

UNIVERSIDADE DE LISBOA  
FACULDADE DE CIÊNCIAS  
DEPARTAMENTO DE ESTATÍSTICA E INVESTIGAÇÃO OPERACIONAL



**Modelação da distribuição espacial de algumas espécies de tubarões de profundidade - uma abordagem com recurso a processos pontuais espaciais**

Ricardo Jorge da Rocha Machado

**Mestrado em Estatística e Investigação Operacional**  
Especialidade em Estatística

Dissertação orientada por:  
Professora Doutora Patrícia Cortés de Zea Bermudez  
Doutora Teresa Moura



## Agradecimentos

Tudo o que somos, o que construímos e o que alcançamos é influenciado pelos contributos, decisões e ações das pessoas que fazem parte da nossa vida e das que, não fazendo, se tornam parte dela. Assim, neste percurso que acabo de realizar, não poderia deixar de expressar o meu agradecimento àqueles que dele fizeram parte.

Às minhas orientadoras, professora Patrícia Bermudez, pelo desafio, pelas inúmeras aprendizagens ao longo deste percurso, pela ajuda e exigência na orientação desta dissertação; à doutora Teresa Moura, pela ajuda, disponibilidade e por me ter apresentado e permitido aprender sobre uma pequena parte do mundo dos tubarões.

À professora Soraia Pereira, pelas aprendizagens realizadas, por toda a ajuda e paciência ao longo da realização deste trabalho.

À Doutora Ivone Figueiredo, por ter possibilitado a realização deste estudo.

Ao Instituto Português do Mar e da Atmosfera, I.P. (IPMA) e ao Programa Nacional de Amostragem Biológica (PNAB/DCF), pela cedência dos dados analisados; e a todos os colaboradores do IPMA que participaram na recolha dos mesmos.

Aos amigos mais próximos, pela força e apoio que me deram, apesar da minha ausência. Pelas palavras de coragem e incentivo que sempre souberam dizer nas alturas em que mais precisava delas e pelos momentos de descontração, sem os quais tudo teria sido bem mais difícil. Em especial, à Margarida César, por ser quem é, pela força e palavra amiga; ao *Crazy Science Group* pela amizade e partilha de momentos agradáveis, mas também de desânimo e frustração; e ao Marcos, pela amizade e pelo apoio e incentivo constantes.

Por último, e mais fundamental deste percurso: à minha família. Em especial à Gi, pelo amor, amizade, paciência e por ter sempre uma palavra sábia nos momentos certos. Aos meus queridos filhos, Martim e Miguel, pelo amor e por compreenderem as minhas ausências, tendo sempre um sorriso e abraço de conforto. A vocês dedico este trabalho! Aos meus pais, pelo amor incondicional, pelo apoio e por me terem educado tal como sou. Aos meus sogros, que apesar de estarem longe, sempre tiveram uma palavra de apoio, de incentivo e de amizade.

A todos o meu muito obrigado!



## Resumo

A estatística espacial é uma área da estatística que se dedica ao estudo e análise de dados que possuem uma componente espacial, isto é, estão geograficamente localizadas. De entre os tipos de dados espaciais existentes, os padrões pontuais espaciais ocupam um lugar de destaque. A capacidade de identificar padrões espaciais, prever eventos futuros e aplicar esse conhecimento em situações do mundo real torna a estatística espacial e, em especial, os processos pontuais espaciais, uma ferramenta essencial quando se pretende estudar a distribuição de algumas espécies, como por exemplo os tubarões de profundidade, *Etmopterus spinax* e *Etmopterus pusillus*. Estas espécies enfrentam desafios na conservação das suas populações devido à sua captura acidental pela pesca comercial.

O Instituto Português do Mar e da Atmosfera (IPMA) realiza campanhas de investigação anuais de arrasto de fundo desenhadas para monitorizar algumas espécies de interesse comercial, em que estas espécies de tubarão de profundidade são capturadas acessoriamente. O principal objetivo deste trabalho é identificar as zonas nas quais as duas espécies ocorrem e quais os fatores que levam a essa distribuição espacial. Os dados disponíveis compreendem uma série temporal de 1997 a 2018, que permitiu modelar a intensidade da distribuição espacial. Para tal, utilizámos ferramentas de análise espacial de processos pontuais de Poisson, incluindo processos pontuais marcados, com recurso ao pacote *spatstat* do R.

Os resultados sugerem a existência de regiões onde há uma concentração significativamente maior de tubarões destas duas espécies. Para além disso, os modelos construídos permitem identificar zonas de concentração de tubarões juvenis. As conclusões deste estudo irão contribuir para possíveis medidas de proteção e preservação das populações de ambas as espécies.

**Palavras-chave:** Estatística espacial; Processos pontuais espaciais de Poisson; tubarões de profundidade (*Etmopterus pusillus* e *Etmopterus spinax*).



# Abstract

Spatial statistics is an area of statistics that focuses on the study and analysis of data that have a spatial component, that is, geographically localised. Among the existing types of spatial data, those relating to spatial point patterns occupy a prominent place. The ability to identify spatial patterns, predict future events, and apply this knowledge to real-world situations makes spatial statistics, particularly spatial point processes, an essential tool when studying some deep-sea shark species, namely *Etmopterus spinax* and *Etmopterus pusillus*. These species face challenges in the conservation of their populations due to their accidental capture in commercial fisheries.

The *Portuguese Institute of the Sea and Atmosphere* (Instituto Português do Mar e da Atmosfera - IPMA) conducts annual research bottom trawl surveys designed to monitor other species of commercial interest. These deep-sea sharks are also caught so information about both species is collected. The main goal of this work is to identify the areas in which the two species occur and the factors that lead to their spatial distribution. The available data comprise a time series from 1997 to 2018, which enabled modelling the intensity of spatial distribution. To that purpose, we used tools for spatial analysis of Poisson point processes, including marked point processes, through the *R spatstat* package.

The results suggest the existence of areas where there is a significantly higher concentration of sharks of these two species. The models built allow to identify areas of concentration of juveniles. Conclusions from this study will contribute to the adoption of potential measures to protect and preserve the populations of both species.

**Keywords:** Spatial statistics; Poisson spatial point processes; Deep-sea sharks (*Etmopterus pusillus* and *Etmopterus spinax*).



# Índice Geral

Agradecimentos .....	i
Resumo .....	iii
Abstract .....	v
Índice Geral .....	vii
Índice de Figuras .....	ix
Índice de Tabelas .....	xi
<b>1   Introdução .....</b>	<b>1</b>
<b>1.1. Objetivos .....</b>	<b>2</b>
<b>1.2. Organização da dissertação .....</b>	<b>2</b>
<b>2   Tubarões de profundidade: <i>Etmopterus spinax</i> e <i>Etmopterus pusillus</i> .....</b>	<b>5</b>
<b>2.1. Introdução .....</b>	<b>5</b>
<b>2.2. Aspectos da biologia e ecologia de <i>E. spinax</i> e <i>E. pusillus</i> .....</b>	<b>5</b>
2.2.1. Distribuição e caracterização .....	5
2.2.2. Reprodução e ciclo reprodutivo .....	7
2.2.3. Idade e crescimento .....	8
2.2.4. Dieta .....	8
<b>2.3. Características das pescarias que capturam <i>E. spinax</i> e <i>E. pusillus</i> .....</b>	<b>9</b>
<b>2.4. Avaliação do estado das populações de <i>E. spinax</i> e <i>E. pusillus</i> e medidas de gestão .....</b>	<b>10</b>
<b>2.5. Conservação de elasmobrânquios e sua sustentabilidade .....</b>	<b>11</b>
<b>3   Processos Pontuais Espaciais .....</b>	<b>13</b>
<b>3.1. Introdução .....</b>	<b>13</b>
<b>3.2. Processos pontuais espaciais .....</b>	<b>16</b>
3.2.1. Processos de Poisson homogêneos e não homogêneos .....	17
3.2.2. Propriedades de primeira ordem .....	19
3.2.3. Propriedades de segunda ordem .....	20
<b>3.3. Metodologia .....</b>	<b>22</b>
<b>4   Dados .....</b>	<b>23</b>
<b>4.1. Descrição dos dados e definição das variáveis e covariáveis em estudo .....</b>	<b>23</b>
<b>4.2. Análise exploratória dos dados .....</b>	<b>26</b>
4.2.1. <i>Etmopterus spinax</i> .....	26
4.2.2. <i>Etmopterus pusillus</i> .....	33

<b>5</b>	<b>  Resultados</b> .....	39
<b>5.1.</b>	<b>Análise exploratória espacial dos dados</b> .....	39
5.1.1.	<i>Etmopterus spinax</i> .....	39
5.1.2.	<i>Etmopterus pusillus</i> .....	49
<b>5.2.</b>	<b>Modelação</b> .....	57
5.2.1.	<i>Etmopterus spinax</i> .....	57
5.2.2.	<i>Etmopterus pusillus</i> .....	58
<b>6</b>	<b>  Considerações Finais</b> .....	61
	<b>Referências bibliográficas</b> .....	65
	<b>Anexos</b> .....	69

# Índice de Figuras

2.1. Exemplar de um <i>Etmopterus spinax</i> .....	5
2.2. Exemplar de um <i>Etmopterus pusillus</i> .....	5
2.3. Distribuição global da espécie <i>Etmopterus spinax</i> .....	6
2.4. Distribuição global da espécie <i>Etmopterus pusillus</i> .....	6
3.1. Mapa de Londres, em 1856, onde se propagou a doença .....	13
3.2. Dados referentes a pontos: Precipitação média medida em 143 estações no estado do Paraná, Brasil .....	14
3.3. Dados referentes a áreas: Número de mortes súbitas infantis no estado da Carolina do Norte (EUA) em 1974 .....	15
3.4. Dados referentes a processos pontuais espaciais: Distribuição das duas espécies de formigas <i>Cataglyphis</i> e <i>Messor</i> numa determinada região de interesse .....	15
3.5. Tipo de padrão espacial: (A) - aleatório ( <i>random</i> ); (B) - regular ( <i>regular</i> ); (C) - agregado ( <i>clustered</i> ) .....	17
3.6. Função-K para cada tipo de padrão pontual espacial: (A) - aleatório ( <i>random</i> ); (B) agregado ( <i>clustered</i> ); (C) - regular ( <i>regular</i> ). .....	21
4.1. Grelha da campanha de arrasto de crustáceos nas Unidades Funcionais 28 e 29 ..	24
4.2. <i>Box-plot</i> da <i>Duração</i> do arrasto .....	27
4.3. <i>Box-plot</i> da variável <i>NINDIV</i> .....	28
4.4. Número total de indivíduos da espécie <i>E. spinax</i> ao longo dos anos .....	29
4.5. <i>Box-plot</i> do <i>Comprimento</i> da espécie <i>E. spinax</i> .....	30
4.6. Número de indivíduos da espécie <i>E. spinax</i> por classe da variável <i>Profundidade</i>	32
4.7. <i>Box-plot</i> do número de indivíduos da espécie <i>E. spinax</i> em função da <i>Costa</i> .....	32
4.8. <i>Box-plot</i> da profundidade em cada zona da costa – <i>E. spinax</i> .....	33
4.9. <i>Box-plot</i> da variável <i>NINDIV</i> .....	34
4.10. Número total de indivíduos da espécie <i>E. pusillus</i> ao longo dos anos .....	34
4.11. Número de indivíduos da espécie <i>E. pusillus</i> por classe da variável <i>Profundidade</i>	36
4.12. <i>Box-plot</i> do número de indivíduos da espécie <i>E. pusillus</i> em função da <i>Costa</i> .....	36
4.13. <i>Box-plot</i> da profundidade em cada zona da costa – <i>E. pusillus</i> .....	37
5.1. Distribuição espacial dos tubarões da espécie <i>E. spinax</i> (2006 a 2018) .....	40
5.2. Distribuição espacial dos tubarões da espécie <i>E. spinax</i> (2006-2009, 2010-2014 e 2015-2018) .....	40
5.3. Distribuição espacial dos tubarões da espécie <i>E. spinax</i> (2006-2009, 2010-2014 e 2015-2018) .....	41
5.4. Região de interesse com os eventos observados da espécie <i>E. spinax</i> .....	42
5.5. Função-K de Ripley para a espécie <i>E. spinax</i> .....	42
5.6. Envelope da função-K para a espécie <i>E. spinax</i> .....	43
5.7. Técnica de contagem em quadrados para a espécie <i>E. spinax</i> .....	44
5.8. Estimativa kernel da intensidade do padrão com diferentes larguras de banda ...	45
5.9. Função-K de Ripley não homogênea para a espécie <i>E. spinax</i> .....	45

5.10.	Distribuição dos eventos na região de interesse de acordo com a marca <i>comprimento mediano</i> – <i>E. spinax</i> .....	46
5.11.	Distribuição dos eventos na região de interesse de acordo com a marca categórica <i>comprimento mediano</i> – <i>E. spinax</i> .....	47
5.12.	Estimativa de kernel para cada grupo de <i>comprimento mediano</i> – <i>E. spinax</i> .....	47
5.13.	Estimativa de kernel para cada grupo de <i>comprimento mediano</i> – <i>E. spinax</i> entre 2006-2009, 2010-2014 e 2015-2018 .....	48
5.14.	Distribuição espacial dos tubarões da espécie <i>E. pusillus</i> (2006 a 2018) .....	49
5.15.	Região de interesse com os eventos observados da espécie <i>E. pusillus</i> .....	50
5.16.	Função-K de Ripley para a espécie <i>E. pusillus</i> .....	51
5.17.	Estimativa kernel da intensidade do padrão com diferentes larguras de banda ...	52
5.18.	Função-K de Ripley não homogénea para a espécie <i>E. pusillus</i> .....	53
5.19.	Distribuição dos eventos na região de interesse de acordo com a marca <i>comprimento mediano</i> – <i>E. pusillus</i> .....	53
5.20.	Distribuição dos eventos na região de interesse de acordo com a marca categórica <i>comprimento mediano</i> – <i>E. pusillus</i> .....	54
5.21.	Estimativa de kernel para cada grupo de <i>comprimento mediano</i> – <i>E. pusillus</i> .....	55
5.22.	Estimativa de kernel para cada grupo de <i>comprimento mediano</i> – <i>E. pusillus</i> entre 2006-2009, 2010-2014 e 2015-2018 .....	55
5.23.	Distribuição espacial das duas espécies de tubarão .....	56

# Índice de Tabelas

4.1.	Descrição das variáveis do conjunto de dados para cada uma das espécies ( <i>E. spinax</i> e <i>E. pusillus</i> ).....	25
4.2.	Descrição das variáveis do conjunto de dados relativos às características de ambas as espécies .....	25
4.3.	Valores mínimo e máximos da <i>Latitude</i> e <i>Longitude</i> das observações .....	26
4.4.	Medidas descritivas sumárias da <i>Profundidade</i> .....	27
4.5.	Medidas descritivas sumárias da <i>Duração do arrasto</i> .....	27
4.6.	Medidas descritivas sumárias da variável <i>NINDIV</i> .....	28
4.7.	Medidas descritivas sumárias da variável <i>Comprimento</i> .....	29
4.8.	Resumo das observações para a espécie de tubarão de profundidade <i>E. spinax</i> ..	31
4.9.	Medidas descritivas sumárias para a amostra final da espécie <i>E. spinax</i> .....	31
4.10.	Medidas descritivas sumárias da variável <i>NINDIV</i> .....	33
4.11.	Resumo das observações para a espécie de tubarão de profundidade <i>E. pusillus</i>	35
4.12.	Medidas descritivas sumárias para a amostra final da espécie <i>E. pusillus</i> .....	35
5.1.	Número de indivíduos da espécie <i>E. spinax</i> por <i>Costa</i> de acordo com a marca categórica <i>comprimento mediano</i> .....	47
5.2.	Número de indivíduos da espécie <i>E. pusillus</i> por <i>Costa</i> de acordo com a marca categórica <i>comprimento mediano</i> .....	54
5.3.	Parâmetros estimados e erros padrão associados ao modelo com covariável <i>Profundidade</i> – <i>E. spinax</i> .....	57
5.4.	Parâmetros estimados e erros padrão associados ao modelo com covariável <i>Costa</i> – <i>E. spinax</i> .....	57
5.5.	Parâmetros estimados e erros padrão associados ao modelo com covariáveis <i>Profundidade</i> e <i>Costa</i> – <i>E. spinax</i> .....	58
5.6.	Parâmetros estimados e erros padrão associados ao modelo com covariável <i>Profundidade</i> – <i>E. pusillus</i> .....	58
5.7.	Parâmetros estimados e erros padrão associados ao modelo com covariável <i>Costa</i> – <i>E. pusillus</i> .....	59
5.8.	Parâmetros estimados e erros padrão associados ao modelo com covariáveis <i>Profundidade</i> e <i>Costa</i> – <i>E. pusillus</i> .....	59



# 1 | Introdução

A estatística espacial é uma área da estatística que tem como finalidade o estudo de um determinado fenómeno, tendo em conta a localização espacial dos pontos onde este ocorre. (Carvalho & Natário, 2008; Gaetan & Guyan, 2010; Gelfand et al., 2010; van Lieshout, 2019). A sua aplicação tem vindo a crescer, sendo essencial em diversas áreas do conhecimento como a ecologia e a conservação ambiental (por exemplo, na identificação de áreas de alta concentração de espécies e para avaliar a eficácia das áreas protegidas), a epidemiologia e a saúde pública (por exemplo, na identificação de surtos de doenças e análise da propagação de uma doença), a climatologia e a meteorologia (por exemplo, no estudo de padrões climáticos, como variações de temperatura e precipitação em diferentes regiões), a economia (por exemplo, na identificação de padrões de consumo e na localização de pontos de venda), entre outras.

Uma das principais razões pelas quais a estatística espacial é importante é a sua capacidade de analisar padrões espaciais. Ao contrário dos métodos clássicos de análise de dados, a análise espacial considera a distribuição espacial e a dependência espacial, isto é, a influência que a localização de um ponto tem sobre os pontos vizinhos. Com as ferramentas apropriadas, é possível identificar se os eventos estão agrupados (*clusters*), dispersos ou distribuídos de forma aleatória. Essa análise permite compreender os fatores que influenciam os padrões e tomar decisões mais informadas sobre a organização e dinâmica dos processos que ocorrem nessas localizações (Gaetan & Guyan, 2010; Haining, 2004).

Os tubarões constituem um vasto grupo de espécies e um exemplo de sucesso de adaptação ao ambiente marinho, onde desempenham um papel fundamental no equilíbrio dos ecossistemas. No entanto, existem ameaças às suas populações tais como, a pesca e as alterações das condições oceanográficas. Isso constitui um risco para a conservação destes recursos, que apresentam distribuições espaciais complexas e estratégias de vida caracterizadas por crescimento lento, baixa fecundidade e 1.<sup>a</sup> maturação tardia (Coelho & Erzini, 2008a, 2008b, 2010).

Por oposição às espécies que vivem em águas mais superficiais, o conhecimento sobre espécies de tubarões de profundidade é mais limitado e, por vezes, mais difícil de obter devido quer a constrangimentos na recolha de informação quer ao fraco interesse comercial de algumas destas espécies. Em particular, salienta-se o pouco conhecimento sobre a distribuição espacial das suas populações, algo fundamental para o apoio científico à definição de medidas de gestão que garantam a conservação das populações (Henriques et al., 2021; Moura et al., 2014, 2018).

O Instituto Português do Mar e da Atmosfera (IPMA) tem em curso campanhas de investigação anuais para monitorizar espécies de interesse nacional, tais como o lagostim, cujo delineamento foi especificamente dirigido a essas espécies. No entanto, são também capturadas outras espécies, incluindo espécies de tubarões de profundidade, destacando-se as lixinhas da fundura, *Etmopterus spinax*, e as xarinhas pretas, *Etmopterus pusillus*. Por não terem valor comercial são, geralmente, devolvidas ao mar, pelo que se torna importante avaliar o estado dessa população e, eventualmente, propor medidas que garantam a conservação destas espécies de tubarão de profundidade.

Neste contexto, a estatística espacial desempenha um papel significativo, em particular os processos pontuais espaciais, que são ferramentas estatísticas que permitem analisar e prever

a ocorrência de eventos em locais específicos de uma determinada zona de interesse (Baddeley et al., 2016; Illian et al., 2008). Um dos processos pontuais espaciais amplamente utilizado na estatística espacial é o processo de Poisson. Descreve a distribuição de eventos ao longo do espaço, considerando que a probabilidade de ocorrência de um evento em determinada região é proporcional à sua área (Baddeley et al., 2016; Diggle, 2003; Illian et al., 2008).

### 1.1. Objetivos

Para melhor compreender a distribuição espacial destas duas espécies de tubarões, recorreremos aos processos pontuais espaciais de Poisson para analisar a intensidade dos eventos e modelar a distribuição espacial, com base em dados recolhidos numa das campanhas de investigação do IPMA. Para tal, é necessário perceber as zonas nas quais estas duas espécies existem e quais os fatores que motivam essa distribuição espacial. Assim, definiram-se para este estudo os seguintes objetivos: (1) identificar as zonas de maior abundância destas duas espécies de tubarões; e (2) explicar o eventual efeito de covariáveis na distribuição observada (em termos de presença/ausência) na região de estudo.

Pelo que foi dito, esta dissertação tem uma orientação interdisciplinar, na medida em que aplica princípios da estatística espacial, em especial dos processos pontuais espaciais, a situações reais relacionadas com a biologia e a ecologia.

### 1.2. Organização da dissertação

Em termos de organização, este documento inclui sete capítulos, referências bibliográficas e anexos. No Capítulo 1, **Introdução**, discutimos a pertinência do tema escolhido, identificamos os objetivos que orientaram este estudo, bem como descrevemos a estrutura deste trabalho.

Os Capítulos 2 e 3 constituem o quadro de referência teórico que sustenta este trabalho. O Capítulo 2, **Tubarões de Profundidade**, é dedicado a aspetos relacionados com as duas espécies de tubarão de profundidade em estudo, *Etmopterus spinax* e *Etmopterus pusillus*, no que respeita a aspetos da biologia e ecologia, às características das pescarias que capturam estas duas espécies, à avaliação do estado das suas populações e potenciais medidas de gestão que garantam a conservação destas duas espécies de tubarão. No Capítulo 3, **Processos Pontuais Espaciais**, apresentamos alguns dos conceitos que estão na base deste estudo, nomeadamente, a análise espacial e o tipo de dados espaciais existentes, os processos pontuais espaciais (processos de Poisson homogéneo e não homogéneo) e as suas propriedades. Para além disso, descrevemos os modelos utilizados, bem como o software e pacotes aos quais recorreremos.

No Capítulo 4, **Dados**, começamos por enquadrar a problemática que envolve o estudo, explicitando os objetivos que o motivaram e descrevem-se os dados e definem-se as variáveis e covariáveis de estudo. Apresentamos também a análise exploratória desses dados.

No Capítulo 5, **Resultados**, apresentamos e discutimos os resultados, tendo em conta o enquadramento teórico que construímos.

Nas Capítulo 6, **Considerações Finais**, apresentamos as principais conclusões deste estudo, procurando analisar as implicações do trabalho desenvolvido, as suas limitações e perspetivas de trabalho futuro.

Por último, indicamos as referências bibliográficas e incluímos nos anexos os documentos que nos parecem úteis para uma compreensão mais alargada deste trabalho: alguns resultados que permitem complementar a análise e discussão efetuadas, bem como todos os códigos em linguagem R que deram origem aos resultados apresentados.



## 2 | Tubarões de profundidade:

### *Etmopterus spinax* e *Etmopterus pusillus*

#### 2.1. Introdução

Os elasmobrânquios são peixes cartilágneos, ou seja, o seu esqueleto é composto por cartilagem, e agregam dois grandes grupos: os tubarões e as raias. Este grupo de espécies habita a diferentes profundidades, desde zonas costeiras até profundidades superiores a 2000m, ocupando uma grande diversidade de *habitats* (García et al., 2008; Musick, 2005).

O presente estudo foca-se em duas espécies de tubarões de profundidade, frequentes em águas nacionais: a lixinha da fundura, *Etmopterus spinax* (Linnaeus, 1758) (Figura 2.1.) e a xarinha preta, *Etmopterus pusillus* (Lowe, 1839) (Figura 2.2.). Por estarmos a realizar este estudo em Portugal, e por existirem características destas espécies que são específicas de cada área, decidimos centrar este capítulo em investigações efetuadas em Portugal. Apenas faremos menção a estudos internacionais quando o julgarmos essencial.



Figura 2.1. Exemplar de um *Etmopterus spinax* (Fonte: <https://www.sharksandrays.com/velvet-belly-lanternshark/> )



Figura 2.2. Exemplar de um *Etmopterus pusillus* (Fonte: <https://www.shark-references.com/species/view/Etmopterus-pusillus>)

#### 2.2. Aspetos da biologia e ecologia de *E. spinax* e *E. pusillus*

##### 2.2.1. Distribuição e caracterização

A espécie *Etmopterus spinax* ocorre na costa leste do Oceano Atlântico, desde a Islândia e Noruega até ao Gabão, incluindo Açores, Ilhas Canárias e Cabo Verde (Compagno et al., 2005). Também habita o Mar Mediterrâneo, incluindo o Mar Jónico, o baixo Adriático e o Mar Egeu. Distribui-se na plataforma continental e talude superior a profundidades compreendidas

entre os 70 e os 2000m, com especial incidência entre os 200 e os 500m (Compagno et al., 2005). Na Figura 2.3. podemos observar a distribuição global desta espécie.



**Figura 2.3.** Distribuição global da espécie *Etmopterus spinax*  
(Fonte: [https://www.wikiwand.com/en/Velvet\\_belly\\_lanternshark](https://www.wikiwand.com/en/Velvet_belly_lanternshark))

A espécie *Etmopterus pusillus* distribui-se nos Oceanos Atlântico, Índico e Pacífico (Compagno et al., 2005). No Nordeste Atlântico é frequente de Portugal à Namíbia. Habita no talude continental, junto ao fundo, entre os 274 e os 1000m de profundidade, mas também já foi observado em águas oceânicas entre a África do Sul e a Argentina. Na Figura 2.4. podemos observar a distribuição global desta espécie.



**Figura 2.4.** Distribuição global da espécie *Etmopterus pusillus*.  
(Fonte: [https://www.wikiwand.com/en/Smooth\\_lanternshark](https://www.wikiwand.com/en/Smooth_lanternshark))

Em Portugal continental, estas duas espécies são frequentes na vertente continental, em particular entre os 400 e 700m de profundidade (Moura et al., 2018). Um estudo mais detalhado sobre a distribuição em profundidade destas espécies na costa portuguesa (Coelho & Erzini, 2010) concluiu que não ocorriam a profundidades inferiores a 300m e que atingiam o máximo de ocorrência (em número e peso) no estrato de 500m de profundidade.

Ambas as espécies são de dimensões relativamente pequenas quando comparadas com outras espécies de tubarões: na nossa costa, Coelho e Erzini (2010) amostraram fêmeas de *E. spinax* com comprimentos entre os 9.8 e 41.1cm e machos com comprimentos entre 10.2 a 32.9cm. Num outro estudo, Coelho e Erzini (2005) observaram comprimentos de *E. spinax* entre 9.1 e 40.7cm (fêmeas) e de 10.4 a 33.8cm (machos), enquanto que em *E. pusillus* variaram entre 15.9 e 50.2cm (fêmeas) e de 16.1 a 47.9cm (machos). O comprimento refere-se ao

comprimento total, medido em linha reta desde a ponta do focinho até à ponta da barbatana caudal.

É reconhecido que os tubarões podem apresentar segregação espacial, ou seja, a sua distribuição pode ser diferente consoante o tamanho ou fase de vida (Moura et al., 2014; Wearmouth & Sims, 2008). Isto significa que a profundidade e o local em que as operações de pesca decorrem são variáveis importantes para a sustentabilidade destas espécies. Neste sentido, observou-se que, entre os 300 e os 500m de profundidade, o comprimento dos indivíduos capturados era semelhante para ambos os sexos, mas a maior profundidade (600m), as fêmeas tendiam a ser maiores do que os machos. Importa realçar que as fêmeas podem atingir maiores dimensões e ser mais pesadas. Também quanto à idade, numa maior profundidade (600m e 700m), os espécimes mais novos encontrados já tinham, pelo menos, 4 anos. A relação entre sexo e profundidade mostrou que, nos 700m, apenas se capturaram fêmeas (2 espécimes). Entre os 300 e os 500m o número de machos e de fêmeas observado foi semelhante. A maturação também se relaciona com a profundidade: os indivíduos maduros encontram-se em maiores profundidades (> 500m), com exceção das fêmeas na fase final de desenvolvimento embrionário que tendem a ocorrer a profundidades menores ou iguais a 500m.

### 2.2.2. Reprodução e ciclo reprodutivo

Os tubarões das espécies *Etmopterus spinax* e *E. pusillus* têm uma maturação tardia. O estado de maturação é atribuído por observação das características do sistema reprodutivo, seguindo escalas de maturação pré-definidas. Em ambas as espécies, as fêmeas tendem a atingir a primeira maturação mais cedo e a serem maiores do que os machos (Coelho & Erzini, 2005). Os tamanhos de primeira maturação de *E. spinax*, segundo Coelho e Erzini (2005), são, em média, de 30.86cm para as fêmeas (75.8% do comprimento máximo observado) e 25.39cm para os machos (75.1% do comprimento máximo observado). As fêmeas atingem a primeira maturação mais tarde (4.67 anos) do que os machos (3.97 anos) (Coelho & Erzini, 2008a).

No caso de *E. pusillus* observou-se um comprimento médio de primeira maturação de 43.60cm nas fêmeas e de 38.10cm nos machos (86.9% e 79.5% do comprimento máximo observado, respetivamente; Coelho & Erzini, 2005). Estes resultados são semelhantes aos de Porcu et al. (2014), no Mediterrâneo, que observaram que o comprimento de primeira maturação corresponde a 80.7% e 79% do comprimento máximo das fêmeas e machos, respetivamente. As fêmeas atingem a maturação mais tarde do que os machos, 9.86 e 7.13 anos, respetivamente (Coelho & Erzini, 2007).

Estas espécies têm fertilização interna, são vivíparas e aplacentárias, ou seja, o desenvolvimento embrionário decorre no interior da fêmea e sem transferência de nutrientes da mãe para o embrião, dependendo este apenas da reserva de vitelo. Têm uma baixa fecundidade e um ciclo reprodutivo longo, que pode durar cerca de 2 ou 3 anos (Coelho & Erzini, 2008b). Nestas espécies vivíparas, pode estimar-se a fecundidade ovárica e a fecundidade uterina. A primeira refere-se ao número médio de folículos maduros observados no ovário de fêmeas maduras. A fecundidade uterina corresponde ao número de embriões no interior do útero durante o desenvolvimento embrionário. Coelho e Erzini (2008b) observaram uma fecundidade baixa em *E. spinax*, com uma média de 9.94 oócitos e 7.59 embriões por ciclo reprodutivo. No caso de *E. pusillus*, para o Mediterrâneo, Porcu et al. (2014) reportaram uma fecundidade ovárica de

16.5 de folículos maduros em *E. pusillus*, corroborando os dados obtidos por Coelho e Erzini (2007) na costa portuguesa, em que a fecundidade ovárica foi estimada em 10.44 folículos maduros. Num estágio inicial do desenvolvimento embrionário, foram observados um a seis embriões. Foi amostrada uma única fêmea no estado final do desenvolvimento embrionário a qual tinha 6 embriões totalmente formados. Segundo Coelho e Erzini (2007), as diferenças entre a fecundidade ovárica e uterina podem ser explicadas por: (1) alguns dos folículos nunca se desenvolverem em embriões; e (2) sendo uma espécie sem placenta e sem cordão umbilical que ligue o embrião à mãe, o *stress* provocado pelo processo de pesca pode fazer com que alguns embriões sejam expulsos quando as fêmeas grávidas são capturadas.

No caso de *E. spinax*, as fêmeas maduras, com embriões em início de desenvolvimento e pós-parturição, são capturadas ao longo de todos os meses do ano. Já as fêmeas na fase final do desenvolvimento embrionário, apenas foram capturadas em junho. No caso dos machos, os indivíduos maduros também foram capturados ao longo de todos os meses do ano, embora os machos não-ativos fossem capturados em percentagens mais elevadas nos meses de verão. Estes resultados sugerem que pode haver sazonalidade nos eventos reprodutivos (Coelho & Erzini, 2008b). Num estudo realizado na Sardenha (Mediterrâneo), os machos maduros de *E. spinax* foram amostrados entre a primavera e outono, enquanto que os machos ativos foram amostrados no outono e no inverno (Porcu et al., 2014). No caso de *E. pusillus*, foram detetadas fêmeas grávidas entre novembro e abril (Coelho & Erzini, 2007), mas o número amostrado foi reduzido o que condiciona as conclusões do estudo. No caso dos machos, foram observados machos ativos ao longo de todo o ano o que é indicativo de não existência de uma época reprodutiva definida.

### 2.2.3. Idade e crescimento

Nestas espécies de tubarões, a idade tem sido estudada com base na contagem de bandas de crescimento em vértebras (Coelho & Erzini, 2007, 2008b; Gennari & Scacco, 2007). A recolha desta informação permite o ajuste de modelos de crescimento, os quais devem ser ajustados para fêmeas e machos em separado para posterior teste de existência de diferenças no crescimento entre sexos. Coelho e Erzini (2008b) estudaram o crescimento de *E. spinax* tendo observado machos com a idade máxima de 8 anos e fêmeas com 11 anos. Neste estudo não se observaram diferenças nos parâmetros de crescimento entre os sexos dos 0 aos 4 anos, mas sim a partir dos 5 anos. No que se refere à idade de *E. pusillus*, Coelho e Erzini (2007) verificaram que os machos atingiam um máximo de 13 anos e as fêmeas de 17 anos. Observaram-se diferenças entre sexos nos parâmetros de crescimento, mas estas não são evidentes entre 1 e 5 anos de idade.

### 2.2.4. Dieta

Muñoz (2015) estudou a composição da dieta destas duas espécies na costa algarvia. Um resultado importante é não se verificarem grandes diferenças na dieta destas duas espécies. Observou-se que elas partilham os mesmos recursos, embora em proporções diferentes. Ambas se alimentam principalmente de crustáceos, peixes e cefalópodes. Para *E. spinax*, o padrão alimentar inclui crustáceos da subordem Natantia (presas preferenciais), peixes não identificados (presas secundárias) e cefalópodes (presas acessórias) (Muñoz, 2015). Nesta

espécie, verificou-se uma predominância de pequenos crustáceos nos indivíduos imaturos, enquanto os maturos se alimentavam de presas maiores, como peixes. Desta forma, concluiu-se que, à semelhança de outras espécies de peixes cartilagíneos, a fase do ciclo de vida influencia a dieta. Segundo a mesma autora, as principais presas encontradas na dieta de *E. pusillus* foram peixes não identificados (presas preferenciais), crustáceos da subordem Natantia (presas secundárias) e cefalópodes (presas acessórias).

Neiva et al. (2006) também caracterizaram a dieta de *E. spinax* na costa Sul de Portugal (Algarve) concluindo que se baseava em macro- e microplâncton, peixes e cefalópodes. Estes autores não encontraram diferenças significativas na dieta em função do sexo ou da maturação, mas sim em função do comprimento. Os espécimes de maior dimensão (> 28cm) alimentam-se predominantemente de peixes e cefalópodes. Os de menor dimensão consomem sobretudo crustáceos. Estas diferenças podem dever-se a uma maior capacidade predadora (nadarem mais rapidamente, terem melhores estratégias de predação, além de bocas e estômagos de maiores dimensões).

Xavier et al. (2012) estudaram a dieta de *E. pusillus* na costa Sul de Portugal (Algarve), identificando que esta se baseava em peixe (87%), crustáceos (7.7%) e cefalópodes (4.7%). Alimentam-se de espécies não-comerciais, pelo que não competem diretamente com a pesca comercial. Não encontraram diferenças significativas entre os sexos no que se refere à dieta. Quanto às diferenças ontogénicas, identificaram quatro grupos de comprimento, com quatro dietas diferenciadas:

- 1)  $\leq 25$ cm – dieta quase exclusivamente de crustáceos (78.8%) e alguns cefalópodes (11.2%) e peixes (5.5%).
- 2) 26 a 30cm – predominância de crustáceos Natantia.
- 3) 31 a 35cm – predominância de peixes.
- 4)  $> 35$ cm – predominância de peixes teleósteos (em particular verdinho *Micromesistius poutassou* e indivíduos da família Myctophidae não identificados).

Com o aumento do comprimento, os crustáceos perdem e os peixes ganham importância na dieta desta espécie. Esta mudança na dieta está provavelmente relacionada com a capacidade predatória, tal como sugerido para *E. spinax*: maior velocidade na natação, boca e estômagos de maiores dimensões.

### **2.3. Características das pescarias que capturam *E. spinax* e *E. pusillus***

Tanto *E. spinax* como *E. pusillus* são capturados em diversas pescarias que ocorrem na costa portuguesa, em particular as que operam a maiores profundidades como as pescarias de arrasto dirigidas ao lagostim, gamba e camarão vermelho, e nas pescarias com palangre de fundo, dirigidas ao cherne, congro, pescada e peixe-espada preto (Bordalo-Machado et al., 2009; Coelho & Erzini, 2007, 2008b; Fernandes et al., 2017). Os arrastões com pesca dirigida a crustáceos operam geralmente em fundos lamacentos e arenosos, enquanto os palangreiros operam frequentemente em fundos rochosos.

De acordo com Coelho e Erzini (2008a), as pescarias com redes de arrasto capturam espécimes de menor tamanho e peso, correspondendo a maioria a indivíduos imaturos (cerca de 80% em ambas as espécies). No mesmo estudo, verificou-se que na pesca com palangre

69.2% de *E. pusillus* eram imaturos e 88.2% de *E. spinax* maduros. Estes dados sugerem que a pesca com redes de arrasto pode ter um impacto mais negativo nas populações destas duas espécies.

Coelho e Erzini (2008a) verificaram que os machos de *E. pusillus* foram mais frequentes nas redes de arrasto do que as fêmeas, enquanto que nos palangres dirigidos à pescada, congro e cherne, ocorreram mais fêmeas de *E. spinax* e machos de *E. pusillus* (Coelho & Erzini, 2008a). Assim, estas duas espécies parecem ser afetadas de forma diferente por cada um destes tipos de pesca.

Para além de serem captura acessória, estas espécies não têm valor comercial sendo geralmente devolvidas ao mar assim que são capturadas. Porém, a sua capacidade de sobrevivência é reduzida, morrendo durante ou depois da operação de pesca. Coelho e Erzini (2005) focam duas explicações para a elevada mortalidade: (1) rápidas diferenças de pressão e temperatura durante a operação de pesca; e (2) a manipulação a que são sujeitos enquanto estão a bordo das embarcações de pesca comercial. Num estudo citado por Coelho e Erzini (2007), em que os animais capturados foram mantidos num tanque com temperatura controlada, estes morreram num período de 48 horas. Estes autores consideram que é possível que a taxa de sobrevivência, depois de devolvidos ao mar, possa estar perto do zero. Num estudo posterior, referente a *E. spinax*, foi observado que, na pesca de arrasto, os espécimes tendiam a chegar mortos aos barcos, enquanto que na pesca com palangre muitos ainda chegavam vivos, embora com ferimentos causados pelos anzóis, bem como pelas diferenças de pressão e temperatura, acabando igualmente por não sobreviver (Coelho & Erzini, 2008b).

Dado que estas duas espécies são devolvidas ao mar por não terem interesse comercial, não são reportadas e não constam das estatísticas de pesca, dificultando o estudo da mortalidade e dos impactes da pesca nestas espécies. Esta falta de dados impede a avaliação rigorosa do estado das suas populações (Coelho & Erzini, 2005, 2007, 2008b).

#### **2.4. Avaliação do estado das populações de *E. spinax* e *E. pusillus* e medidas de gestão**

Desde 2005 que estão em vigor regulamentos que pretendem minimizar a captura de tubarões de profundidade nas pescarias europeias (e.g., Regulamento (CE) 2270/2004 do Conselho). Foi estabelecido um TAC para um conjunto de espécies cujo valor diminuiu até 2010, ano em que foi estabelecido um TAC 0, ou seja, em que deixou de ser possível desembarcar espécies constantes da lista mencionada. Desde 2021 que estas espécies estão proibidas (Regulamento (UE) 2021/91 do Conselho). *Etmopterus spinax* faz parte desta lista espécies proibidas, ao contrário de *E. pusillus*. Segundo o Conselho Internacional para a Exploração do Mar (ICES) (2021), esta lista tem como objetivo proteger as espécies de maior importância para a conservação. As espécies objeto deste estudo não são alvo de aconselhamento científico no âmbito do ICES, ao contrário de espécies que tiveram maior interesse comercial no passado como a lixa *Centropristis squamosus* e o caroco *Centroscymnus coelolepis*. *Etmopterus spinax* é, no entanto, avaliada no âmbito da Diretiva-Quadro Estratégia Marinha. No último relatório de avaliação das estratégias marinhas, esta foi considerada como estando em Bom Estado Ambiental (MM, 2020). Esta avaliação considerou dados de biomassa recolhidos em campanhas de investigação do IPMA. No entanto, não considera a distribuição espacial da espécie, pelo que é bastante útil o seu estudo ao longo da

costa portuguesa assim como da sua congénere *E. pusillus*, que poderá ser avaliada no futuro. Não obstante, é importante continuar a obter informação espacial e temporal para responder adequadamente aos diferentes critérios e ações emanadas pelas diretivas internacionais e nacionais (MM, 2020).

## **2.5. Conservação de elasmobrânquios e sua sustentabilidade**

No início deste século vários estudos analisaram ou mencionaram a captura acessória de elasmobrânquios no sul de Portugal, realçando a importância de investigar estas espécies. Monteiro et al. (2001) analisaram as capturas involuntárias da pesca de arrasto. Erzini et al. (2001) estudaram a pesca com palangre de profundidade. Coelho et al. (2003) estudaram as capturas acessórias de elasmobrânquios na pescaria com palangre de fundo dirigida à pescada. Coelho et al. (2005) descreveram as capturas de elasmobrânquios semipelágicos com palangre e redes de tresmalho no sul de Portugal identificando a composição das capturas, taxas de capturas e devoluções ao mar. Estes estudos são importantes pois permitem caracterizar as capturas destes predadores que têm um papel essencial nos ecossistemas marinhos, contribuindo para um melhor conhecimento com vista à sua sustentabilidade.

*Etmopterus spinax* e *E. pusillus*, tal como outros tubarões, possuem características de vida únicas, como um crescimento mais lento, maior longevidade, menor fecundidade e uma maturação mais tardia que a maioria dos outros peixes o que os torna mais vulneráveis a uma exploração pesqueira intensa (Hoenig & Gruber, 1990). De notar que as espécies de profundidade são geralmente mais vulneráveis do que as espécies oceânicas, costeiras e epipelágicas, pois estas características de vida são agravadas (García et al., 2008). Dado o seu crescimento lento e baixa fecundidade, percebemos que, quando as populações diminuem drasticamente (como, por exemplo, por efeito da pesca), são necessárias várias décadas para que possam, eventualmente, vir a recuperar (Pratt & Casey, 1990). Estão documentados decréscimos acentuados de abundância em algumas populações de elasmobrânquios, devido à pesca (Henriques et al., 2021). Quer uma avaliação correta do estado da população quer a proposta de medidas que evitem ou minimizem a sua captura nas diferentes artes de pesca, requer a realização de estudos detalhados sobre espécies e impacto da pesca nas suas populações (Coelho et al., 2015). Tal aplica-se às duas espécies em estudo: como afirmam Coelho e Erzini (2010) sobre *E. spinax*, “Dada a elevada mortalidade por pesca que esta espécie sofre atualmente ao longo da costa portuguesa, torna-se necessário compreender como esta espécie se distribui ao longo da sua profundidade, de forma a compreender as repercussões ecológicas destas pescarias”.

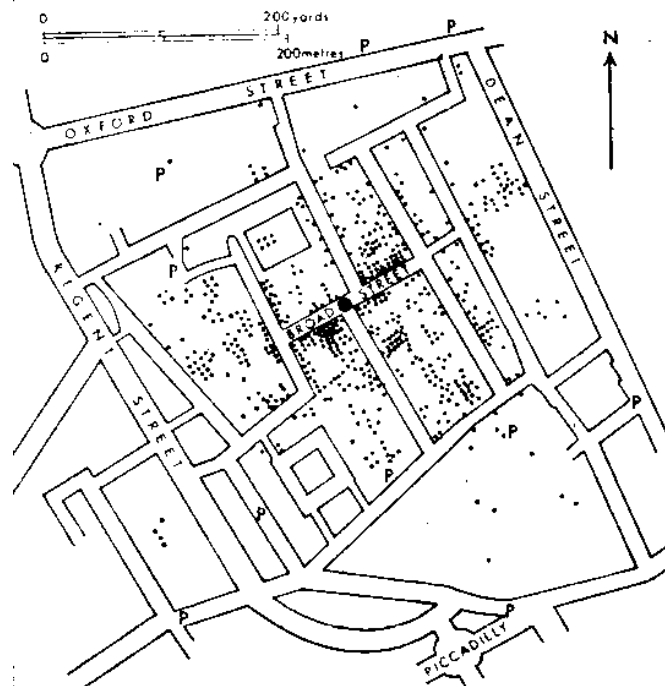


### 3 | Processos Pontuais Espaciais

#### 3.1. Introdução

A análise espacial tem vindo a assumir um papel importante em inúmeras áreas como, por exemplo, na epidemiologia (Lin & Wen, 2022), na ecologia (Owen et al., 2017), na criminologia (Tavares & Costa, 2021), na prevenção de incêndios (Serra et al., 2013), na estimação do desemprego (Pereira et al., 2021), entre outras (Gelfand et al., 2010; Haining, 2004; van Lieshout, 2019; Yue & Loh, 2015).

Quando se começa a trabalhar nesta área, um dos primeiros exemplos que nos aparece como essencial para a compreensão da existência e importância dos dados espaciais, está relacionado com o trabalho do médico britânico John Snow, em 1854 (Carvalho & Natário, 2008; Snow, 1855). Nessa altura, fruto de uma epidemia de cólera trazida da Índia, e que se propagou em Londres, John Snow, recorrendo ao mapa da zona de Londres, localizou os locais dos óbitos provocados pela doença e as bombas de água que abasteciam a cidade (ver Figura 3.1.).



Legenda: P – poço; • - poço contaminado; • - óbitos

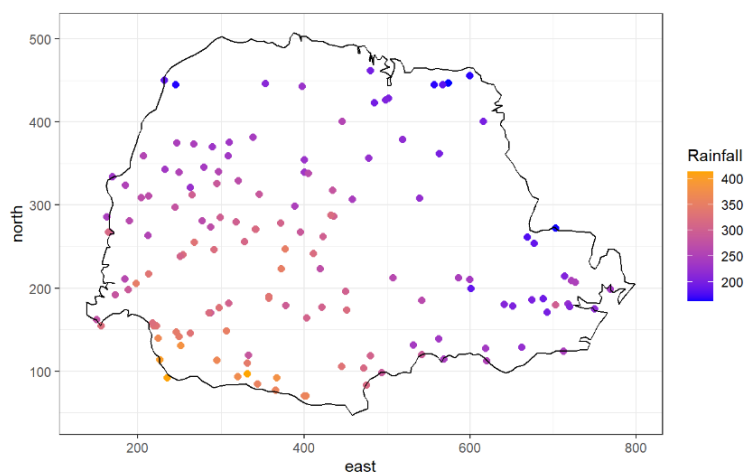
**Figura 3.1.** Mapa de Londres, em 1856, onde se propagou a doença.  
(Fonte: [https://www.york.ac.uk/depts/math/histstat/snow\\_map.htm](https://www.york.ac.uk/depts/math/histstat/snow_map.htm))

Este registo permitiu perceber que havia um padrão, estabelecendo uma relação entre os locais onde ocorreram os óbitos e as bombas de água que abasteciam a cidade. A partir deste tipo simples de análise espacial, John Snow foi capaz de identificar a origem do surto de cólera:

um poço de água contaminado. Depois de alguns estudos posteriores, veio a confirmar-se a hipótese avançada por este médico, o que levou ao encerramento deste poço, salvando muitas vidas. Não só a taxa de mortalidade devido à cólera diminuiu em Londres, como também forneceu novos conhecimentos e provas à comunidade médica, que acabou por identificar que a doença não era transmitida por via aérea, mas era o resultado da ingestão de alimentos e bebidas contaminados. Desta forma, o seu trabalho é considerado pioneiro, sendo o primeiro exemplo de um estudo espacial de um problema de saúde pública (Carvalho & Natário, 2008; Gelfand et al., 2010).

A necessidade de compreender, interpretar e prever a ocorrência de acontecimentos que dependem da localização espacial tem despertado interesse nas mais diversas áreas de conhecimento, contribuindo para o desenvolvimento de modelos que incorporem esse carácter espacial dos dados (Cressie et al., 2022; Møller & Waagepetersen, 2017). Os dados espaciais podem ser classificados em três categorias: (1) dados referenciados por pontos (também designada por geoestatística); (2) dados de áreas; e (3) dados de processos pontuais espaciais (Baddeley et al., 2016; Carvalho & Natário, 2008; Haining, 2004; van Lieshout, 2019).


De acordo com Carvalho e Natário (2008) e van Lieshout (2019), os dados referenciados por pontos correspondem a observações fixas de um domínio espacial contínuo limitado. Quando se recorre a este tipo de dados, o objetivo é a predição de uma determinada característica do fenómeno observado nessas localizações fixas para pontos que não foram observados. Como exemplo deste tipo de dados espaciais, pode observar-se, na Figura 3.2., a precipitação média para o período Maio-Junho (estação seca) em diferentes anos, recolhida em 143 estações em todo o Estado do Paraná, Brasil (R Foundation, 2020). Estes dados, acedidos no *package geoR* (Ribeiro et al., 2022), na base de dados *parana*, representam medidas de pluviosidade obtidas em estações específicas, podendo-se prever a pluviosidade em locais não amostrados.



**Figura 3.2.** Dados referentes a pontos: Precipitação média medida em 143 estações no estado do Paraná, Brasil.

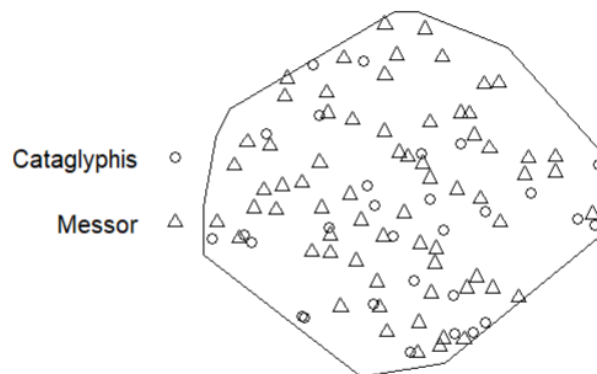
Por outro lado, os dados referentes a áreas correspondem a contagens ou a médias de quantidades de interesse num conjunto de áreas de determinada região. Tal como no tipo de dados referenciados por pontos, a finalidade da utilização de dados em áreas é a predição de

valores não observados numa ou mais áreas, bem como a procura de padrões espaciais da distribuição das observações numa determinada região (Carvalho & Natário, 2008). Na Figura 3.3. pode observar-se um exemplo deste tipo de dados, em que é retratado o número de mortes súbitas infantis em cada um dos condados da Carolina do Norte, EUA, em 1974 (R Foundation, 2020). Nesta situação, os dados acedidos no *package spData* (Bivand et al., 2023), base de dados *nc.sids*, permitem perceber que a região de interesse (o estado da Carolina do Norte) apresenta-se dividida num número finito de sub-regiões (condados), sendo as observações agregadas por condado.



**Figura 3.3.** Dados referentes a áreas: Número de mortes súbitas infantis no estado da Carolina do Norte (EUA) em 1974.

Por último, nos dados referentes a processos pontuais espaciais o interesse centra-se nas localizações onde ocorre determinado fenómeno, numa determinada região, habitualmente designada por janela. O objetivo dessa análise prende-se com estudar a disposição das ocorrências do evento de interesse no espaço (por exemplo, aleatório ou aglomerado) e encontrar modelos que permitam explicar o padrão observado. Considerando o exemplo disponível no *package spatstat* do R (Baddeley et al., 2016) – *Harkness-Isham ants' nests data* – estudou-se a localização dos ninhos de duas espécies de formigas, *Cataglyphis* e *Messor*, numa determinada região de interesse, para se perceber se existia ou não competição entre as duas espécies e, como tal, se haveria uma distribuição preferencial dos ninhos, de acordo com a espécie (ver Figura 3.4.).



**Figura 3.4.** Dados referentes a processos pontuais espaciais: Distribuição das duas espécies de formigas *Cataglyphis* e *Messor* numa determinada região de interesse

De acordo com a classificação apresentada anteriormente e tendo em conta a natureza dos dados utilizados nesta dissertação, a análise estatística realizada recorre a processos pontuais espaciais. Assim, neste capítulo iremos apresentar alguns conceitos e propriedades dos processos pontuais espaciais que nos permitirão nortear a análise a efetuar.

### 3.2. Processos pontuais espaciais


A teoria dos processos pontuais surgiu com a necessidade de modelar como aleatória a localização de acontecimentos de interesse (Carvalho & Natário, 2008; Diggle, 2003). Assim, a análise associada aos processos pontuais espaciais procura descrever padrões dos pontos no espaço, ou seja, avaliar se a distribuição dentro da área observada, é regular ou irregular, inferindo sobre essa distribuição. Nos processos pontuais espaciais todos os pontos disponíveis numa determinada região considerada são observáveis e os locais são variáveis aleatórias.

Na teoria dos processos pontuais espaciais, cada ponto é tratado como um evento, ou seja, cada ponto corresponde à localização de um determinado evento de interesse e, por isso, pode acontecer com uma determinada probabilidade. Portanto, o conjunto de todas as ocorrências do evento de interesse determina um padrão de pontos específico. Assim, estabelecendo uma relação com o exemplo da cólera anteriormente focado, a informação que se tem é a localização de todas as casas onde foram observadas mortes por essa doença, ou seja, a localização dos eventos e a totalidade dos mesmos, criando-se um mapa com o padrão das respetivas ocorrências.

Desta forma, um padrão de pontos pode ser encarado como um conjunto de localizações  $\mathbf{x} = (x_1, x_2, x_3, \dots)$  numa região de estudo definida,  $R$ , onde os eventos de interesse são observados e registados. Esta região  $R$  pode ser retangular ou assumir uma forma poligonal mais complexa. Em todo o caso, e para este estudo, iremos assumir que a região  $R$  é um subconjunto de  $\mathbb{R}^2$ , isto é,  $R \subseteq \mathbb{R}^2$ , uma vez que apenas nos referimos a processos pontuais espaciais em  $\mathbb{R}^2$ , embora a metodologia se possa adaptar a qualquer espaço  $\mathbb{R}^d$ , numa dimensão arbitrária  $d$ , em que  $d \in \mathbb{N}$ .

De acordo com Gatrell et al. (1996) e Illian et al. (2008), considera-se um padrão de pontos espaciais como o resultado de um processo espacial estocástico, ou seja, o número de eventos que ocorrem numa região arbitrária  $A$ , em que  $A \subseteq R$ . Assim, o processo pontual espacial é representado por uma variável aleatória  $N(A)$ , onde  $N(A)$  é o número de eventos que ocorrem na região  $A$ .

De uma forma geral, os processos pontuais espaciais podem ser divididos em três classes, de acordo com a forma como os pontos estão distribuídos, agrupados ou dispersos, como podemos observar na Figura 3.5., cujos exemplos foram retirados do *package spatstat* do R (Baddeley et al., 2016) da base de dados *japanesepines* (A), *cells* (B) e *redwood* (C) (R Foundation, 2020).



**Figura 3.5.** Tipo de padrão espacial: (A) - aleatório (*random*) ; (B) - regular (*regular*); (C) - agregado (*clustered*)

Quando o padrão de pontos espaciais não tem uma disposição óbvia é designado por aleatório (*random*), referido muitas vezes por aleatoriedade espacial completa (*Complete Spatial Randomness* (CSR)) (Figura 3.5. - A). No caso de existir uma estrutura em que os pontos tendem a ser distribuídos uniformemente é chamado regular (*regular*) (Figura 3.5. - B). Quando o padrão de pontos espaciais tem uma distribuição em que os pontos tendem a agrupar-se em determinados locais, é designado por padrão agregado (*clustered*) (Figura 3.5. - C) (Baddeley et al., 2016; Bivand et al., 2008; Gaetan & Guyan, 2010; Illian et al., 2008).

Quando num processo pontual espacial a cada ponto se associa uma determinada característica – marca – passa-se a ter um processo pontual espacial marcado (Baddeley et al., 2016; Carvalho & Natário, 2008). Essa marca permite anexar informação adicional ao objeto em estudo, podendo ser numérica (por exemplo, a altura de uma espécie de uma árvore) ou categórica (por exemplo, o tipo de espécie, o tipo de crime, o tipo de doença).

### 3.2.1. Processos de Poisson homogêneos e não homogêneos

Os processos pontuais espaciais são bem modelados por uma distribuição de Poisson (Baddeley et al., 2006; Baddeley et al., 2016; Gaetan & Guyan, 2010). Habitualmente, a distribuição de Poisson está relacionada com a modelação da frequência de eventos raros como, por exemplo, a modelação de acidentes ou de casos de doenças raras, entre outros (Baddeley et al., 2006; Baddeley et al., 2016).

Assumindo que a variável aleatória  $N$  tem distribuição de Poisson, a probabilidade de se obterem exatamente  $k$  eventos é dada por:

$$P\{N = k\} = \frac{\lambda^k}{k!} e^{-\lambda}$$

onde  $k = 0,1,2,3, \dots$  e  $\lambda > 0$  é o único parâmetro, sendo igual ao valor médio e à variância da distribuição.

Considerando  $R$  a região de interesse e  $N(R)$  o número de eventos que ocorrem em  $R$ , o processo pontual espacial de Poisson diz-se homogéneo se verificar as seguintes condições:

- (1) Para um determinado valor  $\lambda$ , com  $\lambda > 0$ ,  $N(R)$  segue uma distribuição de Poisson, com valor médio igual a  $\lambda|R|$ , onde  $|R|$  representa a área de  $R$
- (2) Dado  $N(R) = s$ , os  $s$  eventos formam uma amostra aleatória independente a partir de uma distribuição uniforme em  $R$ .
- (3) Para duas quaisquer regiões disjuntas  $A$  e  $B$ , as variáveis aleatórias  $N(A)$  e  $N(B)$  são independentes.

O parâmetro  $\lambda$  do processo de Poisson, que é uma constante, designa-se por intensidade.

Deste modo, considera-se um processo espacial de Poisson homogéneo com intensidade  $\lambda$ , com  $\lambda > 0$ , quando este é descrito por uma distribuição de Poisson; é homogéneo, isto é, o número de eventos que ocorre numa determinada região tem como valor médio o produto entre a área da região de interesse e o valor médio do número de eventos por unidade de área; e é independente, ou seja, considerando partições da região de interesse que não se sobreponham, o número de eventos em cada partição são variáveis aleatórias independentes. Em suma, um processo espacial de Poisson é homogéneo quando a intensidade dos pontos é constante e as localizações dos eventos são independentes umas das outras.

Nestas condições,  $\lambda$  não depende de qualquer variável, pelo que é o esperado que aconteça num padrão de pontos espaciais aleatórios. Nesse tipo de padrão não há tendência para que os eventos ocorram em locais específicos e, portanto, cada evento é igualmente provável ocorrer em qualquer local da região de interesse (homogeneidade). Assim, a aleatoriedade espacial completa (CSR) é satisfeita pelo processo de Poisson homogéneo, onde todos os eventos são localizados independentemente uns dos outros (independência). Ainda que esta situação não seja observável na prática, esta tem um papel importante como modelo nulo e como ponto de partida para a construção de modelos de processos pontuais espaciais mais adequados à realidade (Baddeley et al., 2006; Baddeley et al., 2016; Carvalho & Natário, 2008; Yue & Loh, 2015).

Nesse sentido, para ultrapassar a questão da homogeneidade, considera-se uma extensão do processo de Poisson, que se designa por Processo de Poisson não homogéneo, em que se substitui o parâmetro  $\lambda$  por uma função espacialmente variável  $\lambda(\mathbf{x})$ . Assim, considerando  $R$  a região de interesse e  $N(R)$  o número de eventos em  $R$ , o processo pontual espacial de Poisson diz-se não homogéneo se verifica as seguintes condições:

- (1) Para uma determinada função  $\lambda(\mathbf{x}) > 0, \forall \mathbf{x} \in R$ ,  $N(R)$  segue uma distribuição de Poisson, com valor médio igual a  $\int_R \lambda(\mathbf{x}) d\mathbf{x}$ .
- (2) Dado  $N(R) = s$ , os  $s$  eventos formam uma amostra aleatória independente a partir da distribuição em  $R$  com função de densidade de probabilidade proporcional a  $\lambda(\mathbf{x})$ .
- (3) Para duas quaisquer regiões disjuntas  $A$  e  $B$ , as variáveis aleatórias  $N(A)$  e  $N(B)$  são independentes.

Neste processo, o parâmetro  $\lambda(x)$  designa-se por função de intensidade do processo de Poisson não homogéneo. Como a função intensidade é agora variável em  $x$ , este modelo é capaz de representar diferenças entre localizações na região de interesse  $R$ .

Assim, comparando os dois tipos de processos espaciais de Poisson, existem duas condições que permanecem iguais, ou seja, ambos os processos são descritos por uma distribuição de Poisson e são independentes. No entanto, quando se considera um processo espacial de Poisson não homogéneo, a intensidade constante do processo Poisson homogéneo é substituída por uma função de intensidade,  $\lambda(x)$ , cujo valor varia com a localização. Para além disso, a função de intensidade incorpora tanto a abundância de pontos, como a distribuição espacial dos pontos individuais, por consequência da condição (2), em que os eventos são independentes e identicamente distribuídos com densidade de probabilidade proporcional à função de intensidade.

Como caso particular de um processo pontual espacial de Poisson não homogéneo temos o processo espacial de Cox Log-Gaussiano (*Log Gaussian Cox Process, LGCP*) (Baddeley et al., 2016). Sendo uma extensão dos processos pontuais espaciais de Poisson, a importância do LGCP reside na sua capacidade de capturar a dependência espacial dos eventos, ou seja, como a ocorrência de um evento num local afeta a probabilidade de ocorrerem eventos em locais vizinhos. Isso é particularmente útil em cenários em que os eventos não estão distribuídos de forma independente, como aglomerados (*clustering*), como é comum em dados espaciais do mundo real. Neste tipo de modelos, a intensidade do processo é considerada uma função aleatória (Baddeley et al., 2016).

Os processos pontuais espaciais de Poisson têm determinadas propriedades que serão apresentadas com base nas definições e resultados apresentados em Baddeley et al. (2016), Carvalho e Natário (2008) e Illian et al. (2008).

### 3.2.2. Propriedades de primeira ordem

As propriedades de primeira ordem dos processos estocásticos dizem respeito à caracterização dos efeitos em larga escala. No caso dos processos pontuais espaciais de Poisson, estas correspondem a variações no valor médio do processo no espaço e são descritas através de uma função de intensidade de primeira ordem (Carvalho & Natário, 2008).

De acordo com Baddeley et al. (2016), a intensidade é a densidade (localizada) esperada de pontos por unidade de área. É usualmente interpretada como a taxa de ocorrência, abundância ou incidência dos eventos registados no padrão de pontos. Assim, a intensidade é uma característica descritiva básica de qualquer processo pontual espacial e é definida por:

$$\lambda(x) = \lim_{|dx| \rightarrow 0} \left\{ \frac{E[N(dx)]}{|dx|} \right\}$$

onde  $dx$  é uma pequena região contendo o ponto  $x$  e  $|dx|$  é a área dessa região.

Desta forma, se se considerar um processo espacial pontual de Poisson homogéneo numa determinada região, então  $\lambda(x) = \lambda$ , ou seja, a intensidade é constante em toda a região. Assim, neste caso, corresponde à interpretação mais simples de intensidade, isto é, o número

esperado de pontos por unidade de área. Um estimador da intensidade é dado por (Baddeley et al., 2016):

$$\hat{\lambda} = \frac{n(\mathbf{x})}{|R|}$$

em que  $\mathbf{x}$  é o conjunto de pontos observados na região de interesse  $R$ , e  $n(\mathbf{x})$  é o número de pontos em  $\mathbf{x}$ .

No caso de a intensidade não ser homogênea na região de interesse, esta pode ser estimada não parametricamente, com recurso a duas técnicas:

- (1) Contagem em quadrados (*quadrat counting*), em que a região de interesse é dividida em quadrados de igual área e se verifica se essas regiões contêm, aproximadamente, igual número de pontos.
- (2) Estimativa por *kernel*, em que se utiliza um estimador de intensidade do processo pontual por meio de uma função *kernel*, isto é, uma função que conta todos os pontos dentro da região de influência, ponderando-os pela distância de cada um à localização de interesse. Assim, esta técnica suaviza a superfície, calculando a densidade de cada região da área de estudo, utilizando interpolação. De acordo com Baddeley et al. (2016), o estimador de intensidade de *kernel* é muito útil, pois permite obter uma visão geral da distribuição de primeira ordem dos eventos.

### 3.2.3. Propriedades de segunda ordem

As propriedades de segunda ordem representam a dependência espacial ou correlação espacial existente no processo pontual. De uma forma informal, pode considerar-se a intensidade de segunda ordem entre dois pontos como a probabilidade de ocorrência de qualquer par de eventos nas proximidades desses dois pontos.

De acordo com Diggle (2003), as propriedades de segunda ordem são descritas pela função de intensidade de segunda ordem, em que é medida a estrutura de dependência entre localizações  $x_1$  e  $x_2$ :

$$\lambda_2(x_1, x_2) = \lim_{|dx_1|, |dx_2| \rightarrow 0} \left\{ \frac{E[N(dx_1)N(dx_2)]}{|dx_1||dx_2|} \right\}$$

onde  $dx_1$  e  $dx_2$  são pequenas regiões contendo os pontos  $x_1$  e  $x_2$ , respetivamente e  $|dx_1|$  e  $|dx_2|$  representam as áreas das regiões.

Diggle (2003) refere que a função de intensidade de segunda ordem de um processo pontual espacial de Poisson homogêneo é definida por:

$$\lambda_2(x_1, x_2) = \lambda_2(t)$$

onde  $t = \|x_1 - x_2\|$  e  $\|\cdot\|$  a distância euclidiana. Assim, e dado que a intensidade é constante, podemos reescrever a função de intensidade de segunda ordem como:

$$\lambda_2(x_1, x_2) = \lambda^2, \quad t > 0$$

podendo a sua demonstração ser consultada em Carvalho e Natário (2008).


No entanto, torna-se difícil a interpretação da intensidade de segunda ordem, pelo que se recorre habitualmente à função- $K$  de Ripley (Carvalho & Natário, 2008; Diggle, 2003; Ripley, 1977) definida por:

$$K(r) = 2\pi \lambda^{-2} \int_0^r \lambda_2(u) u du, \quad r > 0$$

Assim, a função- $K$  está relacionada com o número esperado de pontos num círculo de raio  $r$  centrado num ponto arbitrário, dividido pela intensidade desse processo (Ripley, 1977). Esta função é facilmente estimada a partir dos dados, o que torna a sua utilização mais vantajosa relativamente à função  $\lambda_2$ . Esta função permite testar a hipótese de aleatoriedade espacial completa (para mais detalhes do teste pode consultar-se Baddeley et al. (2016)).

A função- $K$  é uma ferramenta chave para o estudo das interações nos padrões pontuais espaciais. Para um processo espacial de Poisson, o produto da função- $K$  com a intensidade para cada distância origina o número esperado de pontos adicionais dentro dessa distância a partir de um ponto típico. Quando se tratam de processos espaciais não homogêneos de Poisson, a função- $K$  é estendida para dar resposta à questão da intensidade não ser constante, ou seja, variável ao longo da região de interesse (Baddeley et al., 2016). Para a definição da função- $K$  não homogênea e o seu respetivo estimador pode consultar-se Baddeley et al. (2016).

Considerando os tipos de padrões apresentados na Figura 3.6., podemos construir a função- $K$  para cada um deles, como podemos observar a seguir.



**Figura 3.6.** Função- $K$  para cada tipo de padrão pontual espacial: (A) - aleatório (*random*); (B) - agregado (*clustered*); (C) - regular (*regular*). Legenda: iso - Ripley isotropic correction estimate of  $K(r)$ ; trans - translation-corrected estimate of  $K(r)$ ; bord - border-corrected estimate of  $K(r)$ ; pois - theoretical Poisson  $K(r)$ .

Observando a Figura 3.6., a função- $K$  para a situação A (curva preta) está bastante próxima da teórica para CSR (curva azul), embora ligeiramente inferior (dispersa) para raios

em torno de 0.15. Já para a situação B, a curva preta é consistentemente superior (agrupada) em todos os raios em relação à curva azul. Na última situação, a curva preta está abaixo da curva azul até ao ponto 0.15, sendo que depois disso, está em conformidade com a CSR.

### 3.3. Metodologia

Para este estudo, construíram-se modelos de Cox Log-Gaussiano (LGCP) cuja equação do modelo é dada por:

$$\lambda(s) = \exp(\beta_0 + \beta_1 x_{1(s)} + \beta_2 x_{2(s)} + \dots + Z(s))$$

em que  $\lambda(s)$  é a função de intensidade de um processo de Poisson,  $\beta_i$  são os parâmetros ( $i = 0, 1, 2, \dots, p$ ) que modelam os efeitos das covariáveis ( $x_{1(s)}, x_{2(s)}, x_{3(s)}, \dots$ ) na intensidade do processo e  $Z(s)$  é um campo gaussiano aleatório que captura a variação espacial não explicada pelas covariáveis. Este campo aleatório permite modelar a incerteza e/ou a complexidade da estrutura espacial do próprio processo, ou seja, permite capturar padrões espaciais não lineares e variações locais que não foram tidas em consideração de forma explícita nas covariáveis. Por exemplo, pode ser assumido que pontos espacialmente próximos tendem a ter intensidades mais similares do que pontos mais distantes.

Para o tratamento e análise dos dados recorreu-se ao *software* R (R Foundation, 2020), que é um ambiente de estatística computacional que possui um conjunto de ferramentas para a manipulação de dados, realização de cálculos e apresentação de gráficos. Desde a sua criação, em 1993, o R tem resultado de um trabalho colaborativo de várias pessoas de todo o mundo, através do desenvolvimento de novos pacotes e da atualização dos existentes, sendo gerido pela *R Foundation*.

Neste trabalho, atendendo ao enquadramento teórico, o pacote principal que utilizámos foi o *spatstat* (Baddeley et al., 2016), uma vez que nos permite criar e manipular dados espaciais, construindo representações gráficas de padrões espaciais. Para além disso, possibilita a realização de uma análise exploratória de dados espaciais e o ajustamento de modelos, permitindo, ainda, a simulação de processos pontuais. No entanto, também foram utilizados outros pacotes do R que complementaram a análise efetuada, como o *ggplot2*, *fields*, *maps*, *rgdal*, *raster*, *dplyr*, *tidyverse* e *sf*.

## 4 | Dados

### 4.1. Descrição dos dados e definição das variáveis e covariáveis em estudo

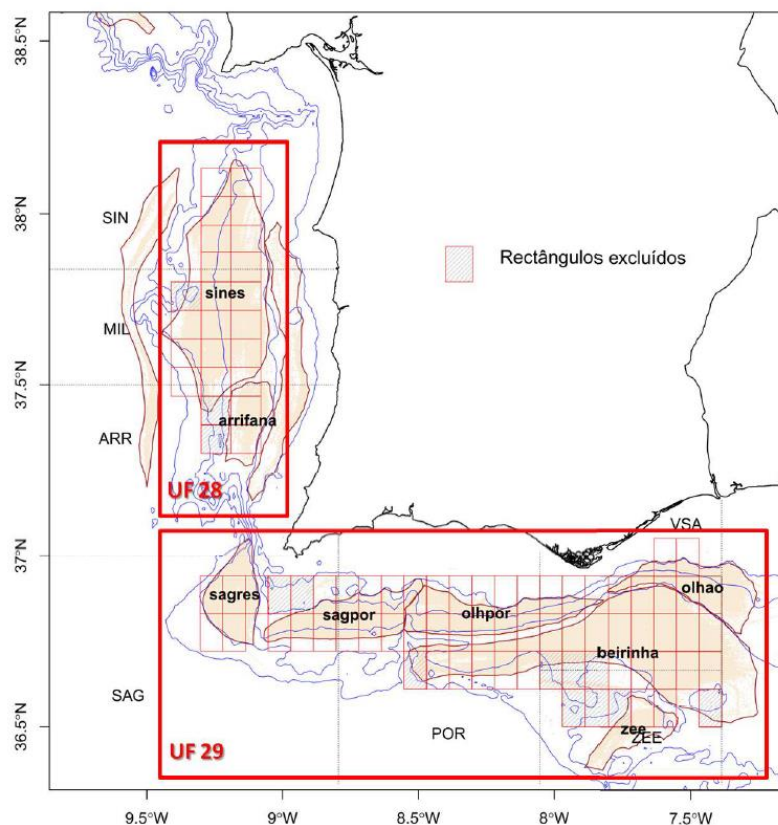
Neste capítulo serão descritas as opções metodológicas associadas ao estudo realizado, bem como uma breve descrição dos dados que foram alvo de análise.

Atendendo a que se pretendeu estudar a distribuição espacial de duas espécies de tubarões, *E. spinax* e *E. pusillus*, foram facultados, pelo IPMA, dados reais que permitiram realizar essa análise. O IPMA tem em curso campanhas de investigação anuais dirigidas à monitorização de espécies de interesse comercial, mas que recolhem igualmente informação sobre outras espécies, nomeadamente tubarões de profundidade, como as duas espécies em estudo neste trabalho. Estas campanhas decorrem no âmbito do Programa Nacional de Amostragem Biológica (PNAB - *Data Collection Framework*).

As espécies *E. spinax* e *E. pusillus* são frequentemente capturadas acessoriamente por pescarias dirigidas a outras espécies marinhas, não tendo valor comercial e sendo, geralmente, devolvidas ao mar (ver Capítulo 2). Uma vez que, à semelhança de outras espécies de tubarões, são espécies vulneráveis, o seu estudo é muito importante para avaliar o estado das suas populações e, se necessário, propor medidas que garantam a sua conservação. Para tal, é preciso perceber as zonas nas quais estas duas espécies existem e quais os fatores que levam a essa distribuição espacial. Assim, definiram-se os seguintes objetivos: (1) identificar as zonas de maior abundância destas duas espécies; e (2) explicar o eventual efeito de covariáveis na distribuição observada.

Os dados foram recolhidos no âmbito das campanhas de crustáceos, durante o período de 1997 a 2018, em Portugal Continental. Estas campanhas decorrem anualmente, em Maio/Junho e têm como principal objetivo obter estimativas de abundância de algumas espécies de crustáceos como, por exemplo, o lagostim (*Nephrops norvegicus*) e a gamba (*Parapenaeus longirostris*). De acordo com Silva et al. (2018), a área amostrada contempla a Costa Sudoeste (Alentejo), entre os 200 e os 750m de profundidade, e a Costa Sul (Algarve), entre os 100 e os 750m de profundidade (Figura 4.1.).

Segundo Silva et al. (2018), nesta campanha de crustáceos, o plano de amostragem tem por base uma grelha regular (ver Figura 4.1.) constituída por retângulos de 33mn<sup>2</sup>, com uma estação de arrasto programada em cada retângulo. A grelha é dinâmica, sendo atualizada com a inclusão de áreas onde a pesca comercial atua, tendo por base os registos georreferenciados obtidos através de *Vessel Monitoring Systems* (VMS). Atualmente, a grelha inclui 78 retângulos: 21 no sudoeste Alentejano (correspondente à unidade funcional 28 de lagostim) e 57 no Algarve (correspondente à unidade funcional 29 do lagostim; unidade funcional refere-se à área de avaliação e gestão de lagostim, espécie à qual a campanha é dirigida).



**Figura 4.1.** Grelha da campanha de arrasto de crustáceos nas Unidades Funcionais 28 e 29 (Silva et al., 2018, p. 25).

Em cada estação é registada a composição específica de toda a captura, em número e em peso, sendo também registados os comprimentos de todas as espécies de peixes. Para além disso, é efetuada a amostragem biológica das espécies comerciais de crustáceos, entre outras espécies consideradas relevantes (Silva et al., 2018). Ainda em relação à recolha de dados, há a referir que os lances de arrasto devem ter, desde 2005, a duração de 30 minutos e lances com duração inferior a 15 minutos não são considerados válidos (Silva et al., 2018).

O conjunto de dados cedidos pelo IPMA comportou três bases de dados, em que duas dizem respeito a informações referentes a cada estação de pesca e quantidades capturadas, para cada uma das espécies em estudo (ver Tabela 4.1.) e a terceira base de dados contém características relativas a cada indivíduo de ambas as espécies para a mesma localização (Tabela 4.2.), embora os dados referentes ao sexo dos indivíduos só se referissem ao ano de 2018. Assim, no total, consideraram-se 31 variáveis cujos nomes e descrições se encontram indicados em ambas as tabelas.

**Tabela 4.1.** Descrição das variáveis do conjunto de dados para cada uma das espécies (*E. spinax* e *E. pusillus*)

Variável	Descrição
TIPO	Tipo de campanha (neste caso, Crustáceos)
TIPOREDE	Tipo de rede usada no arrasto (CAM ou CAR; esta última usada apenas em 3 estações)
MALHAGEM	Malhagem da rede (em mm)
Vessel	Embarcação (2="NI Noruega", embarcação onde decorreram todas as campanhas)
REF	Referência que combina "Cruzeiro" e "Estação"
DATA	Data em a estação foi amostrada
ANO	Ano em que decorreu a campanha
MÊS	Mês em que ocorreu o arrasto
CRUZEIRO	Código da campanha
ESTACAO	Estação da campanha
DURACAO	Duração do arrasto (minutos)
HORAINI	Hora de início do arrasto
ESTRATO	Designação do estrato (corresponde ao Sector - área geográfica definida pelo IPMA - combinada com código para profundidade: 1= 0 a 100m; 2=100 a 200m; 3=200 a 500 m; 4=500 a 750m)
SECTOR	SIN=Sines; MIL=VN Milfontes; ARR=Arrifana; SAG=Sagres; POR=Portimão; VSA=Vila Real Santo António; ZEE=setor não definido, geralmente na zona de VSA, mais ao largo.
LAT_ini	Latitude inicial (decimal)
LONG_ini	Longitude inicial (decimal)
LAT_fim	Latitude final (decimal)
LONG_fim	Longitude final (decimal)
PROFINI	Profundidade inicial (metros)
PROFIM	Profundidade final (metros)
NAMOSTR	Número de indivíduos amostrados da espécie
PESAMOST	Peso amostrado da espécie (kg)
NINDIV	Número de indivíduos capturados na estação
PESO	Peso total capturado da espécie na estação (em kg)
Nhour	Número de indivíduos da espécie capturados na estação, por hora (estimado)
Whour	Biomassa da espécie capturada na estação, por hora (kg) (estimado)
Subamostra	Identificação de estações de pesca em que a amostragem se baseou numa subamostra (0=toda a captura é amostrada; 1=subamostra)
FREQ_HORA	Número de indivíduos amostrados na classe de comprimento, por hora

**Tabela 4.2.** Descrição das variáveis do conjunto de dados relativos às características de ambas as espécies

Variável	Descrição
ESPECIE	Espécie (ETP= <i>Etmopterus pusillus</i> ; ETX= <i>Etmopterus spinax</i> )
SEXO	Sexo dos indivíduos (F=Fêmea; M=Macho)
COMPRIM	Classe de comprimento (cm)

Neste trabalho seguimos a metodologia proposta por Baddeley et al., (2016), em que se estudaram as propriedades de 1.<sup>a</sup> e de 2.<sup>a</sup> ordens de um processo pontual espacial. De seguida, construíram-se alguns modelos com vista a poder explicar a intensidade do processo pontual espacial na distribuição das duas espécies de tubarões de profundidade na zona de interesse (em termos de presença/ausência). Construiu-se uma nova variável binária designada por *Costa*. Esta variável identifica os casos que foram observados na costa Sudoeste ou na costa Sul, assumindo o valor 0 no caso da costa Sudoeste e 1 na costa Sul. Desta forma, consideraram-se como covariáveis a estudar a *Profundidade* e a *Costa*. Por fim, utilizando processos pontuais espaciais marcados, também se tentou explicar a distribuição dos indivíduos de cada espécie, considerando como marca o *comprimento mediano* dos indivíduos.

## 4.2. Análise exploratória dos dados

Nesta parte serão apresentadas algumas medidas estatísticas e gráficos dos dados a fim de analisar e compreender a informação contida no conjunto de dados em estudo. Constatamos que existiram 1348 observações tanto para a espécie *E. spinax* como para a espécie *E. pusillus*, organizadas em 31 variáveis, que se encontram descritas nas Tabelas 4.1. e 4.2. A recolha de dados decorreu entre os anos 1997 e 2018 (com exceção do ano 2012 em que a campanha não decorreu), sempre na mesma altura do ano (maio-junho).

### 4.2.1. *Etmopterus spinax*

Relativamente a esta espécie de tubarão, irá ser apresentada a análise descritiva e exploratória das variáveis *Latitude inicial e final*, *Longitude inicial e final*, *Profundidade*, *Duração do arrasto*, *NINDIV* e *Comprimento da espécie*, essenciais para posterior construção de modelos estatísticos que nos ajudem a atingir os objetivos delineados para este estudo. Realçamos que estamos a analisar cada uma das variáveis usando a informação das estações, ou seja, quando existe ou não ocorrência da espécie.

Na Tabela 4.3. podemos observar as informações respeitantes à Latitude e Longitude (inicial e final).

**Tabela 4.3.** Valores mínimo e máximos da Latitude e Longitude das observações

	Mínimo	Máximo
Latitude inicial	36.43	38.24
Latitude final	36.39	38.22
Longitude inicial	-9.34	-7.37
Longitude final	-9.36	-7.40

No que respeita à latitude e longitude podemos observar, através da Tabela 4.3., que todas as observações (i.e., estações) estão localizadas em duas zonas geográficas (Sudoeste e Sul). Atendendo aos objetivos deste estudo, esta foi a razão pela qual se decidiu criar a variável binária *Costa* indicada anteriormente, que toma valores 0 e 1 (Sudoeste = 0) e (Sul = 1). Refira-se que, para as coordenadas que constituem a localização de cada ponto observável, seleccionou-se a latitude final e a longitude final, ou seja, a latitude e a longitude no final do arrasto.

**Tabela 4.4.** Medidas descritivas sumárias da *Profundidade*

	<b>Mínimo</b>	<b>1.º Quartil</b>	<b>Mediana</b>	<b>Média</b>	<b>3.º Quartil</b>	<b>Máximo</b>
Profundidade inicial (em metros)	42	319.8	481	450.5	576	776
Profundidade final (em metros)	42	320.5	488	450.6	578	795

No que respeita à variável *Profundidade* (ver Tabela 4.4.) podemos constatar que 25% das observações foram registadas a profundidades inferiores a cerca de 320m, profundidades onde, provavelmente, a espécie não ocorre, de acordo com Coelho e Erzini (2010). Por outro lado, observamos que cerca de 75% da amostra foi recolhida a profundidades compreendidas entre 320m e 800m, aproximadamente, profundidades onde a espécie ocorre, de acordo com Moura et al. (2018). Para este estudo, optou-se por criar uma variável, designada por *MedPROF*, que resulta da média entre o valor da profundidade inicial e o da profundidade final.

**Tabela 4.5.** Medidas descritivas sumárias da *Duração do arrasto*

	<b>Mínimo</b>	<b>1.º Quartil</b>	<b>Mediana</b>	<b>Média</b>	<b>3.º Quartil</b>	<b>Máximo</b>
Duração do arrasto (em minutos)	15	30	30	39.35	60	63

## Duração do arrasto




Figura 4.2. - Boxplot da Duração do arrasto

Para a variável *Duração do arrasto*, observamos que o tempo varia entre 15 e 63 minutos, estando 50% das observações compreendidas entre 30 e 60 minutos (Tabela 4.5. e Figura 4.2.).

Na Tabela 4.6. podemos observar as medidas sumárias da variável *NINDIV*.

Tabela 4.6. Medidas descritivas sumárias da variável *NINDIV*

	Mínimo	1.º Quartil	Mediana	Média	3.º Quartil	Máximo
NINDIV	0	0	0	7.056	2	661

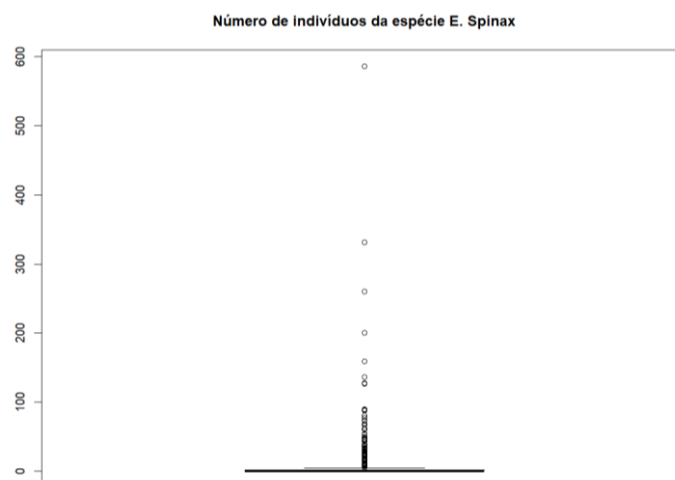



Figura 4.3. Box-plot da variável *NINDIV*

Com base na informação anterior, analisou-se a percentagem de zeros existentes na amostra, constatando-se que, em cerca da 65.88% das observações (estações de pesca), esta espécie não ocorreu. Em algumas estações em que a captura foi muito elevada, foi feita uma estimativa do número de indivíduos com base numa subamostra. Alguns dos valores mais elevados estão associados a estas estações (Figura 4.3.).

Para esta variável, foi ainda analisado o número total de indivíduos observados, por ano (Figura 4.4.).



**Figura 4.4.** Número total de indivíduos da espécie *E. spinax* ao longo dos anos

Podemos observar que, durante o ano de 2012, não houve amostragem desta espécie, resultado da não realização da campanha. Para além disso, existem dois anos – 2002 e 2018 – nos quais o número de indivíduos observados desta espécie é bastante mais elevado comparativamente aos dos outros anos de recolha de dados. Refira-se que, em 2002 e 2018, em algumas estações, a amostragem do número de indivíduos baseou-se numa subamostra do total capturado, o que poderá ter influenciado o valor desta variável.

Para além disso, e atendendo a que a duração do arrasto deve ser de 30 minutos (Silva et al., 2018), criou-se uma nova variável, em que se estandardizou a duração do arrasto em qualquer localização para 30 minutos, arredondando o número de indivíduos da espécie, para o número inteiro mais próximo, quando aplicável, designando-a por *NINDIV\_arrasto\_arred.*

**Tabela 4.7.** Medidas descritivas sumárias da variável *Comprimento*

	Mínimo	1.º Quartil	Mediana	Média	3.º Quartil	Máximo
Comprimento (em cm)	9	20	26	25.35	31	57

### Comprimento da espécie *E. spinax*




Figura 4.5. Box-plot do Comprimento da espécie *E. spinax*

Por fim, quanto à variável *Comprimento*, esta distribui-se entre os 9cm e os 57cm. Constatamos que 75% dos indivíduos da amostra medem entre 9cm e 31cm (Tabela 4.7.), o que se coaduna com o que afirmam Coelho e Erzini (2005, 2010) quanto ao comprimento habitual desta espécie (fêmeas e machos). Para além disso, também podemos identificar alguns valores candidatos a *outliers* (Figura 4.5.). Acrescente-se que não se dispõe da informação desta variável para todos os anos que compõem a amostra, apenas desde 2006.

Como em cada localização existiram indivíduos de *E. spinax* com diferentes comprimentos, optou-se por considerar uma nova variável que, para cada estação, associa a mediana do comprimento dos indivíduos da espécie observada, designando-a por *Comp\_mediano*.

Em suma, e tendo em conta a análise exploratória anterior, não foram consideradas todas as observações, tendo em conta os seguintes critérios:

- (1) atendendo que a informação disponível para esta espécie provém de uma campanha não planeada para a sua monitorização, há localizações em que o número de espécimes capturados é igual a zero. Desta forma, as estações de pesca onde não se registaram capturas não foram consideradas na modelação;
- (2) não se incluíram na análise as estações de pesca em que o número de indivíduos de *E. spinax* foi estimado com base numa subamostra;
- (3) garantiu-se a existência de informações para todas as variáveis em estudo, em especial, a correspondente ao comprimento.

Desta forma, e tendo em conta os critérios adotados anteriormente, apenas foram consideradas as observações a partir do ano de 2006 (inclusive). Na Tabela 4.8. encontra-se o resumo das observações para a espécie *E. spinax*.

**Tabela 4.8.** Resumo das observações para a espécie de tubarão de profundidade *E. spinax*


	N.º total de observações	N.º de observações não consideradas (por não ocorrência, por subamostragem ou por serem anteriores a 2005)	Dimensão final da amostra
<i>Etmopterus spinax</i>	1348	1080	268

Considerando a amostra final, procedeu-se à construção da seguinte tabela onde se incluem as medidas estatísticas sumárias para as variáveis apresentadas anteriormente (Tabela 4.9.):

**Tabela 4.9.** Medidas descritivas sumárias para a amostra final da espécie *E. spinax*


	Mínimo	1.º Quartil	Mediana	Média	3.º Quartil	Máximo
Latitude final	36.51	36.78	36.93	37.24	37.70	38.14
Longitude final	-9.32	-9.25	-9.125	-8.775	-8.42	-7.45
MedPROF (em metros)	210	519.5	551.5	548.4	592.5	766.5
NINDIV_arrasto_arred	1	2	6.5	13.69	17.25	90
Comprimento mediano (em cm)	9	22	26	25.46	30	44.50

Tendo em conta a amostra final, e ainda no âmbito da análise exploratória, fomos avaliar a possibilidade de existência de relações entre algumas variáveis.



**Figura 4.6.** Número de indivíduos da espécie *E. spinax* por classe da variável *Profundidade*


Para a construção deste histograma, seguiu-se a definição dos estratos construídos com base na profundidade descrita na Tabela 4.1., ou seja, 0 a 100m, 100 a 200m, 200 a 500m e 500 a 750m. Ao observar o histograma da Figura 4.6., podemos constatar que existe um maior número de indivíduos desta espécie de tubarão a profundidades mais elevadas, ou seja, superiores a 500m.



**Figura 4.7.** Box-plot do número de indivíduos da espécie *E. spinax* em função da *Costa*

Analisando a Figura 4.7. e, considerando o número de tubarões de profundidade desta espécie em função da *Costa*, podemos observar que a distribuição dos mesmos é diferente nestas duas zonas (Sudoeste=0 e Sul=1).

Elaborou-se um *boxplot* em que se considerou a profundidade de captura da espécie em cada uma das costas (ver Figura 4.8.).



**Figura 4.8.** *Box-plot* da profundidade em cada zona da costa – *E. spinax*


Analisando a figura anterior, podemos observar que as duas distribuições apresentam medianas diferentes, sugerindo que esta espécie de tubarão tem um comportamento distinto. Por outro lado, essa diferença observada é estatisticamente significativa (teste Mann-Whitney, em que  $p - \text{valor} < 2.2 \times 10^{-16}$ ).

#### 4.2.2. *Etmopterus pusillus*

Para esta espécie de tubarão foi efetuada uma análise descritiva e exploratória semelhante à realizada anteriormente para *E. spinax*, tendo em conta as variáveis *Latitude*, *Longitude*, *Profundidade*, *Duração do arrasto*, *NINDIV* e *Comprimento da espécie*. Refira-se que apenas iremos apresentar a análise referente à variável *NINDIV* (ver Tabela 4.10. e Figura 4.9.) e à evolução do número de indivíduos ao longo dos anos, assim como a síntese final das medidas descritivas sumárias para a amostra final da espécie *E. pusillus*. Para mais informação, poderá ser consultado o Anexo A.

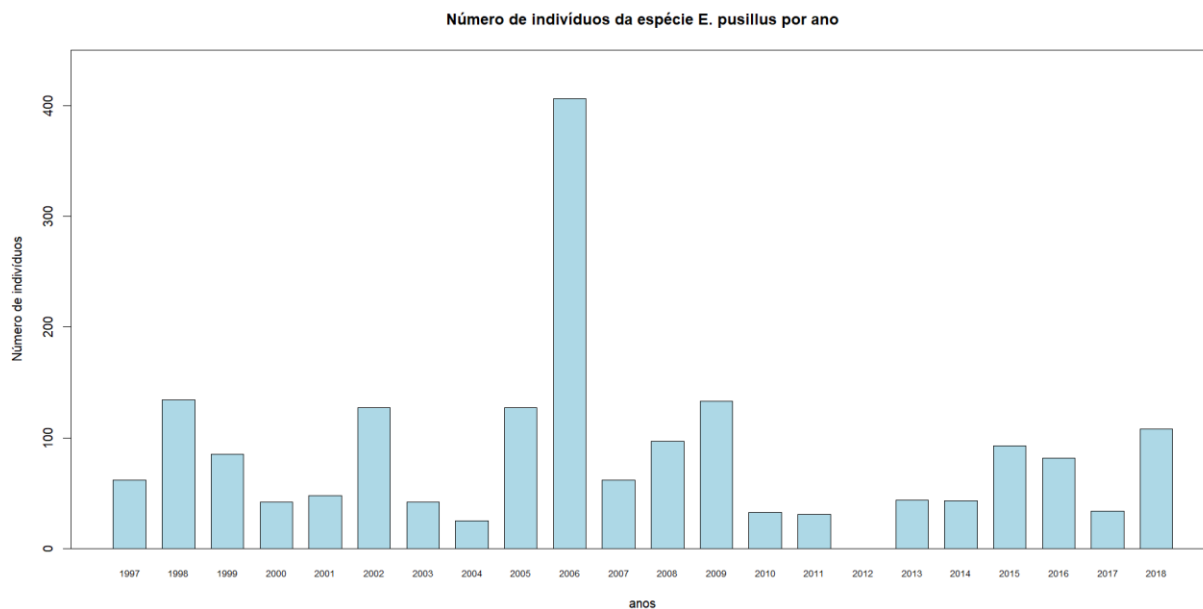
**Tabela 4.10.** Medidas descritivas sumárias da variável *NINDIV*

	<b>Mínimo</b>	<b>1.º Quartil</b>	<b>Mediana</b>	<b>Média</b>	<b>3.º Quartil</b>	<b>Máximo</b>
<i>NINDIV</i>	0	0	0	1.378	0	324.111



**Figura 4.9.** Box-plot da variável *NINDIV*

Com base na informação anterior, analisou-se a percentagem de zeros existentes na amostra, constatando-se que, em cerca da 78.78% das observações, não houve contabilização desta espécie por não ter sido capturada na campanha de crustáceos. Foi também analisado o número total de indivíduos observados desta espécie, por ano (Figura 4.10.).



**Figura 4.10.** Número total de indivíduos da espécie *E. pusillus* ao longo dos anos

Comparativamente à espécie *E. spinax*, o número de indivíduos amostrado é bastante inferior e, com exceção do ano de 2006, este não ultrapassa as 150 unidades. Para além disso,

com exceção de 2006, não parece haver uma tendência crescente ou decrescente no número de indivíduos da espécie *E. pusillus* ao longo dos anos.

Nem todas as observações foram selecionadas para análise, tendo-se aplicado os mesmos critérios que em *E. spinax*. Nas Tabelas 4.11. e 4.12. podemos observar o resumo da informação selecionada (para mais detalhes ver Anexo A).

**Tabela 4.11.** Resumo das observações para a espécie de tubarão de profundidade *E. pusillus*


	N.º total de observações	N.º de observações não consideradas (por não ocorrência, por subamostragem, e por serem anteriores a 2005)	Dimensão final da amostra
<i>Etmopterus pusillus</i>	1348	1165	183

**Tabela 4.12.** Medidas descritivas sumárias para a amostra final da espécie *E. pusillus*

	Mínimo	1.º Quartil	Mediana	Média	3.º Quartil	Máximo
Latitude final	36.52	36.79	36.90	37.28	37.79	38.14
Longitude final	-9.33	-9.26	-9.17	-8.891	-8.69	-7.58
MedPROF (em metros)	231	527.5	562.5	565.5	637	758
NINDIV_arrasto_arred	1	1	2	4.475	5	29
Comprimento mediano (em cm)	10.50	26	30.5	30.49	35.50	46.50


Analisando as duas tabelas (Tabela 4.11 e Tabela 4.12), constata-se que o número de observações consideradas para a análise é inferior comparativamente à dimensão da amostra final para a espécie *E. spinax*. Concluimos, também, que as localizações (longitude e latitude) onde esta espécie de tubarão foi amostrada, assim como a profundidade, são semelhantes. Para além do número de indivíduos da espécie *E. pusillus* ser bastante inferior ao observado da espécie *E. spinax*, o comprimento é geralmente superior ao da outra espécie de tubarão.

À semelhança do que foi realizado na outra espécie de tubarão, fomos avaliar a possibilidade de existência de relações de algumas variáveis, considerando a amostra final.



**Figura 4.11.** Número de indivíduos da espécie *E. pusillus* por classe da variável Profundidade

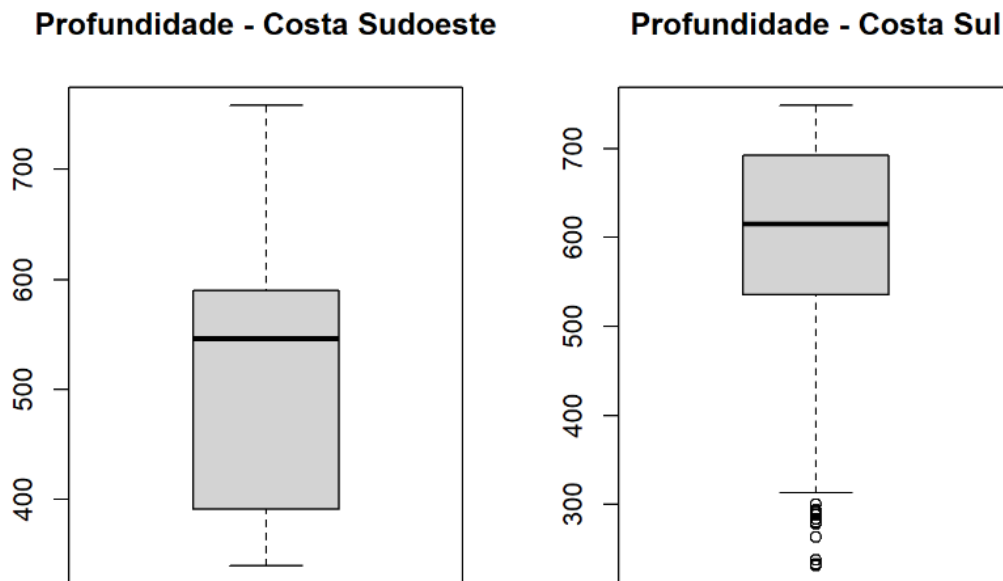
Para a construção deste histograma, seguiu-se a definição dos estratos construídos com base na profundidade descrita na Tabela 4.1., ou seja, 0 a 100m, 100 a 200m, 200 a 500m e 500 a 750m. Ao observar o histograma da Figura 4.11., podemos constatar que existe um maior número de indivíduos desta espécie de tubarão a profundidades mais elevadas, ou seja, superiores a 500m.



**Figura 4.12.** Box-plot do número de indivíduos da espécie *E. pusillus* em função da *Costa*

Considerando o número de tubarões de profundidade desta espécie em função da *Costa*, podemos observar na Figura 4.12 que o número é semelhante em ambas as zonas (Sudoeste=0 e Sul=1).

Elaborou-se um *boxplot* em que se considerou a profundidade de captura da espécie em cada uma das costas (ver Figura 4.13.).



**Figura 4.13.** *Box-plot* da profundidade em cada zona da Costa – *E. pusillus*.

Tendo em conta a figura anterior, podemos constatar que as duas distribuições apresentam medianas diferentes, sugerindo que os dados admitem um comportamento distinto. Por outro lado, essa diferença observada é estatisticamente significativa (teste Mann-Whitney, em que  $p - valor = 1.262 \times 10^{-12}$ ).



## 5 | Resultados

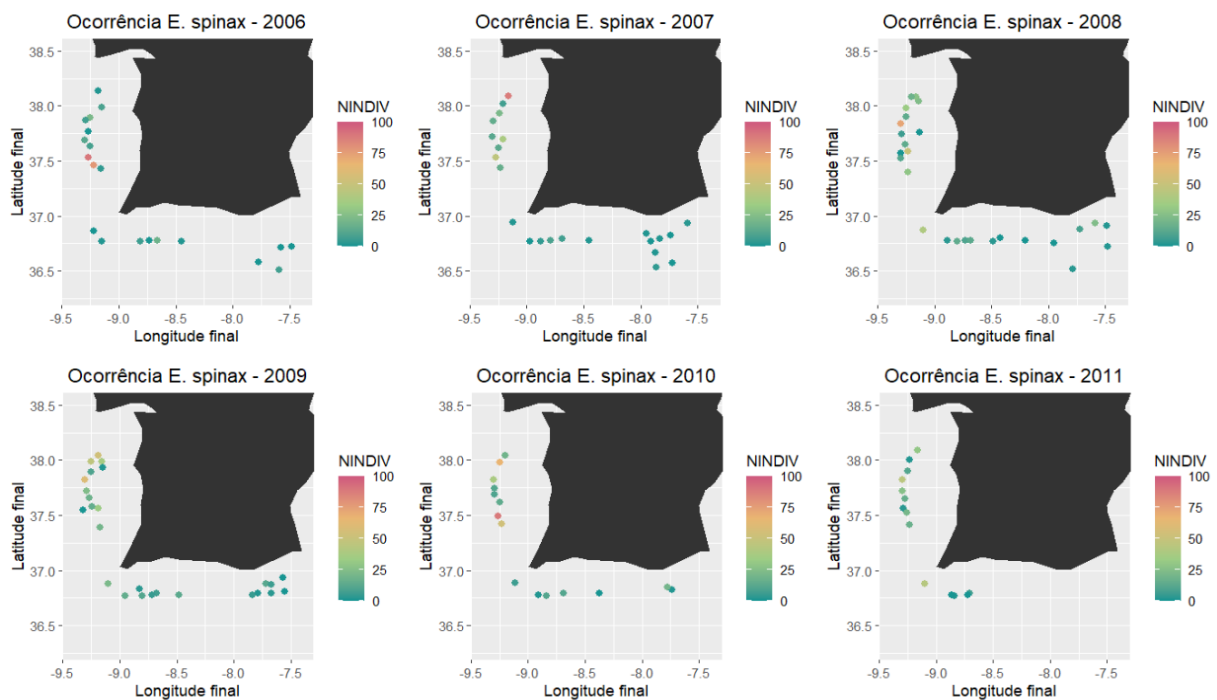
Neste capítulo apresentar-se-á a análise dos resultados respeitante aos processos pontuais espaciais, assim como a modelação estatística que nos permite obter alguma informação sobre o comportamento destas duas espécies de tubarão. Todos os códigos R que permitiram obter os *outputs* apresentados nesta secção encontram-se em anexo (Anexos A e B).

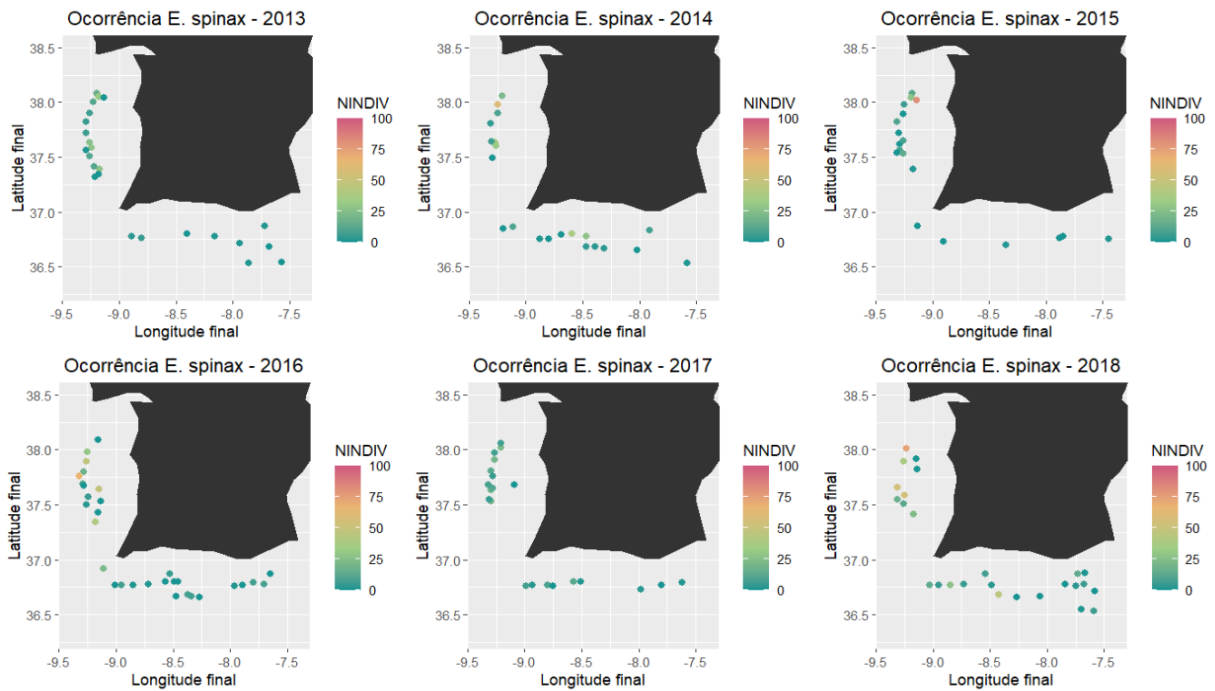
### 5.1. Análise exploratória espacial dos dados

Nesta parte serão apresentados alguns mapas com a distribuição espacial das duas espécies de tubarão nas zonas de interesse, com o intuito de se realizar uma análise exploratória espacial, nos anos 2006 a 2018. Para além disso, discutir-se-ão as propriedades de 1.<sup>a</sup> e 2.<sup>a</sup> ordens de forma a avaliar o tipo de padrão pontual espacial presente.

#### 5.1.1. *Etmopterus spinax*


Foram construídos mapas nos quais podemos observar a distribuição espacial de *E. spinax* bem como da sua abundância (*NINDIV\_arrasto\_arred*) (Figura 5.1.)





**Figura 5.1.** Distribuição espacial dos tubarões da espécie *E. spinax* (2006 a 2018)

Analisando os vários mapas, pode constatar-se que existe uma maior abundância de indivíduos da espécie *E. spinax* na Costa Sudoeste, quando ocorreu, a espécie foi capturada em maiores quantidades. Ao longo dos anos, observa-se a mesma tendência. Na zona de interesse correspondente à Costa Sul observa-se que existem menos ocorrências da espécie *E. spinax* e, quando existem, é sempre em menor número, comparativamente à Costa Sudoeste.




**Figura 5.2.** Distribuição espacial dos tubarões da espécie *E. spinax* (2006-2009, 2010-2014 e 2015-2018)

Atendendo a que se dispõe de 12 anos de observações, optou-se por agrupá-los em três grupos (2006-2009, 2010-2014, 2015-2018), pois a dimensão da amostra em cada ano é muito reduzida para uma análise com base em processos pontuais espaciais (Figura 5.2.). Em seguida, juntaram-se todas as observações no mesmo mapa (Figura 5.3.).

Pela observação das duas figuras e posterior verificação com código (ver Anexo B), podemos constatar a existência de pontos sobrepostos. Para além disso, o número de

ocorrências desta espécie de tubarão é muito semelhante nos dois primeiros grupos (2006-2009 e 2010-2014), assim como a quantidade de tubarões *E. spinax* capturados. No último grupo (2015-2018) parece existir um maior número de ocorrências desta espécie na costa algarvia comparativamente aos outros dois grupos. No entanto, ainda assim, a quantidade de indivíduos capturados é menor.




**Figura 5.3.** Distribuição espacial dos tubarões da espécie *E. spinax* (2006-2009, 2010-2014 e 2015-2018)

Por último, foi feita uma transformação às coordenadas cartesianas repetidas ( $\pm 0.01$ ,  $0.02$ ) para garantir que não existia sobreposição de pontos, tal como é esperado nos processos pontuais espaciais de Poisson (Baddeley et al., 2016).


Uma das finalidades da análise espacial, e em particular dos processos pontuais espaciais, está relacionada com a verificação de existência de alguma tendência nos eventos observados. Assim, para dar início a essa análise, procedeu-se à construção de uma região de interesse que incorporasse as localizações nas quais a espécie *E. spinax* ocorreu, considerando o período único entre 2016 e 2018. Atendendo à metodologia referida por Baddeley et al.

(2016), considerou-se como região de interesse o polígono apresentado na Figura 5.4., construído tendo em conta a localização dos eventos observados.




**Figura 5.4.** Região de interesse com os eventos observados da espécie *E. spinax*

Apesar da análise visual e imediata que se consegue realizar sobre a distribuição dos pontos na região de interesse e que nos leva a considerar um padrão não aleatório, nesta fase pretende verificar-se se a hipótese de aleatoriedade espacial completa (CRS) se adequa a este processo pontual. Para tal, procedeu-se à construção do gráfico da função-K de Ripley (Baddeley et al., 2016; Ripley, 1977) (Figura 5.5.).



**Figura 5.5.** Função-K de Ripley para a espécie *E. spinax*. Legenda: iso - Ripley isotropic correction estimate of  $K(r)$ ; trans - translation-corrected estimate of  $K(r)$ ; bord - border-corrected estimate of  $K(r)$ ; pois - theoretical Poisson  $K(r)$ .

Observando o gráfico podemos concluir que se rejeita a hipótese de aleatoriedade espacial completa, uma vez que existe uma discrepância entre a curva azul (valor teórico sob a hipótese de CSR) e os valores estimados (usando uma correção diferente). Neste caso, podemos afirmar que esta discrepância incide num valor sobrestimado da função-K. Adicionalmente, para sustentar a conclusão de não existência de aleatoriedade espacial completa no processo pontual em causa, realizou-se o envelope da função-K, como se pode observar na Figura 5.6.




**Figura 5.6.** Envelope da função-K para a espécie *E. spinax*

Através da Figura 5.6., podemos constatar que a função  $K(r)$  observada (curva preta) está fora do envelope, independentemente da distância que se considere, pelo que indica que a distribuição dos pontos não segue a CSR. Neste caso, como o valor observado da função  $K(r)$  é maior do que o valor esperado para qualquer distância, significa que a distribuição é mais agrupada do que uma distribuição aleatória.

Desta forma, e atendendo à conclusão anterior, procedeu-se à exploração das propriedades de 1.<sup>a</sup> ordem de um processo pontual, isto é, à análise da intensidade do processo, recorrendo a técnicas não paramétricas (contagem em quadrados e estimativa de *kernel*).

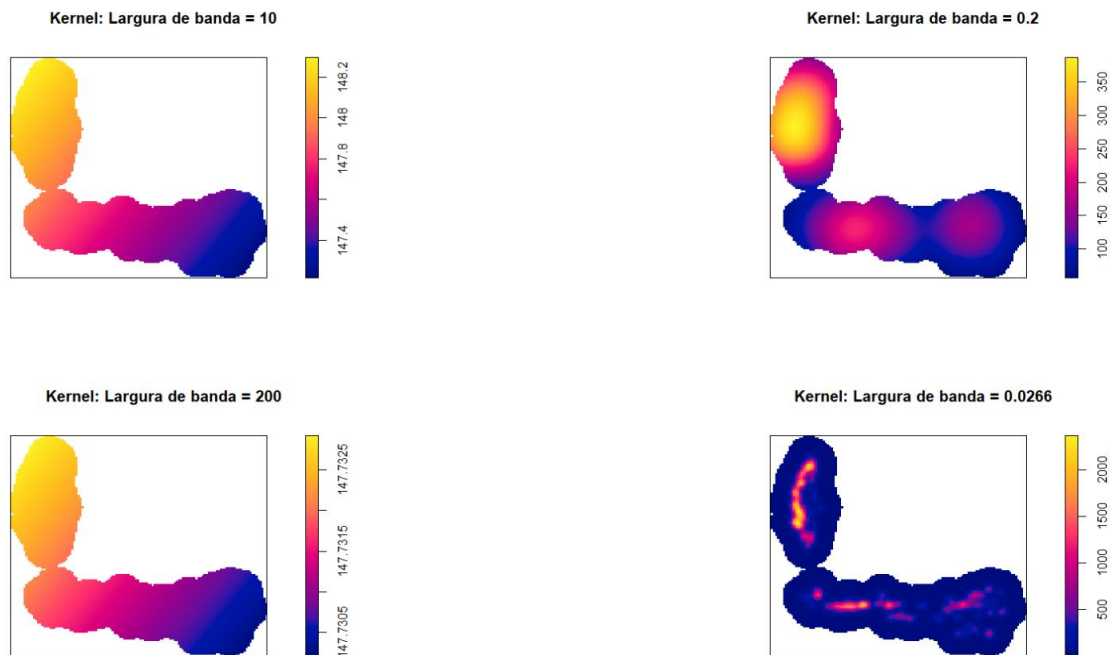
Tal como referem Baddeley et al. (2016), a técnica de contagem em quadrados envolve dividir a região de interesse em quadrados e, em seguida, contar o número de pontos em cada quadrado, permitindo inferir sobre a intensidade do processo ser constante ou não. Na Figura 5.7. encontra-se o resultado da técnica de contagem em quadrados considerando a divisão da região de interesse de forma diferente.



**Figura 5.7.** Técnica de contagem em quadrados para a espécie *E. spinax*

Ao observar a Figura 5.7., podemos concluir que o número de eventos (i.e., estações em que a espécie ocorreu) em cada quadrado é diferente, tanto considerando a divisão da região de interesse em 10x10 (figura da esquerda) ou em 20x30 (figura da direita). Assim, constata-se que a intensidade do processo pontual não é constante. Este facto é corroborado através da realização do teste de hipóteses para a homogeneidade da técnica de contagem de quadrados, em que a hipótese nula é a aleatoriedade espacial completa do processo pontual espacial. Sob a hipótese nula, a distribuição da estatística de teste é, aproximadamente, qui-quadrado. Assim, efetuando o referido teste de hipóteses, existe evidência estatística para não aceitar a hipótese nula (*valor* –  $p < 2.2 \times 10^{-16}$  para a divisão da figura da esquerda; e *valor* –  $p < 2.2 \times 10^{-16}$  para a divisão da figura da direita). No entanto, tal como alguns autores referem, este tipo de técnica não permite uma análise mais fina, uma vez que depende do número de divisões que se considera (Baddeley et al., 2016; Bivand et al., 2008; Illian et al., 2008).


Considerando o estudo da intensidade através do estimador de densidade Kernel, que consiste em transformar o conjunto dos eventos pontuais numa superfície contínua que represente a intensidade, é necessário ter em conta, também, a largura da banda (*bandwidth*). Como alguns autores referem, a escolha da largura da banda irá determinar a forma como se pode, ou não, identificar os locais de maior intensidade de uma forma mais explícita. Assim, esses autores apontam como largura de banda mais adequada a usar o coeficiente de Diggle, que é calculado tendo em conta os eventos (Baddeley et al., 2016; Diggle, 2003; Illian et al., 2008). Na Figura 5.8., podemos observar a estimativa kernel da intensidade do padrão com diferentes larguras de banda, incluindo a que se obtém com o coeficiente de Diggle ( $\sigma = 0.0266$ ). Considerou-se como mais adequada a largura de banda igual a 0.2.



**Figura 5.8.** Estimativa kernel da intensidade do padrão com diferentes larguras de banda

Analisando a figura anterior, verifica-se uma concentração de ocorrência da espécie *E. spinax* em certas zonas da região de interesse (tons mais próximos do amarelo), traduzindo-se numa intensidade do processo pontual não constante, tal como afirmado anteriormente. Desta forma, conclui-se que estamos perante a um processo pontual de Poisson não homogéneo, em que a intensidade é variável na região de interesse.


Tendo em conta que o processo é pontual de Poisson não homogéneo, a propriedade de segunda ordem deverá ser adaptada a essa situação (Baddeley et al., 2016).



**Figura 5.9.** Função-K de Ripley não homogénea para a espécie *E. spinax*. Legenda: iso - Ripley isotropic correction estimate of  $K(r)$ ; trans - translation-corrected estimate of  $K(r)$ ; bord - border-corrected estimate of  $K(r)$ ; pois - theoretical Poisson  $K(r)$ .


Analisando o gráfico anterior (Figura 5.9.), podemos afirmar que existe uma melhor aproximação da função estimada (curva preta) com a correspondente função teórica (curva azul) quando se assume falta de homogeneidade. Para além disso, a distâncias inferiores a, aproximadamente, 0.3, o conjunto de pontos tende a estar mais agrupado (curva preta acima da curva azul) do que a distâncias superiores.

Foi tida em conta também para esta análise a marca correspondente ao comprimento mediano dos tubarões em cada localização. Na Figura 5.10. encontra-se a distribuição dos pontos observados na região de estudo, tendo em conta a marca *comprimento mediano*.



**Figura 5.10.** Distribuição dos eventos na região de interesse de acordo com a marca *comprimento mediano* – *E. spinax*

Iremos considerar três grupos de comprimento que foram definidos tendo por base o conhecimento adquirido sobre a biologia a espécie (ver Capítulo 2): (1) recém-nascidos ( $< 15$  cm); (2) juvenis (no intervalo  $[15, 30[$ cm); e (3) adultos ( $\geq 30$ cm). Na Figura 5.11. apresentamos a distribuição dos pontos de acordo com as três categorias na região de interesse.




**Figura 5.11.** Distribuição dos eventos na região de interesse de acordo com a marca categórica *comprimento mediano* – *E. spinax*

**Tabela 5.1.** Número de indivíduos da espécie *E. spinax* por *Costa* de acordo com a marca categórica *comprimento mediano*

	Recém-nascidos	Juvenis	Adultos
Costa Sudoeste	4	100	27
Costa Sul	9	95	33

Ao observar a figura e tabela anterior, constatamos que existem mais ocorrências no grupo dos juvenis e adultos do que no grupo dos recém-nascidos. Na Figura 5.12. apresentamos a estimativa de kernel para cada um dos grupos indicados anteriormente.

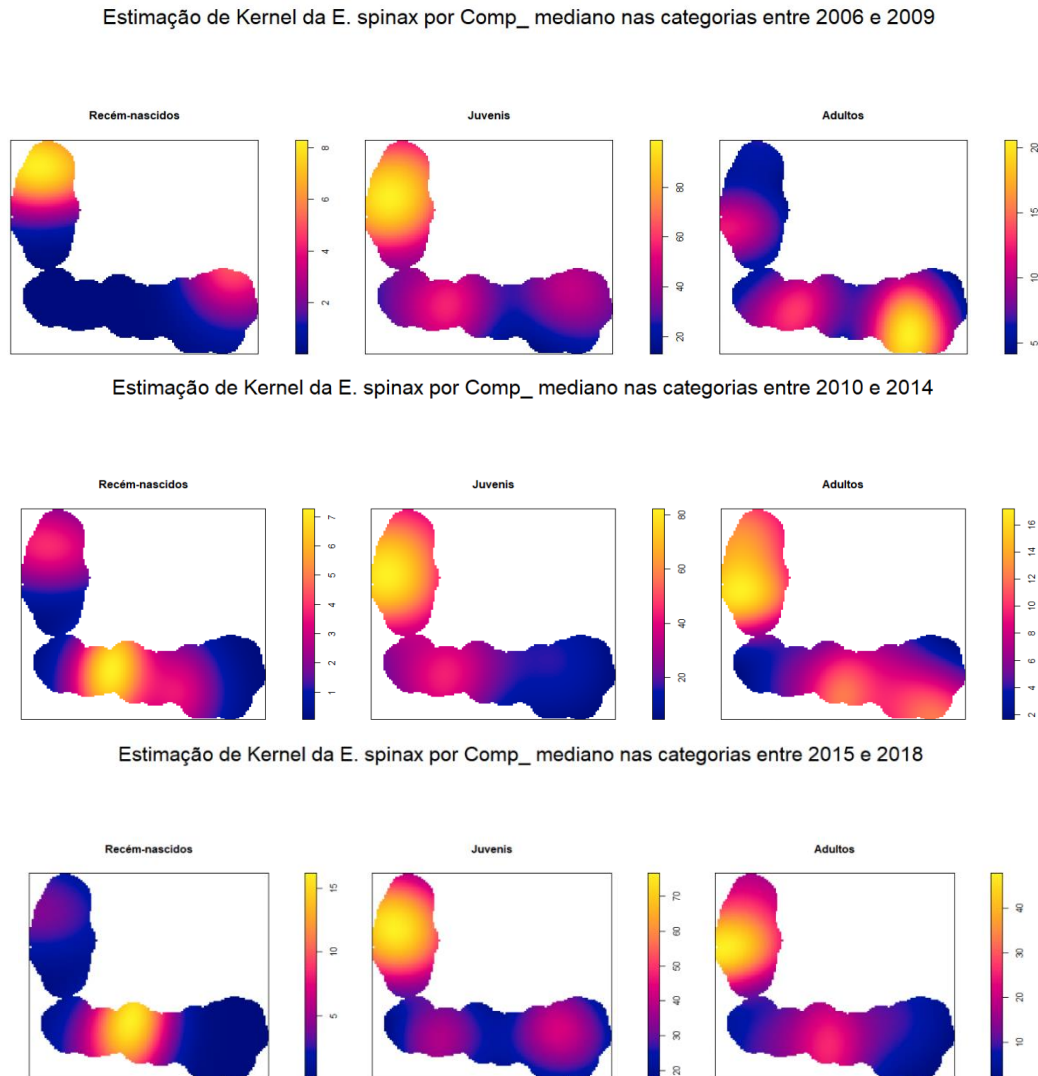


**Figura 5.12.** Estimativa de kernel para cada grupo de *comprimento mediano* – *E. spinax*

Observando a estimativa de intensidade em cada grupo de *comprimento mediano*, podemos constatar uma maior concentração de recém-nascidos da espécie *E. spinax* na Costa Sul, enquanto nos dois grupos de *comprimento mediano* a maior concentração se incide mais

na Costa Sudoeste. No entanto, realçamos que, dado que o número de indivíduos recém-nascidos é bastante reduzido, a interpretação dos dados obtidos deverá se feita com reservas.

Na Figura 5.13. podemos observar a evolução da estimativa de intensidade destes grupos de comprimento entre 2006 e 2018, dividindo em três grupos de anos.



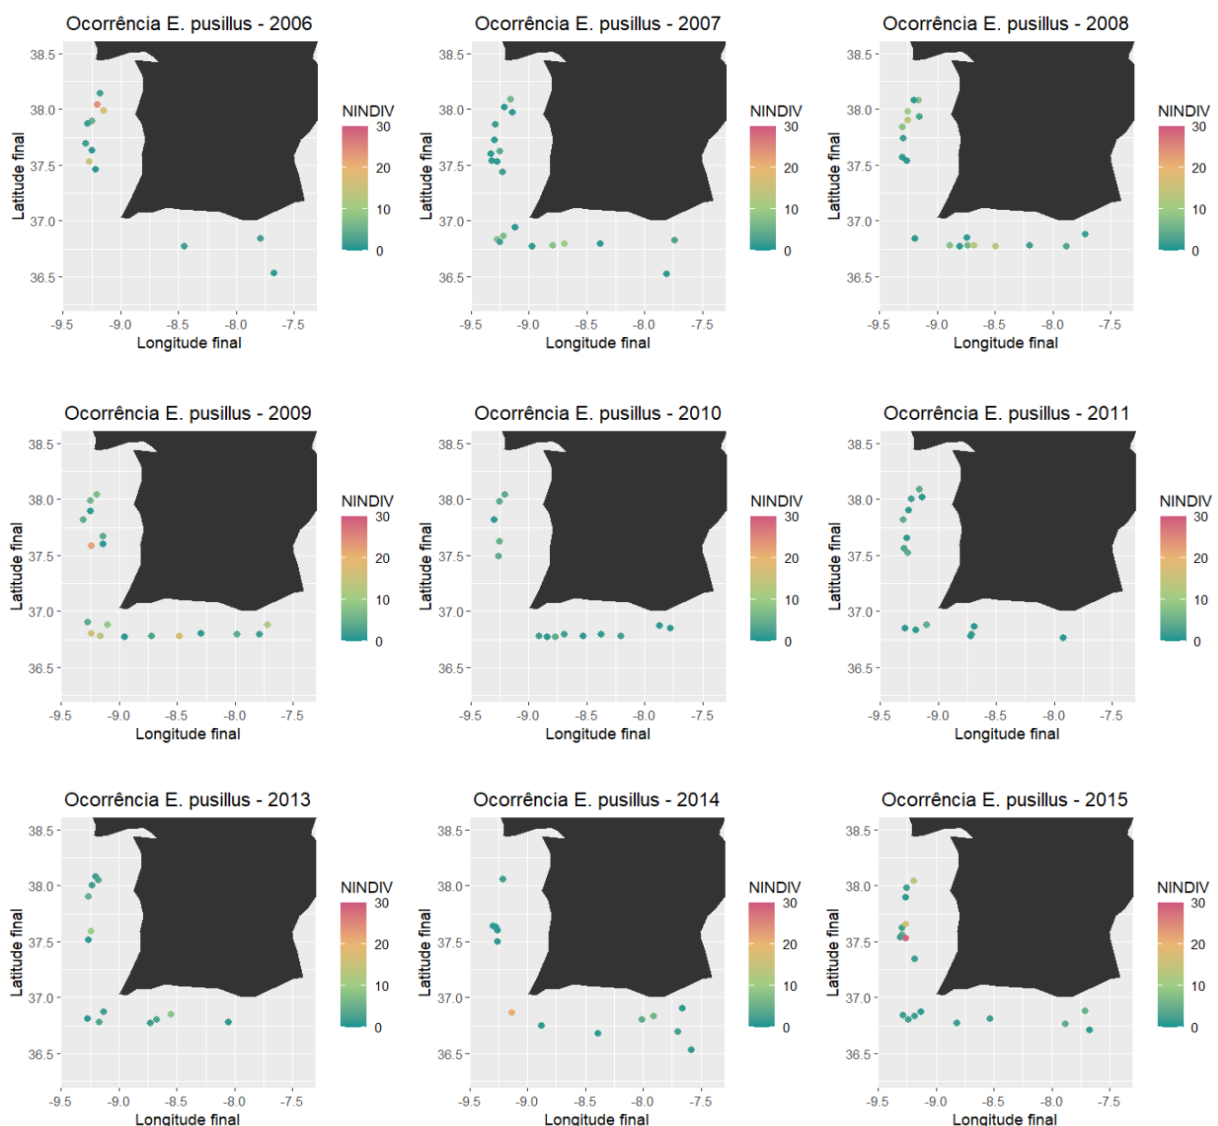
**Figura 5.13.** Estimativa de kernel para cada grupo de *comprimento mediano* – *E. spinax* entre 2006-2009, 2010-2014 e 2015-2018


No que respeita aos “juvenis” observamos que existe uma maior concentração na Costa Sudoeste, independentemente do grupo de anos que se considera. Já no grupo dos “recém-nascidos”, constatamos uma maior concentração na costa Sudoeste entre 2006 e 2009, o que não acontece entre 2010 e 2014 e entre 2015 e 2018, em que temos uma maior intensidade na Costa Sul, em especial no setor de Sagres e Portimão. Em relação ao grupo dos “adultos”, entre 2006 e 2009 existe uma maior concentração na Costa Sul, enquanto que nos restantes anos, assistimos a uma maior intensidade na Costa Sudoeste.

### 5.1.2. *Etmopterus pusillus*

No que respeita a esta espécie de tubarão de profundidade, realizou-se uma análise semelhante à anterior, pelo que apresentaremos apenas alguns resultados que considerámos pertinentes, sendo que a restante análise se encontra em anexo (ver Anexo A).


Considerando a Figura 5.14., podemos observar que a distribuição desta espécie de tubarão de profundidade é mais frequente na Costa Sudoeste do que na Costa Algarvia. No entanto, contrariamente ao que acontece na espécie *E. spinax*, o maior número de indivíduos capturados tanto pode observar-se na Costa Sudoeste como na Costa Algarvia, consoante o ano que se considere, pelo que não se pode afirmar a existência de uma tendência para a captura numa determinada zona da costa.






**Figura 5.14.** Distribuição espacial dos tubarões da espécie *E. pusillus* (2006 a 2018)

Na Figura 5.15. podemos observar a zona de interesse que foi construída em função dos eventos observados para a espécie *E. pusillus*, considerando o período único entre 2016 e 2018.



**Figura 5.15.** Região de interesse com os eventos observados da espécie *E. pusillus*

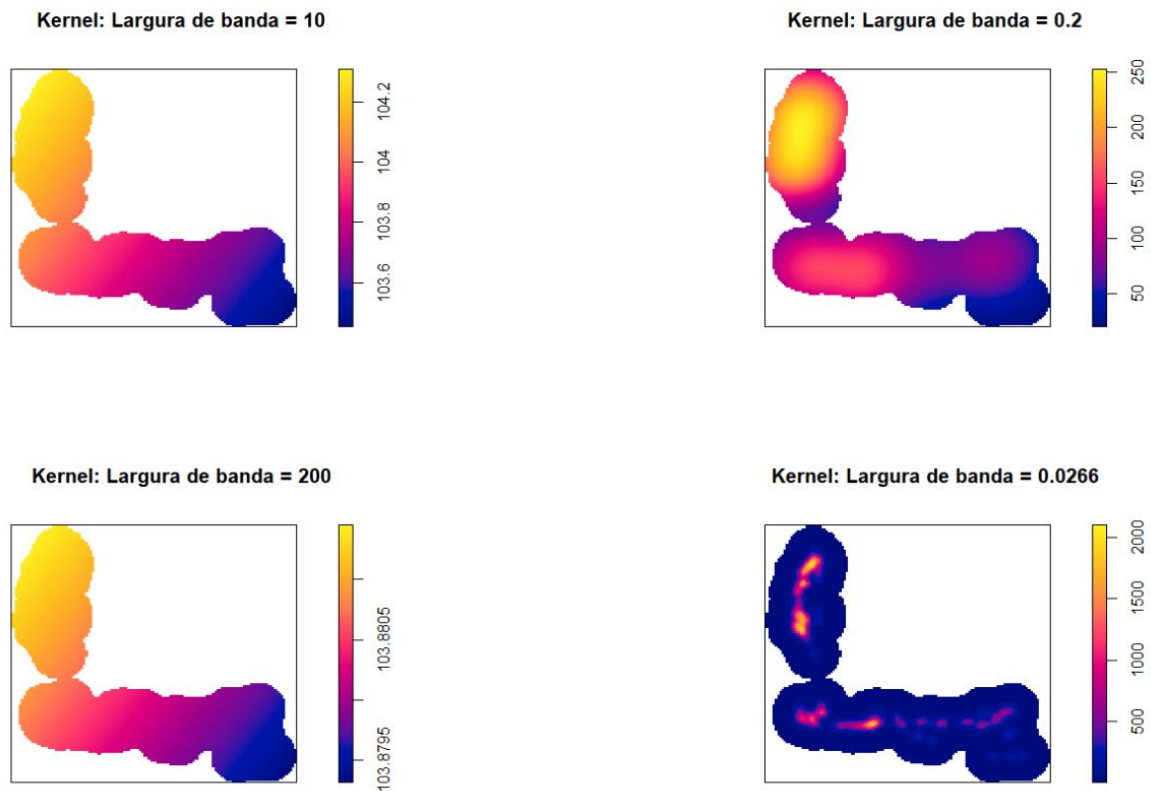
À semelhança de *E. spinax*, a distribuição dos pontos na região de interesse não segue a hipótese de aleatoriedade espacial completa, tal como podemos concluir pela observação da Figura 5.16., onde se encontra a função-K de Ripley (Baddeley et al., 2016; Ripley, 1977).



**Figura 5.16.** Função-K de Ripley para a espécie *E. pusillus* Legenda: iso - Ripley isotropic correction estimate of  $K(r)$ ; trans - translation-corrected estimate of  $K(r)$ ; bord - border-corrected estimate of  $K(r)$ ; pois - theoretical Poisson  $K(r)$ .

Observando o gráfico podemos concluir que se rejeita a hipótese de aleatoriedade espacial completa, uma vez que existe uma discrepância entre a curva azul (valor teórico sob a hipótese de CSR) e os valores estimados (usando uma correção diferente).


No que respeita à exploração das propriedades de 1.<sup>a</sup> ordem de um processo pontual, também se procedeu à análise da intensidade do processo recorrendo a técnicas não paramétricas. Na Figura 5.17. podemos observar a estimativa kernel da intensidade do padrão com diferentes larguras de banda, incluindo a que se obtém com o coeficiente de Diggle ( $\sigma = 0.0266$ ). Considerou-se como mais adequada a largura de banda igual a 0.2.



**Figura 5.17.** Estimativa kernel da intensidade do padrão com diferentes larguras de banda

Analisando a figura anterior, verifica-se uma concentração de ocorrência da espécie *E. pusillus* em certas zonas da região de interesse, traduzindo-se numa intensidade do processo pontual não constante, tal como afirmado anteriormente. Desta forma, conclui-se que estamos perante a um processo pontual de Poisson não homogéneo, em que a intensidade é variável na região de interesse.


Tendo em conta que o processo é pontual de Poisson não homogéneo, a propriedade de segunda ordem deverá ser adaptada a essa situação (Baddeley et al., 2016).



**Figura 5.18.** Função-K de Ripley não homogênea para a espécie *E. pusillus*


Analisando o gráfico anterior (Figura 5.18.), podemos afirmar que existe uma melhor aproximação da função estimada (curva preta) com a correspondente função teórica quando se assume falta de homogeneidade (curva azul). Para além disso, a distâncias inferiores a, aproximadamente, 0.3, o conjunto de pontos tende a estar mais agrupado (curva preta acima da curva azul) do que a distâncias superiores.

Foi também tida em consideração para esta análise a marca correspondente ao comprimento mediano dos tubarões em cada localização. Na Figura 5.19. encontra-se a distribuição dos pontos observados na região de interesse, tendo em conta a marca *comprimento mediano*.



**Figura 5.19.** Distribuição dos eventos na região de interesse de acordo com a marca *comprimento mediano* – *E. pusillus*

Iremos considerar três grupos que foram definidos com base na revisão de literatura efetuada no Capítulo 2: (1) recém-nascidos ( $< 15\text{cm}$ ); (2) juvenis (no intervalo  $[15, 43[$ cm); e (3) adultos ( $\geq 43\text{cm}$ ). Na Figura 5.20. apresentamos a distribuição dos pontos de acordo com as três categorias na região de interesse.



**Figura 5.20.** Distribuição dos eventos na região de interesse de acordo com a marca categórica *comprimento mediano* – *E. pusillus*

**Tabela 5.2.** Número de indivíduos da espécie *E. pusillus* por *Costa* de acordo com a marca categórica *comprimento mediano*

	Recém-nascidos	Juvenis	Adultos
Costa Sudoeste	2	85	1
Costa Sul	2	89	4

Ao observar a figura e tabela anterior, constatamos que existe uma maior ocorrência no grupo dos juvenis e que existem muito poucas ocorrências nos grupos dos recém-nascidos e dos adultos. Assim, realçamos que, dado que o número de indivíduos recém-nascidos e adultos é bastante reduzido, a interpretação dos dados obtidos deverá ser feita com cuidado. Na Figura 5.21. apresentamos a estimativa de kernel para cada um dos grupos indicados anteriormente.




Figura 5.21. Estimativa de kernel para cada grupo de comprimento mediano – *E. pusillus*

Observado a estimativa de intensidade em cada grupo de comprimento mediano, uma das primeiras conclusões que se pode retirar deste estudo é que foram observados muito mais juvenis do que recém-nascidos ou adultos. Por outro lado, podemos constatar uma maior concentração de juvenis da espécie *E. pusillus* na Costa Sudoeste.

Na Figura 5.22. podemos observar a evolução da estimativa de intensidade destes grupos de comprimento entre 2006 e 2018, dividindo em três grupos de anos.

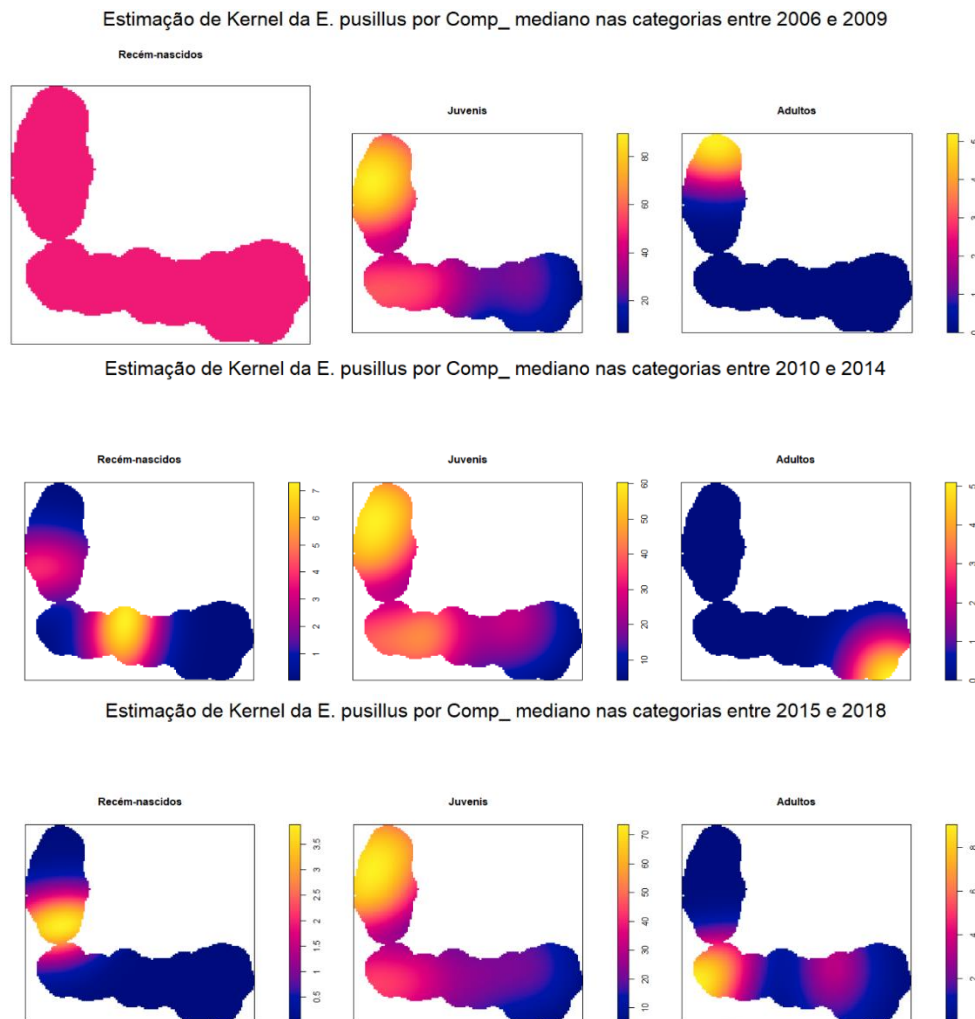



Figura 5.22. Estimativa de kernel para cada grupo de comprimento mediano – *E. pusillus* entre 2006-2009, 2010-2014 e 2015-2018

No que respeita aos “recém-nascidos” observamos que entre 2006 e 2009 não se registaram ocorrências. Ainda no mesmo grupo, entre 2010 e 2014, constatamos uma maior concentração na Costa Sul (mais exatamente, no setor Portimão) e entre 2015 e 2018 na Costa Sudoeste (mais propriamente, no setor Arrifana). No entanto, importa referir que nestes três grupos de anos, o número de indivíduos capturados é bastante baixo. Já no grupo dos “juvenis” há uma maior concentração na Costa Sudoeste, independentemente do grupo de anos que se considere. Relativamente ao grupo dos “adultos” observamos que existe uma maior concentração na Costa Sudoeste entre 2006 e 2009 (mais propriamente, no setor Sines), enquanto, entre 2010 e 2014 e entre 2015 e 2018, a concentração ocorre na Costa Sul. Tal como acontece com o grupo dos “recém-nascidos”, o número de indivíduos capturados é baixo.

Por último, apresentamos na Figura 5.23. a distribuição espacial das duas espécies de tubarões de profundidade.



**Figura 5.23.** Distribuição espacial das duas espécies de tubarão

Observando a Figura 5.23., podemos constatar que ambas as espécies de tubarão se distribuem em localizações semelhantes. No entanto, na Costa Sudoeste a espécie *E. pusillus* encontra-se mais afastada da costa, portanto a maiores profundidades, comparativamente à outra espécie.

## 5.2. Modelação

No seguimento da análise das propriedades de primeira e segunda ordens do processo pontual espacial, no qual se concluiu a não verificação da hipótese de aleatoriedade espacial completa, interessa agora modelar e explicar a distribuição espacial desta espécie de tubarão de profundidade.

Desta forma, os modelos considerados serão os processos pontuais de Poisson não homogêneos, em especial os modelos Cox Log-Gaussianos (*Log Gaussian Cox Process*), em que se terá em conta como covariáveis a *Profundidade* e a *Costa*, na modelação da intensidade do processo, i.e., modelação do número de indivíduos em cada estação de pesca (*NINDIV\_arrasto\_arred*).

Em todos estes modelos considerou-se a intensidade como função log-linear, cuja equação se encontra descrita no Capítulo 3 (ponto 3.3.).

### 5.2.1. *Etmopterus spinax*

Na Tabela 5.3. podemos observar o ajustamento do modelo que inclui apenas a *Profundidade* como covariável.

**Tabela 5.3.** Parâmetros estimados e erros padrão associados ao modelo com covariável *Profundidade* – *E. spinax*

Modelo	Covariável	$\beta_0$	Erro padrão $\beta_0$	$\beta_1$	Erro padrão $\beta_1$
1	Profundidade	4.658	1.009	0.0006	0.0018

Ao construir o modelo com a covariável *Profundidade* e, atendendo aos dados disponíveis, concluímos que esta não é significativa para explicar a distribuição da espécie *E. spinax* (em termos de presença/ausência) na região de interesse (intervalo de confiança a 95% para  $\beta_1$ : ] - 0.0029, 0.0042[, em que o zero pertence ao IC).

Considerando a covariável *Costa*, que é uma variável binária (Costa Sudoeste, Costa Sul) construiu-se o modelo cujo resultado se apresenta na Tabela 5.4.

**Tabela 5.4.** Parâmetros estimados e erros padrão associados ao modelo com covariável *Costa* – *E. spinax*

Modelo	Covariável	$\beta_0$	Erro padrão $\beta_0$	$\beta_1$	Erro padrão $\beta_1$
2	Costa	6.093	0.8898	-0.6868	0.5150

De acordo com os dados, podemos afirmar que não existe evidência que a covariável *Costa* tenha influência significativa na distribuição da espécie *E. spinax* (em termos de presença/ausência) na região de interesse (intervalo de confiança a 95% para  $\beta_1$ : ] - 1.6962, 0.32253[, em que o zero pertence ao IC).

De seguida, construiu-se um modelo em que se incluíram as covariáveis *Costa* e *Profundidade*. Na Tabela 5.5. apresenta-se o modelo ajustado.

**Tabela 5.5.** Parâmetros estimados e erros padrão associados ao modelo com covariáveis *Profundidade* e *Costa* – *E. spinax*

Modelo	Covariável	$\beta_0$	Erro padrão $\beta_0$	$\beta_1$	Erro padrão $\beta_1$	$\beta_2$	Erro padrão $\beta_2$
3	Profundidade e Costa	5.4943	1.1617	0.0014	0.0018	-0.7994	0.5619

De acordo com os dados, também neste modelo não existe evidência de que ambas as covariáveis permitem explicar a distribuição da espécie *E. spinax* (em termos de presença/ausência) na região de interesse ((intervalos de confiança a 95% para  $\beta_1$  e  $\beta_2$ : ] - 0.0021, 0.0049[ e ] - 1.9001, 0.3018[, respetivamente, em que o zero pertence a ambos os IC).

### 5.2.2. *Etmopterus pusillus*

No que respeita à construção de modelos para a intensidade do processo pontual de Poisson não homogéneo, consideraram-se, também, como covariáveis a *Profundidade* e a *Costa*.

Na Tabela 5.6. podemos observar as estimativas dos parâmetros do modelo incluindo a *Profundidade* como covariável.

**Tabela 5.6.** Parâmetros estimados e erros padrão associados ao modelo com covariável *Profundidade* – *E. pusillus*

Modelo	Covariável	$\beta_0$	Erro padrão $\beta_0$	$\beta_1$	Erro padrão $\beta_1$
1	Profundidade	4.2994	1.2121	0.0006	0.0021

Atendendo aos dados disponíveis, concluímos que a *Profundidade* não é significativa para explicar a distribuição da espécie *E. pusillus* (em termos de presença/ausência) na região de estudo (intervalo de confiança a 95% para  $\beta_1$ : ] - 0.0035, 0.0047[, em que o zero pertence

ao IC). À semelhança do que aconteceu com a espécie *E. spinax*, esta covariável não foi considerada significativa.

Considerando a covariável *Costa*, que é uma variável binária (Costa Sudoeste, Costa Sul), o modelo ajustado é apresentado na Tabela 5.7.

**Tabela 5.7.** Parâmetros estimados e erros padrão associados ao modelo com covariável *Costa* – *E. pusillus*

Modelo	Covariável	$\beta_0$	Erro padrão $\beta_0$	$\beta_1$	Erro padrão $\beta_1$
2	Costa	5.6336	1.0552	-0.6208	0.6124

De acordo com os dados, podemos afirmar que também não existe evidência que a covariável *Costa* tenha influência significativa na distribuição da espécie *E. pusillus* (em termos de presença/ausência) na região de interesse (intervalo de confiança a 95% para  $\beta_1$ : ] – 1.8212, 0.5795[, em que o zero pertence ao IC).

De seguida, construiu-se um modelo em que se incluíram as covariáveis *Profundidade* e *Costa*. Na Tabela 5.8. encontram-se os resultados dos parâmetros estimados desse modelo.

**Tabela 5.8.** Parâmetros estimados e erros padrão associados ao modelo com covariáveis *Profundidade* e *Costa* – *E. pusillus*

Modelo	Covariável	$\beta_0$	Erro padrão $\beta_0$	$\beta_1$	Erro padrão $\beta_1$	$\beta_2$	Erro padrão $\beta_2$
3	Profundidade e Costa	5.0219	1.3749	0.0014	0.0022	-0.7423	0.6607

De acordo com os dados, também neste modelo não existe evidência de que ambas as covariáveis permitam explicar a distribuição da espécie *E. pusillus* (em termos de presença/ausência) na região de interesse (intervalos de confiança a 95% para  $\beta_1$  e  $\beta_2$ : ] – 0.0029, 0.0058[ e ] – 2.0372, 0.5526[, respetivamente, em que o zero pertence a ambos os IC).



## 6 | Considerações Finais

Este estudo pretendeu conhecer a distribuição espacial de duas espécies de tubarões de profundidade, as lixinhas da fundura (*Etmopterus spinax*) e as xarinhas pretas (*Etmopterus pusillus*), recorrendo a técnicas associadas aos processos pontuais espaciais de Poisson. Teve como principais objetivos a identificação de zonas de maior abundância dessas duas espécies de tubarões de profundidade e explicar o eventual efeito de covariáveis na distribuição observada. O IPMA facultou um conjunto de dados recolhidos numa campanha de investigação anual, não dirigida à monitorização destas duas espécies de tubarão, mas que recolhe informação sobre as mesmas, ao longo da costa Sudoeste e da Costa Sul de Portugal Continental.

Constatou-se que o número de ocorrências de indivíduos da espécie *E. spinax* é superior ao da espécie *E. pusillus*, na mesma zona de interesse. Para além disso, o número de tubarões capturados em cada estação é maior para a espécie *E. spinax* do que para a espécie *E. pusillus*. Refira-se que na campanha de investigação anual estas duas espécies são capturadas acessoriamente e que, na mesma estação podem ser capturadas as duas espécies, apenas uma, ou nenhuma delas.

Relativamente à distribuição espacial destas duas espécies, os resultados mostraram que existem zonas que apresentam uma maior concentração destes tubarões de profundidade, indicando possíveis áreas de agregação ou preferência de *habitat*. Estes resultados estão de acordo com estudos realizados com outras espécies de tubarões, em que se verifica uma segregação entre indivíduos quer por comprimento, quer por fase do ciclo de vida quer por sexo (Moura et al., 2014; Wearmouth & Sims, 2008). Por outro lado, verificou-se que a espécie *E. pusillus* é mais frequente em zonas de maior profundidade. Daí que as estações onde se tenha capturado esta espécie de tubarão de profundidade se encontrem mais afastadas da costa.

Através dos modelos construídos, foi possível identificar algumas tendências e padrões significativos na distribuição destas duas espécies de tubarões. Os resultados mostraram que a covariável *Profundidade* não tem uma contribuição estatisticamente significativa para explicar a intensidade do processo na distribuição dos tubarões de profundidade. Isso sugere que a profundidade não é um fator determinante para a presença ou ausência dessas espécies na zona de interesse considerada para este estudo, já restrita a profundidades entre os 200m e 750m (profundidades a que opera a campanha de investigação). Também a covariável binária *Costa* não se mostrou significativa para explicar a intensidade do processo na distribuição desta espécie de tubarões (em termos de presença/ausência). No entanto, e apesar desta conclusão, foi observado que a área próxima à costa Sudoeste apresenta uma maior concentração de tubarões das duas espécies em comparação com a Costa Sul.

No geral, os resultados obtidos indicam que as espécies têm distribuições diferentes e que utilizam diferentes áreas ao longo do seu ciclo de vida. Este conhecimento é relevante para a definição de medidas de conservação de ambas as espécies, como por exemplo, a proteção desses locais. É também muito importante pois constitui informação base para a avaliação do estado das populações destes tubarões.

Ainda no que respeita aos processos pontuais espaciais marcados, em que se considerou como marca o *comprimento mediano* da espécie, concluímos que existe uma assimetria nos grupos “recém-nascidos”, “juvenis” e “adultos” nas duas espécies de tubarões de profundidade. É no grupo dos “juvenis” que se capturou um maior número de indivíduos. Para além disso, é na Costa Sudoeste que a intensidade do processo é maior em ambas as espécies, em especial no grupo dos “juvenis” e “adultos”.

É importante mencionar que este estudo, como acontece com a generalidade dos estudos, também possuiu algumas limitações. A utilização única de uma metodologia mais clássica, no âmbito da estatística espacial, recorrendo ao pacote *spatstat*, não permitiu uma análise mais rica e aprofundada dos dados. Esta limitação está relacionada, por exemplo, com o facto deste pacote ainda não ter contemplado modelos LGCP na modelação de processos pontuais espaciais marcados. Por outro lado, em algumas situações, o facto da sintaxe exigida pelo próprio pacote ser bastante rígida, não permitiu uma fácil adaptação aos dados que tínhamos disponíveis. Por fim, relativamente a este pacote, a análise dos resíduos e posterior adequabilidade do modelo aos dados é ainda algo limitada, como confirmam alguns autores (Baddeley et al., 2016). Por exemplo, quando se trata de processos pontuais marcados, a função que permite realizar um diagnóstico para a adequabilidade não se encontra ainda implementada para estes tipos de modelos.

Outro aspeto que considerámos como limitação deste estudo diz respeito à informação disponível para ser analisada. O facto de não podermos ter contabilizado todos os anos da série temporal inicial, fez com que houvesse poucos pontos para o estudo dos processos pontuais espaciais. Para além disso, apenas se considerou para a construção dos modelos duas covariáveis, sendo uma contínua e outra categórica, o que pode ter limitado as conclusões deste estudo.

Em síntese: apesar das limitações anteriormente assinaladas, este trabalho permitiu destacar a importância da estatística espacial, em especial dos processos pontuais espaciais, em contexto real. Também possibilitou conhecer, de uma forma geral, a distribuição espacial destas duas espécies de tubarões na Costa Sudoeste e na Costa Sul de Portugal Continental. A melhoria do conhecimento sobre o seu padrão de distribuição pode permitir a proposta de medidas de proteção dos habitats e, assim, contribuir para o delineamento de medidas de conservação e gestão destas espécies.

Em relação a trabalhos futuros, seria importante analisar os mesmos dados recorrendo a uma abordagem diferente, como a estatística bayesiana, uma vez que esta permite uma análise mais aprofundada e rica dos dados, complementando a análise efetuada neste estudo. Também seria interessante incluir dados mais recentes (a partir de 2018) para se perceber a evolução das ocorrências de ambas as espécies. Sugeria que se incluísse não só a dimensão espaço, como foi feito, mas também a dimensão tempo e, verificar diferenças e semelhanças existem com os resultados obtidos neste trabalho. Seria ainda interessante incluir outras covariáveis (como, por exemplo, o tipo de substrato, presas (abundância)) ou marcas (como, por exemplo, o sexo dos indivíduos capturados), como também a exploração de relações não lineares para a intensidade do processo. Finalmente, terá interesse alargar a recolha de dados destas espécies e consequente análise quer à região a norte da área de estudo quer a maiores profundidades, de forma a obter-se uma visão mais alargada da sua distribuição em águas nacionais e desta forma, ter-se melhor

conhecimento quer para avaliar o estado das populações quer para garantir a conservação das suas populações.



## Referências bibliográficas

- Baddeley, A., Gregori, P., Mateu, J., Stoica, R., & Stovan, D. (Eds.) (2006). *Case studies in spatial point process modeling*. Springer.
- Baddeley, A., Rubak, E., & Turner, R. (2016). *Spatial point patterns: Methodology and applications with R*. CRC Press.
- Bivand, R. S., Pebesma, E. J., & Gómez-Rubio, V. (2008). *Applied spatial data analysis with R*. Springer.
- Bivand, R., Nowosad, J., & Lovelace, R. (2023). *spData: Datasets for spatial analysis* (R package version 2.2.2). <https://CRAN.R-project.org/package=spData>
- Bordalo-Machado, P., Fernandes, A. C., Figueiredo, I., Moura, O., Reis, S., Pestana, G., & Gordo, L. S. (2009). The black scabbardfish (*Aphanopus carbo* Lowe, 1839) fisheries from the Portuguese mainland and Madeira Island. *Scientia Marina*, 73(S2), 63-76.
- Carvalho, M. L., & Natário, I. C. (2008). *Análise de dados espaciais*. Sociedade Portuguesa de Estatística.
- Coelho, R., Alpizar-Jara, R., & Erzini, K. (2015). Demography of a deep-sea lantern shark (*Etmopterus spinax*) caught in trawl fisheries of the northeastern Atlantic: Application of Leslie matrices with incorporated uncertainties. *Deep-Sea Research II: Topical Studies in Oceanography*, 115, 64-72. <http://dx.doi.org/10.1016/j.dsr2.2014.01.012>
- Coelho, R., Bentes, L., Gonçalves, J. M. S., Lino, P. G., Ribeiro J., & Erzini, K. (2003). Reduction of elasmobranch by-catch in the hake semipelagic near-bottom longline fishery in the Algarve (Southern Portugal). *Fisheries Science*, 69, 293-299.
- Coelho, R., & Erzini, K. (2005). Length at first maturity of two species of lantern shark (*Etmopterus spinax* and *Etmopterus pusillus*) off southern Portugal. *Journal of the Marine Biological Association of the United Kingdom*, 85, 1163-1165.
- Coelho, R., & Erzini, K. (2007). Population parameters of the smooth lantern shark, *Etmopterus pusillus*, in southern Portugal (NE Atlantic). *Fisheries Research*, 86, 42-57.
- Coelho, R., & Erzini, K. (2008a). Effects of fishing methods on deep water shark species caught as by-catch off southern Portugal. *Hydrobiologia*, 606, 187-193.
- Coelho, R., & Erzini, K. (2008b). Life history of a wide-ranging deepwater lantern shark in the north-east Atlantic, *Etmopterus spinax* (Chondrichthyes: Etmopteridae), with implications for conservation. *Journal of Fish Biology*, 73, 1419-1443.
- Coelho, R., & Erzini, K. (2010). Depth distribution of the velvet belly, *Etmopterus spinax*, in relation to growth and reproductive cycle: The case study of a deep-water lantern shark with a wide-ranging critical habitat. *Marine Biology Research*, 6(4), 381-389.
- Coelho, R., Erzini, K., Bentes, L., Correia, C., Lino, P. G., Monteiro, P., Ribeiro, J., & Gonçalves, J. M. S. (2005). Semi-pelagic longline and trammel net elasmobranch catches

- in southern Portugal: catch composition, catch rates and discards. *Journal of Northwest Atlantic Fishery Science*, 35, 531-537.
- Compagno, L., Dando, M., & Fowler, S. (2005). *A field guide to the sharks of the world*. Harper Collins Publishers.
- Cressie, N., Sainsbury-Dale, M., & Zammit-Mangio, A. (2022). Basis-fuction models in spatial statistics. *Annual Review of Statistics and Its Application*, 9, 373-400.
- Diggle, P. (2003). *Statistical Analysis of Spatial Point Patterns*. Hodder Arnold.
- Fernandes, A. C., Prista, N., & Azevedo, M. (2017). *Relatórios científicos e técnicos: Discards from the Portuguese bottom otter trawl operating in ices division 27.9.a (2004-2015)*. Instituto Português do Mar e da Atmosfera (IPMA).
- Gaetan, C., & Guyan, X. (2010). *Spatial statistics and modeling*. Springer.
- García, V. B., Lucifora, L. O., & Myers, R. A. (2008). The importance of habitat and life history to extinction risk in sharks, skates, rays and chimaeras. *Proceeding of The Royal Society B*, 275, 83-89.
- Gatrell, A., Bailey, T., Diggle, P., & Rowlingsont, B. (1996). Spatial point pattern analysis and its application in geographical epidemiology. *Transactions of the Institute of British Geographers*, 21, 256-274.
- Gelfand, A. E., Diggle, P., Fuentes, M., & Guttorp, P. (Eds.) (2010). *Handbook of spatial statistics*. Chapman & Hall/CRC.
- Gennari, E., & Scacco, U. (2007). First age and growth estimates in the deep water shark, *Etmopterus Spinax* (Linnaeus, 1758), by deep coned vertebral analysis. *Marine Biology*, 152, 1207-1214.
- Haining, R. (2004). *Spatial data analysis: Theory and practice*. Cambridge.
- Henriques, A. C., Sá, R., & Grilo, C. (2021). *Tubarões e raias: Guardiões do oceano em crise. Relatório 2021*. ANP.
- Hoenig, J. M., & Gruber, S. H. (1990). Life-history patterns in the elasmobranchs: Implications for fisheries management. In H. L. Pratt Jr., S. H. Gruber, & T. Taniuchi (Eds.), *Elasmobranchs as living resources: Advances in biology, ecology, systemics, and the status of the fisheries*. NOAA Technical Report 90.
- Illian, J., Penttinen, A., Stoyan, H., & Stoyan, D. (2008). *Statistics analysis and modelling of spatial point patterns*. John Wiley & Sons, Ltd.
- International Council for the Exploration of the Sea (ICES) (2021). *Working group on elasmobranch fishes (WGEF). ICES Scientific Reports*. 3(59). <https://doi.org/10.17895/ices.pub.8199>
- van Lieshout, M. N. M. (2019). *Theory of spatial statistics: A concise introduction*. CRC Press.
- Lin, Chia-Hsien & Wen, Tzai-Hung (2022). How spatial epidemiology helps understand infectious human disease transmission. *Tropical Medicine and Infectious Disease*, 7, 164.

- Ministério do Mar (MM) (2020). *Reavaliação do estado ambiental e definição de metas: Parte D, Subdivisão do Continente. Estratégia marinha, Relatório do 2.º ciclo*. MM.
- Møller, J., & Waagepetersen, R. (2017). Some recent developments in statistics for spatial point pattern. *Annual Review of Statistics and Its Application*, 4, 317-342.
- Monteiro, P., Araújo, A., Erzini, K., & Castro, M. (2001). Discards of the Algarve (southern Portugal) crustacean trawl fishery. *Hydrobiologia*, 449, 267-277.
- Moura, T., Jones, E., Clarke, M. W., Cotton, C. F., Crozier, P., Daley, R. K., ... & Figueiredo, I. (2014). Large-scale distribution of three deep-water squaloid sharks: integrating data on sex, maturity and environment. *Fisheries Research*, 157, 47-61.
- Moura, T., Fernandes, A., Figueiredo, I., Alpoim, R., & Azevedo, M. (2018). Management of deep-water sharks' by-catch in the Portuguese anglerfish fishery: From EU regulations to practice. *Marine Policy*, 90, 55-67.
- Muñoz, L. (2015). *Feeding ecology of small deep-water lanternsharks (Etmopterus spinax and Etmopterus pusillus) off the Algarve Coast* (Dissertação de mestrado). Universidade do Algarve, Faro.
- Musick, J. (2005). Introduction. In S. Fowler, R. Cavanagh, M. Camhi, G. Burgess, G. Cailliet, S. Fordham, C. Simpfendorfer, & J. Musick (Eds.), *Sharks, Rays and Chimaeras: The Status of the Chondrichthyan Fishes* (pp. 1-3). IUCN Publications Services Unit.
- Myllymäki, M., Mrkvicka, T., Grabarnik, P., Seijo, H., & Hahn, U. (2016). Global envelope tests for spatial processes. *Journal of the Royal Statistical Society – Serie B*, 79(2), 381-404.
- Neiva, J., Coelho, R., & Erzini, K. (2006). Feeding habits of the velvet belly lanternshark *Etmopterus spinax* (Chondrichthyes: Etmopteridae) off the Algarve, southern Portugal. *Journal of the Marine Biological Association of the United Kingdom*, 86, 835-841.
- Owen, S., Sieg, C., Meador, A., Fulé, P., Iniguez, J., Baggett, L., Fornwalt, P., & Battaglia, M. (2017). Spatial patterns of ponderosa pine regeneration in high-severity burn patches. *Forest Ecology and Management*, 405, 134-149.
- Pereira, S., Turkman, K. F., Correia, L., & Rue, H. (2021). Unemployment estimation: Spatial point referenced methods and models. *Spatial Statistics*, 41, 100345.
- Porcu, C., Marongiu, M. F., Follesa, M. C., Bellodi, A., Mulas, A., Pesci, P., & Cau, A. (2014). Reproductive aspects of the velvet belly *Etmopterus spinax* (Chondrichthyes: Etmopteridae), from the central western Mediterranean Sea. Notes on gametogenesis and oviducal gland microstructure. *Mediterranean Marine Science*, 15(2), 313-326.
- R Foundation (2020). *The R Project for Statistical Computing*. Acedido em 25 de outubro de 2020, em: <https://www.r-project.org/>
- Ribeiro Jr, P. J., Diggle, P., Christensen, O., Schlather, M., Bivand, R., & Ripley, B. (2022). *geoR: Analysis of geostatistical data* (R package version 1.9-2). <https://CRAN.R-project.org/package=geoR>

- Ripley, B. D. (1977). Modelling spatial patterns. *Journal of the Royal Statistics Society – Serie B*, 2, 172-192.
- Serra, L., Juan, P., Varga, D., Mateu, J., & Saez, M. (2013). Spatial pattern modelling of wildfires in Catalonia, Spain 2004-2008. *Environmental Modelling & Software*, 40, 235-244.
- Silva, C., Chaves, C., & Costa A. M. C. (2018). *Relatório da Campanha “Crustáceos-2017”*. IPMA. [On-line: <http://ipma.pt>]
- Snow, J. (1855). *On the Mode of Communication of Cholera* (2<sup>nd</sup> ed.). London.
- Tavares, J. P., & Costa, A. C. (2021). Spatial modeling and analysis of the determinants of property crimes in Portugal. *International Journal of Geo-Information*, 10, 731.
- Wearmouth, V. J., & Sims, D. W. (2008). Sexual segregation in marine fish, reptiles, birds and mammals: behaviour patterns, mechanisms and conservation implications. *Advances in marine biology*, 54, 107-170.
- Xavier, J. C., Vieira, C., Assis, C., Cherel, Y., Hill, S., Costa, E., Borges, T., & Coelho, R. (2012). Feeding ecology of the deep-sea lanternshark *Etmopterus pusillus* (elasmobranchii: Etmopteridae) in the northeast Atlantic. *Scientia Marina*, 76(2), 301-310.
- Yue, Y. R., & Loh, J. M. (2015). Variable selection for inhomogeneous spatial point process models. *The Canadian Journal of Statistics*, 43(2), 288-305.

## **Anexos**



## A | Anexos

### *Etmopterus pusillus*

#### Análise exploratória dos dados

**Tabela.** Valores mínimo e máximos da Latitude e Longitude das observações

	<b>Mínimo</b>	<b>Máximo</b>
Latitude inicial	36.43	38.24
Latitude final	36.39	38.22
Longitude inicial	-9.342	-7.367
Longitude final	-9.355	-7.398

**Tabela.** Medidas descritivas sumárias da *Profundidade*

	<b>Mínimo</b>	<b>1.º Quartil</b>	<b>Mediana</b>	<b>Média</b>	<b>3.º Quartil</b>	<b>Máximo</b>
Profundidade inicial (em metros)	42	319.8	481	450.5	576	776
Profundidade final (em metros)	42	320.5	488	450.6	578	795

**Tabela.** Medidas descritivas sumárias da *Duração do arrasto*

	<b>Mínimo</b>	<b>1.º Quartil</b>	<b>Mediana</b>	<b>Média</b>	<b>3.º Quartil</b>	<b>Máximo</b>
Duração do arrasto (em minutos)	15	30	30	39.35	60	63




Figura. Box-plot da Duração do arrasto

Tabela. Medidas descritivas sumárias da variável Comprimento

	Mínimo	1.º Quartil	Mediana	Média	3.º Quartil	Máximo
Comprimento (em cm)	10	23	29	29.11	36	48






Figura. Box-plot do Comprimento da espécie E. pusillus

## Análise exploratória espacial dos dados




**Figura.** Distribuição espacial dos tubarões da espécie *E. pusillus* (2006-2009, 2010-2014 e 2015-2018)

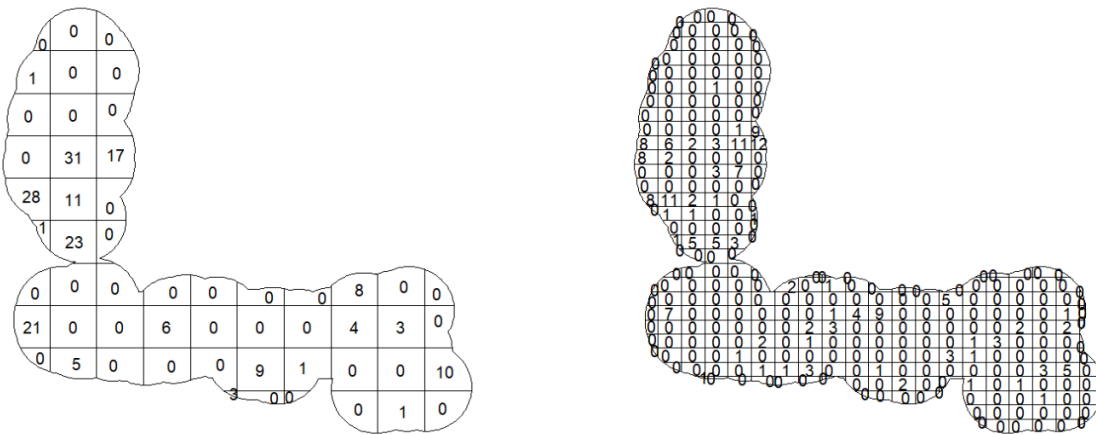


**Figura.** Distribuição espacial dos tubarões da espécie *E. pusillus* (2006-2009, 2010-2014 e 2015-2018)

## Modelação Estatística – Processos Pontuais Espaciais



**Figura.** Envelope da função-K para a espécie *E. pusillus*



**Figura.** Técnica de contagem em quadrados para a espécie *E. pusillus*

## B | Anexos

### Código R – *Etmopterus spinax*

[este código é análogo para a espécie *E. pusillus*]

```
dados_etx<-read.table(file="ETX_data_crustaceans_complete_vf-3.csv", header = T, sep=";")
dados_comp<-read.table(file="TL_data_Etmopterus_FCUL-vf.csv", header = T, sep=";")
colnames(dados_etx)
colnames(dados_comp)
dados_etx$Costa
summary(dados_etx)
summary(dados_comp)
#Análise do número de indivíduos da espécie
boxplot(dados_etx$NINDIV,main="Número de indivíduos da espécie S. Spinax", col="red")
boxplot(dados_etx$NINDIV_arrasto_arred,main="Número de indivíduos da espécie E. Spinax", col="red")
#Análise do comprimento da espécie de tubarões
d2<-data.frame(dados_comp$ANO,dados_comp$ESPECIE, dados_comp$FREQ_Arrasto_arred,dados_comp$COMPRIM)
colnames(d2)
summary(d2)
#Análise do comprimento ETX
comp_etx<-filter(d2, dados_comp.ESPECIE=="ETX")
comp_etx
str(comp_etx)
summary(comp_etx)
boxplot(comp_etx$dados_comp.COMPRIM, main="Comprimento da espécie E.spinax")
summary(dados_etx)
#Análise da latitude e longitude
par(mfrow=c(2,2))
boxplot(dados_etx$LAT_ini,main="Latitude inicial")
boxplot(dados_etx$LAT_fim, main="Latitude final")
boxplot(dados_etx$LONG_ini, main="Longitude inicial")
boxplot(dados_etx$LONG_fim, main="Longitude final")
#Análise da profundidade
par(mfrow=c(1,2))
boxplot(dados_etx$PROFINI,main="Profundidade inicial")
boxplot(dados_etx$PROFIM,main="Profundidade final")
#Análise da duração do arrasto
boxplot(dados_etx$DURACAO,main="Duração do arrasto")
#####
```

```

# Análise de ocorrências por ano
#####
#####
c1<-data.frame(dados_etx$ANO,dados_etx$NINDIV, dados_etx$Subamostra)
a1997<-filter(c1,dados_etx$ANO=="1997")
b1997<-sapply(a1997[2],sum)
a1998<-filter(c1,dados_etx$ANO=="1998")
b1998<-sapply(a1998[2],sum)
a1999<-filter(c1,dados_etx$ANO=="1999")
b1999<-sapply(a1999[2],sum)
a2000<-filter(c1,dados_etx$ANO=="2000")
b2000<-sapply(a2000[2],sum)
a2001<-filter(c1,dados_etx$ANO=="2001")
b2001<-sapply(a2001[2],sum)
a2002<-filter(c1,dados_etx$ANO=="2002")
b2002<-sapply(a2002[2],sum)
a2003<-filter(c1,dados_etx$ANO=="2003")
b2003<-sapply(a2003[2],sum)
a2004<-filter(c1,dados_etx$ANO=="2004")
b2004<-sapply(a2004[2],sum)
a2005<-filter(c1,dados_etx$ANO=="2005")
b2005<-sapply(a2005[2],sum)
a2006<-filter(c1,dados_etx$ANO=="2006")
b2006<-sapply(a2006[2],sum)
a2007<-filter(c1,dados_etx$ANO=="2007")
b2007<-sapply(a2007[2],sum)
a2008<-filter(c1,dados_etx$ANO=="2008")
b2008<-sapply(a2008[2],sum)
a2009<-filter(c1,dados_etx$ANO=="2009")
b2009<-sapply(a2009[2],sum)
a2010<-filter(c1,dados_etx$ANO=="2010")
b2010<-sapply(a2010[2],sum)
a2011<-filter(c1,dados_etx$ANO=="2011")
b2011<-sapply(a2011[2],sum)
a2012<-filter(c1,dados_etx$ANO=="2012")
b2012<-sapply(a2012[2],sum)
a2013<-filter(c1,dados_etx$ANO=="2013")
b2013<-sapply(a2013[2],sum)
a2014<-filter(c1,dados_etx$ANO=="2014")
b2014<-sapply(a2014[2],sum)
a2015<-filter(c1,dados_etx$ANO=="2015")
b2015<-sapply(a2015[2],sum)

```

```

a2016<-filter(c1,dados_etx$ANO=="2016")
b2016<-sapply(a2016[2],sum)
a2017<-filter(c1,dados_etx$ANO=="2017")
b2017<-sapply(a2017[2],sum)
a2018<-filter(c1,dados_etx$ANO=="2018")
b2018<-sapply(a2018[2],sum)
v_nindiv<-c(b1997, b1998, b1999, b2000, b2001, b2002, b2003, b2004, b2005, b2006, b2007, b2008, b2009, b2010,
            b2011, b2012, b2013, b2014, b2015, b2016, b2017, b2018)
v_nhour<-as.numeric(v_nindiv)
anos<-c("1997","1998","1999","2000","2001","2002","2003","2004","2005","2006","2007","2008","2009","2010",
"2011","2012","2013","2014","2015","2016","2017","2018")
anos_nindiv<-data.frame(anos,v_nindiv)
barplot(v_nindiv,names=anos,main="Número de indivíduos da espécie E. spinax por ano",
        xlab="anos",ylab="Número de indivíduos",col="light blue", ylim=c(0,1300),space=0.5,
        cex.names=0.7);box()
#####
#Análise das variáveis Latitude, Longitude, Profundidade, Comprimento, NINDIV_arrasto_arred
#sem a subamostra e a partir de 2006
#####
d1<-data.frame(dados_etx$ANO, dados_etx$ESTRATO,dados_etx$LAT_ini, dados_etx$LAT_fim, dados_etx$LONG_ini,
              dados_etx$LONG_fim,
              dados_etx$PROFINI, dados_etx$PROFIM, dados_etx$MedPROF,dados_etx$Subamostra,
              dados_etx$NINDIV_arrasto_arred, dados_etx$Costa)
d2006<-filter(d1, dados_etx$ANO=="2006", dados_etx$Subamostra==0,dados_etx$NINDIV_arrasto_arred!=0)
d2007<-filter(d1, dados_etx$ANO=="2007", dados_etx$Subamostra==0,dados_etx$NINDIV_arrasto_arred!=0)
d2008<-filter(d1, dados_etx$ANO=="2008", dados_etx$Subamostra==0,dados_etx$NINDIV_arrasto_arred!=0)
d2009<-filter(d1, dados_etx$ANO=="2009", dados_etx$Subamostra==0,dados_etx$NINDIV_arrasto_arred!=0)
d2010<-filter(d1, dados_etx$ANO=="2010", dados_etx$Subamostra==0,dados_etx$NINDIV_arrasto_arred!=0)
d2011<-filter(d1, dados_etx$ANO=="2011", dados_etx$Subamostra==0,dados_etx$NINDIV_arrasto_arred!=0)
d2013<-filter(d1, dados_etx$ANO=="2013", dados_etx$Subamostra==0,dados_etx$NINDIV_arrasto_arred!=0)
d2014<-filter(d1, dados_etx$ANO=="2014", dados_etx$Subamostra==0,dados_etx$NINDIV_arrasto_arred!=0)
d2015<-filter(d1, dados_etx$ANO=="2015", dados_etx$Subamostra==0,dados_etx$NINDIV_arrasto_arred!=0)
d2016<-filter(d1, dados_etx$ANO=="2016", dados_etx$Subamostra==0,dados_etx$NINDIV_arrasto_arred!=0)
d2017<-filter(d1, dados_etx$ANO=="2017", dados_etx$Subamostra==0,dados_etx$NINDIV_arrasto_arred!=0)
d2018<-filter(d1, dados_etx$ANO=="2018", dados_etx$Subamostra==0,dados_etx$NINDIV_arrasto_arred!=0)
d0618<-rbind(d2006,d2007,d2008,d2009,d2010,d2011,d2013,d2014,d2015,d2016,d2017,d2018)
summary(d0618)
#Comprimento da espécie ETX
e2006<-filter(d2, d2$dados_comp.ANO=="2006", d2$dados_comp.ESPECIE=="ETX")
e2007<-filter(d2, d2$dados_comp.ANO=="2007", d2$dados_comp.ESPECIE=="ETX")
e2008<-filter(d2, d2$dados_comp.ANO=="2008", d2$dados_comp.ESPECIE=="ETX")
e2009<-filter(d2, d2$dados_comp.ANO=="2009", d2$dados_comp.ESPECIE=="ETX")

```

```

e2010<-filter(d2, d2$dados_comp.ANO=="2010", d2$dados_comp.ESPECIE=="ETX")
e2011<-filter(d2, d2$dados_comp.ANO=="2011", d2$dados_comp.ESPECIE=="ETX")
e2013<-filter(d2, d2$dados_comp.ANO=="2013", d2$dados_comp.ESPECIE=="ETX")
e2014<-filter(d2, d2$dados_comp.ANO=="2014", d2$dados_comp.ESPECIE=="ETX")
e2015<-filter(d2, d2$dados_comp.ANO=="2015", d2$dados_comp.ESPECIE=="ETX")
e2016<-filter(d2, d2$dados_comp.ANO=="2016", d2$dados_comp.ESPECIE=="ETX")
e2017<-filter(d2, d2$dados_comp.ANO=="2017", d2$dados_comp.ESPECIE=="ETX")
e2018<-filter(d2, d2$dados_comp.ANO=="2018", d2$dados_comp.ESPECIE=="ETX")
e0618<-rbind(e2006,e2007,e2008,e2009,e2010,e2011,e2013,e2014,e2015,e2016,e2017,e2018)
summary(e0618)

#Análise do número de tubarões em função da Costa
boxplot(d0618$dados_etx.NINDIV_arrasto_arred ~ d0618$dados_etx.Costa,
        ylab = "Número de indivíduos", xlab = "Costa",
        main = "Número de indivíduos da espécie E. spinax em função da Costa")

#verificação se as medianas são significativas
# Realização do teste Mann-Witney (teste não paramétrico para amostras independentes)
g_etx<-wilcox.test(d0618$dados_etx.NINDIV_arrasto_arred ~ d0618$dados_etx.Costa)

# Análise do número de tubarões em função da profundidade
#seleção do número de tubarões por estrato (profundidade)
## 1=0 a 100m; 2=100 a 200m; 3=200 a 500m; 4=500 a 750
table(d0618$dados_etx.ESTRATO)
limites<-c(0, 100, 200, 500, 780)
hist(d0618$dados_etx.MedPROF, breaks=limites, main="Histograma do número de indivíduos da espécie E. spinax
      em função da profundidade", xlab="Profundidade", ylab="Número de indivíduos", freq=TRUE)
#####

## Construção de mapas desde 1998 a 2018
#Usou-se a variável NINDIV_arrasto_arred
#####
d1<-data.frame(dados_etx$ANO,dados_etx$LAT_ini,dados_etx$LONG_ini,dados_etx$LAT_fim,      dados_etx$LONG_fim,
              dados_etx$NINDIV_arrasto_arred, dados_etx$Subamostra)
a1997<-filter(d1, dados_etx$ANO=="1997")
b1997<-filter(d1, dados_etx$ANO=="1997", dados_etx$NINDIV_arrasto_arred!=0)
c1997<-data.frame(b1997[6])
d1997<-unlist(c1997)
a1998<-filter(d1, dados_etx$ANO=="1998")
b1998<-filter(d1, dados_etx$ANO=="1998", dados_etx$NINDIV_arrasto_arred!=0)
c1998<-data.frame(b1998[6])
d1998<-unlist(c1998)
a1999<-filter(d1, dados_etx$ANO=="1999")
b1999<-filter(d1, dados_etx$ANO=="1999", dados_etx$NINDIV_arrasto_arred!=0)
c1999<-data.frame(b1999[6])
d1999<-unlist(c1999)

```

```

a2000<-filter(d1, dados_etx$ANO=="2000")
b2000<-filter(d1, dados_etx$ANO=="2000", dados_etx$NINDIV_arrasto_arred!=0)
c2000<-data.frame(b2000[6])
d2000<-unlist(c2000)
a2001<-filter(d1, dados_etx$ANO=="2001")
b2001<-filter(d1, dados_etx$ANO=="2001", dados_etx$NINDIV_arrasto_arred!=0)
c2001<-data.frame(b2001[6])
d2001<-unlist(c2001)
a2002<-filter(d1, dados_etx$ANO=="2002")
b2002<-filter(d1, dados_etx$ANO=="2002", dados_etx$NINDIV_arrasto_arred!=0)
c2002<-data.frame(b2002[6])
d2002<-unlist(c2002)
a2003<-filter(d1, dados_etx$ANO=="2003")
b2003<-filter(d1, dados_etx$ANO=="2003", dados_etx$NINDIV_arrasto_arred!=0)
c2003<-data.frame(b2003[6])
d2003<-unlist(c2003)
a2004<-filter(d1, dados_etx$ANO=="2004")
b2004<-filter(d1, dados_etx$ANO=="2004", dados_etx$NINDIV_arrasto_arred!=0)
c2004<-data.frame(b2004[6])
d2004<-unlist(c2004)
a2005<-filter(d1, dados_etx$ANO=="2005")
b2005<-filter(d1, dados_etx$ANO=="2005", dados_etx$NINDIV_arrasto_arred!=0)
c2005<-data.frame(b2005[6])
d2005<-unlist(c2005)
a2006<-filter(d1, dados_etx$ANO=="2006")
b2006<-filter(d1, dados_etx$ANO=="2006", dados_etx$NINDIV_arrasto_arred!=0, dados_etx$Subamostra==0)
c2006<-data.frame(b2006[6])
d2006<-unlist(c2006)
a2007<-filter(d1, dados_etx$ANO=="2007")
b2007<-filter(d1, dados_etx$ANO=="2007", dados_etx$NINDIV_arrasto_arred!=0, dados_etx$Subamostra==0)
c2007<-data.frame(b2007[6])
d2007<-unlist(c2007)
a2008<-filter(d1, dados_etx$ANO=="2008")
b2008<-filter(d1, dados_etx$ANO=="2008", dados_etx$NINDIV_arrasto_arred!=0, dados_etx$Subamostra==0)
c2008<-data.frame(b2008[6])
d2008<-unlist(c2008)
a2009<-filter(d1, dados_etx$ANO=="2009")
b2009<-filter(d1, dados_etx$ANO=="2009", dados_etx$NINDIV_arrasto_arred!=0, dados_etx$Subamostra==0)
c2009<-data.frame(b2009[6])
d2009<-unlist(c2009)
a2010<-filter(d1, dados_etx$ANO=="2010")
b2010<-filter(d1, dados_etx$ANO=="2010", dados_etx$NINDIV_arrasto_arred!=0, dados_etx$Subamostra==0)

```

```

c2010<-data.frame(b2010[6])
d2010<-unlist(c2010)

a2011<-filter(d1, dados_etx$ANO=="2011")
b2011<-filter(d1, dados_etx$ANO=="2011", dados_etx$NINDIV_arrasto_arred!=0, dados_etx$Subamostra==0)
c2011<-data.frame(b2011[6])
d2011<-unlist(c2011)
a2013<-filter(d1, dados_etx$ANO=="2013")
b2013<-filter(d1, dados_etx$ANO=="2013", dados_etx$NINDIV_arrasto_arred!=0, dados_etx$Subamostra==0)
c2013<-data.frame(b2013[6])
d2013<-unlist(c2013)
a2014<-filter(d1, dados_etx$ANO=="2014")
b2014<-filter(d1, dados_etx$ANO=="2014", dados_etx$NINDIV_arrasto_arred!=0, dados_etx$Subamostra==0)
c2014<-data.frame(b2014[6])
d2014<-unlist(c2014)
a2015<-filter(d1, dados_etx$ANO=="2015")
b2015<-filter(d1, dados_etx$ANO=="2015", dados_etx$NINDIV_arrasto_arred!=0, dados_etx$Subamostra==0)
c2015<-data.frame(b2015[6])
d2015<-unlist(c2015)
a2016<-filter(d1, dados_etx$ANO=="2016")
b2016<-filter(d1, dados_etx$ANO=="2016", dados_etx$NINDIV_arrasto_arred!=0, dados_etx$Subamostra==0)
c2016<-data.frame(b2016[6])
d2016<-unlist(c2016)
a2017<-filter(d1, dados_etx$ANO=="2017")
b2017<-filter(d1, dados_etx$ANO=="2017", dados_etx$NINDIV_arrasto_arred!=0, dados_etx$Subamostra==0)
c2017<-data.frame(b2017[6])
d2017<-unlist(c2017)
a2018<-filter(d1, dados_etx$ANO=="2018")
b2018<-filter(d1, dados_etx$ANO=="2018", dados_etx$NINDIV_arrasto_arred!=0, dados_etx$Subamostra==0)
c2018<-data.frame(b2018[6])
d2018<-unlist(c2018)

#####
#### Construção dos mapas
#####

pt<-ggplot2::map_data("world",region="Portugal")
map97<-ggplot() +
  geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  geom_point(data = b1997, aes(x=dados_etx.LONG_fim, y=dados_etx.LAT_fim, color=d1997),
    size = 1) +
  scale_colour_gradientn("NINDIV", colours = hcl.colors(4, palette = "temps")) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +

```

```

xlab("Longitude final") + ylab("Latitude final") +
ggtitle("Ocorrência E. spinax - 1997")+
  theme(plot.title = element_text(hjust = 0.5))
map98<-ggplot() +
  geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  geom_point(data = b1998, aes(x=dados_etx.LONG_fim, y=dados_etx.LAT_fim, color=d1998),
    size = 1) +
  scale_colour_gradientn("NINDIV", colours = hcl.colors(4, palette = "temps")) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  xlab("Longitude final") + ylab("Latitude final") +
  ggtitle("Ocorrência E. spinax - 1998")+
  theme(plot.title = element_text(hjust = 0.5))
map99<-ggplot() +
  geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  geom_point(data = b1999, aes(x=dados_etx.LONG_fim, y=dados_etx.LAT_fim, color=d1999),
    size = 1) +
  scale_colour_gradientn("NINDIV", colours = hcl.colors(4, palette = "temps")) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  xlab("Longitude final") + ylab("Latitude final") +
  ggtitle("Ocorrência E. spinax - 1999")+
  theme(plot.title = element_text(hjust = 0.5))
map00<-ggplot() +
  geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  geom_point(data = b2000, aes(x=dados_etx.LONG_fim, y=dados_etx.LAT_fim, color=d2000),
    size = 1) +
  scale_colour_gradientn("NINDIV", colours = hcl.colors(4, palette = "temps")) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  xlab("Longitude final") + ylab("Latitude final") +
  ggtitle("Ocorrência E. spinax - 2000")+
  theme(plot.title = element_text(hjust = 0.5))
map01<-ggplot() +
  geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  geom_point(data = b2001, aes(x=dados_etx.LONG_fim, y=dados_etx.LAT_fim, color=d2001),
    size = 1) +
  scale_colour_gradientn("NINDIV", colours = hcl.colors(4, palette = "temps")) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  xlab("Longitude final") + ylab("Latitude final") +
  ggtitle("Ocorrência E. spinax - 2001")+

```

```

theme(plot.title = element_text(hjust = 0.5))

map02<-ggplot() +
  geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  geom_point(data = b2002, aes(x=dados_etx.LONG_fim, y=dados_etx.LAT_fim, color=d2002),
    size = 1) +
  scale_colour_gradientn("NINDIV", colours = hcl.colors(4, palette = "temps")) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  xlab("Longitude final") + ylab("Latitude final") +
  ggtitle("Ocorrência E. spinax - 2002")+
  theme(plot.title = element_text(hjust = 0.5))

map03<-ggplot() +
  geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  geom_point(data = b2003, aes(x=dados_etx.LONG_fim, y=dados_etx.LAT_fim, color=d2003),
    size = 1) +
  scale_colour_gradientn("NINDIV", colours = hcl.colors(4, palette = "temps")) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  xlab("Longitude final") + ylab("Latitude final") +
  ggtitle("Ocorrência E. spinax - 2003")+
  theme(plot.title = element_text(hjust = 0.5))

map04<-ggplot() +
  geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  geom_point(data = b2004, aes(x=dados_etx.LONG_fim, y=dados_etx.LAT_fim, color=d2004),
    size = 1) +
  scale_colour_gradientn("NINDIV", colours = hcl.colors(4, palette = "temps")) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  xlab("Longitude final") + ylab("Latitude final") +
  ggtitle("Ocorrência E. spinax - 2004")+
  theme(plot.title = element_text(hjust = 0.5))

map05<-ggplot() +
  geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  geom_point(data = b2005, aes(x=dados_etx.LONG_fim, y=dados_etx.LAT_fim, color=d2005),
    size = 1) +
  scale_colour_gradientn("NINDIV", colours = hcl.colors(4, palette = "temps")) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  xlab("Longitude final") + ylab("Latitude final") +
  ggtitle("Ocorrência E. spinax - 2005")+
  theme(plot.title = element_text(hjust = 0.5))

```

```

map06<-ggplot() +
  geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  geom_point(data = b2006, aes(x=dados_etx.LONG_fim, y=dados_etx.LAT_fim, color=d2006),
    size = 2) +
  scale_colour_gradientn("NINDIV", colours = hcl.colors(4, palette = "temps"),limits = c(0, 100)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  xlab("Longitude final") + ylab("Latitude final") +
  ggtitle("Ocorrência E. spinax - 2006")+
  theme(plot.title = element_text(hjust = 0.5))
map07<-ggplot() +
  geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  geom_point(data = b2007, aes(x=dados_etx.LONG_fim, y=dados_etx.LAT_fim, color=d2007),
    size = 2) +
  scale_colour_gradientn("NINDIV", colours = hcl.colors(4, palette = "temps"),limits = c(0, 100)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  xlab("Longitude final") + ylab("Latitude final") +
  ggtitle("Ocorrência E. spinax - 2007") +
  theme(plot.title = element_text(hjust = 0.5))
map08<-ggplot() +
  geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  geom_point(data = b2008, aes(x=dados_etx.LONG_fim, y=dados_etx.LAT_fim, color=d2008),
    size = 2) +
  scale_colour_gradientn("NINDIV", colours = hcl.colors(4, palette = "temps"),limits = c(0, 100)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  xlab("Longitude final") + ylab("Latitude final") +
  ggtitle("Ocorrência E. spinax - 2008")+
  theme(plot.title = element_text(hjust = 0.5))
map09<-ggplot() +
  geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  geom_point(data = b2009, aes(x=dados_etx.LONG_fim, y=dados_etx.LAT_fim, color=d2009),
    size = 2) +
  scale_colour_gradientn("NINDIV", colours = hcl.colors(4, palette = "temps"),limits = c(0, 100)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  xlab("Longitude final") + ylab("Latitude final") +
  ggtitle("Ocorrência E. spinax - 2009")+
  theme(plot.title = element_text(hjust = 0.5))

```

```

map10<-ggplot() +
  geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  geom_point(data = b2010, aes(x=dados_etx.LONG_fim, y=dados_etx.LAT_fim, color=d2010),
    size = 2) +
  scale_colour_gradientn("NINDIV", colours = hcl.colors(4, palette = "temps"),limits = c(0, 100)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  xlab("Longitude final") + ylab("Latitude final") +
  ggtitle("Ocorrência E. spinax - 2010")+
  theme(plot.title = element_text(hjust = 0.5))
map11<-ggplot() +
  geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  geom_point(data = b2011, aes(x=dados_etx.LONG_fim, y=dados_etx.LAT_fim, color=d2011),
    size = 2) +
  scale_colour_gradientn("NINDIV", colours = hcl.colors(4, palette = "temps"),limits = c(0, 100)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  xlab("Longitude final") + ylab("Latitude final") +
  ggtitle("Ocorrência E. spinax - 2011")+
  theme(plot.title = element_text(hjust = 0.5))
map13<-ggplot() +
  geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  geom_point(data = b2013, aes(x=dados_etx.LONG_fim, y=dados_etx.LAT_fim, color=d2013),
    size = 2) +
  scale_colour_gradientn("NINDIV", colours = hcl.colors(4, palette = "temps"),limits = c(0, 100)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  xlab("Longitude final") + ylab("Latitude final") +
  ggtitle("Ocorrência E. spinax - 2013")+
  theme(plot.title = element_text(hjust = 0.5))
map14<-ggplot() +
  geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  geom_point(data = b2014, aes(x=dados_etx.LONG_fim, y=dados_etx.LAT_fim, color=d2014),
    size = 2) +
  scale_colour_gradientn("NINDIV", colours = hcl.colors(4, palette = "temps"),limits = c(0, 100)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  xlab("Longitude final") + ylab("Latitude final") +
  ggtitle("Ocorrência E. spinax - 2014")+
  theme(plot.title = element_text(hjust = 0.5))
map15<-ggplot() +
  geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +

```

```

coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
geom_point(data = b2015, aes(x=dados_etx.LONG_fim, y=dados_etx.LAT_fim, color=d2015),
  size = 2) +
scale_colour_gradientn("NINDIV", colours = hcl.colors(4, palette = "temps"),limits = c(0, 100)) +
coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
xlab("Longitude final") + ylab("Latitude final") +
ggtitle("Ocorrência E. spinax - 2015")+
theme(plot.title = element_text(hjust = 0.5))
map16<-ggplot() +
geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +
coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
geom_point(data = b2016, aes(x=dados_etx.LONG_fim, y=dados_etx.LAT_fim, color=d2016),
  size = 2) +
scale_colour_gradientn("NINDIV", colours = hcl.colors(4, palette = "temps"),limits = c(0, 100)) +
coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
xlab("Longitude final") + ylab("Latitude final") +
ggtitle("Ocorrência E. spinax - 2016")+
theme(plot.title = element_text(hjust = 0.5))
map17<-ggplot() +
geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +
coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
geom_point(data = b2017, aes(x=dados_etx.LONG_fim, y=dados_etx.LAT_fim, color=d2017),
  size = 2) +
scale_colour_gradientn("NINDIV", colours = hcl.colors(4, palette = "temps"),limits = c(0, 100)) +
coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
xlab("Longitude final") + ylab("Latitude final") +
ggtitle("Ocorrência E. spinax - 2017") +
theme(plot.title = element_text(hjust = 0.5))
map18<-ggplot() +
geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +
coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
geom_point(data = b2018, aes(x=dados_etx.LONG_fim, y=dados_etx.LAT_fim, color=d2018),
  size = 2) +
scale_colour_gradientn("NINDIV", colours = hcl.colors(4, palette = "temps"),limits = c(0, 100)) +
coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
xlab("Longitude final") + ylab("Latitude final") +
ggtitle("Ocorrência E. spinax - 2018") +
theme(plot.title = element_text(hjust = 0.5))
#### Grelha com os mapas
grid.arrange(map97, map98, map99, map00, map01, map02, map03, map04, map05, map06,nrow=5, ncol=3)
grid.arrange(map06,map07,map08, map09, map10, map11, map13, map14, map15, map16,
  map17, map18, nrow=4, ncol=3)

```

```

grid.arrange(map06,map07,map08, nrow=1, ncol=3)
grid.arrange(map09, map10, map11, nrow=1, ncol=3)
grid.arrange(map13, map14, map15, nrow=1, ncol=3)
grid.arrange(map16, map17, map18, nrow=1, ncol=3)
#####
##### Mapa com as duas espécies de tubarão
#####
dados_etp<-read.table(file="ETP_data_crustaceans_complete_vf.csv", header = T, sep=";")
d1p<-data.frame(dados_etp$ANO,dados_etp$LAT_ini, dados_etp$LONG_ini, dados_etp$LAT_fim, dados_etp$LONG_fim,
dados_etp$NINDIV_arrasto_arred, dados_etp$Subamostra)
a2006p<-filter(d1p, dados_etp$ANO=="2006")
b2006p<-filter(d1p, dados_etp$ANO=="2006", dados_etp$NINDIV_arrasto_arred!=0, dados_etp$Subamostra==0)
c2006p<-data.frame(b2006p[6])
d2006p<-unlist(c2006p)
a2007p<-filter(d1p, dados_etp$ANO=="2007")
b2007p<-filter(d1p, dados_etp$ANO=="2007", dados_etp$NINDIV_arrasto_arred!=0, dados_etp$Subamostra==0)
c2007p<-data.frame(b2007p[6])
d2007p<-unlist(c2007p)
a2008p<-filter(d1p, dados_etp$ANO=="2008")
b2008p<-filter(d1p, dados_etp$ANO=="2008", dados_etp$NINDIV_arrasto_arred!=0, dados_etp$Subamostra==0)
c2008p<-data.frame(b2008p[6])
d2008p<-unlist(c2008p)
a2009p<-filter(d1p, dados_etp$ANO=="2009")
b2009p<-filter(d1p, dados_etp$ANO=="2009", dados_etp$NINDIV_arrasto_arred!=0, dados_etp$Subamostra==0)
c2009p<-data.frame(b2009p[6])
d2009p<-unlist(c2009p)
a2010p<-filter(d1p, dados_etp$ANO=="2010")
b2010p<-filter(d1p, dados_etp$ANO=="2010", dados_etp$NINDIV_arrasto_arred!=0, dados_etp$Subamostra==0)
c2010p<-data.frame(b2010p[6])
d2010p<-unlist(c2010p)
a2011p<-filter(d1p, dados_etp$ANO=="2011")
b2011p<-filter(d1p, dados_etp$ANO=="2011", dados_etp$NINDIV_arrasto_arred!=0, dados_etp$Subamostra==0)
c2011p<-data.frame(b2011p[6])
d2011p<-unlist(c2011p)
a2013p<-filter(d1p, dados_etp$ANO=="2013")
b2013p<-filter(d1p, dados_etp$ANO=="2013", dados_etp$NINDIV_arrasto_arred!=0, dados_etp$Subamostra==0)
c2013p<-data.frame(b2013p[6])
d2013p<-unlist(c2013p)
a2014p<-filter(d1p, dados_etp$ANO=="2014")
b2014p<-filter(d1p, dados_etp$ANO=="2014", dados_etp$NINDIV_arrasto_arred!=0, dados_etp$Subamostra==0)
c2014p<-data.frame(b2014p[6])
d2014p<-unlist(c2014p)

```

```

a2015p<-filter(d1p, dados_etc$ANO=="2015")
b2015p<-filter(d1p, dados_etc$ANO=="2015", dados_etc$NINDIV_arrasto_arred!=0, dados_etc$Subamostra==0)
c2015p<-data.frame(b2015p[6])
d2015p<-unlist(c2015p)
a2016p<-filter(d1p, dados_etc$ANO=="2016")
b2016p<-filter(d1p, dados_etc$ANO=="2016", dados_etc$NINDIV_arrasto_arred!=0, dados_etc$Subamostra==0)
c2016p<-data.frame(b2016p[6])
d2016p<-unlist(c2016p)
a2017p<-filter(d1p, dados_etc$ANO=="2017")
b2017p<-filter(d1p, dados_etc$ANO=="2017", dados_etc$NINDIV_arrasto_arred!=0, dados_etc$Subamostra==0)
c2017p<-data.frame(b2017p[6])
d2017p<-unlist(c2017p)
a2018p<-filter(d1p, dados_etc$ANO=="2018")
b2018p<-filter(d1p, dados_etc$ANO=="2018", dados_etc$NINDIV_arrasto_arred!=0, dados_etc$Subamostra==0)
c2018p<-data.frame(b2018p[6])
d2018p<-unlist(c2018p)
#####
## Marca - Espécie de tubarão - ETX e ETP
#####
b0618<-rbind(b2006,b2007,b2008,b2009,b2010,b2011,b2013,b2014,b2015,b2016,b2017,b2018)
#Associar estas observações a ETX
b0618["Grupo"]<-c("E. spinax")
b0618
b0618p<-rbind(b2006p,b2007p,b2008p,b2009p,b2010p,b2011p,b2013p,b2014p,b2015p,b2016p,b2017p,b2018p)
b0618p
#Associar estas observações a ETP
b0618p["Grupo"]<-c("E. pusillus")
b0618p
#Colocar as colunas com o mesmo nome
colnames(b0618)<-c("Ano", "LAT_ini", "LONG_ini", "LAT_fim", "LONG_fim", "NINDIV_arrasto_arred", "Grupo")
colnames(b0618p)<-c("Ano", "LAT_ini", "LONG_ini", "LAT_fim", "LONG_fim", "NINDIV_arrasto_arred", "Grupo")
total_etc_etc<-rbind(b0618, b0618p)
#Mapa geral
ggplot() +
  geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  geom_point(data = total_etc_etc, aes(x=LONG_fim, y=LAT_fim, color=Grupo),
             size = 1) +
  scale_colour_manual("Grupo", values = c("green", "blue")) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  xlab("Longitude final") + ylab("Latitude final") +
  ggtitle("Ocorrência das duas espécies - 2006 a 2018")+

```

```

theme(plot.title = element_text(hjust = 0.5))
#Tivemos que começar em 2006, pois como não existem dados em 2012, para termos 3 series de 4 anos.
a2006<-filter(d1, dados_etx$ANO=="2006", dados_etx$NINDIV_arrasto_arred!=0, dados_etx$Subamostra==0)
a2007<-filter(d1, dados_etx$ANO=="2007", dados_etx$NINDIV_arrasto_arred!=0, dados_etx$Subamostra==0)
a2008<-filter(d1, dados_etx$ANO=="2008", dados_etx$NINDIV_arrasto_arred!=0, dados_etx$Subamostra==0)
a2009<-filter(d1, dados_etx$ANO=="2009", dados_etx$NINDIV_arrasto_arred!=0, dados_etx$Subamostra==0)
b0609<-rbind(a2006,a2007,a2008,a2009)
c0609<-data.frame(b0609[6])
d0609<-unlist(c0609)
a2010<-filter(d1, dados_etx$ANO=="2010", dados_etx$NINDIV_arrasto_arred!=0, dados_etx$Subamostra==0)
a2011<-filter(d1, dados_etx$ANO=="2011", dados_etx$NINDIV_arrasto_arred!=0, dados_etx$Subamostra==0)
a2013<-filter(d1, dados_etx$ANO=="2013", dados_etx$NINDIV_arrasto_arred!=0, dados_etx$Subamostra==0)
a2014<-filter(d1, dados_etx$ANO=="2014", dados_etx$NINDIV_arrasto_arred!=0, dados_etx$Subamostra==0)
b1014<-rbind(a2010,a2011,a2013,a2014)
c1014<-data.frame(b1014[6])
d1014<-unlist(c1014)
a2015<-filter(d1, dados_etx$ANO=="2015", dados_etx$NINDIV_arrasto_arred!=0, dados_etx$Subamostra==0)
a2016<-filter(d1, dados_etx$ANO=="2016", dados_etx$NINDIV_arrasto_arred!=0, dados_etx$Subamostra==0)
a2017<-filter(d1, dados_etx$ANO=="2017", dados_etx$NINDIV_arrasto_arred!=0, dados_etx$Subamostra==0)
a2018<-filter(d1, dados_etx$ANO=="2018", dados_etx$NINDIV_arrasto_arred!=0, dados_etx$Subamostra==0)
b1518<-rbind(a2015,a2016,a2017,a2018)
c1518<-data.frame(b1518[6])
d1518<-unlist(c1518)
#####
##### MAPAS COM MARCA NINDIV_Arrasto_arred #####
#####
map0609<-ggplot() +
  geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  geom_point(data = b0609, aes(x=dados_etx.LONG_fim, y=dados_etx.LAT_fim, color=d0609),
    size = 1) +
  scale_colour_gradientn("NINDIV", colours = hcl.colors(4, palette = "temps"), limits = c(0, 100)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  xlab("Longitude final") + ylab("Latitude final") +
  ggtitle("Ocorrência E. spinax - 2006 a 2009")+
  theme(plot.title = element_text(hjust = 0.5))
map1014<-ggplot() +
  geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +
  coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
  geom_point(data = b1014, aes(x=dados_etx.LONG_fim, y=dados_etx.LAT_fim, color=d1014),
    size = 1) +
  scale_colour_gradientn("NINDIV", colours = hcl.colors(4, palette = "temps"), limits = c(0, 100)) +

```

```

coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
xlab("Longitude final") + ylab("Latitude final") +
ggtitle("Ocorrência E. spinax - 2010 a 2014")+
theme(plot.title = element_text(hjust = 0.5))
map1518<-ggplot() +
geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +
coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
geom_point(data = b1518, aes(x=dados_etx.LONG_fim, y=dados_etx.LAT_fim, color=d1518),
size = 1) +
scale_colour_gradientn("NINDIV", colours = hcl.colors(4, palette = "temps"), limits = c(0, 100)) +
coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
xlab("Longitude final") + ylab("Latitude final") +
ggtitle("Ocorrência E. spinax - 2015 a 2018")+
theme(plot.title = element_text(hjust = 0.5))
#Grelha com os 3 mapas
grid.arrange(map0609, map1014, map1518, nrow=1, ncol=3)
#####
## MAPA COM OS 12 ANOS #####
## A marca é GRUPO #####
#####
#converter os anos 2006 a 2009 no G1
b0609["Grupo"]<-c("2006-2009")
#converter os anos 2010 a 2014 no G2
b1014["Grupo"]<-c("2010-2014")
#converter os anos 2015 a 2018 no G3
b1518["Grupo"]<-c("2015-2018")
a0615<-rbind(b0609,b1014,b1518)
ggplot(a0615, aes(x=grupo, y=dados_etx.NINDIV_arrasto_arred, fill=grupo))+
geom_boxplot() +
scale_colour_manual("Grupo", values = c("red", "blue", "green")) +
ggtitle("Boxplot número de indivíduos E. spinax nos três grupos")
#Mapa geral
ggplot() +
geom_polygon(data = pt, aes(x = long, y = lat, group = group)) +
coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
geom_point(data = a0615, aes(x=dados_etx.LONG_fim, y=dados_etx.LAT_fim, color=Grupo),
size = 1) +
scale_colour_manual("Grupo", values = c("red", "blue", "green")) +
coord_fixed(xlim=c(-9.4,-7.4), ylim=c(36.3,38.5)) +
xlab("Longitude final") + ylab("Latitude final") +
ggtitle("Ocorrência E. spinax - 2006 a 2018")+
theme(plot.title = element_text(hjust = 0.5))

```

```

#Selecionar apenas as colunas com a LONG (x) e LAT (y)
st1<-c0618[, c("dados_etx.LONG_fim2","dados_etx.LAT_fim2")]
#Construção do polígono à volta dos pontos
st2<-st_as_sf(st1, coords = c("dados_etx.LONG_fim2","dados_etx.LAT_fim2"))
st2
plot(st2)
l0<-st_buffer(st2, dist=0.2)
plot(l0)
geom = st_geometry(st2)
buf <- st_buffer(geom, dist = 0.2)
plot(buf, border = 'red')
plot(geom, add = TRUE)
plot(st_buffer(geom, dist=0.2), add = TRUE, border = 'blue')
pol1<-st_union(buf)
plot(pol1)
pol1
#Nomear o polígono que será a janela
w<-as.owin(pol1)
plot(w)
#transformar os dados sem subamostra no formato ppp
etx<-ppp(c0618$dados_etx.LONG_fim2,c0618$dados_etx.LAT_fim2>window = w)
#Verificar se existem pontos sobrepostos
any(duplicated(etx))
multiplicity(etx)
summary(etx)
plot(etx, main="Região de interesse com os eventos observados - E. spinax")
#Análise da intensidade
#Vamos verificar se a intensidade é homogénea ou não homogénea.
b2<-bw.ppl(etx, diggle=TRUE) # valor do sigma - kernel bandwidth sigma com a correção de Diggle's
b2
plot(density(etx))
c2<-plot(density(etx, sigma=b2))
#Análise da intensidade considerando diferentes largura de banda
par(mfrow=c(2,2))
plot(density(etx, sigma=10), main="Kernel: Largura de banda = 10")
plot(density(etx, sigma=0.2), main="Kernel: Largura de banda = 0.2")
plot(density(etx, sigma=200), main="Kernel: Largura de banda = 200")
plot(density(etx, sigma=b2), main="Kernel: Largura de banda = 0.0266")
# Pela análise do gráfico anterior, observamos que a intensidade não será homegénea
#Vamos testar a hipótese de aleatoriedade espacial completa (CSR) através da função K (Ripley's K-function)
csr2<-Kest(etx)
plot(csr2, main="Função-K - Espécie E. spinax")

```

#É mais adequado proceder à análise da intensidade recorrendo a técnicas não paramétricas como Quadrat count e o estimador de Kernel.

```
Q2<-quadratcount(etx,nx=10, ny=10)
```

```
plot(Q2)
```

```
quadrat.test(Q2)
```

```
Q3<-quadratcount(etx, nx=20, ny=30)
```

```
plot(Q3)
```

```
quadrat.test(Q3)
```

```
#visualização das duas situações
```

```
par(mfrow=(c(1,2)))
```

```
plot(Q2)
```

```
plot(Q3)
```

```
#Kernel estimation
```

```
etx_kernel2 <- density(etx)
```

```
plot(etx_kernel2)
```

```
plot(etx, add = TRUE, cex = 0.01)
```

```
plot(density(etx, sigma=b2, add= TRUE, cex=1))
```

```
#Mostramos que é um processo de Poisson não homogéneo, ou seja, que o pressuposto CRS não é verificado
```

```
ts<-quadrat.test(etx, method = "MonteCarlo")
```

```
ts
```

```
plot(ts)
```

```
#Também podemos usar o seguinte teste para mostrar que o processo de Poisson é não homogéneo
```

```
plot(envelope(etx))
```

```
#####
```

```
#### Modelo com Profundidade e Costa
```

```
#####
```

```
d1<-data.frame(dados_etx$ANO, dados_etx$LAT_fim2, dados_etx$LONG_fim2, dados_etx$MedPROF,
```

```
          dados_etx$Subamostra, dados_etx$NINDIV_arrasto_arred, dados_etx$Comp_mediano,dados_etx$Costa)
```

```
summary(d1)
```

```
#####
```

```
#criação de uma dataframe com as localizações (x,y) e a variável dicotómica Costa)
```

```
c0618$dados_etx.Costa<-factor(c0618$dados_etx.Costa, label=c("0", "1"), levels=c(0,1)) #converter em variável dicotómica
```

```
summary(c0618$dados_etx.Costa)
```

```
a2<-data.frame(etx, c0618$dados_etx.Costa)
```

```
#alterar o nome da última coluna para "Costa"
```

```
colnames(a2)[colnames(a2) == "c0618.dados_etx.Costa"] <- "Costa"
```

```
summary (a2)
```

```
#### Modelo - Cox model
```

```
mod0a<-kppm(etx ~ 1, clusters="LGCP")
```

```
summary(mod0a)
```

```
#####
```

```
#### Modelo com a covariável Profundidade
```

```
#####
prof1<-data.frame(MedPROF=c(c0618$dados_etx.MedPROF))
dummy1<-default.dummy(etx)
summary(dummy1)
plot(dummy1)
q1<- quadscheme(etx, dummy1)
plot(q1) # região de interesse com as observações efetivas e os dummy points
m2<-data.frame(dummy1) #data frame com os dummy points
b2<-bw.ppl(etx, diggle=TRUE) # valor do sigma - kernel bandwidth sigma com a
#correção de Diggle's
#Extrapolação dos valores da profundidade em todo o polígono.
prof_mark<-ppp(st1$dados_etx.LONG_fim2, st1$dados_etx.LAT_fim2,marks=c0618$dados_etx.MedPROF>window=w)
summary(prof_mark)
kernel_prof_b2<-Smooth.ppp(prof_mark,sigma=b2,edge = TRUE, diggle=TRUE)
summary(kernel_prof_b2)
c1<-raster(kernel_prof_b2)
c1
plot(c1)
v2<-raster::extract(c1,m2)
p3<-c(v2)
str(v2)
prof2<-c(prof1)
df <- data.frame(prof3=c(prof2$MedPROF,p3))
mod1a<-kppm(q1, ~ prof3, "LGCP", covariates=list(prof3=kernel_prof_b2))
summary(mod1a)
### Verifica-se que a profundidade não contribui significativamente para a distribuição da espécie ETX
#####
#### Modelo com a covariável Costa
#####
#Acrescentar a variável dicotômica "Costa" aos dummy points
# Definir os valores limites para a longitude (x) e a latitude (y)
limite_x_min <- -9.502
limite_x_max <- -8.757
limite_y_min <- 37.20
limite_y_max <- 38.50
# Acrescentar a nova variável dicotômica "Costa" aos dummy points; 0 - Sudoeste; 1 - Sul
m2t <- m2 %>%
  mutate(Costa = ifelse(x>=limite_x_min & x<=limite_x_max & y>=limite_y_min &
    y<=limite_y_max, "0", "1"))
m2t
m2t$Costa<-factor(m2t$Costa, label=c("0", "1"), levels=c(0,1)) #converter em variável dicotômica
str(m2t$Costa)
```

```

summary(m2t)
#Juntar as duas dataframe - com os pontos observáveis (a2) e com os dummy points (m2);
#Vamos designar essa nova dataframe por m3
m3<- bind_rows(a2,m2t)
summary(m3)
m3$Costa<-factor(m3$Costa, label=c("0", "1"), levels=c(0,1)) #converter em variável dicotômica
#summary(m3$Costa) # número de pontos em cada uma das Costas: Sudoeste (0); Sul (1)
m4<- data.frame(costa3=c(m3$Costa))
#####
##### Modelo com a covariável Costa
#####
costa_mark<-ppp(st1$dados_etx.LONG_fim2, st1$dados_etx.LAT_fim2,marks=c0618$dados_etx.Costa>window=w)
summary(costa_mark)
kernel_costa_b2<-Smooth.ppp(costa_mark,sigma=b2,edge=TRUE, diggle=TRUE)
plot(kernel_costa_b2)
# Dividir os pontos numa lista para cada categoria
points_list<- split(costa_mark, costa_mark$marks)
points_list
plot(density(points_list))
df_costa<-data.frame(costa3=c(a2$Costa,m2$Costa))
df_costa
mod23<-kppm(q1, ~ costa3, "LGCP", covariates=list(costa3=kernel_costa_b2))
summary(mod23)
# De acordo com os dados, verifica-se que a covariável "Costa" não contribui significativamente para a distribuição da
espécie ETX
#####
##### Modelo com as covariáveis Profundidade e Costa
#####
modcostaprof1<-kppm(q1, ~ prof3 + costa3, "LGCP", covariates=list(prof3=kernel_prof_b2,costa3=kernel_costa_b2))
summary(modcostaprof1)
#####
##### Marca COMPRIMENTO Mediano
#####
#transformar os dados no formato ppp com a marca Comp_mediano
etxcomp<-ppp(c0618$dados_etx.LONG_fim2,c0618$dados_etx.LAT_fim2>window = w,
marks=c0618$dados_etx.Comp_mediano)
etxcomp
summary(etxcomp)
plot(etxcomp)
k_etxcomp<-Kest(etxcomp)
plot(k_etxcomp, main="Função K, Espécie E. spinax com marca Comp_mediano")
kernel_comp_b2<-Smooth.ppp(etxcomp,sigma=b2,edge = TRUE, diggle=TRUE)

```

```

plot(kernel_comp_b2)
summary(kernel_comp_b2)
cc<-raster(kernel_comp_b2)
plot(cc)
par(mfrow=(c(1,2)))
plot(etxcomp)
plot(cc)
#Kernel estimation
etxcomp_kernel <- density(etxcomp)
plot(etxcomp_kernel)
#Função de correlação do processo pontual marcado
mark2<-markcorr(etxcomp)
plot(mark2)
### Como a marca Comp_mediano é contínua, este pacote não permite a modelação com este tipo de variável
# Assim, de acordo com Baddeley & Turner (2005), iremos converter este processo pontual marcado num
# processo pontual multitypo, em que convertemos a marca Comp_mediano numa marca categórica.
## Vamos classificar a marca Comp_mediano em três categorias: Baixo, Médio e Elevado.
## Tendo em conta as medidas sumárias, vamos considerar as seguintes categorias:
## Recém-nascidos : <15
## Juvenis: 15 e 30 (Q3)
## Adultos: superior a 30
marcacompat_cat<-cut(c0618$dados_etx.Comp_mediano, breaks = c(0,15, 30, Inf),
                    labels = c("Recém-nascidos", "Juvenis", "Adultos"))
table(marcacompat_cat) # Recem = 13; Juvenis = 195; Adultos = 60
#Processo pontual com a marca Comp_mediano categórica
etxcomp2<-ppp(c0618$dados_etx.LONG_fim2,c0618$dados_etx.LAT_fim2>window = w, marks=marcacompat_cat)
summary(etxcomp2)
plot(etxcomp2)
l1<-split(etxcomp2) # separar os pontos pelas três categorias
plot(l1, main="Ocorrência da espécie E. spinax com a marca Comp_mediano agrupada nas categorias")
#####
#### Análise das 3 categorias pelos grupos de anos definidos 2006-2009; 2010-2014 e 2015-2018
#####
d2006<-filter(c0618, dados_etx.ANO=="2006")
d2007<-filter(c0618, dados_etx.ANO=="2007")
d2008<-filter(c0618, dados_etx.ANO=="2008")
d2009<-filter(c0618, dados_etx.ANO=="2009")
e0609<-rbind(d2006,d2007,d2008,d2009)

d2010<-filter(c0618, dados_etx.ANO=="2010")
d2011<-filter(c0618, dados_etx.ANO=="2011")
d2013<-filter(c0618, dados_etx.ANO=="2013")

```

```

d2014<-filter(c0618, dados_etx.ANO=="2014")
e1014<-rbind(d2010,d2011,d2013,d2014)
d2015<-filter(c0618, dados_etx.ANO=="2015")
d2016<-filter(c0618, dados_etx.ANO=="2016")
d2017<-filter(c0618, dados_etx.ANO=="2017")
d2018<-filter(c0618, dados_etx.ANO=="2018")
e1518<-rbind(d2015,d2016,d2017,d2018)
marcacomp_cat_0609<-cut(e0609$dados_etx.Comp_mediano, breaks = c(0,15, 30, Inf),
      labels = c("Recém-nascidos", "Juvenis", "Adultos"))
table(marcacomp_cat_0609) # Recem = 3; Juvenis = 78; Adultos = 16
#Processo pontual com a marca Comp_mediano categórica em 2006 a 2009
etxcomp2_0609<-ppp(e0609$dados_etx.LONG_fim2,e0609$dados_etx.LAT_fim2>window = w,
marks=marcacomp_cat_0609)
summary(etxcomp2_0609)
# Kernel estimation por categoria: 2006-2009
plot(density(split(etxcomp2_0609)), main="Estimação de Kernel da E. spinax por Comp_mediano nas categorias entre 2006
e 2009")
marcacomp_cat_1014<-cut(e1014$dados_etx.Comp_mediano, breaks = c(0,15, 30, Inf),
      labels = c("Recém-nascidos", "Juvenis", "Adultos"))
table(marcacomp_cat_1014) # Recem = 4; Juvenis = 55; Adultos = 15
#Processo pontual com a marca Comp_mediano categórica em 2006 a 2009
etxcomp2_1014<-ppp(e1014$dados_etx.LONG_fim2,e1014$dados_etx.LAT_fim2>window = w,
marks=marcacomp_cat_1014)
summary(etxcomp2_1014)
# Kernel estimation por categoria: 2010-2014
plot(density(split(etxcomp2_1014)), main="Estimação de Kernel da E. spinax por Comp_mediano nas categorias entre 2010
e 2014")
marcacomp_cat_1518<-cut(e1518$dados_etx.Comp_mediano, breaks = c(0,15, 30, Inf),
      labels = c("Recém-nascidos", "Juvenis", "Adultos"))
table(marcacomp_cat_1518) # Recem = 6; Juvenis = 62; Adultos = 29
#Processo pontual com a marca Comp_mediano categórica em 2006 a 2009
etxcomp2_1518<-ppp(e1518$dados_etx.LONG_fim2,e1518$dados_etx.LAT_fim2>window = w,
marks=marcacomp_cat_1518)
summary(etxcomp2_1518)
# Kernel estimation por categoria: 2015-2018
plot(density(split(etxcomp2_1518)), main="Estimação de Kernel da E. spinax por Comp_mediano nas categorias entre 2015
e 2018")

```