

Métodos em Herpetologia

BOAS PRÁTICAS NA ANÁLISE DE SÉRIES TEMPORAIS EM HERPETOLOGIA

Karoline Ceron^{1*}, Marcos R. Severgnini¹ & Diogo B. Provete^{1,2}

1 Pós-Graduação em Ecologia e Conservação, Instituto de Biociências, Universidade Federal de Mato Grosso do Sul, Cidade Universitária, 79070-900, Campo Grande, MS, Brasil.

2 Gothenburg Global Biodiversity Centre, Box 461, SE-405 30, Göteborg, Sweden.

* Corresponding author: adenomera@gmail.com

O tempo pode ser considerado um recurso, assim como um eixo do nicho (Post, 2019). Enquanto recurso, ele influencia a distribuição das espécies, já que a escolha de quando se reproduzir é crucial para o desempenho (*fitness*, Cayuela et al., 2014). Os processos envolvidos na mudança na abundância das espécies dependem da extensão espacial e temporal dos dados. Diferenças na abundância ou atividade das espécies ao longo do tempo podem gerar efeitos de prioridade e outros tipos de processos dependentes do tempo que afetam o resultado das interações entre as espécies. As regras de montagem das comunidades podem ser uma consequência de tais eventos de curto prazo, na medida em que a ordem de chegada das espécies nas comunidades influencia a estrutura da comunidade. Outras

regras de montagem podem não ter uma dependência temporal explícita, mas refletir diferenças na capacidade competitiva, diferenças na resistência à predação ou tendências das espécies de ocorrerem em comunidades diferentes (Morin, 2011). Apesar dos processos temporais serem importantes na ecologia, eles têm sido menos explorados do que os espaciais (Magurran, 2011), pois demandam maior esforço amostral por um longo período de tempo, o que torna essa abordagem limitada.

As mudanças temporais (*temporal turnover*) na composição de espécies em comunidades ecológicas – resultado da imigração, extinção local, assim como a variação da abundância das espécies residentes ao longo do tempo – é relacionada a inúmeros fenômenos, tais como competição, predação e dinâmicas populacionais (Magurran, 2011;

Leibold & Chase, 2018). Essas mudanças nas comunidades podem ocorrer de duas formas: a primeira é quando a comunidade se move de um estado para outro. Essa alteração direcional geralmente ocorre após distúrbios, poluição ou invasão de espécies que modificam a estrutura da comunidade. Por exemplo, a introdução do anuro exótico *Lithobates catesbeianus* pode modificar, mesmo que sutilmente, a temporada de reprodução dos anuros nativos, uma vez que a espécie exótica é maior, territorial e um predador voraz (Both & Grant, 2012, Leivas et al., 2012). A segunda é quando uma comunidade sofre uma mudança não-direcional, ou seja, uma variação natural na estrutura da comunidade ao longo do tempo sem um gradiente ou direção (Legendre & Gauthier, 2014). Por exemplo, causada por deriva ecológica que altera a abundância das espécies ao longo do tempo via estocasticidade demográfica (Velend, 2016).

Em geral, a distribuição da abundância e riqueza de anfíbios e répteis ao longo do ano é sazonal devido à influência das condições abióticas na atividade reprodutiva das espécies, tais como precipitação, temperatura e umidade (Aichinger, 1987). Consequentemente, um objetivo comum de estudos herpetológicos, especialmente nos Trópicos (revisados em Wells, 2007), é relacionar a incidência, riqueza e/ou abundância das espécies às variáveis abióticas locais (e.g., Bertoluci & Rodrigues,

2002; Kopp & Eterovick, 2006; Both et al., 2008; Ceron et al., 2020). No entanto, é comum encontrarmos análises empregadas de maneira errônea, seja aplicando métodos inadequados para o conjunto de dados ou violando as premissas dos métodos, principalmente na avaliação de dinâmicas temporais.

Neste artigo apresentamos vários métodos para lidar com dados temporalmente autocorrelacionados. Em seguida, demonstramos como utilizá-los de maneira correta. Apresentaremos métodos para lidar com dados univariados de riqueza, abundância, frequência, incluindo a estatística circular (Teste de Rayleigh) e modelos lineares (GLS - *generalized least squares* e GAMM - *Generalized Additive Mixed-effects Models*) (Fig. 1-2). Quando a variável de interesse é multivariada, tal como uma matriz de composição de espécies (locais por espécies) falaremos sobre o teste de *Space-time interaction*, STATICO (*STATIS* e *CO-inertia analysis*) e os mapas de autovetores assimétricos (*Asymmetric Eigenvectors Maps* - AEM) e para os modelos de previsão a Média Móvel Integrada AutoRegressiva sem (*AutoRegressive Integrated Moving Average* - ARIMA) e com sazonalidade (SARIMA) (Fig. 1-2). Mas antes, vamos entender por que correlações lineares simples não são adequadas para lidar com dados temporalmente autocorrelacionados (veja também Ives & Zhu, 2006).

Entendendo a autocorrelação temporal

Os coeficientes de correlação indicam o grau de associação entre duas variáveis aleatórias. Por ser uma padronização da covariância, seus valores variam entre -1 e 1. Uma correlação igual a 1 indica perfeita relação linear positiva entre as variáveis (quando uma variável aumenta a outra aumenta na mesma direção) e a correlação -1 indica uma perfeita associação linear negativa (quando uma variável aumenta a outra diminui) (Quinn & Keough, 2002; Fujita et al., 2009). A correlação de Pearson indica o grau de associação linear entre duas variáveis aleatórias quantitativas que apresentam distribuições normal ou Gaussiana, sem, no entanto, assumir uma relação de dependência entre elas. Quando essa premissa é rompida, ou seja, quando os dados não têm distribuição normal, uma alternativa é utilizar a correlação não-paramétrica de Spearman (Restrepo & González, 2007).

Entretanto, a maioria dos testes utilizados para inferência estatística assumem independência entre as amostras, ou seja, uma unidade amostral não pode estar relacionada com outra. Essa dependência entre unidades amostrais é comum em dados coletados ao longo do tempo ou do espaço (Ives & Zhu, 2006), o que impede a utilização dos coeficientes de correlação quando o objetivo é explicar uma variável em função de outra(s), sob o risco de aumentar o

Erro Tipo I. Por exemplo, se estivermos interessados em testar o efeito da temperatura sobre a riqueza de espécies e registrarmos quantas espécies de anfíbios vocalizam e a temperatura do ar em cada mês, a unidade amostral neste caso é o mês. Porém, se observarmos a distribuição da temperatura durante um ano, vemos que os valores de temperatura são mais parecidos entre si em meses próximos um do outro, digamos, janeiro e fevereiro, do que entre meses distantes, janeiro e julho. Essa é a definição de autocorrelação temporal. Consequentemente, os meses não são independentes entre si, o que viola um dos pressupostos de modelos lineares (definidos pelo Teorema de Gauss-Markov) e de correlações. Como vimos acima, dados autocorrelacionados temporalmente rompem este pressuposto e nos impedem de utilizar métodos comumente aplicados, tais como regressão ou correlação linear simples. Neste caso temos de utilizar métodos que nos permitem modelar explicitamente a matriz de variância-covariância dos resíduos.

Modelos de previsão

O modelo de previsão tem como objetivo prever como um determinado conjunto de dados irá se comportar no futuro a partir da análise do passado. Por exemplo, temos dados da abundância relativa mensal de girinos em uma poça permanente entre 2000 e 2003 e gos-

taríamos de prever o valor da abundância no futuro (Fig. 2). Tais previsões serão obtidas a partir de um modelo que captura a estrutura de dependência na série estudada. Um desses modelos é o ARIMA, cuja sigla significa *AutoRegressive Integrated Moving Average* (Média Móvel Integrada AutoRegressiva). Os modelos ARIMA são a classe mais geral de modelos para prever uma série temporal que pode ser estacionária, utilizando dados passados para prever o futuro através de dois recursos principais: a autocorrelação e médias móveis.

Uma variável aleatória de uma série temporal é estacionária se todas as suas propriedades estatísticas forem constantes ao longo do tempo. Uma série estacionária não tem tendência, suas variações em torno da média tem uma amplitude constante e oscilam de maneira consistente, ou seja, seus padrões de tempo aleatório de curto prazo sempre parecem os mesmos (Nau, 2020). Uma variável aleatória pode ser vista como uma combinação de sinal e ruído. O modelo ARIMA pode ser visto como um filtro que separa o sinal do ruído e, em seguida, o sinal é extrapolado para o futuro para obter previsões (Nau, 2020). O modelo ARIMA é composto por três parâmetros principais: “*p*” (representado pelas letras AR na sigla), “*d*” (representado pela letra I) e “*q*” (representado pelas letras MA). *p* significa o número de valores *x* adiantados/atrasados que devem ser adicionados ou subtraídos de *x* no modelo, de modo a fazer melhores

previsões com base em períodos de crescimento/declínio dos dados. Isso captura a natureza auto-regressiva do ARIMA. *d* representa o número de vezes em que os dados precisam ser diferenciados para produzir um sinal estacionário. Isso captura a natureza integrada do ARIMA. Se *d* = 0, nossos dados não tendem a variar a longo prazo (ou seja, o modelo se torna estacionário). Nesse caso, o modelo se resume ao ARMA, pois apenas os parâmetros *p* e *q* variam livremente. Se *p*=1, os dados estão variando linearmente. Se *p* = 2, os dados estão variando exponencialmente. *q* representa o número de valores adiantados/atrasados para o termo de erro que são adicionados/subtraídos a *x*. Isso captura a parte da média móvel do ARIMA (Hyndman & Khandakar, 2008). Quando uma série não é estacionária, a mesma pode apresentar um padrão sazonal, com padrão cíclico e periódico, comum em dados de riqueza e abundância da herpetofauna coletados ao longo de anos. Para prever o comportamento de uma série temporal sazonal devemos utilizar o modelo SARIMA, que é basicamente, o ARIMA formado pela inclusão de termos sazonais (o parâmetro *d*; Hyndman & Athanasopoulos, 2018). Todos estes modelos de previsão podem ser incluídos em exercícios de modelagem que tenham como objetivo relacionar variáveis preditoras com uma variável resposta, considerando a dependência temporal, tais como GLS ou GAMM (veja abaixo) para modelar a matriz de variância-covariância dos resíduos.

Métodos univariados

O modelo de mínimos quadrados generalizados (GLS - *generalized least squares*) estende a estimativa dos mínimos quadrados ordinários (OLS), onde podemos explicitamente indicar a autocorrelação dos dados. Portanto, este método é adequado quando trabalhamos com séries temporais, onde os resíduos não são independentes (Ives & Zhu, 2006; Fox & Weisberg, 2018). No entanto, como são mínimos quadrados, este método ainda assume que a variável resposta seja normalmente distribuída (Zuur et al., 2009).

Por exemplo, temos uma série temporal com dados de altura de empoleiramento de lagartos e dados abióticos de temperatura, precipitação e umidade para um local amostrado e gostaríamos de saber se há uma relação direta entre os dados abióticos e a altura de empoleiramento registrada (Fig. 2). Para utilizar o GLS devemos formular um modelo específico que inclui a estrutura de variância-covariância dos erros, além da relação esperada entre a(s) variável(is) preditor(a)s e a variável resposta. Existem algumas opções de estruturas de correlações para dados autocorrelacionados temporalmente derivados de modelos de previsão (e.g., corAR1, corARMA, corCAR1 etc.). Tais estruturas diferem basicamente nos intervalos de tempo da série, que podem ser igualmente espaçados (corAR1), desigualmente espaçados (corCAR1)

ou dinâmicos (corARMA). Assim, você pode criar vários modelos, variando a estrutura de correlação, e ver qual melhor se ajusta aos seus dados. Para fazer isso utilizamos uma seleção de modelos utilizando o Critério de Informação de Akaike (AIC) (Burnham & Anderson 2002; Mazerolle 2006). O AIC mede o ajuste do modelo aos dados com uma função de verossimilhança e introduz um fator de correção que penaliza o modelo pelo número de parâmetros (Turkman & Silva, 2000). Assim, o AIC faz uma estimativa da distância relativa entre o modelo ajustado e os valores observados, permitindo uma otimização entre poder explicativo e número de parâmetros (Burnham & Anderson, 2002).

Quando a variável resposta é um dado de contagem (e.g., abundância) ou frequência (e.g., frequência de ocorrência) brutos (sem transformação), o GLS já não é o método mais adequado, já que permite apenas modelar dados com distribuição Gaussiana. Nestes casos, o método mais adequado são GAMM (modelos aditivos generalizados de efeito misto, *Generalized Additive Mixed-effects Model*). O principal aspecto deste modelo é o fato dele ser “aditivo”. O GAMM é uma extensão do Modelo Linear Generalizado (GLM; Zuur et al., 2009), em que podemos ajustar diferentes distribuições de frequência de acordo com o tipo de variável resposta (e.g., Poisson ou binomial negativa para dados de contagem, bino-

mial para dados de incidência etc.). No entanto, o GAMM difere do GLM em dois importantes aspectos. Um deles é que o GAMM permite que modelemos a variável resposta de acordo com funções *smooth*. Em outras palavras, o método permite modelar a variável resposta por variáveis independentes sem necessariamente assumir uma relação a priori entre elas. Os *smooth* são funções reais definidas por funções polinomiais (funções básicas). Consequentemente, um modelo aditivo generalizado não assume linearidade entre as variáveis, ao contrário, diferentes parâmetros (tensores) suavizam uma curva para adequar o modelo aos dados. Um outro aspecto do GAMM que o distingue do GLM é a possibilidade de incluir estruturas de correlação (e.g., *corAR1*, *corARMA*) para modelar a dependência nos resíduos (Wood, 2017), seja ela devido à dependência temporal ou espacial entre unidades amostrais. No entanto, é preciso cautela com o uso exagerado de parâmetros do modelo (“over parameterization”). Modelos com estruturas de correlação mais complexas podem descrever melhor a autocorrelação nos resíduos, porém o excesso de parâmetros pode interferir nas estimativas dos parâmetros do modelo (Zuur et al., 2009). Para evitar isso, podemos utilizar o Critério de Informação de Akaike (AIC) para escolher entre estruturas de correlação alternativas (veja exemplos em Zuur et al., 2009).

Além da característica de autocorrelação, séries temporais podem apresentar outra característica: a sazonalidade. Nos Trópicos, geralmente a distribuição dos anuros é bastante sazonal, com a maior abundância e riqueza concentradas na época mais quente e úmida do ano (e.g. Prado et al., 2005; Ceron et al., 2020). Por exemplo, temos dados de abundância mensal de anuros ao longo de um ano e queremos testar se a abundância de espécies apresenta um padrão sazonal (Fig. 2). Podemos testar essa hipótese através do teste de Rayleigh, um tipo de análise circular. A estatística circular utiliza ângulos para distribuir os dados em um círculo completo de 360°. A partir disso, testa-se se os dados estão distribuídos de maneira aleatória ou concentrados em alguma região do círculo. A estatística do teste de Rayleigh é derivada do comprimento médio resultante (r), que é uma medida da concentração dos dados em torno de um círculo. O teste de Rayleigh (Zar, 2010) é um teste paramétrico, e sua derivação original envolvia a suposição de que, se houvesse um desvio da uniformidade, esse desvio seria aproximado pela distribuição de von Mises. Assim, a principal premissa do teste é que os dados apresentam a distribuição de von Mises, que é análoga à distribuição normal em dados circulares (Landler et al., 2018).

Métodos multivariados

Ecólogos e zoólogos frequentemente realizam amostragem de espécies em comunidades repetidamente ao longo do tempo, seja para monitoramento ambiental ou para testar hipóteses ecológicas por trás das modificações ambientais. Uma pergunta comum desse tipo de estudo é se existe diferença na composição de espécies entre locais ao longo do tempo. Mas comumente essa amostragem dura um curto período de tempo, não permitindo que utilizemos métodos para modelar séries temporais longas. Os fenômenos de curto prazo incluem padrões sazonais que se tornam aparentes ao longo de dias ou meses, já as séries de longo prazo podem exigir décadas a séculos para ocorrer (Morin, 2011). Em casos de amostragens de vários locais com poucas réplicas no tempo, uma alternativa seria utilizar uma análise de *space-time interaction* (Legendre et al., 2010). Esta análise permite testar se existe uma estrutura espacial na composição de espécies ou mesmo se a mudança ao longo do tempo na composição de espécies não é a mesma em todos os locais. Por exemplo, temos dados de abundância ou incidência mensal de anuros em dez comunidades ao longo de um ano (série curta) e gostaríamos de testar se existe diferença na composição de espécies ao longo dos meses nas comunidades (Fig. 2). Neste sentido, uma interação entre a estrutura espacial e temporal da comunidade pode indicar

que a composição de espécies muda em função do tempo, ou mesmo que a diferença da composição no tempo não é a mesma em todos os locais (Legendre et al., 2010). Para isso, a análise descreve o espaço (cada bloco de localidades) e o tempo (cada evento de amostragem) usando contrastes de Helmert (+1, -1) e representa a interação entre espaço e tempo usando uma técnica multivariada chamada *distance-based Moran Eigenvector Maps* (dbMEMs). Para testar então o efeito de cada fator e a interação entre eles implementa uma análise de variância fatorial (two-way ANOVA) (Legendre et al., 2010).

Com um objetivo semelhante de testar a estabilidade temporal em dados multivariados de composição de espécies (matriz local por espécie), o Índice de Diversidade Beta Temporal (*Temporal Beta diversity Index* - TBI) proposto por Legendre (2019) permite testar se há diferença na dissimilaridade de composição de espécies de um local entre dois períodos de tempo (T1 e T2). Ainda, este método permite analisar e plotar quais espécies foram adicionadas ou perdidas na comunidade ao longo do tempo. Ao invés da identidade taxonômica da espécie, também é possível testar diferenças temporais em atributos funcionais.

Assim como analisamos o efeito de variáveis climáticas na riqueza ou abundância de espécies, também podemos utilizar métodos multivariados para

analisar como a composição de espécies (matriz espécie por local) muda ao longo do tempo em função de variáveis ambientais. Para testar essas perguntas podemos usar um método chamado STATICO (Thioulouse et al., 2004). Este método realiza uma ordenação do conjunto de matrizes pareadas para indicar mudanças espaço-temporais das relações entre a composição de espécies e variáveis ambientais (Thioulouse, 2011). Por exemplo, temos dados de abundância e riqueza mensal de anuros em comunidades ao longo de um ano e dados das variáveis abióticas como temperatura, umidade e precipitação dos mesmos locais nos mesmos dias amostrados. A partir disso, gostaríamos de saber se a relação entre a composição de espécies e o ambiente muda ao longo do tempo (Fig. 2). A análise se dá em três estágios: a) a primeira etapa consiste em analisar cada matriz com uma ordenação irrestrita (ou análise de fator) (*one-table method*), que pode ser uma análise de componentes principais (PCA) para os dados ambientais ou uma análise de correspondência (CA) para a matriz das espécies; b) depois, em cada par de tabelas é empregada a análise de *Co-inertia* (Dolédec & Chessel, 1994; Dray et al., 2003), que é um método de junção de duas matrizes, permitindo que uma matriz cruzada seja calculada entre as variáveis das duas matrizes (entre composição de espécies e variáveis ambientais); c) por último uma análise triádica parcial (*Partial Triadic*

Analysis, Thioulouse & Chessel, 1987) é usada para analisar a sequência pareada de matrizes. Como resultado, o STATICO retorna três gráficos: o primeiro demonstra a semelhança entre cada par de matrizes e exibe para cada estação/ano/mês (dependendo da unidade temporal utilizada) a semelhança entre as variáveis ambientais, as espécies e os locais estudados. O segundo é a ordenação das variáveis ambientais e das espécies num espaço reduzido, indicando a relação espaço-ambiente, e o terceiro mapeia a trajetória das espécies e das variáveis ambientais em cada estação/ano/mês a fim de resumir a estrutura das matrizes cruzadas (Ceron et al., 2020).

Se você estiver interessado em incorporar a dependência temporal entre as unidades amostrais para utilizar em métodos tanto univariados quanto multivariados você pode construir mapas de autovetores assimétricos (*Asymmetric Eigenvector Maps* - AEM). Este método foi desenvolvido originalmente para modelar relações espaciais geradas por um processo físico direcional, por exemplo, dispersão de populações ao longo da correnteza de rios, correntes de vento nas montanhas e glaciações em escalas de tempo históricas (Legendre & Gauthier, 2014). No entanto, os AEMs também são adequados para a análise de séries temporais porque os processos associados ao tempo são direcionais: ontem sempre vem antes do hoje, que vem antes do amanhã

(Borcard et al., 2018). Por exemplo, podemos analisar dados de abundância mensal de serpentes em uma comunidade ao longo de um ano e perguntar se há um padrão temporal da abundância. O cálculo do AEM é simples. Inicialmente se constrói uma matriz *E* representando um grafo com nós (horas ou locais) como as linhas e as arestas (conexões direcionais entre nós) como as colunas. Para cada nó, a matriz *E* lista as arestas que estão no caminho que liga esse nó ao ponto de origem do processo (simbolizado por *O*). Quando uma aresta liga um nó a outro na direção da origem *O*, é codificada 1; caso contrário, essa aresta representa um segmento que não contribui para o nó e é codificado como 0. Quando há informações disponíveis sobre a força das conexões, as arestas podem ser ponderadas. Na análise AEM, os pesos representam a facilidade de ligação entre dois nós, já que as conexões não operacionais possuem peso 0. A matriz *E* dos nós pelas bordas é então decomposta em uma análise de componentes principais (PCA) ou decomposição de valor singular (SVD) para obter os autovetores e autovalores respectivos. Como todos os autovalores são positivos, o *I* de Moran de correlação temporal pode ser calculado para cada autovetor para avaliar se ele modela uma autocorrelação positiva ou negativa (Legendre & Gauthier, 2014; Borcard et al., 2018).

Conclusão

Aqui descrevemos uma série de métodos que permitem analisar dados temporalmente autocorrelacionados, sejam eles uni- ou multivariados. Esperamos que o leitor tenha entendido por que utilizar uma correlação de Spearman para testar a influência da temperatura ou umidade na riqueza ou abundância de anuros ou répteis é inadequado e possa encontrar um caminho melhor para responder às suas questões por meio destes métodos acima. Para auxiliá-lo a encontrar o melhor método criamos uma árvore de decisão (Fig. 1) e também um esquema que mostra como preparar os dados para entrar nos métodos discutidos (Fig. 2). Além disso, fornecemos juntamente com o texto um passo-a-passo para realizar análises circulares no programa ORIANA e também uma página da internet com a descrição dos métodos e exemplos de análise no R (Provete & Melo, 2002; <https://github.com/karolceron/tutorial>).

Agradecimentos

KC é grata à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior — Brasil (CAPES) — Finance Code 001 por sua bolsa de estudos.

Referências

- Aichinger M. 1987. Annual activity patterns of anurans in a seasonal neotropical environment. *Oecologia* 71:583–592.
- Bertoluci J., Rodrigues M.T. 2002. Utilização de habitats reprodutivos e micro-habitats de vocalização em uma taxocenose de anuros (Amphibia) da Mata Atlântica do sudeste do Brasil. *Papéis Avulsos de Zoologia* 42:287–297.
- Borcard, D., Gillet F., Legendre P. 2018. Numerical ecology with R. Springer, New York.
- Both C., Kaefer I.L., Santos T.G., Cechin S.T.Z. 2008. An austral anuran assemblage in the Neotropics: seasonal occurrence correlated with photoperiod. *Journal of Natural History* 42:205–222.
- Both C., Grant T. 2012. Biological invasions and the acoustic niche: the effect of bullfrog calls on the acoustic signals of white-banded tree frogs. *Biology Letters* 8:714–716.
- Burnham K.P., Anderson D.R. 2002. Model selection and multimodel inference: a practical information-theoretic approach. Springer Science & Business Media, New York.
- Cayuela H., Besnard A., Bonnaire E., Perret H., Rivoalen J., Miaud C., Joly P. 2014. To breed or not to breed: past reproductive status and environmental cues drive current breeding decisions in a long-lived amphibian. *Oecologia* 176:107–116.
- Ceron K., Santana D.J., Lucas E.M., Zocche J.J., Provete D.B. 2020. Climatic variables influence the temporal dynamics of an anuran metacommunity in a nonstationary way. *Ecology and Evolution* 10:4630–4639. doi:<https://doi.org/10.1002/ece3.6217>.
- Dolédec S., Chessel D. 1994. Co-inertia analysis: an alternative method for studying species–environment relationships. *Freshwater Biology* 31:277–294.
- Dray S., Chessel D., Thioulouse J. 2003. Co-inertia analysis and the linking of ecological data tables. *Ecology* 84:3078–3089.
- Fox J., Weisberg S. 2018. An R companion to applied regression. Sage publications, USA.
- Fujita A., Sato J.R., Demasi M.A.A., Sogayar M.C., Ferreira C.E., Miyano S. 2009. Comparing Pearson, Spearman and Hoeffding's D measure for gene expression association analysis. *Journal of Bioinformatics and Computational Biology* 7:663–684.
- Hyndman R.J., Athanasopoulos G. 2018. Forecasting: principles and practice. OTexts, USA.

- Hyndman R.J., Khandakar Y. 2008. Automatic Time Series Forecasting: The forecast Package for R. Monash University, Department of Econometrics and Business Statistics, Australia.
- Ives A.R., Zhu J. 2006. Statistics for correlated data: phylogenies, space, and time. *Ecological Applications* 16:20–32.
- Kopp K., Eterovick P.C. 2006. Factors influencing spatial and temporal structure of frog assemblages at ponds in southeastern Brazil. *Journal of Natural History* 40:1813–1830. doi:<https://doi.org/10.1080/00222930601017403>
- Landler L., Ruxton G.D., Malkemper E.P. 2018. Circular data in biology: advice for effectively implementing statistical procedures. *Behavioral Ecology and Sociobiology* 72:128. doi:<https://doi.org/10.1007/s00265-018-2538-y>
- Leibold M.A., Chase J.M. 2018. Metacommunity ecology. Princeton, Princeton University Press.
- Leivas P.T., Leivas F.W.T., Moura M. 2012. Diet and trophic niche of *Lithobates catesbeianus* (Amphibia:Anura). *Zoologia* 29:405–412. doi:<https://doi.org/10.1590/S1984-46702012000500003>
- Legendre P., Cáceres M.D., Borcard D. 2010. Community surveys through space and time: testing the space–time interaction in the absence of replication. *Ecology* 91:262–272. doi:<https://doi.org/10.1890/09-0199.1>
- Legendre P., Gauthier O. 2014. Statistical methods for temporal and space-time analysis of community composition data. *Proceedings of the Royal Society B* 281:20132728. doi:<https://doi.org/10.1098/rspb.2013.2728>
- Legendre P. 2019. A temporal beta-diversity index to identify sites that have changed in exceptional ways in space–time surveys. *Ecology and Evolution* 9:3500–3514. doi:<https://doi.org/10.1002/ece3.4984>
- Magurran A. 2011. Measuring biological diversity in time (and space). Pp 85–93, in Magurran A, McGill B. (Eds), *Biological diversity: frontiers in measurement and assessment*. Oxford, New York.
- Mazerolle M. 2006. Improving data analysis in herpetology: using Akaike’s Information Criterion (AIC) to assess the strength of biological hypotheses. *Amphibia-Reptilia* 27:169–180.
- Morin P.J. 2011. *Community ecology*. John Wiley & Sons, New Jersey.
- Nau R. 2020. Statistical forecasting: notes on regression and time series analysis. Available at: <https://people.duke.edu/~rnau/411home.htm> [Accessed June 2, 2020].

- Post E. 2019. Time in Ecology. Princeton University Press, New Jersey.
- Prado C.P.A., Uetanabaro M., Haddad C.F.B. 2005. Breeding activity patterns, reproductive modes, and habitat use by anurans (Amphibia) in a seasonal environment in the Pantanal, Brazil. *Amphibia-Reptilia* 26:211–221. doi:<https://doi.org/10.1163/1568538054253375>
- Provete D.B., Melo A.S. 2012. O Programa R e suas aplicações em Herpetologia. *Herpetologia Brasileira* 1:15–17.
- Quinn, G.P., M. J. Keough. 2002. Experimental design and data analysis for biologists. Cambridge University Press, UK.
- Restrepo L.F., González J. 2007. From Pearson to Spearman. *Revista Colombiana de Ciencias Pecuarias* 20:183–192.
- Thioulouse J. 2011. Simultaneous analysis of a sequence of paired ecological tables: A comparison of several methods. *The Annals of Applied Statistics* 5:2300–2325.
- Thioulouse J., Chessel D. 1987. Les analyses multitableaux en écologie factorielle. I. De la typologie d'état à la typologie de fonctionnement par l'analyse triadique. *Acta Oecologica Oecologia Gen.* 8:463–480.
- Thioulouse, J., Simier M., Chessel D. 2004. Simultaneous analysis of a sequence of paired ecological tables. *Ecology* 85:272–283. doi:<https://doi.org/10.1890/02-0605>
- Turkman M., Silva G. 2000. Modelos Lineares Generalizados-da teoria à prática. SPE Edition, Lisboa.
- Vellend M. 2016. The Theory of Ecological Communities. Princeton University Press, Princeton.
- Wells K.D. 2007. The ecology and behavior of amphibians. University of Chicago Press, Chicago.
- Wood S.N. 2017. Generalized additive models: an introduction with R. CRC press, United Kingdom.
- Zar J. 2010. Biostatistical Analysis. Prentice Hall, New Jersey.
- Zuur A., Ieno E.N., Walker N., Saveliev A.A., Smith G.M. 2009. Mixed effects models and extensions in ecology with R. Springer Science & Business Media, United Kingdom.

Editor: Alexandro Tozetti

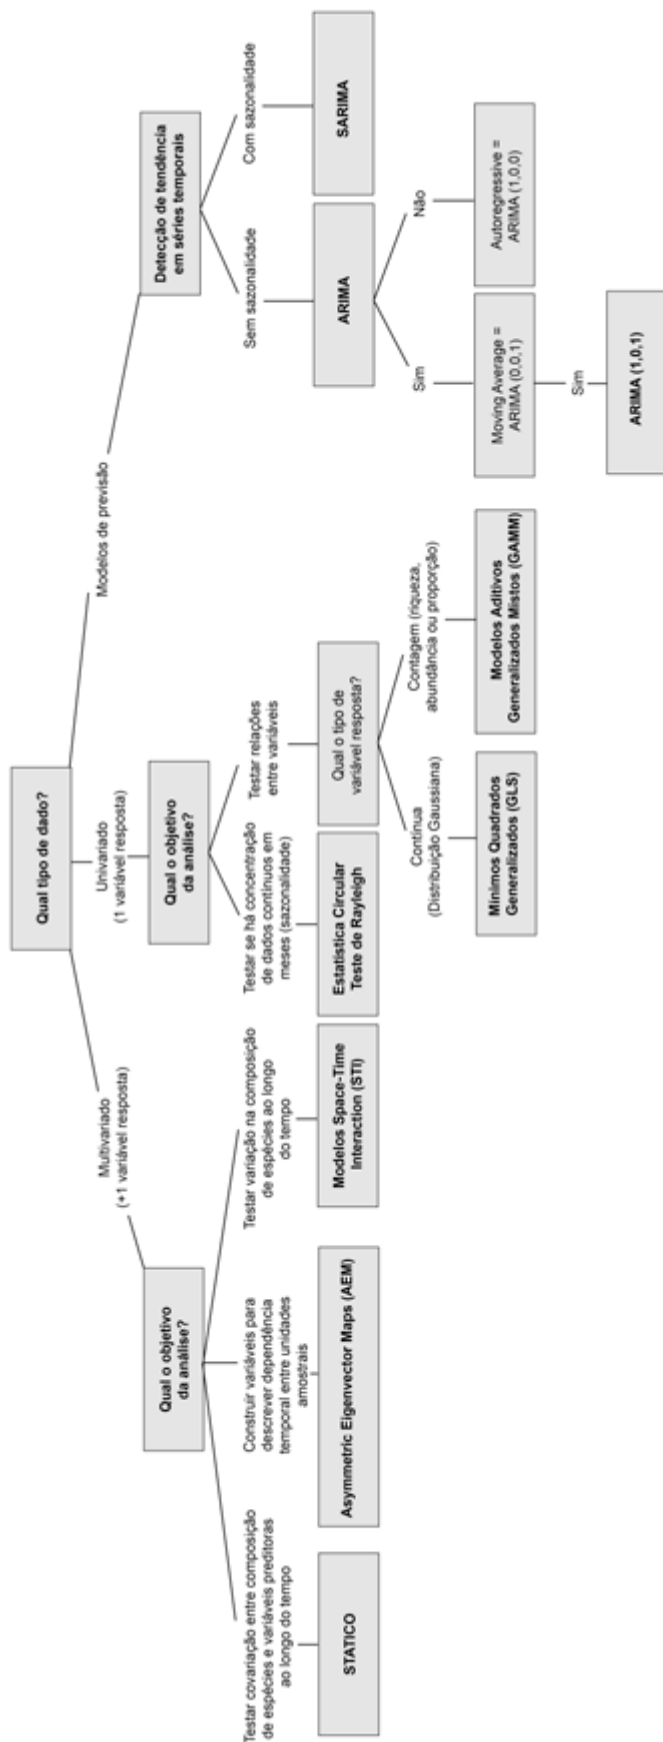


Figura 1. Árvore de decisão para a análise de séries temporais incluindo dados univariados, multivariados e modelos de previsão.

Univariado (1 variável resposta)

GAMM (dados de contagem ou proporção)

Amostra	Precipitação	Umidade	Temperatura	Abundância ou Riqueza
1	10	40	33	20
2	0	30	36	27
3	15	60	29	25
4	5	40	30	37

GLS (distribuição Gaussiana)

Amostra	Precipitação	Umidade	Temperatura	Altura
1	10	40	33	10
2	0	30	36	30
3	15	60	29	15
4	5	40	30	5

Teste de Rayleigh

Data	Abundância ou Riqueza
01/02/2020	20
01/03/2020	27
01/04/2020	25
01/05/2020	37

Modelos de previsão

ARIMA e SARIMA

Ano	Jan	Fev	Mar
2000	15	5	1
2001	9	7	5
2002	10	14	5
2003	5	7	9

Multivariado (+1 variável resposta)

Space-time interaction

Local	Tempo	Sp1	Sp2	Sp3
1	1	0	2	4
2	1	1	2	3
1	2	1	5	2
2	2	6	4	2

AEM

Data	Tempo	Sp1	Sp2	Sp3
01/02/2020	1	0	2	4
01/03/2020	2	1	2	3
01/04/2020	3	1	5	2
01/05/2020	4	6	4	2

STATICO

Local	Estação	Local	Mês	Sp1	Sp2	Sp3
1	Verão	1	1	0	2	4
2	Verão	2	1	1	2	3
1	Primavera	1	2	1	5	2
2	Primavera	2	2	6	4	2

Local	Mês	Precipitação	Umidade	Temperatura
1	Verão1	10	40	33
2	Verão1	0	30	36
1	Verão2	15	60	29
2	Verão2	5	40	30
1	Primavera1	15	60	29
2	Primavera1	5	40	30
1	Primavera2	0	30	36
2	Primavera2	10	40	33

Figura 2. Exemplos de entrada de dados de séries temporais para cada análise exemplificada no manuscrito.