

Universidade de Lisboa
Instituto de Geografia e Ordenamento do Território



LISBOA

UNIVERSIDADE
DE LISBOA

Estatística Espacial para Gestão de Dádivas de Sangue em Portugal

Raquel Garcia dos Santos

Relatório de Estágio orientado
pelo Professor Doutor Fernando Jorge Pedro da Silva Pinto da Rocha

Mestrado em Sistemas de Informação Geográfica e Modelação Territorial
Aplicados ao Ordenamento

2022

Universidade de Lisboa
Instituto de Geografia e Ordenamento do Território



Estatística Espacial para Gestão de Dádivas de Sangue em Portugal

Raquel Garcia dos Santos

Relatório de Estágio orientado

pelo Professor Doutor Fernando Jorge Pedro da Silva Pinto da Rocha

Júri:

Presidente: Professor Doutor Paulo Alexandre Morgado Sousa do Instituto de Geografia e Ordenamento do Território da Universidade de Lisboa;

Vogais:

- Professora Doutora Rita da Mata Graça Roquette e Silva do Instituto da Vinha e do Vinho;
- Professora Doutora Cláudia Morais Viana do Instituto de Geografia e Ordenamento do Território da Universidade de Lisboa.

Agradecimentos

Gostaria de agradecer ao Professor Doutor Jorge Rocha por toda a orientação, interesse demonstrado, total disponibilidade e saber que me transmitiu, indispensável à realização deste trabalho.

Ao Instituto Português do Sangue e da Transplantação, como instituição de acolhimento, que me proporcionou todas as condições para realizar o estágio e em especial ao Doutor Alexandre Matos pela simpatia com que me recebeu, sempre disponível para esclarecer todas as minhas dúvidas.

Por fim, queria agradecer à minha família e amigos, por todo o carinho, incentivo e apoio em todas as minhas decisões.

Resumo

A doação de sangue é indispensável para salvar vidas, sendo em algumas situações inevitável a transfusão. Em Portugal todos os dias são necessárias entre 900 e 950 unidades de sangue nos hospitais e tendo em conta que os componentes sanguíneos têm um prazo de validade é de extrema importância manter a regularidade das colheitas, sendo as dádivas regulares essenciais para garantir a estabilidade das reservas e o funcionamento do sistema de saúde. A pouca disponibilidade de ferramentas que possibilitem o estudo geográfico destes fenómenos, dificulta o planeamento de sessões de colheita. Face a estes dados é fundamental que haja na área da saúde, sistemas de informação (SI) que permitam uma boa gestão das sessões de colheita de forma a contribuir para uma eficaz racionalização de recursos.

Este estágio teve por objetivo principal os seguintes pontos de atuação: i) identificação geográfica das sessões de colheita de sangue; ii) análise da distribuição geográfica dos diferentes grupos sanguíneos. Neste trabalho é construído um *dashboard* que permite auxiliar o Instituto Português do Sangue e Transplantação (IPST) no planeamento de sessões de colheita. De forma a facilitar a construção e o acesso do *dashboard* foi utilizado o *software Power BI*, que não só facilita a introdução de novos registos, como permite que a informação esteja sempre atualizada.

Inicialmente procedeu-se à recolha e tratamento de dados com o intuito de criação e estruturação de uma base de dados em *Excel*. Posteriormente realizou-se a geocodificação das sessões de colheita de sangue. Preparada a informação, pretende-se compreender as dinâmicas espaciais da dádiva de sangue, desse modo aplicaram-se métodos estatísticos, nomeadamente o Índice de *Moran* e análise de *Hot Spot*, com vista a identificar padrões espaciais e constatar se a distribuição espacial é aleatória ou aglomerada. De modo a observar de forma coesa a densidade de brigadas móveis, procedeu-se à aplicação do método da densidade de *Kernel*. Foi também realizada uma análise de potencial, recorrendo ao método Regressão Linear Múltipla (RLM), como forma de perspetivar se alguns aspetos populacionais influenciam o número de dádivas. Por fim, através da aplicação *Power BI* procedeu-se à criação de um *dashboard* que foi apresentado e disponibilizado ao IPST.

Palavras-chave: Dádivas de sangue; Sessões de colheita; Análise espacial

Abstract

Blood donation is essential to save lives, and in some situations, transfusion is unavoidable. In Portugal, between 900 and 950 units of blood are needed every day in hospitals and, taking into account that blood components have an expiration date, it is extremely important to maintain the regularity of collections, with regular donations being essential to guarantee the stability of reserves and the functioning of the health system. The limited availability of tools that allow the geographical study of these phenomena makes it difficult to plan collection sessions. In view of these data, it is essential that there are information systems in the health area that allow for a good management of collection sessions in order to contribute to an effective rationalization of resources.

The main objective of this internship was the following points of action: i) geographical identification of the blood collection sessions; ii) analysis of the geographic distribution of the different blood groups. In this work, a dashboard is built that helps the Portuguese Institute of Blood and Transplantation (IPST) in the planning of harvesting sessions. In order to facilitate the construction and access of the dashboard, the Power BI software was used, which not only facilitates the introduction of new records, but also allows the information to be always updated.

Initially, data was collected and processed with the aim of creating and structuring a database in Excel. Subsequently, the geocoding of the blood collection sessions was carried out. Having prepared the information, it is intended to understand the spatial dynamics of blood donation, in this way statistical methods were applied, namely the Moran Index and Hot Spot analysis, in order to identify spatial patterns and verify if the spatial distribution is random or agglomerated. In order to, cohesively observe the density of mobile brigades, the Kernel density method was applied. A potential analysis was also carried out, using the Multiple Linear Regression (MLR) method, as a way of envisioning whether some population aspects influence the number of donations. Finally, through the Power BI application, a dashboard was created that was presented and made available to the IPST.

Keywords: Blood donations; Harvest sessions; Spatial analysis

Índice Geral

Resumo	iii
Abstract.....	v
Índice de Figuras	ix
Índice de Tabelas	xi
Siglas e Acrónimos	xiii
Capítulo 1. Introdução	1
Capítulo 2. Enquadramento Geral	4
2.1. Sangue	4
2.2. Transfusão	5
2.3. Doação.....	7
2.4. Instituto Português do Sangue e da Transplantação, IP	7
2.5. Enquadramento geográfico da área de estudo	8
Capítulo 3. Geografia e Saúde.....	10
3.1. A Geografia no estudo da saúde	10
3.2. Geografia da Saúde	10
3.3. Sistemas de Informação Geográfica	11
3.4. Aplicação dos SIG na saúde pública	14
3.5. Business Intelligence	18
3.6. Power BI	19
Capítulo 4. Metodologia	21
4.1. Aquisição e tratamento da informação	21
4.2. Construção de uma base de dados	22
4.3. Geocodificação	22
4.4. Análise da informação.....	24

4.5. Métodos de análise e classificação de dados	30
4.5.1. Índice de Moran.....	32
4.5.2. Análise de Hot Spot (Getis-Ord G_i^*).....	34
4.5.3. Densidade de Kernel.....	35
4.5.4. Regressão Linear Múltipla	37
4.6. Dashboard de apoio à decisão	41
Capítulo 5. Análise dos Resultados	45
5.1. Índice de Moran	45
5.2. Análise de Hot Spot (Getis-Ord G_i^*).....	47
5.3. Densidade de Kernel	49
5.4. Regressão Linear Múltipla.....	50
Considerações finais	52
Bibliografia	55
Legislação Consultada.....	61

Índice de Figuras

Figura 1 - Representação de um vaso sanguíneo	4
Figura 2 - Compatibilidade dos grupos sanguíneos	6
Figura 3 - Enquadramento geográfico da área de estudo	9
Figura 4 - Componentes de um SIG	13
Figura 5 - Casos de cólera durante a epidemia em Londres em 1854.....	15
Figura 6 - Artigos publicados em cada ano sob os termos de pesquisa	17
Figura 7 – Funcionamento do Power BI.....	19
Figura 8 – Componentes do Power BI	20
Figura 9 – Distribuição geográfica das brigadas	25
Figura 10 - População residente com idade para dar sangue (20-64 anos) por município, 2020	26
Figura 11 – Indicador do poder de compra per capita por município, 2019.....	27
Figura 12 – Taxa de conclusão do ensino básico por município, 2020.....	28
Figura 13 – Taxa de conclusão do ensino secundário por município, 2020	28
Figura 14 – População empregada por município, 2019.....	29
Figura 15 – População empregada no setor primário por município, 2019.....	30
Figura 16 – População empregada no setor secundário por município, 2019.....	30
Figura 17 – População empregada no setor terciário por município, 2019.....	30
Figura 18 - Autocorrelação Espacial Positiva (a), Autocorrelação Espacial Negativa (b) e Aleatoriedade Espacial (c).....	33
Figura 19 – Valor do pico utilizado para definir o raio da área de influência.....	37
Figura 20 – Dashboard de informação sobre as brigadas	43
Figura 21 – Dashboard de informação sobre os grupos sanguíneos.....	44
Figura 22 – Resultado do índice de Moran nos municípios.....	45

Figura 23 – Resultado do índice de Moran nas freguesias	45
Figura 24 – Resultado do índice Local de Moran nos municípios	47
Figura 25 – Resultado do índice Local de Moran nas freguesias.....	47
Figura 26 - Clusters espaciais de dádivas de sangue nos municípios	48
Figura 27 - Clusters espaciais de dádivas de sangue nas freguesias	48
Figura 28 – Densidade de Kernel	49
Figura 29 - Resíduos da regressão linear múltipla.....	51

Índice de Tabelas

Tabela 1 - Informação utilizada	22
Tabela 2 - Esquema da aplicação dos métodos de análise espacial	32
Tabela 3 - Valores de VIF para as variáveis independentes.....	39
Tabela 4 – Informação disponível no dashboard.....	42

Siglas e Acrónimos

AML – Área Metropolitana de Lisboa

AMP – Área Metropolitana do Porto

BI – *Business Intelligence*

CAOP – Carta Administrativa Oficial de Portugal

CGIS – *Canadian Geographic Information System*

DGT – Direção Geral do Território

INE – Instituto Nacional de Estatística

IPST – Instituto Português do Sangue e da Transplantação

LISA – *Local Indicators of Spatial Association*

RGP – Regressão Geográfica Ponderada

RLM – Regressão Linear Múltipla

SI – Sistemas de Informação

SIG – Sistemas de Informação Geográfica

SNS – Serviço Nacional de Saúde

SVE – Sistemas de Vigilância Epidemiológica

VIF – *Variance Inflation Factor*

Capítulo 1. Introdução

A constituição do sangue é de tal maneira complexa, que a medicina ainda não conseguiu produzir um substituto, sendo por isso indispensável a contribuição de doadores de sangue para salvar vidas. A sobrevivência de alguns doentes depende de tratamentos diários com sangue, em Portugal todos os dias são necessárias entre 900 e 950 unidades de sangue nos hospitais e de acordo com os dados recolhidos em 2017 pelo Instituto Português do Sangue e da Transplantação (IPST) há cerca de 209 mil doadores de sangue. Por outro lado, os componentes sanguíneos têm um prazo de armazenamento, nomeadamente os concentrados eritrócitários, que perdem a validade ao fim de 35 a 42 dias, e as plaquetas, ao fim de 5 a 7 dias (SNS, 2021¹). Face a estes dados é fundamental que haja na área da saúde, sistemas de informação (SI) que permitam uma boa gestão das sessões de colheita de sangue.

Para ajudar a colmatar a inexistência de SI funcionais e no âmbito do Mestrado em Sistemas de Informação Geográfica e Modelação Territorial aplicados ao Ordenamento, realizou-se um estágio curricular com a duração de 3 meses no Instituto Português do Sangue e da Transplantação, IP.

Este estágio teve por objetivo principal os seguintes pontos de atuação: i) identificação geográfica das sessões de colheita de sangue; ii) análise da distribuição geográfica dos diferentes grupos sanguíneos. Neste trabalho com recurso à aplicação *Power BI* é construído um *dashboard* de apoio à decisão, que permite a rápida visualização da localização das sessões de colheita de sangue, do número de dádivas, dos grupos sanguíneos, entre outros, o que permite não só auxiliar o IPST no planeamento de sessões de colheita, como contribui para uma eficaz racionalização de recursos. A escolha do *Power BI* deveu-se ao facto do IPST já trabalhar com o mesmo e ser um *software* bastante “amigo do utilizador” o que facilita a sua utilização. Para além disso, permite a introdução de novos registos na base de dados por parte do IPST, garantindo que a informação está sempre atualizada. Ao integrar SI o IPST potencia a mudança e modernização administrativa, aumentando a sua fiabilidade e interoperabilidade.

¹ Site: www.sns.gov.pt – Acedido a 14/11/2021

Inicialmente procedeu-se à recolha e tratamento de dados com o intuito de criação e estruturação de uma base de dados em *Excel*. Posteriormente realizou-se a geocodificação das sessões de colheita de sangue, através do método de pesquisa única (*single search*). A geocodificação assume um papel importante pois permite identificar onde se localizam os dados, permitindo determinar áreas de atuação para, por exemplo, sessões de colheita.

Preparada a informação, pretende-se compreender as dinâmicas espaciais da dádiva de sangue em Portugal Continental, através de análises ligadas à estatística espacial, com vista a propor medidas que possam melhorar o planeamento. Desse modo procedeu-se à aplicação de métodos estatísticos, nomeadamente o Índice de *Moran* e análise de *Hot Spot*, com vista a identificar padrões espaciais e constatar se a distribuição espacial é aleatória ou aglomerada (em *clusters*). De modo a observar de forma coesa a densidade de brigadas móveis que há ao longo da extensão territorial, procedeu-se à aplicação do método da densidade de *Kernel*. Foi também realizada uma análise de potencial, recorrendo ao método de Regressão Linear Múltipla (RLM), como forma de perspetivar se alguns aspetos populacionais influenciam o número de dádivas. Por fim, através da aplicação *Power BI* procedeu-se à criação de um *dashboard* de apoio à decisão que foi apresentado e disponibilizado ao conselho científico do IPST.

O presente relatório encontra-se dividido em 4 capítulos, excluindo a introdução e a conclusão, constituídos por vários subcapítulos:

- **Capítulo 2 – Enquadramento Geral:** Introdução aos conceitos de sangue, transfusão e doação e as suas características gerais; breve apresentação da instituição de acolhimento; e enquadramento geográfico da área de estudo;
- **Capítulo 3 – Geografia e Saúde:** A geografia no estudo da saúde pública, bem como o seu contributo; introdução e descrição dos SIG, bem como a sua relação com a geografia; exemplos de aplicação dos SIG na área da saúde e o seu contributo enquanto ferramenta de apoio à tomada de decisão; análise espacial; exploração do *software Power BI*;
- **Capítulo 4 – Metodologia:** Identificação e análise das variáveis a utilizar no estudo; tratamento da informação; técnicas de geocodificação; identificação e descrição dos métodos estatísticos e análise de potencial; construção do *dashboard* de apoio à decisão;

- **Capítulo 5 – Análise dos Resultados:** Análise e discussão dos resultados obtidos.

No final, são apresentadas as principais conclusões do relatório.

Capítulo 2. Enquadramento Geral

2.1. Sangue

O sangue é uma forma particular de tecido, percorre o sistema circulatório e possui como principal função a manutenção da vida, através do transporte e distribuição de oxigénio e nutrientes para os tecidos e órgãos, do transporte de hormonas, entre outros. O sangue é constituído essencialmente pelo plasma (fase líquida) e células em suspensão (Figura 1). O plasma representa, em média, 55% do sangue e é constituído por água (cerca de 92%), proteínas plasmáticas (cerca de 8%) e outras substâncias como dióxido de carbono, ureia, ácido láctico, entre outras. As células, nomeadamente, glóbulos vermelhos, glóbulos brancos e plaquetas representam, em média, 45% do sangue. Os glóbulos vermelhos ou eritrócitos são responsáveis pelo transporte de oxigénio, os glóbulos brancos ou leucócitos pelo combate de infeções, fazendo parte do sistema imunitário e as plaquetas ou trombócitos pela coagulação, auxiliando no controlo de hemorragias (Hospital da Luz, 2019²).




Figura 1 - Representação de um vaso sanguíneo

Fonte: Encyclopaedia Britannica, Inc.

² Site: <https://www.hospitaldaluz.pt/pt> –/ Acedido a 18/12/2021

2.2. Transfusão

Uma transfusão de sangue ou de componentes sanguíneos consiste na administração, através de um cateter venoso, de componentes do sangue (glóbulos vermelhos, plaquetas, plasma) ou de substâncias que intervêm na formação e funções normais do sangue (fibrinogénio, fatores de coagulação, entre outros). O processo transfusional é composto por componentes sanguíneos, que são submetidos a um conjunto de exames, decompostos e quando validados, tornam-se disponíveis para serem usados numa transfusão, evitando que haja incompatibilidade sanguínea (Hospital da Luz, 2019).

Em 1613 William Harvey alcançou um dos passos mais importantes na história da transfusão com a descoberta da circulação do sangue. Na altura acreditava-se que os pulmões eram responsáveis pelo movimento do sangue pelo corpo. Harvey, ao observar o coração de animais vivos, percebeu que este era o órgão que ao contrair bombeava o sangue, verificando que a quantidade de sangue que saía do coração era demasiada para os tecidos absorverem, conseguiu determinar que as válvulas e as veias eram responsáveis pela circulação do sangue pelo corpo (Besterman, 2004). Harvey descreveu em pormenor a sua descoberta em *“Exercitatio Anatomica de Motu Cordis et Sanguinis in Animalibus”*.

Em 1665 Richard Lower realizou as primeiras experiências de transfusão direta de sangue entre animais. Dois anos mais tarde ocorreu a primeira reação transfusional hemolítica num doente que recebeu sangue incompatível. A incompatibilidade verificada causou a morte de muitos doentes, o que veio a determinar a proibição das transfusões de sangue em 1678. Face a isto, só um século mais tarde se voltou a ponderar a realização de transfusões. James Blundell em 1818, utilizou sangue do próprio doente (transfusão autóloga) e de outros seres. A terapêutica umas vezes era bem-sucedida, outras não, tendo alguns doentes apresentado problemas após transfusão que conduziram à sua morte (IPST, 2021³). A 22 de dezembro de 1818, Blundell publicou o seu primeiro artigo sobre transfusão de sangue entre humanos (Giangrande, 2000).

Coube a Karl Landsteiner⁴ em 1900 a descoberta da substância A e B do Sistema AB0, ao identificar que os eritrócitos de algumas pessoas ficavam aglutinados quando em contacto com o plasma ou soro de outras. Após estudos com várias amostras de sangue,

³ Site: www.ipst.pt –/ Acedido a 18/12/2021

⁴ Médico e biólogo norte-americano, de origem austríaca.

conseguiu provar que o sangue não tinha toda a mesma constituição, conseguindo assim classificar os grupos sanguíneos em A, B e O. Landsteiner descobriu que os glóbulos vermelhos não eram todos iguais como se pensava na época. Havia uns glóbulos que tinham uma substância que chamou de A e todos os que tivessem essa substância seriam do grupo A. Outros tinham uma substância diferente da primeira que chamou de B e todos os que tivessem essa substância seriam do grupo B. Os que tinham estas duas substâncias seriam do grupo AB. Não tendo nenhum dos antigénios nos eritrócitos, possui o tipo sanguíneo O. Cerca de 40 anos depois descobriu uma outra substância que chamou de D, na qual uns eram Rh⁺ e outros Rh⁻. A associação dos dois sistemas de grupos sanguíneos, ABO e Rh, determina a existência de 8 grupos diferentes: A⁺, A⁻, B⁺, B⁻, AB⁺, AB⁻, O⁺ e O⁻. Pela classificação dos grupos sanguíneos, sistema ABO, e descoberta do fator Rh, Landsteiner foi agraciado com o Nobel de Fisiologia/Medicina de 1930.

A pesquisa de Landsteiner foi o primeiro passo para transfusões de sangue mais seguras, revelando que indivíduos com o mesmo tipo sanguíneo ou com sangue compatível podem receber transfusões umas das outras (Figura 2). Nas situações que envolvem emergência médica e se desconhece o tipo de sangue do doente, o tipo de sangue administrado é o dador universal (grupo O⁻). A generalização da prática de transfusão de sangue, em Portugal e no Mundo, aconteceu verdadeiramente na última metade do século XX.

SE ÉS RH+	PODES RECEBER	PODES DAR
A+	A+ A- O+ O-	A+ AB+
B+	B+ B- O+ O-	B+ AB+
O+	O+ O-	O+ A+ B+ AB+
AB+	Todos com RH+ e RH-	AB+
SE ÉS RH-	PODES RECEBER	PODES DAR
A-	A- O-	A- A+ AB- AB+
B-	B- O-	B- B+ AB- AB+
O-	O-	Todos com RH+ e RH-
AB-	Todos com RH-	AB- AB+

Figura 2 - Compatibilidade dos grupos sanguíneos

Fonte: IPST

2.3. Doação

Uma doação de sangue é o processo pela qual um dador voluntário disponibiliza uma dádiva. O processo de doação de sangue abrange várias etapas sendo elas: consulta de doação, colheita, decomposição, validação e disponibilização das unidades sanguíneas.

Segundo a Lei n.º 37/2012, de 27 de agosto de 2012, Artigo 3.º, “entende-se por dador de sangue aquele que, depois de aceite clinicamente, doa benevolmente e de forma voluntária parte do seu sangue para fins terapêuticos”. Artigo 4.º “a dádiva de sangue é um ato cívico, voluntário, benévolo e não remunerado”. Podem dar sangue os indivíduos entre os 18 e os 65 anos. Sendo que para os que o fazem pela primeira vez só podem até aos 60 anos. É ainda necessário ser saudável e pesar no mínimo 50 quilos. A doação de sangue pode ser efetuada de quatro em quatro meses pelas mulheres e de três em três meses pelos homens, com um intervalo mínimo de 2 meses entre as dádivas. Em cada doação são recolhidos cerca de 450 ml de sangue, o que corresponde a cerca de 10% de sangue, volume considerado seguro para o dador (SNS, 2021).

O Dia Mundial do Dador de Sangue foi instituído pela Organização Mundial da Saúde, em maio de 2005. A escolha da data, 14 de junho, tem por objetivo homenagear Karl Landsteiner, nascido nesse dia. Em Portugal, o dia Nacional do Dador de Sangue assinala-se a 27 de março.

2.4. Instituto Português do Sangue e da Transplantação, IP

O IPST, IP é um instituto público que regula, a nível nacional, a atividade da medicina transfusional e da transplantação e visa “garantir a dádiva, colheita, análise, processamento, preservação, armazenamento e distribuição de sangue humano, de componentes sanguíneos, de órgãos, tecidos e células de origem humana” (IPST, 2021).

A visão do instituto é a de promover a dádiva com o objetivo de contribuir em tempo e qualidade para a vida humana, tendo por base as boas práticas e conhecimentos científicos. Os valores institucionais assentam na excelência e inovação, assumindo-se como uma instituição dedicada ao suporte da vida humana através das áreas do sangue e da transplantação.

Segundo o Plano Estratégico de 2015-2024 do IPST, as orientações estratégicas na área funcional do sangue passam por:

- Assegurar a autossuficiência em sangue e componentes, incluindo plasma inativado, e suficiência tendencial em derivados de plasma;
- Criar uma maior especificidade na colheita;
- Mudar o paradigma da colheita;
- Reformular o modelo de relacionamento com as associações e grupos de doadores.

2.5. Enquadramento geográfico da área de estudo

A área de estudo do presente estágio corresponde a Portugal Continental (Figura 3). Apresenta uma área de 89 015 km², distribuídos por 18 distritos, 278 concelhos e 2882 freguesias, e, de acordo com os censos de 2021, um total de 9 860 175 habitantes, com um padrão de distribuição fortemente marcado pela litoralização e processos de metropolização em torno das cidades de Lisboa e do Porto, cujas respetivas áreas metropolitanas concentram perto de metade da população do país. Portugal Continental localiza-se na extremidade SW da Península Ibérica e faz fronteira a N e E com Espanha, sendo limitado a S e W pelo Oceano Atlântico Norte. Segundo Orlando Ribeiro, citado por António Ferreira, Portugal Continental “tem uma extensão Norte-Sul (de 42º 09’ até 36º 58’N) atinge os 561 km e a máxima extensão Leste-Oeste (de 6º 12’ até 9º 30’W) é de 218 km”.

Em Portugal Continental é possível dar sangue nos Centros de Sangue e Transplantação de Lisboa, Porto e Coimbra, ou serviços hospitalares com recolha de sangue, sendo o IPST responsável por cerca de 72% das colheitas.



Figura 3 - Enquadramento geográfico da área de estudo

Capítulo 3. Geografia e Saúde

3.1. A Geografia no estudo da saúde

A geografia aplicada ao estudo da saúde verifica-se indispensável quando a dimensão espacial assume importância para compreender a incidência e prevalência de determinadas doenças (Lyseen et al., 2014), auxiliando a compreensão das relações que se estabelecem entre os aspetos geográficos e os diferentes fenómenos centrados em torno da saúde da população.

A necessidade de integração da componente espacial nos estudos epidemiológicos deve-se ao efeito da localização na saúde (Sabel et al., 2009). Neste contexto, a emergência de problemas de saúde resulta de processos interdependentes entre os indivíduos e o ambiente.

O interesse no estudo das relações que se estabelecem entre o espaço e a saúde recua a épocas remotas. Os primeiros contributos empíricos que deram corpo à associação entre o espaço e a saúde datam da Grécia Antiga, quando Hipócrates (460 - 377 a.C.) identificou elementos físicos e a «natureza dos lugares» como fatores causais para as enfermidades que afetavam a humanidade (Nossa, 2005).

Atualmente muitos geógrafos dedicam-se a analisar a difusão espacial de doenças, articulando esses padrões com as características da população e dos territórios, nomeadamente as condições da habitação (presença de humidade, falta de saneamento), as condições físicas, por exemplo, as condições climáticas como a temperatura (a exposição ao calor e ao frio é frequentemente associada a doenças cardiovasculares, respiratórias e mentais), a humidade (surto de asma), a qualidade do ar (doenças respiratórias), entre outras (Santana, 2014).

3.2. Geografia da Saúde

A Geografia da Saúde ou Geografia Médica, designação pela qual primeiramente foi conhecida, trata questões relativas a “desigualdades em saúde e nos acessos aos cuidados de saúde, à reemergência de doenças infecciosas, às políticas de saúde, ao envelhecimento e

aumento dos cuidados de saúde, ou, ainda, às consequências da pobreza e da exclusão na saúde e as políticas de saúde pública consequentes” (Santana, 2014). Importa distinguir que geralmente a Geografia Médica refere-se a questões de doenças e a Geografia da Saúde relaciona-se com uma visão mais integradora das doenças e suas causas e o suporte dos serviços de saúde à população (Santana, 2014). Alguns autores rejeitam a intitulação “Médica” e sugerem rótulos como “Geografia Epidemiológica”, “Geografia das Doenças” ou “Geografia da Saúde Pública” (Mayer, 2010). A importância e afirmação da Geografia da Saúde foi reconhecida e institucionalizada em Washington, em 1992.

A Geografia da Saúde revela-se uma área científica interdisciplinar, constituindo-se como uma plataforma metodológica que consegue articular e integrar vários domínios científicos (Ciências Sociais, Ciências da Terra e Ciências da Saúde). A Geografia da Saúde preocupa-se com a análise de problemas a diversas escalas geográficas, sendo de grande utilidade em equipas pluridisciplinares nas áreas do Ambiente, da Sociologia, do Planeamento e Ordenamento do Território, da Economia e da Saúde (Santana, 2005).

Atualmente o estudo da distribuição de doenças e respetivas causas está centrado nas áreas do conhecimento da Geografia, da Epidemiologia e da Saúde Pública, beneficiando estas da análise espacial integrada em Sistemas de Informação Geográfica (SIG) enquanto meios para extrair evidências dos padrões espaciais. Neste sentido, a Geografia (Médica e da Saúde) tem associações importantes com a saúde pública, contribuindo para criar evidências de como a localização influencia os padrões de saúde e doenças (Curtis *et al.*, 2009).

À escala internacional surgiram várias investigações focadas nas conexões entre lugar, identidade e saúde, suportadas em metodologias qualitativas, que procuram avaliar o impacto do lugar na saúde e nos cuidados de saúde (Nogueira e Remoaldo, 2010). Atualmente existe uma Comissão intitulada *Health and Environment*, que se dedica às questões da saúde e da sua relação com o ambiente.

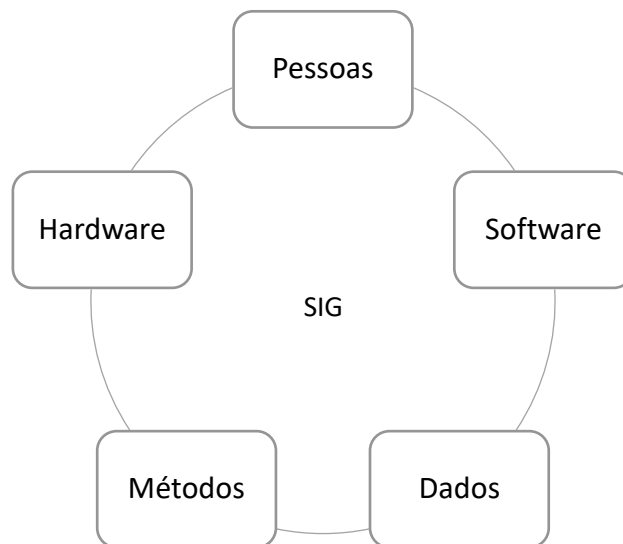
3.3. Sistemas de Informação Geográfica

No final dos anos 1960, através de Waldo Tobler, foi introduzida pela primeira vez nas Universidades Americanas a cartografia analítica. Tal acontecimento foi motivado pela sua

visão de que os geógrafos utilizavam mapas como ferramentas analíticas para compreender e teorizar acerca da Terra e da distribuição de fenómenos à sua superfície (Kemp, 2008).

Na década de 1960 verificam-se as primeiras tentativas de aplicar sistemas de computação para manipular e processar informações geográficas. Roger Tomlinson, considerado o “pai dos SIG”, foi responsável pela criação do *Canadian Geographic Information System* (CGIS), considerado o primeiro SIG na essência do termo, para inventariação dos recursos naturais e para o planeamento. Roger Tomlinson advogava a necessidade de se criarem *softwares* e *toolboxes* que permitissem medir os fenómenos geográficos de forma mais automática. No final da década de 1970, assiste-se à convergência entre a computação e a informação geográfica. Nos anos 1980 surge a primeira indústria dedicada à criação e comercialização de *software* SIG, dando início à era dos SIG (Goodchild, 1992). Em Portugal os SIG surgiram na segunda metade da década de oitenta do século XX. A partir dos anos noventa, a sua aplicação incidiu bastante em fenómenos geográficos no domínio ambiental e de desenvolvimento do território (Nogueira e Remoaldo, 2010).

Atualmente os SIG são utilizados nas mais diversas áreas de trabalho e inúmeras são as possibilidades e ferramentas de tratamento e análise de informação disponibilizadas, com aplicações transversais a um conjunto de fenómenos, desde o planeamento de uso do solo, avaliação de riscos, monitorização de dispersão de fenómenos epidémicos, análise e definição de áreas de mercado, gestão de recursos naturais, entre outros (Chang, 2019). São constantemente apontados como ferramentas de apoio à decisão. Segundo autores como Rocha (2012) e Longley et al. (2015), os SIG são ferramentas computacionais utilizados para armazenar, processar, analisar e visualizar informação geográfica, permitindo a construção de modelos espaciais. São sistemas que permitem analisar fenómenos em relação aos quais a localização geográfica é uma característica importante. É possível definir cinco componentes essenciais dos SIG, nomeadamente, as pessoas (responsáveis pela manipulação e desenvolvimento dos SIG), o *software* (fornece os programas e as ferramentas para gerir, analisar e manipular os dados), os dados (informação geográfica), o *hardware* (computadores onde os SIG operam) e os métodos (descrevem como a tecnologia é aplicada) (González et al., 2012) (Figura 4).



*Figura 4 - Componentes de um SIG
Adaptado de Longley et al. (2005)*

Os SIG distinguem-se de outros sistemas de informação pelo tipo de dados envolvidos. Estes dados representam maioritariamente localizações na superfície terrestre em termos de coordenadas geográficas/cartográficas. Pelo facto de os SIG estarem enquadrados num grande domínio aplicacional, pode-se aferir que os mesmos constituem instrumentos modernos indispensáveis de gestão e de suporte à tomada de decisão.

“Quase tudo o que acontece, acontece em algum lugar. Saber onde algo acontece pode ser muito importante” (Longley et al., 2015). Quase todas as atividades humanas e decisões envolvem uma componente geográfica. Diversas áreas consideram a variável espaço um elemento explicativo e beneficiam de um conjunto de técnicas de geoprocessamento, através do tratamento e manipulação de dados, que vão desde a deteção remota, aos sistemas de posicionamento global (GPS), inclusive a técnica de geoprocessamento - os SIG (Nossa, 2005). Os SIG revelam-se um importante instrumento de trabalho em todos os domínios do conhecimento onde a localização e o espaço são componentes determinantes (Alves, 2005).

A incorporação dos SIG traz diversas vantagens nomeadamente:

- Sistematiza e facilita o trabalho com largos volumes de dados;

- Integra e normaliza dados diminuindo o custo de gestão e armazenamento;
- Facilita a exploração e análise de informação geográfica;
- Permite uma fácil atualização dos dados geográficos;
- Tem um reduzido tempo de resposta.

3.4. Aplicação dos SIG na saúde pública

Abordagens geográficas nos estudos sobre a saúde pública são comuns na literatura e a utilização de SIG e técnicas de análise espacial mostram grande aplicabilidade ao estudo da distribuição de doenças.

Os estudos de análise espacial com recurso a mapeamento de doenças iniciaram-se durante o século XVIII nos Estados Unidos da América, com a representação cartográfica da residência de pessoas afetadas com o vírus da febre amarela (Rican & Salem, 2009). Também no início do século XVIII surgiam os *dot maps* (mapas de pontos que mostravam o padrão da epidemia), sendo os mais célebres os de Seaman (mapas de febre-amarela num setor de Nova Iorque, em 1798) e de Pascalis (idem, para outro sector de Nova York, no mesmo ano) (Nogueira e Remoaldo, 2010). No entanto, a grande utilidade da análise espacial aplicada à epidemiologia revelou-se com um surto de cólera em Londres no século XIX.

Em 1854 o médico John Snow⁵ demonstrou a importância da geografia nas atividades de monitorização e análise. Na época, a cidade de Londres estava assolada por um surto de cólera (bactéria *vibrio cholerae*), Snow procedeu ao mapeamento das mortes por cólera em cerca de seis quarteirões (Snow, 1855), onde sobressaíram *clusters*⁶ espaciais com efeitos de enfraquecimento face à distância das fontes de água (Moore e Carpenter, 1999). Tal mapa (Figura 5) conduziu à hipótese que uma bomba de água que abastecia cerca de seis quarteirões da cidade de Londres era o epicentro do surto de cólera. Após a remoção da bomba, observou-se uma redução significativa na incidência de cólera e na sua mortalidade (Cerdeira e Valdivia, 2007), o que auxiliou a comunidade médica a concluir que a cólera era

⁵ Médico inglês, considerado o pai da epidemiologia moderna.

⁶ *Cluster* espacial pode ser definido como um excesso de eventos ou valores no espaço geográfico. Deve ser visto como um padrão espacial que é diferente da variação geográfica que se espera que ocorra na ausência dos processos espaciais que estão a ser analisados (Jacquez, 2008).

uma doença relacionada com a água, ao invés de surgir por miasma como se acreditava na época (Lumpkin, 2003). Mesmo sem conhecer a causa bacteriana ou o meio de transmissão da cólera em meados do século XIX, Snow conseguiu conter a propagação do surto, uma vez que compreendeu os seus aspetos espaciais (Moore e Carpenter, 1999). Esta ocorrência remete-nos à primeira lei da geografia de Waldo Tobler (1970), em que “tudo está relacionado com tudo, mas os fenómenos mais próximos estão mais relacionados do que os fenómenos distantes”. O primeiro SIG aplicado à saúde foi consensualmente atribuído a Snow (Snow, 1849).



Figura 5 - Casos de cólera durante a epidemia em Londres em 1854

Esta situação evidência a relação entre a geografia e a medicina, dado que a análise espacial dos dados contribui para a compreensão do fenómeno, revelando-se um dos primeiros exemplos da importância da análise espacial, que demonstra como os SIG podem contribuir para outras investigações e análises no contexto da saúde pública.

A informação existente nos sistemas de informação de saúde possui habitualmente dados geográficos, como a morada e o código postal, o que permite explorar e sobrepor informação no território e dar assim maior conhecimento da realidade e das relações que se estabelecem que de outra forma não são tão facilmente perceptíveis (Miranda and Dolinoy, 2005).

Os sistemas computacionais, nomeadamente a produção de mapas e gráficos, têm-se revelado uma ferramenta útil na medicina, sobretudo na epidemiologia e no planeamento da prestação dos cuidados de saúde. Entender a distribuição espacial e temporal da doença é parte integrante da investigação em saúde pública (Rushton 2003; Ricketts, 2003).

A implementação da componente geográfica e de SIG nos estudos sobre a saúde oferece uma mais-valia, permitindo a análise e uso de dados espaciais (Hanchette, 2003). Estas contribuições fazem-se sentir em múltiplas áreas de análise no campo da saúde, tais como na compreensão da influência que os fatores ambientais possuem na etiologia de certas doenças; na tentativa de melhorar a eficácia da prestação de cuidados de saúde às populações, intervindo na preparação de modelos de localização para infraestruturas e permitindo direcionar os meios de intervenção para locais de acidente; bem como no desenvolvimento de sistemas de vigilância epidemiológica (SVE) (Cunha *et al.*, 2011).

O crescimento do número de publicações científicas a relacionar a Geografia, a Análise Espacial e os SIG com a Saúde (Figura 6) reforça a importância da dimensão espacial, com as possibilidades de análise espacial amplamente beneficiadas pela utilização de SIG (Cromley, 2003; Lyseen et al., 2014). Nesta sequência, assiste-se na área da saúde ao crescimento do interesse da análise da distribuição espacial, como por exemplo a distribuição de determinadas patologias, na tentativa de identificar determinantes para justificar os padrões espaciais (Rican & Salem, 2009).




Figura 6 - Artigos publicados em cada ano sob os termos de pesquisa

Fonte: B-on

Segundo Elzubair (2009), a utilização de SIG no domínio da saúde pública apresenta inúmeros benefícios tais como:

- Capacidade de combinar dados provenientes de diversas fontes e geri-los de forma a permitir planejar intervenções no domínio da prevenção da doença e promoção da saúde;
- Variedade de ferramentas de tratamento e análise de dados, como por exemplo, sistemas de posicionamento global, úteis para identificar e explicar os focos de algumas patologias;
- Permitem a partilha de dados e importar informação proveniente de outros *softwares*;
- Eficiente apoio na tomada de decisão;
- Assegurar a manutenção de registos, assim como a gestão da informação geográfica.

Estas ferramentas têm sido bastante utilizadas no âmbito da investigação em saúde (Martin et al., 2002) (Kistemann et al., 2002), permitindo auxiliar os profissionais na tomada de decisões. Segundo a Organização Mundial de Saúde (2010) “o SIG é muito adequado para análise de dados, revelando tendências e inter-relações que seriam difíceis de encontrar em formato de tabelas”.

Atualmente existem diversas organizações internacionais que procuram relacionar as patologias com aspetos físicos e socioeconómicos. Em Portugal o caso mais evidente é a plataforma SIG do Alto Comissariado da Saúde⁷, que ilustra a relevância e o contributo dos SIG, sendo os fatores de índole geográfica determinantes tanto para compreender as consequências, como para antecipar e prevenir impactes negativos, isto é, na delineação de estratégias mais eficientes (Goodchild, 2003).

A possibilidade de sintetizar grandes volumes de informação numa imagem relativa a uma determinada área geográfica é de particular relevância para os profissionais do IPST. Tal visualização permite a perceção da distribuição geográfica dos dados de sangue, bem como a identificação e análise de padrões espaciais.

3.5. Business Intelligence

Em 1989, Howard Dresner introduziu o termo *Business Intelligence* (BI) como sendo “um conjunto de *softwares* e soluções para agrupar, consolidar, analisar e fornecer acesso aos dados de forma a permitir aos utilizadores melhorar a tomada de decisão” (Chan et al., 2009).

Atualmente não existe uma definição universal, pode apresentar diversas interpretações, conforme as áreas de intervenção e de estudo (Watson, 2009). De forma abrangente, BI tem o propósito de transformar os dados em conhecimento (Niu et al., 2009). Segundo Watson (2009), BI refere-se a um conjunto de aplicações, tecnologias e processos com o intuito de recolher, armazenar, aceder e analisar dados de forma a ajudar no suporte à tomada de decisão.

O crescimento do número de produtos e serviços de BI, bem como a adoção destes por parte das organizações, (Chaudhuri, Dayal, & Narasayya, 2011) reforça a sua importância enquanto ferramenta de apoio à tomada de decisão. BI tem vindo a ser identificada como essencial para a melhoria da qualidade da informação disponível para a tomada de decisão estratégica nas organizações (Turban, Sharda, & Delen, 2010).

⁷ Disponível na internet em: <http://www.websig.acs.min-saude.pt/>

A implementação de um sistema BI contribui de forma eficiente no desenvolvimento de uma organização, criando o conhecimento necessário para projetos futuros, de modo a minimizar falhas e maximizar o seu desempenho.

3.6. Power BI

O *Power BI* é uma aplicação BI da *Microsoft* que permite transformar os dados em informação útil através das ferramentas de visualização, trata-se de uma ferramenta de integração, análise e visualização de dados. Permite acesso rápido e fácil às bases de dados com várias origens (Figura 7), garante que a informação esteja sempre atualizada e que qualquer pessoa numa organização possa utilizar e produzir informação geográfica sem a necessidade de especialistas em SIG ou do uso de ferramentas complexas, sendo considerado um *software* “amigo do utilizador”.

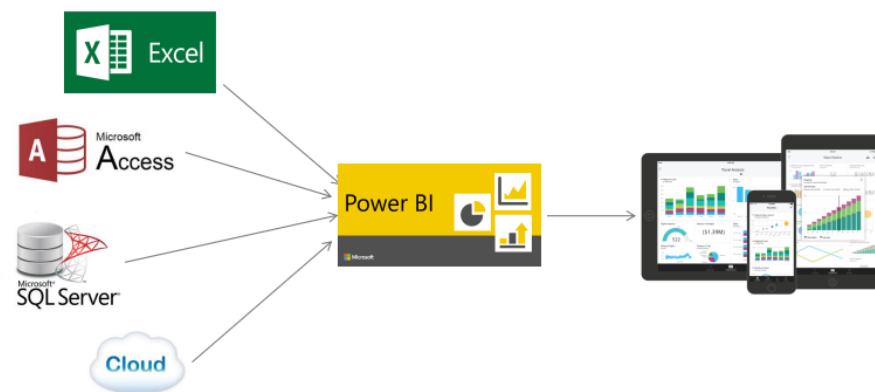


Figura 7 – Funcionamento do Power BI

Adaptado de Power BI

Os componentes principais do *Power BI* são expostos na Figura 8. O *Power BI Desktop* é utilizado para integrar dados, criar modelos analíticos e gerar relatórios. O *Power BI Service* tem como objetivo publicar, criar *dashboards* e partilhá-los. O *Power BI Mobile* é utilizado para exibir e interagir através de dispositivos móveis. Neste projeto foram utilizados o *Power BI Desktop* e o *Power BI Service*. As ferramentas de análise desta aplicação são bastante intuitivas o que facilitou a sua utilização. Para além disso, permite a

introdução de novos registos na base de dados por parte do IPST, garantindo que a informação esteja sempre atualizada, permitindo auxiliar o processo de tomada de decisão.

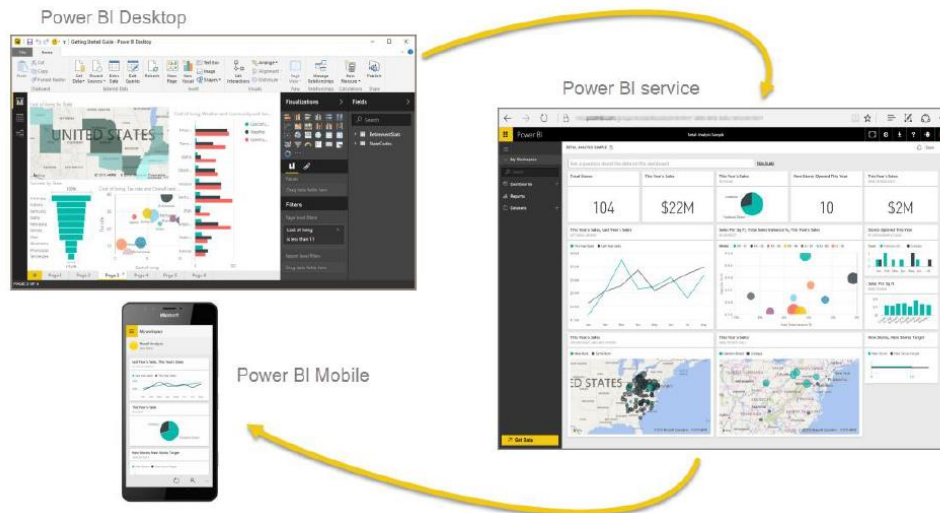


Figura 8 – Componentes do Power BI

Fonte: Microsoft

A criação de um *dashboard* de apoio à decisão em *Power BI* permite visualizar, realizar análises e partilhar informação, sendo possível visualizar dados em gráfico ou lista e filtrar a informação consoante as necessidades. É também exequível visualizar padrões de dados num mapa temático bem como criar um mapa de comparação entre dois atributos.

Capítulo 4. Metodologia

4.1. Aquisição e tratamento da informação

No presente estudo a informação inicial foi disponibilizada pelo IPST e refere-se aos códigos de brigadas móveis e de postos fixos de recolha de sangue, com informação sobre o respetivo número de dádivas e grupo sanguíneo. Esta informação encontra-se disponibilizada ao nível do município, com uma escala temporal correspondente aos anos de 2019, 2020 e 2021. Posteriormente, de modo a enriquecer o estudo, procedeu-se à recolha de variáveis de cariz populacional, disponibilizadas pelo website do Instituto Nacional de Estatística (INE), nomeadamente:

- População residente (N.º)
- Poder de compra per capita
- População empregada por conta de outrem (N.º)
- População empregada por setores de atividade económica (N.º)
- Taxa de transição/ conclusão no ensino básico (%)
- Taxa de transição/ conclusão no ensino secundário (%)

A escolha das variáveis resulta da revisão bibliográfica efetuada e da disponibilidade de informação espacial para os municípios de Portugal Continental. Foi considerada a disparidade máxima de 3 anos entre a atualidade e a data da informação de base geográfica possível de obter para o nível municipal e utilizou-se o ano mais atual disponibilizado pelo website do INE.

Na Tabela 1 são descritos os dados utilizados e as respetivas fontes. Todos os dados utilizados foram previamente projetados e desenhados para o sistema de coordenadas ETRS89 / Portugal TM06.

Tabela 1 - Informação utilizada

Informação	Tipo de Informação	Fonte
Municípios de Portugal (CAOP 2020)	Polígonos	DGT
Informação demográfica	Polígonos	INE
Brigadas móveis	Pontos	IPST
Postos fixos	Pontos	IPST

4.2. Construção de uma base de dados

Uma base de dados é uma coleção de dados partilhados, interrelacionados e usados para múltiplos objetivos, são extremamente importantes pois são transacionais, o que significa que podem ser constantemente atualizadas consoante surjam novas informações (Longley et al., 2011). Apresenta como principais vantagens permitir armazenar os dados num único local, a maior independência dos dados, a partilha dos dados pelas aplicações e uma maior flexibilidade de acesso.

Após a recolha e tratamento da informação, os dados foram agregados num ficheiro *Excel*, que servirá de base de dados para o projeto, de modo a facilitar a exportação para a aplicação *Power BI*. Este *software* permite a visualização, análise e partilha de informação, auxiliando o processo de tomada de decisão.

4.3. Geocodificação

Por geocodificação (*geocoding*) entende-se o processo de conversão de um endereço num ponto referenciado pela latitude e longitude com localização geográfica (Croner et al., 1996). Através da geocodificação é possível criar uma tabela, em que constem inúmeras designações de locais, que posteriormente são transformados em pontos (x,y), com posição geográfica no espaço, onde constam determinados atributos que podem ser utilizados em análises espaciais. A precisão do processo de geocodificação, depende da

qualidade da base de dados utilizada para gerar a georreferenciação, e da integridade e exatidão dos endereços (Siffel et al., 2006).

Os primeiros sistemas de geocodificação utilizados nos censos dos Estados Unidos da América nos anos 1960 apenas transformavam endereços postais e edifícios importantes em áreas geográficas delimitadas por códigos numéricos (O'Reagan e Saalfeld, 1987). Atualmente a geocodificação permite ajudar organizações a identificar onde se localiza o seu público-alvo, permitindo determinar áreas de atuação para, por exemplo, atividades promocionais (Robinson e Kaplan, 2012).

A geocodificação é um procedimento automático, que para além de recursos como endereços, mapas e conhecimento da região em estudo, dispensa qualquer outro recurso, sendo um processo simples e rápido de executar. Contudo, para o processo de correção, é indispensável o trabalho manual (Siffel *et al.*, 2006). A geocodificação traduz-se numa componente importante de assimilação de dados que carecem de representação espacial em estudos ligados à saúde (Zimmerman *et al.*, 2008), tornando-se frequente a sua utilização na investigação e em práticas no âmbito da saúde pública. Este é um método que tem demonstrado um leque de vantagens acrescidas, onde devem ser aproveitadas as suas potencialidades pelos decisores dos diversos níveis de implementação de políticas de saúde (Riner *et al.*, 2004).

No que concerne aos tipos de geocodificação (manuais e automáticos), existem diversos sendo eles:

- I. Geocodificação por lote de dados (*batch geocoding*): consiste na geocodificação automática de uma lista de moradas, onde atribui a endereços as coordenadas geográficas correspondentes, introduzindo a informação num *software* específico. Este processo automático requer o cuidado adicional de verificação de erros;
- II. Pesquisa única (*single search*): pesquisa manual de apenas uma morada de cada vez. Este método é utilizado quando a lista de moradas é mais pequena e é possível verificar se o processo é bem efetuado;
- III. Geocodificação inversa (*reverse geocoding*): permite identificar, a partir de coordenadas, a respetiva morada ou localidade a que essas coordenadas se referem. Este nome resulta do facto de ser feito o processo inverso da

geocodificação habitual, sendo também possível ser executado por lote de dados.

Dado que a informação referente aos códigos de brigadas móveis e postos fixos não continha as respetivas moradas, ou os códigos postais, recorreu-se ao método de georreferenciação por pesquisa única, através do motor de pesquisa *Google Maps*. Adicionou-se à base de dados um campo com a latitude e um campo com a longitude e para uma análise mais pormenorizada foi ainda acrescentado um campo com informação sobre as respetivas freguesias. De modo a estabelecer relações entre diferentes tabelas, foram ainda acrescentados três campos com informação sobre os códigos de distrito, de município e de freguesia, cada código permite identificar unicamente cada distrito, cada município e cada freguesia, sendo que os dois primeiros dígitos do código identificam o distrito, os dois dígitos seguintes o município e os dois últimos dígitos a freguesia. A informação sobre os respetivos códigos foi obtida através dos Correios de Portugal (CTT) e denominada DTCC. Dos 295 códigos de brigadas de recolha de sangue, foi possível georreferenciar 295 o que se traduz numa taxa de sucesso de 100%. Posteriormente importou-se a informação para *Power BI* e *ArcMap*.

4.4. Análise da informação

O IPST disponibilizou informação referente aos códigos de brigadas móveis e postos fixos de recolha de sangue realizadas entre os anos de 2019, 2020 e 2021. Em 69 municípios de Portugal Continental não foram realizadas brigadas pelo IPST⁸ (Figura 9).

⁸ Alandroal, Albufeira, Alcoutim, Aljezur, Aljustrel, Almodôvar, Alter do Chão, Alvito, Arcos de Valdevez, Arraiolos, Arronches, Avis, Barrancos, Beja, Borba, Boticas, Campo Maior, Castelo de Vide, Castro Marim, Castro Verde, Crato, Cuba, Elvas, Estremoz, Évora, Ferreira do Alentejo, Freixo de Espada À Cinta, Fronteira, Gavião, Idanha-A-Nova, Lagos, Mação, Macedo de Cavaleiros, Marvão, Melgaço, Mértola, Monchique, Monforte, Montemor-O-Novo, Mora, Moura, Mourão, Nisa, Odemira, Ourique, Penedono, Ponte da Barca, Ponte de Sor, Portel, Redondo, Ribeira de Pena, Sabrosa, Santa Marta de Penaguião, Santiago do Cacém, São Brás de Alportel, Sardoal, Serpa, Silves, Sines, Sousel, Tavira, Valença, Viana do Alentejo, Vidigueira, Vila do Bispo, Vila Nova de Paiva, Vila Real de Santo António, Vila Viçosa e Vinhais

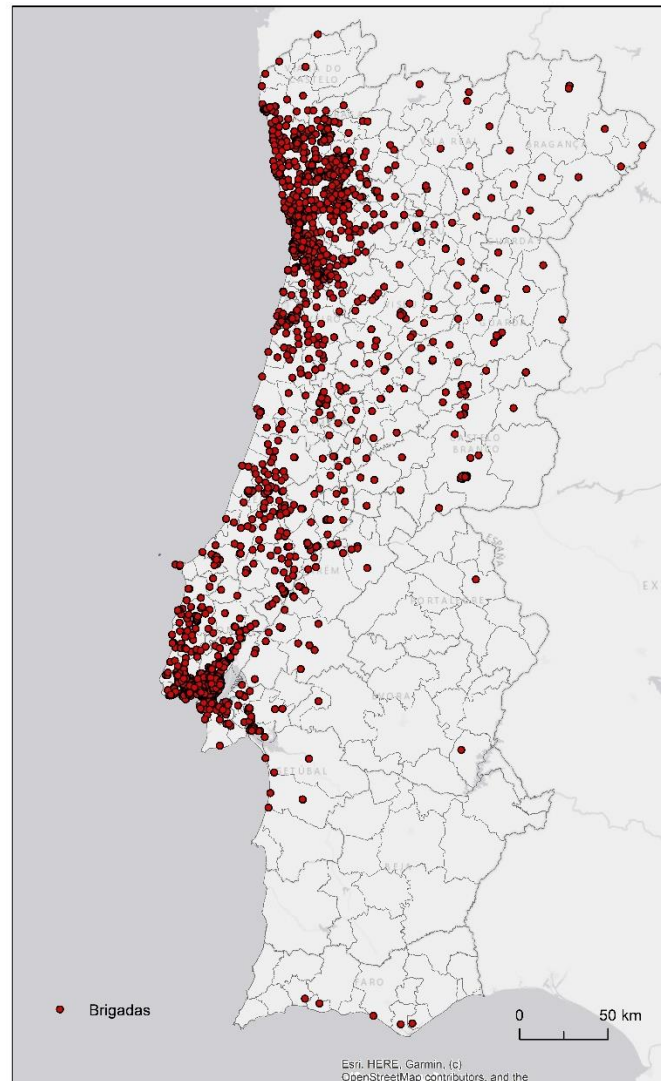


Figura 9 – Distribuição geográfica das brigadas, 2019 - 2021

De modo a analisar a influência que determinadas variáveis podem ter no número de dádivas de sangue, procedeu-se à recolha de variáveis de cariz populacional. Tendo em conta que para dar sangue os indivíduos têm de ter idades compreendidas entre os 18 e os 65 anos, sendo que para os que o fazem pela primeira vez só podem até aos 60 anos, foi importante analisar a distribuição espacial da população residente por grupos etários. Como podemos observar na Figura 10, as maiores concentrações de população com idade para dar sangue (20 – 64 anos), encontram-se maioritariamente na Área Metropolitana de Lisboa (AML) e na Área Metropolitana do Porto (AMP), com destaque para os municípios de Lisboa (255 088), Sintra (237 582) e Vila Nova de Gaia (183 572).

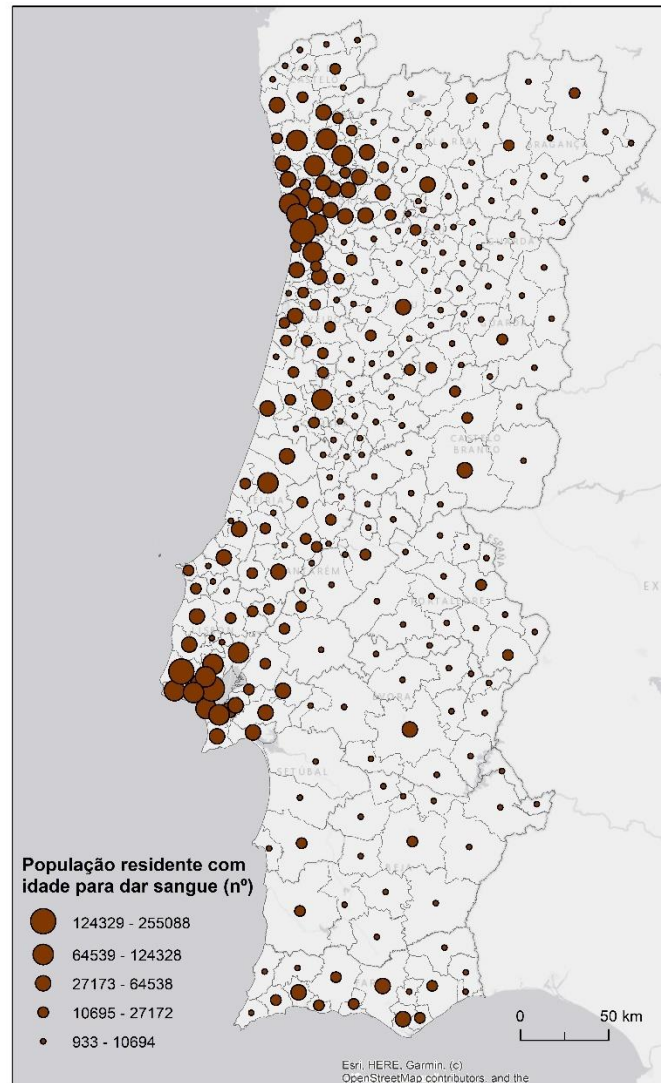


Figura 10 - População residente com idade para dar sangue (20-64 anos) por município, 2020

As Figuras 11, 12 e 13 representam a análise de outras características da população residente, sendo estas o poder de compra e a taxa de transição/ conclusão do ensino básico e secundário. Segundo o INE, o Indicador *per Capita* do poder de compra pretende traduzir o poder de compra manifestado, em termos *per capita*, nos diferentes municípios ou regiões, tendo por referência o valor nacional (Portugal = 100). Como podemos observar na Figura 11, o poder de compra *per capita* é tendencialmente mais elevado no Litoral e mais reduzido no Interior. O poder de compra *per capita* é superior à média nacional em cerca de 10% dos municípios (32 num total de 308). Metade destes 32 municípios encontram-se na AML (10 em 18) e na AMP (6 em 17). “No conjunto, as duas áreas metropolitanas concentram mais de metade (52%) do poder de compra” (INE, 2021). O município de Lisboa

apresenta o mais elevado índice de poder de compra (205,62), sendo o único município a mais do que duplicar o índice nacional, o município do Porto (154,02) encontra-se em segundo lugar, de mencionar que quase metade dos municípios (45%) apresentam valores abaixo de 75.

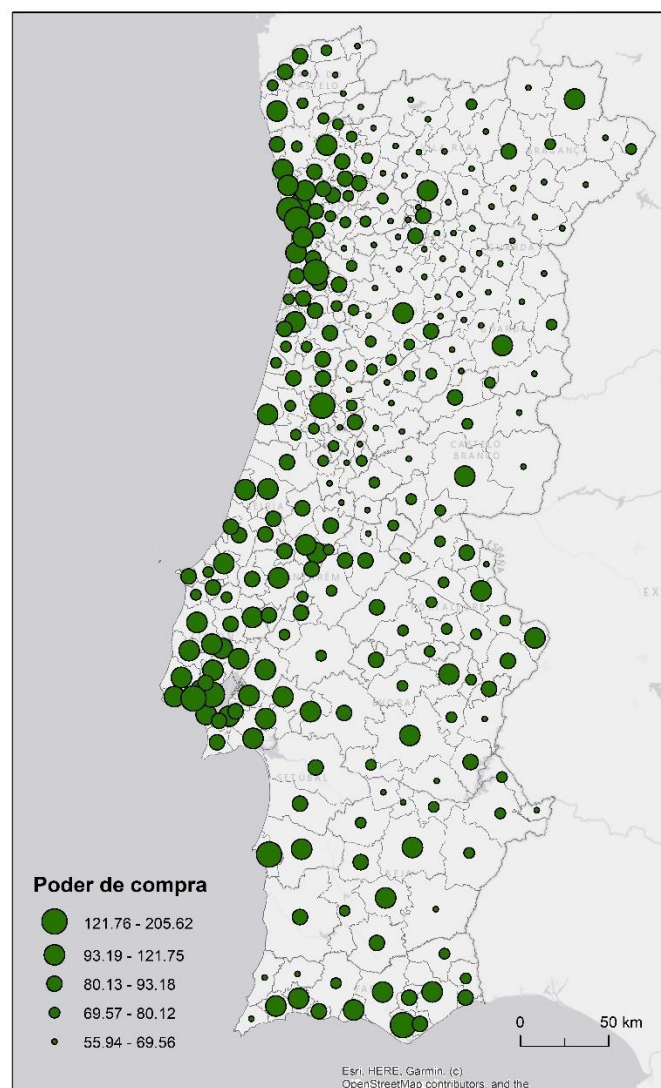


Figura 11 – Indicador do poder de compra per capita por município, 2019

Relativamente à taxa de conclusão do ensino básico (Figura 12), podemos observar valores elevados em praticamente todos os municípios, com destaque para os municípios de Alvaiázere, Barrancos, Castelo de Vide, Mesão Frio, Pinhel, Sabrosa, Santa Comba Dão, Santa Marta de Penaguião, Terras de Bouro, Vila de Rei, Vila Nova da Barquinha e Vimioso

com taxas de conclusão de 100%. A taxa de conclusão do ensino secundário (Figura 13) apresenta valores de 100% nos municípios de Aljezur, Arronches e Portel.

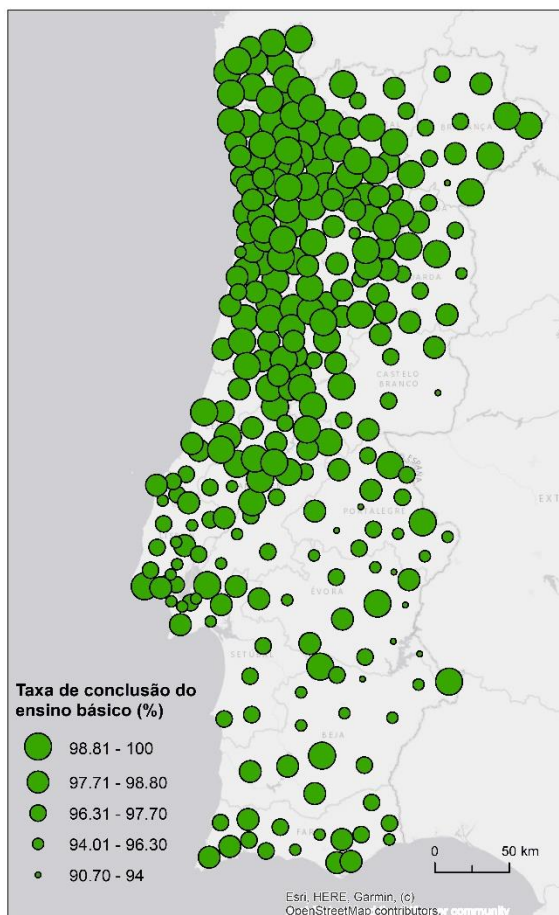


Figura 12 – Taxa de conclusão do ensino básico por município, 2020

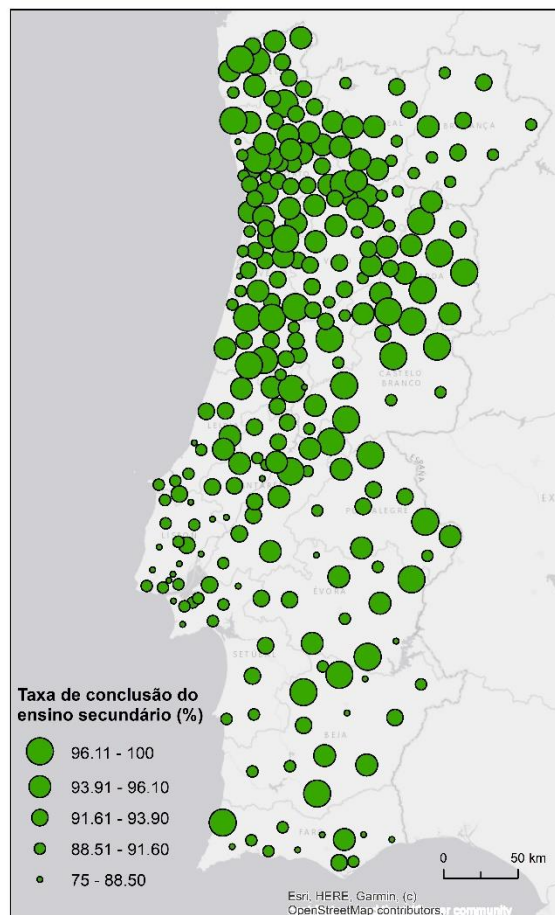


Figura 13 – Taxa de conclusão do ensino secundário por município, 2020

Um dos pressupostos estratégicos do IPST é a mudança de paradigma da colheita, que passa por “privilegiar a colheita em postos fixos e com horários flexíveis durante a semana e desse modo, diminuir progressivamente a colheita ao fim de semana” aproveitando o período pós-laboral, sendo assim importante considerar a população que trabalha num município. Como podemos observar na Figura 14, tal como seria de esperar, as maiores concentrações de população empregada encontram-se na faixa litoral, destacando-se o município de Lisboa com valores mais elevados de população empregada (318 799), seguindo-se o município do Porto (97 470) e de Oeiras (73 860).

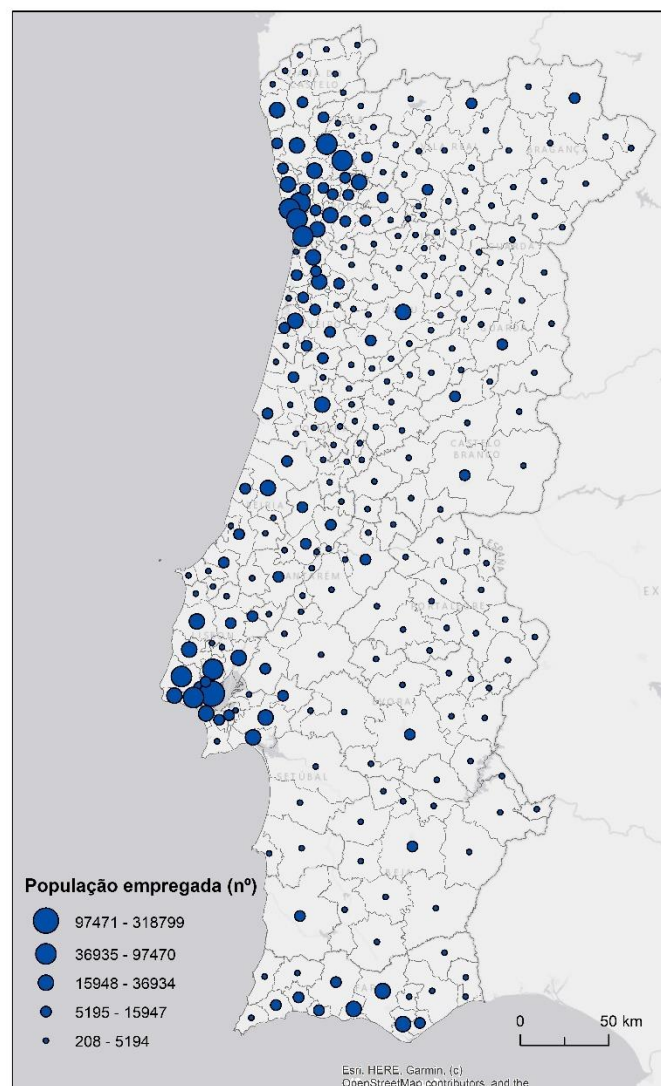


Figura 14 – População empregada por município, 2019

As Figuras 15, 16 e 17 representam a análise da população empregada segundo os setores de atividade económica. Podemos observar que o maior número de população empregada no setor primário encontra-se nos municípios de Odemira (4257), Torres Vedras (1197) e Beja (1075), no setor secundário nos municípios de Guimarães (27 248), Vila Nova de Famalicão (23 195) e Barcelos (20 780) e no setor terciário nos municípios de Lisboa (299 603), Porto (88 969) e Oeiras (65 070).

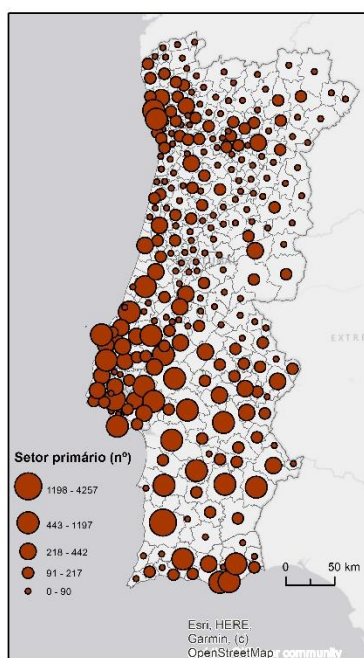


Figura 15 – População empregada no setor primário por município, 2019

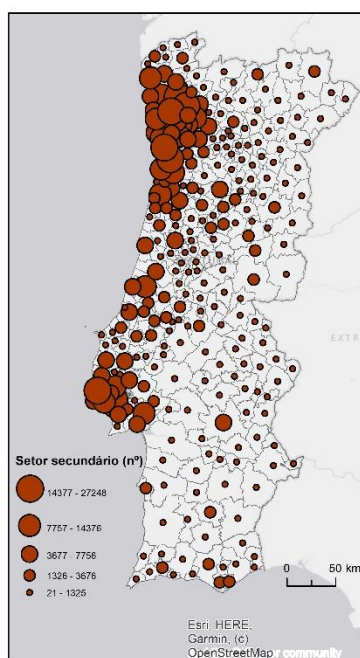


Figura 16 – População empregada no setor secundário por município, 2019

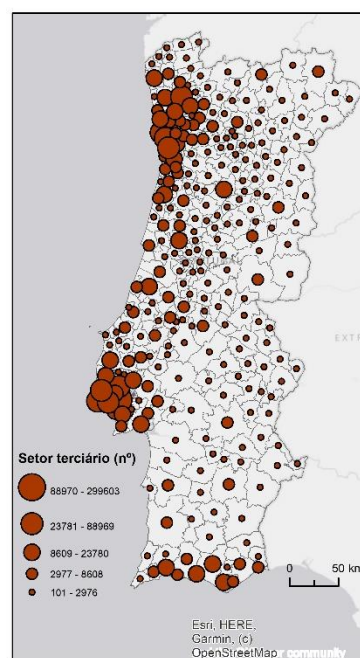


Figura 17 – População empregada no setor terciário por município, 2019

4.5. Métodos de análise e classificação de dados

A análise espacial pode ser considerada como um tipo de processo de análise em SIG e diz respeito a métodos que permitem quantificar propriedades da distribuição de dados geográficos e associações espaciais com fatores como a proximidade, contiguidade e sobreposição (Jacquez, 2000), permitindo avaliar a dependência espacial, a autocorrelação espacial e relações entre atributos e propriedades de dados relativos a localizações. Possui ainda a capacidade de revelar *clusters* espaciais, existindo vários métodos de identificação e medição desses *clusters* espaciais. Os métodos apresentam diferenças entre si, pois são desenhados para responder a diferentes aspetos dos *clusters*, baseando-se em diferentes paradigmas para examinar a realidade (Lu, 2000).

Em análise espacial devemos considerar o conceito de dependência espacial. A maioria dos fenómenos que ocorrem no espaço, estabelecem relações que dependem da distância e, segundo uma das propriedades da geografia, unidades espaciais próximas estão mais relacionadas entre si que unidades espaciais distantes. A análise espacial permite acrescentar valor à informação geográfica, evidenciando propriedades, padrões e anomalias

e permitindo estabelecer relações entre múltiplos atributos espaciais (Chang, 2019). Uma das áreas onde a análise espacial é mais valiosa é no estudo da distribuição de doenças, tendo-se expandido a aplicação dos SIG e técnicas de análise e estatística espacial a questões de saúde (Lyseen *et al.*, 2014).

De acordo com Chainey e Ratcliffe (2005), a autocorrelação espacial relaciona o grau de dependência entre a localização espacial e os valores do local. O conceito de autocorrelação espacial, pode ser definido como a expressão computacional da dependência espacial. A relação entre duas entidades geográficas, implica a existência de uma correlação positiva ou negativa que pode ser causal ou depender de variáveis externas. A medição da autocorrelação espacial pode ser feita utilizando diferentes indicadores todos eles com o objetivo de quantificar a relação espacial existente entre uma entidade e os seus vizinhos (o índice mais comum é o Índice de *Moran*).

Numa primeira análise recorreu-se ao Índice Global e Local de *Moran* com o intuito de confirmar a autocorrelação espacial do número de dádivas de sangue e, determinar quais as aglomerações estatisticamente significativas. De modo a perspetivar a significância dos valores de *clustering* estatisticamente significativos face ao número de dádivas de sangue, recorreu-se ao método de análise de *Hot Spot*. De modo a observar de forma coesa a densidade de brigadas móveis que há ao longo da extensão territorial, procedeu-se à aplicação do método da densidade de *Kernel*. Para o estudo de padrões espaciais e exploração de relações existentes entre alguns aspetos populacionais e o número de dádivas, aplicou-se o método de análise de RLM. A Tabela 2 sintetiza os respetivos métodos de análise espacial.

Tabela 2 - Esquema da aplicação dos métodos de análise espacial

Método Estatístico	Propósito
Índice Global de Moran's	Perspetivar se existe significância estatística nas observações, assim como a existência de autocorrelação espacial face ao número de dados.
Índice Local de Moran's	Identificar os municípios e as freguesias de concentração de dados, através da análise baseada na relação espacial entre as observações.
Análise de Hot Spot (Getis-Ord G_i^*)	Detetar a significância dos valores de <i>clustering</i> estatisticamente significativos nos municípios e nas freguesias face ao número de dados.
Densidade de Kernel	Calcular a densidade de brigadas móveis com o intuito de analisar padrões espaciais no território.
Regressão Linear Múltipla	Identificar os aspetos populacionais que influenciam a localização geográfica dos dados, de modo a apurar áreas com potencial para a localização de brigadas.

4.5.1. Índice de Moran

O Índice de *Moran* mede a autocorrelação espacial a partir do produto dos desvios em relação à média. Este índice é uma medida global da autocorrelação espacial, pois indica o grau de associação espacial presente no conjunto de dados (Rocha, 2012). O Índice Global de *Moran* é dado por:

$$I = \frac{n}{S_0} \frac{\sum_{i=1}^n \sum_{j=1}^n W_{i,j} Z_i Z_j}{\sum_{i=1}^n Z_i^2} \quad (1)$$

Onde Z_i é o desvio de um atributo do elemento i relativamente à sua média ($X_i - \bar{X}$), $w_{i,j}$ é a ponderação espacial entre o elemento i e j , n corresponde ao número total de elementos e S_0 é a agregação de todos os pesos espaciais, de tal forma que

$$S_0 = \sum_{i=1}^n \sum_{j=1}^n w_{i,j} \quad (2)$$

De uma forma geral, o Índice de *Moran* corresponde a um teste, cuja hipótese nula é a aleatoriedade espacial, sendo que neste caso o seu valor seria zero. Valores positivos (entre 0 e +1) indicam uma autocorrelação espacial positiva e valores negativos, (entre 0 e -1) uma autocorrelação espacial negativa. “A hipótese implícita do cálculo do Índice de *Moran* é a estacionariedade de primeira e segunda ordem, e o índice perde sua validade ao ser calculado para dados não estacionários” (Rocha, 2012). Assim, valores elevados positivos indicam a existência de localizações com vizinhos que apresentam similaridade de valores, ou seja, *clusters* espaciais. Já valores negativos elevados identificam *outliers*, isto é, unidades territoriais que não se assemelham à sua vizinhança. Apesar de este índice não ter representação espacial, os exemplos de padrões associados aos limiares apresentados anteriormente podem ser interpretados a partir da Figura 18.




Figura 18 - Autocorrelação Espacial Positiva (a), Autocorrelação Espacial Negativa (b) e Aleatoriedade Espacial (c)

Fonte: Anselin & Piras (2009)

A análise de autocorrelação espacial local é realizada através de Indicadores Locais de Associação Espacial (LISA) (*Local Indicators of Spatial Association*). Os métodos LISA têm como finalidade quantificar o grau de associação espacial a que cada localização do conjunto amostral está submetida, em função de um modelo de vizinhança pré-estabelecido (Rocha, 2012). Anselin (1995) demonstra que os métodos LISA permitem identificar *clusters* significativos de valores semelhantes em torno de determinadas localizações. Um dos métodos LISA mais difundido é o Índice Local de Moran (I_i), expresso pela seguinte equação:

$$I_i = \frac{A_i - \bar{X}}{S^2} \sum_{j=j \neq i}^i W_{i,j} (X_j - \bar{X}) \quad (3)$$

Onde A_i é o atributo do elemento i , $W_{i,j}$ representa o peso espacial (grau de conexão) entre as duas *features*, \bar{X} é a média do atributo correspondente e S^2 é calculado por:

$$S^2 = \frac{\sum_{j=j \neq i}^i W_{i,j} (X_j - \bar{X})}{n - 1} \quad (4)$$

Onde n equivale ao número total de observações.

Foi calculado o Índice Global de Moran e o Índice Local de Moran para os municípios e as freguesias, utilizando o número de dádivas recolhidas, como parâmetros definiu-se a distância euclidiana e o método *Inverse Distance Squared*.

4.5.2. Análise de Hot Spot (Getis-Ord G_i^*)

A análise de *Hot Spot* funciona num contexto de vizinhança e tem por base o cálculo estatístico *Getis-Ord G_i^** , que identifica quais os *clusters* espaciais com valores altos (*hot spot*) ou com valores baixos (*cold spot*) dos quais resultam os valores de *z-score* e de *p*-

value. Permite identificar padrões espaciais estatisticamente significativos num contexto de vizinhança, cartografando se valores altos estão rodeados de valores altos ou se valores baixos estão rodeados de valores baixos e qual a sua significância estatística. A significância estatística permite rejeitar a hipótese dos dados se aproximarem de um padrão aleatório. Um ponto com um valor alto não significa que seja um *hot spot* estatisticamente significativo. Para ser um *hot spot* estatisticamente significativo, um ponto tem de ter um valor alto e ser “rodeado” por outros pontos com valores também altos. A soma local para um ponto e os seus vizinhos é comparada proporcionalmente à soma de todos os pontos. Quando a soma local é muito diferente da soma local esperada, e essa diferença é demasiado grande, resulta num valor z estatisticamente significativo (Mitchell, 2005).

O Índice de *Getis-Ord Gi** é dado pela seguinte equação:

$$Gi^*(f) = \frac{\sum_j W_{ij}(f)X_j}{\sum_j X_j} \quad (5)$$

Onde (*d*) representa a estatística de *Gi** e inclui o valor na localização dentro da medida de agrupamento e W_{ij} é a matriz normalizada que determina a vizinhança entre as áreas.

Foi realizada a análise de *Hot Spot* nos municípios e nas freguesias de Portugal Continental, utilizando o número de dádivas de sangue, como parâmetros definiu-se a distância euclidiana e optou-se pelo método *fixed distance band*.

Uma das vantagens da estatística *Getis-Ord Gi** é a de neutralizar a distribuição espacial dos pontos, o que permite aos investigadores testar hipóteses sem que o padrão de pontos venha a distorcer os resultados (Getis e Ord, 1992).

4.5.3. Densidade de Kernel

De modo a observar de forma coesa a densidade de brigadas móveis que há ao longo da extensão territorial, procedeu-se à aplicação do método da densidade de *Kernel*. Consiste numa técnica de interpolação e de análise de padrões espaciais de pontos que

permite identificar a intensidade com que uma variável se manifesta no espaço (Pfeiffer, 1996). Os valores da superfície gerada são mais elevados junto aos pontos existentes e vão diminuindo à medida que se afastam dos mesmos.

Consideremos uma determinada área, onde ocorrem diversos eventos (S_1, S_2, K, S_n). A intensidade (I) de uma variável numa localização (S_i), pode ser definida como (Gatrell et al., 1996):

$$I(s) = \sum_{i=1}^n \frac{1}{r^2} k\left(\frac{s - s_i}{r}\right) \quad (6)$$

onde, K representa uma função de ponderação e r corresponde ao raio da área de influência de uma localização S .

A densidade de *Kernel* torna-se uma mais-valia quando a amostra de pontos é de grande dimensão, sendo um método estatístico simples e de fácil compreensão. A sua aplicação difunde-se pela área da saúde, sendo bastante útil na análise de padrões de informação pontual relacionados com a epidemiologia (Gatrell et al., 1996). As principais limitações da sua utilização estão relacionadas com a definição do raio da área de influência, uma vez que não existe uma teoria universal sobre a utilização deste parâmetro (Rocha, 2012). O raio da área de influência deve ser maior quando se trata de uma distribuição mais espaçada e menor quando se trata de uma distribuição mais concentrada espacialmente. Neste estudo, de modo a definir o raio da área de influência, utilizou-se a ferramenta *Incremental Spatial Autocorrelation* (Figura 19) na qual o pico mais elevado se traduz no raio a definir, neste caso, o pico mais elevado é de 45000 metros.

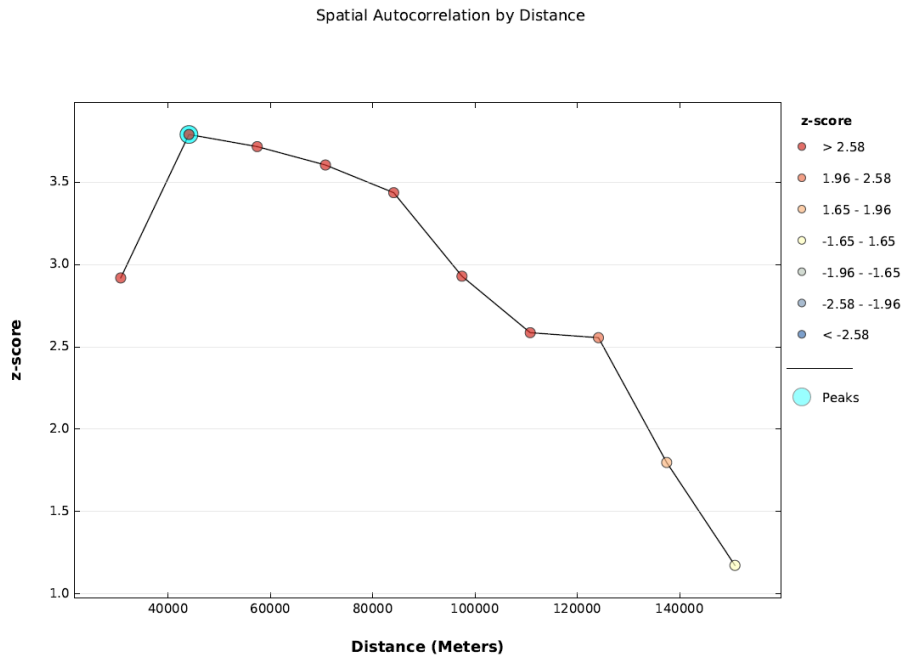


Figura 19 – Valor do pico utilizado para definir o raio da área de influência

4.5.4. Regressão Linear Múltipla

Um modelo de regressão descreve a tendência da relação estatística entre uma variável de resposta Y a variar com uma ou mais variáveis preditoras X (Kutner *et al.*, 1996). No caso de uma regressão linear com uma única variável independente a expressão é dada por:

$$Y = b_0 + b_1 X_1 \quad (7)$$

Onde b_1 é o valor estimado do coeficiente de regressão que quantifica a associação entre a variável explanatória (X_1) e a dependente (Y). Se este valor for positivo, existe um efeito dessa variável para o aumento da dependente no número de unidades expressas pelo coeficiente de regressão. No caso de o coeficiente ser negativo, a associação existente entre as variáveis é inversa, ou seja, o aumento da variável independente provoca a redução do valor da dependente.

Perante a situação de uma regressão com múltiplos preditores, a equação é dada por:

$$Y = b_0 + b_1X_1 + b_2X_2 + \dots \quad (8)$$

Em que Y é a variável dependente, X_1 a X_n são as várias variáveis independentes ou explanatórias, b_0 é o valor de Y quando todas as variáveis independentes são zero e b_1 a b_n são os coeficientes de regressão estimados (Beta).

Com o objetivo de explorar as relações espaciais existentes entre alguns aspetos populacionais e o número de dívidas aplicou-se uma análise de RLM. Um dos primeiros aspetos a considerar na esquematização de um modelo de regressão linear é a seleção dos fatores explicativos (variáveis) a utilizar, dado que uma variável independente adicional pode melhorar a previsão da variável dependente (Encalada, 2016).

Foram selecionadas 9 variáveis, que podem apresentar influência sobre o número total de dívidas (variável dependente), para serem utilizadas como variáveis independentes, nomeadamente:

- V1) População residente com idade para dar sangue (N.º)
- V2) Poder de compra per capita
- V3) População empregada por conta de outrem (N.º)
- V4) Taxa de transição/ conclusão no ensino básico (%)
- V5) Taxa de transição/ conclusão no ensino secundário (%)
- V6) População empregada no setor primário (N.º)
- V7) População empregada no setor secundário (N.º)
- V8) População empregada no setor terciário (N.º)
- V9) Brigadas (N.º)

Procedeu-se à normalização das mesmas, para que as diferenças nas unidades não influenciem os resultados. Face a possíveis situações de multicolinearidade procedeu-se à utilização de uma técnica designada por fator de inflação de variação (*Variance Inflation Factor [VIF]*), cujos valores elevados indicam a existência de multicolinearidade. O *VIF* é uma medida do grau em que cada variável independente é explicada pelas demais variáveis

independentes. Quanto maior for o fator de inflação da variância, mais severa será a multicolinearidade (Rocha, 2012). O *VIF* é dado pela seguinte equação:

$$VIF = \frac{1}{1 - R_j^2} \quad (9)$$

Onde R_j resulta da regressão de X_j com as outras variáveis.

Como regra geral, as variáveis explicativas com valores de *VIF* superiores a 7,5 devem ser removidas do modelo de regressão (Encalada, 2016). Das 9 variáveis pré-selecionadas, 3 foram excluídas por apresentarem valores de *VIF* superiores a esse limite (Tabela 3).

Tabela 3 - Valores de *VIF* para as variáveis independentes

Código	Variável independente	VIF
V1	População residente com idade para dar sangue (N.º)	5,209
V2	Poder de compra <i>per capita</i>	2,235
V3	População empregada por conta de outrem (N.º)	>1000
V4	Taxa de transição/ conclusão no ensino básico (%)	1,217
V5	Taxa de transição/ conclusão no ensino secundário (%)	1,112
V6	População empregada no setor primário (N.º)	1,620
V7	População empregada no setor secundário (N.º)	120,364
V8	População empregada no setor terciário (N.º)	>1000
V9	Brigadas (N.º)	7,305

Posto isto, as variáveis a considerar são: população residente com idade para dar sangue; poder de compra *per capita*; taxa de transição/ conclusão no ensino básico; taxa de

transição/ conclusão no ensino secundário; população empregada no setor primário e brigadas.

No seguimento do processo, dá-se o cálculo da Regressão Geográfica Ponderada (RGP) (*Geographically Weighted Regression*). Esta é aplicada às variáveis explicativas que se denotam como aquelas que auxiliam a predizer o comportamento da variável dependente que se pretende modelar. Assim, tem-se a equação:

$$Y = \alpha + \beta_1 X_1 + \beta_2 X_2 \dots + \beta_n X_n \quad (10)$$

Onde Y é a variável dependente, α o intercepto do eixo Y , X as variáveis explicativas e β os coeficientes de regressão.

O R^2 (coeficiente de determinação) funciona como uma medida da qualidade de ajuste. O modelo apresenta um R^2 ajustado da regressão de 0,89, o que significa que as variáveis independentes escolhidas explicam 89% da variável dependente. O R^2 varia entre 0 e 1 e quanto mais próximo de 1, maior a validade da regressão. Na prática, não é expectável encontrar uma correlação perfeita ($R^2=1$) pois existem muitos fatores que influenciam o comportamento de uma variável. A performance do modelo só pode ser validada quando o R^2 é suficientemente alto para explicar a variação do fenómeno em análise. Geralmente a referência para aceitação de um modelo de regressão linear implica que pelo menos 70% da variação da variável dependente seja explicada pela(s) independente(s), ou seja, um R^2 nunca inferior a 0,7.

Como vantagens principais do modelo de regressão múltipla, podemos identificar a capacidade de determinar a influência relativa de variáveis preditoras na variável dependente e a capacidade de identificar *outliers* ou anomalias.

A principal desvantagem é que muitos fenómenos do mundo real não correspondem às suposições de um modelo linear. Qualquer outra desvantagem advém das características dos dados utilizados, e.g., dados incompletos ou concluir erradamente que uma correlação é uma causa.

4.6. Dashboard de apoio à decisão

Segundo Few (2006), um *dashboard* consiste na “apresentação visual das informações mais importantes, necessárias para atingir um ou mais objetivos, com a informação consolidada e organizada num único ecrã para que esta possa ser monitorizada de imediato.”

Foi construído um *dashboard* de apoio à decisão (Figuras 20 e 21), que permite a visualização da localização das sessões de colheita de sangue, bem como consultar informação sobre o número de dádivas efetuadas, o respetivo grupo sanguíneo, entre outros (Tabela 4). Ao *dashboard* aplicou-se filtros de visualização que permitem ao utilizador filtrar consoante as suas necessidades, por exemplo, no filtro “Distrito” pode seleccionar ver apenas o distrito de Lisboa, pode ainda seleccionar mais que um distrito em simultâneo. Utilizando o filtro “Ano” e o filtro “Mês” é possível visualizar sessões de colheita que tenham ocorrido muito perto geograficamente, o que permite não só auxiliar o IPST no planeamento de sessões de colheita, como contribui para uma eficaz racionalização de recursos. Ao filtrar um determinado grupo sanguíneo é possível visualizar no mapa áreas onde a frequência relativa é maior, sendo uma ferramenta bastante útil que permite determinar, em caso de necessidade de determinado grupo sanguíneo, áreas de atuação para sessões de colheita.

Tabela 4 – Informação disponível no dashboard

Tema	Atributos
Distrito / Concelho / Freguesia	Nome do Distrito, Concelho e Freguesia Sigla correspondente ao centro de sangue (CST) Número de dádivas (total) Frequência relativa do grupo sanguíneo
Posto fixo / Brigada móvel	Código do posto fixo e da brigada móvel Designação do posto fixo e da brigada móvel Distrito, concelho e freguesia do posto fixo e da brigada móvel Morada do posto fixo do posto fixo e da brigada móvel Data de realização da dádiva no posto fixo e na brigada móvel Número de dádivas (total) Grupo sanguíneo Frequência relativa do grupo sanguíneo

Na primeira página do *dashboard* (Figura 20), o mapa “Distribuição das brigadas” permite visualizar a distribuição das brigadas de recolha de sangue, sendo esta informação atualizada consoante o filtro selecionado. Através do gráfico “Total de colheitas por brigada”, o utilizador pode visualizar o número de dádivas de sangue por sessões de colheita, neste caso, com o filtro de 2019 aplicado, podemos observar que o posto fixo de Lisboa registou o maior número de dádivas (11 837), seguindo-se o posto fixo do Porto (11 148). Através dos gráficos “Total de colheitas por concelho” e “Total de colheitas por freguesia” o utilizador pode visualizar o total de colheitas por concelho e por freguesia, sendo o concelho de Lisboa o que registou o maior número de colheitas (22 823), seguindo-

se o concelho do Porto (12 998), nas freguesias destaca-se Alvalade (14 558), seguindo-se Paranhos (11 861). Através da tabela é possível visualizar informação sobre todas as brigadas que ocorreram num determinado ano, de mencionar que ao clicar numa brigada a sua localização fica evidenciada no mapa.

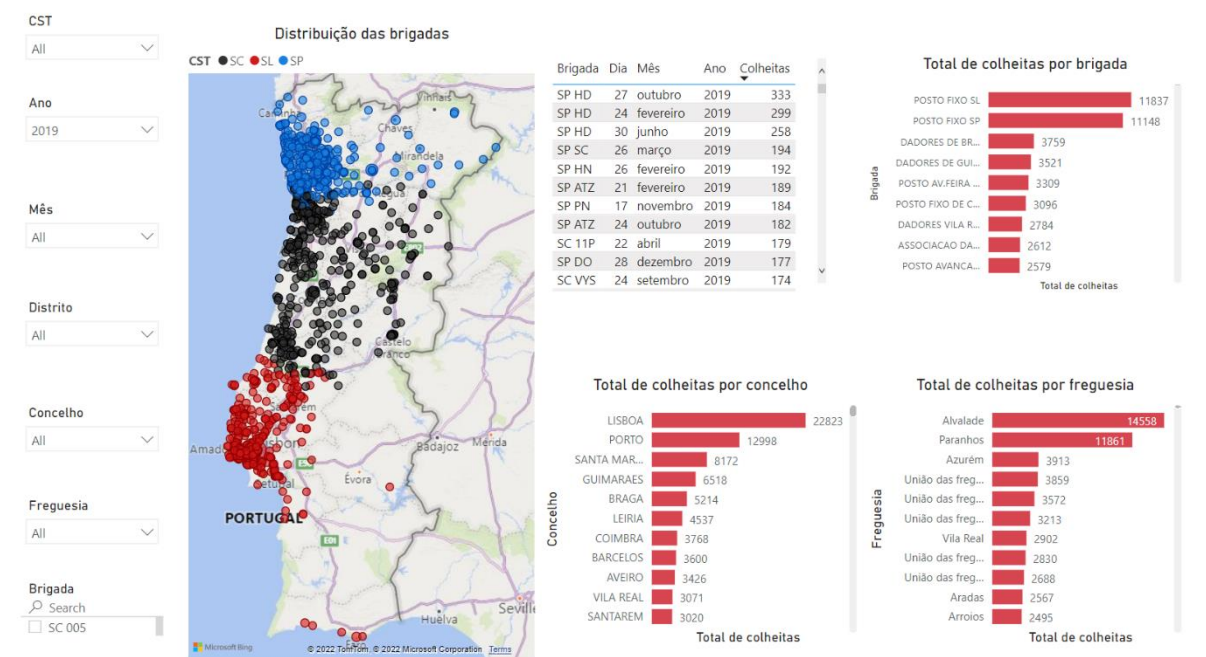


Figura 20 – Dashboard de informação sobre as brigadas

Na segunda página do *dashboard* (Figura 21), com o objetivo de visualizar brigadas com um total de colheitas significativo, procedeu-se à aplicação de um filtro onde apenas visualizamos brigadas cujo total de colheitas foi superior a 40. Através do mapa é possível observar a frequência relativa de cada grupo sanguíneo. No gráfico “Frequência relativa por concelho” é possível visualizar a frequência relativa de determinado grupo sanguíneo por concelho. O gráfico “Frequência relativa por brigada” evidência a frequência relativa para todos os grupos sanguíneos em determinada brigada, permitindo ainda ordenar a frequência relativa do maior para o menor e vice-versa. Por fim, caso não esteja nenhum grupo sanguíneo filtrado, o gráfico “Frequência relativa dos grupos sanguíneos” dá-nos uma visão do panorama nacional, sendo possível observar que em Portugal Continental, predominam os grupos sanguíneos A⁺ (37,9%) e O⁺ (35,8%).

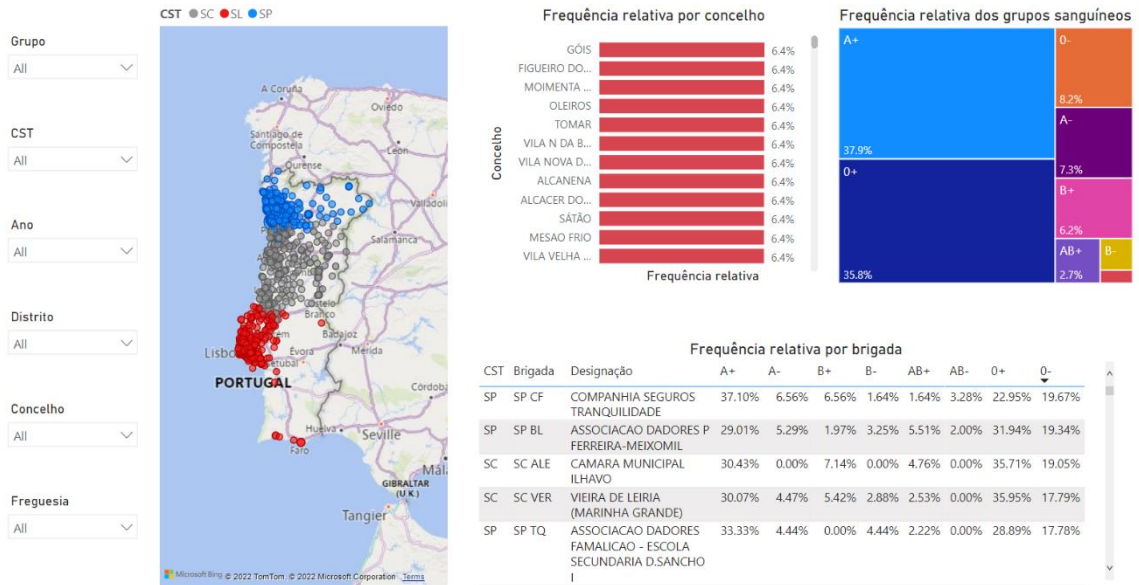
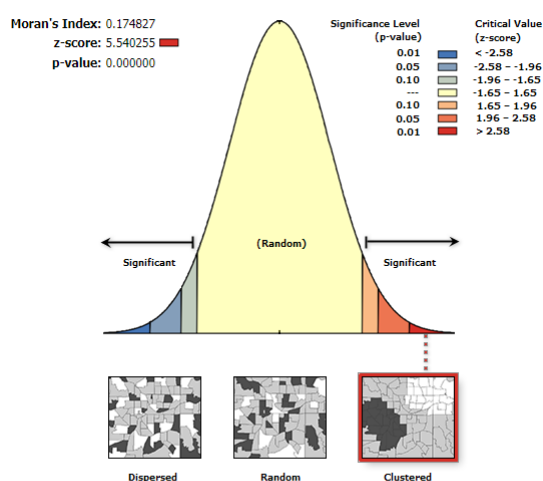


Figura 21 – Dashboard de informação sobre os grupos sanguíneos

Capítulo 5. Análise dos Resultados

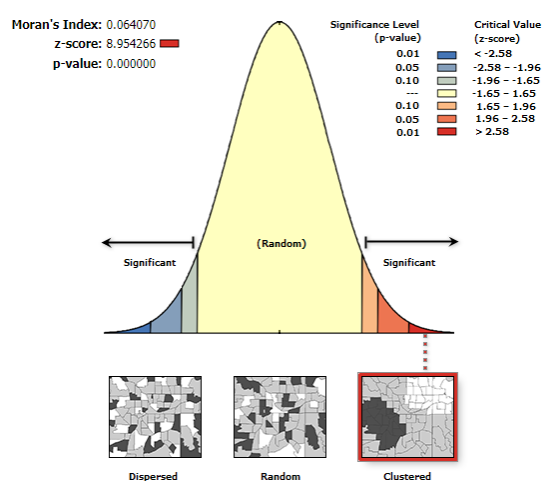
5.1. Índice de Moran

Foi calculado o Índice Global de *Moran* para os municípios, utilizando o número de dívidas recolhidas. Quanto aos resultados obtidos (Figura 22), registou-se um Índice Global de *Moran* de 0,17, ou seja, ficou acima do índice esperado, o que confirma uma correlação direta. O valor de *z-score* de 5,54 reforça a autocorrelação positiva. Relativamente ao valor de *p-value* de 0 este permite afastar a probabilidade de que o padrão espacial observado tenha sido criado por algum processo aleatório, sendo possível rejeitar a hipótese nula. Para efeitos de comparação foi calculado o Índice Global de *Moran* para as freguesias. Quanto aos resultados obtidos (Figura 23), registou-se um Índice Global de *Moran* de 0,06 o que confirma uma correlação direta. O valor de *z-score* de 8,95 reforça a autocorrelação positiva. O valor de *p-value* de 0 permite afastar a probabilidade de que o padrão espacial observado tenha sido criado por algum processo aleatório.



Given the z-score of 5.54025547226, there is a less than 1% likelihood that this clustered pattern could be the result of random chance.

Figura 22 – Resultado do índice de Moran nos municípios



Given the z-score of 8.95426649991, there is a less than 1% likelihood that this clustered pattern could be the result of random chance.

Figura 23 – Resultado do índice de Moran nas freguesias

Quanto aos resultados obtidos pelo Índice Local de *Moran* nos municípios (Figura 24) é possível constatar que os *clusters* de baixa magnitude são os que predominam no território (correlação indireta), principalmente na região do Alentejo, o que demonstra uma concentração espacial menor de dádivas face ao que seria esperado nestes municípios. Por outro lado, na AML os municípios de Almada, Amadora, Cascais, Loures, Mafra, Odivelas, Oeiras e Sintra apresentam valores de índice positivo (correlação direta) e na AMP os municípios de Espinho, Gondomar, Maia, Matosinhos, Oliveira de Azeméis e Paredes, bem como os municípios de Esposende, Lousada, Ovar e Vizela também apresentam valores de índice positivo, ou seja, os *clusters* de maior magnitude localizam-se nestas regiões.

O Índice Local de *Moran* nas freguesias (Figura 25), contrariamente aos valores obtidos no Índice Local de *Moran* nos municípios, demonstra que os *clusters* de baixa magnitude se localizam principalmente na região norte e centro do território e tais diferenças nos resultados, podem ser explicadas devido a uma análise local mais pormenorizada à escala da freguesia. Os *clusters* de maior magnitude também se localizam na AML e AMP.

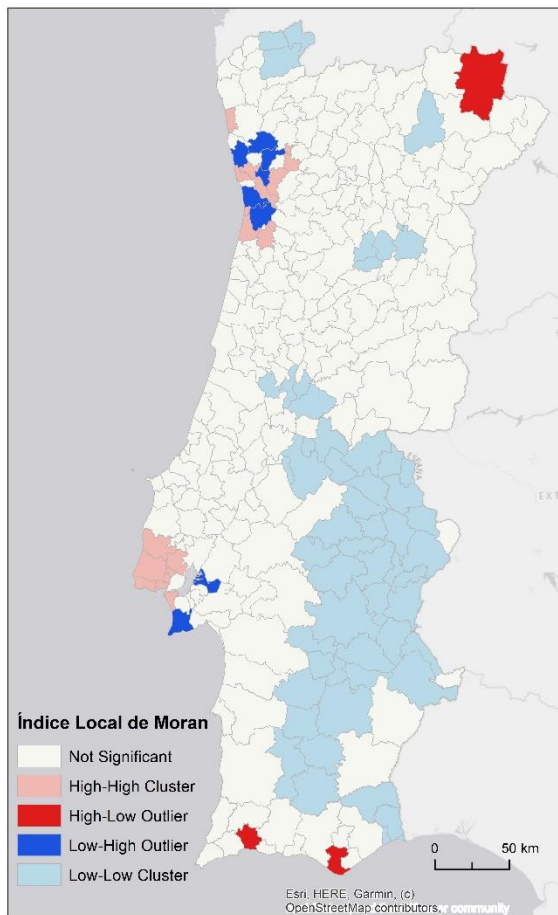


Figura 24 – Resultado do índice Local de Moran nos municípios

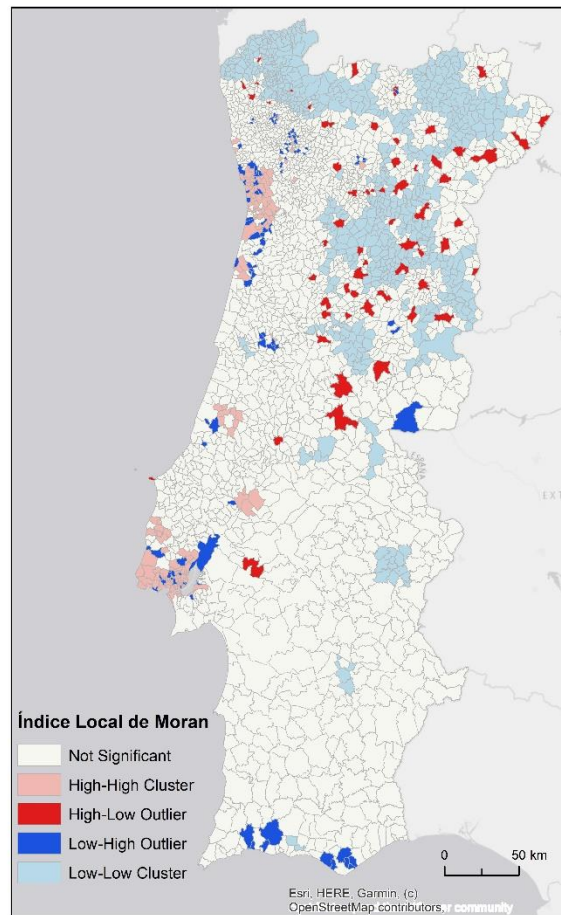


Figura 25 – Resultado do índice Local de Moran nas freguesias

5.2. Análise de Hot Spot (Getis-Ord G_i^*)

Foi realizada a análise de *Hot Spot* nos municípios e nas freguesias de Portugal Continental, utilizando o número de dádivas de sangue. Analisando os resultados obtidos nos municípios (Figura 26), subsistem 40 municípios estatisticamente significativos (*hot spot* superior a 90%) localizados na AML e na AMP, na restante área de estudo são considerados insignificantes, dado que não existem casos suficientemente “robustos” de dádivas de sangue. Os *clusters* espaciais com uma maior significância (99%) localizam-se nos seguintes municípios: Alcochete, Almada, Amadora, Arruda dos Vinhos, Barreiro, Cascais, Espinho, Gondomar, Lisboa, Loures, Mafra, Maia, Moita, Odivelas, Oeiras, Paços de Ferreira, Paredes, Penafiel, Porto, Póvoa de Varzim, Santa Maria da Feira, Santo Tirso, Seixal, Sesimbra, Sintra, Sobral de Monte Agraço, Trofa, Valongo, Vila do Conde, Vila Franca de Xira, Vila Nova de Famalicão e Vila Nova de Gaia, seguindo-se com 95% de significância: Braga, Felgueiras,

Matosinhos e Vizela e com 90% Barcelos, Castelo de Paiva, Guimarães e Lousada. Tal resultado pode ser explicado pelo facto de serem os municípios com maior cariz populacional.

Analisando os resultados obtidos nas freguesias (Figura 27), para além das Áreas Metropolitanas de Lisboa e Porto, destaca-se também o Algarve com freguesias estatisticamente significativas de 95% em Olhão, Pechão, Quelfes, União das freguesias de Faro (Sé e São Pedro) e União das freguesias de Moncarapacho e Fuseta e de 90% em Almancil, Montenegro, Santa Bárbara de Nexe e União das freguesias de Conceição e Estoi, na região centro sobressaem ainda as freguesias de Amor e Moita. Na restante área de estudo os valores não são considerados significativos.



Figura 26 - Clusters espaciais de dívidas de sangue nos municípios

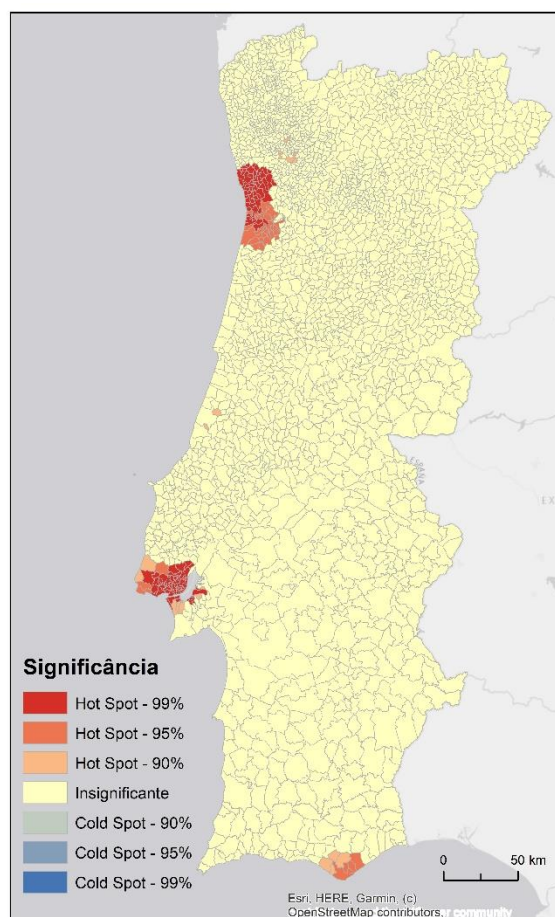


Figura 27 - Clusters espaciais de dívidas de sangue nas freguesias

5.3. Densidade de Kernel

De modo a observar de forma coesa a densidade de brigadas móveis ao longo da extensão territorial, procedeu-se à aplicação do método da densidade de *Kernel*. Analisando os resultados obtidos (Figura 28), podemos observar dois focos de densidade de brigadas móveis localizados na AML e na AMP, sendo estas as áreas com maior cariz populacional, a restante área de estudo apresenta baixa densidade, uma vez que praticamente não foram realizadas brigadas móveis.




Figura 28 – Densidade de Kernel

5.4. Regressão Linear Múltipla

Foi realizada uma análise de potencial, recorrendo ao método RLM, como forma de perspetivar se alguns aspetos populacionais influenciam o número de dádivas de sangue, nomeadamente: população residente com idade para dar sangue; poder de compra per capita; taxa de transição/ conclusão no ensino básico; taxa de transição/ conclusão no ensino secundário; população empregada no setor primário e brigadas.

Analisando os resultados (Figura 29), a informação acerca dos resíduos indica a existência de municípios onde o número de dádivas é superior ao expectável (resíduos positivos $> 2,5$), nomeadamente: Porto (8,78), Santa Maria da Feira (8,58), Santarém (3,79) e Lisboa (3,03) e municípios onde o número de dádivas é inferior ao expectável (resíduos negativos $< 2,5$), mais propriamente: São João da Madeira (-6,76), Vila Nova de Gaia (-5,29), Coimbra (-4,87) e Amadora (-3,44).

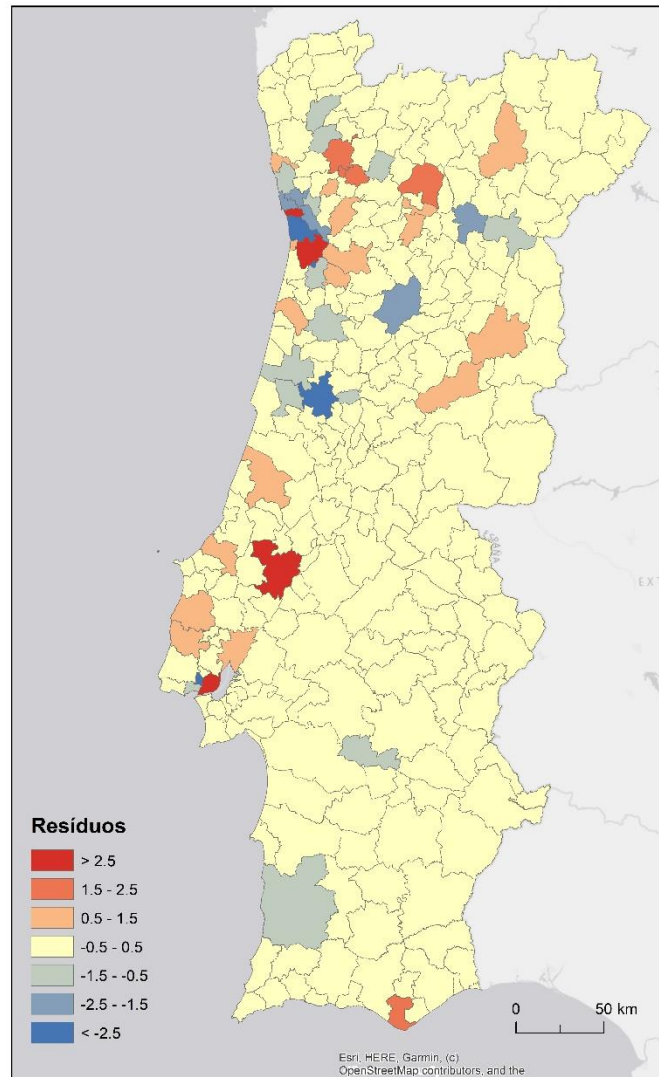


Figura 29 - Resíduos da regressão linear múltipla

Os municípios que se encontram abaixo do número de dádivas expectável, são áreas com elevado potencial de doação, sendo necessário dedicar especial atenção e apostar em ações de sensibilização.

Considerações finais

Na área da saúde existe carência de sistemas de informação que permitam uma boa gestão das sessões de colheita de sangue, dessa forma os processos criados e os resultados obtidos neste trabalho assumem um papel importante para a gestão de dádivas de sangue no país. A disponibilização do *dashboard* ao IPST cumpriu o objetivo de apoiar na gestão de dádivas de sangue em Portugal Continental. O *dashboard* demonstrou algumas situações onde o planeamento não foi o mais adequado, ao revelar sessões de colheita muito próximas geograficamente durante o mesmo período temporal, tendo em conta que é necessário um intervalo mínimo de 2 meses entre as dádivas, tal situação pode ser um desperdício de recursos, podendo ser evitada com a utilização de SIG.

De acordo com a informação disponibilizada pelo IPST, apenas 14% das dádivas de sangue são realizadas por jovens entre os 18 e os 25 anos, e o grupo de dadores até aos 25 anos tem vindo a diminuir, sendo também quem dá sangue menos vezes durante o ano, “em média um jovem até aos 25 anos faz 1,2 doações por ano enquanto os cidadãos a partir dos 55 fazem cerca de 1,7 doações”. O envelhecimento da população é também um dos principais desafios que a dádiva de sangue enfrenta em Portugal. Posto isto, de modo a assegurar a continuidade da dádiva de sangue a longo prazo, é precisamente em municípios como Cascais, Lisboa, Loures, Sintra e Vila Nova de Gaia, por serem os municípios com maior número de população residente entre os 20 e os 24 anos, que devem intervir com ações de sensibilização para a dádiva de sangue.

Relativamente à distribuição geográfica dos grupos sanguíneos, o tipo de sangue A⁺ (37,9%) e O⁺ (35,8%) são os que predominam em Portugal Continental, em menor percentagem estão os tipos de sangue AB⁻ (0,6%) e B⁻ (1,4%). Tendo em conta que o grupo sanguíneo O⁻ é dador universal, e, portanto, um grupo sanguíneo bastante necessário nos hospitais, através do *dashboard* é possível determinar a localização de potenciais dadores. Podemos concluir que é precisamente nos municípios de Mangualde e Alcochete que a frequência relativa deste grupo sanguíneo é maior, sendo áreas estratégicas para atuação de brigadas móveis. O *dashboard* permite ao IPST o conhecimento da distribuição geográfica dos grupos sanguíneos, servindo de ferramenta para auxiliar as orientações estratégicas na área funcional do sangue, definidas no Plano Estratégico de 2015-2024 do IPST, ao permitir criar uma maior especificidade na colheita, assegurando a autossuficiência

sem desperdício de grupos de baixa utilização (AB e B). Este conhecimento constitui um importante contributo na gestão dos *stocks* dos bancos de sangue, auxiliando o planeamento de sessões de colheita.

Os métodos de análise espacial demonstraram a sua utilidade e eficácia. Os SIG na área da saúde assumem um papel muito importante enquanto ferramentas de apoio à decisão, ao permitirem analisar a distribuição espacial das sessões de colheita, bem como dos dadores, na qual a localização geográfica é uma característica importante.

Analisando os resultados obtidos pelos métodos de análise espacial, é possível identificar padrões espaciais e constatar que a distribuição espacial não é aleatória. Podemos concluir que é precisamente na AML e na AMP que se registam os *clusters* de maior magnitude, sendo precisamente nestas áreas onde a densidades de brigadas móveis é maior. Tal pode ser explicado pelo facto de possuírem maior concentração de população residente com idade para dar sangue, de população empregada, maior poder de compra e onde a taxa de escolarização é maior. Podemos destacar na AML os municípios de Almada, Amadora, Cascais, Loures, Mafra, Odivelas, Oeiras e Sintra e na AMP os municípios de Espinho, Gondomar, Maia, Matosinhos e Paredes. Por outro lado, no interior do país registam-se *clusters* espaciais negativos. A estes resultados junta-se o facto de os Centros de Sangue e Transplantação de Lisboa e Porto, serem os principais recetores de dádivas de sangue, assumindo um papel fulcral na gestão de dádivas.

Através da análise de potencial, podemos constatar a existência de municípios que tendo em conta as suas características, o número de dádivas é superior ao expectável, nomeadamente: Porto, Santa Maria da Feira, Santarém e Lisboa e municípios onde o número de dádivas é inferior ao expectável, nomeadamente: São João da Madeira, Vila Nova de Gaia, Coimbra e Amadora. Os municípios que se encontram abaixo do número de dádivas expectável, são áreas com elevado potencial de doação, uma vez que possuem um número elevado de população residente com idade para dar sangue, destaque para o município de Vila Nova de Gaia que corresponde ao terceiro município com maior número de população com idade para dar sangue e, ademais, o município de Coimbra, devido à localização do Centro de Sangue e Transplantação, que deveria funcionar como um dos principais recetores de dádivas de sangue, sendo necessário dedicar especial atenção e apostar em ações de sensibilização.

Em suma, o *dashboard* construído demonstrou ser uma ferramenta útil para o planeamento de sessões de colheita de sangue, evitando sessões muito próximas geograficamente e permitindo, em caso de necessidade de determinado grupo sanguíneo, realizar sessões em locais estratégicos, tem também grande utilidade na medida em que permite que os dados estejam sempre atualizados. A possibilidade de introduzir novas variáveis pode ser uma mais-valia, nomeadamente variáveis de cariz populacional, podendo revelar padrões geográficos e localizações estratégicas. O *dashboard* apresenta diversas vantagens tais como: fácil utilização; possibilita a interseção de nova informação, como por exemplo, variáveis de cariz populacional; permite a alteração da escala de trabalho; permite que a informação esteja sempre atualizada; enquanto ferramenta de apoio à tomada de decisão, permite auxiliar o planeamento de sessões de colheita.

Bibliografia

- Alves, R. M. A. (2005). *Os sistemas de informação geográfica*. In Costa, J. S. (coord.), *Compêndio de Economia Regional*, Col. APDR, 2ª ed., Coimbra, pp. 809-842.
- Anselin, L. (1995). Local Indicators of Spatial Association—LISA. *Geographical Analysis*, 27(2), 93–115. <https://doi.org/10.1111/j.1538-4632.1995.tb00338.x>
- Anselin, L., & Piras, G. (2009). *Approaches Towards the Identification of Patterns in Violent Events, Baghdad, Iraq* (Issue May). <https://hdl.handle.net/11681/13859>
- Besterman, E. M. M. (2004). *William Harvey and his discovery of the circulation of the blood*. *West Indian Med. J.* 53, 425–426. <http://dx.doi.org/10.1186/2040-2384-1-3>
- Cerda, J. & Valdivia, G. (2007). *John Snow, la epidemia de cólera y el nacimiento de la epidemiología moderna*. Pontificia Universidad Católica de Chile. Facultad de Medicina, Departamento de Salud Pública. (24): 331-334.
- Chainey, S., & Ratcliffe, J. (2005). *GIS and crime mapping*. London: John Wiley & Sons Ltd., 442 pp.
- Chang, K.-T. (2019). *Introduction to geographic information systems* (9th ed.). McGraw-Hill Education.
https://books.google.pt/books/about/ISE_Introduction_to_Geographic_Informati.html?id=5VHetwEACAAJ&redir_esc=y
- Chan, L., Chee, T., Chuah, M., Rahman, A., Tan, C., Wong, S. & Yeoh, W. (2009). Business Intelligence Systems: State-of-the-art review and contemporary applications. *Symposium on Progress in Information and Communication Technology 2* (4), 96–101.
- Chaudhuri, S., Dayal, U., & Narasayya, V. (2011). *An Overview of Business Intelligence Technology*. *Communications of the ACM*, 88- 98.
- Cromley, E. K. (2003). GIS and disease. *Annual Review of Public Health*, 24, 7–24. <https://doi.org/10.1146/annurev.publhealth.24.012902.141019>

- Croner, M., Sperling, J., & Broome R. (1996). *Geographic information systems (GIS): New perspectives in understanding human health and environmental relationships*. *Statistics in Medicine*, (15): 17:18.
- Cunha, G., Cunha, R. J., Cabral, P., Cabral, M., & Oliveira, A. (2011). *Bioestatística e Qualidade na Saúde*. Lidel.
- Curtis, S., Riva, M., & Rosenberg, M. (2009). Health Geography and Public Health. In *A Companion to Health and Medical Geography* (pp. 323–345). <https://doi.org/https://doi.org/10.1002/9781444314762.ch18>
- Elzubair, R. (2009). *Aiding decision making in public health domain using WebGIS*. University Teknologi Malaysi.
- Encalada, L. (2016). *Big Data e Redes Sociais na Análise Espacial de Padrões Turísticos em Contexto Urbano*. O caso de Lisboa. Dissertação de Mestrado, 142:143.
- Ferreira, A. M. P. J. (2000). *Dados Geoquímicos de Base de Sedimentos Fluviais de Amostragem de Baixa Densidade de Portugal Continental: Estudo de Factores de Variação Regional*. Tese de Doutoramento. Universidade de Aveiro. Departamento de Geociências. Aveiro, (2), 19– 61
- Few, S. (2006). *Information dashboard design: The effective visual communication of data*. O'Reilly Media, Inc.
- Gatrell, A., Bailey, T., Diggle, P., & Rowlingson, B. (1996). *Spatial point pattern analysis and its application in geographical epidemiology*. *Transactions of the Institute of British Geographers, New Series*, 21(1): 256-274.
- Getis, A., & Ord, J. K. (1992). *The Analysis of Spatial Association by Use of Distance Statistics*. *Geographical Analysis*, 24(3), 189–206. doi:10.1111/j.1538- 4632.1992.tb00261.x
- Giangrande, P. L. F. (2000). *The history of blood transfusion*. *Br. J. Haematol.* 110, 758–767. doi:10.1046/j.1365-2141.2000.02139.x
- González, I. B., Freire, C. F., Morente, I. M. F., & Asensio, E. p. (2012). *Los sistemas de informacion geográfica y la investigación en ciencias humanas y sociales*. CSIC: Confederación Española de Centros de Estudios Locales.

- Goodchild, M. F. (1992). Geographical information science. *International journal of geographical information systems*, 6(1), 31-45.
- Goodchild, M. (2003). *Geographic Information Science and Systems for Environmental Management*. Annual Review of Environment and Resources, (28): 493-519. <https://doi.org/10.1146/annurev.energy.28.050302.105521>
- Hanchette, C. L. (2003). *Public Health Informatics and Information Systems*, In O'Carroll, P.W., Ripp, L.H., Yasnoff, W.A., Ward, M.E., Martin, E.L. (Eds.), Springer, New York, NY, pp. 431–466.
- Jacquez, G. M. (2000). Spatial analysis in epidemiology: Nascent science or a failure of GIS? *Journal of Geographical Systems*, 2(1), 91–97. <https://doi.org/10.1007/s101090050035>
- Jacquez, G. M. (2008). *Spatial Cluster Analysis*. In S. Fotheringham e J. Wilson (Eds.), *The Handbook of Geographic Information Science* (pp. 395–416). Blackwell Publishing.
- Kemp, K. K. (2008). *Encyclopedia of Geographic Information Science*. SAGE. <https://dx.doi.org/10.4135/9781412953962>
- Kistemann, T., Dangendorf, F., & Schweikart, J. (2002). New perspectives on the use of Geographical Information Systems (GIS) in environmental health sciences. *International Journal of Hygiene and Environmental Health*, 205, 169-181.
- Kutner, M. H., Nachtsheim, C. J., Neter, J., & Li, W. (1996). *Applied linear statistical models*. Irwin. <https://books.google.pt/books?id=q2sPAQAAMAAJ>
- Longley, P. A., Goodchild, M. F., Maguire, D. J. e Rhind D. W. (2005). *Geographical Information Systems and Science*. John Wiley & Sons Ltd, 2^a nd edition, England.
- Longley, P. A., Goodchild, M. F., Maguire, D. J., & Rhind, D. W. (2011). *Geographical Information Systems and Science*, City. doi:10.2307/215736
- Longley, P. A., Goodchild, M. F., Maguire, D. J., & Rhind, D. W. (2015). *Geographic Information Science and Systems* (4th Edition). Wiley. https://books.google.pt/books/about/Geographic_Information_Science_and_Syste.html?id=C_EwBgAAQBAJ&redir_esc=y

- Lu, Y. (2000). *Spatial Cluster Analysis for Point Data: Location Quotients verses Kernel Density*. In Proceedings of the Information Science Summer Assembly, Portland, Oregon.
- Lumpkin, J. R. (2003). *History and significance of information systems and public health*. In P.W. O'Carroll, Y.A. Yasnoff, M.E. Ward, L.H. Ripp, and E.L. Martin (Ed.), *Public Health Informatics* (pp. 16–38). New York, NY: Springer.
- Lyseen, A. K., Nøhr, C., Sørensen, E. M., Gudes, O., Geraghty, E. M., Shaw, N. T., & Bivona-Tellez, C. (2014). A Review and Framework for Categorizing Current Research and Development in Health Related Geographical Information Systems (GIS) Studies. *Yearbook of Medical Informatics*, 9, 110–124. <https://doi.org/10.15265/IY-2014-0008>
- Martin, C., Curtis, B., Fraser, C., & Sharp, B. (2002). *The use of a GIS-based malaria information system for malaria research and control in South Africa*. *Health & Place*, 8, 227-236.
- Mayer, J. D. (2010). Medical Geography. In *A Companion to Health and Medical Geography* (pp. 33–54). John Wiley & Sons, Ltd. <https://doi.org/https://doi.org/10.1002/9781444314762.ch3>
- Miranda, M. L., & Dolinoy, D. C. (2005). *Using GIS-Based Approaches to Support Research on Neurotoxicants and Other Children's Environmental Health Threats*. *NeuroToxicology*, 26, 223-228.
- Mitchell, A. (2005). *The ESRI Guide to GIS Analysis, Volume 2: Spatial Measurements and Statistics*. ESRI Press, Environmental Systems Research Institute, Redlands, California.
- Moore, D., & Carpenter, T. (1999). *Spatial analytical methods and geographic information systems: use in health research and epidemiology*. *Epidemiol Rev.* Volume 21 n°2: 143–161. <https://doi.org/10.1093/oxfordjournals.epirev.a017993>
- Niu, L., Lu, J. & Zhang, G. (2009). Business intelligence. In: *Cognition-Driven Decision Support for Business Intelligence*, Berlin: Springer, pp. 19–29.
- Nogueira, H., & Remoaldo, P. (2010). *Olhares geográficos sobre a Saúde*. Colibri.

- Nossa, P. (2005). *Abordagem Geográfica da Oferta/Procura dos Cuidados de Saúde, o caso da Sida*. Tese de Doutoramento em Geografia (Geografia Humana), Universidade do Minho.
- O'Reagan, R. T., & Saalfeld, A. (1987). *Geocoding theory and practice at the Bureau of the Census*. Washington, D.C.
- Pfeiffer, D. (1996). *Issues related to handling of spatial data*. Proceedings of the epidemiology and state veterinary programmes. Australian Veterinary Association, Second Pan Pacific Veterinary Conference, New Zeland.
- Rican, S., & Salem, G. (2009). Mapping Disease. In *A Companion to Health and Medical Geography* (pp. 96–110).
<https://doi.org/https://doi.org/10.1002/9781444314762.ch6>
- Ricketts, C. (2003). *Geographic information systems and public health*. Annual Review of Public Health 24: 1-6.
- Riner, M. E., Cunningham, C., & Johnson, A. (2004). *Public health education and practice using geographic information system technology*. Public Health Nursing, 21(1): 57-65.
- Robinson, S., & Kaplan, V. (2012). *The Geocoding Advantage: Best Practices for Managing Customer and Location-based Data in Telecommunications*.
- Rocha, J. (2012). *Sistemas Complexos, Modelação e Geosimulação da Evolução de Padrões de Uso e Ocupação do Solo*. Diss. de Doutoramento em Geografia.
- Rushton, G. (2003). *Public health, GIS, and spatial analytic tools*. Annual Review of Public Health. 24 (1): 43-56.
- Sabel, C. E., Pringle, D., & Schærström, A. (2009). Infectious Disease Diffusion. In *A Companion to Health and Medical Geography* (pp. 111–132).
<https://doi.org/https://doi.org/10.1002/9781444314762.ch7>
- Santana, P. (2005). *Geografias da Saúde e do Desenvolvimento*. Evolução e Tendências em Portugal. Coimbra, Edições Almedina.
- Santana, P. (2014). *Introdução à Geografia da Saúde: Território, Saúde e Bem-Estar*. Coimbra University. <https://doi.org/http://dx.doi.org/10.14195/978-989-26-0727-6>

- Siffel, C., Strickland, M. J., Gardner, B. R., Kirby, R. S., & Correa, A. (2006). *Role of geographic information systems in birth defects surveillance and research*. Birth Defects Research Part A: Clinical and Molecular Teratology, 76(11):825–833.
- Snow, J. (1849). *On the Pathology and Mode of Communication of Cholera*.
- Snow, J. (1855). *On the mode of communication of cholera*. John Churchill, London.
- Tobler, W. R. (1970). *A Computer Movie Simulation Urban Growth in Detroit Region*. Econ. Geography. 46: 234-240. <https://doi.org/10.1126/science.11.277.620>
- Turban, E., Sharda, R., & Delen, D. (2010). *Decision support and business intelligence systems* (9 ed.). Upper Saddle River, NJ, USA: Prentice Hall Press.
- Watson, H. J. (2009). Tutorial: Business Intelligence – Past, Present, and Future. *Communications of the Association for Information Systems* 25 (39), 487–510. <https://doi.org/10.17705/1CAIS.02539>
- Zimmerman, D. L., Fang, X. M., & Mazumdar S. (2008). *Spatial clustering of the failure to geocode and its implications for the detection of disease clustering*. Statistics in medicine, 27(21): 4254-4266.

Legislação Consultada

Assembleia da República. Estatuto do Dador de Sangue - Lei n.º 37/2012. Diário da República n.º 165/2012, Serie I, pages 4701 – 4703 de 2012-08-27. Consultado a 04/11/2021