



**UFG**

UNIVERSIDADE FEDERAL DE GOIÁS (UFG)  
INSTITUTO DE CIÊNCIAS BIOLÓGICAS (ICB)  
PROGRAMA DE PÓS GRADUAÇÃO EM ECOLOGIA E EVOLUÇÃO

DAIANY CAROLINE JONER

**Projeções futuras de índice de vegetação e os  
efeitos das mudanças climáticas em regiões áridas e  
semiáridas**

GOIÂNIA  
30 de março 2019



UNIVERSIDADE FEDERAL DE GOIÁS  
INSTITUTO DE CIÊNCIAS BIOLÓGICAS

## TERMO DE CIÊNCIA E DE AUTORIZAÇÃO (TECA) PARA DISPONIBILIZAR VERSÕES ELETRÔNICAS DE TESES

### E DISSERTAÇÕES NA BIBLIOTECA DIGITAL DA UFG

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio da Biblioteca Digital de Teses e Dissertações (BDTD/UFG), regulamentada pela Resolução CEPEC nº 832/2007, sem ressarcimento dos direitos autorais, de acordo com a [Lei 9.610/98](#), o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou download, a título de divulgação da produção científica brasileira, a partir desta data.

O conteúdo das Teses e Dissertações disponibilizado na BDTD/UFG é de responsabilidade exclusiva do autor. Ao encaminhar o produto final, o autor(a) e o(a) orientador(a) firmam o compromisso de que o trabalho não contém nenhuma violação de quaisquer direitos autorais ou outro direito de terceiros.

#### 1. Identificação do material bibliográfico

Dissertação     Tese     Outro\*: \_\_\_\_\_

\*No caso de mestrado/doutorado profissional, indique o formato do Trabalho de Conclusão de Curso, permitido no documento de área, correspondente ao programa de pós-graduação, orientado pela legislação vigente da CAPES.

**Exemplos:** Estudo de caso ou Revisão sistemática ou outros formatos.

#### 2. Nome completo do autor

Daiany Caroline Joner

#### 3. Título do trabalho

Projeções futuras de índice de vegetação e os efeitos das mudanças climáticas em regiões áridas e semiáridas

#### 4. Informações de acesso ao documento (este campo deve ser preenchido pelo orientador)

Concorda com a liberação total do documento  SIM     NÃO<sup>1</sup>

**[1]** Neste caso o documento será embargado por até um ano a partir da data de defesa. Após esse período, a possível disponibilização ocorrerá apenas mediante:

**a)** consulta ao(a) autor(a) e ao(a) orientador(a);

**b)** novo Termo de Ciência e de Autorização (TECA) assinado e inserido no arquivo da tese ou dissertação.

O documento não será disponibilizado durante o período de embargo.

Casos de embargo:

- Solicitação de registro de patente;
- Submissão de artigo em revista científica;
- Publicação como capítulo de livro;
- Publicação da dissertação/tese em livro.

**Obs. Este termo deverá ser assinado no SEI pelo orientador e pelo autor.**



Documento assinado eletronicamente por **Daiany Caroline Joner, Discente**, em 23/09/2024, às 11:46, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

---



Documento assinado eletronicamente por **Rafael Dias Loyola, Professor do Magistério Superior**, em 16/10/2024, às 14:32, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).

---



A autenticidade deste documento pode ser conferida no site

[https://sei.ufg.br/sei/controlador\\_externo.php?](https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0)

[acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](https://sei.ufg.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **4846221** e o código CRC **C6DCFB65**.

---

DAIANY CAROLINE JONER

**Projeções futuras de índice de vegetação e os efeitos das mudanças climáticas em regiões áridas e semiáridas**

Tese apresentada ao Programa de Pós-Graduação em Ecologia e Evolução, do Instituto de Ciências Biológicas (ICB), da Universidade Federal de Goiás (UFG), como requisito para obtenção do título de Doutor em Ecologia e Evolução

Área de concentração: Ecologia

Linha de pesquisa: Biogeografia da Conservação

Orientador: Professor Doutor Rafael Dias Loyola

GOIÂNIA  
30 de março 2019

Ficha de identificação da obra elaborada pelo autor, através do Programa de Geração Automática do Sistema de Bibliotecas da UFG.

Joner, Daiany Caroline

Projeções futuras de índice de vegetação e os efeitos das mudanças climáticas em regiões áridas e semiáridas [manuscrito] / Daiany Caroline Joner. - 2019.

CVIII , 108 f.

Orientador: Prof. Dr. Rafael Dias Loyola.


Tese (Doutorado) - Universidade Federal de Goiás, Instituto de Ciências Biológicas (ICB), Programa de Pós-Graduação em Ecologia e Evolução, Goiânia, 2019.

Bibliografia.

Inclui mapas, gráfico, tabelas.

1. cobertura vegetal. 2. secas. 3. modelos de nicho. 4. ARIMA. 5. espécies endêmicas. I. Loyola, Rafael Dias, orient. II. Título.

CDU 574

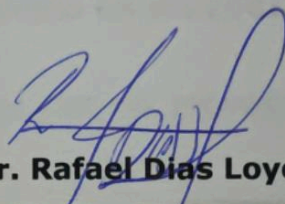


SERVIÇO PÚBLICO FEDERAL  
UNIVERSIDADE FEDERAL DE GOIÁS - UFG  
INSTITUTO DE CIÊNCIAS BIOLÓGICAS - ICB  
PROGRAMA DE PÓS-GRADUAÇÃO EM ECOLOGIA E EVOLUÇÃO - PPGE

**ATA DA SESSÃO PÚBLICA DE DEFESA DE TESE Nº 79**

Aos vinte e oito dias do mês de fevereiro de 2019 (28/02/2019), às quatorze horas (14h), no Auditório do ICB V, UFG, reuniram-se os componentes da banca examinadora: **Prof. Dr. Rafael Dias Loyola, ICB/UFG; Dr. Carlos Afonso Nobre, INPE (via teleconferência); Dr. Frederico Augusto Martins Valtuille Faleiro, INCT/ICB/UFG; Profa. Dra. Levi Carina Terribile, UFG/Jataí; Prof. Dr. Paulo De Marco Júnior, ICB/UFG;** para, em sessão pública presidida pelo (a) primeiro(a) examinador(a) citado(a), procederem à avaliação da defesa de tese intitulada: **“Projeções futuras de índice de vegetação e os efeitos das mudanças climáticas em regiões áridas e semiáridas”**, em nível de doutorado, área de concentração em Ecologia e Evolução, de autoria de **Daiany Caroline Joner**, discente do Programa de Pós-Graduação em Ecologia e Evolução da Universidade Federal de Goiás. A sessão foi aberta pelo(a) presidente(a), que fez a apresentação formal dos membros da banca. A palavra, a seguir, foi concedida a(o) autor(a) da tese que, em cerca de 40 minutos, procedeu à apresentação de seu trabalho. Terminada a apresentação, cada membro da banca arguiu a(o) examinada(o), tendo-se adotado o sistema de diálogo sequencial. Terminada a fase de arguição, procedeu-se à avaliação da tese. Tendo-se em vista o que consta na Resolução nº 1127 de dezembro de 2012 do Conselho de Ensino, Pesquisa, Extensão e Cultura (CEPEC), que regulamenta o Programa de Pós-Graduação em Ecologia e Evolução, a tese foi aprovada, considerando-se integralmente cumprido este requisito para fins de obtenção do título de Doutor(a) em Ecologia e Evolução pela Universidade Federal de Goiás. A conclusão do curso dar-se-á quando da entrega da versão definitiva da tese na secretaria do programa, com as devidas correções sugeridas pela banca examinadora, no prazo de trinta dias

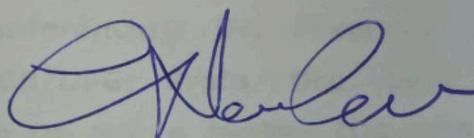
a contar da data da defesa. Cumpridas as formalidades de pauta, às 17 h e 35 min., encerrou-se a sessão de defesa e, para constar, eu, Suely Ana Ribeiro, secretária executiva da Universidade Federal de Goiás - UFG, lavrei a presente ata que, após lida e aprovada, será assinada pelos membros da banca examinadora em três vias de igual teor.



**Prof. Dr. Rafael Dias Loyola**

**Presidente da banca**

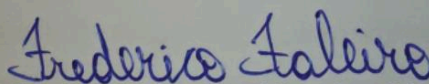
**ICB/UFG**



**Dr. Carlos Afonso Nobre**

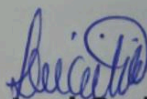
**(via teleconferência)**

**INPE**



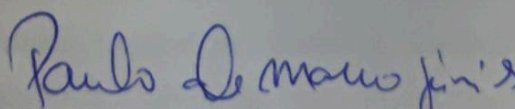
**Dr. Frederico Augusto Martins Valtuille Faleiro**

**INCT/ICB/UFG;**



**Profa. Dra. Levi Carina Terribile**

**UFG/Jataí**



**Prof. Dr. Paulo De Marco Júnior**

**ICB/UFG**

*Dedico este trabalho aos meus pais e meu irmão.*

*“Faça o seu melhor, na condição que você tem,  
enquanto você não tem condições melhores  
para fazer melhor ainda!” Mário Sérgio Cortella.*

## Agradecimentos

É impossível começar os meus agradecimentos sem contar brevemente como cheguei até aqui. Sou de Barreiras, oeste da Bahia e estou em Goiânia desde o mestrado em 2013. Terminei o mestrado e logo continuei comecei o doutorado em 2015. Aparentemente tudo estava normal, uma aluna fazendo doutorado como qualquer outro aluno. Entretanto, ainda no primeiro ano de doutorado comecei a sentir muitas dores pelo corpo e entrei num processo de automedicação que realmente não indico a ninguém! As dores só pioraram e em outubro de 2017 fui diagnosticada com um carcinoma *in situ* no colo de útero. Fiz a cirurgia e retirei o tumor e no ano seguinte, 6 meses depois, um novo começou a se desenvolver. Então procurei novos médicos e fui detectada com quadro imunológico muito baixo, o qual possibilitou a invasão do HPV bem como o surgimento de várias alergias alimentares: alergia ao leite, alergia à soja, alergia à milho, alergia à aveia e intolerância à frutose. E esse foi 2018, meu último ano de doutorado. Um ano cheio de dores e tratamentos, várias cauterizações, antialérgicos e o tratamento de imunoterapia específica para tentar conter o avanço de novos tumores no útero. Foi um ano muito decisivo para mim, e entrei num processo de depressão. Para minha mente, eram muitas transformações ocorrendo ao mesmo tempo. Uma grande amiga minha, irmã praticamente, a Fran, me carregou até o Saudavelmente, um órgão de apoio psicológico da própria UFG, que presta atendimento aos alunos e funcionários. Então à partir do tratamento psicológico e psiquiátrico, meu processo de depressão foi acompanhado por ótimos profissionais. Então, no próximo parágrafo, os agradecimentos começarão a fazer mais sentido.

Agradeço profundamente ao professor Dr. Rafael Loyola, carinhosamente chamado de Rafa, por ter me aceitado novamente em sua equipe. Por ter me incentivado em muitos momentos críticos durante o doutorado, mesmo sabendo que eu tinha tantos problemas que me impediam de frequentar a UFG. Por ter conversado comigo sempre que eu precisei, ouvido minhas angústias, dores e desabafos, principalmente nos últimos dois anos de doutorado, quando pensei em desistir muitas vezes. O seu respeito aos meus momentos difíceis foi muito importante para o meu crescimento pessoal e profissional. Muito obrigada Rafa!!! Acredito que sua ajuda foi além da sua obrigação.

Agradeço muito ao professor Dr. Paulo De Marco Jr., que corrigia meus relatórios a cada fim de ano, e ao saber que eu estava passando por dificuldades na vida pessoal, se prontificou em me ajudar no que fosse possível. Muito obrigada, professor!

Agradeço também ao professor Dr. Carlos Nobre, que nem sabia das condições em que eu trabalhava mas teve grande paciência e sabedoria em lidar com meus atrasos em trabalhos com a minha parceria. Muito obrigada, professor!

Agradeço ao professor Dr. Matheus Ribeiro pelas dúvidas tiradas em e-mails, sempre muito atencioso com os alunos! Muito obrigada, professor!

Agradeço também a professora Dra. Levi Carina pelas contribuições desde lá no mestrado, e por ser um exemplo feminino dentro da pós-graduação para mim! Muito obrigada, professora!

Agradeço à todos os membros da minha banca, por disponibilizarem o seu tempo para ler e participar da minha defesa. Sei que é preciso muito tempo de dedicação para isso e que todos tiveram que abdicar de suas atividades. Muito obrigada, professores!

Agradeço a CAPES por fornecer minha bolsa, que permitisse que eu ficasse aqui em Goiânia.

Agradeço ao pessoal do CB-Lab/UFG por estarem do meu lado! Velhos e novos companheiros! Ex e atuais componentes do laboratório. Fred, Nath, Priscila, Lilian, Lara, Fernando, Fer, Bruno, Luiza, Rafa, Thalline, Larissa, Fábio, Daniel, Bruno 2, Lorena...com todos eles eu tenha uma história carinhosa!! Lorena me dando conselhos pessoais, sempre muito querida! A Thalline tb!! A Nath desde o mestrado! A Lilian que foi minha vizinha e se tornou uma grande amiga!! O esposo da Lilian, o Renan, também se tornou um grande amigo! A Fer ficava aqui em casa quando vinha para Goiânia, ouvia meus desabafos e ríamos muito com *The Big Bang Theory*. A Lara foi minha companheira de república e junto com a Fran se tornou uma presença fundamental

pra mim. O Fernando também foi companheiro de república e se tornou um grande amigo!! Fernando, quero ter uma paz como a sua! Você é um exemplo para mim! O Bruno sempre foi muito prestativo em ajudar! Bom...são muitas pessoas do CB-Lab que me ajudaram! Vocês são incríveis! Nay, não podia deixar de te mencionar! Você foi adotada pelo CB-Lab, mas não tem ideia da grandeza de pessoa dentro de você! A Nay fez uma campanha para arrecadar dinheiro para fazer a minha cirurgia. A cada dia ela me encanta mais! A Flávia é um amor! Sempre prestativa e apta a me ouvir! A Luiza, que além de amar os gatos como eu, me acompanhou em uma sessão de cauterização! Eu tive muita sorte em 2018, apesar de tudo!

Agradeço muito à Tati e o Marcelo, que antigamente eram meros colegas de pós-graduação, mas quando me mudei para vilinha, descobri um enorme potencial de amizade! Ouviram tantos choros meus, que não saberia contar. Virei madrinha de casamento deles e tive oportunidade de conhecer Campo Grande (MS). Sou madrinha também da Aryazils (a gatinha gorducha deles). Tati, você se tornou uma grande parceira/irmã! Passamos por momentos difíceis e nos abraçamos. Passamos dias e dias juntas! Feliz quem tem você ao lado! Marcelo, você me ensinou a fazer molho branco apto pra minhas alergias! Mas foi muito mais que isso, sempre ouviu minhas reclamações e sempre me ajudou além do que poderia! Tati e Marcelo! Muito obrigada!!

Agradeço a minha amiga Amanda, que conheci no mestrado e até hoje sempre temos encontramos com muitos desabafos e risadas!!!

Agradeço a Milena também! Nos encontramos pouco, mas quando nos vemos, não falta assunto!

Agradeço ao pessoal da Academia Clap (quando eu ia rsrs) de me proporcionar momentos únicos de distração! Obrigada Jú, Bartira e Jair!

Agradeço aos meus amigos de terapia do Saudavelmente! Somos tão diferentes e tão parecidos ao mesmo tempo!! Ludy, sempre gentil e com coração enorme!! Luiz, o querido poeta e grande observador! Arianne, sensível e impossível de não amar! Ruver, transmissor de uma energia incrível, não tem como ficar de mau humor ao lado dele! Lucas, jovem sábio sonhador, sua energia é incrível também! Lorena, fez parte pouco tempo mas muito querida!! Tati, parceira da vida até na terapia!! E, a Laís, nossa querida psicóloga!! Eu não teria crescido tanto sem sua ajuda, Laís!! Os remédios me ajudaram, sim! Mas a terapia com a sua presença foi formidável! Entendi que podemos extrair coisas boas de um processo de depressão. Eu entrei na terapia como um robô e saí mais humana que em 35 anos de vida. Para onde eu for, minha convivência com vocês será lembrada como o despertar do meu coma.

Agradeço aos meus amigos de Barreiras! Biaaaaaaaaaaaaaaaaaa!! Quando eu voltar para Barreiras, vamos aprontar muito na cozinha e ouvir Ed Sheeran!!!! Marquinhos e Luciano, ano que vem já temos novo encontro marcado pra comer o hambúrguer gigante de Itu!!! Meu amigo Vinícius, considero meu irmão mais novo, você é incrível!! Não imagino uma vida sem sua existência!! Ananda, minha A.!! O que dizer de você? Tenho vontade de apertar, amassar, abraçar (e olha que só faço isso com gatos)!!! Jú, minha gêmea de coração! Kelly, Marisa, Ramônica, Ynayara, Tarsi, Ítalo!! Meus barulhos queridos e amados!!!! Denise, sempre me ouvindo também!

Agradeço também a minha querida tia Ivanir e seus filhos, Anne, Gabi e Álvaro, que estão sempre apoiando desde quando entrei em Ciências Biológicas e também às conversas agradáveis e incentivadoras com a minha prima Tieni Carla.

Bom...impossível chegar até aqui e deixar de agradecer a minha amiga/irmã, a Fran!! Fran, aprendi tantas coisas com você e devo muito o meu crescimento à sua companhia! Você é umas mulheres mais fortes que já conheci. Esse tipo de força do acaso me faz acreditar que existam pessoas boas e leais pelo mundo. Eu levo muito puxão de orelha da Fran...e às vezes quase uma chinelada rsrs. Quem dera todas as pessoas com depressão terem um braço estendido como a Fran me estendeu! Muito obrigada Fran!! Muito obrigada Alexandro (esposo da Fran)!! Também levo muito puxão de orelha do Alexandro, mas pensem num cara que parece uma fortaleza por fora, mas quando sento pra conversar, sempre tenho prazer em ouvi-lo!!! Fran e Alexandro, muito obrigada pela amizade de vocês, é uma honra pra mim!

Preciso muito agradecer a minha ex-orientadora, Luci Ribeiro. Luci, se estou aqui hoje na UFG, foi por você ter me encorajado a sair da pequena Barreiras e explorar o mundo. Muito obrigada pelas conversas e conselhos!

E por último, quero muito agradecer a minha mãe, meu pai, meu irmão e a namorada do meu irmão (Thianne)!! Mãe, não sei como você teve tanta paciência comigo, porque em muitos momentos descontei minha frustração em você e mesmo assim não saiu de perto em nenhum momento. Nossos laços sem dúvida se fortaleceram desde que fui embora de Barreiras, e se tem uma pessoa que merece todo o respeito do mundo, é você mãe! Você é muito mais que um exemplo pra mim. Só tem um defeito...sempre pensa no bem-estar dos outros rsrs Mãe, espero que você viva mais uns 350 anos! Pai, às vezes a gente discute bastante, mas é tão diferente que na minha adolescência! Geralmente nossas discussões acabam em uma reflexão produtiva rsrs Joni, meu único irmão, que talvez tenha cuidado de mim como um pai. Sempre tivemos muitas divergências filosóficas, mas hoje em dia temos um respeito pelo outro que todas as pessoas que pensam diferente deveriam ter, independentemente de serem irmãs ou não. Meus pais não tiveram condições de pagar a maior parte do meu tratamento aqui em Goiânia, e você fez todo o esforço possível para eu ter o melhor tratamento possível, com os melhores médicos. Muito obrigada! Muito obrigada Thianne por também estar ao meu lado, me incentivar a lutar sempre e me inspirar na causa animal! E muito obrigada por cuidar do meu irmão peludo e falecido Pingo, o gatinho mais importante da minha vida. Muito obrigada!

Enfim, peço mil desculpas se não citei o nome de alguém...não foi esquecimento, mas minha lista de agradecimentos deve ser menor que a tese de doutorado (rsrs) então termino por aqui, deixando uma mensagem para os próximos estudantes de pós-graduação, cientistas, professores e as demais pessoas que chegarem a ler esse documento: *Deixem um bom legado para as próximas gerações, não importa se parecer pouco o que você faz, mas faça o pouco com dedicação e sua consciência estará em paz.*

## Sumário

<b>Resumo</b> .....	7
<b>Abstract</b> .....	8
<b>Apresentação</b> .....	9
<b>Referências</b> .....	13
<b>Capítulo I</b> .....	17
<b>Mudanças climáticas e vertebrados endêmicos em ambientes áridos e semiáridos do planeta</b> .....	18
<b>Resumo</b> .....	19
<b>1 – Introdução</b> .....	20
<b>2 – Material e métodos</b> .....	21
2.1 <i>Coleta de dados, triagem e preparação das variáveis climáticas</i> .....	21
2.2 <i>Etapa da modelagem de nicho potencial</i> .....	24
2.3 <i>Integração da modelagem de nicho potencial à metanálise</i> .....	25
<b>3 – Resultados</b> .....	27
<b>4 – Discussão</b> .....	34
<b>Referências</b> .....	37
<b>Apêndice</b> .....	46
<b>Capítulo II</b> .....	50
<b>De olho no verde: modelagem futura de índice de vegetação para projeção de seca no semiárido brasileiro</b> .....	51
<b>Resumo</b> .....	52
<b>1 – Introdução</b> .....	53
<b>2 – Material e métodos</b> .....	55
2.1 <i>Área de estudo:</i> .....	55
2.2 <i>Obtenção de dados históricos do NDVI</i> .....	56
2.3 <i>Criação do modelo auto ARIMA para predição do NDVI futuro</i> .....	59
2.4 <i>Avaliação do desempenho do NDVI estimado</i> .....	61
<b>3 – Resultados</b> .....	62
<b>4 – Discussão</b> .....	67
<b>Referências</b> .....	69
<b>Capítulo III</b> .....	79
<b>Uso de índice de vegetação em modelos de nicho ecológico para distribuição futura de espécies endêmicas do semiárido brasileiro</b> .....	80
<b>Resumo</b> .....	81
<b>1 – Introdução</b> .....	82
<b>2 – Material e métodos</b> .....	83
2.1 <i>Área de estudo:</i> .....	83
2.2 <i>Espécies analisadas</i> .....	85
2.3 <i>Variáveis climáticas</i> .....	86
2.4 <i>Construindo variáveis do NDVI</i> .....	87
2.5 <i>Modelagem de nicho</i> .....	88
<b>3 – Resultados</b> .....	90

<b>4 – Discussão</b> .....	96
<b>Referências</b> .....	99
<b>Conclusão geral</b> .....	108

## Resumo

A preocupação e a incerteza com os efeitos das mudanças climáticas têm aumentado a necessidade de mais estudos nos últimos anos. Algumas regiões no mundo são mais vulneráveis, como os ecossistemas áridos e semiáridos, cujas projeções futuras indicam aumento na frequência de extremos climáticos. A cobertura vegetal tem papel fundamental na manutenção desses ambientes para a biodiversidade e a população. Generalizações sobre a resposta de espécies exclusivas de ambientes árido e semiáridos às mudanças climáticas são difíceis de fazer devido às lacunas de informações. Na primeira etapa, geramos modelos de nicho climático das espécies de vertebrados desses ecossistemas, cujos resultados foram utilizados em estatística de metanálise para avaliarmos se havia algum tipo de tendência. As 166 espécies utilizadas totalizaram 1660 resultados devido à combinação de métodos e modelos climáticos. Desses resultados, 37% indicaram perda de áreas climáticas favoráveis, 40.92% são inconclusivos e 22.08% apontaram para ganho de áreas climáticas. A heterogeneidade dos resultados, bem como os resultados inconclusivos, indica a influência do uso de diferentes métodos utilizados em modelagem de nicho. Mesmo assim, à nível global existe tendência em haver redução de áreas climáticas favoráveis para vertebrados endêmicos. Na segunda etapa, consideramos o índice foliar NDVI uma variável equivalente à cobertura vegetal. Para projetar essa variável para o futuro, usamos um modelo de série temporal, denominado ARIMA, que foi construído com base em dados de NDVI compreendidos entre 2001 e 2017. Os dados de NDVI, disponibilizados de 16 em 16 dias na resolução de 250m, foram transformados em dados mensais na resolução de 0.1°. Utilizamos como modelo o semiárido brasileiro, fazendo projeções do NDVI para o presente para que pudéssemos validar os resultados e posteriormente projetamos para o futuro (2050 e 2070). Obtemos bons resultados com o modelo estimado para 2017, cuja correlação de Pearson entre o estimado e o observado foi de 0.7552 para a média de toda área do semiárido brasileiro. Os valores de correlação também variaram entre os meses, sendo o mês de janeiro com o maior valor (0.8887). Os valores da raiz quadrada do erro médio (RMSE) também foram baixos, indicando bom desempenho dos modelos. As diferenças observadas entre os meses, os menores valores de correlação e maiores erros médios podem estar relacionados tanto à presença de anomalias climáticas como também aos efeitos das mudanças de uso solo não inseridos nos modelos. O bom desempenho indica grande potencial de uso do NDVI como uma variável equivalente à cobertura vegetal, podendo contribuir de forma significativa para estudos de mudanças climáticas. A terceira e última etapa foi a comparação dos modelos nicho de vertebrados endêmicos do semiárido brasileiro com o uso do NDVI juntamente com as variáveis climáticas com o uso apenas das variáveis climáticas. Das cinco espécies modeladas, todas apresentaram redução de áreas climáticas com ou sem o uso do NDVI. Entretanto a frequências da quantidade de áreas muda ao inserir o NDVI, o que também é observado espacialmente, indicando que a cobertura vegetal pode contribuir em refúgios para algumas espécies. Conclui-se que a cobertura vegetal deve ser considerada em estudos da biodiversidade que investigam mudanças climáticas. Existe também um grande potencial para investigação de períodos de seca. Esses estudos podem fornecer informações importantes tanto para os efeitos da biodiversidade como para a população que depende desses recursos naturais para a sobrevivência.

**Palavras-chave:** cobertura vegetal, secas, modelos de nicho, ARIMA, espécies endêmicas

## **Abstract**

Uncertainties with the effects of climate change has increased the need for more studies in recent years. Some regions in the world are more vulnerable, such as arid and semiarid ecosystems whose future projections indicate an increase in the frequency of extreme climate events. Vegetation cover has a fundamental role in maintaining these environments for biodiversity and population. Generalize about the response to climate change of endemic species from arid and semiarid environments to climate change is difficult to make due to information gaps. In the first part, we generated climatic niche models of the vertebrate species of these ecosystems using the results in meta-analysis statistics to evaluate if there was any tendency. The 166 species used totaled 1660 results due to the combination of climate models and methods. Of these results, 37% indicated loss of favorable climate areas, 40.92% were inconclusive and 22.08% indicated a gain in favorable climate areas. The heterogeneity of the results as well as the inconclusive results indicates the influence of different methods used in niche modeling. Even so, there is a tendency at global level to reduce favorable climate areas for endemic vertebrates. In the second part, we considered the Normalized Difference Vegetation Index (NDVI) a proxy of the vegetal cover. We used the ARIMA time series model to design this variable for the future based on NDVI data between 2001 and 2017. The NDVI data are available every 16 days at 250m resolution. We converted into monthly data and 0.1° degree resolution. We used the Brazilian semiarid as model to project NDVI to the present, validate the results and subsequently to projected for the future (2050 and 2070). We obtained good results with of 0.7552 between the estimated and the observed. Pearson correlation values also varied between months, with January being the highest value (0.8887). The root mean square deviation (RMSE) values were also low, indicating good performance of the models. The observed differences between the months, lowest values of correlation and errors can be related to the presence of climatic anomalies as well as the effects of land use changes. The good performance indicates a great potential of use of the NDVI as proxy of vegetation cover, thus contributing in climate change research. The third part, we evaluated niche models of endemic vertebrates of the Brazilian semi-arid with the use of NDVI integrated with climatic variables. The five species studied lost favorable climatic areas with or without the use of NDVI. However, the frequency of the number of areas changes with the use of NDVI can indicate refuges for some species. Vegetation cover should be considered in biodiversity research investigating climate change. There is great potential for research into drought periods. These studies can provide important information both for the effects of biodiversity and population that depends on these natural resources for survival.

**Keywords:** vegetation cover, drought, niche modeling, arima, endemic species.

## **Apresentação**

O aquecimento global é tema de discussão em diferentes esferas da sociedade. O fenômeno deixou de ser uma preocupação de cunho ambiental e passou a ter implicações na economia, saúde pública, política e segurança alimentar (Houghton et al., 2001). De maneira geral, as mudanças climáticas têm implicação direta no bem-estar da população humana (Adger, 2010). Entretanto, os efeitos das mudanças climáticas têm sido contestados, principalmente quando associadas às atividades humanas e os chamados céticos do clima sugerem não haver tais efeitos. Essa afirmação repercute na sociedade de tal forma, que muitas decisões importantes para a sobrevivência no planeta acabam sendo mal informadas e prejudicadas.

Com o desenvolvimento industrial, tecnológico e de urbanização, o consumo de combustíveis fósseis para a produção de energia intensificou significativamente (Clark & York, 2005) e portanto, o dióxido de carbono e outros gases de efeito estufa vêm se acumulando na atmosfera em ritmo muito acelerado (Meylan et al., 2015). Essas modificações globais foram tão significativas que foi proposto o início de um novo período geológico chamado de Antropoceno, reconhecido a partir do final do século XVIII (Crutzen, 2002; Smith & Zeder, 2013).

O dióxido de carbono é um gás que compõe a atmosfera terrestre desde o passado quando a espécie humana não existia, sendo formado durante o ciclo do carbono, o qual é controlado por três mecanismos: fotossíntese, respiração das plantas e respiração do solo. Como tal ciclo é particularmente conectado ao clima, há influência sobre os processos de aquecimento e resfriamento do planeta (Cao & Woodward, 1998). É possível estudar o clima do passado com base em registros de carbono. Uma das formas mais utilizadas de se obter dados de concentração de dióxido de carbono, em períodos históricos, é a partir de amostragem de sedimentos de bolhas de ar em calotas gelo (Berner et al., 1980; Neftel et al., 1982; Ahn et al., 2009). Outra forma mais recente e promissora que vem sendo utilizada é a composição de registros fósseis de plantas (McElwain, 1998; Rundgren & Beerling, 2003; Seyfullah, 2012; Hand, 2017).

Dessa forma, até se chegar ao contexto dos efeitos humanos sobre o clima, houveram muitos estudos anteriores que associaram as concentrações de dióxido de carbono às atividades normais existentes no planeta, como erupções vulcânicas e variabilidade na radiação solar (Crowley, 2000; Shindell et al., 2003; Biktash, 2017). Um equívoco cometido por alguns cientistas ao negar o efeito humano sobre o clima é comparar o aquecimento da terra com períodos antigos muito mais quentes nos quais não havia atividade humana. Assim, os efeitos antrópicos puderam ser detectados pois, desde o registro da espécie humana no planeta, o aumento da concentração do dióxido de carbono na atmosfera passou a aumentar de forma não natural a partir do seu desenvolvimento industrial e tecnológico (Cox et al., 2000; Crutzen, 2002; Caldeira & Wickett, 2003; Smith & Zeder, 2013).

Com base nos estudos sobre o clima atual, estima-se que a concentração de dióxido de carbono teve um aumento de 25% desde o período industrial (Etheridge et al., 1996; MacFarling Meure et al., 2006; Ahn et al., 2009). A partir de então, vários estudos começaram a investigar os efeitos das mudanças climáticas associando às questões ambientais. Em 1979, foi formalizada pela Organização Meteorológica Mundial (WMO, sigla em inglês) a ciência de estudos climáticos durante a Primeira Conferência Mundial do Clima, cujas atividades antrópicas foram apontadas como o principal direcionador das mudanças climáticas atuais (Bodansky, 2001; Bhandari, 2018). Mas foi apenas em 1988 que a maior autoridade atual em estudos climáticos foi criada com a parceria entre a Organização Meteorológica Mundial e o Programa das Nações Unidas para o Meio Ambiente (UNEP, sigla em inglês), nomeada de Painel Intergovernamental sobre Mudanças Climáticas (IPCC, sigla em inglês).

O IPCC a partir de então passou a elaborar relatórios com dados sobre as mudanças climáticas e seus riscos ao longo do globo terrestre. Entretanto o primeiro relatório, lançado em 1990, tratava apenas da publicação do consenso das informações reunidas pela comunidade científica (Gupta, 2010). Ações de mitigação e adaptação nos anos seguintes puderam ser estabelecidas para diversos setores da sociedade e também como a contribuição dos países ocorreria, principalmente os mais industrializados (Bodansky, 2001). Diversas convenções vêm sendo realizadas a partir de então, como a ECO 92 ocorrida no Rio de Janeiro, onde diversos

acordos e metas foram estabelecidas, com apoio de vários países. Boa parte das ações de mitigação está associada à redução de emissão de gases de efeito estufa causados por desmatamento (Bellassen et al., 2008).

Além disso, com a atuação de diversas áreas nos grupos de pesquisa do IPCC, principalmente por físicos e modeladores atmosféricos, estimar projeções futuras do clima futuro tem permitido avaliar os riscos (Williamson, 2016). O quinto e mais recente relatório IPCC aponta aumento dos impactos das mudanças climáticas, e há chances de que a principal causa está relacionada às atividades humanas (IPCC, 2014a). No Brasil, o Painel Brasileiro de Mudanças Climáticas (PBMC) foi criado em 2009 pelos Ministérios da Ciência e Tecnologia e do Meio Ambiente com objetivos muito semelhantes ao IPCC, mas com dados e relatórios relacionados às mudanças climáticas no Brasil. A adoção de ações de mitigação e adaptação às mudanças climáticas abordadas pelos relatórios do PBMC são estratégicas para o desenvolvimento sustentável no Brasil, o qual possui papel muito importante no cenário global (PBMC & BPBES, 2018).

Algumas regiões do mundo, com ecossistemas áridos e semiáridos são apontadas como umas das mais vulneráveis ao aquecimento global, devido às projeções de aumento de aridez nesses ambientes (IPCC, 2007, 2014b; Schlaepfer et al., 2017). Ambientes áridos e semiáridos, são dois subtipos de ambientes que compõem as *drylands*, que cobrem cerca de 41% da superfície terrestre (Adeel et al., 2005) e abrigam aproximadamente 40% da população mundial, sendo a maioria de baixa renda (White & Nackoney, 2003). Esses ecossistemas são caracterizados principalmente por limitação na disponibilidade de água, com forte variação interanual de precipitação (D’Odorico & Bhattachan, 2012). Estudos indicam que está havendo aumento na intensificação dos eventos extremos nesses ambientes (Katz & Brown, 1992; Karl et al., 1995; Maestre et al., 2012), principalmente em relação às mudanças climáticas previstas pelo IPCC (IPCC, 2007, 2014b).

Além das mudanças climáticas, a desertificação pode se tornar um dos principais problemas em ambientes áridos e semiáridos, afetando desde a biodiversidade como também a produtividade nessas áreas (Safriel & Adeel, 2008). Afetando uma população que já vulnerável e sobrevive de diversos serviços providos por essas regiões, como alimentos, fibras, lenha, carvão vegetal,

produtos medicinais. Salazar (2007) por meio de modelos climáticos investigou que o aumento da temperatura previsto para o futuro poderá transformar ecossistemas áridos e semiáridos em áreas de deserto (Salazar et al., 2007), intensificando ainda mais a necessidade de práticas de manejo que evitem a desertificação.

A cobertura vegetal das regiões áridas e semiáridas é fundamental no escoamento da água da chuva, impedindo que atinja diretamente a superfície do solo e atuam como barreira contra a erosão. Assim, investir em conservação nessas regiões é um grande desafio, mas que irá favorecer tanto a população como a biodiversidade. O planejamento espacial é fundamental para conciliar desenvolvimento sustentável, mudanças climáticas e conservação da biodiversidade (Smith et al., 2018).

Como ecóloga, tenho como objetivo principal na tese projetar o índice de cobertura vegetal NDVI (*Normalized Difference Vegetation Index*, em inglês) para o futuro, de modo que possa ser utilizado em análises espaciais futuras que possam conciliar mudanças climáticas, conservação da biodiversidade e desenvolvimento sustentável em ambientes áridos e semiáridos. Minha tese está estruturada em três capítulos.

No Capítulo I, intitulado “*Efeitos das Mudanças climáticas em vertebrados endêmicos de ambientes áridos e semiáridos*”, simulei técnicas de metanálise com resultados modelos de nicho (gerados aqui no próprio capítulo) de espécies endêmicas de regiões áridas e semiáridas, para avaliar tendências em escalas globais dos efeitos das mudanças climáticas sobre a potencial distribuição das espécies. Esse capítulo foi importante por duas razões: (1) muitos trabalhos publicados utilizam diferentes técnicas de modelagem e os resultados podem variar significativamente, não havendo consenso; (2) Há registros insuficientes sobre a distribuição das espécies desses ambientes dificultando investigações mais profundas sobre os efeitos das mudanças climáticas.

O Capítulo II, intitulado “*Utilizando previsões futuras do NDVI como indicadores de secas no semiárido brasileiro*”, foi elaborado com o intuito de gerar a partir de um modelo de série temporal, denominado ARIMA, valores futuros do NDVI com base em dados históricos

compreendidos entre 2001 e 2017. O NDVI tem sido utilizado em diversos estudos como equivalente (*proxy*) de cobertura vegetal, e o seu uso em mudanças climáticas já tem sido reportado em estudos que avaliam o período histórico até o atual. Porém, para projeções futuras ainda é um desafio, e integrar o uso do NDVI juntamente com variáveis climáticas poderá contribuir com diversas áreas, principalmente para conservação.

O Capítulo III, intitulado “*Integrando o NDVI para avaliar os efeitos das mudanças climáticas na potencial distribuição de espécies endêmicas do semiárido brasileiro*”, teve como objetivo gerar variáveis a partir do banco de dados do Capítulo II, e avaliar os efeitos das mudanças climáticas por meio da modelagem de nicho na potencial distribuição de espécies endêmicas do semiárido brasileiro, comparando o uso e o não uso do NDVI. Sendo assim, umas das possíveis aplicabilidades para o uso do NDVI como *proxy* de cobertura vegetal no futuro.

Deste modo, essa tese combina o uso de variáveis climáticas com uso de uma variável que possa corresponder à cobertura vegetal, tornando os trabalhos daqui por diante mais refinados e mais estratégicos para o planejamento sistemático considerando os efeitos das mudanças climáticas.

## Referências

Adeel Z., Safriel U., Niemeijer D., R W., G de K., Glantz M., Salem B., Scholes B., Niamir-Fuller M., Ehui S., & Yapi-Gnaore (2005) *Ecosystems and Human Well-Being: desertification synthesis*. World Resources Institute, Washington,

Adger W.N. (2010) Climate Change, Human Well-Being and Insecurity. *New Political Economy*, **15**, 275–292.

Ahn J., Brook E.J., & Howell K. (2009) A high-precision method for measurement of paleoatmospheric CO<sub>2</sub> in small polar ice samples. *Journal of Glaciology*, **55**, 499–506.

Bellassen V., Crassous R., Dietzsch L., & Schwartzman S. (2008) Reducing emissions from deforestation and degradation: What contribution from carbon markets? .

Berner W., Oeschger H., & Stauffer B. (1980) Information on the CO<sub>2</sub> cycle from ice core studies. *Radiocarbon*, **22**, 227–235.

Bhandari M.P. (2018) Climate change science: a historical outline. *Advances in Agriculture and Environmental Science: Open Access (AAEOA)* (ed. by M. P. Bhandari), pp. 5–12.

Biktash L. (2017) Long-term global temperature variations under total solar irradiance, cosmic rays, and volcanic activity. *Journal of Advanced Research*, **8**, 329–332.

Bodansky D. (2001) The History of the Global Climate Change Regime. *International Relations and Global Climate Change* (ed. by U. Luterbacher and D.F. Sprinz), pp. 23–40. MIT Press, Cambridge, MA.

Caldeira K. & Wickett M.E. (2003) Anthropogenic carbon and ocean pH. *Nature*, **425**, 365–365.

Cao M. & Woodward F.I. (1998) Dynamic responses of terrestrial ecosystem carbon cycling to global climate change. *Nature*, **393**, 249–252.

Clark B. & York R. (2005) Carbon metabolism: Global capitalism, climate change, and the biospheric rift. *Theory and Society*, **34**, 391–428.

Cox P.M., Betts R.A., Jones C.D., Spall S.A., & Totterdell I.J. (2000) Acceleration of global warming due to carbon-cycle feedbacks in a coupled climate model. *Nature*, **408**, 184–187.

Crowley T.J. (2000) Causes of Climate Change Over the Past 1000 Years. *Science*, **289**, 270–277.

Crutzen P.J. (2002) Geology of mankind. *Nature*, **415**, 23–23.

D’Odorico P. & Bhattachan A. (2012) Hydrologic variability in dryland regions: impacts on ecosystem dynamics and food security. *Philosophical transactions of the Royal Society of London. Series B, Biological sciences*, **367**, 3145–57.

Etheridge D.M., Steele L.P., Langenfelds R.L., Francey R.J., Barnola J.-M., & Morgan V.I. (1996) Natural and anthropogenic changes in atmospheric CO<sub>2</sub> over the last 1000 years from air in Antarctic ice and firn. *Journal of Geophysical Research: Atmospheres*, **101**, 4115–4128.

Gupta J. (2010) A history of international climate change policy. *Wiley Interdisciplinary*

*Reviews: Climate Change*, **1**, 636–653.

Hand E. (2017) Fossil leaves bear witness to ancient carbon dioxide levels. *Science*, **355**, 14–15.

Houghton J.T., Ding Y., Griggs D.J., Noguer M., van der Linden P.J., Dai X., Maskell K., & Johnson C.A. (2001) *Climate Change 2001: The Scientific Basis*. Cambridge University Press, Cambridge,

IPCC (2007) *Climate Change 2007: Impacts, Adaptation and Vulnerability*. .

IPCC (2014a) *Climate Change 2014 Synthesis Report*.

IPCC (2014b) *Climate Change 2014: Impacts, Adaptation, and Vulnerability. Part A: Global and Sectoral Aspects*. .

Karl T.R., Knight R.W., & Plummer N. (1995) Trends in high-frequency climate variability in the twentieth century. *Nature*, **377**, 217–220.

Katz R.W. & Brown B.G. (1992) Extreme events in a changing climate: Variability is more important than averages. *Climatic Change*, **21**, 289–302.

MacFarling Meure C., Etheridge D., Trudinger C., Steele P., Langenfelds R., van Ommen T., Smith A., & Elkins J. (2006) Law Dome CO<sub>2</sub>, CH<sub>4</sub> and N<sub>2</sub>O ice core records extended to 2000 years BP. *Geophysical Research Letters*, **33**, L14810.

Maestre F.T., Salguero-Gómez R., & Quero J.L. (2012) It is getting hotter in here: determining and projecting the impacts of global environmental change on drylands. *Philosophical transactions of the Royal Society of London. Series B, Biological sciences*, **367**, 3062–75.

McElwain J.C. (1998) Do fossil plants signal palaeoatmospheric carbon dioxide concentration in the geological past? *Philosophical Transactions of the Royal Society of London. Series B: Biological Sciences*, **353**, 83–96.

Meylan F.D., Moreau V., & Erkman S. (2015) CO<sub>2</sub> utilization in the perspective of industrial ecology, an overview. *Journal of CO<sub>2</sub> Utilization*, **12**, 101–108.

Neftel A., Oeschger H., Schwander J., Stauffer B., & Zimbrunn R. (1982) Ice core sample measurements give atmospheric CO<sub>2</sub> content during the past 40,000 yr. *Nature*, **295**, 220–223.

PBMC & BPBES (2018) *Potência Ambiental da Biodiversidade : um caminho inovador para o Brasil*. PBMC, COPPE – UFRJ, Rio de Janeiro, Brasil.

Rundgren M. & Beerling D. (2003) Fossil leaves: Effective bioindicators of ancient CO<sub>2</sub> levels? *Geochemistry, Geophysics, Geosystems*, **4**, 45.

Safriel U. & Adeel Z. (2008) Development paths of drylands: Thresholds and sustainability. *3*, 117–123.

Salazar L.F., Nobre C. a., & Oyama M.D. (2007) Climate change consequences on the biome distribution in tropical South America. *Geophysical Research Letters*, **34**, .

Schlaepfer D.R., Bradford J.B., Lauenroth W.K., Munson S.M., Tietjen B., Hall S.A., Wilson S.D., Duniway M.C., Jia G., Pyke D.A., Lkhagva A., & Jamiyansharav K. (2017) Climate change reduces extent of temperate drylands and intensifies drought in deep soils. *Nature Communications*, **8**, 14196.

Seyfullah L.J. (2012) Fossil Focus : Using Plant Fossils to Understand Past Climates and Environments. *Paleontology Online*, **2**, 1–8.

Shindell D.T., Schmidt G.A., Miller R.L., & Mann M.E. (2003) Volcanic and Solar Forcing of Climate Change during the Preindustrial Era. *Journal of Climate*, **16**, 4094–4107.

Smith B.D. & Zeder M.A. (2013) The onset of the Anthropocene. *Anthropocene*, **4**, 8–13.

Smith R., Guevara O., Wenzel L., Dudley N., Petrone-Mendoza V., Cadena M., & Rhodes A. (2018) Ensuring Co-benefits for Biodiversity, Climate Change and Sustainable Development. *Handbook of Climate Change and Biodiversity* pp. 151–166. Springer International Publishing,

White R. & Nackoney J. (2003) Drylands, People, and Ecosystem Goods and Services: A Web-based Geospatial Analysis. *World Resource Institute*, 1–58.

Williamson P. (2016) Emissions reduction: Scrutinize CO<sub>2</sub> removal methods. *Nature*, **530**, 153–155.

# **Capítulo I**

**Mudanças climáticas e vertebrados endêmicos em ambientes**

**áridos e semiáridos do planeta**

# Mudanças climáticas e vertebrados endêmicos em ambientes áridos e semiáridos do planeta

Daiany Caroline Joner<sup>1,2\*</sup>

Jean Carlo Gonçalves Ortega<sup>3</sup>

Luis Mauricio Bini<sup>2</sup>

Rafael Loyola<sup>1,2,4</sup>

## Authors' affiliation:

<sup>1</sup>Laboratório de Biogeografia da Conservação, Departamento de Ecologia, Universidade Federal de Goiás, Goiânia, Goiás, Brasil.

<sup>2</sup>Programa de Pós-Graduação em Ecologia e Evolução, Universidade Federal de Goiás, Goiânia, Goiás, Brasil.

<sup>3</sup>Programa de Pós-Graduação em Ecologia de Ambientes Aquáticos Continentais, Universidade Estadual de Maringá, Maringá, Paraná, Brasil.

<sup>4</sup>Fundação Brasileira para o Desenvolvimento Sustentável, Rio de Janeiro, Brasil

## \* Corresponding author's address:

Daiany Caroline Joner  
Goiânia | Goiás. Email: [dadaiany@gmail.com](mailto:dadaiany@gmail.com)

## Resumo

As mudanças climáticas têm sido apontadas como uma das principais ameaças à sobrevivência às espécies no futuro. Em ecossistemas áridos e semiáridos, o sinergismo das mudanças climáticas com desertificação e aumento na frequência de secas, pode aumentar a vulnerabilidade das espécies desses ambientes. Porém ainda não há consenso entre os pesquisadores sobre a resposta das espécies que compõem esses ecossistemas. A lacuna de informações, principalmente a de espécies endêmicas, e o uso de diferentes métodos dificulta essas conclusões. Para tentar preencher essa lacuna, obtemos registros de espécies endêmicas de ambientes áridos e semiáridos, geramos modelos de nicho da combinação de cinco métodos de modelagem e quatro modelos climáticos para prever a potencial distribuição para o futuro (2080). Utilizamos os resultados dos modelos de nicho para simular uma metanálise e averiguar tendência em ganho ou perda de áreas climáticas favoráveis. Com a triagem dos dados conseguimos obter dados de 166 espécies, distribuídas em nove ecorregiões, totalizando 10 estudos por espécie, 1660 para meta-análise. Dessas espécies, 114 eram répteis, 32 aves, 15 mamíferos e 5 anfíbios. De uma forma geral, há maior tendência em perder áreas climáticas. Cerca de 37% dos estudos indicam perda de áreas climáticas e 22.08% indicam a perda. Entretanto, 40.92% indicam resultados inconclusivos que podem ocorrer tanto pela variação na escolha de métodos como pela coleta de dados da espécie. Utilizamos a metaregressão com ecorregiões e classe taxonômica para avaliar possíveis fontes dessa heterogeneidade. O modelo climático MRI conseguiu capturar melhor as variações entre as ecorregiões. Recomendamos que os modelos climáticos sejam analisados previamente conforme a escala e ecossistema a ser pesquisado, e que seja observada a combinação entre modelos climáticos e métodos de modelagem. A integração da metanálise com a modelagem de nicho poderá fornecer futuramente a identificação de espécies e áreas mais estáveis às mudanças climáticas, mas também as mais vulneráveis de uma forma mais eficiente.

**Palavras chave:** espécies ameaçadas, modelagem de nicho, metanálise, métodos de modelagem, biogeografia da conservação

## Abstract

Climate change may be the major threat to species survival in the future. In arid and semi-arid ecosystems, the synergism of desertification and frequency of droughts with climate change may increase the vulnerability of species in these environments. However, there is no consensus among researchers on the response of species in these ecosystems. The information gap, especially that of endemic species, and the use of different methods difficult these conclusions. To fill this gap, we obtain records of endemic species from arid and semiarid environments to generate niche models from the combination of five modeling methods, and four climate models to predict potential distribution for the future (2080). We use the results of niche models to simulate a meta-analysis and analyze trend in gain or loss of favorable climatic areas. We obtained data of 166 species, distributed in nine ecoregions, totaling 10 studies per species, 1660 for meta-analysis. Of these species, 114 were reptiles, 32 birds, 15 mammals and 5 amphibians. In general, there is a greater tendency to lose climatic areas. About 37% of studies indicate loss of favorable climatic areas and 22.08% indicate loss. However, 40.92% indicate inconclusive results that can occur both by variation in the choice of methods and by the collection of species data.

We used meta-regression with ecoregions and taxonomic class to evaluate possible sources of this heterogeneity. The MRI climate model captured variations among ecoregions. We recommend that climate models be previously analyzed according to the scale and ecosystem as also the combination of climate models and modeling methods. Integrating meta-analysis with niche modeling may provide in future the identification of species and areas more stable to climate change in a more efficient way.

**Keywords:** threatened species, niche modeling, meta-analyze, modeling methods, conservation biogeography

## 1 – Introdução

Mudanças climáticas são projetadas como uma das principais causas do declínio global da biodiversidade no século 21 (Leadley et al., 2010), e que atuando em sinergismo com outros fatores, o impacto negativo sobre as espécies é intensificado ainda mais (Brook et al., 2008). Em ambientes áridos e semiáridos, conhecidos mundialmente como *drylands*, a degradação do solo e o processo de desertificação são acentuados pelas mudanças climáticas (Sampaio et al., 2007; Chasek et al., 2011). Portanto, esses ambientes são considerados extremamente frágeis e um dos mais vulneráveis às alterações do clima (IPCC et al., 2007; Salazar et al., 2007; Burney et al., 2014).

Embora haja evidências limitadas de que as mudanças climáticas estejam direcionando as espécies atuais à extinção (Bellard et al., 2012), estudos históricos têm demonstrado que espécies podem modificar sua distribuição geográfica em função do clima (Parmesan et al., 1999; Davis, 2001; Parmesan & Yohe, 2003; Thomas et al., 2004; Chen et al., 2011; Menéndez et al., 2014), podendo ser contraída, expandida ou deslocada (Walther et al., 2002; Meynecke, 2004; Alagador et al., 2016). Deste modo, estudos têm utilizado a modelagem de nicho ecológico para tentar prever como a distribuição das espécies pode ser afetada (Araujo & Rahbek, 2006; Wiens et al., 2009; Anderson, 2013) pelo aumento da temperatura prevista para o futuro (IPCC, 2014).

De uma forma geral, estes estudos sobre impactos de mudanças climáticas ainda não chegaram a um consenso sobre a resposta das espécies, e os resultados acabam variando principalmente pelo uso de diferentes abordagens, métodos, espécies, regiões, extensão da área de estudo (Urban, 2015; Hornsey et al., 2016). O grau de consenso é essencial pois fornece suporte para implantação de políticas públicas direcionadas à impactos das mudanças climáticas (Ding et al., 2011). Sendo assim, a meta análise pode ser uma abordagem útil, que além de sumarizar os resultados extraídos de estudos individuais, também revela a magnitude do efeito (Monleon & Lintz, 2015). E ao identificar padrões e fortalecer generalizações, suas análises podem servir de guia e referência para tomadores de decisão (Franke, 2001; Carbone & Rivers, 2014).

Entretanto, segundo Urban (2015), atualmente ainda existem muitas lacunas e relações inconsistentes entre a extinção de espécies e mudanças climáticas, principalmente generalizações

em grandes escalas. Em *drylands*, por exemplo, além da deficiência sobre o número e o grau de ameaça das espécies, há uma lacuna considerável sobre a distribuição de espécies endêmicas (Bonkougou, 2009), o que também dificulta generalizações sobre a ameaça em relação à mudanças climáticas. Grande parte dos estudos que avaliam o efeito das mudanças climáticas sobre as espécies nesses ambientes são de escalas regionais e também apresentam resultados variados (Barrows, 2011; Oliveira et al., 2012; Pliscoff et al., 2014; Requena-Mullor et al., 2014; Sow et al., 2014; Gelviz-Gelvez et al., 2015)

Dessa forma, este estudo tem como objetivo avaliar, por meio da modelagem de nicho ecológico, o efeito das mudanças climáticas previstas para o futuro (2080) sobre a distribuição potencial de vertebrados endêmicos em ambientes áridos e semiáridos a nível global, encontrando padrões globais por meio de uma abordagem de metanálise. Especificamente, queremos: (1) quantificar expansão e retração de áreas climáticas favoráveis de mamíferos endêmicos de ambientes áridos e semiáridos com as mudanças climáticas no futuro (2080) à nível global; e (2) sintetizar resultados de expansão e retração de áreas climáticas favoráveis por meio de simulação de uma metanálise.

## **2 – Material e métodos**

### *2.1 Coleta de dados, triagem e preparação das variáveis climáticas*

Para avaliar o efeito das mudanças climáticas no futuro (2080) sobre vertebrados de ambientes áridos e semiáridos no mundo, a primeira ferramenta utilizada foi a modelagem de nicho potencial, de abordagem correlativa, cujos pontos de ocorrência das espécies são correlacionados com as variáveis ambientais desses locais. Como primeiro passo, foram selecionadas as áreas áridas e semiáridas do mundo seguindo o critério de ecorregiões definidas por Olson e colaboradores (2001), disponível para download em <https://www.worldwildlife.org/publications/terrestrial-ecoregions-of-the-world>. Sendo assim, selecionei todas as ecorregiões descritas como *Deserts and Xeric Shrublands*, um total de 95 áreas distribuídas em seis regiões biogeográficas (Figura 1).

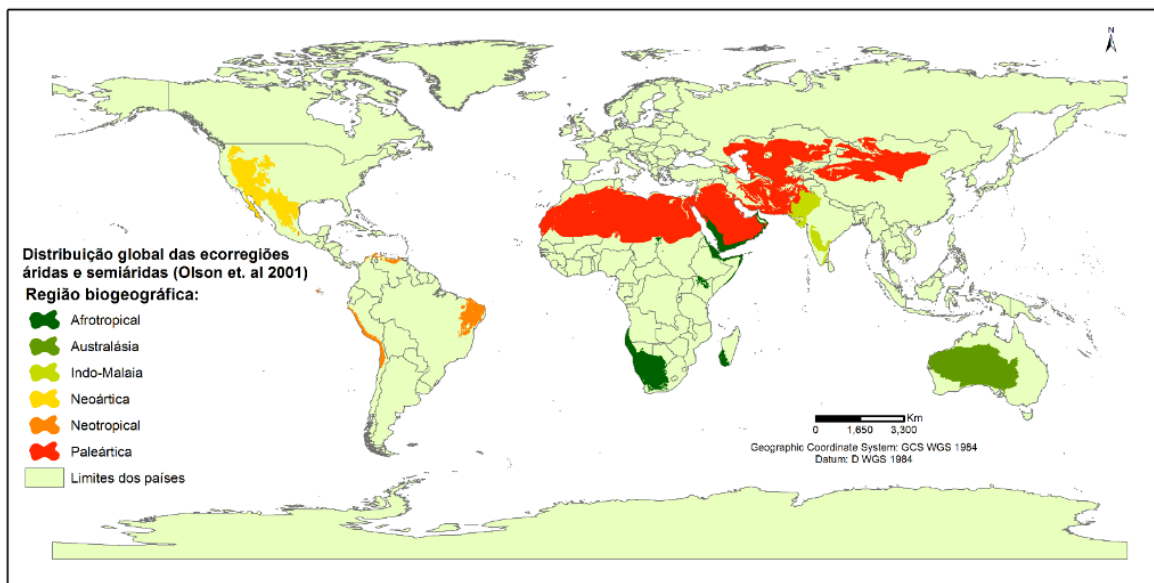


Figura 1. Distribuição das ecorregiões áridas e semiáridas conforme classificação de Olson e colaboradores (2001).

A partir daí realizamos a busca por vertebrados endêmicos (anfíbios, répteis, aves e mamíferos) dessas ecorregiões usando o banco de dados produzidos pela WWF, o qual também se baseava na classificação e delimitação das ecorregiões de Olson e colaboradores (2001), e está disponível para download em <http://www.worldwildlife.org/publications/wildfinder-database>. A busca então de espécies endêmicas nesse banco de dados foi dada por cada ecorregião, e após a listagem completa de 1429 espécies, os dados de ocorrência foram obtidos por meio do pacote SPOCC, utilizável pelo software livre R. A vantagem da utilização desse pacote é a obtenção simultânea dos dados de ocorrências das espécies de vários bancos de dados como: GBIF, BISON, VertNet, eBird, AntWeb.

Os dados de ocorrência foram plotados sobre as ecorregiões, espécie por espécie para realização da primeira etapa de filtragem. Esse procedimento foi necessário pelas discrepâncias entre espécies indicadas como endêmicas na lista da WWF, que ao serem plotadas ultrapassavam os limites de ecorregiões muito pequenas, e, portanto, estavam distribuídas em áreas mais amplas, embora ainda restritas a ambientes áridos e semiáridos. Dessa forma, elaboramos uma classificação artificial de nove ecorregiões com base na distribuição das espécies indicadas previamente como endêmicas pela WWF. Após a criação de uma grade de  $0.25 \times 0.25^\circ$  (ca.  $27 \times 27$  km) para cada

uma das nove ecorregiões, realizei uma nova etapa de filtragem dos pontos de ocorrências das espécies, excluindo então espécies que ocorriam em menos de 10 células, como também eliminando pontos dentro da mesma célula para diminuir a correlação espacial. Então, do total das 1.429 espécies previamente listadas pelo banco de dados das ecorregiões da WWF, foram viáveis de se modelar após os procedimentos de filtragem apenas 166 espécies (114 répteis, 32 aves, 15 mamíferos e 5 anfíbios) das nove ecorregiões (Figura 2).

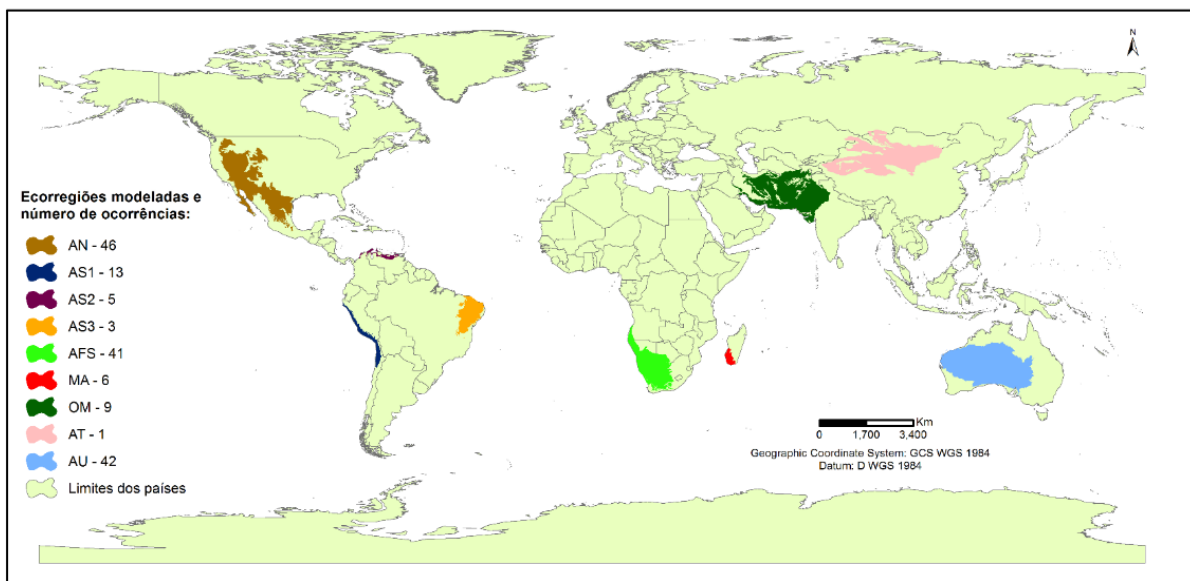


Figura 2. Ecorregiões geradas utilizadas e respectivos registros de ocorrências obtidos após todas as triagens.

Posteriormente, obtivemos as 19 variáveis climáticas na resolução de 0.5°, gratuitamente no banco de dados do ecoClimate (<http://ecoclimate.org/downloads/>), tanto para o presente (1950-1999), como para o cenário futuro (média das simulações para 2080-2100) de efeitos intermediários de gases e efeitos estuda (RCP 6.0), e recortei os dados para cada uma das nove regiões. Houve a preferência por esse banco de dados por possuir um presente modelado para cada Modelo de Circulação Geral da Atmosfera-Oceano (AOGCMs), o que possibilitou incluir as incertezas de todos os modelos climáticos e assim podendo comparar os diferentes resultados do presente com os diferentes resultados do futuro. Dessa forma, utilizei as variáveis climáticas de quatro AOGCMs, cuja escolha foi baseada no trabalho de Knutti e colaboradores (2013), portanto modelos climáticos mais diferentes entre si, sendo eles: CCSM (*Community Climate System Model*), IPSL (*Institut Pierre Simon Laplace*), MIROC (*Model for Interdisciplinary Research on Climate*), MRI (*Meteorological Research Institute*). Essas variáveis climáticas foram interpoladas para resolução de 0.25° e posteriormente reduzimos o número de variáveis climáticas predictoras do presente por meio da Análise de Componentes Principais (PCA) separadamente para cada uma das nove ecorregiões. Esse procedimento foi repetido para as variáveis do futuro mantendo a configuração da PCA do presente, porém projetando para os dados do futuro. Sendo assim, utilizamos os escores resultantes para o presente e futuro na modelagem de nicho.

## *2.2 Etapa da modelagem de nicho potencial*

Como métodos de modelagem, selecionamos métodos com diferentes abordagens: 1) Bioclim – denominado de envelope climático por utilizar apenas dados de presenças das espécies para definir a tolerância ambiental das mesmas (Busby, 1991); 2) Distância Euclidiana – também caracterizado por envelope climático, no qual o ótimo ecológico para espécie é determinado pelo centroide de todos os pontos de ocorrência de uma espécie dentro de um determinado espaço ambiental (Nabout et al., 2010; Lima-Ribeiro & Diniz-Filho, 2012); 3) Distância de Gower – Utiliza a distância para quantificar a similaridade entre dois locais, entretanto, diferente da distância euclidiana, esse método padroniza a amplitude das variáveis para igualar a contribuição de cada

uma (Carpenter et al., 1993); 4) ENFA (*Ecological Niche Factor Analysis*) – é um método que utiliza análises multivariadas para descrever os locais de ocorrência das espécies, onde o nicho é estimado no quanto que a média da espécie se difere da amplitude de total de condições ambientais da área amostrada (Hirzel et al., 2002; Franklin, 2010); 5) GARP (*Genetic Algorithm for Rule-set Production*) – é um algoritmo de aprendizagem automática que utiliza dados de presença e pseudo-ausência para criar regras de decisões em relação às variáveis ambientais por processos análogos à seleção natural, onde as melhores regras são selecionadas (Stockwell & Peters, 1999; Franklin, 2010); 6) Maxent (*Maximum Entropy*) – também é um algoritmo de aprendizagem automática, utiliza dados de presença e pseudo-ausência/background, e é baseado no conceito de máxima entropia (Phillips et al., 2006). Nesse método, informações dos locais ocorrências de espécies são contrastadas com locais amostrados de uma paisagem (*background*), cuja a presença da espécie é desconhecida, e a partir daí são geradas probabilidades de ocorrência das espécies (Merow et al., 2013).

Os dados de ocorrência foram divididos em 75% para calibração e 25% para teste, repetindo esse processo 10 vezes. O desempenho dos modelos resultantes foi avaliado, utilizando como medida a TSS (*True Skill Statistics*), cuja a variação de -1 a +1 indicam a performance, sendo o resultado mais próximo de +1, melhor a performance do modelo (Allouche et al., 2006). Espécies com modelos muito pobres (TSS < 0.5) foram eliminados das análises. Os modelos foram construídos, utilizando a configuração padrão da plataforma BioEnsembles (Rangel et al., 2009). Tal plataforma fornece diferentes dados de saída, entretanto para a integração com a abordagem de meta análise optou-se por utilizar o número de células preditas para cada espécie nos modelos no presente e o número de células preditas no futuro, ou seja, *range size* do presente e *range size* do futuro. Portanto, a quantificação da expansão ou retração da amplitude de distribuição (potencial) para cada espécie.

### 2.3 Integração da modelagem de nicho potencial à metanálise

Em uma meta análise convencional, por meio de uma revisão sistemática da literatura, uma série de estudos individuais, cujo tema investigado é comum, são reunidos em um mesmo banco

de dados e posteriormente através de um estatística é calculada a variância dos resultados (Roscoe & Jenkins, 2005). Posteriormente, é calculado o tamanho do efeito, ou seja, o quão forte é a relação de uma variável com outra, sendo esse geralmente o objetivo primário dos estudos de meta análise (Hedges, 1981).

Entretanto, aqui esses estudos individuais foram substituídos pelo resultado da *range size* (quantidade de células preditas) do presente e do futuro de cada espécie que obtive por meio da modelagem de nicho potencial, sendo, portanto, cada espécie um estudo. Adotamos esse procedimento com o objetivo de obter um padrão de resposta de expansão ou contração do *range* das espécies de regiões áridas e semiáridas em função das mudanças climáticas. Utilizamos então como estatística para avaliar a variância ( $V_D$ ) entre os estudos (espécies) a médias das diferenças (estatística  $D$ ) entre o presente e o futuro para cada AOGCMs e método de modelagem, dadas pela fórmula:

$$D = \bar{X}_{diff},$$
$$V_D = \frac{S_{diff}^2}{n},$$

Como as ecorregiões possuíam extensões de áreas variadas, o *range* do presente e do futuro das espécies foi transformado em proporção para que as medidas de cada estudo fossem padronizados. As análises foram realizadas por AOGCMs e métodos de modelagem por meio do pacote *Metafor*, utilizável na plataforma R. Além disso, será feita análise de metaregressão utilizando as ecorregiões e os quatro grupos taxonômicos com moderadores em busca de fatores que explicam as diferenças entre os resultados encontrados (Borenstein et al., 2009). Para este estudo, utilizamos o modelo de efeito aleatório na metanálise por partir do pressuposto que as variações encontradas nos estudos não se dão apenas por erros amostrais, mas por considerar a variabilidade intrínseca existente entre os estudos.

### **3 – Resultados**

No total, para cada espécie foram simulados 10 estudos, resultantes das combinações de modelagem utilizando 4 AOGCMs + 6 Métodos de modelagem, totalizando 1.660 “estudos” para as 166 espécies. De uma forma geral, ao agrupar todos os resultados por AOGCMs e métodos de modelagem, cerca de 37% dos estudos apontaram perda de áreas climáticas adequadas no futuro, 40% dos resultados foram inconclusivos por não serem significativos e 22% dos estudos apontaram para ganho de áreas climáticas no futuro (Figura 3).




Figura 3. Gráfico de floresta (*forest plot*) de todos os resultados (AOGCMS e métodos de modelagem) das médias das diferenças de proporção entre range do presente e futuro da cada espécie. Cada linha do eixo y representa a variação dos resultados obtidos e o círculo vazio indica a média da diferença para cada espécie. As linhas em vermelho indicam espécies que perdem áreas climaticamente favoráveis, as linhas em verde os resultados não são significativos pois cruzam o eixo no valor zero, e as linhas azuis indicam espécies que ganham áreas climaticamente favoráveis com as mudanças climáticas. A linha tracejada vertical indica eixo com valores igual a zero.

Ao analisar separadamente os estudos com base nos AOGCMs, todos indicam perda de áreas climáticas favoráveis segundo as médias das diferenças (Tabela 1), ou seja, contração das áreas, entretanto apenas o IPSL não há diferença significativa entre presente e futuro significativamente. E o tamanho do efeito (*se - size effect*), que representa a magnitude que o evento ocorre, varia entre os modelos, sendo maior para MIROC. Os valores de  $I^2$ , que indicam a heterogeneidade dos estudos, também foi variada entre os modelos, sendo já considerada uma heterogeneidade considerável valores superiores 50% (Higgins & Thompson, 2002). Os valores de  $Tau^2$ , que representam a quantidade total de heterogeneidade, seguiram, portanto, o mesmo padrão de  $I^2$ , sendo maiores para IPSL e MIROC.

Ao analisar os métodos de modelagem separadamente, quatro métodos indicaram a perda de áreas climáticas favoráveis e dois indicaram ganho de área, sendo o GARP com maior perda de áreas e o Maxent com maior ganho de áreas. Porém apenas para o método Gower a diferença entre o presente e o futuro não foram significativas. O tamanho de efeito (*se*) também variou entre os métodos e todos os valores de heterogeneidade ( $I^2$ ) foram superiores a 50%.

Ao utilizar as ecorregiões como moderadores da metanálise, foram gerados 90 estudos, devido à combinação de 9 ecorregiões com 4 AOGCMs + 6 métodos de modelagem. Destes 90 estudos, 62.22% (n=56) tiveram médias negativas, indicando que a maioria das ecorregiões tendem a perder áreas climáticas favoráveis, embora apenas 22 dessas a diferença foi significativa entre o presente e o futuro. Enquanto que o restante, 37.78% (n=34), tendem a ganhar áreas climáticas favoráveis, sendo apenas seis dessas com diferenças significativas, quando a linha horizontal não cruza o zero, indicada pela linha vertical tracejada (Figura 4). O padrão de diferenças de médias de *range size* entre o presente e o futuro variou bastante em relação às ecorregiões, sendo que cinco ecorregiões tiveram médias negativas em pelo menos sete AOGCMs/métodos (AFS, AS1, AS3, AU, NA), duas com cinco médias negativas e cinco positivas (AS2, OM), e duas com a maioria das médias positivas (AT, MA). As ecorregiões com menor variação de *range size* foram as ecorregiões com maior número de ocorrência de espécies (Figura 4).




Figura 4. Gráfico de floresta (*forest plot*) de todos os resultados (AOGCMS e métodos de modelagem) das médias das diferenças de proporção entre range do presente e futuro da cada espécie, utilizando as ecorregiões como moderadores. Cada linha do eixo y representa a variação dos resultados obtidos e símbolo no meio indica a média da diferença para cada estudo (ecorregião). As cores das linhas representam os diferentes métodos de modelagem e os AOGCMS, e os símbolos representam cada uma das ecorregiões geradas no estudo. A linha tracejada vertical indica eixo com valores igual a zero.

Ao analisar o quanto que as ecorregiões podem explicar a heterogeneidade observada nos estudos ( $I^2$ ), entre os AOGCMs apenas para o CCSM e o MRI as ecorregiões possuem algum poder de explicação ( $R^2$ ) e conseqüentemente o valor do  $I^2$  diminui para ambos os modelos (Tabela 2) quando comparados a análise em moderador (Tabela 1). Em relação aos métodos de modelagem, para o Bioclim, GARP e Gower as ecorregiões puderam explicar a heterogeneidade dentro dos estudos, entretanto o teste com os moderadores não é significativo para o GARP (P-valor = 0.9027).

Tabela 1. Resultados da meta análise considerando tipos de modelos climáticos (AOGCMs) e métodos de modelagem. AOGCMs = CCSM, IPSL, MIROC, MRI; Métodos de modelagem = Bioclim, ENFA, Euclidiana, GARP, Gower, Maxent; Média da diferença = indica a diferença de range size entre o presente e o futuro, valores negativos indicam perda de áreas climáticas favoráveis no futuro e valores positivos indicam ganho de áreas climáticas favoráveis no futuro; Tamanho do efeito (se) = indica a magnitude da perda ou ganho de área climática favorável; Limite inferior = quando negativo, indica os valores de maior perda de áreas climáticas favoráveis e quando positivo, indica os menores valores de ganho de áreas; Limite superior = quando negativo, indica os menores valores de perda de área climática favorável e quando positivo, indica os maiores valores de ganho de áreas; P-valor = indica se as diferenças entre presente e futuro foram significativas;  $I^2$  (%) = porcentagem de heterogeneidade dos estudos;  $Tau^2$  = Quantidade total de heterogeneidade;  $H^2$  = Quantidade total de heterogeneidade / heterogeneidade entre os estudos.

<b>AOGCM/Método</b>	<b>Média da diferença</b>	<b>Tamanho do efeito (se)</b>	<b>Limite inferior</b>	<b>Limite superior</b>	<b>P-valor</b>	<b><math>I^2</math> (%)</b>	<b><math>Tau^2</math></b>	<b><math>H^2</math></b>
CCSM	-5.7244	0.8906	-7.4699	-3.9789	<.0001	39.44	30.0951	1.65
IPSL	-1.9932	1.3681	-4.6746	0.6882	0.1451	67.82	140.486	3.11
MIROC	-5.3551	1.5719	-8.4359	-2.2742	0.0007	71.89	199.298	3.56
MRI	-3.2912	1.0236	-5.2973	-1.285	0.0013	40.4	50.278	1.68
Bioclim	-15.1274	1.3716	-17.8157	-12.4391	<.0001	76.79	166.49	4.31
ENFA	-1.4108	0.6498	-2.6843	-0.1373	0.0299	86.34	35.4299	7.32
Euclidiana	-7.5948	1.3751	-10.2901	-4.8996	<.0001	74.03	125.185	3.85
GARP	-19.0701	5.1034	-29.0726	-9.0676	0.0002	96.23	1968.41	26.54
Gower	0.1967	1.121	-2.0005	2.3939	0.8607	68.97	103.376	3.22
Maxent	12.439	1.769	8.9718	15.9062	<.0001	84.59	303.049	6.49

Tabela 2. Resultados da metaregressão utilizando ecorregiões como moderadores. AOGCMs = CCSM, IPSL, MIROC, MRI; Métodos de modelagem = Bioclim, ENFA, Euclidiana, GARP, Gower, Maxent; I<sup>2</sup> (%) = porcentagem de heterogeneidade dos estudos (heterogeneidade residual/variabilidade desconhecida); R<sup>2</sup>: Porcentagem de explicação da heterogeneidade/variabilidade dos estudos pelo moderador; Tau<sup>2</sup> = Quantidade total de heterogeneidade; H<sup>2</sup> = variabilidade desconhecida/heterogeneidade amostrada; P-valor = teste de significância dos moderadores.

<b>AOGCM/Método</b>	<b>I<sup>2</sup></b>	<b>R<sup>2</sup></b>	<b>Tau<sup>2</sup></b>	<b>H<sup>2</sup></b>	<b>P-valor</b>
CCSM	32.61%	8.91%	27.414	1.48	0.0278
IPSL	65.34%	0.00%	153.3152	2.89	0.0005
MIROC	68.66%	0.00%	218.226	3.19	0.0023
MRI	29.98%	30.95%	34.7164	1.43	0.0003
Bioclim	71.74%	14.80%	141.8448	3.54	0.0008
ENFA	86.68%	0.00%	41.5477	7.51	0.1804
Euclidiana	68.44%	0.00%	156.6986	3.17	0.0027
GARP	91.28%	16.88%	1636.236	11.46	0.9027
Gower	64.77%	10.62%	92.3922	2.84	0.0039
Maxent	81.45%	0.00%	312.4676	5.39	0.0008

Ao utilizar os grupos taxonômicos (classes) como moderadores, também houve variação entre os AOGCMs e métodos de modelagem. Foram gerados nesse caso 44 estudos resultantes da combinação de 4 moderadores x 4 AOGCMs + 6 métodos de modelagem, sendo que 32 destes (72.72%) apresentaram médias negativas e oito (18.18%) apresentaram médias positivas (Figura 5). Desses resultados, 15 médias negativas foram significativas (quando a linha horizontal não cruza a linha vertical tracejada do zero), indicando perda de áreas climáticas favoráveis e apenas uma média positiva foi significativa e indicando ganho de área climática favorável no futuro. Além disso, todas as classes tiveram pelo menos sete médias negativas do total de 10 estudos para cada classe (Figura 5).




Figura 5. Gráfico de floresta (*forest plot*) de todos os resultados (AOGCMS e métodos de modelagem) das médias das diferenças de proporção entre range do presente e futuro de cada classe (grupo taxonômico). Cada linha do eixo y representa a variação dos resultados obtidos e o símbolo no meio indica a média da diferença para cada estudo (classe de vertebrado). As cores das linhas representam os diferentes métodos de modelagem e os AOGCMS, e os símbolos representam cada uma das classes de vertebrados. A linha tracejada vertical indica eixo com valores igual a zero.

Ao analisar se as classes poderiam explicar variações nos resultados, apenas um AOGCM, o MRI, conseguiu identificar a classe como fonte de variação nos estudos ( $R^2 = 2.41\%$ ) e dos métodos de modelagem, apenas o Bioclim ( $R^2 = 1.22\%$ ) e o GARP ( $R^2 = 20.07\%$ ). Porém, o teste dos moderados para todos os casos não foi significativo (Tabela 3).

Tabela 3. Resultados da metaregressão utilizando classes como moderadores. AOGCMs = CCSM, IPSL, MIROC, MRI; Métodos de modelagem = Bioclim, ENFA, Euclidiana, GARP, Gower, Maxent;  $I^2$  (%) = porcentagem de heterogeneidade dos estudos (heterogeneidade residual/variabilidade desconhecida);  $R^2$ : Porcentagem de explicação da heterogeneidade/variabilidade dos estudos pelo moderador;  $Tau^2$  = Quantidade total de heterogeneidade;  $H^2$  = variabilidade desconhecida/heterogeneidade amostrada; P-valor = teste de significância dos moderadores.

AOGCM/método	$I^2$	$R^2$	$Tau^2$	$H^2$	p-val
CCSM	39.37%	0.00%	32.5508	1.65	0.3439
IPSL	66.75%	0.00%	146.9229	3.01	0.2477
MIROC	72.23%	0.00%	216.4607	3.6	0.8166
MRI	39.22%	2.41%	49.0653	1.65	0.1142
Bioclim	75.91%	1.22%	164.452	4.15	0.7076
ENFA	86.40%	0.00%	38.3901	7.35	0.711
Euclidiana	72.86%	0.00%	156.3944	3.68	0.1342
GARP	93.12%	20.07%	1573.3142	14.54	0.9765
Gower	69.02%	0.00%	104.8582	3.23	0.3944
Maxent	84.84%	0.00%	320.4106	6.6	0.1998

#### 4 – Discussão

De uma forma geral houve tendência das espécies amostradas em ecorregiões áridas e semiáridas ao longo do globo, reduzirem as áreas climáticas favoráveis à sua sobrevivência no futuro. Entretanto, há uma série de considerações que precisam ser levantadas aqui. Diversos estudos têm utilizado várias abordagens para estimar a vulnerabilidade das espécies com as mudanças climáticas por meio da modelagem de nicho ecológico. Portanto, há muita variação desde a coleta de dados, escolha dos métodos de modelagem e modelos climáticos (Franklin, 2009; De Marco & Siqueira, 2009; Wiens et al., 2009) e muitas vezes dificultam o poder das generalizações na ecologia (Vepsäläinen & Spence, 2000).

Neste estudo, observamos um padrão de alta heterogeneidade ( $I^2$ ) nos estudos simulados com os dados das espécies. Em meta análises convencionais, o alto grau de heterogeneidade é preocupante para interpretação dos estudos uma vez que as causas podem não ser conhecidas assim

como também pode ocorrer diminuição na credibilidade dos estudos. Devido a isso, o uso da metaregressão é indicado não só para indicar as fontes de incerteza (Nakagawa & Poulin, 2012; Pereira & Galvão, 2014), como também leva ao refinamento de teorias (Nakagawa & Poulin, 2012). Então, apesar dos altos valores de heterogeneidade nesse estudo é possível observar resultados interessantes. Entre os modelos climáticos, o IPSL foi o único que não apresentou significância na metanálise, sugerindo que em trabalhos à níveis globais o mesmo pode não obter boas respostas para ambientes árido e semiáridos.

De forma contrária, o modelo climático MRI além de possuir significância nos resultados, o mesmo conseguiu capturar 30.95% de explicação pela metaregressão quando as ecorregiões foram usadas como preditoras, sugerindo que o uso desse modelo obteve melhor resposta ao avaliar mudanças climáticas para espécies de ambientes áridos e semiáridos. Isso ocorre, pois, os modelos climáticos possuem diferentes performances a depender das regiões ao longo do planeta (Reifen & Toumi, 2009). Pesquisas apontam que a melhor abordagem é trabalhar com o consenso com modelos climáticos (Srinivasa Raju et al., 2017; Crawford et al., 2019), entretanto sugerimos que dependendo do tipo de ecossistema e a escala a ser trabalhada, sejam feitas pesquisas prévias sobre a performance dos modelos climáticos. Assim, uma das possíveis combinações observadas ao utilizar moderadores (preditores) é o uso do modelo climático MRI com método de modelagem Bioclim. O modelo climático CCSM, possuiu a menor variação de resposta às mudanças climáticas em nosso estudo, e também tem sido utilizado nas pesquisas em *drylands* (Archer & Tadross, 2009; Msongaleli et al., 2014; Alba-Sánchez et al., 2015; Lu & Zuo, 2018). Portanto, a escolha do modelo climático pode depender do objetivo da pesquisa.

Porém, se tratando dos métodos de modelagem, a variação dos algoritmos é muito maior segundo vários estudos (Diniz-Filho et al., 2009; Wiens et al., 2009; Loyola et al., 2012; Zhang et al., 2015) e devido a isso tem sido recomendado a abordagem de consenso entre os métodos (Araújo & New, 2007; Marmion et al., 2009; Garcia et al., 2012; Loyola et al., 2014; Zhang et al., 2015). Vários fatores durante o delineamento e calibração dos modelos de nicho têm influência direta sobre as predições, como a quantidade e qualidade dos registros das espécies (Mateo et al., 2010;

van Proosdij et al., 2016), a extensão da distribuição geográfica da espécie (Hernandez et al., 2006) e registro de ausências verdadeiras da espécies (Tessarolo et al., 2014).

Em nosso banco de dados de espécies houve uma quantidade de registros de ocorrência muito variável, desde 10 até mais de 1.000 pontos por espécie. Isso pode ter contribuído com a não significância do método Gower na metanálise e o resultado oposto do Maxent, o qual indicou ganho de áreas climáticas favoráveis enquanto todos os outros indicaram perda de áreas climáticas na metanálise. Em relação às ecorregiões, a variabilidade de pontos de ocorrência também pode ter contribuído com as diferenças entre os resultados, uma vez que as ecorregiões com mais registros de ocorrências (AFS, NA e AU) estão entre as regiões com mais médias negativas, indicando perda de áreas climáticas. Assim, a amostragem de espécies mais vulneráveis às mudanças acaba sendo maior nessas áreas, o que tornaria aparentemente essas áreas mais vulneráveis que as outras talvez de forma equivocada.

A discrepância entre os dados de ocorrência ao separar categoria taxonômica (classe) é ainda maior, tendo apenas cinco espécies de anfíbios contra 144 de répteis, e apesar dessa diferença, a maioria dos estudos utilizando classe como moderados indica diminuição das áreas climáticas favoráveis. Essa diferença de ocorrências também pode ter contribuído com a menor variação de *range size* em répteis. A heterogeneidade (variação) nesse caso pode se dar também por outros fatores ainda não investigados nesse estudo, como características e atributos funcionais das espécies. Enfatizamos ainda a importância de mais coletas de dados sobre as espécies, não só taxonômica como também de distribuição. Portanto, resultados não significativos na metanálise podem ter ocorrido devido à deficiência dos dados.

Segundo Schwartz (2012), os modelos de nicho podem contribuir com estratégias de conservação na indicação de áreas que tendem a ser mais estáveis. Deste modo, uma das formas de contribuir na conservação ao integrar a metanálise com modelos de nicho, é indicação de espécies e áreas que tendem ser mais estáveis com as mudanças climáticas, bem como indicar as áreas e espécies mais susceptíveis. Muitas decisões práticas e políticas são tomadas com base em sínteses, que nem sempre possuem evidências, ou são contraditórias, ou não respondem determinadas

questões (Stewart & Ward, 2018), e assim a metanálise se torna uma ferramenta útil em preencher essas lacunas (Teoh et al., 2019). E mesmo que não seja possível responder todas as perguntas, esse tipo de análise contribuiu no aprofundamento de teorias que poderão posteriormente serem testadas (Berger-Tal et al., 2018).

É importante a realização de mais estudos em escalas maiores, principalmente envolvendo regiões áridas e semiáridas. Neste trabalho, observamos fortes tendências de reduções de áreas adequadas climaticamente para as espécies, as quais atualmente podem já estar sofrendo pressões de natureza antrópica. Sendo assim, estudos que envolvam todas essas regiões áridas e semiáridas podem fornecer informações importantes para tomadas de decisões em escalas globais, tanto em planejamentos que englobem adaptações às mudanças climáticas quanto prevenção e combate à desertificação. Metodologicamente, nosso estudo mostra que a integração dos modelos nicho com a metanálise poderá fornecer qual a melhor combinação de modelos climáticos e métodos de modelagem que poderão responder melhor aos questionamentos sobre as possíveis mudanças de distribuição das espécies com o aquecimento global.

## Referências

Alagador D., Cerdeira J.O., & Araújo M.B. (2016) Climate change, species range shifts and dispersal corridors: an evaluation of spatial conservation models. *Methods in Ecology and Evolution*, **7**, 853–866.

Alba-Sánchez F., López-Sáez J.A., Nieto-Lugilde D., & Svenning J.-C. (2015) Long-term climate forcings to assess vulnerability in North Africa dry argan woodlands. *Applied Vegetation Science*, **18**, 283–296.

Allouche O., Tsoar A., & Kadmon R. (2006) Assessing the accuracy of species distribution models: prevalence, kappa and the true skill statistic (TSS). *Journal of Applied Ecology*, **43**, 1223–1232.

Anderson R.P. (2013) A framework for using niche models to estimate impacts of climate

change on species distributions. *Annals of the New York Academy of Sciences*, **1297**, 8–28.

Araújo M.B. & New M. (2007) Ensemble forecasting of species distributions. *Trends in ecology & evolution*, **22**, 42–7.

Araujo M.B. & Rahbek C. (2006) How Does Climate Change Affect Biodiversity? *Science*, **313**, 1396–1397.

Archer E.R. & Tadross M.A. (2009) Climate change and desertification in South Africa—science and response. *African Journal of Range & Forage Science*, **26**, 127–131.

Barrows C.W. (2011) Sensitivity to climate change for two reptiles at the Mojave–Sonoran Desert interface. *Journal of Arid Environments*, **75**, 629–635.

Bellard C., Bertelsmeier C., Leadley P., Thuiller W., & Courchamp F. (2012) Impacts of climate change on the future of biodiversity. *Ecology letters*, 365–377.

Berger-Tal O., Greggor A.L., Macura B., Adams C.A., Blumenthal A., Bouskila A., Candolin U., Doran C., Fernández-Juricic E., Gotanda K.M., Price C., Putman B.J., Segoli M., Snijders L., Wong B.B.M., & Blumstein D.T. (2018) Systematic reviews and maps as tools for applying behavioral ecology to management and policy. *Behavioral Ecology*, 1–8.

Bonkougou E.G. (2009) *Biodiversity in Drylands: Challenges and Opportunities for Conservation and Sustainable Use*. Challenge paper. The Global Drylands Initiative, UNDP Drylands Development Centre, Nairobi, Kenya,

Borenstein M., Hedges L. V, Higgins J.P.T., & Rothstein H.R. (2009) Meta-regression. *Introduction to meta-analysis* pp. 187–203. John Wiley & Sons, Ltd,

Brook B.W., Sodhi N.S., & Bradshaw C.J. a (2008) Synergies among extinction drivers under global change. *Trends in ecology & evolution*, **23**, 453–60.

Burney J., Cesano D., Russell J., La Rovere E.L., Corral T., Coelho N.S., & Santos L. (2014) Climate change adaptation strategies for smallholder farmers in the Brazilian Sertão. *Climatic Change*, **126**, 45–59.

Busby J.R. (1991) BIOCLIM - a bioclimate analysis and prediction system. *Nature Conservation: Cost Effective Biological Surveys and Data Analysis* (ed. by C.R. Margules and M.P.

Austin), pp. 64–68. CSIRO,

Carbone J.C. & Rivers N. (2014) *Climate policy and competitiveness : Policy guidance and quantitative evidence*.

Carpenter G., Gillison A.N., & Winter J. (1993) DOMAIN : a flexible modelling procedure for mapping potential distributions of plants and animals. *Biodiversity and Conservation*, **2**, 667–680.

Chasek P., Essahli W., Akhtar-Schuster M., Stringer L.C., & Thomas R. (2011) Integrated land degradation monitoring and assessment: Horizontal knowledge management at the national and international levels. *Land Degradation & Development*, **22**, 272–284.

Chen I.-C., Hill J.K., Ohlemüller R., Roy D.B., & Thomas C.D. (2011) Rapid range shifts of species associated with high levels of climate warming. *Science (New York, N.Y.)*, **333**, 1024–1026.

Crawford J., Venkataraman K., & Booth J. (2019) Developing climate model ensembles: A comparative case study. *Journal of Hydrology*, **568**, 160–173.

Davis M.B. (2001) Range Shifts and Adaptive Responses to Quaternary Climate Change. *Science*, **292**, 673–679.

Ding D., Maibach E.W., Zhao X., Roser-Renouf C., & Leiserowitz A. (2011) Support for climate policy and societal action are linked to perceptions about scientific agreement. *Nature Climate Change*, **1**, 462–466.

Diniz-Filho J.A.F., Bini L.M., Rangel T.F., Loyola R.D., Hof C., Nogués-Bravo D., & Araújo M.B. (2009) Partitioning and mapping uncertainties in ensembles of forecasts of species turnover under climate change. *Ecography*, **32**, 897–906.

Franke G.R. (2001) Applications of Meta-Analysis for Marketing and Public Policy: A Review. *Journal of Public Policy & Marketing*, **20**, 186–200.

Franklin J. (2009) *Mapping Species Distributions Spatial Inference and Prediction*. Cambridge: Cambridge University Press.,

Franklin J. (2010) *Mapping species distributions: spatial inference and prediction*.

Cambridge University Press, New York.

Garcia R.A., Burgess N.D., Cabeza M., Rahbek C., & Araújo M.B. (2012) Exploring consensus in 21st century projections of climatically suitable areas for African vertebrates. *Global Change Biology*, **18**, 1253–1269.

Gelviz-Gelvez S.M., Pavón N.P., Illoldi-Rangel P., & Ballesteros-Barrera C. (2015) Ecological niche modeling under climate change to select shrubs for ecological restoration in Central Mexico. *Ecological Engineering*, **74**, 302–309.

Hedges L. V (1981) Distribution Theory for Glass's Estimator of Effect Size and Related Estimators. *Journal of Educational Statistics*, **6**, 107.

Hernandez P.A., Graham C.H., Master L.L., & Albert D.L. (2006) The effect of sample size and species characteristics on performance of different species distribution modeling methods. *Ecography*, **29**, 773–785.

Higgins J.P.T. & Thompson S.G. (2002) Quantifying heterogeneity in a meta-analysis. *STATISTICS IN MEDICINE*, **21**, 1539–1558.

Hirzel A.H., Hausser J., Chessel D., & Perrin N. (2002) Ecological-niche factor analysis: How to compute habitat-suitability maps without absence data? *Ecology*, **83**, 2027–2036.

Hornsey M.J., Harris E.A., Bain P.G., & Fielding K.S. (2016) Meta-analyses of the determinants and outcomes of belief in climate change. *Nature Climate Change*, **6**, 622–626.

IPCC (2014) *Climate Change 2014 Synthesis Report*.

IPCC, Metz B., Davidson O., Barker T., Bashmakov I., Bernstein L., Bogner J., Bosch P., Dave R., Fisher B., Grubb M., Gupta S., Halsnaes K., Heij B.J., Ribeiro S.K., Kobayashi S., Levine M., Martino D., Cerutti O.M., Meyer L., Nabuurs G.-J., Najam A., Nakicenovic N., Rogner H.H., Roy J., Sathaye J., Schock R., Shukla P., Sims R., Smith P., Swart R., Tirpak D., Ürge-Vorsatz D., & Dadi Z. (2007) Summary for Policymakers. *Climate Change 2007: Mitigation. Contribution of Working Group III to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge University Press, Cambridge.

Knutti R., Masson D., & Gettelman A. (2013) Climate model genealogy: Generation

CMIP5 and how we got there. *Geophysical Research Letters*, **40**, 1194–1199.

Leadley P., Pereira H., Alkemade R., JF. F.-M., Proenca V., Scharlemann J., & Walpole M. (2010) *Biodiversity Scenarios: Projections of 21st century change in biodiversity and associated ecosystem services*.

Lima-Ribeiro M. de S. & Diniz-Filho J.A.F. (2012) Modelando a distribuição geográfica das espécies no passado: uma abordagem promissora em paleoecologia. *Revista Brasileira de Paleontologia*, **15**, 371–385.

Loyola R.D., Lemes P., Brum F.T., Provete D.B., & Duarte L.D.S. (2014) Clade-specific consequences of climate change to amphibians in Atlantic Forest protected areas. *Ecography*, **37**, 65–72.

Loyola R.D., Lemes P., Faleiro F. V, Trindade-Filho J., & Machado R.B. (2012) Severe loss of suitable climatic conditions for marsupial species in Brazil: challenges and opportunities for conservation. *PloS one*, **7**, e46257.

Lu S. & Zuo H. (2018) Improvement and Validation of the Common Land Model on Cropland Covered by Plastic Film in the Arid Region of China. *Journal of Applied Meteorology and Climatology*, **57**, 2071–2089.

Marco-Júnior P. & Siqueira M.F. (2009) Como determinar a distribuição potencial de espécies sob uma abordagem conservacionista? *Megadiversidade*, **5**, 65–76.

Marmion M., Parviainen M., Luoto M., Heikkinen R.K., & Thuiller W. (2009) Evaluation of consensus methods in predictive species distribution modelling. *Diversity and Distributions*, **15**, 59–69.

Mateo R.G., Felicísimo Á.M., & Muñoz J. (2010) Effects of the number of presences on reliability and stability of MARS species distribution models: the importance of regional niche variation and ecological heterogeneity. *Journal of Vegetation Science*, **21**, 908–922.

Menéndez R., González-Megías A., Jay-Robert P., & Marquéz-Ferrando R. (2014) Climate change and elevational range shifts: evidence from dung beetles in two European mountain ranges. *Global Ecology and Biogeography*, **23**, 646–657.

Merow C., Smith M.J., & Silander J.A. (2013) A practical guide to MaxEnt for modeling species' distributions: what it does , and why inputs and settings matter. *Ecography*, **36**, 1058–1069.

Meynecke J.-O. (2004) Effects of global climate change on geographic distributions of vertebrates in North Queensland. *Ecological Modelling*, **174**, 347–357.

Monleon V.J. & Lintz H.E. (2015) Evidence of Tree Species' Range Shifts in a Complex Landscape. *PLOS ONE*, **10**, e0118069.

Msongaleli B., Rwehumbiza F., Tumbo S.D., & Kihupi N. (2014) Sorghum Yield Response to Changing Climatic Conditions in Semi-Arid Central Tanzania: Evaluating Crop Simulation Model Applicability. *Agricultural Sciences*, **05**, 822–833.

Nabout J.C., Diniz-filho J.A.F., De Marco Júnior P., Telles M.P.D.C., Naves R.V., & Chaves L.J. (2010) Combining multiple models to predict the geographical distribution of the Barú tree (*Dipteryx alata* Vogel) in the Brazilian Cerrado. *Brazilian Journal of Biology*, **70**, 911–919.

Nakagawa S. & Poulin R. (2012) Meta-analytic insights into evolutionary ecology: An introduction and synthesis. *Evolutionary Ecology*, **26**, 1085–1099.

Oliveira G., Araújo M.B., Rangel T.F., Alagador D., & Diniz-Filho J.A.F. (2012) Conserving the Brazilian semiarid (Caatinga) biome under climate change. *Biodiversity and Conservation*, **21**, 2913–2926.

Olson D.M., Dinerstein E., Wikramanayake E.D., Burgess N.D., Powell G.V.N., Underwood E.C., D'amico J. a., Itoua I., Strand H.E., Morrison J.C., Loucks C.J., Allnutt T.F., Ricketts T.H., Kura Y., Lamoreux J.F., Wettengel W.W., Hedao P., & Kassem K.R. (2001) Terrestrial Ecoregions of the World: A New Map of Life on Earth. *BioScience*, **51**, 933.

Parmesan C., Ryrholm N., Stefanescu C., Hill J.K., Thomas C.D., Descimon# H., Huntley B., Kaila L., Kullberg J., Tammaru T., Tennent W.J., Thomas J. a, & Warren M. (1999) Poleward shifts in geographical ranges of butterfly species associated with regional warming. *Nature*, **399**, 579–583.

Parmesan C. & Yohe G. (2003) A globally coherent fingerprint of climate change impacts

across natural systems. *Nature*, **421**, 37–42.

Pereira M.G. & Galvão T.F. (2014) Heterogeneidade e viés de publicação em revisões sistemáticas. *Epidemiologia e Serviços de Saúde*, **23**, 775–778.

Phillips S.J., Anderson R.P., & Schapire R.E. (2006) Maximum entropy modeling of species geographic distributions. *Ecological Modelling*, **190**, 231–259.

Plissock P., Luebert F., Hilger H.H., & Guisan A. (2014) Effects of alternative sets of climatic predictors on species distribution models and associated estimates of extinction risk: A test with plants in an arid environment. *Ecological Modelling*, **288**, 166–177.

van Proosdij A.S.J., Sosef M.S.M., Wieringa J.J., & Raes N. (2016) Minimum required number of specimen records to develop accurate species distribution models. *Ecography*, **39**, 542–552.

Rangel T.F.L.V.B., Diniz-Filho J.A.F., & Araújo M.B. (2009) Bioensembles - Software for computer intensive ensemble forecasting of species distributions under climate change. .

Reifen C. & Toumi R. (2009) Climate projections: Past performance no guarantee of future skill? *Geophysical Research Letters*, **36**, L13704.

Requena-Mullor J.M., López E., Castro A.J., Cabello J., Virgós E., González-Miras E., & Castro H. (2014) Modeling spatial distribution of European badger in arid landscapes: an ecosystem functioning approach. *Landscape Ecology*, **29**, 843–855.

Roscoe D.D. & Jenkins S. (2005) A Meta-Analysis of Campaign Contributions' Impact on Roll Call Voting. *Social Science Quarterly*, **86**, 52–68.

Salazar L.F., Nobre C. a., & Oyama M.D. (2007) Climate change consequences on the biome distribution in tropical South America. *Geophysical Research Letters*, **34**, .

Sampaio G., Nobre C., Costa M.H., Satyamurty P., Soares-Filho B.S., & Cardoso M. (2007) Regional climate change over eastern Amazonia caused by pasture and soybean cropland expansion. *Geophysical Research Letters*, **34**, L17709.

Schwartz M.W. (2012) Using niche models with climate projections to inform conservation management decisions. *Biological Conservation*, **155**, 149–156.

Sow A.S., Martínez-Freiría F., Dieng H., Fahd S., & Brito J.C. (2014) Biogeographical analysis of the Atlantic Sahara reptiles: Environmental correlates of species distribution and vulnerability to climate change. *Journal of Arid Environments*, **109**, 65–73.

Srinivasa Raju K., Sonali P., & Nagesh Kumar D. (2017) Ranking of CMIP5-based global climate models for India using compromise programming. *Theoretical and Applied Climatology*, **128**, 563–574.

Stewart G. & Ward J. (2018) Meta-science urgently needed across the environmental nexus: a comment on Berger-Tal et al. *Behavioral Ecology*, .

Stockwell D. & Peters D. (1999) The GARP modelling system: problems and solutions to automated spatial prediction. *International Journal of Geographical Information Science*, **13**, 143–158.

Teoh S.H.S., Symes W.S., Sun H., Pienkowski T., & Carrasco L.R. (2019) A global meta-analysis of the economic values of provisioning and cultural ecosystem services. *Science of The Total Environment*, **649**, 1293–1298.

Tessarolo G., Rangel T.F., Araújo M.B., & Hortal J. (2014) Uncertainty associated with survey design in Species Distribution Models. *Diversity and Distributions*, 1–12.

Thomas C.D., Cameron A., Green R.E., Bakkenes M., Beaumont L.J., Collingham Y.C., Erasmus B.F.N., de Siqueira M.F., Grainger A., Hannah L., Hughes L., Huntley B., van Jaarsveld A.S., Midgley G.F., Miles L., Ortega-Huerta M.A., Townsend Peterson A., Phillips O.L., & Williams S.E. (2004) Extinction risk from climate change. *Nature*, **427**, 145–148.

Urban M.C. (2015) Accelerating extinction risk from climate change. *Science*, **348**, 571–573.

Vepsäläinen K. & Spence J.R. (2000) Generalization in Ecology and Evolutionary Biology: From Hypothesis to Paradigm. *Biology and Philosophy*, **15**, 211–238.

Walther G.-R., Post E., Convey P., Menzel A., Parmesan C., Beebee T.J.C., Fromentin J.-M., Hoegh-Guldberg O., & Bairlein F. (2002) Ecological responses to recent climate change. *Nature*, **416**, 389–395.

Wiens J. a, Stralberg D., Jongsomjit D., Howell C. a, & Snyder M. a (2009) Niches, models, and climate change: Assessing the assumptions and uncertainties. *Proceedings of the National Academy of Sciences*, **106**, 19729–19736.

Zhang L., Liu S., Sun P., Wang T., Wang G., Zhang X., & Wang L. (2015) Consensus forecasting of species distributions: The effects of niche model performance and niche properties. *PLoS ONE*, **10**, 1–18.

## Apêndice

### Material suplementar 1

#### Lista de espécies utilizadas na modelagem de nicho

<b>Espécies</b>	<b>Classe</b>	<b>Eco</b>	<b>Região Biogeográfica</b>
<b>Anaxyrus retiformis</b>	Amphibia	AN	Neoártica
<b>Aspidoscelis sonorae</b>	Reptilia	AN	Neoártica
<b>Bipes biporus</b>	Reptilia	AN	Neoártica
<b>Chaetodipus lineatus</b>	Mammalia	AN	Neoártica
<b>Chilomeniscus stramineus</b>	Reptilia	AN	Neoártica
<b>Chionactis palarostris</b>	Reptilia	AN	Neoártica
<b>Coleonyx brevis</b>	Reptilia	AN	Neoártica
<b>Coleonyx switaki</b>	Reptilia	AN	Neoártica
<b>Crotalus tigris</b>	Reptilia	AN	Neoártica
<b>Crotaphytus insularis</b>	Reptilia	AN	Neoártica
<b>Crotaphytus reticulatus</b>	Reptilia	AN	Neoártica
<b>Gopherus flavomarginatus</b>	Reptilia	AN	Neoártica
<b>Hylocharis xantusii</b>	Aves	AN	Neoártica
<b>Kinosternon sonoriense</b>	Reptilia	AN	Neoártica
<b>Lampropeltis alterna</b>	Reptilia	AN	Neoártica
<b>Lampropeltis mexicana</b>	Reptilia	AN	Neoártica
<b>Lampropeltis pyromelana</b>	Reptilia	AN	Neoártica
<b>Lithobates onca</b>	Amphibia	AN	Neoártica
<b>Petrosaurus thalassinus</b>	Reptilia	AN	Neoártica
<b>Phrynosoma mcallii</b>	Reptilia	AN	Neoártica
<b>Phrynosoma platyrhinos</b>	Reptilia	AN	Neoártica
<b>Phyllodactylus nocticolus</b>	Reptilia	AN	Neoártica
<b>Phyllodactylus unctus</b>	Reptilia	AN	Neoártica
<b>Phyllorhynchus decurtatus</b>	Reptilia	AN	Neoártica
<b>Pseudemys gorzugi</b>	Reptilia	AN	Neoártica
<b>Salvadora deserticola</b>	Reptilia	AN	Neoártica
<b>Sauromalus ater</b>	Reptilia	AN	Neoártica
<b>Sauromalus obesus</b>	Reptilia	AN	Neoártica
<b>Sceloporus couchii</b>	Reptilia	AN	Neoártica
<b>Sceloporus hunsakeri</b>	Reptilia	AN	Neoártica
<b>Sceloporus maculosus</b>	Reptilia	AN	Neoártica
<b>Sceloporus merriami</b>	Reptilia	AN	Neoártica
<b>Sceloporus ornatus</b>	Reptilia	AN	Neoártica
<b>Sceloporus zosteromus</b>	Reptilia	AN	Neoártica
<b>Sylvilagus robustus</b>	Mammalia	AN	Neoártica
<b>Tamias panamintinus</b>	Mammalia	AN	Neoártica
<b>Tantilla atriceps</b>	Reptilia	AN	Neoártica
<b>Tantilla wilcoxi</b>	Reptilia	AN	Neoártica
<b>Terrapene coahuila</b>	Reptilia	AN	Neoártica

<b>Espécies</b>	<b>Classe</b>	<b>Eco</b>	<b>Região Biogeográfica</b>
<b>Trachemys gaigeae</b>	Reptilia	AN	Neoártica
<b>Uma exsul</b>	Reptilia	AN	Neoártica
<b>Uma inornata</b>	Reptilia	AN	Neoártica
<b>Uma notata</b>	Reptilia	AN	Neoártica
<b>Uma scoparia</b>	Reptilia	AN	Neoártica
<b>Urosaurus graciosus</b>	Reptilia	AN	Neoártica
<b>Xerospermophilus mohavensis</b>	Mammalia	AN	Neoártica
<b>Anairetes reguloides</b>	Aves	AS1	Neotropical
<b>Cinclodes taczanowskii</b>	Aves	AS1	Neotropical
<b>Geositta crassirostris</b>	Aves	AS1	Neotropical
<b>Geositta peruviana</b>	Aves	AS1	Neotropical
<b>Microlophus peruvianus</b>	Reptilia	AS1	Neotropical
<b>Microlophus thoracicus</b>	Reptilia	AS1	Neotropical
<b>Microlophus tigris</b>	Reptilia	AS1	Neotropical
<b>Phyllodactylus gerrhopygus</b>	Reptilia	AS1	Neotropical
<b>Phyllodactylus microphyllus</b>	Reptilia	AS1	Neotropical
<b>Phyllotis amicus</b>	Mammalia	AS1	Neotropical
<b>Rhinella limensis</b>	Amphibia	AS1	Neotropical
<b>Sicalis raimondii</b>	Aves	AS1	Neotropical
<b>Xenospingus concolor</b>	Aves	AS1	Neotropical
<b>Anolis onca</b>	Reptilia	AS2	Neotropical
<b>Inezia tenuirostris</b>	Aves	AS2	Neotropical
<b>Leucippus fallax</b>	Aves	AS2	Neotropical
<b>Phyllodactylus ventralis</b>	Reptilia	AS2	Neotropical
<b>Synallaxis candei</b>	Aves	AS2	Neotropical
<b>Gyalophylax hellmayri</b>	Aves	AS3	Neotropical
<b>Megaxenops paraguayae</b>	Aves	AS3	Neotropical
<b>Picumnus limae</b>	Aves	AS3	Neotropical
<b>Allactaga balikunica</b>	Mammalia	AT	Paleártica
<b>Amytornis barbatus</b>	Aves	AU	Australásia
<b>Amytornis goyderi</b>	Aves	AU	Australásia
<b>Amytornis purnelli</b>	Aves	AU	Australásia
<b>Aprasia pseudopulchella</b>	Reptilia	AU	Australásia
<b>Austrotyphlops centralis</b>	Reptilia	AU	Australásia
<b>Crinia riparia</b>	Amphibia	AU	Australásia
<b>Ctenophorus decresii</b>	Reptilia	AU	Australásia
<b>Ctenophorus femoralis</b>	Reptilia	AU	Australásia
<b>Ctenophorus gibba</b>	Reptilia	AU	Australásia
<b>Ctenophorus maculosus</b>	Reptilia	AU	Australásia
<b>Ctenophorus rufescens</b>	Reptilia	AU	Australásia
<b>Ctenophorus tjantjalka</b>	Reptilia	AU	Australásia
<b>Ctenophorus vadrappa</b>	Reptilia	AU	Australásia
<b>Ctenotus iapetus</b>	Reptilia	AU	Australásia
<b>Ctenotus maryani</b>	Reptilia	AU	Australásia
<b>Ctenotus rutilans</b>	Reptilia	AU	Australásia
<b>Ctenotus septenarius</b>	Reptilia	AU	Australásia

Espécies	Classe	Eco	Região Biogeográfica
<i>Dasyuroides byrnei</i>	Mammalia	AU	Australásia
<i>Delma elegans</i>	Reptilia	AU	Australásia
<i>Delma pax</i>	Reptilia	AU	Australásia
<i>Diplodactylus klugei</i>	Reptilia	AU	Australásia
<i>Diplodactylus savagei</i>	Reptilia	AU	Australásia
<i>Diporiphora linga</i>	Reptilia	AU	Australásia
<i>Diporiphora valens</i>	Reptilia	AU	Australásia
<i>Gehyra montium</i>	Reptilia	AU	Australásia
<i>Lagorchestes hirsutus</i>	Mammalia	AU	Australásia
<i>Lerista neander</i>	Reptilia	AU	Australásia
<i>Lerista onsloviana</i>	Reptilia	AU	Australásia
<i>Lerista petersoni</i>	Reptilia	AU	Australásia
<i>Lerista uniduo</i>	Reptilia	AU	Australásia
<i>Lerista vermicularis</i>	Reptilia	AU	Australásia
<i>Liopholis margaretae</i>	Reptilia	AU	Australásia
<i>Nephrurus amyaee</i>	Reptilia	AU	Australásia
<i>Nephrurus deleani</i>	Reptilia	AU	Australásia
<i>Notomys fuscus</i>	Mammalia	AU	Australásia
<i>Notoryctes caurinus</i>	Mammalia	AU	Australásia
<i>Notoscincus butleri</i>	Reptilia	AU	Australásia
<i>Ophidiocephalus taeniatus</i>	Reptilia	AU	Australásia
<i>Petrogale xanthopus</i>	Mammalia	AU	Australásia
<i>Pogona nullarbor</i>	Reptilia	AU	Australásia
<i>Pseudechis butleri</i>	Reptilia	AU	Australásia
<i>Varanus pilbarensis</i>	Reptilia	AU	Australásia
<i>Coua verreauxi</i>	Aves	MA	Afrotropical
<i>Nesillas lantzii</i>	Aves	MA	Afrotropical
<i>Newtonia archboldi</i>	Aves	MA	Afrotropical
<i>Oplurus cyclurus</i>	Reptilia	MA	Afrotropical
<i>Tracheloptychus madagascariensis</i>	Reptilia	MA	Afrotropical
<i>Uratelornis chimaera</i>	Aves	MA	Afrotropical
<i>Bunopus crassicauda</i>	Reptilia	OM	Paleártica
<i>Calomyscus baluchi</i>	Mammalia	OM	Paleártica
<i>Cyrtopodion gastropholis</i>	Reptilia	OM	Paleártica
<i>Dendrocopos assimilis</i>	Aves	OM	Paleártica
<i>Laudakia erythrogastra</i>	Reptilia	OM	Paleártica
<i>Passer pyrrhonotus</i>	Aves	OM	Paleártica
<i>Podoces pleskei</i>	Aves	OM	Paleártica
<i>Pseudepidalea surda</i>	Amphibia	OM	Paleártica
<i>Stenodactylus affinis</i>	Reptilia	OM	Paleártica
<i>Acontias garipeensis</i>	Reptilia	AFS	Afrotropical
<i>Afroedura africana</i>	Reptilia	AFS	Afrotropical
<i>Bitis cornuta</i>	Reptilia	AFS	Afrotropical
<i>Bitis schneideri</i>	Reptilia	AFS	Afrotropical
<i>Certhilauda benguelensis</i>	Aves	AFS	Afrotropical
<i>Certhilauda curvirostris</i>	Aves	AFS	Afrotropical

<b>Espécies</b>	<b>Classe</b>	<b>Eco</b>	<b>Região Biogeográfica</b>
<b>Colopus kochii</b>	Reptilia	AFS	Afrotropical
<b>Emarginata schlegelii</b>	Aves	AFS	Afrotropical
<b>Emarginata tractrac</b>	Aves	AFS	Afrotropical
<b>Eremopterix australis</b>	Aves	AFS	Afrotropical
<b>Erythropygia coryphoeus</b>	Aves	AFS	Afrotropical
<b>Eupodotis rueppellii</b>	Aves	AFS	Afrotropical
<b>Gerbillurus setzeri</b>	Mammalia	AFS	Afrotropical
<b>Gerbillurus vallinus</b>	Mammalia	AFS	Afrotropical
<b>Goggia lineata</b>	Reptilia	AFS	Afrotropical
<b>Meroles anchietae</b>	Reptilia	AFS	Afrotropical
<b>Meroles ctenodactylus</b>	Reptilia	AFS	Afrotropical
<b>Meroles cuneirostris</b>	Reptilia	AFS	Afrotropical
<b>Meroles knoxii</b>	Reptilia	AFS	Afrotropical
<b>Meroles reticulatus</b>	Reptilia	AFS	Afrotropical
<b>Namibornis herero</b>	Aves	AFS	Afrotropical
<b>Narudasia festiva</b>	Reptilia	AFS	Afrotropical
<b>Ouroborus cataphractus</b>	Reptilia	AFS	Afrotropical
<b>Pachydactylus austeni</b>	Reptilia	AFS	Afrotropical
<b>Pachydactylus haackei</b>	Reptilia	AFS	Afrotropical
<b>Pachydactylus labialis</b>	Reptilia	AFS	Afrotropical
<b>Pachydactylus rangei</b>	Reptilia	AFS	Afrotropical
<b>Pachydactylus scherzi</b>	Reptilia	AFS	Afrotropical
<b>Pachydactylus scutatus</b>	Reptilia	AFS	Afrotropical
<b>Parotomys brantsii</b>	Mammalia	AFS	Afrotropical
<b>Pedioplanis breviceps</b>	Reptilia	AFS	Afrotropical
<b>Pedioplanis gaerdesi</b>	Reptilia	AFS	Afrotropical
<b>Pedioplanis laticeps</b>	Reptilia	AFS	Afrotropical
<b>Phragmacia substriata</b>	Aves	AFS	Afrotropical
<b>Rhoptropus afer</b>	Reptilia	AFS	Afrotropical
<b>Rhoptropus barnardi</b>	Reptilia	AFS	Afrotropical
<b>Rhoptropus biporosus</b>	Reptilia	AFS	Afrotropical
<b>Rhoptropus bradfieldi</b>	Reptilia	AFS	Afrotropical
<b>Telescopus beetzi</b>	Reptilia	AFS	Afrotropical
<b>Trachylepis hoeschi</b>	Reptilia	AFS	Afrotropical
<b>Typhlosaurus vermis</b>	Reptilia	AFS	Afrotropical

# **Capítulo II**

**De olho no verde: modelagem futura de índice de vegetação**

**para projeção de seca no semiárido brasileiro**

# De olho no verde: modelagem futura de índice de vegetação para projeção de seca no semiárido brasileiro

Daiany Caroline Joner<sup>1,2\*</sup>

Marcelo Bruno Pessoa<sup>2</sup>

Tatiana Souza do Amaral<sup>2</sup>

Franciele Fath<sup>3</sup>

Rafael Loyola<sup>1,2,4</sup>

## Authors' affiliation:

<sup>1</sup>Laboratório de Biogeografia da Conservação, Departamento de Ecologia, Universidade Federal de Goiás, Goiânia, Goiás, Brasil.

<sup>2</sup>Programa de Pós-Graduação em Ecologia e Evolução, Universidade Federal de Goiás,

<sup>3</sup>Núcleo de Geoinformação (NGeo) do Centro Nacional de Pesquisa e Conservação de Répteis e Anfíbios, Goiânia, Goiás, Brasil.

<sup>4</sup>Fundação Brasileira para o Desenvolvimento Sustentável, Rio de Janeiro, Brasil

## \* Corresponding author's address:

Daiany Caroline Joner  
Goiânia | Goiás. Email: [dadaiany@gmail.com](mailto:dadaiany@gmail.com)

## Resumo

A necessidade de tomada de decisões que mitiguem os efeitos das mudanças climáticas está ocorrendo em diversos setores da sociedade. Regiões áridas e semiáridas mundo são mais vulneráveis aos efeitos das mudanças climáticas e requerem medidas mais rapidamente. A cobertura vegetal desses ecossistemas tem papel fundamental na proteção da biodiversidade e manutenção dos recursos naturais que fornecem diversos benefícios à população. O NDVI é um índice que tem sido utilizado para acompanhar a dinâmica da vegetação e em estudos mais recentes é usado como equivalente da cobertura vegetal. A existência de banco de dados históricos permite a projeção de valores futuros por meio de modelos matemáticos de séries temporais, como o ARIMA. Dessa forma, nosso principal objetivo foi projetar valores futuros de NDVI para que pudessem ser utilizados como indicador de secas e possivelmente áreas mais vulneráveis à desertificação. Para isso, utilizamos dados históricos de NDVI para o semiárido brasileiro, compreendidos entre 2001 e 2017, e estimamos valores atuais de NDVI por meio do modelo ARIMA para que pudessem ser validados com os dados observados no presente. Após o ajuste com os dados observados, geramos projeções futuras (2030, 2050, 2070). Em geral os modelos estimados para o período atual (2017) apresentaram bom desempenho, possuindo em média para todo o semiárido uma correlação de Pearson de 0.7552 e com menor valor da raiz quadrada do erro médio (RMSE) de 0.0602. Os padrões de diminuição de cobertura vegetal (valores de NDVI) foram semelhantes entre o modelo observado e estimado durante os meses de 2017. O padrão também é parecido entre os meses nos períodos futuros. Porém, há projeções de aumento de regiões secas (com menores valores de NDVI), cerca de 48.05% para 2030, 48.44% para 2050 e 46.49% em relação ao período atual de 2017. Sugerimos que os valores de NDVI estimados pelo modelo ARIMA podem fornecer informações importantes sobre a dinâmica da cobertura vegetal no semiárido brasileiro. Além disso, pode ser uma abordagem promissora em outros ecossistemas semelhantes, em diferentes escalas e diferentes objetos de estudo que investiguem os efeitos das mudanças climáticas, principalmente por representar áreas mais susceptíveis à períodos de seca.

**Palavras chave:** NDVI, ARIMA, mudanças climáticas, desertificação, biogeografia da conservação

## Abstract

The need for decision-making to mitigate the effects of climate change is occurring in many sectors of society. Arid and semiarid environments are more vulnerable to the effects of climate change and require faster actions. The vegetal cover of these ecosystems plays a fundamental role in the protection of biodiversity and the maintenance of the natural resources that provide diverse benefits to the population. NDVI is an index that has been used to monitor vegetation dynamics and as proxy of vegetal cover in recent studies. The existence of a historical database allows the projection of future values through mathematical models of time series, such as ARIMA. Thus, our main objective was to predict future NDVI values to use as indicators of droughts and areas more vulnerable to desertification. We used historical NDVI data for the Brazilian semiarid between 2001 and 2017 and estimated current values of NDVI using the ARIMA model to be validate with the data observed. After adjusting for the observed data, we generated future projections (2030, 2050, 2070). In general, the models estimated for the current period (2017) performed well, with a Pearson correlation of 0.7552 and root-mean-square error (RMSE) of 0.0602 for entire semiarid region. Decreasing patterns in vegetal cover (NDVI values) were similar between the model observed and estimated during the months of 2017. The pattern is also similar between the months in the future periods. However, there are projections for the increase of dry regions (with lower NDVI values), about 48.05% for 2030, 48.44% for 2050 and 46.49% for the current period of 2017. We suggest that NDVI values estimated by the ARIMA model may provide important information on the dynamics of vegetal cover in the Brazilian semiarid. In addition, the promising approach can be used in other similar ecosystems, at different scales and different objects of study that investigate the effects of climate change, mainly in areas more susceptible to periods of drought.

**Keywords:** NDVI, ARIMA, climate change, desertification, conservation biogeography

## 1 – Introdução

Mudanças climáticas têm sido foco de debates intensos em diversos setores da sociedade nos últimos anos, pois trazem impactos políticos, econômicos, sociais e ambientais (Houghton et al., 2001; Debray et al., 2018). Embora vários fatores indiquem que a sinergia das mudanças climáticas com a desertificação pode aumentar os efeitos negativos sobre a sociedade em geral, são as grandes extensões de regiões áridas e semiáridas que estarão mais expostas (IPCC et al., 2007; IPCC, 2014).

Essas regiões também conhecidas como *drylands*, ocupam cerca de 45% da superfície terrestre e são compostas por savanas, pastagens, arbustos, plantas xerófitas, desertos quentes e frios (Allen-Diaz et al., 1996). Além de serem regiões com alta densidade populacional humana (Mortimore, 2009), tal população depende significativamente dos recursos desses ecossistemas, sendo as pessoas mais impactadas por períodos de seca e desertificação (Reed & Stringer, 2016). Ainda hoje, os processos que levam à degradação do solo e às mudanças climáticas são muito estudados individualmente, entretanto a interação entre eles ainda é pouco compreendida (Reed & Stringer, 2016), porém de extrema importância para regiões áridas e semiáridas para que tomadas de decisões que contemplem impactos das mudanças climáticas seja mais eficiente.

A vegetação que compõe a biodiversidade em regiões áridas e semiáridas é responsável pelo fornecimento de diversos serviços ecossistêmicos importantes para a população desses ecossistemas, como provisão de comida, fibra e combustível (Manhães et al., 2016, 2018). Além destes, um dos principais serviços fornecidos pela vegetação é a proteção do solo contra a erosão e que portanto, interagem frequentemente com o do volume de precipitação (Adeel et al., 2005). Portanto, as mudanças climáticas previstas para essas regiões, como redução da precipitação, erosão eólica, aumento da evapotranspiração e frequência das secas (IPCC et al., 2007; Thomas, 2008; Burney et al., 2014), tendem a reduzir a proteção do solo e potencializando o risco de secas e desertificação (Scarano et al., 2018).

Atualmente diversos estudos têm criado índices ou métodos para mapear e descrever áreas de risco de desertificação (Bowker et al., 2008; Ibáñez et al., 2008; Dakos et al., 2012; Higginbottom & Symeonakis, 2014; Seekell & Dakos, 2015). O NDVI (*Normalized Difference Vegetation Index*) é um índice de cobertura vegetal que começou a ser usado em diversos estudos para acompanhar as condições de crescimento da vegetação (Tucker et al., 2005) e avaliar potenciais área de desertificação no presente (Piao, 2005; Cui et al., 2011; Weishou et al., 2011). Entretanto, passou também a ser usado em diversas áreas como na ecologia, por exemplo, como *proxy* de habitat de espécies em modelagem de nicho ecológico (Lu et al., 2016). Mais recentemente, tem sido investigado como promissor para estudos que envolvam mudanças climáticas (Usman et al., 2013; Miao et al., 2015).

Além disso, modelos de séries temporais têm sido utilizados para predição em diversos campos tais como, economia, finanças, ciências e engenharia (Shumway & Stoffer, 2010; Adhikari & Agrawal, 2013) e atualmente também têm sido empregados em estudos sobre mudanças climáticas globais (Lobell et al., 2013). Por meio de técnicas de sensoriamento remoto (Fernández-Manso et al., 2011). A modelagem de séries temporais tem como objetivo analisar, com auxílio de dados históricos, a relação entre as observações temporais e extrair informações para construção de modelos capazes de realizarem predições (Raicharoen et al., 2003; Adhikari & Agrawal, 2013).

Um modelo particular de série temporal que tem sido usado em predições é o ARIMA (sigla de *autoregressive integrated moving-average*) (Christodoulos et al., 2010; Sarpong, 2013; Anwar et al., 2016; Tian et al., 2016; Shao & Dai, 2018). Entre os estudos, o NDVI também tem sido incorporado ao ARIMA em escalas menores para investigação da dinâmica da vegetação (Fernández-Manso et al., 2011; Bayr et al., 2016), incluindo em regiões do Brasil (Gonçalves et al., 2012; Nassur et al., 2015a). Criado a partir da abordagem de Box e Jenkins (1970), o modelo ARIMA tem sido usado principalmente pela sua simplicidade e boa capacidade de predição (Stevenson, 2007; Adhikari & Agrawal, 2013). Seus principais pressupostos consideram que as séries temporais são lineares e com distribuição normal dos dados (Adhikari & Agrawal, 2013).

Sendo assim, nosso estudo tem como objetivo principal gerar previsões futuras do NDVI (*Normalized Difference Vegetation Index*) para o semiárido brasileiro que possam ser incorporadas em avaliações de risco em áreas com potencial de secas e desertificação. Especificamente, pretendemos: (1) criar um modelo de séries temporais adaptadas para o NDVI na escala do semiárido brasileiro, (2) avaliar o desempenho dos modelos com o NDVI atual, (3) gerar um banco de dados de NDVI futuro para a região do semiárido brasileiro.

## **2 – Material e métodos**

### *2.1 Área de estudo:*

A área de estudo denominada semiárido brasileiro é composta por três biomas brasileiros sendo eles a Caatinga (751.063,270 km<sup>2</sup>), o Cerrado (141.195,320 km<sup>2</sup>) e a Mata Atlântica (87.874,387 km<sup>2</sup>) (Figura 1). Obtivemos dados sobre sua distribuição na mapoteca do Instituto Nacional do Semiárido (INSA), que se baseia na base cartográfica do Instituto Brasileiro de Geografia e Estatística (IBGE) elaborada para o território nacional, em 2013. A delimitação do semiárido abrange nove estados brasileiros (Alagoas, Bahia, Ceará, Minas Gerais, Paraíba, Pernambuco, Piauí, Rio Grande do Norte e Sergipe) e 1.135 municípios, sendo a maioria do Nordeste e uma parte menor no Sudeste. Assim, representando aproximadamente 20% do território do Brasil (Vieira et al., 2013).

Os critérios para inclusão da classificação semiárida segundo MMA/SRH (2004) incluíram três características: precipitação pluviométrica média anual igual ou inferior a 800 mm, índice de aridez de *Thornthwaite* igual ou inferior a 0,50 (razão da precipitação e da evapotranspiração potencial) e percentual diário de déficit hídrico igual ou superior a 60%, considerando todos os dias do ano. O período de precipitação no semiárido brasileiro costuma ocorrer entre fevereiro a maio, porém com grande variabilidade entre os anos (Oyama & Nobre, 2004), forte insolação, altas temperaturas (Angelotti et al., 2009) e portanto sendo a água o principal fator limitante, muitas vezes insuficiente para as necessidades da população (Silva et al., 2010).

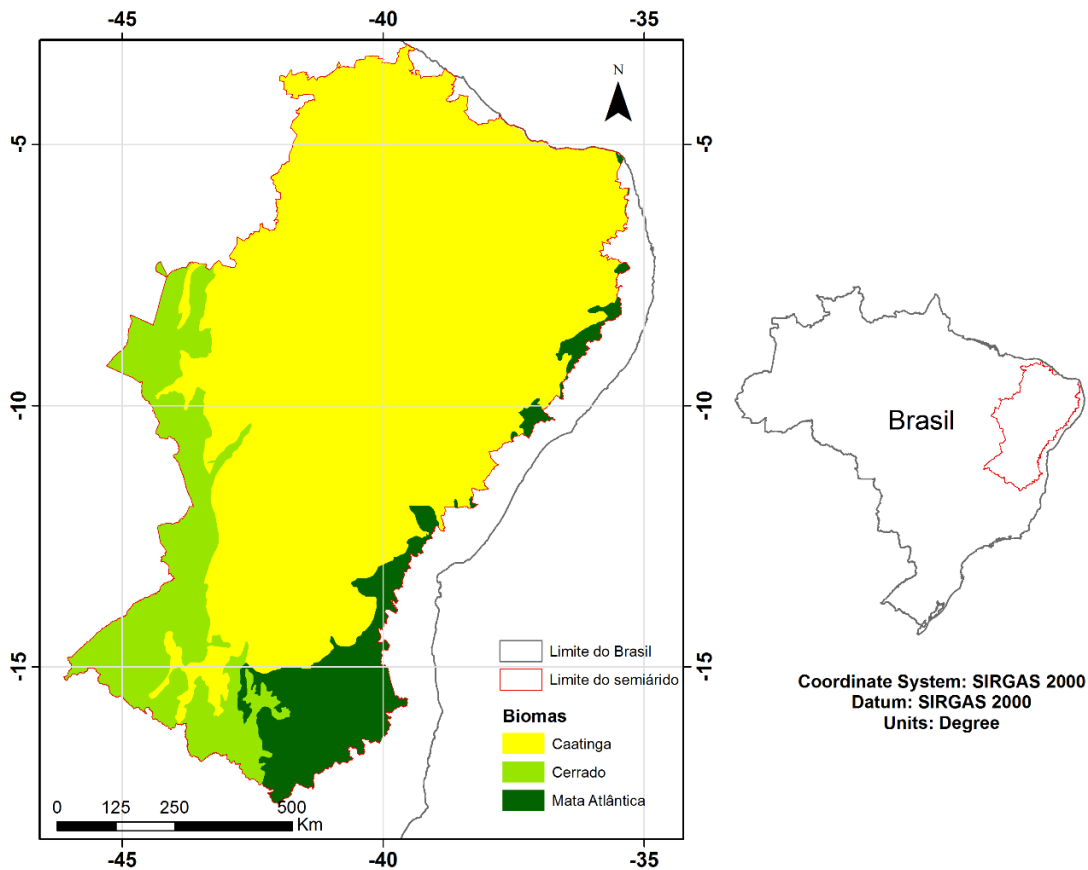


Figura 1. Área de estudo: delimitação do Semiárido brasileiro

Apesar do semiárido brasileiro ser dominado pela Caatinga, caracterizada por mosaico de arbustos espinhosos a florestas secas (Leal et al., 2005b), também possui manchas de florestas semidecíduais, floresta sempre verde, manchas de cerrado e boa parte com pastagens mistas e terras agrícolas (Leal et al., 2005a; Vieira et al., 2013; Cunha et al., 2015). Esse conjunto de formações vegetais ocorrem devido a variabilidade abiótica no semiárido (Araújo et al., 2005), principalmente da disponibilidade de água (Rocha, 2009).

## 2.2 Obtenção de dados históricos do NDVI

O NDVI é um índice de vegetação originalmente proposto por Rouse e colaboradores (1972), que utiliza contrastes de duas bandas espectrais de imagens de satélite, representada pela equação:  $NDVI = \frac{\text{Infra Vermelho} - \text{Vermelho}}{\text{Infra Vermelho} + \text{Vermelho}}$ . O resultado varia entre -1 a +1. Os valores mais próximos de +1 indicam maior densidade de vegetação na

célula (*pixel*) da imagem, enquanto locais não vegetados, como corpos de água e locais úmidos, são responsáveis pelos valores negativos (até -1). Solo exposto é definido por valores positivos, porém muito próximos a zero (Lillesand et al., 2004). Dessa forma, podemos baixar imagens de satélite e calcularmos manualmente os valores de NDVI que serão dados para cada célula. Entretanto, é necessário que o usuário tenha conhecimento em técnicas de sensoriamento remoto responsáveis para corrigir diversos erros nas imagens. Para a montagem do nosso banco de dados, utilizamos dados de NDVI prontos, previamente tratados e corrigidos.

Para projetar o NDVI para o futuro, utilizamos imagens históricas de satélite do banco de produtos MODIS na base estadual Brasileira desenvolvido pela equipe da Embrapa Informática Agropecuária. Esse banco de dados teve como principal vantagem a facilidade de acesso aos produtos do sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*), fornecendo produtos em recortes estaduais e prontos para o uso, disponíveis gratuitamente no site <https://www.modis.cnptia.embrapa.br/geonetwork/srv/pt/main.home>.

Essas imagens disponibilizadas pela Embrapa Informática foram pré-processadas pelo LP-DAAC (*Land Processes Distributed Active Center*), que incluem correção radiométrica, geométrica e atmosférica. A partir daí, produtos contendo variáveis sobre o balanço de energia, os ecossistemas e o uso da terra são produzidos, entre eles o NDVI (Esquerdo et al., 2010). Os dados disponíveis pelo banco de produtos MODIS na base estadual brasileira estavam disponíveis a partir de fevereiro de 2000 até o período atual, com períodos de NDVI disponíveis em intervalos de 16 em 16 dias (devido a resolução temporal do sensor MODIS), resolução de 250m, Projeção geográfica *Datum* WGS-84, em formatos GeoTIFF. Os valores dos índices estavam multiplicados por 10.000, por isso os valores de NDVI variavam entre -3000 (falhas e corpos d'água), e os intervalo de valores válidos entre -2000 a 10.000.

Portanto, criamos o nosso banco de dados históricos, baixando imagens com NDVI para os nove estados contidos no semiárido (Alagoas, Bahia, Ceará, Minas Gerais, Paraíba, Pernambuco, Piauí, Rio Grande do Norte e Sergipe), a partir de janeiro de 2001 até dezembro de 2017. Posteriormente, unimos as imagens e recortamos para os limites do semiárido, interpolamos para a

resolução de  $0.16^\circ$ , re-escalamos os valores das células para -1 a 1 e por fim, extraímos esses valores em arquivo de texto para tabular os dados para modelagem de série temporal para o futuro. Entretanto, como os valores tinham intervalo de 16 em 16 dias, calculamos a média mensal do NDVI para cada ano, e, portanto, criamos uma série histórica de 17 anos de NDVI mensal para o semiárido (Figura 2). Em nossos modelos, consideramos valores entre 0 e 0.2 como provável com risco de seca.

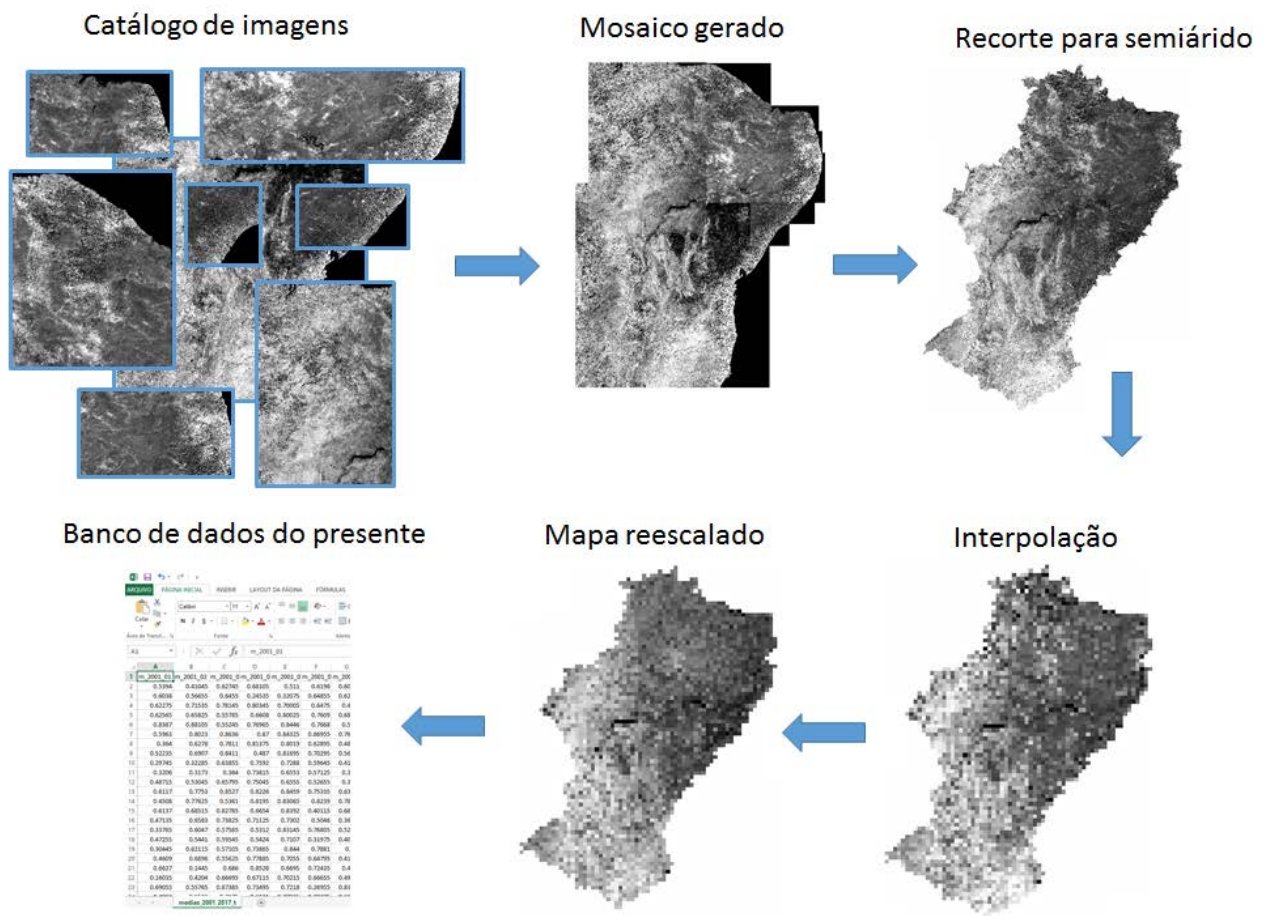


Figura 2 - Obtenção e transformação de dados do NDVI no período de 2001 a 2017.

### 2.3 Criação do modelo auto ARIMA para predição do NDVI futuro

O modelo ARIMA é um modelo misto e iterativo composto pela integração três modelos matemáticos: modelo autoregressivo (AR), modelo de diferenciação (I) e modelo de médias móveis (MA), nos quais são definidos respectivamente pelos parâmetros  $p$ ,  $d$ , e  $q$ , e, portanto, se é construído um modelo ARIMA ( $p, d, q$ ) (Sarpong, 2013; Murat et al., 2018). Um dos pressupostos do modelo ARIMA é a estacionariedade dos dados, ou seja, quando a variável muda aleatoriamente dentro de um tempo, porém sempre ao redor de uma média constante. Porém, nem todos os dados podem estar dispostos nessa condição e então o primeiro passo da construção de um modelo ARIMA é a diferenciação ( $d$ ), na qual é definida pelo número de diferenciações necessárias para se tornar o modelo estacionário. Se  $d=1$ , foi necessário apenas um modelo de diferenciação, ARIMA ( $p, 1, q$ ).

Para determinar o parâmetro  $p$ , são analisadas as dependências dos dados após a transformação dos dados em modelo estacionário, portanto são calculadas as correlações entre os tempos, porém descontando a dependência. A ordem do parâmetro  $p$  é determinado pelo gráfico da função de autocorrelação parcial (PACF, em inglês), que se dá conforme a análise dos picos do gráfico. Por exemplo, se logo depois do tempo 0, as correlações caem, se conta quantos tempos depois as linhas voltam a ficar dentro do intervalo crítico (sombra azul). Nesse caso, no gráfico PACF, após 8 picos os valores voltam a ficar dentro no intervalo crítico (Figura 3A). Ou seja, um modelo ARIMA ( $8,1,q$ )

Em seguida, é calculado o parâmetro  $q$ , onde são definidos os números de erros das previsões anteriores e por meio da função do gráfico de autocorrelação (ACF, em inglês), os valores de  $q$  são determinados. Da mesma forma que o parâmetro anterior, são analisados os picos, porém do gráfico ACF (Figura 3B). Nesse caso, após 5 picos, os valores voltam a ficar dentro do intervalo crítico, ou seja, ARIMA ( $8,1,5$ ).

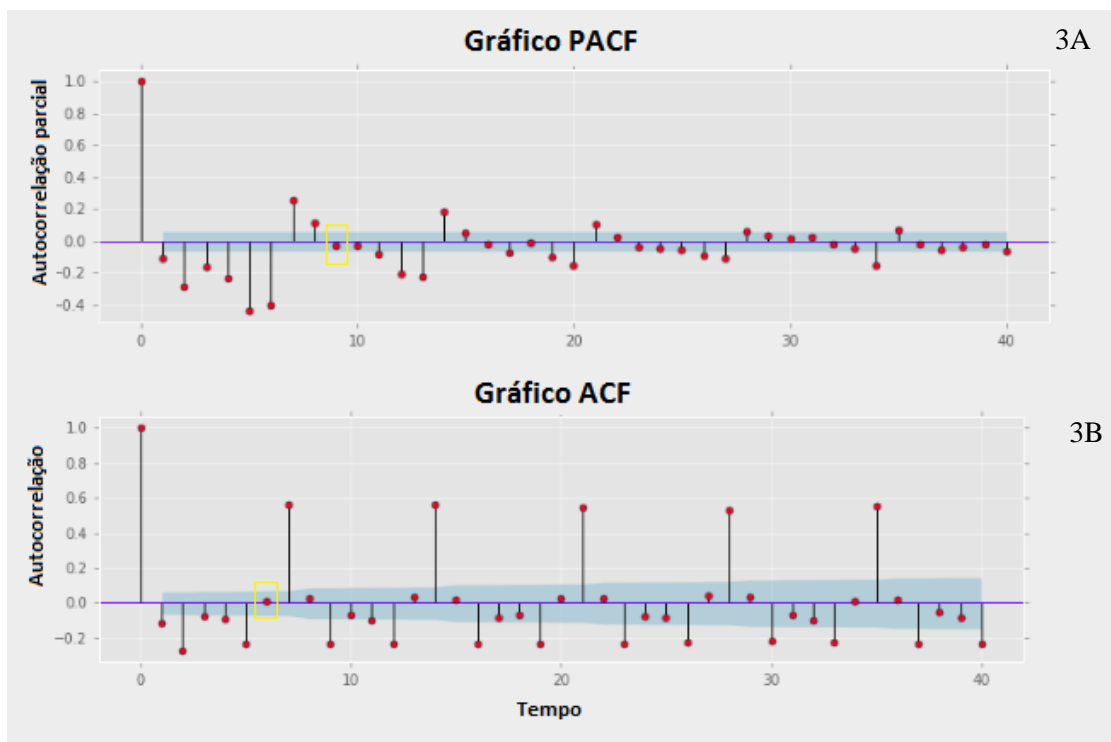


Figura 3. Gráfico de autocorrelação parcial (PACF) e de autocorrelação (ACF).

Até aqui identificamos os parâmetros do ARIMA que precisam então ser ajustados aos modelos, em seguida prevê-los e então os modelos são avaliados. Esse processo é iterativo pois as previsões são avaliadas conforme as várias combinações de parâmetros  $p$ ,  $d$ ,  $q$  e então os melhores modelos são escolhidos conforme os critérios de informação de *Akaike Information Criterion* (AIC) e de *Schwartz Bayesian Criterion* (SBC).

Optamos por utilizar o pacote *forecast* (Hyndman & Khandakar, 2008) na plataforma R para utilizar o modelo ARIMA para prever dados do NDVI futuro. Essa função permite seguir a escolha de dois processos diferentes de chegar aos modelos de previsão. A primeira forma, *arima()*, exige seguir todos os passos anteriores de forma manual, dependendo de conhecimento muito aprofundado da função pelo usuário, mas a principal desvantagem é o gasto de tempo com a parametrização a depender do tamanho do conjunto de dados.

Devido a isso, selecionamos a função *auto.arima* (Figura 4) para automatizar os critérios de seleção de parâmetros e criamos uma outra função iterativa para que o processo fosse repetido para cada célula do semiárido e, portanto, gerando previsões futuras do NDVI para todas as células,

pois tanto a função arima como auto.arima construiriam projeções apenas para uma única célula. Os melhores modelos foram escolhidos pelos critérios de AIC e BIC dentro dos argumentos da própria função. As projeções do NDVI futuro foram feitas para 2030, 2050 e 2070.



Figura 4. Passos do método auto.arima() do pacote “forecast”

#### 2.4 Avaliação do desempenho do NDVI estimado

Para avaliarmos a qualidade dos nossos modelos, usamos o banco de dados do entre 2001 a 2016 para prever o período de 2017, mês a mês. Então usamos duas formas para avaliar o quanto o modelo usado ARIMA usado para prever 2017 pode corroborar com os dados observados de NDVI de 2017: erro médio quadrático (RMSE, em inglês) e correlação de Pearson ( $r^2$ ).

Além disso, calculamos o coeficiente de variação da quantidade de células em intervalos válidos do NDVI (0 a 0.2, 0.2 a 0.4, 0.4 a 0.6, 0.6 a 0.8, 0.8 a 1), ao longo dos períodos de tempo estimado. Utilizamos esse cálculo para avaliar a magnitude de variação dos intervalos de valores de NDVI em relação à média dos dados usando a fórmula:  $Cv = \frac{s}{\bar{X}} \cdot 100$ , onde  $s$  é o desvio padrão e  $\bar{X}$  é a média dos dados.

### 3 – Resultados

De uma forma geral, obtivemos um bom desempenho na estimação do modelo de NDVI para 2017, cuja correlação de Pearson entre o observado e estimado foi de 0.7552 ( $t = 888.65$ ,  $gl = 594660$ ,  $p$ -valor  $< 0.05$ ). O maior valor de correlação foi obtido no mês de janeiro (0.8887) e o menor valor em fevereiro (-0.7668) (Figura 5). Os valores da raiz quadrada do erro médio (RMSE) também indicam bom desempenho do modelo (Figura 6), com menores valores de erro em novembro (0.0602) e os maiores em fevereiro (0.1055). Os valores de NDVI ao longo do ano de 2017, entre os dados observados e estimados, seguem os mesmos padrões, com valores entre 0.2 e 0.4 reduzindo à partir de fevereiro e voltando a aumentar em maio.

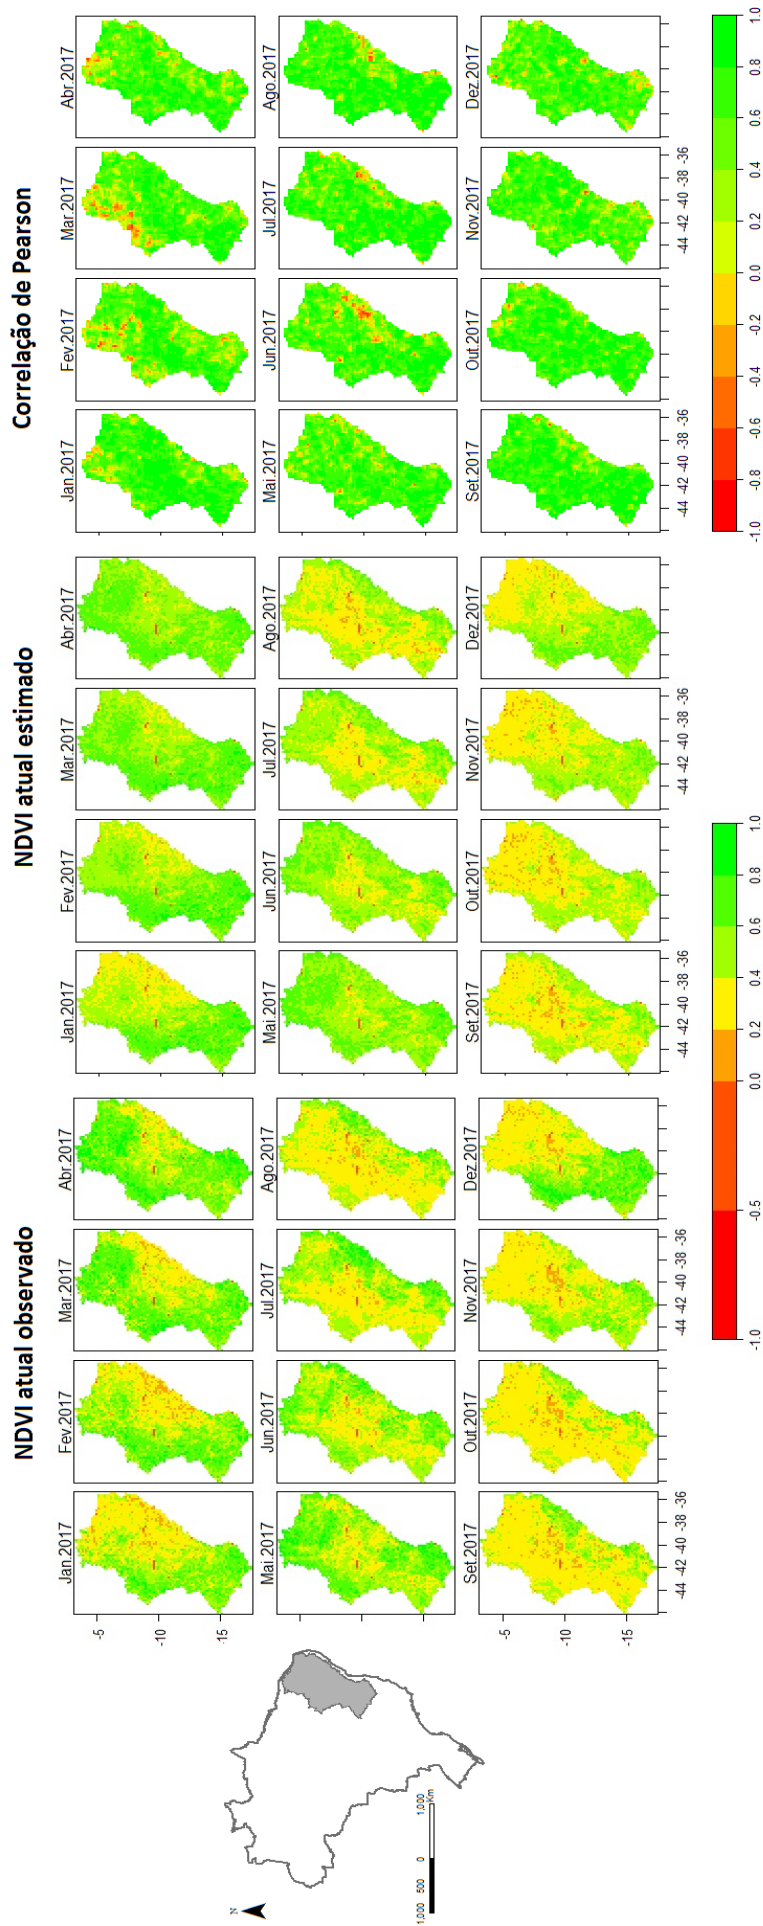


Figura 5. Valores de NDVI atuais observados, atuais estimados e correlação de Pearson por pixel entre observado e estimado.

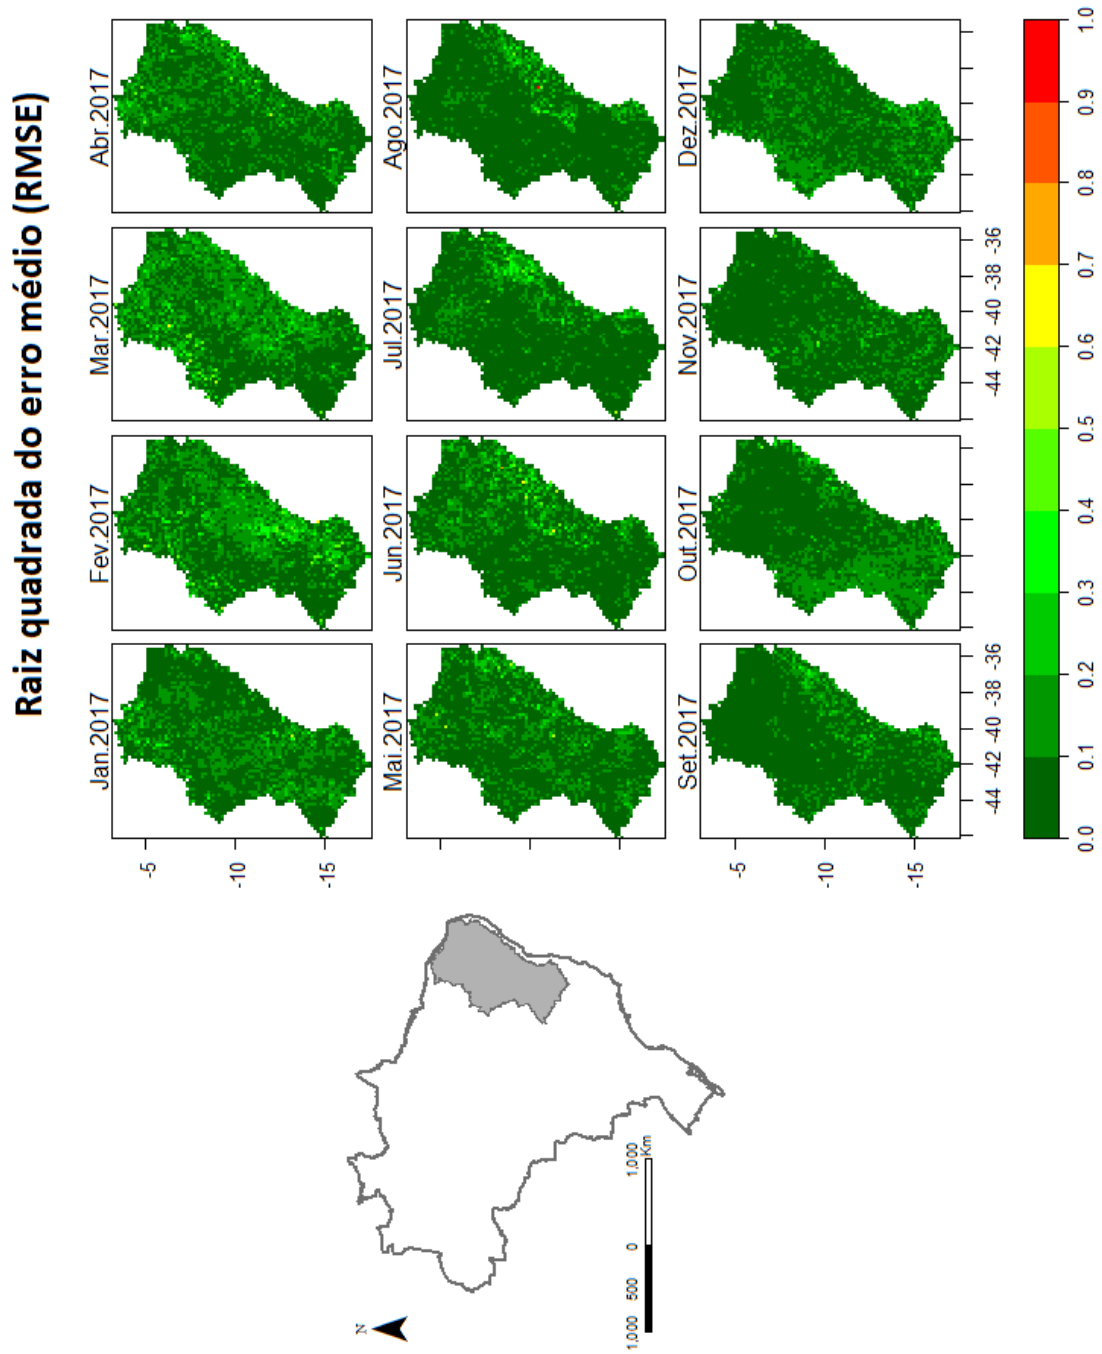


Figura 6. Valores da raiz quadrada do erro médio (RMSE) entre os valores observados de 2017 e os valores estimados do mesmo período;

Os valores considerados como secos, compreendidos entre 0 e 0.2, se tornam mais parecidos à partir do mês de agosto, com frequência máxima de seca até outubro de 2017 (Figura 7). Em relação às projeções futuras (2030, 2050 e 2070), foram observados padrões parecidos entre os meses nas três janelas de tempo (Figura 7). Porém, nos três períodos do futuro houve aumento áreas secas (valores de NDVI entre 0 e 0.2), sendo, um aumento de 48.05% para 2030, 48.44% para 2050 e 46.49% em relação ao período atual de 2017 (Tabela 1). Entretanto, entre os três períodos futuros houve pouca diferença.

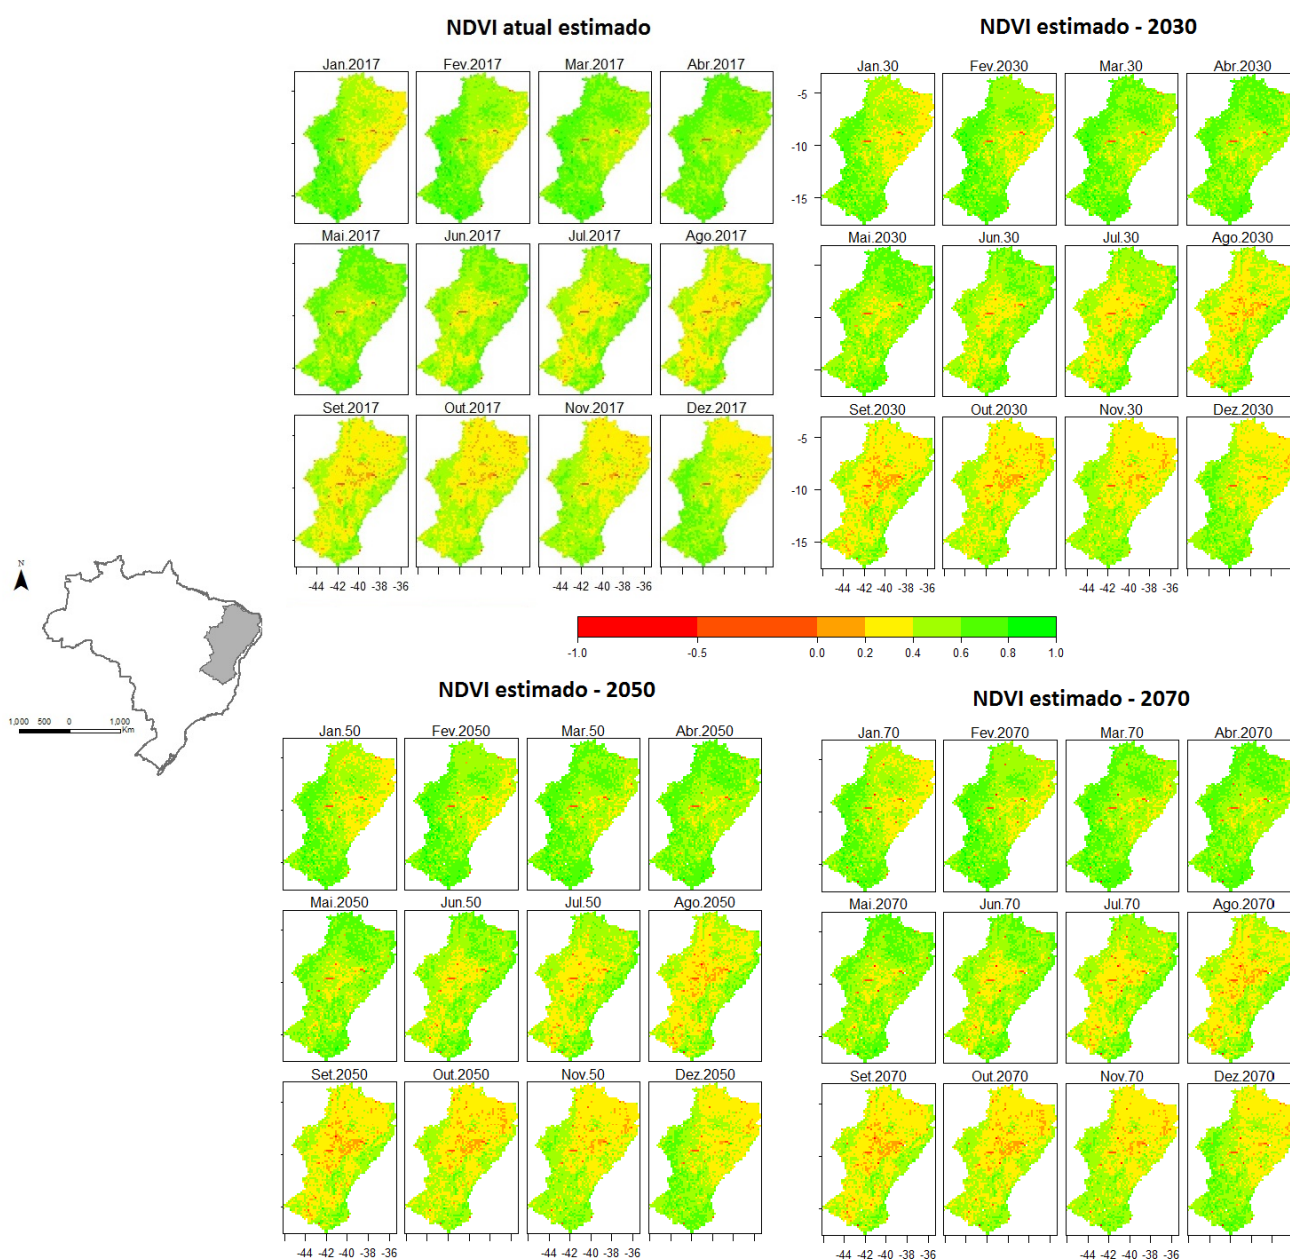


Figura 7. Mapas mensais do NDVI estimado atual (2017) e estimados para o futuro (2030, 2050 e 2070).

Tabela 1. Número total de células por ano estimado (atual e futuros) para intervalos válidos de NDVI. O total de células no semiárido durante um ano é de 34.980.

Ano	Número de células				
	NDVI (0 - 0.2)	NDVI (0.2 - 0.4)	NDVI (0.4 - 0.6)	NDVI (0.6 - 0.8)	NDVI (0.8 - 1.0)
<b>2017</b>	514	10.390	15.619	8.003	327
<b>2030</b>	761	10.844	15.376	7.649	230
<b>2050</b>	763	10.846	15.306	7.630	251
<b>2070</b>	753	10.823	15.277	7.622	242

Esse padrão também foi encontrado ao analisar o coeficiente de variação entre vários períodos (Tabela 2). O maior coeficiente de variação (89.10%) foi observado entre o período de 2001 e 2017) e à medida que o tempo de previsão aumenta, o coeficiente de variação diminuiu entre os futuros estimados.

Tabela 2. Coeficiente de variação (%) entre os períodos estimados atual (2017) e futuros (2030, 2050, 2070)

Período	Coeficiente de variação (%)				
	NDVI (0 - 0.2)	NDVI (0.2 - 0.4)	NDVI (0.4 - 0.6)	NDVI (0.6 - 0.8)	NDVI (0.8 - 1.0)
<b>2001-2017</b>	89.10960658	22.0265447	7.925407403	1.307433916	0.445663622
<b>2001-2030</b>	58.91883724	19.88858838	7.941787672	1.370519233	0.35990537
<b>2001-2050</b>	42.92155824	16.15571888	6.699206323	1.158309234	0.281432799
<b>2001-2070</b>	35.40627705	13.85666652	5.811978425	0.992146263	0.254464767
<b>2017-2030</b>	1.841472497	0.255899668	0.122086547	0.105579957	0.012107626
<b>2017-2050</b>	1.751096124	0.175485896	0.119787461	0.113000391	0.075879415
<b>2017-2070</b>	1.511265276	0.163555371	0.16568952	0.160687827	0.140047525
<b>2030-2050</b>	0.305466934	0.113429686	0.139469428	0.132267371	0.120316938
<b>2030-2070</b>	0.475513632	0.087933252	0.092516639	0.085178589	0.060499624
<b>2050-2070</b>	0.595686472	0.122166903	0.073568088	0.065263958	0.074424273

#### 4 – Discussão

Nosso estudo mostra a abordagem promissora do modelo ARIMA em estimar o NDVI futuro para contribuição em estudos que indiquem áreas com maiores frequências de seca e que podem estar mais vulneráveis à processos de desertificação. A disponibilidade de dados globais recentes e históricos, a boa associação com a dinâmica da vegetação e a fácil interpretação desse índice (Kogan, 1990, 2019), tornam o NDVI uma ferramenta viável para representar condições futuras. Deste modo, estudos futuros com esta ferramenta serão de grande utilidade em políticas nacionais e internacionais que visam a mitigação e adaptação de ambientes áridos e semiáridos com as mudanças climáticas, favorecendo não só a conservação da biodiversidade como a proteção de recursos naturais de uso da população.

No semiárido brasileiro já foi observada uma boa relação entre os padrões de precipitação com os valores de NDVI, principalmente em períodos de seca (Santos & Negri, 1997; Barbosa et al., 2006). Ao integrar NDVI com o modelo de série temporal ARIMA, estudos também indicaram boa acurácia para o período atual (Ceroni et al., 2015; Bayr et al., 2016; Mwanga et al., 2017), sendo considerados promissores para diversas áreas (Mwanga et al., 2017). O NDVI tem sido capaz de ter uma boa captura da dinâmica da vegetação, principalmente em áreas áridas e semiáridas (Bayarjargal et al., 2006; Bao et al., 2014) e podem ser úteis para prever períodos de seca (Sruthi & Aslam, 2015). Essa vantagem ocorre porque o NDVI é mais sensível em regiões com predomínio de vegetação herbácea e o crescimento da vegetação é rapidamente detectado após a estação de chuva nessas áreas (Archibald & Scholes, 2007; Andela et al., 2013).

O padrão de cobertura vegetal segundo o NDVI estimado é bem variado entre os meses de 2017. O período de chuvas geralmente ocorre entre janeiro a maio, com picos precipitação mais altas em março e abril (Marengo et al., 2011; Salgado et al., 2015) e os meses últimos seis meses sendo os mais secos (Alves et al., 2017), o que pode justificar o aumento de cobertura vegetal (valores maiores de NDVI) a partir fevereiro e diminuição da cobertura vegetal a partir de julho.

Segundo Marengo e colaboradores (2011), na maior parte do semiárido a estação seca é mais intensa entre os meses de agosto e outubro, o que também foi observado nos padrões que obtivemos em nosso modelo de 2017.

Entretanto, foram observadas baixas correlações, bem como maior erro (RMSE) em algumas porções do semiárido, bem como mais frequentes em fevereiro, março e junho. Vários fatores podem estar associados nesse resultado, um deles pode ser a ausência de inclusão de anomalias no modelo ARIMA. As anomalias climáticas são flutuações diferentes ou extremas em relação à variabilidade esperada, sendo as mais conhecidas associadas ao regime de chuva (Amado et al., 2002). Essas anomalias no semiárido podem estar relacionadas tanto com as inversão de pressão do mar no Pacífico tropical leste e no Atlântico tropical, como também à eventos como de *El Niño* ou *La Niña* (Saravanan & Chang, 2000; Kayano & Andreoli, 2007; Marengo et al., 2011; Kayano et al., 2013).

Para Marengo e colabores (2016), a variabilidade climática observada no semiárido brasileiro é uma condição que já ocorreu no passado, vem ocorrendo atualmente e possível de se intensificar no futuro. Nossos modelos predisseram variação maior a partir de 2030 e nos 20 anos seguintes não ocorreram mudanças mais drásticas. Esses resultados podem ter ocorrido não só pela ausência de anomalias no modelo ARIMA, como dito anteriormente, como também com a perda da capacidade de com o aumento do tempo de previsão (Nassur et al., 2015b).

Os padrões de variação menores nos valores de NDVI do futuro também podem estar relacionados com a ausência de variáveis de exploração e uso do solo nesse período, enquanto que no período compreendido entre 2001 a 2017 ocorre a influência de desmatamento na captura de dados de vegetação. Esse fato também é relatado por outros trabalhos, cuja a captura de atividades antropogênicas tem sido um dos principais desafios para predição da vegetação futura (Hutchinson et al., 2000; Thonicke et al., 2007; Wang et al., 2014). Os dados de cobertura vegetal indicam que entre o período de 2002 e 2011 no bioma Caatinga, houve uma taxa média de desmatamento entre 2002 e 2011 foi de 2.235,4 km<sup>2</sup> /ano (Ganem, 2017; Ministério do Meio Ambiente, 2017). Essas modificações antrópicas na cobertura vegetal atuam não só sobre os fatores climáticos, como

mudanças da intensidade e frequência de chuvas, mas também em taxas de erosão, cujos ambientes semiáridos e áridos estão mais susceptíveis que outros (Cantón et al., 2001; Rodríguez-Caballero et al., 2018).

Apesar disso, nosso estudo demonstra o uso promissor do modelo ARIMA como predição no NDVI para o futuro e, portanto, indicador de secas nessa região. O ARIMA também tem sido usado em áreas áridas semiáridas para prever, no entanto com outras variáveis como a precipitação e temperatura (Ali Hasaniha & Meghdadi, 2010; Babazadeh & Shamsnia, 2014; Saada, 2014). Porém, devido à falta de precisão modelos climáticos globais, denominados AOGCMs (Atmosphere-Ocean General Circulation Models), segundo Du Pisani e colaboradores (1998), ao estudar períodos de seca em locais semiáridos e áridos da África, concluiu que índices de secas poderão ser mais realísticos para esses ambientes.

Portanto, nossos resultados demonstram que o NDVI pode ser utilizado como *proxy* de cobertura vegetal no semiárido e indicar áreas que estarão mais susceptíveis às mudanças climáticas. Embora não haja consenso entre modelos climáticos para a Caatinga, há possibilidade do aumento de áreas áridas dentro desse bioma com as mudanças climáticas (Salazar et al., 2007). Assim, é preciso investir mais esforços no semiárido, principalmente por ser uma região cujos recursos naturais são base para a economia regional e dependem significativamente da cobertura vegetal, disponibilidade de água e qualidade do solo.

## Referências

Adeel Z., Safriel U., Niemeijer D., R W., G de K., Glantz M., Salem B., Scholes B., Niamir-Fuller M., Ehui S., & Yapi-Gnaore (2005) *Ecosystems and Human Well-Being: desertification synthesis*. World Resources Institute, Washington,

Adhikari R. & Agrawal R.K. (2013) *An Introductory Study on Time Series Modeling and Forecasting*. .

Ali Hasaniha H. & Meghdadi M. (2010) The Analysis of Spring Precipitation in Semi-Arid Regions: Case Study in Iran. *Journal of Water Resource and Protection*, **02**, 69–76.

Allen-Diaz B., Chapin F.S., Diaz S., Howden M., Puigdefabregas, J., Stafford Smith M., Benning T., Bryant F., Campbell B., DuToit J., Galvin K., Holland E., Joyce L., Knapp A.K., Matson P., Miller R., Ojima D., Polley W., Seastedt T., Suarez A., Svejcar T., & Wessman C. (1996) Rangelands in a changing climate: Impacts, adaptations and mitigation. *Climate Change 1995 Impacts, Adaptation and Mitigation, Contribution of Working Group II to the Second Assessment Report of the Intergovernmental Panel on Climate Change* (ed. by R.T. Watson, M.C. Zinyowera, M.R. H., and D.J. Dokken), pp. 131–158. University Press, Cambridge, Cambridge.

Alves J.M.B., Silva E.M. da, Sombra S.S., Barbosa A.C.B., Santos A.C.S. dos, & Lira M.A.T. (2017) Eventos Extremos Diários de Chuva no Nordeste do Brasil e Características Atmosféricas. *Revista Brasileira de Meteorologia*, **32**, 227–233.

Amado T.J.C., Prochnow D., & Eltz F.L.F. (2002) Perdas de solo e água em períodos de anomalias climáticas: “El Niño” e “La Niña” no sul do Brasil. *Revista Brasileira de Ciência do Solo*, **26**, 819–827.

Andela N., Liu Y.Y., M. Van Dijk A.I.J., De Jeu R.A.M., & McVicar T.R. (2013) Global changes in dryland vegetation dynamics (1988-2008) assessed by satellite remote sensing: Comparing a new passive microwave vegetation density record with reflective greenness data. *Biogeosciences*, **10**, 6657–6676.

Angelotti F., Sá I.B., & Melo R.F. de (2009) Mudanças climáticas e desertificação no Semi-Árido brasileiro. *Mudanças climáticas e desertificação no Semi-Árido brasileiro*. (ed. by F. ANGELOTTI, I.B. SÁ, E.A. MENEZES, and G.. PELLEGRINO), pp. 41–49. Embrapa Informática Agropecuária, Petrolina, PE: Embrapa Semiárido; Campinas, SP:

Anwar M.Y., Lewnard J.A., Parikh S., & Pitzer V.E. (2016) Time series analysis of malaria in Afghanistan: using ARIMA models to predict future trends in incidence. *Malaria Journal*, **15**, 566.

Araújo F.S., Rodal M.J.N., Barbosa M.R.V., & Martins F.R. (2005) Repartição da flora lenhosa no domínio da Caatinga. *Análise das variações da biodiversidade do bioma Caatinga: suporte a estratégias regionais de conservação* (ed. by F.S. Araújo, M.J.N. Rodal, and O. Barbosa,

M. R. V.), pp. 15–34. Ministério do Meio Ambiente, Brasília.

Archibald S. & Scholes R.J. (2007) Leaf green-up in a semi-arid African savanna - separating tree and grass responses to environmental cues. *Journal of Vegetation Science*, **18**, 583–594.

Babazadeh H. & Shamsnia S.A. (2014) Modeling climate variables using time series analysis in arid and semi arid regions. *African Journal of Agricultural Research*, **9**, 2018–2027.

Bao G., Qin Z., Bao Y., Zhou Y., Li W., & Sanjjav A. (2014) NDVI-based long-term vegetation dynamics and its response to climatic change in the Mongolian plateau. *Remote Sensing*, **6**, 8337–8358.

Barbosa H.A., Huete A.R., & Baethgen W.E. (2006) A 20-year study of NDVI variability over the Northeast Region of Brazil. *Journal of Arid Environments*, **67**, 288–307.

Bayarjargal Y., Karnieli A., Bayasgalan M., Khudulmur S., Gandush C., & Tucker C.J. (2006) A comparative study of NOAA-AVHRR derived drought indices using change vector analysis. *Remote Sensing of Environment*, **105**, 9–22.

Bayr C., Gallaun H., Kleb U., Kornberger B., Steinegger M., & Winter M. (2016) Satellite-based forest monitoring: spatial and temporal forecast of growing index and short-wave infrared band. *Geospatial Health*, **11**, 31–42.

Bowker M.A., Belnap J., Bala Chaudhary V., & Johnson N.C. (2008) Revisiting classic water erosion models in drylands: The strong impact of biological soil crusts. *Soil Biology and Biochemistry*, **40**, 2309–2316.

Box G.E.P. & Jenkins G.M. (1970) *Time series analysis: forecasting and control*. Holden-Day,

Burney J., Cesano D., Russell J., La Rovere E.L., Corral T., Coelho N.S., & Santos L. (2014) Climate change adaptation strategies for smallholder farmers in the Brazilian Sertão. *Climatic Change*, **126**, 45–59.

Cantón Y., Domingo F., Solé-Benet A., & Puigdefábregas J. (2001) Hydrological and erosion response of a badlands system in semiarid SE Spain. *Journal of Hydrology*, **252**, 65–84.

Ceroni M., Achkar M., Gazzano I., & Burgeño J. (2015) Estudio del NDVI mediante análisis multiescalar y series temporales utilizando imágenes SPOT, durante el período 1998-2012 en el Uruguay. *Revista de Teledeteccion*, **2015**, 31–42.

Christodoulos C., Michalakelis C., & Varoutas D. (2010) Forecasting with limited data: Combining ARIMA and diffusion models. *Technological Forecasting and Social Change*, **77**, 558–565.

Cui G., Lee W.-K., Kwak D.-A., Choi S., Park T., & Lee J. (2011) Desertification monitoring by LANDSAT TM satellite imagery. *Forest Science and Technology*, **7**, 110–116.

Cunha A.P.M., Alvalá R.C., Nobre C.A., & Carvalho M.A. (2015) Monitoring vegetative drought dynamics in the Brazilian semiarid region. *Agricultural and Forest Meteorology*, **214–215**, 494–505.

Dakos V., Carpenter S.R., Brock W.A., Ellison A.M., Guttal V., Ives A.R., Kéfi S., Livina V., Seekell D.A., van Nes E.H., & Scheffer M. (2012) Methods for detecting early warnings of critical transitions in time series illustrated using simulated ecological data. *PLoS ONE*, **7**, .

Debray V., Wezel A., Lambert-Derkimba A., Roesch K., Lieblein G., & Francis C.A. (2018) Agroecological practices for climate change adaptation in semiarid and subhumid Africa. *Agroecology and Sustainable Food Systems*, **00**, 1–28.

Esquerdo J.C.D.M., Antunes J.F.G., & Andrade J.C. (2010) *Desenvolvimento do Banco de Produtos MODIS na Base Estadual Brasileira*. Campinas: Embrapa Informática Agropecuária (Embrapa Informática Agropecuária. Comunicado técnico, 100),

Fernández-Manso A., Quintano C., & Fernández-Manso O. (2011) Forecast of NDVI in coniferous areas using temporal ARIMA analysis and climatic data at a regional scale. *International Journal of Remote Sensing*, **32**, 1595–1617.

Ganem R.S. (2017) *Caatinga: estratégias de conservação*. Consultora Legislativa da Área XI Meio Ambiente e Direito Ambiental, Organização Territorial, Desenvolvimento Urbano e Regional.,

Gonçalves R.R. V., Zullo J., Romani L.A.S., Nascimento C.R., & Traina A.J.M. (2012)

Analysis of NDVI time series using cross-correlation and forecasting methods for monitoring sugarcane fields in Brazil. *International Journal of Remote Sensing*, **33**, 4653–4672.

Higginbottom T.P. & Symeonakis E. (2014) Assessing Land Degradation and Desertification Using Vegetation Index Data: Current Frameworks and Future Directions. *Remote Sensing*, **6**, 9552–9575.

Houghton J.T., Ding Y., Griggs D.J., Nogueir M., van der Linden P.J., Dai X., Maskell K., & Johnson C.A. (2001) *Climate Change 2001: The Scientific Basis*. Cambridge University Press, Cambridge,

Hutchinson C.F., Unruh J.D., & Bahre C.J. (2000) Land use vs. climate as causes of vegetation change: A study in SE Arizona. *Global Environmental Change*, **10**, 47–55.

Hyndman R.J. & Khandakar Y. (2008) Automatic Time Series Forecasting: The forecast Package for R. *Journal of Statistical Software*, **27**, .

Ibáñez J., Valderrama J.M., & Puigdefábregas J. (2008) Assessing desertification risk using system stability condition analysis. *Ecological Modelling*, **213**, 180–190.

IPCC (2014) Climate Change 2014: Synthesis Report. *Contribution of Working Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*, .

IPCC, Metz B., Davidson O., Barker T., Bashmakov I., Bernstein L., Bogner J., Bosch P., Dave R., Fisher B., Grubb M., Gupta S., Halsnaes K., Heij B.J., Ribeiro S.K., Kobayashi S., Levine M., Martino D., Cerutti O.M., Meyer L., Nabuurs G.-J., Najam A., Nakicenovic N., Rogner H.H., Roy J., Sathaye J., Schock R., Shukla P., Sims R., Smith P., Swart R., Tirpak D., Ürge-Vorsatz D., & Dadi Z. (2007) Summary for Policymakers. *Climate Change 2007: Mitigation. Contribution of Working Group III to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge University Press, Cambridge.

Kayano M.T. & Andreoli R. V. (2007) Relations of South American summer rainfall interannual variations with the Pacific Decadal Oscillation. *International Journal of Climatology*, **27**, 531–540.

Kayano M.T., Andreoli R. V., & Ferreira de Souza R.A. (2013) Relations between ENSO

and the South Atlantic SST modes and their effects on the South American rainfall. *International Journal of Climatology*, **33**, 2008–2023.

Kogan F. (2019) Monitoring Drought from Space and Food Security. pp. 75–113. Springer International Publishing, Cham.

Kogan F.N. (1990) Remote sensing of weather impacts on vegetation in non-homogeneous areas. *International Journal of Remote Sensing*, **11**, 1405–1419.

Leal I., Silva J. DA, Tabarelli M., & Lacher T.E. (2005a) Changing the course of biodiversity conservation in the Caatinga of northeastern Brazil. *Conservation biology*, **19**, 701–706.

Leal I.R., Da Silva J.M.C., Tabarelli M., & Lacher T. (2005b) Mudando o curso da conservação da biodiversidade na Caatinga do Nordeste do Brasil. *Megadiversidade*, **1**, 7.

Lillesand T.M., Kiefer R.W., & Chipman J.W. (2004) *Remote sensing and image interpretation*. Wiley,

Lu L., Ren Z., Yue Y., Yu X., Lu S., Li G., Li H., Wei J., Liu J., Mu Y., Hai R., Yang Y., Wei R., Kan B., Wang H., Wang J., Wang Z., Liu Q., & Xu J. (2016) Niche modeling predictions of the potential distribution of *Marmota himalayana*, the host animal of plague in Yushu County of Qinghai. *BMC Public Health*, **16**, 183.

Manhães A.P., Loyola R., Mazzochini G.G., Ganade G., Oliveira-Filho A.T., & Carvalho A.R. (2018) Low-cost strategies for protecting ecosystem services and biodiversity. *Biological Conservation*, **217**, 187–194.

Manhães A.P., Mazzochini G.G., Oliveira-Filho A.T., Ganade G., & Carvalho A.R. (2016) Spatial associations of ecosystem services and biodiversity as a baseline for systematic conservation planning. *Diversity and Distributions*, **22**, 932–943.

Marengo J.A., Alves L.M., Beserra E. a, & Lacerda F.F. (2011) Variabilidade e mudanças climáticas no semiárido brasileiro. *Recursos hídricos em regiões áridas e semiáridas* pp. 383–422.

Marengo J.A., Cunha A.P., & Alves L.M. (2016) A seca de 2012-2015 no semiárido do Nordeste do Brasil. *Revista Climanálise*, 1–5.

Miao L., Ye P., He B., Chen L., & Cui X. (2015) Future Climate Impact on the Desertification in the Dry Land Asia Using AVHRR GIMMS NDVI3g Data. *Remote Sensing*, **7**, 3863–3877.

Ministério do Meio Ambiente (2017) *Caatinga – monitoramento do desmatamento dos biomas brasileiros por satélite. Relatório Técnico 2010-2011.*

MMA/SRH M. do M.A.S. de R.H. (2004) *Programa de ação nacional de combate à desertificação e mitigação dos efeitos da seca.* Brasília.

Mortimore M. (2009) *Dryland opportunities.* IUCN, Gland, Switzerland, HED, London, UK and UNDP, New York, USA.,

Murat M., Malinowska I., Gos M., & Krzyszczak J. (2018) Forecasting daily meteorological time series using ARIMA and regression models. *International Agrophysics*, **32**, 253–264.

Mwanga D., Ong 'ala J., & Orwa G (2017) Modeling Sugarcane Yields in the Kenya Sugar Industry: A SARIMA Model Forecasting Approach. *International Journal of Statistics and Applications*, **7**, 280–288.

Nassur O.A.C., Ferreira E., Sáfyadi T., & Dantas A.A.A. (2015a) Monitoramento e projeção futura do Parque Nacional do Itatiaia através do sensoriamento remoto. *CERNE*, **21**, 511–517.

Nassur O.A.C., Ferreira E., Sáfyadi T., & Dantas A.A.A. (2015b) Monitoramento e projeção futura da vegetação no parque nacional do Itatiaia através de sensoriamento remoto. *Cerne*, **21**, 511–517.

Oyama M.D. & Nobre C.A. (2004) Climatic consequences of a large-scale desertification in northeast Brazil: A GCM simulation study. *Journal of Climate*, **17**, 3203–3213.

Piao S. (2005) NDVI-indicated decline in desertification in China in the past two decades. *Geophysical Research Letters*, **32**, L06402.

Du Pisani L.G., Fouché H.J., & Venter J.C. (1998) Assessing rangeland drought in South Africa. *Agricultural Systems*, **57**, 367–380.

Raicharoen T., Lursinsap C., & Sanguanbhokai P. (2003) Application of critical support vector machine to time series prediction. *5*, V-741-V-744.

Reed M.S. & Stringer L.C. (2016) *Land Degradation, Desertification and Climate Change: Anticipating, Assessing and Adapting to Future Change*. Routledge, New York.

Rocha W.F. (2009) Situação da cobertura vegetal do bioma Caatinga. *Mudanças climáticas e desertificação no Semiárido brasileiro* (ed. by F. Angelotti, I.B. Sá, E.A. Menezes, and G.Q. Pellegrino), pp. 77–94. Petrolina: Embrapa Semiárido; Campinas: Embrapa Informática Agropecuária,

Rodríguez-Caballero E., Lázaro R., Cantón Y., Puigdefabregas J., & Solé-Benet A. (2018) Long-term hydrological monitoring in arid-semiarid Almería, SE Spain. What have we learned? *Cuadernos de Investigación Geográfica*, **44**, 581.

Rouse J.W., Hass R.H., Schell J.A., & Deering D.W. (1972) Monitoring Vegetation Systems in the Great Plains with ERTS. *Third Earth Resources Technology Satellite-1 Symposium*.

Saada N. (2014) Time series modeling of monthly rainfall in arid areas: Case study for Saudi Arabia. *American Journal of Environmental Sciences*, **10**, 277–282.

Salazar L.F., Nobre C. a., & Oyama M.D. (2007) Climate change consequences on the biome distribution in tropical South America. *Geophysical Research Letters*, **34**, .

Salgado E.V., Andrade E.M. de, Hevia J.N., Nunes E.P., & Rodrigues M.M. de A. (2015) Rainfall patterns and the contribution of litter in the caatinga dry tropical forest. *REVISTA CIÊNCIA AGRONÔMICA*, **46**, 299–309.

Santos P. & Negri A.J. (1997) A Comparison of the Normalized Difference Vegetation Index and Rainfall for the Amazon and Northeastern Brazil. *Journal of Applied Meteorology*, **36**, 958–965.

Saravanan R. & Chang P. (2000) Interaction between Tropical Atlantic Variability and El Niño–Southern Oscillation. *Journal of Climate*, **13**, 2177–2194.

Sarpong S.A. (2013) Modeling and Forecasting Maternal Mortality; an Application of ARIMA Models. *International Journal of Applied Science and Technology*, **3**, 19–28.

Scarano F.R., Santos A.S., Kahnn S., Nobre C.A., Marengo J.A., Ommeto J.P., Ceotto P., Loyola R., Pires A.P.F., Ribeiro J.B., & Carneiro B.L.R. (2018) *Potência Ambiental da*

*Biodiversidade : um caminho inovador para o Brasil. Relatório Especial do Painel Brasileiro de Mudanças Climáticas e da Plataforma Brasileira de Biodiversidade e Serviços Ecossistêmicos. Sumário para Tomadores de Decisão.* PBMC, COPPE – UFRJ, Rio de Janeiro, Brasil.

Seekell D.A. & Dakos V. (2015) Heteroskedasticity as a leading indicator of desertification in spatially explicit data. *Ecology and Evolution*, **5**, 2185–2192.

Shao Y.E. & Dai J.-T. (2018) Integrated Feature Selection of ARIMA with Computational Intelligence Approaches for Food Crop Price Prediction. *Complexity*, **2018**, 1–17.

Shumway R.H. & Stoffer D.S. (2010) *Time Series Analysis and Its Applications: With R Examples*. Springer New York, New York, NY.

Silva P.C.G. da, Moura M.S.B. de, Kiill L.H.P., Brito L.T. de L., Pereira L.A., Sá I.B., Correia R.C., Teixeira A.H. de C., Cunha T.J.F., & Guimarães-Filho C.G. (2010) Caracterização do Semiárido brasileiro: fatores naturais e humanos. *Semiárido brasileiro: pesquisa, desenvolvimento e inovação. Petrolina: Embrapa Semiárido, 2010.* pp. 18–48.

Sruthi S. & Aslam M.A.M. (2015) Agricultural Drought Analysis Using the NDVI and Land Surface Temperature Data; a Case Study of Raichur District. *Aquatic Procedia*, **4**, 1258–1264.

Stevenson S. (2007) A comparison of the forecasting ability of ARIMA models. *Journal of Property Investment & Finance*, **25**, 223–240.

Thomas R.J. (2008) Opportunities to reduce the vulnerability of dryland farmers in Central and West Asia and North Africa to climate change. *Agriculture, Ecosystems and Environment*, **126**, 36–45.

Thonicke K., Venevsky S., Sitch S., Cramer W., Ecology G., Terrestrial E., & Modelling E. (2007) The Role of Fire Disturbance for Global Vegetation Dynamics : Coupling Fire into a Dynamic Global Vegetation Model The role of fire disturbance for global vegetation dynamics : coupling fire into a Dynamic Global Vegetation Model. **10**, 661–677.

Tian M., Wang P., & Khan J. (2016) Drought Forecasting with Vegetation Temperature Condition Index Using ARIMA Models in the Guanzhong Plain. *Remote Sensing*, **8**, 690.

Tucker C.J., Pinzon J.E., Brown M.E., Slayback D.A., Pak E.W., Mahoney R., Vermote E.F., & Saleous N. El (2005) An extended AVHRR 8-km NDVI dataset compatible with MODIS and SPOT vegetation NDVI data. *International Journal of Remote Sensing*, **26**, 4485–4498.

Usman U., Yelwa S.A., Gulumbe S.U., Danbaba A., & Nir R. (2013) Modelling Relationship between NDVI and Climatic Variables Using Geographically Weighted Regression. **1**, 24–28.

Vieira R.M. da S.P., Cunha A.P.M. do A., Alvalá R.C. dos S., Carvalho V.C., Ferraz Neto S., & Sestini M.F. (2013) Land use and land cover map of a semiarid region of Brazil for meteorological and climatic models. *Revista Brasileira de Meteorologia*, **28**, 129–138.

Wang Y., Roderick M.L., Shen Y., & Sun F. (2014) Attribution of satellite-observed vegetation trends in a hyper-arid region of the Heihe River basin, Western China. *Hydrology and Earth System Sciences*, **18**, 3499–3509.

Weishou S., Di J., Hui Z., Shouguang Y., Haidong L., & Naifeng L. (2011) The Response Relation between Climate Change and NDVI over the Qinghai-Tibet plateau. *World Academy of Science, Engineering and Technology*, **59**, 2216–2222.

# Capítulo III

**Uso de índice de vegetação em modelos de nicho ecológico para  
distribuição futura de espécies endêmicas do semiárido brasileiro**

# **Uso de índice de vegetação em modelos de nicho ecológico para distribuição futura de espécies endêmicas do semiárido brasileiro**

Daiany Caroline Joner<sup>1,2\*</sup>

Rafael Loyola<sup>1,2,3</sup>

## **Authors' affiliation:**

<sup>1</sup>Laboratório de Biogeografia da Conservação, Departamento de Ecologia, Universidade Federal de Goiás, Goiânia, Goiás, Brazil.

<sup>2</sup>Programa de Pós-Graduação em Ecologia e Evolução, Universidade Federal de Goiás, Goiânia, Goiás, Brasil.

<sup>3</sup>Fundação Brasileira para o Desenvolvimento Sustentável, Rio de Janeiro, Brasil

## **\* Corresponding author's address:**

Daiany Caroline Joner  
Goiânia | Goiás. Email: [dadaiany@gmail.com](mailto:dadaiany@gmail.com)

## Resumo

As mudanças climáticas indicam impactos negativos em diversos segmentos da sociedade. Ambientes áridos e semiáridos tendem a ser os mais afetados. A cobertura vegetal em ambientes áridos e semiáridos tem papel fundamental na proteção dos recursos naturais e conservação da biodiversidade. Diversos estudos têm utilizado a modelagem de nicho ecológico como ferramenta para estimar o quanto a distribuição das espécies pode ser afetada pelas mudanças climáticas. Entretanto, a maioria dos estudos tem incluído apenas variáveis climáticas para estimar a potencial distribuição no futuro. Alguns índices foliares têm sido utilizados como equivalente de cobertura vegetal no presente para aumentar a eficiência em estudos sobre a distribuição das espécies. O NDVI (Índice de Vegetação da Diferença Normalizada) é um desses índices. Nosso estudo teve como objetivo gerar variáveis do presente e do futuro que sejam equivalentes à cobertura vegetal do semiárido brasileiro, a partir de um banco de dados modelados de NDVI, e a partir da modelagem de nicho, estimar a potencial distribuição de espécies endêmicas dessa região. Geramos 11 variáveis de banco de dados de 2050 e para reduzir a colinearidade utilizamos a técnica PCA e reduzimos para três variáveis. Utilizamos também cinco variáveis climáticas das 19 disponíveis pelo banco de dados do *Worldclim*, também reduzidas por PCA, para o ano de 2050. Selecionamos quatro métodos de modelagem (GAM, MARS, BRT, SVM) para posteriormente fazer o consenso dos mesmos. Primeiro, realizamos a modelagem de nicho apenas com as variáveis climáticas e depois, utilizamos as variáveis climáticas com as três variáveis de NDVI. Com a triagem de dados de ocorrências, modelamos o total de cinco espécies: *Anodorhynchus leari*, *Gyalophylax hellmayri*, *Kerodon rupestris*, *Lygodactylus klugei* e *Megaxenops parnaguae*. Todas as espécies podem perder áreas climáticas no futuro com ou sem o uso de NDVI. Entretanto, a frequência de células com áreas climáticas adequadas no futuro varia conforme o uso do NDVI. O padrão de distribuição das áreas climáticas mais favoráveis também muda com o uso do NDVI e a depender da espécie. Sugerimos que o NDVI pode ser um bom estimador para a cobertura vegetal no futuro e poderá ser utilizado para indicar áreas com mais riscos de seca como também áreas que podem ser mais estáveis para conservação das espécies.

**Palavras chave:** NDVI, secas, mudanças climáticas, desertificação, biogeografia da conservação

## Abstract

Climate change indicates negative impacts on different segments of society. Arid and semiarid environments tend to be most affected. Vegetation cover in arid and semiarid environments plays a fundamental role in protecting natural resources and conserving biodiversity. Several studies have used ecological niche modeling as a tool to estimate how species distribution can be affected by climate change. However, most studies have included only climate variables to estimate potential distribution in the future. Some vegetation indices have been used as proxy of vegetation cover in studies on the distribution of the species. NDVI (Normalized Difference Vegetation Index) is one such index. The objective of our study was to generate present and future variables that are proxy to the Brazilian semiarid vegetation cover, based on NDVI database, and from the niche modeling, to estimate the potential distribution of endemic species of this region. We generated 11 database variables from 2050 and to reduce collinearity we used the PCA technique and reduced it to three variables. We also used five climatic. We selected four modeling methods (GAM, MARS, BRT, SVM) to make consensus. We performed the niche modeling only with the climatic variables and then we used the climatic variables with the three variables of NDVI. We modeled five species: *Anodorhynchus leari*, *Gyalophylax hellmayri*, *Kerodon rupestris*, *Lygodactylus klugei* and *Megaxenops parnaguae*. All species may lose climatic areas in the future with or without the use of NDVI. However, the frequency of cells with suitable climatic areas in the future varies according to the use of NDVI. The pattern of distribution of the most favorable climatic areas also changes with the use of NDVI and depending on the species. We suggest that NDVI may be a good estimator for future vegetation cover and may be used to indicate areas with greater drought risk and areas that may be more stable for species conservation.

**Keywords:** NDVI, drought, climate change, desertification, conservation biogeography

## 1 – Introdução

O aquecimento global previsto para as próximas décadas é alvo de preocupação de diversos segmentos da sociedade, pois trarão conflitos para a população em área de saúde, bem-estar, economia, alimentação, migração humana e até mesmo a disponibilidade à água potável (Feng & Fu, 2013; Hsiang & Burke, 2014; Cai et al., 2016). Em regiões áridas e semiáridas a frequência de secas tem aumentando além do normal nos últimos 50 anos (Breshears et al., 2005; Allen et al., 2010; Park Williams et al., 2013) e projeções indicam expansão de áreas áridas e até mesmo de áreas desérticas (Le Houérou, 1996; Lickley & Solomon, 2018), inclusive para o semiárido brasileiro (Salazar et al., 2007).

A vegetação nativa do semiárido brasileiro tem sido substituída nas últimas décadas por diversas atividades que alteram o solo e o risco de desertificação e frequência de secas também estão aumentando. A cobertura vegetal possui papel fundamental nesses sistemas. Devido à natureza efêmera da vegetação em *drylands* (Ravi et al., 2010), que está associada à alta variação da precipitação, a regulação geomorfológica e eólica depende de forma significativa da cobertura vegetal (Mayaud & Webb, 2017). Assim, a conservação da cobertura vegetal no semiárido brasileiro pode ser um requisito chave para a manutenção do ecossistema tanto para a população local como também para biodiversidade. Espécies do semiárido brasileiro também estão sendo apontadas como vulneráveis às mudanças climáticas (Oliveira et al., 2012; Santos et al., 2014).

Alguns índices foliares têm sido utilizados para acompanhar a dinâmica da cobertura vegetal para e avaliar os efeitos de mudanças climáticas globais (Zaitunah et al., 2018). Esse é o caso do NDVI (*Normalized Difference Vegetation Index*). Utilizado como um *proxy* de atividade fotossintéticas das plantas essa foi a primeira abordagem derivada de imagens de satélite utilizada para detectar repostas da vegetação em relação às mudanças climáticas (Zhou et al., 2001; Tucker et al., 2005). A partir daí o NDVI tem sido utilizado para detecção de períodos de seca em *drylands* (Liu & Negrón Juárez, 2001; Karnieli et al., 2010; Fernández-Manso et al., 2011; Nassur et al., 2015; Tian et al., 2016).

Portanto, o NDVI pode ser uma ferramenta útil para ser associado às outras que têm sido utilizadas para avaliar o efeito das mudanças de climáticas sobre as espécies, como a modelagem de nicho ecológico. Tal modelagem é utilizada para estimar a potencial distribuição das espécies no futuro conforme a mudança dos requerimentos ambientais (Parmesan, 2006; Peterson, 2006; Peterson & Soberón, 2012). Dessa forma, o objetivo do nosso estudo é avaliar o efeito das mudanças climáticas sobre espécies de vertebrados endêmicos do semiárido, integrando o NDVI nos modelos de nicho como um estimador de cobertura vegetal para o futuro. De forma específica iremos: (1) gerar diferentes variáveis de NDVI para serem inseridas nos modelos de nicho, e (2) comparar a modelagem de nicho das espécies endêmicas do semiárido sem e com o uso do NDVI;

## **2 – Material e métodos**

### *2.1 Área de estudo:*

A área de estudo denominada Semiárido brasileiro é composta por três biomas brasileiros sendo eles: Caatinga (751.063,270 km<sup>2</sup>), Cerrado (141.195,320 km<sup>2</sup>) e Mata Atlântica (87.874,387 km<sup>2</sup>) (Figura 1). Obtemos esses dados na mapoteca do Instituto Nacional do Semiárido (INSA), que se baseia na base cartográfica do Instituto Brasileiro de Geografia e Estatística (IBGE) elaborada para o território nacional em 2013. A delimitação do semiárido abrange nove estados brasileiros (Alagoas, Bahia, Ceará, Minas Gerais, Paraíba, Pernambuco, Piauí, Rio Grande do Norte e Sergipe) e 1135 municípios, sendo a maioria do Nordeste e uma parte menor no Sudeste. Assim, representando aproximadamente 20% do território do Brasil (Vieira et al., 2013).

Os critérios para inclusão da classificação semiárida segundo MMA/SRH (2004) incluíram três características: precipitação pluviométrica média anual igual ou inferior a 800 mm, índice de aridez de *Thornthwaite* igual ou inferior a 0,50 (razão da precipitação e da evapotranspiração potencial) e percentual diário de déficit hídrico igual ou superior a 60%, considerando todos os dias do ano. O período de precipitação no semiárido brasileiro costuma ocorrer entre fevereiro a maio, porém com grande variabilidade entre os anos (Oyama & Nobre, 2004), forte insolação, altas

temperaturas (Angelotti et al., 2009) e portanto sendo a água o principal fator limitante, muitas vezes insuficiente para as necessidades da população (Silva et al., 2010).

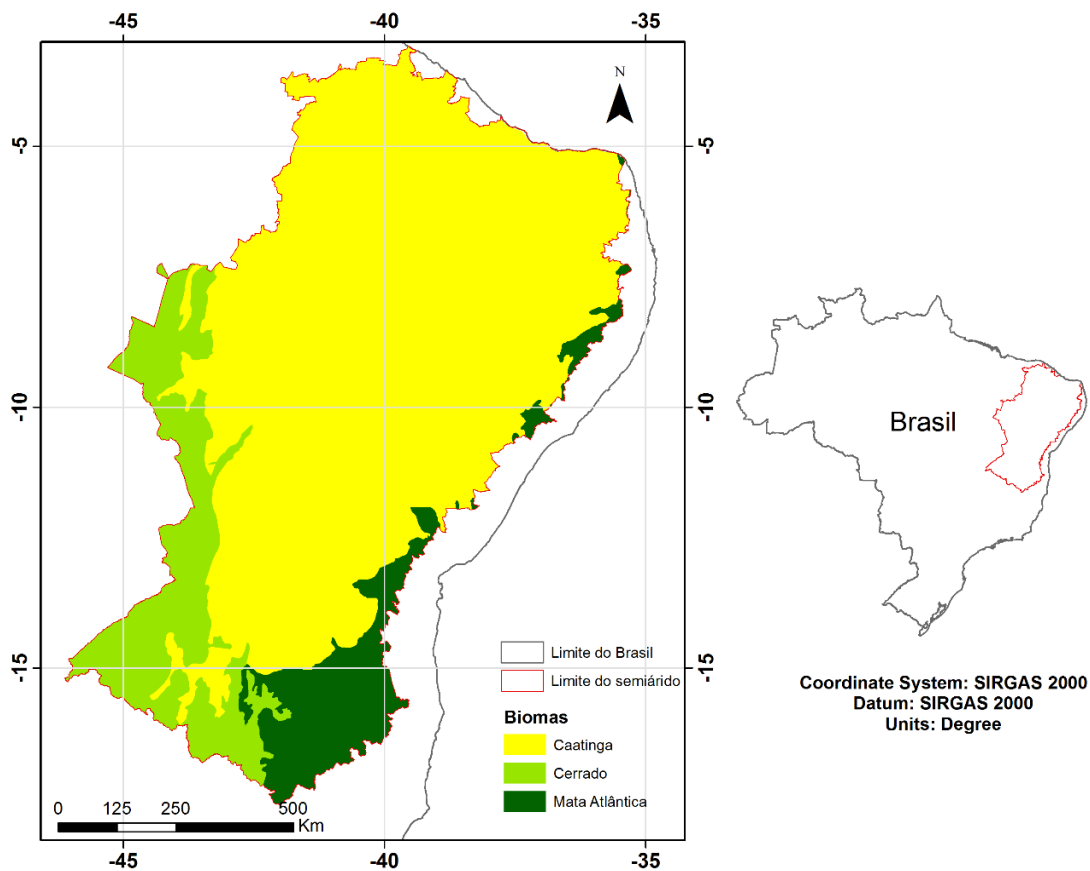


Figura 1. Área de estudo: delimitação do Semiárido brasileiro

Apesar do semiárido brasileiro ser dominado pela Caatinga, caracterizada por mosaico de arbustos espinhosos a florestas secas (Leal et al., 2005b), possui manchas de florestas semidecíduais, floresta sempre verde, manchas de cerrado e boa parte com pastagens mistas e terras agrícolas (Leal et al., 2005a; Vieira et al., 2013; Cunha et al., 2015). Esse conjunto de formações vegetais ocorrem devido a variabilidade abiótica no semiárido (Araújo et al., 2005), principalmente da disponibilidade de água (Rocha, 2009).

## 2.2 Espécies analisadas

Optamos por modelar o nicho ecológico de espécies endêmicas da região do semiárido brasileiro por viverem exclusivamente nesse ambiente mais sensível. Portanto, além de evitar vieses estatísticos sobre a captura de informações relativas a amplitude de nicho, procuramos investigar o quanto o NDVI no futuro, utilizado como *proxy* de cobertura vegetal, pode interferir na potencial distribuição das espécies quando associamos com as mudanças climáticas.

Dessa forma, utilizamos o banco de dados de ocorrências de espécies do GBIF (*Global Biodiversity Information Facility*) e do Portal da Biodiversidade para baixarmos os pontos, utilizando listas prévias sobre espécies endêmicas do bioma Caatinga. Posteriormente, cruzamos os dois resultados, eliminados pontos duplicados, com erros de georreferenciamento (por exemplo, no mar) e selecionamos apenas as espécies com pontos de ocorrência contidos totalmente dentro do semiárido brasileiro. Dessa forma, chegamos ao total de cinco espécies endêmicas para essa região, sendo elas: *Anodorhynchus leari* Bonaparte, 1856 (Psittaciformes, popularmente chamada de arara azul de lear), *Gyalophylax hellmayri* Reiser, 1905 (Passeriformes, chamada de João Chique-Chique), *Kerodon rupestris* Wied, 1820 (Rodentia, popularmente mocó), *Lygodactylus klugei* Smith, Martin & Swain, 1977 (Squamata, popularmente largartixa anã da Caatinga) e *Megaxenops paraguayae* Reiser, 1905 (Passeriformes, popularmente bico-virado-da-caatinga).

Das cinco espécies, a arara azul de lear é considerada uma espécie ameaçada pela IUCN (*International Union for Conservation of Nature*) e o mocó como uma espécie vulnerável. Entretanto, ambas espécies possuem relações importantes com a população do semiárido. As principais ameaças à arara azul de lear são a perda e comércio ilegal (Barros et al., 2006), o que torna, com grande importância, a participação da população local para a conservação da espécie. Já o mocó, tem sido utilizado como fonte alternativa de alimentação pela população (Lacher, 1979; Santana et al., 2003), e atualmente está sob forte pressão da caça (Alves et al., 2009, 2012). Portanto, entender como essas espécies podem responder às mudanças climáticas e cobertura vegetal, pode fornecer critérios importantes para preservação dessas.

### 2.3 Variáveis climáticas

Utilizamos a abordagem correlativa de nicho de modelagem de nicho, na qual convencionalmente se utiliza a relação de variáveis climáticas com os pontos de ocorrências das espécies para se estimar a potencial distribuição dessas. Tais variáveis climáticas são geradas a partir de modelos climáticos, conhecidos como AOGCMs (*Atmosphere-Ocean General Circulation Models*) e disponíveis gratuitamente em diversos bancos de dados, em diversos formatos e resoluções espaciais. Esses modelos climáticos são gerados por diferentes centros de pesquisas, portanto possuindo relações matemáticas diferentes, e são apresentados pelos relatórios do Painel Intergovernamental sobre Mudanças Climáticas (IPCC, sigla em inglês).

No entanto, não existe um consenso sobre qual modelo climático pode ser o mais eficiente para o Brasil. Entretanto, estudos testaram quais fatores mais influenciaram na variação das predições de nicho ecológico, e os métodos de modelagem de nicho acabam sendo a maior fonte de variação dos resultados (Diniz-Filho et al., 2009). Por esse motivo, optamos por trabalhar com um único modelo climático, o modelo CCSM4 (*Community Climate System Model*), o qual têm sido bastante utilizados por estudos no Brasil (Collevatti et al., 2013; de Oliveira et al., 2015; Sobral-Souza et al., 2015; de Melo et al., 2016; Caten et al., 2017; Maciel et al., 2017; Terribile et al., 2018) e foi apresentado no Quinto Relatório do IPCC (AR5).

Obtivemos os dados do CCSM4 no banco de dados do *Worldclim*, para o período futuro (2050), para o cenário de emissão de carbono RCP 4.5, considerado um modelo um cenário intermediário. Para o tempo presente, o banco de dados do *Worldclim* não possui dados modelados conforme os AOGCMs, sendo então dados de estações interpolados para o tempo atual. Utilizamos como tempo presente os dados de 1970 a 2000. Obtemos ambos os dados em resolução de 10 minutos ( $0.16^\circ$  e  $\cong 16$  km).

Os dados contêm 19 variáveis climáticas na extensão global e então recortadas para a extensão do semiárido brasileiro. Entre essas 19 variáveis, muitas podem estar correlacionadas e, portanto, podem prejudicar a acurácia e precisão dos modelos de nicho (Lima-Ribeiro & Diniz-filho, 2013). Dessa forma, realizamos análise fatorial com rotação varimax (Terribile, 2012), que

indicou 5 eixos independentes, nos quais as variáveis Bio3 (isotermalidade), Bio7 (amplitude anual da temperatura), Bio10 (média da temperatura do trimestre mais quente), Bio16 (precipitação do trimestre mais úmido) e Bio 17 (precipitação do trimestre mais seco) apresentaram os mais altos coeficientes. Portanto, selecionados essas cinco variáveis climáticas para a modelagem de nicho no semiárido (ver detalhes sobre a modelagem, abaixo).

#### 2.4 Construindo variáveis do NDVI

Proposto por Rouse e colaboradores (1972), o NDVI é um índice de vegetação originado do contraste de duas bandas espectrais de imagens de satélite seu resultado entre -1 a +1. Os valores mais próximos de +1 indicam maior densidade de vegetação na célula (*pixel*) da imagem, enquanto locais não vegetados, como corpos de água e locais úmidos, são responsáveis pelos valores negativos (até -1). Enquanto solo exposto é definido por valores positivos, porém muito próximos a zero (Lillesand et al., 2004). Dessa forma, podemos baixar imagens de satélite e calcularmos manualmente os valores de NDVI que serão dados para cada célula. Em nossos modelos, consideramos valores entre 0 e 0.2 como provável com risco de seca.

Existem diversos bancos de dados atuais do NDVI, porém para o futuro, utilizamos o banco de dados que nós modelamos para o futuro, no capítulo anterior, utilizando o modelo de série temporal ARIMA (sigla de *autoregressive integrated moving-average*). Geramos esse banco de dados para o futuro por meio de imagens de satélite baixadas da plataforma Embrapa Informática Agropecuária, disponíveis gratuitamente e a partir de 2000 ao período atual. Então, a partir de dados de NDVI dos nove estados brasileiros que compõe o semiárido brasileiro, geramos previsões para o período atual (2001 a 2017) e para futuro (2030, 2050, 2070), sendo esses dados divididos mensalmente em resolução de 10 minutos (0.16°).

Portanto, para este capítulo, construímos 11 variáveis de NDVI que pudessem representar a variação de NDVI ao longo dos anos e meses. O critério para seleção das variáveis se deu com base na análise das projeções para o período atual que foram modeladas (2001-2017). Além disso,

nos baseamos na criação de variáveis climáticas disponíveis no *WorldClim*. Assim, criamos as seguintes variáveis:

Tabela 1. Variáveis de NDVI criadas com base da análise das projeções atuais (2001 a 2017)

Variável	Significado
<b>Bio1</b>	NDVI médio anual
<b>Bio2</b>	Coefficiente de variação do NDVI (sazonalidade)
<b>Bio3</b>	Máximo NDVI do mês com maior cobertura vegetal (abril)
<b>Bio4</b>	Mínimo NDVI do mês com menor cobertura vegetal (outubro)
<b>Bio5</b>	Amplitude anual do NDVI (Bio3 – Bio4)
<b>Bio6</b>	Média de NDVI período com maior cobertura vegetal (fevereiro-maio)
<b>Bio7</b>	Média de NDVI período com menor cobertura vegetal (agosto-novembro)
<b>Bio8</b>	Máximo de NDVI período com maior cobertura vegetal (fevereiro-maio)
<b>Bio9</b>	Máximo de NDVI período com menor cobertura vegetal (agosto-novembro)
<b>Bio10</b>	Mínimo de NDVI período com maior cobertura vegetal (fevereiro-maio)
<b>Bio11</b>	Mínimo de NDVI período com menor cobertura vegetal (agosto-novembro)

Em nosso estudo, consideramos então como período atual a média das projeções entre 2001 e 2017. Para o futuro utilizados apenas a janela de tempo de 2050 para ser o mais equivalente possível com os dados das variáveis climáticas do *Worldclim*. Assim, para o futuro, fizemos também uma média de 17 anos, sendo, portanto, considerado para 2050, a média entre 2042 a 2058.

Dessa forma utilizamos análise fatorial com rotação varimax para reduzir a colinearidade (Terribile, 2012), que indicou três eixos independentes, sendo as variáveis Bio2 (Coeficiente de variação do NDVI), Bio3 (Máximo NDVI do mês com maior cobertura vegetal) e Bio4 (Mínimo NDVI do mês com menor cobertura vegetal) com os coeficientes mais altos.

## 2.5 Modelagem de nicho

Para a realização da modelagem de nicho ecológico, utilizamos quatro métodos com diferentes abordagens matemáticas, sendo eles: GAM (*Generalized additive models*), MARS (*Multivariate Adaptive Regression Splines*), BRT (*Boosted regression trees*) e SVM (*Support Vector Machines*).

O método GAM é uma extensão do modelo linear generalizado (GLM) porém não é necessário haver relação linear entre as variáveis e os dados são ajustados por funções de “suavizações” (Wood, 2006). O método MARS combina múltiplas regressões lineares, onde os dados são particionados e para cada partição é feita uma regressão linear (Friedman, 1991; Mateo et al., 2010). O método BRT utiliza dois tipos de algoritmos, árvore de decisão e árvore de regressão para a classificação, e então a partir daí o conjunto de modelos são combinados (Elith et al., 2008). Diferente dos métodos anteriores, o SVM é um método de aprendizagem que separa os dados em duas classes de treinamento dentro de um espaço multidimensional, de forma que haja maior separação possível entre as margens em um hiperplano (Drake et al., 2006).

Com os dados de espécies, variáveis climáticas e NDVI preparados, escolhemos o pacote de modelagem *sdm* (Naimi & Araújo, 2016), desenvolvido para rodar na plataforma *R*. Esse pacote tem como o objetivo de facilitar o uso de diversos parâmetros para preparação dos dados, bem como unificar a interface que já é utilizada por outros pacotes de modelagem como o *dismo*. Como primeira etapa, preparamos os dados de ocorrência para os métodos de modelagem, gerando pseudo-ausências de forma aleatória sobre a extensão do semiárido, mantendo a prevalência de 0.5, ou seja, 50% de presenças e 50% de pseudo-ausências (Caten et al., 2017).

Posteriormente, particionamos os dados para teste e treino. O pacote *sdm* nos permite associar tipos de partições simultâneas e então selecionados os métodos *bootstrapping* e validação cruzada *k fold* (com o *k fold* dividido em cinco grupos), e fazendo 10 replicações para cada método. Por último, utilizamos a função *ensemble* do próprio pacote, fazendo então o consenso de todos os modelos gerados usando o critério de média ponderada (*weighted*) por AUC (*area under curve*). Os valores de AUC variam entre 0 e 1, quando valores mais próximos de 1, maior é a probabilidade de acertos dos modelos.

O método AUC é uma forma de avaliação da performance dos modelos, que é independente de limiar, ou seja, não precisamos converter os dados em presença e ausência (dados binários) das espécies. Portanto, mantendo os resultados dos modelos na forma de adequabilidade das espécies,

ou seja, valores contínuos entre 0 e 1, onde valores mais próximos de 1, as áreas são consideradas mais adequadas ambientalmente para a espécie.

Como o objetivo do nosso estudo foi avaliar o efeito do NDVI sobre as espécies, realizamos duas etapas de modelagem. Na primeira etapa a modelagem de nicho foi feita apenas utilizando as variáveis climáticas e na segunda etapa utilizamos as mesmas variáveis climáticas adicionando as três variáveis de NDVI na modelagem.

### 3 – Resultados

Em geral, nossos modelos apresentaram bom desempenho, apresentando bons valores de AUC sem e com a utilização do NDVI (Tabela 2). Todas as cinco espécies analisadas perderiam áreas adequadas, usando apenas as variáveis climáticas como também quando integramos o NDVI (Figuras 2 a 6).

Tabela 2. Valores máximos de AUC para as espécies com e sem o uso do NDVI como proxy de cobertura vegetal.

<b>Espécie</b>	<b>AUC - sem NDVI</b>	<b>AUC - com NDVI</b>
<i>Anodorhynchus leari</i>	1	1
<i>Gyalophylax hellmayri</i>	0.945	1
<i>Kerodon rupestris</i>	1	1
<i>Lygodactylus klugei</i>	1	0.922
<i>Megaxenops parnaguae</i>	0.88	0.909

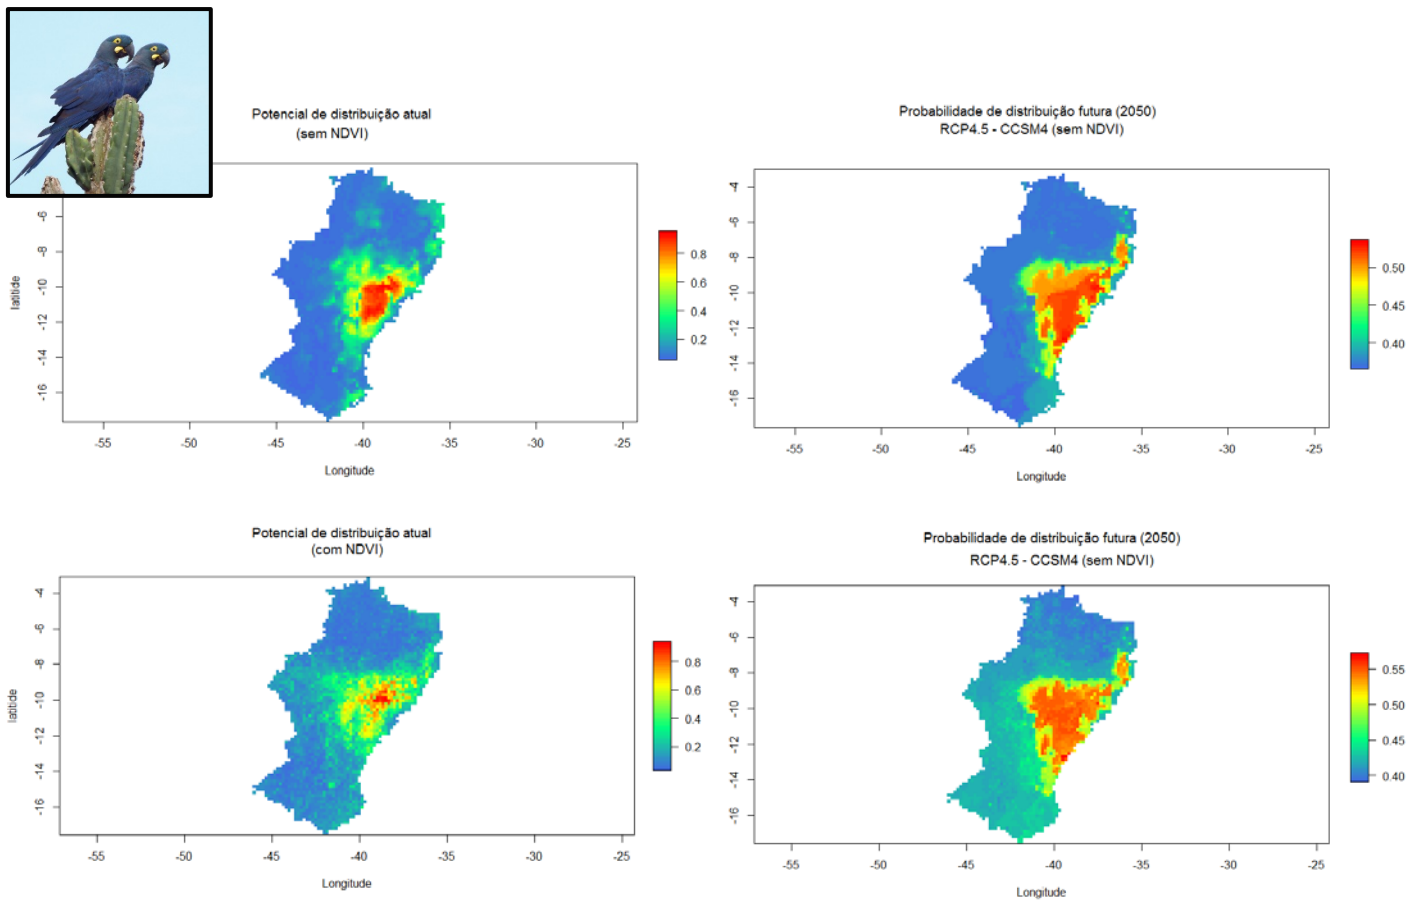


Figura 2. Distribuição potencial da espécie *Anodorhynchus leari* para o período atual (com e sem o uso de NDVI) e para o período futuro (com e sem o uso de NDVI).

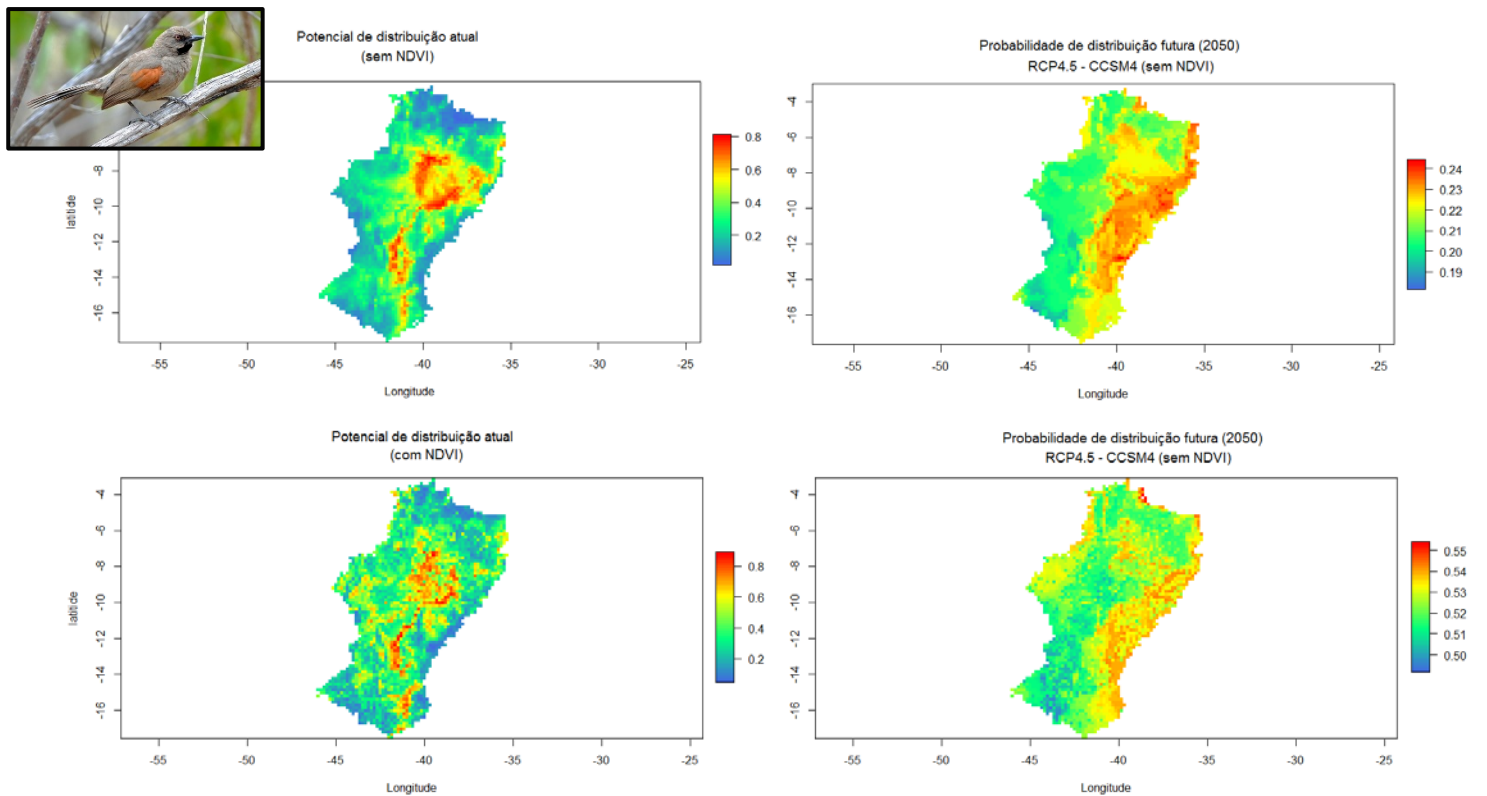


Figura 2. Potencial de distribuição da espécie *Gyalophylax hellmayri* para o período atual (com e sem o uso de NDVI) e para o período futuro (com e sem o uso de NDVI).

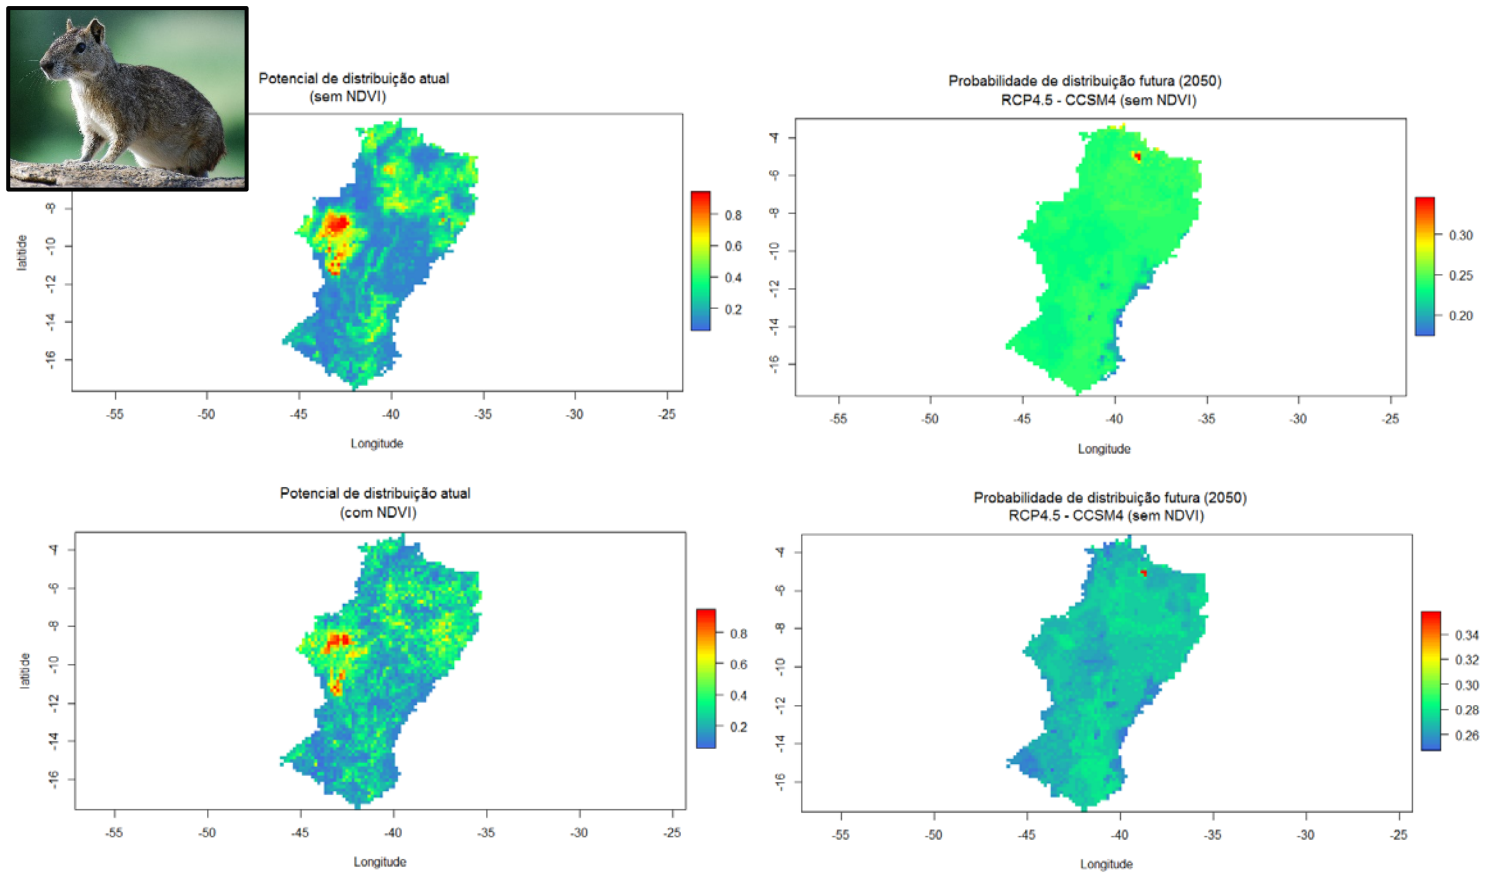


Figura 4. Potencial de distribuição da espécie *Kerodon rupestris* para o período atual (com e sem o uso de NDVI) e para o período futuro (com e sem o uso de NDVI).

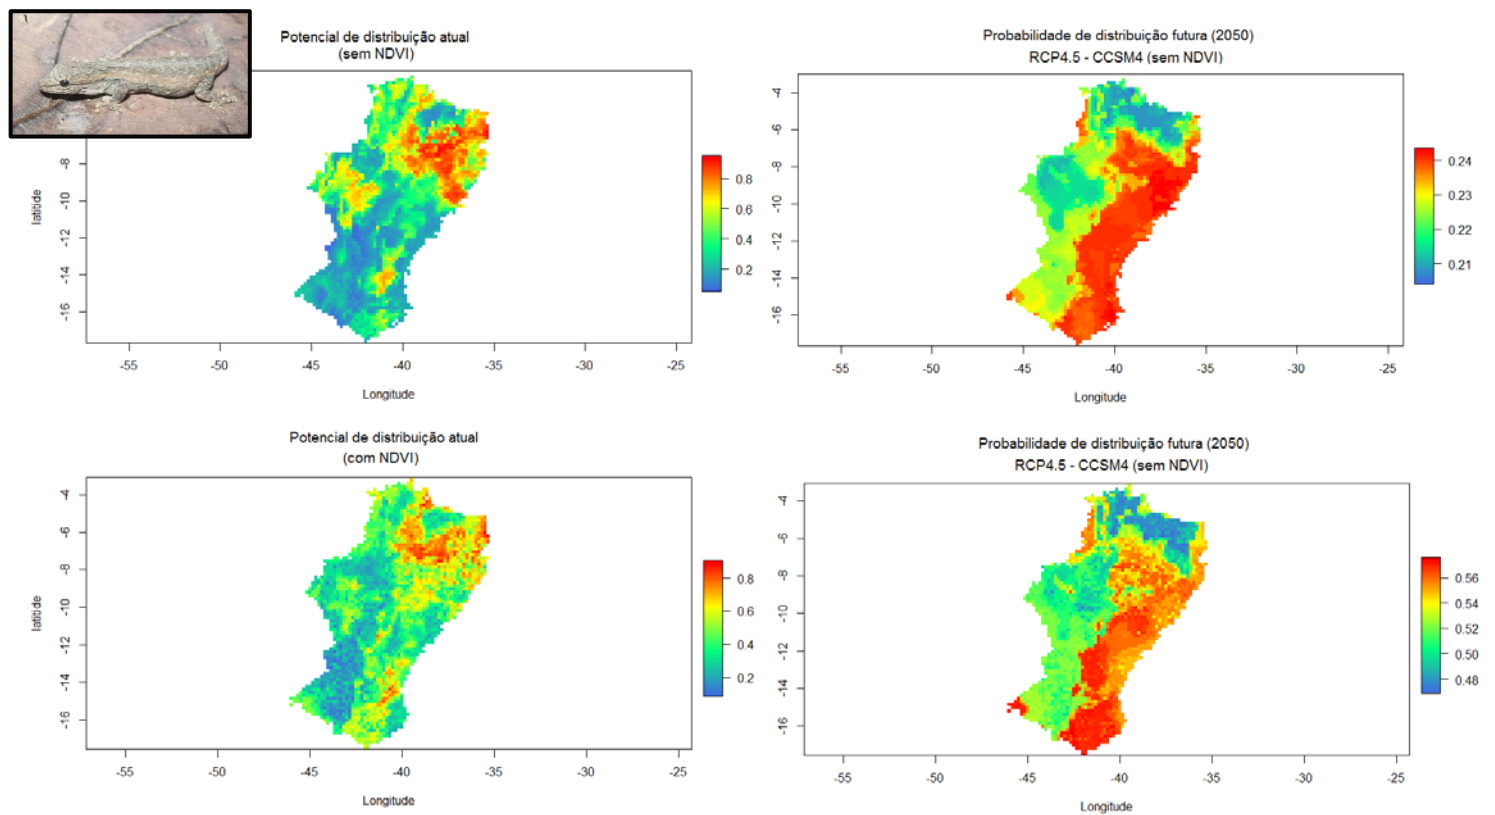


Figura 5. Potencial de distribuição da espécie *Lygodactylus klugei* para o período atual (com e sem o uso de NDVI) e para o período futuro (com e sem o uso de NDVI).

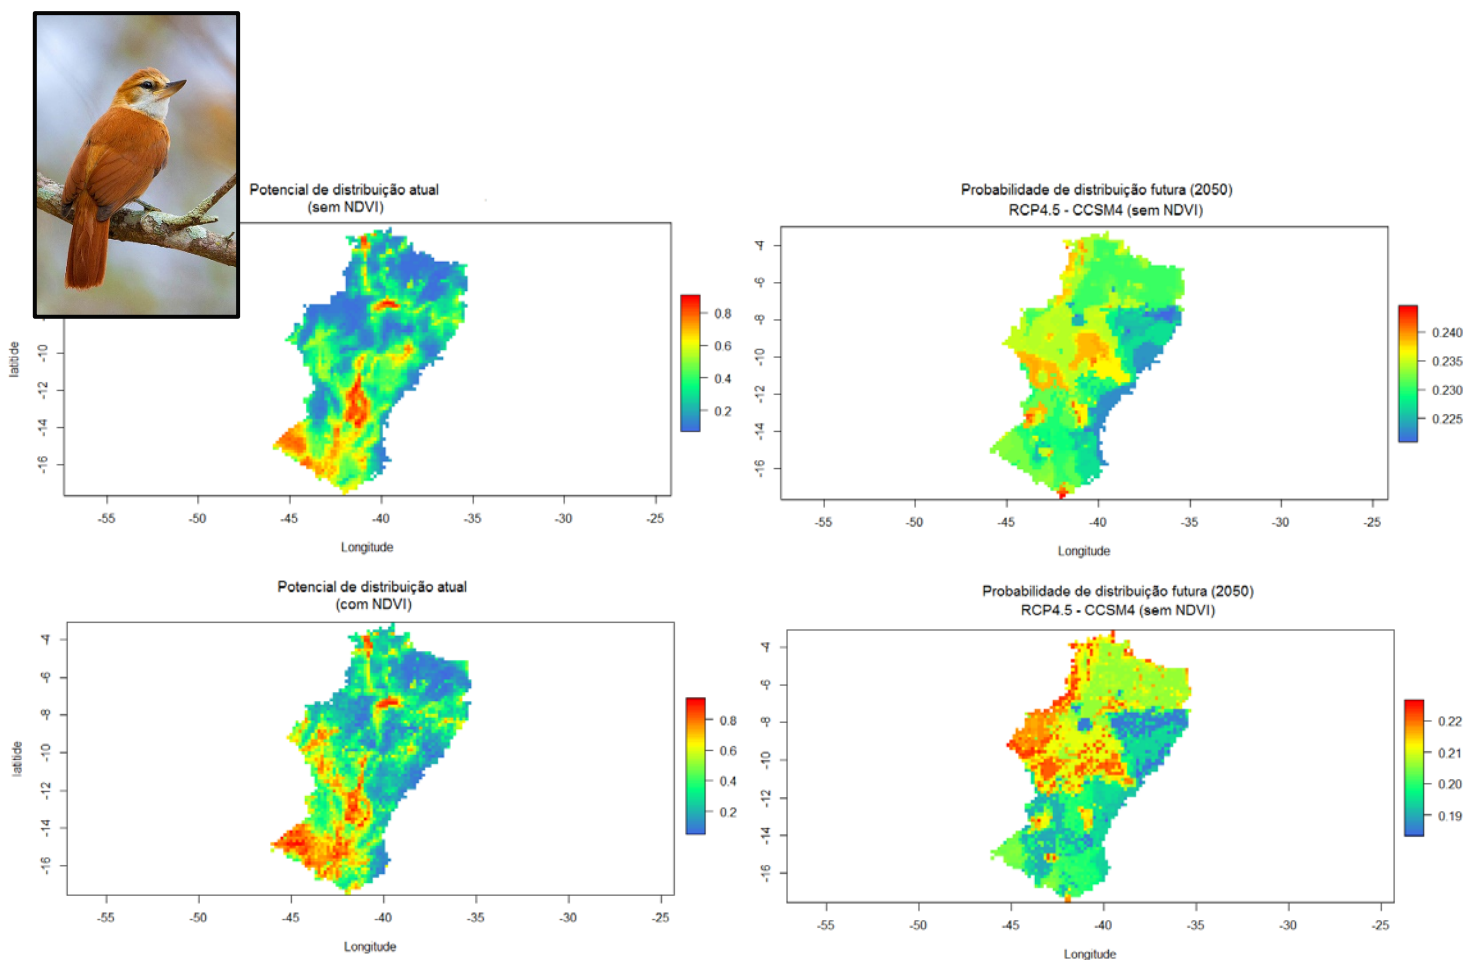


Figura 6. Potencial de distribuição da espécie *Megaxenops parnaguae* para o período atual (com e sem o uso de NDVI) e para o período futuro (com e sem o uso de NDVI).

Ao comparar as potenciais distribuições entre o presente e o futuro, o padrão mais distinto observado foi do roedor *K. rupestris*, cujas regiões mais adequadas no período atual, aparecem em porções muito pequenas no norte no semiárido (Figura 4). Para as outras quatro espécies, em contrapartida, as áreas mais adequadas diminuem no futuro, porém mais estão próximas das áreas mais adequadas no presente (Figura 2, 3, 5 e 6). Porém, o valor de adequabilidade para o passeriforme *G. hellmayri* (sem NDVI) e o squamata *L. klugei* (sem NDVI), não alcança o valor de 0.5 no futuro. Enquanto o roedor *K. rupestris* e o passeriforme *Megaxenops parnaguae*, a adequabilidade máxima não alcançam o valor de 0.3, integrando ou não o NDVI.

Os padrões de potencial distribuição com e sem o uso do NDVI se assemelham ao longo do semiárido, entretanto, a frequências das células dos valores preditos são diferentes, tanto no período atual como no futuro (Figuras 7 a 11).



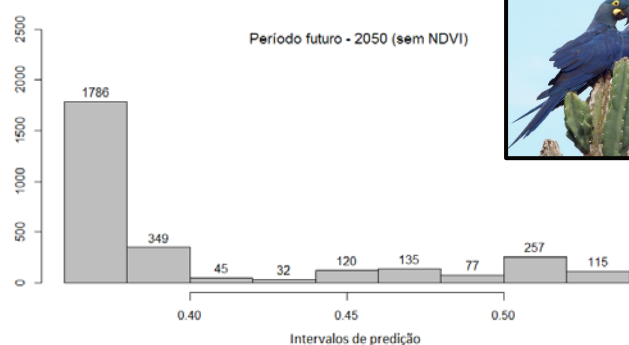
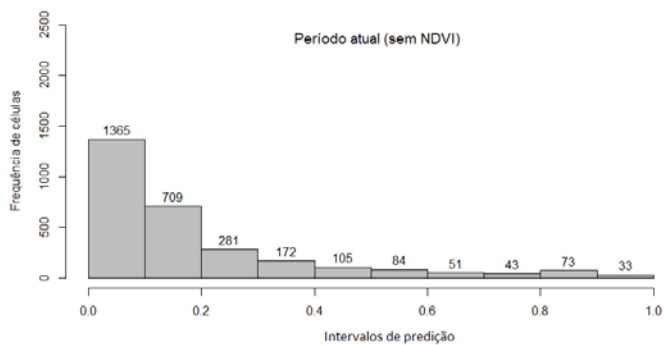


Figura 7. Histograma de frequência de células dos valores preditos da espécie *Anodorhynchus leari* do período atual (com e sem o uso de NDVI) e para o período futuro (com e sem o uso de NDVI).



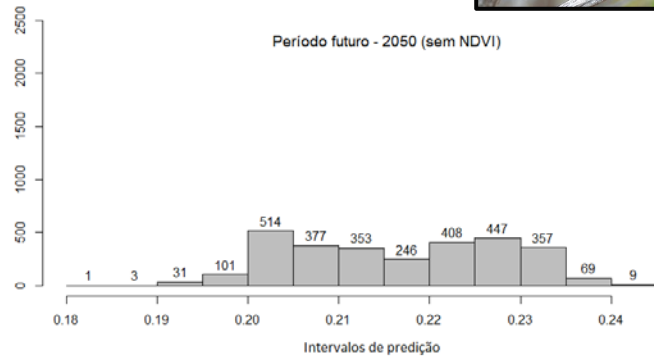



Figura 8. Histograma de frequência de células dos valores preditos da espécie *Gyalophylax hellmayri* do período atual (com e sem o uso de NDVI) e para o período futuro (com e sem o uso de NDVI).

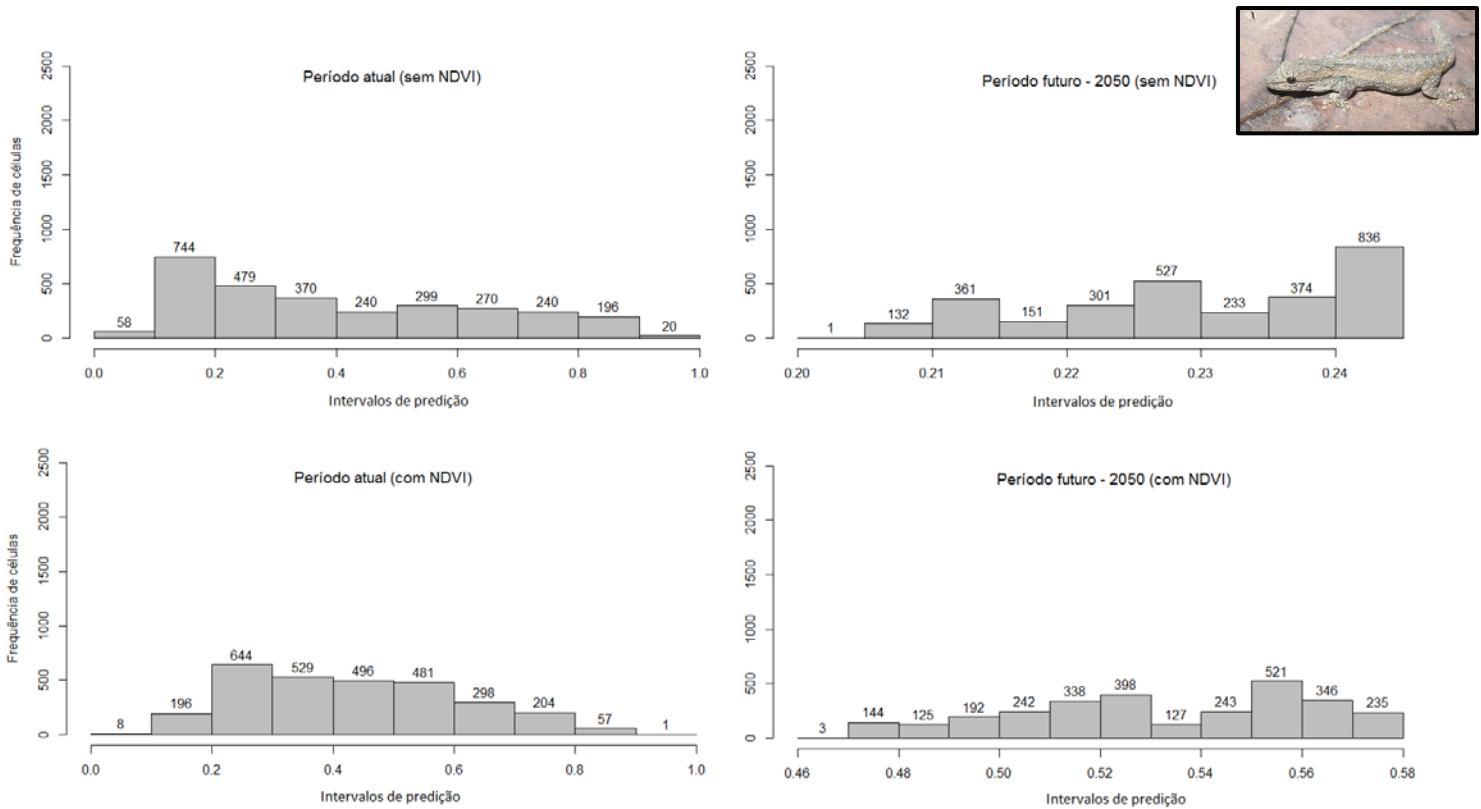


Figura 10. Histograma de frequência de células dos valores preditos da espécie *Lygodactylus klugei* do período atual (com e sem o uso de NDVI) e para o período futuro (com e sem o uso de NDVI).

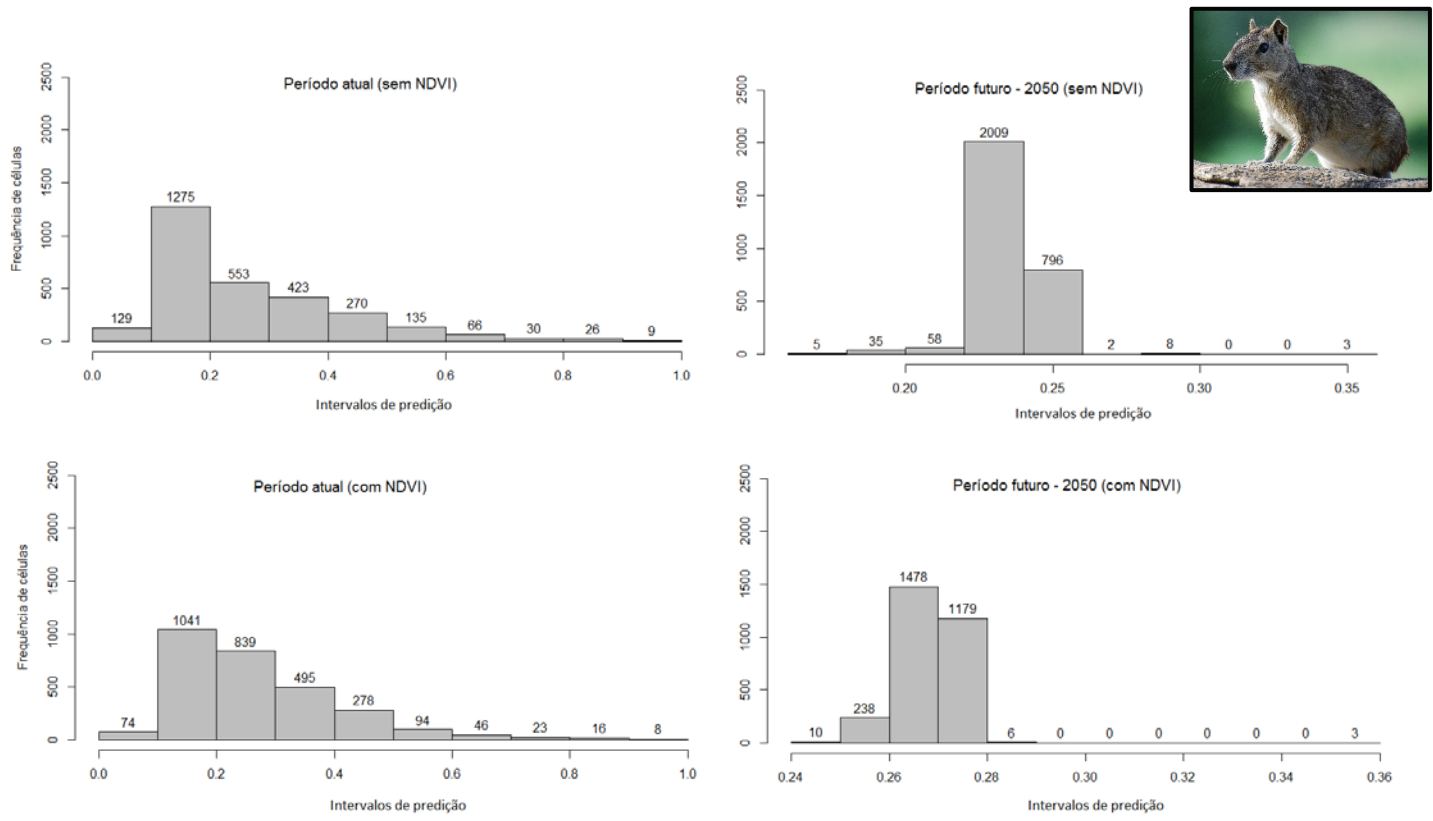


Figura 9. Histograma de frequência de células dos valores preditos da espécie *Kerodon rupestris* do período atual (com e sem o uso de NDVI) e para o período futuro (com e sem o uso de NDVI).

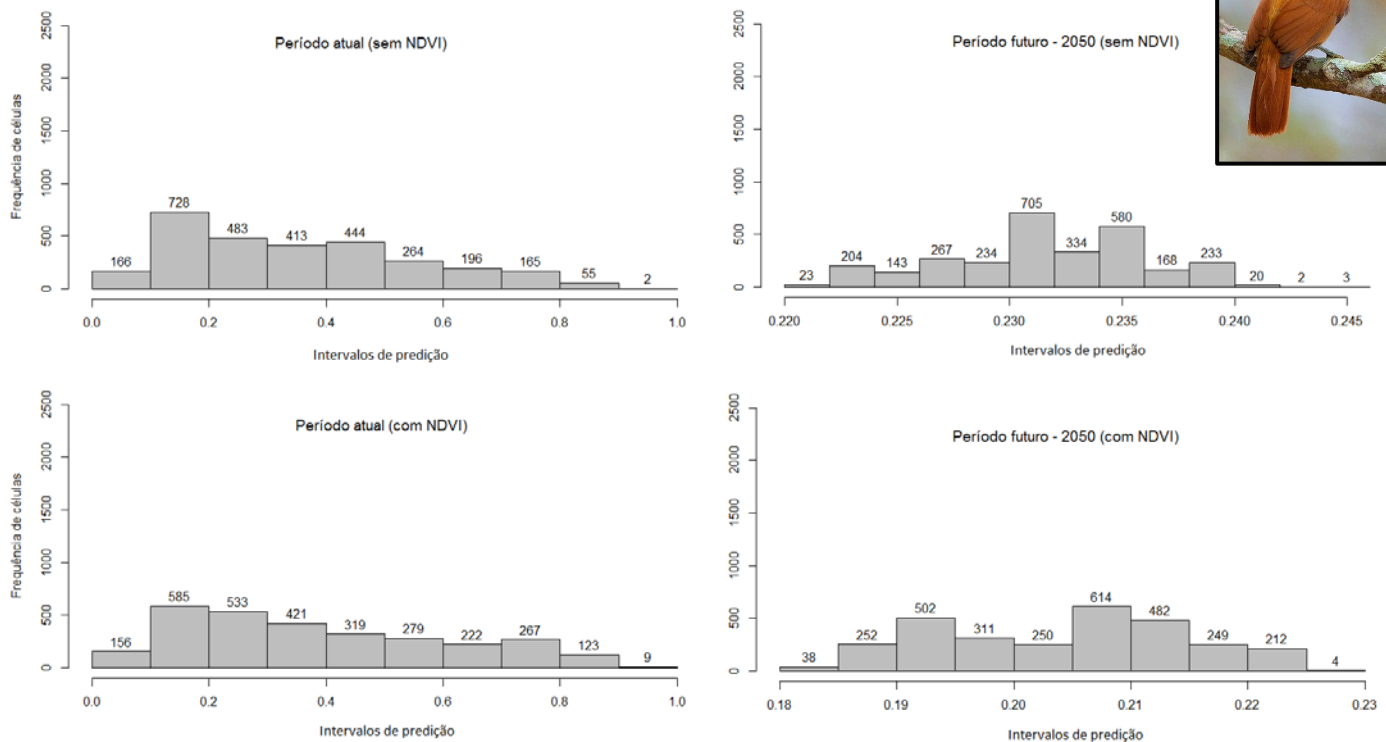


Figura 11. Histograma de frequência de células dos valores preditos da espécie *Megaxenops paraguaye* do período atual (com e sem o uso de NDVI) e para o período futuro (com e sem o uso de NDVI).

#### 4 – Discussão

De uma forma geral, percebemos diferenças ao utilizar o NDVI nas projeções futuras da distribuição das espécies. Embora nosso estudo não possa indicar isso, alguns trabalhos encontram relação positiva do uso do NDVI com o melhor desempenho dos modelos (Escobar et al., 2015; Lu et al., 2016; Yañez-Arenas et al., 2018). Isso não significa que a cobertura vegetal inferida pelo NDVI seja condicionada pelos valores de desempenho, mas que é preciso avaliar como o NDVI melhor representa a cobertura vegetal, e, portanto, como são criadas as variáveis.

Em nosso estudo, observamos diferentes gradientes com o uso do NDVI ao compararmos com o uso apenas das variáveis climáticas. Isso pode ter ocorrido devido a detecção de heterogeneidade da cobertura vegetal pelo NDVI (Ning et al., 2015). Como o semiárido é composto em maior proporção pela Caatinga, essa heterogeneidade também pode ter sido observada pelo

nosso estudo devido aos remanescentes estarem distribuídos de forma irregular ao longo do bioma (Antongiovanni et al., 2018).

A diferença nos modelos que observamos com uso do NDVI também pode ter ocorrido devido às respostas das espécies em relação às variáveis utilizadas. É possível que o NDVI, *proxy* de cobertura vegetal, tenha favorecido as espécies em que o valor de adequabilidade maior no futuro, quando comparado ao modelo apenas com as variáveis climáticas. Assim, observamos dois tipos de resultados interessantes que poderão ser incorporados em estudos futuros: (1) a indicação de áreas mais vulneráveis às secas (2) indicação de áreas estáveis para melhor conservação das espécies.

Embora os valores de adequabilidade futura indiquem valores muito mais baixos que no período atual, é importante ressaltar que os nossos modelos não considerarem a adaptação climática das espécies. Os nossos modelos com os valores de NDVI também não consideram as possíveis mudanças de uso de solo de origem antrópica que ocorrerão no futuro, portanto observamos padrões de mudanças futuras considerando uma abordagem mais otimista.

Mesmo assim, é possível identificar áreas que podem ser mais resistentes às secas. Segundo Acosta Salvatierra e colaboradores (2017), ao analisarem os índices de NDVI entre 2008 e 2013, observaram que áreas de proteção integral foram mais resistentes às secas ocorridas nesse período, portanto, as mais resistentes ao distúrbios de origem antrópica. Porém, na Caatinga, as áreas de proteção integral além de esparsas, representam um pouco mais de 1% de território protegido (Seyffarth & Rodrigues, 2017), indicando então a necessidade de manter a cobertura vegetal também em outras áreas.

Das espécies analisadas em nosso estudo a *A. leari* (arara azul de lear), que está criticamente ameaçada de extinção, a maior parte das ocorrências ocorre apenas dentro da Estação Ecológica do Raso da Catarina (Paes & Dias, 2008). O Plano de Manejo dessa EE é enfático sobre a necessidade de inserir às práticas de educação ambiental relacionadas ao efeito da desertificação sobre as aves, bem como a importância do apoio do setor privado e público regionais. Embora nossos modelos impliquem que as espécies podem se deslocar livremente para os locais climáticos mais adequados,

devido ao pressuposto de dispersão ilimitada (Thomas et al., 2004; Pearson, 2006; Franklin, 2010), a capacidade de dispersão pode estar associada às características e requerimentos das espécies.

Em nosso estudo, a potencial distribuição futura do roedor *K. rupestris* pode ocorrer em locais bem mais distantes dos locais no presente. Entretanto, essa espécie é uma restrita à afloramentos rochosos (Alho, 1982; Lessa et al., 2005), o que pode ser indicado como uma possível barreira para sua dispersão, pois esses afloramentos se encontram bastante isolados entre eles (Lessa et al., 2005). Dessa forma, assim como para aves, a cobertura vegetal poderia influenciar a eficiência de movimentação para várias espécies (Crist et al., 1992; Neumann et al., 2015). Estudos com séries temporais da vegetação então poderão contribuir para avaliar movimento e migração animal (Beck et al., 2008).

Além do NDVI ser uma ferramenta útil para avaliar a potencial distribuição das espécies, o *proxy* de cobertura vegetal também pode ser utilizado em estudos de abundância das espécies (Pettorelli et al., 2005). A influência da cobertura vegetal sobre a distribuição das espécies tem sido relatada em diversos trabalhos (Rodríguez-Cabal & Branch, 2011; Corcuera & Zavala-Hurtado, 2014; Flores-Peredo & Vázquez-Domínguez, 2016), principalmente para comunidades de aves em regiões áridas e semiáridas (Corcuera & Zavala-Hurtado, 2014), cuja agregação de espécies foi observada em períodos de seca. Portanto, nossos resultados contribuem na seleção estratégica de locais mais favoráveis para as espécies em projetos de conservação.

É imprescindível analisar como a vegetação responde às mudanças climáticas esperadas. A cobertura vegetal da Caatinga é composta de espécies de plantas que até então eram consideradas mais adaptadas às secas. Entretanto, foi observada mortalidade além do normal dessas espécies no período de seca registrada em 2010 (Seyffarth & Rodrigues, 2017). A manutenção da cobertura vegetal associada ao manejo adequado dos recursos hídricos (Jat et al., 2012) e aspectos sociais regionais (Angelotti et al., 2009), aumentam a resiliência às mudanças climáticas nesses ecossistemas.

Segundo Martins e colaboradores (2017), um dos principais problemas no Brasil em relação às mudanças climáticas é o caráter reativo do gerenciamento. Ou seja, as ações tomadas ocorrem

apenas durante os períodos de seca e não contribuem de forma preventiva, gerando o agravamento dos efeitos do aquecimento global. Embora a Caatinga tenha perdido mais da metade da sua vegetação nativa, o bioma possui fragmentos maiores que 25 mil hectares, permitindo a criação de ações de conservação proativas (Antongiovanni et al., 2018), que requerem menor investimento à longo prazo, porém ações devem ser imediatas (Brooks et al., 2006).

É preciso envolver várias estratégias para a conservação no semiárido brasileiro. Como os períodos de seca afetam os moradores do semiárido devido à escassez de água, energia e segurança alimentar, ocorre aumento de pressão sobre os recursos naturais (Gutiérrez et al., 2014; Marengo et al., 2017). Entretanto, dentro do semiárido existem diferentes contextos sociais e econômicos, os quais requerem que ações de conservação sejam aplicadas de forma mais direcionadas às demandas locais. Sugerimos que nos próximos estudos de conservação no semiárido brasileiro, sejam considerados projeções futuras de cobertura vegetal. O NDVI pode ser um bom índice utilizado como *proxy* da cobertura vegetal e aumentar a eficiência em tomadas de decisões, podendo tornar a biodiversidade menos vulnerável à episódios de eventos de seca.

## Referências

Acosta Salvatierra L.H., Ladle R.J., Barbosa H., Correia R.A., & Malhado A.C.M. (2017) Protected areas buffer the Brazilian semi-arid biome from climate change. *Biotropica*, **49**, 753–760.

Alho C.J.R. (1982) Brazilian rodents: their habitats and habits. *Mammalian Biology in South America* pp. 143–166. Pittsburgh: Special Publication, Pymatuning Laboratory of Ecology, University of Pittsburgh,

Allen C.D., Macalady A.K., Chenchouni H., Bachelet D., McDowell N., Vennetier M., Kitzberger T., Rigling A., Breshears D.D., Hogg E.H. (Ted), Gonzalez P., Fensham R., Zhang Z., Castro J., Demidova N., Lim J.-H., Allard G., Running S.W., Semerci A., & Cobb N. (2010) A global overview of drought and heat-induced tree mortality reveals emerging climate change risks for forests. *Forest Ecology and Management*, **259**, 660–684.

Alves R.R.N., Gonçalves M.B.R., & Vieira W.L.S. (2012) Caça , uso e conservação de vertebrados no semiárido Brasileiro. *Tropical Conservation Science*, **5**, 394–416.

Alves R.R.N., Mendonça L.E.T., Confessor M.V. a, Vieira W.L.S., & Lopez L.C.S. (2009) Hunting strategies used in the semi-arid region of northeastern Brazil. *Journal of ethnobiology and ethnomedicine*, **5**, 12.

Angelotti F., Sá I.B., & Melo R.F. de (2009) Mudanças climáticas e desertificação no Semi-Árido brasileiro. *Mudanças climáticas e desertificação no Semi-Árido brasileiro*. (ed. by F. ANGELOTTI, I.B. SÁ, E.A. MENEZES, and G.. PELLEGRINO), pp. 41–49. Embrapa Informática Agropecuária, Petrolina, PE: Embrapa Semiárido; Campinas, SP:

Antongiovanni M., Venticinque E.M., & Fonseca C.R. (2018) Fragmentation patterns of the Caatinga drylands. *Landscape Ecology*, **33**, 1353–1367.

Araújo F.S., Rodal M.J.N., Barbosa M.R.V., & Martins F.R. (2005) Repartição da flora lenhosa no domínio da Caatinga. *Análise das variações da biodiversidade do bioma Caatinga: suporte a estratégias regionais de conservação* (ed. by F.S. Araújo, M.J.N. Rodal, and O. Barbosa, M. R. V.), pp. 15–34. Ministério do Meio Ambiente, Brasília.

Barros Y.M., Linares S.F.T.P., Sousa A.E.B.A., Neto J.R.S., Neto P.S., Bianchi C.A., Marini-Filho O.J., & Nascimento J.L.. (2006) *Plano de Manejo da Arara-Azul-de-Lear*.

Beck P.S.A., Wang T.J., Skidmore A.K., & Liu X.H. (2008) Displaying remotely sensed vegetation dynamics along natural gradients for ecological studies. *International Journal of Remote Sensing*, **29**, 4277–4283.

Breshears D.D., Cobb N.S., Rich P.M., Price K.P., Allen C.D., Balice R.G., Romme W.H., Kastens J.H., Floyd M.L., Belnap J., Anderson J.J., Myers O.B., & Meyer C.W. (2005) Regional vegetation die-off in response to global-change-type drought. *Proceedings of the National Academy of Sciences*, **102**, 15144–15148.

Brooks T.M., Mittermeier R.A., da Fonseca G.A.B., Gerlach J., Hoffmann M., Lamoreux J.F., Mittermeier C.G., Pilgrim J.D., & Rodrigues A.S.L. (2006) Global Biodiversity Conservation Priorities. *Science*, **313**, 58–61.

Cai R., Feng S., Oppenheimer M., & Pytlikova M. (2016) Climate variability and international migration: The importance of the agricultural linkage. *Journal of Environmental Economics and Management*, **79**, 135–151.

Caten C. Ten, Lima-Ribeiro M. de S., da Silva N.J., Moreno A.K., & Terribile L.C. (2017) Evaluating the Effectiveness of Brazilian Protected Areas Under Climate Change. *Tropical Conservation Science*, **10**, 194008291772202.

Collevatti R.G., Terribile L.C., de Oliveira G., Lima-Ribeiro M.S., Nabout J.C., Rangel T.F., & Diniz-Filho J.A.F. (2013) Drawbacks to palaeodistribution modelling: the case of South American seasonally dry forests. *Journal of Biogeography*, **40**, 345–358.

Corcuera P. & Zavala-Hurtado J.A. (2014) The influence of vegetation on bird distribution in dry forests and oak woodlands of western Mexico. *Revista de Biología Tropical*, **54**, 657.

Crist T.O., Guertin D.S., Wiens J.A., & Milne B.T. (1992) Animal Movement in Heterogeneous Landscapes: An Experiment with *Eleodes* Beetles in Shortgrass Prairie. *Functional Ecology*, **6**, 536.

Cunha A.P.M., Alvalá R.C., Nobre C.A., & Carvalho M.A. (2015) Monitoring vegetative drought dynamics in the Brazilian semiarid region. *Agricultural and Forest Meteorology*, **214–215**, 494–505.

Diniz-Filho J.A.F., Bini L.M., Rangel T.F., Loyola R.D., Hof C., Nogués-Bravo D., & Araújo M.B. (2009) Partitioning and mapping uncertainties in ensembles of forecasts of species turnover under climate change. *Ecography*, **32**, 897–906.

Drake J.M., Randin C., & Guisan A. (2006) Modelling ecological niches with support vector machines. *Journal of Applied Ecology*, **43**, 424–432.

Elith J., Leathwick J.R., & Hastie T. (2008) A working guide to boosted regression trees. *Journal of Animal Ecology*, **77**, 802–813.

Escobar L.E., Peterson A.T., Papeş M., Favi M., Yung V., Restif O., Qiao H., & Medina-Vogel G. (2015) Ecological approaches in veterinary epidemiology: mapping the risk of bat-borne rabies using vegetation indices and night-time light satellite imagery. *Veterinary Research*, **46**, 92.

- Feng S. & Fu Q. (2013) Expansion of global drylands under a warming climate. *Atmospheric Chemistry and Physics*, **13**, 10081–10094.
- Fernández-Manso A., Quintano C., & Fernández-Manso O. (2011) Forecast of NDVI in coniferous areas using temporal ARIMA analysis and climatic data at a regional scale. *International Journal of Remote Sensing*, **32**, 1595–1617.
- Flores-Peredo R. & Vázquez-Domínguez G. (2016) Influence of vegetation type and season on rodent assemblage in a Mexican temperate forest mosaic. *Therya*, **7**, 357–369.
- Franklin J. (2010) *Mapping species distributions: spatial inference and prediction*. Cambridge University Press, New York.
- Friedman J.H. (1991) Multivariate Adaptive Regression Splines. *The Annals of Statistics*, **19**, 1–67.
- Gutiérrez A.P.A., Engle N.L., De Nys E., Molejón C., & Martins E.S. (2014) Drought preparedness in Brazil. *Weather and Climate Extremes*, **3**, 95–106.
- Le Houérou H.N. (1996) Climate change, drought and desertification. *Journal of Arid Environments*, **34**, 133–185.
- Hsiang S.M. & Burke M. (2014) Climate, conflict, and social stability: what does the evidence say? *Climatic Change*, **123**, 39–55.
- Jat R.A., Craufurd P., Sahrawat K.L., & Wani S.P. (2012) Climate change and resilient dryland systems: Experiences of ICRISAT in Asia and Africa. *Current Science*, **102**, 1650–1659.
- Karnieli A., Agam N., Pinker R.T., Anderson M., Imhoff M.L., Gutman G.G., Panov N., & Goldberg A. (2010) Use of NDVI and land surface temperature for drought assessment: Merits and limitations. *Journal of Climate*, **23**, 618–633.
- Lacher T.E. (1979) Rates of growth in *Kerodon rupestris* and an assessment of its potencial as a domesticated food source. *Papéis Avulsos de Zoologia*, **33**, 67–76.
- Leal I., Silva J. DA, Tabarelli M., & Lacher T.E. (2005a) Changing the course of biodiversity conservation in the Caatinga of northeastern Brazil. *Conservation biology*, **19**, 701–706.

Leal I.R., Da Silva J.M.C., Tabarelli M., & Lacher T. (2005b) Mudando o curso da conservação da biodiversidade na Caatinga do Nordeste do Brasil. *Megadiversidade*, **1**, 7.

Lessa G., Gonçalves P.R., & Pessôa L.M. (2005) Variação geográfica em caracteres cranianos quantitativos de *Kerodon rupestris* (Wied, 1820) (Rodentia, Caviidae). *Arquivos do Museu Nacional Rio de Janeiro*, **63**, 75–88.

Lickley M. & Solomon S. (2018) Drivers, timing and some impacts of global aridity change. *Environmental Research Letters*, **13**, 104010.

Lillesand T.M., Kiefer R.W., & Chipman J.W. (2004) *Remote sensing and image interpretation*. Wiley,

Lima-Ribeiro M.S. & Diniz-filho J.A.F. (2013) *Modelos Ecológicos e a Extinção da Megafauna: Clima e Homem na América do Sul*. São Carlos: Editora Cubo.

Liu W.T. & Negrón Juárez R.I. (2001) ENSO drought onset prediction in northeast Brazil using NDVI. *International Journal of Remote Sensing*, **22**, 3483–3501.

Lu L., Ren Z., Yue Y., Yu X., Lu S., Li G., Li H., Wei J., Liu J., Mu Y., Hai R., Yang Y., Wei R., Kan B., Wang H., Wang J., Wang Z., Liu Q., & Xu J. (2016) Niche modeling predictions of the potential distribution of *Marmota himalayana*, the host animal of plague in Yushu County of Qinghai. *BMC Public Health*, **16**, 183.

Maciel J.R., Sánchez-Tapia A., Siqueira M.F. De, & Alves M. (2017) Palaeodistribution of epiphytic bromeliads points to past connections between the Atlantic and Amazon forests. *Botanical Journal of the Linnean Society*, **183**, 348–359.

Marengo J.A., Torres R.R., & Alves L.M. (2017) Drought in Northeast Brazil—past, present, and future. *Theoretical and Applied Climatology*, **129**, 1189–1200.

Mateo R.G., Felicísimo Á.M., & Muñoz J. (2010) Effects of the number of presences on reliability and stability of MARS species distribution models: the importance of regional niche variation and ecological heterogeneity. *Journal of Vegetation Science*, **21**, 908–922.

Mayaud J. & Webb N. (2017) Vegetation in Drylands: Effects on Wind Flow and Aeolian Sediment Transport. *Land*, **6**, 64.

de Melo W.A., Lima-Ribeiro M.S., Terribile L.C., & Collevatti R.G. (2016) Coalescent Simulation and Paleodistribution Modeling for *Tabebuia rosealba* Do Not Support South American Dry Forest Refugia Hypothesis. *PLOS ONE*, **11**, e0159314.

MMA/SRH M. do M.A.S. de R.H. (2004) *Programa de ação nacional de combate à desertificação e mitigação dos efeitos da seca*. Brasília.

Naimi B. & Araújo M.B. (2016) sdm: a reproducible and extensible R platform for species distribution modelling. *Ecography*, **39**, 368–375.

Nassur O.A.C., Ferreira E., Sáfyadi T., & Dantas A.A.A. (2015) Monitoramento e projeção futura da vegetação no parque nacional do Itatiaia através de sensoriamento remoto. *Cerne*, **21**, 511–517.

Neumann W., Martinuzzi S., Estes A.B., Pidgeon A.M., Dettki H., Ericsson G., & Radeloff V.C. (2015) Opportunities for the application of advanced remotely-sensed data in ecological studies of terrestrial animal movement. *Movement Ecology*, **3**, 8.

Ning T., Liu W., Lin W., & Song X. (2015) NDVI Variation and Its Responses to Climate Change on the Northern Loess Plateau of China from 1998 to 2012. *Advances in Meteorology*, **2015**, 1–10.

Oliveira G., Araújo M.B., Rangel T.F., Alagador D., & Diniz-Filho J.A.F. (2012) Conserving the Brazilian semiarid (Caatinga) biome under climate change. *Biodiversity and Conservation*, **21**, 2913–2926.

de Oliveira G., Lima-Ribeiro M.S., Terribile L.C., Dobrovolski R., Telles M.P. d. C., & Diniz-Filho J.A.F. (2015) Conservation biogeography of the Cerrado's wild edible plants under climate change: Linking biotic stability with agricultural expansion. *American Journal of Botany*, **102**, 870–877.

Oyama M.D. & Nobre C.A. (2004) Climatic consequences of a large-scale desertification in northeast Brazil: A GCM simulation study. *Journal of Climate*, **17**, 3203–3213.

Paes M.L.N. & Dias I. de F.O. (2008) *Plano de manejo: Estação Ecológica Raso da Catarina*.

Park Williams A., Allen C.D., Macalady A.K., Griffin D., Woodhouse C.A., Meko D.M., Swetnam T.W., Rauscher S.A., Seager R., Grissino-Mayer H.D., Dean J.S., Cook E.R., Gangodagamage C., Cai M., & McDowell N.G. (2013) Temperature as a potent driver of regional forest drought stress and tree mortality. *Nature Climate Change*, **3**, 292–297.

Parnesan C. (2006) Ecological and Evolutionary Responses to Recent Climate Change. *Annual Review of Ecology, Evolution, and Systematics*, **37**, 637–669.

Pearson R.G. (2006) Climate change and the migration capacity of species. *Trends in Ecology and Evolution*, **21**, 111–113.

Peterson A. (2006) Uses and requirements of ecological niche models and related distributional models. *Biodiversity Informatics*, 59–72.

Peterson A.T. & Soberón J. (2012) Species Distribution Modeling and Ecological Niche Modeling: Getting the Concepts Right. *Natureza & Conservação*, **10**, 102–107.

Ravi S., Breshears D.D., Huxman T.E., & D’Odorico P. (2010) Land degradation in drylands: Interactions among hydrologic–aeolian erosion and vegetation dynamics. *Geomorphology*, **116**, 236–245.

Rocha W.F. (2009) Situação da cobertura vegetal do bioma Caatinga. *Mudanças climáticas e desertificação no Semiárido brasileiro* (ed. by F. Angelotti, I.B. Sá, E.A. Menezes, and G.Q. (Org. . Pellegrino), pp. 77–94. Petrolina: Embrapa Semiárido; Campinas: Embrapa Informática Agropecuária,

Rodriguez-Cabal M.A. & Branch L.C. (2011) Influence of habitat factors on the distribution and abundance of a marsupial seed disperser. *Journal of Mammalogy*, **92**, 1245–1252.

Rouse J.W., Hass R.H., Schell J.A., & Deering D.W. (1972) Monitoring Vegetation Systems in the Great Plains with ERTS. *Third Earth Resources Technology Satellite-1 Symposium*,

Salazar L.F., Nobre C. a., & Oyama M.D. (2007) Climate change consequences on the biome distribution in tropical South America. *Geophysical Research Letters*, **34**, .

Santana J.J., Albuquerque J.F.G. De, Moura C.E.B. De, Costa W.P., Oliveira M.F. De,

Barreto Júnior R.A., & Miglino M.A. (2003) Origem do plexo braquial de mocós (*Kerodon rupestris* wied, 1820). *Brazilian Journal of Veterinary Research and Animal Science*, **40**, 391–396.

Santos M.G., Oliveira M.T., Figueiredo K. V., Falcão H.M., Arruda E.C.P., Almeida-Cortez J., Sampaio E.V.S.B., Ometto J.P.H.B., Menezes R.S.C., Oliveira A.F.M., Pompelli M.F., & Antonino A.C.D. (2014) Caatinga, the Brazilian dry tropical forest: can it tolerate climate changes? *Theoretical and Experimental Plant Physiology*, **26**, 83–99.

Seyffarth J.A.S. & Rodrigues V. (2017) Impactos da seca sobre a biodiversidade da Caatinga. *Parcerias Estratégicas*, **22**, 41–62.

Silva P.C.G. da, Moura M.S.B. de, Kiill L.H.P., Brito L.T. de L., Pereira L.A., Sá I.B., Correia R.C., Teixeira A.H. de C., Cunha T.J.F., & Guimarães-Filho C.G. (2010) Caracterização do Semiárido brasileiro: fatores naturais e humanos. *Semiárido brasileiro: pesquisa, desenvolvimento e inovação. Petrolina: Embrapa Semiárido, 2010.* pp. 18–48.

Sobral-Souza T., Francini R.B., & Lima-Ribeiro M.S. (2015) Species extinction risk might increase out of reserves: allowances for conservation of threatened butterfly *Actinote quadra* (Lepidoptera: Nymphalidae) under global warming. *Natureza & Conservação*, **13**, 159–165.

Terribile L.C. et al. (2012) Areas of climate stability of species ranges in the Brazilian Cerrado: disentangling uncertainties through time. *Natureza & Conservação*, **10**, 152–159.

Terribile L.C., Feitosa D.T., Pires M.G., de Almeida P.C.R., de Oliveira G., Diniz-Filho J.A.F., & Silva N.J. da (2018) Reducing Wallacean shortfalls for the coralsnakes of the *Micrurus lemniscatus* species complex: Present and future distributions under a changing climate. *PLOS ONE*, **13**, e0205164.

Thomas C.D., Cameron A., Green R.E., Bakkenes M., Beaumont L.J., Collingham Y.C., Erasmus B.F.N., de Siqueira M.F., Grainger A., Hannah L., Hughes L., Huntley B., van Jaarsveld A.S., Midgley G.F., Miles L., Ortega-Huerta M.A., Townsend Peterson A., Phillips O.L., & Williams S.E. (2004) Extinction risk from climate change. *Nature*, **427**, 145–148.

Tian M., Wang P., & Khan J. (2016) Drought Forecasting with Vegetation Temperature Condition Index Using ARIMA Models in the Guanzhong Plain. *Remote Sensing*, **8**, 690.

Torres R.R., Lapola D.M., & Gamarra N.L.R. (2017) Future Climate Change in the Caatinga. *Caatinga* pp. 383–410. Springer International Publishing, Cham.

Tucker C.J., Pinzon J.E., Brown M.E., Slayback D.A., Pak E.W., Mahoney R., Vermote E.F., & Saleous N. El (2005) An extended AVHRR 8-km NDVI dataset compatible with MODIS and SPOT vegetation NDVI data. *International Journal of Remote Sensing*, **26**, 4485–4498.

Vieira R.M. da S.P., Cunha A.P.M. do A., Alvalá R.C. dos S., Carvalho V.C., Ferraz Neto S., & Sestini M.F. (2013) Land use and land cover map of a semiarid region of Brazil for meteorological and climatic models. *Revista Brasileira de Meteorologia*, **28**, 129–138.

Wood S.N. (2006) *Generalized Additive Models: An introduction with R*. Chapman and Hall/CRC,

Yañez-Arenas C., Rioja-Nieto R., Martín G.A., Dzul-Manzanilla F., Chiappa-Carrara X., Buenfil-Ávila A., Manrique-Saide P., Correa-Morales F., Díaz-Quiñónez J.A., Pérez-Rentería C., Ordoñez-Álvarez J., Vazquez-Prokopec G., & Huerta H. (2018) Characterizing environmental suitability of *Aedes albopictus* (Diptera: Culicidae) in Mexico based on regional and global niche models. *Journal of Medical Entomology*, **55**, 69–77.

Zaitunah A., Samsuri, Ahmad A.G., & Safitri R.A. (2018) Normalized difference vegetation index (ndvi) analysis for land cover types using landsat 8 oli in besitang watershed, Indonesia. *IOP Conference Series: Earth and Environmental Science*, **126**, 012112.

Zhou L., Tucker C.J., Kaufmann R.K., Slayback D., Shabanov N. V., & Myneni R.B. (2001) Variations in northern vegetation activity inferred from satellite data of vegetation index during 1981 to 1999. *Journal of Geophysical Research: Atmospheres*, **106**, 20069–20083.

## Conclusão geral

Nós demonstramos pela metanálise que apesar da lacuna de informações sobre o registro das espécies em ambientes áridos e semiáridos no mundo, há possibilidade de as espécies desses ecossistemas perderem áreas climáticas favoráveis no futuro. Isso foi observado considerando apenas as variáveis climáticas. Entretanto, quando desenvolvemos valores que podem substituir a cobertura vegetal por meio de séries históricas de NDVI, as áreas mais propícias à períodos de seca e até mesmo que podem mais susceptíveis à desertificação, poderão ser mapeadas e com isso, serem integradas em avaliações futuras sobre a vulnerabilidade das espécies às mudanças climáticas.

O uso do modelo ARIMA para estimar o NDVI teve bom desempenho e pode aprimorado em diferentes escalas e resoluções mais finas, podendo tornar as investigações mais eficientes ainda. Em espécies endêmicas do semiárido brasileiro foi averiguada a diferença das predições ao utilizar os valores de NDVI. Portanto, para a criação de estratégias de conservação da biodiversidade, acreditamos que esse novo recurso poderá ser promissor. Além disso, os valores futuros estimados de NDVI poderão ser utilizados em diversas áreas de pesquisa, principalmente as que envolvam a manutenção dos recursos naturais do semiárido, sendo a cobertura vegetal de grande importância para proteção de diversos serviços ecossistêmicos fornecidos por esse ambiente à população.

Pela disponibilidade global de banco de dados de NDVI, esses estudos poderão ser estendidos para diversas regiões áridas e semiáridas do mundo.