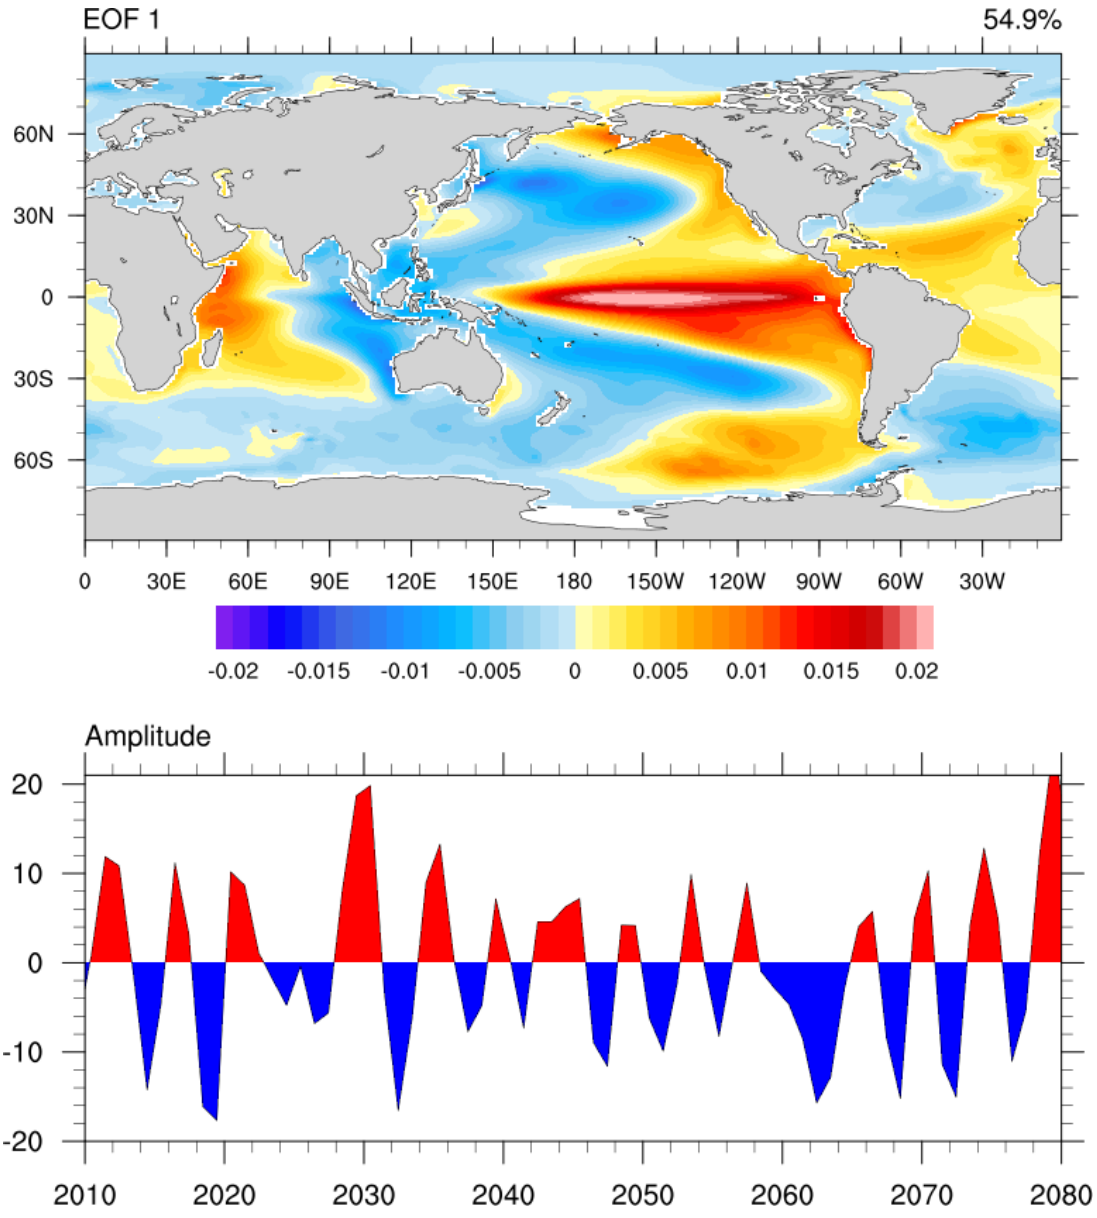

Figura 11: Padrões espaciais do primeiro modo da temperatura da superfície do oceano (EOF1) e série temporal dos coeficientes de expansão (componente principal 1 - PC1) do primeiro modo. As séries temporais são adimensionais. Simulação BRCP85***.***

5 Conclusão

O intuito do presente estudo foi mostrar como a computação de alta performance desempenha um papel importante na geração de simulações do clima e, consequentemente, permite avançar no entendimento dos padrões e tendências das mudanças climáticas.

Além das simulações do clima, também são fundamentais para o desenvolvimento das ciências climáticas as técnicas de análises de tais simulações. Neste estudo foram apresentadas e aplicadas algumas técnicas de análise de dados de forma a tentar reduzir o enorme volume de resultados produzidos por uma simulação do clima e com isso destacar padrões emergentes de tais simulações. Os resultados provenientes de tais análises mostram um padrão claro de aumento da temperatura média global do oceano tanto para um experimento que busca reproduzir o clima do século XX, quanto para um experimento de projeção climática, que considera um cenário forçante severo de aquecimento global. O aumento de temperatura do oceano mostra sua capacidade de acumular energia e ao mesmo tempo demonstra o fenômeno da mudança climática ao longo do século XX até os dias atuais.

Com relação ao uso de técnicas estatísticas (análise por Funções Ortogonais Empíricas - EOF) que buscam evidenciar padrões (estatísticos) espaço-temporais relevantes de um determinado campo, mostrou-se que o modo (físico) de variabilidade espaço-temporal conhecido como El-Niño/Oscilação Sul, cujos impactos climáticos são sentidos em diversas regiões do planeta, foi capturado e quantificado por tal análise.

Por fim, considerando o contexto do paradigma científico fortemente baseado na ciência de dados, a aproximação de técnicas computacionais e estatísticas sofisticadas, como visualização de dados, *machine learning*, entre outras, com as ciências climáticas possui um grande potencial para gerar avanços em ambas as áreas do conhecimento.

Referências

Church, J. A., White, N. J., Konikow, L. F., Domingues, C. M., Cogley, J. G., Rignot, E., Gregory, J. M., van den Broeke, M. R., Monaghan, A. J., Velicogna, I., 2011. Revisiting the earth's sea-level and energy budgets from 1961 to 2008. Geophysical Research Letters 38 (18), n/a–n/a, l18601.
URL http://dx.doi.org/10.1029/2011GL048794 22

Danabasoglu, G., Bates, S. C., Briegleb, B. P., Jayne, S. R., Jochum, M., Large, W. G., Peacock, S., Yeager, S. G., 2012. The ccsm4 ocean component. Journal of Climate 25 (5), 1361–1389.
URL https://doi.org/10.1175/JCLI-D-11-00091.1 9

Deser, C., Alexander, M. A., Xie, S.-P., Phillips, A. S., 2010. Sea surface temperature variability: Patterns and mechanisms. Annual Review of Marine Science 2 (1), 115–143, pMID: 21141660.
URL https://doi.org/10.1146/annurev-marine-120408-151453 28

Griffies, S., 2004. Fundamentals of Ocean Climate Models. Princeton University Press.
URL https://books.google.com.br/books?id=tqNpQgAACAAJ 10

Griffies, S. M., Danabasoglu, G., Durack, P. J., Adcroft, A. J., Balaji, V., Böning, C. W., Chassignet, E. P., Curchitser, E., Deshayes, J., Drange, H., Fox-Kemper, B., Gleckler, P. J., Gregory, J. M., Haak, H., Hallberg, R. W., Heimbach, P., Hewitt, H. T., Holland, D. M., Ilyina, T., Jungclaus, J. H., Komuro, Y., Krasting, J. P., Large, W. G., Marsland, S. J., Masina, S., McDougall, T. J., Nurser, A. J. G., Orr, J. C., Pirani, A., Qiao, F., Stouffer, R. J., Taylor, K. E., Treguier, A. M., Tsujino, H., Uotila, P., Valdivieso, M., Wang, Q., Winton, M., Yeager, S. G., 2016. Omip contribution to cmip6: experimental and diagnostic protocol for the physical component of the ocean model intercomparison project. Geoscientific Model Development 9 (9), 3231–3296.
URL https://www.geosci-model-dev.net/9/3231/2016/ 16

Hunter, J. D., 2007. Matplotlib: A 2d graphics environment. Computing In Science & Engineering 9 (3), 90–95. 37

Intel, 2017. Intel® parallel studio xe 2017 .

URL https://software.intel.com/en-us/intel-parallel-studio-xe 14

Kay, J. E., Deser, C., Phillips, A., Mai, A., Hannay, C., Strand, G., Arblaster, J. M., Bates, S. C., Danabasoglu, G., Edwards, J., Holland, M., Kushner, P., Lamarque, J.-F., Lawrence, D., Lindsay, K., Middleton, A., Munoz, E., Neale, R., Oleson, K., Polvani, L., Vertenstein, M., 2015. The community earth system model (cesm) large ensemble project: A community resource for studying climate change in the presence of internal climate variability. Bulletin of the American Meteorological Society 96 (8), 1333–1349.

URL http://dx.doi.org/10.1175/BAMS-D-13-00255.1 3, 7, 9, 10

Kharin, V. V., Zwiers, F. W., 2002. Climate predictions with multimodel ensembles. Journal of Climate 15 (7), 793–799.

URL https://doi.org/10.1175/1520-0442(2002)015<0793:CPWME>2.0.CO;2 7

Lorenz, E. N., 1963. Deterministic nonperiodic flow. Journal of the Atmospheric Sciences 20 (2), 130–141.

URL https://doi.org/10.1175/1520-0469(1963)020<0130:DNF>2.0.CO;2 6

Philander, S., 1990. El Niño, La Niña, and the Southern Oscillation. International geophysics series. Academic Press.

URL https://books.google.com.br/books?id=zlOeAQAACAAJ 28

Riahi, K., Rao, S., Krey, V., Cho, C., Chirkov, V., Fischer, G., Kindermann, G., Nakicenovic, N., Rafaj, P., Aug 2011. Rcp 8.5—a scenario of comparatively high greenhouse gas emissions. Climatic Change 109 (1), 33.

URL https://doi.org/10.1007/s10584-011-0149-y 9

Stocker, T. F., Qin, D., Plattner, G.-K., Tignor, M., Allen, S. K., Boschung, J., Nauels, A., Xia, Y., Bex, B., Midgley, B., 2013. Ipcc, 2013: climate change 2013: the physical science basis. contribution of working group i to the fifth assessment report of the intergovernmental panel on climate change . 3, 13

van der Walt, S., Colbert, S. C., Varoquaux, G., March 2011. The numpy array: A structure for efficient numerical computation. Computing in Science Engineering 13 (2), 22–30. 37

von Storch, H., Zwiers, F., 2001. Statistical Analysis in Climate Research. Cambridge University Press.
URL https://books.google.com.br/books?id=_VHxE26QvXgC 17

Wainer, I., Venegas, S. A., 2002. South atlantic multidecadal variability in the climate system model. Journal of Climate 15 (12), 1408–1420.
URL https://doi.org/10.1175/1520-0442(2002)015<1408:SAMVIT>2.0.CO;2 17

A Tamanhos dos *outputs*

Exemplos do tamanho dos arquivos de saída do modelo e tamanho total dos dados baixados e analisados durante esse trabalho:

Formato do nome do arquivo:

```
$ ls -lhs
  total 436G
  23G -rw-r--r-- 1 bruno labmet 23G Aug 23 08:55
      b.e11.B20TRC5CNBDRD.f09_g16.001.pop.h.TEMP.185001-200512.nc
 ...
 ...
  13G -rw-r--r-- 1 bruno labmet 13G Aug 23 20:34
      b.e11.B20TRC5CNBDRD.f09_g16.034.pop.h.TEMP.192001-200512.nc
$ du -h
  260G  TEMP/1850_control
  470G  TEMP/RCP85_projection
  436G  TEMP/20TR_historical
  1.2T  TEMP/
```

B Softwares e ferramentas

Todos os resultados, gráficos e análises apresentados nesse trabalho foram produzidos utilizando *softwares* de código aberto. Abaixo segue uma lista dos principais *softwares* utilizados.

- The NCAR Command Language (Version 6.4.0 - 2017), UCAR/NCAR/CISL/TDD. http://dx.doi.org/10.5065/D6WD3XH5;

  Utilizado para a análise de EOF.

- CDO: Climate Data Operators, http://www.mpimet.mpg.de/cdo;

  Utilizado para gerar os campos interpolados para uma grade física (t, x, y, z)

- NOAA/PMEL Ferret Data Visualization and Analysis https://github.com/NOAA-PMEL/Ferret;

  Utilizada para gerar as visualizações dos mapas de temperatura.

- NetCDF 4.5.0 - UCAR/Unidata, http://doi.org/10.5065/D6H70CW6;

  Bibliotecas para manipulação dos arquivos de *output* do modelo.

- Bibliotecas do Python: NumPy (van der Walt *et al.*, 2011) e Matplotlib (Hunter, 2007)

  Para gerar as análises de series temporais; Modelo do Atractor de Lorenz e geração de gráficos.

C Apreciação pessoal e crítica

Boa parte do trabalho realizado durante esse ano de desenvolvimento do projeto de TCC estão muito além do contido nos resultados apresentados nessa monografia. Grande parte do tempo dedicado foi utilizado com a familiarização do formato dos dados utilizados e sua manipulação. Foram diversas horas gastas na "área de *cracking*" centenas de *gigabytes* de dados científicos, o que proporcionou um grande aprendizado de ferramentas de análise e tratamento de dados.

Trabalhar também em um tema que faz uma interface entre duas diferentes áreas, a computação e as ciências climáticas, ajudou bastante a ampliar a visão de como o conhecimento computacional é aplicado a diversas áreas do conhecimento.

Gostaria de mencionar também a importância das disciplinas cursadas durante o curso do BCC para realização e familiarização com algumas técnicas utilizadas nesse trabalho. Destaco aqui os cursos de Cálculos que foram bastante importantes para entendimentos dos conceitos de modelos matemáticos envolvendo equações diferencias. A disciplina de Métodos Numéricos da Álgebra Linear, foi bastante importante para o entendimento do uso da técnica de EOF usada na análise dos dados. Uma outra disciplina que ajudou bastante foi uma optativa feita no Instituto Oceanográfica, chamada Técnicas de Visualização de Dados, que ajudou bastante na geração de alguns gráficos apresentados nessa monografia. Programação Concorrente e Paralela, também foi bastante importante por introduzir a importância do High Performance Computing nos avanços científicos. Enfim, todas as disciplinas cursadas contribuíram de alguma forma, seja de forma direta ou com o desenvolvimento do pensamento crítico computacional, para a realização do presente estudo!