



Tópicos Especiais em **Modelagem do Tempo, Clima e Sistema Terrestre**

Fernanda Casagrande
Noele Franchi Leonardo
Ana Carolina Nascimento Santos
Helena Barbieri de Azevedo
Regiane Moura
(Organizadoras)



AYA EDITORA

2024

Dra. Fernanda Casagrande
Dra. Noele Franchi Leonardo
Dra. Ana Carolina Nascimento Santos
Dra. Helena Barbieri de Azevedo
Dra. Regiane Moura
(Organizadoras)

Tópicos Especiais em Modelagem do Tempo, Clima e Sistema Terrestre

Ponta Grossa
2024

Direção Editorial

Prof.º Dr. Adriano Mesquita Soares

Organizadoras

Dra. Fernanda Casagrande

Dra. Noele Franchi Leonardo

Dra. Ana Carolina Nascimento Santos

Dra. Helena Barbieri de Azevedo

Dra. Regiane Moura

Capa

AYA Editora©

Revisão

Os Autores

Executiva de Negócios

Ana Lucia Ribeiro Soares

Produção Editorial

AYA Editora©

Imagens de Capa

br.freepik.com

Área do Conhecimento

Ciências Exatas e da Terra

Conselho Editorial

Prof.º Dr. Adilson Tadeu Basquerote Silva

Universidade para o Desenvolvimento do Alto Vale do Itajaí

Prof.º Dr. Aknaton Toczec Souza

Centro Universitário Santa Amélia

Prof.ª Dr.ª Andréa Haddad Barbosa

Universidade Estadual de Londrina

Prof.ª Dr.ª Andreia Antunes da Luz

Faculdade Sagrada Família

Prof.º Dr. Argemiro Midonês Bastos

Instituto Federal do Amapá

Prof.º Dr. Carlos López Noriega

Universidade São Judas Tadeu e Lab. Biomecatrônica - Poli - USP

Prof.º Dr. Clécio Danilo Dias da Silva

Centro Universitário FACEX

Prof.ª Dr.ª Daiane Maria de Genaro Chirolí

Universidade Tecnológica Federal do Paraná

Prof.ª Dr.ª Danyelle Andrade Mota

Universidade Federal de Sergipe

Prof.ª Dr.ª Déborah Aparecida Souza dos Reis

Universidade do Estado de Minas Gerais

Prof.ª Ma. Denise Pereira

Faculdade Sudoeste – FASU

Prof.ª Dr.ª Eliana Leal Ferreira Hellvig

Universidade Federal do Paraná

Prof.º Dr. Emerson Monteiro dos Santos

Universidade Federal do Amapá

Prof.º Dr. Fabio José Antonio da Silva

Universidade Estadual de Londrina

Prof.º Dr. Gilberto Zammar

Universidade Tecnológica Federal do Paraná

Prof.ª Dr.ª Helenadja Santos Mota

Instituto Federal de Educação, Ciência e Tecnologia Baiano, IF Baiano - Campus Valença

Prof.ª Dr.ª Heloísa Thaís Rodrigues de Souza

Universidade Federal de Sergipe

Prof.ª Dr.ª Ingridi Vargas Bortolaso

Universidade de Santa Cruz do Sul

Prof.ª Ma. Jaqueline Fonseca Rodrigues

Faculdade Sagrada Família

Prof.ª Dr.ª Jéssyka Maria Nunes Galvão

Faculdade Santa Helena

Prof.º Dr. João Luiz Kovaleski

Universidade Tecnológica Federal do Paraná

Prof.º Dr. João Paulo Roberti Junior

Universidade Federal de Roraima

Prof.º Me. Jorge Soistak

Faculdade Sagrada Família

Prof.º Dr. José Enildo Elias Bezerra

Instituto Federal de Educação Ciência e Tecnologia do Ceará, Campus Ubajara

Prof.^a Dr.^a Karen Fernanda Bortoloti

Universidade Federal do Paraná

Prof.^a Dr.^a Leozenir Mendes Betim

Faculdade Sagrada Família e Centro de Ensino Superior dos Campos Gerais

Prof.^a Ma. Lucimara Glap

Faculdade Santana

Prof.^o Dr. Luiz Flávio Arreguy Maia-Filho

Universidade Federal Rural de Pernambuco

Prof.^o Me. Luiz Henrique Domingues

Universidade Norte do Paraná

Prof.^o Dr. Milson dos Santos Barbosa

Instituto de Tecnologia e Pesquisa, ITP

Prof.^o Dr. Myller Augusto Santos Gomes

Universidade Estadual do Centro-Oeste

Prof.^a Dr.^a Pauline Balabuch

Faculdade Sagrada Família

Prof.^o Dr. Pedro Fauth Manhães Miranda

Universidade Estadual de Ponta Grossa

Prof.^o Dr. Rafael da Silva Fernandes

Universidade Federal Rural da Amazônia, Campus Parauapebas

Prof.^a Dr.^a Regina Negri Pagani

Universidade Tecnológica Federal do Paraná

Prof.^o Dr. Ricardo dos Santos Pereira

Instituto Federal do Acre

Prof.^a Ma. Rosângela de França Bail

Centro de Ensino Superior dos Campos Gerais

Prof.^o Dr. Rudy de Barros Ahrens

Faculdade Sagrada Família

Prof.^o Dr. Saulo Cerqueira de Aguiar Soares

Universidade Federal do Piauí

Prof.^a Dr.^a Sílvia Aparecida Medeiros

Rodrigues

Faculdade Sagrada Família

Prof.^a Dr.^a Sílvia Gaia

Universidade Tecnológica Federal do Paraná

Prof.^a Dr.^a Sueli de Fátima de Oliveira

Miranda Santos

Universidade Tecnológica Federal do Paraná

Prof.^a Dr.^a Thaisa Rodrigues

Instituto Federal de Santa Catarina

© 2024 - **AYA Editora** - O conteúdo deste Livro foi enviado pelos autores para publicação de acesso aberto, sob os termos e condições da Licença de Atribuição *Creative Commons* 4.0 Internacional (**CC BY 4.0**). Este livro, incluindo todas as ilustrações, informações e opiniões nele contidas, é resultado da criação intelectual exclusiva dos autores. Os autores detêm total responsabilidade pelo conteúdo apresentado, o qual reflete única e inteiramente a sua perspectiva e interpretação pessoal. É importante salientar que o conteúdo deste livro não representa, necessariamente, a visão ou opinião da editora. A função da editora foi estritamente técnica, limitando-se ao serviço de diagramação e registro da obra, sem qualquer influência sobre o conteúdo apresentado ou opiniões expressas. Portanto, quaisquer questionamentos, interpretações ou inferências decorrentes do conteúdo deste livro, devem ser direcionados exclusivamente aos autores.

T757 Tópicos especiais em modelagem do tempo, clima e do sistema terrestre [recurso eletrônico]. / Fernanda Casagrande (organizadora)...[et al.] -- Ponta Grossa: Aya, 2024. 136 p.

Inclui biografia
Inclui índice
Formato: PDF
Requisitos de sistema: Adobe Acrobat Reader
Modo de acesso: World Wide Web
ISBN: 978-65-5379-425-2
DOI: 10.47573/aya.5379.2.258

. Meteorologia. 2. Oceanografia. 3. Climatologia agrícola. 4. Meteorologia agrícola. I. Casagrande, Fernanda. II. Leonardo, Noele Franchi. III. Santos, Ana Carolina Nascimento. IV. Azevedo, Helena Barbieri de. V. Moura, Regiane Silva. VI. Título

CDD: 551.5

Ficha catalográfica elaborada pela bibliotecária Bruna Cristina Bonini - CRB 9/1347

International Scientific Journals Publicações de Periódicos e Editora LTDA

AYA Editora©

CNPJ: 36.140.631/0001-53
Fone: +55 42 3086-3131
WhatsApp: +55 42 99906-0630
E-mail: contato@ayaeditora.com.br
Site: <https://ayaeditora.com.br>
Endereço: Rua João Rabello Coutinho, 557
Ponta Grossa - Paraná - Brasil
84.071-150

SUMÁRIO

Apresentação..... 9

01

Origens da modelagem do tempo, clima e sistema terrestre 10

Fernanda Casagrande
Everton Holz Brignol
Madeleine Sánchez Gácita Casagrande
Helena Barbieri de Azevedo
Rose Ane Pereira de Freitas
Luís Felipe Ferreira de Mendonça
André Lanfer Marquez
Noele Franchi Leonardo
Marcus Jorge Bottino

DOI: 10.47573/aya.5379.2.265.1

02

Modelagem do tempo e clima utilizando modelos atmosféricos e oceânicos regionais: Parte I - avanços e desafios 20

Luís Felipe Ferreira de Mendonça
Rose Ane Pereira de Freitas
Rafael Afonso do Nascimento Reis
Fernanda Casagrande
Helena Barbieri de Azevedo
Ricardo Acosta Gotuzzo
André Lanfer Marquez
Carlos Alexandre Domingos Lentini
Rita de Cássia Marques Alves

DOI: 10.47573/aya.5379.2.265.2

03

Modelagem do tempo e clima utilizando modelos atmosféricos e oceânicos regionais: Parte II - equações 31

Luís Felipe Ferreira de Mendonça
Rose Ane Pereira de Freitas
Rafael Afonso do Nascimento Reis
Fernanda Casagrande
Helena Barbieri de Azevedo
Ricardo Acosta Gotuzzo
Carlos Alexandre Domingos Lentini
André Lanfer Marquez
Rita de Cássia Marques Alves

DOI: 10.47573/aya.5379.2.265.3

04

Aspectos sobre a modelagem de ondas 48

André Lanfer Marquez
Luís Felipe Ferreira de Mendonça
Fernanda Casagrande
Regiane Moura

DOI: 10.47573/aya.5379.2.265.4

05

Assimilação de dados no contexto da Previsão Numérica do Tempo 61

Helena Barbieri de Azevedo
Fernanda Casagrande
Luís Felipe Ferreira de Mendonça
Rose Ane Pereira de Freitas

DOI: 10.47573/aya.5379.2.265.5

06

Introdução à modelagem da superfície continental .. 71

Aline Anderson de Castro

DOI: [10.47573/aya.5379.2.265.6](https://doi.org/10.47573/aya.5379.2.265.6)

07

Desastres naturais: aspectos sobre modelagem hidrológica a partir da previsão numérica de tempo .. 82

Leandro Casagrande

Minella Alves Martins

Fernanda Casagrande

Ana Carolina Nascimento Santos

DOI: [10.47573/aya.5379.2.265.7](https://doi.org/10.47573/aya.5379.2.265.7)

08

Modelagem agrometeorológica: monitoramento, previsão e adaptação frente aos extremos climáticos 98

Minella Alves Martins

Erica Acioli Canamary

Ana Carolina Nascimento Santos

Javier Tomasella

DOI: [10.47573/aya.5379.2.265.8](https://doi.org/10.47573/aya.5379.2.265.8)

09

Modelagem da interação entre aerossóis e nuvens . 113

Madeleine Sánchez Gácita Casagrande

Fernanda Casagrande

DOI: [10.47573/aya.5379.2.265.9](https://doi.org/10.47573/aya.5379.2.265.9)

Organizadoras..... 128

Índice Remissivo..... 130

Apresentação

Este livro apresenta uma visão abrangente sobre a Modelagem Numérica do Tempo, Clima e Sistema Terrestre, abordando tópicos especiais que vão desde as origens da modelagem até os processos de interação entre aerossóis e nuvens. No primeiro capítulo, são discutidas as origens da modelagem do tempo, clima e sistema terrestre, apresentando a evolução histórica e os principais desafios enfrentados atualmente. Os capítulos seguintes abordam a modelagem do tempo e clima utilizando modelos atmosféricos e oceânicos regionais, com destaque para os avanços e desafios na área e o equacionamento envolvido.

O livro também apresenta aspectos importantes sobre a modelagem de ondas, assimilação de dados no contexto da previsão numérica do tempo e a modelagem da superfície continental. Além disso, são discutidos os aspectos sobre modelagem hidrológica a partir da previsão numérica de tempo, com foco em desastres naturais, e a modelagem agrometeorológica, que aborda o monitoramento, previsão e adaptação frente aos extremos climáticos. Por fim, o livro apresenta a modelagem da interação entre aerossóis e nuvens, um tema de grande relevância para a compreensão dos processos atmosféricos e climáticos.

Com uma abordagem clara e objetiva, este livro é indicado para estudantes e profissionais das áreas de meteorologia, climatologia, oceanografia e ciências ambientais, bem como para aqueles interessados em compreender os processos envolvidos na modelagem numérica do tempo, clima e sistema terrestre.

Boa leitura!

Prof.º Dr. Adriano Mesquita Soares

Editor Chefe | AYA Editora

Origens da modelagem do tempo, clima e sistema terrestre

Fernanda Casagrande

Everton Holz Brignol

Madeleine Sánchez Gácita Casagrande

Helena Barbieri de Azevedo

Rose Ane Pereira de Freitas

Luís Felipe Ferreira de Mendonça

André Lanfer Marquez

Noele Franchi Leonardo

Marcus Jorge Bottino

RESUMO

Entre os avanços científicos mais significativos do século passado está a capacidade do ser humano em simular processos físicos não lineares complexos, como o tempo e o clima, e prever sua evolução. Neste capítulo introdutório, aborda-se a progressão histórica dos modelos de tempo e clima, desde suas origens até os sofisticados modelos numéricos atuais, destacando-se os principais marcos e avanços que moldaram a compreensão atual dos processos atmosféricos e climáticos. A evolução desses modelos reflete uma jornada histórica que vai desde a observação empírica até o desenvolvimento de modelos numéricos complexos capazes de representar os processos acoplados entre os diversos componentes do sistema terrestre em uma ampla gama de escalas temporais e espaciais.

INTRODUÇÃO

A previsão do tempo e clima é uma ferramenta essencial para tomada de decisões em diversos setores, como agronegócio, energia, pesca, navegação, aviação e turismo. Além disso, as previsões são fundamentais para monitoramento e alerta de desastres naturais, bem como para avaliação de cenários de mudanças climáticas em uma ampla gama de escalas temporais e espaciais.

A previsão do tempo e do clima se desenvolveu ao longo de séculos e continua em constante evolução. Os primeiros registros de previsão, embora rudimentares e baseados na intuição, datam da antiguidade, quando os povos antigos observavam os padrões climáticos e meteorológicos para prever condições futuras. Desde então, diversos avanços contribuíram para o desenvolvimento de modelos numéricos capazes de representar os movimentos atmosféricos e suas complexas interações com os outros componentes do sistema terrestre, como oceano, superfície e criosfera.



Dentre os importantes marcos da história da previsão de tempo e clima estão: (i) criação de instrumentos meteorológicos e satélites, bem como as redes de observação de tempo e clima, (ii) desenvolvimento de equações físicas capazes de representar os movimentos atmosféricos e suas trocas de calor e energia, (iii) avanços tecnológicos associados à capacidade computacional que permitiram a criação de modelos de previsão de tempo e clima cada vez mais complexos e sofisticados.

Nos últimos 40 anos, os avanços tecnológicos e metodológicos permitiram o desenvolvimento de modelos de previsão cada vez mais sofisticados e confiáveis. Ainda assim, diversos são os desafios e limitações inerentes à representação de vários processos físicos acoplados no sistema climático. Por exemplo, a falta de dados precisos em algumas regiões do planeta (regiões polares, por exemplo) ainda representa um desafio frente a necessidade de melhorias nas parametrizações dos modelos climáticos (técnicas utilizadas para representar processos físicos que ocorrem em escalas menores do que a resolução espacial do modelo). Apesar dos desafios, a previsão de tempo e clima continuam sendo uma ferramenta poderosa e fundamental para sociedade.

Nesse capítulo abordam-se as origens históricas e desenvolvimento da modelagem numérica, indicando-se os principais avanços que moldaram a compreensão atual dos processos atmosféricos e climáticos na modelagem numérica.

CONHECIMENTO DO TEMPO E CLIMA: UM LEGADO DE MILÊNIOS

Desde os primórdios da civilização, o céu foi um livro aberto para a humanidade. Para nossos antepassados, ele era um manual que contava histórias sobre o clima, desde tempestades severas até colheitas prósperas. A cada amanhecer e entardecer, o horizonte oferecia sinais sobre o que estava por vir, como por exemplo a formação de nuvens carregadas que anunciavam a ocorrência de tempestades. Embora a modernidade nos tenha presenteado com ferramentas avançadas para entender o tempo e o clima, é importante lembrar que nosso interesse e conexão com os padrões atmosféricos é um legado que se estende por milênios (Lynch, 2008).

Desprovidos de satélites, supercomputadores ou redes de observações meteorológicas, nossos ancestrais desenvolveram uma sabedoria intuitiva sobre o clima. Mesmo que de forma aleatória e imprecisa, suas observações lhes permitiam prever o tempo, com base em mudanças de variáveis atmosféricas, como o vento, a temperatura e a umidade, e também no comportamento das aves. Esse conhecimento era essencial para a sobrevivência, pois os agricultores precisavam saber quando plantar e quando colher, os pescadores quando sair para o mar e os viajantes como se orientar e evitar perigos.

O interesse humano pelo tempo e clima é antigo e profundo. Na Bíblia, por exemplo, a passagem Mateus 16:2-3 menciona a observação de que “céu vermelho ao entardecer, bom tempo amanhã”. Essa observação, embora rudimentar, destaca a compreensão de que um sistema sinótico atuante pode prever uma condição futura. Não eram meras suposições, mas sim compreensões intuitivas baseadas na experiência e na observação contínua. A sabedoria ancestral, como por exemplo, a crença de que as gaivotas buscam refúgio em terra antes de uma tempestade, é um conhecimento que foi transmitido de

geração em geração que permanece até os dias atuais.

O século XVII, que viu o surgimento do Renascimento, foi um período de grandes avanços científicos, incluindo a meteorologia. Os pioneiros dessa época, motivados pela necessidade de melhor compreender o sistema climático começaram a realizar observações quantitativas dos principais parâmetros atmosféricos, além das simples observações qualitativas que eram feitas até então.

Um dos primeiros desenvolvimentos importantes foi a invenção do barômetro, instrumento capaz de medir a pressão atmosférica, por Evangelista Torricelli em 1643. Torricelli observou que a pressão do ar é altamente correlacionada com as mudanças nas condições atmosféricas. A descoberta de que uma queda na pressão atmosférica poderia indicar a aproximação de uma tempestade foi importante no contexto de “previsão meteorológica” baseada em dados observacionais.

Em 1709, o engenheiro alemão Daniel Gabriel Fahrenheit desenvolveu o termômetro a álcool e, mais tarde, o mais preciso termômetro de mercúrio, ambos capazes de quantificar a temperatura do ar (parâmetro crucial para previsão de tempo e clima). Daniel Gabriel Fahrenheit também foi responsável pela criação da conhecida escala de Fahrenheit (1724), utilizada até hoje.

Em meio a essas inovações, o químico francês Antonie Laurent de Lavoisier em 1765 emergiu não apenas como uma figura central na meteorologia, mas também como uma coluna vertebral da ciência moderna. Ao mensurar diariamente uma variedade de parâmetros meteorológicos (pressão do ar, umidade, temperatura, velocidade e direção do vento) ele visualizou o que seria o primeiro sistema de previsão do tempo. Sua convicção de que era possível prever as condições de tempo com antecedência pavimentou o caminho para o futuro da meteorologia. De acordo com Antonie Laurent de Lavoisier “É quase possível prever com um dois dias de antecedência dentro de uma ampla faixa de probabilidade, como serão as condições de tempo, pensa-se até que não será impossível publicar previsões de tempo diárias que seriam muito úteis à sociedade”.

A evolução e desenvolvimento dos primeiros passos em direção ao desenvolvimento de sistemas de previsão de tempo não parou por aí. Com a Revolução Industrial em pleno andamento no século XIX, a necessidade de entender e prever os padrões meteorológicos tornou-se cada vez mais premente. Instrumentos como o telégrafo elétrico, introduzido em 1837, permitiram um método para comunicação de padrões meteorológicos em extensas regiões geográficas (que permitiram também um avanço no conhecimento sobre os movimentos atmosféricos), alterando o panorama da colaboração meteorológica.

Em 1849 sob a liderança do norte americano Joseph Henry, o Instituto Smithsonian estabeleceu uma rede de observações meteorológicas nos Estados Unidos, no entanto a ideia de um sistema nacional de previsão de tempo demorou para se concretizar, tanto na Europa quanto nos Estados Unidos. Os avanços na meteorologia foram fortemente influenciados pela conhecida tragédia no Mar Negro em 1854, onde aproximadamente 38 navios franceses naufragaram devido a uma violenta tempestade, que culminou na morte de aproximadamente três mil pessoas. A tragédia serviu como um despertar para a importância de prever e entender as condições meteorológicas em situações marítimas e

militares. A perda de vidas e navios poderia ter sido evitada com sistemas de monitoramento meteorológico eficazes, ainda inexistentes à época. Apenas um ano após a tragédia (1855), as sábias recomendações do francês Urbain Le Verrier culminaram no estabelecimento de um sistema nacional de alerta de tempestades na França. E não demorou muito para a Inglaterra seguir o exemplo, com Robert Fitzroy utilizando a tecnologia emergente do telégrafo para produzir as primeiras cartas sinóticas e publicar as primeiras “previsões de tempo”.

Esta era de descobertas ao longo dos séculos XVII e XIX não foi apenas um período de avanços técnicos-científicos, mas uma época que definiu nossa relação com as condições de tempo e estabeleceu as bases de alguns dos entendimentos meteorológicos que utilizamos hoje. Em 1873, Viena se tornou o berço da Organização Meteorológica Mundial (OMM) e nos Estados Unidos, o exército estava tomando iniciativas pioneiras ao emitir seu primeiro alerta de furacão.

Apesar dos avanços, as análises ainda eram baseadas principalmente em observações empíricas, intuição e padrões históricos de tempo e clima. Contudo, uma nova fase estava prestes a começar, dando origem à previsão numérica do tempo e clima.

AS ORIGENS DA MODELAGEM NUMÉRICA DE TEMPO, CLIMA E DE SISTEMA TERRESTRE

Em 1916, Vilhelm Bjerknes, um físico norueguês, introduziu um conjunto de equações de movimentos da atmosfera com base na teoria dos fluídos. Estas equações combinavam as leis da termodinâmica e os princípios de conservação de massa e momento e seriam mais tarde conhecidas como “equações primitivas”. Bjerknes estabeleceu um plano de duas etapas para previsão, uma etapa diagnóstica, na qual o estado inicial da atmosfera é determinado por meio de observações, e uma etapa prognóstica, na qual as leis do movimento são usadas para calcular como esse estado muda ao longo do tempo. Bjerknes desenvolveu um método gráfico qualitativo para resolver as equações, pois não conseguia resolvê-las numericamente e uma solução analítica estava fora de questão. Sua ideia era representar o estado inicial da atmosfera por meio de uma série de gráficos que mostrassem a distribuição das variáveis em diferentes níveis (Lynch, 2008). Métodos gráficos baseados nas equações fundamentais poderiam então ser aplicados para construir um novo conjunto de cartas descrevendo a atmosfera algumas horas depois. Este processo poderia ser iterado até que o comprimento de previsão desejado fosse alcançado. Bjerknes comparou os métodos da meteorologia com os da astronomia, para os quais são possíveis previsões de grande precisão, e declarou seu objetivo: fazer da meteorologia uma ciência exata, uma verdadeira física da atmosfera. Até dias atuais, essas equações primitivas são reconhecidas como a base da dinâmica e termodinâmica atmosférica. Bjerknes fundou a “Escola de Bergen” de meteorologia e produziu contribuições inovadoras para o conhecimento da ciclogênese (Stocker, 2011).

Usando esses conhecimentos, Lewis Fry Richardson, um meteorologista britânico, vislumbrou um futuro onde essas equações não seriam apenas teóricas, mas teriam aplicações práticas. Richardson propôs um modelo revolucionário intitulado: Previsão do

tempo por processos numéricos (Richardson, 1922). Nesse trabalho, Richardson utilizou cálculos numéricos para resolver a tendência temporal de cada termo das equações em uma determinada grade, conduzindo assim a primeira previsão numérica do tempo (Lynch, 2006). A publicação foi baseada em um experimento conduzido em 1917, onde Richardson realizou cálculos (equações primitivas e equação de estado) utilizando dados observacionais de 12 perfis verticais de pressão e temperatura em diferentes estações por toda Europa. Esses dados serviram como condições iniciais para os cálculos de Richardson que definiu uma grade com resolução de $3^\circ \times 1.8^\circ$ e cinco camadas verticais, totalizando 150 pontos de grade nos quais as tendências eram calculadas. O experimento levou cerca de 3 meses para ser concluído e previu um aumento irrealístico na pressão atmosférica na ordem de 145 milibares (muito acima dos valores observados). Embora o experimento tenha falhado devido a erros nos cálculos associados a pequenos erros nas condições iniciais que se multiplicaram durante o procedimento numérico e levaram a fortes tendências de pressão, esse foi considerado um marco da previsão numérica de tempo e rendeu a Richardson o título de pai dos modelos climáticos atuais (McGuffie e Henderson-Sellers, 2001).

Segundo McGuffie e Henderson-Seller (2001), o método de Richardson estava pelo menos trinta anos à frente da capacidade muito modesta dos primeiros computadores. Ainda, Richardson conhecia e reconhecia a importância de aspectos negligenciados na época, como o oceano através da temperatura da superfície do mar (TSM).

De acordo com Stocker (2011) isso aponta para o fato de que as condições iniciais, ou a inicialização das condições meteorológicas é um problema central do qual o modelador deve estar sempre atento. Não apenas as condições iniciais, mas também a formulação de equações de conservação é crucial. Mesmo os dados iniciais mais precisos teriam levado à instabilidade usando as equações de Richardson, porque continham processos físicos (ondas gravitacionais), que desestabilizam a solução e tornam impossível uma previsão a longo prazo.

Técnicas de integração numérica adequadas que evitariam tal erro só foram desenvolvidas anos mais tarde e quando essas técnicas foram aplicadas aos cálculos, os resultados foram robustos e precisos. Mais tarde, Richardson propôs um método para paralelizar os cálculos. Ele imaginou um “teatro de cálculos”, onde um vasto salão seria utilizado para simular o globo terrestre. Em sua visão, “computadores” humanos se posicionariam em vários pontos deste teatro, cada um fazendo cálculos para sua respectiva posição geográfica. Este conceito foi precursor no entendimento acerca do paralelismo em computação. Segundo o cientista, ao dividir o trabalho, poder-se-ia acelerar o processo e vencer a complexidade das equações de Bjerknes (Stocker, 2011).

Embora o sonho de Richardson parecesse irrealizável, uma série de desenvolvimentos importantes nas décadas seguintes criaram o cenário para o progresso. Houveram desenvolvimentos científicos importantes na área da meteorologia que forneceram uma compreensão crucial dos estudos da dinâmica atmosférica. Ainda, os avanços na análise numérica possibilitaram o projeto de algoritmos estáveis. A invenção da radiossondagem e a sua introdução numa rede global significaram que observações oportunas da atmosfera em três dimensões estavam a tornar-se disponíveis. E, finalmente, o desenvolvimento do computador digital proporcionou um meio de atacar a enorme tarefa computacional envolvi-

da na previsão do tempo (Lynch, 2008). Esse também é considerado um marco histórico, a ciência que antes era baseada apenas em observações agora utilizava métodos numéricos “sofisticados” baseados em equações dinâmicas e termodinâmicas da atmosfera para desvendar as complexidades da previsão numérica de tempo (Shuman, 1989).

Carl-Gustav Rossby (Rossby, 1939), alcançou um grande avanço ao perceber que a conservação da vorticidade era uma restrição mais robusta do que a do momento. Essa abordagem é adequada para o sistema terrestre em rotação, porque o efeito Coriolis pode ser implementado de forma natural. Ondas planetárias (ondas de Rossby) aparecem em fluidos em rotação, como a atmosfera e o oceano. Atmosfera e oceano respondem a perturbações com a propagação de ondas de Rossby que causam correntes que então são capazes de modificar o estado de fundo. As ondas de Rossby são fundamentais para a compreensão dos sistemas meteorológicos na atmosfera e a circulação em grande escala no oceano (Stocker, 2011).

A década de 1940 foi um ponto de virada na integração da tecnologia e das observações meteorológicas. Com os primeiros sistemas de computadores programáveis (ENIAC - *Electronic Numerical Integrator and Computer*), desenvolvidos em Princeton para o Exército Americano, uma janela de oportunidades se abriu para vários campos da ciência (Platzman, 1979; Shuman, 1989). Em 1955 a primeira integração de longo prazo de um modelo simplificado de circulação atmosférica foi realizada por Norman Phillips (Phillips, 1956). O evento histórico marcou o início da utilização de modelos de circulação geral, que resolveriam as equações completas do fluxo atmosférico. Além dos problemas numericamente complexos, estudos teóricos sobre os fundamentos do comportamento dinâmico da atmosfera e do oceano foram avançados.

A conservação do momento e da vorticidade em um fluido em rotação implica em não linearidade dos termos no sistema de equações. Eles resultam da advecção do momento em um fluxo. Além disso, num referencial em rotação como a Terra, a força de coriolis provoca um acoplamento dos componentes dos movimentos horizontais. As não linearidades são responsáveis pela previsibilidade finita de tal fluxo como Edward Lorenz descobriu em 1963. Em seu artigo histórico intitulado “Fluxo não periódico determinístico” (Lorenz, 1963), ele descreve como os padrões de fluxo em grande escala podem levar a um comportamento caótico. Este artigo pioneiro estabeleceu a base para um domínio científico inteiramente novo: A Teoria do Caos. Embora a evolução de um sistema clássico possa ser calculada de forma determinística (resolvendo equações diferenciais parciais), o sistema perde sua previsibilidade após um tempo finito. Menores diferenças nas condições iniciais podem resultar em estados totalmente diferentes após um curto período de tempo. A determinação do estado final em função das condições iniciais não é mais possível. Esta constatação é bem conhecida como “efeito borboleta”.

Em meados da década de 1960, quase 20 anos após o desenvolvimento dos primeiros modelos de circulação da atmosfera, foram formulados modelos oceânicos tridimensionais (Bryan e Cox 1967).

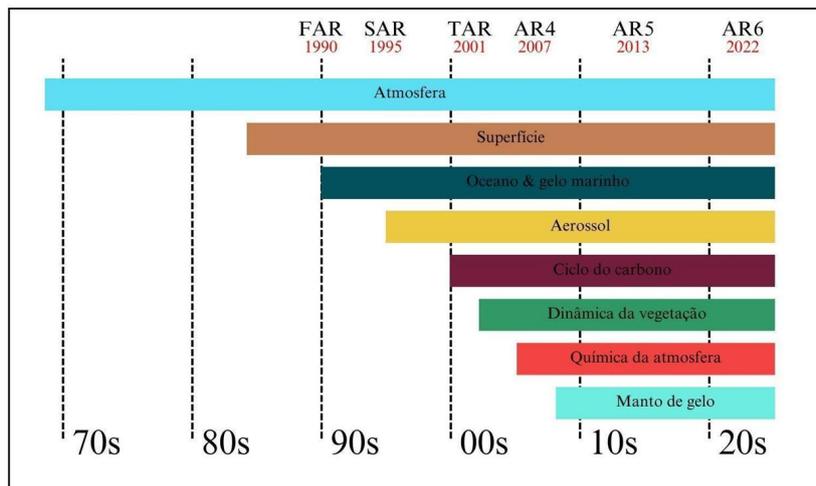
Syukuro Manabe descobriu que para a pesquisa climática, as componentes atmosféricas e oceânicas precisariam ser combinadas. O primeiro modelo acoplado foi desenvolvido por ele no final da década de 1960 (Manabe e Bryan 1969). Uma dificuldade

particular encontrada está relacionada as escalas de tempo completamente diferentes na atmosfera e no oceano. Um problema notório era que os fluxos de calor e água necessários entre a atmosfera e o oceano, que produzem climatologias coerentes com as observações, não foram compatíveis. Isto exigiu a introdução de uma correção de fluxo não física, que foi utilizada na maioria dos modelos ao longo de quase 30 anos.

O problema só poderia ser resolvido na última década graças ao aumento da resolução espacial dos modelos (geralmente é necessária uma resolução de pelo menos $2^\circ \times 2^\circ$) e melhorias nos esquemas de parametrizações.

A figura 1 mostra a evolução dos modelos climáticos e as características nele incluídas ao longo das últimas décadas. Os primeiros modelos climáticos dos anos 1970 eram relativamente simples, baseados nas equações fundamentais da dinâmica dos fluídos e tinham parametrizações simplificadas para radiação solar e precipitação, devido à importância destes fatores na energia atmosférica. Estas parametrizações eram essenciais porque os modelos da época não podiam resolver diretamente todos os processos atmosféricos em detalhes.

Figura 1 - Cronologia do desenvolvimento dos modelos climáticos.



Fonte: Adaptado de Navarro e Merino (2022)

Nos anos 1980, surgiram os modelos de superfície, melhorando a gestão dos fluxos de umidade. Alguns desses modelos também estimavam a nebulosidade melhorando as estimativas do balanço de energia. Por volta de 1990, os modelos de oceano foram introduzidos, permitindo que os oceanos funcionassem como reservatórios de calor, sem incluir circulações oceânicas. Essas simulações foram incluídas no Primeiro relatório FAR publicado pelo Painel Intergovernamental sobre Mudanças do Clima (FAR-IPCC) em 1990. Em torno de 1996, os modelos evoluíram para incluir representações mais complexas do oceano como as correntes oceânicas, e houve um foco adicional na interação entre a erupção do Pinatubo em 1991 e os aerossóis de sulfato, devido ao interesse crescente nos efeitos da chuva ácida e na relação da erupção com o sistema climático.

No início dos anos 2000, especificamente em 2001, os modelos climáticos deram um salto significativo em precisão. Parametrizações microfísicas avançadas foram introduzidas, permitindo simulações mais acuradas de precipitação, usando concentrações de aerossóis para determinar taxas de precipitação. Além disso, foi implementado um ciclo hidrológico

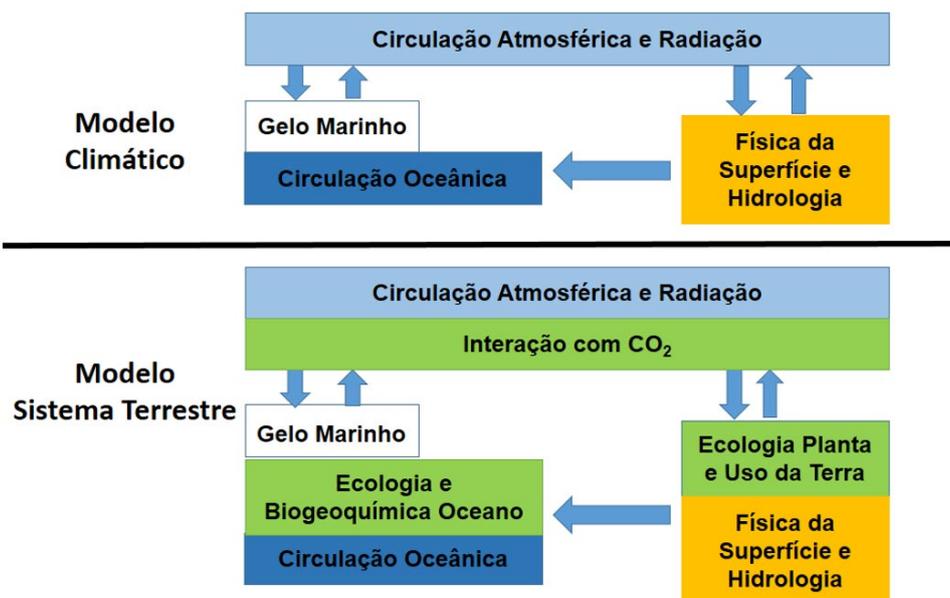
mais detalhado integrando precipitação, umidade do solo e escoamento superficial de forma mais coerente.

Desde o início da década de 1990, melhorias significativas foram alcançadas através da incorporação de outros componentes do sistema terrestre aos modelos climáticos (figura 1). Os modelos climáticos tornaram-se mais completos e complexos dando origem aos conhecidos Modelos de Sistema Terrestre (ESMs). Um Modelo ESM é um modelo climático acoplado que também simula explicitamente o movimento do carbono através do sistema terrestre. A figura 2 mostra de forma simplificada as diferenças entre um modelo de clima e um ESM. A presença das componentes nas caixas verdes (bioquímicas e biogeoquímicas) tornam um modelos climático em um ESM.

O ciclo do carbono, as formulações dinâmicas dos tipos de vegetação, a química da atmosfera e os mantos de gelo, pertencem as componentes que estão atualmente implementados em modelos de circulação geral existentes hoje. Em consequência disso, a modelagem climática e de sistema terrestre se tornou uma ciência interdisciplinar.

Além de modelos cada vez mais detalhados, também foram desenvolvidos modelos climáticos simplificados. Eles permitem o estudo de problemas básicos das ciências climáticas de uma forma eficiente. O desenvolvimento e aplicação de modelos climáticos de complexidade reduzida (frequentemente chamados de EMICs, Modelos de Sistema Terrestre de Complexidade Intermediária) fizeram contribuições importantes para a compreensão do sistema climático, em particular na interpretação quantitativa de reconstruções paleoclimáticas e simulações conjuntas de mudanças climáticas futuras. Os rótulos FAR, SAR, TAR, AR5 e AR6 na figura 1 indicam os modelos em uso na época de cada um dos seis Relatórios de Avaliação do IPCC.

Figura 2 - Estrutura de um Modelo Climático Acoplado e de um Modelo de Sistema Terrestre.



Adaptado de SOCCOM (2023)

CONSIDERAÇÕES FINAIS

Os modelos de tempo e clima são ferramentas poderosas que nos ajudam a melhor compreender e prever o tempo e o clima em uma ampla gama de escalas temporais e espaciais. Os modelos de tempo são amplamente utilizados para alertar sobre eventos extremos como por exemplo tempestades, tornados, ondas de calor, auxiliando nas tomadas de decisões. Os Modelos Climáticos e de Sistema Terrestre são utilizados para estudar as causas e efeitos das mudanças climáticas auxiliando no desenvolvimento de estratégias de adaptação às mudanças climáticas, identificação de áreas vulneráveis e fornecendo projeções a longo prazo que auxiliam no desenvolvimento de medidas associadas à redução de riscos. Embora tenha havido grandes avanços na modelagem de tempo e clima ao longo dos últimos 40 anos de história da modelagem, mesmo os modelos mais sofisticados permanecem muito mais simples do que as complexidades inerentes ao sistema climático completo.

Apesar dos avanços na modelagem de tempo, clima e do sistema terrestre nas últimas décadas, ainda existem desafios significativos a serem superados. Entre os principais desafios destacam-se: (i) desafios associados à necessidade de melhor representar as complexidades dos processos climáticos nos modelos numéricos e parametrizações físicas, (ii) necessidade de ampliação das redes observacionais e (iii) melhorias na resolução espacial e temporal dos modelos.

Outro desafio importante é a necessidade de integrar diferentes fontes de dados e modelos para obter previsões mais precisas e confiáveis. Isso requer a colaboração entre diferentes expertises como a meteorologia, oceanografia, biologia, química, ciência da computação e estatística, e a adoção de abordagens interdisciplinares para a modelagem de tempo e clima. Além disso, a modelagem de tempo e clima deve ser capaz de lidar com a incerteza e a variabilidade natural do clima, bem como com as mudanças climáticas antropogênicas.

Para superar esses desafios, é necessário continuar investindo em pesquisa e desenvolvimento de novas técnicas e modelos de modelagem de tempo e clima. Isso inclui o desenvolvimento de modelos mais sofisticados e precisos, a melhoria da resolução espacial e temporal dos modelos, a ampliação das redes de observação e a integração de diferentes fontes de dados e modelos. Além disso, é importante investir em educação e conscientização pública sobre a importância da modelagem de tempo e clima para a tomada de decisões informadas em diferentes setores, como agricultura, energia, transporte e gestão de riscos de desastres naturais.

REFERÊNCIAS

BRYAN, K.; COX, M. D. A numerical investigation of the oceanic general circulation. **Tellus**, v. 19, n. 1, p. 54-80, 1967.

LORENZ, E. N. Deterministic nonperiodic flow. **Journal of Atmospheric Sciences**, v. 20, n. 2, p. 130-141, 1963.

LYNCH, P. The origins of computer weather prediction and climate modeling. **Journal of**

Computational Physics, v. 227, n. 7, p. 3431-3444, 2018.

LYNCH, P. **The emergence of numerical weather prediction: Richardson's dream**. Cambridge University Press, 2006.

MANABE, S.; BRYAN, K. Climate calculations with a combined ocean-atmosphere model. **Journal of Atmospheric Sciences**, v. 26, n. 4, p. 786-789, 1969.

MCGUFFIE, K.; HENDERSON-SELLERS, A. Forty years of numerical climate modeling. **International Journal of Climatology: A Journal of the Royal Meteorological Society**, v. 21, n. 9, p. 1067-1109, 2001.

NAVARRO, A., MERINO, A. (2022). **Precipitation in Earth system models: advances and limitations**. In *Precipitation Science* (pp. 637-659). Elsevier.

PHILLIPS, Norman A. The general circulation of the atmosphere: A numerical experiment. **Quarterly Journal of the Royal Meteorological Society**, v. 82, n. 352, p. 123–164, 1956.

PLATZMAN, G. W. The ENIAC computations of 1950—Gateway to numerical weather prediction. **Bulletin of the American Meteorological Society**, v. 60, n. 4, p. 302-312, 1979.

RICHARDSON, L. F. **Weather prediction by numerical process**. Cambridge University Press, 1922.

ROSSBY, C. G. Relation between variations in the intensity of the zonal circulation of the atmosphere and the displacements of the semi-permanent centers of action. **Journal of Marine Research**, v. 2, n. 1, p. 38–55, 1939.

SHUMAN, F. G. History of numerical weather prediction at the National Meteorological Center. **Weather and Forecasting**, v. 4, n. 3, p. 286-296, 1989.

STOCKER, T. **Introduction to climate modeling**. Springer Science & Business Media, 2011.

SOCOM. What Earth System Model (ESM). Disponível em: <<https://socom.princeton.edu/modeling/what-earth-system-model-esm>>. Acesso em: [13 out. 2023].

Modelagem do tempo e clima utilizando modelos atmosféricos e oceânicos regionais: Parte I - avanços e desafios

Luís Felipe Ferreira de Mendonça
Rose Ane Pereira de Freitas
Rafael Afonso do Nascimento Reis
Fernanda Casagrande
Helena Barbieri de Azevedo
Ricardo Acosta Gotuzzo
André Lanfer Marquez
Carlos Alexandre Domingos Lentini
Rita de Cássia Marques Alves

RESUMO

Os modelos numéricos regionais são ferramentas essenciais para estudar e prever mudanças climáticas em escalas menores, como regiões específicas. Eles possuem resoluções mais elevadas em comparação com os modelos climáticos globais, o que permite considerar informações detalhadas sobre topografia, cobertura do solo e tipos de solo, influenciando o sistema climático local. Neste capítulo abordam-se os principais aspectos sobre a modelagem regional atmosférica e oceânica, vantagens, avanços e desafios e aplicações científicas e por fim discutimos os desenvolvimentos futuros dos modelos regionais atmosféricos e oceânicos.

INTRODUÇÃO

O que são modelos regionais de clima e tempo? Bem, você conhece aquelas previsões do tempo que ouve dos meteorologistas? Eles não as criam magicamente do nada. Na verdade, eles usam dados meteorológicos e modelos de previsão para analisar as condições atmosféricas atuais e futuras. É como se eles tivessem uma bola de cristal, mas em vez de magia, confiam na ciência. Os modelos numéricos são simulações matemáticas que utilizam equações para prever e analisar fenômenos físicos. Eles são amplamente utilizados em ciência, engenharia e muitos outros campos para entender e prever sistemas complexos (Vogel e O'Brien).

Os modelos regionais são um tipo de modelo numérico que se concentram em uma região específica de interesse, como uma área costeira, uma bacia hidrográfica ou uma cadeia de montanhas, etc. Agora, você pode perguntar, por que precisamos de modelos regionais se já temos



modelos climáticos globais? Bem, os modelos regionais fornecem dados de alta resolução e podem levar em conta variações locais na topografia, correntes oceânicas ou condições atmosféricas (Hagemann e Gates, 2003). Eles também permitem que os cientistas estudem fenômenos específicos, como furacões, ondas de calor ou florações de algas prejudiciais, com mais precisão e detalhes.

A história dos modelos numéricos regionais oceânicos e atmosféricos remonta à década de 1970, quando as primeiras equações primitivas foram desenvolvidas para simular as correntes oceânicas (Edwards, 2011). Desde então, muitos modelos foram desenvolvidos e aprimorados, utilizando métodos matemáticos avançados, computação de alto desempenho e dados observacionais. A evolução desses modelos percorreu um longo caminho, desde os primeiros métodos de previsão do tempo até o desenvolvimento de modelos de previsão global e a evolução para modelos regionais (Dudhia, 2014).

Atualmente, diferentes modelos usam diferentes métodos de solução, como métodos de diferenças finitas para todas as três dimensões espaciais na maioria dos modelos globais, métodos espectrais para as dimensões horizontais em alguns modelos globais e modelos regionais e métodos de diferenças finitas na vertical. Surpreendentemente, grande parte dos dados usados para inicializar e orientar as previsões meteorológicas vem de fora da região de interesse.

Estes dados permitem aos modelos regionais entender e prever sistemas naturais com uma precisão e detalhes sem precedentes. No entanto, eles também apresentam muitos desafios e oportunidades, como melhorar a assimilação de dados, lidar com incertezas e explorar novas aplicações. Então, da próxima vez que você olhar para o oceano ou para o céu, lembre-se de que existe todo um mundo de modelos numéricos trabalhando nos bastidores para desvendar seus mistérios.

VANTAGENS DE MODELOS REGIONAIS ATMOSFÉRICOS E OCEÂNICOS

Pois bem, quem necessita de previsões meteorológicas precisas, afinal? Quer dizer, quem se importa se o meteorologista errar de vez em quando? Não é como se as pessoas planejassem seus piqueniques, casamentos, passeios de barco ou eventos ao ar livre com base nessas previsões, certo? Ah espera, na verdade fazem! É por isso que os modelos regionais atmosféricos e oceânicos são tão importantes no mundo da previsão do tempo. Esses modelos trazem uma grande atualização para a precisão da previsão do tempo. Foram-se os dias de previsões vagas como “parcialmente nublado com chance de chuva”.

Com modelos regionais, cientistas podem entrar em detalhes minuciosos e fornecer previsões mais precisas para áreas específicas. Esses modelos também permitem uma análise detalhada dos padrões climáticos locais. Não estamos falando da temperatura média de um país inteiro, mas das variações de temperatura e clima dentro de regiões menores. Isso é especialmente útil para usuários como agricultores, que podem tomar decisões melhores sobre escolhas de culturas e irrigação com base nas condições climáticas específicas de sua área. Sem esquecer do impacto das mudanças climáticas, uma vez que modelos regionais podem identificar regiões específicas mais vulneráveis aos efeitos do

aumento do nível do mar, eventos extremos de calor ou aumento da precipitação.

Essas informações são cruciais para formuladores de políticas e planejadores para desenvolver estratégias e medidas para mitigar os riscos e se adaptar ao clima em mudança. Então, veja, modelos regionais atmosféricos e oceânicos não são apenas ferramentas extravagantes para estudos do clima. Eles desempenham um papel crucial na melhoria da precisão da previsão do tempo, na compreensão dos padrões climáticos locais e na identificação do impacto das mudanças climáticas em regiões específicas. E isso, meus amigos, é por quê deveríamos ser gratos por esses modelos - mesmo que isso signifique que não podemos culpá-los mais por arruinar nossos planos do final de semana.

Simplificando, os modelos numéricos utilizam equações matemáticas para simular fenômenos naturais, como correntes oceânicas e atmosféricas. Esses modelos ajudam os cientistas a entender as complexas interações entre diferentes variáveis e prever resultados futuros. Modelos regionais, como o próprio nome sugere, focam em regiões geográficas específicas, permitindo que os pesquisadores estudem padrões e fenômenos locais com mais detalhes.

MODELOS REGIONAIS ACOPLADOS OCEANO-ATMOSFERA

Como o nome sugere, os modelos acoplados oceano-atmosfera simulam interações entre o oceano e a atmosfera para entender como a mudança climática pode afetar ambos (Neelin *et al.*, 1994). Os modelos incluem a atmosfera e o oceano como componentes separados que interagem por meio de processos como evaporação, troca de calor e correntes oceânicas (Woollings *et al.*, 2012). Eles são usados para estudar todo o sistema terrestre, inclusive o aquecimento global, a variabilidade climática e o ciclo do carbono. Nos primórdios da modelagem climática, a atmosfera era o único componente que estava sendo estudado, e a maioria dos modelos climáticos eram modelos somente de atmosfera.

O primeiro modelo climático acoplado oceano-atmosfera foi desenvolvido na década de 1980, quando os cientistas tentaram usar o oceano como uma forma de entender como o clima poderia mudar em períodos mais longos (Hulme, 2001). A primeira geração de modelos acoplados era rudimentar e limitada em sua utilidade para estudos de climatologia. O acoplamento entre a atmosfera e o oceano era fraco, e muitos processos físicos no sistema real de atmosfera-oceano não eram bem representados no modelo (Reicher e Kim, 2008). Na década de 1990, as melhorias no poder de processamento dos computadores permitiram o desenvolvimento de modelos mais complexos, possibilitando o detalhamento de determinados processos físicos, como a troca de calor entre a atmosfera e o oceano, bem como os efeitos das correntes oceânicas e da mistura. O modelo HadCM3 do Hadley Centre for Climate Prediction and Research tornou-se o primeiro modelo acoplado atmosférico-oceânico de alta resolução, o que representou um marco importante na modelagem regional acoplada (Wang *et al.*, 2009). Atualmente, a maioria dos modelos regionais e globais em uso tem acoplamento oceano-atmosfera e até mesmo ondas, incluindo os conhecidos modelos do IPCC.

O uso deste tipo de modelo levou a avanços importantes nos estudos de mudança climática, processos costeiros, transferência energética e de gases entre os sistemas

ecológicos (Foley *et al.*, 2000). Esses modelos mostraram que a troca de calor entre o oceano e a atmosfera tem um efeito significativo sobre o clima em diferentes escalas. Por exemplo, a ressurgência impulsionada pelo vento e as correntes oceânicas podem trazer água mais fria para a superfície, o que afeta a quantidade de CO₂ que é absorvida pelo oceano. Da mesma forma, os modelos ajudam a solucionar algumas das inconsistências entre os modelos somente da atmosfera e do oceano, e se mostraram importantes para a interpretação de registros climáticos obtidos de núcleos de sedimentos do fundo do mar (Schneider *et al.*, 2010).

O uso de modelos regionais acoplados oceano-atmosfera permite previsões locais mais precisas para diferentes variáveis, o que pode ajudar no desenvolvimento de estratégias de adaptação. Esses modelos acoplados facilitam uma melhor compreensão do orçamento global de carbono, dos impactos do aquecimento global nos padrões de circulação oceânica e da frequência e intensidade de eventos climáticos extremos (Ridgwell e Hargreaves, 2007). Esses impactos são significativos em domínios científicos e não científicos, pois aprimoraram significativamente nossa capacidade de prever mudanças de longo prazo, o que é fundamental para a adoção de medidas para estratégias de mitigação e adaptação.

APLICAÇÕES CIENTÍFICAS DE MODELOS REGIONAIS ATMOSFÉRICOS E OCEÂNICOS

As aplicações científicas dos modelos atmosféricos e oceânicos regionais são vastas e revolucionaram nossa compreensão da variabilidade climática e dos impactos de eventos climáticos extremos em uma escala muito mais detalhada. Esses modelos fornecem *insights* valiosos sobre a dinâmica complexa dos sistemas climáticos regionais, permitindo que os cientistas façam previsões e avaliações mais precisas (Flato *et al.*, 2014). Uma das principais aplicações científicas desses modelos é a compreensão da variabilidade climática regional.

Ao simular as interações entre a atmosfera, os oceanos e a terra, esses modelos podem identificar padrões e tendências de temperatura, precipitação e outras variáveis climáticas específicas de uma determinada região. Essas informações são cruciais para o desenvolvimento de estratégias eficazes de mitigação e adaptação para lidar com as mudanças climáticas em nível local (Mendonça *et al.*, 2023). Além disso, os modelos regionais desempenham um papel vital na avaliação dos impactos de eventos climáticos extremos, ao simular furacões, secas, ondas de calor e outros eventos extremos, os cientistas podem avaliar sua intensidade, duração e distribuição espacial (Yates *et al.*, 2014).

Adicionalmente, os modelos regionais são instrumentais na previsão de mudanças nos ecossistemas, uma vez que, eles podem incorporar informações detalhadas sobre cobertura vegetal, vegetação e distribuição de espécies, podendo projetar como as variações climáticas afetam os habitats, a biodiversidade e os processos ecológicos. Essas informações auxiliam no planejamento de estratégias de conservação e gestão que promovem a resiliência dos ecossistemas e garantem a sobrevivência de espécies vulneráveis. Com essas aplicações, os modelos atmosféricos e oceânicos regionais são

ferramentas inestimáveis na pesquisa climática. Ao fornecerem informações detalhadas sobre a dinâmica climática regional, impactos de eventos climáticos extremos e mudanças nos ecossistemas (Hannah *et al.*, 2002), esses modelos contribuem para nossa compreensão do complexo sistema climático da Terra e nos ajudam a nos preparar para desafios futuros.

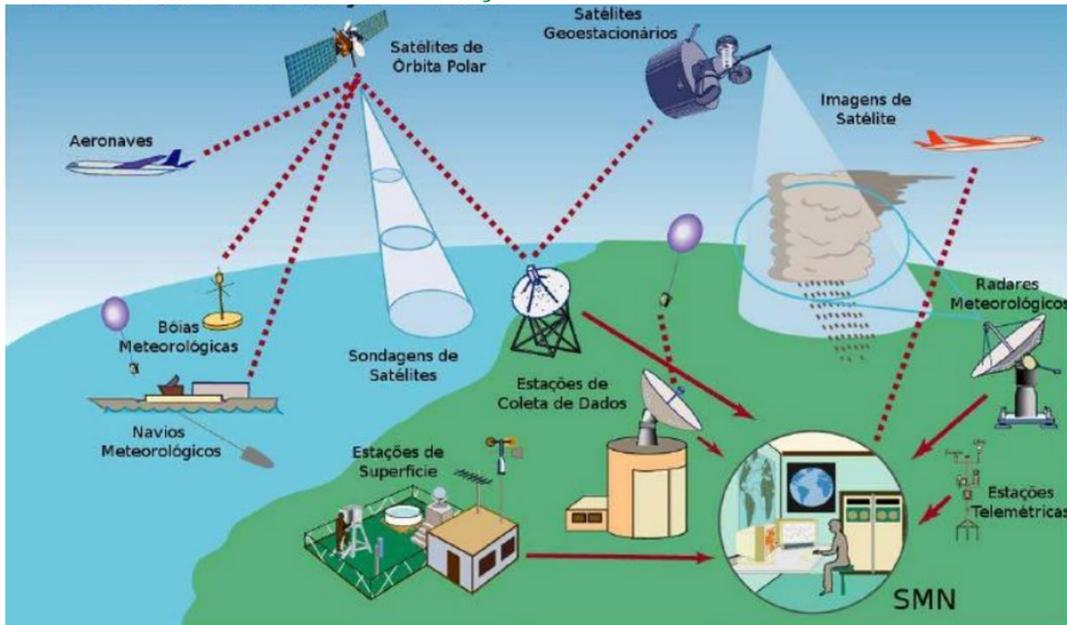
DESAFIOS NA MODELAGEM DO TEMPO E CLIMA

Nenhum sistema numérico de modelagem é considerado perfeito, logo, eles apresentam um constante número de desafios a serem vencidos. Por mais que os modelos atmosféricos e oceânicos regionais tenham suas vantagens, eles também vêm com seus próprios desafios. Vamos analisar alguns desses obstáculos? Primeiramente, temos a complexidade dos sistemas da Terra. A Terra é um sistema enorme e intrincado, com inúmeras variáveis em jogo. Desde a mistura atmosférica até as correntes oceânicas, há tantos fatores que influenciam o tempo e o clima. Tentar capturar toda essa complexidade em um modelo pode ser uma verdadeira dor de cabeça. Em seguida, temos as limitações computacionais. Sabe como é, “mais modelos, mais problemas!” Criar e rodar esses modelos requer um poder de processamento sério. A quantidade de dados e cálculos envolvidos pode fazer sua cabeça girar mais rápido do que um furacão. E não dê nem ideia de começar a falar sobre o tempo que leva para rodar simulações. Pode parecer que você está esperando um caracol terminar uma maratona!

Conforme mostrado na figura 1, o sistema de observação global é complexo, e não podemos esquecer da coleta e precisão dos dados. Coletar dados precisos e abrangentes é crucial para construir modelos confiáveis. Mas às vezes, encontrar os dados certos pode ser tão desafiador quanto encontrar o Wally em uma multidão! Além disso, há sempre a possibilidade de erros ou lacunas nos dados, o que leva a previsões menos precisas. É como tentar prever o tempo com um barômetro quebrado. Mas, apesar desses desafios, os cientistas estão constantemente empurrando os limites da modelagem do clima e do tempo. Eles estão trabalhando em melhorar a resolução espacial e temporal, integrando mais componentes do sistema terrestre e aprimorando as técnicas de assimilação de dados. É tudo sobre ficar um passo à frente da mãe natureza, certo? Portanto, embora a modelagem regional do clima e do tempo possa ter seus próprios desafios, o potencial para avanços na previsão do tempo e na projeção do clima é tão vasto quanto o céu aberto. Afinal, quem não gosta de um bom desafio? Como diz o ditado, “mar calmo nunca fez bom marinheiro!”

O uso de modelos numéricos para a previsão do tempo começou em meados do século XX, com o advento dos computadores eletrônicos (Mesinger *et al.*, 2018). Antes disso, a previsão do tempo dependia de métodos puramente observacionais, como a observação visual e o registro manual de dados meteorológicos. Entretanto, esses métodos se mostraram pouco confiáveis e demorados, especialmente para previsões de longo alcance. O desenvolvimento das técnicas de previsão numérica do tempo permitiu que os meteorologistas inserissem as condições atmosféricas atuais em um programa de computador, que poderia então usar equações matemáticas para prever os padrões climáticos futuros (Lynch, 2008).

Figura 1 - Sistema de Observação Global a partir de diferentes formas de coletas de informações ambientais.



Fonte: Adaptado de (World Meteorological Organization, 2003)

A precisão dessas previsões dependia muito da quantidade e da qualidade dos dados de entrada. O primeiro modelo meteorológico numérico bem-sucedido foi desenvolvido no final da década de 1940 por Jule Charney e seus colegas (Harper *et al.*, 2007). Esse modelo foi capaz de prever o movimento de um sistema de alta pressão no Hemisfério Norte usando as equações fundamentais da dinâmica de fluidos. Apesar de seu sucesso, a previsão do tempo enfrentou vários desafios nos primeiros anos, incluindo a limitação da capacidade dos computadores e a imprecisão dos dados de entrada (Weyn *et al.*, 2020). À medida que os computadores se tornaram mais potentes na década de 1960, modelos mais sofisticados foram desenvolvidos, usando dados de entrada mais detalhados e um número maior de equações para modelar a atmosfera.

O primeiro modelo de previsão global (GFM – Sigla em inglês para Global Forecast Model) foi desenvolvido em 1955 por Norman Phillips. Esse modelo dividiu a atmosfera da Terra em uma grade tridimensional, com variáveis como temperatura, pressão e umidade calculadas em cada ponto da grade (Bandara *et al.*, 2021). Ele usava métodos numéricos para prever padrões climáticos com até sete dias de antecedência. Os modelos GFM tornaram-se mais precisos e complexos com o passar do tempo, com o desenvolvimento de equações mais avançadas e a inclusão de novas variáveis no modelo.

Atualmente, os modelos são capazes de prever padrões climáticos em escala global e regional com alta precisão com até duas semanas de antecedência. Em contraste com os modelos, os modelos regionais (também conhecidos como modelos de área limitada, ou LAM's sigla em inglês para Limited Area Model) são projetados para prever padrões climáticos em uma área geográfica específica (Colin *et al.*, 2010). Os modelos regionais usam um tamanho de grade menor que os modelos globais, o que lhes permite capturar fenômenos mais localizados e fazer previsões mais precisas para regiões específicas (Mendonça *et al.*, 2017).

Uma grande limitação dos modelos regionais é que eles dependem diretamente dos

modelos globais para fornecer condições de limite na borda de seu domínio. Isso permite que o modelo leve em conta o efeito dos padrões climáticos de fora da região sobre o clima dentro da região. Apesar de sua maior precisão, os modelos regionais enfrentam vários desafios, incluindo imprecisões nos dados de limite fornecidos pelos modelos globais e erros no próprio modelo regional (Ray *et al.*, 2010). De modo geral, a evolução da previsão numérica do tempo permitiu que os meteorologistas fizessem previsões mais precisas e detalhadas dos padrões climáticos. E o desenvolvimento de modelos regionais permitiu previsões mais direcionadas, enquanto os avanços na capacidade dos computadores e a inclusão de novas variáveis nos modelos permitiram previsões de longo alcance com maior precisão

MODELOS USADOS NA PREVISÃO

Os modelos numéricos de previsão são usados para determinar as condições atmosféricas futuras de uma determinada região (figura 2), fornecendo informações que vão desde a temperatura e a velocidade do vento até a precipitação e a cobertura de nuvens (Olaiya e Adeyemo, 2012). Esses modelos percorreram um longo caminho desde seu surgimento no início do século XX e agora são ferramentas essenciais no campo da meteorologia. As interações entre os pontos vizinhos são avaliadas para fornecer uma saída para as condições atmosféricas futuras, no qual a evolução dos campos escalares de densidade, pressão e temperatura potencial, juntamente com o campo vetorial de velocidade de fluxo ao longo do tempo, é prevista por meio de um conjunto de equações conhecidas como equações primitivas (Boukharfane *et al.*, 2018).

Alguns modelos incluem até mesmo equações de transporte adicionais para poluentes, sedimentos e aerossóis. Os modelos de previsão são executados em vários centros em todo o mundo e são usados para produzir previsões meteorológicas que são amplamente consumidas pelo público. A *National Oceanic and Atmospheric Administration* (NOAA) desempenha uma função importante na previsão global por meio do *Global Forecast System* (GFS), que fornece previsões atualizadas a cada seis horas, enquanto o Centro Europeu de Previsões Meteorológicas de Médio Prazo (ECMWF) também executa um modelo de previsão global que é considerado um dos modelos mais precisos do mundo (Miles, 2014; Harrison, 2022).

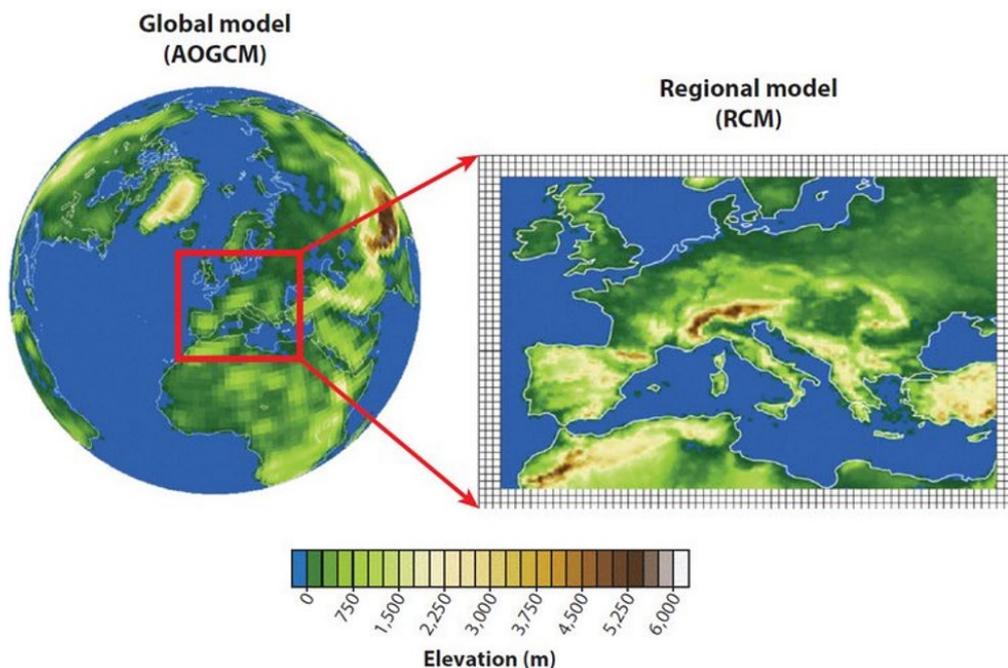
No entanto, apesar de sua precisão, os modelos globais têm uma resolução limitada, o que muitas vezes dificulta a previsão de fenômenos meteorológicos de menor escala. Aí entra a funcionalidade dos modelos regionais, que permitem a previsão por meio de um espaçamento de grade mais refinado, detalhando uma área específica de estudo. Essa resolução mais fina ajuda a resolver explicitamente fenômenos meteorológicos e oceanográficos de pequena escala, como tempestades e *storm surges* que não podem ser representadas em uma grade mais grossa de um modelo global.

Os modelos regionais são computacionalmente menos dispendiosos do que os modelos globais, pois ensinam a simular uma região comparativamente pequena, exigindo menos recursos computacionais (Giorgi e Mearns, 1999). Logo, rodar operacionalmente modelos regionais permite que centros de pesquisa menores, consigam criar grades de

simulação com uma previsão e assimilação local de alta qualidade. Os modelos regionais se tornaram uma ferramenta importante na previsão do tempo devido à sua alta precisão em regiões com terreno complexo e regiões costeiras. Esses modelos aproveitam muitas das novas tecnologias de modelagem, como computação paralela, escalonamento de tempo e análise de dados complicada.

Embora os modelos regionais de previsão sejam incrivelmente úteis e ofereçam maior precisão e resolução em determinadas áreas, eles têm algumas limitações: geralmente têm problemas com o início da convecção devido a pequenos distúrbios ou elevações variáveis que podem afetar significativamente o início do processo convectivo (Dickinson *et al.*, 1989). Em modelos meteorológicos regionais as previsões de chuvas localizadas e tempestades são difíceis de serem previstas com exatidão. A previsão precisa do início da convecção é essencial para alertar as populações sobre chuvas potencialmente danosas e inundações em áreas onde a convecção é um fenômeno recorrente (Golding, 2000). No entanto, estes modelos exigem a assimilação de medições precisas de vários dados atmosféricos com relação ao tempo e ao espaço, o que às vezes pode ser difícil de obter. A ausência destes dados costuma afetar a precisão das previsões do modelo (Bannister *et al.*, 2020).

Figura 2 - Figura representativa da grade de um Modelo Climático Regional comparada a um Modelo Climático Global.



Fonte: Giorgi e Gutowski, 2015

CONSIDERAÇÕES FINAIS

Vimos que os modelos regionais atmosféricos e oceânicos são ferramentas essenciais que os cientistas utilizam para prever e entender as diferentes condições ambientais dinâmicas do nosso planeta. Eles fornecem informações valiosas sobre padrões climáticos, mudanças climáticas e seus impactos em várias regiões. Neste capítulo, exploramos as vantagens dos modelos atmosféricos e oceânicos regionais e suas aplicações científicas em estudos globais de tempo e clima.

Os modelos atmosféricos e oceânicos regionais oferecem várias vantagens que contribuem para previsões mais precisas e *insights* mais profundos sobre os padrões climáticos, regionais e locais. Porém, ainda existem muitos desafios na modelagem regional, uma vez que a complexidade dos sistemas da Terra, incluindo as interações entre a atmosfera, oceanos, terra, ondas e gelo, são um obstáculo significativo. Incorporar todos esses componentes completamente nos modelos requer uma capacidade computacional e recursos de dados substanciais. Limitações computacionais são outro desafio na modelagem, uma vez que os modelos de alta resolução necessários para previsões detalhadas requerem grandes quantidades de tempo e recursos computacionais. Além disso, a coleta e a precisão dos dados apresentam desafios, pois reunir dados extensos e precisos de regiões remotas ou inacessíveis pode ser difícil.

O futuro reserva desenvolvimentos empolgantes em modelos atmosféricos e oceânicos regionais e melhorias na resolução espacial e temporal permitirão previsões mais detalhadas e precisas. O surgimento de modelos de maior resolução aprimorará nossa compreensão dos padrões climáticos locais, eventos extremos e impactos das mudanças climáticas. E a integração de outras componentes do sistema terrestre nos modelos regionais, como processos biogeoquímicos e interações entre a criosfera e a atmosfera, fornecerá uma compreensão mais abrangente do sistema climático da Terra. Ao considerar essas conexões intrincadas, os cientistas podem melhorar a precisão das previsões climáticas e avaliar os ciclos de retroalimentação que impulsionam as mudanças climáticas. Técnicas avançadas de assimilação de dados também contribuirão para os avanços nos modelos regionais.

A incorporação de dados observacionais em tempo real nos modelos melhorará sua precisão e permitirá uma adaptação mais rápida às condições climáticas em constante mudança. Em conclusão, os modelos atmosféricos e oceânicos regionais são ferramentas poderosas que oferecem inúmeras vantagens e aplicações científicas nos estudos de tempo e clima. Conforme a tecnologia avança e as capacidades computacionais aumentam, esses modelos continuarão a evoluir, fornecendo previsões mais precisas e *insights* sobre nosso clima em mudança. Ao utilizar modelos regionais, podemos entender melhor e mitigar os impactos de eventos climáticos e mudanças climáticas em regiões específicas, levando a uma tomada de decisão mais informada e um futuro mais resiliente.

REFERÊNCIAS

- BANDARA, K., HEWAMALAGE, H., LIU, Y. H., KANG, Y., BERGMEIR, C. (2021). Improving the accuracy of global forecasting models using time series data augmentation. **Pattern Recognition**, 120, 108148.
- BANNISTER, R. N., CHIPILSKI, H. G., MARTINEZ-ALVARADO, O. (2020). Techniques and challenges in the assimilation of atmospheric water observations for numerical weather prediction towards convective scales. **Quarterly Journal of the Royal Meteorological Society**, 146(726), 1-48.
- BOUKHARFANE, R., RIBEIRO, F. H. E., BOUALI, Z., MURA, A. (2018). A combined ghost-point-forcing/direct-forcing immersed boundary method (IBM) for compressible flow simulations. **Computers and fluids**, 162, 91-112.

- COLIN, J., DÉQUÉ, M., RADU, R., SOMOT, S. (2010). Sensitivity study of heavy precipitation in Limited Area Model climate simulations: influence of the size of the domain and the use of the spectral nudging technique. **Tellus A: Dynamic Meteorology and Oceanography**, 62(5), 591-604.
- DICKINSON, R. E., ERRICO, R. M., GIORGI, F., BATES, G. T. (1989). A regional climate model for the western United States. **Climatic change**, 15, 383-422.
- DUDHIA, J. (2014). A history of mesoscale model development. **Asia-Pacific Journal of Atmospheric Sciences**, 50, 121-131.
- EDWARDS, P. N. (2011). History of climate modeling. **Wiley Interdisciplinary Reviews: Climate Change**, 2(1), 128-139.
- FLATO, G., MAROTZKE, J., ABIODUN, B., BRACONNOT, P., CHOU, S. C., COLLINS, W., RUMMUKAINEN, M. (2014). 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* (pp. 741-866). Cambridge University Press.
- FOLEY, J. A., LEVIS, S., COSTA, M. H., CRAMER, W., POLLARD, D. (2000). Incorporating dynamic vegetation cover within global climate models. **Ecological Applications**, 10(6), 1620-1632.
- GIORGI, F., MEARNNS, L. O. (1999). Introduction to special section: Regional climate modeling revisited. **Journal of Geophysical Research: Atmospheres**, 104(D6), 6335-6352.
- GOLDING, B. W. (2000). Quantitative precipitation forecasting in the UK. **Journal of hydrology**, 239(1-4), 286-305.
- HAGEMANN, S., GATES, L. D. (2003). Improving a subgrid runoff parameterization scheme for climate models by the use of high resolution data derived from satellite observations. **Climate Dynamics**, 21, 349-359.
- HANNAH, L., MIDGLEY, G. F., MILLAR, D. (2002). Climate change-integrated conservation strategies. **Global Ecology and Biogeography**, 11(6), 485-495.
- HARPER, K., UCCELLINI, L. W., KALNAY, E., CAREY, K., MORONE, L. (2007). 50th anniversary of operational numerical weather prediction. **Bulletin of the American Meteorological Society**, 88(5), 639-650.
- HULME, M. (2001). Climatic perspectives on Sahelian desiccation: 1973–1998. **Global Environmental Change**, 11(1), 19-29.
- LYNCH, P. The origins of computer weather prediction and climate modeling. **Journal of computational physics**, 227(7), 3431-3444, 2008.
- MENDONÇA, L. F. F.; FETTER-FILHO, A. F. H.; ANDRADE, M. M.; DE OLIVEIRA, F. S. C.; LINDEMANN, D. S.; FREITAS, R. A. P.; REIS, R. A. N.; LENTINI, C. A. D.; PARISE, C. K.; SANTOS, D. C. Analysis of a coastal-trapped wave generated by the 2016 extra-tropical cyclonic system in the Southern Brazilian continental shelf with COAWST modeling system. *Journal of South American Earth Sciences*, v. 129, p. 104522-19, 2023.
- MENDONÇA, L. F.; SOUZA, R. B.; ASEFF, C. R. C.; PEZZI, L. P.; MÖLLER, O. O.; AALVES, R. C. M. Regional modeling of the water masses and circulation annual variability at the Southern Brazilian Continental Shelf. **JOURNAL OF GEOPHYSICAL RESEARCH-OCEANS**, v. 122, p. 1232-1253, 2017.
- MESINGER, F.; RANČIĆ, M.; PURSER, R. J. Numerical methods in atmospheric models. **Oxford Research Encyclopedia of Climate Science**, 2018.

- MILES, K. **Superstorm**: nine days inside hurricane sandy. Penguin, 2014.
- NEELIN, J. D.; LATIF, M.; JIN, F. F. Dynamics of coupled ocean-atmosphere models: The tropical problem. *Annual review of fluid mechanics*, 26(1), 617-659, 1994.
- OLAIYA, F.; ADEYEMO, A. B. Application of data mining techniques in weather prediction and climate change studies. **International Journal of Information Engineering and Electronic Business**, 4(1), 51, 2012.
- RAY, R. D., EGBERT, G. D., EROFEEVA, S. Y. (2010). Tide predictions in shelf and coastal waters: Status and prospects. **Coastal altimetry**, 191-216.
- REICHLER, T., KIM, J. (2008). How well do coupled models simulate today's climate?. *Bulletin of the American Meteorological Society*, 89(3), 303-312.
- RIDGWELL, A., HARGREAVES, J. C. (2007). Regulation of atmospheric CO₂ by deep-sea sediments in an Earth system model. **Global Biogeochemical Cycles**, 21(2).
- SCHNEIDER, B., LEDUC, G., PARK, W. (2010). Disentangling seasonal signals in Holocene climate trends by satellite-model-proxy integration. **Paleoceanography**, 25(4).
- VOGEL, C., O'BRIEN, K. (2006). Who can eat information? Examining the effectiveness of seasonal climate forecasts and regional climate-risk management strategies. **Climate Research**, 33(1), 111-122.
- WANG, B., ZHOU, T., YU, Y., WANG, B. (2009). A view of earth system model development. **Acta Meteorologica Sinica**, 23(1), 1-17.
- WEYN, J. A., DURRAN, D. R., CARUANA, R. (2020). Improving data-driven global weather prediction using deep convolutional neural networks on a cubed sphere. **Journal of Advances in Modeling Earth Systems**, 12(9), e2020MS002109.
- WOOLLINGS, T., GREGORY, J. M., PINTO, J. G., REYERS, M., BRAYSHAW, D. J. (2012). Response of the North Atlantic storm track to climate change shaped by ocean-atmosphere coupling. **Nature Geoscience**, 5(5), 313-317.
- YATES, D., LUNA, B. Q., RASMUSSEN, R., BRATCHER, D., GARRE, L., CHEN, F., ... FRIIS-HANSEN, P. (2014). Stormy weather: Assessing climate change hazards to electric power infrastructure: A Sandy case study. **IEEE Power and Energy Magazine**, 12(5), 66-75.

Modelagem do tempo e clima utilizando modelos atmosféricos e oceânicos regionais: Parte II - equações

Luís Felipe Ferreira de Mendonça
Rose Ane Pereira de Freitas
Rafael Afonso do Nascimento Reis
Fernanda Casagrande
Helena Barbieri de Azevedo
Ricardo Acosta Gotuzzo
Carlos Alexandre Domingos Lentini
André Lanfer Marquez
Rita de Cássia Marques Alves

RESUMO

Os modelos regionais são cruciais para entender as mudanças naturais na meteorologia e oceanografia, assim como o impacto das atividades humanas no ambiente. Além disso, eles possibilitam previsões detalhadas sobre como as mudanças climáticas afetarão áreas específicas. A modelagem oceânica e atmosférica regional é particularmente valiosa, com resoluções espaciais entre 1 a 50 km, considerando interações entre padrões climáticos em grande escala e características locais do terreno. Nesse capítulo revisamos aspectos sobre as equações primitivas utilizadas na previsão numérica de tempo, sistemas de grade e métodos de solução utilizados na modelagem regional, equações utilizadas nos modelos regionais atmosféricos e oceânicos.

INTRODUÇÃO

Antes de mergulharmos nas equações utilizadas, vamos dar uma breve olhada nos modelos numéricos e porque os modelos regionais são importantes. Simplificando, os modelos numéricos utilizam equações matemáticas para simular fenômenos naturais, como correntes oceânicas e atmosféricas. Esses modelos ajudam os cientistas a entender as complexas interações entre diferentes variáveis e prever resultados futuros. Modelos regionais, como o próprio nome sugere, focam em regiões geográficas específicas, permitindo que os pesquisadores estudem padrões e fenômenos locais com mais detalhes.

Quando se trata de previsão numérica do tempo, as equações que compõem as equações primitivas são a espinha dorsal de tudo. Mas o



que são equações primitivas e por que elas são tão importantes? Vamos nos aprofundar no assunto! As equações primitivas são um conjunto de equações matemáticas usadas para modelar o movimento atmosférico. Elas foram desenvolvidas pela primeira vez na década de 1950 e, desde então, tornaram-se a base da maioria dos modelos de previsão numérica do tempo (Shuman, 1989). O objetivo das equações primitivas é simular o movimento do ar na atmosfera. Elas fazem isso resolvendo diferentes variáveis, como temperatura, pressão e velocidade do vento.

Ao entender como essas variáveis mudam ao longo do tempo, os meteorologistas podem prever o clima. As equações específicas usadas em equações primitivas variam de acordo com o modelo que está sendo usado. No entanto, todas elas compartilham algumas características importantes. Primeiro, elas se baseiam nas leis da física que regem o movimento atmosférico. Em segundo lugar, elas são não lineares, o que significa que pequenas alterações nas condições iniciais podem levar a resultados significativamente diferentes (Jühnlein *et al.*, 2019). Por fim, são equações diferenciais parciais, que podem ser difíceis de resolver analiticamente.

Agora que temos uma compreensão básica dos modelos numéricos e sua importância, e da importância das equações primitivas para os modelos numéricos, vamos seguir para um detalhamento maior dessas equações, além das equações utilizadas nos principais modelos regionais atmosféricos e oceânicos.

EQUAÇÕES PRIMITIVAS NA PREVISÃO NUMÉRICA DO TEMPO

As equações primitivas geralmente incluem equações para a conservação de massa, também conhecida como a Equação de Continuidade. Ela é uma equação fundamental na física e na engenharia que descreve a conservação da massa de um fluido em um sistema. Ela é expressa matematicamente da seguinte forma:

$$\partial\rho/\partial t + \nabla\cdot(\rho\mathbf{u}) = 0 \quad (1)$$

No qual: ρ (Rho): representa a densidade do fluido, que é a quantidade de massa por unidade de volume (geralmente em kg/m^3). No contexto da atmosfera, ρ refere-se à densidade do ar, ou seja, quanta massa de ar está presente por unidade de volume, t representa o tempo (geralmente em segundos). A equação leva em consideração como a densidade do fluido muda com o tempo; \mathbf{u} é o vetor de velocidade do fluido (geralmente em m/s). Este vetor descreve a velocidade do fluxo do fluido em uma determinada direção e posição; $\nabla\cdot$ representa o operador de divergência, que é uma operação matemática que mede como um campo vetorial se espalha a partir de um ponto específico. No contexto da equação, $\nabla\cdot(\rho\mathbf{u})$ é a divergência do produto da densidade do fluido ρ pelo vetor de velocidade \mathbf{u} . Essa parte da equação expressa como a massa está fluindo dentro ou fora de uma região específica do espaço.

A equação de continuidade afirma que a variação da densidade do fluido com o tempo, dada pela primeira parte da equação ($\partial\rho/\partial t$), é igual à divergência do fluxo de massa, dado pela segunda parte da equação ($\nabla\cdot(\rho\mathbf{u})$). Em outras palavras, ela descreve o princípio fundamental de que a massa de um fluido é conservada, e quaisquer mudanças

na densidade devem ser devidas ao fluxo do fluido na região em consideração. É uma equação importante em fluidodinâmica e é usada para modelar o comportamento de fluidos em diversas situações, incluindo a atmosfera terrestre (Ding, 2007).

Aproxima é a equação do momento ou as Equações de Navier-Stokes, que compõem um conjunto de equações fundamentais na física que descrevem o comportamento dos fluidos, incluindo o movimento do ar na atmosfera (Giraldo e Restelli, 2008). Elas são compostas por três equações, uma para cada componente das direções espaciais (x, y e z), e representam a conservação de momento, também conhecida como a segunda lei do movimento de Newton, aplicada a um fluido.

A primeira equação de Navier-Stokes foi desenvolvida para a direção x (u):

$$\partial u / \partial t + (u \cdot \nabla) u = -\nabla P / \rho + F_x \quad (2)$$

Onde u é a componente da velocidade do ar na direção x (m/s); t representa o tempo (s); $-\partial u / \partial t$ é variação da velocidade na direção x com o tempo, ou seja, a aceleração na direção x; o termo convectivo que representa a advecção é o $-(u \cdot \nabla) u$, ou seja, como a velocidade transporta a velocidade em uma determinada direção; $-\nabla P / \rho$: Gradiente negativo da pressão atmosférica (Pa/m) dividido pela densidade do ar (kg/m^3), que descreve como a pressão age sobre o fluido; F_x : Forças externas aplicadas na direção x, como a força de Coriolis, força de atrito ou outras forças (N/m^3).

A segunda equação de Equação de Navier-Stokes é para a direção y (v):

$$\partial v / \partial t + (u \cdot \nabla) v = -\nabla P / \rho + F_y \quad (3)$$

Onde v: Componente da velocidade do ar na direção y (m/s); $\partial v / \partial t$: Variação da velocidade na direção y com o tempo; $(u \cdot \nabla) v$: Termo convectivo que representa como a velocidade na direção x afeta a velocidade na direção y; $-\nabla P / \rho$: Gradiente negativo da pressão atmosférica (Pa/m) dividido pela densidade do ar, que descreve como a pressão age sobre o fluido; F_y : Forças externas aplicadas na direção y, como a força de Coriolis, força de atrito ou outras forças.

E a terceira e última equação de Navier-Stokes para a direção z (w):

$$\partial w / \partial t + (u \cdot \nabla) w = -\nabla P / \rho + F_z \quad (4)$$

Onde w: Componente da velocidade do ar na direção z (m/s); $\partial w / \partial t$: Variação da velocidade na direção z com o tempo; $(u \cdot \nabla) w$: Termo convectivo que representa como a velocidade na direção x afeta a velocidade na direção z; $-\nabla P / \rho$: Gradiente negativo da pressão atmosférica (Pa/m) dividido pela densidade do ar, que descreve como a pressão age sobre o fluido; F_z : Forças externas aplicadas na direção z, como a força de Coriolis, força de atrito ou outras forças.

Estas equações de Navier-Stokes descrevem o movimento do ar na atmosfera e no oceano, levando em consideração a pressão, a densidade e as forças externas, como a força de Coriolis devido à rotação da Terra e a força de atrito. Elas são fundamentais na modelagem e previsão do comportamento do vento e têm ampla aplicação em meteorologia, engenharia aerodinâmica e estudos de dinâmica dos fluidos atmosféricos (Cermak, 1975). Vale ressaltar que as equações de Navier-Stokes são equações diferenciais parciais não

lineares e, em muitos casos, são resolvidas numericamente devido à complexidade das soluções analíticas.

A seguinte equação primitiva é fundamental, pois envolve a Conservação de Energia e é muitas vezes chamada de equação de transporte de temperatura. Uma vez que ela é fundamental na oceanografia e na meteorologia, pois descreve como a temperatura do ar e do oceano variam com o tempo e o espaço, levando em consideração diversos processos físicos. A equação é expressa da seguinte forma:

$$\partial T / \partial t + \mathbf{u} \cdot \nabla T = Q - (P/\rho) \nabla \cdot \mathbf{u} + D \quad (5)$$

Onde T Representa a temperatura do ar (em Kelvin, K). A temperatura é uma medida da energia térmica do ar; t: Representa o tempo (em segundos, s); u: É o vetor de velocidade do ar (em metros por segundo, m/s). Ele descreve como o ar se move no espaço; Q: Representa fontes e sumidouros de calor (em Watts por metro cúbico, W/m³). Essas fontes e sumidouros podem ser devidos a processos como radiação solar, aquecimento interno, resfriamento evaporativo, entre outros; P: Representa a pressão atmosférica (em Pascals, Pa). A pressão é uma medida da força exercida pelo ar em uma determinada região; ρ: Representa a densidade do ar (em quilogramas por metro cúbico, kg/m³). A densidade é uma medida da quantidade de massa de ar em uma unidade de volume; D: Representa a difusão de calor (em Watts por metro cúbico, W/m³). A difusão térmica descreve como o calor é transferido de regiões mais quentes para regiões mais frias devido ao movimento aleatório das moléculas.

Esta equação de conservação de energia descreve como a temperatura do ar muda com o tempo ($\partial T / \partial t$) devido a vários processos como: Advecção ($\mathbf{u} \cdot \nabla T$): O primeiro termo à esquerda da equação representa o transporte da temperatura pelo vento. Ele descreve como o ar em movimento transporta a temperatura para diferentes locais no espaço. Fontes e sumidouros de calor (Q): O segundo termo à direita da equação representa a contribuição de fontes (adicionam calor) e sumidouros (removem calor) para a temperatura do ar. Variação de pressão ($-(P/\rho) \nabla \cdot \mathbf{u}$): O terceiro termo à direita da equação considera como a variação de pressão afeta a temperatura. Variações de pressão podem causar mudanças na temperatura do ar. Difusão de calor (D): O último termo à direita da equação descreve a difusão térmica, que é responsável por equalizar a temperatura em regiões adjacentes.

Em resumo, a equação de conservação de energia é essencial para entender como a temperatura do ar na atmosfera terrestre evolui ao longo do tempo e do espaço, levando em consideração uma variedade de processos físicos que contribuem para essas mudanças (Lynch, 2008). Ela é fundamental na modelagem meteorológica e na previsão do tempo, bem como em estudos de dinâmica dos fluidos atmosféricos.

Por fim, ainda temos a equação do vapor de água na atmosfera, que para os meteorologistas é importantíssima, uma vez que ela inclui termos sobre a condensação em nuvens e precipitação, é governada por várias equações e processos relacionados. Dentre as equações e variáveis-chave envolvidas na descrição desse comportamento, podemos citar:

A equação de Clausius-Clapeyron relaciona a pressão de vapor de água (e) à temperatura (T) e é fundamental para entender como a quantidade de vapor de água na

atmosfera varia com a temperatura:

$$\ln(e_2/e_1) = (L/R_v) * (1/T_1 - 1/T_2) \quad (6)$$

Onde e_1 e e_2 : Pressões de vapor em diferentes temperaturas (Pa); L: O calor latente de vaporização da água (J/kg); R_v : A constante específica dos gases para vapor de água (J/(kg·K)); T_1 e T_2 : Temperaturas correspondentes às pressões de vapor e_1 e e_2 (K). Esta equação descreve como o vapor de água se comporta em diferentes temperaturas e como a pressão de vapor varia com a temperatura (Mazur e Schneider, 1986).

A equação da Umidade Relativa (UR), que calcula a medida da quantidade de vapor de água presente na atmosfera em relação à quantidade máxima que poderia existir a uma determinada temperatura. A UR é calculada usando a seguinte equação:

$$UR (\%) = (e / e_s) * 100 \quad (7)$$

Onde e : Pressão de vapor atual (Pa); e_s : Pressão de vapor saturado, que é a pressão de vapor máxima possível a uma determinada temperatura (Pa). A umidade relativa descreve o quão “saturada” ou “úmida” a atmosfera está em relação à sua capacidade máxima de conter vapor de água a uma temperatura específica.

Na equação de Taxa de Condensação, calculamos qual o vapor de água na atmosfera se transforma em água líquida (condensa) para formar nuvens e, eventualmente, precipitação. A taxa de condensação é calculada usando a equação de Kessler:

$$dq/dt = A * (e - e_s) \quad (8)$$

Onde dq/dt : Taxa de mudança da quantidade de água por unidade de tempo (kg/s); A: Coeficiente de condensação de massa e tamanho das gotículas de nuvem; e : Pressão de vapor atual (Pa); e_s : Pressão de vapor saturado (Pa).

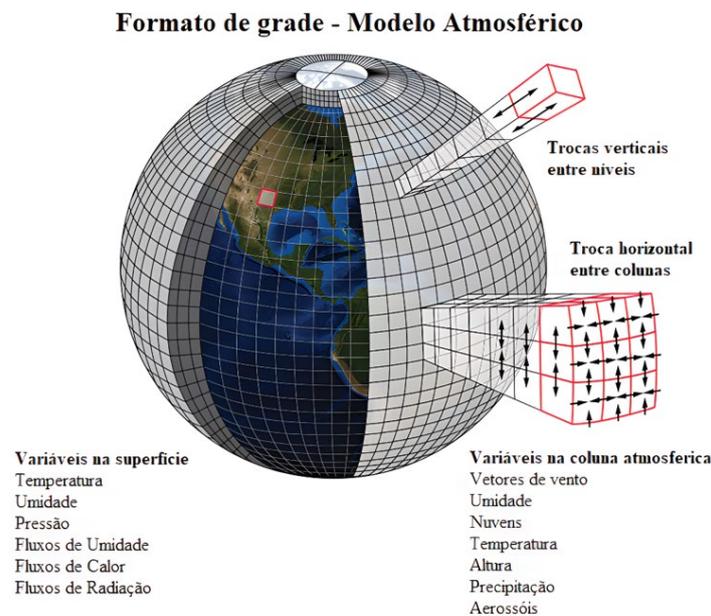
Essas equações descrevem como o ar se move pela atmosfera e como ele troca calor e momento com o solo e outras massas de ar. Um dos maiores desafios ao trabalhar com equações primitivas é o fato de elas serem equações diferenciais parciais não lineares. Isso significa que elas não podem ser resolvidas analiticamente e, em vez disso, devem ser resolvidas por meio de métodos numéricos. O processo de resolução numérica destas equações é complexo e exige uma enorme capacidade de computação. Mesmo com os supercomputadores modernos, pode levar horas ou até dias para executar uma única previsão. Outro desafio é que pequenos erros nas condições iniciais podem levar a resultados significativamente diferentes (Lorenz, 1965).

Isso é conhecido como efeito borboleta e impossibilita a previsão do tempo com precisão perfeita (Petrie e Dance, 2010). Apesar desses desafios, as equações primitivas provaram ser uma ferramenta poderosa para a previsão do tempo. Ao compreender a física que rege o movimento atmosférico, os meteorologistas podem criar modelos mais precisos e fazer previsões melhores. Em conclusão, as equações primitivas são a base da previsão numérica do tempo e compõem um conjunto de equações diferenciais parciais não lineares usadas para simular o movimento atmosférico e prever o clima. Embora o trabalho com elas possa ser desafiador, elas permitiram enormes avanços na previsão do tempo e em nossa capacidade de prever e nos preparar para eventos climáticos severos.

SISTEMAS DE GRADE E MÉTODOS DE SOLUÇÃO UTILIZADOS NA MODELAGEM REGIONAL

A previsão numérica regional do tempo envolve a divisão de áreas do planeta em uma grade tridimensional (figura 1) e o cálculo de variáveis meteorológicas e oceanográficas em cada ponto, conhecido como pontos de grade. Um modelo de previsão atmosférico, por exemplo, resolve equações de toda a troposfera da Terra usando um sistema de grade 3D. Esse modelo inicializa e prevê dados meteorológicos em determinados locais e altitudes para tempos futuros usando um conjunto de equações.

Figura 1 - Esquema de uma grade de modelo meteorológico ou climático, dividida em componentes horizontais e verticais.



Adaptada de (K. Cantner, AGI)

Os modelos globais e quase todos os modelos regionais usam métodos de diferenças finitas para todas as três dimensões espaciais, enquanto outros modelos globais e poucos modelos regionais usam métodos espectrais para as dimensões horizontais e métodos de diferenças finitas na vertical (Zhang *et al.*, 2012). Na previsão numérica do tempo, é essencial ter um sistema de coordenadas adequado para dividir o planeta em um sistema de grade. Os vários sistemas de coordenadas usados pelos modelos de previsão numérica incluem a altura geométrica (z), o sistema de coordenadas de pressão e as coordenadas de pressão normalizadas, conhecidas como coordenadas sigma (Zhang *et al.*, 2015).

Em um sistema de coordenadas de altura geométrica, a altura é usada como a coordenada vertical, enquanto em um sistema de coordenadas de pressão, os níveis de pressão ou os níveis de altura com níveis de pressão constantes são usados como representações (Song e Haidvogel, 1994). Por outro lado, as coordenadas sigma são variáveis nas quais a camada vertical é esticada ou expandida para tornar os espaçamentos entre níveis uniformes em uma atmosfera hidrostática e Boussinesq (Adcroft e Campin, 2004). Todos os três sistemas de coordenadas são usados em diferentes modelos de previsão, e a decisão de qual usar depende dos requisitos do modelo. Os modelos de previsão global usam um sistema de grade 3D que divide o planeta em uma grade com

espaçamento igual nas direções latitudinal e longitudinal e espaçamento vertical variável. As informações meteorológicas em cada ponto da grade são calculadas levando-se em conta vários fatores, como ventos, transferência de calor, radiação, umidade relativa e hidrologia da superfície (Lehning *et al.*, 2006).

O modelo de grade global usa métodos espectrais para dimensões horizontais, enquanto os métodos de diferença finita são usados na vertical. Além de ser executado a cada seis horas e fornecer previsões meteorológicas com até dez dias de antecedência. Os modelos regionais permitem o uso de um espaçamento de grade mais fino do que os modelos globais, pois os recursos computacionais disponíveis são concentrados em uma área específica em vez de serem distribuídos globalmente (Mendonça *et al.*, 2017). Isso permite que os modelos regionais resolvam explicitamente fenômenos meteorológicos de menor escala que são impossíveis de representar na grade mais grossa do modelo global.

Na modelagem oceânica regional a escolha de um sistema de coordenadas verticais (figura 2) é um dos aspectos mais importantes do design de um modelo. Há três sistemas de coordenadas verticais principais em uso. Cada um deles tem suas vantagens e desvantagens, o que levou ao desenvolvimento de sistemas de coordenadas híbridas (Mellor *et al.*, 2002). Essa é uma área de pesquisa e desenvolvimento muito ativa em modelos numéricos oceânicos. As coordenadas Z (figura 2 b,c), são similares aos modelos atmosféricos e constituem um sistema de coordenadas verticais em que a profundidade, denotada por “z”, serve como referência primária.

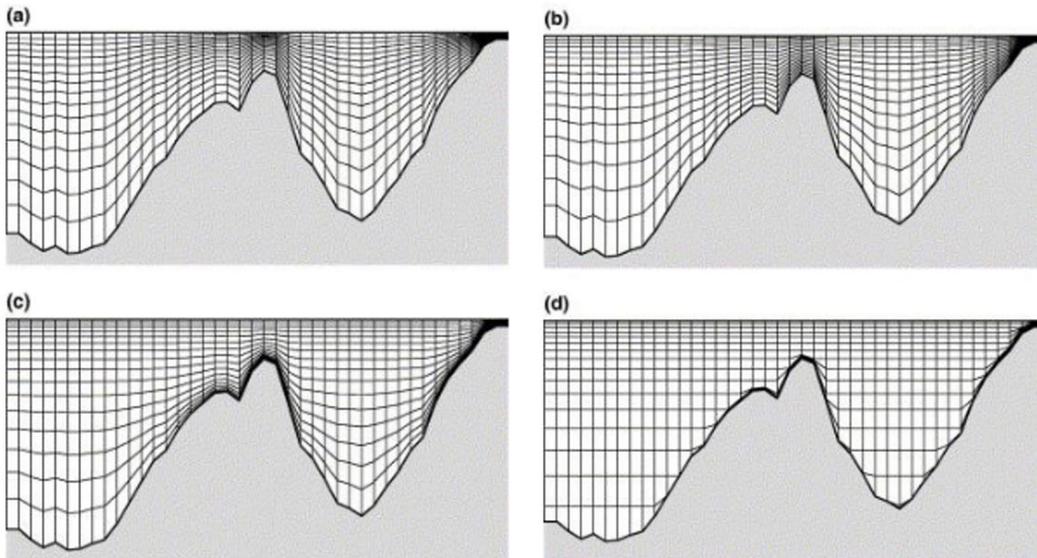
Este sistema, caracterizado pela sua simplicidade, tem encontrado utilidade em vários modelos oceânicos desde há muitas décadas. Os modelos de coordenadas Z são particularmente eficazes em áreas bem misturadas, uma vez que podem fornecer a resolução fina necessária para uma representação precisa dos fenômenos turbulentos tridimensionais. Os níveis de profundidade do oceano são tipicamente fixos em número, permitindo uma colocação estratégica que dá prioridade a uma maior resolução na camada superficial crucial. No entanto, as coordenadas z enfrentam um inconveniente em regiões com topografia inclinada, uma vez que estes níveis intersectam a batimetria, conduzindo potencialmente a velocidades verticais irrealistas perto do fundo do mar. Para melhorar a representação do escoamento próximo do fundo, é necessário aumentar o número de níveis verticais, embora com um custo computacional significativo (Marks *et al.*, 1998).

As coordenadas Sigma (σ) são utilizadas neste tipo de modelo (Figura 2d), em que a coordenada vertical se alinha com a batimetria, mantendo um número consistente de pontos de grade verticais em todo o domínio, independentemente da profundidade da coluna de água (Pain *et al.*, 2005). A espessura das camadas varia de um ponto de grade horizontal para outro, adaptando-se às alterações na profundidade do fundo.

Os níveis Sigma não estão limitados a uma distribuição uniforme em toda a coluna de água; apresentam frequentemente um espaçamento mais denso perto da superfície e/ou do fundo, aumentando efetivamente a resolução nas camadas limite em todo o domínio. Para atingir este nível de pormenor com um modelo de nível z, seria necessário um número de níveis impraticável. As coordenadas Sigma encontram a sua melhor aplicação na plataforma continental e nas regiões costeiras, onde as camadas limites da superfície e do fundo se podem fundir (Tilburg, 2003). No entanto, têm dificuldade em lidar com mudanças

topográficas abruptas entre pontos de grelha adjacentes, introduzindo potencialmente padrões de fluxo irrealistas devido a erros de gradiente de pressão. Para mitigar estes problemas, é frequentemente necessário aumentar a resolução horizontal ou suavizar a batimetria.

Figura 2 - Exemplos de sistemas de coordenadas verticais: (a) Coordenada-S de Song e Haidvogel (1994), com $\theta_s = 3$ e $\theta_b = 0,01$; (b,c) sistemas de coordenadas híbridas z- σ , obtidos pelo relaxamento do sistema de coordenadas-z (d) em direção à coordenada-S.

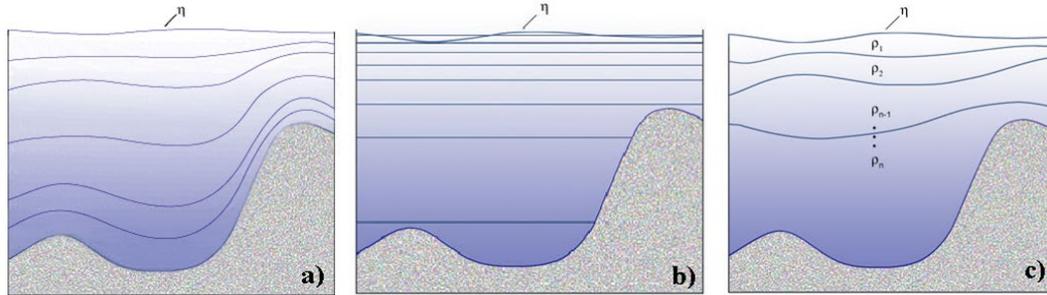


Fonte: Adaptada de (Shchepetkin, 2005)

As coordenadas Sigma (σ) são utilizadas neste tipo de modelo, em que a coordenada vertical se alinha com a batimetria, mantendo um número consistente de pontos de grelha verticais em todo o domínio, independentemente da profundidade da coluna de água (Pain *et al.*, 2005). A espessura das camadas varia de um ponto de grelha horizontal para outro, adaptando-se às alterações na profundidade do fundo. Os níveis Sigma não estão limitados a uma distribuição uniforme em toda a coluna de água; apresentam frequentemente um espaçamento mais denso perto da superfície e/ou do fundo, aumentando efetivamente a resolução nas camadas limite em todo o domínio. Para atingir este nível de pormenor com um modelo de nível z, seria necessário um número de níveis impraticável. As coordenadas Sigma encontram a sua melhor aplicação na plataforma continental e nas regiões costeiras, onde as camadas limites da superfície e do fundo se podem fundir (Tilburg, 2003). No entanto, têm dificuldade em lidar com mudanças topográficas abruptas entre pontos de grelha adjacentes, introduzindo potencialmente padrões de fluxo irrealistas devido a erros de gradiente de pressão. Para mitigar estes problemas, é frequentemente necessário aumentar a resolução horizontal ou suavizar a batimetria.

Por fim, temos as coordenadas isopicnais (figura 3), também conhecidas como modelos em camadas, utilizam a densidade potencial referenciada a um nível de pressão específico como coordenada vertical (Petersen *et al.*, 2015). Esta abordagem segmenta essencialmente a coluna de água em camadas discretas e homogêneas, com as suas espessuras sujeitas a variações espaciais e temporais. Esta escolha de sistema de coordenadas revela-se eficaz para simular o transporte de marcadores, que ocorre predominantemente ao longo de superfícies consistentes com a densidade. Apesar da utilização comum da densidade como coordenada vertical, existem distinções subtis entre os modelos em camadas e os modelos isopicnais.

Figura 3 – Exemplos de grades com coordenada Sigma (a), altura geométrica Z (b) e Isopicnal (c). Fonte: Navy Operational Ocean Circulation and Tide Models.



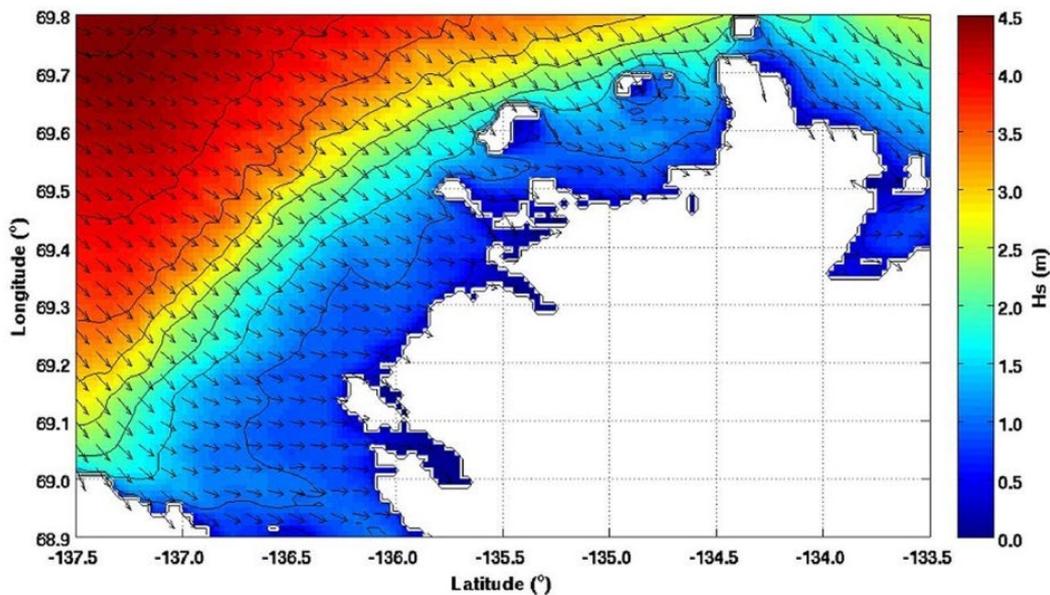
Fonte: Oceanography Department at the Naval Postgraduate School. Disponível em: https://www.oc.nps.edu/nom/modeling/vertical_grids.html

Explicamos que o modelo regional usa um modelo global para especificar as condições de limite na borda de seu domínio, a fim de permitir que os sistemas de fora do domínio do modelo regional se desloquem para sua área (Mendonça *et al.*, 2023). Entretanto, a incerteza e os erros são introduzidos no modelo regional pelo modelo global, usado para as condições de limite na borda do domínio e repassando os erros atribuíveis ao próprio modelo regional. A importância dos métodos de solução usados está na sua precisão na previsão dos fenômenos meteorológicos e oceanográficos. Os métodos de solução mais comuns usados nos modelos numéricos de previsão do tempo são os métodos Eulerianos e os métodos Lagrangianos. Os métodos Eulerianos resolvem as equações determinantes em pontos de grade fixos no tempo, calculando o movimento do fluido em referência às coordenadas Eulerianas fixas (Marras *et al.*, 2016).

Por outro lado, os métodos Lagrangianos resolvem as equações determinantes rastreando o movimento das parcelas de fluido no tempo, em vez de em pontos de grade fixos em referência a um quadro fixo de coordenadas. Em termos de modelos oceânicos, as simulações numéricas de ondas oceânicas são realizadas por meio de modelos de ondas (figura 4). Os modelos matemáticos começaram a simular ondas na década de 1960, mas apresentavam deficiências, pois enfatizavam demais o impacto do vento no desenvolvimento das ondas e ignoravam os fenômenos de interação das ondas (Korde e Ringwood, 2016). Em 1988, surgiram os modelos de ondas de terceira geração, que utilizavam a equação de transporte espectral de ondas para prever a geração, a transmissão, a refração, a dissipação e a formação de cardumes.

A equação de transporte de ondas espectrais pode ser um produto de assimilação de campos de entrada computados por modelos numéricos, como o modelo global de previsão numérica do tempo (Weng e Liu, 2003). Em conclusão, os sistemas de grade e os métodos de solução usados na previsão numérica do tempo são essenciais para fazer previsões meteorológicas precisas. A decisão de qual sistema usar depende dos requisitos do modelo de previsão, enquanto a precisão dos métodos de solução depende de sua capacidade de prever fenômenos meteorológicos com precisão. O futuro da previsão numérica do tempo está no desenvolvimento de modelos mais avançados que assimilam dados meteorológicos de várias fontes e refinam a precisão dos modelos regionais.

Figura 4 - Altura significativa das ondas (Hs) e direções médias das ondas na região do Mar de Canadian Beufort, aninhada de resolução fina durante o pico da tempestade às 23:00 de 17 de setembro de 1985.



Fonte: Hoque *et al.* (2020).

EQUAÇÕES UTILIZADAS NOS MODELOS REGIONAIS ATMOSFÉRICOS

Os modelos de pesquisa regionais atmosféricos são baseados principalmente em um conjunto de equações complexas que descrevem os processos físicos da atmosfera. Isso inclui desde o comportamento dos gases até o movimento das massas de ar e nuvens. Um conjunto importante de equações usadas nestes modelos regionais atmosféricos é lida através da radiação emitida pelo sol e pela Terra. Essas equações levam em conta fatores como a posição do sol em relação à Terra, a refletividade de diferentes superfícies e a absorção de radiação por vários gases na atmosfera (Rahman *et al.*, 1993).

Outro conjunto de equações é usado para modelar a mistura turbulenta e a convecção. Essas equações levam em conta o movimento do ar devido a diferenças de temperatura e pressão, bem como o comportamento de turbulências. A modelagem da mistura turbulenta e da convecção em modelos numéricos atmosféricos envolve a resolução de equações que descrevem o comportamento do ar devido a diferenças de temperatura e pressão, bem como o comportamento das turbulências (Xue, *et al.*, 2000). Duas equações fundamentais usadas nesse contexto são a equação de conservação da quantidade de movimento (ou equação do momentum) e a equação de conservação da energia.

A equação de conservação da quantidade de movimento (momentum) para o ar na atmosfera pode ser escrita na forma vetorial para cada componente (x, y, z) da velocidade do ar (u, v, w). A equação simplificada para a componente x (u) pode ser expressa numericamente da seguinte maneira:

$$\frac{\partial u}{\partial t} + (u\frac{\partial u}{\partial x} + v\frac{\partial u}{\partial y} + w\frac{\partial u}{\partial z}) = -1/\rho \frac{\partial P}{\partial x} + F_x + v(\frac{\partial^2 u}{\partial x^2} + \frac{\partial^2 u}{\partial y^2} + \frac{\partial^2 u}{\partial z^2}) \quad (9)$$

Onde u , v , e w são as componentes da velocidade do ar nas direções x , y e z , respectivamente; t é o tempo; ρ é a densidade do ar; P é a pressão; F_x é a força resultante na direção x (por exemplo, devido à gravidade); ν é a viscosidade cinemática do ar; $\partial/\partial x$, $\partial/\partial y$ e $\partial/\partial z$ representam as derivadas parciais em relação às coordenadas espaciais x , y e z , respectivamente.

A equação de conservação da energia descreve como a temperatura do ar (T) evolui devido ao transporte de calor e às trocas de energia. A equação simplificada pode ser expressa numericamente da seguinte forma:

$$\partial T/\partial t + (u\partial T/\partial x + v\partial T/\partial y + w\partial T/\partial z) = \alpha(\partial^2 T/\partial x^2 + \partial^2 T/\partial y^2 + \partial^2 T/\partial z^2) + Q \quad (10)$$

Nesta equação: T é a temperatura do ar; α é a difusividade térmica do ar e Q é uma fonte ou sumidouro de calor (por exemplo, devido à radiação solar).

Essas equações levam em consideração o movimento do ar (convecção e advecção), a difusão térmica (transporte de calor devido à variação de temperatura), a pressão atmosférica e a viscosidade do ar. Para modelar a turbulência na atmosfera, são necessários modelos adicionais, como os modelos de turbulência de Reynolds-Averaged Navier-Stokes (RANS) ou os modelos de simulação de grandes escalas (LES), que incorporam parâmetros turbulentos e equações específicas para a turbulência (Wyngaard, 2010).

A resolução numérica destas equações em modelos atmosféricos é complexa e requer discretização espacial e temporal, bem como a consideração de condições iniciais e de contorno adequadas para simular o comportamento da atmosfera, incluindo a mistura turbulenta e a convecção. A grande maioria dos modelos regionais atmosféricos também usa equações para descrever a formação e movimento de nuvens e precipitação, por meio de equações que levam em conta fatores como a temperatura e a umidade do ar, bem como o comportamento de turbulências em pequena escala dentro das nuvens. Eles são particularmente importantes para fazer previsões precisas de padrões climáticos em escala regional e local. A capacidade do modelo em incorporar todas essas equações em um sistema completo é o que o torna uma ferramenta tão poderosa para a previsão do tempo.

Ao levar em conta todos os diferentes processos físicos que afetam a atmosfera, o modelo é capaz de gerar previsões altamente precisas de padrões climáticos futuros. No entanto, o modelo não pode se limitar a solucionar apenas a previsão do tempo, ele precisa fazer um *hindcast* preciso, além de analisar qualidade do ar e previsão de energia renovável. Nessas aplicações, sua capacidade de modelar com precisão fenômenos em escala regional e local é particularmente valiosa. Apesar de todas as suas vantagens, o modelo regional atmosférico não está isento de desafios, uma vez que a necessidade de dados precisos de entrada é fundamental. Como o modelo se baseia em um alto nível de detalhe e resolução, até mesmo pequenos erros nos dados de entrada podem levar a imprecisões significativas na saída final. Isso torna o controle cuidadoso de qualidade dos dados essencial para garantir resultados precisos.

Devido à complexidade de suas equações e a alta resolução espacial, simulações usando modelos regionais podem ser extremamente intensivas em termos de computação. Isso significa que a execução de uma única simulação pode levar uma quantidade

significativa de tempo e exigir uma grande quantidade de energia computacional. Apesar desses desafios, a modelagem numérica continua sendo uma das ferramentas mais poderosas disponíveis para previsão do tempo e pesquisa científica. Sua capacidade de modelar com precisão processos físicos complexos em escala regional e local o tornam uma ferramenta essencial para uma ampla gama de aplicações.

EQUAÇÕES USADAS NOS MODELOS REGIONAIS OCEÂNICOS

Primeiramente, as equações de Navier-Stokes são a base da dinâmica dos fluidos, que é o estudo de fluidos (líquidos e gases) em movimento (Armstrong, 2015). Essas equações descrevem como a velocidade, pressão, temperatura e densidade de um fluido evoluem ao longo do tempo, dadas as condições iniciais e forças externas (Liu *et al.*, 2013). Em outras palavras, elas nos permitem prever como um fluido irá se comportar em diferentes cenários. Agora, quando se trata de modelos como o Regional Ocean Model System (ROMS), as equações de Navier-Stokes são usadas para descrever o movimento e a mistura das correntes oceânicas (Warner *et al.*, 2010).

As equações de Navier-Stokes são um conjunto de equações diferenciais parciais que descrevem a dinâmica dos fluidos, incluindo como a velocidade, a pressão, a temperatura e a densidade de um fluido mudam ao longo do tempo e do espaço (Kanarska *et al.*, 2007). Elas são amplamente usadas na física e na engenharia para modelar o comportamento de fluidos em diversos cenários. Para resolver numericamente as equações de Navier-Stokes, são necessárias técnicas de discretização espacial e temporal, como diferenças finitas, elementos finitos ou métodos de volume finito. A resolução numérica dessas equações é fundamental em áreas como a simulação de fluxo de fluidos em engenharia, meteorologia, estudos de oceano, entre outros campos. As equações de Navier-Stokes podem ser expressas de forma numérica da seguinte maneira:

A Equação de conservação de massa (Equação de Continuidade):

$$\partial\rho/\partial t + \nabla(\rho * V) = 0 \quad (11)$$

Onde ρ é a densidade do fluido, t é o tempo, V é o vetor de velocidade do fluido, ∇ é o operador nabla, que representa o gradiente espacial.

Essa equação descreve como a densidade do fluido muda no tempo e no espaço devido ao fluxo de massa. Enquanto a equação de conservação do momento (Equações de Navier-Stokes para o movimento), descreve como a velocidade do fluido muda ao longo do tempo e do espaço devido à pressão, viscosidade e forças externas, que é representada por:

$$\partial V/\partial t + (V \cdot \nabla)V = -1/\rho * \nabla P + \nu \nabla^2 V + F \quad (12)$$

Onde V é o vetor de velocidade do fluido, P é a pressão, ν é a viscosidade cinemática do fluido, $\nabla^2 V$ é o laplaciano da velocidade, representando a divergência do gradiente da velocidade, F são as forças externas que atuam no fluido, como forças de corpo ou forças de superfície.

A equação de conservação de energia (Equação da Energia) mostra como a

temperatura do fluido muda ao longo do tempo e do espaço devido ao transporte de calor, condução térmica e fontes de calor. Sendo descrita como:

$$\partial T / \partial t + (\mathbf{V} \cdot \nabla) T = (1 / \rho C_p) \nabla \cdot (k \nabla T) + Q \quad (13)$$

Onde T é a temperatura do fluido, C_p é a capacidade calorífica a pressão constante do fluido, k é a condutividade térmica do fluido, Q é uma fonte de calor.

No entanto, resolver essas equações para sistemas em grande escala, como o oceano, não é tarefa fácil. Na verdade, requer algumas simplificações e aproximações, o que nos leva ao próximo ponto. A aproximação de Boussinesq é uma simplificação das equações de Navier-Stokes frequentemente usada em oceanografia e em outros campos da dinâmica de fluidos quando se deseja modelar o comportamento de fluidos com variações de densidade relativamente pequenas, como é o caso dos oceanos (Ferziger *et al.*, 2019). Ela pressupõe que a densidade do fluido seja constante, exceto quando aparece no termo de fluatibilidade, que surge das diferenças de temperatura e salinidade no oceano.

Ao negligenciar as variações de densidade em outros termos das equações, a aproximação de Boussinesq reduz a complexidade do problema e permite cálculos mais eficientes. Essa aproximação assume que a densidade do fluido é constante, exceto quando aparece no termo de fluatibilidade, que leva em consideração as variações de densidade devido a diferenças de temperatura e salinidade no oceano (Mellor e Ezer, 1995). A equação de Boussinesq modificada, que considera essa aproximação, pode ser representada de forma numérica da seguinte maneira:

Equação de conservação de massa (Equação de Continuidade):

$$\partial \rho / \partial t + \nabla \cdot (\rho \mathbf{V}) = 0 \quad (14)$$

Nessa equação, ρ representa a densidade do fluido e \mathbf{V} é o vetor de velocidade do fluido.

Equação de conservação do momento (Equações de Navier-Stokes para o movimento):

$$\partial \mathbf{V} / \partial t + (\mathbf{V} \cdot \nabla) \mathbf{V} = -\nabla P + (\rho_0 - \rho) * \mathbf{g} * \mathbf{e}_z + \nu \nabla^2 \mathbf{V} + \mathbf{F} \quad (15)$$

Nessa equação, ρ_0 é a densidade de referência do fluido (geralmente constante), P é a pressão, \mathbf{g} é a aceleração devido à gravidade, \mathbf{e}_z é o vetor unitário na direção vertical.

Equação de conservação de energia (Equação da Energia):

$$\partial T / \partial t + (\mathbf{V} \cdot \nabla) T = \alpha \nabla^2 T + Q \quad (16)$$

Nessa equação, T é a temperatura do fluido, α é a difusividade térmica do fluido e Q é uma fonte de calor.

A principal simplificação introduzida pela aproximação de Boussinesq é a suposição de que a densidade ρ do fluido é aproximadamente constante em todas as equações, exceto na equação de conservação do momento, onde a diferença de densidade ($\rho_0 - \rho$) aparece no termo de fluatibilidade, que é proporcional à aceleração gravitacional (\mathbf{g}) e à variação de densidade. Isso permite que os efeitos das variações de densidade devido a mudanças de

temperatura e salinidade sejam considerados de forma simplificada na modelagem.

A resolução numérica das equações de Boussinesq costuma ser realizada usando métodos de discretização espacial e temporal, como diferenças finitas ou elementos finitos, e é fundamental em estudos oceanográficos para entender a circulação oceânica, as correntes e os fenômenos relacionados às variações de temperatura e salinidade. Em seguida, aplicando algoritmos iterativos, eles atualizam os valores na grade até que se alcance um estado estacionário ou uma solução dependente do tempo. No contexto dos modelos regionais como o ROMS, os métodos de diferenças finitas são usados para discretizar o domínio do oceano, que pode ser incrivelmente complexo e irregular (Chen *et al.*, 2012). Ao dividir o domínio em uma grade de células, os métodos de diferenças finitas permitem que os pesquisadores calculem os valores de velocidade, pressão e outras variáveis em cada ponto da grade, e então simulem a evolução desses valores ao longo do tempo.

Agora que temos uma compreensão básica das equações utilizadas em um modelo regional como o ROMS, vamos falar sobre as vantagens deste modelo oceânico regional. Uma das maiores vantagens é sua modelagem de alta resolução, que permite aos pesquisadores capturar características e detalhes de pequena escala que muitas vezes são ignorados em modelos globais (Judt e Rios-Berrios, 2021). Isso é particularmente importante para estudar regiões costeiras, onde interações complexas entre o oceano e a terra podem ter impactos significativos no meio ambiente e na economia. A flexibilidade na configuração do modelo permite que os pesquisadores possam escolher entre uma ampla gama de variáveis e parâmetros para personalizar seu modelo de acordo com a região e os fenômenos de interesse. Isso é especialmente útil para estudar mudanças ao longo do tempo ou em diferentes escalas espaciais e temporais, além de diferentes cenários. Os modelos regionais oceânicos têm a capacidade de levar em conta múltiplos processos simultaneamente, como termodinâmica, interações entre ondas e correntes, e dinâmica biológica (Haidvogel *et al.*, 2008). Ao integrar diferentes modelos e fontes de dados, os pesquisadores podem criar uma compreensão mais abrangente dos sistemas oceânicos

Apesar de diversos modelos regionais simularem áreas costeiras e abrigadas, uma das principais aplicações dos modelos regionais são voltados para a compreensão da natureza complexa e dinâmica dos padrões de circulação oceânica. Seus domínios podem ser utilizados para modelar o movimento da água ao longo de corpos d'água no mundo todo, incluindo as interações complexas que ocorrem entre diferentes correntes e ondulações. Essas informações podem ser utilizadas para fazer previsões sobre o movimento de detritos ou poluentes no oceano, bem como para entender os efeitos das mudanças climáticas nos oceanos do mundo.

Ao modelar a distribuição de diferentes espécies dentro de um determinado ecossistema, podemos ajudar os pesquisadores a entender as relações entre diferentes espécies e como elas interagem com seu ambiente. Essas informações podem ser utilizadas para desenvolver estratégias de conservação e compreender melhor os efeitos da atividade humana em ecossistemas frágeis. Em geral, as aplicações de modelos regionais oceânicos são diversas e amplas, tornando-se uma ferramenta valiosa tanto para a pesquisa científica quanto para aplicações práticas. Seja usado para estudar padrões de circulação oceânica,

dinâmica de ecossistemas ou riscos costeiros, um modelo numérico poderoso pode ajudar a lançar luz sobre alguns dos sistemas mais complexos e dinâmicos da Terra.

REFERÊNCIAS

CERMAK, J. E. (1975). **Applications of fluid mechanics to wind engineering**—a Freeman Scholar lecture.

CHEN, C., BEARDSLEY, R. C., COWLES, G., QI, J., LAI, Z., GAO, G., ... LIN, H. (2012). An unstructured-grid, finite-volume community ocean model: FVCOM user manual. Cambridge, MA, USA: Sea Grant College Program, **Massachusetts Institute of Technology**.

DING, H., SPELT, P. D., SHU, C. (2007). Diffuse interface model for incompressible two-phase flows with large density ratios. **Journal of Computational Physics**, 226(2), 2078-2095.

FERZIGER, J. H., PERIĆ, M., STREET, R. L. (2019). **Computational methods for fluid dynamics**. springer.

HAIDVOGEL, D. B., ARANGO, H., BUDGELL, W. P., CORNUELLE, B. D., CURCHITSER, E., DI LORENZO, E., ... WILKIN, J. (2008). Ocean forecasting in terrain-following coordinates: Formulation and skill assessment of the Regional Ocean Modeling System. **Journal of computational physics**, 227(7), 3595-3624.

HOQUE, M. A., PERRIE, W., SOLOMON, S. M. (2020). Application of SWAN model for storm generated wave simulation in the Canadian Beaufort Sea. **Journal of Ocean Engineering and Science**, 5(1), 19-34.

JUDT, F., RIOS-BERRIOS, R. (2021). Resolved convection improves the representation of equatorial waves and tropical rainfall variability in a global nonhydrostatic model. **Geophysical Research Letters**, 48(14), e2021GL093265.

KANARSKA, Y., SHCHEPETKIN, A., MCWILLIAMS, J. C. (2007). Algorithm for non-hydrostatic dynamics in the regional oceanic modeling

KORDE, U. A.; RINGWOOD, J. Hydrodynamic control of wave energy devices. Cambridge University Press, 2016.

LEHNING, M.; VÖLKSCH, I.; GUSTAFSSON, D.; NGUYEN, T. A.; STÄHLI, M.; ZAPPA, M. ALPINE3D: a detailed model of mountain surface processes and its application to snow hydrology. **Hydrological Processes: An International Journal**, 20(10), 2111-2128, 2006.

LIU, J.; LIN, L.; SONG, R.; ZHAO, J. A pore scale modeling of fluid flow in porous medium based on navier-stokes equation. **Disaster Advances**, 6(supplement 1), 5-11, 2013.

LORENZ, E. N. **A study of the predictability of a 28-variable atmospheric model**. *Tellus*, 17(3), 321-333, 1965.

LYNCH, P. The origins of computer weather prediction and climate modeling. **Journal of computational physics**, 227(7), 3431-3444, 2008.

- MARKS, F. D.; SHAY, L. K.; PDT-5. Landfalling tropical cyclones: Forecast problems and associated research opportunities. **Bulletin of the American Meteorological Society**, 79(2), 305-323, 1998.
- MARRAS, S.; KELLY, J. F.; MORAGUES, M.; MÜLLER, A.; KOPERA, M. A.; VÁZQUEZ, M.; JORBA, O. A review of element-based Galerkin methods for numerical weather prediction: Finite elements, spectral elements, and discontinuous Galerkin. **Archives of Computational Methods in Engineering**, 23, 673-722, 2016.
- MAZUR, P.; SCHNEIDER, U. Osmotic responses of preimplantation mouse and bovine embryos and their cryobiological implications. **Cell biophysics**, 8, 259-285, 1986.
- MELLOR, G. L.; EZER, T. Sea level variations induced by heating and cooling: An evaluation of the Boussinesq approximation in ocean models. **Journal of Geophysical Research: Oceans**, 100(C10), 20565-20577, 1995.
- MELLOR, G. L.; HÄKKINEN, S. M.; EZER, T.; PATCHEN, R. C. A generalization of a sigma coordinate ocean model and an intercomparison of model vertical grids. **Ocean forecasting: conceptual basis and applications**, 55-72, 2002.
- MENDONÇA, L. F. F.; FETTER-FILHO, A. F. H.; ANDRADE, M. M.; DE OLIVEIRA, F. S. C.; LINDEMANN, D. S.; FREITAS, R. A. P.; REIS, R. A. N.; LENTINI, C. A. D.; PARISE, C. K.; SANTOS, D. C. Analysis of a coastal-trapped wave generated by the 2016 extra-tropical cyclonic system in the Southern Brazilian continental shelf with COAWST modeling system. **Journal of South American Earth Sciences**, v. 129, p. 104522-19, 2023.
- MENDONÇA, L. F.; SOUZA, R. B.; ASEFF, C. R. C.; PEZZI, L. P.; MÖLLER, O. O.; AALVES, R. C. M. Regional modeling of the water masses and circulation annual variability at the Southern Brazilian Continental Shelf. **JOURNAL OF GEOPHYSICAL RESEARCH-OCEANS**, v. 122, p. 1232-1253, 2017.
- PAIN, C. C.; PIGGOTT, M. D.; GODDARD, A. J. H.; FANG, F.; GORMAN, G. J.; MARSHALL, D. P.; DE OLIVEIRA, C. R. E. Three-dimensional unstructured mesh ocean modelling. **Ocean Modelling**, 10(1-2), 5-33, 2005.
- PETERSEN, M. R.; JACOBSEN, D. W.; RINGLER, T. D.; HECHT, M. W.; MALTRUD, M. E. Evaluation of the arbitrary Lagrangian–Eulerian vertical coordinate method in the MPAS-Ocean model. **Ocean Modelling**, 86, 93-113, 2015.
- PETRIE, R. E.; DANCE, S. L. Ensemble-based data assimilation and the localisation problem. **Weather**, 65(3), 65-69, 2010.
- RAHMAN, H.; VERSTRAETE, M. M.; PINTY, B. Coupled surface-atmosphere reflectance (CSAR) model: 1. Model description and inversion on synthetic data. **Journal of Geophysical Research: Atmospheres**, 98(D11), 20779-20789, 1993.
- REICHLER, T., KIM, J. (2008). How well do coupled models simulate today's climate?. **Bulletin of the American Meteorological Society**, 89(3), 303-312.
- SHCHEPETKIN, Alexander F.; MCWILLIAMS, James C. The regional oceanic modeling system (ROMS): a split-explicit, free-surface, topography-following-coordinate oceanic model. **Ocean modelling**, v. 9, n. 4, p. 347-404, 2005.

SHUMAN, F. G. (1989). History of numerical weather prediction at the National Meteorological Center. **Weather and forecasting**, 4(3), 286-296.

SONG, Y., HAIDVOGEL, D. (1994). A semi-implicit ocean circulation model using a generalized topography-following coordinate system. **Journal of Computational Physics**, 115(1), 228-244.

SONG, Yuhe; HAIDVOGEL, Dale. A semi-implicit ocean circulation model using a generalized topography-following coordinate system. **Journal of Computational Physics**, v. 115, n. 1, p. 228-244, 1994.

TILBURG, C. E. (2003). Across-shelf transport on a continental shelf: Do across-shelf winds matter?. **Journal of Physical Oceanography**, 33(12), 2675-2688.

WARNER, J. C., ARMSTRONG, B., HE, R., ZAMBON, J. B. (2010). Development of a coupled ocean–atmosphere–wave–sediment transport (COAWST) modeling system. **Ocean modelling**, 35(3), 230-244.

WENG, F., LIU, Q. (2003). Satellite data assimilation in numerical weather prediction models. Part I: Forward radiative transfer and Jacobian modeling in cloudy atmospheres. **Journal of the atmospheric sciences**, 60(21), 2633-2646.

WYNGAARD, J. C. (2010). *Turbulence in the Atmosphere*. Cambridge University Press.

XUE, M., DROEGEMEIER, K. K., WONG, V. (2000). The Advanced Regional Prediction System (ARPS)—A multi-scale nonhydrostatic atmospheric simulation and prediction model. Part I: Model dynamics and verification. **Meteorology and atmospheric physics**, 75, 161-193.

ZHANG, W., ZHANG, Z., CHEN, X. (2012). Three-dimensional elastic wave numerical modelling in the presence of surface topography by a collocated-grid finite-difference method on curvilinear grids. **Geophysical Journal International**, 190(1), 358-378.

ZHANG, Y. J., ATELJEVICH, E., YU, H. C., WU, C. H., JASON, C. S. (2015). A new vertical coordinate system for a 3D unstructured-grid model. **Ocean Modelling**, 85, 16-31.

Aspectos sobre a modelagem de ondas

André Lanfer Marquez
Luís Felipe Ferreira de Mendonça
Fernanda Casagrande
Regiane Moura

RESUMO

As ondas oceânicas são um importante e complexo componente do sistema climático. A modelagem das ondas oceânicas é essencial para uma ampla gama de aplicações. Incluindo a segurança das atividades marítimas, engenharia costeira, previsão de tempo e eventos extremos. Neste capítulo abordam-se aspectos importantes sobre as propriedades básicas das ondas do mar, geração e propagação, estado do mar e clima das ondas e aspectos sobre a modelagem regional das ondas oceânicas.

INTRODUÇÃO

A superfície relativa dos oceanos cobre uma grande porção da superfície do nosso planeta Terra. Nesta vasta e ampla superfície, dois fluidos entram em contato e interagem entre si, ou seja, a atmosfera se inter-relaciona com os oceanos através desta interface. As trocas que ocorrem através da interação oceano-atmosfera, conectam a porção inferior da atmosfera, ou Camada Limite Planetária (CLP), com a porção superior dos oceanos, também chamada de Camada de Mistura Oceânica (CMO). Esta interação se dá por meio de troca de fluxos, sejam eles de calor latente e sensível, bem como de momentum, sendo que estes fluxos estabelecem um maior ou menor acoplamento entre o oceano e atmosfera, representando, desta forma processos chave no sistema climático (Well, 2014).

O gradiente entre a temperatura da baixa atmosfera (Tar) e a temperatura da superfície do mar (TSM), a diferença de velocidades entre o vento e as correntes marítimas, a rugosidade da superfície do mar acarretam em diferentes graus de acoplamento entre ambos os meios. Ainda, as umidades relativa e absoluta do ar, a concentração de gases, fluxos de calor e energia, e a presença de gelo marinho também afetam o acoplamento entre o oceano e atmosfera.

Independente do processo de acoplamento oceano-atmosfera analisado, as ondas existentes na superfície marinha condicionam essas trocas. De fato, as ondas estão presentes em todos os fenômenos físicos e podem ser entendidas como o meio pelo qual se movimenta a energia



intrínseca aos processos físicos. Segundo Sato (2023): “As ondas são resultantes de uma combinação entre forças restauradoras que tendem a trazer o sistema de volta ao seu estado inicial de repouso e da inércia que o faz ultrapassar a posição que se encontrava quando em repouso”.

Um dos resultados, e ao mesmo tempo condicionante, decorrente da interação entre o oceano e a atmosfera são as ondas de gravidade superficiais que se formam nos oceanos geradas pelo vento. Essas ondas possuem como força restauradora a gravidade. Entendemos como força restauradora a força que age para que o sistema volte ao equilíbrio. Considerando que as ondas na superfície do oceano são perturbações em relação a uma superfície em repouso, a força da gravidade age para atenuar, e por fim anular progressivamente as ondas superficiais.

Entre todos os possíveis movimentos que ocorrem na superfície do mar, as ondas superficiais de gravidade são as que possuem maior energia. Uma análise detalhada dos movimentos que existem na CMO revela que a energia associada a estes movimentos se distribui principalmente entre as frequências de 10^2 à 10^{-7} Hz. É relevante observar que a distribuição de energia nas diferentes frequências não é uniforme, variando substancialmente, com algumas frequências apresentando níveis significativamente mais elevados de energia do que outras. A figura 1 apresenta a distribuição da quantidade de energia existente para as diversas frequências de movimento, bem como a identificação dos mecanismos geradores e restauradores associados a cada tipo de movimento. Observa-se uma grande quantidade de energia associada às frequências (3-30 segundos) características das ondas de gravidade superficiais geradas pelo vento.

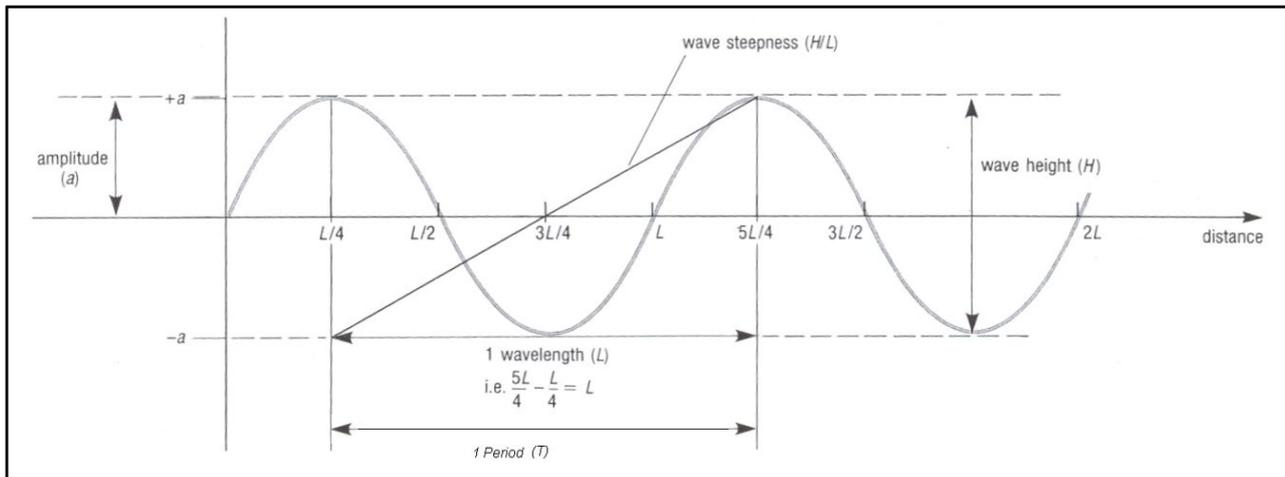
A investigação das ondas na superfície do mar pode ser conduzida utilizando diversas teorias, sendo a teoria linear a abordagem mais utilizada. Neste capítulo abordam-se as propriedades básicas das ondas do mar, geração e propagação de ondas, clima de ondas e modelos regionais de ondas e sua evolução.

PROPRIEDADES BÁSICAS DAS ONDAS DO MAR

Existem vários tipos de ondas que são geradas e propagadas na superfície dos oceanos. Segundo a teoria linear de ondas, pode-se definir propriedades básicas destas ondas. Levando em consideração uma onda idealizada, na forma de uma senoide apresentada na figura 1, pode-se definir o ponto de máxima elevação de uma onda como sendo a crista da onda, o ponto de mínima elevação como sendo o cavado ou a base da onda. A distância entre duas cristas consecutivas é denominada de comprimento de onda (L) e a distância vertical entre a base da onda e a crista pode ser entendida como sendo a altura de onda (H). A distância entre a crista ou cavado até o nível médio em repouso se denomina amplitude de onda (a). A razão entre a altura de onda e o comprimento de onda (H/L) se denomina esbeltez de onda. O período (T) pode ser definido como o tempo gasto para que duas cristas sucessivas passem pelo mesmo ponto no espaço, já a frequência de onda (f) é o inverso do período ($1/T$). A celeridade de onda, ou simplesmente velocidade de fase (c_f) se relaciona com o comprimento e o período pela relação $c_f = L/T$ e pode ser entendida como a velocidade de propagação de uma onda individual. Em águas profundas,

ou seja, onde a onda não sente o fundo, ou simplesmente quando a profundidade (h) é muito maior que a metade do comprimento de onda, pode-se definir a celeridade para águas profundas como sendo $c = \sqrt{gT/2\pi}$, sendo g a força de gravidade. O número de onda (k) é definido como sendo $k = 2\pi/L$ e por fim a frequência angular (σ) é definida como $\sigma = 2\pi/f$ (Kinsman, 1984; Massel, 1996).

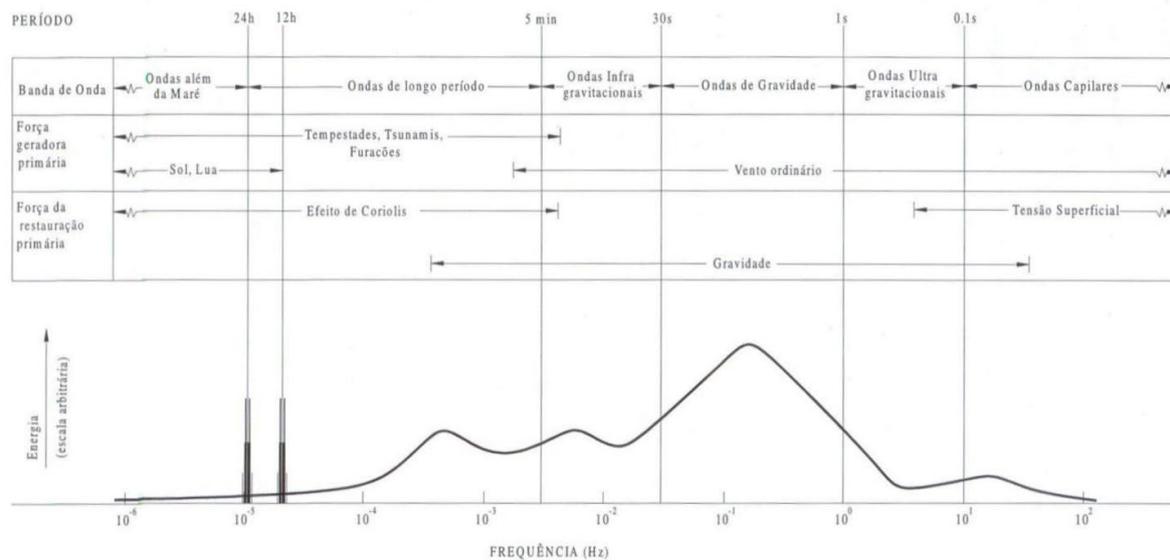
Figura 1 - Parâmetros básicos para ondas uniformes senoidais.



Fonte: Adaptado de Open University (1994)

A superfície do mar é suscetível a uma variedade de influências externas, como a atração gravitacional exercida por corpos celestes, como o Sol e a Lua, a força de *Coriolis*, resultante da rotação da Terra, as forças do gradiente de pressão atmosférico, a força de arrasto do vento, e os efeitos decorrentes da tensão superficial. Todas estas forças têm capacidade de gerar ondas na superfície marinha, que se manifestam em diversas escalas espaciais e temporais. Em termos das escalas espaciais, estas ondas podem variar desde alguns milímetros até dezenas ou centenas de quilômetros, para os fenômenos das marés astronômicas, se nota a grande amplitude de fenômenos relacionados. Na escala temporal, a gama de variação é igualmente notável, abrangendo desde ondas com períodos menores que um segundo, como as ondas capilares, até oscilações que se estendem por horas, como as marés (Alfredini e Arasaki, 2009). As ondas no mar apresentam forças geradoras, comportamentos de propagação e forças restauradoras distintas. A figura 2 mostra uma classificação dos tipos de ondas encontradas nos oceanos com base nestes parâmetros. Destaca-se a concentração de energia na faixa das ondas cuja força de restauração é a gravidade (1s – 30s). Tratando-se das ondas de curto período, cujas forças restauradoras compreendem tanto a gravidade quanto a tensão superficial, a ação do vento é a principal força geradora primária. Em outras palavras, o atrito ou a tensão de cisalhamento do vento na superfície do mar é uma das grandes fontes de transferência de energia entre a atmosfera e os oceanos, onde parte desta energia é responsável pela geração e manutenção das ondas na superfície do mar. Aqui, o enfoque será especificamente nas ondas de gravidade geradas pelo vento, caracterizadas por períodos típicos entre 1 a 30 segundos.

Figura 2 - Classificação do tipo de onda, força geradora primária e força de restauração, para diferentes períodos.



Fonte: Alfredini e Arasaki (2009)

GERAÇÃO E PROPAGAÇÃO DAS ONDAS

A formação de ondas de superfície geradas pelo vento ocorre através de uma série de processos físicos. O principal processo é o de transferência de energia entre a atmosfera e a superfície marinha através da tensão de cisalhamento. Entretanto, outros processos também são muito importantes, tais como, variações e oscilações do campo de pressão, interações não-lineares entre as componentes de ondas e processos dissipativos. Segundo sugerido por Jeffreys (1925), as cristas das ondas causam regiões de sombras criando pequenas diferenças de pressões e estas acabam por alimentar as ondas com a energia do vento. Esta explicação parece bastante válida para ondas a partir de um certo tamanho, entretanto não explicam o início da geração das ondas. Imaginando uma superfície marinha completamente em repouso, a ação do vento, num primeiro momento, causa o aumento da rugosidade da superfície do mar, criando as primeiras ondas de frequências mais altas. Isto ocorre devido as micro flutuações de pressão na superfície causadas pela turbulência do vento como apontado por Phillips (1957). Outro processo responsável pela formação das ondas seria o mecanismo de acoplamento linear instável entre as ondas de superfície e o fluxo médio atmosférico da camada limite planetária (Miles, 1957).

Estas primeiras ondas, com tamanhos de alguns milímetros até alguns centímetros, são conhecidas como ondas capilares, cujo mecanismo de restauração é a tensão superficial que ocorre na superfície do meio aquático. Com a continuidade do vento, pequenas rugosidades vão se tornando ondas maiores com direções de propagação, alturas, períodos e comprimentos de ondas variados. Neste momento a interação não-linear entre as ondas individuais é bastante importante, amplificando os mecanismos de crescimento das ondas (Stiassnie, 2012).

As ondas dentro de sua área de geração são denominadas de vagas. O crescimento

das ondas dentro da área de geração se relaciona com a velocidade do vento, com a duração deste vento e com o tamanho da área em que ele sopra (pista de vento). A partir de um certo momento as alturas das ondas atingem uma estabilidade, devido ao equilíbrio entre a velocidade do vento e a velocidade de propagação das ondas. Em última análise, a taxa de transferência de energia vento-onda depende muito da diferença de velocidades entre as ondas e o vento, tendo um pico quando as ondas se deslocam até aproximadamente um terço da velocidade do vento (Kinsman, 1984). Quando há esse equilíbrio considera-se que as ondas atingiram um estágio completamente desenvolvido (Craik, 2005).

Embora na teoria esse equilíbrio entre a velocidade do vento e a velocidade de propagação das ondas marinhas é atingido sempre, na prática isso raramente acontece devido a natureza caótica e variante dos ventos. Desta forma, espera-se que ondas de variados tamanhos e períodos sejam geradas mesmo após um longo intervalo de tempo. Pode-se inferir o quão bem organizadas estão as ondas ou qual é o grau de desenvolvimento de um grupo de ondas através do termo idade da onda. Este termo é definido pelo quociente da velocidade média de fase pela velocidade do vento atuante.

As vagas ao moverem-se para fora da área de geração, ou seja, onde o papel desempenhado pela ação do vento local não é mais atuante, continuam a interagir entre si e se agrupam segundo suas características (Laing, 1996). Neste contexto, a busca pelo equilíbrio com a força restauradora passa a desempenhar o papel principal como condição governante.

A propagação das ondas sofre influência da profundidade local em que se encontram. De uma forma geral, podemos classificar as profundidades por onde as ondas se propagam em 3 categorias: águas profundas, onde as ondas não sentem e não são afetadas pela batimetria; águas intermediárias, onde as ondas começam a interagir com o leito marinho (seja perdendo energia por fricção, seja modificando a sua trajetória por refração ou diminuindo o seu comprimento de onda e por consequência aumentando sua esbeltez); e águas rasas, nas quais os processos mencionados anteriormente para águas intermediárias se acentuam (tabela 1).

Tabela 1 - Critérios de classificação para comportamentos de propagação (adaptado de (Alfredini e Arasaki, 2009))

Classificação	Critério $\frac{h}{L}$
Água profunda	$> \frac{1}{2}$
Água intermediária	$\frac{1}{25}$ a $\frac{1}{2}$
Água rasa	$< \frac{1}{25}$

Em oposição às vagas presentes nas áreas de geração de onda, os marulhos ou ondulações (*swell*), são ondas que se afastaram da área de sua geração e estão se

propagando em uma direção. Após um estágio inicial de acomodação, estas ondulações apresentam características distintas, incluindo cristas e cavados bem definidos, um padrão de direção de propagação e velocidades de propagação que são bem determinadas pelas componentes de ondas existentes dentro desta ondulação (Kinsman, 1984).

ESTADO DE MAR

Através de um registro de ondas pode-se facilmente perceber que existem uma grande gama de ondas de diferentes alturas e períodos. Portanto, seria interessante caracterizar um determinado intervalo de tempo com as condições de ondas presentes. A esta caracterização denomina-se *Estado de Mar* (Alfredini e Arasaki, 2009).

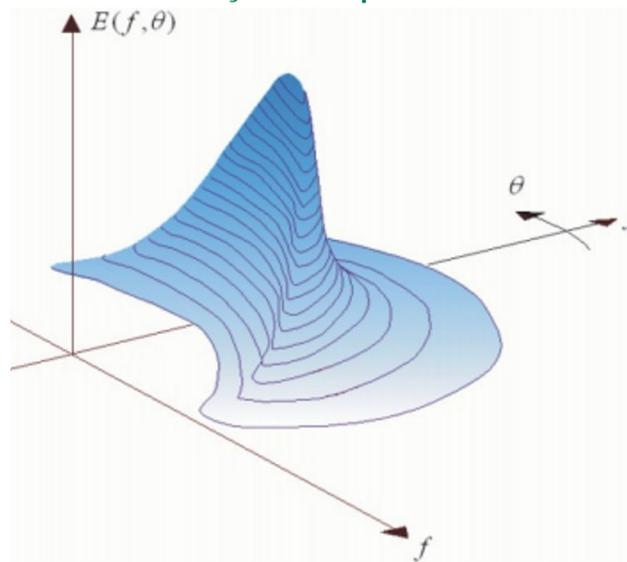
De uma forma generalista, e baseada na teoria linear de ondas, pode-se imaginar que um determinado estado de mar seja composto por um conjunto de componentes harmônicas individuais. Ou seja, uma condição de mar com ondas irregulares pode ser compreendido como sendo a somatória linear de diferentes componentes de ondas regulares (Hasselmann *et al.*, 1973). Desta forma, um determinado estado de mar pode ser representado pelo seu espectro de ondas, assumindo que durante o intervalo de tempo considerado haja uma certa estacionalidade nas distribuições estatísticas dos parâmetros de ondas. Valores típicos de intervalo de tempo onde se pode assumir uma *quasi* estacionalidade variam entre 15 minutos e 3 horas dependendo da aplicação (Holthuijsen, 2009). O espectro de ondas, e por consequência seu espectro de energia, pode ser obtido identificando as ondas individuais de um registro *in situ* seguido de uma análise harmônica simples (transformada de Fourier), onde é determinada a quantidade de observações de alturas pelas diversas frequências existentes na série temporal original. Desta forma, obtém-se um espectro de ondas a partir de uma série temporal de dados observados de altura de onda.

A energia de onda pode ser calculada individualmente através da equação:

$$E = \frac{1}{8} \rho g H^2 \quad (1)$$

Onde, ρ é a densidade da água, g é a força de gravidade e H é a altura de onda. Portanto, pode-se calcular o espectro de energia, ou o espectro de ondas unidirecional, ao integrar esta formulação por todas as componentes (frequências) de ondas de um estado de mar. Como as ondas de um determinado estado de mar obedecem relativamente bem os pressupostos da distribuição estatística de Rayleigh, pode-se agrupar as ondas e definir parâmetros estatísticos descritivos deste estado de mar. Adicionando mais um grau de liberdade, ou seja, informações das direções de propagação das ondas, pode-se obter o espectro bi-dimensional. Neste caso, a energia é distribuída por frequências e direções. A figura 3 mostra um exemplo de espectro bidimensional.

Figura 3 - Exemplo de espectro bidimensional com espalhamento de energia pelas direções e frequências.



Fonte. Adaptado de HOLTHUIJSEN (2009)

Portanto, partindo do espectro de ondas, pode-se definir os parâmetros estatísticos básicos delas, tais como: altura média, altura máxima, altura significativa, período médio, período de pico, etc. Além da definição clássica, na qual a altura significativa de ondas pode ser descrita como a altura que representa ao um terço das maiores ondas, a altura significativa de ondas pode ser definida através de quatro vezes a raiz quadrada da ordem de momento zero. Como mostrado na equação.

$$H_s = 4\sqrt{m_0} \quad (2)$$

E as ordens de momento j , por sua vez podem ser calculadas através do espectro, pela formulação (3) abaixo:

$$m_j = \int_0^{\infty} f^j E(f) df \quad (3)$$

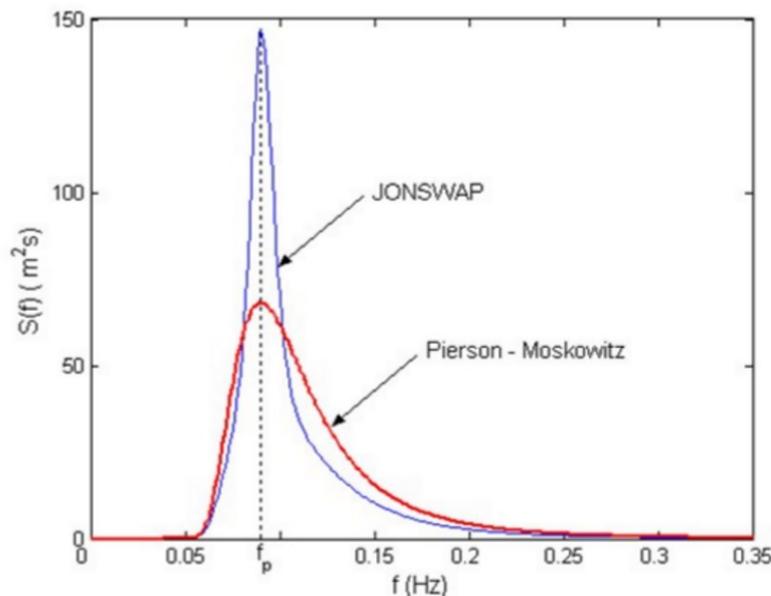
A altura significativa é uma das medidas mais utilizadas pois acredita-se que representa muito bem o que um observador humano vê ao se deparar com um certo estado de mar.

Hasselmann *et al.* (1973), dentro do projeto Joint North Sea Wave Project (JONSWAP), por meio de ondógrafos, estabeleceu uma distribuição característica do espectro de ondas unidirecional para estados de mar quase totalmente desenvolvidos, baseados apenas nos valores espectrais encontrados e um parâmetro α constante, baseados na distribuição de Pierson-Moskowitz (figura 4). Este coeficiente é o coeficiente de Charnock amplamente utilizado até os dias de hoje, para quantificar a os fluxos de momentum entre a atmosfera e os oceanos. A baixo segue a equação de distribuição de Jonswap:

$$E(f) = \alpha g^2 (2\pi)^{-4} f^{-5} \exp\left[-\frac{5}{4}\left(\frac{f}{f_p}\right)^{-4}\right] \gamma \exp\left[-\frac{1}{2}\left(\frac{f-f_p}{\delta f_p}\right)^2\right] \quad (4)$$

Onde, $\alpha = 0,008$; $\gamma = 3,3$; f_p é a frequência associada ao período de pico do espectro de onda. A figura 4 mostra uma diferença na forma do espectro unidimensional de ondas entre as distribuições de Jonswap e Pierson. Pode-se perceber que a distribuição de Pierson possui um espalhamento maior da energia contida num estado de mar, ou seja, a energia está mais espalhada em direção às frequências maiores, revelando um estado de mar menos desenvolvido. Por sua vez, o espectro de Jonswap concentra sua energia ao redor da frequência de pico do espectro.

Figura 4 - Distribuições espectrais características calculadas pelas formulações de Jonswap e Pierson-Moskowitz.



Fonte: www.meted.ucar.edu

CLIMA DE ONDAS

Para o desenvolvimento sustentável de atividades econômicas nas zonas costeiras e em mar aberto, são necessárias informações de longo período das condicionantes ambientais, tais como o clima de ondas, e um plano coerente de atuação (Soares, 2008). Como visto anteriormente, os parâmetros espectrais de ondas podem ser inferidos para um período de tempo curto onde haja uma relativa estacionalidade, determinando desta forma um estado de mar numa determinada localidade.

Para inferir a variabilidade das ondas são necessários dados sobre os parâmetros de ondas que se deseja analisar. De forma geral, pode-se dividir os dados em quatro categorias: dados observacionais, dados instrumentais *in situ*, dados instrumentais obtidos de forma remota (i.e. altímetros embarcados em satélites) e dados de modelos numéricos e estatísticos.

Os dados observacionais são aqueles obtidos por meio de um observador, ou seja, uma pessoa treinada que ao olhar para o mar consiga estimar de forma média a altura, período e direção das ondas. A principal fonte destes dados são os barcos e navios em rota, que observam e tomam nota das características das ondas que encontram pelo caminho. Muito se questiona sobre a qualidade destes dados (Gulev, 2003), sendo bastante comum

subestimativas de eventos extremos, bem como superestimativas em condições de mar de vento (Balsillie e Carter, 1984). Além disso, esses tipos de dados não apresentam uma homogeneidade, não sendo classificados nem como espaciais nem temporais (uma vez que não há a formação de séries temporais) e, os navios geralmente adotam rotas preestabelecidas.

Dados instrumentais *in situ* são aqueles que registram informações sobre os parâmetros de ondas localmente. Bóias meteo-oceanográficas e sensores de pressão são os equipamentos mais comuns e podem ser encontrados em diversas localidades, existindo alguns programas bastante robustos que mantêm redes de boias de forma operacional (Meindl e Hamilton, 1992; Fanjul *et al.*, 2003). Entretanto, sofrem com a grande variabilidade de cobertura espacial, existindo grandes regiões sem um único instrumento fundeado. A cobertura temporal também é deficitária, uma vez que a manutenção destes instrumentos é bastante dispendiosa, mesmo que algumas agências tenham conseguido manter equipamentos por relativos longos períodos. Além disto, uma parcela considerável destes equipamentos pertencem à iniciativa privada e a disponibilização dos dados nem sempre é uma realidade.

Embora os dados instrumentais *in situ*, de uma forma geral, serem bastante precisos e poderem servir para validação de modelos em águas profundas, seu uso para estudos climáticos é questionável. Alguns autores, utilizando dados de ondógrafos, tem estabelecido climatologias locais. Uma aplicação direta destes dados, ocorre em regiões costeiras, onde há a necessidade de estimar parâmetros de ondas para fins de engenharia.

Os dados coletados por altímetros de satélite são relativamente recentes, hoje algo em torno de 25 anos, mas fornecem dados com uma boa precisão, apesar da necessidade de calibração (Alves e Young, 2003), e ampla distribuição espacial. Porém, dados de satélites; devido as suas trajetórias, não constituem séries temporais homogêneas, sendo que a repetição de um mesmo ponto no oceano somente ocorra com uma baixa frequência. Esta característica dificulta a elaboração de climatologias robustas.

Base de dados de altímetros podem ser utilizados para validação de modelos numéricos e estatísticos (Dimitrova *et al.*, 2013), uma vez que existe uma grande confiabilidade nos seus dados.

Muitos estudos de climatologia de ondas se baseiam na utilização de modelos numéricos. Alguns projetos de reanálise dos grandes centros incluem as variáveis de ondas em suas distribuições (Sterl *et al.*, 1998), outros provêm os campos forçantes necessários para que seja construída a reanálise de ondas, por meio de modelos de geração e propagação de ondas (Swail e Cox, 2000; Soares *et al.*, 2002).

A partir destes conjuntos de reanálise e reconstrução de climas passados, muitos estudos de variabilidade dos parâmetros de ondas foram conduzidos ao longo do tempo (Young, 1999; Sotillo *et al.*, 2003; Caires e Sterl, 2005; Sterl e Caires, 2005). Variabilidades sazonais, inter-anuais, tendências de longo prazo, eventos extremos, correlação entre parâmetros de ondas e outras variáveis oceânicas e atmosféricas, enfim um grande leque de possibilidades existe nos estudos de climas de ondas.

Dentro das perspectivas de mudanças climáticas, o pré-requisito de estacionalidade

ao longo do tempo vem sendo quebrado, tanto para variáveis oceânicas com para variáveis atmosféricas, como apontado pelos estudos do IPCC (Houghton *et al.*, 1990; IPCC, 1996, 2001). Métodos estatísticos convencionais e projeções futuras baseadas em climatologias históricas perdem suas importâncias relativas frente a projeções que levem em conta novas tensões radiativas (Houghton *et al.*, 1992).

MODELOS REGIONAIS DE ONDAS OCEÂNICAS E SUA EVOLUÇÃO

A previsão de ondas desempenha um papel fundamental na determinação da segurança das atividades marítimas, na engenharia costeira e na previsão do impacto de sistemas meteorológicos, tsunamis e outros eventos que influenciam a geração de ondas. O desenvolvimento desses modelos remonta à década de 1960 e, desde então, eles passaram por uma evolução significativa. Os modelos regionais de ondas de primeira geração foram desenvolvidos nas décadas de 1960 e 1970 (Group, 1988). Naquela época, havia pouco conhecimento sobre o comportamento das ondas, e os pesquisadores se baseavam muito em suposições.

Estes modelos geralmente apresentavam deficiências e limitações que incluíam: (i) superestimativa do papel do vento no desenvolvimento das ondas; (ii) subestimativa das interações entre as ondas e (iii) representação incorreta das ondas impulsionadas pelo vento. Estas deficiências eram causadas principalmente devido a dificuldade dos modelos em representar os campos de vento que mudam rapidamente (como os dos ciclones tropicais e sistema frontais), bem como a falta de capacidade computacional que limitava e restringia significativamente o desempenho dos modelos. De acordo com Group (1988), a principal limitação dos modelos de primeira geração era sua falta de sofisticação, pois não conseguiam prever com precisão o comportamento das ondas, e seu desempenho era afetado por mudanças no vento. Ainda, os modelos eram incapazes de considerar a interação entre ondas de diferentes frequências. Estes modelos presumiam que as ondas de diferentes frequências eram independentes umas das outras. Com o passar dos anos e a evolução destes modelos regionais de ondas, surgiu a segunda geração na década de 1980. Esses modelos foram aprimorados em relação aos primeiros, mas ainda apresentavam problemas com a modelagem precisa de ondas de swell e ondas impulsionadas pelo vento.

A terceira geração de modelos, desenvolvidos a partir do final da década de 1980, apresentou uma melhoria significativa em relação aos modelos anteriores. Estes modelos usaram a equação de transporte de onda espectral para descrever a mudança no espectro da onda em uma topografia variável (Lavidas e Venugopal, 2018). A equação simula a geração de ondas, o movimento das ondas (propagação em um fluido), a formação de cardumes de ondas, a refração, a transferência de energia entre as ondas e a dissipação das ondas. A equação de transporte de onda espectral pode ser representada de forma geral da seguinte maneira:

$$\partial S / \partial t + U * \partial S / \partial x + V * \partial S / \partial y + W * \partial S / \partial z = -2 * \alpha * S \quad (5)$$

onde S é a função espectral que descreve o espectro da onda em função de sua frequência (f) e direção (θ). Em outras palavras, $S(f, \theta, t, x, y, z)$ é a distribuição de energia das ondas em um determinado ponto e tempo; t é o tempo, x, y, z são as coordenadas

espaciais; U , V e W são as componentes da velocidade do fluido na direção x , y e z , respectivamente; α é um coeficiente de atenuação que modela a dissipação de energia das ondas devido a vários processos, como a fricção do fundo do mar.

Esta equação descreve como o espectro de ondas (S) muda com o tempo (t) e a posição (x , y , z) devido à advecção pelas correntes do oceano (U , V , W) e à dissipação de energia (α). A equação é uma forma simplificada e generalizada da equação de transporte de onda espectral, que pode ser mais complexa dependendo dos detalhes do problema. A resolução numérica regional desta equação envolve discretizar as variáveis espaciais e temporais e usar métodos numéricos adequados, como os métodos de diferenças finitas ou métodos espectrais, para calcular a evolução do espectro de ondas ao longo do tempo e em diferentes posições na topografia variável.

Juntamente com a dissipação de energia por meio de ressonância entre as ondas, esses modelos usaram dados produzidos por modelos numéricos de previsão do tempo como entradas para determinar quanta energia é transferida da atmosfera para a camada na superfície do oceano (Kim *et al.*, 2003). Assim, a equação de transporte de ondas espectrais é baseada no conceito de densidade de energia espectral. A equação representa a evolução dos espectros de ondas de diferentes frequências e direções devido às interações com o oceano e outros processos físicos. A equação é resolvida numericamente, usando uma variedade de métodos numéricos, incluindo a transformada de Fourier, o método de elementos finitos e o método de diferenças finitas (Gray e Pinder, 1976). A equação de transporte de ondas espectrais baseia-se no conceito de densidade de energia espectral e descreve a evolução dos espectros de ondas de diferentes frequências e direções devido a várias interações físicas, como a propagação da onda, a dissipação de energia, a refração e a reflexão (JANSSEN, 2008). A forma numérica da equação pode ser representada da seguinte maneira:

$$\partial S(f, \theta, t, x, y, z) / \partial t + \nabla(U * S(f, \theta, t, x, y, z)) = Q(f, \theta, t, x, y, z) \quad (6)$$

onde $S(f, \theta, t, x, y, z)$ é a densidade de energia espectral, que descreve a distribuição de energia das ondas em função da frequência (f), direção (θ) e coordenadas espaciais (x , y , z) em um determinado ponto e tempo, $\partial S / \partial t$ é a derivada parcial da densidade de energia espectral em relação ao tempo; ∇ representa o operador nabla, que descreve o gradiente espacial em relação às coordenadas (x , y , z), U é a velocidade do fluido, que pode variar em função das coordenadas espaciais e do tempo; $Q(f, \theta, t, x, y, z)$ é uma fonte ou sumidouro que representa os processos físicos que afetam o espectro de ondas, como a dissipação de energia devido à fricção do vento, refração devido a gradientes de velocidade e outros fenômenos.

A resolução numérica desta equação envolve discretizar as variáveis espaciais e temporais e usar métodos numéricos adequados para calcular a evolução dos espectros de ondas em diferentes frequências e direções ao longo do tempo e em diferentes posições no oceano (Gazdag, 1981). Esta solução numérica produz um histórico de tempo do espectro da onda, a partir do qual várias características da onda podem ser derivadas, incluindo altura, período, frequência e propagação direcional da onda. Em conclusão, os modelos de ondas oceânicas regionais percorreram um longo caminho desde seu desenvolvimento na década de 1960. No entanto, com o advento de novas tecnologias e a contribuição de

modelos numéricos de previsão do tempo, os modelos mais recentes de terceira geração tornaram-se mais precisos e sofisticados na previsão do comportamento das ondas no oceano.

REFERÊNCIAS

- ALFREDINI, P.; ARASAKI, E. **Obras e gestão de portos e costas: a técnica aliada ao enfoque logístico e ambiental**. 2. ed. rev. e ampl. São Paulo: Edgard Blücher, 2009.
- ALVES, J. H. GM; YOUNG, I. R. On estimating extreme wave heights using combined Geosat, Topex/Poseidon and ERS-1 altimeter data. **Appl. Ocean Res.**, v. 25, n. 4, p. 167-186, 2003.
- BALSILLIE, J. H.; CARTER, R. W. G. The visual estimation of shore-breaking wave heights. **Coastal Engineering**, v. 8, n. 4, p. 367–385, 1984.
- CAIRES, S.; STERL, A. 100-Year Return Value Estimates for Ocean Wind Speed and Significant Wave Height from the ERA-40 Data. **Journal of Climate**, v. 18, n. 7, p. 1032–1048, 2005.
- CRAIK, A. D. D. GEORGE GABRIEL STOKES ON WATER WAVE THEORY. **Annu. Rev. Fluid Mech.**, v. 37, n. 1, p. 23–42, 2005.
- FANJUL, E. A. *et al.* Real-time monitoring of Spanish coastal waters: The deep water network. **Elsevier Oceanogr. Ser.** Elsevier, p. 398-402, 2003.
- GULEV, S. K. Assessment of the reliability of wave observations from voluntary observing ships: Insights from the validation of a global wind wave climatology based on voluntary observing ship data. **J. Geophys. Res.**, v. 108, n. C7, 2003.
- HASSELMANN, Klaus *et al.* Measurements of wind-wave growth and swell decay during the Joint North Sea Wave Project (JONSWAP). **Dtsch. Hydrogr. Zeitschrift, Reihe A**, 1973.
- HOLTHUIJSEN, L. H. Waves in oceanic and coastal waters. **Digitally printed version ed. Cambridge: Univ.Pr**, 2009.
- HOUGHTON, J. T.; B. A. CALLANDER; S. K. VARNEY. **Climate Change 1992**. Cambridge: University Press, 1992.
- HOUGHTON, J. T.; JENKINS, G. J.; EPHRAUMS, J. J. Climate change: the IPCC scientific assessment. **American Scientist; (United States)**, v. 80, n. 6, 1990.
- IPCC. IPCC Second Assessment Report. 1996.
- IPCC. IPCC Third Assessment Report. 2001.
- JEFFREYS, H. On the Formation of Water Waves by Wind. Proc. R. Soc. A: **Math. Phys. Eng. Sci.**, v. 107, n. 742, p. 189-206, 1925.
- KINSMAN, B. Wind waves: their generation and propagation on the ocean surface. **New York: Dover Publications**, 1984.

LAING, A. K. Dynamics and modelling of ocean waves. By GJ Komen, L. Cavaleri, M. Donelan, K. Hasselmann, S. Hasselmann and PAEM Janssen. Cambridge University Press, Pp. 339, 1995. ISBN 0 521 470471, **Q. J. R. Meteorol. Soc.**, v. 122, n. 530, p. 564–565, 1996.

MEINDL, E. A.; HAMILTON, G. D. Programs of the National Data Buoy Center. **Bull. Am. Meteorol. Soc.**, v. 73, n. 7, p. 985–993, 1992.

MILES, J. W. On the generation of surface waves by shear flows. **Journal of Fluid Mechanics**, v. 3, n. 02, p. 185, 1957.

PHILLIPS, O. M. On the generation of waves by turbulent wind. **Journal of Fluid Mechanics**, v. 2, n. 05, p. 417, 1957.

SATO, O.. IOF1224-Ondas e Marés. Disponível em: <https://edisciplinas.usp.br/pluginfile.php/7548738/mod_resource/content/10/notes.pdf>. Acesso em 10 de outubro de 2023.

SOARES, C. G. Hindcast of Dynamic Processes of the Ocean and Coastal Areas of Europe. **Coastal Engineering**, v. 55, n. 11, p. 825–826, 2008.

SOARES, C. G. *et al.* **A 40 Year Hindcast of Wind, Sea Level and Waves in European Waters.** ASME, 2002. Disponível em: <<http://proceedings.asmedigitalcollection.asme.org/proceeding.aspx?articleid=1576353>>. Acesso em: 1 fev. 2016.

SOTILLO, M. G.; RATSIMANDRESY, A. W.; CARRETERO, J. C. A 40-YEAR ATMOSPHERIC HINDCAST FOR THE MEDITERRANEAN BASIN WITHIN THE HIPOCAS PROJECT. 2003.

STERL, A.; CAIRES, S. Climatology, variability, and extrema of ocean waves: the Web-based KNMI/ERA-40 wave atlas. **Int. J. Climatol.**, v. 25, n. 7, p. 963–977, 2005.

STIASSNIE, M. Fetch-limited growth of wind waves. **J. Geophys. Res.**, v. 117, 8, 2012.

SWAIL, V. R.; COX, A.T. On the use of NCEP–NCAR reanalysis surface marine wind fields for a long-term North Atlantic wave hindcast. **J. Atmos. Ocean. Technol.**, v. 17, n. 4, p. 532-545, 2000.

Assimilação de dados no contexto da Previsão Numérica do Tempo

Helena Barbieri de Azevedo

Fernanda Casagrande

Luís Felipe Ferreira de Mendonça

Rose Ane Pereira de Freitas

RESUMO

A assimilação de dados tem um papel fundamental para a geração de previsões numéricas de tempo de qualidade. Ela é capaz de gerar um determinado estado combinando informações de observações com informações de modelo, considerando seus erros. À medida que mais e mais observações foram surgindo, e que os modelos numéricos foram evoluindo, houve também uma evolução nos sistemas de assimilação de dados. Dessa forma, neste capítulo, será discutida a importância das observações e alguns sistemas de assimilação de dados serão brevemente apresentados.

INTRODUÇÃO

A assimilação de dados, no contexto da Previsão Numérica do Tempo (PNT), tem como objetivo, através de dados observacionais, corrigir uma previsão de curto prazo do modelo (*background*). Esse processo é realizado para que se obtenha uma condição inicial (também chamada de análise) adequada para o modelo numérico. Nela são levados em consideração as incertezas das observações e também os erros relacionados ao modelo. A análise representa o estado atual da atmosfera em um momento específico. Ela é representada pela equação 1, onde \mathbf{x}^a é o campo de análise, \mathbf{x}^b é o campo de *background*, \mathbf{K} é a matriz peso (também chamada de matriz Ganho de Kalman), \mathbf{y} é o vetor das observações e H é o operador observação (ele tem a função de levar o campo do espaço do modelo para o espaço das observações).

$$\mathbf{x}^a = \mathbf{x}^b + \mathbf{K}[\mathbf{y} - H(\mathbf{x}^b)] \quad (1)$$

A matriz Ganho de Kalman é calculada conforme a equação 2. Nela, \mathbf{B} é a matriz de covariância dos erros do *background*, \mathbf{H} é a matriz com diferenças entre as observações e o *background* e \mathbf{R} é a matriz de covariância dos erros das observações. Dependendo do sistema de assimilação de dados, a matriz \mathbf{B} pode ser fixa ou variar conforme o que chamamos de “erros do dia”.



$$\mathbf{K} = \mathbf{B}\mathbf{H}^T(\mathbf{H}\mathbf{B}\mathbf{H}^T + \mathbf{R})^{-1} \quad (2)$$

Para que a assimilação de dados tenha sucesso, não depende apenas do sistema de assimilação que é utilizado, ele depende também do modelo de PNT e das observações que são utilizadas. Atualmente, os métodos mais utilizados pelos centros operacionais são mais sofisticados quando comparados aos primeiros que surgiram, como, por exemplo, os métodos variacionais 3DVar e 4DVar, métodos por conjunto como EnKF (*Ensemble Kalman Filter*) e ainda os sistemas híbridos. Esses sistemas serão discutidos com maiores detalhes nas seções seguintes assim como uma breve discussão sobre os dados.

OBSERVAÇÕES E SEUS IMPACTOS

As observações possuem um papel fundamental no processo de assimilação de dados, afinal, elas são utilizadas para “corrigir” o estado do modelo numérico. Desde de que a primeira previsão de tempo foi reportada com sucesso houve um aumento significativo dos dados observacionais, porém é importante mencionar que não é apenas a quantidade de dados que interfere na qualidade da análise, a qualidade desses dados também.

Com o passar do tempo, esses sistemas de observações passaram de apenas medições diretas como de temperatura e vento, obtidas via estações SYNOP, radiossondas e até mesmo boias, para as observações indiretas, contendo os inúmeros dados de temperatura de brilho obtidos via sensoriamento remoto, por exemplo. No Centro Europeu de Previsão de Tempo de Médio Prazo (da sigla em inglês ECMWF) (ECMWF, 2023), por exemplo, se processa rotineiramente dados de cerca de 90 instrumentos de satélite como parte das suas atividades operacionais diárias de assimilação e monitoramento de dados. Eles recebem no centro cerca de 800 milhões de observações diariamente, e 60 milhões de observações com qualidade controlada estão disponíveis diariamente para uso no sistema de previsão.

Com o expressivo aumento no número de observações se fez necessário a criação de técnicas para avaliar como interagem essas observações com sistemas de assimilação de dados em modelos de PNT e também como elas interagem entre si. A técnica mais difundida ao redor do mundo é chamada de OSE (do inglês *Observing System Experiment*). Esta é uma técnica onde, segundo Lupu *et al.* (2011), são inseridos novos sistemas de observação ou onde um ou mais sistemas de observação são retidos no processo de assimilação de dados (*data denial*) a fim de avaliar o impacto da inclusão ou exclusão de uma determinada observação na qualidade da previsão numérica de tempo, seja na análise ou na previsão. É uma técnica relativamente custosa, pois é necessário executar rodadas do modelo o número de vezes conforme o número de sistemas de observação que se quer avaliar. Azevedo *et al.* (2017) utilizaram essa técnica para avaliar o impacto dos dados de radiossonda, radiâncias provenientes dos sensores AMSU-A, MHS, HIRS-4, IASI e AIRS e, dados de GPS-RO, no sistema G3DVar no Centro de Previsão de Tempo e Estudos Climáticos do Instituto Nacional de Pesquisas Espaciais (CPTEC/INPE). Os autores encontraram um impacto de aproximadamente 24hs nas previsões para o hemisfério sul quando retiraram os dados de radiância. Esse tipo de resultado é observado pois grande parte do hemisfério sul é tomado por oceanos, o que dificulta a obtenção de dados, tornando os dados de satélite de extrema

importância para tal região. Já para o hemisfério norte esse impacto é menor, uma vez que nessa região existem outras fontes de dados que acabam suprimindo a falta dos dados de satélites, ou ainda, são mais importantes.

Um exemplo de como os dados podem afetar na rotina da previsão numérica de tempo foi visto em 2020 durante a pandemia de COVID-19. Durante um certo período da pandemia de COVID-19, muitos voos sofreram cancelamento. Grande parte deles, situados sobre o hemisfério norte. Por esse motivo, houve então um decréscimo no número de dados obtidos via aeronaves (aproximadamente 75%, segundo James *et al.* 2020). James *et al.* (2020) mostraram como os efeitos dessa falta de dados impactaram nas previsões numéricas de tempo da Administração Nacional Oceânica e Atmosférica (da sigla em inglês NOAA) dos Estados Unidos.

Outra técnica que é utilizada para avaliar impacto de observação nas previsões é a chamada FSO (do inglês *Forecast Sensitivity to the Observations*) (Kunii *et al.*, 2012). Essa metodologia fornece uma avaliação quantitativa das contribuições de todas as observações assimiladas durante um ciclo de assimilação sem a necessidade de realizar experimentos de dados negados ou adicionados, como a metodologia descrita anteriormente. Os resultados obtidos podem ser classificados de acordo com variados critérios: tipo de instrumento, variável observada, região geográfica, nível vertical e outros. No CPTEC, Diniz (2012) implementou essa técnica no sistema LETKF/CPTEC e verificou o impacto dos diversos tipos de observações no ciclo de assimilação de dados em suas previsões de curto prazo.

TÉCNICAS DE ASSIMILAÇÃO DE DADOS

Sistemas de assimilação de dados variacionais

A abordagem variacional surgiu devido a uma necessidade de se levar em consideração os erros associados ao modelo numérico e também em utilizar observações assintóticas. Nessa abordagem o objetivo é minimizar uma função custo J na qual determina a menor distância entre dados modelados e dados observados, levando em consideração seus erros. O mínimo dessa função é encontrado quando $\mathbf{x} = \mathbf{x}^a$, sendo chamado de análise ótima e corresponde ao estado de maior probabilidade, também levando o nome de melhor estimativa (Kalnay, 2003).

Para um sistema de assimilação de dados 3DVar, por exemplo, a função custo J é dada pela equação 3, onde \mathbf{x} é o campo de análise, \mathbf{x}^b é o campo de *background*, \mathbf{y} é o vetor de observações, \mathbf{B} é a matriz de covariância dos erros do *background*, \mathbf{R} é a matriz de covariância dos erros das observações e H é o operador observação. Espera-se encontrar um valor para $\mathbf{x} = \mathbf{x}^a$ que resulte em um menor valor para a função J . Para isso, é calculado o gradiente da função (equação 4) de modo iterativo.

$$J(\mathbf{x}^a) = (\mathbf{x}^a - \mathbf{x}^b)^T \mathbf{B}^{-1}(\mathbf{x}^a - \mathbf{x}^b) + (\mathbf{y} - H(\mathbf{x}^a))^T \mathbf{R}^{-1}(\mathbf{y} - H(\mathbf{x}^a)) \quad (3)$$

$$\nabla J(\mathbf{x}^a) = 2\mathbf{B}^{-1}(\mathbf{x}^a - \mathbf{x}^b) - 2\mathbf{H}^T \mathbf{R}^{-1}(\mathbf{y} - H(\mathbf{x}^a)) \quad (4)$$

Existe também uma variação do 3DVar, conhecida como 3DVar-PSAS (Da Silva *et al.* 1995). Sua grande diferença é que a minimização é calculada no espaço das

observações e não mais no espaço do modelo como feito pelo 3DVar tradicional. Por esse motivo, se torna difícil a utilização de dados não-convencionais, como por exemplo, dados de radiâncias pelo 3DVar-PSAS.

O 4DVar, por sua vez, é uma generalização do 3DVar para as observações que estão distribuídas irregularmente no tempo. O 3DVar considera que as observações na janela de assimilação são todas válidas no mesmo tempo, o 4DVar leva em consideração o momento em que a medição foi realizada. Utiliza-se as mesmas equações do 3DVar, porém, o operador observação é generalizado para incluir o tempo, permitindo comparações entre os estados do modelo e as observações no seu tempo, conforme apresentado na equação 5. Nela, o índice i representa o tempo em que qualquer observação está disponível.

$$J(\mathbf{x}^a) = (\mathbf{x}^a - \mathbf{x}^b)^T \mathbf{B}^{-1} (\mathbf{x}^a - \mathbf{x}^b) + \sum_{i=0}^n (\mathbf{y}_i - H_i(\mathbf{x}^a_i))^T \mathbf{R}_i^{-1} (\mathbf{y}_i - H_i(\mathbf{x}^a_i)) \quad (5)$$

A primeira motivação para a criação de um sistema de assimilação de dados 4DVar foi a necessidade de utilizar dados assínóticos em seu devido tempo. Ele é um sistema complexo, envolvendo latitude, longitude, altura e tempo, e ainda apresenta um custo computacional alto, pois necessita um modelo adjunto e um tangente linear. O modelo adjunto é utilizado para obter os erros do modelo. De acordo com Kalnay (2003), existe uma equivalência entre as análises geradas pelo 4DVar e pelas geradas pelo Filtro de Kalman. Em Bouttier e Courtier (1999), essa afirmação é discutida em detalhes. Para maiores informações sobre os sistemas variacionais, pode-se encontrar em Bouttier e Courtier (1999). Nessas notas de aula, os autores fazem uma compilação de diversos materiais sobre os métodos variacionais.

Sistemas de assimilação de dados por conjunto

Os métodos de assimilação de dados por conjunto surgiram como uma evolução das técnicas tradicionais de assimilação de dados, como a assimilação variacional. Esses métodos foram desenvolvidos para lidar com as limitações e desafios enfrentados pelas abordagens mais antigas, especialmente em contextos onde a incerteza é alta e as complexidades dos sistemas são mais evidentes. Os sistemas por conjunto são abordagens que utilizam múltiplas simulações (ou o que chamamos de membros) de um modelo numérico para melhor representar a incerteza nas previsões e estimar o estado atual de um sistema. Esses métodos têm como objetivo combinar informações dos modelos de previsão com as observações disponíveis de maneira apropriada, considerando a variabilidade e as incertezas inerentes aos modelos e às observações.

Os métodos por conjunto mais utilizados na PNT são os métodos baseados em Filtragem de Kalman (Kalman, 1960). A primeira abordagem para lidar com os sistemas não-lineares foi proposta na década de 1990 por Evensen (1994): o EnKF, sendo hoje muito utilizado para aplicações realistas com modelos de equações primitivas para oceano e atmosfera. Nesse sistema, é criado um conjunto de perturbações que é adicionado, por exemplo, às observações que são assimiladas por cada membro do estado inicial. Depois disso, cada um dos estados iniciais são usados para integrar o modelo e criar uma previsão por conjunto subsequente que será usada como *background* para o próximo conjunto de análises. Depois do surgimento do EnKF, outros sistemas similares foram explorados como o *Ensemble Transform Kalman Filter* (ETKF) (Bishop *et al.*, 2001), o *Ensemble Square*

Root Filter (EnSRF) (Whitaker; Hamill, 2002) e o *Local Ensemble Transform Kalman Filter* (LETKF).

Em 2001, Bishop *et al.* (2001) propuseram o ETKF, porém, alguns anos depois, em 2004 essa metodologia sofreu algumas modificações (Wang *et al.*, 2004). Uma das vantagens desse sistema (computacionalmente mais rápido que o EnSRF) é que ele é capaz de calcular rapidamente a covariância do erro do *background*. O equacionamento desses sistemas (EnKF, ETKF e EnSRF) é bem apresentado em Petrie (2008). No ano de 2004, o parâmetro de localização foi inserido nesses sistemas, surgiu então o LEKF (*Local Ensemble Kalman Filter*) (Ott *et al.*, 2004). Nele, a análise é calculada localmente no ponto de grade, usando as variáveis do estado do modelo e todas as observações em uma região centrada em cada ponto de grade, podendo ser esse sistema massivamente paralelizável.

Em 2007, Hunt *et al.* (2007) lançaram o LETKF. Esse sistema foi desenvolvido pelo Grupo *Weather and Chaos* da Universidade de Maryland. Desde sua criação, o LETKF foi testado utilizando observações sintéticas em um cenário de modelo perfeito (Harlim; Hunt, 2005; Liu *et al.*, 2008) e utilizando observações reais (Li *et al.*, 2007; Miyoshi; Sato, 2007). Szunyogh *et al.* (2008) e Whitaker *et al.* (2008) assimilaram dados convencionais em um modelo de baixa resolução do Centro Nacional de Previsão Ambiental (NCEP, sigla em inglês) dos Estados Unidos. Aravéquia *et al.* (2011) avaliaram estratégias para assimilar dados de radiâncias utilizando esse sistema.

A principal vantagem do LETKF em relação aos demais sistemas apresentados até aqui é a combinação da localização com a transformação aplicada ao processo de assimilação de dados. Ele ainda é computacionalmente mais eficiente e fornece uma flexibilidade na localização que é necessária para a assimilação de radiâncias de satélite. Ele resolve as equações localmente no espaço do modelo, dividindo o domínio do modelo em domínios locais, dessa forma, a equação da análise é calculada para cada um desses domínios, sendo essa uma vantagem para poder utilizar computação massivamente em paralelo. Outra vantagem é que o LETKF, diferente de alguns sistemas que usam a matriz de covariância do erro do *background* fixa, calcula a covariância do erro do *background* usando o conjunto de estados do modelo e atualiza a covariância em cada ciclo de assimilação. Por esse motivo, ele pode representar melhor os “erros do dia” dentro do sistema, permitindo uma solução mais adequada. Esses erros representam uma das principais fontes de incertezas do processo de modelagem como um todo.

Evensen (2003) apresenta uma revisão de toda a evolução do EnKF até o ano de 2003. Já Houtekamer e Zang (2016), apresentam uma revisão muito completa sobre o EnKF e suas variações, incluindo uma breve passagem pelo próximo tópico: os sistemas híbridos.

Sistemas híbridos

A assimilação híbrida, quando surgiu, visava incluir os “erros do dia” vindos de sistemas por conjunto em sistemas de assimilação de dados variacionais, através da combinação das matrizes de covariância dos erros do *background*, fazendo com que a matriz B do 3DVar se tornasse mais robusta. Ela surgiu em 2000, quando Hamill e Snyder

(2000) propuseram um sistema baseado no EnKF e no 3DVar utilizando um modelo quasi-geostrófico perfeito. Os autores calcularam uma nova matriz \mathbf{B} utilizando a equação 6. Nela, α é o peso atribuído aos sistemas ($0 \leq \alpha \leq 1$), \mathbf{P}^b é a matriz de covariância dos erros do *background* do EnKF e \mathbf{B}_{3DVAR} é a matriz de covariância dos erros do *background* do 3DVar.

$$\mathbf{B} = (1 - \alpha)\mathbf{P}^b + \alpha\mathbf{B}_{3DVAR} \quad (6)$$

Desde o surgimento dessa primeira versão, outras tantas foram desenvolvidas (Etherton e Bishop (2004), Wang *et al.* (2007), Zhang *et al.* (2009). Centros como NCEP, MetOffice e ECMWF utilizaram versões como as desenvolvidas por Wang *et al.* (2013), Clayton *et al.* (2013) e Bonavita *et al.* (2015), respectivamente. No Brasil, no CPTEC, Bastarz (2017) calculou uma nova matriz de covariância do *background* utilizando o EnKF, EnSRF e o 3DVar no Modelo de Circulação Geral da Atmosfera (MCGA) do CPTEC/INPE.

Em 2014, uma nova abordagem de sistema híbrido foi desenvolvida por Penny (2014). Ele sugeriu uma nova metodologia na qual a ideia principal é de utilizar a análise média gerada por um sistema por conjunto como o *background* utilizado por um sistema variacional e por fim realizar uma combinação linear entre ambas análises. O Híbrido Médio visa resolver a combinação linear apresentada na equação 7, onde \mathbf{x}_{HM}^a é a análise final, $\bar{\mathbf{x}}_{LETKF}^a$ é a análise média vinda do sistema de assimilação de dados por conjunto, \mathbf{x}_{3DVAR}^a é a análise vinda do sistema variacional utilizando o $\bar{\mathbf{x}}_{LETKF}^a$ como seu *background*. Por fim, o α que é o coeficiente de ajuste linear ($0 \leq \alpha \leq 1$).

$$\mathbf{x}_{HM}^a = (1 - \alpha)\bar{\mathbf{x}}_{LETKF}^a + \alpha\mathbf{x}_{3DVAR}^a \quad (7)$$

Essa metodologia foi implementada no início de 2015 no ECMWF por Bonavita *et al.* (2015). No CPTEC, Azevedo *et al.* (2020) adicionou um fator de ponderação para o α utilizando informações do espalhando gerado pelo LETKF, tornando-o dinâmico e variando conforme o tempo e o espaço.

Como os sistemas híbridos fornecem melhores resultados mesmo para conjuntos pequenos (dependendo da abordagem aplicada), esses métodos de assimilação de dados se tornaram atrativos para atividades operacionais e foi rapidamente reconhecido pela comunidade científica. Hoje em dia, ganhou espaço e é amplamente utilizado por centros de pesquisa e por centros operacionais de PNT (conforme já mostrado). Desses, o híbrido 4DVar-EnKF é atualmente um dos métodos híbridos mais utilizado por centros operacionais de PNT. Porém, apresenta duas deficiências principais: o complexo desenvolvimento e manutenção dos modelos tangente linear e adjunto e a combinação empírica dos resultados de 4DVar e EnKF. Dong *et al.* (2023), apresenta um novo método híbrido baseado em aprendizado de máquina (HDA-ML), que segundo os autores, supera essas desvantagens. De acordo com Dong *et al.* (2023) no novo método, os modelos tangente linear e adjunto na parte 4DVar do algoritmo híbrido podem ser facilmente obtidos usando uma rede neural bilinear para substituir o modelo de previsão, e um modelo de rede neural convolucional é adotado para fundir a análise de 4DVar e EnKF para obter adaptativamente o coeficiente de combinação ideal em vez do coeficiente empírico como no método híbrido tradicional.

CONSIDERAÇÕES FINAIS

A evolução dos sistemas de assimilação de dados anda lado a lado com a evolução dos modelos numéricos e com a evolução dos sistemas de observação (seja em quantidade, como em novas fontes). Os avanços na assimilação de dados estão permitindo um aproveitamento ainda melhor das observações, tanto na sua caracterização quanto na assimilação de alta frequência. Além disso, os métodos de aprendizado de máquina estão sendo introduzidos na comunidade de assimilação de dados em uma velocidade surpreendente, com muitos resultados promissores (Dong *et al.* (2023)).

Olhando para o futuro, pode-se especular alguns pontos por onde a assimilação de dados poderá percorrer para acompanhar a evolução da previsão numérica de tempo: (a) maior resolução espacial e temporal: os modelos de previsão numérica do tempo estão se tornando cada vez mais sofisticados, com resoluções espaciais e temporais mais altas. Isso exige uma assimilação de dados mais precisa para garantir que as informações observacionais sejam adequadamente incorporadas em modelos mais detalhados; (b) integração de novos tipos de dados: além das observações tradicionais, como os mencionados anteriormente, espera-se que a assimilação de dados incorpore informações de novas fontes, como sensores remotos, drones e sistemas de sensoriamento urbano. Isso aumentará a quantidade de informações disponíveis para serem trabalhadas pelos sistemas de PNT; (c) *machine learning* e inteligência artificial: o uso de técnicas de aprendizado de máquina e inteligência artificial na assimilação de dados está em crescimento. Essas abordagens podem ajudar a identificar padrões complexos nos dados observacionais e aprimorar a eficiência dos processos de assimilação; e (d) melhorias nos sistemas de assimilação: os métodos de assimilação de dados também estão evoluindo. Isso inclui o desenvolvimento de algoritmos mais avançados que possam lidar melhor com erros e incertezas inerentes ao processo.

Espera-se que, com o constante aprimoramento dos sistemas de PNT, seja possível obter melhores resultados e, com melhores previsões, ajudar a população e os tomadores de decisão em planos de contingência contribuindo para a capacidade de salvar vidas e mitigar danos significativos de eventos climáticos extremos.

REFERÊNCIAS

ARAVÉQUIA, J. A.; SZUNYOGH, I.; FERTIG, E. J.; KALNAY, E.; KUHL, D.; KOSTELICH, E. J. Evaluation of a strategy for the assimilation of satellite radiance observations with the local ensemble transform kalman filter. **Monthly Weather Review**, v. 139, n. 6, p. 1932–1951, 2011.

AZEVEDO, H. B. d.; GONÇALVES, L. G. G. d.; BASTARZ, C. F.; SILVEIRA, B. B. Observing system experiments in a 3DVAR data assimilation system at CPTEC/INPE. **Weather and Forecasting**, v. 32, n. 3, p. 873–880, 2017. ISSN0882-8156. Available from: <<http://journals.ametsoc.org/doi/10.1175/WAF-D-15-0168.1>>.

AZEVEDO, H. B. D.; GONÇALVES, L. G. G. D.; KALNAY, E.; WESPETAL, M. Dynamically weighted hybrid gain data assimilation: perfect model testing. **Tellus A: Dynamic Meteorology and Oceanography**, v. 72, n. 1, p. 1–11, 2020. Available from: <<https://doi.org/10.1080/16000870.2020.1835310>>.

- BASTARZ, C. F. **Assimilação de dados global híbrida por conjunto-variacional no CPTEC.** São José dos Campos, 275 p, 2017. Tese (Doutorado) - Instituto Nacional de Pesquisas Espaciais (INPE).
- BISHOP, C. H.; ETHERTON, B. J.; MANJUNDAR, S. J. Adaptive sampling with the ensemble transform kalman filter. part i: theoretical aspects. **Monthly Weather Review**, v. 129, p. 420–436, 2001.
- BONAVITA, M., HÓLM, E., ISAKSEN, L., FISHER, M. (2015). *The evolution of the ECMWF hybrid data assimilation system.* **Quarterly Journal of the Royal Meteorological Society**, 142(694), 287–303. doi:10.1002/qj.2652
- BOUQUIER, F.; COURTIER, P. **Data assimilation concepts and methods.** Disponível em: <https://www.ecmwf.int/sites/default/files/elibrary/2002/16928-data-assimilation-concepts-and-methods.pdf>. Acesso em: 01 agosto. 2023.
- CLAYTON, A. M.; LORENC, A. C.; BARKER, D. M. Operational implementation of a hybrid ensemble/4d-var global data assimilation system at the Met Office. **Quarterly Journal of the Royal Meteorological Society**, v. 139, n. 675, p. 1445–1461, 2013.
- DA SILVA, A.; PFAENDTNER, J.; GUO, J.; SIENKIEWICZ, M.; COHN, S. Assessing the effects of data selection with dao's physical-space statistical analysis system. **Monthly Weather Review**, p. 273–278, 1995.
- DINIZ, F. L. **Impacto das observações nas previsões de curto prazo.** São José dos Campos. 2012. Dissertação (Mestrado) — Instituto Nacional de Pesquisas Espaciais. Disponível em: <<http://urlib.net/8JMKD3MGP7W/3D559CB>>.
- DONG R, LENG H, ZHAO C, SONG J, ZHAO J AND CAO X. A hybrid data assimilation system based on machine learning. **Frontiers in Science**. 10:1012165. doi: 10.3389/feart.2022.1012165
- ECMWF, 2023. **Observations.** Disponível em: <https://www.ecmwf.int/en/research/data-assimilation/observations> Acesso em: 30 de agosto 2023.
- EVENSEN, G. Sequential data assimilation with a nonlinear quasi-geostrophic model using monte carlo methods to forecast error statistics. **Journal of Geophysical Research**, v. 99, p. 10143–10162, 1994.
- EVENSEN, G. The ensemble kalman filter: theoretical formulation and practical implementation. **Ocean Dynamics**, v. 53, p. 343-367, 2003.
- HAMILL, T. M.; SNYDER, C. A hybrid ensemble kalman filter- 3d variational analysis scheme. **Monthly Weather Review**, v. 128, n. 8, p. 2905–2919, 2000.
- HARLIM, J.; HUNT, B. R. **Local Ensemble Transform Kalman Filter: an Efficient Scheme For Assimilating Atmospheric Data.** 2005.
- HOUTEKAMER, P. L., AND F. ZHANG, 2016: Review of the Ensemble Kalman Filter for Atmospheric Data Assimilation. **Monthly Weather Review**, 144, 4489–4532, <https://doi.org/10.1175/MWR-D-15-0440.1>. 2016.

- HU, G., DANCE, S. L., BANNISTER, R. N., CHIPILSKI, H. G., GUILLET, O., MACPHERSON, B., WEISSMANN, M., YUSSOUF, N. (2023). Progress, challenges, and future steps in data assimilation for convection-permitting numerical weather prediction: Report on the virtual meeting held on 10 and 12 November 2021. **Atmospheric Science Letters**, 24(1), e1130. <https://doi.org/10.1002/asl.1130>
- HUNT, B. R.; KOSTELICH, E. J.; SZUNYOGH, I. Objective weather-map analysis. **Physica D Nonlinear Phenomena**, v. 230, n. 1-2, p. 112–126, 2007.
- JAMES, E. P., S. G. BENJAMIN, AND B. D. JAMISON, 2020: Commercial-Aircraft-Based Observations for NWP: Global Coverage, Data Impacts, and COVID-19. **J. Appl. Meteor. Climatol.**, **59**, 1809–1825, <https://doi.org/10.1175/JAMC-D-20-0010.1>.
- KALMAN, R. E. A new approach to linear filtering and prediction problems. **Transactions of the ASME—Journal of Basic Engineering**, v. 82, p. 35–45, 1960.
- KALNAY, E. **Atmospheric modeling, data assimilation and predictability**. Cambridge University, 2003.
- KUNII, M.; MIYOSHI, T.; KALNAY, E. Estimating the impact of real observations in regional numerical weather prediction using an ensemble kalman filter. **Monthly Weather Review**, v. 140, p. 1975–1987, 2012.
- LI, H.; LIU, J.; FERTIG, E.; KALNAY, E.; ARAVÉQUIA, J. A.; SZUNYOGH, I.; KOSTELICH, E. J.; TODLING, R. Improved analyses and forecasts with airs retrievals using the local ensemble transform kalman filter. , 2007.
- LUPU, C.; GAUTHIER, P.; S., L. Evaluation of the impact of observations on analyses in 3d- and 4d-var based information content. **Monthly Weather Review**, v. 139, p. 726–737, 2011.
- MIYOSHI, T.; SATO, Y. Assimilating satellite radiances with a local ensemble transform kalman filter (LETKF) applied to the jma global model (GSM). **Online Letters on the Atmosphere**, v. 135, p. 37–40, 2007.
- OTT, E.; HUNT B. H.AND SZUNYOGH, I.; ZIMIN, A. V.; KOSTELICH, E. J. A local ensemble kalman filter for atmospheric data assimilation. **Tellus**, v. 56, p. 415–428, 2004.
- PENNY, S. G. The hybrid Local Ensemble Transform Kalman Filter. **Monthly Weather Review**, v. 142, p. 2139–2149, 2014.
- PETRIE, R. E. **Localization in the ensemble Kalman Filter**. Reading, 80 p., 2008. Tese (Doutorado) - University of Reading.
- SZUNYOGH, I.; KOSTELICH, E. J.; GYARMATI, G.; KALNAY, E.; HUNT, B. R.; OTT, E.; SATTERFIELD, E.; YORKE, J. A. A local ensemble transform kalman filter data assimilation system for the ncep global model. **Tellus**, v. 60A, p. 113–130, 2008.
- VALMASSOI, A., AND COAUTHORS, 2023: Current Challenges and Future Directions in Data Assimilation and Reanalysis. **Bull. Amer. Meteor. Soc.**, **104**, E756–E767, <https://doi.org/10.1175/BAMS-D-21-0331.1>.
- WANG, X.; BISHOP, C. H.; JULIER, S. J. Which is better, an ensemble of positive-negative pairs or

a centered spherical simplex ensemble. **Monthly Weather Review**, v. 132, p. 1590–1605, 2004.

WANG, X.; HAMILL, T. M.; WHITAKER, J. S.; BISHOP, C. H. A comparison of hybrid ensemble transform kalman filter optimum interpolation and ensemble square root filter analysis schemes. **Monthly Weather Review**, v. 135, n. 3, p. 1055–1076, 2007.

WANG, X.; PARRISH, D.; KLEIST, D.; WHITAKER, J. Gsi 3dvar-based ensemble–variational hybrid data assimilation for ncep global forecast system: single-resolution experiments. **Monthly Weather Review**, v. 141, n. 11, p. 4098–4117, 2013.

WHITAKER, J. S.; HAMILL, T. M. Ensemble data assimilation without perturbed observations. **Monthly Weather Review**, v. 130, p. 1913–1924, 2002.

WHITAKER, J. S. T. M. H.; WEI, X.; SONG, Y.; TOTH, Z. Ensemble data assimilation with the ncep global forecast system. **Monthly Weather Review**, v. 136, p. 463–482, 2008.

ZHANG, F.; ZHANG, M.; HANSEN, J. Coupling ensemble kalman filter with four-dimensional variational data assimilation. **Advances in Atmospheric Sciences**, v. 26, n. 1, p. 1–8, 2009.

Introdução à modelagem da superfície continental

Aline Anderson de Castro

RESUMO

A superfície continental e a atmosfera estão conectadas em diversos aspectos que envolvem troca de energia, momentum e elementos entre elas. Da atmosfera vem a energia e a água necessários para os processos associados ao crescimento e manutenção de vegetação. A vegetação, por sua vez, absorve CO_2 atmosférico e transpira H_2O , podendo funcionar como sumidouro de carbono e fonte de água. Na biosfera terrestre, o ciclo da água e dos elementos está conectado em diversos aspectos. A disponibilidade de água no solo modula a produtividade primária líquida, e pode alterar as atividades biogeoquímicas associadas à decomposição de matéria orgânica e os processos associados à respiração do solo e de raízes. Todos esses processos são bastante sensíveis às mudanças climáticas e mudanças no uso e cobertura do solo, o que torna fundamental uma boa representação deles em modelos do sistema terrestre, tanto para previsões de tempo quanto para projeções climáticas mais confiáveis. Este capítulo aborda os principais processos de interação entre a biosfera e a atmosfera, com foco nos fluxos de energia e nos ciclos da água e carbono, e também as estratégias para a modelagem dessas interações.

INTRODUÇÃO

A superfície terrestre continental, apesar de representar a menor parte do planeta, quando comparada aos oceanos e atmosfera, é a parte do sistema terrestre com a qual os animais e plantas terrestres interagem diretamente (Fisher *et al.*, 2020; Wallace e Hobbs, 2006). A biosfera terrestre, em especial a vegetação, exerce um papel fundamental na formação dos ambientes e é essencial para a evolução do clima e para o ciclo natural do carbono (Foley *et al.*, 1996, Steiner, 2020 - 20/09). Assim, grande atenção vem sendo dada ao estudo do funcionamento e da dinâmica natural dos ecossistemas terrestres e como eles afetam os ciclos globais de carbono, nitrogênio e água (Kucharik *et al.*, 2000).

Quando se fala em estudar os processos físicos da superfície continental, é preciso ter em mente que o que vai alimentar os processos são fatores atmosféricos, como radiação, precipitação, temperatura, etc., e a superfície continental, por sua vez, retroalimenta a atmosfera com os fluxos de água, carbono e energia. De fato, radiação incidente, disponibilidade de água e temperatura são fatores chave na distribuição global de vegetação (Wallace e Hobbs, 2006; Hartman livro tb, sfc).



Por outro lado, os processos fisiológicos, biofísicos e ecológicos da superfície continental também interferem no clima. Alguns exemplos são o particionamento dos fluxos de calor sensível e latente e do efeito da rugosidade da superfície na turbulência que vai formar a camada limite planetária (Stull, 1988; Hartmann, 1994; Wallace e Hobbs, 2006), e o albedo, que vai influenciar a quantidade de radiação refletida de volta para a atmosfera. Além disso, a superfície também é responsável por parte da troca dos gases de efeito estufa (GEE) na atmosfera, podendo atuar como fonte ou sumidouro dos mesmos.

Durante muito tempo, o foco da modelagem da interação entre a superfície continental e atmosfera eram os fluxos de água, energia e momentum. Atualmente, muito esforço da comunidade científica vem sendo empenhado no desenvolvimento de modelos que representem da forma mais realística possível os processos e os feedbacks entre o clima e os ciclos dos principais gases de efeito estufa no sistema terrestre, através do desenvolvimento de modelos de dinâmica da vegetação, conhecidos como DGVM, do inglês *Dynamical Global Vegetation Model*. Esses modelos incluem, além dos fluxos de energia, água e momentum, processos como o crescimento da vegetação, emissão/absorção de GEE, mortalidade, decomposição de matéria orgânica no solo, entre outros. Além disso, parte deles já inclui também alguns processos antrópicos, como o desmatamento e queimadas.

O foco deste capítulo será em dar uma visão geral dos principais fluxos e ciclos envolvidos nos processos de superfície associados às interações entre a biosfera terrestre e a atmosfera, como o ciclo da água, do carbono e o balanço de energia. Adicionalmente, também será apresentada uma visão geral sobre as estratégias usadas nos modelos para representar esses processos e as limitações que ainda são encontradas na modelagem de superfície.

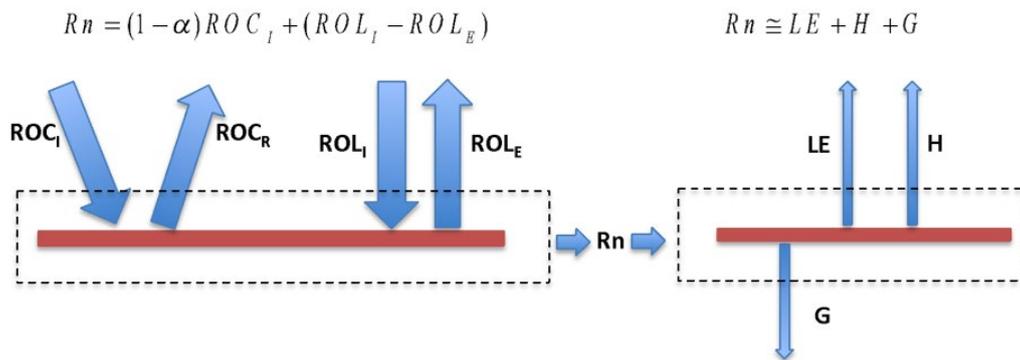
BALANÇO DE ENERGIA

A principal fonte de energia externa que movimenta os processos no sistema terrestre vem do Sol, na forma de radiação de onda curta (ROC_i). O balanço de radiação envolve muitas trocas durante o percurso da radiação na atmosfera, como interação com nuvens, entre outros. Em relação aos fluxos próximos à superfície (figura 1), devido ao efeito do albedo (α), que representa um coeficiente de reflexão, que varia de 1 para superfícies mais claras a zero para corpos negros, parte da ROC_i é refletida de volta para a atmosfera (ROC_r). Além da radiação de onda curta, a superfície também recebe radiação de onda longa (ROL_i), proveniente da emissão de radiação que foi absorvida por partículas e nuvens na atmosfera, e também devolve parte dessa emissão na forma de onda longa (ROL_e). O saldo entre a radiação que entra e a que sai vai dar a radiação líquida disponível para os fluxos de superfície (R_n).

Uma vez na superfície, essa radiação vai ser usada para aquecimento do solo (fluxo de calor no solo - G), aquecimento do ar (fluxo de calor sensível - H), evaporação da água (fluxo de calor latente - LE) e uma pequena fração para a realização da fotossíntese, processo que vai ser discutido no ciclo do carbono. Por simplificação, devido à pequena magnitude da radiação usada na fotossíntese, ela é desconsiderada e a soma dos fluxos

de calor é aproximada para a soma entre os fluxos de G, H e LE.

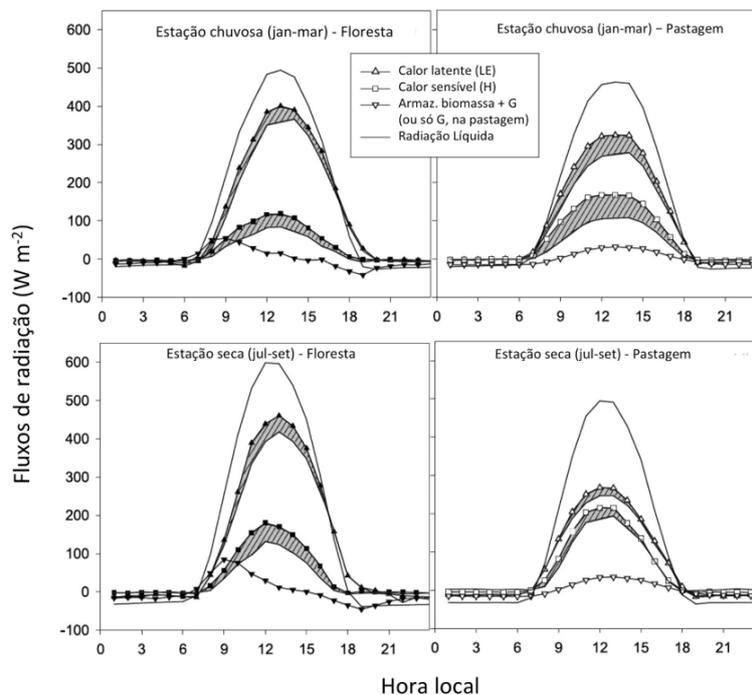
Figura 1 - Diagrama esquemático dos fluxos de energia na superfície terrestre.



Fonte: Adaptado de Foken, 2008

Todos esses termos, por serem uma função da incidência de radiação solar, apresentam um ciclo diário e também diferem de acordo com o tipo de cobertura vegetal e disponibilidade de água, como pode ser visto na figura 2. Ela mostra a diferença entre o particionamento de energia em uma região de floresta e de pastagem para as estações seca e chuvosa na Amazônia (baseada nos resultados de Von Randow *et al.*, 2004). O que se observa é que na floresta, nas duas estações, o fluxo de calor latente é bem maior que o de calor sensível, enquanto na pastagem os fluxos quase se igualam na estação seca, quando a disponibilidade de água é menor.

Figura 2 - Padrão de média diária de Rn, H, LE e G (+ armazenamento na biomassa) para a) estação chuvosa na floresta, b) estação chuvosa na pastagem, c) estação seca na floresta e d) estação seca na pastagem. As partes sombreadas representam a faixa dos fluxos usando dois diferentes métodos de cálculo.



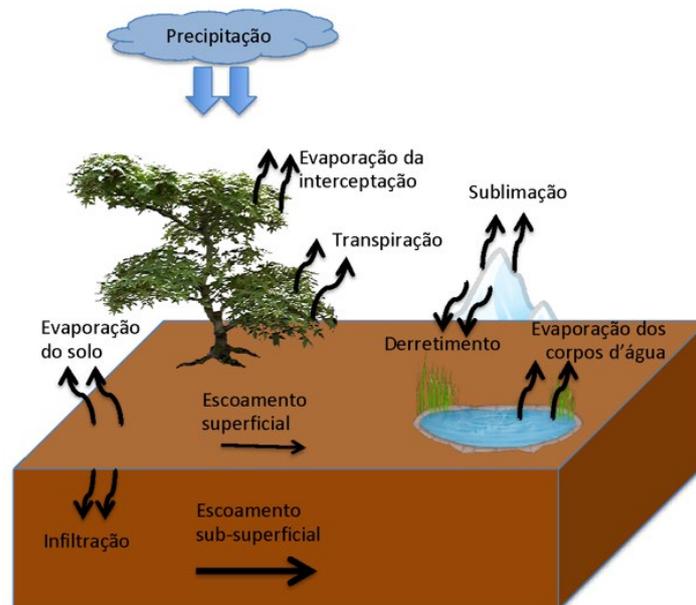
Fonte: von Randow *et al.* 2004

CICLO DA ÁGUA

Os fluxos de energia se conectam ao ciclo da água através do calor latente, que está associado à evapotranspiração. Analogamente, a quantidade de umidade do solo em uma região determina o particionamento da energia que volta à atmosfera. Em uma região seca, a superfície funciona, preferencialmente, como fonte de calor sensível, enquanto em regiões com maior disponibilidade de umidade o fluxo pode ocorrer também na forma de energia latente, levando umidade da superfície para atmosfera e liberando energia no nível da atmosfera onde ocorrer a condensação deste vapor d'água.

Da água precipitada sobre o ecossistema (figura 3), uma parte é interceptada pela vegetação e pode ser diretamente evaporada de volta para a atmosfera ou escorrer para o solo. Da água que chega ao solo, uma parcela é infiltrada e outra parte é escoada, formando o escoamento superficial. A quantidade de água que vai infiltrar depende das características do solo, como porosidade e condutividade hidráulica, por exemplo.

Figura 3 - Ciclo da água na superfície continental.



Fonte: Autoria própria (2023)

Da fração infiltrada, parte pode ser evaporada diretamente do solo, parte transpirada pela vegetação, durante o processo de fotossíntese, e parte vai percolar até atingir o lençol freático. A soma das frações evaporadas pelo solo, da interceptação e da transpiração forma a evapotranspiração e os escoamentos superficial e sub-superficial são direcionados para os rios e corpos d'água, de onde podem ser evaporados de volta para a atmosfera. Em regiões com gelo, ocorre também a sublimação e o derretimento do gelo.

CICLO DO CARBONO

A formação de biomassa está diretamente ligada à disponibilidade de energia (na forma de radiação solar) e aos ciclos da água e do C e é limitada pela disponibilidade de nutrientes, em especial o fósforo e o nitrogênio. Segundo Bormann e Likens (1967), os ciclos da água e dos elementos estão interligados em diversos pontos: i) a estocagem de biomassa

em um ecossistema é função do regime de precipitação, entre outras coisas; ii) as atividades biogeoquímicas, a captação de nutrientes pela biomassa e a liberação de nutrientes no solo por decomposição biológica são fortemente dependentes da disponibilidade de água; iii) o movimento da água carrega consigo material lixiviado tanto para dentro como para fora dos ecossistemas.

O dióxido de carbono (CO_2) atmosférico entra no sistema solo-vegetação através da fotossíntese, que é o processo bioquímico onde o CO_2 é captado da atmosfera e fixado na forma de matéria orgânica na biomassa (Ometto e Martinelli, 2008; Schlesinger, 1997). Durante este processo, oxigênio e vapor d'água são liberados para a atmosfera. Essa troca entre a planta e a atmosfera se dá através dos estômatos, que são microscópicas aberturas nas folhas, e que as plantas tem a capacidade de regular a abertura e fechamento para evitar a perda de água. Essa regulação vai depender da disponibilidade de água e a pressão parcial de CO_2 ($p\text{CO}_2$) entre o sistema planta-atmosfera (Schlesinger, 1997). O carbono total absorvido pela vegetação representa um fluxo conhecido como produção primária bruta (GPP, do inglês *Gross Primary Production*). Desse total absorvido, uma parte é alocada nos reservatórios de folha, tronco e raiz da planta e outra parte é perdida pela respiração autotrófica (RA), que é a respiração associada à vegetação. Essa parte assimilada pela vegetação é conhecida como produção primária líquida (NPP, do inglês *Net Primary Production*), e representa o saldo entre o que foi absorvido (GPP) e o que se perde por respiração autotrófica. A disponibilidade de água no solo modula a produção primária líquida da biomassa e a falta de água pode alterar a alocação de carbono (C) entre a parte aérea e do solo (nas raízes), além de diminuir a NPP e até levar à mortandade da vegetação.

Com o passar do tempo, parte da biomassa acumulada na vegetação é perdida e vai para o solo, onde é decomposta pela microfauna, bactérias e fungos, formando a matéria orgânica. Durante o processo de decomposição ocorre desprendimento de H_2O , nutrientes e CO_2 , em um processo conhecido como respiração heterotrófica (RH). Essa reciclagem da matéria orgânica por decomposição é um processo bastante importante pois regula a principal fonte primária de nutrientes disponibilizados para as plantas na maioria dos ecossistemas terrestres (Norris *et al.*, 2013). As atividades biogeoquímicas associadas à decomposição de matéria orgânica, os processos associados à respiração do solo, incluindo a respiração das raízes e decomposição da liteira, têm maior magnitude na estação chuvosa que na seca (Davidson *et al.*, 2000; Saleska *et al.*, 2003).

A matéria orgânica no solo pode ser dividida em uma fração lábil, ou disponível para o consumo, e uma fração estável, ou humificada (Pillon *et al.*, 2002; Schlesinger, 1997). A fração lábil é formada por resíduos de plantas e animais e pela biomassa microbiana e responde rapidamente às mudanças no uso do solo e no clima (Pillon *et al.*, 2002). A fração estável é formada por compostos orgânicos altamente resistentes, que se acumulam nas camadas inferiores do perfil de solo e constituem a maior parte da matéria orgânica do solo, o *humus* (Schlesinger, 1997). A matéria orgânica formada pode ser perdida pelo sistema de solo através do escoamento superficial, pela respiração microbiana ou ainda por percolação através do perfil de solo, onde pode aumentar o conteúdo de matéria orgânica profunda ou chegar até as águas subterrâneas (Usselman *et al.*, 2007).

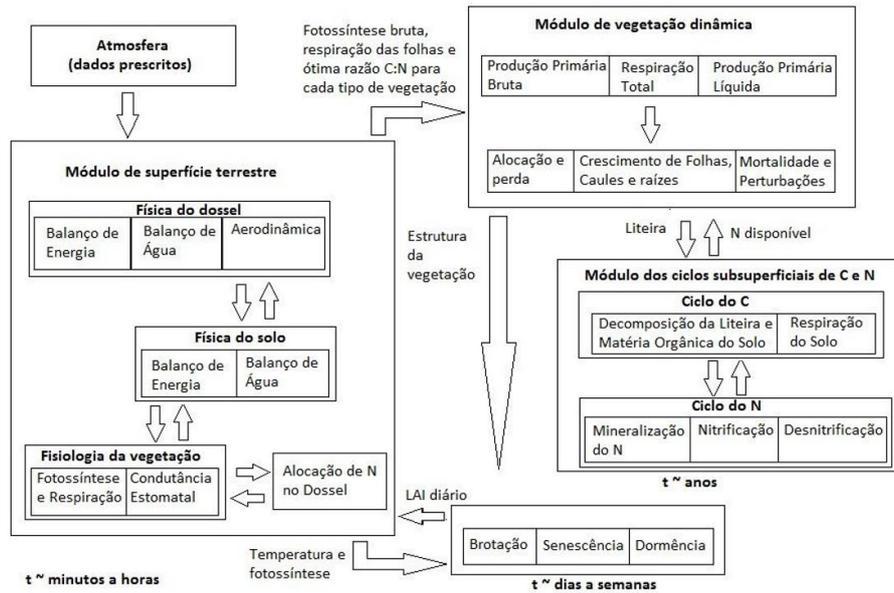
O saldo do fluxo de CO₂ entre a atmosfera e a superfície continental é dado pela diferença entre GPP e os processos de respiração da vegetação e do solo, que forma a respiração do ecossistema (RECO = RH + RA), e é conhecido como troca líquida do ecossistema (NEE, do inglês *Net Ecosystem Exchange*). Por convenção, a NEE é dada do ponto de vista da atmosfera, ou seja, se tem um sinal negativo, significa que a superfície está absorvendo mais CO₂ do que emitindo. Por outro lado, temos também o conceito de NEP, que é a produção líquida do ecossistema (NEP, do inglês *Net Ecosystem Production*), positiva quando o ecossistema terrestre “ganha” carbono, resultando em um crescimento da biomassa aérea e aumento na biomassa microbiana e de raízes abaixo do solo, e a atmosfera “perde” CO₂.

MODELOS GLOBAIS DE DINÂMICA DA VEGETAÇÃO

Para representar esta gama de processos e suas retroalimentações, grande parte dos modelos é dividido em módulos, que são resolvidos em escala temporal que vai desde minutos, como os fluxos de calor e energia, até a escala anual, como a decomposição de matéria orgânica no solo (figura 4 – baseada nos módulos do modelo IBIS). Existe atualmente uma variedade grande de modelos de superfície que possuem suas peculiaridades. Assim, para descrever as estratégias de modelagem, vamos considerar o modelo IBIS (do inglês *Integrated Biosphere Simulator*), descrito por Foley *et al.* (1996) e Kucharik *et al.* (2000).

Este modelo possui um módulo de superfície, onde são representados os processos de balanço de energia, de água e processos aerodinâmicos no dossel e fisiológicos da planta, como fotossíntese, respiração e condutância estomática. O módulo de dinâmica da vegetação simula a variação com o tempo na cobertura de vegetação resultante de alterações na produtividade primária líquida, assimilação de carbono, crescimento da biomassa, mortalidade e volume de biomassa para cada categoria de planta (Foley *et al.*, 1996). O módulo de biogeoquímica simula o fluxo de carbono de forma completa no solo, onde são calculados produtividade primária líquida, respiração do solo e decomposição, entre outros. No módulo de superfície, a vegetação é a classificação em diferente tipos funcionais de planta (PFT, do inglês *Plant Functional Type*). Os PFTs definem diferentes características das plantas, como se é árvore ou vegetação mais baixa, se tem um ciclo anual de perda de folhas (decídua) ou se é sempre verde, por exemplo. Diferentes PFTs podem ou não ocorrer em algumas regiões, dependendo de restrições climáticas, e tem diferentes parâmetros para as equações do modelo, como coeficientes de respiração da folha e intervalo de temperatura que suporta, por exemplo.

Figura 4 - Diagrama representativo do esquema modular do modelo IBIS.



Fonte: Adaptado de Kucharick (2000).

O modelo considera 6 camadas de solo, para facilitar a representação dos fluxos de calor e água em diferentes profundidades, e representa duas camadas de dossel: baixa, que considera os arbustos e gramíneas e alta, que considera as árvores (figura 5). A fotossíntese é calculada de forma diferenciada para plantas C3 e C4 e a NPP e condutância dos estômatos são calculadas para cada PFT. A perda de folhas ocorre quando médias de algumas variáveis climáticas chave atingem valores pré-definidos e a competição entre espécies se dá pela facilidade em acessar água e luz, ou seja, plantas baixas podem sofrer efeito de sombra das mais altas, por exemplo, mas também acessam água disponibilizada pela precipitação mais facilmente (Kucharik *et al.*, 2000). O modelo não representa a competição ou limitação por nutrientes, como nitrogênio e fósforo, por exemplo.

Os estoques de carbono assimilados pela vegetação são divididos entre as raízes, troncos e folhas, e o carbono total pode ser obtido tanto pela soma dos dossel alto e baixo quanto pela soma desses reservatórios. Para a mortalidade, os tempos de residência são dados como parâmetros e a variação no estoque de carbono na biomassa em cada reservatório é dada pela equação 1.

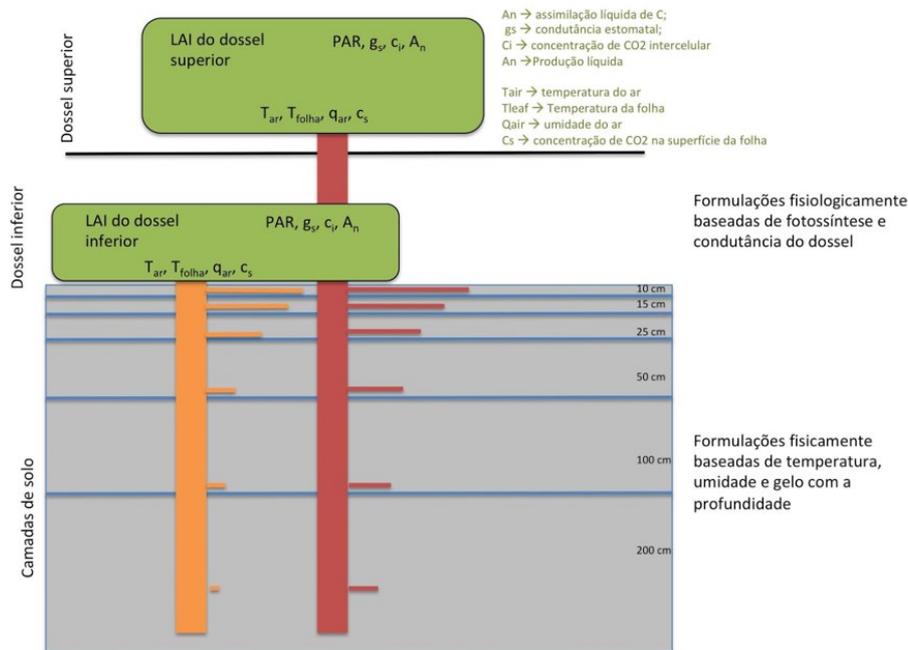
$$\frac{dC_R}{dt} = a_R NPP(t) - \frac{C_R}{\tau} - \delta C_R \quad (1)$$

onde C_R é o carbono estocado no reservatório (tronco, folhas ou raízes), a_R é o coeficiente de alocação (parâmetro), τ o tempo de residência e δ representa os distúrbios, como o fogo, por exemplo.

A evapotranspiração total é obtida como a soma dos fluxos por evaporação do solo, evaporação da parcela interceptada pela vegetação e transpiração. A água que atinge o solo é dividida entre uma parcela que infiltra o solo e outra que escoar superficialmente e, da que infiltra, parte pode ser evaporada do solo, transpirada ou drenada para fora da última camada do perfil de solo, gerando o escoamento sub-superficial. A transpiração é calculada separadamente para cada PFT. Diferentes PFTs extraem água de diferentes camadas

de solo (Foley *et al.*, 1996). Todos estes processos são influenciados pela textura e pela quantidade de matéria orgânica do solo (Kucharik *et al.*, 2000).

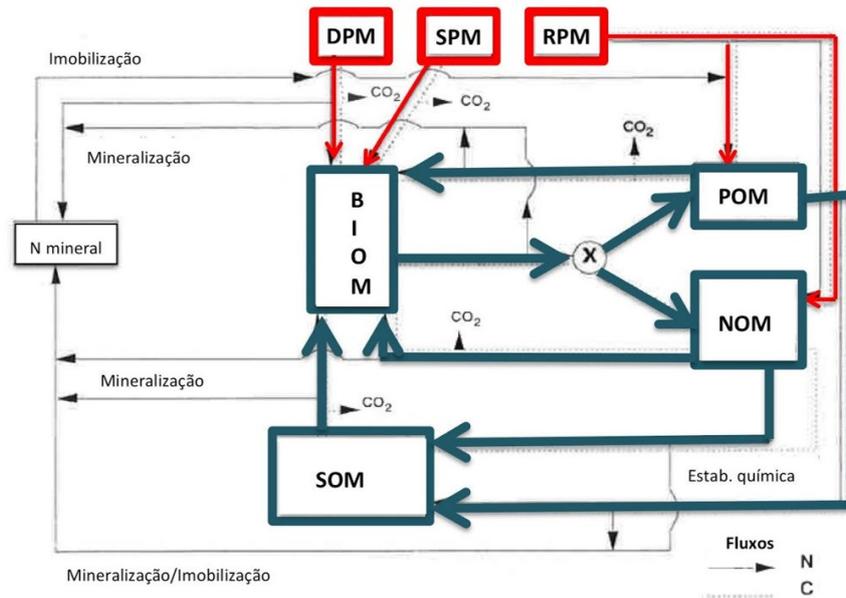
Figura 5 - Camadas de vegetação e solo no modelo IBIS.



Fonte: Adaptado de Kucharick *et al.*, (2000)

O módulo de biogeoquímica trabalha com dois compartimentos, um acima do solo que acumula os resíduos da biomassa de superfície e um dentro, que acumula a matéria orgânica do solo proveniente da decomposição de raízes finas e da biomassa microbiana (Foley *et al.*, 1996). Dentro destes compartimentos, os detritos resultantes de folhas, troncos e raízes são tratados separadamente e divididos entre resistente (RPM), estrutural (SPM), disponível (DPM) (figura 6). O C sub-superficial é dividido entre os reservatórios de biomassa microbiana (BIOM), de matéria orgânica protegida (POM) e não protegida (NOM), e o de matéria orgânica estabilizada (SOM), com diferentes tempos de residência (horas a dias, 10 a 30 anos e milênios, respectivamente). A atividade microbiana é uma função da temperatura e do conteúdo de água no solo; o crescimento da biomassa microbiana e a razão de mineralização de N são uma função da textura do solo.

Figura 6 - Esquema de biogeoquímica do solo no IBIS. Em vermelho as entradas de matéria orgânica (RPM resistente, SPM estrutural e DPM disponível) e em azul a distribuição dentro do solo (POM protegida, NOM não protegida, BIOM biomassa e SOM estabilizada)



Fonte: adaptado de Verberne *et al.* (1990).

CONSIDERAÇÕES FINAIS

As mudanças climáticas, causadas pelo aumento da quantidade de gases do efeito estufa na atmosfera provindos das perturbações antrópicas, podem provocar alterações nos ciclos biogeoquímicos entre os componentes do Sistema Terrestre, o que pode ocasionar retroalimentações positivas ou negativas nos distúrbios decorrentes destas ações antrópicas (Denman *et al.*, 2007). Neste capítulo foram descritos alguns pontos onde ocorrem as conexões entre a biosfera terrestre e a atmosfera. O que pode ser notado é que estes componentes estão fortemente ligados, de forma que é praticamente impossível alterar um deles sem ocasionar efeitos nos outros. Assim, a gama de impactos que ações antrópicas pode ocasionar é muito ampla, tornando muito difícil estimar o *feedback* que uma alteração em um dos ciclos pode ter nos demais e na vida do planeta.

O aumento da concentração de CO_2 na atmosfera, por exemplo, pode ocasionar a “fertilização por CO_2 ”, que leva à redução no tempo de abertura dos estômatos da planta devido ao aumento na disponibilidade de CO_2 na atmosfera, ocasionando um maior ganho de biomassa com uma menor perda de água pela transpiração. Por outro lado, o aumento na temperatura do planeta, uma das consequências do aumento de CO_2 na atmosfera, pode alterar o ciclo da água, ocasionando situações de seca em regiões como a Amazônia, por exemplo, que pode ter sua cobertura vegetal alterada para outro tipo adaptado à regiões de menor pluviosidade.

Na natureza, o efeito da “fertilização por CO_2 ” é limitado pela disponibilidade de nutrientes, mas nem todos os modelos representam essa limitação, o que pode levar a erros nas projeções futuras. Tendo isso em mente, é necessário o desenvolvimento de modelos que possam representar da forma mais completa possível, para o atual nível

computacional disponível, os processos do sistema terrestre como um todo, já que os feedbacks se sobrepõem. Desta forma, ainda há uma alta demanda de estudos, tanto observacionais quanto de modelagem, e muito se tem a aprender sobre como nossas ações podem gerar impactos no nosso futuro e no futuro dos recursos limitados e fundamentais para a manutenção da vida no planeta, como água e alimentação.

Nas duas últimas décadas houve uma evolução considerável dos modelos, que passaram a representar mais satisfatoriamente processos mortalidade por fogo, pestes ou seca, distribuição de carbono nas camadas de solo, efeito do nitrogênio na fotossíntese, entre outros (Blyth *et al.*, 2021). Ainda assim, aprofundar o entendimento dos processos associados às interações entre a biosfera terrestre e a atmosfera é de extrema importância para reduzir as incertezas associadas à previsão dos efeitos ocasionados por as ações antrópicas ao meio ambiente (Davín *et al.*, 2016, Huang *et al.*, 2023).

REFERÊNCIAS

- BLYTH, E. M., ARORA, V. K., CLARK, D. B., DADSON, S. J., DE KAUWE, M. G., LAWRENCE, D. M., ... YUAN, H. (2021). Advances in land surface modelling. **Current Climate Change Reports**, 7(2), 45-71.
- BORMANN, F. H., LIKENS, G. E. (1967). Nutrient cycling. **Science**, 155, 424–429.
- DAVIN, E. L., MAISONNAVE, E., SENEVIRATNE, S. (2016). Is land surface processes representation a possible weak link in current Regional Climate Models? **Environ. Res. Lett.** 11 074027.
- DENMAN, K. L., BRASSEUR, G., CHIDTHAISONG, A., CIAIS, P., COX, P. M., DICKINSON, R. E., HAUGLUSTAINE, D., *et al.* (2007). Couplings Between Changes in the Climate System and Biogeochemistry. In S. Solomon, D. Qin, M. Manning, Z. Chen, M. Marquis, K. B. Averyt, M. Tignor, *et al.* (Eds.), *Climate Change 2007: The Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change*. **Cambridge: Cambridge University Press**.
- FISHER, R. A., KOVEN, C. D. (2020). Perspectives on the future of land surface models and the challenges of representing complex terrestrial systems. **Journal of Advances in Modeling Earth Systems**, 12, e2018MS001453. <https://doi.org/10.1029/2018MS001453>
- FOKEN, T., NAPO, C. J. (2008). **Micrometeorology** (Vol. 2). Berlin: Springer.
- FOLEY, J. A., PRENTICE, I. C., RAMANKUTTY, N., LEVIS, S., POLLARD, D., SITCH, S., HAXELTINE, A. (1996). An integrated biosphere model of land surface processes, terrestrial carbon balance, and vegetation dynamics. **Global Biogeochemical Cycles**, 10, 603–628. Retrieved from <http://www.agu.org/pubs/crossref/1996/96GB02692.shtml>
- HARTMANN, D. L. (1994). Global physical climatology. **International Geophysics Series**, 56, 411.
- HUANG B, LI Y AND TÖLLE MH (2023), **Editorial: Interactions between land surface and climate**. *Front. Environ. Sci.* 11:1169298. doi: 10.3389/fenvs.2023.1169298

KUCHARIK, J., FOLEY, J. A., DELIRE, C., FISHER, V. A., COE, T., LENTERS, D., NORMAN, J. M., *et al.* (2000). Testing the performance of a Dynamic Global Ecosystem Model : Water balance , carbon balance , and vegetation structure I and Navin. **Global Biogeochemical Cycles**, 14(3), 795–825.

NIYOGI D (2019) Land surface processes, in: Current trends in the representation of physical processes in weather and climate models. **Springer**, pp. 349–370

NORRIS, M. D., AVIS, P. G., REICH, P. B., HOBBIE, S. E. (2013). **Positive feedbacks between decomposition and soil nitrogen availability along fertility gradients**, 347–361. doi:10.1007/s11104-012-1449-3

OMETTO, J., MARTINELLI, L. A. (2008). Ciclos Biogeoquímicos. **Biologia das Mudanças Climáticas no Brasil** (1st ed.). São Carlos: Rima.

PILLON, C. N., MIELNICZUK, J., MARTIN NETO, L. (2002). Dinâmica da matéria orgânica no ambiente. **Pelotas: Embrapa Clima Temperado**, 41 p..

SCHLESINGER, W. H. (1997). **Biogeochemistry: an analysis of global change**. (A. Press, Ed.) (p. 595).

STEINER, A. L. (2020). Role of the terrestrial biosphere in atmospheric chemistry and climate. **Accounts of Chemical Research**, 53(7), 1260-1268.

STULL, R. B. (1988). An introduction to boundary layer meteorology (Vol. 13). **Springer Science & Business Media**.

USELMAN, S. M., QUALLS, R. G., LILIENFEIN, J. (2007). Contribution of Root vs. Leaf Litter to Dissolved Organic Carbon Leaching through Soil. **Soil Science Society of America Journal**, 71(5), 1555. doi:10.2136/sssaj2006.0386

VERBERNE, E.L., J. HASSINK, P. DE WILLIGEN, J.J.R. GROOT, AND J.A. VAN VEEN, (1990). **Modeling organic matter dynamics in different soils**, Neth. J. Agr. Sci., 38, 221-238.

VON RANDOW, C., MANZI, A. O., KRUIJT, B., DE OLIVEIRA, P. J., ZANCHI, F. B., SILVA, R. D., ... KABAT, P. (2004). Comparative measurements and seasonal variations in energy and carbon exchange over forest and pasture in South West Amazonia. **Theoretical and Applied Climatology**, 78, 5-26.

WALLACE, J. M.; HOBBS, P. V. (2006). *Atmospheric Science – An introductory survey*. **Academic Press**, 483 p.

Desastres naturais: aspectos sobre modelagem hidrológica a partir da previsão numérica de tempo

Leandro Casagrande

Minella Alves Martins

Fernanda Casagrande

Ana Carolina Nascimento Santos

RESUMO

Com o aumento da frequência dos desastres naturais, a antecipação de eventos hidrometeorológicos com potencial de causar danos à população e meio ambiente é cada vez mais urgente. Neste contexto, o presente capítulo visa abordar o papel da modelagem hidrológica como componente fundamental para um sistema de alerta, fornecendo exemplos do potencial de implementação desta ferramenta em diversas regiões do Brasil. Adicionalmente, são discutidos alguns dos desafios que persistem para a previsão de desastres, como a necessidade de aprimorar a precisão das previsões de precipitação, integração de modelos atmosféricos e hidrológicos e as incertezas inerentes à modelagem. Essa análise visa elucidar sobre a necessidade contínua de busca por estratégias eficazes de monitoramento e melhoria da resposta a desastres naturais no Brasil.

INTRODUÇÃO

Desastres naturais de origem hidrometeorológica ocupam uma posição de destaque no contexto brasileiro, representando 47% dos eventos registrados no período de 1991 a 2022. Desta parcela, mais de 50% são devidos a inundações graduais e bruscas (CEPED, 2022).

As inundações graduais ocorrem geralmente nas partes baixas das grandes bacias hidrográficas, e são derivados de processos lentos, onde a evolução do nível do rio leva alguns dias ou até meses, como no caso da Bacia Amazônica.

As inundações bruscas, bastante comuns no Brasil, são desencadeadas por precipitações intensas e concentradas, caracterizadas por escoamento superficial de alta velocidade e energia de transporte. Este fenômeno é notável pela sua capacidade de acumulação de água superficial e pelo poder destrutivo (Nobre e Young, 2011). Os impactos associados a tais eventos abrangem uma ampla gama de prejuízos de ordem material, social e ambiental, frequentemente resultando na perda



de vidas humanas.

Tais impactos observados nos últimos anos tendem a se intensificar. De acordo com o sexto relatório do Painel Intergovernamental sobre Mudanças Climáticas (IPCC, 2023), há um aumento no número de eventos de precipitações intensas, associados às inundações, em várias regiões do planeta. Além disso, simulações com modelos numéricos também têm apontado incrementos significativos em eventos de precipitação extrema, como consequência das mudanças climáticas (Avila-Diaz *et al.*, 2020; Medeiros *et al.*, 2022). Considerando esse cenário, a capacidade de prever com antecedência e de forma confiável esses eventos hidrológicos extremos, se torna essencial para o eficaz gerenciamento de riscos de desastres. Por essa razão, o Brasil tem direcionado recursos e esforços para o aprimoramento das previsões meteorológicas e climáticas, bem como para a sua integração com modelos hidrológicos (Casagrande, 2015).

Além da questão meteorológica, os desastres naturais estão intrinsecamente ligados à vulnerabilidade da população (IPCC, 2023). O número de eventos está constantemente aumentando nos países em desenvolvimento devido ao seu desenvolvimento histórico pautado em condições econômicas, sociais, culturais e políticas precárias, o que amplia sua fragilidade e exposição a ameaças (Monte *et al.*, 2021).

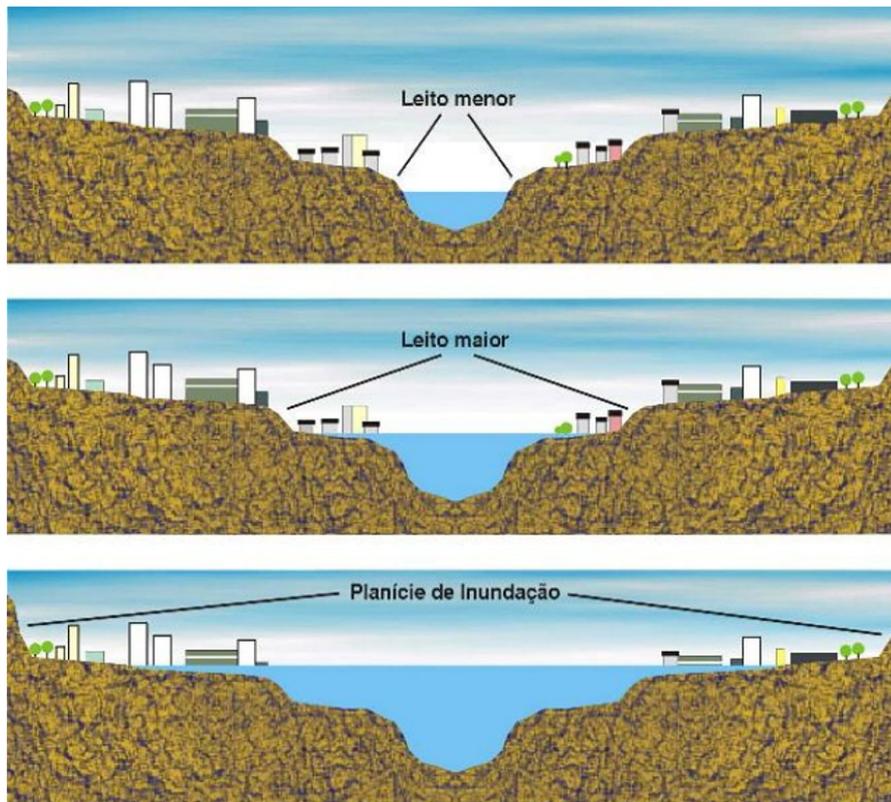
No período compreendido entre 1991 e 2022, foram documentados no Brasil um total de 62.273 registros de desastres naturais. Destes, 9.386 estão relacionados a ocorrências de desastres causados por inundações súbitas ou enxurradas, enquanto 6.055 se referem a inundações graduais, representando, respectivamente, 15% e 10% do total de eventos registrados (CEPED, 2022).

Quando se trata de antecipar eventos de desastres desencadeados por processos de origem hidrológica, como enchentes e inundações, a previsão meteorológica e a modelagem hidrológica são ferramentas cruciais. No contexto brasileiro, a hidrologia evoluiu nas últimas décadas com avanços tecnológicos na observação ambiental e no entendimento dos conceitos relacionados à hidrologia e aos recursos hídricos. Isso deu origem a diversas aplicações da modelagem hidrológica, abrangendo desde o monitoramento ambiental até o planejamento do desenvolvimento urbano, entre outros aspectos (Casagrande *et al.*, 2017).

Nesse contexto, este capítulo representa uma contribuição para a compreensão e aplicação da modelagem hidrológica como uma ferramenta na gestão de desastres naturais relacionados à água. É destinado a profissionais e acadêmicos envolvidos na proteção de vidas e recursos naturais, bem como na busca de soluções para a redução dos impactos de inundações e desastres hidrometeorológicos no Brasil.

DEFINIÇÕES

Quando se trata de desastres naturais, a identificação da tipologia do desastre desempenha um papel crucial, contribuindo para uma compreensão mais precisa e eficaz dos eventos catastróficos. O conceito de inundação é muitas vezes confundido, tanto por apresentar ligeiras diferenças dentre as instituições que trabalham com desastres naturais, quanto por haver caracterizações diferentes. A figura 1 exemplifica como ocorre essa caracterização relacionada à ascensão do nível da água nos rios que culmina na inundação.

Figura 1 – Caracterização da ascensão do nível dos rios.

Fonte: CPRM (2017)

A primeira situação representa a normalidade do escoamento dos rios, a água ocupa o espaço do leito menor. A segunda situação é a enchente (ou cheia do rio) e ocorre, geralmente na estação chuvosa ou em eventos atípicos de chuvas. O aumento do volume de água no rio resulta em aumento no nível, fazendo com que ele ocupe o leito maior. No entanto, refere-se à condição de escoamento do rio dentro da calha normal até o nível de suas margens, sem que haja o seu transbordamento (Goerl e Kobiyama, 2005). Geralmente este ponto é considerado em um sistema de alerta como antecedente à condição de inundação (Casagrande, 2015). A terceira situação exemplificada na figura 1 é a inundação, as águas ultrapassam as margens do rio, invadindo as áreas adjacentes (planície de inundação) (CPRM, 2017). Esta é a situação mais preocupante no contexto de desastres naturais. Ela ocorre quando o nível do rio ultrapassa seu limite máximo e transborda. Dependendo da intensidade deste evento, e da topografia da região, o transbordamento do rio pode atingir áreas distantes da calha do rio, impactando a população, infraestruturas e os ecossistemas ao redor. Este tipo de evento é bastante crítico e, em última instância, pode ocasionar mortes.

Vale também destacar os alagamentos. O termo “alagamento” refere-se à ocorrência transitória de acúmulo de água em determinada área, resultado de limitações no sistema de drenagem (Peiter, 2012). Esse tipo de desastre decorre da combinação de chuvas intensas com a sobrecarga dos sistemas de escoamento urbano, resultando no represamento de água em infraestruturas urbanas. Geralmente, os alagamentos se caracterizam por acúmulos rasos de água que afetam vias públicas, causando perturbações temporárias na circulação de pedestres e veículos. No entanto, em algumas regiões, os alagamentos podem ocorrer de forma simultânea com as inundações, agravando a situação devido à

dificuldade de escoamento da água transbordadas dos rios.

Em função do padrão evolutivo, as inundações podem ser classificadas como graduais ou bruscas. De acordo com o Manual de planejamento em defesa civil (Castro, 1999), as inundações graduais caracterizam-se pela elevação de forma paulatina e previsível do nível das águas no rio, mantendo-se em situação de cheia durante algum tempo e, a seguir, escoam gradualmente. Normalmente, as inundações graduais são cíclicas e nitidamente sazonais (inundação gradual ou enchente). Por outro lado, as inundações bruscas são provocadas por chuvas intensas e concentradas em regiões de relevo acidentado, caracterizando-se por súbitas e violentas elevações dos caudais dos rios, os quais escoam de forma rápida e intensa.

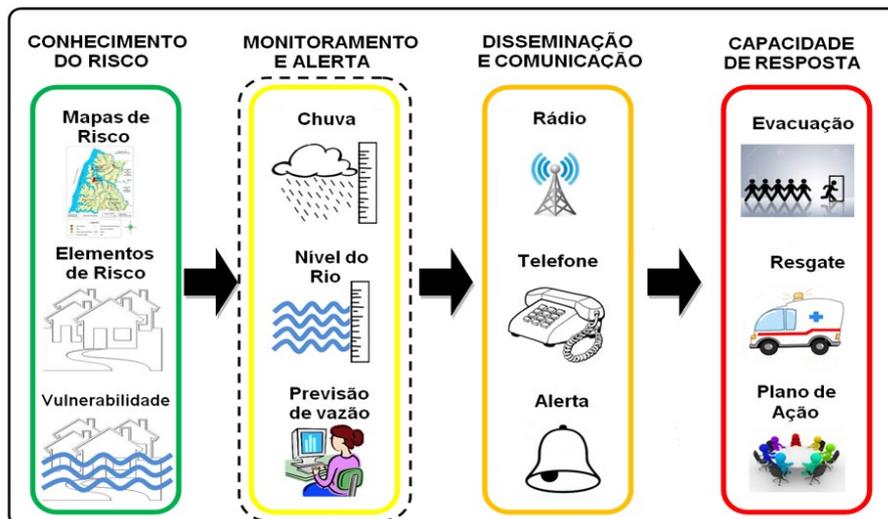
SISTEMAS DE ALERTA

As principais estratégias para mitigar os impactos decorrentes de eventos de chuvas intensas podem ser categorizadas em medidas estruturais e não-estruturais. Tipicamente, as medidas estruturais incluem a realização de obras, como a construção de barragens e a retificação de canais. Por outro lado, as medidas não-estruturais têm um caráter preventivo e visam aprimorar a convivência da população com as enchentes (Filho *et al.*, 2000).

Um exemplo de medida não-estrutural de grande relevância é a implementação de sistemas de alerta. Esses sistemas oferecem vantagens substanciais, principalmente devido aos custos relativamente baixos em comparação com os investimentos significativos, frequentemente necessários para a realização de obras de infraestrutura

No Plano de Ação de Hyogo, adotado durante a Conferência Mundial das Nações Unidas sobre a Redução de Desastres, são identificados quatro elementos cruciais de um Sistema de Alerta para desastres naturais (UNISDR, 2005), conforme ilustrado na figura 2:

Figura 2 - Elementos Fundamentais de um Sistema de Alerta a Desastres Naturais.



Fonte: Casagrande (2015, adaptado de UNISDR, 2006)

No Brasil, poucas são as iniciativas que se encaixam na estrutura dos elementos de um Sistema de Alerta e, em grande parte, surgiram como resposta a eventos extremos históricos que resultaram em significativas perdas em áreas geográficas específicas do

país. Dentre os Sistemas de Alerta existentes no Brasil, tem-se o Sistema de Alerta de Cheias do Instituto Estadual do Ambiente do Rio de Janeiro - INEA, implantado em 2007 e mantido pelo governo do Estado (INEA, 2023), o Sistema de Alerta Contra Enchentes do rio Doce, iniciado em 1997, mantido pelo Serviço Geológico do Brasil (Companhia de Pesquisa de Recursos Minerais - CPRM) em parceria com a Agência Nacional das Águas (ANA) e o Instituto Mineiro de Gestão das Águas (IGAM), que abrange os Estados de Minas Gerais e Espírito Santo (CPRM, 2023), o Sistema de Alerta e Controle de Enchentes da Bacia do Rio Caí (SACE-CAÍ), no Estado do Rio Grande do Sul, iniciado em 2010, também mantido pela CPRM, o Sistema de Alerta a Inundações de São Paulo - SAISP (FCTH, 2023), iniciado em 1977, operado pela Fundação Centro Tecnológico de Hidráulica (FCTH) e, a partir de 2011, o Centro Nacional de Monitoramento e Alertas de Desastres Naturais (CEMADEN), vinculado ao Ministério da Ciência, Tecnologia e Inovação (MCTI), no escopo do Plano Nacional de Gestão de Riscos e Respostas a Desastres, monitora 1038 municípios em todas as regiões brasileiras (CEMADEN, 2023).

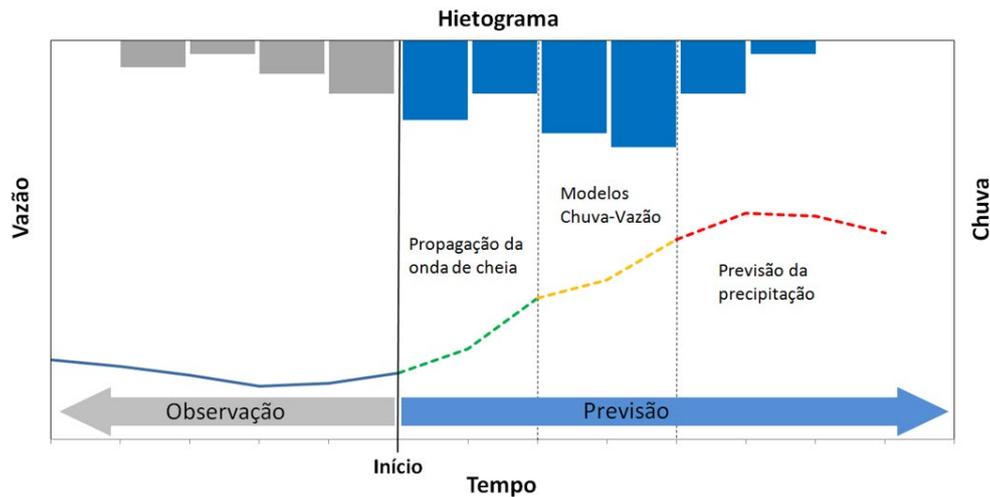
Em resumo, esses sistemas costumam usar informações de diferentes fontes para auxiliar na tomada de decisões e, frequentemente, compartilham a manutenção da infraestrutura. Apesar de não estarem diretamente integrados com previsões meteorológicas numéricas, os operadores dos Sistemas de Alerta baseiam suas ações em prognósticos de tempo fornecidos por instituições como o Centro de Previsão de Tempo e Estudos climáticos do Instituto Nacional de Pesquisas Espaciais - CPTEC/INPE e o Instituto Nacional de Meteorologia - INMET, que emitem avisos regionais sobre condições climáticas severas no Brasil.

PREVISÃO DE CHEIAS

As previsões de cheias podem ser feitas em curto ou longo prazo, com diferentes objetivos. No curto prazo, o foco é alertar a população que vive às margens do rio com algumas horas de antecedência. Esse alerta pode ser feito com base em diferentes metodologias como propagação da onda de cheia (Both e Haetinger, 2008), usando modelos hidrológicos chuva–vazão, com base na chuva observada (Rao *et al.*, 2011) ou através da integração de modelos chuva–vazão com modelos de previsão de tempo (Bao *et al.*, 2011).

No longo prazo, as previsões têm foco no gerenciamento de recursos hídricos (Collischonn *et al.*, 2005) ou na avaliação dos impactos das mudanças do clima (Mohor *et al.*, 2015; Siqueira-Júnior *et al.*, 2015). Além disso, estimativas de longo prazo, derivadas de dados históricos, podem ser usadas para criar mapas de risco baseados em diferentes períodos de retorno (Graciosa, 2010).

A escolha dos métodos de previsão depende, além do objetivo, de fatores como a disponibilidade de dados, as características físicas da bacia hidrográfica. A figura 3 exemplifica o horizonte de atuação para cada método. Enquanto o método de propagação de ondas de cheia é bastante preciso, ele tem antecedência limitada devido ao tempo de propagação da onda. Por outro lado, os modelos baseados em chuva observada têm limitações no tempo de resposta da bacia. Dessa forma, o uso de previsões de precipitação permite estender a previsão de modelos chuva-vazão além desse tempo de resposta da bacia.

Figura 3 - Horizontes de Previsão de Cheias para diferentes metodologias.

Fonte: Casagrande (2015).

De modo geral, a previsão de cheias por meio de modelos chuva-vazão envolve sistemas que combinam modelos hidrológicos e hidrodinâmicos para simular a propagação de inundações na rede de drenagem de uma bacia hidrográfica. A complexidade dessas ferramentas varia, mas em sua essência, elas dependem de dados meteorológicos (Casagrande, 2015).

De acordo com Falk *et al.* (2021), os sistemas operacionais de previsão de cheias dependem do uso de dados de entrada de precipitação, geralmente coletados por redes de pluviômetros, estimativas de precipitação por satélite e/ou observações de radares terrestres. No entanto, uma vez que os prazos de previsão com base em observações são limitados pelo tempo de propagação da onda de cheia, o tempo disponível entre as previsões e o pico do fluxo pode não ser adequado para planejar ações de mitigação em bacias de resposta rápida, geralmente associadas a um maior número de perdas de vidas humanas. Dessa forma, o uso de modelos numéricos de previsão do tempo permite antecipar as previsões de cheias, mas também suprir a deficiência de dados observacionais, devido à baixa densidade de estações meteorológicas e radares.

Modelo numérico de previsão de tempo

A previsão numérica do tempo se tornou a ferramenta mais importante para a previsão do tempo em todo o mundo (Pu e Kalnay, 2018). Os modelos numéricos de previsão do tempo levam em consideração os processos físicos essenciais na atmosfera, na superfície e no solo para modelar a evolução temporal de variáveis como pressão, temperatura, vento, vapor d'água, nuvens e precipitação (Joe *et al.*, 2022). Esses modelos segmentam a atmosfera em camadas verticais e a superfície em uma grade horizontal composta por vários pontos, onde as equações são processadas, resultando em uma representação tridimensional (Sampaio e Dias, 2014). O conjunto de equações consideradas governa o movimento e a evolução atmosférica e descreve leis básicas de conservação, incluindo a conservação de momento, massa, energia e vapor d'água. Para prever o estado atmosférico futuro, é necessário integrar esse conjunto de equações no tempo (Pu e Kalnay, 2018).

Modelos numéricos de previsão de tempo podem usar como domínio de simulação

todo o globo e, portanto, são chamados de Modelos Atmosféricos de Circulação Global (MCGs). Geralmente apresentam resolução espacial na ordem de várias dezenas a centenas de quilômetros. Apesar de cobrirem todo o globo, não conseguem capturar processos de superfície específicos, por exemplo, a influência de uma determinada característica topográfica no movimento de massas atmosféricas. No entanto, são essenciais para prever sistemas meteorológicos de macroescala, como frentes, sistemas de alta e baixa pressão e padrões climáticos globais.

Por outro lado, modelos com domínio de simulação regionais, conhecidos como Modelos de Circulação Regional (MCRs), reduzem sua área de abrangência em prol da melhoria da resolução espacial, cobrem um continente, país ou regiões menores e apresentam resolução espacial de poucas dezenas de quilômetros. Os modelos regionais geralmente usam dados fornecidos por modelos globais como condições de contorno lateral para suas previsões e aprimoram essas previsões locais com informações específicas da região, como por exemplo, a umidade do solo (Resende e Chou, 2014).

Devido à melhor capacidade de capturar eventos meteorológicos locais, os modelos regionais de alta resolução apresentam maior potencial para prever eventos extremos (Chou *et al.*, 2005; Olsson *et al.*, 2015; Torma *et al.*, 2015), fornecendo informações cruciais para um sistema de monitoramento e alerta de desastres naturais

No Brasil, o Modelo Eta é um modelo regional que apresenta uma área de abrangência que inclui a América do Sul e as regiões oceânicas adjacentes (Chou, 1996; Chou *et al.*, 2005; Mesinger *et al.*, 2012). Ele apresenta diferentes resoluções espaciais, variando de 5 a 40 km, a depender da versão utilizada. Ele é utilizado para previsões de curto prazo (Mesinger *et al.*, 2012), previsões sazonais (Chou *et al.*, 2020) e como suporte em pesquisas relacionadas as mudanças climáticas (Chou *et al.*, 2014a; 2014b). O modelo Eta representa o estado atmosférico através da discretização em pontos de grade. Uma das principais vantagens do modelo é a coordenada vertical Eta, caracterizando a estabilidade numérica (Mesinger *et al.*, 1990), o que contribui para redução dos erros, usualmente significativos em regiões de topografia íngreme (Chou e Nunes, 2000). O esquema de previsão por conjunto utilizado no modelo Eta considera as variações nas previsões devido às incertezas nas condições iniciais e nas parametrizações dos processos físicos. O uso de previsões por conjunto fornece um intervalo da possível evolução dos estados atmosféricos previstos pelo modelo, acrescentando informações sobre sua confiabilidade (Gomes *et al.*, 2022). As variáveis prognósticas do modelo são: temperatura do ar, umidade, pressão à superfície, vento horizontal, energia cinética turbulenta, precipitação, dentre outras, previstas em intervalos de seis horas.

Para a previsão de cheias, a precipitação desempenha um papel crucial e, embora a incerteza na sua estimativa possa levar a erros significativos nas aplicações hidrológicas e na previsão de cheias (Bravo *et al.*, 2009), a integração de previsões numéricas meteorológicas por conjunto em modelos hidrológicos é uma abordagem bastante utilizada e conhecida como previsões de vazão por conjuntos ou H-EPS (Sistema de Previsão de Conjunto Hidrológico). Isso permite considerar as incertezas nas previsões de precipitação (Cloke e Pappenberger, 2009), ampliando as capacidades de gerenciamento de risco.

Modelagem hidrológica

Os modelos hidrológicos buscam descrever os fenômenos físicos que ocorrem na bacia hidrográfica, por meio de equações matemáticas. Esses modelos podem ser categorizados com base em várias dimensões, incluindo a natureza estocástica ou determinística, a abordagem conceitual ou empírica, e a representação concentrada ou distribuída (Tucci, 2005).

Tomasella *et al.* (2022) ressalta que, a seleção de um modelo deve ser guiada pelas características da região de estudo e pelos objetivos da modelagem. A escolha da resolução da simulação (em termos de escala espacial e temporal do modelo) é influenciada pelas informações disponíveis para representar e calibrar os processos, bem como pelos recursos computacionais disponíveis.

O Modelo Hidrológico Distribuído do Instituto Nacional de Pesquisas Espaciais (MHD-INPE) é um modelo determinístico e distribuído que demonstrou sucesso em uma variedade de bacias de diferentes áreas, com aplicações para previsões de curto prazo (Casagrande *et al.*, 2017; Negrão *et al.*, 2017; Tomasella *et al.*, 2018; Falck *et al.*, 2021) e longo prazo (Oliveira *et al.*, 2022; Michels-Brito *et al.*, 2021).

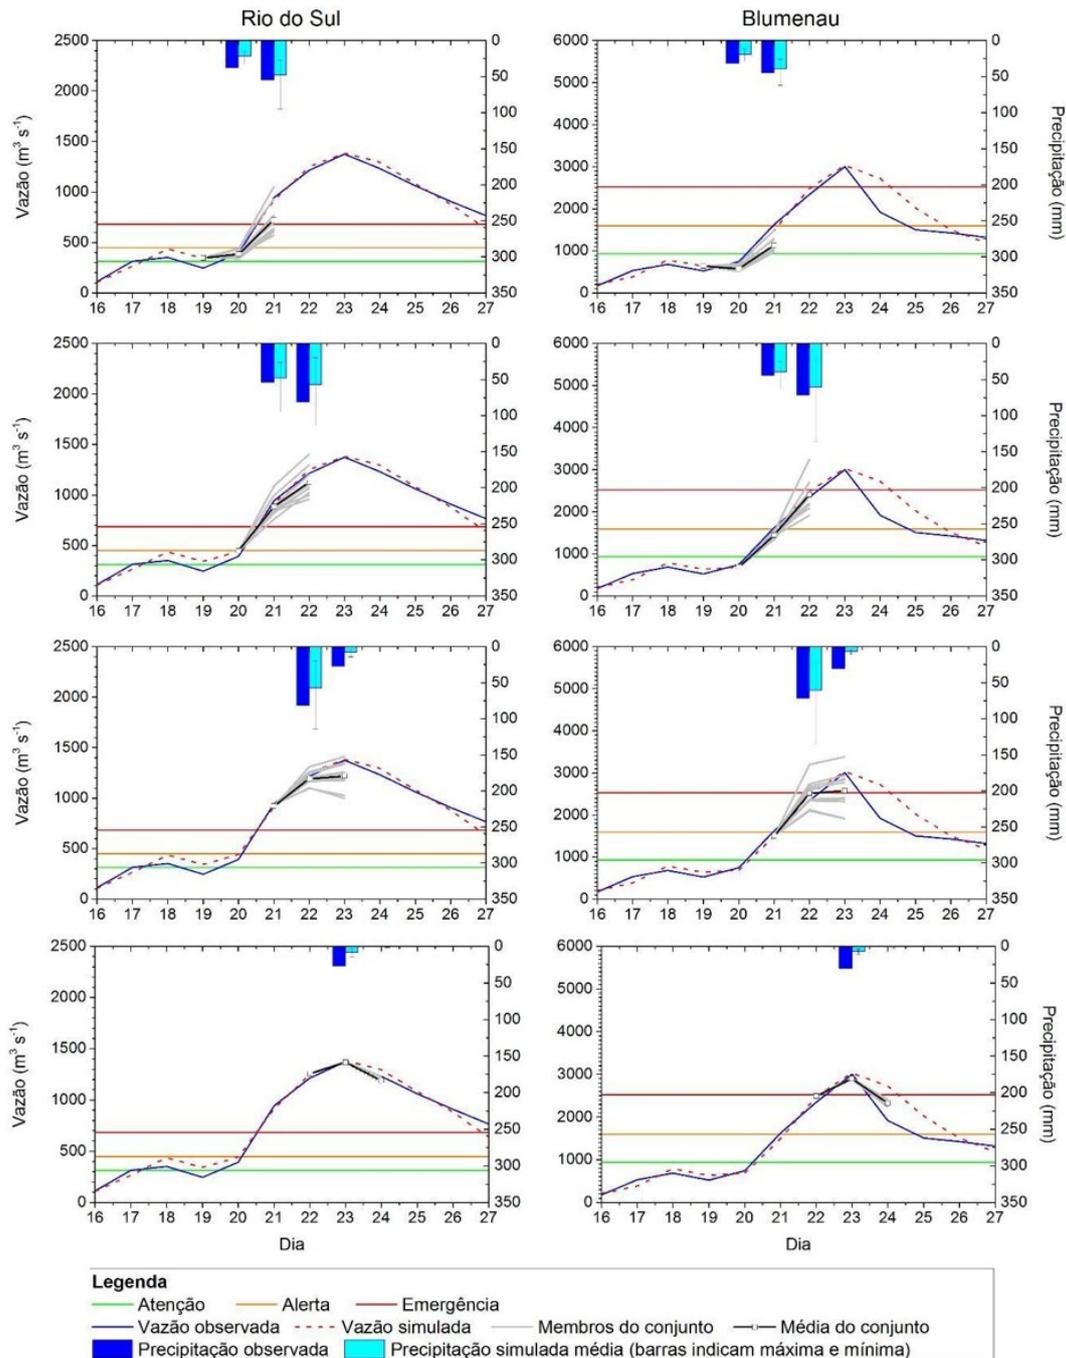
O MHD-INPE representa os processos hidrológicos por meio de formulações conceituais de balanço hídrico e propagação de escoamento. Utiliza uma distribuição espacial em grades regulares, onde cada célula da grade simula os processos do ciclo hidrológico e o escoamento resultante é encaminhado por uma rede de drenagem (Tomasella *et al.*, 2022). O modelo utiliza unidades de resposta hidrológica em cada célula de grade, que resultam da combinação do tipo de solo e do uso da terra. O modelo está organizado em diversos módulos que incluem: i) Balanço d'água no solo; ii) Evaporação de superfície de água livre, áreas saturadas, interceptação e transpiração da vegetação (evapotranspiração); iii) Escoamentos superficial, subsuperficial e subterrâneo em cada célula; e iv) Escoamento na rede de drenagem.

Dentre os dados necessários para calibração e simulação estão dados meteorológicos, dados relativos à rede de drenagem, direção do fluxo, áreas de acúmulo de fluxo, delimitação da bacia, comprimento e declive dos trechos dos rios.

Dentre as aplicações para previsão de cheias, vale destacar os resultados de Casagrande *et al.* (2017) que avaliaram o uso das previsões em conjunto do modelo regional Eta e do modelo hidrológico MHD-INPE para compor um sistema operacional de alerta de cheias na Bacia do rio Itajaí-Açú em Santa Catarina. Os autores selecionaram um evento extremo ocorrido em setembro de 2013, que levou a cidade de Rio Sul a decretar estado de calamidade pública.

A figura 4, apresenta as previsões para as estações de Rio Sul e Blumenau, considerando 4 dias, a partir de 19 de setembro de 2013. É possível observar que, a média dos membros do conjunto da previsão de 19 de outubro de 2013, um dia antes do início do evento de precipitação, já indicava um aumento na vazão do rio na estação de Rio do Sul, com um valor acima do nível de emergência, com 48 horas de antecedência. O mesmo padrão foi verificado na estação de Blumenau, onde as vazões próximas ao nível de emergência foram previstas em 20 de setembro de 2013, com 48 horas de antecedência.

Figura 4 - Previsão de cheia para 24 e 48 horas de antecedência e observação diária do fluxo de água nas estações de Rio do Sul e Blumenau.



Fonte: Casagrande *et al.* (2017).

Os resultados obtidos são relevantes no contexto de um sistema de alerta operacional, na qual a tomada de decisão para a emissão de um alerta é geralmente baseada no nível de certeza da previsão em relação ao potencial impacto de um evento (Casagrande *et al.*, 2017).

Uma outra aplicação interessante para previsão de cheias foi demonstrada por Tomasella *et al.* (2018) para a Bacia Rio Doce, que abrange parte dos Estados de Minas Gerais e Espírito Santo.

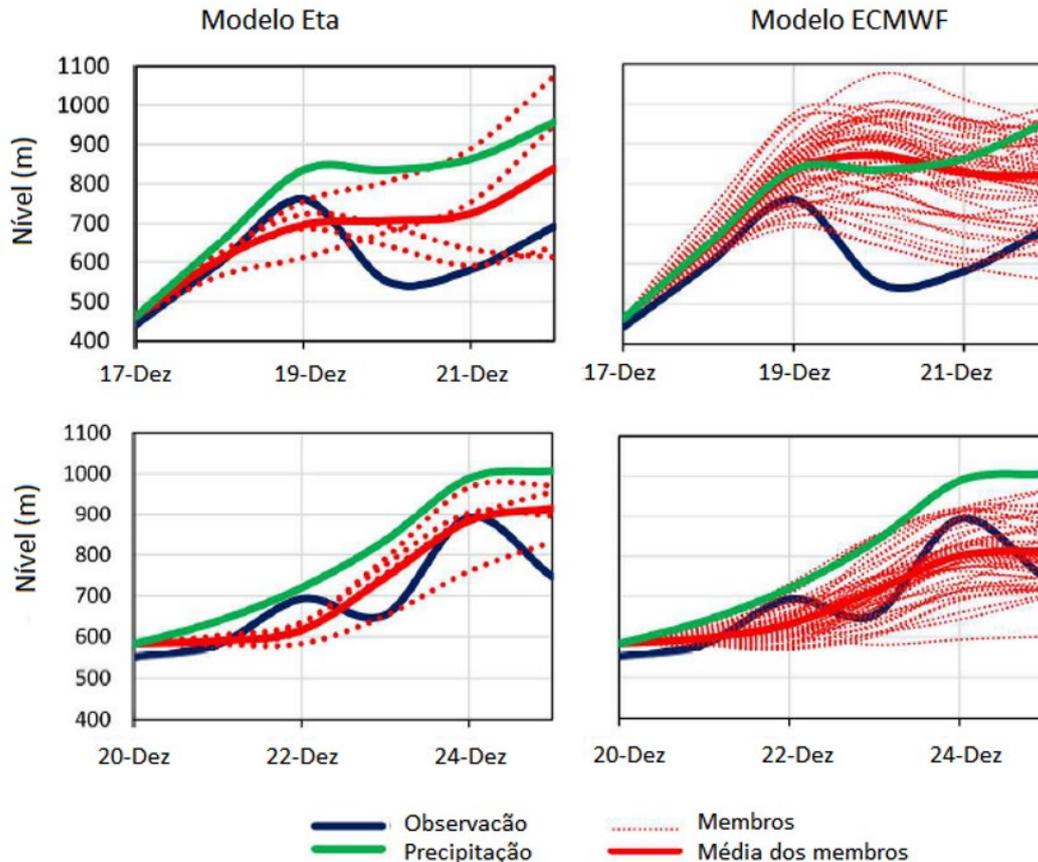
O evento analisado foi referente ao período de 17 a 24 de dezembro de 2013,

quando eventos de chuva intensa afetaram a Bacia do Rio Doce. Esse evento em particular foi considerado a segunda cheia mais grave ocorrida na bacia durante o período de 1939 a 2014.

Estes autores analisaram o desempenho da previsão por conjunto de vazão, com estimativas do modelo hidrológico MHD-INPE, usando três fontes diferentes de informação como entrada: as previsões do modelo Eta (4 membros, resolução espacial de 5km), as previsões do modelo ECMWF (51 membros, resolução de 32 km) e a precipitação interpolada. Sendo este último usado como referência, uma vez que reflete erros nas previsões devido ao modelo hidrológico e à interpolação da precipitação.

A figura 5 apresenta os resultados das simulações para a estação de Colatina, para as previsões iniciadas em 17/12/2013 e 20/12/2013 em termos de nível de água. Os resultados indicam que a previsão de nível em 17/12 previu adequadamente o pico verificado no dia 19, tanto pelos modelos Eta quanto pelo ECMWF. Enquanto o modelo Eta subestimou o pico, o ECMWF superestimou. Ambos os modelos falharam em prever a diminuição do nível observado do dia 20 ao dia 22 de dezembro. Esse comportamento também foi verificado na simulação do modelo hidrológico que usou a interpolação de precipitação como entrada. Em relação à previsão de nível em 20/12 para o segundo pico, os resultados mostram que o modelo Eta previu adequadamente o pico em 24 de dezembro, enquanto o modelo ECMWF subestimou o evento. Apesar disso, ambos os modelos tiveram desempenho superior na simulação hidrológica baseada em dados de precipitação interpolada.

Figura 5 - Previsões probabilísticas de vazão iniciadas em 17/12/2013 (parte superior) e 20/12/2013 (parte inferior) com os modelos Eta (esquerda) e ECMWF (direita).



Fonte: Tomasella *et al.* (2018)

Os autores ressaltam a competitividade dos modelos atmosféricos em comparação com os campos de precipitação interpolados, mesmo para previsões com 5 dias de antecedência. No entanto, abrem uma ressalva, sugerindo que esses resultados não significam que os modelos atmosféricos superarão sempre as interpolações de precipitação, mas parece ser o caso para eventos de chuvas intensas, nos quais a alta variabilidade espacial associada a convecção intensa torna as previsões de vazão muito sensíveis à estrutura espacial do evento de chuva.

DESAFIOS NA PREVISÃO DE DESASTRES HIDROMETEOROLÓGICOS

A previsão de desastres hidrometeorológicos desempenha um papel de extrema importância devido ao impacto significativo que eventos como enchentes e inundações podem causar nas comunidades e no meio ambiente. No entanto, essa tarefa é desafiadora e enfrenta obstáculos que precisam ser superados para aprimorar a precisão e a confiabilidade das previsões e alertas de desastres naturais.

Um dos desafios centrais é a precisão das previsões de precipitação, uma vez que a quantidade e intensidade da chuva desempenham um papel fundamental na ocorrência desses desastres. Prever com precisão quando, onde e quanta chuva ocorrerá é particularmente desafiador, especialmente em eventos de grande magnitude que exigem alertas com antecedência (Adams e Dymond, 2019). Erros nas previsões de precipitação podem levar a alertas prematuros ou tardios, impactando a capacidade de resposta e preparação das comunidades.

Outro desafio envolve a integração de modelos atmosféricos e hidrológicos para prever como as condições meteorológicas se traduzirão em eventos hidrometeorológicos. Isso requer a combinação de dados de diferentes modelos e escalas espaciais, enfrentando desafios de incertezas meteorológicas e hidrológicas, resoluções espaço-temporais discrepantes e abordagens na previsão meteorológica (determinísticas ou por conjunto) (Trošelj *et al.*, 2023).

A singularidade de cada bacia hidrográfica representa um obstáculo adicional, pois um modelo eficaz em uma bacia pode não funcionar da mesma forma em outra, devido às características distintas de cada local (Beven, 2001).

Além disso, as incertezas associadas aos parâmetros do modelo e aos dados de entrada exercem influência nos resultados dos modelos hidrológicos, tornando essencial o tratamento adequado dessas incertezas (Arduino *et al.*, 2005; Younis *et al.*, 2008). Os parâmetros usados pelos modelos com frequência condensam em um único valor as características de uma célula da grade e, às vezes, são obtidos de maneira empírica através do uso de dados de outras localidades ou em outras condições. Por outra parte, os dados de entrada são também sujeitos a erros, às vezes pela heterogeneidade espacial dentro de cada célula considerada na simulação (Liang e Xie, 2001).

Por fim, a comunicação eficaz dos riscos e a compreensão do comportamento humano diante das previsões de desastres desempenham um papel crucial. As decisões tomadas pelas pessoas podem afetar diretamente a eficácia dos sistemas de alerta. Portanto,

superar esses desafios exige uma abordagem multidisciplinar que envolve especialistas de diversas áreas, incluindo meteorologistas, hidrólogos, cientistas climáticos, comunicadores de risco e formuladores de políticas. Além disso, a pesquisa contínua e investimentos em tecnologia são essenciais para aprimorar a previsão de desastres hidrometeorológicos e reduzir seus impactos.

CONSIDERAÇÕES FINAIS

Nas últimas décadas, o crescimento populacional, aliado à ocupação desordenada das áreas urbanas, tem aumentado significativamente a vulnerabilidade da população brasileira aos desastres naturais, em especial os eventos hidrológicos de curta duração. Estes desastres provocam danos expressivos de ordem material, social e ambiental, frequentemente resultando na perda de vidas humanas. Portanto, a capacidade de antecipar esses eventos hidrológicos, de modo a fornecer à Defesa Civil informações confiáveis, dentro das atuais limitações tecnológicas, desempenha um papel crucial nas estratégias de resposta dos órgãos competentes.

Acompanhando o crescente aumento no registro de desastres naturais, o país tem direcionado seus esforços para o desenvolvimento de sistemas de alerta e modelos de previsão, com o objetivo de aprimorar a capacidade de antecipação e gestão dos riscos.

A modelagem hidrológica tem se estabelecido como uma ferramenta essencial na antecipação de eventos naturais com potencial para impactar negativamente tanto a população quanto o meio ambiente.

Entretanto, persistem desafios a serem enfrentados, particularmente no que se refere à melhoria da precisão das previsões de precipitação e à integração de modelos atmosféricos e hidrológicos. É crucial considerar as particularidades de cada bacia hidrográfica e abordar as incertezas inerentes aos modelos.

A busca por soluções a esses desafios é fundamental para a proteção das comunidades brasileiras diante da crescente ameaça dos desastres naturais, e reflete o compromisso contínuo do país em aprimorar suas estratégias de prevenção e resposta a esses eventos críticos.

REFERÊNCIAS

ADAMS, III, E., T., DYMOND, R. L. Possible hydrologic forecasting improvements resulting from advancements in precipitation estimation and forecasting for a real-time flood forecast system in the Ohio River Valley, USA. **Journal of Hydrology**, 579, 124138. 2019. <https://doi.org/10.1016/j.jhydrol.2019.124138>

ARDUINO, G.; REGGIANI, P.; TODINI, E. Recent advances in flood forecasting and flood risk assessment. **Hydrology and Earth System Sciences**, v. 9, n. 4, p. 280–284, 2005.

AVILA-DIAZ, A., BENEZOLI, V., JUSTINO, F., TORRES, R., WILSON, A. Assessing current and future trends of climate extremes across Brazil based on reanalyses and earth system model projections. **Climate Dynamics**, 55(5), 1403–1426. 2020. <https://doi.org/10.1007/s00382-020-05333-z>

BAO, H.-J., ZHAO, L.-N., HE, Y., LI, Z.-J., WETTERHALL, F., CLOKE, H. L., PAPPENBERGER, F., AND MANFUL, D.: Coupling ensemble weather predictions based on TIGGE database with Grid-Xinanjiang model for flood forecast, **Adv. Geosci.**, 29, 61–67, 2011. <https://doi.org/10.5194/adgeo-29-61-2011>

BRAVO, J. M. *et al.* Incorporating Forecasts of Rainfall in Two Hydrologic Models Used for Medium-Range Streamflow Forecasting. **Journal of Hydrologic Engineering**, v. 14, p. 435–445, 2009.

BEVEN, K. How far can we go in distributed hydrological modelling? **Hydrology and Earth System Sciences**, v. 5, n. 1, p. 1–12, 2001.

BOTH, G. C.; HAETINGER, C. Uso da modelagem matemática para a previsão de enchentes no Vale do Taquari – RS. p. 1–7, 2008.

CASAGRANDE, L. Previsão de enchentes e inundações a partir do uso de previsão numérica do tempo na modelagem hidrológica da bacia do rio Itajaí-Açu, SC. Tese de Doutorado em Ciência do Sistema Terrestre. São José dos Campos: INPE, 2015.

CASAGRANDE, L., TOMASELLA, J., DOS SANTOS ALVALÁ, R. C., BOTTINO, M. J., DE OLIVEIRA CARAM, R. Early flood warning in the Itajaí-Açu River basin using numerical weather forecasting and hydrological modeling. **Natural Hazards**, 88(2), 741–757. 2017. <https://doi.org/10.1007/s11069-017-2889-0>

CASTRO, A. L. **Manual de planejamento em defesa civil. Volume I.** 1. ed. Brasília: Ministério da Integração Nacional, 1999. v. I

CEMADEN- CENTRO NACIONAL DE MONITORAMENTO E ALERTA PRECOCE DE DESASTRES NACIONAIS. Municípios monitorados. 2023. <http://www2.cemaden.gov.br/municipios-monitorados-2/#:~:text=No%20escopo%20do%20Plano%20Nacional,em%20todas%20as%20regi%C3%B5es%20brasileiras> Acesso em 29 Out 2023.

CEPED - CENTRO DE ESTUDOS E PESQUISAS EM ENGENHARIA E DEFESA CIVIL. Atlas de Desastres Naturais. 2022. Disponível em <http://atlasdigital.mdr.gov.br/> Acesso em 27 Jul 2023.

CHOU, S. C. Modelo regional Eta. **Climanálise ISSN: 0103-0019**, v. Edição Esp, p. 203–207, 1996.

CHOU, S. C.; NUNES, A. M. B. Extended Range Forecasts Over South America Using the Eta Regional. **Journal of Geophysical Research**, v. 105, p. 10147–10160, 2000.

CHOU SC, BUSTAMANTE J, GOMES JL. Evaluation of Eta Model seasonal precipitation forecasts over South America. **Nonlin Processes in Geophys** 12: 537-555.2005.

CHOU, S. C., LYRA, A., MOURÃO, C., DERECZYNSKI, C., PILOTTO, I. ; GOMES, J.; BUSTAMANTE, J., TAVARES, P., SILVA, A., RODRIGUES, D.; CAMPOS, D., CHAGAS, D., SUEIRO, G. SIQUEIRA, G., MARENGO, J.. Assessment of Climate Change over South America under RCP 4.5 and 8.5 Downscaling Scenarios. **American Journal of Climate Change**, v. 03, p. 512-527. 2014^a.

CHOU, S. C., LYRA, A., MOURÃO, C., DERECZYNSKI, C., PILOTTO, I. ; GOMES, J.; BUSTAMANTE, J., TAVARES, P., SILVA, A., RODRIGUES, D.; CAMPOS, D., CHAGAS, D., SUEIRO, G. SIQUEIRA, G., NOBRE, P. Evaluation of the Eta Simulations Nested in Three Global Climate Models. **American Journal of Climate Change**, v. 03, p. 438-454. 2014b

CHOU, S.C., DERECZYNSKI, C., GOMES, J.L., PESQUERO, J.F., AVILA, A., RESENDE, N.C., BUSTAMANTE, J.F.F. Ten-year seasonal climate reforecasts over South America using the Eta regional climate model. **An. Acad. Bras. Cienc.** 92. 2020. <https://doi.org/10.1590/0001-3765202020181242>.

CLOKE, H. L.; PAPPENBERGER, F. Ensemble flood forecasting: A review. **Journal of Hydrology**, v. 375, n. 3-4, p. 613–626, 2009.

CPRM – SERVIÇO GEOLÓGICO DO BRASIL. Processos hidrológicos Inundações, enchentes, enxurradas e alagamentos na geração de áreas de risco. Curso de Capacitação de Técnicos Municipais para Prevenção e Gerenciamento de Riscos de Desastres Naturais. Vitória/ES. 2017.

CPRM. **Sistema de Alerta Contra Enchentes do rio Doce**. Disponível em <https://www.cbhdoce.org.br/noticias/sistema-de-alerta-entra-em-operacao-na-bacia-do-rio-doce/> . Acesso em: 1 jul. 2023.

COLLISCHONN, W.; MORELLI TUCCI, C. E.; CLARKE, R. T. Previsão Sazonal de Vazão na Bacia do Rio Uruguai 2: Previsão Climática-Hidrológica. **Revista Brasileira de Recursos Hídricos**, v. 10, p. 61–72, 2005.

FALCK, A. S., TOMASELLA, J., DINIZ, F. L. R., MAGGIONI, V. Applying a precipitation error model to numerical weather predictions for probabilistic flood forecasts. *Journal of Hydrology*, 598, 126374. 2021.

FCTH – Fundação Centro Tecnológico de Hidráulica. **Sistema de Alerta a Inundações de São Paulo**. Disponível em: <<http://www.saisp.br/>>. Acesso em: 6 Jul 2023.

FILHO, A. G. A.; SZÉLIGA, M. R.; ENOMOTO, C. F. Estudo de medidas não estruturais para controle de inundações urbanas. **PUBLICATIO UEPG**, v. 6, p. 69–90, 2000.

GOERL, R. F.; KOBAYAMA, M. **Considerações sobre as inundações no Brasil**. XVI SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS. **Anais...** João Pessoa: ABRH, 2005. Disponível em: http://www.labhidro.ufsc.br/Artigos/ABRH2005_inundacoes.pdf

GOMES, W. DE B., SATYAMURTY, P., CORREIA, F. W. S., CHOU, S. C., VERGASTA, L. A., DE ARRUDA LYRA, A.. Intraseasonal scale ensemble forecasts of precipitation and evapotranspiration for the Madeira River basin using different physical parameterizations. *Atmospheric Research*, 270, 106086. 2022. <https://doi.org/10.1016/j.atmosres.2022.106086>

GRACIOSA, M. C. P. **Modelo de seguro para riscos hidrológicos com base em simulação hidráulico-hidrológica como ferramenta de gestão de risco de inundações. (Tese de doutorado)**. [s.l.] USP-São Carlos, 2010.

JOE, P.; SUN, J.; YUSSOUF, N.; GOODMAN, S.; RIEMER, M.; GOUDA, K.C.; GOLDING, B.; ROGERS, R.; ISAAC, G.; WILSON, J.; LI, P.W.P.; WULFMEYER, V. Predicting the Weather: A Partnership of Observation Scientists and Forecasters. In (Ed) Golding, B. Towards the “Perfect” Weather Warning. Springer. 2022. <https://doi.org/10.1007/978-3-030-98989-7>

INEA. **Sistema de Alerta de Cheias do Instituto Estadual do Ambiente**. Disponível em: <http://alertadecheias.inea.rj.gov.br/> Acesso em 20 Ago 2023.

IPCC – INTERNATIONAL PANEL ON CLIMATE CHANGE. Climate Change 2023: Synthesis Report. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change [Core Writing Team, H. Lee and J. Romero (eds.)]. IPCC, Geneva, Switzerland, pp. 35-115, 2023. doi: 10.59327/IPCC/AR6-9789291691647

LIANG, X.; XIE, Z. A new surface runoff parameterization with subgrid-scale soil heterogeneity for land surface models. **Advances in Water Resources**, v. 24, n. 9-10, p. 1173–1193, 2001.

MEDEIROS, J. F., OLIVEIRA, C.P, AVILA-DIAZ, A. Evaluation of extreme precipitation climate indices and their projected changes for Brazil: From CMIP3 to CMIP6. **Weather and Climate Extremes**, 38, 100511. 2022. <https://doi.org/10.1016/j.wace.2022.100511>

MESINGER, F., CHOU, S.C., GOMES, J.L., JOVIC, D., BASTOS, P., BUSTAMANTE, J.F., VELJOVIC, K. An upgraded version of the Eta model. *M. Meteorog. Atmos. Phys.* 116 (3), 63–79. 2012. <https://doi.org/10.1007/s00703-012-0182-z>.

MICHELS-BRITO, A., RODRIGUEZ, D. A., JUNIOR, W. L. C., DE SOUZA VIANNA, J. N. The climate change potential effects on the run-of-river plant and the environmental and economic dimensions of sustainability. *Renewable and Sustainable Energy Reviews*, 147, 111238. 2021. doi: 10.1016/j.rser.2021.111238

MONTE, B. E. O., GOLDENFUM, J. A., MICHEL, G. P., CAVALCANTI, J. R. DE A. Terminology of natural hazards and disasters: A review and the case of Brazil. 2021. **International Journal of Disaster Risk Reduction**, 52, 101970. <https://doi.org/10.1016/j.ijdrr.2020.101970>

MOHOR, G. S. *et al.* Exploratory analyses for the assessment of climate change impacts on the energy production in an Amazon run-of-river hydropower plant. **Journal of Hydrology: Regional Studies**, v. 4, p. 41–59, 2015.

NEGRAO, A. C.; RODRIGUEZ, D.A.; CHOU, SIN CHAN; MEDEIROS, G. S.; SIQUEIRA JUNIOR JOSE LAZARO; CAMARGO, C. P. . Previsão de vazão de eventos extremos utilizando o Modelo Hidrológico Distribuído MHD-INPE e previsões meteorológicas do modelo Eta-INPE para uma alta resolução espacial - Estudo de caso: São Luís do Paraitinga (SP). **Revista Brasileira de Cartografia** (online), 69, 647-657, 2017.

NOBRE, C.A.; YOUNG, A. F. Vulnerabilidade das megacidades brasileiras às mudanças climáticas: Região Metropolitana de São Paulo. 2011. Disponível em https://www.nepo.unicamp.br/publicacoes/livros/megacidades/megacidades_RMSP.pdf Acesso em 27 Jul 2023.

OLIVEIRA, KD; TOMASELLA, J; CARAM, R O; FALCK, A S; SANCHES, ID OLIVEIRA. Impacts of sugarcane expansion on water availability in a river basin in southeastern Brazil. **Catena**, 216(B), 106437. 2022. doi: 10.1016/j.catena.2022.106437

PEITER, C. M. Desastres naturais: enchentes e inundações e o papel do Estado e da sociedade na gestão de segurança pública. Dissertação (mestrado). Universidade do Vale do Itajaí, 2012.

PU, Z., KALNAY E. Numerical Weather Prediction Basics: Models, Numerical Methods, and Data Assimilation. In: Duan Q., Pappenberger F., Thielen J., Wood A., Cloke H., Schaake J. (eds) *Handbook of Hydrometeorological Ensemble Forecasting*. Springer, Berlin, Heidelberg. 2018

RAO, K. H. V. D., RAO, V. V., DADHWAL, V. K., BEHERA, G., SHARMA, J. R. A distributed model for real-time flood forecasting in the Godavari Basin using space inputs. **International Journal of Disaster Risk Science**, 2(3), 31–40. 2011. <https://doi.org/10.1007/s13753-011-0014-7>

RESENDE, N.; CHOU, S.C. influência das condições do solo na climatologia da previsão sazonal do modelo Eta. **Revista Brasileira de Climatologia**. Ano 10 – Vol. 15. 2014. 10.5380/abclima.v15i0.37366

SAMPAIO G.; DIAS. P. L. S. Evolução dos modelos climáticos e de previsão de tempo e clima. *Revista USP*, n 103, p. 41-54. 2014.

SIQUEIRA-JÚNIOR, J. L.; TOMASELLA, J.; RODRIGUEZ, D. A. Impacts of future climatic and land cover changes on the hydrological regime of the Madeira River basin. **Climatic Change**, p. 117–129, 2015.

TOMASELLA, J.; GONÇALVES, A.S.; FALCK, A.S.; CARAM, R.O; DINIZ, F.L.R.; RODRIGUEZ, D.A.; PRADO, M.C.R.; NEGRÃO, A.C.; MEDEIROS, G.S.; SIQUEIRA, G.C.. Probabilistic flood forecasting in the Doce Basin in Brazil: Effects of the basin scale and orientation and the spatial distribution of rainfall. *Journal of Flood Risk Management*, 2018; e12452. <https://doi.org/10.1111/jfr3.12452>

TOMASELLA, J.; SANTOS, A.C.N.; FALCK, A.; MELO, P.A.; CARAM, R.O. Modelo hidrológico distribuído MHD-INPE. Manual de implementação. Versão 2.0. 2022.

TROŠELJ, J., NAYAK, S., HOBOHM, L., TAKEMI, T. Real-time flash flood forecasting approach for development of early warning systems: integrated hydrological and meteorological application. *Geomatics, Natural Hazards and Risk*, 14(1), 2269295. 2023. <https://doi.org/10.1080/19475705.2023.2269295>

TUCCI, C. E. M. **Modelos hidrológicos**. 2. ed. Porto Alegre: Editora da UFRGS/ABRH, 2005.

UNISDR- UNITED NATIONS OFFICE FOR DISASTER RISK REDUCTION. **Hyogo Framework for Action 2005-2015: Building the Resilience of Nations and Communities to Disasters**. 2005. Hyogo: [s.n.]. Disponível em www.unisdr.org/wcdr/ Acesso em 29 Set 2023.

UNISDR - UNITED NATIONS OFFICE FOR DISASTER RISK REDUCTION. **Global Survey of Early Warning SystemsUN**. 2006. Vienna: [s.n.]. Disponível em: <http://www.unisdr.org/ppew/info-resources/ewc3/Global-Survey-of-Early-Warning-Systems.pdf> Acesso em 29 Set 2023

YOUNIS, J.; ANQUETIN, S.; THIELEN, J. The benefit of high-resolution operational weather forecasts for flash flood warning. **Hydrology and Earth System Sciences**, v. 12, p. 1039–1051, 2008.

Modelagem agrometeorológica: monitoramento, previsão e adaptação frente aos extremos climáticos

Minella Alves Martins

Erica Acioli Canamary

Ana Carolina Nascimento Santos

Javier Tomasella

RESUMO

Apesar da bem reconhecida influência do clima na agricultura, a modelagem agrometeorológica é relativamente recente. Em diversas áreas da ciência, como meteorologia, agronomia e hidrologia, os modelos desempenham um papel crucial ao simular processos complexos por meio de estruturas matemáticas ou computacionais. A modelagem agrometeorológica desempenha, por sua vez, um papel fundamental ao simular o comportamento das culturas, ciclos de crescimento e respostas às condições ambientais, contribuindo tanto para a compreensão científica quanto para embasar a tomada de decisões. Neste contexto, o presente capítulo oferece uma análise abrangente do impacto dos elementos meteorológicos no crescimento e desenvolvimento das culturas agrícolas. Além disso, explora diversas categorias de modelos agrometeorológicos, enfatizando sua aplicação. A diversidade de aplicações se estende também à gestão de recursos hídricos e energéticos por meio da modelagem integrada agro-hidrológica. Além disso, o capítulo busca apresentar abordagens para enfrentar as principais limitações associadas à modelagem agrometeorológica.

INTRODUÇÃO

Em diversos ramos da ciência como a meteorologia, agronomia e hidrologia, os modelos são uma forma de simplificar a realidade por meio de uma série de suposições e representações de processos (Van Ittersum e Donatelli, 2003). São ferramentas úteis por auxiliar na compreensão de diversos processos complexos ao simulá-los, podendo, inclusive, serem usados para auxiliar na estimativa de dados que são difíceis, caros ou complicados de medir (Pasquel *et al.*, 2022).

No caso da agricultura, uma das atividades econômicas mais suscetíveis a riscos, a modelagem vem a contribuir com conhecimento de impactos do clima e interações de fatores genéticos com o meio ambiente, complementando experimentos de campo (Pasquel *et al.*, 2022).



Estima-se que mais de 70% da produtividade agrícola seja impactada por variáveis climáticas, enquanto aproximadamente 30% da produtividade das culturas seja determinada por práticas de manejo agrícola (Sentelhas *et al.*, 2015). No entanto, estes valores variam a depender da cultura e da região avaliada (Vogel *et al.*, 2015).

Apesar da influência clima x agricultura ser bastante clara e conhecida há muito anos, a antecipação dos impactos do clima na produção agrícola ainda é um desafio. Isto porque a inter-relação entre as plantas e o ambiente envolve uma intrincada rede de processos físicos, químicos e biológicos. A análise conjunta de todos esses fatores é indispensável para um bom planejamento, monitoramento e análise de risco para a agricultura.

Neste contexto, a modelagem agrometeorológica surge para contribuir com o entendimento e antecipação dos impactos do clima na agricultura através de representações matemáticas e/ou computacionais que descrevam interações entre fatores climáticos e agrícolas. Esses modelos podem variar desde abordagens estatísticas até modelos de processos detalhados, buscando simular o comportamento das culturas, os ciclos de crescimento, as respostas a diferentes práticas de manejo e as influências do ambiente climático (Monteith e Unsworth, 2014). Através da modelagem, é possível simular cenários diversos e antecipar o comportamento das plantas diante de diferentes condições ambientais, contribuindo para uma melhor compreensão científica ou apoio à tomada de decisão (Jones *et al.*, 2017).

Considerando essa temática, o presente capítulo tem como propósito oferecer uma análise abrangente dos elementos de tempo e clima, explorando os efeitos que eles exercem sobre a produtividade agrícola. Adicionalmente, são apresentados os principais tipos de modelos agrometeorológicos, destacando a maneira pela qual a modelagem pode ser empregada como uma ferramenta decisiva. Essa aplicabilidade se estende não apenas ao setor agrícola, mas também à gestão de recursos hídricos, através da modelagem integrada agro-hidrológica. Ademais, o capítulo também busca apresentar abordagens para enfrentar as principais limitações associadas à modelagem agrometeorológica.

INTERAÇÃO ENTRE OS ELEMENTOS METEOROLÓGICOS E PRODUTIVIDADE AGRÍCOLA

Os elementos meteorológicos que exercem impacto significativo sobre o crescimento e desenvolvimento vegetal englobam a radiação solar, a temperatura do ar, a precipitação, o fotoperíodo, a umidade do ar e do solo, bem como a velocidade e direção do vento. Estas variáveis desempenham um papel crucial na determinação dos resultados agrícolas e têm sido extensivamente estudadas devido à sua influência direta e indireta nas interações complexas entre as plantas e o ambiente (Hoogenboom, 2000; Mavi e Tupper, 2004).

A quantidade e intensidade da radiação solar afetam a fotossíntese, o crescimento e a formação de frutos nas plantas. A deficiência de radiação solar pode resultar em crescimento limitado e menor produção.

A temperatura, além de influenciar a fotossíntese e o metabolismo vegetal, afeta uma série de outros processos nas plantas, incluindo a respiração de manutenção, a

transpiração, as fases fenológicas das culturas, a indução da floração, a composição de óleo nas sementes e a taxa de germinação das sementes (Pereira *et al.*, 2002; Mavi e Tupper, 2004). Essa gama de influências destaca a temperatura como a principal variável meteorológica a ser considerada nos estudos de zoneamento agroclimático, juntamente com a precipitação (Camargo *et al.*, 1977). Extremos de temperatura, como geadas ou ondas de calor, podem causar danos severos às plantas.

A precipitação é a principal fonte de umidade para o solo, principalmente para os cultivos de sequeiro. Baixa umidade do solo induz ao fechamento dos estômatos, reduzindo a fotossíntese, enquanto chuvas excessivas podem causar encharcamento e problemas de drenagem, reduzindo a oxigenação do solo e absorção de água pelas raízes. Ambos os extremos de disponibilidade hídrica reduzem a produtividade das culturas (Hoogenboom, 2000).

O fotoperíodo (horas de sol diárias exigida pela planta) é uma variável do ambiente que interfere tanto no crescimento quanto no desenvolvimento das culturas. No contexto do crescimento, o fotoperíodo corresponde ao tempo em que as plantas realizam o processo da fotossíntese. A adaptação de diferentes cultivares a determinadas regiões depende, além das exigências hídricas e térmicas, de sua exigência fotoperiódica (Farias *et al.*, 2021).

O vento afeta as culturas indiretamente, podendo ter impacto positivo ou negativo, dependendo de sua velocidade. De acordo com Pereira *et al.* (2002), em velocidades baixas a moderadas, o vento contribui para renovar o suprimento de CO₂ e manter a transpiração das plantas. No entanto, em velocidades excessivas, o vento aumenta a transpiração das plantas, levando ao fechamento dos estômatos, redução das folhas e área foliar, resultando em queda abrupta da fotossíntese.

Por fim, a umidade do ar influencia a taxa de evaporação e regula a transpiração das plantas. Além disso, a umidade do ar desempenha um papel crucial na interação entre as plantas e microorganismos, notadamente fungos e bactérias causadores de doenças, podendo favorecer o surgimento de doenças (Sentelhas, 2004).

TIPOS DE MODELOS AGROMETEOROLÓGICOS

Um modelo é uma representação esquemática da concepção de um sistema (Mavi e Tupper, 2004). Os modelos agrometeorológicos são modelos agrícolas (*crop models*) que representam a influência das variáveis meteorológicas nos sistemas agrícolas, mas podem associar outras variáveis de interesse, como por exemplo, características específicas da planta, propriedades físico-hídricas e ciclo de nutrientes no solo, as práticas de manejo da cultura, a incidência de pragas e doenças. A complexidade de cada modelo depende do objetivo que se almeja e das variáveis disponíveis para simulação. No entanto, é importante ter em mente que, como trata-se de uma representação simplificada da realidade, todo modelo contém limitações e erros inerentes aos processos simulados.

De forma geral, os modelos podem ser classificados em modelos estatísticos e modelos de simulação dinâmica (Mavi e Tupper, 2004).

Os modelos estatísticos, também conhecidos como modelos empíricos, relacionam

alguma variável ou fenômeno meteorológico com alguma componente agrícola, como por exemplo, a produtividade final da cultura. Eles dependem principalmente de técnicas estatísticas, como correlação ou regressão e não exigem informações detalhadas sobre a fenologia da planta.

Os modelos estatísticos são capazes de reconhecer os anos em que se pode esperar safras excepcionais e aqueles onde é provável uma frustração nas colheitas, desde que o clima em questão esteja dentro da normalidade. Apesar da sua simplicidade e relação direta entre a produtividade e um ou mais fatores ambientais, não são suficientemente precisos para serem usados em outras regiões e condições ambientais diferentes daquelas para as quais foram ajustados (Jones *et al.*, 2017).

Um exemplo de modelo agrometeorológico estatístico é apresentado por Aparecido *et al.* (2020). Estes autores utilizaram regressão linear múltipla (equação 1) para prever a produtividade da soja no Mato Grosso do Sul.

$$Y = CL + aX1 + bX2 + cX3 + dX4 + eX5 + e \quad (1)$$

Este modelo, relaciona Y, a produtividade da soja (sacas por hectare) com variáveis independentes X1, X2, X3, X4 e X5, que podem ser as variáveis climáticas selecionadas. Os coeficientes a, b, c, d e e são os parâmetros do modelo (pesos), CL é o coeficiente linear (termo constante) e ϵ é o erro aleatório. Neste estudo, Aparecido *et al.* (2020) utilizaram as variáveis climáticas: temperatura do ar ($^{\circ}\text{C}$) - T, precipitação (mm) - P, evapotranspiração potencial (mm) - ETP, déficit hídrico - DEF e excesso hídrico (mm) - EXC. Inúmeros modelos foram gerados para cada região do estado do Mato Grosso do Sul (norte, central e sul), sendo selecionado o modelo com a maior precisão para cada uma das regiões. A tabela 1 apresenta os 3 modelos selecionados. Observa-se que, em cada região um conjunto de variáveis meteorológicas foi mais adequado para explicar a variação da produtividade de soja.

Tabela 1 - Modelos estatísticos calibrados para estimar a produtividade de soja no estado do Mato Grosso do Sul.

Regiões	Modelos	Previsão (meses)
Norte	$Y = 0.029 * P_{DEZP} - 0.245 * ETR_{NOVP} - 0.252 * ETR_{JANC} + 0.028 * EXC_{JANC} + 82.461$	2
Centro	$Y = 0.0214 * P_{JANC} - 0.290 * ETP_{DEZP} - 0.012 * ETR_{JANC} + 0.0183 * EXC_{DEZP} + 63.91$	2
Sul	$Y = 0.056 * P_{DEZP} - 0.045 * EXC_{NOVP} - 0.035 * EXC_{JANC} + 0.053 * EXC_{FEVC} + 39.817$	1

Fonte: adaptado de Aparecido *et al.* (2020)

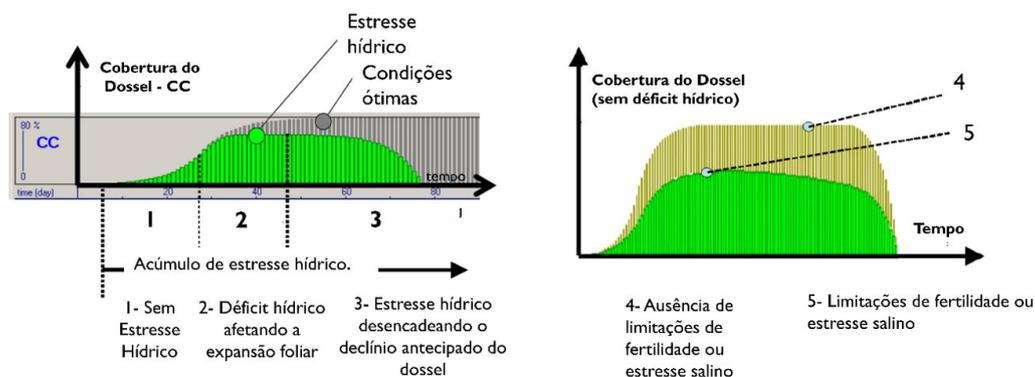
Interessante notar que, cada modelo foi capaz de antecipar a produtividade em tempos diferentes. Isso é decorrente da previsibilidade de cada região atrelada às variáveis meteorológicas selecionadas em cada modelo. Este modelo foi eficiente para prever a produtividade da soja nas porções norte e centro do estado com 2 meses de antecedência. Um período essencial para que os produtores possam realizar o planejamento pré e pós-colheita (Aparecido *et al.*, 2020).

Em contraste aos modelos estatísticos, os modelos de simulação dinâmica, também conhecidos como mecanicistas, dependem da modelagem de processos biofísicos (Pasquel *et al.*, 2022). Eles se baseiam em equações matemáticas que descrevem o processo de desenvolvimento e crescimento das plantas, impulsionados pelo clima. Além disso, é possível incluir a simulação e efeitos dos nutrientes no solo, do manejo e da dinâmica da água no crescimento das plantas (Basso e Liu, 2019).

Em outras palavras, estes modelos visam simular interações entre o solo-planta-atmosfera-manejo (Hoogenboom, 2000). Para alcançar isso, abordagens multidisciplinares são necessárias e os modelos de cultivo podem levar em consideração componentes biológicos, fisiológicos, ecológicos, físicos e econômicos (Pasquel *et al.*, 2022). A integração dessas abordagens na modelagem levou ao desenvolvimento de inúmeros modelos de cultivo como os diversos modelos da família DSSAT (Boote *et al.*, 2019), APSIM (Holzworth *et al.*, 2014), WOFOST (De Wit *et al.*, 2019), AquaCrop (Steduto *et al.*, 2009), dentre inúmeros outros.

Uma vez que estes modelos representam o desenvolvimento da cultura, eles fornecem informações mais detalhadas que os modelos estatísticos. No entanto, quanto mais acurado um modelo dinâmico, mais informações são necessárias para simulação. Na figura 1 é apresentado um desenho esquemático da simulação de desenvolvimento de uma cultura hipotética, na qual é possível notar os efeitos do estresse hídrico e de fertilidade do solo.

Figura 1 – Simulação do desenvolvimento do dossel de uma cultura hipotética mostrando o comportamento sem estresse hídrico (1) e com estresse hídrico (2 e 3) sem estresse de fertilidade no solo (4) e com limitações nutricionais e excesso de salinidade.



Fonte: adaptado de Raes *et al.* (2018)

Interessante notar que, nas simulações dinâmicas, é possível avaliar as componentes agrícolas no decorrer de toda a safra. Nestes exemplos apresentados nas figura 1, é possível acompanhar o desenvolvimento do dossel e o exato momento no decorrer da safra onde iniciou-se o estresse hídrico e impactos da deficiência nutricional.

Outras características que distinguem muitos modelos são suas escalas de simulação. Em se tratando de escala espacial, a maioria dos modelos agrometeorológicos são modelos pontuais, ou seja, simulam a nível de uma pequena área, talhão ou uma fazenda. Por sua vez, eles não levam em consideração dados ou efeitos de áreas vizinhas. Por outro lado, diversas ferramentas e adaptações têm sido desenvolvidas para permitir

que tais modelos simulem de forma espacial, ou seja, considerem grandes áreas para simulação e levem em consideração a variabilidade espacial das variáveis de entrada e produza variáveis de saída considerando tal variabilidade. No caso do modelo AquaCrop, a ferramenta AquaCrop GIS (Lorite *et al.*, 2013), apesar de não se tratar de simulação espacial, permite que as simulações pontuais sejam exibidas em um Sistema de Informações Geográficas (GIS). Mais recentemente, uma adaptação do AquaCrop para a linguagem Fortran foi desenvolvida para permitir simulações espaciais e de longos períodos (Tomasella *et al.*, 2023).

Em termos de escala temporal, as variáveis, principalmente as meteorológicas, podem ser diárias, decendiais, quinzenais, mensais ou mesmo por ciclo da cultura. Cada tipo de modelo requer ou permite simulações em diferentes escalas temporais, sendo a diária a mais recomendada. Tais informações podem ser provenientes de dados observados, no entanto, nos últimos anos, tem sido muito frequente o uso de informações provenientes de modelos climáticos, sejam elas da previsão de tempo, de clima na escala sazonal ou subsazonal e projeções climáticas.

Dessa forma, a depender do tipo de modelo e das escalas espacial e temporal utilizadas, é possível determinar a melhor aplicação.

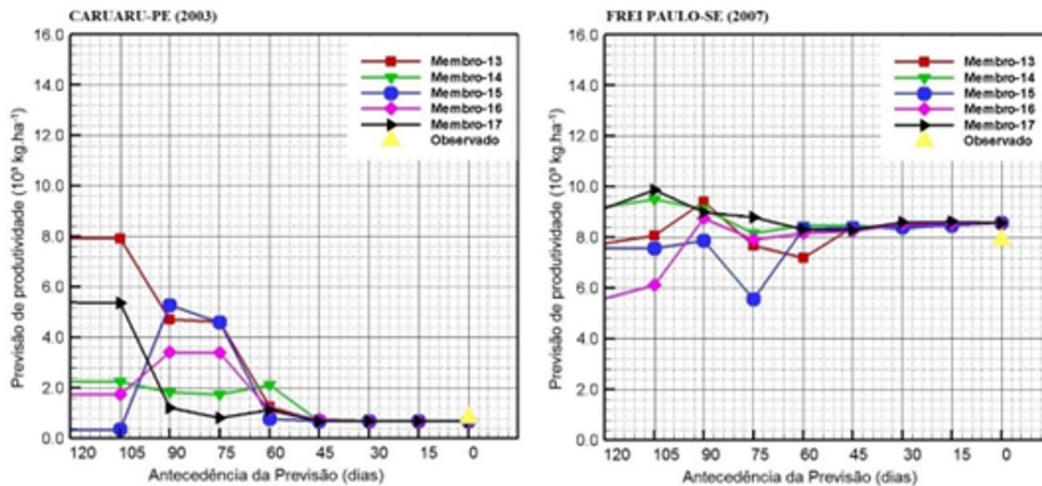
APLICAÇÕES DA MODELAGEM AGROMETEORÓLOGICA

Dentre as diversas aplicações da modelagem agrometeorológica, o trabalho de Soler *et al.* (2007) utiliza o modelo CERES-MAIZE para prever produtividade de milho safrinha. Estes autores relataram boa previsibilidade com antecedência de 45 dias, além de relacionar a produtividade com variabilidades climáticas como El Niño Oscilação Sul – ENOS.

Outra aplicação foi apresentada por Martins *et al.* (2018). Estes autores demonstraram a viabilidade de compor um Sistema de Previsão sazonal de Produtividade de milho na região Nordeste do Brasil, com uso do modelo AquaCrop com dados históricos e previsão climática sazonal do modelo Eta (Chou *et al.*, 2005). A figura 2 exemplifica as previsões para Caruaru - PE e Frei Paulo - SE.

Apesar de no início da safra os membros apresentarem alta variabilidade, à medida que a estação de crescimento progride e mais observações se tornaram disponíveis, a produtividade prevista rapidamente converge para a produtividade observada. De forma geral, valores muito próximos aos observados na colheita foram previstos pelo modelo com 60 dias de antecedência. Este estudo de caso traz ainda uma questão interessante por se tratar de um ano muito seco (2003) e um ano muito chuvoso (2007), sendo possível também avaliar a sensibilidade do modelo a estações chuvosas atípicas.

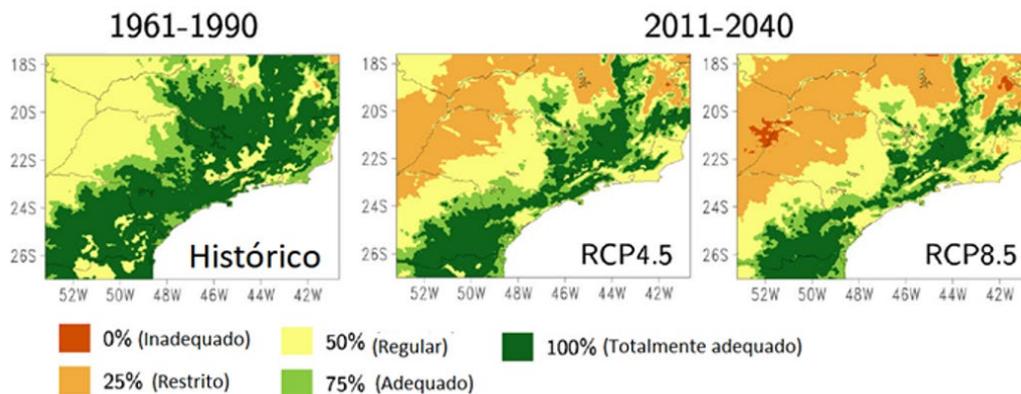
Figura 2 - Simulação de um sistema de previsão climática sazonal para o milho em Caruaru -PE (2003) e Frei Paulo-SE (2007) utilizando o modelo AquaCrop e com previsões sazonais do modelo Eta.



Fonte: adaptado de Martins *et al.* (2018)

Considerando uma escala de tempo de longo prazo, Tavares *et al.* (2017) elaboraram um Zoneamento Agroclimático - ZA do café Arábica na região Sul de Minas Gerais, considerando projeções climáticas do modelo regional Eta. O estudo mostra que as áreas adequadas para produção de café tendem a reduzir de 20 a 60% das áreas atualmente adequadas para o cultivo de café no Sudeste do Brasil (figura 3). Além disso, áreas de alto risco climático aumentam devido ao aumento da temperatura, resultando em quedas de produtividade cerca de 25% até o final do século XXI.

Figura 3 - Zoneamento Agroclimático da cultura do café no Sul de Minas Gerais.



Fonte: adaptado de Tavares *et al.* (2017)

Este tipo de abordagem vem sendo cada vez mais utilizada na modelagem agrometeorológica com a finalidade de avaliar impactos e riscos das mudanças climáticas em diferentes culturas agrícolas e propor medidas de adaptação que sejam eficientes na redução dos danos. Outros exemplos dessa abordagem podem ser consultados em Asseng *et al.* (2015), Boonwichai *et al.* (2019), Martins *et al.* (2019).

Modelagem integrada agro-hidrológica

Os impactos das mudanças globais, sejam elas relacionadas ao clima ou a padrões de vida em sociedade, tem colocado pressão sobre o uso de recursos naturais. Sendo a

agricultura um dos maiores consumidores de água, entender o impacto das retiradas de água para suprimento agrícola e seu impacto na vazão dos rios é primordial para garantir sustentabilidade na produção de alimentos e de outros usos, como abastecimento público/industrial, geração de energia e manutenção dos ecossistemas aquáticos e terrestres associados. Esses diferentes interesses passam a ser conflitantes em situações de escassez hídrica, quando a água deve prioritariamente ser destinada ao consumo humano e animal, segundo a Política Nacional de Recursos Hídricos (Brasil, 1997), justificando, muitas vezes, a imposição de restrições as demais atividades.

Além da gestão desses múltiplos interesses, é importante verificar a melhor escala para análise do problema. Mesmo que os modelos agrometeorológicos possam ser integrados a ferramentas de informações geográficas para permitir uma análise discretizada do espaço, a unidade básica para análise dos processos hidrológicos é a bacia hidrográfica, sendo fundamental a identificação das suas fronteiras.

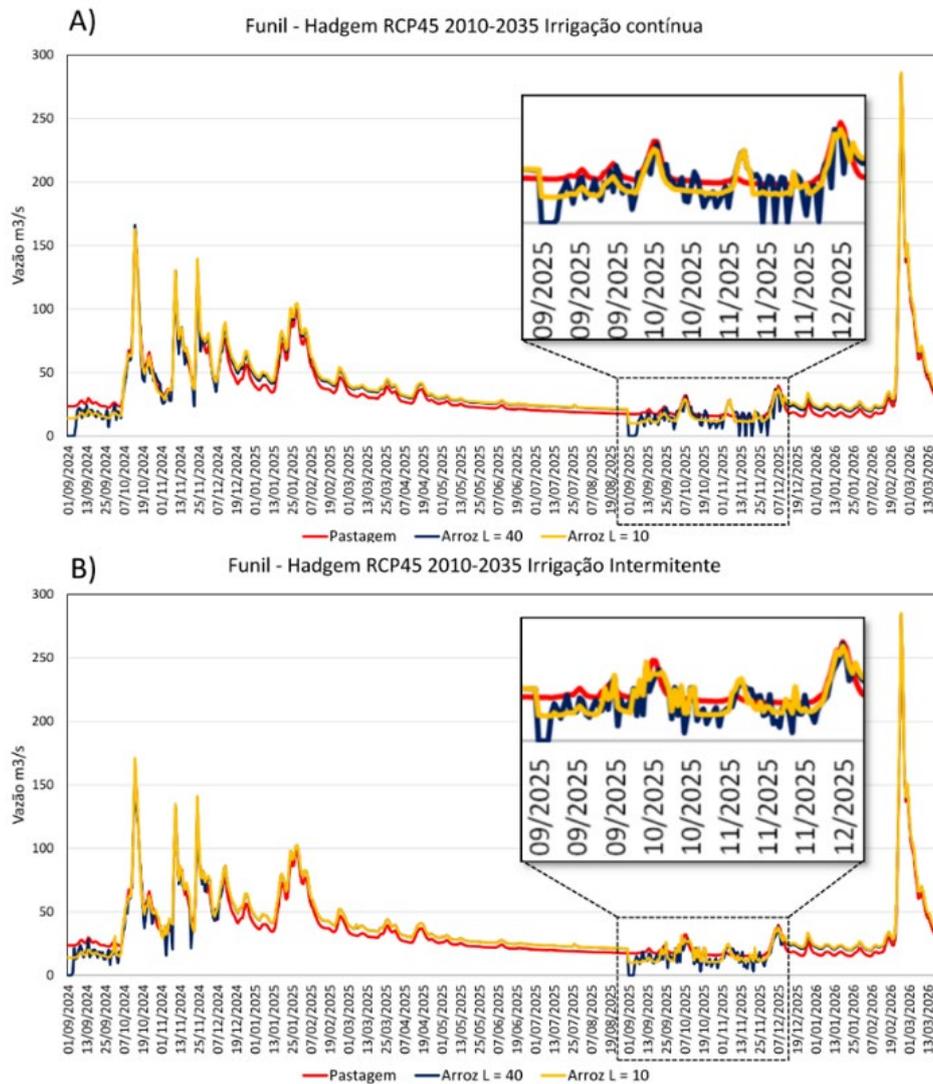
Uma das formas de considerar interações complexas entre esses múltiplos componentes é com uso de modelagem integrada. Diversos modelos podem ser integrados a fim de se contabilizar um número maior de variáveis. Para análise da questão de uso de água e produção de alimentos, pode ser utilizado a modelagem agrometeorológica integrada à modelagem hidrológica. Este tipo de acoplamento visa, além de focar no sistema agrícola, subsidiar a gestão de recursos hídricos e energéticos.

Uma abordagem mais recente que fundamenta a proposição de ferramentas e metodologias destinadas a gestão de múltiplos recursos é conhecida como *nexo água, energia e alimentos*. Essa nova perspectiva tem como princípio básico a identificação das possíveis conexões existentes entre esses recursos, sejam elas de compensação ou de competição, sinergias e *trade-offs*. Diversos exemplos de modelagem integrada no âmbito da abordagem *nexo* foram propostos, com diferentes níveis de complexidade, como por ser visto em Amjath-Babu *et al.* (2019) e Vinca *et al.* (2020).

No Brasil, a resolução espacial em grade celular também possibilitou o acoplamento do modelo agrícola AquaCrop (Tomasella *et al.*, 2023), com o modelo hidrológico distribuído MHD-INPE (Rodriguez e Tomasella, 2016). Essa integração foi realizada para avaliar o impacto dos processos de uso e ocupação do solo, de mudanças climáticas e de políticas de uso da água na disponibilidade hídrica futura da bacia do rio Paraíba do Sul (Canamary *et al.*, 2023). Essa região está situada entre os Estados de São Paulo, Rio de Janeiro e Minas Gerais e localiza duas transposições que garantem a manutenção da segurança hídrica das regiões metropolitanas de São Paulo e Rio de Janeiro. Essa integração de modelos permitiu, portanto, a composição de cenários a partir da combinação de projeções de ampliação do serviço de abastecimento e do nível de consumo de água, além de cenários de irrigação da cultura de arroz (Martins *et al.*, 2023), inundação contínua e intermitente, maior demanda agrícola da região estudada.

Um exemplo de simulação realizada com essa ferramenta, mostra o impacto de diferentes estratégias de irrigação na vazão afluente a usina hidrelétrica do Funil (figura 4), cuja capacidade instalada é de 216 MW, uma das maiores da região.

Figura 4 - Simulação da vazão afluyente ao reservatório do Funil na bacia do rio Paraíba do Sul para diferentes estratégias de irrigação de arroz usando diferentes lâminas de reposição. A) irrigação contínua e B) irrigação intermitente.



Fonte: Autoria Própria (2023)

As simulações consideram os dados climáticos do modelo Eta-HadGEM2-ES e o cenário RCP 4.5 de emissões de gases do efeito estufa. Comparou-se o impacto nas vazões do Rio Paraíba do Sul ao considerar a região plantada com pastagem e arroz. Para o arroz duas estratégias de irrigação foram utilizadas: contínua (mantendo a lâmina de água na superfície a 8 cm) e intermitente (sem manutenção de lâmina acima da superfície). Para cada uma delas testou-se diferentes reposições de água, reposição de 40 mm (L=40) e reposição de 10 mm (L=10).

A figura 4 mostra que, as simulações considerando a cultura do arroz tem períodos concentrados de irrigação que, em anos secos, resulta em colapso na vazão do rio, por exemplo, ao considerar L=40 e irrigação contínua (figura 4A). Ao reduzir a lâmina de reposição para L=10, a irrigação contínua reduz o impacto na vazão do rio, no entanto, ainda contribui para sua manutenção em valores baixos durante toda o período de irrigação (figura 4A). Por outro lado, ao considerar L=10 e irrigação intermitente (figura 4B), tem-se um impacto mais equilibrado na vazão do rio. Apesar da vazão oscilar durante o período de irrigação, os valores são ligeiramente superiores à irrigação contínua com a mesma lâmina de irrigação.

Vale ressaltar que, as diferentes estratégias de irrigação resultaram em variações pouco significativas do ponto de vista de produtividade agrícola (Martins *et al.*, 2023). Em contrapartida, do ponto de vista de gestão de recursos hídricos, tais simulações mostram que, estratégias de irrigação mais eficientes podem ser a resposta para períodos de escassez hídrica. Estes resultados servem como subsídio à gestão de recursos hídricos e energéticos na Bacia, a fim de otimizar os usos de água e evitar comprometimento no suprimento hídrico para os diferentes usuários.

LIMITAÇÕES E DESAFIOS

Frente a todas as vantagens e possibilidades de aplicação da modelagem agrometeorológica, é preciso destacar algumas limitações, que vão desde a calibração de parâmetros da cultura até obtenção de dados meteorológicos observados e a falta de uma eficiente interação modelo-usuário final.

A parametrização dos modelos agrometeorológicos requer informações detalhadas de culturas desenvolvidas em ambientes controlados sob influência de condições ambientais ótimas, suprimento hídrico e nutricional adequados e livres de pragas e doenças. No Brasil, estes experimentos são, em sua maioria, desenvolvidos por universidades e institutos de pesquisa. No entanto, nem sempre é fácil encontrar tais dados no detalhamento requerido pelo modelo. Por exemplo, na maioria dos experimentos de campo são feitas medidas de produtividade final, mas raramente são feitas medidas de biomassa, crescimento do dossel, índice de área foliar, dentre outras variáveis que são imprescindíveis na calibração dos modelos. Para substituir os dados experimentais, tem sido utilizado dados de sensoriamento remoto, seja por meio de fotografias aéreas por drones para estimativa da área foliar (Liu *et al.*, 2019, Martins *et al.*, 2023), seja por meio de imagens de satélite para estimar o acúmulo de biomassa no decorrer do desenvolvimento da cultura (Ndikumana *et al.*, 2018, Martins *et al.*, 2023).

Outro aspecto que constitui uma limitação à modelagem agrometeorológica é a indisponibilidade de dados meteorológicos provenientes de uma rede com boa densidade de estações. Segundo Sentelhas (2012) este fator torna as simulações pouco abrangentes e pouco confiáveis. A necessidade de uma boa estrutura observacional é imprescindível para a simulação e há regiões no Brasil em que a densidade de estações de observações é muito baixa, comprometendo os resultados, principalmente quando há necessidade de interpolar dados. Aliado à questão da baixa densidade de estações meteorológicas, inclui-se as falhas das séries históricas existentes, tanto de dados climatológicos, quanto de dados de solos. No caso da precipitação, que talvez seja a variável mais importante na simulação agrometeorológica, uma alternativa é o uso de produtos que unem diferentes bases de dados, como por exemplo dados do MERGE (Rozante *et al.*, 2020), WorldClim (Fick e Hijmans, 2017) e CHIRPS (*Climate Hazards Group InfraRed Precipitation with Station data*) (Funk *et al.*, 2015).

No caso de dados de solo, é possível consultar o levantamento de perfis de solo do Projeto Radam-Brasil (Radam-Brasil, 1981) e o *SoilGrids* (Poggio *et al.*, 2021), com dados disponíveis para todo globo. No entanto, estes bancos de dados possuem informações

de propriedades físicas do solo, sendo necessário, na maioria dos modelos, informações de propriedades hídras do solo. Tais informações podem ser obtidas por estimativas por meio de funções de pedotransferência, conforme detalhado por Ottoni *et al.* (2019).

Apesar da modelagem climática ter evoluído bastante nos últimos tempos, sabe-se que os modelos apresentam destrezas diferentes em diferentes regiões. Portanto, algumas áreas são passíveis de maiores erros que outras, dependendo da dificuldade que os modelos têm de representar o estado da atmosfera. Dessa forma, a acurácia das previsões de curto e médio prazo configuram um grande desafio para modelagem agrícola. Como forma de contornar tal limitação, tem sido utilizadas técnicas de correção de viés de tais modelos. Isso evita que erros sistemáticos da modelagem climática sejam propagados na modelagem agrícola. Detalhes sobre o uso de algumas destas técnicas de correção de viés podem ser vistos em Bardossy e Pegram (2011) e Oliveira *et al.* (2015). Além disso, o uso de previsão climática subsazonal, ainda pouco utilizado no Brasil, deve ser avaliado como uma forma de melhorar a antecipação dos fenômenos meteorológicos e seus impactos.

Por fim, mas não exaurindo todas as limitações, é importante salientar as limitações inerentes ao uso dos modelos agrometeorológicos e das informações geradas por eles. A modelagem agrometeorológica é uma ferramenta eficaz, considerada uma forma eficiente de transmitir os resultados da pesquisa para agricultores e profissionais que trabalham na área agrícola (Moreto, 2020; Zhao *et al.*, 2019). No entanto, segundo Archontoulis e Licht (2016), estes modelos têm sido utilizados muito mais para fins de pesquisa do que para abordar questões práticas (do dia a dia), como por exemplo, para subsídio à agricultura de precisão. Neste caso, há uma limitação visível na transferência de informações da academia para o usuário final. Os modelos aqui tratados podem ser adaptados para uso em diversas instâncias, na academia para pesquisas científicas, mas também para o produtor dentro de sua fazenda, com uma interface intuitiva e amigável.

Assim, para disseminar o uso de tais modelos, é imprescindível que haja uma intermediação entre as duas pontas (o desenvolvedor do modelo e o usuário final).

Neste sentido, a comunicação científica, assim como o papel da extensão universitária e extensão rural seria importante para fazer essa “ponte” e tornar o conhecimento “utilizável” para sanar problemas, não somente do ponto de vista científico, mas principalmente, os problemas que ocorrem no âmbito da fazenda.

CONSIDERAÇÕES FINAIS

Os modelos agrometeorológicos são ferramentas importantes no apoio à tomada de decisão, tanto para subsidiar as políticas governamentais, como para inovar na criação de políticas de gerenciamento dos riscos e alerta precoce, tornando a sociedade preparada para enfrentar os efeitos da seca e ainda fazendo as comunidades mais resilientes aos impactos.

Tendo em vista as projeções de mudanças no clima e estimativas de aumento de demanda hídrica, principalmente por parte do setor agrícola, a modelagem integrada será cada vez mais importantes como ferramenta para avaliar estratégias mais eficientes de

irrigação, que não conflitam com a geração de energia e demais usos.

Além das aplicações aqui exemplificadas, diversas outras são possíveis com uso de modelos agrometeorológicos em suas diversas escalas temporais e espaciais. Modelos agrometeorológicos têm sido utilizados em conjunto com sensoriamento remoto e, mais recentemente, com técnicas de redes neurais, aprendizado de máquina e inteligência artificial, o que tem contribuído para melhorar o desempenho das simulações.

A escolha do modelo a ser utilizado deve sempre partir do objetivo que se deseja alcançar e dos dados disponíveis para simulação. Considerar as limitações inerentes à modelagem é mandatório, principalmente para subsídios à tomada de decisão. Por fim, conhecer e antecipar os riscos que afetam a produção agrícola e poder avaliar as possibilidades de enfrentamento são as maiores vantagens ao utilizar a modelagem agrometeorológica.

REFERÊNCIAS

AMJATH-BABU, T. S., SHARMA, B., BROUWER, R., RASUL, G., WAHID, S. M., NEUPANE, N., BHATTARAI, U., SIEBER, S. Integrated modelling of the impacts of hydropower projects on the water-food-energy nexus in a transboundary Himalayan River basin. **Applied Energy**, 239, 494–503. 2019.

ARCHONTOULIS, S; LICHT, M. Crop Modeling Has Answers for Real-life Problems. 2016. Disponível em: <https://www.extension.iastate.edu/news/crop-modeling-has-answers-real-life-problems>. Acesso em 04 Set 2023.

ASSENG, S., ZHU, Y., WANG, E., ZHANG, W. Crop modeling for climate change impact and adaptation. **Crop Physiology**, 505–546. 2015.

APARECIDO, L. E. O, TORSONI, G. B., DA SILVA CABRAL DE MORAES, J. R., DE MENESES, K. C., LORENÇONE, J. A., LORENÇONE, P. A. Modeling the impact of agrometeorological variables on soybean yield in the Mato Grosso Do Sul: 2000–2019. **Environment, Development and Sustainability**. 2020.

BARDOSSY, A., PEGRAM, G. Downscaling precipitation using regional climate models and circulation patterns toward hydrology. **Water Resour. Res.** 47. 2011.

BASSO, B.; LIU, L. Seasonal crop yield forecast: Methods, applications, and accuracies. **Advances in Agronomy**. 2019.

BOONWICHAI, S., SHRESTHA, S., BABEL, M.S., WEESAKUL, S., DATTA, A. Evaluation of climate change impacts and adaptation strategies on rainfed rice production in Songkhram River Basin, Thailand. **Sci. Total Environ.** 652, 2019.

BOOTE, K.J. (Ed.). **Advances in Crop Modeling for a Sustainable Agriculture**. Burleigh Dodds Science Publishing, Cambridge, United Kingdom. 2019.

BRASIL. Lei nº 9.433, de 8 de janeiro de 1997. Institui a Política Nacional de Recursos Hídricos. **Diário Oficial da República Federativa do Brasil**, Brasília, DF 09/01/1997, P. 470. 1997.

- CAMARGO, A. P.; ALFONSI, R. R., PINTO, H. S.; CHIARINI, J. V. Zoneamento de aptidão climática para culturas comerciais em áreas de cerrado. In: IV Simpósio sobre o Cerrado: bases para a utilização agropecuária. **Anais**. Coord. MG. Ferri, Belo Horizonte, Ed. Itatiaia, São Paulo, EDUSP, 1977, p.89-105.
- CANAMARY, E. A., TOMASELLA, J., MARCHEZINI, V., PAIVA, A. C. E., MARTINS, M. A.; SILVA, D. DE M. Segurança Hídrica e Energética na Bacia do Paraíba do Sul Diante das Mudanças Climáticas. In **Anais IV SRHPS - Simpósio de Recursos Hídricos da Bacia do Rio Paraíba do Sul 2023**.
- CHOU, S.C., BUSTAMANTE, J.F., GOMES, J.L. Evaluation of eta model seasonal precipitation forecasts over South America. **Nonlinear Process Geophys.** 2005.
- DE WIT, A., BOOGAARD, H., FUMAGALLI, D., JANSSEN, S., KNAPEN, R., VAN KRAALINGEN, D., *et al.* 25 years of the WOFOST cropping systems model. **Agricultural Systems**, 168, 154–167. 2019.
- FARIAS, J.R.B.; NEPOMUCENO, A.L.; NEUMAIER, N. Fotoperíodo. Embrapa Soja. 2021. Disponível em: <https://www.embrapa.br/agencia-de-informacao-tecnologica/cultivos/soja/pre-producao/caracteristicas-da-especie-e-relacoes-com-o-ambiente/exigencias-climaticas/fotoperiodo>. Acesso em 05 Set 2023.
- FICK, S.E., HIJMANS, R.J. WorldClim 2: new 1-km spatial resolution climate surfaces for global land areas. **Int J Climatol** 37(12):4302–4315. 2017.
- FUNK, C., PETERSON, P., LANDSFELD, M., PEDREROS, D., VERDIN, J., SHUKLA, S., HUSAK, G., ROWLAND, J., HARRISON, L., HOELL, A., MICHAELSEN, J. The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. **Sci Data** 2:150066. 2015.
- HOLZWORTH, D. P., HUTH, N. I., DEVOIL, P. G., ZURCHER, E. J., HERRMANN, N. I., MCLEAN, G., *et al.* APSIM—Evolution towards a new generation of agricultural systems simulation. **Environmental Modelling & Software**, 62, 327–350. 2014.
- HOOGENBOOM, G. Contribution of agrometeorology to the simulation of crop production and its applications. *Agricultural and Forest Meteorology*, 103(1–2), 137–157. 2000.
- JONES, J. W., ANTLE, J. M., BASSO, B., BOOTE, K. J., CONANT, R. T., FOSTER, I., *et al.* Brief history of agricultural systems modeling. **Agricultural Systems**. 2017.
- LIU, J.; PATTEY, E.; ADMIRAL, S. Assessment of in situ crop LAI measurement using unidirectional view digital photography. **Agricultural and Forest Meteorology**. 2019.
- LORITE, I. J., GARCÍA-VILA, M., SANTOS, C., RUIZ-RAMOS, M., FERERES, E. AquaData and AquaGIS: Two computer utilities for temporal and spatial simulations of water-limited yield with AquaCrop. **Computers and Electronics in Agriculture**. 2013.
- MARTINS, M. A., TOMASELLA, J., BASSANELLI, H. R., PAIVA, A. C. E., VIEIRA, R. M. S. P., CANAMARY, E. A., ALVARENGA, L. A. On the sustainability of paddy rice cultivation in the Paraíba do Sul River basin (Brazil) under a changing climate. *Journal of Cleaner Production*, 386. 2023.

- MARTINS, M. A., TOMASELLA, J., AND DIAS, C. G. Maize yield under a changing climate in the Brazilian northeast: impacts and adaptation. **Agric. Water Manag.** 2019.
- MARTINS, M. A., TOMASELLA, J., RODRIGUEZ, D. A., ALVALÁ, R. C. S., GIAROLLA, A., GAROFOLO, L. L., *et al.* Improving drought management in the Brazilian semiarid through crop forecasting. **Agric. Syst.** 160, 21–30. 2018.
- MARVI, H.S.; TUPPER, G.J. **Agrometeorology Principles and Applications of Climate. Studies in Agriculture**, Food Products Press, New York. 2004.
- MONTEITH, J.L; UNSWORTH, M.H. **Principles of Environmental Physics: Plants, Animals, and the Atmosphere.** Fourth Edition. Academic Press. 2014.
- MORETO, V.B. **Modelagem para auxiliar na otimização do sistema “climate-smart-agriculture” para cultivo de cana-de-açúcar.** Jaboticabal. 2020. Tese (doutorado). UNESP.
- NDIKUMANA, E., MINH, D.H.T., NGUYEN, H. T.D. *et al.* Estimation of Rice Height and Biomass Using Multitemporal SAR Sentinel-1 for Camargue, Southern France. **Remote Sensing**, 10(9), 1394. 2018.
- OLIVEIRA, G.G.; PEDROLLO, O. C.; CASTRO, N.M.R. As incertezas associadas às condições climáticas obtidas pelo modelo Eta CPTec/HADCM3: avaliação comparativa entre os dados simulados e observados de precipitação, evapotranspiração e vazão na bacia hidrográfica do rio Ijuí, Brasil. **Revista Brasileira de Meteorologia**, v. 30, n. 1, 101 – 121. 2015.
- OTTONI, M. V., FILHO, T. B. O., LOPES-ASSAD, M. L. R. C., FILHO, O. C. R. Pedotransfer functions for saturated hydraulic conductivity using a database with temperate and tropical climate soils. **Journal of Hydrology**. 2019.
- PASQUEL, D.; ROUX, S.; RICHETTI, J.; CAMMARANO, D., TISSEYRE, B; TAYLOR, J.A. A review of methods to evaluate crop model performance at multiple and changing spatial scales. **Precision Agriculture**. 23:1489–1513. 2022.
- PEREIRA, A. R.; ANGELOCCI, L. R.; SENTELHAS, P. C. **Agrometeorologia: Fundamentos e aplicações práticas.** Guaíba: Agropecuária, 2002. 478p.
- POGGIO, L., DE SOUSA, L. M., BATJES, N. H., HEUVELINK, G. B. M., KEMPEN, B., RIBEIRO, E., AND ROSSITER, D. SoilGrids 2.0: producing soil information for the globe with quantified spatial uncertainty, **SOIL**, 7, 217–240, 2021.
- RADAM-BRASIL. **Levantamento de Recursos Naturais.** Rio de Janeiro: IBGE. 1981.
- RAES, D., STEDUTO, P., HSIAO, T. C., AND FERERES, E. AquaCrop reference manual, AquaCrop version 4.0. Rome, Italy: FAO. 2018.
- RODRIGUEZ, D. A.; TOMASELLA, J. On the ability of large-scale hydrological models to simulate land use and land cover change impacts in Amazonian basins. **Hydrological Sciences Journal**, v. 61, n. 10, p. 1831–1846, 2016.
- ROZANTE, J. R., GUTIERREZ, E. R., FERNANDES, A. DE A., VILA, D. A. Performance of precipitation products obtained from combinations of satellite and surface observations. **International Journal of Remote Sensing**, 41(19), 2020.

SENTELHAS, P., BATTISTI, R., CÂMARA, G., FARIAS, J., HAMPF, A., NENDEL, C. The soybean yield gap in Brazil – magnitude, causes and possible solutions for sustainable production. **The Journal of Agricultural Science**, 153(8). 2015.

SENTELHAS, P.C. Uso de modelos de simulação de culturas como ferramentas para identificação dos agentes deflagradores de colapso na produção agrícola. Apresentação da III Reunião Técnica do CEMADEN. Fortaleza. 2012. Disponível em < <http://www.cemaden.gov.br/apresentacoes/IIIrtdocemaden.php>. Acesso em 25 Ago 2023.

SENTELHAS, P.C. **Duração do período de molhamento foliar: aspectos operacionais na sua medida, variabilidade espacial em diferentes culturas e sua estimativa a partir do modelo de Pernman-Motheith**. Piracicaba, São Paulo. 2004.

SOLER, C. M. T., SENTELHAS P. C. AND HOOGENBOOM G. Application of the CSM-CERES-661 Maize model for planting date evaluation and yield forecasting for maize grown off-662 season in a subtropical environment. **European Journal of Agronomy** 27(2-4), 165-77. 2007

STEDUTO, P., HSIAO, T. C., RAES, D., FERERES, E. AquaCrop-The FAO crop model to simulate yield response to water: I. Concepts and underlying principles. **Agronomy Journal**, 101(3), 426–437. 2009.

TAVARES, P. da S., GIAROLLA, A., CHOU, S. C., SILVA, A. J. DE P., LYRA, A. DE A. Climate change impact on the potential yield of Arabica coffee in southeast Brazil. *Regional Environmental Change*, 18(3), 873–883. 2017.

TOMASELLA, J., MARTINS, M.A. AND SHRESTHA, N. An open-source tool for improving on-farm yield forecasting systems. **Front. Sustain. Food Syst.** 2023.

VAN ITTERSUM, M. K., DONATELLI, M. Modelling cropping systems—Highlights of the symposium and preface to the special issues. **European Journal of Agronomy**, 2003. 18, 187–197.

VINCA, A., PARKINSON, S., BYERS, E., BUREK, P., KHAN, Z., KREY, V., DIUANA, F. A., WANG, Y., ILYAS, A., KÖBERLE, A. C., STAFFELL, I., PFENNINGER, S., MUHAMMAD, A., ROWE, A., SCHAEFFER, R., RAO, N. D., WADA, Y., DJILALI, N., RIAHI, K. The NExus Solutions Tool (NEST) v1.0: An open platform for optimizing multi-scale energy-water-land system transformations. **Geoscientific Model Development**, 13(3), 1095–1121. 2020.

VOGEL E, DONAT MG, ALEXANDER VL, MEINSHAUSEN M, RAY DK, KAROLY D, *et al*. The effects of climate extremes on global agricultural yields. *Environmental Research Letters*. 2019.

ZHAO, Y.U., JUSTINA, D. D. D., WATANABE, J., ROCHA, J. V., GRAZIANO, P., LAMPARELLI, R. A. C. Multivariety sugarcane sucrose estimation using a combination of spectral and agrotechnology methods. **Proceedings** of the SPIE, Volume 10783, id. 107830L 14 pp.2018.

Modelagem da interação entre aerossóis e nuvens

Madeleine Sánchez Gácita Casagrande
Fernanda Casagrande

RESUMO

As interações entre aerossóis e nuvens afetam o ciclo hidrológico e representam uma das maiores fontes de incerteza na quantificação da forçante climática dos aerossóis. O presente capítulo descreve de forma resumida os fundamentos teóricos que descrevem a ativação dos aerossóis como núcleos de condensação de nuvens, incluindo a teoria de Köhler, a representação das propriedades higroscópicas dos aerossóis, os mecanismos presentes na ativação dos aerossóis como CCN dentro da nuvem e, por fim, a abordagem tipicamente seguida para parametrizar estes processos e assim incluí-los na modelagem numérica do tempo e do clima.

INTRODUÇÃO

As interações entre as partículas de aerossol e as nuvens na atmosfera são uma das maiores fontes de incerteza na quantificação da forçante climática dos aerossóis (Bauer e Menon, 2012; IPCC, 2013). A atividade como CCN (do inglês *cloud condensation nuclei*) e IN (do inglês *ice nuclei*) dos aerossóis tem uma enorme importância no ciclo hidrológico. Em função da quantidade de partículas ativadas atuando como núcleos de condensação, a precipitação pode ser suprimida ou a convecção revigorada, neste último caso, resultando em tormentas mais intensas (Dagan *et al.*, 2015; Jiang *et al.*, 2010, 2008; Khain *et al.*, 2005; Rosenfeld *et al.*, 2008, entre outros).

A teoria de ativação de partículas de aerossol está fundamentada na teoria de Köhler (Köhler, 1936) que rege o crescimento por condensação de partículas de aerossol em equilíbrio com o ambiente, considerando o tamanho e composição do aerossol (do qual vai depender a sua higroscopicidade). Esta teoria, assim como considerações sobre a modelagem de populações de aerossóis com diferentes estados de mistura, é descrita neste capítulo de forma resumida. Posteriormente, aborda-se a ativação como CCN de partículas fora das condições de equilíbrio. As abordagens mais comuns para as parametrizações da ativação de partículas como CCN são comentadas a continuação. O capítulo termina, por fim, com as considerações finais.

Ainda que o conhecimento dos processos envolvidos na ativação dos aerossóis tem melhorado consideravelmente em anos recentes



(Farmer *et al.*, 2015), a inclusão de informações detalhadas sobre as populações de aerossóis nos modelos globais e regionais é muitas vezes inviável, sendo muito relevante a avaliação das incertezas derivadas de simplificações frequentemente consideradas na modelagem destes processos.

TEORIA DE KÖHLER

Uma partícula de aerossol encontra-se em equilíbrio com uma dada umidade do ambiente quando o tamanho da partícula fica estável. A razão de saturação do ambiente para a qual a partícula encontra-se em equilíbrio é denominada S_{eq} . Pela sua vez, $S = \frac{e}{e_{sat}}$, onde e representa a pressão de vapor e e_{sat} a pressão de vapor de saturação. A teoria de Köhler estabelece que existe uma relação entre S_{eq} e o tamanho da partícula úmida, d dada por (Köhler, 1936; Pruppacher, H. R.; Klett, 1997; Seinfeld; Pandis, 2006):

$$S_{eq} = a_w \exp\left(\frac{A}{d}\right) \quad (1)$$

onde a_w , é a atividade da água na solução, e representa a extensão da lei de Raoult para uma solução real; $A = \frac{4M_w\sigma_w}{RT\rho_w}$ é denominado termo de Kelvin ou termo de curvatura; M_w e ρ_w representam a massa molar e a densidade da água, respectivamente; $\frac{\sigma_w}{s}$ denota a tensão superficial da solução, assumida como sendo igual à da água; e, por fim, R é a constante universal dos gases e T a temperatura. A equação 1 é válida tanto para uma atmosfera subsaturada quanto para uma atmosfera sobressaturada, sempre e quando a umidade ambiente for elevada o suficiente para que os componentes da partícula alcancem o estado de deliquescência.

Para uma partícula de aerossol composta por material completamente solúvel e um núcleo insolúvel de diâmetro d_{dry} , que também pode ser entendido como o tamanho do aerossol totalmente seco, e lembrando que $\ln(S_{eq}) = \ln(S_{eq} + 1) \approx S_{eq}$ quando $S_{eq} \rightarrow 0$, a equação 1 pode ser aproximada pela expressão (Pruppacher, H. R.; Klett, 1997):

$$S_{eq} \approx \frac{A}{d} - \frac{Bd_{dry}^3}{d^3} \quad (2)$$

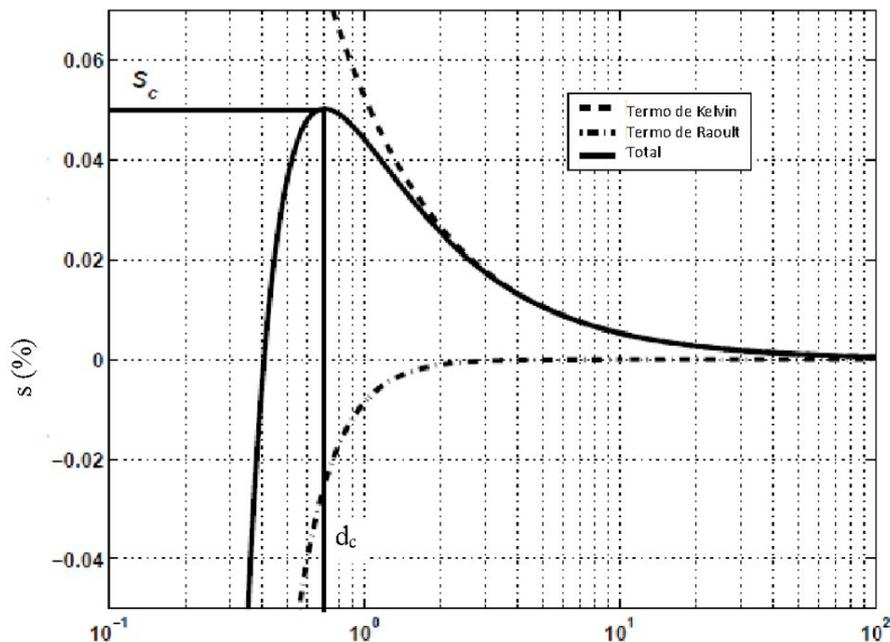
onde S_{eq} denota a supersaturação de equilíbrio. Nesta forma da equação de Köhler, B representa o termo de Raoult ou termo de soluto, que pode ser estimado como $B = \frac{\nu M_w \rho_s}{M_s \rho_w}$, onde ν é o número de íons nos quais o material do qual a partícula de aerossol está composta, também chamado de soluto, é dissociado; e M_s ρ_s representam a massa molar e a densidade do soluto, respectivamente.

A contribuição de ambos os termos de Kelvin e Raoult à supersaturação de equilíbrio conforme aumenta o diâmetro úmido da partícula de aerossol aparece representada na figura 1. O termo de Kelvin tende a infinito quando o tamanho da partícula tende a zero. Assim, para partículas pequenas o termo de Raoult contribui para a diminuição do valor da supersaturação de equilíbrio da partícula. No entanto, na medida em que o tamanho

da partícula aumenta, o termo de Kelvin diminui, enquanto a contribuição do termo de Raoult aumenta. A contribuição destes dois termos resulta numa curva de supersaturação de equilíbrio que alcança um valor máximo s_c quando a partícula possui diâmetro crítico, d_c , e tende a um valor próximo de zero para partículas grandes. Considerando a forma simplificada dada pela equação 2, pode-se demonstrar que $s_c = \left(\frac{4A^3}{27Bd_{dry}^3} \right)^{\frac{1}{2}}$ e que este valor é alcançado para $d_c = \left(\frac{3B}{A} \frac{d_{dry}^3}{A} \right)^{\frac{1}{2}}$.

Quando o tamanho da partícula excede o valor de d_c , o tamanho da partícula vai aumentar sem restrições devido à condensação de vapor de água na superfície da mesma. Assim a gotícula formada passa a formar parte da população de gotículas da nuvem em formação. Diz-se então que a partícula foi ativada como CCN. Em condições de equilíbrio, a partícula alcança o tamanho d_c quando a razão de saturação do ambiente for igual à S_{eq} . Entretanto, se a partícula não estiver em equilíbrio com o ambiente, o crescimento da mesma não responderá instantaneamente a mudanças na razão de saturação.

Figura 1 - Formulação de Köhler: contribuição dos termos de Kelvin e de Raoult.



Fonte: Adaptado de (McFiggans *et al.*, 2006)

REPRESENTAÇÃO DAS PROPRIEDADES HIGROSCÓPICAS DOS AEROSSÓIS

Em condições de umidade ambiente abaixo da saturação, o crescimento higroscópico das partículas de aerossol por condensação de vapor de água na superfície das mesmas é usualmente caracterizado através do fator de crescimento higroscópico G_f , definido como $G_f = \frac{d}{d_{dry}}$, onde d é o diâmetro do aerossol à uma umidade relativa determinada, elevada o suficiente para que todos os componentes do aerossol tenham passado ao estado de

deliquescência. G_f é usualmente determinado através de um equipamento denominado H-TDMA (do inglês *Hygroscopic Tandem Differential Mobility Analyzer*) que, adicionalmente, permite obter informações relativas ao estado de mistura da população de aerossóis analisada.

Além do parâmetro G_f para condições de subsaturação, vários outros parâmetros têm sido propostos para descrever o crescimento por condensação de partículas de aerossóis nos regimes de subsaturação e sobressaturação de umidade (Rissler *et al.*, 2010). Entre estes, o parâmetro de higroscopicidade efetiva K_p , proposto por Petters e Kreidenweis (2007), representa o impacto do soluto na atividade da água na solução a_w (Petters; Kreidenweis, 2007). Este parâmetro é definido através da relação $\frac{1}{a_w} = 1 + \kappa_p \frac{V_s}{V_w}$ onde V_s é o volume da partícula de aerossol seca e V_w o volume da água na partícula úmida. Assim, a equação 1 pode ser expressa como (Petters; Kreidenweis, 2007):

$$S_{eq} = s_{eq} + 1 = \frac{d^3 - d_{dry}^3}{d^3 - d_{dry}^3(1 - \kappa_p)} \exp\left(\frac{4M_w\sigma_w}{RT\rho_w d}\right) \quad (3)$$

Ainda, pode-se demonstrar que K_p está relacionada à G_f através da relação:

$$\kappa_p = (G_f^3 - 1)(a_w^{-1} - 1) \quad (4)$$

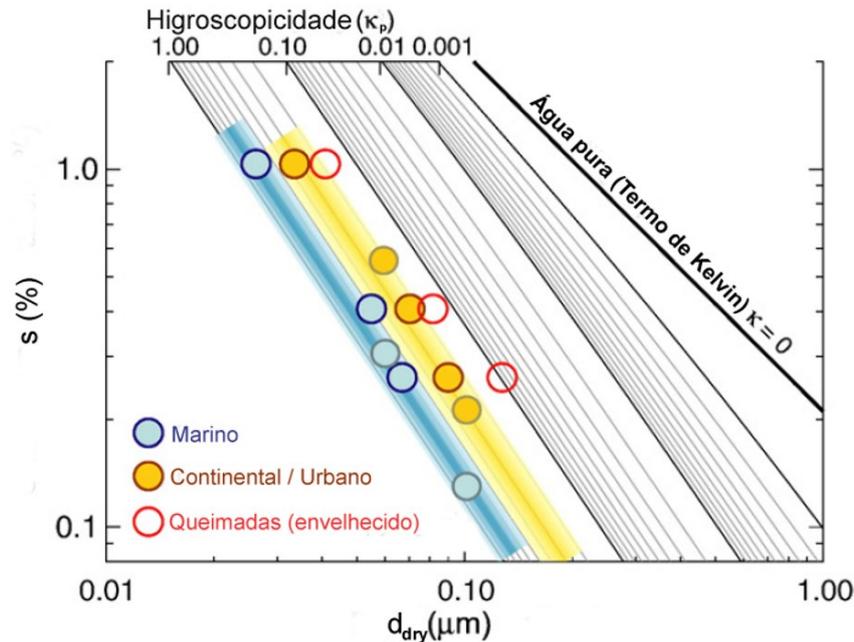
Onde a atividade da água é calculada como

$$a_w = \frac{\frac{RH}{100}}{\exp\left(\frac{4M_w\sigma_w}{RT\rho_w G_f d_{dry}}\right)} \quad (5)$$

Após o trabalho de Peter e Kreidenweis (2007), o parâmetro de higroscopicidade efetiva K_p tem sido amplamente usado e o seu valor tem sido estimado para vários compostos e populações de aerossóis (Almeida *et al.*, 2014; Lathem *et al.*, 2011; Petters; Kreidenweis, 2007). Ainda, para $\kappa_p > 0,2$ e $S_c < 1\%$ e K_p o parâmetro B é praticamente idêntico ao termo de Raoult na equação 2 (Petters; Kreidenweis, 2007).

A relação dada pela equação 3 está representada graficamente na Figura 2 utilizando escalas logarítmicas em ambos os eixos. Pode se verificar que, entre aerossóis com o mesmo diâmetro seco, aqueles mais higroscópicos, isto é, com maior valor de K_p , possuem um menor valor de supersaturação crítica. Para $\kappa_p > 0,2$ a derivada da curva é $\sim -3/2$, conforme esperado (ver supersaturação crítica S_c na seção anterior), enquanto que para valores menores do parâmetro as linhas afastam-se do comportamento linear e a derivada alcança o valor assintótico $-3/2$ para partículas com diâmetro seco maior. Ainda, aparece representada a curva para água pura (apenas o termo de Kelvin), com derivada igual à -1 .

Figura 2 - Relação entre a supersaturação crítica e o diâmetro seco da partícula, calculada segundo a formulação de Petters e Kreidenweis (2007)



Legenda: As linhas indicadas em cinza correspondem a valores de constante; as bandas coloridas correspondem a aerossol continental (laranja) e marinho (azul); por fim, os pontos correspondem a dados observados ou recalculados para populações de aerossóis.

Fonte: Adaptado de (Andreae; Rosenfeld, 2008)

Outros parâmetros também podem ser usados para descrever o crescimento por absorção de vapor de água. Entre eles podem ser mencionados a fração de volume solúvel ε e o parâmetro K_R (Rissler *et al.*, 2004; Vestin *et al.*, 2007). Ambos partem de uma representação da partícula de aerossol úmida como composta por um núcleo insolúvel e uma fração solúvel, assumida como composta por um sal de referência. Desta forma, Rissler *et al.* (2004) definiram a fração solúvel da partícula através da relação $\varepsilon = \frac{G_f^3 - 1}{G_f^{3_{salt}} - 1}$. Já o parâmetro K_R surgiu como alternativa ao uso de ε , representando o número de moles de íons solúveis por unidade de partícula de aerossol seca, e está relacionado à ε através da relação $K_R = \varepsilon \frac{v \rho_s}{M_s}$. Ambos parâmetros podem ser convertidos ao parâmetro K_p seguindo as relações (Gunthe *et al.*, 2009):

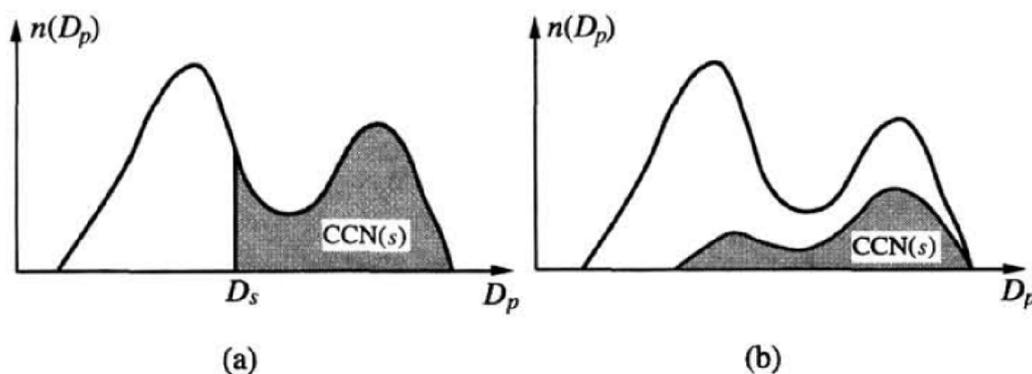
$$K_p \approx K_{p_{salt}} \varepsilon \approx K_{p_{salt}} K_R \frac{M}{v_{salt} \rho_{salt}} \quad (6)$$

Onde o subíndice *salt* indica o sal de referência utilizada na estimativa de ε ou K_R ; e K_p , M , v e ρ denotam, respectivamente, o parâmetro de higroscopicidade, a massa molar, a densidade e o fator de dissociação [do sal].

ATUAÇÃO DE PARTÍCULAS DE AEROSSÓIS COMO CCN NA ATMOSFERA

Dado um valor de supersaturação, se todas as partículas estão em equilíbrio com o ambiente e tem a mesma composição química, todas as partículas de diâmetro maior do que a menor partícula ativada também serão ativadas (figura 3a). Entretanto, como a ativação como CCN depende não apenas do tamanho mas também da composição da partícula, temos que quando esta última é variável, a ativação responderá a um padrão mais complexo no qual partículas menores, porém mais higroscópicas, podem ser ativadas como CCN; enquanto que outras maiores e menos higroscópicas permanecerão como aerossol intersticial dentro da nuvem (figura 3b). Este e outros conceitos da teoria de Köhler para equilíbrio se aplicam de forma geral à ativação de aerossóis como CCN na formação de nuvens. Ainda, é importante salientar que a ativação das partículas de aerossol como CCN no interior das nuvens envolve uma competição pelo vapor de água disponível e, por tanto, o processo é também influenciado pela dinâmica da nuvem e pelos processos cinéticos que intervêm no crescimento por condensação do aerossol.

Figura 3 - Diagrama esquemático da fração de aerossóis ativada como CCN para uma dada distribuição de tamanho de aerossóis.



Legenda: (a) composição química uniforme, (b) composição química dependente do tamanho do aerossol

Fonte: (Seinfeld; Pandis, 2006)

Assim, a quantidade de vapor de água e a velocidade em ascensão da parcela de atmosfera considerada (também chamada de velocidade de *updraft*), a concentração de número de partículas de aerossol e as diferenças em tamanho e composição das partículas de aerossol, entre outros, afetam a concentração de número de CCN ativado (Farmer *et al.*, 2015; Mcfiggans *et al.*, 2006). Desta forma, o número de aerossóis ativado como CCN dentro de uma nuvem vai depender da supersaturação máxima alcançada, mas também tem um efeito de retroalimentação sobre a mesma. Esta retroalimentação pode ser vista também do ponto de vista matemático através da relação entre o crescimento das partículas, o conteúdo de água líquido e a supersaturação do ambiente, como descrito a seguir.

O crescimento por condensação de uma partícula de aerossol segue (Seinfeld; Pandis, 2006) :

$$\frac{dd}{dt} = \frac{4G}{d} (s - s_{eq}) \quad (7)$$

Onde o coeficiente de crescimento G , também chamado de coeficiente de crescimento para partículas, depende do tamanho do aerossol úmido. Desta forma, o crescimento por condensação das partículas de aerossol na nuvem é regido pela diferença entre a supersaturação do ambiente e a supersaturação de equilíbrio do aerossol. Quando esta diferença é positiva, a partícula de aerossol experimenta uma força positiva ao crescimento por condensação.

Por sua vez, o aumento do tamanho úmido das partículas representa um aumento no conteúdo de água líquida na nuvem W_L . Assim, para uma distribuição de número de aerossóis representada idealmente através de um conjunto de *bins* ou intervalos de tamanhos, dentro dos quais assume-se que as partículas têm um tamanho único, W_L pode ser calculado como:

$$\frac{dw_L}{dt} = \frac{\pi \rho_w}{2 \rho_a} \sum_{i=1}^n N_i d_i^2 \frac{dd_i}{dt} \quad (8)$$

Onde n representa o número de *bins* da distribuição de tamanhos da população de aerossóis, i denota o bin em questão e N_i e d_i denotam o número e o tamanho das partículas no bin i . Entretanto, a tendência da supersaturação de vapor de água do ambiente aumenta com a velocidade de *updraft* W , mas diminui com a formação de água líquida, como descrito pela relação:

$$\frac{ds}{dt} = \alpha(T)W - \gamma(p, T) \frac{dw_L}{dt} \quad (9)$$

Desta forma, a supersaturação aumenta a uma taxa praticamente constante devido ao resfriamento da parcela em ascensão. Entretanto, uma vez que o crescimento das partículas de aerossol já ativadas como CCN é praticamente irrestrito, o consequente aumento de água líquida leva à diminuição do conteúdo de vapor de água devido à condensação do mesmo na superfície de partículas de aerossol ativadas, resultando na diminuição da supersaturação.

Como já foi mencionado, as partículas de aerossol de igual composição química podem ser consideradas ativadas como CCN quando alcançam tamanhos iguais ou maiores do que o diâmetro crítico, determinado como o diâmetro para o qual é alcançada a supersaturação crítica em condições de equilíbrio. Tanto o diâmetro crítico quanto a supersaturação crítica dependem do tamanho do aerossol “seco” e da higroscopicidade (composição) do mesmo. Por outro lado, aerossóis da moda grossa (ou seja, aqueles maiores do que 10 μm), experimentam limitações inerciais ao crescimento, e mesmo experimentando uma força positiva ao crescimento durante toda a evolução inicial da nuvem, já que os mesmos apresentam uma supersaturação de equilíbrio pequena, podem não conseguir alcançar a ativação devido ao fato de possuir valores grandes de diâmetro crítico. Ainda assim, estas partículas maiores podem modificar sensivelmente a quantidade de vapor de água e o conteúdo de água líquida na nuvem. Desta forma, Nenes *et al.* (2001) discutiram que, para efeitos práticos, estas partículas podem também ser consideradas como ativadas, mesmo sem ser ativadas no sentido estrito (já que o tamanho delas é inferior ao diâmetro crítico).

Quando a supersaturação do ambiente diminui abaixo da supersaturação de

equilíbrio de partículas ativadas, essas partículas começam a perder água por evaporação. Elas inclusive podem desativar se o diâmetro delas diminuir até ficar menor do que o seu diâmetro crítico. Este mecanismo de “desativação” é também resultado de processos cinéticos e foi descrito em detalhes por Nenes *et al.* (2001). Adicionalmente, nem sempre é possível considerar como válida a premissa de que as partículas de aerossol se encontrarão em equilíbrio com o ambiente no interior da nuvem até que a máxima supersaturação ambiente seja alcançada. As partículas pequenas crescem um tanto lentamente, e aquelas com baixa higroscopicidade, ainda mais. Assim, ainda se a supersaturação de equilíbrio destas partículas é menor do que a supersaturação ambiente máxima e as mesmas experimentam uma força positiva ao crescimento, o período de tempo durante o qual esta força é positiva pode ser insuficiente para que a partícula alcance o seu tamanho crítico e ative como CCN devido às limitações cinéticas que a partícula experimenta para responder instantaneamente às mudanças na supersaturação da nuvem. Este mecanismo, chamado de “evaporação”, também foi descrito no trabalho de Nenes *et al.* (2001). Enquanto as partículas inercialmente limitadas para crescer e ativar continuam a crescer durante a formação da nuvem, as partículas de aerossol sujeitas a estas duas limitações cinéticas eventualmente se tornam aerossóis intersticiais.

No estudo das propriedades microfísicas dos aerossóis, é interessante conhecer a fração CCN/CN, onde CN (do inglês, *condensation nuclei*) denota as partículas que podem ativar a uma supersaturação de 400%, o que a efeitos práticos inclui todas as partículas disponíveis (Seinfeld; Pandis, 2006). No entanto, as partículas de diâmetro menor do que 30 nm dificilmente ativam nas supersaturações tipicamente encontradas na atmosfera (< 2 %), e na estimativa da fração CCN/CN é frequente considerar como possível CN apenas as partículas de diâmetro maior do que 30 nm (ver, por exemplo, Gunthe *et al.*, 2009).

A ativação como CCN é significativamente afetada pela velocidade de updraft e pelo número de partículas que pode potencialmente ativar como CCN dada uma supersaturação suficientemente elevada, ou seja, o CN. Considerando os resultados de um modelo de parcela de ar adiabático para uma velocidade de updraft constante, Reutter *et al.* (2009) encontraram três regimes nos quais a ativação de aerossóis se comporta de forma diferente, identificados de acordo com a razão entre a velocidade de updraft e o número de partículas. Estes são: um regime limitado pelo updraft, no qual a ativação é praticamente independente da concentração de aerossóis; um segundo regime limitado pela quantidade de aerossol, no qual a ativação é aproximadamente proporcional à concentração em número de aerossóis; e, por fim, um regime intermediário, sensível tanto ao updraft quanto ao aerossol (Reutter *et al.*, 2009). Além da velocidade de updraft e o CN, a concentração de CCN também é modificada pelos parâmetros da distribuição de tamanho do aerossol, i.e. o diâmetro geométrico médio e o desvio padrão (McFiggans *et al.*, 2006; Ward *et al.*, 2010).

A sensibilidade à composição química do aerossol, especificamente à higroscopicidade, assim como à razão de mistura da população, tem sido tipicamente consideradas como secundárias em comparação (Dusek *et al.*, 2006; Feingold, 2003; Reutter *et al.*, 2009). No entanto, estudos recentes indicam que a composição química pode ser relevante para um conjunto não desprezível de situações (Ervens *et al.*, 2010; Padró *et al.*, 2012; Sánchez Gácita *et al.*, 2017; Topping; McFiggans, 2012; Ward *et al.*, 2010; Wex *et al.*, 2010), e que a razão entre a velocidade de updraft e o número de partículas em alguns casos

se apresenta insuficiente para descrever de forma adequada a atividade como CCN dos aerossóis (Hernández Pardo, L. *et al.*, 2019).

MODELAGEM DA ATIVAÇÃO DE AEROSSÓIS COMO CCN

A concentração de CCN tem sido frequentemente parametrizada em função da supersaturação ambiente segundo lei de potência, log-normal ou algébrica, entre outras (Khvorostyanov; Curry, 2009). Um dos exemplos mais conhecidos é a lei de potência $CCN(s) = Cs^k$ (Twomey, 1959), onde C e k são parâmetros empíricos e C representa o CCN ($s = 1\%$). A parametrização de CCN usando uma lei de potência pode ser considerada como sendo a mais extensamente utilizada na modelagem da ativação como CCN dos aerossóis, e C e k tem sido determinados empiricamente para diferentes regiões (Pruppacher, H.; Klett, 1997; Seinfeld; Pandis, 2006).

A desvantagem fundamental das parametrizações da concentração de CCN como função apenas da supersaturação s é que os parâmetros costumam ser derivados de dados empíricos e, por tanto, não estão diretamente relacionados às propriedades microfísicas dos aerossóis cujas atividade como CCN foi avaliada. Ainda, para supersaturações muito altas, a lei de potência resulta em soluções irrealistas com $CCN > CN$ (Khvorostyanov; Curry, 2009). Neste sentido, a relação $AOT_{500} = aCCN_{0.4}^b$ proposta por Andreae (2009) apresenta uma vantagem. Esta relação pode ser utilizada para estimar o CCN a $s = 0.4\%$ como função da profundidade óptica do aerossol em 500 nm AOT_{500} , que pela sua vez pode ser determinada a partir dos dados disponibilizados pela rede AERONET (Eck *et al.*, 2003; Holben *et al.*, 2001), ou mesmo modelada. No trabalho de Andreae (2009) as propriedades ópticas e microfísicas do aerossol mostraram estar relacionadas entre si e, neste sentido, a relação proposta pelo autor guarda uma relação mais direta com as propriedades intrínsecas das partículas de aerossol.

Contudo, as dependências complexas das propriedades microfísicas dos aerossóis com as características físicas e químicas do aerossol, assim como com a dinâmica da nuvem, não são descritas adequadamente por estas abordagens mais simplificadas.

No intuito de ter uma caracterização mais realista da ativação como CCN, parametrizações com maior embasamento físico vem sendo propostas nos últimos anos. Estas parametrizações tipicamente consideram como ponto de partida a teoria de Köhler, e consideram que as partículas de aerossol podem ser consideradas em equilíbrio com o ambiente até que a máxima supersaturação seja alcançada. A supersaturação crítica de cada partícula pode ser calculada como função dos termos de Kelvin e de Raoult, já mencionados no início do capítulo, e partículas com valores de supersaturação crítica abaixo da máxima supersaturação alcançada na atmosfera serão consideradas como ativadas. Seguindo esta abordagem, o problema da determinação da fração CCN/CN é reduzido ao problema da estimativa da máxima supersaturação alcançada, S_{max} .

Para estimar S_{\max} , o procedimento inicial seguido pelas diferentes parametrizações é muito semelhante. Como as partículas com diâmetros maiores do que o valor crítico correspondente à supersaturação ambiente serão também ativadas, é possível expressar a equação de tendência do supersaturação como função da supersaturação crítica e não do diâmetro úmido da partícula (equação 9) (Ghan *et al.*, 2011). A equação resultante pode ser combinada com a de tendência do conteúdo de água líquido, equação 8, no momento em que a máxima supersaturação é alcançada. Como segundo passo, a equação 7, a qual determina o crescimento da partícula úmida, é integrada desde o momento t_{act} em que a partícula é ativada até o momento t_{\max} em que a máxima supersaturação é alcançada. Considerando que na máxima supersaturação $\frac{ds}{dt} = 0$, definindo $\gamma^* = \frac{4\pi\rho_w\gamma(p, T)}{\rho_a}$ e combinando ambos resultados, é possível obter a seguinte relação (mais detalhes em Ghan *et al.*, 2011):

$$\alpha(T)W = \gamma^* G S_{\max} \int \left(r^2(t_{\text{act}}) + 2G \int s dt \right)^{1/2} \frac{dCN}{ds_c} ds_c \quad (10)$$

Se, na equação 10, são consideradas separadamente as partículas com S_c próxima a S_{\max} , para as quais se satisfaz $r^2(t_{\text{act}}) \gg 2G \int s dt$, e aquelas com $s_c \ll S_{\max}$, para as quais se satisfaz $r^2(t_{\text{act}}) \ll 2G \int s dt$, é obtida a expressão:

$$\alpha(T)W = \gamma^* G S_{\max} \int \left(2G \int s dt \right)^{1/2} \frac{dCN}{ds_c} ds_c + \int r(t_{\text{act}}) \frac{dCN}{ds_c} ds_c \quad (11)$$

Onde S_{part} denota uma supersaturação limiar que distingue partículas que crescem substancialmente entre t_{act} e t_{\max} , e aquelas que crescem comparativamente pouco.

Assumindo $S_{\text{part}} = S_{\max}$, o segundo termo é eliminado. Presupondo ainda que o espectro de CCN satisfaz uma lei potencial da supersaturação e aproximando $\int s dt \approx \frac{s_{\max}^2 - s_c^2}{\alpha(T)W}$ é possível resolver a equação 11 como função de W e os parâmetros C e K . Esta foi a abordagem seguida por Twomey (1959) e que tem sido estendida posteriormente para outras formas funcionais do espectro CCN diferentes da forma potencial.

Na família de parametrizações iniciada a partir dos trabalhos de Abdul-Razzak e Ghan (1998), ambos termos da equação 11 são integrados desde 0 até S_{\max} e os termos de curvatura e soluto são negligenciados após a ativação, i.e. $s_{\text{eq}} \approx 0$ (Abdul-Razzak, H.; Ghan, 2000; Abdul-Razzak; Ghan, 1998, 2002). Desta forma, em Abdul-Razzak e Ghan (1998) os autores conseguem aproximar $\frac{S_m}{S_{\max}}$ (onde S_m denota a supersaturação crítica correspondente ao diâmetro geométrico médio da distribuição de tamanho de aerossóis, assumida neste caso como de tipo log-normal) como função de termos adimensionais determinados numericamente para um amplo conjunto de parâmetros. A abordagem de

Abdul-Razzak e Ghan, a semelhança do trabalho de Twomey (1959), não considera o efeito das limitações cinéticas na ativação como CCN.

Já na família de parametrizações construídas a partir da abordagem de Nenes e Seinfeld (2003), é introduzido o conceito de divisão da população de aerossóis (do inglês, *population splitting*), e S_{part} é considerado como de valor não trivial (Barahona; Nenes, 2007; Fountoukis; Nenes, 2005; Nenes; Seinfeld, 2003). Estas parametrizações conseguem resolver as limitações cinéticas e, inclusive, considerar o efeito da influência da cinética das espécies gasosas na difusividade do vapor de água. Entretanto, o processo de solução é iterativo e o custo computacional é superior ao da parametrização de Abdul-Razzak e Ghan num fator entre 20 e 100 vezes (Ghan *et al.*, 2011).

CONSIDERAÇÕES FINAIS

Na modelagem numérica, não é raro que exista a necessidade de simplificar processos para viabilizar a obtenção de resultados a um custo computacional aceitável. Assim, mesmo que a modelagem da ativação dos aerossóis como CCN seja essencial para os modelos numéricos de previsão de tempo e clima dado o seu impacto no ciclo hidrológico, dadas as simplificações frequentemente realizadas na mesma, frequentemente ela representa uma fonte de incerteza significativa para os resultados dos modelos.

Abordagens iniciais consideravam a ativação uma função da supersaturação ambiente segundo uma lei de potência, log-normal ou algébrica, e do número de partículas, também chamado de CN. Nestas abordagens, os parâmetros são obtidos de maneira empírica e por tanto não descrevem as características intrínsecas dos aerossóis aos quais se referem. Numa sofisticação destas abordagens, diversos autores tem estabelecidos regimes dados pela relação entre a supersaturação e o número de partículas, dentro dos quais a ativação segue um padrão característico.

Abordagens mais sofisticadas consideram a higroscopicidade e a razão de mistura das populações de aerossóis. Estes parâmetros, considerados inicialmente como pouco relevantes, tem se mostrado em diversos estudos como essenciais para a correta descrição dos processos estudados, e a sua incorporação aos modelos numéricos vem sendo cada vez mais estendida.

O próximo passo provavelmente será dado na direção da introdução das restrições cinéticas à ativação dos aerossóis como CCN. O embasamento teórico para este passo vem sendo consolidado, sendo o elevado custo computacional desta abordagem a principal limitação para a sua inclusão na modelagem numérica do tempo e do clima.

A determinação de parâmetros que descrevam a higroscopicidade para um maior número de populações de aerossóis ainda é necessária. Por fim, a consideração de diversas populações de aerossóis e a possibilidade de razões de mistura entre as mesmas, ainda é limitado a um pequeno número de modelos que descrevem processos químicos na atmosfera e não apenas o tempo e o clima, permitindo assim esta abordagem mais completa.

REFERÊNCIAS

- ABDUL-RAZZAK, H.; GHAN, S. J. A parameterization of aerosol activation 1. Single aerosol type. **J. Geophys. Res.**, v. 103, p. 6123–6131, 1998.
- ABDUL-RAZZAK, H.; GHAN, S. J. A parameterization of aerosol activation 2. Multiple aerosol types. **J. Geophys. Res.**, v. 105, p. 6837–6844, 2000.
- ABDUL-RAZZAK, H.; GHAN, S. J. A parameterization of aerosol activation: 3. Sectional representation. **J. Geophys. Res.**, v. 107, p. 1–6, 2002.
- ALMEIDA, G. P.; BRITO, J.; MORALES, C. A.; ANDRADE, M. F.; ARTAXO, P. Measured and modelled cloud condensation nuclei (CCN) concentration in São Paulo, Brazil: The importance of aerosol size-resolved chemical composition on CCN concentration prediction. **Atmospheric Chemistry and Physics**, v. 14, n. 14, p. 7559–7572, 2014.
- ANDREAE, M. O.; ROSENFELD, D. Aerosol–cloud–precipitation interactions. Part 1. The nature and sources of cloud-active aerosols. **Earth-Sci. Rev.**, v. 89, p. 13–41, 2008.
- ANDREAE, M. O. Correlation between cloud condensation nuclei concentration and aerosol optical thickness in remote and polluted regions. **Atmospheric Chemistry and Physics**, v. 9, p. 543–556, 2009.
- BARAHONA, D.; NENES, A. Parameterization of cloud droplet formation in large-scale models: Including effects of entrainment. **Journal of Geophysical Research**, v. 112, n. D16, p. D16206, 2007.
- BAUER, S. E.; MENON, S.: Aerosol direct, indirect, semidirect, and surface albedo effects from sector contributions based on the IPCC AR5 emissions for preindustrial and present-day conditions, **J. Geophys. Res.-Atmos.**, v. 117, p. 1–15, doi:10.1029/2011JD016816, 2012.
- DAGAN, G.; KOREN, I.; ALTARATZ, O. Competition between core and periphery-based processes in warm convective clouds – from invigoration to suppression. **Atmospheric Chemistry and Physics**, v. 15, p. 2749–2760, 2015.
- DUSEK, U.; FRANK, G. P.; HILDEBRANDT, L.; *et al.* Size matters more than chemistry for cloud-nucleating ability of aerosol particles. **Science**, v. 312, n. 5778, p. 1375–8, 2006.
- ECK, T. F.; HOLBEN, B. N.; REID, J. S.; *et al.* High aerosol optical depth biomass burning events: A comparison of optical properties for different source regions. **Geophysical Research Letters**, v. 30, n. 20, p. 2035, 2003.
- ERVENS, B.; CUBISON, M. J.; ANDREWS, E.; *et al.* CCN predictions using simplified assumptions of organic aerosol composition and mixing state: a synthesis from six different locations. **Atmospheric Chemistry and Physics**, v. 10, n. 10, p. 4795–4807, 2010.
- FARMER, D. K.; CAPPALÀ, C. D.; KREIDENWEIS, S. M. Atmospheric Processes and Their Controlling Influence on Cloud Condensation Nuclei Activity. **Chemical Reviews**, p. 150313151440005, 2015.
- FEINGOLD, G. Modeling of the first indirect effect: Analysis of measurement requirements. **Geophysical Research Letters**, v. 30, n. 19, p. 1–4, 2003.

- FOUNTOUKIS, C.; NENES, A. Continued development of a cloud droplet formation parameterization for global climate models. **Journal of Geophysical Research**, v. 110, n. D11, p. D11212, 2005.
- GHAN, S. J.; ABDUL-RAZZAK, H.; NENES, A.; *et al.* Droplet nucleation: Physically-based parameterizations and comparative evaluation. **Journal of Advances in Modeling Earth Systems**, v. 3, n. 10, p. 1–33, 2011.
- GUNTHER, S. S.; KING, S. M.; ROSE, D.; *et al.* Cloud condensation nuclei in pristine tropical rainforest air of Amazonia: size-resolved measurements and modeling of atmospheric aerosol composition and CCN activity. **Atmospheric Chemistry and Physics**, v. 9, n. 1, p. 7551–7575, 2009.
- HERNÁNDEZ PARDO, L.; TOLEDO MACHADO, L. A.; AMORE CECCHINI, M.; SÁNCHEZ GÁCITA, M. Quantifying the aerosol effect on droplet size distribution at cloud top. **Atmos. Chem. Phys.**, v. 19, p. 7839–7857, 2019. <https://doi.org/10.5194/acp-19-7839-2019>
- HOLBEN, B. N.; TANRÉ, D.; SMIRNOV, A.; *et al.* An emerging ground-based aerosol climatology: Aerosol optical depth from AERONET. **Journal of Geophysical Research**, v. 106, n. D11, p. 12067, 2001.
- JIANG, H.; FEINGOLD, G.; SOROOSHIAN, A. Effect of Aerosol on the Susceptibility and Efficiency of Precipitation in Warm Trade Cumulus Clouds. *Journal of the Atmospheric Sciences*, v. 67, n. 11, p. 3525–3540, 2010.
- JIANG, J. H.; SU, H.; SCHOEBERL, M. R.; *et al.* Clean and polluted clouds: Relationships among pollution, ice clouds, and precipitation in South America. *Geophysical Research Letters*, v. 35, n. 14, p. L14804, 2008.
- KHAIN, A. P.; ROSENFELD, D.; POKROVSKY, A. Aerosol impact on the dynamics and microphysics of deep convective clouds. **Quarterly Journal of the Royal Meteorological Society**, v. 131, p. 2639–2663 ST – Aerosol impact on the dynamics and, 2005.
- KHVOROSTYANOV, V. I.; CURRY, J. A. Parameterization of Cloud Drop Activation Based on Analytical Asymptotic Solutions to the Supersaturation Equation. **Journal of the Atmospheric Sciences**, v. 66, n. 1993, p. 1905–1925, 2009.
- KÖHLER, H.: The nucleus in and the growth of hygroscopic droplets, **T. Faraday Soc.**, v. 32, p. 1152–1161, 1936.
- LATHEM, T. L.; KUMAR, P.; NENES, A.; *et al.* Hygroscopic properties of volcanic ash. **Geophysical Research Letters**, v. 38, n. 11, p. 2–5, 2011.
- MCFIGGANS, G.; ARTAXO, P.; BALTENSPERGER, U.; *et al.* The effect of physical and chemical aerosol properties on warm cloud droplet activation. **Atmos. Chem. Phys.**, v. 6, p. 2593–2649, 2006.
- NENES, A.; GHAN, S.; ABDUL-RAZZAK, H.; CHUANG, P. Y.; SEINFELD, J. H. Kinetic limitations on cloud droplet formation and impact on cloud albedo. **Tellus B**, v. 53, n. 2, p. 133–149, 2001.
- NENES, A.; SEINFELD, J. H. Parameterization of cloud droplet formation in global climate models. **Journal of Geophysical Research**, v. 108, n. D14, p. 4415, 2003.

PADRÓ, L. T.; MOORE, R. H.; ZHANG, X.; *et al.* Mixing state and compositional effects on CCN activity and droplet growth kinetics of size-resolved CCN in an urban environment. **Atmospheric Chemistry and Physics**, v. 12, n. 21, p. 10239–10255, 2012.

PETTERS, M. D.; KREIDENWEIS, S. M. A single parameter representation of hygroscopic growth and cloud condensation nucleus activity. **Atmospheric Chemistry and Physics**, v. 7, n. 8, p. 1961–1971, 2007.

PRUPPACHER, H.; KLETT, J. **Microphysics of clouds and precipitation**. Second Edition. Cambridge, Massachusetts: Kluwer Academic Publishers, 1997.

REUTTER, P.; SU, H.; TRENTMANN, J.; *et al.* Aerosol- and updraft-limited regimes of cloud droplet formation: influence of particle number, size and hygroscopicity on the activation of cloud condensation nuclei (CCN). **Atmospheric Chemistry and Physics**, v. 9, n. 18, p. 7067–7080, 2009.

RISSLER, J.; SVENNINGSSON, B.; FORS, E. O.; BILDE, M.; SWIETLICKI, E. An evaluation and comparison of cloud condensation nucleus activity models: Predicting particle critical saturation from growth at subsaturation. **Journal of Geophysical Research**, v. 115, n. D22, p. D22208, 2010.

RISSLER, J.; VESTIN, A.; SWIETLICKI, E.; *et al.* Size distribution and hygroscopic properties of aerosol particles from dry-season biomass burning in Amazonia. **Atmos. Chem. Phys.**, p. 471–491, 2006.

RISSLER, J.; SWIETLICKI, E.; ZHOU, J.; *et al.* Physical properties of the sub-micrometer aerosol over the Amazon rain forest during the wet-to-dry season transition – comparison of modeled and measured CCN concentrations. **Atmos. Chem. Phys.**, v. 4, p. 2119–2143, 2004.

ROSENFELD, D.; LOHMANN, U.; RAGA, G. B.; *et al.* Flood or drought: how do aerosols affect precipitation? **Science** (New York, N.Y.), v. 321, n. 5894, p. 1309–1313, 2008.

SÁNCHEZ GÁCITA, M.; LONGO, K. M.; FREITAS, S. R.; FREIRE, J. L.; MARTIN, S. T. Impact of mixing state and hygroscopicity on CCN activity of biomass burning aerosol in Amazonia. **Atmos. Chem. Phys.**, v. 17, p. 2373–2392, 2017. doi:10.5194/acp-17-2373-2017

SEINFELD, J. H.; PANDIS, S. N. **Atmospheric Chemistry and Physics: From Air Pollution to Climate Change**. 2nd. ed. New Jersey: Wiley Interscience, 2006.

TOPPING, D. O.; MCFIGGANS, G. Tight coupling of particle size, number and composition in atmospheric cloud droplet activation. **Atmospheric Chemistry and Physics**, v. 12, p. 3253–3260, 2012.

TWOMEY, S. The nuclei of natural cloud formation part II: The supersaturation in natural clouds and the variation of cloud droplet concentration. **Geofisica Pura e Applicata**, v. 43, n. 1, p. 243–249, 1959.

VESTIN, A.; RISSLER, J.; SWIETLICKI, E.; FRANK, G. P.; ANDREAE, M. O. Cloud-nucleating properties of the Amazonian biomass burning aerosol: Cloud condensation nuclei measurements and modeling. **Journal of Geophysical Research**, v. 112, n. D14, p. D14201, 2007.

WARD, D. S.; EIDHAMMER, T.; COTTON, W. R.; KREIDENWEIS, S. M. The role of the particle size distribution in assessing aerosol composition effects on simulated droplet activation.

Atmospheric Chemistry and Physics, v. 10, n. 2008, p. 5435–5447, 2010.

WARD, D.; COTTON, W. A method for forecasting cloud condensation nuclei using predictions of aerosol physical and chemical properties from WRF/Chem. **Journal of Applied Meteorology and Climatology**, v. 50, n. 7, p. 1601–1615, 2011.

WEX, H.; MCFIGGANS, G.; HENNING, S.; STRATMANN, F. Influence of the external mixing state of atmospheric aerosol on derived CCN number concentrations. **Geophysical Research Letters**, v. 37, n. 10, p. n/a–n/a, 2010.

Organizadoras

Dra. Fernanda Casagrande

Bacharel em Meteorologia pela Universidade Federal de Pelotas (2005), possui Especialização em Manejo de Água para Irrigação (2007), Mestrado em Meteorologia (2008) pela Universidade Federal de Alagoas, Doutorado em Ciência Do Sistema Terrestre e Pós Doutorado em Meteorologia pelo Instituto Nacional de Pesquisas Espaciais (2016). Atua na área de Geociências, com ênfase em Meteorologia, Mudanças Climáticas e Modelagem Numérica.

Dra. Noele Franchi Leonardo

Doutora em Meteorologia aplicada pela Universidade Federal de Viçosa, linha de pesquisa Modelagem Paleoclimática do Carbono Marinho. Possui Mestrado em Meteorologia pela UFRJ e graduação em Oceanografia pela UFPR. Atua na área de Geociências, com ênfase em Oceanografia, Meteorologia e Modelagem Numérica.

Dra. Ana Carolina Nascimento Santos

Doutora em Irrigação e Drenagem pela Escola Superior de Agricultura Luiz de Queiroz (2014), linha de pesquisa em Modelagem da Perda se Solo. Possui mestrado em Meio Ambiente e Recursos Hídricos pela Universidade Federal de Itajubá (2010) e graduação em Engenharia Agrícola e Ambiental pela Universidade Federal de Viçosa (2007). Trabalhou como analista no Centro Nacional de Monitoramento e Alertas de Desastres Naturais de 2012 a 2017. Atua na área de modelagem hidrológica para previsão de vazão.

Dra. Helena Barbieri de Azevedo

Bacharel em Meteorologia pela Universidade Federal de Pelotas (UFPel), possui mestrado e doutorado em Meteorologia pelo curso de Pós-Graduação em Meteorologia do Instituto Nacional de Pesquisas Espaciais (INPE), ambos com ênfase em assimilação de dados. Foi pesquisadora visitante na University of Maryland (UMD) em 2017 e pós doutoranda na Université Catholique de Louvain (UCL) (2021 - 2023). Tem experiência na área de Geociências, com ênfase em Meteorologia, Previsão Numérica do Tempo e Assimilação de Dados.

Dra. Regiane Moura

Doutora em Meteorologia pelo Instituto Nacional de Pesquisas Espaciais (2017), onde também realizou o Pós-Doutorado em Meteorologia (2020). Obteve o mestrado em Sistemas Costeiros e Oceânicos pela Universidade Federal do Paraná (2011), e licenciatura em Física pela Universidade Federal de São Carlos (2007). Atua na área de Geociências, com ênfase em Meteorologia, Oceanografia, Mudanças Climáticas e Modelagem Numérica. Seu trabalho de pesquisa concentra-se principalmente na análise de processos físicos de interação oceano-atmosfera.

Índice Remissivo

A

abordagem 15, 38, 49, 63, 64, 66, 88, 89, 93, 104, 105, 113, 121, 122, 123
abordagens 18, 64, 67, 92, 98, 99, 102, 113, 121, 123
acoplamento 15, 22
aerossóis 16, 26, 113, 114, 116, 117, 118, 119, 120, 121, 122, 123
agricultura 18, 98, 99, 105, 108
agrometeorológica 98, 99, 103, 104, 105, 107, 108, 109
agrometeorológicos 98, 99, 100, 102, 105, 107, 108, 109
agronegócio 10
agronomia 98
assimilação de dados 21, 24, 28, 61, 62, 63, 64, 65, 66, 67
ativação 113, 118, 119, 120, 121, 122, 123
atmosfera 13, 14, 15, 16, 17, 22, 23, 25, 28, 32, 33, 34, 35, 36, 40, 41, 48, 49, 50, 51, 54, 58, 61, 64, 71, 72, 74, 75, 76, 79, 80
aumento da temperatura 104

B

biodiversidade 23
biomassa 73, 74, 75, 76, 77, 78, 79, 107
biosfera terrestre 71, 72, 79, 80

C

carbono 17, 22, 23, 71, 72, 75, 76, 77, 80
ciclo hidrológico 16, 89, 113, 123
clima 10, 11, 12, 13, 17, 18, 19, 20, 21, 22, 23, 24, 26, 27, 28, 31, 32, 35, 36, 48, 49, 55, 71, 72, 75, 86, 97, 98, 99, 101, 103, 104, 105, 108, 109, 113, 123
climáticas 10, 11, 17, 18, 20, 21, 22, 23, 24, 27, 28, 31, 44, 45, 56, 71, 76, 77, 79, 83, 86, 87, 88, 89, 96, 99, 101, 103, 104, 105, 111
climáticos 10, 11, 14, 16, 17, 18, 20, 21, 22, 23, 24, 25, 26, 27, 28, 35, 36, 41, 56, 97, 86, 88, 93, , 98, 99, 24, 106
composição do aerossol 113
condições ambientais 27, 98, 99, 101, 107

D

desastres naturais 10, 18, 82, 83, 84, 85, 88, 92, 93
desenvolvimento 10, 11, 12, 14, 15, 16, 17, 18, 19, 21,
22, 23, 25, 26, 37, 39, 52, 55, 57, 58, 66, 67, 72, 79,
83, 93, 94, 98, 99, 100, 24, 102, 39, 107
desenvolvimentos 12, 14, 20, 28
diversas ferramentas 102
diversidade 98

E

ecossistemas 23, 24
enchente 84, 85
energéticos 98, 105, 107
energia 10, 11, 16, 18, 34, 40, 41, 42, 43, 48, 49, 50, 51,
52, 53, 54, 55, 57, 58, 71, 72, 73, 74, 76
equação 14, 32, 33, 34, 35, 39, 40, 41, 42, 43
equações 11, 13, 14, 15, 16, 20, 21, 22, 25, 26, 31, 32,
33, 34, 24, 35, 36, 39, 40, 41, 42, 43, 44
equações matemáticas 31, 22, 32, 89, 24
equações primitivas 13, 14, 21, 26, 31, 32, 35
estratégias 18, 22, 23, 24, 44, 65, 71, 72, 76, 82, 85, 93,
94, 105, 106, 107, 108

F

fatores ambientais 101
fenômenos naturais 22, 31
ferramenta 10, 11, 27, 35, 41, 42, 44, 82, 83, 87, 93, 95
ferramentas 11, 18, 20, 22, 24, 26, 27, 28, 42, 83, 87, 98,
102, 105, 108, 109, 112

G

geográfica 14, 25, 63
gestão 16, 18, 23, 83, 93, 95, 96, 98, 99, 105, 107

H

hidrologia 37, 83, 98
hidrometeorológicos 82, 83, 92, 93
higroscopicidade 113, 116, 117, 119, 120, 123

I

instrumentos 11, 56, 62
inundações 27, 82, 83, 84, 85, 87, 92, 94, 95, 96

L

lei de potência 121, 123

M

marítimas 12, 48, 57
meio ambiente 44, 80, 82, 92, 93, 98
meteorologia 12, 13, 14, 15, 18, 26, 31, 33, 34, 42, 98
meteorológicas 11, 12, 14, 15
modelagem 10, 11, 17, 18, 19, 20, 22, 23, 24, 27, 28,
31, 33, 34, 35, 37, 40, 42, 44, 48, 57, 65, 71, 72, 76,
80, 82, 83, 89, 93, 94, 98, 99, 102, 103, 104, 105,
107, 108, 109
modelagem hidrológica 82, 83, 93, 94
modelagem integrada 98, 99, 105, 108
modelagem meteorológica 34
modelagem numérica 11, 42, 113, 123
modelagem regional 20, 22, 24, 28, 31, 48
modelos numéricos 10, 11, 18, 20, 21, 22, 24, 26
mudanças climáticas 10, 11, 17, 18, 20, 21, 22, 23, 24,
27, 28, 31, 44, 45, 56, 71, 79, 83, 88, 96

O

observações 11, 12, 13, 14, 15, 16
ocênicas 48
oceanografia 18, 31, 34, 43

P

padrões climáticos 10, 21, 22, 24, 25, 26, 27, 28
parametrização 107, 121, 123
parametrizações 11, 16, 18, 88, 113, 121, 122, 123
políticas 22
previsão de cheias 87, 88, 89, 90
previsão de tempo 11, 12, 13, 48, 62, 86, 87, 97, 103, 123
previsão numérica de tempo 14, 15, 31, 62, 63, 67
previsão numérica do tempo 13, 14, 31, 26, 31, 32, 24, 35, 36, 39, 39
previsões 10, 12, 13, 18, 20, 21, 23, 24, 25, 26, 27, 28, 62, 35, 36, 37, 41, 44, 45, 61, 63, 64, 24, 39
previsões meteorológicas 21, 26, 37, 86, 39, 96
processo 13, 14, 27, 35, 48, 51
processos 10, 11, 14, 16, 18, 22, 23, 28, 34, 40, 41, 42, 44, 48, 49, 51, 52, 58, 67, 71, 72, 75, 76, 78, 80, 82, 83, 87, 88, 89, 98, 99, 100, 102, 105, 113, 114, 118, 120, 123
processos atmosféricos 10, 11, 16
processos complexos 98
processos físicos 10, 11, 14, 22, 34, 40, 41, 42, 49, 51, 58, 71
produtividade 71, 76, 99, 100, 101, 103, 104, 107
projeções climáticas 71

R

recursos hídricos 83, 86, 98, 99, 105, 107

S

satélite 56, 62, 65
sistema 5, 10, 11, 12, 13, 15, 16, 17, 18
sistema agrícola 105
sistema climático 11, 12, 16, 17, 18, 20, 24, 28, 48
sistemas 12, 13, 15, 20, 21, 22, 23, 24, 28, 31, 36, 37, 38, 39, 43, 44, 45, 57, 61, 62, 64, 65, 66, 67, 39
sistemas de alerta 85, 92, 93
sistema terrestre 10, 15, 17, 18
superfície continental 71, 72, 74, 76
suprimento hídrico 107

T

tempo 10, 11, 12, 13, 14, 15, 16, 18

terrestre 10, 14, 15, 17, 18



AYA EDITORA
2024