



Lisbon School
of Economics
& Management
Universidade de Lisboa

MESTRADO

MÉTODOS QUANTITATIVOS PARA A DECISÃO ECONÓMICA E EMPRESARIAL

TRABALHO FINAL DE MESTRADO

**DISSERTAÇÃO ELABORADA PARA A OBTENÇÃO DE GRAU DE
MESTRE**

**IMPACTO DA TEMPERATURA NA SAÚDE EM PORTUGAL
CONTINENTAL: MORTALIDADE E ATENDIMENTOS EM
URGÊNCIA HOSPITALAR**

LARA KWAI MAK

ORIENTAÇÃO:

PROFESSORA DOUTORA ALEXANDRA MOURA

PROFESSOR DOUTOR CARLOS OLIVEIRA

OUTUBRO - 2022

Agradecimentos

Quero agradecer,

Ao meu pai, por todas as horas que se sentou comigo a estudar, pela paciência e por me ter ensinado “Treino duro, Combate fácil”.

À minha mãe, por todas as vezes que me disse exatamente o que precisava de ouvir, especialmente nos momentos mais complicados.

À minha irmã, a minha protetora independentemente do quão longe ou perto está.

Ao avô Toino e à avó Amélia por todos os valores de força, perseverança, empatia e amor que me transmitiram, que foram e são valiosos no meu percurso pessoal e académico.

Ao Alexandre, o melhor companheiro, melhor amigo que nunca me deixou vacilar em momento algum.

Aos meus amigos de toda a vida, por crescerem ao meu lado.

Aos professores com que me cruzei no meu percurso académico, tanto na Universidade de Évora como no ISEG que me fizeram apaixonar pelas áreas que escolhi.

Obrigada, a todos pela força, carinho, apoio e ensinamentos.

Resumo

Os estudos epidemiológicos têm vindo a demonstrar a existência de uma relação de causalidade significativa entre oscilações da temperatura do ar e expressivas flutuações no estado de saúde da população humana.

Para compreender estas associações em Portugal Continental, e nas suas várias regiões de saúde, pretende-se estudar a relação entre a temperatura mínima e máxima do ar com indicadores de saúde, tais como a mortalidade e o número de atendimentos em urgência hospitalar por triagem de Manchester. Para desenvolver este estudo realiza-se uma análise descritiva das variáveis acima mencionadas bem como uma investigação do seu comportamento em períodos de ondas de frio e de calor. Por fim, são utilizados Modelos Lineares Generalizados, mais precisamente a regressão Binomial Negativa, nos dados de contagens da mortalidade diária, por região de saúde.

Os resultados obtidos evidenciam que a mortalidade é superior nos meses inverniais, e é inferior nos meses estivais. Por sua vez os atendimentos em urgência hospitalar por triagem de Manchester, dependendo da cor da pulseira, apresentam um comportamento diferente. Também se evidencia que a variação da mortalidade durante as ondas de calor é superior à variação da mortalidade durante as ondas de frio, comparativamente aos períodos homólogos. Por outro lado, a variação dos atendimentos em urgência durante as ondas de calor foi inferior à variação dos atendimentos em urgência durante as ondas de frio, relativamente aos períodos homólogos.

Através da aplicação dos Modelos Lineares Generalizados aos dados da mortalidade diária entre 2014 e 2019, demonstra-se que a diminuição de 1°C da temperatura mínima resulta no aumento entre a 1 a 2% do valor esperado do número de óbitos diários. E que a diminuição de 1°C da temperatura máxima resulta num aumento de 0 a 1% do valor esperado do número de óbitos diários em Portugal Continental.

Palavras-chave: Temperatura, Mortalidade, Atendimentos em urgência, MLG

Abstract

Epidemiological studies have shown the existence of a significant causal relationship between oscillations in the air temperature and significant fluctuations in the health status of the human population.

To understand these associations in Continental Portugal, and in its various health regions, we intend to study the relationship between minimum and maximum air temperature with health indicators, such as mortality and the number of emergency department visits by Manchester triage. To develop this study, a descriptive analysis of the variables is carried out as well as an investigation of their behavior in periods of cold and heat waves. Finally, Generalized Linear Models, more precisely Negative Binomial Regression, are used in the daily mortality counts data, per health region.

The results obtained show that mortality is higher in winter months and lower in summer months. On the other hand, emergency care by Manchester triage, depending on the color of the wristband, shows a different behavior. It is also evident that the variation in mortality during heat waves is higher than the variation in mortality during cold waves, compared to homologous periods. On the other hand, the variation of emergency department visits during heat waves was lower than the variation of emergency department visits during cold waves, relative to the homologous periods.

By applying Generalized Linear Models to the daily mortality data between 2014 and 2019, it is shown that a 1°C decrease in minimum temperature results in an increase of between 1 and 2% in the number of daily deaths. And that a 1°C decrease in maximum temperature results in a 0 to 1% increase in the number of daily deaths in mainland Portugal.

Keywords: Temperature, Mortality, Emergency Room Attendance, MLG

Índice

Agradecimentos	1
Resumo	2
Abstract.....	3
Índice	4
Índice de Figuras	7
Índice de Tabelas	8
Lista de Siglas e Abreviaturas	9
1. Introdução	10
2. Revisão da Literatura	12
2.1. Impacto da temperatura do ar na saúde humana	12
2.2. Métodos de séries temporais aplicados na literatura	16
3. Metodologia	18
3.1. Análise descritiva das variáveis	21
3.1.1. Aplicação da Média Móvel Simples	21
3.1.2. Análise dos <i>Boxplots</i>	21
3.1.3. Decomposição das forças componentes – Modelo Aditivo	22
3.2. Definição dos períodos de ondas de frio e de calor.....	22
3.3. Estudo das flutuações dos indicadores de saúde	23
3.4. Processo de modelação e interpretação da informação	24
3.4.1. Modelos Lineares Generalizados	24
3.4.2. Formulação dos modelos.....	25
3.4.3. Modelos Lineares Generalizados para dados de contagens	26
3.4.4. Regressão Binomial Negativa	27
3.4.5. Avaliação da qualidade das regressões de Binomiais Negativas	28

3.4.5.1.	Teste de ajustamento χ^2 e de Pearson.....	28
3.4.5.2.	Análise dos <i>Quantile-Quantile Plots</i> dos resíduos.....	28
3.4.6.	Método de interpretação dos dados.....	29
3.4.7.	Introdução de variáveis quadráticas.....	29
3.4.8.	Comparação entre regressões Binomiais Negativas de primeiro e de segundo grau.....	30
3.4.8.1.	<i>Akaike's Information Criterion</i> (AIC).....	30
3.4.8.2.	Teste de Razão de Verossimilhança.....	31
3.4.9.	Métodos de interpretação das regressões quadráticas.....	31
4.	Análise descritiva dos indicadores de saúde.....	33
4.1.	Mortalidade Diária.....	33
4.1.1.	Análise descritiva da Mortalidade por Região de Saúde.....	36
4.2.	Atendimentos em urgência hospitalar por triagem de Manchester.....	40
5.	Análise estatística dos períodos de ondas de calor e de frio.....	45
5.1.	Identificação de ondas de calor e de frio.....	45
5.2.	Flutuações dos indicadores de saúde nos períodos de frio e calor.....	46
5.2.1.	Ondas frio.....	46
5.2.2.	Ondas de Calor.....	47
6.	Aplicação dos Modelos Lineares Generalizados.....	49
6.1.	Aplicação da regressão Binomial Negativa.....	51
6.1.1.	Interpretação dos modelos.....	53
6.1.2.	Introdução de variáveis quadráticas.....	54
6.1.2.1.	Interpretação das regressões quadráticas.....	55
7.	Discussão dos Resultados.....	58
7.1.	Comportamento dos indicadores de saúde.....	58
7.2.	Ondas de frio e de calor.....	59
7.3.	Modelos Lineares Generalizados.....	60

8.	Conclusão.....	62
9.	Bibliografia	64
	Anexos.....	68

Índice de Figuras

Figura 3. 1 Regiões de Saúde em Portugal Continental	18
Figura 3. 2. Estações meteorológicas por RS	19
Figura 4. 1. Mortalidade Diária total (2014-2019)	33
Figura 4. 2. Mortalidade Diária total (2014-2021) – MMS62.....	34
Figura 4. 3. Média e variância mensal da mortalidade diária total (2014-2019 VS 2014-2021).....	35
Figura 4. 4. Mortalidade Diária por RS (2014-2021)	36
Figura 4. 5. Mortalidade diária por RS (2014-2021) – MMS62	38
Figura 4. 6. <i>Boxplots</i> da Mortalidade Diária (2014-2021)	39
Figura 4. 7. Decomposição das forças componentes por RS (2014-2021).....	40
Figura 4. 8. Atendimentos em urgência hospitalar, por RS (07/16-12/21)	41
Figura 4. 9. <i>Boxplots</i> dos atendimentos em urgência hospitalar por triagem de Manchester (07/16-12/2021).....	42
Figura 4. 10. <i>Boxplots</i> dos atendimentos em urgência hospitalar por triagem de Manchester (07/16-12/2019)	43
Figura 4. 11. Atendimentos em urgência hospitalar por triagem de Manchester, e por RS (07/16-12/2021).....	44
Figura 6. 1. Correlogramas por RS – Coeficiente de correlação de Pearson	50
Figura 6. 2. <i>Q-Q Plots</i> dos resíduos– Distribuição Binomial Negativa	52

Índice de Tabelas

Tabela 3. 1 Variáveis da temperatura e indicadores de saúde	20
Tabela 4. 1 Valor Mínimo, Médio e Máximo da mortalidade diária total, por ano	34
Tabela 4. 2. Mortalidade média diária e mortalidade média diária por milhão (2014-2021)	37
Tabela 4. 3. Média mensal do número de atendimentos em urgência hospitalar e número de atendimentos em urgência hospitalar mensal por milhão, por RS (07/16-12/19)	41
Tabela 4. 4. Nº de Atendimentos em urgência por triagem de Manchester, e por RS (07/16-12/2021).....	44
Tabela 5. 1. Ondas de frio.....	45
Tabela 5. 2. Ondas de calor	46
Tabela 6. 1. Medidas de estatística descritivas da mortalidade diária.....	50
Tabela 6. 2. Regressões Binomiais Negativas estimadas para cada RS	51
Tabela 6. 3. Regressões Binomiais Negativas estimadas e transformadas para cada RS	53
Tabela 6. 4. Coeficientes, e respectivos intervalos de confiança a 95% estimados (%), para cada RS	53
Tabela 6. 5. Regressões Binomiais Negativas quadráticas estimadas, por RS.....	54
Tabela 6. 6. Impacto da temperatura mínima no log (μY) caso esta aumente de 1°C para 2°C, por RS	55
Tabela 6. 7. Impacto da temperatura máxima no log (μY) caso esta aumente de 30°C para 31°C, por RS	56

Lista de Siglas e Abreviaturas

SNS – Serviço Nacional de Saúde

IPMA – Instituto Português do Mar e da Atmosfera

RS – Região de Saúde

MLG – Modelo Linear Generalizado

1. Introdução

A associação entre as temperaturas e a saúde humana é um tema frequentemente investigado a nível global, principalmente devido ao impacto cada vez maior das mudanças climáticas. Estes estudos focam-se geralmente na análise da mortalidade estudando os fatores que a influenciam tais como o sexo, a faixa etária e as doenças que causam o óbito. Para além da mortalidade também são muitas vezes analisados indicadores relacionados com a utilização das unidades de cuidados de saúde, como por exemplo o número de episódios de urgência.

Os principais objetivos desta dissertação são, evidenciar que existe uma possível associação entre a temperatura do ar e a saúde em Portugal Continental, mas também quantificar a magnitude do impacto de flutuações da temperatura na saúde. Para tal procura-se compreender o comportamento dos indicadores de saúde ao longo do horizonte temporal, identificar períodos de temperaturas extremas e perceber como os indicadores de saúde variam nesses períodos. Por fim, estudar a forma como a temperatura mínima e máxima impacta a contagem da mortalidade através da construção de regressões de séries temporais.

As variáveis de saúde utilizadas são a mortalidade e os atendimentos em urgência hospitalar por triagem de Manchester em Portugal Continental, obtidas através de bases de dados públicas do Serviço Nacional de Saúde (SNS). A informação das temperaturas do ar foi obtida através do Instituto Português do Mar e da Atmosfera (IPMA).

Em primeiro lugar apresenta-se uma revisão da literatura com o intuito de estudar os métodos utilizados e os resultados já obtidos por outros investigadores a nível global, para também os enquadrar neste trabalho (Secção 2). De seguida, encontram-se os dados e a metodologia, onde são apresentadas as áreas geográficas, as variáveis e o processo de análise desenvolvido ao longo deste estudo (Secção 3). Este processo pode ser dividido em três grandes etapas: (i) a primeira etapa consiste numa análise descritiva dos indicadores de saúde em estudo (Secção 4); (ii) na segunda etapa identificam-se as ondas de frio e de calor e analisa-se a variação dos indicadores de saúde entre os períodos de temperaturas extremas e os seus períodos homólogos (Secção 5); (iii) na terceira etapa são utilizados Modelos Lineares Generalizados (MLG), mais precisamente a regressão Binomial Negativa, nos dados da mortalidade diária (Secção 6). Posteriormente, são

discutidos os resultados obtidos no desenvolvimento deste estudo (Secção 7). Por fim, na conclusão, apresentam-se as ilações mais importantes acerca da possível relação associativa das temperaturas do ar com a mortalidade e os atendimentos em urgência hospitalar (Secção 8).

2. Revisão da Literatura

Neste capítulo é feita uma revisão da literatura, que estuda a relação entre a temperatura e indicadores de saúde. Para além de algumas associações investigadas anteriormente, também estão presentes os principais métodos utilizados em estudos epidemiológicos que investigam esta temática.

2.1. Impacto da temperatura do ar na saúde humana

A associação entre a temperatura do ar e o risco para a saúde das populações humanas tem sido objeto de estudo sobre o qual se têm debruçado investigadores a nível global (Baccini et al., 2008; Basu et al., 2008; Marques & Antunes, 2009; Sun et al., 2014; Liddell et al., 2015). Com as alterações climáticas, principalmente o aumento da temperatura do planeta, a frequência e intensidade das ondas de calor têm vindo a intensificar-se. Consequentemente, o número de estudos científicos que analisam a relação entre temperaturas do ar e diferentes variáveis de saúde tem vindo a aumentar (Gosling et al., 2008; Basu, 2009). Apesar das ondas de calor isoladas constituírem um grave risco para a saúde, conclui-se que a sua influência na mortalidade e no incremento da atividade nos sistemas de saúde é significativamente menor do que aquela que se verifica durante os períodos com temperaturas baixas (Seltenrich, 2015).

O número de excesso de mortes no inverno relativamente à mortalidade ocorrida noutras estações do ano, é muitas vezes uma das métricas utilizadas para quantificar a associação entre temperaturas baixas e a mortalidade. Os países com invernos mais amenos, como Portugal, são os que normalmente apresentam maior excesso de mortalidade no inverno relativamente a países com invernos mais rigorosos como o Canadá. Este facto deve-se ao “paradoxo do excesso de mortalidade no inverno”. Segundo este paradoxo, as pessoas têm maior probabilidade de falecer durante os períodos de frio, em que a mortalidade tem tendência a aumentar ao longo do tempo e não apenas num curto espaço de tempo como ocorre nos períodos de calor (Seltenrich, 2015; Liddell et al., 2015). Visto que são os países com temperaturas invernais mais amenas que apresentam um maior excesso de mortalidade no inverno conclui-se que não é o frio o elemento determinante, mas sim fatores sociais, como o acesso a cuidados de

saúde tais como as vacinas e a qualidade das habitações (Rau, 2007; Almendra et al., 2015).

A exposição a temperaturas extremas impacta diretamente a saúde ao comprometer a capacidade do corpo humano de regular a sua temperatura interna. Considera-se uma temperatura corporal elevada acima dos 40°C, e abaixo dos 35°C uma temperatura baixa (Seltenrich, 2015). A perda de controlo interno da temperatura pode causar diversas doenças ou agravar condições crónicas, como patologias cardiovasculares, respiratórias, cerebrovasculares e doenças relacionadas com a diabetes (Sarofim et al., 2016). A capacidade de regular a temperatura corporal em altas ou baixas temperaturas depende principalmente da idade, da pré-existência de doenças, do uso excessivo de álcool ou drogas, e do sexo (Seltenrich, 2015).

Normalmente, a mortalidade é um dos principais indicadores de saúde escolhidos para estudar o impacto da temperatura na saúde humana. No artigo de Basu & Malig, 2011, “*High ambient temperature and mortality in California: Exploring the roles of age, disease, and mortality displacement*”, estudou-se o impacto de altas temperaturas do ar na mortalidade na Califórnia, através de métodos de séries temporais. Neste artigo, observou-se que os níveis da mortalidade podem ser afetados até 3 dias após a exposição a ondas de calor. Inferiu-se que um aumento de 5,6°C está associado a um excesso de risco de mortalidade igual a 4,3%. Foram também observados riscos idênticos para a mortalidade causada por doenças cardiovasculares e respiratórias, como também entre as faixas etárias dos 0 aos 18 anos e pessoas com mais de 50 anos (Basu & Malig, 2011).

Na literatura existem estudos que para além de abordar o impacto de temperaturas altas na saúde também incluem o impacto de temperaturas baixas. Estes textos científicos comprovam que as alterações na mortalidade causadas pela exposição a temperaturas altas prolongam-se menos no tempo do que as consequências da exposição a temperaturas baixas (Anderson & Bell, 2009; Huang et al., 2014; Chung et al., 2015). Num estudo realizado em 107 comunidades norte americanas, observou-se um aumento do risco da mortalidade de 4,2% quando comparado períodos com temperaturas extremamente baixas do primeiro percentil com períodos de temperaturas baixas do décimo percentil (Anderson & Bell, 2009).

As variáveis relativas à utilização das unidades de saúde hospitalares tais como o número de internamentos, o número de consultas, o número de atendimentos em urgência hospitalar e até o número de ambulâncias acionadas em caso de urgência, são também utilizadas para compreender o impacto das temperaturas na saúde humana. Para além desta finalidade também são usadas na definição de políticas públicas bem como na preparação dos sistemas de saúde (Rizmie et al., 2022; Almendra, 2019; Nóbrega, 2018; Sun et al., 2014). Em Rizmie et al., 2022, apresenta-se o primeiro estudo de larga escala em Inglaterra onde se analisa o número de internamentos de emergência, no horizonte temporal de 2001 a 2012, para avaliar o efeito de temperaturas extremas em toda a população. Verificou-se que o número de hospitalizações associado a temperaturas extremamente frias é superior relativamente ao número de hospitalizações associado a temperaturas extremamente quentes. Também foi demonstrado que períodos de frio e de calor com temperaturas menos extremas influenciam da mesma forma que os períodos com temperaturas extremas, no entanto, com níveis de hospitalização menores. As classes inglesas mais afetadas pelos efeitos negativos da exposição a temperaturas extremas são os mais idosos e a população com menores condições de vida (Rizmie et al., 2022).

Foi realizado um estudo semelhante em Nova Iorque, nos verões entre 1991 e 2004, que utilizou o número de internamentos. Associou-se um aumento de cerca de 3% dos internamentos devido a doenças respiratórias, à exposição a temperaturas consideradas prejudiciais para a saúde. (Lin et al., 2009).

A definição de temperaturas extremas bem como de ondas de calor e de frio não é unânime a nível internacional (Nogueira et al., 2013; Radinović & Ćurić, 2011). É de realçar que os critérios definidos para a duração mínima, e quais as variáveis a ter em conta são diferentes entre países, apesar de grande parte da Europa utilizar o mesmo critério (World Meteorological Organization & World Health Organization, 2015).

Uma forma comum de identificar intervalos de tempo com temperaturas extremas consiste em definir os percentis da série das temperaturas do ar numa determinada localização. Por exemplo, um grupo de especialistas desenvolveu um projeto que avalia o nível do risco da mortalidade causada por baixas e altas temperaturas em cerca de 384 localizações a nível global, entre 1985 e 2012. Neste estudo foi calculado o número de mortes devido a temperaturas extremamente quentes e extremamente frias. Os limites foram identificados com base nos percentis 2,5 e 97,5 para temperaturas baixas e altas,

respetivamente. Os resultados mostraram que temperaturas extremas, ou seja, que se encontram abaixo do percentil 2,5 e acima do percentil 97,5, causaram cerca de 0,86% da mortalidade total (Gasparri et al., 2015).

Posteriormente à identificação dos percentis, de forma a perceber o comportamento das variáveis de saúde à exposição de temperaturas anómalas, também é possível calcular a variação do indicador em causa no período de temperaturas extremas em relação aos períodos homólogos que não sofreu de anomalias climáticas (Nóbrega, 2018).

A presente dissertação baseou-se na definição de onda de calor e de frio do “*Heat and Cold Wave Index*” (HCWI), implementado no Copernicus European Drought Observatory, (Comissão Europeia, 2018). Segundo este indicador, durante uma onda de calor, tanto as temperaturas mínimas e máximas diárias apresentam valores acima do seu respetivo percentil 90, ao longo de pelos menos 3 dias. O mesmo se aplica a ondas de frio sendo que o limite é o percentil 10. É de realçar, que a World Meteorological Organization (WMO) também utiliza um critério de duração próximo de pelo menos 2 a 3 dias para ondas de calor (World Meteorological Organization & World Health Organization, 2015). Os limites a partir dos quais as temperaturas se consideram moderadas e extremas, são calculados a partir de um horizonte temporal de aproximadamente 30 anos. Em casos particulares quando são identificadas duas ondas de calor ou de frio separadas apenas por um dia, considera-se como um evento único.

Para encontrar períodos de temperaturas extremas relevantes, em termos do seu impacto na vida humana, as ondas de calor são definidas com base em dados de abril a setembro, ou seja, nos meses mais quentes em toda a Europa. Por outro lado, as ondas de frio são definidas entre outubro e março, sendo estes os meses mais frios. A utilização do método dos percentis baseados no calendário permite identificar períodos com temperaturas anómalas numa determinada altura do ano e numa localização geográfica específica (Lavaysse et al., 2018).

A principal diferença desta definição relativamente a outros estudos é que se utiliza a temperatura mínima e máxima diária, em vez de apenas utilizar a temperatura máxima ou a mínima, para identificar períodos de temperaturas extremas (Lavaysse et al., 2018). A utilização de ambas as variáveis da temperatura é um dos pontos fortes deste

método, pois tem em conta o impacto das temperaturas noturnas (principalmente a temperatura mínima) durante uma onda de calor. Isto é, durante um período de temperaturas extremamente quentes, em muitas localizações, o calor é armazenado durante o dia e é libertado lentamente durante a noite para o ambiente dificultando a regulação da temperatura interna do corpo humano. Este fator é algo a ter em conta segundo a WMO (World Meteorological Organization & World Health Organization, 2015).

2.2. Métodos de séries temporais aplicados na literatura

Para avaliar a associação entre fatores climáticos e indicadores de saúde, grande parte da literatura utiliza métodos baseados em séries temporais. Um dos métodos utilizados é o estudo temporal da correlação entre variáveis, com base nos coeficientes de Spearman e Pearson (Marques & Antunes, 2009; Huang et al., 2011; Marques, 2007), sendo o segundo aplicado neste trabalho. O principal método consiste na aplicação de diversos modelos como os Modelos Lineares Generalizados (MLG) e os Modelos Aditivos Generalizados (MAL) (Gasparrini & Armstrong, 2010).

A maior parte dos MLG e dos MAL aplicados neste tipo de estudos epidemiológicos consistem numa regressão de Poisson, em que a variável dependente é uma variável de contagem, por exemplo o número de mortes ou de hospitalizações, e as variáveis independentes os níveis das temperaturas. Muitas vezes também são incluídas nestes modelos potenciais variáveis espúria, como as tendências de longo-prazo ou sazonais, a poluição do ar e até variáveis relativas à utilização de ar-condicionado nas habitações (Gasparrini & Armstrong, 2010; Armstrong, 2006; Basu & Malig, 2011). O propósito destes modelos é quantificar a variação do número de ocorrências de um indicador de saúde associada a flutuações das temperaturas.

Apesar da aplicação de regressões de Poisson para dados de contagens ser mais comum, os MLGs também incluem regressões Binomiais Negativas que permitem também estudar este tipo de dados. Por exemplo, em Ranandeh Kalankesh et al., 2015 foram aplicadas regressões Binomiais Negativas para investigar a relação entre a temperatura e a humidade com mortes traumáticas em Kerman, Irão.

No presente estudo estimaram-se MLGs sem desfasamento temporal das variáveis explicativas, mas na literatura existente aplicam-se frequentemente desfasamentos, ou “lags”¹, nas regressões. Estes desfasamentos são utilizados para compreender por quantos dias após a exposição a temperaturas extremas as variáveis de saúde são afetadas (Armstrong, 2006; Huang et al., 2014; Baccini et al., 2008; Basu et al., 2008).

¹ *Lags*: desfasamentos das variáveis preditivas, ou seja, “variáveis passadas no tempo” (Ferreira, 2016)

3. Metodologia

Ao longo deste capítulo está disposta toda a metodologia implementada, desde as áreas geográficas estudadas, às variáveis utilizadas e todo o processo de análise desenvolvido de forma a atingir os objetivos estabelecidos inicialmente.

A presente dissertação está projetada com base nas diferentes Regiões de Saúde (RS) definidas pelo Serviço Nacional de Saúde - SNS. Segundo o Anexo do decreto-lei número 11/93 relativo ao Estatuto do Serviço Nacional de Saúde são cinco as RS em Portugal Continental: Norte; Centro; Lisboa e Vale do Tejo (LVT); Alentejo e Algarve (Figura 3.1.).



Figura 3.1 Regiões de Saúde em Portugal Continental

As variáveis utilizadas neste estudo, são a temperatura máxima e a temperatura mínima. Os dois indicadores de saúde utilizados são a Mortalidade Diária e o Número de Atendimentos em Urgência Hospitalar por Triagem de Manchester.

As temperaturas do ar foram disponibilizadas pelo Instituto Português do Mar e da Atmosfera (IPMA). A partir de um ficheiro com diversas estações meteorológicas, tanto automáticas como manuais, dispersas a nível nacional (Figura 3.2.), foi criada uma estrutura de dados com a média diária das temperaturas mínimas e máximas das estações de cada RS desde 1990 a 2019.

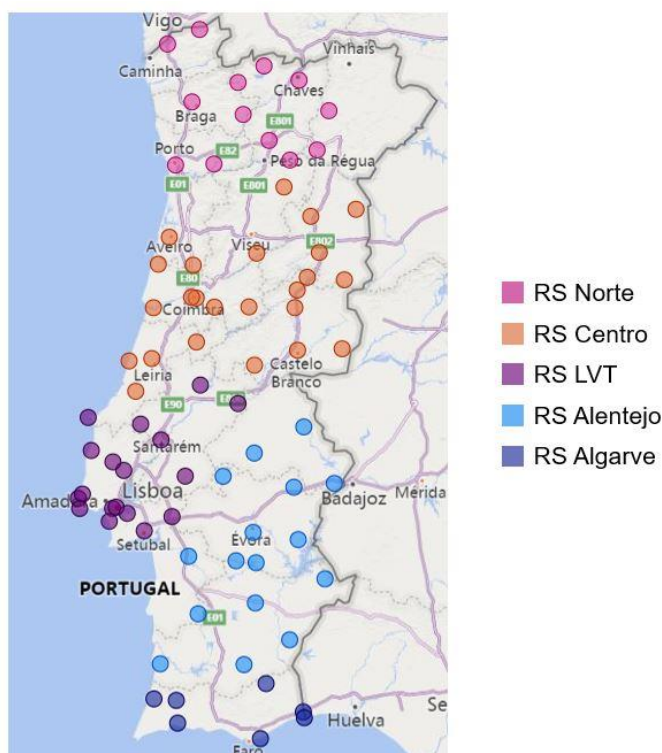


Figura 3. 2. Estações meteorológicas por RS

Quanto aos indicadores de saúde (Tabela 3.1.), a mortalidade diária por RS está disponível *online* no Sistema de informação de Certificados de Óbito (SICO) da Direção Geral da Saúde (DGS), que sustenta o Sistema de Vigilância Eletrónica de Mortalidade em tempo real (eVM). O horizonte temporal analisado é de 2014 a 2021.

Para além da mortalidade diária, também foi investigado o número de atendimentos em urgência hospitalar por triagem de Manchester no período de julho de 2016 a dezembro de 2019. Estes dados foram obtidos a partir do Portal da Transparência da DGS. O sistema de triagem de Manchester, é o sistema utilizado pelos hospitais para determinar a ordem de atendimento das urgências com base no risco clínico que cada paciente apresenta. Existem cinco pulseiras para distinguir os utentes: vermelha, laranja, amarela, verde e azul, sendo esta a ordem da mais urgente para a menos urgente (Serviço de Urgência Geral e a Urgência Pediátrica do Centro Hospitalar de Lisboa Ocidental, 2016; Grupo Português de Triagem, 2021).

Tabela 3. 1 Variáveis da temperatura e indicadores de saúde

Variável	Horizonte Temporal
Temperatura do Ar (máxima e mínima)	1990 - 2019
Mortalidade diária	2014 - 2021
Número de atendimentos em urgência hospitalar por Triagem de Manchester	julho 2017 – dezembro 2021

Sendo o principal objetivo deste estudo quantificar o impacto da temperatura em indicadores de saúde, primeiramente procede-se à análise descritiva de cada uma das variáveis de saúde para melhor compreender estas séries individualmente e identificar possíveis associações com a temperatura do ar. De seguida é realizada uma análise das flutuações significativas da mortalidade e dos atendimentos em urgência hospitalar em períodos de ondas de frio e de calor com base nos critérios estabelecidos na revisão da literatura.

Posteriormente aplicam-se Modelos Lineares Generalizados (MLG) com distribuição Binomial Negativa aos dados da mortalidade diária de cada RS. Nestes a mortalidade diária, é a variável resposta, e as temperaturas mínimas e máximas, as variáveis explicativas. A aplicação destes modelos permite uma análise mais robusta da associação entre flutuações das variáveis climáticas e da mortalidade. Não são utilizados os dados do número de atendimentos em urgência hospitalar por triagem de Manchester devido ao facto de se tratar de séries temporais com apenas 42 observações, um número baixo para desenvolver modelos com qualidade estatística. Toda esta análise é realizada com o recurso ao Microsoft Excel para organização dos dados e software estatístico R para a análise descritiva e aplicação dos modelos MLG.

É importante referir que os anos de 2020 e 2021 são excluídos do estudo das ondas de calor e de frio, como também dos modelos, devido à não existência de informação relativa às temperaturas do ar, e por se tratar de um período irregular no que respeita a dados de saúde relativamente aos anos antecedentes à pandemia Covid-19. Assim a série temporal da mortalidade diária é constituída por 2191 observações.

3.1. Análise descritiva das variáveis

Na análise descritiva das variáveis de saúde são implementadas diversas técnicas estatísticas aplicáveis a séries temporais e realiza-se paralelamente uma análise gráfica. As técnicas utilizadas são a média móvel simples, a análise dos *boxplot* e adicionalmente apenas para a mortalidade diária a decomposição das forças componentes. Primeiramente é analisada a mortalidade diária total em Portugal Continental e posteriormente é feita a análise por RS, de 2014 a 2021. Os atendimentos em urgência hospitalar mensais por triagem de Manchester, de julho de 2016 a dezembro de 2021, são analisados a nível nacional e a nível das RS, mas também discriminadas por tipo de pulseiras.

3.1.1. Aplicação da Média Móvel Simples

Para as diferentes áreas geográficas é realizada a análise dos gráficos das séries originais, e de seguida aplicada uma média móvel simples à série. Uma média móvel simples permite suavizar ou eliminar as oscilações de uma série temporal através do cálculo de médias aritméticas consecutivas (Reis, 2008). Este processo pode ser representado por:

$$SMA = \frac{Y_{n+1-K} + Y_{n+2-K} + \dots + Y_n}{K} \quad (1)$$

Em que Y é a série original, n é a n -ésima observação e K o número de valores sucessivos da série temporal, ou seja, a ordem da MMS. Quanto maior a ordem de K maior será o alisamento aplicado (Reis, 2008). A MMS aplicada é de 62 dias (aproximadamente 2 meses), sendo esta a ordem suficiente para diminuir a variância dos dados e alisar as séries temporais.

3.1.2. Análise dos *Boxplots*

Para cada indicador, de cada RS, e no caso dos atendimentos em urgência hospitalar para cada cor de pulseira, são analisados os *boxplots*, para compreender o comportamento das séries anualmente. A partir desta técnica, também é possível estudar a variabilidade mensal dos dados bem como as respetivas medidas estatísticas e identificar *outliers* (observações anormais relativamente ao resto da série). É de realçar

que este método permite uma comparação entre uma análise com e sem período da pandemia Covid-19.

3.1.3. Decomposição das forças componentes – Modelo Aditivo

As séries temporais podem ser decompostas em quatro forças componentes: a tendência (X_t), a sazonalidade (S_t), a componente cíclica (C_t) e a irregular (I_t). Através desta técnica é possível analisar de forma mais robusta o comportamento de cada série. O modelo aplicado para combinar as diversas componentes é o modelo aditivo (2), sendo este utilizado quando a magnitude das flutuações sazonais não varia consoante o nível da série original (Reis, 2008). Visto que as flutuações sazonais da série da mortalidade diária não variam muito com a tendência considera-se a decomposição aditiva mais apropriada (Mehra, 2017). Sendo Y_t o valor observado na série no período t , este modelo pode ser representado por:

$$Y_t = X_t + S_t + C_t + I_t \quad (2)$$

3.2. Definição dos períodos de ondas de frio e de calor

A definição dos períodos de ondas de calor e de frio é realizada com base na definição descrita na revisão da literatura através do cálculo dos percentis das séries das temperaturas do ar. Utiliza-se o período de referência de 1990 a 2019 para as RS em estudo.

Em primeiro lugar constrói-se uma estrutura de dados com a temperatura máxima e a temperatura mínima para cada dia e para todos os anos do período de referência. Posteriormente, são calculados os percentis 5 e 10 entre outubro e março de todos os anos, visto que, de acordo com a definição anteriormente apresentada, considera-se uma onda de frio um intervalo temporal de pelo menos três dias consecutivos com ambas as temperaturas mínimas e máximas abaixo do percentil 10. Para temperaturas extremas considera-se abaixo do percentil 5. Por outro lado, a definição das ondas de calor é realizada através do cálculo dos percentis 90 e 95 das temperaturas entre abril e setembro de todos os anos.

Nesta análise são identificadas ondas de frio e de calor a partir de julho de 2016 a dezembro de 2019, pois este é o horizonte temporal em que é possível comparar com ambos os indicadores de saúde. Com o intuito de simplificar a análise, apenas foi escolhida uma onda de frio e uma de calor por cada RS com base em 2 critérios: primeiro a onda de frio ou de calor com maior duração é a escolhida; e segundo, caso existam duas ondas com a mesma duração, a escolhida será a que contém mais dias com temperaturas abaixo de percentil 5 para ondas de frio e acima do percentil 95 para ondas de calor.

3.3. Estudo das flutuações dos indicadores de saúde

Nesta etapa, o objetivo é confrontar a mortalidade e o recurso às urgências hospitalares nos períodos de ondas de calor e de frio com os seus períodos homólogos no horizonte temporal de referência. Neste sentido, para cada indicador das diferentes RS determinou-se:

- Média anual dos períodos homólogos;
- Número de ocorrências no período de onda de frio e de calor;
- Variação entre o período em causa e os períodos homólogos;
- Valor máximo diário de ocorrências no período em causa e a respetiva variação relativamente aos períodos homólogos.

O cálculo da variação, Δ , é realizado entre o valor observado e a média, \bar{x} , dos períodos homólogos de acordo com uma dissertação da Escola Nacional de Saúde Pública (Nóbrega, 2018):

$$\Delta = \frac{(n.º \text{ de ocorrências no período de onda de frio ou calor} - \bar{x} \text{ do } n.º \text{ de ocorrências nos períodos homólogos})}{\bar{x} \text{ do } n.º \text{ de ocorrências nos períodos homólogos}} \quad (3)$$

É de realçar, que para a mortalidade é possível calcular a variação do valor máximo diário, pois é um indicador com periodicidade diária, para o número de atendimentos em urgência hospitalar mensais por triagem de Manchester este exercício, apenas foi possível comparar o mês em que ocorreu a onda de frio ou de calor.

3.4. Processo de modelação e interpretação da informação

Para compreender melhor a possível associação entre a mortalidade diária e as flutuações das temperaturas do ar, procede-se à construção de Modelos Lineares Generalizados (MLG).

3.4.1. Modelos Lineares Generalizados

Os Modelos Lineares Generalizados (MLGs), apresentados por Nelder e Wedderburn em 1972 são compostos por uma componente aleatória e uma componente sistemática (Nelder & Wedderburn, 1972).

A componente aleatória é determinada através da escolha da distribuição de probabilidade, sendo esta sugerida pela variável resposta ou pela inferência de como a variância se altera com a média. Os MLGs assumem que a variável dependente Y (resposta) segue uma distribuição pertencente à *família de modelos de dispersão exponencial*, ou seja, a variável resposta pode assumir ou não uma distribuição Normal (Dunn & Smyth, 2018).

Relativamente à componente sistemática, esta é sugerida pela forma como as variáveis explicativas (X) se relacionam com a média da variável resposta (μ_Y). Ou seja, os MLGs recorrem a um preditor linear, η , (4):

$$\eta = \beta_0 + \sum_{j=1}^p \beta_j x_j \quad (4)$$

em que, β_j são os parâmetros do modelo, x_j as variáveis explicativas, e j o j -ésimo parâmetro. Este preditor linear apresenta-se ligado à média da variável resposta μ_Y , através de uma função de ligação $g()$, demonstrando que os MLGs exibem uma estrutura de regressão linear em termos de parâmetros (Dunn & Smyth, 2018):

$$g(\mu_Y) = \eta = \beta_0 + \sum_{j=1}^p \beta_j x_j \quad (5)$$

Relativamente aos parâmetros β_j , estes são estimados através da Máxima Verosimilhança (Turkman & Silva, 2000).

Nos MLGs estimados a variável resposta segue uma distribuição Binomial Negativa, sendo esta aplicável a dados de contagens. Estes modelos são frequentemente chamados de regressão Binomial Negativa (James et al., 2013; Dunn & Smyth, 2018; Kabacoff, 2011).

3.4.2. Formulação dos modelos

Previamente à estimação dos modelos são estudadas as correlações entre as variáveis. Para tal foram construídos correlogramas com base no coeficiente de correlação de Pearson, r , que indica o grau de associação linear entre duas variáveis quantitativas (Reis, 2008). Esta medida produz um resultado entre -1 e 1, em que, -1 traduz uma correlação perfeita negativa e 1 uma correlação perfeita positiva. Esta medida pode ser expressa por:

$$r = \frac{n \sum X_i Y_i - \sum X_i \sum Y_i}{\sqrt{[\sum X_i^2 - (\sum X_i)^2][n \sum Y_i^2 - (\sum Y_i)^2]}} \quad (6)$$

Em que X e Y são variáveis quantitativas, i a i -ésima observação, e n o tamanho da amostra (Reis, 2008).

Nesta mesma fase é analisada a distribuição dos dados da mortalidade diária, através do estudo dos histogramas das séries e dos coeficientes de assimetria, das RS. O coeficiente de assimetria, γ_Y , mede a simetria de uma variável. Caso $\gamma_Y < 0$, a distribuição é assimétrica negativa, e caso $\gamma_Y > 0$, a distribuição é assimétrica positiva (Yau, 2009). Visto que os dados em causa são contagens, à priori assume-se a não-normalidade dos mesmos, justificando-se o uso de MLGs com distribuições discretas próprias para dados de contagens.

3.4.3. Modelos Lineares Generalizados para dados de contagens

Quando a variável resposta são observações de contagens, ou seja, números inteiros positivos, é possível aplicar MLGs através de regressões com base em distribuições discretas (não normais). As distribuições mais comuns para construir modelos com este tipo de resposta são a distribuição de Poisson e a distribuição Binomial Negativa (Faraway, 2006; Dunn & Smyth, 2018). Ambas as regressões de Poisson e Binomial Negativa são MLGs com uma função de ligação logarítmica, representado da seguinte forma:

$$\log(\mu_Y) = \beta_0 + \sum_{j=1}^p \beta_j x_j \quad (7)$$

onde, μ_Y é a média de Y , a variável resposta que segue uma distribuição Poisson ou Binomial Negativa, β_j são os parâmetros do modelo, x_j as variáveis explicativas, e j o j -ésimo parâmetro (Kabacoff, 2011).

A grande diferença entre a aplicação de uma regressão de Poisson e uma regressão Binomial Negativa é que a distribuição de Poisson implica que a média da variável resposta seja igual à sua variância, enquanto a distribuição Binomial Negativa permite que a variância seja superior à média (Faraway, 2006; Rodríguez, 2013). Caso a média seja inferior à variância ocorre sobredispersão caso contrário existe subdispersão (Dunn & Smyth, 2018), sendo o primeiro caso mais frequente que o segundo (Dunn & Smyth, 2018; Kabacoff, 2011). No presente estudo, lida-se com a existência de sobredispersão, assim o foco nesta etapa é encontrar uma solução para lidar com dados desta natureza.

A sobredispersão pode afetar os parâmetros estimados $\hat{\beta}_j$ visto que produz desvios-padrão dos parâmetros subestimados. Assim, os testes às variáveis explicativas devolvem resultados mais significativos do que os dados justificam (Dunn & Smyth, 2018), levando a conclusões inválidas. Normalmente, os intervalos de confiança da regressão Binomial Negativa são maiores relativamente aos da regressão de Poisson (UCLA, 2013). A existência de sobredispersão pode ser causada pela omissão de uma variável explicativa importante, mas também devido ao facto de se assumir a

independência entre observações, o que muitas vezes não é o que se verifica (Kabacoff, 2011). Na secção seguinte encontra-se a forma utilizada para modelar sobredispersão.

3.4.4. Regressão Binomial Negativa

A regressão Binomial Negativa pode ser considerada uma generalização da regressão de Poisson, no sentido em que apresentam a mesma estrutura da média, mas exibem adicionalmente um parâmetro para modelar a sobredispersão (UCLA, 2013). Ou seja, a regressão Binomial Negativa tem como base uma regressão de Poisson e adicionalmente uma variável aleatória não observável θ de forma a representar a heterogeneidade não observada. Este modelo postula que a distribuição da variável resposta Y dado uma variável não observável θ é uma distribuição de Poisson com média e variância $\mu\theta$ (Rodríguez, 2013; Venables & Ripley, 2002):

$$Y|\theta \sim P(\mu\theta) \quad (8)$$

Caso $\theta > 1$, significa que o modelo conseguiu capturar fatores não observados. O parâmetro θ segue uma distribuição *gamma* (α, ψ), com média α/ψ e variância α/ψ^2 , assim, com $\alpha = \psi = 1/\sigma_\theta^2$, a média do efeito não observável é igual a 1 e a sua variância σ_θ^2 (Rodríguez, 2013). Por sua vez, a variância do efeito não observável é igual ao inverso do parâmetro θ (Venables & Ripley, 2002):

$$\sigma_\theta^2 = \frac{1}{\theta} \quad (9)$$

Com base nestes pressupostos define-se a média e a variância de Y da seguinte forma (Rodríguez, 2013; Venables & Ripley, 2002):

$$E(Y) = \mu, \quad var(Y) = \mu + \frac{\mu^2}{\theta} \quad (10)$$

Relativamente ao parâmetro θ , este foi estimado através do método de Máxima Verosimilhança de acordo com estudos realizados, com recurso ao Software R (Venables & Ripley, 2002; Dunn & Smyth, 2018). Quanto maior for o parâmetro θ , menor será a variância de Y , e nesse sentido, a distribuição da variável resposta aproximar-se-á à

distribuição Poisson. Ou seja, quanto maior o parâmetro θ , maior a heterogeneidade não observável capturada (Rodríguez, 2013).

Aplicando a regressão Binomial Negativa formula-se o seguinte modelo:

$$\log(\mu_{n.º \text{ de óbitos diários}}) = \beta_0 + \beta_1 Tmín + \beta_2 Tmáx \quad (11)$$

em que $Tmín$ é a temperatura mínima, $Tmáx$ a temperatura máxima e ε os resíduos do modelo.

3.4.5. Avaliação da qualidade das regressões de Binomiais Negativas

Para avaliar a qualidade dos MLGs são utilizados vários métodos para inferir quanto ao seu ajustamento. Em primeiro lugar realiza-se um Teste de ajustamento de χ^2 e de Pearson, e posteriormente é realizada uma análise gráfica dos *Quantile-Quantile Plots* dos resíduos.

3.4.5.1. Teste de ajustamento χ^2 e de Pearson

O Teste de ajustamento com estatística χ^2 e de Pearson tem como hipótese nula a adequação do modelo aos dados, ou seja, que os dados seguem a distribuição especificada (Dunn & Smyth, 2018). Caso o desvio residual, isto é, a diferença entre o desvio do modelo em estudo e o desvio máximo do modelo ideal em que a previsão é idêntica aos valores reais, e a estatística de teste de Pearson sejam superiores ao valor χ^2 que tem em conta os graus de liberdade residuais (valor tabelado), existe evidencia estatística de que os dados não se aproximam da distribuição especificada e por isso o modelo não apresenta um bom ajustamento (Dunn & Smyth, 2018).

3.4.5.2. Análise dos *Quantile-Quantile Plots* dos resíduos

Com vista a completar esta análise, são estudados os *Quantile-Quantile Plots* (*Q-Q Plots*) dos resíduos. Estes gráficos evidenciam se dois tipos de amostras seguem a mesma distribuição, uma amostra teórica/simulada (eixo x) e a amostra que se modelou (eixo y) (Ben & Yohai, 2004). Os *Q-Q plots* são uma ferramenta comum para avaliar se

a distribuição do modelo se aproxima à distribuição especificada. Se os pontos destes gráficos, os resíduos do modelo e uma amostra simulada, formarem uma linha linear diagonal a distribuição do modelo aproxima-se da distribuição em causa (Ben & Yohai, 2004).

3.4.6. Método de interpretação dos dados

Os modelos estudados são modelos com uma função de ligação logarítmica, em que o número médio de ocorrências μ_Y aparece em logaritmos e X em níveis (Roback & Legler, 2021). Desta forma, a interpretação dos coeficientes, baseia-se em taxas de variação. Normalmente, interpreta-se os coeficientes da regressão na escala original da variável resposta, sendo isto possível através da exponencial dos coeficientes, ou seja:

$$\mu_Y = \exp(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_i x_j) \quad (12)$$

$$= \exp \beta_0 \times (\exp \beta_1)^{x_1} \times (\exp \beta_2)^{x_2} \times \dots \times (\exp \beta_j)^{x_j} \quad (13)$$

Esta transformação da regressão original conduz a que o impacto de cada variável explicativa seja multiplicativo, e assim o aumento de uma unidade de x_j leva ao aumento de (aproximadamente) μ_Y por $(\exp \beta_j)$ vezes (Dunn & Smyth, 2018).

3.4.7. Introdução de variáveis quadráticas

Com vista a melhorar o ajustamento do modelo, e assim o seu poder explicativo, são adicionados dois termos quadráticos da temperatura mínima e máxima. Em geral, a introdução de variáveis de segundo grau num modelo permite modelar curvaturas com um ponto de inversão (Kabacoff, 2011). A inclusão destas variáveis é normalmente sugerida pela forma como os dados originais se comportam, mas também através dos gráficos “*Residuals versus Fitted*”, que apresentam os resíduos no eixo y e as respostas estimadas no eixo x, permitindo detetar não-linearidade (Roback & Legler, 2021; 4.2 - *Residuals vs. Fits Plot / STAT 462*, 2018). Caso estes gráficos apresentem uma forma curvilínea é indicativo que a inclusão de variáveis quadráticas poderá melhorar a qualidade do modelo (Draper & Smith, 1998; Roback, 2021). A nova regressão formulada pode ser representada da seguinte forma:

$$\log(\mu_{n.º \text{ de óbitos diários}}) = \beta_0 + \beta_1 Tmín + \beta_2 Tmáx + \beta_3 Tmín^2 + \beta_4 Tmáx^2 \quad (14)$$

Em que $Tmín^2$ e $Tmáx^2$ são os termos quadráticos das temperaturas mínimas e máximas, respetivamente.

3.4.8. Comparação entre regressões Binomiais Negativas de primeiro e de segundo grau

Após a estimação dos modelos com variáveis de segundo grau, é necessário comparar aos modelos de primeiro grau, os modelos restringidos, estimados anteriormente. Esta avaliação é realizada com base em três critérios, primeiro no resultado dos testes-T para a significância individual das variáveis, em que caso o $p\text{-value} < 0.05$ significa que existe evidência estatística de que a variável é individualmente significativa (Ferreira, 2016; Roback & Legler, 2021). Outro critério utilizado foi o AIC, apresentado na Secção 3.4.8.1. Por fim foi realizado um Teste de razão de verosimilhança descrito na Secção 3.4.8.2..

3.4.8.1. Akaike's Information Criterion (AIC)

A aplicação do critério AIC para a seleção do melhor modelo é bastante importante, pois esta medida quantifica o *trade-off* entre o número de parâmetros incluído num modelo e o aumento do erro do mesmo (Mattheakis & Protopapas, 2018). O critério AIC pode ser definido como:

$$AIC = -2 \text{ maximum log likelihood} + 2p \quad (15)$$

Em que p é o número de parâmetros do modelo (Faraway, 2006).

Assim, o modelo com o menor AIC é aquele com maior poder explicativo e com o melhor ajuste dos dados (Turkman & Silva, 2000).

3.4.8.2. Teste de Razão de Verosimilhança

O teste de Razão de Verosimilhança é utilizado para comparar o ajustamento do modelo global (com as novas variáveis) com o do restringido (apenas com T_{\min} e T_{\max}) (Roback & Legler, 2021). Para testar se os dois modelos são significativamente diferentes quanto à sua qualidade explicativa, este teste baseia-se nas seguintes hipóteses:

H_0 : Não existe diferença significativa quanto ao ajuste de ambos os modelos, logo deve-se utilizar o modelo restringido. (16)

H_1 : Existe diferença significativa quanto ao ajuste de ambos os modelos, logo deve-se utilizar o modelo global.

Caso o $p\text{-value} < 0,05$, existe evidência estatística de que se deve rejeitar H_0 (Roback & Legler, 2021).

3.4.9. Métodos de interpretação das regressões quadráticas

A interpretação das novas regressões estimadas tem de ser realizada de uma forma diferente da interpretação das regressões de primeiro grau, devido à presença de termos quadráticos. Isto acontece porque as variáveis explicativas passam a estar associadas a dois parâmetros β_j , um para o termo linear e outro para o termo quadrático, impossibilitando a típica interpretação de como varia a variável resposta quando uma variável explicativa aumenta ou diminui uma unidade (Ferreira, 2016). Para interpretar o modelo é necessário utilizar o conceito de derivada. A partir do modelo já formulado, e mantendo o resto constante (Ferreira, 2016):

$$\frac{\partial \log(\mu_Y)}{\partial X} = \hat{\beta}_1 + 2\hat{\beta}_3 X \quad (17)$$

Através desta expressão evidencia-se que a variação de Y depende do valor verificado para X:

$$\frac{\Delta \log(\hat{\mu}_Y)}{\Delta X} \approx \hat{\beta}_1 + 2\hat{\beta}_3 X \quad (18)$$

simplificando:

$$\Delta \log (\hat{\mu}_Y) \approx (\hat{\beta}_1 + 2\hat{\beta}_3 X)\Delta X \quad (19)$$


O sinal do parâmetro do termo linear indica a direção da relação entre a parte dependente e a independente da expressão, ou seja, se a relação é positiva ou negativa, enquanto o sinal do parâmetro do termo quadrático indica a concavidade da relação (Ferreira, 2016).

4. Análise descritiva dos indicadores de saúde

Nesta Secção encontra-se uma análise descritiva da mortalidade diária total e por RS, bem como do número de atendimentos em urgência hospitalar por RS e por triagem de Manchester. Nesta etapa pretende-se perceber como os indicadores de saúde variam ao longo do horizonte temporal, mas principalmente o seu comportamento anual, de forma a encontrar possíveis associações com as flutuações da temperatura ao durante o ano.

4.1. Mortalidade Diária

Analisando a mortalidade diária no horizonte temporal de 2014 a 2019 (Figura 4.1.), é possível observar que esta apresenta um comportamento sazonal/cíclico. Na primeira metade de cada ano o número de óbitos decresce, invertendo-se esta tendência até ao fim do mesmo. É importante a associação deste fenómeno com as diferentes estações do ano. Verifica-se através da observação da série temporal que os picos positivos mais elevados ocorrem na época invernal, e os picos negativos na época estival, o que sugere uma relação associativa entre a mortalidade e a temperatura do ar.



Na Tabela 4.1. observa-se que o ano que atingiu maior número de óbitos entre 2014 e 2019 foi 2017, com 550 mortos a 2 de janeiro. No período de 2020 a 2021, devido à pandemia da Covid-19, a mortalidade assumiu valores bastante irregulares. Nesse período, o pico absoluto positivo foi atingido logo no início do ano 2021, a 22 de janeiro

com 727 mortes. O ano com maior mortalidade média diária foi 2021 com aproximadamente 327 óbitos por dia, de seguida 2020 com cerca de 323, por sua vez 2018 com um valor próximo de 296. Os anos com uma menor média diária de óbitos foram 2014 com cerca de 273, e 2015 com sensivelmente 281 mortos.

Tabela 4. 1 Valor Mínimo, Médio e Máximo da mortalidade diária total, por ano

Ano	Mínimo	Média	Máximo
2014	184	273	377
2015	185	281	479
2016	207	288	457
2017	200	287	550
2018	214	296	493
2019	217	293	470
2020	234	323	457
2021	208	327	727

Para conseguir uma melhor visualização dos dados, e um melhor entendimento sobre o seu comportamento, aplica-se uma média móvel simples para um período de 62 dias, aproximadamente 2 meses, para suavizar a série temporal. A partir da Figura 4.2. observa-se que desde 2016 que ocorre um ligeiro aumento da mortalidade a meio de cada ano, na época estival. Este fenómeno evidencia a possível associação positiva entre a mortalidade e a temperatura do ar.




Figura 4. 2. Mortalidade Diária total (2014-2021) – MMS62

Posteriormente, faz sentido analisar dois *boxplots* que exibem os dados da mortalidade diária organizados por meses homólogos, o primeiro considerando o período entre 2014 e 2019, e o segundo considerando o adicionalmente período da pandemia, entre 2020 e 2021 (Figura 4.3.). A partir de ambos, é possível verificar a mortalidade diária é mais acentuada no inverno, nos meses de janeiro, fevereiro, novembro e dezembro decrescendo até aos meses da altura do verão: junho, julho, agosto, e setembro, que são os meses que apresentam menor número de óbitos diário. Quanto à variabilidade dos dados, os meses que apresentam uma maior variação são aqueles com maior mortalidade (janeiro, fevereiro, novembro e dezembro), com intervalos interquartílicos superiores. Por outro lado, junho, julho, agosto e setembro, são os meses que apresentam menor dispersão. É de realçar que agosto apresenta uma maior variabilidade nos dados relativamente ao seu mês predecessor e sucessor.

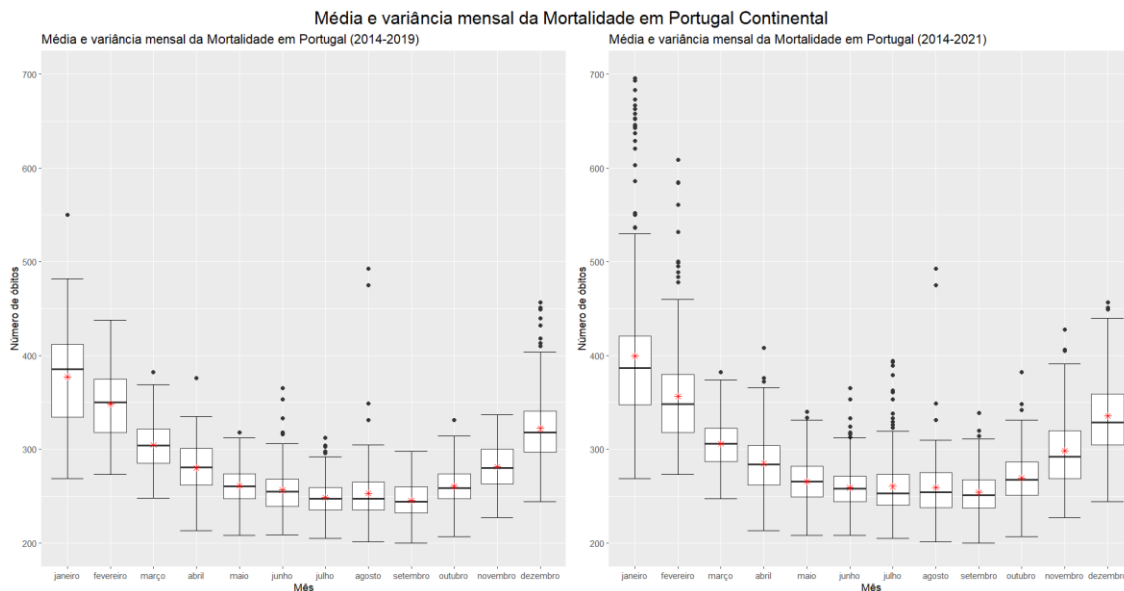


Figura 4. 3. Média e variância mensal da mortalidade diária total (2014-2019 VS 2014-2021)

A partir da Figura 4.3. é possível verificar que a grande diferença entre os dois *boxplots*, é que o segundo, referente ao período 2014 a 2021, apresenta uma dispersão mensal inferior relativamente ao primeiro, referente ao período de 2014 a 2019. No entanto, é evidente que o número de *outliers* no segundo *boxplot* é superior ao número de *outliers* do primeiro *boxplot*. A diferença do número de *outliers* é explicada pelos dois anos afetados pela pandemia Covid-19. Esta disparidade faz com que a variabilidade das caixas de bigodes de cada mês decresça. Destaca-se que discrepância de *outliers* é mais significativa nos meses de janeiro e fevereiro. Apesar das diferenças entre os dois

boxplots, é possível afirmar a possível relação associativa entre a mortalidade diária e a temperatura do ar é traduzida de uma forma muito semelhante.

Em ambos os *boxplot* o mês de janeiro é o que apresenta uma maior dispersão, e uma média e mediana superior relativamente a todos os outros meses, seguindo-se o mês de fevereiro e dezembro. Por outro lado, os meses que apresentam menor dispersão, são em ambos os *boxplot* meses da época estival, sendo que no primeiro *boxplot* o mês com menor variabilidade é o mês de julho e no segundo o mês de setembro. É de realçar que independentemente da consideração ou não do período da pandemia Covid-19, o mês de setembro foi aquele que apresentou uma menor média.

4.1.1. Análise descritiva da Mortalidade por Região de Saúde

Ao analisar a mortalidade diária por RS, verifica-se com clareza a existência de um comportamento cíclico/sazonal nas diferentes RS. Nas RS Algarve os dados exibem uma variância superior relativamente à restantes RS, ou seja, trata-se de uma série temporal mais “ruidosa” (Figura 4.4.).

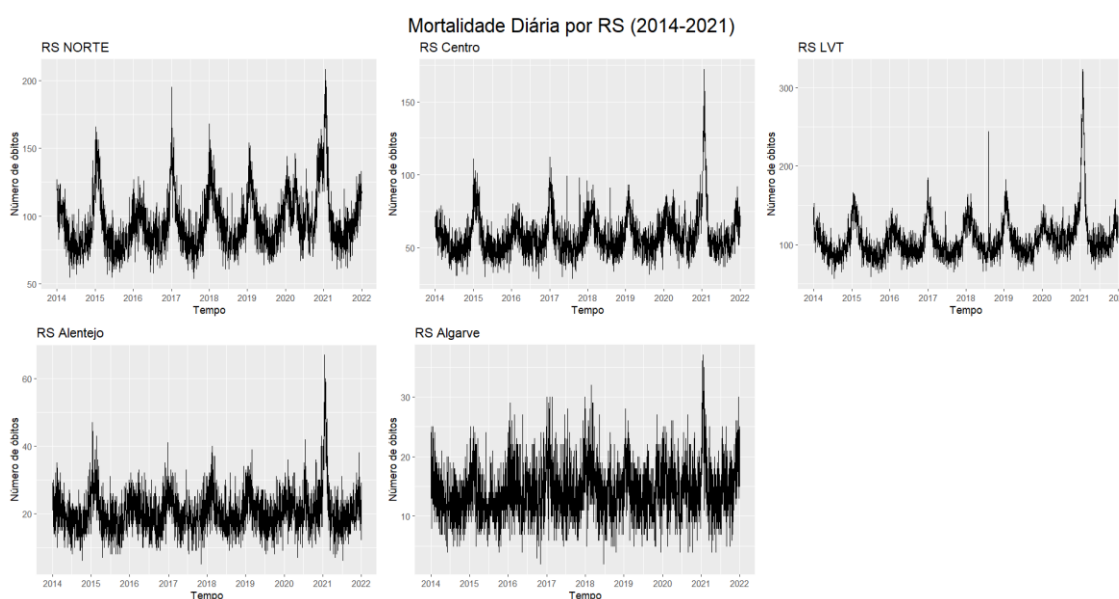


Figura 4. 4. Mortalidade Diária por RS (2014-2021)

Quanto à mortalidade média diária, a RS LVT e a RS Norte são as RS que apresentam um maior número médio de óbitos diários com um valor de 107 e 96, respetivamente. Estes valores estão de acordo com o facto de serem as regiões com maior população de Portugal. No entanto, a RS Alentejo é a que exibe um maior número óbitos

por milhão de habitantes, com um valor de 43, de seguida a RS Centro, Algarve, LVT e Norte (Tabela 4.2.).

Tabela 4. 2. Mortalidade média diária e mortalidade média diária por milhão (2014-2021)

RS	População Residente	Mortalidade média diária	Mortalidade média diária por milhão de habitantes
Norte	3.688.037	96	26
Centro	1.640.831	58	35
LVT	3.705.326	107	29
Alentejo	469.928	20	43
Algarve	467.112	14	30

Fonte: Dados da população residente obtidos através de (*População Residente: Total E Por Grandes Grupos Etários, 2022*)

De seguida, é aplicada uma média móvel simples a 62 dias (2 meses) para suavizar as séries temporais e observar com maior facilidade sua sazonalidade. A partir da Figura 4.5., verifica-se que se obtêm séries temporais menos irregulares, no entanto, a RS do Algarve continua a exibir um comportamento “ruidoso”, que pode ser causado pela elevada granularidade dos dados, e também pela elevada variabilidade destes.

Outro ponto importante é de que em todas as RS ocorre um ligeiro aumento da mortalidade diária entre cada pico positivo extremo de cada ano, ou seja, aumenta a meio do ano na altura do verão. Ao observar os picos absolutos positivos, é possível verificar que o mais baixo de todos os anos foi em 2016, sendo esta uma afirmação verdadeira transversal a todas as RS.




Figura 4. 5. Mortalidade diária por RS (2014-2021) – MMS62

Com o intuito de compreender a mortalidade organizada por meses homólogos por RS, são analisados os *boxplots* dos dados (Figura 4.6.). Observa-se que nos meses de janeiro, fevereiro, novembro e dezembro, ou seja, na época invernal, a média diária da mortalidade é superior bem como a variabilidade dos dados relativos a estes meses. Por outro lado, nos meses de junho, julho, agosto e setembro, o número médio de óbitos é inferior tal como a variabilidade dos dados destes meses.

De entre todas as RS, a região de LVT foi a que apresentou na sua generalidade dados mensais com menor dispersão, enquanto a RS Algarve é a que exibiu uma maior dispersão dos valores. É de realçar que a RS do Algarve apresenta um fenómeno que não se destaca tanto nas restantes RS, que é o facto de os valores da média da mortalidade diária aumentarem substancialmente em julho e agosto, meses que acabam por apresentar uma maior variabilidade.

As RS do Centro e a RS LVT foram as que exibiram um maior número de *outliers* em janeiro, o que pode ser explicado pelo facto de terem sido as que mais contribuíram para o elevado número de óbitos no pico da pandemia em janeiro de 2021.

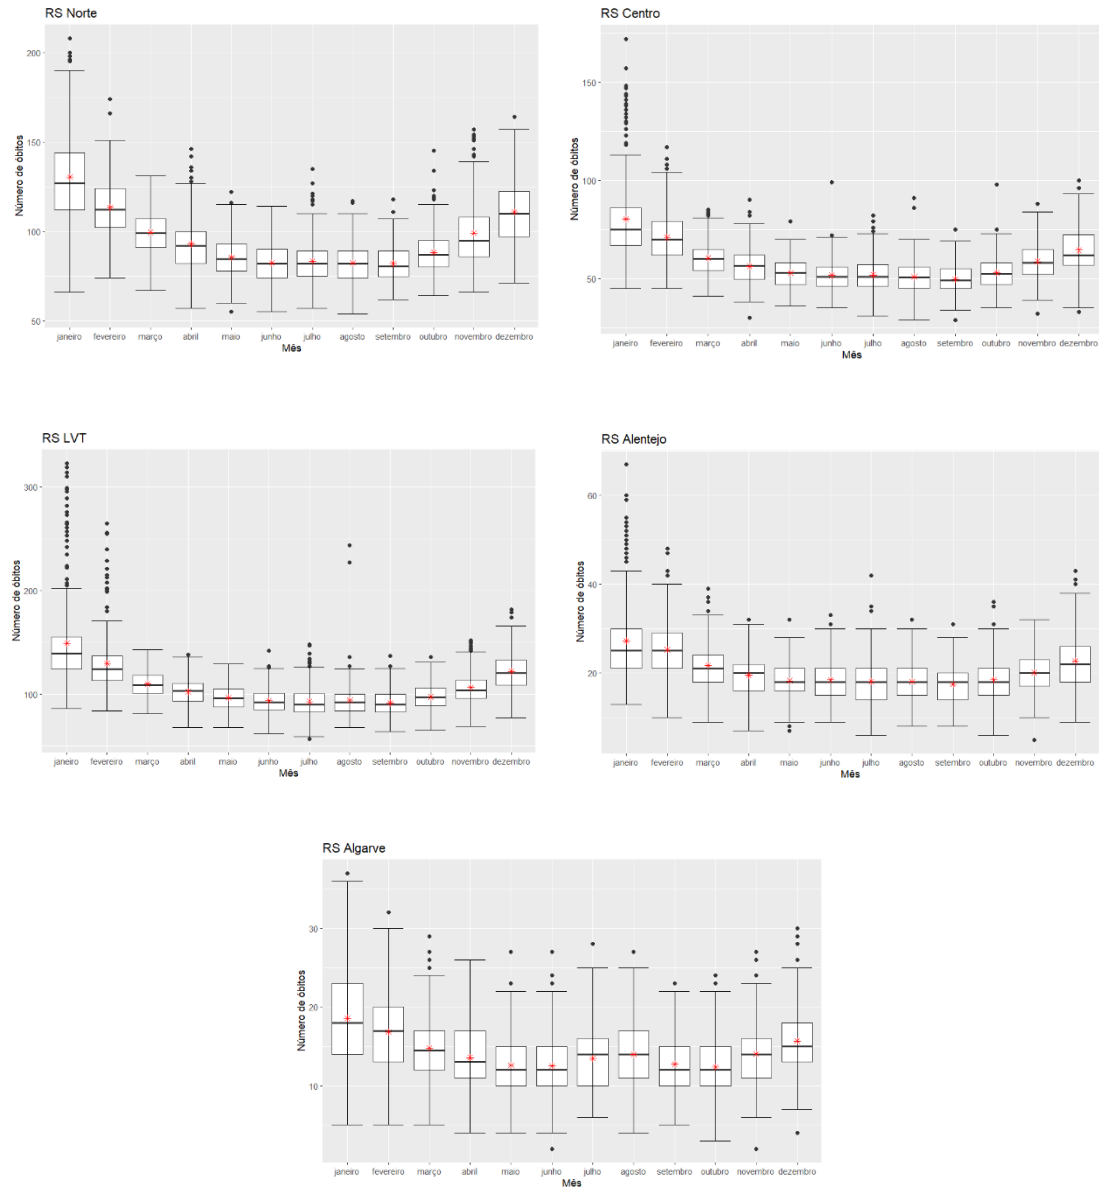


Figura 4. 6. Boxplots da Mortalidade Diária (2014-2021)

Seguidamente recorre-se à decomposição das forças componentes (Figura 4.7.), através do método aditivo, para compreender o comportamento da série de uma forma mais robusta. Com base neste processo é possível confirmar o comportamento sazonal da mortalidade em todas as RS. No Norte, Centro e LVT a tendência mostra-se ligeiramente positiva até 2020. A partir desse ano a tendência torna-se mais acentuada. Na RS Alentejo, antes da pandemia a tendência mostra-se relativamente constante até que com o impacto da pandemia a tendência torna-se bastante mais positiva. É de realçar que em todas as RS dá-se uma depressão da tendência sensivelmente entre a segunda metade do ano 2015 e a

primeira metade de 2016 , o que vai de acordo com a diminuição da mortalidade em 2016 anteriormente referida.

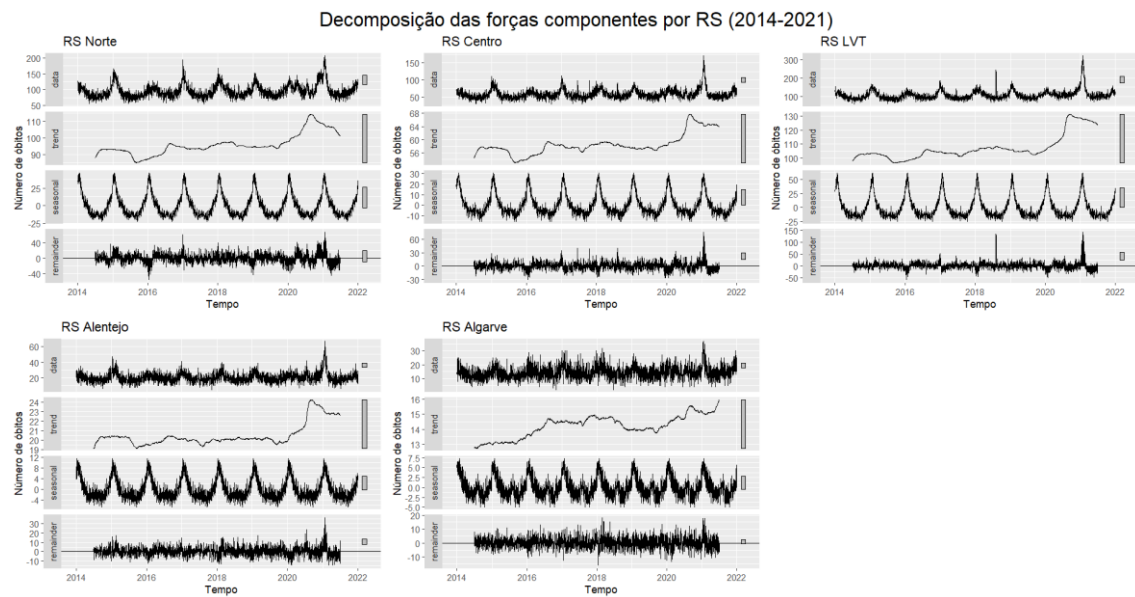


Figura 4. 7. Decomposição das forças componentes por RS (2014-2021)

4.2. Atendimentos em urgência hospitalar por triagem de Manchester

Os atendimentos em urgência hospitalar, na RS Norte e na RS LVT foram superiores às restantes RS ao longo de julho de 2016 até ao fim de 2021. De seguida, foram as RS Centro, Algarve e por fim a RS Alentejo. Esta ordem faz sentido visto que é semelhante à ordem decrescente de número de residentes nestas regiões, com a diferença de que a RS Alentejo tem uma população maior que a RS Algarve (Figura 4.8.).

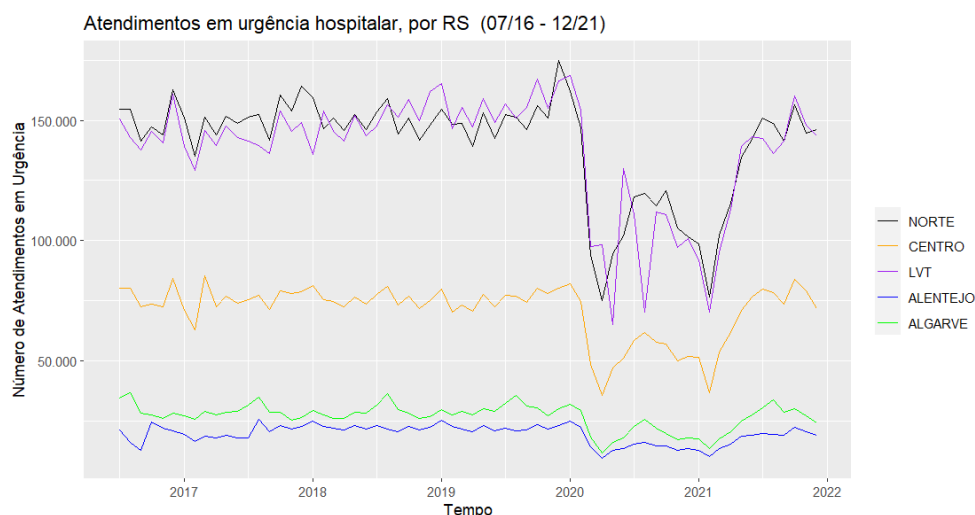


Figura 4. 8. Atendimentos em urgência hospitalar, por RS (07/16-12/21)

Relativamente ao período pré-pandemia Covid-19, ou seja, até 2020, as médias de atendimentos em urgência hospitalar mensal nas RS Norte e de LVT foram bastante próximas, assumindo um valor de 140.000 e 137.877 ocorrências, respetivamente. A RS Centro teve em média 70.977 ocorrências mensais, enquanto o sul de Portugal apresentou valores muito menores próximos das 20.000 ocorrências. Verifica-se que a RS Centro e Algarve foram as que apresentaram maior número de atendimentos em urgência hospitalar mensal por milhão com um valor de 43.257 e 42.883, respetivamente.

No período afetado pela Covid-19, ocorreu um decréscimo muito grande da procura dos atendimentos nas unidades de urgência. Ao longo de 2021 essa tendência reverteu-se.

Tabela 4. 3. Média mensal do número de atendimentos em urgência hospitalar e número de atendimentos em urgência hospitalar mensal por milhão, por RS (07/16-12/19)

RS	População Residente	Média mensal do número de atendimentos em urgência hospitalar	Número de atendimentos em urgência hospitalar mensal por milhão
Norte	3.688.037	140.000	37.961
Centro	1.640.831	70.977	43.257
LVT	3.705.326	137.877	37.210
Alentejo	469.928	19.650	41.815
Algarve	467.112	20.031	42.883

Fonte: Dados da população residente obtidos através de (*População Residente: Total e por Grandes Grupos Etários, 2022*)

Ao observar os *boxplots* do total de atendimentos em urgência hospitalar por triagem de Manchester incluindo o período da pandemia (Figura 4.9.), é possível verificar

que, consoante a cor da pulseira, estas exibem comportamentos sazonais diferentes ao longo de um ano. As pulseiras associadas a ocorrências mais graves, como a pulseira vermelha e laranja exibem um comportamento em forma de U, ou seja, são mais frequentes nos meses de janeiro, fevereiro, novembro e dezembro.

Os atendimentos urgências com pulseira amarela e verde, decrescem até abril revertendo-se a tendência até agosto. A partir dos mês de agosto, apresentam uma tendência alternada entre positiva e negativa, no entanto, com pouca amplitude entre as médias até dezembro. Apesar de a pulseira laranja apresentar um comportamento parecido a este claramente os meses invernais destacam-se com médias e variâncias superiores.

A pulseira azul, tem um comportamento contrário ao das restantes pulseiras, sendo que o maior número médio de ocorrências se deu nos meses de verão, e mais precisamente em agosto. Por outro lado, os meses de inverno (janeiro, fevereiro, novembro e dezembro) exibem menor número médio de atendimentos em urgência hospitalar com pulseiras azuis.

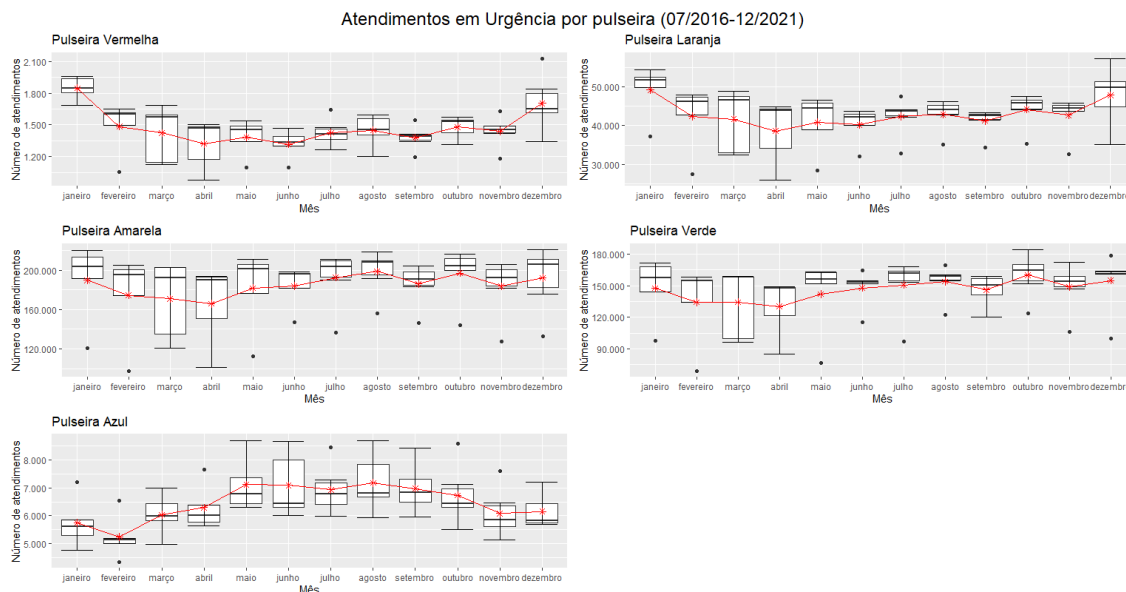


Figura 4.9. Boxplots dos atendimentos em urgência hospitalar por triagem de Manchester (07/16-12/2021)

Não considerando os anos da pandemia (Figura 4.10.), observa-se que as pulseiras vermelhas e laranjas apresentaram um formato em U mais acentuado relativamente ao *boxplot* que incluía 2020 e 2021, destacando-se os meses de janeiro e dezembro. As pulseiras amarelas e verdes exibiram uma tendência alternada entre negativa e positiva ao longo do ano, exceto entre julho e agosto em que as médias mensais se mantiveram

praticamente constantes. Os meses com mais pulseiras amarelas e verdes são os meses de outubro e dezembro. As pulseiras azuis exibem uma tendência decrescente entre janeiro e fevereiro, no entanto, nos meses mais quentes apresentam um aumento generalizado do número médio de ocorrências, voltando a decrescer mais acentuadamente a partir de outubro até dezembro. Os meses com mais pulseiras azuis são julho e agosto.




Figura 4. 10. Boxplots dos atendimentos em urgência hospitalar por triagem de Manchester (07/16-12/2019)

A partir da análise das séries temporais por RS e por pulseira (Figura 4.11. e Tabela 4.4.) é possível observar que a RS Algarve foi a região com menor percentagem de pulseiras vermelhas, enquanto nas restantes RS este tipo de pulseira foi de aproximadamente 0,4%. A RS Algarve foi a que exibiu maior frequência de atendimentos com pulseiras laranjas (14,6%) relativamente às restantes regiões.

A RS Norte e a RS Centro apresentaram o mesmo peso de pulseiras amarelas (53,6%). Em todas as RS, exceto a RS LVT, a pulseira amarela foi a que exibiu maior número de atendimentos em urgência hospitalar. Na RS LVT a pulseira verde foi a pulseira predominante.

Relativamente às pulseiras azuis, a RS LVT apresentou uma maior percentagem com o valor de 2%. Com isto pode-se concluir que na RS LVT as pulseiras com menor urgência são mais frequentes que nas restantes regiões. Contrariamente, as RS Norte e Centro foram as regiões que demonstram uma maior percentagem de atendimentos em urgência hospitalar com pacientes em estados mais graves (pulseira amarela, laranja e vermelha), um valor de 65,2%.

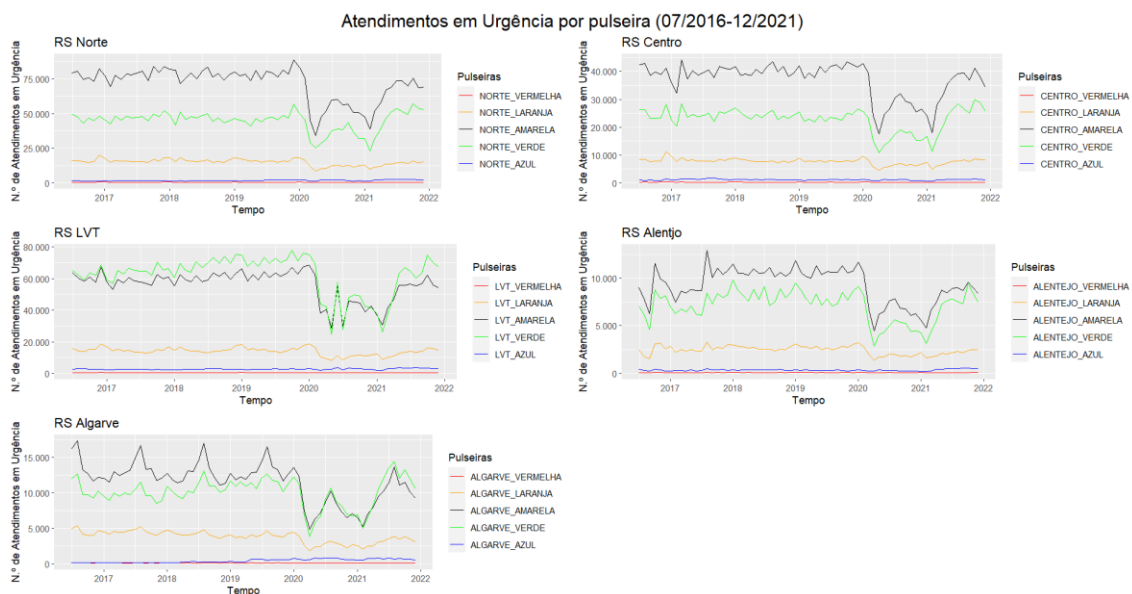


Figura 4. 11. Atendimentos em urgência hospitalar por triagem de Manchester, e por RS (07/16-12/2021)

Tabela 4. 4. N.º de Atendimentos em urgência por triagem de Manchester, e por RS (07/16-12/2021)

RS	P. vermelha (%)	P. laranja (%)	P. amarela (%)	P. verde (%)	P. azul (%)
RS Norte	0,4	11,3	53,6	33,4	1,4
RS Centro	0,4	11,2	53,6	33,1	1,7
RS LVT	0,4	10,3	41,4	45,9	2,0
RS Alentejo	0,4	12,7	48,1	37,1	1,7
RS Algarve	0,3	14,6	44,7	38,9	1,5

5. Análise estatística dos períodos de ondas de calor e de frio

5.1. Identificação de ondas de calor e de frio

Tendo como referência temporal 1990 a 2019, procede-se à identificação dos períodos de onda de frio, em que as temperaturas máximas e mínimas se encontram conjuntamente abaixo do percentil 10 entre novembro e abril, e também os períodos de ondas de calor em que as temperaturas máximas e mínimas se encontram associadamente acima do percentil 90 entre maio e outubro. Os percentis calculados encontram-se no Anexo 1, e os períodos de temperaturas extremas identificadas no Anexo 2.

Posteriormente seleciona-se os períodos de temperaturas extremas, compatíveis com os horizontes temporais das séries dos indicadores de saúde (Tabela 5.1 e 5.2.)

Tabela 5. 1. Ondas de frio

	RS	Dias	Número de dias abaixo do percentil 10	Número de dias abaixo do percentil 5
Ondas de frio	Norte	5 a 7 fevereiro, 2018	3	1
	Centro	6 a 8 fevereiro, 2018	3	0
	LVT	---	---	---
	Alentejo	5 a 9 fevereiro, 2018	5	3
	Algarve	5 a 9 fevereiro, 2018	5	4

As ondas de frio identificadas ocorreram todas entre os dias 5 e 9 de fevereiro, o que vai de acordo com o Boletim Climatológico do IPMA de fevereiro de 2018 que identificou este mês como o terceiro mês, até à data, com menor temperatura média desde o ano 2000 (IPMA, 2018a).

Tabela 5. 2. Ondas de calor

	RS	Dias	Número de dias acima do percentil 90	Número de dias acima do percentil 95
Ondas de calor	Norte	24 a 29 julho, 2016	6	5
	Centro	17 a 21 junho, 2017	5	4
	LVT	2 a 5 agosto, 2018	4	4
	Alentejo	6 a 13 agosto, 2016	8	1
	Algarve	2 a 6 agosto, 2018	5	5

É importante referir que de 2 a 6 agosto de 2018 registaram-se ondas de calor também bastantes impactantes em todas as RS, atingindo-se todos os dias temperaturas acima do percentil 95, as tabelas descritivas deste fenómeno encontram-se no Anexo 1. Este facto vai de acordo com o Boletim Climatológico do IPMA, que refere que este período se caracterizou pelas temperaturas extremamente quentes e que até à data de 2018 tinha sido o segundo mês mais quente desde 2003 (IPMA, 2018b).

5.2. Flutuações dos indicadores de saúde nos períodos de frio e calor

Os resultados obtidos do cálculo da variação dos períodos de ondas de frio e de calor comparativamente aos seus períodos homólogos encontram-se dispostos nos anexos 3 e 4. É importante referir que os períodos homólogos com os quais foram calculadas as variações relativas à mortalidade diária têm como referência os anos de 2014 a 2019, e ao número de atendimentos em urgência hospitalar por triagem de Manchester os meses entre julho de 2016 a dezembro de 2019.

5.2.1. Ondas frio

Através da análise das ondas de frio em fevereiro de 2018, transversal às RS Norte, Centro, Alentejo e Algarve, é possível salientar que relativamente aos períodos homólogos:

- Na RS Norte, verifica-se um aumento de 7% da mortalidade diária e uma variação positiva de 8% nos dias 7 e 8 de fevereiro de 2018. Para além disso, o número de atendimentos em urgência hospitalar com pulseira amarela sofreu um aumento de

11%. No geral o número de atendimentos em urgência hospitalar na RS Norte aumentou cerca de 4%.

- Na RS Centro, a mortalidade diária apresentou uma taxa de crescimento de apenas 3%, enquanto o dia que apresentou o valor máximo de óbitos, 7 de fevereiro de 2018, exibiu um aumento de 7%. Em termos de número atendimentos em urgência hospitalar todas as pulseiras apresentaram uma taxa de variação positiva salientando-se o número de pulseiras vermelhas que teve um aumento substancial de 31%. As pulseiras verdes também se destacaram com uma flutuação positiva de 19%. Por outro lado, o tipo de pulseira com uma taxa de crescimento menor foi a pulseira amarela, a mais frequente a nível anual, com 10%. No geral todos os tipos de pulseira apresentaram uma subida de frequência, sendo que no total de atendimentos em urgência hospitalar deu-se um aumento de 13%.
- Na RS Alentejo, o nível de óbitos diários aumentou 5%, sendo que o dia com maior mortalidade foi o dia 5 de fevereiro de 2018 demonstrando um aumento de 45%. O número de atendimentos em urgência hospitalar aumentou para todas as pulseiras sendo que a pulseira vermelha apresentou o maior aumento de 18%, de seguida as pulseiras amarelas e verdes exibiram um aumento de 16%, as pulseiras azuis aumentaram 15% e as laranjas 13%. No total o número de atendimentos em urgência hospitalar aumentou em 16%.
- Na RS Algarve, a mortalidade diária teve uma taxa de crescimento de 15% e o dia que exibiu um maior número de óbitos foi o dia 5 fevereiro de 2018 com um aumento em 45%. Todos os tipos de pulseiras, exceto as azuis que decresceram em 29%, apresentaram uma variação positiva. No geral, o número de atendimentos em urgência hospitalar aumentou em 3%. As pulseiras vermelhas e laranjas foram as que tiveram um maior aumento de 5 e 15%, respetivamente. A restantes (amarela e verdes) apenas tiveram um aumento pouco significativo de 1 e 2%.

5.2.2. Ondas de Calor

Analisando as ondas de calor que foram mais frequentes nos meses de junho, julho e agosto, é possível destacar que relativamente aos períodos homólogos:

- Na RS Norte, verifica-se um aumento de 18% da mortalidade diária ao longo da onda de calor e uma variação positiva de 28% no dia 28 de julho de 2016. Relativamente ao número de atendimentos em urgência hospitalar, as pulseiras vermelhas sofreram um aumento de 4%, no mesmo sentido a frequência de pulseiras amarelas e verdes aumentou em 2% e 6% respetivamente. No geral o número de atendimentos em urgência hospitalar aumentou cerca de 2%.
- Na RS Centro, deu-se um aumento de 29% da mortalidade diária ao longo da onda de calor e uma variação positiva extraordinária de 92% no dia 18 de junho de 2017. Em termos de número de atendimentos em urgência hospitalar as pulseiras vermelhas e verdes sofreram um aumento de apenas 1%, no mesmo sentido a frequência de pulseiras laranjas aumentou em 2%. É de realçar que o número ocorrências com pulseiras azuis teve um aumento bastante significativo de 21%. Apesar destes aumentos, no geral o número de atendimentos em urgência hospitalar diminuiu cerca de 1%.
- Na RS LVT, deu-se um aumento significativo de 70% da mortalidade diária e uma variação positiva extraordinária 180% no dia 5 de agosto de 2018. O número de atendimentos em urgência hospitalar aumentou em todas as pulseiras, de realçar as vermelhas que aumentaram em 14%, as pulseiras amarelas aumentaram em 7%, as verdes e as azuis, associadas a urgências com menor gravidade, em 12%. No geral o número de atendimentos em urgência hospitalar na aumentou 9%.
- Na RS Alentejo, verifica-se um aumento 26% da mortalidade diária e uma variação positiva extraordinária 58% no dia 8 de agosto de 2016. No geral o número de atendimentos em urgência hospitalar na diminuiu em 28%.
- Na RS Algarve, deu-se um aumento de 22% da mortalidade diária e uma variação positiva elevada de 45% no dia 5 de agosto de 2018. O número de atendimentos em urgência hospitalar com pulseira verde foi o que demonstrou uma maior variação positiva de 6%, de seguida as pulseiras azuis com 2% e as pulseiras amarelas com um crescimento de apenas 1%. As restantes pulseiras apresentaram variações negativas. No geral o número de atendimentos em urgência hospitalar na aumentou 2%.

6. Aplicação dos Modelos Lineares Generalizados

Nesta Secção encontram-se os resultados do processo de modelação dos dados da Mortalidade Diária de todas as RS desde 2014 a 2019, através dos MLGs, mais precisamente da regressão Binomial Negativa.

Analisando os correlogramas, isto é, as matrizes de correlação de Pearson, (Figura 6.1.) é possível afirmar que a mortalidade diária em cada uma das RS está negativamente correlacionada com a temperatura mínima e a temperatura máxima. Ou seja, o aumento da temperatura do ar conduz a uma diminuição do número de óbitos diários de forma linear. A RS Norte é a região que apresenta maiores coeficientes de Pearson, de -0,56, para ambas as variáveis da temperatura. Por outro lado, RS Algarve é aquela que exhibe menores coeficientes de Pearson, -0,26 e -0,25, para a temperatura mínima e máxima, respetivamente. Verifica-se que os coeficientes vão decrescendo de norte para sul de Portugal. É importante realçar que, com exceção da RS Norte, as restantes RS apresentam correlações mais fortes entre a mortalidade e a temperatura mínima, do que entre a mortalidade e a temperatura máxima.

Correlogramas por RS – Coeficiente de correlação de Pearson







Figura 6. 1. Correlogramas por RS – Coeficiente de correlação de Pearson

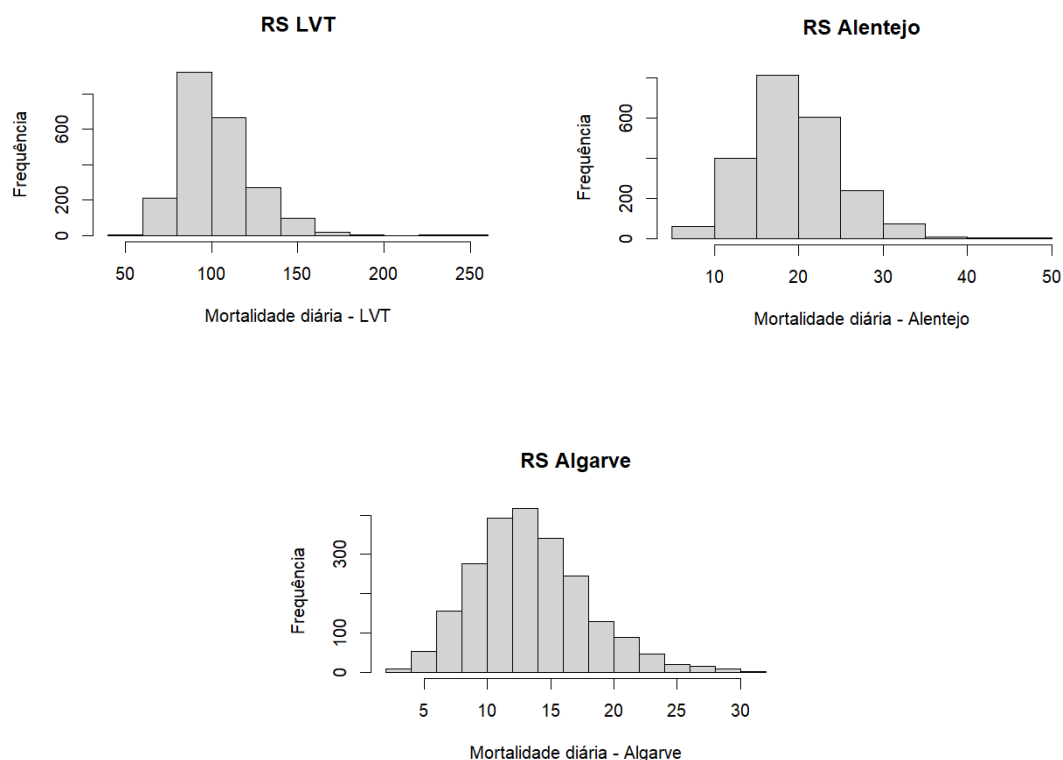
Através dos histogramas de cada RS, verifica-se que a variável dependente parece seguir uma distribuição assimétrica positiva, o que é corroborado pelos valores do coeficiente de assimetria (γ_Y), sendo que estes são superiores a zero (Tabela 6.1.). Neste caso, os dias com maior número de óbitos, bastante acima da média, ocorrem com menor frequência. Para além destas características, os histogramas e a Tabela 6.1. demonstram que a variância da mortalidade é superior à sua média, o que pressupõe a existência de sobredispersão. Como tal recorre-se à regressão Binomial Negativa para estimar os modelos, sendo esta capaz de modelar sobredispersão.

Tabela 6. 1. Medidas de estatística descritivas da mortalidade diária

RS	Variância	Média	γ_Y
Norte	364,9	92,7	1,03
Centro	144,3	56,8	0,89
LVT	409,5	102,9	1,06
Alentejo	29,4	19,8	0,54
Algarve	19,8	13,9	0,57

Histogramas por RS





6.1. Aplicação da regressão Binomial Negativa

Nestes modelos, a variável resposta é o número de óbitos diários, e as variáveis explicativas são as temperaturas diárias mínimas e máximas. Na Tabela 6.2. encontram-se os coeficientes dos modelos para cada RS, e os seus respetivos AIC e θ estimados.

Tabela 6. 2. Regressões Binomiais Negativas estimadas para cada RS

RS	β_0 (<i>p-value</i>)	β_1 (<i>p-value</i>)	β_2 (<i>p-value</i>)	AIC	θ
Norte	4,780 (0,0)	-0,012 (0,0)	-0,008 (0,0)	17983	66,4
Centro	4,307 (0,0)	-0,014 (0,0)	-0,007 (0,0)	16349	67,3
LVT	5,051 (0,0)	-0,017 (0,0)	-0,011 (0,0)	18384	65,5
Alentejo	3,266 (0,0)	-0,011 (0,0)	-0,007 (0,0)	13197	81,2
Algarve	2,882 (0,0)	-0,014 (0,0)	-0,004 (0,0)	12551	44,2

Verifica-se que existe evidencia estatística de que as variáveis explicativas são individualmente significativas ($p\text{-value} < 0,05$), com um nível de confia de 95%. Para avaliar a adequabilidade da regressão Binomial Negativa realizou-se um Teste de Ajustamento com estatística χ^2 e estatística de Pearson (Anexo 5). O resultado deste teste

corresponde à não rejeição da hipótese nula, logo o modelo tem um bom ajustamento e a adequa-se aos dados.

Através da análise gráfica dos *Q-Q plots* dos resíduos (Figura 6.2.), verifica-se que os resíduos do modelo se aproximam bastante a uma distribuição Binomial Negativa teórica, visto que estes formam uma linha diagonal linear. Este comportamento indica o bom ajustamento e qualidade explicativa dos modelos.

Q-Q Plots dos resíduos– Distribuição Binomial Negativa

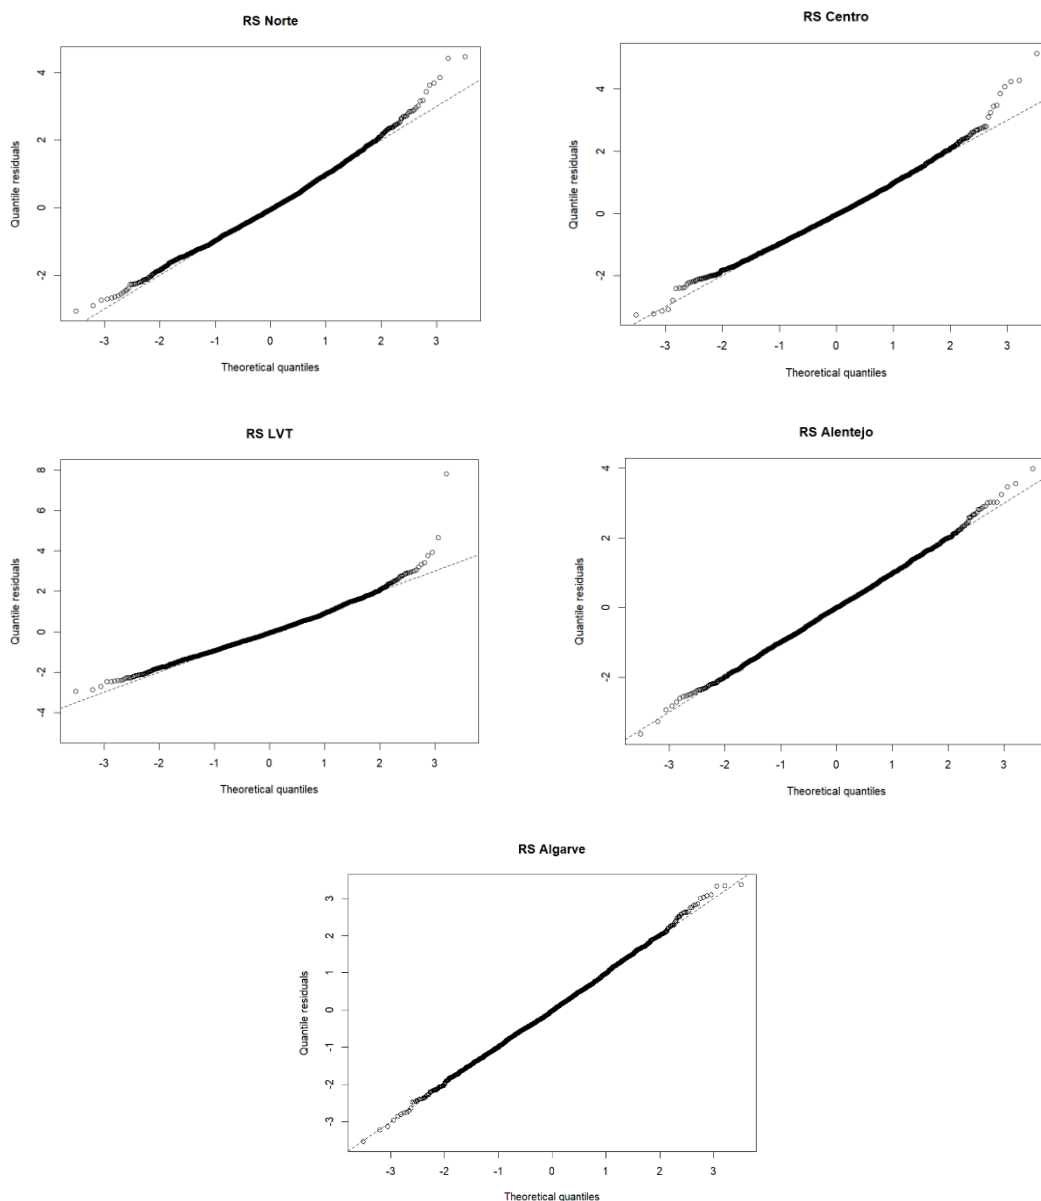


Figura 6. 2. *Q-Q Plots* dos resíduos– Distribuição Binomial Negativa

6.1.1. Interpretação dos modelos

Para interpretar as regressões na escala original da variável resposta é necessário recorrer ao cálculo do exponencial dos parâmetros β_j (Tabela 6.3.).

Tabela 6. 3. Regressões Binomiais Negativas estimadas e transformadas para cada RS

RS	$exp\beta_0$	$exp\beta_1$	$exp\beta_2$
Norte	121,466	0,988	0,992
Centro	74,239	0,987	0,993
LVT	156,189	0,983	0,990
Alentejo	26,208	0,989	0,993
Algarve	17,852	0,986	0,996

Com o intuito de simplificar a interpretação das regressões, na Tabela 6.4. estão dispostos os coeficientes, e respetivos intervalos de confiança a 95% (IC95%) da cada variável explicativa em percentagem.

Tabela 6. 4. Coeficientes, e respetivos intervalos de confiança a 95% estimados (%), para cada RS

RS	$exp\beta_0$	$\Delta\% \mu_Y = -[(1 - exp\beta_1) \times 100]T_{mín}$ (IC95% (%))	$\Delta\% \mu_Y = -[(1 - exp\beta_2) \times 100]T_{máx}$ (IC95%)
Norte	121,466	-1,2 [-1,5; -1,0]	-0,8 [-0,9; -0,5]
Centro	74,239	-1,3 [-1,7; -1,0]	-0,7 [-0,9; -0,5]
LVT	156,189	-1,7 [-1,9; -1,4]	-1,0 [-1,2; -0,9]
Alentejo	26,208	-1,1 [-1,5; -0,8]	-0,7 [-0,9; -0,5]
Algarve	17,852	-1,4 [-2,0; -0,7]	-0,4 [-1,0; -0,0]

Tomando como exemplo a RS Norte, verifica-se que caso não exista alteração das temperaturas mínimas e máximas, o valor esperado da mortalidade diária para um determinado dia é de aproximadamente 121 óbitos. Caso ocorra uma diminuição da temperatura mínima em 1°C infere-se que o valor esperado da mortalidade diária aumenta em 1,2%, ceteris paribus. Por outro lado, se a temperatura máxima diminuir 1°C dá-se um

aumento de 0,8% do valor esperado da mortalidade diária , ceteris paribus. Este raciocínio pode ser replicado para as restantes RS.

6.1.2. Introdução de variáveis quadráticas

Através da análise gráfica da série original observa-se que existe um comportamento cíclico da mortalidade diária, o que indica que a introdução de termos quadráticos pode melhorar o modelo. No mesmo sentido, os gráficos dos resíduos versus os valores estimados das regressões Binomiais Negativas apresentam uma forma curvilínea (Anexo 6), indicando também que a inclusão dos termos quadráticos é indicada.

Os modelos estimados com os termos quadráticos encontram-se na Tabela 6.5.:

Tabela 6. 5. Regressões Binomiais Negativas quadráticas estimadas, por RS

RS	β_0 (p-value)	β_1 (p-value)	β_2 (p-value)	β_3 (p-value)	β_4 (p-value)	AIC	θ
Norte	5,084 (0,0)	-0,028 (0,0)	-0,034 (0,0)	0,001 (0,0)	0,0006 (0,0)	17762	78,8
Centro	4,754 (0,0)	-0,037 (0,0)	-0,043 (0,0)	0,002 (0,0)	0,0007 (0,0)	16131	83,8
LVT	6,085 (0,0)	-0,037 (0,0)	-0,096 (0,0)	0,001 (0,0)	0,002 (0,0)	18078	81,8
Alentejo	3,653 (0,0)	-0,025 (0,0)	-0,037 (0,0)	0,0009 (0,0)	0,0006 (0,0)	13122	96,5
Algarve	3,677 (0,0)	-0,053 (0,0)	-0,061 (0,0)	0,002 (0,0)	0,001 (0,0)	12407	54,6

Nos modelos com os termos quadráticos, tal como nos modelos sem estes termos, existe evidencia estatística de que as variáveis são individualmente significativas ($p\text{-values} < 0,05$). Relativamente aos AICs, os modelos de segundo grau apresentam valores menores comparativamente às regressões de primeiro grau indicando um melhor ajuste aos dados.

A heterogeneidade não observável nos modelos de segundo grau é menor relativamente à dos modelos de primeiro grau, pois os parâmetros θ de todas as regressões de segundo grau são superiores aos das regressões de primeiro grau. Isto significa que a variância de Y dos modelos com termos quadráticos é inferior relativamente à dos

modelos com apenas termos lineares, indicando que os modelos quadráticos são mais eficazes.

O resultado dos testes de razão de verosimilhança (Anexo 7) levou à rejeição da hipótese nula ($p\text{-value}=0<0,05$), logo existe evidencia estatística de que a os modelos com as estruturas quadráticas demonstram um ajustamento significativamente melhor que os modelos com apenas termos lineares.

Com base nestes resultados é possível afirmar que os modelos de regressão Binomial Negativa com termos de segundo grau, melhoram o poder explicativo dos modelos, sendo estes os mais adequados para estimar o impacto das temperaturas mínimas e máximas no número de óbitos diários em cada uma das RS.

6.1.2.1. Interpretação das regressões quadráticas

Analisando os sinais dos parâmetros β_j da regressão acima selecionada, os termos lineares têm coeficientes negativos, e os termos quadráticos têm coeficientes positivos. Isto significa, que a relação entre o logaritmo do valor esperado do número de óbitos diários e a temperatura mínima ou máxima é negativa, e que a função é côncava - $\log(\mu_Y)$ decresce com a temperatura mínima e máxima, e decresce cada vez mais.

Visto que o cálculo da variação de $\log(\mu_Y)$ depende do nível atual das temperaturas, tanto mínima como máxima, é necessário assumir uma temperatura “base”, para poder interpretar o impacto das temperaturas no logaritmo do valor esperado do número de óbitos diários.

Na Tabela 6.6. está exposta a variação do logaritmo do valor esperado do número de óbitos diários, $\Delta \log(\mu_Y)$, assumindo que a temperatura mínima “base”, $T_{mín}$, aumenta de 1°C para 2°C em todas as RS ($\Delta T_{mín} = 1$), mantendo o resto contante.

Tabela 6. 6. Impacto da temperatura mínima no $\log(\mu_Y)$ caso esta aumente de 1°C para 2°C, por RS

RS	$\Delta \log(\mu_Y) \approx (\hat{\beta}_1 + 2\hat{\beta}_3 T_{mín})\Delta T_{mín}$
Norte	-0,026
Centro	-0,033
LVT	-0,035
Alentejo	-0,024
Algarve	-0,051

Tomando como exemplo a RS Algarve, verifica-se que o aumento da temperatura mínima de 1°C para 2°C equivale a uma variação negativa de -0,051 do $\log(\mu_Y)$. O mesmo raciocínio se aplica para as outras RS.

É possível observar que a variação de $\log(\mu_Y)$ é negativa, em todas as RS, para o caso em que a $T_{mín}$ é 1°C e que $\Delta T_{mín} = 1$. Caso, $\Delta T_{mín}$ aumente, $\Delta \log(\mu_Y)$ será cada vez mais negativa.

Outra interpretação importante é que à medida que as temperaturas mínimas “base” são superiores, considerando $\Delta T_{mín}$ como um valor fixo, a variação de $\log(\mu_Y)$ irá ser cada vez menos negativa até passar a ser positiva. Por exemplo, considerando um intervalo de temperaturas mínimas “base” discretas entre 1°C e 20°C e que $\Delta T_{mín} = 1$ (Anexo 8), verifica-se que nas RS Norte, Alentejo e Algarve, a partir de uma temperatura mínima “base” de 14°C, a variação do $\log(\mu_Y)$ será cada vez mais positiva. Ou seja, a partir deste patamar de $T_{mín}$ qualquer variação positiva da temperatura mínima impactará positivamente a variação do $\log(\mu_Y)$. No caso da RS LVT este patamar encontra-se nos 19°C e na RS Centro nos 10°C.

Com o intuito de realizar a mesma análise para a temperatura máxima, na Tabela 6.7. está exposta a variação do logaritmo do valor esperado do número de óbitos diários assumindo que ocorre um aumento da temperatura máxima de 30°C para 31°C em todas as RS, mantendo o resto contante.

Tabela 6. 7. Impacto da temperatura máxima no $\log(\mu_Y)$ caso esta aumente de 30°C para 31°C, por RS

RS	$\Delta \log(\mu_Y) \approx (\hat{\beta}_2 + 2\hat{\beta}_4 X)\Delta T_{máx}$
Norte	0,0032
Centro	0.0004
LVT	0.028
Alentejo	0.0002
Algarve	0.001

Tomando como exemplo a RS LVT, verifica-se que o aumento da temperatura máxima de 31°C para 32°C equivale a uma variação positiva de 0.028 do $\log(\mu_Y)$. O mesmo raciocínio se aplica para as outras RS.

Tal como na relação entre $\Delta \log(\mu_Y)$ e a temperatura mínima, à medida que as temperaturas máximas “base” são superiores, considerando $\Delta T_{m\acute{a}x}$ como um valor fixo, a variação de $\log(\mu_Y)$ irá ser cada vez menos negativa até passar a ser positiva. Aplicando o mesmo método utilizado acima com $T_{m\acute{i}n}$, com a diferença que se considera um intervalo entre 1°C e 35°C (Anexo 9), verifica-se que nas RS Centro, Alentejo e Algarve a partir de uma temperatura máxima “base” de 31°C, a variação do $\log(\mu_Y)$ será cada vez mais positiva. Ou seja, a partir deste patamar de $T_{m\acute{a}x}$ qualquer variação positiva da temperatura máxima impactará positivamente a variação do $\log(\mu_Y)$. No caso da RS Norte este patamar encontra-se nos 29°C e na RS LVT nos 24°C.

7. Discussão dos Resultados

Nesta Secção, são discutidos os resultados obtidos nas secções anteriores. Primeiramente são abordados os resultados obtidos a partir da análise descritiva dos indicadores de saúde. Posteriormente, são discutidos os resultados obtidos da identificação de ondas de calor e de frio, e do cálculo da respetiva variação dos indicadores de saúde nesse período relativamente aos períodos homólogos. Por fim, são interpretados os MLGs estimados para compreender o impacto da temperatura mínima e máxima na mortalidade diária.

7.1. Comportamento dos indicadores de saúde

Os resultados da análise descritiva dos dados da mortalidade diária indicam uma possível associação com a temperatura do ar. Este indicador de saúde apresenta um comportamento cíclico anual, sendo que os picos positivos absolutos ocorrem no início e fim de cada ano.

A partir da construção de *boxplots* com os dados organizados por meses, evidencia-se uma possível associação entre a mortalidade e as flutuações anuais da temperatura, uma vez que os meses com maior mortalidade são novembro, dezembro, janeiro e fevereiro, ou seja, os meses inverniais, com temperatura mais baixas. O mês com maior média e variância, para todas as RS, é o mês de janeiro. Os meses com menor mortalidade são os meses de junho, julho, agosto e setembro, ou seja, os meses estivais, que atingem temperaturas mais altas. Em todas as RS, o mês com menor média diária de mortes é setembro, exceto na RS Algarve em que as médias diárias se mantêm próximas ao longo do ano, e apenas nos meses inverniais apresentam valores superiores. Durante os meses de julho e agosto a média diária de mortos é ligeiramente superior relativamente a junho e setembro. Também foi possível compreender que os meses que apresentam uma maior variabilidade, são os meses inverniais. Por outro lado, os meses com menor variabilidade são os meses estivais.

A tendência da mortalidade em todas as RS, é relativamente constante com apenas algumas oscilações até 2019. No período da pandemia Covid-19, deu-se um aumento acentuado da mortalidade, no entanto, verifica-se que as conclusões retiradas acerca da possível associação entre a mortalidade e a temperatura do ar são as mesmas incluindo e

excluindo este período. A diferença reside no facto de que existem muitos outliers associados ao período irregular da pandemia.

A partir da análise descritiva do número de atendimentos em urgência hospitalar, verifica-se que as RS que apresentam maior valor médio mensal por milhão de habitantes são as RS Centro e a RS Algarve, seguidas da RS Alentejo, RS Norte e RS LVT por ordem decrescente. O período da pandemia de Covid-19, tendo sido um período bastante atípico no que respeita aos cuidados de saúde prestados, apresenta uma queda extraordinária do número de atendimentos em urgência hospitalar no ano de 2020.

O estudo do número de atendimentos em urgência hospitalar por triagem de Manchester permitiu compreender que em todas as RS a pulseira amarela é a mais frequente no horizonte temporal estudado, exceto na RS LVT em que é a pulseira verde é a que tem maior frequência.

A análise dos *boxplots* com os dados organizados por meses, que não incluía o período da pandemia Covid-19, permitiu verificar que as pulseiras vermelhas e laranjas, são mais frequentes nos meses inverniais (novembro, dezembro, janeiro e fevereiro). Com um comportamento contrário à das pulseiras para pacientes mais graves, as pulseiras azuis são mais frequentes nos meses de verão, sendo que os meses com maior número de atendimentos em urgência com pulseira azul são julho e agosto. As pulseiras amarelas e verdes comportam-se segundo uma tendência cíclica, ou seja, as médias mensais aumentam e descresem alternadamente, à exceção de julho e agosto em que se mantêm praticamente constantes. Os meses com maior número médio de atendimentos são os meses de outubro e dezembro, em que as temperaturas são mais baixas. É também de realçar que as RS Centro e Norte onde as temperaturas são geralmente mais baixas, são as que apresentam uma maior percentagem de pacientes em estados mais graves (pulseira vermelha, laranja e amarela).

7.2. Ondas de frio e de calor

O estudo do comportamento dos indicadores de saúde em ondas de frio ou calor relativamente aos seus períodos homólogos, permite verificar-se que em ambos os casos a mortalidade e o número de atendimentos em urgência hospitalar sofrem efeitos negativos devido às temperaturas extremas.

Todas as ondas de frio identificadas para cada RS, exceto para a RS LVT em que não foi identificada nenhuma, ocorreram em fevereiro de 2018 e levaram a um aumento entre 1 e 15% da mortalidade diária relativamente aos períodos homólogos. O número de atendimentos em urgência hospitalar aumentou na sua generalidade em todas as RS, em cerca de 4 a 16% relativamente aos períodos homólogos. As variações mais acentuadas identificadas foram relativas às pulseiras vermelhas mesmo não sendo transversal a todas as RS.

As ondas de calor identificadas para cada RS ocorreram nos meses de junho, julho e mais frequentemente em agosto. A mortalidade diária nesses períodos aumentou no geral entre 14 e 29% relativamente ao período homólogo, no entanto a RS LVT demonstrou um aumento extraordinário de 70% relativamente ao período homólogo. Os atendimentos em urgência hospitalar aumentaram entre 1 e 2%, excluindo o caso da RS LVT que apresentou uma variação superior de 9% relativamente aos períodos homólogos.

Em todas as RS, as ondas de frio identificadas tiveram menor duração relativamente às ondas de calor identificadas nessa mesma RS, exceto na RS Algarve em que a onda de frio e de calor teve a mesma duração.

Estes resultados mostram que durante uma onda de calor a variação da mortalidade é superior à variação da mortalidade numa onda de frio, relativamente aos seus períodos homólogos. Também demonstram que a atividade nas urgências hospitalares é menor numa onda de calor, do que numa onda de frio, comparativamente aos seus períodos equivalentes.

7.3. Modelos Lineares Generalizados

Nesta secção analisam-se os resultados obtidos através da aplicação dos MLGs, mais precisamente da regressão Binomial Negativa aos dados da mortalidade diária.

A partir das regressões de primeiro grau verifica-se que em todas as RS a diminuição da temperatura mínima contribui mais para o aumento do número de óbitos comparativamente a uma diminuição da temperatura máxima na mesma proporção, mantendo o resto constante. Uma flutuação da temperatura mínima tem um impacto com sinal negativo no valor esperado do número de óbitos diários, de cerca de 1 a 2%, no geral

das RS. A variação da temperatura máxima afetou com sinal negativo em cerca de 0-1% no valor esperado do número de óbitos diários em Portugal continental.

De todas as RS, a RS LVT é aquela em que a diminuição da temperatura mínima contribuiu mais (em 1,7%) para o aumento da Mortalidade Diária, ao contrário da RS Alentejo, em que a diminuição da temperatura mínima corresponde a uma flutuação positiva do número de óbitos diários superior relativamente ao resto das RS.

Relativamente à temperatura máxima, na RS LVT o aumento da temperatura máxima resulta numa flutuação negativa menor do número de óbitos diários (-0,1%) relativamente às restantes RS. Por outro lado, a RS Norte é a RS em que o aumento da temperatura máxima contribuiu menos para o aumento do número de óbitos diários (-0,8%).

A partir dos modelos com termos quadráticos, é possível verificar que na maioria das RS a partir de uma temperatura mínima próxima dos 14°C a variação do logaritmo do valor esperado da mortalidade diária passa a ser positiva. Apenas na RS Centro e na RS LVT ocorre a partir de uma temperatura mínima próxima dos 10°C e 19°C. Por outro lado, também se verifica que na maioria das RS a partir de uma temperatura máxima próxima dos 31°C a variação do logaritmo do valor esperado da mortalidade diária passa a ser positiva. Apenas na RS Norte e na RS LVT ocorre a partir de uma temperatura mínima próxima dos 29°C e 24°C.

8. Conclusão

Nesta dissertação mostra-se que existe uma relação associativa entre as temperaturas e a saúde humana em Portugal Continental. Conseguiu-se avaliar o impacto das temperaturas extremas durante ondas de frio e de calor na saúde, assim como quantificar a magnitude do impacto das temperaturas mínimas e máximas na mortalidade no horizonte temporal em estudo.

A análise descritiva dos indicadores de saúde, evidenciou que, apesar de algumas diferenças no comportamento da mortalidade entre as RS, no geral é superior nos meses inverniais, quando a temperatura é mais baixa e superior nos meses estivais, com temperaturas mais quentes. Os atendimentos em urgência hospitalar por sua vez têm um comportamento diferente dependendo da cor da pulseira atribuída na triagem de Manchester. As pulseiras mais graves, as vermelhas e as laranjas, foram claramente mais frequentes nos meses inverniais, e menos frequentes nos meses de verão. As pulseiras amarelas foram as mais frequentes em todas as RS, exceto na RS LVT em que foram as pulseiras verdes. Estas duas cores demonstraram uma tendência alternada ao longo do ano, sendo que outubro e dezembro foram os meses com maior frequência. Por fim, as pulseiras menos graves ocorreram com maior frequência nos meses mais quentes de verão. A análise descritiva das variáveis permitiu evidenciar uma possível associação entre as temperaturas do ar e os indicadores de saúde.

As ondas de frio e de calor foram identificadas utilizando o método dos percentis recorrendo-se simultaneamente aos percentis da temperatura mínima e máxima. Verificou-se a existência de ondas de frio em todas as RS a fevereiro de 2018, exceto para a RS LVT onde não se identificou nenhuma no horizonte temporal estudado. As ondas de calor identificadas em cada RS ocorreram em junho, julho e com mais frequência em agosto. Em geral as ondas de calor mostraram ter maior duração do que as ondas de frio, apenas na RS Algarve os períodos de temperaturas extremamente quentes e frias tiveram a mesma duração. Verificou-se que a variação da mortalidade durante as ondas de calor foi superior à variação da mortalidade durante as ondas de frio, comparativamente aos períodos homólogos. Por outro lado, a variação dos atendimentos em urgência durante as ondas de calor foi inferior à variação dos atendimentos em urgência durante as ondas de frio, relativamente aos períodos homólogos.

Por fim aplicaram-se MLGs, mais precisamente regressões Binomiais Negativas aos dados da mortalidade diária, concluindo-se que em Portugal Continental a diminuição da temperatura mínima contribuiu mais para o aumento do número de óbitos relativamente a uma diminuição na mesma proporção da temperatura máxima, mantendo o resto constante. Mostra-se também que a diminuição de um grau centígrado da temperatura mínima resultou num aumento do valor esperado do número de óbitos diários entre 1 e 2%. No mesmo sentido, a diminuição de um grau centígrado da temperatura máxima resultou num aumento do valor esperado do número de óbitos diários em Portugal Continental de 0 a 1%. Através da introdução de variáveis quadráticas nos MLGs, foi possível concluir que caso as temperaturas aumentem exponencialmente a mortalidade também aumenta.

Durante a realização desta dissertação existiram algumas limitações. A quantidade de dados acerca do número de atendimentos em urgência hospitalar por triagem de Manchester é reduzida tanto em termos do período como de granularidade. O facto de não serem disponibilizados dados de todos os hospitais públicos a nível nacional fez com que o horizonte temporal do estudo fosse mais curto, o que não permitiu a identificação de mais períodos de temperaturas extremas. Adicionalmente a aplicação de MLGs aos dados dos atendimentos em urgência hospitalar não foi possível devido à escassez dos dados.

Sugere-se para trabalho futuro que sejam desenvolvidos MLGs com a aplicação de *lags*, de forma a estudar por quanto tempo de exposição a uma determinada temperatura pode afetar a mortalidade diária. Com base na literatura (Armstrong, 2006; Huang et al., 2014; Baccini et al., 2008; Basu et al., 2008), sabe-se que as ondas de calor podem impactar até três dias a saúde humana, e que as ondas de frio podem afetar a mortalidade até 20 dias. Desta forma, propõem-se a aplicação de *lags* de 0 a 20 dias nas regressões desenvolvidas.

9. Bibliografia

1. 4.2 - Residuals vs. Fits Plot | STAT 462. (2018). Online.stat.psu.edu. Consultado em 2022, outubro 10 <https://online.stat.psu.edu/stat462/node/117/>
2. Almendra, R., Freire, E., Vasconcelos, J., & Santana, P. (2015). *Excesso de Mortalidade no inverno nos países da Europa Mediterrânea*. 823-824. XIII Congresso Ibérico de Geografia, Santiago de Compostela.
3. Almendra, J. (2019). A vulnerabilidade ao frio em Portugal: custos sociais e económicos do excesso de mortalidade e de morbilidade durante o inverno [Tese de Doutoramento]. In *Estudogeral.uc.pt* (pp. 1–30). <http://hdl.handle.net/10316/87620>
4. Anderson, B. G., & Bell, M. L. (2009). Weather-Related Mortality. *Epidemiology*, 20(2), 205–213. <https://doi.org/10.1097/ede.0b013e318190ee08>.
5. Armstrong, B. (2006). Models for the Relationship Between Ambient Temperature and Daily Mortality. *Epidemiology*, 17(6), 624–631. <https://doi.org/10.1097/01.ede.0000239732.50999.8f>
6. Baccini, M., Biggeri, A., Accetta, G., Kosatsky, T., Katsouyanni, K., Analitis, A., Anderson, H. R., Bisanti, L., D’Ippoliti, D., Danova, J., Forsberg, B., Medina, S., Paldy, A., Rabczenko, D., Schindler, C., & Michelozzi, P. (2008). Heat Effects on Mortality in 15 European Cities. *Epidemiology*, 19(5), 711–719. <https://doi.org/10.1097/ede.0b013e318176bfcd>
7. Basu, R. (2009). High ambient temperature and mortality: a review of epidemiologic studies from 2001 to 2008. *Environmental Health*, 8(1), 1-13. <https://doi.org/10.1186/1476-069x-8-40>
8. Basu, R., Feng, W.-Y., & Ostro, B. D. (2008). Characterizing Temperature and Mortality in Nine California Counties. *Epidemiology*, 19(1), 138–145. <https://doi.org/10.1097/ede.0b013e31815c1da7>
9. Basu, R., & Malig, B. (2011). High ambient temperature and mortality in California: Exploring the roles of age, disease, and mortality displacement. *Environmental Research*, 111(8), 1286–1292. <https://doi.org/10.1016/j.envres.2011.09.006>
10. Ben, M. G., & Yohai, V. J. (2004). Quantile–Quantile Plot for Deviance Residuals in the Generalized Linear Model. *Journal of Computational and Graphical Statistics*, 13(1), 36–47. https://doi.org/10.1198/1061860042949_a
11. Chung, Y., Lim, Y.-H., Honda, Y., Guo, Y.-L. L., Hashizume, M., Bell, M. L., Chen, B.-Y., & Kim, H. (2015). Mortality Related to Extreme Temperature for 15 Cities in Northeast Asia. *Epidemiology*, 26(2), 255–262. <https://doi.org/10.1097/ede.0000000000000229>
12. Comissão Europeia. (2018). *Heat and Cold Wave Index (HCWI)* (pp. 1–5). https://edo.jrc.ec.europa.eu/documents/factsheets/factsheet_heatColdWaveIndex.pdf
13. Draper, N. R., & Smith, H. (1998). *Applied regression analysis* (3rd ed., pp. 63–67). Jonh Wiley & Sons, Inc.
14. Dunn, P. K., & Smyth, G. K. (2018). Generalized Linear Models with Examples in R. In *SpringerLink* (1st ed., pp. 211–327, 371–312). Springer New York. <https://doi.org/10.1007-978-1-4419-0118-7>
15. Faraway, J. (2006). *Extending the Linear Model with R - Generalized Linear, Mixed Effects and Nonparametric Regression Models* (pp. 1–324). Taylor & Francis Group, LLC.

16. Ferreira, P. J. S. (2016). *Princípios de econometria* (pp. 40–45, 48–53). Bubok.
17. Gasparrini, A., & Armstrong, B. (2010). Time series analysis on the health effects of temperature: Advancements and limitations. *Environmental Research*, *110*(6), 633–638. <https://doi.org/10.1016/j.envres.2010.06.005>
18. Gasparrini, A., Guo, Y., Hashizume, M., Lavigne, E., Zanobetti, A., Schwartz, J., Tobias, A., Tong, S., Rocklöv, J., Forsberg, B., Leone, M., De Sario, M., Bell, M. L., Guo, Y.-L. L., Wu, C., Kan, H., Yi, S.-M., de Sousa Zanotti Stagliorio Coelho, M., Saldiva, P. H. N., & Honda, Y. (2015). Mortality risk attributable to high and low ambient temperature: a multicountry observational study. *The Lancet*, *386*(9991), 369–375. [https://doi.org/10.1016/s0140-6736\(14\)62114-0](https://doi.org/10.1016/s0140-6736(14)62114-0)
19. Gosling, S. N., Lowe, J. A., McGregor, G. R., Pelling, M., & Malamud, B. D. (2008). Associations between elevated atmospheric temperature and human mortality: a critical review of the literature. *Climatic Change*, *92*(3-4), 299–341. <https://doi.org/10.1007/s10584-008-9441-x>
20. Grupo Português de Triagem. (2021, February 17). *Protocolo Triagem Manchester | Grupo Português Triagem*. Grupo Português de Triagem. <https://www.grupoportuguestriagem.pt/grupo-portugues-triagem/protocolo-triagem-manchester/>
21. Huang, F., Zhou, S., Zhang, S., Wang, H., & Tang, L. (2011). Temporal correlation analysis between malaria and meteorological factors in Motuo County, Tibet. *Malaria Journal*, *10*(1), 1–8. <https://doi.org/10.1186/1475-2875-10-54>
22. Huang, J., Wang, J., & Yu, W. (2014). The Lag Effects and Vulnerabilities of Temperature Effects on Cardiovascular Disease Mortality in a Subtropical Climate Zone in China. *International Journal of Environmental Research and Public Health*, *11*(4), 3982–3994. <https://doi.org/10.3390/ijerph110403982>
23. IPMA. (2018a). *BOLETIM CLIMATOLÓGICO Agosto 2018* (pp. 1–3). https://www.ipma.pt/resources.www/docs/im.publicacoes/edicoes.online/20180924/QyzZvZwgxxBnLFiHkSkX/cli_20180801_20180831_pcl_mm_co_pt.pdf
24. IPMA. (2018b). *BOLETIM CLIMATOLÓGICO agosto 2018* (pp. 1–3). https://www.ipma.pt/resources.www/docs/im.publicacoes/edicoes.online/20180924/QyzZvZwgxxBnLFiHkSkX/cli_20180801_20180831_pcl_mm_co_pt.pdf
25. James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). An Introduction to Statistical Learning. In *SpringerLink* (pp. 164–170). Springer New York. <https://doi.org/10.1007-978-1-4614-7138-7>
26. Kabacoff, R. (2011). *R in action : Data analysis and graphics with R* (1st ed., pp. 303–330). Manning.
27. Lavaysse, C., Cammalleri, C., Dosio, A., van der Schrier, G., Toreti, A., & Vogt, J. (2018). Towards a monitoring system of temperature extremes in Europe. *Natural Hazards and Earth System Sciences*, *18*(1), 91–104. <https://doi.org/10.5194/nhess-18-91-2018>
28. Liddell, C., Morris, C., Thomson, H., & Guiney, C. (2015). Excess winter deaths in 30 European countries 1980–2013: a critical review of methods. *Journal of Public Health*, *38*(4), 806–814. <https://doi.org/10.1093/pubmed/fdv184>
29. Lin, S., Luo, M., Walker, R. J., Liu, X., Hwang, S.-A., & Chinery, R. (2009). Extreme High Temperatures and Hospital Admissions for Respiratory and Cardiovascular Diseases. *Epidemiology*, *20*(5), 738–746. <https://doi.org/10.1097/ede.0b013e3181ad5522>
30. Marques, J. (2007). Condições climáticas de inverno e a mortalidade diária do distrito de Lisboa [Tese de Mestrado]. In *Repositorio.ul.pt* (pp. 23–94). <http://hdl.handle.net/10451/452>

31. Marques, J., & Antunes, S. (2009). A perigosidade natural da temperatura do ar em Portugal continental: a avaliação do risco na mortalidade. *Territorium*, 16, 49–61. https://doi.org/10.14195/1647-7723_16_5
32. Mattheakis, M., & Protopapas, P. (2018). *Model Selection & Information Criteria: Akaike Information Criterion*. 8–15. <https://harvard-iacs.github.io/2018-CS109A/a-sections/a-section-2/presentation/a-sec2-MLEtoAIC.pdf>
33. Mehra, V. (2017). Forecasting USD to INR foreign exchange rate using Time Series Analysis techniques like HoltWinters Simple Exponential Smoothing, ARIMA and Neural Networks. *Academia.edu*, 4–5. <https://doi.org/10.13140/RG.2.2.23465.08800>
34. Nelder, J. A., & Wedderburn, R. W. M. (1972). Generalized Linear Models. *Journal of the Royal Statistical Society. Series a (General)*, 135(3), 370–383. <https://doi.org/10.2307/2344614>
35. Nóbrega, T. (2018). Alterações Climáticas e Saúde: Estudo ecológico sobre ondas de calor e utilização de cuidados de saúde na região do Alentejo em 2018 (pp. 1–75) [Tese de Mestrado]. <https://run.unl.pt/handle/10362/89819>
36. Nogueira, P. J., Paixão, E. J., & Morais, L. (2013). Temperaturas do ar de Lisboa e Portugal (por distritos). Distribuições semanais e geográficas : modelos para previsão e monitorização dos impactos das ondas de calor na mortalidade humana. *Portugal Saúde Em Números*, 1, 8–18. <https://doi.org/2182-7389>
37. Pordata. (2022). *População residente: total e por grandes grupos etários*. Pordata.pt.<https://www.pordata.pt/municipios/populacao+residente+total+e+por+grandes+grupos+etarios-390>
38. Radinović, D., & Čurić, M. (2011). Criteria for heat and cold wave duration indexes. *Theoretical and Applied Climatology*, 107(3-4), 505–510. <https://doi.org/10.1007/s00704-011-0495-8>
39. Ranandeh Kalankesh, L., Mansouri, F., & Khanjani, N. (2015). Association of Temperature and Humidity with Trauma Deaths. *Trauma Monthly*, 20(4), 1–5. <https://doi.org/10.5812/traumamon.23403>
40. Rau, R. (2007). *Seasonality in human mortality: a demographic approach* (pp. 5–15). Springer.
41. Reis, E. (2008). *Estatística Descritiva* (pp. 185–186, 204–206, 212). Edições Sílabo.
42. Rizmie, D., de Preux, L., Miraldo, M., & Atun, R. (2022). Impact of extreme temperatures on emergency hospital admissions by age and socio-economic deprivation in England. *Social Science & Medicine*, 308, 1–10. <https://doi.org/10.1016/j.socscimed.2022.115193>
43. Roback, P., & Legler, J. (2021). *Beyond Multiple Linear Regression: Applied Generalized Linear Models and Multilevel Models in R*. In *Bookdown.org* (1st ed.). Taylor & Francis Group, LLC. <https://bookdown.org/robback/bookdown-BeyondMLR/>
44. Rodríguez, G. (2013). *Models for Count Data With Overdispersion* (pp. 3–5). <https://data.princeton.edu/wws509/notes/c4a.pdf>
45. Sarofim, M. C., Saha, S., Hawkins, M. D., Mills, D. M., Hess, J., Horton, R., Kinney, P., Schwartz, J., & St. Juliana, A. (2016). *Ch. 2: Temperature-Related Death and Illness. The Impacts of Climate Change on Human Health in the United States: A Scientific Assessment*. <https://doi.org/10.7930/j0mg7mdx>
46. Seltnerich, N. (2015). Between Extremes: Health Effects of Heat and Cold. *Environmental Health Perspectives*, 123(11), 276–279. <https://doi.org/10.1289/ehp.123-a275>

47. Serviço de Urgência Geral e a Urgência Pediátrica do Centro Hospitalar de Lisboa Ocidental. (2016). *Triagem de Manchester*. Min-Saude.pt. <https://www.chlo.min-saude.pt/index.php/triagem-de-manchester>
48. Sun, X., Sun, Q., Yang, M., Zhou, X., Li, X., Yu, A., Geng, F., & Guo, Y. (2014). Effects of temperature and heat waves on emergency department visits and emergency ambulance dispatches in Pudong New Area, China: a time series analysis. *Environmental Health*, 13(1), 1–8. <https://doi.org/10.1186/1476-069x-13-76>
49. Turkman, A., & Silva, G. (2000). *Modelos Lineares Generalizados - da teoria à prática*. 27–44, 71–72. <https://www.spestatistica.pt/publicacoes/publicacao/modelos-lineares-generalizados-da-teoria-pratica>
50. UCLA. (2013). *Negative Binomial Regression | R Data Analysis Examples*. Ucla.edu. <https://stats.oarc.ucla.edu/r/dae/negative-binomial-regression/>
51. Venables, W. N., & Ripley, B. D. (2002). *Modern Applied Statistics with S* (4th ed., pp. 206–210). Springer Science+Business Media New York. <https://link.springer.com/book/10.1007/978-0-387-21706-2>
52. World Meteorological Organization, & World Health Organization. (2015). *Heatwaves and health : guidance on warning-system development* (pp. 1–28). World Meteorological Organization. <https://public.wmo.int/en/resources/library/heatwaves-and-health-guidance-warning-system-development>
53. Yau, C. (2009). R Tutorial With Bayesian Statistics Using Stan. In *R-tutor.com*. <http://www.r-tutor.com/elementary-statistics/numerical-measures/skewness>

Anexos

Anexo 1

Tabela anexo 1.1. Percentis calculados entre outubro e março

outubro - março								
RS	Temperatura Mínima (°C)				Temperatura máxima (°C)			
	5%	10%	90%	95%	5%	10%	90%	95%
Norte	-0,8	0,4	10,6	12,0	8,8	9,9	21,5	23,6
Centro	0,4	1,5	11,5	13,0	9,9	11,0	21,4	23,4
LVT	2,8	4,0	13,5	14,8	13,1	14,0	22,9	24,8
Alentejo	0,7	2,0	12,5	14,1	11,7	12,8	24,1	26,3
Algarve	2,8	3,8	13,8	15,2	13,5	14,5	23,2	25,0

Tabela anexo 1.2. Percentis calculados entre abril e setembro

abril - setembro								
RS	Temperatura Mínima (°C)				Temperatura máxima (°C)			
	5%	10%	90%	95%	5%	10%	90%	95%
Norte	5,2	6,8	16,3	17,3	14,8	16,9	32,4	34,0
Centro	6,0	7,6	16,7	17,6	15,4	17,3	31,6	33,3
LVT	8,6	9,8	17,1	17,7	17,6	19,0	30,4	32,2
Alentejo	6,8	8,3	17,7	19,0	17,7	19,7	36,3	37,9
Algarve	8,8	10,1	19,5	20,5	18,9	20,2	32,4	33,7

Anexo 2

Tabela anexo 2: Onda de frio e de calor (07/2016-12/2019)

RS Norte		
Ondas de frio	Número de dias abaixo do percentil 10	Número de dias abaixo do percentil 5
5 a 7 fevereiro, 2018	3	1
Ondas de calor	Número de dias acima do percentil 90	Número de dias acima do percentil 95
24 a 29 julho, 2016	6	5
6 a 9 agosto, 2016	4	2
16 a 21 junho, 2017	6	3
13 a 16 julho, 2017	4	2
2 a 5 agosto, 2018	4	4
10 a 12 julho, 2019	3	1
RS Centro		
Ondas de frio	Número de dias abaixo do percentil 10	Número de dias abaixo do percentil 5
6 a 8 fevereiro, 2018	3	0
Ondas de calor	Número de dias acima do percentil 90	Número de dias acima do percentil 95
6 a 9 agosto, 2016	4	2
3 a 6 setembro, 2016	4	2
17 a 21 junho, 2017	5	4
2 a 5 agosto, 2018	4	4
RS LVT		
Ondas de frio	Número de dias abaixo do percentil 10	Número de dias abaixo do percentil 5
----	----	----
Ondas de calor	Número de dias acima do percentil 90	Número de dias acima do percentil 95
2 a 5 agosto, 2018	4	4
RS Alentejo		
Ondas de frio	Número de dias abaixo do percentil 10	Número de dias abaixo do percentil 5
5 a 9 de fevereiro, 2018	5	3
Ondas de calor	Número de dias acima do percentil 90	Número de dias acima do percentil 95
15 a 17 de julho, 2016	3	0
24 a 26 julho, 2016	3	1
6 a 13 agosto, 2016	8	1
3 a 6 setembro, 2016	4	3
16 a 20 junho, 2017	5	3
2 a 6 de agosto, 2018	5	5
19 a 21 agosto, 2018	3	1
23 a 24 setembro, 2018	3	0

RS Algarve		
Ondas de frio	Número de dias abaixo do percentil 10	Número de dias abaixo do percentil 5
5 a 9 fevereiro, 2018	5	4
Ondas de calor	Número de dias acima do percentil 90	Número de dias acima do percentil 95
2 a 6 agosto, 2018	5	5

Anexo 3

Tabela anexo 3.1: RS Norte – Onda de Frio a fevereiro de 2018

RS Norte – Onda de Frio a fevereiro de 2018					
Indicador de saúde		Média anual dos períodos homólogo	Nº de ocorrências no período de 2018	Δ	Valor máximo diário de ocorrências no período de 2018
Mortalidade diária		335,2	358	7%	6 e 7 de fevereiro de 2018 Número de óbitos: 121 Média do dia no período equivalente: 112 $\Delta = 8\%$
Número de atendimentos em urgência hospitalar	Pulseira vermelha	587,5	538	-8%	-----
	Pulseira laranja	16.033,5	15.421	-4%	-----
	Pulseira amarela	73.263,5	81.185	11%	-----
	Pulseira verde	43.780	41.666	-5%	-----
	Pulseira azul	1.378,5	1.194	-13%	-----
	Total	135.043	140.004	4%	-----

Tabela anexo 3.2: RS Centro – Onda de Frio a fevereiro de 2018

RS Centro – Onda de Frio a fevereiro de 2018					
Indicador de saúde		Média anual no período homólogo	Nº de ocorrências no período de 2018	Δ	Valor máximo diário de ocorrências no período de 2018
Mortalidade diária		207,8	2015	3%	7 de fevereiro de 2018 Número de óbitos: 76 Média do dia no período equivalente: 70,8 $\Delta = 7\%$
Número de atendimentos em urgência hospitalar	Pulseira vermelha	272,5	357	31%	-----
	Pulseira laranja	7.597	8.557	13%	-----
	Pulseira amarela	34.929	38.514	10%	-----
	Pulseira verde	21.191	25.146	19%	-----
	Pulseira azul	1.040,5	1.185	14%	-----
	Total	65.030	73.759	13%	-----

Tabela anexo 3.3: RS Alentejo – Onda de Frio a fevereiro de 2018

RS Alentejo – Onda de Frio a fevereiro de 2018					
Indicador de saúde		Média anual no período equivalente	Nº de ocorrências no período de 2018	Δ	Valor máximo diário de ocorrências no período de 2018
Mortalidade diária		124	130	5%	5 de fevereiro de 2018 Número de óbitos: 32 Média do dia no período equivalente: 22 $\Delta = 45\%$
Número de atendimentos em urgência hospitalar	Pulseira vermelha	84	99	18%	-----
	Pulseira laranja	2.529	2.864	13%	-----
	Pulseira amarela	9.042	10.516	16%	-----
	Pulseira verde	7.504	8.670	16%	-----
	Pulseira azul	276	318	15%	-----
	Total	19.433	22.467	16%	-----

Tabela anexo 3.4: RS Algarve – Onda de Frio a fevereiro de 2018

RS Algarve – Onda de Frio a fevereiro de 2018					
Indicador de saúde		Média anual no período equivalente	Nº de ocorrências no período de 2018	Δ	Valor máximo diário de ocorrências no período de 2018
Mortalidade diária		84	97	15%	5 de fevereiro de 2018 Número de óbitos: 25 Média do dia no período equivalente: 18 $\Delta = 37\%$
Número de atendimentos em urgência hospitalar	Pulseira vermelha	89	93	5%	-----
	Pulseira laranja	2.892	4.465	15%	-----
	Pulseira amarela	11.692	11.804	1%	-----
	Pulseira verde	9.902	1.138	2%	-----
	Pulseira azul	177	125	-29%	-----
	Total	25.750	26.625	3%	-----

Anexo 4

Tabela anexo 4.1: RS Norte – Onda de Calor a julho de 2016

RS Norte – Onda de Calor a julho de 2016					
Variável		Média anual no período equivalente	Nº de ocorrências no período de 2016	Δ	Valor máximo diário de ocorrências no período de 2016
Mortalidade diária		471,2	554	18%	28 de julho de 2016 Número de óbitos: 102 Média do dia no período equivalente: 80 $\Delta = 28\%$
Número de atendimentos em urgência hospitalar	Pulseira vermelha	548,5	572	4%	-----
	Pulseira laranja	16.210	16.117	-1%	-----
	Pulseira amarela	78.414,2	79.378	1%	-----
	Pulseira verde	46.550,2	49.378	6%	-----
	Pulseira azul	1.378,5	1.616	-6%	-----
	Total	143.445,5	146.881	2%	-----

Tabela anexo 4.2: RS Centro – Onda de Calor a junho de 2017

RS Centro – Onda de Calor a junho de 2017					
Variável		Média anual no período equivalente	Nº de ocorrências no período de 2017	Δ	Valor máximo diário de ocorrências no período de 2017
Mortalidade diária		272,6	353	29%	18 de junho de 2017 Número de óbitos: 99 Média do dia no período equivalente: 51,6 $\Delta = 92\%$
Número de atendimentos em urgência hospitalar	Pulseira vermelha	295,8	265	1%	-----
	Pulseira laranja	7.771,7	7.958	2%	-----
	Pulseira amarela	40.128	38.679	-4%	-----
	Pulseira verde	23.615,1	23.837	1%	-----
	Pulseira azul	1.124	1.363	21%	-----
	Total	72.934,6	72.102	-1%	-----

Tabela anexo 4.3: RS LVT – Onda de Calor a agosto de 2018

RS LVT – Onda de Calor a agosto de 2018					
Variável		Média anual no período equivalente	Nº de ocorrências no período de 2018	Δ	Valor máximo diário de ocorrências no período de 2018
Mortalidade diária		346,2	589	70%	5 de agosto de 2018 Número de óbitos: 244 Média do dia no período equivalente: 87,2 Δ = 180%
Número de atendimentos em urgência hospitalar	Pulseira vermelha	484,3	552	14%	-----
	Pulseira laranja	13.492,7	13.722	2%	-----
	Pulseira amarela	59.467,3	63.460	7%	-----
	Pulseira verde	65.613	73.215	12%	-----
	Pulseira azul	2.751,3	3068	12%	-----
	Total	141.808,7	154.017	9%	-----

Tabela anexo 4.4: RS Alentejo – Onda de Calor a agosto de 2016

RS Alentejo – Onda de Calor a agosto de 2016					
Variável		Média anual no período equivalente	Nº de ocorrências no período de 2016	Δ	Valor máximo diário de ocorrências no período de 2016
Mortalidade diária		139,8	154	26%	8 de agosto de 2016 Número de óbitos: 25 Média do dia no período equivalente: 16 Δ = 58%
Número de atendimentos em urgência hospitalar	Pulseira vermelha	80,7	39	-52%	-----
	Pulseira laranja	2.701,4	1.730	-36%	-----
	Pulseira amarela	10.720,7	7.723	-28%	-----
	Pulseira verde	8.141,9	6.168	-24%	-----
	Pulseira azul	346,2	282	-19%	-----
	Total	21.991	15.942	-28%	-----

Tabela anexo 4.5: RS Algarve – Onda de Calor a agosto de 2018

RS Algarve – Onda de Calor a agosto de 2018					
Variável		Média anual no período equivalente	Nº de ocorrências no período de 2018	Δ	Valor máximo diário de ocorrências no período de 2018
Mortalidade diária		135,4	176	22%	5 de agosto de 2018 Número de óbitos: 18 Média do dia no período equivalente: 12 $\Delta = 45\%$
Número de atendimentos em urgência hospitalar	Pulseira vermelha	115	115	0%	-----
	Pulseira laranja	5.074	4.857	-4%	-----
	Pulseira amarela	16.873,7	17.056	1%	-----
	Pulseira verde	12.293	13.083	6%	-----
	Pulseira azul	246,3	251	2%	-----
	Total	34.602	35.362	2%	-----

Anexo 5

Norte

```
c(X2=v_X2, Resid.Dev=deviance(m_BN), Pearson.X2=X2)
      X2 Resid.Dev Pearson.X2
2297.934 2161.359 2221.018
```

Centro

```
c(Df=v_X2, Resid.Dev=deviance(m_BN), Pearson.X2=X2)
      Df Resid.Dev Pearson.X2
2297.934 2167.325 2225.985
```

LVT

```
c(Df=v_X2, Resid.Dev=deviance(m_BN), Pearson.X2=X2)
      Df Resid.Dev Pearson.X2
2297.934 2173.992 2378.697
```

Alentejo

```
c(X2=v_X2, Resid.Dev=deviance(m_BN), Pearson.X2=X2)
      X2 Resid.Dev Pearson.X2
2297.934 2196.533 2197.796
```

Algarve

```
c(Df=v_X2, Resid.Dev=deviance(m_BN), Pearson.X2=X2)
      Df Resid.Dev Pearson.X2
2297.934 2205.566 2201.540
```

Figura anexo 5: Testes de ajustamento χ^2 e de Pearson

Anexo 6

Resíduos versus Valores estimados – Regressão Binomial Negativa

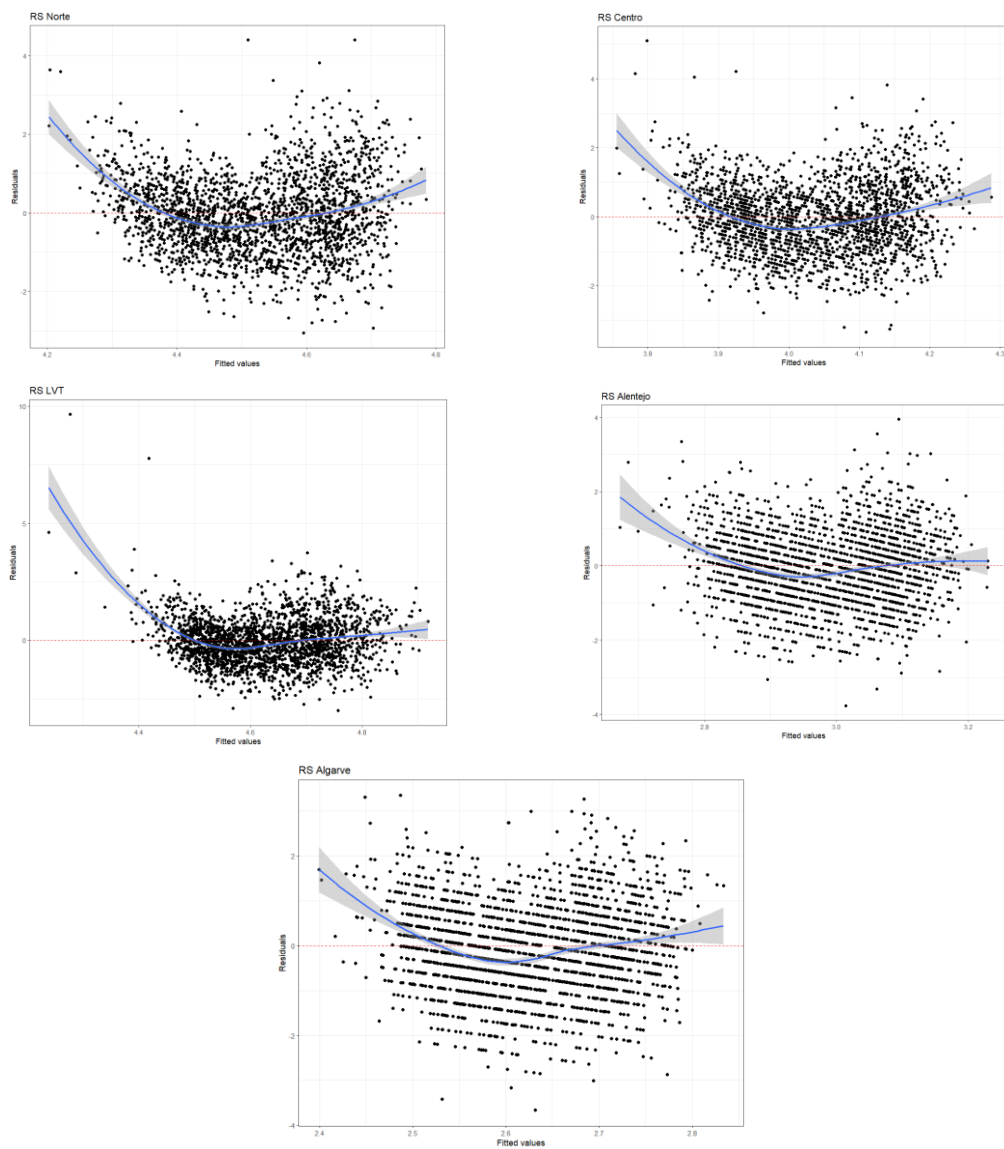


Figura anexo 6: Resíduos versus Valores estimados das Regressões Binomiais Negativas, por RS

Anexo 7

RS Norte

Likelihood ratio test

```
Model 1: MORTnorte ~ Tmin + Tmax + Tmin_square + Tmax_square
Model 2: MORTnorte ~ Tmin + Tmax
#Df LogLik Df Chisq Pr(>Chisq)
```

```
1 6 -8875.0
2 4 -8987.6 -2 225.09 < 2.2e-16 ***
```

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

RS Centro

Likelihood ratio test

```
Model 1: MORTcentro ~ Tmin + Tmax + Tmin_square + Tmax_square
Model 2: MORTcentro ~ Tmin + Tmax
#Df LogLik Df Chisq Pr(>Chisq)
```

```
1 6 -8059.7
2 4 -8170.3 -2 221.18 < 2.2e-16 ***
```

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

RS LVT

Likelihood ratio test

```
Model 1: MORTlvt ~ Tmin + Tmax + Tmin_square + Tmax_square
Model 2: MORTlvt ~ Tmin + Tmax
#Df LogLik Df Chisq Pr(>Chisq)
```

```
1 6 -9033.2
2 4 -9188.1 -2 309.68 < 2.2e-16 ***
```

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

RS Alentejo

Likelihood ratio test

```
Model 1: MortAlentejo ~ Tmin + Tmax + Tmin_square + Tmax_square
Model 2: MortAlentejo ~ Tmin + Tmax
#Df LogLik Df Chisq Pr(>Chisq)
```

```
1 6 -6554.9
2 4 -6594.3 -2 78.82 < 2.2e-16 ***
```

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

RS Algarve

Likelihood ratio test

```
Model 1: MortAlgarve ~ Tmin + Tmax + Tmin_square + Tmax_square
Model 2: MortAlgarve ~ Tmin + Tmax
#Df LogLik Df Chisq Pr(>Chisq)
```

```
1 6 -6197.5
2 4 -6251.6 -2 108.2 < 2.2e-16 ***
```

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Figura anexo 7: Testes de razão de Verossimilhança, por RS

Anexo 8

Tabela anexo 8: Variação de $\log(\mu_Y)$ a variação de T_{\min} "base"

RS Norte				RS Centro				RS LVT				RS Alentejo				RS Algarve			
T_{\min}	β_1	β_2	$\Delta\log(\mu_Y)$	T_{\min}	β_1	β_2	$\Delta\log(\mu_Y)$	T_{\min}	β_1	β_2	$\Delta\log(\mu_Y)$	T_{\min}	β_1	β_2	$\Delta\log(\mu_Y)$	T_{\min}	β_1	β_2	$\Delta\log(\mu_Y)$
1	-0.028	0.001	-0.026	1	-0.037	0.002	-0.033	1	-0.037	0.001	-0.035	1	-0.025	0.0009	-0.0232	1	-0.053	0.002	-0.049
2	-0.028	0.001	-0.024	2	-0.037	0.002	-0.029	2	-0.037	0.001	-0.033	2	-0.025	0.0009	-0.0214	2	-0.053	0.002	-0.045
3	-0.028	0.001	-0.022	3	-0.037	0.002	-0.025	3	-0.037	0.001	-0.031	3	-0.025	0.0009	-0.0196	3	-0.053	0.002	-0.041
4	-0.028	0.001	-0.02	4	-0.037	0.002	-0.021	4	-0.037	0.001	-0.029	4	-0.025	0.0009	-0.0178	4	-0.053	0.002	-0.037
5	-0.028	0.001	-0.018	5	-0.037	0.002	-0.017	5	-0.037	0.001	-0.027	5	-0.025	0.0009	-0.016	5	-0.053	0.002	-0.033
6	-0.028	0.001	-0.016	6	-0.037	0.002	-0.013	6	-0.037	0.001	-0.025	6	-0.025	0.0009	-0.0142	6	-0.053	0.002	-0.029
7	-0.028	0.001	-0.014	7	-0.037	0.002	-0.009	7	-0.037	0.001	-0.023	7	-0.025	0.0009	-0.0124	7	-0.053	0.002	-0.025
8	-0.028	0.001	-0.012	8	-0.037	0.002	-0.005	8	-0.037	0.001	-0.021	8	-0.025	0.0009	-0.0106	8	-0.053	0.002	-0.021
9	-0.028	0.001	-0.01	9	-0.037	0.002	-0.001	9	-0.037	0.001	-0.019	9	-0.025	0.0009	-0.0088	9	-0.053	0.002	-0.017
10	-0.028	0.001	-0.008	10	-0.037	0.002	0.003	10	-0.037	0.001	-0.017	10	-0.025	0.0009	-0.007	10	-0.053	0.002	-0.013
11	-0.028	0.001	-0.006	11	-0.037	0.002	0.007	11	-0.037	0.001	-0.015	11	-0.025	0.0009	-0.0052	11	-0.053	0.002	-0.009
12	-0.028	0.001	-0.004	12	-0.037	0.002	0.011	12	-0.037	0.001	-0.013	12	-0.025	0.0009	-0.0034	12	-0.053	0.002	-0.005
13	-0.028	0.001	-0.002	13	-0.037	0.002	0.015	13	-0.037	0.001	-0.011	13	-0.025	0.0009	-0.0016	13	-0.053	0.002	-0.001
14	-0.028	0.001	0	14	-0.037	0.002	0.019	14	-0.037	0.001	-0.009	14	-0.025	0.0009	0.0002	14	-0.053	0.002	0.003
15	-0.028	0.001	0.002	15	-0.037	0.002	0.023	15	-0.037	0.001	-0.007	15	-0.025	0.0009	0.002	15	-0.053	0.002	0.007
16	-0.028	0.001	0.004	16	-0.037	0.002	0.027	16	-0.037	0.001	-0.005	16	-0.025	0.0009	0.0038	16	-0.053	0.002	0.011
17	-0.028	0.001	0.006	17	-0.037	0.002	0.031	17	-0.037	0.001	-0.003	17	-0.025	0.0009	0.0056	17	-0.053	0.002	0.015
18	-0.028	0.001	0.008	18	-0.037	0.002	0.035	18	-0.037	0.001	-0.001	18	-0.025	0.0009	0.0074	18	-0.053	0.002	0.019
19	-0.028	0.001	0.01	19	-0.037	0.002	0.039	19	-0.037	0.001	0.001	19	-0.025	0.0009	0.0092	19	-0.053	0.002	0.023
20	-0.028	0.001	0.012	20	-0.037	0.002	0.043	20	-0.037	0.001	0.003	20	-0.025	0.0009	0.011	20	-0.053	0.002	0.027

Anexo 9

Tabela anexo 9: Variação de $\log(\mu_Y)$ a variação de T_{\max} "base"

RS Norte				RS Centro				RS LVT				RS Alentejo				RS Algarve			
T_{\max}	β_1	β_2	$\Delta\log(\mu_Y)$	T_{\max}	β_1	β_2	$\Delta\log(\mu_Y)$	T_{\max}	β_1	β_2	$\Delta\log(\mu_Y)$	T_{\max}	β_1	β_2	$\Delta\log(\mu_Y)$	T_{\max}	β_1	β_2	$\Delta\log(\mu_Y)$
1	-0.034	0.0006	-0.0328	1	-0.043	0.0007	-0.0416	1	-0.096	0.002	-0.092	1	-0.037	0.0006	-0.0358	1	-0.061	0.001	-0.059
2	-0.034	0.0006	-0.0316	2	-0.043	0.0007	-0.0402	2	-0.096	0.002	-0.088	2	-0.037	0.0006	-0.0346	2	-0.061	0.001	-0.057
3	-0.034	0.0006	-0.0304	3	-0.043	0.0007	-0.0388	3	-0.096	0.002	-0.084	3	-0.037	0.0006	-0.0334	3	-0.061	0.001	-0.055
4	-0.034	0.0006	-0.0292	4	-0.043	0.0007	-0.0374	4	-0.096	0.002	-0.08	4	-0.037	0.0006	-0.0322	4	-0.061	0.001	-0.053
5	-0.034	0.0006	-0.028	5	-0.043	0.0007	-0.036	5	-0.096	0.002	-0.076	5	-0.037	0.0006	-0.031	5	-0.061	0.001	-0.051
6	-0.034	0.0006	-0.0268	6	-0.043	0.0007	-0.0346	6	-0.096	0.002	-0.072	6	-0.037	0.0006	-0.0298	6	-0.061	0.001	-0.049
7	-0.034	0.0006	-0.0256	7	-0.043	0.0007	-0.0332	7	-0.096	0.002	-0.068	7	-0.037	0.0006	-0.0286	7	-0.061	0.001	-0.047
8	-0.034	0.0006	-0.0244	8	-0.043	0.0007	-0.0318	8	-0.096	0.002	-0.064	8	-0.037	0.0006	-0.0274	8	-0.061	0.001	-0.045
9	-0.034	0.0006	-0.0232	9	-0.043	0.0007	-0.0304	9	-0.096	0.002	-0.06	9	-0.037	0.0006	-0.0262	9	-0.061	0.001	-0.043
10	-0.034	0.0006	-0.022	10	-0.043	0.0007	-0.029	10	-0.096	0.002	-0.056	10	-0.037	0.0006	-0.025	10	-0.061	0.001	-0.041
11	-0.034	0.0006	-0.0208	11	-0.043	0.0007	-0.0276	11	-0.096	0.002	-0.052	11	-0.037	0.0006	-0.0238	11	-0.061	0.001	-0.039
12	-0.034	0.0006	-0.0196	12	-0.043	0.0007	-0.0262	12	-0.096	0.002	-0.048	12	-0.037	0.0006	-0.0226	12	-0.061	0.001	-0.037
13	-0.034	0.0006	-0.0184	13	-0.043	0.0007	-0.0248	13	-0.096	0.002	-0.044	13	-0.037	0.0006	-0.0214	13	-0.061	0.001	-0.035
14	-0.034	0.0006	-0.0172	14	-0.043	0.0007	-0.0234	14	-0.096	0.002	-0.04	14	-0.037	0.0006	-0.0202	14	-0.061	0.001	-0.033
15	-0.034	0.0006	-0.016	15	-0.043	0.0007	-0.022	15	-0.096	0.002	-0.036	15	-0.037	0.0006	-0.019	15	-0.061	0.001	-0.031
16	-0.034	0.0006	-0.0148	16	-0.043	0.0007	-0.0206	16	-0.096	0.002	-0.032	16	-0.037	0.0006	-0.0178	16	-0.061	0.001	-0.029
17	-0.034	0.0006	-0.0136	17	-0.043	0.0007	-0.0192	17	-0.096	0.002	-0.028	17	-0.037	0.0006	-0.0166	17	-0.061	0.001	-0.027
18	-0.034	0.0006	-0.0124	18	-0.043	0.0007	-0.0178	18	-0.096	0.002	-0.024	18	-0.037	0.0006	-0.0154	18	-0.061	0.001	-0.025
19	-0.034	0.0006	-0.0112	19	-0.043	0.0007	-0.0164	19	-0.096	0.002	-0.02	19	-0.037	0.0006	-0.0142	19	-0.061	0.001	-0.023
20	-0.034	0.0006	-0.01	20	-0.043	0.0007	-0.015	20	-0.096	0.002	-0.016	20	-0.037	0.0006	-0.013	20	-0.061	0.001	-0.021
21	-0.034	0.0006	-0.0088	21	-0.043	0.0007	-0.0136	21	-0.096	0.002	-0.012	21	-0.037	0.0006	-0.0118	21	-0.061	0.001	-0.019
22	-0.034	0.0006	-0.0076	22	-0.043	0.0007	-0.0122	22	-0.096	0.002	-0.008	22	-0.037	0.0006	-0.0106	22	-0.061	0.001	-0.017
23	-0.034	0.0006	-0.0064	23	-0.043	0.0007	-0.0108	23	-0.096	0.002	-0.004	23	-0.037	0.0006	-0.0094	23	-0.061	0.001	-0.015
24	-0.034	0.0006	-0.0052	24	-0.043	0.0007	-0.0094	24	-0.096	0.002	0	24	-0.037	0.0006	-0.0082	24	-0.061	0.001	-0.013
25	-0.034	0.0006	-0.004	25	-0.043	0.0007	-0.008	25	-0.096	0.002	0.004	25	-0.037	0.0006	-0.007	25	-0.061	0.001	-0.011
26	-0.034	0.0006	-0.0028	26	-0.043	0.0007	-0.0066	26	-0.096	0.002	0.008	26	-0.037	0.0006	-0.0058	26	-0.061	0.001	-0.009
27	-0.034	0.0006	-0.0016	27	-0.043	0.0007	-0.0052	27	-0.096	0.002	0.012	27	-0.037	0.0006	-0.0046	27	-0.061	0.001	-0.007
28	-0.034	0.0006	-0.0004	28	-0.043	0.0007	-0.0038	28	-0.096	0.002	0.016	28	-0.037	0.0006	-0.0034	28	-0.061	0.001	-0.005
29	-0.034	0.0006	0.0008	29	-0.043	0.0007	-0.0024	29	-0.096	0.002	0.02	29	-0.037	0.0006	-0.0022	29	-0.061	0.001	-0.003
30	-0.034	0.0006	0.002	30	-0.043	0.0007	-0.001	30	-0.096	0.002	0.024	30	-0.037	0.0006	-0.001	30	-0.061	0.001	-0.001
31	-0.034	0.0006	0.0032	31	-0.043	0.0007	0.0004	31	-0.096	0.002	0.028	31	-0.037	0.0006	0.0002	31	-0.061	0.001	0.001
32	-0.034	0.0006	0.0044	32	-0.043	0.0007	0.0018	32	-0.096	0.002	0.032	32	-0.037	0.0006	0.0014	32	-0.061	0.001	0.003
33	-0.034	0.0006	0.0056	33	-0.043	0.0007	0.0032	33	-0.096	0.002	0.036	33	-0.037	0.0006	0.0026	33	-0.061	0.001	0.005
34	-0.034	0.0006	0.0068	34	-0.043	0.0007	0.0046	34	-0.096	0.002	0.04	34	-0.037	0.0006	0.0038	34	-0.061	0.001	0.007
35	-0.034	0.0006	0.008	35	-0.043	0.0007	0.006	35	-0.096	0.002	0.044	35	-0.037	0.0006	0.005	35	-0.061	0.001	0.009