

MODELAGEM DA ESTRUTURA TEMPORAL DE CAPTURAS INCIDENTAIS EM PESCARIAS COMERCIAIS ATRAVÉS DE MODELOS HIERÁRQUICOS BAYESIANOS

Fernando Pol MAYER^{1,3}

Rodrigo SANT'ANA²

Paulo Justiniano RIBEIRO JUNIOR³

- RESUMO: Em pescarias comerciais, frequentemente ocorrem capturas de espécies que não são o alvo principal, denominadas de “captura incidental”. No oceano Atlântico, o agulhão-negro (*Makaira nigricans*) é capturado incidentalmente por embarcações que utilizam o espinhel de superfície como artefato de pesca, tendo como alvo os atuns e o espadarte. A análise dos padrões temporais de captura desta espécie em um contexto histórico, pode auxiliar nas decisões para o manejo pesqueiro. O objetivo deste trabalho é construir, avaliar e comparar modelos que descrevam esta estrutura de dependência temporal das capturas do agulhão-negro. Para isso, foram utilizados modelos hierárquicos bayesianos com estrutura gaussiana latente para modelar a captura (em número) dos agulhões capturados no Atlântico sul pela frota do Japão no período 1970–2009. Foram considerados componentes de tendência temporal, assumindo os modelos de passeio aleatório (RW) e autoregressivos (AR), além de um componente sazonal para os trimestres. Os parâmetros foram estimados através de inferência bayesiana, utilizando o método de integração aproximada aninhada de Laplace (INLA). A distribuição mais apropriada aos dados foi a binomial negativa, já que observou-se superdispersão em relação à distribuição de Poisson. O modelo temporal mais adequado foi o autoregressivo de ordem 10, AR(10). O efeito da tendência temporal foi mais pronunciado do que o efeito da sazonalidade. A inferência realizada através do método INLA demonstrou ser uma alternativa efetiva para o uso em grandes bases de dados, como a utilizada neste trabalho.

¹Universidade Federal do Paraná - UFPR, Departamento de Estatística, Caixa Postal 19.081, CEP: 81531-980, Curitiba, PR, Brasil. Universidade de São Paulo - USP, Escola Superior de Agricultura “Luiz de Queiroz”, Programa de Pós-Graduação em Estatística e Experimentação Agronômica, CEP: 13418-900, Piracicaba, SP, Brasil. E-mail: fernandomayer@gmail.com

²Universidade do Vale do Itajaí - UNIVALI, Escola do Mar, Laboratório de Estudos Marinhos Aplicados, CEP: 88302-901, Itajaí, SC, Brasil. E-mail: rsantana@univali.br

³Universidade Federal do Paraná - UFPR, Departamento de Estatística, Caixa Postal 19.081, CEP: 81531-980, Curitiba, PR, Brasil. E-mail: paulojus@ufpr.br

- PALAVRAS-CHAVE: Modelos temporais; inferência bayesiana; captura incidental; Agulhão-negro.

1 Introdução

Pescarias comerciais são atividades extrativistas, praticadas em todos os oceanos. Há grandes variações quanto às espécies capturadas e ao ambiente em que se encontram, desde pequenos animais bentônicos (moluscos e camarões) até grandes peixes pelágicos (atuns e tubarões). O impacto gerado pela extração de organismos pela pesca vai desde a alteração do ambiente físico (*e.g.* redes de arrasto passando sobre fundos coralinos) até a depleção dos estoques pesqueiros.

Uma das modalidades de pesca de maior importância econômica é aquela praticada com espinhéis de superfície, que tem como alvo a captura de atuns e espécies afins em regiões oceânicas. No Atlântico, estas pescarias são realizadas principalmente por frotas de países como Estados Unidos, Espanha e Japão. Este tipo de espinhel pelágico consiste de uma extensa linha principal suspensa por boias. Nesta linha principal são conectadas diversas linhas secundárias, as quais tem na extremidade um único anzol. Um espinhel tradicional possui em torno de 60 km de extensão, por onde são distribuídos cerca de 1100 anzóis. Apesar deste aparente alto “poder” de pesca, os espinhéis são artefatos de pesca passivos, e portanto são considerados como um dos métodos de pesca mais “sustentáveis” atualmente.

Em pescarias oceânicas, como as de espinhel de superfície, muitos dos estoques explotados são compartilhados por diversos países. Isso se deve à ampla distribuição e a capacidade de migração dos grandes peixes pelágicos (SUND *et al.*, 1931). Sendo assim, torna-se inviável que cada país tenha suas próprias medidas de manejo. Portanto, para que medidas reguladoras fossem elaboradas e compartilhadas entre as diferentes nações que possuem alguma frota atuando sobre atuns e espécies afins no oceano Atlântico, criou-se a *International Commission for the Conservation of Atlantic Tunas* (ICCAT). Esta comissão tem como finalidade: (a) requerer e organizar as informações pesqueiras de todos os países membros; (b) promover reuniões para a avaliação dos estoques; e (c) recomendar medidas de manejo para as espécies de atuns e afins.

Em pescarias comerciais, frequentemente ocorrem capturas de espécies que não são o alvo principal, denominadas de “captura incidental”. No caso da pescaria com espinhel de superfície no oceano Atlântico, onde os alvos são os atuns e o espadarte, outras espécies de peixes são também atraídas pelas iscas nos anzóis e capturadas de forma não intencional. Este é o caso de várias espécies de tubarões e de agulhões, que possuem populações frágeis e diversas espécies ameaçadas de extinção.

A redução das mortalidades dos agulhões tem sido tomada como meta internacional devido à tendência atual de declínio da abundância dos estoques (ICCAT, 2012). A gravidade do problema fez com que, em 2000, fosse criado um Plano de Recuperação das Populações de Agulhões. Este Plano de Recuperação estabelece duas medidas principais: um limite anual de captura para algumas

espécies, e a devolução ao mar de todos os exemplares que ainda estiverem vivos no momento da captura. Mesmo com esta regulamentação, a captura anual dos últimos anos vêm se mantendo acima das capturas máximas recomendadas (ICCAT, 2012). Além disso, a liberação de indivíduos capturados vivos é ainda uma questão em aberto pois não existem informações suficientes sobre as estimativas da proporção de capturados vivos/mortos, e nem da frequência com que os vivos são liberados. No Brasil a pescaria de agulhões é regulamentada por uma instrução normativa (IN 12, de 14 de julho de 2005), que tenta proibir a captura destas espécies, estabelecendo que os agulhões capturados vivos devem ser devolvidos, e os mortos devem ser recolhidos e destinados à doação. No entanto, ainda não existem formas de se evitar a captura incidental destas espécies.

A análise dos padrões de distribuição temporal destas espécies é fundamental para o conhecimento do estado atual dos estoques de agulhões. A identificação de padrões temporais em uma série histórica pode auxiliar no entendimento do comportamento sazonal destas espécies, podendo auxiliar nas tomadas de decisão para o manejo pesqueiro. Por exemplo, podem-se identificar os períodos de maior vulnerabilidade destas espécies para a captura, e optar-se por reduzir o esforço pesqueiro nestas épocas. Nesse sentido, os modelos para séries temporais são ferramentas que podem auxiliar na identificação de padrões que colaborem para o gerenciamento de estoques pesqueiros.

Normalmente, a modelagem da captura de uma determinada espécie é realizada sem qualquer suposição sobre a estrutura ou a dependência das observações no tempo. No entanto, sabe-se por exemplo que as capturas de um ano são influenciadas, entre muitos outros fatores, pelas capturas realizadas no ano anterior. Biologicamente, a abundância de uma população no tempo t é influenciada pela abundância no tempo $t - 1$. Sabe-se ainda, que diferentes espécies tendem a ocupar uma determinada área por diversos motivos, como por exemplo a disponibilidade de comida e a temperatura da água, dependendo da época do ano. Por esses motivos, a dependência temporal deve ser levada em consideração na modelagem de dados de populações biológicas.

O objetivo deste trabalho é construir, avaliar, e comparar modelos que descrevem a estrutura de dependência temporal das capturas do agulhão-negro (*Makaira nigricans*), capturado pela frota de espinhel de superfície que atuam no oceano Atlântico sul. O agulhão-negro é uma espécie de população frágil, capturada de maneira incidental pelos barcos espinheleiros, e que faz parte dos planos nacionais e internacionais de manejo pesqueiro. Esta espécie se distribui principalmente em águas temperadas e tropicais do oceano Atlântico, sendo considerada a mais oceânica entre todas as espécies de peixes de bico. Possui peso médio de 150 kg, mas pode chegar a 580 kg e mais de 3 metros de comprimento (SYLVA; BREDER, 1997).

Os modelos analisados foram construídos considerando diferentes estruturas para a dependência temporal. A intenção é entender o comportamento temporal das capturas do agulhão-negro, com a finalidade de que este conhecimento possa servir de embasamento para análises futuras, além de poder auxiliar nas tomadas

de decisão no manejo desta pescaria no Atlântico sul. Em termos de manejo, as variações sazonais na captura de um determinado recurso podem auxiliar na compreensão de épocas com maior vulnerabilidade do estoque à atividade de pesca e, com isto, permitir que o processo de decisão considere a adoção de medidas de mitigação e redução de capturas focadas nestes períodos. Além disso, variações temporais e sazonais na captura podem ainda refletir, indiretamente, respostas do recurso às taxas de remoções sofridas, seja por interface direta da atividade de pesca, seja por componentes indiretas resultantes de processos não avaliados no manejo, mas que estão atuando sobre o estoque de alguma maneira (*e.g.* variações climáticas, sucesso nos padrões reprodutivos).

2 Metodologia

2.1 Fonte dos dados

Os dados de captura em número do agulhão-negro são provenientes do banco de dados *Task 2* da *International Commission for the Conservation of Atlantic Tunas* (ICCAT). Os países signatários desta comissão tem o direito de participar de todo o processo de debate e deliberação sobre novas medidas de manejo. Em contrapartida é requisitado que todas as nações reportem anualmente informações sobre as diversas pescarias de atuns e afins que ocorrem sob sua jurisdição. A base de dados analisada (assim como outras informações) é de livre acesso e pode ser consultada no endereço www.iccat.int.

A princípio, foram selecionadas as entradas correspondentes a todas as frotas que atuaram sobre o estoque sul do agulhão-negro (latitudes ao sul de 5°N). Através de uma breve análise do número de informações por ano, trimestre e frota, constatou-se que apenas a frota do Japão apresenta dados suficientes para uma análise temporal da captura dos agulhões. As demais frotas apresentaram informações dispersas ao longo do tempo, e muitas vezes com longos intervalos anuais sem dados. Por esse motivo, optou-se por utilizar os dados referentes apenas à frota do Japão, a partir do ano de 1970 até 2009, uma vez que essa foi a série temporal utilizada na última avaliação de estoque do agulhão-negro (ICCAT, 2012).

Cada linha da base de dados contém informações como a posição geográfica, o trimestre, o esforço de pesca (número de anzóis) e a captura. Com o objetivo de se analisar a série temporal das capturas do estoque sul do agulhão-negro, os dados de captura e esforço foram agregados por ano e trimestre. Com isso, foram obtidas 160 linhas de informações, a partir do primeiro trimestre de 1970 até o quarto trimestre de 2009.

2.2 Definição dos modelos

Para analisar o padrão temporal das capturas do agulhão-negro no Atlântico sul, foram construídos modelos hierárquicos bayesianos com estrutura gaussiana

latente para representar os efeitos temporais e sazonais. Nesta abordagem, assume-se que a variável resposta “captura” (em forma de contagem do número de peixes), Y_{it} , com $i = 1, \dots, n$ trimestres ($n = 4$) e $t = 1, \dots, T$ unidades de tempo (combinação de ano e trimestre, $T = 160$), segue uma distribuição de probabilidade apropriada para contagens. Neste trabalho foram analisados e comparados os modelos assumindo as distribuições de Poisson e binomial negativa.

A distribuição de Poisson é a escolha natural normalmente utilizada para modelar dados em forma de contagens. Sua função de probabilidade é dada por

$$P[Y = y] = \frac{e^{-\lambda} \lambda^y}{y!}, \quad y = 0, 1, \dots$$

onde o parâmetro $\lambda > 0$ é o valor médio das contagens. A esperança e a variância são dadas por

$$E(Y) = \mu = \lambda \quad \text{e} \quad \text{Var}(Y) = \sigma^2 = \lambda$$

onde nota-se que uma propriedade importante desta distribuição é que a esperança e a variância são iguais. Na prática, esta propriedade muitas vezes não é verificada, devido à uma série de fatores que fazem com que a variância das contagens seja menor ou maior do que a média, fenômenos denominados de subdispersão e superdispersão, respectivamente.

Uma forma de contornar o problema da superdispersão observada em dados amostrais, é utilizar a distribuição binomial negativa. A parametrização desta distribuição adotada aqui é aquela que considera $Y \sim \text{Pois}(\lambda)$, e λ também possui uma distribuição de probabilidade. Se λ segue uma distribuição gama com parâmetros $\delta > 0$ e $\beta > 0$, de forma que $E(\lambda) = \delta/\beta$ e $\text{Var}(\lambda) = \delta/\beta^2$, então a função de probabilidade de Y será a binomial negativa dada por

$$P[Y = y] = \binom{y + \delta - 1}{y} \pi^\delta (1 - \pi)^y, \quad y = 0, 1, \dots \quad (1)$$

onde $\pi = \beta/(\beta + 1)$ é a probabilidade de sucesso do evento de interesse, e δ é o número de sucessos, que não necessariamente precisa ser inteiro. Dessa forma, a esperança e a variância de Y são dadas por

$$E(Y) = \mu = \delta \frac{1 - \pi}{\pi} \quad \text{e} \quad \text{Var}(Y) = \sigma^2 = \mu \left(1 + \frac{\mu}{\delta} \right).$$

Note que, nesse caso, a variância sempre excede a média, já que $\delta > 0$. Por esse motivo, δ também é chamado de parâmetro de superdispersão, e a distribuição binomial negativa é mais indicada quando a variância é maior do que a média em dados de contagem.

Quando ambas distribuições dependem de variáveis explicativas, elas estarão funcionalmente associadas com a média da variável resposta através de um preditor linear η_{it} . A esperança da variável resposta é associada com o preditor linear através

de uma função de ligação $g(\cdot)$ conhecida, monótona e diferenciável

$$g(\mu_{it}) = f_{it} \exp(\eta_{it}).$$

A função de ligação canônica (que lineariza a relação entre a média da variável resposta e o preditor linear) para os modelos Poisson e binomial negativo é a logarítmica, portanto

$$\ln(\mu_{it}) = \ln(f_{it}) + \eta_{it}$$

onde f_{it} é o intervalo de observação para as contagens, um valor conhecido porém não necessariamente constante, conhecido como *offset*. Quando este intervalo não é constante, então é necessária a sua inclusão no preditor linear, para que as contagens sejam consideradas apropriadamente. Neste trabalho foi considerado o número de anzóis (esforço de pesca) como *offset* no modelo, uma vez que as capturas foram observadas em diferentes cenários e com números variável de anzóis.

O modelo latente completo como definido na expressão anterior, possui o preditor linear dado por

$$\eta_{it} = \alpha + \rho_i + \gamma_t. \quad (2)$$

O parâmetro α representa o nível médio do processo (intercepto), ρ_i é o componente sazonal, e γ_t é o componente de tendência temporal. Estes dois componentes podem ser estruturados ou não estruturados. Quando não assumem nenhuma relação temporal são ditos não estruturados, e assume-se que as observações sejam independentes e identicamente distribuídas (iid). Quando assume-se que as observações possuem alguma dependência temporal, estes componentes podem ser estruturados de acordo com algum processo de dependência no tempo.

O modelo formulado em (2) é completamente especificado quando definem-se as distribuições *a priori* para os dois componentes, $\boldsymbol{\rho} = (\rho_1, \dots, \rho_n)'$ e $\boldsymbol{\gamma} = (\gamma_1, \dots, \gamma_T)'$, que definem blocos de efeitos aleatórios em η_{it} . Assume-se como *priori*, que estas distribuições são normais multivariadas com vetor de médias igual a zero e matriz de precisão $\tau \mathbf{K}$, onde τ é um escalar desconhecido e \mathbf{K} é a matriz que define a estrutura de dependência temporal. Nesta abordagem, τ_ρ e τ_γ são parâmetros de precisão associados aos efeitos sazonal e temporal, respectivamente, e que indicam a relevância de cada um dos termos de efeitos aleatórios. Como a precisão é definida como o inverso da variância, espera-se que termos importantes no modelo possuam uma baixa precisão, indicando uma alta variabilidade, e portanto, uma importância maior do termo.

Diferentes matrizes \mathbf{K} podem ser especificadas, descrevendo a estrutura de dependência temporal em cada componente do modelo. Para o termo de componente sazonal ρ , um modelo com periodicidade m para o vetor $\boldsymbol{\rho} = (\rho_1, \dots, \rho_n)$, $n > m$, é obtido assumindo que as somas $\rho_i + \rho_{i+1} + \dots + \rho_{i+m-1}$ são independentes e possuem distribuição normal com média zero e parâmetro de precisão τ_ρ . Neste trabalho, adotou-se a periodicidade trimestral, portanto $m = 4$.

Para o termo de componente de tendência temporal, γ , diversas estruturas de dependência da matriz \mathbf{K} foram avaliadas. Inicialmente, pode-se considerar que uma observação no tempo t é influenciada apenas pela observação no tempo

anterior ($t - 1$). Esse processo é denominado de passeio aleatório, ou *random walk*, de primeira ordem, e denotado por RW(1). Considerando o vetor gaussiano $\gamma = (\gamma_1, \dots, \gamma_T)$, o modelo RW(1) é definido por

$$\Delta\gamma_t = \gamma_{t+1} - \gamma_t, \quad t = 1, \dots, T - 1 \quad (3)$$

onde $\Delta\gamma_t \sim N(0, \tau_\gamma^{-1})$ e também é chamado de diferença de primeira ordem entre duas observações consecutivas. Pode-se ainda definir passeios aleatórios de ordens superiores. Por exemplo, um processo *random walk* de ordem 2, RW(2), é obtido a partir da diferença de segunda ordem, ou seja, a diferença entre diferenças de primeira ordem consecutivas (NATÁRIO; KNORR-HELD, 2003)

$$\begin{aligned} \Delta^2\gamma_t &= \Delta(\Delta\gamma_t) \\ &= \Delta(\gamma_{t+1} - \gamma_t) \\ &= (\gamma_{t+1} - \gamma_t) - (\gamma_t - \gamma_{t-1}) \\ &= \gamma_{t+1} - 2\gamma_t + \gamma_{t-1}, \quad t = 2, \dots, T - 1 \end{aligned} \quad (4)$$

onde $\Delta^2\gamma_t \sim N(0, \tau_\gamma^{-1})$. Sendo assim, note que, dados os valores observados em todos os tempos, tanto as observações no tempo $(t - 1)$, quanto as observações no tempo $(t + 1)$, ajudam a prever as observações no tempo t . De fato, o termo $\gamma_{t+1} - 2\gamma_t + \gamma_{t-1}$ pode ser interpretado como uma estimativa da derivada de segunda ordem de uma função no tempo contínuo $\gamma(t)$ no ponto $t = i$, usando valores de $\gamma(t)$ nos pontos $t = i + 1, i$, e $i - 1$ (LINDGREN; RUE, 2015). Portanto, na prática, a diferença entre os modelos RW(1) e RW(2), é que este último deverá apresentar um comportamento mais suavizado do que o primeiro (FAHRMEIR; LANG, 2001).

Outro processo possível para o termo de componente de tendência temporal é considerar que as observações em um ano são dependentes somente das observações nos anos anteriores. Nesse caso, um modelo sugerido é o autoregressivo de ordem p , AR(p), o qual especifica que a variável resposta depende linearmente dos seus valores anteriores, gerando uma estrutura Markoviana. Os modelos AR(p) são definidos para o mesmo vetor gaussiano $\gamma = (\gamma_1, \dots, \gamma_T)$, como

$$\gamma_t = \phi_1 \gamma_{t-1} + \phi_2 \gamma_{t-2} + \dots + \phi_p \gamma_{t-p} + \epsilon_t, \quad (5)$$

para $t = p, \dots, n$, com parâmetros ϕ_1, \dots, ϕ_p e ϵ_t representa o ruído branco com $E(\epsilon_t) = 0$, $\text{Var}(\epsilon_t) = \sigma_\epsilon^2 = \tau_\gamma^{-1}$, e $\text{Cov}(\epsilon_i, \epsilon_j) = 0, \forall i \neq j$. Isso implica que o ruído branco possui média zero, variância constante e que não existe correlação entre eles. Sendo assim, para um processo AR(1) com ϕ positivo, apenas a observação de um ano anterior do processo e o termo de ruído branco contribuem para a observação atual. Se ϕ está próximo de zero, então o processo se aproxima apenas do ruído branco.

Para se determinar a ordem p do processo autoregressivo para a captura de agulhões, foram ajustados todos os modelos AR(p) para $p = 1, \dots, 10$. Além disso, os modelos AR(p) foram comparados com os modelos RW(1) e RW(2) para

determinar qual destes processos é mais plausível para explicar a variabilidade temporal da captura do agulhão-negro. A comparação e escolha do modelo mais apropriado foi realizada conforme critérios de seleção de modelos apresentados na próxima seção.

Para completar a especificação do modelo, é necessário especificar as distribuições *a priori* para todos os parâmetros envolvidos. Seguindo a proposta de Natário e Knorr-Held (2003) e Schrödle *et al.* (2011), assume-se que os parâmetros de precisão, τ_ρ e τ_γ para os efeitos sazonal (ρ) e temporal (γ), associados à matriz estrutural \mathbf{K} , possuem distribuição *a priori* $G(1, 0.00005)$, onde $G(a, b)$ é a distribuição Gama com esperança a/b e variância a/b^2 . Para o parâmetro α , que determina a média geral do processo, assumiu-se uma distribuição *a priori* vaga, ou seja, uma uniforme no intervalo $(-\infty, \infty)$.

As estruturas assumidas para os efeitos temporais definem campos aleatórios gaussianos markovianos (*Gaussian Markov Random Fields*, GMRF) (RUE; HELD, 2005). A grande dimensão do vetor de efeitos aleatórios pode tornar a inferência baseada em simulação, como os métodos de Monte Carlo via Cadeias de Markov (MCMC), computacionalmente ineficientes ou até mesmo inviáveis. Por esse motivo, foi utilizado um método baseado em aproximações numéricas para inferência bayesiana em modelos gaussianos latentes altamente estruturados, definido inicialmente por Rue *et al.* (2009). A metodologia denominada INLA (*Integrated Nested Laplace Approximation*) faz uso de métodos de integração numérica para se obterem as distribuições marginais *a posteriori*, e contorna os problemas de elevado tempo computacional e de convergência em métodos como o MCMC. As funções para o cálculo das distribuições posteriores estão implementadas no ambiente estatístico R (R Core Team, 2018), através do pacote INLA (LINDGREN; RUE, 2015), disponível em www.r-inla.org.

2.3 Seleção de modelos

Ao todo, foram ajustados 14 modelos para cada distribuição (Poisson e binomial negativa): o modelo nulo (apenas com o intercepto), um modelo que considera que não existe nenhum tipo de relação temporal entre as observações (*i.e.* observações são independentes e identicamente distribuídas, iid), os modelos de passeio aleatório RW(1) e RW(2) como definidos em (3) e (4), e os modelos AR(p), $p = 1, \dots, 10$ como definidos em (5). Em todos estes modelos também foi considerado o efeito sazonal para os trimestres.

Para a comparação destes modelos, foram utilizados quatro critérios em conjunto: a redução na deviance, o número efetivo de parâmetros, o critério de informação da deviance (DIC), e a ordenada preditiva condicional (*conditioning predictive ordinate*, CPO). Como medida de diagnóstico do modelo selecionado foi utilizada a transformação integral de probabilidade (*Probability Integral transform*, PIT).

A distribuição posterior da estatística deviance é dada por

$$D(\boldsymbol{\theta}) = -2 \log f(\mathbf{y}|\boldsymbol{\theta}) + 2 \log h(\mathbf{y})$$

onde $f(\mathbf{y}|\boldsymbol{\theta})$ é a função de verossimilhança para o vetor de dados observado \mathbf{y} , dado o vetor de parâmetros $\boldsymbol{\theta}$, e $h(\mathbf{y})$ é uma função de padronização que depende apenas dos dados (não interferindo no processo de seleção de modelos). Dessa forma, uma medida de bondade de ajuste do modelo pode ser resumida pela esperança da distribuição posterior da deviance, $\bar{D} = E_{\theta|\mathbf{y}}[D]$, e uma medida de complexidade do modelo pode ser representada pelo número efetivo de parâmetros p_D ,

$$p_D = E_{\theta|\mathbf{y}}[D] - D(E_{\theta|\mathbf{y}}[\boldsymbol{\theta}]) = \bar{D} - D(\bar{\boldsymbol{\theta}})$$

ou seja, a diferença entre a esperança de distribuição posterior da deviance e a deviance da distribuição posterior no seu ponto médio (SPIEGELHALTER *et al.*, 2002). De maneira geral, o número efetivo de parâmetros deve estar entre zero e o número total de parâmetros do modelo (CARLIN; LOUIS, 2009). Como a deviance é uma função dos dados, então o número efetivo de parâmetros também é uma variável aleatória, e é razoável supor que esta medida também dependa dos dados (GELMAN *et al.*, 2014). Dessa forma, dados mais dispersos podem apresentar valores de p_D maiores. Para mais detalhes veja Spiegelhalter *et al.* (2002) e Carlin e Louis (2009, p. 211). O critério de informação da deviance (DIC) é então definido como

$$\text{DIC} = \bar{D} + p_D = 2\bar{D} - D(\bar{\boldsymbol{\theta}})$$

que considera tanto os valores da deviance quanto do número efetivo de parâmetros (SPIEGELHALTER *et al.*, 2002). Assim, valores de DIC menores indicam modelos mais bem ajustados. Note que valores individuais de DIC não possuem uma interpretação prática. Apenas a diferença entre DICs de diferentes modelos são de interesse (CARLIN; LOUIS, 2009).

A ordenada preditiva condicional (CPO) é definida por

$$f(y_i|\mathbf{y}_{(i)}) = \frac{f(\mathbf{y})}{f(\mathbf{y}_{(i)})} = \int f(y_i|\boldsymbol{\theta}, \mathbf{y}_{(i)})p(\boldsymbol{\theta}|\mathbf{y}_{(i)})d\boldsymbol{\theta}$$

que define o valor da verossimilhança para cada observação i (y_i), dado o restante das observações sem i ($\mathbf{y}_{(i)}$). Note que esta medida pode ser utilizada como uma forma de validação cruzada. A média do logaritmo da CPO, $\text{LCPO} = -\frac{1}{160} \sum_{i=1}^{160} \log(\text{CPO}_i)$, é uma medida utilizada como indicativo do poder de predição de um modelo (BEGIN *et al.*, 2012). Nesse caso, modelos com valores menores de LCPO possuem uma menor capacidade preditiva (HELD *et al.*, 2010). Uma característica importante desta medida é que ela pode ser utilizada para comparação entre modelos sem a necessidade de que estes modelos sejam aninhados ou mesmo relacionados de alguma forma (SCHRODLE *et al.*, 2011).

A transformação integral de probabilidade (PIT) é definida como $\text{PIT}_i = P(Y_i \leq y_i|\mathbf{y}_{(i)})$, onde Y_i é uma replicação da observação y_i (GELMAN *et al.*,

2014). Esta é uma medida utilizada para se avaliar a adequação da suposição da distribuição assumida para a variável resposta. No caso de distribuições contínuas, um histograma com os valores de PIT deve mostrar uma distribuição que se aproxima de uma uniforme no intervalo $[0,1]$ (SCHRODLE; HELD, 2011). No entanto, para distribuições discretas, como as assumidas aqui, essa suposição não é mais válida. Czado *et al.* (2009) propuseram então um ajuste para os valores de PIT quando são utilizadas distribuições discretas. Portanto, o PIT ajustado $PITa_i = PIT_i + 0.5P(Y_i = y_i|y_{(i)})$, proposto por aqueles autores, foi utilizado neste trabalho. Dessa forma, permanece a interpretação de que se a distribuição dos valores de PITa for próxima de uma uniforme, a variável resposta assumida é adequada (SCHRODLE *et al.*, 2011).

3 Resultados e discussão

A comparação entre os modelos ajustados para as distribuições de Poisson e binomial negativa está demonstrada na Tabela 1. Nota-se que em comparação, os valores de deviance e DIC para os modelos ajustados com a distribuição de Poisson são menores do que as mesmas medidas obtidas para os modelos ajustados com a distribuição binomial negativa. Os valores ligeiramente menores de LCPO também indicam que os modelos de Poisson possuem uma melhor capacidade preditiva. Através destas comparações, os modelos de Poisson parecem ser mais adequados. No entanto, chama a atenção o elevado número efetivo de parâmetros para os modelos de Poisson. Considerando que o conjunto de dados analisado é composto de uma combinação de todos os trimestres para os anos 1970–2009, existem $40 \times 4 = 160$ observações. Em todos os modelos ajustados considerando a distribuição de Poisson, o número efetivo de parâmetros foi sempre superior a 154, ou seja, o modelo não contribui para a redução dos dados. De fato, foi verificado através dos valores preditos de um destes modelos que houve praticamente a reprodução das observações originais. Uma possível explicação para esse fato é que, devido à variabilidade dos dados, a distribuição de Poisson (que possui a propriedade de que a média é igual a variância) não foi capaz de capturar esta alta variabilidade, e uma grande quantidade de parâmetros foi necessária para que o modelo pudesse ser ajustado, promovendo um superaajustamento.

As distribuições dos valores da transformação integral de probabilidade ajustados (PITa) para cada modelo considerando a distribuição de Poisson estavam mais próximas de uma distribuição simétrica do que de uma uniforme, como seria esperado se a suposição de que a variável resposta segue uma distribuição de Poisson fosse adequada. Em geral, os histogramas de PITa para os modelos considerando a distribuição binomial negativa apresentaram distribuições mais próximas de uma uniforme no intervalo $[0,1]$. Isso indica, portanto, que a distribuição mais adequada para a variável resposta seria de fato a binomial negativa. Portanto, mesmo que os valores de DIC e LCPO tenham sido menores para os modelos que consideraram a distribuição de Poisson, as evidências indicam que a distribuição binomial negativa é mais adequada, tanto pelo menor número efetivo de parâmetros, quanto pela

Tabela 1 - Deviance residual, número efetivo de parâmetros (p_D), critério de informação da deviance (DIC), e logaritmo da ordenada preditiva condicional (LCPO) para os diferentes modelos temporais ajustados, considerando as distribuições de Poisson e Binomial Negativa

Modelo	Poisson				Binomial negativa			
	Deviance	p_D	DIC	LCPO	Deviance	p_D	DIC	LCPO
NULL	62603,61	3,46	62607,07	180,77	2395,67	1,00	2397,31	7,49
IID	1435,52	158,71	1594,24	6,16	2382,14	2,89	2387,00	7,46
RW1	1441,00	156,85	1597,88	6,11	2293,40	20,17	2314,81	7,22
RW2	1440,62	156,22	1596,88	6,08	2299,58	11,87	2313,01	7,22
AR1	1439,21	157,25	1596,51	6,10	2291,96	22,60	2315,72	7,23
AR2	1438,90	157,23	1596,21	6,09	2293,95	19,36	2314,87	7,22
AR3	1437,67	155,66	1593,50	6,06	2165,25	67,22	2231,34	7,77
AR4	1441,08	155,85	1597,13	6,06	2181,77	55,81	2239,43	7,41
AR5	1443,05	155,30	1598,60	6,05	2188,75	54,12	2243,28	7,40
AR6	1443,28	155,24	1598,79	6,06	2171,57	60,87	2231,18	7,54
AR7	1443,38	155,23	1598,96	6,06	2201,38	44,90	2248,89	7,08
AR8	1438,51	154,92	1593,78	5,99	2201,20	44,28	2248,70	7,07
AR9	1438,61	154,82	1593,82	5,99	2190,62	48,09	2237,99	7,17
AR10	1438,35	154,79	1593,52	5,99	2152,47	56,90	2216,03	7,02

distribuição dos valores de PITa.

Por estes motivos, desconsideraram-se os modelos de Poisson, e os modelos ajustados com a distribuição binomial negativa foram analisados individualmente. Entre estes modelos, percebe-se inicialmente uma diferença considerável dos valores da deviance para os modelos nulo e não estruturado (iid), ou seja, qualquer outro modelo que considere alguma relação temporal (RW ou AR) para os dados é mais apropriado (Tabela 1).

Este primeiro resultado já indica a necessidade de se considerar os efeitos de dependência temporal para os dados de captura do agulhão-negro no Atlântico sul.

Entre os modelos estruturados temporalmente, nota-se pelos valores da deviance e DIC, que, em geral, os modelos que consideram a estrutura autoregressiva (AR) são mais bem ajustados do que os modelos estruturados através da estrutura de passeios aleatórios (RW). Os valores de LCPO para os modelos RW são, em geral, maiores do que os mesmos valores para a maioria dos modelos AR, o que indica um menor poder preditivo dos modelos com estrutura de passeio aleatório. Entre os modelos AR, aquele que apresentou os menores valores da deviance e DIC foi o AR(10). Este mesmo modelo também possui o menor valor de LCPO, sendo, portanto, aquele com maior poder de predição. Para ajudar na decisão sobre o modelo a ser selecionado, na Figura 1 são apresentados todos os modelos com seus respectivos valores de deviance, DIC e número efetivo de parâmetros. Em uma situação ideal, o melhor modelo entre um conjunto de possíveis modelos, é aquele que apresenta o menor valor nestes três critérios em conjunto. Através desta figura, observa-se que o modelo AR(10) é o que está mais próximo desta situação ideal,

uma vez que possui os menores valores de deviance e DIC entre todos os modelos, e ainda possui o menor número de parâmetros entre os modelos mais próximos em termos de deviance e DIC. Por estes resultados, há uma tendência para a escolha do modelo AR(10).

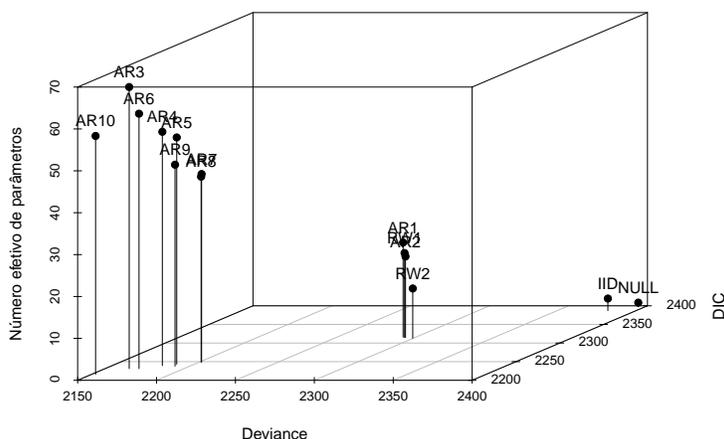


Figura 1 - Gráfico em três dimensões com os valores de deviance, DIC, e número efetivo de parâmetros para todos os modelos considerados, assumindo a distribuição binomial negativa para a variável resposta.

A Tabela 2 apresenta a mediana da distribuição posterior para cada efeito aleatório estimado em todos os modelos considerados (por conveniência, os valores para as autocorrelações parciais para todos os modelos foram suprimidas, mas serão analisadas para o modelo escolhido). Nesse caso, espera-se que valores elevados para o parâmetro de precisão sejam de pouca importância. Uma vez que a precisão é o inverso da variância, componentes com elevado valor de precisão apresentam pouca variabilidade, indicando, portanto, que seus valores estão próximos da média, que por construção do modelo é zero. Ou seja, componentes com alta precisão (baixa variabilidade), tem pouco efeito sobre a variável resposta. Nota-se pela Tabela 2 que a precisão para o parâmetro do componente de tendência temporal (γ) é parecida na maioria dos modelos, com exceção dos modelos IID, RW1 e RW2, que apresentaram valores elevados para este componente. Já para o parâmetro do componente de sazonalidade (ρ), os valores medianos da precisão são mais variados. Analisando especificamente os resultados para o modelo AR(10), que mostrou ser o mais adequado pelos critérios anteriores, nota-se que a precisão para o termo de tendência temporal é a segunda menor entre todos os modelos. Já para

o componente de sazonalidade, a precisão não é tão alta comparativamente. No entanto, parâmetro de superdispersão (δ) para o modelo AR(10) apresentou o valor mediano mais alto entre todos os modelos. Dessa forma, optou-se por selecionar o modelo AR(10) para se fazerem previsões e análises de efeitos dos parâmetros sazonais e temporais.

Tabela 2 - Mediana da distribuição posterior do intercepto (α), dos efeitos aleatórios (componente de tendência temporal, γ , e componente sazonal, ρ), e do parâmetro de superdispersão (δ) da distribuição binomial negativa, para os modelos considerados

Modelo	Efeitos			
	α	δ	γ	ρ
NULL	-9,34	1,29		
IID	-9,37	1,40	13293,40	30,83
RW1	-9,57	2,28	50,37	12,90
RW2	-9,56	2,20	4837,28	12,99
AR1	-9,54	2,30	2,87	12,73
AR2	-9,54	2,29	2,86	12,79
AR3	-9,60	4,78	1,07	34,74
AR4	-9,61	4,45	1,15	36,82
AR5	-9,61	4,14	1,21	24,50
AR6	-9,61	3,99	1,32	49,47
AR7	-9,61	3,99	1,30	32,61
AR8	-9,61	4,04	1,32	22,14
AR9	-9,61	3,98	1,32	29,04
AR10	-9,66	5,48	1,10	19,08

As distribuições posteriores para os efeitos aleatórios (componentes de tendência temporal, sazonalidade e autocorrelações parciais) do modelo AR(10), e do parâmetro de superdispersão da distribuição binomial negativa estão apresentados na Figura 2. Percebe-se inicialmente que a distribuição posterior para o parâmetro de precisão do componente de tendência temporal não contém o zero, e seu valor mediano é baixo, indicando que existe uma grande influência temporal nas capturas do agulhão-negro no Atlântico sul. Da mesma forma, a distribuição posterior para o parâmetro de sazonalidade não inclui o zero, mas sua distribuição exibe grande assimetria à direita. De acordo com a Tabela 2, a mediana desta distribuição posterior é 19,08, que associado com a grande assimetria, indica que o termo sazonal não possui grande importância para explicar as capturas do agulhão-negro. Em relação ao parâmetro de superdispersão da distribuição binomial negativa, nota-se que sua distribuição posterior não inclui o zero, e possui valor mediano de 5,48 (ver Tabela 2), confirmando a presença de superdispersão em relação à distribuição de Poisson, mesmo com a inclusão dos efeitos aleatórios.

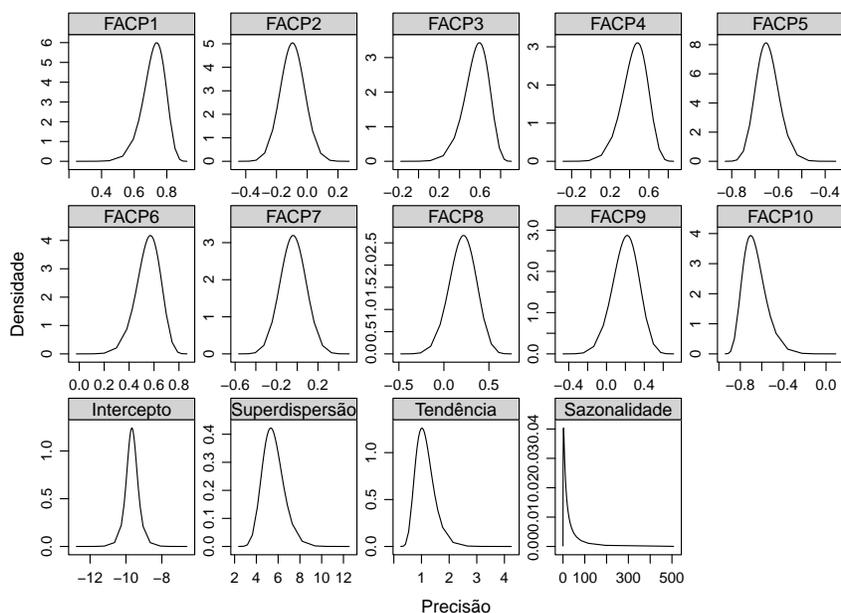


Figura 2 - Distribuições posteriores para o efeito fixo (intercepto), e aleatórios (tendência, sazonalidade e funções de autocorrelação parcial, FACP) do modelo proposto, além da distribuição posterior para o parâmetro de superdispersão da distribuição binomial negativa.

As distribuições posteriores para os parâmetros de autocorrelação parcial estimadas pelo modelo AR(10) (Figura 2) mostram que, em geral, estes termos possuem baixa precisão (valores próximos do zero), ou seja, são importantes para a explicação do modelo. Nota-se que quatro distribuições posteriores, entre as dez das FACP, incluem o zero: FACP2, FACP7, FACP8 e FACP9. Para ficar mais claro a interpretação destes parâmetros, a Figura 3 mostra apenas o valor mediano destas distribuições posteriores, e indica aqueles cujo intervalo de credibilidade inclui (linhas pontilhadas) ou não (linhas sólidas) o valor zero. Por esta figura, percebe-se que a dependência temporal é positiva até a quarta diferença de tempo, ficando negativa na quinta e novamente positiva na sexta. A partir desse ponto as FACP estimadas são não significativas. Apenas na décima diferença de tempo a FACP volta a ser significativa e é negativa. O fato da distribuição posterior da FACP10 não incluir o zero, mostra que é necessário considerar uma longa dependência temporal para explicar a variabilidade das capturas do agulhão-negro ao longo dos anos.

O fato desta espécie possuir uma alta longevidade (em torno de 20 anos, ANDREWS *et al.*, 2017) pode ser um motivo para explicar essa longa dependência. Espécies longevas apresentam um crescimento mais lento, e, por consequência, uma

maior idade de primeira maturação sexual. Alguns estudos (SYLVIA; BREDER, 1997) mencionam que o tamanho de primeira maturação se dá em torno dos 230 cm. Considerando que seu tamanho máximo pode chegar a mais de 350 cm (GOODYEAR, 2015), é possível deduzir, de forma relativa, que o recrutamento leve alguns poucos anos para ocorrer, fazendo com que as capturas sejam dependentes dos recrutamentos em tempos mais distantes.

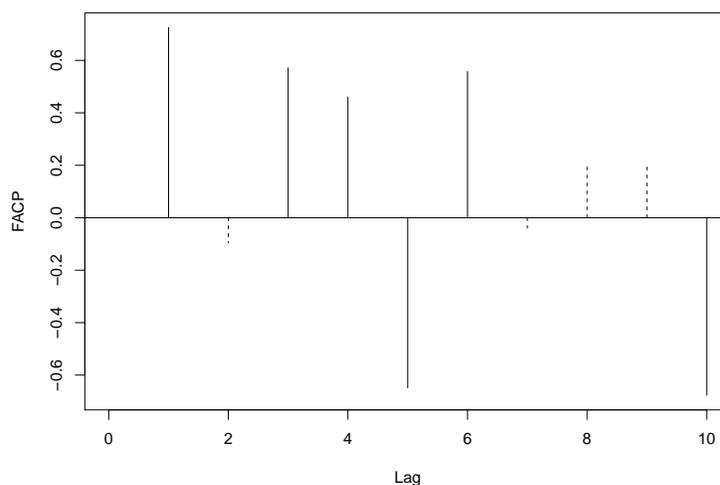


Figura 3 - Mediana da distribuição posterior das funções de autocorrelação parcial (FACP) obtidas pelo modelo AR(10). As linhas sólidas indicam que o intervalo de credibilidade de 95% para a distribuição não inclui o zero. As linhas pontilhadas indicam que o mesmo intervalo contém o zero.

A Figura 4 apresenta os efeitos temporais (tendência temporal) e sazonais, com bandas de credibilidade de 95%. Em relação aos efeitos temporais, observa-se claramente o padrão cíclico de capturas, conforme o trimestre do ano (Figura 4A). Nota-se uma queda nas capturas do agulhão-negro até o primeiro trimestre de 1979. De maneira geral, o período entre o primeiro trimestre de 1976 e o mesmo para 1979, foi o único que apresentou intervalos de credibilidade que não incluem o zero, mostrando assim que esta foi uma época onde as capturas do agulhão-negro eram relativamente mais baixas. Este fato pode estar associado à uma combinação de fatores como por exemplo a estratégia de pesca da frota japonesa naquele período (*e.g.* tipo e profundidade de atuação do anzol, horário de lançamento do equipamento), que fazia com que menos agulhões fossem capturados, ou à uma redução natural da população dos agulhões. Passada essa fase, todos os efeitos para os demais períodos incluem o zero no intervalo de credibilidade, indicando portanto

que não houveram alterações significativas na captura do agulhão-negro para todo o período analisado. Sem poder tirar maiores conclusões, nota-se apenas que a partir de 1985 os efeitos temporais são positivos (apenas o limite inferior do intervalo de credibilidade está próximo do zero), demonstrando capturas mais elevadas. A partir do ano 2000, há uma pequena diminuição e uma oscilação do efeito temporal em torno do zero até o final de 2009.

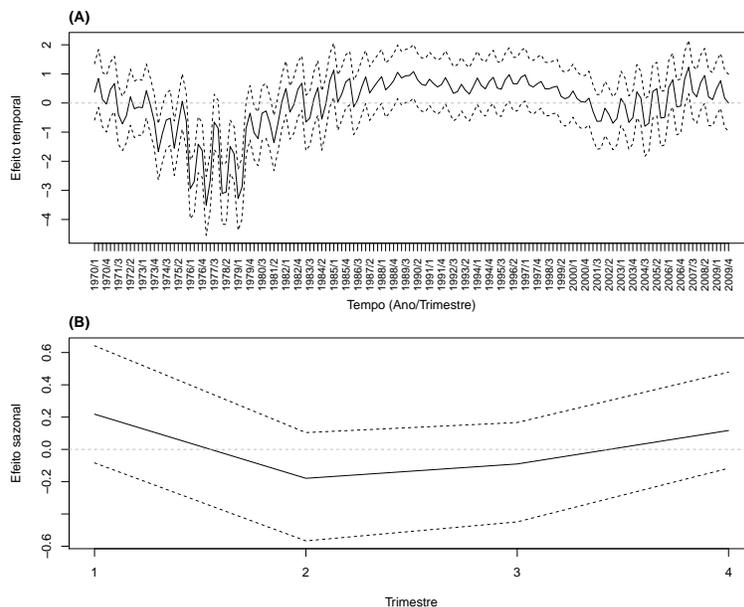


Figura 4 - Mediana e intervalo de credibilidade de 95% das distribuições posteriores para os efeitos de tendência temporal (A), e sazonalidade (B).

Os efeitos sazonais para os trimestres mostram que as capturas são maiores no primeiro e no quarto trimestres (Figura 4B), que são os períodos mais quentes no hemisfério austral. Normalmente nas épocas mais quentes ocorre a agregação de indivíduos desta espécie para fins de reprodução, o que torna os indivíduos mais vulneráveis à pesca. No segundo e no terceiro trimestres os efeitos sazonais são negativos. No entanto, maiores conclusões não podem ser feitas pois em todos os casos, os intervalos de credibilidade para as distribuições posteriores contém o valor zero.

A Figura 5 mostra a série temporal analisada, com a captura total (em número) de agulhões-negros, realizada pela frota do Japão para o período de 1970 a 2009. Sobreposta à esta série, estão os valores de captura estimados (mediana) pelo modelo AR(10), com as respectivas bandas de credibilidade. Percebe-se o bom ajuste do modelo, que de maneira geral tende a seguir o comportamento dos dados observados.

Através desta série, pode-se notar que as capturas eram relativamente baixas até meados de 1981. A partir desse ano, houve um aumento considerável das capturas, embora sempre de maneira oscilatória, até aproximadamente o final dos anos 1990. A partir do início da década de 2000, as capturas foram reduzidas, embora não chegando aos patamares mais baixos observados no início da série. No final da década de 2000, há uma pequena tendência de aumento das capturas, mas ainda com uma grande oscilação.

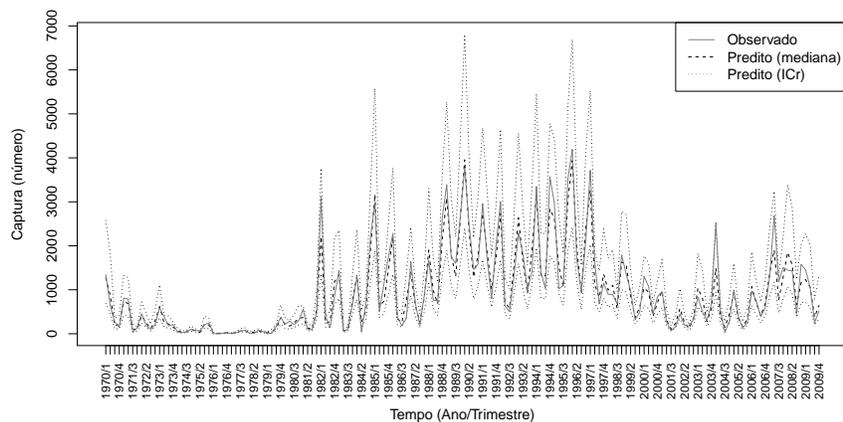


Figura 5 - Número de agulhões-negros capturados no Atlântico sul pela frota japonesa, no período 1970–2009. A linha tracejada representa a mediana, e as linhas pontilhadas o intervalo de credibilidade (ICr) de 95% para a distribuição posterior dos valores ajustados pelo modelo analisado.

Conclusões

A classe de modelos proposta para se analisar as capturas do agulhão-negro no Atlântico sul, permite explorar diversas possibilidades para a estrutura de dependência temporal entre as observações. Através da metodologia utilizada, é possível adquirir uma maior flexibilidade na modelagem de séries temporais. Por exemplo, é possível a utilização de distribuições apropriadas para a variável resposta, como é o caso das contagens com superdispersão neste caso. Além disso, também é possível ajustar diversos modelos com estruturas temporais diferentes e fazer a comparação e seleção através de abordagens baseadas em critérios gerais de comparação e seleção de modelos.

Através da análise de comparação dos modelos, notou-se que o modelo de Poisson, que é comumente utilizado para se modelar dados de contagens, não foi capaz de fornecer uma descrição parcimoniosa dos dados. Pelo contrário, o modelo

de Poisson necessitou de um número de parâmetros muito próximo ao número de informações na amostra, sendo ineficaz no objetivo de resumir os dados. Por outro lado, a modelagem utilizando a distribuição binomial negativa para a variável resposta foi claramente superior, fornecendo boas estimativas com um número reduzido de parâmetros. O fato da distribuição binomial negativa se adequar melhor aos dados analisados provavelmente é devido às características da pescaria de agulhão-negro no Atlântico sul. Por se tratar de uma espécie considerada oriunda de uma população pequena em relação às outras espécies exploradas comercialmente, a captura do agulhão-negro é pouco frequente. Isto faz com que em um grande número de anzóis, poucos indivíduos são capturados, o que gera um excesso de zeros, e que pode ser um dos motivos da elevada superdispersão observada.

Em relação às estruturas temporais analisadas, verificou-se que os modelos que consideram um processo autoregressivo tiveram um melhor desempenho quando comparados com os modelos que consideram um processo de passeio aleatório. Isto sugere que as capturas de agulhões em um determinado tempo t podem ser melhor explicadas pelas capturas nos tempos $t-p$, e não tão bem descritas simultaneamente pelas capturas nos tempos anteriores ($t-1$) e posteriores ($t+1$). Ainda, neste caso, observou-se que as capturas são dependentes no tempo até a ordem $p = 10$, visto que o modelo indicado como o melhor entre os possíveis candidatos foi o AR(10). Para fins de gerenciamento pesqueiro, este resultado sugere que qualquer medida de manejo a ser adotada deve levar em consideração a série histórica de capturas do agulhão-negro.

A análise dos efeitos de tendência temporal e sazonal mostrou que o efeito temporal é mais importante para descrever as capturas dos agulhões, como pôde ser observado pelo baixo valor da precisão (mediana) para este componente. O efeito sazonal, embora menos pronunciado e pouco significativo, apontou evidências de que as capturas são maiores nos meses mais quentes do ano no Atlântico sul.

A análise de dados de pescarias comerciais normalmente envolve a padronização da captura como a primeira etapa para análises subsequentes. Normalmente são utilizados modelos lineares generalizados (MLGs) para essa tarefa, onde, no entanto, a dependência temporal raramente é levada em consideração através de estruturas adequadas. A utilização de estruturas de dependência temporal representa uma alternativa mais acurada para a modelagem deste tipo de dados, uma vez que as capturas em pescarias comerciais são dependentes no tempo, já que atuam sobre populações biológicas que são afetadas pela pesca e dependem do tempo para sua recuperação e volta ao equilíbrio natural.

A realização de inferência bayesiana através do método INLA representa uma alternativa viável e computacionalmente mais eficiente do que os tradicionais métodos de Monte Carlo via cadeias de Markov (MCMC). Esta metodologia resolve o problema de tempo computacional elevado na inferência via MCMC, permitindo a comparação, relativamente rápida, de diversas alternativas de modelagem, que testam diferentes hipóteses sobre padrões do processo em estudo. Especialmente em dados de pescarias comerciais, como os analisados neste trabalho, onde há uma grande quantidade de informação, e possivelmente também um grande número

de covariáveis, este método pode ser uma opção mais plausível para os cálculos necessários na inferência bayesiana e na análise e seleção de modelos.

MAYER, F. P.; SANT'ANA, R.; RIBEIRO JUNIOR, P. J. Modeling the temporal structure of incidental catches in commercial fisheries using hierarchical bayesian models. *Rev. Bras. Biom.*, Lavras, v.37, n.4, p.446-466, 2019.

■ **ABSTRACT:** *In commercial fisheries, catches of species that are not the main target, are called “bycatch”. In the Atlantic Ocean, the Black Marlin (*Makaira nigricans*) is caught incidentally by vessels using longline as fishing gear, and targeting tunas and swordfish. Analysis of temporal patterns in a historical context can help in decisions for fisheries management. The aim of this work is to build, evaluate and compare models that describe the temporal structure of historical catches of Blue Marlin. Bayesian hierarchical models with latent Gaussian structure were used to model marlin catches in the South Atlantic Ocean, with data from the Japanese fleet from 1970 to 2009. Models with random walk (RW) and autoregressive structures were used, as well as a seasonal component for trimesters. Parameters were estimated in a Bayesian context through the Integrated Nested Laplace Approximation (INLA) approach. The negative binomial distribution turned out to be a better alternative for this kind of data, as overdispersion was detected when considering the Poisson distribution. The most appropriate temporal model was autoregressive of order 10. The time trend effect was more pronounced than the effect of seasonality. Inference using the INLA method demonstrated be an effective alternative for use in large databases, such as the one used in this work.*

■ **KEYWORDS:** *Temporal models; Bayesian inference; bycatch; blue marlin.*

Referências

ANDREWS, A. H.; HUMPHREYS, R. L.; SAMPAGA, J. D. Blue marlin (*Makaira nigricans*) longevity estimates confirmed with bomb radiocarbon dating. *Canadian Journal of Fisheries and Aquatic Sciences*, v.75, p.17—25, 2017.

BEGUIN, J.; MARTINO, S.; RUE, H.; CUMMING, S. G. Hierarchical analysis of spatially autocorrelated ecological data using integrated nested Laplace approximation. *Methods in Ecology and Evolution*, v.3, p.921—929, 2012.

CARLIN, B. P.; LOUIS, T. A. *Bayesian methods for data analysis*, Boca Raton: Chapman and Hall, 2009, 552p.

CZADO, C.; GNEITING, T.; HELD, L. Predictive model assessment for count data. *Biometrics*, v.65, p.1254—1261, 2009.

DE SYLVA, D. P.; BREDER, P. R. Reproduction, gonad histology, and spawning cycles of north atlantic billfishes (*Istiophoridae*), *Bulletin of Marine Science*, v.60, p.668—697, 1997.

FAHRMEIR, L.; LANG, S. Bayesian inference for generalized additive mixed models based on Markov random field priors. *Journal of the Royal Statistical Society Series C*, v.50, p.201–220, 2001.

GELMAN, A.; CARLIN, J. B.; STERN, H. S.; DUNSON, D. B.; VEHTARI, A.; RUBIN, D. B. *Bayesian data analysis*. Boca Raton: Chapman and Hall, 2014, 667p.

GOODYEAR, C. P. Understanding maximum size in the catch: Atlantic blue marlin as an example, *Transactions of the American Fisheries Society*, v.144, p.274–282, 2015.

HELD, L.; SCHRÖDLE, B.; RUE, H. Posterior and cross-validators predictive checks: a comparison of MCMC and INLA. In: KNEIB, T.; TUTZ, G. (Ed.). *Statistical modelling and regression structures*. Heidelberg: Physica-Verlag HD, 2010, p. 91–110. (Festschrift in Honour of Ludwig Fahrmeir).

ICCAT. Report of the 2006 ICCAT billfish stock assessment. *Col. Vol. Sci. Pap. ICCAT*, v.60, p.1431–1546, 2007.

ICCAT. Report of the 2011 blue marlin stock assessment and white marlin data preparatory meeting. *Col. Vol. Sci. Pap. ICCAT*, v.68, p.1273–1386, 2012.

LINDGREN, F.; RUE, H. On the second-order random walk model for irregular locations, *Scandinavian Journal of Statistics*, v.35, p.691–700, 2008.

LINDGREN, F.; RUE, H. Bayesian spatial modelling with R-INLA, *Journal of Statistical Software*, v.63, p.1–25, 2015.

NATÁRIO, I.; KNORR-HELD, L. Non-parametric ecological regression and spatial variation, *Biometrical Journal*, v.45, p.670–688, 2003.

R CORE TEAM (2018). *R: A language and environment for statistical computing*. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.

RUE, H.; HELD, L. *Gaussian Markov Random Fields*, Boca Raton: Chapman and Hall, 2005.

RUE, H.; MARTINO, S.; CHOPIN, N. Approximate Bayesian inference for latent Gaussian models by using integrated nested Laplace approximations, *Journal of the Royal Statistical Society, B*, v.71, p.319–392, 2009.

SCHRÖDLE, B.; HELD, L. Spatio-temporal disease mapping using INLA, *Environmetrics*, v.22, p.725–734, 2011.

SCHRÖDLE, B.; HELD, L.; RIEBLER, A.; DANUSER, J. Using integrated nested Laplace approximations for the evaluation of veterinary surveillance data from Switzerland: a case-study. *Journal of the Royal Statistical Society, C*, v.60, p.261–279, 2011.

SPIEGELHALTER, D.; BEST, N.; CARLIN, B.; VAN DER LINDE, A. Bayesian measures of model complexity and fit, *Journal of the Royal Statistical Society, B*, v.64, p.583–639, 2002.

SUND, P.; BLACKBURN, M.; WILLIAMS, F. Tunas and their environment in the Pacific ocean: a review. *Oceanogr. Mar. Biol. Ann. Rev*, v.19, p.443–512, 1981.

Recebido em 30.11.2018.

Aprovado após revisão em 15.04.2019.