

Usabilidade de dados de previsão meteorológica a curto prazo no apoio à calendarização da rega

Guilherme Raposo Rego

Dissertação para obtenção do Grau de Mestre em

Engenharia Agronómica

Orientadores: Doutora Paula Cristina Santana Paredes

Doutor João Rui Rolim Fernandes Machado Lopes

Presidente: Doutor Gonçalo Pereira Fernandes Caleia Rodrigues, Professor auxiliar do Instituto Superior de Agronomia da Universidade de Lisboa.

Vogais: Doutora Paula Cristina Santana Paredes, Professora auxiliar do Instituto Superior de Agronomia da Universidade de Lisboa

Doutora Ana Cristina Machado Russo, Professora auxiliar do Instituto Superior de Agronomia da Universidade de Lisboa

Agradecimentos

Esta dissertação de mestrado foi uma grande lição, não só em termos de conhecimento adquirido, mas acima de tudo na importância da persistência e resiliência nos períodos difíceis da vida. Ultrapassando inseguranças e desmotivação, a sua conclusão não seria possível sem o apoio de várias pessoas.

Em primeiro lugar obrigado à minha família por sempre incentivarem a minha curiosidade e me proporcionarem o privilégio de estudar por todos estes anos. Um obrigado especial à minha avó Luz por me ter dado casa e comida durante os anos que estudei em Lisboa.

Obrigado à Sara por todo o companheirismo, por ser o meu maior apoio e felicidade durante todos estes anos e por sempre acreditar em mim.

Obrigado também aos meus amigos, uns de Portimão outros de Lisboa, que sempre me compreenderam e deram força para acabar este trabalho.

Aos meus orientadores, a professora Paula Paredes e o professor João Rolim, agradeço toda a ajuda e conselhos experientes, sem os quais esta dissertação seria irreconhecível. Obrigado acima de tudo pela paciência e disponibilidade.

Obrigado ao projeto HubIS (Open innovation Hub for Irrigation Systems in Mediterranean agriculture (PRIMA/0006/2019)) pelo fornecimento dos dados climáticos essenciais ao trabalho e igualmente ao projeto WaterQB (Plataforma web para apoio à gestão da rega visando a convivência com a variabilidade e as alterações climáticas (2022.04553.PTDC)).

Resumo

A escassez de água agravada pelas alterações climáticas torna fundamental a implementação de práticas mais eficientes de gestão da rega nos aproveitamentos hidroagrícolas das regiões mediterrânicas. O uso eficiente da água na rega requer a quantificação das necessidades de rega das culturas (NR), a estimativa das necessidades hídricas das culturas e dos restantes termos do balanço hídrico do solo (BH). Para a aplicação precisa do volume necessário, evitando perdas ou stress hídrico indesejado é necessário o conhecimento dos parâmetros culturais, pedológicos e meteorológicos específicos do local.

Neste trabalho pretendeu-se avaliar a utilização de previsões meteorológicas a 3 dias na condução da rega das principais culturas primavera-verão no perímetro de rega do Lucefecit (PRL). A qualidade dos dados de previsão foi avaliada, tendo sido corrigidos quando necessário. Os dados de previsão foram comparados com os dados observados na estação meteorológica do Redondo, de modo a validá-los direta e indiretamente. Validação direta: comparação das distribuições dos dados de previsão e dos dados observados e análise da sua correlação. Validação indireta: análise da condução da rega segundo os dados observados, segundo os dados de previsão, e avaliação dos efeitos da condução com dados de previsão em condições reais.

Os resultados demonstraram que os dados de previsão diários da generalidade das variáveis apresentaram uma elevada correlação com os dados observados e permitiram uma estimativa da evapotranspiração de referência (ET_0) também fortemente correlacionada com a calculada com as observações. O modelo de previsão apresenta, no entanto, uma tendência de rega excessiva, levando à perda de água por drenagem e percolação profunda.

Palavras-chave: Previsões meteorológicas a curto prazo; Condução da rega; Balanço hídrico do solo; Modelação; Necessidades de rega.

Abstract

Water scarcity, exacerbated by climate change, makes it essential to implement more efficient irrigation management practices in the irrigation areas of mediterranean regions. Efficient water use in agriculture requires quantifying the irrigation requirements of crops (IR), the estimation of the crops' water needs and of the remaining terms of the soil water balance (WB). To apply precisely the required water volume, avoiding losses or unwanted water stress, it's necessary to know the specific cultural, soil, and weather parameters of the respective area.

In this study, the goal was to evaluate the use of 3-day ahead weather forecasts in the irrigation scheduling of the main spring-summer crops in the Lucefecit irrigation perimeter (LIP). The quality of the forecast data was assessed and corrected when necessary. The forecast data were compared with the observed data at the Redondo weather station to validate them both directly and indirectly. Direct validation: comparison of the distributions of forecast data and observed data and analysis of their correlation. Indirect validation: analysis of irrigation scheduling according to observed data, according to forecast data, and evaluation of the effects of scheduling with forecast data under real conditions.

The results showed that the daily forecast data of most of the variables showed a high correlation with the observed data and allowed for an estimation of reference evapotranspiration (ET_o) that was also strongly correlated with the one calculated from the observations. However, the forecast model still showed a tendency for excessive irrigation, leading to water loss through drainage and deep percolation.

Keywords: Short-term weather forecasts; Irrigation scheduling; Soil water balance; Modeling; Irrigation Requirements.

Índice:

1. Introdução	1
2. Revisão bibliográfica.....	2
2.1. Clima em Portugal: variabilidade climática e alterações climáticas	2
2.2. Necessidades de rega das culturas.....	4
2.2.1. Evapotranspiração cultural	4
2.2.2. Reserva utilizável de água no solo	8
2.3. Condução da rega	9
2.3.1. Rega para conforto hídrico	9
2.3.2. Rega deficitária.....	9
2.3.3. Condução da rega em tempo real.....	9
2.4. Dados de previsão meteorológica	13
2.4.1. Previsões a longo prazo.....	13
2.4.2. Previsões a curto prazo	14
2.4.3. Bases de dados e espacialização da informação	15
3. Material e Métodos	17
3.1. Caracterização do perímetro de rega do Lucefecit.....	17
3.1.1. Localização	17
3.1.2. Caracterização edáfica	18
3.1.3. Barragem.....	20
3.1.4. Rede de rega primária e secundária	20
3.1.5. Sistemas de Rega	21
3.1.6. Caracterização dos sistemas agrícolas	21
3.2. Caracterização climática da região.....	22
3.3. Caracterização dos Dados meteorológicos	23
3.3.1. Dados Meteorológicos Observados	23
3.3.2. Dados Meteorológicos de Previsão a 3 dias	23
3.4. Seleção dos pontos da grelha	25
3.5. Avaliação da qualidade dos dados	26
3.5.1. Cálculo da ET_0	27
3.6. Validação direta das previsões	27
3.6.1. Comparação da distribuição	28
3.6.2. Análise de correlação	29
3.7. Validação indireta das previsões	31
3.7.1. Parâmetros Culturais.....	31

3.7.2. Parâmetros Pedológicos	35
3.7.3. Características de Rega	35
3.7.4. Necessidades de rega	36
4. Resultados e discussão	37
4.1. Seleção de pontos da grelha	37
4.2. Avaliação prévia da qualidade dos dados	37
4.3. Validação direta das previsões	41
4.3.1. Comparação da distribuição das séries de dados	41
4.3.2. Análise de correlação	43
4.4. Validação indireta das previsões: modelação das necessidades de rega	45
4.4.1. Parâmetros culturais	45
4.4.2. Necessidades de rega	48
4.4.3. Limitações e perspetivas futuras	55
5. Referências bibliográficas	57
6. Anexos	70

Índice de Figuras

Figura 2.1. Curva dos coeficientes culturais de uma cultura anual e definição dos períodos vegetativos correspondentes (Pereira, 2004, 2007).....	7
Figura 3.1. Fluxograma da metodologia utilizada. A verde o input de dados, a cinzento os procedimentos/resultados intermédios e a vermelho o output de resultados.	17
Figura 3.2. Localização e limites do Perímetro de Rega do Lucefecit. Retirado de Aparício (2022).	18
Figura 3.3. Mapa da distribuição e classificação dos solos presentes no Perímetro de Rega do Lucefecit. Retirado de Aparício (2022).	19
Figura 3.4. Frequência relativa dos principais tipos de solos no Perímetro de Rega do Lucefecit: Sr são solos mediterrânicos vermelhos ou amarelos de materiais não calcários, normais, de "rañas" ou depósitos afins; Px são solos mediterrânicos, pardos, de materiais não calcários, normais, de xistos ou grauvaques; A são aluviosolos modernos, não calcários, de textura mediana; e Pc são solos calcários, pardos dos climas de regime xérico, normais, de calcários não compactos (Aparício, 2022).	19
Figura 3.5. Volume médio armazenado na albufeira do Lucefecit nos últimos 10 anos, calculado a partir dos valores mensais, e a média dos respetivos volumes (adaptado de SNIRH, 2023).	20
Figura 3.6. Sistemas de rega e respetivas frequências relativas dos sistemas de rega presentes no Perímetro de rega do Lucefecit (Aparício, 2022).	21

Figura 3.7. Frequência relativa da área ocupada pelas principais culturas regadas do perímetro de rega do Lucefecit e da área não regada (Aparício, 2022).	22
Figura 3.8. Diagrama ombrotérmico da cidade de Évora entre 1981 e 2010 (IPMA, 2022). Onde P é a precipitação média mensal (mm) e T _{méd} é a média mensal das médias diárias da temperatura (°C).	22
Figura 3.9. Fluxograma da origem dos dados de previsão para os 3 dias seguintes. Os modelos informáticos estão a azul-escuro, os submodelos a azul-claro, a laranja dados de input e output e a amarelo o processo de transformação de dados. Adaptado de Bouarfa e Zair (2022).	25
Figura 3.10. Seleção de pontos no mapa - Pontos num raio de 6 km representados a amarelo, estação meteorológica do Redondo a vermelho e pontos não selecionados a preto.	25
Figura 4.1. Comparação dos valores observados (Obs) a), e previstos (Prev) b), da radiação solar global (R _s) a azul, com os valores da radiação solar de céu limpo (R _{so}) a laranja. Os gráficos contêm a radiação (MJ m ⁻² d ⁻¹) em função do dia do ano.	39
Figura 4.2. Valores observados a) e previstos b) corrigidos (Obs-Corr e Prev-Corr) a azul, comparados com os valores da radiação solar de céu limpo (R _{so}), a laranja. Os gráficos contêm a radiação (MJ m ⁻² d ⁻¹) em função do dia do ano.	40
Figura 4.3. Valores diários de ET _o calculados com os dados previstos (ET _o -Prev), observados (ET _o -Obs) e observados mas com a velocidade do vento prevista (ET _o -Obs + u ₂ -Prev); e os respetivos valores médios de todo o período.	41
Figura 4.4. Curvas dos coeficientes culturais (K _c) para cada ano e cultura, representadas em função do dia do ciclo cultural, sendo que o dia 0 corresponde à sementeira e o último à colheita. A azul os valores segundo as observações e a laranja segundo as previsões.	48
Figura 4.5. Gráficos do balanço hídrico para o Milho, a) e b) em 2021, c) e d) em 2022; a) e c) segundo os dados observados (Obs), b) e d) segundo os previstos (Prev). A rosa a capacidade de campo (CC, mm) e o limite da reserva facilmente utilizável (LRFU, mm) e a azul a reserva de água no solo a cada momento (mm).	51
Figura 4.6. Gráficos do balanço hídrico para o Sorgo, a) e b) em 2021, c) e d) em 2022; a) e c) segundo os dados observados (Obs), b) e d) segundo os previstos (Prev). A rosa a capacidade de campo (CC, mm) e o limite da reserva facilmente utilizável (LRFU, mm) e a azul a reserva de água no solo a cada momento (mm).	51
Figura 4.7. Gráficos do balanço hídrico para o milho. segundo as observações (Obs), a) e c), e segundo as previsões tendo em conta as condições observadas (R. Prev), b) e d); em 2021, a) e b), e em 2022, c) e d). A rosa a capacidade de campo (CC, mm) e o limite da reserva facilmente utilizável (LRFU, mm) e a azul a reserva de água no solo a cada momento (mm).	54

Figura 4.8. Gráficos do balanço hídrico para o sorgo. segundo as observações (Obs), a) e c), e segundo as previsões tendo em conta as condições observadas (R. Prev), b) e d); em 2021, a) e b), e em 2022, c) e d). A rosa a capacidade de campo (CC, mm) e o limite da reserva facilmente utilizável (LRFU, mm) e a azul a reserva de água no solo a cada momento (mm).54

Índice de Quadros

Quadro 3.1. Temperatura de base (T_b) e limiar superior de temperatura (T_{cut}) segundo os respetivos autores.	32
Quadro 3.2. Coeficientes culturais (K_c) tabelados para cada fase do ciclo e respetivos autores.	33
Quadro 3.3. Profundidade radicular máxima ($Z_{r_{max}}$, m) e fração de depleção de água no período intermédio do ciclo sem stress (p). $Z_{r_{max}}$ depende da textura e estrutura do solo: o primeiro valor é referente a solos de textura fina e o segundo a solos de textura grosseira.	34
Quadro 3.4. Características das principais classes de solo. Z é a profundidade do solo (m), θ_vCC e θ_vCE são o volume de água por volume de solo (%) à capacidade de campo e no coeficiente de emurchecimento, respetivamente.	35
Quadro 3.5. A capacidade utilizável (U , mm) de cada um dos solos considerados.	35
Quadro 4.1. Comparação da distribuição dos valores diários das diferentes variáveis meteorológicas observadas (Obs) e previstas (Prev).	42
Quadro 4.2. Matriz de confusão da ocorrência de precipitação.	42
Quadro 4.3. Métricas de análise da qualidade da previsão da ocorrência de precipitação.	43
Quadro 4.4. Análise da correlação entre os valores observados e os previstos.	43
Quadro 4.5. Comparação das distribuições da ET_o calculada com os valores observados (ET_o -Obs) com a ET_o calculada apenas com os dados previstos (ET_o -Prev1) e com a ET_o calculada com os valores previstos mas com a velocidade do vento média observada nos últimos 10 anos (ET_o -Prev2).	45
Quadro 4.6. Comparação da correlação entre a ET_o calculada com os valores observados (ET_o -Obs) e a ET_o calculada com os valores previstos (ET_o 1). E comparação da correlação entre a ET_o -Obs e a ET_o calculada com os valores previstos mas com a velocidade do vento média observada nos últimos 10 anos (ET_o 2).	45
Quadro 4.7. Graus-dia de desenvolvimento (GDD) de cada um dos períodos do ciclo cultural em 2020 ($^{\circ}C$ dia).	46
Quadro 4.8. Duração de cada período fenológico e do ciclo completo em 2020.	46
Quadro 4.9. Comparação da duração (dias) de cada período fenológico do milho segundo as observações (Obs) e as previsões (Prev) para cada ano.	46

Quadro 4.10. Valores dos coeficientes culturais simples (K_c) ajustados ao clima para as culturas selecionadas e anos em estudo quando são usados os dados observados (Obs) e os dados previstos (Prev).	47
Quadro 4.11. Volume regado (mm) por mês e o total regado em cada cultura em cada ano, segundo os dados observados (obs) e previstos (prev). O RMSE mensal entre os dois grupos de dados de cada ano.	49
Quadro 4.12. Datas da primeira e última rega e respetiva duração do período de rega (P. de rega, dias) de cada cultura em cada ano, segundo os dados observados (obs) e previstos (prev).....	49
Quadro 4.13. A ET_c acumulada durante o período de rega (ET_c ac., mm), o volume perdido por drenagem e percolação profunda (V. perd., mm) e a quebra de produção devido ao stress hídrico (Q. prod., %).	50
Quadro 4.14. A relação entre a diferença nos volumes aplicados (ΔV) e a diferença de ET_c ac. (ΔET_c). Onde ΔV é o volume de rega previsto menos o observado; e o ΔET_c é a ET_c acumulada prevista menos a observada.....	52
Quadro 4.15. A ET_c acumulada durante o período de rega (ET_c ac., mm), o volume perdido por drenagem e percolação profunda (V. perd., mm) e a quebra de produção devido ao esquema de rega usado (Q. prod., %). Para a condução segundo os dados observados (Obs) e o resultado da condução segundo as previsões tendo em conta as condições observadas (R. Prev).....	53

Lista de Símbolos

θ_{vCC}	Teor de água do solo à capacidade de campo ($m^3 m^{-3}$)
θ_{vCE}	Teor de água do solo ao coeficiente de emurchecimento ($m^3 m^{-3}$)
\bar{x}	Média
b_o	Declive resultante de uma regressão linear forçada à origem (adm.)
E_s	Evaporação do solo (mm)
ET	Evapotranspiração (mm)
ET_c	Evapotranspiração cultural (mm)
ET_c ac.	Evapotranspiração acumulada durante o período de rega (mm)
ET_o	Evapotranspiração de referência (mm)
ET_o -Obs	Evapotranspiração calculada com os dados meteorológicos observados (mm)
ET_o -Prev	Evapotranspiração calculada com os dados meteorológicos previstos (mm)
GDD	Acumulação de unidades de calor ou graus-dia de desenvolvimento ($^{\circ}C$ dia)
HR	Humidade relativa (%)
HR_{max}	Humidade relativa máxima (%)
HR_{med}	Humidade relativa média (%)
HR_{min}	Humidade relativa mínima (%)
K_c	Coeficiente cultural (adm.)
$K_{c\ end}$	Coeficiente cultural na fase final do ciclo da cultura (adm.)
$K_{c\ ini}$	Coeficiente cultural na fase inicial do ciclo da cultura (adm.)
$K_{c\ mid}$	Coeficiente cultural na fase intermédia do ciclo da cultura (adm.)
K_{cb}	Coeficiente de transpiração (adm.)
K_e	Coeficiente de evaporação (adm.)
K_s	Coeficiente de stress hídrico e/ou salino (adm.)
LRFU	Limite da reserva facilmente utilizável (mm)
MSE	Erro quadrático médio
NSE	Coeficiente de eficiência de Nash–Sutcliffe
p	Défice permissível de água no solo (adm.)
P	Precipitação (mm)
Q. prod	Estimativa de quebra de produção devida ao stress hídrico (%)
R^2	Coeficiente de correlação de uma regressão linear normal (adm.)
RFU	Reserva facilmente utilizável (mm)
RMSE	Raiz do erro quadrático médio
R_s	Radiação solar global ($MJ m^{-2} d^{-1}$)

R_{so}	Radiação de curto comprimento de onda com o céu limpo ($\text{MJ m}^{-2} \text{d}^{-1}$)
RU	Reserva utilizável de água no solo (mm)
T_b	Temperatura de base ($^{\circ}\text{C}$)
T_c	Transpiração da cultura (mm)
T_{cut}	Limiar superior de temperatura ($^{\circ}\text{C}$)
T_{max}	Temperatura máxima diária ($^{\circ}\text{C}$)
T_{med}	Temperatura média diária ($^{\circ}\text{C}$)
T_{min}	Temperatura mínima diária ($^{\circ}\text{C}$)
u_2	Velocidade média do vento a 2 m de altura (m s^{-1})
V. perd.	Volume perdido por drenagem e percolação (mm)
Z_r	Profundidade radicular (m)
$Z_{r_{max}}$	Profundidade radicular máxima (m)
ΔET_c	Diferença entre evapotranspiração cultural estimada segundo as previsões e segundo as observações (mm)
ΔV	Diferença entre o volume de rega aplicado segundo as previsões e segundo as observações (mm)
σ	Desvio padrão

Lista de Acrónimos, siglas e abreviaturas

A	Solos Incipientes - aluviosolos modernos, não calcários, de textura mediana
ABL	Associação de beneficiários do Lucefecit
ARW	Advanced Research Weather Research and Forecasting
BH	Balanço hídrico do solo
CC	Capacidade de campo
CE	Coeficiente de emurchecimento
COTR	Centro Operativo e de Tecnologia de Regadio
CROPWAT	Modelo para a simulação do balanço hídrico do solo
Csa	Clima temperado mediterrânico com verão quente e seco
Csb	Clima temperado mediterrânico com verão seco e suave
csv	Formato de ficheiro com valores separados por vírgulas
DI	Rega deficitária convencional
ECMWF	Centro Europeu de Previsão do Tempo a Médio Prazo
EMR	Estação meteorológica do Redondo
FAO	Organização das Nações Unidas para a Alimentação e Agricultura
FAO-PM	Abordagem da FAO para o cálculo da ET_c com a equação de Penman-Monteith
FDR	Refletometria de domínio de frequência
FN	Falsos negativos
FP	Falsos positivos
GFS	Global Forecasting System
GPR	Método georadar
HS	Hargreaves-Samani
HUBIS	Open innovation Hub for Irrigation Systems in Mediterranean agriculture
IDW	Ponderação pelo inverso da distância
IFAP	Instituto de Financiamento da Agricultura e das Pescas
INE	Instituto Nacional de Estatística
INIAV	Instituto Nacional de Investigação Agrária e Veterinária
IPMA	Instituto Português do Mar e da Atmosfera
IrrigRotation	Modelo para a simulação do balanço hídrico do solo
ISAREG	Modelo para a simulação do balanço hídrico do solo
Milho-A	Milho plantado em aluviosolos modernos, não calcários, de textura mediana
NASA	US National Aeronautics and Space Administration
NCAR	National Center for Atmospheric Research

NCEP	National Centers for Environmental Prediction
NGR	Necessidades globais de rega
NMM	Nonhydrostatic Mesoscale Model
NOAA	National Oceanic and Atmospheric Administration
NOMADS	Sistema Nacional de Arquivo e Distribuição de Modelos Operacionais da NOAA
Obs	Dados observados
Pc	Solos calcários, pardos dos climas de regime xérico, normais, de calcários não compactos
PILOTE	Modelo para a simulação do balanço hídrico do solo com rega
PRD	Rega deficitária alternada
Prev	Dados de previsão
PRL	Perímetro de Rega do Lucefecit
Px	Solos Argiluvitados Pouco Insaturados - solos mediterrânicos, pardos, de materiais não calcários, normais, de xistos ou grauvaques
RDI	Rega deficitária controlada
SIMDualKC	Modelo para a simulação do balanço hídrico do solo com rega
Sorgo-Sr	Sorgo plantado em solos mediterrânicos vermelhos ou amarelos de materiais não calcários, normais, de "rañas" ou depósitos afins
Sr	Solos argiluvitados pouco insaturados – solos mediterrânicos vermelhos ou amarelos de materiais não calcários, normais, de "rañas" ou depósitos afins
TDR	Refletometria de domínio de tempo
UCAR	University Corporation for Atmospheric Research
UHA	Unidades homogéneas de análise
VDC	Varição do diâmetro do caule
VN	Verdadeiros negativos
VP	Verdadeiros positivos
VPPT	Valor de produção padrão total
WIS	World Weather Information Service
WMO	World Meteorological Organization
WRF	Weather Research and Forecasting

1. Introdução

A agricultura e a pecuária utilizam 74,7% do volume total de água consumida em Portugal continental (excluindo o sector enérgico) (APA, 2015). Esta água é usada na rega de 14,3% da superfície agrícola utilizada (SAU), de onde provém 56,1% do valor de produção padrão total (VPPT) do país, alcançando as explorações predominantemente de regadio (com área de regadio superior a ¼ da respetiva SAU) um VPPT médio por hectare de 5,5 mil euros, mais do triplo da média nacional (1,7 mil euros) (INE, 2021). Estes valores revelam o impacto do regadio na produtividade agrícola, demonstrando a sua importância para a segurança alimentar, desenvolvimento da sociedade e a sustentação dos meios rurais (Elshaikh et al., 2018).

Portugal é o quinto país da união europeia (UE28) com maior proporção da SAU regada, sendo regada apenas 6,0% da SAU da UE28. Os países do sul da europa apresentam os valores mais elevados, liderando Malta com 31,4% (INE, 2021). A elevada necessidade de rega nestes países deve-se ao clima mediterrânico, caracterizado pela escassez de água, não apenas em termos absolutos, mas pela concentração de precipitação nos meses de inverno e pela elevada variabilidade interanual com a presença de secas frequentes (Lionello et al., 2006), quando a rega é essencial. O bioclima mediterrânico é ainda altamente vulnerável aos efeitos das alterações climáticas (Rocha et al., 2020), sendo esperado que a temperatura aumente mais do que a média mundial e que a dependência da rega seja exacerbada (Fader et. al., 2016). É, portanto, imperativa a otimização da utilização da água na rega em Portugal.

A calendarização da rega, a tomada de decisão sobre quando e quanto regar, tem um papel fulcral na eficiência do uso da água na rega, na produtividade agrícola e nos rendimentos dos agricultores (Pereira, 1999; 2004). Esta tomada de decisão precisa frequentemente de ocorrer com dias de antecedência, pelo que um aspeto essencial para uma boa condução da rega é a capacidade de prever com antecedência e precisão o consumo de água da cultura e o conteúdo de água no solo. Esta previsão depende de vários fatores, como o conteúdo inicial de água no solo, a condição da cultura e das condições meteorológicas (Guo et al., 2022).

No que toca ao solo e à cultura, ferramentas como Sistemas de Informação Geográfica (SIG), Deteção Remota (DR) e modelação do Balanço Hídrico (BH) têm sido usadas nos últimos anos em diversos estudos para estimar parâmetros associados ao regadio, tais como os volumes de água a aplicar na rega, índices de stress hídrico, condução da rega ou gestão do meio ambiente (Calera et al, 2017; Dari et al., 2020, Pôças et al., 2020). Usando estas ferramentas, foi também realizado um estudo que

determinou e especializou as necessidades globais de rega do Perímetro de Rega do Aproveitamento Hidroagrícola do Lucefecit (Aparício, 2022).

A utilização de dados de previsões meteorológicas a curto prazo e sazonais no apoio à decisão têm sido objeto de vários estudos nas últimas décadas. No entanto, esses estudos focam frequentemente a utilização e validação das previsões a um nível nacional ou regional, pelo que os agricultores tendem a beneficiar pouco da informação produzida (Lorite et al., 2015; Capa-Morocho et al., 2016; Cao et al., 2019). É necessário, por isso, o desenvolvimento de métodos que cheguem a uma harmonização entre praticidade, precisão e universalidade (Gu et al. 2020).

O objetivo principal do presente estudo é a avaliação da usabilidade de dados de previsão diários de diversas variáveis meteorológicas no apoio à decisão na condução da rega em culturas selecionadas do Perímetro de rega do Lucefecit. Os dados de previsão são produzidos no âmbito do projeto HUBIS “Open innovation Hub for Irrigation Systems in Mediterranean agriculture, PRIMA/0006/2019, 2020-2023”.

2. Revisão bibliográfica

2.1. Clima em Portugal: variabilidade climática e alterações climáticas

De acordo com o sistema de classificação de Köppen-Geiger, atualizado por Beck et al. (2018), o clima de Portugal continental é classificado como temperado (C) por ter a temperatura média no mês mais quente do ano superior a 10 °C e a do mês mais frio entre 0 e 18 °C. No que toca à precipitação, Portugal continental corresponde ao subtipo verões secos (Cs) por ter uma precipitação no mês mais seco do verão inferior a 40 mm e também inferior a um terço da precipitação no mês mais húmido do ano. Em Portugal continental, o clima Cs está presente em duas variações: clima mediterrânico de verão suave (Csb), em que a temperatura média no mês mais quente é inferior a 22 °C e a temperatura média mensal é superior a 10 °C durante mais de 4 meses, que abrange as regiões do litoral alentejano e todo o norte de Portugal (exceto na terra quente de Trás-os-Montes); e clima mediterrânico de verão quente Csa, em que a temperatura média mensal do mês mais quente é superior a 22 °C (Beck et al., 2018; IPMA, 2024).

Assim, a estação húmida em Portugal continental coincide com o período de menores temperaturas, enquanto a estação seca coincide com o período de temperaturas mais elevadas, altura em que a rega é fundamental para o desenvolvimento das culturas pois colmata a necessidade de água das plantas numa época em que a precipitação não é suficiente (Pereira, 2004). A rega compensa ainda a variabilidade inter e intra-anual da precipitação e da temperatura, que restringe a produção das culturas numa dada região. Assim, para obter elevadas produções e para fazer face à elevada

variabilidade da precipitação (e.g. Claro et al., 2023) a rega de complemento tem vindo a tornar-se uma prática recorrente (e.g. Paredes et al., 2017). A rega atua na proteção das culturas, nomeadamente no controlo das geadas, da temperatura e/ou humidade e no controlo de parâmetros de qualidade produtiva, como a maturação (Oliveira, 2011).

As alterações climáticas aumentam a variabilidade climática e a ocorrência de eventos extremos e com uma tendência para que estes venham a ter proporções e consequências cada vez mais graves, nomeadamente na agricultura (Fraga & Santos 2021; Fonseca et al., 2022). As alterações climáticas têm alterado as datas de ocorrência de eventos fenológicos (Freitas et al., 2023; Fonseca et al., 2024), o crescimento e produção das culturas (e.g. Yang et al., 2017; 2020), as necessidades hídricas das culturas (e.g. Rolim et al., 2017; Rocha et al., 2020; Branquinho et al., 2021), a competição de infestantes e eficiências dos herbicidas (e.g. Peters et al., 2014; Varanasi et al., 2016), na incidência de pragas e doenças (e.g. Raza et al., 2019; Skendžić et al., 2021) e na eficiência dos pesticidas, na taxa de erosão do solo (e.g. Abreu, 2018 Eekhout & de Vente, 2022) e, por último, nas condições económicas, financeiras e sociais, dos agricultores (Fragoso & Noéme, 2014; Abreu, 2018). Alguns estudos assumem um agravamento das alterações climáticas com o aumento da temperatura, a diminuição da precipitação e o aumento da frequência e intensidade de eventos extremos (e.g., secas, inundações, tempestades e deslizamentos de terra), o que resultará na redução da disponibilidade e qualidade da água, afetando a sua distribuição, o escoamento dos rios e as reservas de água subterrânea (Falloon e Betts, 2010; UN-Water, 2020).

No sul da europa, de acordo com Fader et al. (2016), é provável um aumento da temperatura superior à variação global, que poderá resultar num aumento das necessidades brutas de rega de 18% até 2080 (apenas considerando os impactos das alterações climáticas, como fator). Para a zona do Alentejo, Rolim et al. (2017) apresentou uma estimativa de aumento médio das necessidades de rega para as culturas de cevada, trigo, beterraba sacarina, girassol, milho e tomate, de 15 a 20% até 2100.

Como anteriormente mencionado, prevê-se que as situações de escassez de água se tornem mais frequentes e intensas em Portugal, assim como os decorrentes efeitos negativos em termos socioeconómicos, pelo que a racionalização e o aumento da eficiência do uso da água ao nível da produção agrícola são adaptações necessárias a uma gestão sustentada da água a longo prazo (Falloon e Betts, 2010; Rolim et al., 2014). Existe, no entanto, alguma inconsistência no que toca à tendência de um aumento de secas extremas como consequência das alterações climáticas: Moreira et. al (2012) demonstraram que a análise de séries longas (95-135 anos) de dados de precipitação de Portugal não suporta esta conclusão, mas sim a existência nalguns locais do sul, de ciclos de longa duração com alternância entre um subperíodo com poucas secas severas e um subperíodo com secas severas

frequentes, durando cada subperíodo entre 26 a 30 anos; para o norte de Portugal continental, não encontraram qualquer evidência nem de um comportamento cíclico nem de tendência a agravamento das secas. Vicente-Serrano et al. (2022), analisando os défices de precipitação, não encontraram um aumento da intensidade das secas meteorológicas nos últimos 120 anos e que o este aumento parece estar exclusivamente ligado a um forte aumento observado da demanda evaporativa da atmosfera (DEA) nas últimas quatro décadas, com implicações agrícolas e ecológicas significativas, estes estudos reforçam a importância do estudo de séries temporais longas; já Páscoa et al. (2021) demonstraram que as tendências de duração e intensidade das secas na península ibérica variam espacialmente, decrescendo em certas zonas.

2.2. Necessidades de rega das culturas

O uso eficiente da água na agricultura requer o conhecimento adequado das necessidades hídricas das culturas e dos restantes termos do balanço hídrico do solo (BH), a partir das quais se obtêm as necessidades de rega (Allen et al., 1998).

2.2.1. Evapotranspiração cultural

Ao processo de perda de água de um coberto vegetal denomina-se de evapotranspiração cultural (ET_c) e está limitado pela energia disponível assim como pela água disponível do solo. A evapotranspiração cultural tem duas componentes. A primeira corresponde à perda de água pela superfície do solo ou evaporação de água do solo (E_s) e a segunda à transpiração da cultura (T_c), que corresponde à perda de água através dos estomas. Estes dois processos ocorrem simultaneamente e não há maneira fácil de os distinguir, são por isso considerados em conjunto na quantificação do consumo de água. A ET_c depende, para além da energia disponível (radiação), de diferentes variáveis meteorológicas como a temperatura do ar, humidade do ar e da velocidade do vento. A ET_c depende de outros fatores como da disponibilidade hídrica, da permeabilidade do solo, da salinidade do solo, das técnicas de cultivo, estado nutricional e sanitário da cultura assim como da presença de infestantes (Allen et al., 1998; Pereira, 2004).

A ET_c de um coberto pode ser medida ou estimada. Neste último caso a metodologia mais utilizada é a da FAO (Allen et al., 1998), na qual são usados dados meteorológicos e algoritmos que descrevem a energia da superfície e as características aerodinâmicas da vegetação. Como referido, a ET_c pode ser medida usando sistemas que requerem a aplicação de princípios físicos e técnicas relativamente complexas. Allen et al. (2011) revêem os métodos, sua robustez e limitações, usados em campo para a medição da ET_c . A medição da ET_c exige equipamento específico e medições precisas de vários parâmetros físicos. Os equipamentos são normalmente caros e os métodos exigentes na qualidade da sua execução, pelo que são apenas exequíveis por investigadores qualificados, o que os torna

inapropriados para medições rotineiras. Métodos comuns de medição da ET incluem o balanço hídrico do solo, lisimetria (drenagem, pesagem ou de toalha freática), razão de Bowen, método das flutuações instantâneas, e os de medição separada da T_c e E_s utilizando o fluxo de seiva e micro- ou mini-lisímetros respetivamente (Pereira, 2004; Allen et al., 2011). A utilização de deteção remota permite a obtenção da ET quer usando modelos de balanço de energia ou indiretamente usando índices de vegetação para a determinação dos coeficientes culturais. Estes métodos permanecem, no entanto, importantes na avaliação de estimativas de ET obtidas por métodos indiretos (Allen et al., 1998; Allen et al., 2011).

Em muitos sistemas agrícolas, a densidade das plantas, a altura, o vigor e a disponibilidade de água são normalmente uniformes, e a aplicação de algoritmos de estimativa da ET_c e a sua medição são relativamente simples. No caso de florestas e oásis, a sua natureza heterogénea dificulta a estimativa dos processos físicos, pelo que a maior parte da informação relativa à ET_c destes locais provém de medições *in-situ*. Para uma dada cultura, a ET_c corresponde à evapotranspiração da cultura em condições agronómicas ótimas e de plena disponibilidade hídrica do solo, de forma que a cultura atinja o seu potencial produtivo (Allen et al., 2011). No caso de ocorrer stress hídrico, salinidade ou devido a condições não ótimas de cultivo a ET_c passa a ser menor do que o seu valor potencial e denomina-se de evapotranspiração real das culturas ($ET_{c\ act}$).

O método de Penman-Monteith (PM) é um modelo analítico de estimativa da ET, baseando-se em princípios aerodinâmicos e no balanço de energia, é por isto chamado um modelo de combinação (Allen et al., 1998):

$$ET = \frac{\Delta(R_n - G) + \rho_a \times c_p \frac{(e_s - e_a)}{r_a}}{\Delta + \gamma(1 + \frac{r_s}{r_a})} \quad (2.1)$$

onde R_n ($\text{MJ m}^{-2} \text{ day}^{-1}$) é a radiação líquida à superfície da cultura, G o fluxo de calor do solo ($\text{MJ m}^{-2} \text{ day}^{-1}$), $(e_s - e_a)$ é o défice da pressão do vapor no ar (kPa), ρ_a a densidade média do ar a pressão constante (kg m^{-3}), c_p o calor específico do ar ($\text{MJ kg}^{-1} \text{ }^\circ\text{C}^{-1}$), Δ o declive da relação pressão-temperatura na saturação do vapor (kPa), γ a constante psicrométrica ($\text{kPa } ^\circ\text{C}^{-1}$), e r_s e r_a respetivamente a resistência de superfície e aerodinâmica (s m^{-1}).

A aplicação desta equação permite calcular diretamente a ET da respetiva cultura, mas requiere o conhecimento de vários parâmetros, tanto meteorológicos como da superfície evaporante, de modo a estimar a resistência de superfície (r_s) e a resistência aerodinâmica (r_a), que são influenciadas pelas características do copado de cada cultura e das práticas culturais. É extremamente difícil estimar estes parâmetros para cada cultura e estágio de crescimento, pelo que foi introduzido o conceito de

superfície de referência para que, a partir da ET desta superfície (ET_o), fosse depois estimada a ET da cultura em questão (ET_c) usando para tal um coeficiente cultural (K_c) o qual representa as diferenças entre a cultura de referência e aquela em estudo em termos de comportamento energético e aerodinâmico (Allen et al., 1998; Pereira, 2004). Neste sentido, Allen et al. (1998) parametrizaram a equação de PM para uma cultura de referência hipotética, para a qual se assume uma altura constante de 0.12 m, uma r_s constante de 70 s m^{-1} e um albedo de 0.23, semelhante à evapotranspiração de um extenso coberto de relva de altura uniforme, em crescimento ativo, cobrindo totalmente o solo e bem abastecido de água. Assim, a eq. 2.1 toma a forma seguinte, designada como equação FAO-PM para a evapotranspiração de referência (Allen et al., 1998; Pereira, 2004):

$$ET_o = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T + 273} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0.34u_2)} \quad (2.2)$$

onde T é a temperatura do ar a 2 m de altura ($^{\circ}\text{C}$) e u_2 é a velocidade do vento a 2 m de altura (m s^{-1}).

O método FAO-PM é recomendado como o standard para o cálculo da ET_o . Em caso de dados meteorológicos em falta, estão também estandardizados os métodos de cálculo que os permitem estimar.

Usando a metodologia da FAO, a ET_c diária da cultura (mm d^{-1}) é estimada como:

$$ET_c = ET_o \times K_c \quad (2.3)$$

onde ET_o é a evapotranspiração da cultura de referência (mm d^{-1}) e K_c é o coeficiente cultural médio (adimensional).

Sob condições não standard, a ET_c é ajustada usando o coeficiente de stress hídrico e/ou salino (K_s) modificando o K_c (Allen et al., 1998), assim a evapotranspiração real é obtida como $ET_c \text{ act} = K_s K_c ET_o$.

Allen et al. (1998) consideram a utilização de um K_c médio mais relevante e conveniente para um uso prático na condução da rega do que a utilização da aproximação dual, ou seja, usando coeficientes de transpiração e evaporação em separado ($K_{cb} + K_e$), exceto em casos de regas de elevada frequência, como é o caso da microrrega, para culturas com cobertura parcial do solo, como os pomares e as hortícolas (Pereira, 2004; Allen et al., 2005). A aproximação dual permite adicionalmente avaliar os impactos de diferentes práticas agrícolas sobre o uso da água pelas culturas, tanto as que maximizam a transpiração da cultural (T_c) como aquelas que focam a minimização da evaporação do solo (E_s) (Pereira, 2004).

Como mencionado, o K_c varia durante o ciclo da cultura: à medida que a cultura se desenvolve e cresce o valor de K_c aumenta e à medida que a cultura atinge a maturação e inicia a senescência o valor de K_c tende a decrescer. É possível, assim, evitar cálculos diários, nomeadamente da componente de evaporação da água do solo (K_e), ao construir uma curva do K_c que caracterize tipicamente o desenvolvimento de uma dada cultura anual, desde a sementeira ou plantação até à colheita (Figura 2.1.). Para este fim, o ciclo cultural é dividido em quatro períodos, de acordo com a fenologia e o desenvolvimento da cultura: inicial, de crescimento rápido, intermédio e final; e são definidos os valores de K_c que correspondem aos períodos inicial ($K_{c\ ini}$), intermédio ($K_{c\ mid}$) e ao final ($K_{c\ end}$), por último, considera-se que nos períodos de crescimento rápido e final o K_c varia linearmente entre os valores que precedem e sucedem (Allen et al., 1998).




Figura 2.1. Curva dos coeficientes culturais de uma cultura anual e definição dos períodos vegetativos correspondentes (Pereira, 2004, 2007).

Os valores de K_c obtidos em ensaios experimentais ou em campos de agricultores diferem dos valores tabelados pela FAO (Allen et al., 1998), quer por impacto de stress, práticas culturais ou ainda pelo facto de estes terem sido determinados para um clima sub-húmido caracterizado por uma HR_{\min} de 45% e uma velocidade média do vento de 2 m s^{-1} . Assim, em condições meteorológicas díspares é necessário proceder ao ajustamento dos valores do $K_{c\ mid}$ e $K_{c\ end}$ como descrito por Allen et al. (1998).

Em culturas permanentes, no caso de serem árvores de folha caduca, os períodos intermédio e final são bastante longos, pelo que o ajustamento do K_c à HR_{\min} e à u_2 deve ter em consideração a variabilidade climática ao longo dos períodos vegetativos, ou seja, o K_c deverá ser ajustado por estações do ano: e.g., primavera, verão e outono ou estação seca e húmida. No caso de árvores e arbustos de folha persistente, em locais onde a temperatura não varia muito, como em climas tropicais, o $K_{c\ ini}$ e o $K_{c\ end}$ são frequentemente iguais. Nestas condições, ajustes sazonais às condições meteorológicas podem não ser necessários por as variações na ET_c dependerem maioritariamente de variações na ET_o (Allen et al., 1998).

2.2.2. Reserva utilizável de água no solo

É fundamental conhecer as necessidades de rega para decidir quando e quanto regar. O que envolve a contabilização, para um determinado período, das entradas e saídas de água do perfil do solo explorado pelas raízes, ou seja, o balanço hídrico (BH). Se num período as entradas de água forem superiores às saídas de água, devido a chuva ou rega ou ainda a contribuição da toalha freática, o solo reterá a água até que a capacidade de campo (CC) seja atingida. A CC é a quantidade de água que um dado solo consegue reter contra a força gravitacional, a partir da qual toda a água adicionada é drenada e, no caso da rega, tornando-se um uso não benéfico da água (Pereira, 2004; Pereira et al., 2012). Já se as saídas de água forem superiores às entradas de água, o conteúdo de água disponível na zona explorada pelas raízes decrescerá. A redução do teor de água do solo, resulta num aumento da força de retenção da água pelas partículas do solo, tornando progressivamente mais difícil a absorção da água pelas raízes da planta. Eventualmente esta força atinge um valor que não consegue ser superado pelas plantas, nomeadamente as raízes, ficando a cultura incapaz de utilizar a água presente no solo sem entrar em stress (Pereira, 2004). O limiar inferior de água disponível para as plantas corresponde ao coeficiente de emurchecimento (CE), a partir do qual a cultura murchará permanentemente (Ramos et al., 2017).

Deste modo, a reserva útil (RU, mm) é a diferença entre a CC e o CE na zona radicular:

$$RU = 1000(\theta_{vCC} - \theta_{vCE})Z_r \quad (2.4)$$

onde θ_{vCC} é o teor de água do solo à capacidade de campo ($m^3 m^{-3}$), θ_{vCE} é o teor de água do solo ao coeficiente de emurchecimento ($m^3 m^{-3}$), e Z_r a profundidade radicular (m).

A dificuldade de extração de água do solo pela cultura resulta em stress hídrico, comprometendo a produção. Este ponto denomina-se limite da reserva facilmente utilizável (LRFU). À quantidade de água contida entre o CE e a CC e que a cultura consegue extrair sem entrar em stress hídrico corresponde à reserva facilmente utilizável (RFU, mm) (Allen et al., 1998; Pereira, 2004):

$$RFU = RU p \quad (2.5)$$

onde p corresponde à fração da água do solo extraível sem afetar a produção, i.e., a fração da RU que pode ser extraída da zona radicular sem que ocorra stress hídrico (Pereira, 2004; Ramos et al., 2017)

2.3. Condução da rega

A condução da rega consiste na tomada de decisão de quando e quanto regar, tendo em conta múltiplos fatores: como as necessidades de rega da cultura, as características do sistema de rega e a disponibilidade de água.

2.3.1. Rega para conforto hídrico

Quando a água existe em quantidade suficiente e o seu preço é relativamente baixo pode ser praticada rega para conforto hídrico (Oliveira, 2011). Esta rega consiste na prática da rega de modo a impedir o stress hídrico, maximizando a transpiração da planta, a fotossíntese e, conseqüentemente, a produção, o que implica regar frequentemente de modo a não permitir a descida do conteúdo de água do solo abaixo do LRFU (Allen et al., 1998; Oliveira, 2011).

2.3.2. Rega deficitária

Quando a água tem disponibilidade limitada e/ou um custo elevado, a melhor decisão poderá ser a indução deliberada de stress hídrico. Uma condução da rega com defice hídrico permite reduzir o volume de água usada na rega e aumentar a eficiência do uso de água na rega (Pereira, 2004). Para além disso, em muitas culturas, o stress hídrico desempenha um papel fundamental na indução de características culturais desejadas, como alterações na duração dos períodos do ciclo cultural e o aumento da qualidade e valor do produto final (Pereira, 2004; Fereres & Soriano, 2007; Rallo et al. 2017; Vélez-Sánchez et al., 2021; Romero et al. 2022). Existem várias estratégias de rega deficitária: a) Rega deficitária convencional ou “sustained deficit irrigation” (DI), consiste na aplicação de uma fração da evapotranspiração cultural (ET_c) mais ou menos constante desde o início da rega até à proximidade da colheita; b) Rega deficitária controlada ou “Regulated deficit irrigation” (RDI), consiste na imposição de rega deficitária com períodos de stress hídrico em fases específicas do ciclo da cultura.; e c) Rega alternada de parte das raízes ou “partial rootzone drying” (PRD) consiste na rega alternada a cada metade do sistema radicular por determinados períodos podendo variar entre 6 a 15 dias.

2.3.3. Condução da rega em tempo real

A condução envolve o conhecimento das transferências hídricas no conjunto solo-planta-atmosfera e na determinação das necessidades diárias de rega das culturas (Pereira, 2004). Em particular a condução em tempo real implica determinar não só a dotação da rega, mas também a oportunidade da sua aplicação. Assim, existem vários métodos para a condução da rega como descritos nos próximos pontos.

2.3.3.1. Medição do estado hídrico do Solo

A medição do conteúdo de água no solo pode ser feita por métodos diretos ou indiretos. Nos métodos diretos a água no solo é medida calculando a diferença de massa antes e depois de o solo ser seco; nos métodos indiretos são feitas medições através de calibrações com outras variáveis mensuráveis que variam com a humidade do solo (Pereira, 2004; Dobriyal et al., 2012).

O único método direto é o método gravimétrico, no qual uma amostra de solo de volume conhecido é seca a 105 °C durante 24 h e o peso final é subtraído ao inicial. Esta técnica tem as vantagens de ser simples, precisa e ter um baixo custo-benefício, e as desvantagens de ser trabalhosa, demorada, destrutiva e difícil de aplicar em solos rochosos (Dobriyal et al., 2012).

À exceção de deteção remota, todos os métodos indiretos são aplicados in situ, ou seja, envolvem o contacto direto entre os instrumentos e o solo. Destes métodos, alguns dos mais comuns são o uso de tensiómetros, de psicrómetros e de blocos de resistência elétrica (Dobriyal et al., 2012).

O tensiómetro é um instrumento que mede a força ou tensão de retenção da água no solo. O instrumento é inserido no solo e alterações na tensão capilar são medidas por um manómetro (Dobriyal et al., 2012; Abd el Baki et al., 2018).

O reflectómetro de domínio de tempo (TDR) mede a velocidade de propagação de um pulso eletromagnético, através da qual é deduzido o teor volumétrico de água no solo (Dasberg e Dalton, 1985; Rana e Katerji, 2000; Dobriyal et al., 2012). Já a reflectometria de domínio de frequência (FDR) é semelhante à TDR, mas o conteúdo de água é estimado através da variação da frequência do sinal (Dobriyal et al., 2012; Ojo et al., 2015).

O método georadar (GPR) recorre à medição da transmissão e reflexão de uma onda eletromagnética no solo para estimar o conteúdo de água no solo (Gerhards et al., 2008; Bittelli, 2011; Dobriyal et al., 2012).

As sondas psicrométricas medem a capacitância entre dois eléctrodos enterrados no solo e permitem obter o valor absoluto de água no solo e o perfil de humidade (Dobriyal et al., 2012; Sangha et al., 2023).

O bloco de gesso é uma célula eletroquímica com uma solução saturada de sulfato de cálcio servindo de eletrólito. Os blocos absorvem a humidade do solo e a alteração da condutividade elétrica permite saber o potencial matricial e o conteúdo de água do solo (Stenitzer, 1993; Dobriyal et al., 2012).

A deteção remota é um método que consiste na medição e análise da radiação eletromagnética refletida ou emitida por uma superfície e recebida por sensores, sem que sejam necessários o contacto

material entre o sistema observado e o observador. A deteção remota do conteúdo de água no solo depende da intensidade da radiação eletromagnética refletida ou emitida pela superfície do solo, que por sua vez depende da humidade do solo. A deteção remota é mais apropriada para áreas grandes e é complexa e cara. Existe também alguma incerteza na relação entre o brilho, a temperatura e a água no solo, o que limita a precisão. A precisão é também afetada pelo facto de a informação corresponder à média para a área de cada pixel, não sendo detetada heterogeneidade subjacente (Dobriyal et al., 2012; Paredes et al., 2021).

2.3.3.2. Medições ao nível da planta

Alterações na quantidade de água no solo provocam consequentemente alterações ao nível da planta. Alguns destes principais métodos são a medição do fluxo de seiva, a medição da variação do diâmetro do caule e a medição do potencial hídrico foliar e do ramo.

Como já mencionado, o decréscimo do potencial hídrico do solo provoca a diminuição da transpiração da planta. Um dos métodos para a medição desta variação nas plantas lenhosas assenta no facto de, por consequência da diminuição da transpiração, haver também um decréscimo do fluxo ascendente de seiva (xilema) aquando do stress hídrico. Este método tem utilidade na monitorização da ET_c , e respetiva condução da rega, de culturas lenhosas relevantes em Portugal: como a Oliveira (Fernández et al., 2001; Cammalleri et al., 2013) e a vinha (Ginestar et al., 1998; Ferreira et al., 2012), apesar de apresentar limitações práticas no que toca à necessidade de calibração e ao seu custo (Dix et al., 2021).

A variação do diâmetro do caule (VDC) serve como indicador de stress hídrico por as variações no diâmetro do caule causadas pela variação dos níveis de hidratação da planta serem muito maiores que as resultantes do crescimento diário de tecidos ou diretamente de variações de temperatura. Esta medição é feita por um dendrómetro calibrado, atado justo ao caule, sem afetar o crescimento. As medições são interpretadas através de índices, como a contração máxima diária e a taxa de crescimento do caule, que permitem a utilização deste método na calendarização da rega (Feres e Goldhamer, 2003; Fernández e Cuevas, 2010; De la Rosa et al., 2013).

A medição do potencial hídrico foliar serve de indicador do estado hídrico da planta por este diminuir em situações de stress hídrico. Há vários instrumentos que permitem a medição deste potencial, mas o fundamento é a exerceção de pressão sobre uma folha até que a água saia do seu interior. A respetiva pressão exercida corresponde ao potencial foliar (Girona et al., 2006; Bartell et. al, 2021). Um método semelhante é a medição do potencial hídrico do ramo. Neste método, a transpiração foliar é primeiramente impedida de modo que o potencial hídrico da folha fique em equilíbrio com o potencial hídrico do ramo. Esta medição representa o estado hídrico de toda a planta e não o de uma única folha

e, por isso, reduz a variabilidade devido a diferenças de exposição solar e de idade das folhas (Williams e Araujo, 2002).

O estado hídrico das plantas pode ser também indiretamente aferido através da detecção remota medindo os índices de vegetação. A bem estabelecida relação entre a radiação absorvida pela vegetação e a sua ET permite a utilização deste método na calendarização (Tilling et al., 2007; Pôças et al. 2020).

2.3.3.3. Balanço hídrico do solo

O balanço hídrico do solo visa estimar o seu teor de água. De modo a facilitar o seu cálculo e a determinação das necessidades diárias de rega das culturas pode recorrer-se a ferramentas informáticas que aplicam modelos de BH. Destes modelos destacam-se os que utilizam a aproximação dos K_c médios da FAO (Eq. 1): destacam-se o CROPWAT de Surendran et al. (2015), o PILOTE de (Mailhol et al., 1997; Khaledian et al., 2009) e o ISAREG de Teixeira & Pereira (1992). Outras ferramentas que usam os K_c duais incluem o modelo SIMDualKc (Rosa et al., 2012, 2016) e o IrrigRotation (Rolim & Teixeira, 2008), que utilizam a metodologia dos coeficientes culturais duais ($K_{cb} + K_e$), com a separação entre a transpiração das culturas (K_{cb}) e a evaporação do solo (K_e) (Allen et al., 1998). Várias das ferramentas informáticas utilizadas foram revistas em Pereira et al. (2020).

A partir destes modelos, é possível efetuar o BH e estimar, em cada momento (dia), o teor de água no solo e definir a data de cada rega. A utilização dos modelos requer normalmente a sua calibração com base em dados de campo.

Como indicado, o ISAREG (Teixeira e Pereira, 1992) é um modelo de balanço hídrico desenvolvido no ISA que se baseia na metodologia da FAO (Doorenbos e Pruitt 1977), e permite: programar a rega, calculando o dia e o volume de cada rega (calendário da rega), a quebra de produção, caso a cultura tenha estado em stress hídrico; determinar as necessidades globais de rega (NGR) entendidas como as necessidades teóricas de rega calculadas independentemente do modo como a rega se irá processar, desde que a cultura seja convenientemente abastecida de água; avaliar um determinado calendário de rega; e definir os parâmetros de projeto, isto é, as necessidades de rega anuais e o caudal de ponta, mediante a construção de séries estatísticas desses parâmetros. Este modelo permite a avaliação de calendários de rega alternativos, que podem mostrar-se úteis no apoio à decisão quer dos agricultores como de gestores de projetos de rega (Zairi et al., 2000, 2003; Rodrigues et al., 2003; Cholpankulov et al., 2008; Chaterlán et al., 2011; Popova et al., 2014; Wu et al., 2015). Assim, devem favorecer-se as estratégias de rega que visem a poupança de água e a estabilização da produção das culturas tendo em conta os impactos económicos das mesmas.

2.4. Dados de previsão meteorológica

Existem previsões meteorológicas com diferentes resoluções temporais, as denominadas de curto prazo (diárias, 3-dias), médio prazo (semanal a mensal), e de longo prazo (6 meses a 1 ano). A utilização depende do objetivo sendo que para a condução da rega em tempo real são usadas as previsões de curto prazo (Linker e Sylaios, 2016; Cao et al., 2019) enquanto as previsões de longo prazo são mais utilizadas para, por exemplo, o apoio à gestão ao nível dos perímetros de rega (Paredes et al., 2015; Choi, 2015; Ceglar e Toreti, 2021).

2.4.1. Previsões a longo prazo

As previsões meteorológicas a longo prazo, ou sazonais, consistem na previsão das condições meteorológicas com uma antecedência temporal que varia entre 6 meses e 1 ano (Lalić et al., 2018; Ceglar e Toreti, 2021). Estas previsões fornecem informação útil na tomada de decisão dos produtores nas práticas de gestão da produção (Ceglar e Toreti, 2021), como no planeamento da sementeira (Perondi et al., 2019; An-Vo et al., 2021), na seleção de variedades da cultura (van Etten et al., 2019), no planeamento da fertilização (Morari et al., 2021), na calendarização dos tratamentos de pragas e doenças (Kim et al., 2019) e no uso de água na rega (Gunda et al., 2017). Exemplos de aplicação deste tipo de previsões incluem os estudos sobre a estimativa da data da floração do trigo, que pode ser prevista com uma precisão aceitável no início da época, e eventos de seca durante períodos sensíveis da floração e do enchimento do grão, que podem ser previstos no final do inverno (Coelho e Costa, 2010; Choi, 2015; Ceglar e Toreti, 2021).

As previsões sazonais são feitas por vários centros de previsão climática por todo o mundo (Capa-Morocho et al., 2016). Estas previsões implicam a utilização de modelos físicos e dinâmicos do clima global, modelos climáticos regionais, modelos estatísticos empíricos, ou uma combinação de modelos dinâmicos e empíricos. Todas estas abordagens produzem previsões probabilísticas que expressam as incertezas inerentes ao processo de previsão. Por exemplo, para responder à incerteza devido à falta de conhecimento das condições iniciais da atmosfera aquando do começo do modelo, as previsões com base em modelos físicos são produzidas usando condições iniciais ligeiramente diferentes, criando um grupo (*ensemble*) de previsões (Coelho e Costa, 2010; Paredes et al., 2015).

Desta forma, os modelos de previsão sazonal podem ser determinísticos ou estocásticos: no primeiro caso, o resultado dependerá apenas das condições iniciais do modelo, no segundo, é introduzida no modelo uma componente de variabilidade que permite ter em conta a incerteza relativa ao estado inicial considerado. Os modelos estocásticos são modelos estatísticos que criam séries sintéticas das condições meteorológicas diárias a partir de dados históricos. As séries sintéticas são geradas com o

objetivo de partilharem as propriedades estatísticas com os dados meteorológicos observados (Apipattanavis et al., 2010).

2.4.2. Previsões a curto prazo

Tal como referido no ponto 2.3.3., as necessidades hídricas das plantas podem ser medidas e/ou estimadas em tempo real. Estas, são calculadas segundo o balanço hídrico do solo, que tem em conta as entradas e saídas de água até ao momento (Abd el Baki et al., 2020). A utilização de previsões meteorológicas a curto prazo na condução da rega permite uma condução mais informada, tendo em conta as condições meteorológicas esperadas para os próximos dias antes da decisão. Esta condução permite evitar desperdícios de água na rega quando é prevista chuva nos dias seguintes através da utilização de previsões meteorológicas e de simulações numéricas (Abd el Baki et al., 2018, Lorite et al., 2015; Yang et al., 2016).

A usabilidade das previsões meteorológicas na calendarização da rega tem sido objeto de vários estudos, nomeadamente para a determinação da ET_o . Cai et al. (2009) usaram dados diários de previsão meteorológica públicos para o cálculo da ET_o com a aproximação FAO-PM mas usando somente os valores de temperatura, as quais foram posteriormente aplicadas ao balanço hídrico do solo, e concluíram que estas previsões são adequadas para o apoio à condução da rega de complemento do trigo.

No estudo de Lorite et. al (2015) usaram previsões do próprio dia e a 6 dias no cálculo da ET_o e mostraram que a utilização de previsões a curto prazo permite melhorias significativas ao nível da condução da rega.

Abd El Baki et al. (2018) integraram previsões meteorológicas do próprio dia na simulação do BH para a condução da rega de uma cultura de batata-doce no Japão. E verificaram que a utilização das previsões levou à redução de 18 % de água aplicada, ao aumento de 19 % da produção e ao aumento de 25 % do lucro. Similarmente, Abd El Baki et. al (2020) incorporaram dados meteorológicos observados e previstos num modelo numérico de simulação do BH numa cultura de soja no Japão. Esta metodologia demonstrou ser capaz de reduzir em 16 % a água aplicada e levar a um aumento de 22 % do lucro em relação à condução da rega em tempo real.

No trabalho de Yang et al. (2016) foram usados dados de previsão meteorológica públicos a médio prazo (7 dias) para o cálculo da ET_o , tendo concluído que a utilização de previsões meteorológicas de todas as variáveis no modelo PM permite obter melhores previsões da ET_o do que utilizando o modelo Hargreaves-Samani (HS) com apenas as previsões de temperatura. Por outro lado, Zhang et. al (2018) verificaram um bom performance da ET_c prevista com base na ET_o calculada com o modelo HS em

relação à observada, demonstrando que mesmo na presença de apenas previsões da temperatura, a sua utilização pode ser benéfica. Roy et. al (2021) recorreram a previsões meteorológicas para o 3º e 7º dias seguintes e reduziram 10 a 30 % a água regada sem decréscimo significativo da produção. Similarmente, Sangha et. al (2023) utilizaram previsões meteorológicas com até 7 dias de antecedência para a calendarização da rega, e verificaram um aumento da produção, assim como da eficiência do uso da água e do azoto, minimizando simultaneamente o stress hídrico e a percolação profunda e lixiviação do azoto. A literatura mostrou recorrentemente que a condução da rega usando dados de previsão meteorológica a curto prazo pode levar à utilização de menos água na rega, a menos drenagem, a uma produção igual ou superior e mesmo a um maior lucro.

A maior desvantagem deste tipo de previsões é que podem ter um viés quer na precipitação como na temperatura o que pode levar a uma tomada de decisão que leve a regar excessivamente ou, por outro lado, a um atraso na data de rega resultando num deficit hídrico indesejado. No entanto, Linker e Sylaios (2016) demonstraram que mesmo previsões imperfeitas podem contribuir para o aumento da eficiência da rega.

2.4.3. Bases de dados e espacialização da informação

Como anteriormente referido para a cálculo do balanço hídrico do solo são necessários vários tipos de informação sobre condições meteorológicas, solo e cultura.

Existem várias bases de dados que disponibilizam informação climática necessária ao cálculo das necessidades de água e de rega das culturas. A nível mundial, o World Weather Information Service (WIS) da World Meteorological Organization (WMO) contem links para bases de dados com informação meteorológica para todo o mundo (WMO, 2023). O Centro Europeu de Previsão do Tempo a Médio Prazo (ECMWF) também disponibiliza dados de previsões a curto, médio e longo prazo de uma forma operacional. No caso de Portugal, o Instituto Português do Mar e da Atmosfera (IPMA) é a entidade que oficialmente disponibiliza informações de previsão meteorológica diária de 3 a 5 dias agregada por local e por dia, respetivamente; evapotranspiração de referência diária por concelho; precipitação total diária por concelho; temperatura mínima e máxima diária por concelho (IPMA, 2024). Outra instituição que disponibiliza previsões meteorológicas para Portugal é o Instituto Superior Técnico (Meteotécnico, 2024). Glória et al. (2020) compararam os dados meteorológicos históricos e de previsão disponibilizados pelo IPMA com os dados de medição locais no jardim do campo grande em Lisboa e demonstraram que as medições locais em tempo real permitem poupar água na rega. O que suporta a noção de que a utilização de previsões na condução da rega ou de medições em tempo real deve ser analisada caso a caso.

Relativamente à informação sobre as características do solo o Instituto Nacional de Investigação Agrária e Veterinária (INIAV) mantém uma base de dados sobre as características do solo, que contém 3461 perfis de solos estudados em Portugal Continental, entre 1966 e 2014. Esta base de dados contém informações relativas à classificação e às propriedades dos diferentes perfis dos solos (INFOSOLO, 2023). Existem outras fontes de dados de solos quer com abrangência europeia quer mundial, como são o caso da base de dados fornecida pelo ECMWF, [FAO/UNESCO](#) ou OpenLandMap.

Relativamente aos dados sobre as culturas a principal fonte de dados é o Instituto Nacional de Estatística (INE) que contém dados relativos às culturas, áreas plantadas, épocas de sementeira e colheita, produtividade entre outros, relativos a Portugal (INE, 2024). Ao nível dos perímetros de rega uma fonte de dados sobre áreas de cultivos agrícolas são as Associações de beneficiários e regantes e ainda o sistema de parcelário agrícola do Instituto de Financiamento da Agricultura e das Pescas ([IFAP](#)).

Estas bases de dados têm a vantagem de permitirem o acesso a dados precisos e atualizados de forma pública, aos quais os técnicos e agricultores com maior formação podem facilmente recorrer para a tomada de decisão. Possibilitam também a análise de dados históricos e a identificação de tendências, a modelação para previsões futuras e até a integração de múltiplas fontes de dados para conclusões mais abrangentes, aplicações particularmente úteis numa perspetiva académica.

A presença de dados incompletos ou inconsistências é um dos inconvenientes na utilização das bases de dados observados, nomeadamente dados meteorológicos, assim como dificuldades na integração de diversos formatos de dados.

3. Material e Métodos

Neste capítulo, far-se-á a caracterização dos dados, assim como dos métodos utilizados para o tratamento e seleção dos mesmos, tal como representado de forma esquemática na Figura 3.1. Este procedimento envolveu a análise estatística em Python, com recurso a algumas bibliotecas de análise de dados e *machine learning* como *pandas* e *scikit-learn*, e Excel. Assim, foi avaliada a qualidade dos dados. Os dados observados foram comparados diretamente com os dados de previsão, através da análise da sua distribuição estatística assim como da sua correlação, sendo feitos os devidos ajustes de modo a corrigir os dados de previsão. Os dados foram comparados também indiretamente, através das estimativas das necessidades de rega de acordo com cada grupo de dados. Esta etapa foi realizada com recurso ao software ISAREG e com base na caracterização do PRL de Aparício (2022).

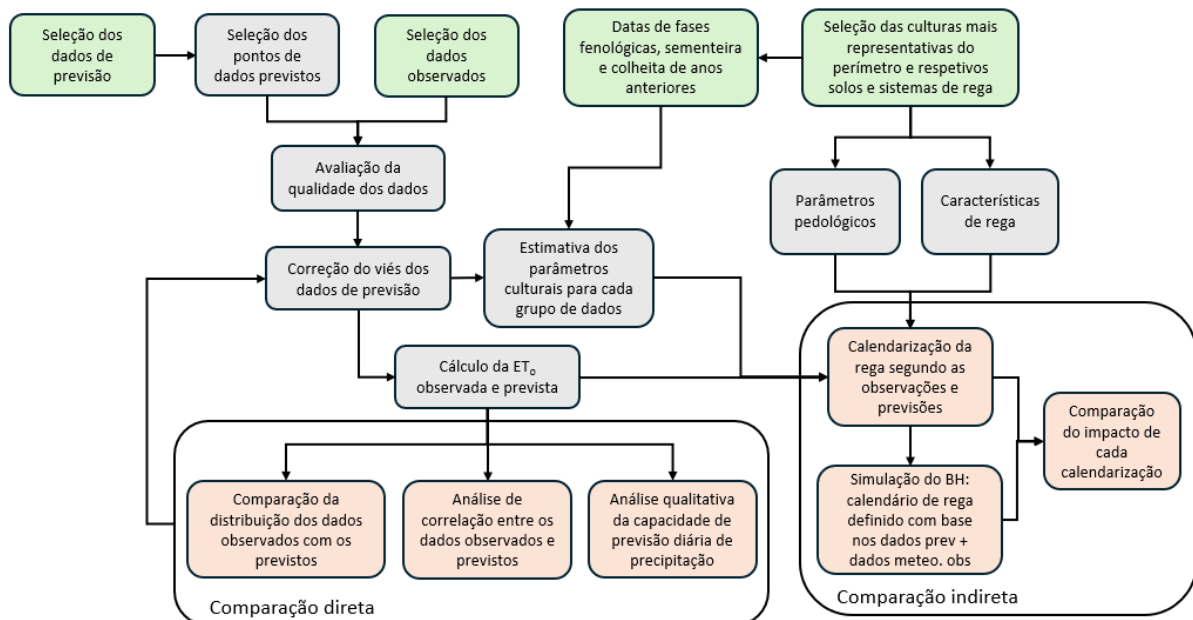


Figura 3.1. Fluxograma da metodologia utilizada. A verde o input de dados, a cinzento os procedimentos/resultados intermédios e a vermelho o output de resultados.

3.1. Caracterização do perímetro de rega do Lucefecit

3.1.1. Localização

A área de estudo corresponde ao Perímetro de Rega do Lucefecit (PRL), gerido pela associação de beneficiários do Lucefecit (ABL). Localiza-se na região do Alentejo, no distrito de Évora, no concelho de Alandroal, entre os paralelos 38°38'38" N e 38°35'0" N e os meridianos 7°25'4" W e 7°22'2" W (Figura 3.2.). O projeto de regadio do PRL foi construído em duas fases: a primeira, de 1977 a 1988,

abastecendo 211 ha com rega por gravidade; e a segunda, de 1990 a 1995, abastecendo 964 ha de rega sob pressão. O PRL abastece atualmente uma área de 1175 ha, que abrange 3 freguesias: União das Freguesias de Alandroal (Nossa Senhora da Conceição, São Brás dos Matos e Juromenha), Terena (S. Pedro) e Capelins (St^o. António), e conta com 101 beneficiários (Aparício, 2022; CM-Alandroal, 2022).

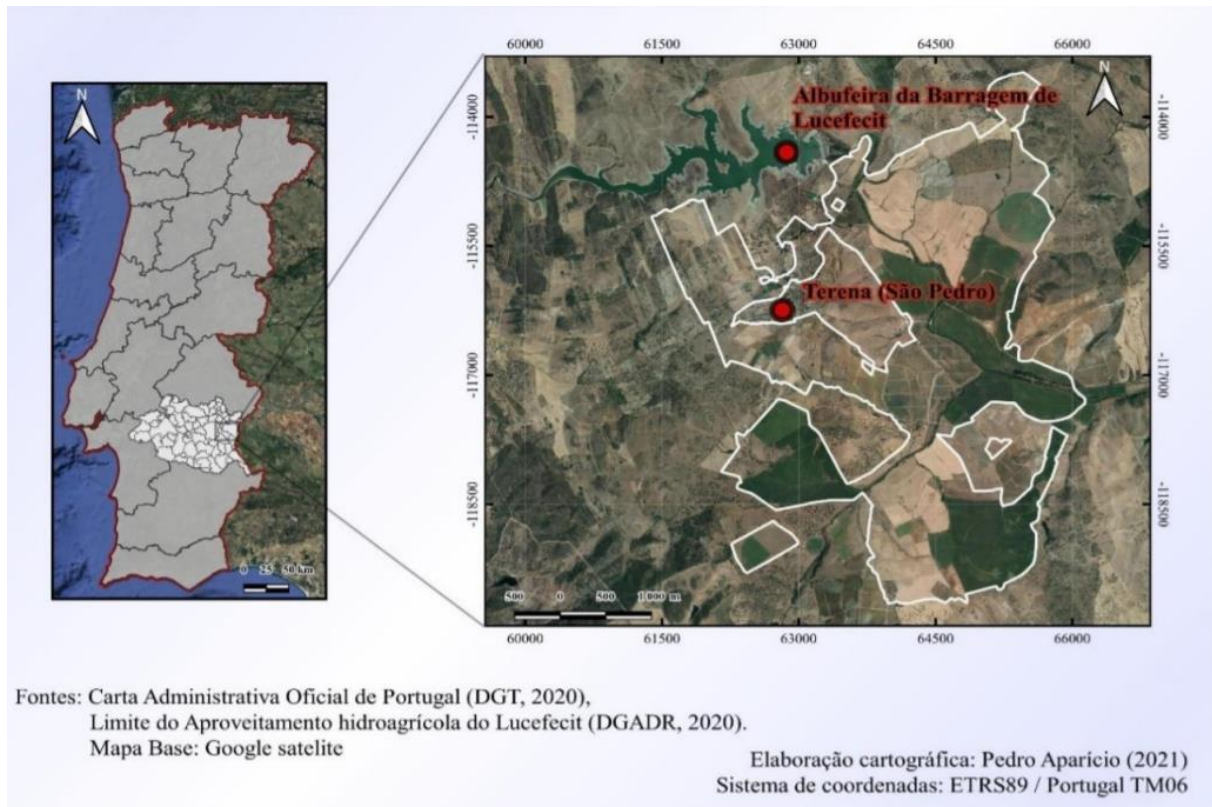


Figura 3.2. Localização e limites do Perímetro de Rega do Lucefecit. Retirado de Aparício (2022).

3.1.2. Caracterização edáfica

De acordo com a carta de solos de Portugal (Figura 3.3.), os solos com maior representatividade no PRL (Figura 3.4.) são solos argiluvitados pouco insaturados – solos mediterrânicos vermelhos ou amarelos de materiais não calcários, normais, de "rañas" ou depósitos afins (Sr, 34%); Solos Argiluvitados Pouco Insaturados - solos mediterrânicos, pardos, de materiais não calcários, normais, de xistos ou grauvaques (Px, 25%); Solos Incipientes - aluviosolos modernos, não calcários, de textura mediana (A, 14%); e os solos calcários, pardos dos climas de regime xérico, normais, de calcários não compactos (Pc, 13%). Os restantes solos representam cerca de 13 % da área total.

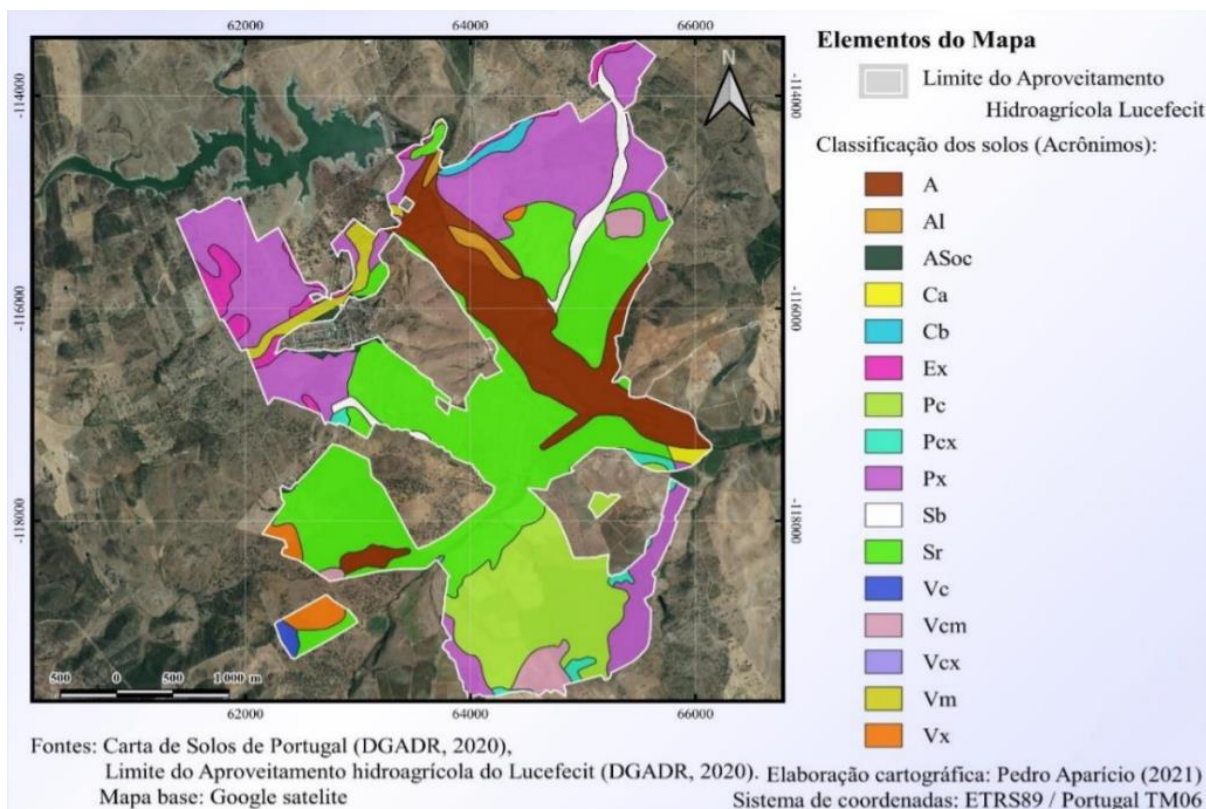


Figura 3.3. Mapa da distribuição e classificação dos solos presentes no Perímetro de Rega do Lucefecit. Retirado de Aparício (2022).




Figura 3.4. Frequência relativa dos principais tipos de solos no Perímetro de Rega do Lucefecit: Sr são solos mediterrânicos vermelhos ou amarelos de materiais não calcários, normais, de "rañas" ou depósitos afins; Px são solos mediterrânicos, pardos, de materiais não calcários, normais, de xistos ou grauvaques; A são aluviossolos modernos, não calcários, de textura mediana; e Pc são solos calcários, pardos dos climas de regime xérico, normais, de calcários não compactos (Aparício, 2022).

3.1.3. Barragem

A barragem situa-se na linha de água da ribeira do Lucefecit, na bacia hidrográfica do rio Guadiana e tem como único objetivo o fornecimento de água ao regadio. Foi construída em aterro, com dois diques na margem esquerda da ribeira, com uma altura máxima acima do leito de 23 m. A cota de pleno armazenamento é 182 m. A albufeira inunda uma área de 169 ha e tem uma capacidade útil de 9 625 000 m³. A Figura 3.5. apresenta o volume médio anual de água disponível na albufeira nos últimos 10 anos, evidenciando 2019 como o ano em que a barragem se encontrou, em média, mais vazia (com 3 069 dam³) e 2021 como o ano em que esteve mais cheia (com 8 418 dam³).




Figura 3.5. Volume médio armazenado na albufeira do Lucefecit nos últimos 10 anos, calculado a partir dos valores mensais, e a média dos respetivos volumes (adaptado de SNIRH, 2023).

3.1.4. Rede de rega primária e secundária

A água é distribuída por uma rede de rega com um total de 46 000 metros: onde 3 500 metros correspondem à rede primária, formada por um canal a céu aberto, e 6 500 metros à rede secundária da 1ª fase (rega por gravidade). Os restantes 36 000 metros são em tubagem enterrada e pertencem à 2ª fase (rega sob pressão). Existem ainda duas estações elevatórias e dois reservatórios unidirecionais, que permitem assegurar a pressão e caudal da rede de rega sob pressão. As estações elevatórias permitem o fornecimento de um caudal máximo de 1 035 m³/h a uma altura manométrica de 87 m (DGADR, 2023).

A distribuição de água às explorações agrícolas é realizada segundo um sistema rígido em rotação para as parcelas alimentadas por gravidade, e um sistema flexível a pedido para as parcelas alimentadas sob pressão. Às primeiras é atribuída uma dotação máxima de água por regante e por hectare, estando o controlo (abertura e fecho das tomadas de água) sob a responsabilidade da ABL (Aparício, 2022). Os

sistemas rígidos de distribuição são caracterizados por eficiências baixas de transporte, distribuição e uso da água, baixa comodidade para o regante, pouca flexibilidade da rega e pouca facilidade de operação da rede. Nos sistemas a pedido, os regantes podem utilizar a água quando, como e durante o tempo que quiserem, permitindo o uso da água à medida das necessidades das culturas, sendo caracterizados por uma elevada comodidade para o regante e elevada flexibilidade da rega (Oliveira, 2011).

3.1.5. Sistemas de Rega

De acordo com Aparício (2022), para o ano de 2020, a rede terciária do PRL tem como sistema predominante de rega por aspersão fixa com cobertura total, correspondendo a 52% da área regada, enquanto o sistema de aspersão por rampa pivotante é responsável por 39%, restando 9% onde é utilizada rega localizada por gota-a-gota (Figura 3.6.).

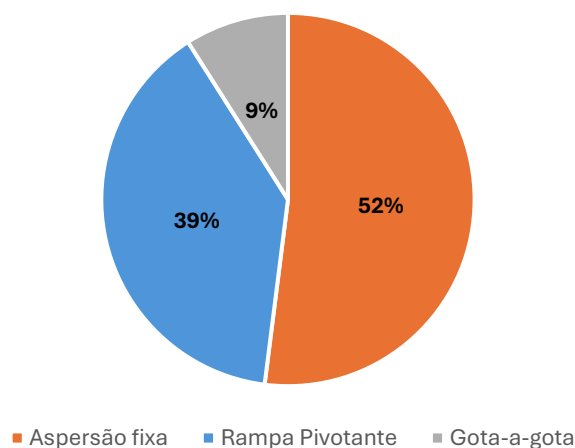


Figura 3.6. Sistemas de rega e respetivas frequências relativas dos sistemas de rega presentes no Perímetro de rega do Lucefecit (Aparício, 2022).

3.1.6. Caracterização dos sistemas agrícolas

Em 2020 54,5% da área total beneficiada foi regada, ocupada maioritariamente por culturas anuais (22,0% milho, 13,4% trigo, 4,0% cevada, 3,7% sorgo e 4,0%: luzerna, meloa, ervilha, feijão frade e outras hortícolas) (Figura 3.7.). As culturas permanentes correspondiam a apenas 7,24% da área (2,5% de olival, 2,2% de vinha, 2,5% de prado e pastagem e 0,04% de pomar). Os restantes 45,5% da área total beneficiada não foram regados (Aparício, 2022).




Figura 3.7. Frequência relativa da área ocupada pelas principais culturas regadas do perímetro de rega do Luçefecit e da área não regada (Aparício, 2022).

3.2. Caracterização climática da região

Segundo a classificação climática de Köppen, o clima da região em estudo é temperado mediterrânico com verão quente e seco (Csa) (Beck et al., 2018). Os dados de precipitação (P) e temperatura média (T_{med}) referentes à cidade de Évora e divulgados pelo IPMA (2022) permitem confirmar esta designação por apresentar as seguintes características: a precipitação no mês mais seco do verão é inferior a 40 mm (3.9 mm, em julho) e inferior também a um terço da precipitação no mês mais húmido do ano (91.9 mm, em dezembro); a temperatura média mensal do mês mais quente é superior a 22 °C (23.6 °C, em julho) (Figura 3.8.).




Figura 3.8. Diagrama ombrotérmico da cidade de Évora entre 1981 e 2010 (IPMA, 2022). Onde P é a precipitação média mensal (mm) e T_{med} é a média mensal das médias diárias da temperatura (°C).

3.3. Caracterização dos Dados meteorológicos

3.3.1. Dados Meteorológicos Observados

A informação meteorológica observada utilizada neste estudo foi fornecida pelo Centro Operativo e de Tecnologia de Regadio (COTR) e abrange dados meteorológicos recolhidos entre 2001 e 2023 na estação meteorológica do Redondo, distrito de Évora, concelho do Redondo, de latitude 38°38'59,28"Norte e longitude 7°32'52,82"Oeste, a 300 m de altitude. Os dados foram fornecidos em formato xls e depois convertidos em formato csv de modo a facilitar o processamento em *Python*, com a biblioteca *pandas*.

Foram selecionadas as datas entre 01/01/2021 e 31/12/2022 e eliminados os dias repetidos. Neste intervalo de tempo foram então utilizadas as seguintes variáveis meteorológicas: temperatura máxima e mínima (T_{max} , T_{min} , °C), humidade relativa máxima, mínima e média (HR_{max} , HR_{min} , HR_{med} , %), velocidade do vento média a 2m de altura (u_2 , $m\ s^{-1}$), radiação solar global (R_s , $kJ\ m^{-2}\ d^{-1}$) e precipitação (P , mm).

3.3.2. Dados Meteorológicos de Previsão a 3 dias

No âmbito do projeto HubIS, foram produzidas previsões diárias para os 5 dias seguintes e previsões sazonais de 6 meses. Este serviço é prestado pela plataforma online [Med-iHub](#), que dá acesso a dados meteorológicos e a ferramentas para gestão da rega. Para este trabalho, foram utilizadas apenas as previsões diárias para o terceiro dia.

As previsões são feitas com recurso ao modelo Weather Research and Forecasting (WRF), que contém dois modelos dinâmicos: o Advanced Research WRF (ARW) e o Nonhydrostatic Mesoscale Model (NMM). O WRF é aplicado tanto a investigação atmosférica como à execução de previsões numéricas operacionais e foi desenvolvido pelo National Center for Atmospheric Research (NCAR), gerido pela University Corporation for Atmospheric Research (UCAR) como domínio aberto. Dos dois modelos que constituem o WRF, foi utilizado o ARW. O modelo ARW permite alterar o seu código consoante as características do local (Bouarfa e Zairi, 2022).

O WRF é um modelo meteorológico regional e, como tal, requiere condições iniciais e de fronteira. As condições iniciais descrevem o estado atual da atmosfera, e são recolhidas por estações meteorológicas por todo o mundo. Depois destes dados serem recolhidos é executado um processo de assimilação de dados para assegurar que o modelo não produzirá instabilidades que prejudiquem a qualidade das previsões. Por outro lado, as condições de fronteira são usadas para informar o modelo de como o estado da atmosfera muda ao redor dos domínios de área que o modelo simula, e provêm de modelos globais. As condições iniciais e limite para as previsões diárias de 5 dias são fornecidas pela

US National Aeronautics and Space Administration (NCAR), através do ciclo de previsão 1200UTC do Global Forecasting System (GFS), numa ampla gama de parâmetros meteorológicos: como temperatura, humidade, velocidade e direção do vento, precipitação e pressão. O GFS é produzido pelo National Centers for Environmental Prediction (NCEP) da US National Aeronautics and Space Administration (NASA). O modelo GFS é um modelo numérico de previsão meteorológica que recorre a um conjunto de equações matemáticas para simular o comportamento da atmosfera. Este modelo é um modelo conjunto que inclui um modelo de simulação da atmosfera, do oceano, da terra/solo e um modelo do gelo marinho (Figura 3.9.). O modelo GFS apresenta uma cobertura global numa resolução horizontal de 28 km (18 milhas) entre pontos da grelha, e é usado por previsores operacionais para prever o tempo até 16 dias no futuro. Este modelo é executado quatro vezes por dia, e a saída está disponível para download através do Sistema Nacional de Arquivo e Distribuição de Modelos Operacionais da NOAA (NOMADS) (Bouarfa e Zairi, 2022).

Os outputs do WRF são representados num elevado número de mapas, tabelas e gráficos, depois disponibilizados para os parceiros do HubIS através da plataforma online [Med-iHub](#). No caso das previsões a 5 dias, o estado da atmosfera é descrito através de mapas que contêm o padrão de temperatura, pressão, velocidade e direção do vento e como evoluirão nos próximos dias.

Como mencionado, o modelo WRF é utilizado por domínios de área: o sudeste português e sudoeste espanhol correspondem ao domínio d03. Os dados referentes a este domínio foram fornecidos pelo grupo de investigadores da Universidade de Tessália e correspondem a uma grelha de previsões de aproximadamente 2km por 2km, fornecidos em formato csv (*comma separated values*). De toda a grelha providenciada, 2705 pontos são referentes a Portugal e, para cada ponto, foram fornecidas as previsões para o primeiro dia seguinte, segundo e terceiro. Das variáveis previstas foram utilizadas: T_{\max} (°C), T_{\min} (°C), humidade relativa média (HR_{med} , %), u_2 (m s^{-1}), R_5 ($\text{MJ m}^{-2} \text{d}^{-1}$) e P (mm). À semelhança dos dados observados na estação do Redondo, os dados englobaram as previsões para todos os dias de 2021 e 2022.

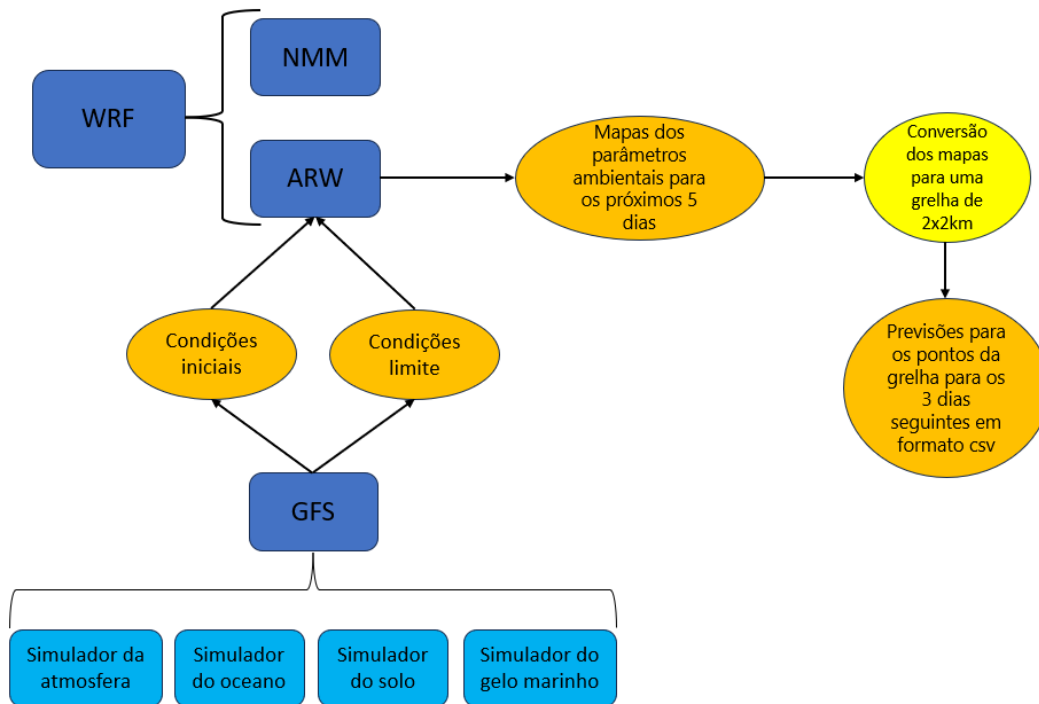


Figura 3.9. Fluxograma da origem dos dados de previsão para os 3 dias seguintes. Os modelos informáticos estão a azul-escuro, os submodelos a azul-claro, a laranja dados de input e output e a amarelo o processo de transformação de dados. Adaptado de Bouarfa e Zair (2022).

3.4. Seleção dos pontos da grelha

À semelhança do trabalho realizado por Paredes et al. (2018), foram utilizados dados de previsão para vários pontos da grelha. Dos 2705 pontos, foram selecionados os que se encontravam num raio de 6 km da estação meteorológica do Redondo (EMR), englobando 25 pontos, sendo que o mais próximo se encontrava a 501m de distância e o mais distante a 5964m (Figura 3.10.).

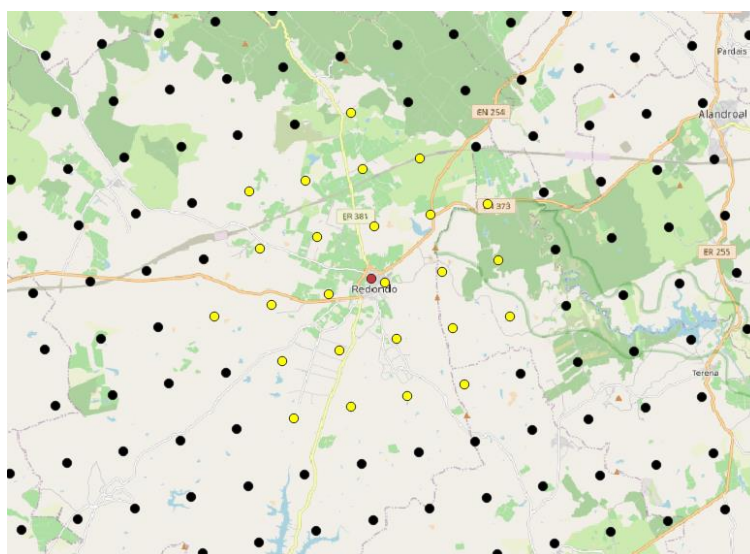


Figura 3.10. Seleção de pontos no mapa - Pontos num raio de 6 km representados a amarelo, estação meteorológica do Redondo a vermelho e pontos não selecionados a preto.

Com o objetivo de selecionar os pontos em que as variáveis meteorológicas melhor se aproximam dos dados observados, de entre os 25, foi feita uma comparação direta entre as previsões para cada um dos pontos e as medições feitas na estação. As previsões consideradas foram as para o 3º dia, por serem as mais favoráveis ao estudo, pois, sendo os resultados promissores neste conjunto de dados, será de esperar que sejam ainda melhores para o 2º e ainda mais para o 1º dia seguinte, embora esta verificação seja fora do âmbito deste trabalho. Para este dia, foram comparadas as variáveis T_{max} , T_{min} , HR_{med} , R_s , u_2 e P (Anexo 6.1.). A qualidade das previsões referentes a cada ponto foi avaliada segundo o coeficiente de correlação (R^2), resultante duma regressão linear normal (Eq. 3.7) e do declive (b_0) resultante de uma regressão linear forçada à origem (Eq. 3.8). Assim, o R^2 indicou a proporção de variabilidade explicada pelo modelo, enquanto o b_0 indicou se existiu alguma tendência de desvio das previsões em relação às observações, daí a importância de forçar a regressão à origem (Paredes et al., 2018). Os intervalos de aceitação considerados para estas métricas foram os seguintes: $R^2 \geq 0.70$; $0.80 \leq b_0 \leq 1.20$.

De modo a reduzir a incerteza das previsões realizadas para apenas um ponto, os dados das previsões foram ponderados pelo inverso da distância (IDW – inverse distance weighting) à estação do Redondo, de modo que as previsões dos pontos mais próximos tivessem mais peso do que as dos mais afastados. Este teste foi feito iterativamente, reduzindo o número de pontos ponderados: por exemplo, com os 25 pontos mais próximos, depois com os 24 e daí em diante até à ponderação dos 2 pontos mais próximos. Os valores ponderados foram então sujeitos ao cálculo das mesmas métricas de anteriormente (Anexo 6.2.).

A partir destes passos foi possível decidir quais os melhores pontos de previsão, assim como qual o número de pontos a utilizar na ponderação dos dados de previsão.

3.5. Avaliação da qualidade dos dados

Nesta etapa, foi avaliada a qualidade dos dados observados e dos de previsão selecionados anteriormente. Primeiramente verificou-se se nenhum dos dias continha valores em falta, quer nas observações quer nas previsões. Verificou-se também se havia algum dia em que $T_{max} < T_{min}$, assim como para a $HR_{max} < HR_{min}$. As HRs foram ainda comparadas com as condições standard, definidas por Allen et al. (1998), e foram contabilizados os dias em que as seguintes condições não se cumpriram: $HR_{max} < 90\%$; $HR_{min} < 25\%$; $HR_{med} < 70\%$.

No caso da radiação (R_s), os valores observados e previstos foram comparados com a radiação de curto comprimento de onda com o céu limpo (R_{so}). Esta comparação foi feita anualmente. Desta comparação resultará um ajuste aos dados da radiação solar, caso estes excedam os valores correspondentes da R_{so} ou caso lhe sejam consistentemente inferiores nos meses de verão (Allen et al., 1998). Foram

também contabilizados os dias em que $u_2 \leq 0.5$ m/s em ambos os grupos, por serem os valores indicados como limitantes para a aplicação no método FAO-PM.

Caso alguma variável apresente valores previstos consistentemente dispares dos observados, esta enviesará o valor da ET_o calculada com as previsões (ET_o -Prev) em relação à calculada com as observações (ET_o -Obs). Com o objetivo de quantificar o impacto deste viés no cálculo da ET_o , esta será então calculada com os dados previstos da variável enviesada e com os dados observados das restantes variáveis. A diferença entre o valor da ET_o calculada por este procedimento “misto” e a ET_o -Obs permitirá avaliar o impacto da previsão enviesada desta variável no cálculo da ET_o -Prev.

3.5.1. Cálculo da ET_o

A ET_o -Obs e ET_o -Prev foram calculadas pela equação FAO-PM (Eq. 2.2), calculando todos os parâmetros como descrito por Allen et al. (1998). Em particular, a pressão do vapor de saturação (e_a) foi calculada pela HR (Eq 3.1) e a radiação solar de céu limpo (R_{so}), através da equação 3.2.

$$e_a = \frac{e^{\circ}(T_{min}) \frac{HR_{max}}{100} + e^{\circ}(T_{max}) \frac{HR_{min}}{100}}{2} \quad (3.1)$$

onde e_a é a pressão de vapor real (kPa) e $e^{\circ}(T_{min})$ e $e^{\circ}(T_{max})$ são as pressões do vapor de saturação às T_{min} e T_{max} diárias (kPa), respetivamente.

$$R_{so} = (0.75 + 2 \cdot 10^{-5}z) R_a \quad (3.2)$$

onde R_{so} é a radiação solar de céu limpo ($MJ \cdot m^{-2} \cdot day^{-1}$), z é a altura acima do nível médio do mar (m) e R_a a radiação extraterrestre ($MJ \cdot m^{-2} \cdot day^{-1}$).

3.6. Validação direta das previsões

O procedimento da validação direta das previsões consistiu na comparação da distribuição e análise da correlação entre os dados de T_{max} , T_{min} , HR_{med} , R_s e P observados e os previstos, assim como entre a ET_o -Obs e a ET_o -Prev. No caso da P , foi adicionalmente analisada qualitativamente a capacidade de previsão diária de precipitação e da sua ausência. Esta análise foi feita através de uma matriz de confusão. Nesta matriz, foram contabilizados: verdadeiros positivos (VP), previsão correta de ocorrência de P ; verdadeiros negativos (VN), previsão correta de ausência de P ; falsos positivos (FP), previsão errada de presença de P ; falsos negativos (FN), previsão errada de ausência de P . Com estes

valores foram depois calculadas as seguintes métricas (Eq. 3.3 - 3.6): acurácia, a proporção de dias em que foi prevista a ocorrência ou ausência de P corretamente; precisão, a proporção de dias em que ocorreu P quando esta foi prevista; sensibilidade, a proporção de dias em que foi prevista P quando esta ocorreu de facto; e a especificidade, a proporção de dias em que foi prevista ausência de P quando esta não ocorreu de facto. Todas estas métricas apresentam valores entre 0 e 1, sendo que os valores serão tão favoráveis ao modelo quanto mais próximos de 1 forem.

$$Acurácia = \frac{VP+VN}{VP+FP+FN+VN} \quad (3.3)$$

$$Precisão = \frac{VP}{VP+FP} \quad (3.4)$$

$$Sensibilidade = \frac{VP}{VP+FN} \quad (3.5)$$

$$Especificidade = \frac{VN}{VN+VP} \quad (3.6)$$

3.6.1. Comparação da distribuição

Na comparação da distribuição dos dados foram calculadas a média (\bar{x}), o desvio padrão (σ), a curtose e a simetria de ambos os grupos de cada variável. A curtose permite analisar o comportamento das caudas da distribuição, em relação à distribuição normal, ou seja, o quão afunilada ou achatada é a distribuição dos dados. A curtose categoriza a distribuição como mesocúrtica, se for 0, o que significa que a distribuição é semelhante à normal, leptocúrtica, se for maior que 0, o que significa que contém mais valores extremos que a normal (mais achatada), e platicúrtica, se for inferior a 0, tendo menos valores extremos que a normal (mais afunilada). Já a simetria diz-nos a direção e a dimensão relativa das caudas: se for positiva, a cauda à direita é maior e mais achatada que a à esquerda, ou seja, a maior parte dos valores são inferiores à média e há muitos valores extremos superiores à mesma; se for negativa ocorre o contrário (Westfall, 2014).

3.6.1.1. Indicadores estatísticos para a distribuição

Todas as métricas de distribuição foram calculadas em python: \bar{x} e σ com as funções “.mean()”, “.std()”, respetivamente, da biblioteca Pandas; a curtose e a simetria usando, “kurtosis()” e “skew()”, respetivamente, do módulo “scipy.stats” da biblioteca SciPy (Anexo 6.3.).

Matematicamente, estes procedimentos corresponderam aos seguintes cálculos:

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n} \quad (3.7)$$

$$\sigma = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{(n-1)}} \quad (3.8)$$

$$curtose = \frac{n(n+1)}{(n-1)(n-2)(n-3)} \times \frac{\sum_{i=1}^n (x_i - \bar{x})^4}{\sigma^4} - \frac{3(n-1)^2}{(n-2)(n-3)} \quad (3.9)$$

$$simetria = \frac{n}{(n-1)(n-2)} \times \frac{\sum_{i=1}^n (x_i - \bar{x})}{\sigma^3} \quad (3.10)$$

onde n é a dimensão da amostra, x_i são os respetivos valores e \bar{x} a sua média

3.6.1.2. Inferência estatística

Dado a igual dimensão dos conjuntos de dados e variâncias desconhecidas, a comparação das médias foi feita segundo um teste t bicaudal assumindo variâncias diferentes (teste t de Welch), como recomendado por Moser e Stevens (1992) para estes casos. Já a comparação dos desvios padrão foi feita posteriormente por um teste F para análise de variâncias.

No presente contexto, diferenças significativas entre observações e previsões não são desejadas, pelo que o que se pretende neste estudo será a impossibilidade de refutar a hipótese nula (dados observados = dados previstos). No entanto, como reforçado por Meyners (2012), um teste de hipóteses pode apenas refutar a hipótese nula, nunca prová-la, pelo que este resultado foi interpretado apenas como um indicador de qualidade das previsões e não como objeto definitivo de conclusões.

A execução de múltiplos testes de hipóteses provoca um risco acentuado de incorrer em erros do tipo I, pelo que por vezes os testes carecem de ajustes de modo a manterem a relevância. Neste caso específico, evitar erros do tipo II (considerar as previsões iguais às observações, não o sendo) é mais prioritário que evitar erros do tipo I (considerar as previsões diferentes das observações, não o sendo), o que, considerando também o pequeno número de comparações, leva a que a melhor decisão seja não executar qualquer correção (Armstrong, 2014), considerando um α de 0.05.

3.6.2. Análise de correlação

Na análise de correlação, os dados foram correlacionados como no procedimento de seleção dos pontos. No entanto, nesta etapa, para além do R^2 e b_0 (Eq. 3.11 e 3.12), foram também calculados o erro quadrático médio (MSE) (Eq. 3.13) e a sua raiz (RMSE), assim como a eficiência de modelação de Nash–Sutcliffe (NSE) (Eq. 3.14).

Como já mencionado na etapa da seleção dos pontos, o R^2 da regressão linear normal revela a proporção da variabilidade descrita pelo modelo enquanto o b_0 da regressão forçada à origem revela se existe tendência de sobrestima ou subestima do modelo (Asuero, 2006). Por sua vez o MSE e RMSE permitem quantificar a diferença entre os valores observados e previstos, sendo que quanto menores forem melhores serão as previsões. Já o NSE quantifica o quão boas as previsões são em relação à média das observações, sendo que 1 será a uma correspondência perfeita entre previsões e observações, e valores negativos indicam que a média das observações é melhor preditor que os dados de previsão (Gupta, 2011).

Caso haja variáveis em que $NSE < 0$, a ET_o -Prev será recalculada utilizando a média das observações destas variáveis nos últimos 10 anos (2011-2020), ao invés dos valores previstos, seguida de uma nova comparação da distribuição e correlação entre a ET_o -Obs e a atualizada ET_o -Prev, de modo a averiguar se esta alteração melhorou o seu poder preditor.

3.6.2.1. Indicadores estatísticos para a correlação

O coeficiente de determinação, R^2 , foi calculado em python usando a função “.r2_score” da biblioteca sklearn. Já o b_0 foi extraído dos coeficientes do modelo linear forçado pelo comando “.coef_[0]”, e o MSE calculado usando a função “mean_squared_error()”, pertencentes à mesma biblioteca (Anexo 6.3.). O NSE foi calculado no excell, inserindo a respetiva fórmula.

Matematicamente, estes procedimentos corresponderam aos seguintes cálculos:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3.11)$$

$$b_0 = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (3.12)$$

$$MSE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad (3.13)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (3.14)$$

onde y_i são os dados observados, \hat{y}_i os resultantes da regressão linear, \bar{y}_i a média dos observados, x_i são os valores previstos e \bar{x} a sua média e n é a dimensão da amostra.

3.7. Validação indireta das previsões

As previsões foram também comparadas com as observações num contexto de calendarização da rega, através da simulação do balanço hídrico no ISAREG, com o objetivo de comparar o calendário de rega e as necessidades de rega segundo cada conjunto de dados.

Esta calendarização foi calculada para as duas culturas anuais de primavera-verão mais representativas do perímetro: o milho e o sorgo. Estas correspondem às culturas de maiores NR no PRL (Aparício, 2022).

O cálculo das necessidades de rega depende, para além da cultura e das variáveis meteorológicas, do tipo de solo, pelo que é necessária a utilização de unidades homogéneas de análise (UHA) cultura-solo para a modelação. As UHA cultura-solo de milho e sorgo, definidas como as mais predominantes por Aparício (2022), são o milho em aluviossolos modernos, não calcários, de textura mediana (Milho-A), com 85.83 ha (13.7% da área total) e o sorgo em solos mediterrânicos vermelhos ou amarelos de materiais não calcários, normais, de "rañas" ou depósitos afins (Sorgo-Sr), com 41.4 ha (6.6% da área total).

3.7.1. Parâmetros Culturais

Neste trabalho, a ET_c foi calculada através da abordagem do K_c médio (Allen et al., 1998), que combina a transpiração da cultura com a evaporação do solo. Assim, foi seguido a metodologia de cálculo definida por Allen et al. (1998): identificar as fases fenológicas da cultura e a sua duração e os respetivos valores de K_c ; ajustar os K_c às condições meteorológicas locais durante as respetivas fases; construir a curva dos K_c ajustados; e, por último, calcular a ET_c como produto da ET_o e do respetivo K_c .

3.7.1.1. Fases Fenológicas

As fases fenológicas destas culturas foram estimadas por Aparício (2022) para 2020, de acordo com a análise da curva do NDVI. Conhecendo as observações da T_{med} para o ano de 2020, foi possível calcular a acumulação de unidades de calor, ou graus-dia de desenvolvimento (GDD, °C dia), necessária para atingir cada fase do ciclo das duas culturas nesse ano. Para este efeito, foram utilizadas as datas de sementeira e colheita obtidas no mesmo estudo (Aparício, 2022).

Na ausência de outros fatores limitantes como a escassez de água, o crescimento e a fenologia das plantas depende em grande parte da acumulação de temperatura. Os GDD necessários para atingir cada fase do ciclo varia de cultura para cultura, mas o conceito mantém-se: o desenvolvimento das plantas ocorre apenas a partir de um limiar de temperatura, que se denomina temperatura de base (T_b), abaixo do qual a taxa de crescimento é considerada desprezável; existe ainda um limiar superior de temperatura (T_{cut}), acima do qual a taxa de crescimento das plantas não aumenta significativamente

(Spinoni et al., 2015). A acumulação térmica para cada dia, a somar à atingida no dia anterior, foi calculada da seguinte forma (Raes et al., 2012):

$$GDD = \frac{T_{max}+T_{min}}{2} - T_b \quad \text{se} \quad T_b < \frac{T_{max}+T_{min}}{2} < T_{cut} \quad (3.15)$$

$$GDD = T_{cut} - T_b \quad \text{se} \quad \frac{T_{max}+T_{min}}{2} \geq T_{cut} \quad (3.16)$$

$$GDD = 0 \quad \text{se} \quad \frac{T_{max}+T_{min}}{2} \leq T_b \quad (3.17)$$

Os valores de T_b e T_{cut} utilizados para cada cultura estão presentes no quadro 3.1.

Quadro 3.1. Temperatura de base (T_b) e limiar superior de temperatura (T_{cut}) segundo os respetivos autores.

Cultura	T_b (°C)	T_{cut} (°C)	Fonte
Milho	8	30	Paredes et al. (2014)
Sorgo	8	30	Raes et al. (2012)

Os valores resultantes deste cálculo foram então usados como referência para a estimativa das datas das fases fenológicas e colheitas dos anos a que o presente estudo se refere (2021 e 2022), permitindo comparar a fenologia segundo a temperatura observada e a prevista. Para estes anos foi usada a data de sementeira do milho em 2021 (29 de abril), obtida por Rodrigues (2022); já a do sorgo foi utilizada novamente a de 2020 (24 de maio), estimada por Aparício (2022). Estas datas de sementeira foram consideradas tanto para 2021 como 2022 por serem as datas conhecidas mais recentes de cada uma das respetivas culturas.

3.7.1.2. Coeficientes culturais

Os valores dos coeficientes culturais padronizados para cada fase do ciclo usados no presente estudo foram selecionados da bibliografia, tendo sido selecionados o manual FAO56 (Allen et al., 1998) e a recente revisão destes valores (Pereira et al., 2021) (Quadro 3.2). Na revisão dos valores padrão feita por Pereira et al. (2021) foi omitido o valor do K_c inicial uma vez que este representa maioritariamente a componente de evaporação do solo, uma vez que a cultura ainda está pouco desenvolvida nesta fase. A fase inicial do ciclo termina quando a fração de solo que é coberta pela cultura atinge 10%. Assim, a componente de transpiração é diminuta comparativamente com a componente evaporativa, dependendo por isso dos eventos de humedecimento do solo, ou seja, quanto maior o número de eventos de humedecimento quer pela precipitação quer pela rega, maior será o valor de $K_{c\ ini}$, devendo

deste modo o valor ser ajustado para as condições de cada local. Assim, dado que o manual FAO56 apresentava valores aconselhados para climas semi-húmidos optou-se por utilizar esses valores.

Quadro 3.2. Coeficientes culturais (K_c) tabelados para cada fase do ciclo e respetivos autores.

	Milho	Sorgo	Fonte
$K_{c\ ini}$	0.3	0.3	Allen et al. (1998)
$K_{c\ mid}$	1.2	1.1	Pereira et al. (2021)
$K_{c\ end}$	0.3	0.45	Pereira et al. (2021)

Segundo os procedimentos definidos por Allen et al. (1998), os valores de $K_{c\ mid}$ e $K_{c\ end}$ superiores a 0.45 carecem de um ajuste de acordo com a HR_{min} e a u_2 , por estas serem diferentes de 45% e de 2 m/s respetivamente. Neste caso, apenas os valores tabelados de $K_{c\ mid}$ ($K_{c\ mid(Tab)}$) carecem de ajuste por serem os únicos superiores a 0.45. Este ajuste resulta da seguinte equação:

$$K_{c\ mid} = K_{c\ mid(Tab)} + (0.04(u_{2\ med} - 2) - 0.004(HR_{min} - 45)) \left(\frac{h}{3}\right)^{0.3} \quad (3.18)$$

onde, $K_{c\ mid(Tab)}$ é o valor de $K_{c\ mid}$ presente na tabela 3.2.; $u_{2\ med}$ é a média da u_2 durante o período intermédio do ciclo cultural, para $1\ m/s \leq u_{2\ med} \leq 6\ m/s$; HR_{min} é a média do valor de humidade relativa mínima diária durante o mesmo período de tempo, para HR_{min} entre 20% e 80%; e h é a altura máxima da cultura durante o respetivo período de tempo, para h entre 0.1 m e 10 m.

No caso dos dados de previsão, o único valor de HR conhecido é HR_{med} , pelo que a mínima, necessária ao ajuste dos K_c s, deverá ser extrapolada das T_{max} e T_{min} , segundo Allen et al. (1998):

$$HR_{min} = \frac{e^o(T_{min})}{e^o(T_{max})} 100 \quad (3.19)$$

onde, $e^o(T_{min})$ e $e^o(T_{max})$ são a pressão de vapor de saturação às T_{min} e T_{max} , respetivamente (kPa). Estes valores foram, por sua vez, calculados da seguinte forma:

$$e^o(T) = 0.6108 \exp\left(\frac{17.27 T}{T+237.3}\right) \quad (3.20)$$

onde, $e^o(T)$ (kPa) é a pressão de vapor de saturação à temperatura T (°C) e \exp é o número de Neper.

No cálculo da equação 3.18, os valores de h utilizados foram os atualizados por Pereira *et al.* (2021), 2,5-3,5 m para o milho e 1,5-2 m para o sorgo. Foram, portanto, utilizados os valores intermédios destes intervalos (3 m para o milho e 2,75 m para o sorgo). Este ajuste foi feito independentemente para cada ano.

Para a execução das curvas, considerou-se que o K_c no período de crescimento rápido aumentou linearmente entre o $K_{c\ ini}$ e $K_{c\ mid}$ e que no período final decresceu da mesma forma entre $K_{c\ mid}$ e $K_{c\ end}$.

3.7.1.3. Profundidade radicular e fração facilmente utilizável

De modo a simular o BH no ISAREG, é necessário fornecer ao modelo todos os valores necessários ao cálculo da RU e da RFU do solo. Como já referido na revisão bibliográfica, o cálculo da RFU carece da fração da RU que pode ser utilizada da zona das raízes sem que a planta entre em stress hídrico (p), que, por sua vez, varia segundo a cultura e a magnitude da ET_c . A RU depende do tipo de solo e da profundidade das raízes (Zr). Foram utilizados novamente os valores atualizados por Pereira *et al.* (2021):

Quadro 3.3. Profundidade radicular máxima (Zr_{max} , m) e fração de depleção de água no período intermédio do ciclo sem stress (p). Zr_{max} depende da textura e estrutura do solo: o primeiro valor é referente a solos de textura fina e o segundo a solos de textura grosseira.

	Zr_{max}	p
Milho	0.60– 1.50	0.5
Sorgo	1.00– 1.50	0.55

Os tipos de solos nas presentes UHA, A (solos incipientes de textura mediana) e Sr (solos argiluvitados pouco insaturados, mediterrânicos vermelhos ou amarelos de materiais não calcários), correspondem, respetivamente, a solos médios e pesados, pelo que o valor de Zr_{max} utilizado para o Milho-A foi a média do intervalo tabelado (1,05 m) e para o Sorgo-Sr foi o valor mínimo (1 m). Tendo em conta que Zr_{max} é atingida no período intermédio, por se tratarem de culturas anuais, para a fase inicial considerou-se a Zr de ambas as culturas como 0.05 m, aproximadamente a profundidade de sementeira (Coronel *et al.*, 2020), e na fase de crescimento rápido o modelo ISAREG considera o crescimento linear da raiz entre 0.05 m e Zr_{max} de cada cultura.

Como já mencionado, os valores de p variam de acordo com a ET_c e os valores tabelados referem-se a $ET_c = 5$ mm/dia, pelo que para outros valores p deverá ser ajustado:

$$p = p_{tab} + 0.04 (5 - ET_c)$$

(3.21)

onde p_{tab} são os valores contidos no Quadro 3.3., p é expresso como fração e ET_c e como mm/dia.

3.7.2. Parâmetros Pedológicos

A RU foi calculada segundo Allen et al. (1998) (Eq. 2.5.). Para isto foi necessário, para além da Z_r , da fração volúmica de água à capacidade de campo (θ_{vCC}) e ao coeficiente de emurchecimento (θ_{vCE}) para cada camada de solo. No âmbito desta dissertação, não se justifica considerar as diferentes camadas de cada solo, considerando-se, assim, as características médias do perfil. Estes dados foram retirados de Cardoso (1965) e Rawls et al. (1982) (Quadro 3.4.).

Quadro 3.4. Características das principais classes de solo. Z é a profundidade do solo (m), θ_{vCC} e θ_{vCE} são o volume de água por volume de solo (%) à capacidade de campo e no coeficiente de emurchecimento, respetivamente.

Classe de solo	Z	θ_{vCC}	θ_{vCE}
A	1.3	21.5	11.05
Sr	0.75	16.79	6.07

O Quadro 3.5. contém os resultados do cálculo da equação 2.4., excluindo a multiplicação por Z_r , para os respetivos solos, inseridos no ISAREG nos respetivos ficheiros do solo “_SOL”.

Quadro 3.5. A capacidade utilizável (U, mm) de cada um dos solos considerados.

Classe de Solo	U (mm)
A	104.5
Sr	107.2

3.7.3. Características de Rega

Nas UHA consideradas, não houve cultura anterior e nos 90 dias que antecederam as sementeiras em ambos os anos, a precipitação foi superior às respetivas RUs, com exceção de 2022 no solo A, tendo ficado a menos de 10 mm da mesma. Deste modo, foi considerada 70% da RU preenchida na zona que recebeu a semente e 100% nas camadas inferiores de ambos os solos em ambos os anos.

Tratando-se de cereais, a rega cessa após a maturação fisiológica ser atingida, permitindo que o grão seja colhido com um teor de água adequado à sua conservação pós-colheita, sendo também a altura em que o stress hídrico afeta menos a produtividade (Paredes et al., 2014). Deste modo, o milho deixa de ser regado 30 a 20 dias antes da colheita (Paredes et al., 2015; Giménez et al., 2016), pelo que foi utilizado o valor intermédio, 25 dias. No caso do sorgo, a literatura recorre a intervalos muito semelhantes, pelo que se considerou a rega também interrompida 25 dias antes da respetiva colheita (O'Shaughnessy et al., 2012).

Em relação à oportunidade de rega, foi considerada a ativação da rega no limite da RFU e o seu término após uma dotação de rega fixa de 10 mm. Este volume corresponde ao usual aplicado por sistemas de rega de rampa pivotante, sistemas majoritários na rega das culturas de milho e de sorgo no PRL (Rodrigues, 2022).

3.7.4. Necessidades de rega

Para modelação das NR foi utilizado o modelo ISAREG, já calibrado e validado para ambas as culturas estudadas (Popova et al., 2006; Ferreira et al., 2022). Como mencionado, o ISAREG simula o BH e, com base nas necessidades hídricas, calcula as necessidades de rega ao longo do tempo. Para isso, em cada simulação, foi necessária a introdução de três tipos de informação no programa: dados meteorológicos, agronómicos e características da rega; cada um em formato de ficheiros de texto (.txt).

Para cada caso (Obs/Prev) e cada ano (2021/2022), os dados meteorológicos foram divididos em dois ficheiros, um para os valores diários de ET_o (mm/dia), com o código “_ET0”, e outro com os valores diários de P (mm/dia), com o código “_PRE”. Enquanto os dados agronómicos foram inseridos num ficheiro com o código “_CUL”, contendo os parâmetros de cada cultura para o ano referente; e num ficheiro com o código “_SOL”, contendo os parâmetros pedológicos correspondentes aos respetivos solos. Os dados referentes às características da rega foram inseridos num ficheiro com o código “_IRR”.

Nos ficheiros dos parâmetros culturais foram incluídos: a data de sementeira e as fases fenológicas, assim como os coeficientes culturais correspondentes; a profundidade radicular para cada fase do ciclo cultural; e a fração facilmente utilizável (ρ).

Por sua vez, nos ficheiros dos parâmetros do solo, foram inseridos: o número de camadas consideradas; a profundidade (Z , m) e os valores da capacidade utilizável de cada solo (U , mm/m), calculados pela equação 2.4.

O ficheiro das características da rega, conteve o esquema de rega, % da RU preenchida na zona que recebe a semente e nas restantes camadas, número de dias antes da colheita em que a rega cessa, a definição da oportunidade e da quantidade de rega a aplicar.

Não foram consideradas restrições à rega nem ascensão capilar.

3.7.4.1. Comparação das necessidades de rega

A diferença no volume de rega (ΔV) resultante de cada caso foi comparada com as respetivas diferenças das ET_c s (ΔET_c). Assim, do cálculo $\Delta V / \Delta ET_c$ foi possível deduzir quanto da diferença de volumes de rega se deveu a diferenças na ET_c .

Com o objetivo de avaliar o impacto direto que a utilização das previsões na calendarização da rega teria nestes dois anos, foi ainda executado um terceiro tipo de simulação: a aplicação do calendário de rega resultante das previsões nas condições culturais e meteorológicas resultantes das observações. Este procedimento permitiu avaliar o impacto das previsões na rega.

4. Resultados e discussão

4.1. Seleção de pontos da grelha

A comparação direta entre os 25 pontos mais próximos demonstrou que as variáveis T_{max} , T_{min} , HR_{med} e R_s cumprem os critérios anteriormente descritos (ver secção 3.4.) em todos os pontos e que a u_2 e a P não os cumprem em qualquer ponto (Anexo 6.4.). Verificou-se que existia uma grande semelhança entre as previsões nos 25 pontos da grelha.

A ponderação pelo inverso da distância à EMR levou a uma ligeira melhoria nos valores das métricas quanto mais pontos foram considerados na interpolação (Anexo 6.5a.), no entanto a diferença entre a ponderação dos 25 pontos para o uso de apenas o ponto mais próximo foi mínima e não significativa ($\alpha = 0.05$) (Anexo 6.5b.).

Estes testes levam à conclusão de que a alternativa mais lógica e parcimoniosa é o uso apenas das previsões correspondentes ao ponto mais próximo da EMR neste trabalho, pelo que foi este o ponto escolhido. Este ponto encontra-se a 501 m de distância da EMR, como referido, e está a uma altitude de 281 m, e tem de longitude $-7,54244995^\circ$ W e de latitude $38,6486244^\circ$ N.

4.2. Avaliação prévia da qualidade dos dados

Confirmou-se que nenhum dos dias continha valores das diferentes variáveis em falta, quer na série de dados de observações quer na de previsões, para o período considerado (01/01/2021 a 31/12/2022). Em ambas as séries não havia também qualquer dia em que a $T_{max} < T_{min}$.

O mesmo foi verificado em relação à HR_{max} e HR_{min} observadas, no entanto, quando comparadas com as condições standard, constatou-se a presença de 199 dias em que $HR_{max} < 90\%$ (27.2% dos dias), e de 187 dias em que $HR_{min} < 25\%$ (25,6% dos dias). Em relação à HR_{med} : os dados observados estiveram abaixo dos 70% em 390 dias (53,4% dos dias analisados) e os previstos em 458 dias (62.7% dos dias), constatando-se que quer nas medições, quer nas previsões, a maioria dos dias apresentam valores de HR_{med} anormalmente baixos. Assim, de acordo com Allen (2008) verifica-se que a estação meteorológica não se encontra nas condições standard para o cálculo da ET_o , ou seja sobre um relvado extenso e bem regado em que é expectável que a HR_{max} diária seja sempre próxima de 100% e a HR_{min}

em climas sub-húmidos é geralmente superior a 30%. Este viés existe quer nos dados observados como nos dados de previsão, pelo que terá impacto em ambas as estimativas da ET_o .

Os valores observados da R_s foram inferiores à R_{s0} todos os dias dos dois anos, no entanto os dados de previsão excederam os valores de R_{s0} em 113 dias de 2021 e 109 de 2022 (Figura 4.1.), denotando uma inconsistência dos valores previstos de R_s relativamente ao máximo possível (R_{s0}). Assim, os modelos usados para a geração dos dados de previsão necessitam ser corrigidos para esta variável, limitando os valores possíveis de R_s . Por outro lado, apesar dos valores observados de R_s não ultrapassarem a R_{s0} , encontravam-se muito longe desses valores nos dias de verão, nos quais é previsível não existirem nuvens, pelo que demonstram a existência de falta de adequada calibração dos sensores ou a falta de manutenção dos equipamentos, e deste modo careceram também de um ajustamento dos valores. No caso das observações de R_s , seguindo a metodologia descrita por Allen (2008) os valores foram aumentados em 3 % para 2021 e em 2 % para 2022, o que permitiu aproximar as observações de R_s aos valores de R_{s0} durante os meses de verão. Para os dados de previsão, o dia de cada ano em que a R_s foi mais elevada relativamente à R_{s0} diária foi então igualado à mesma e os valores dos restantes dias de cada ano reduzidos na mesma proporção (5,2 % para 2021 e 6,2 % para 2022) (Figura 4.2.).

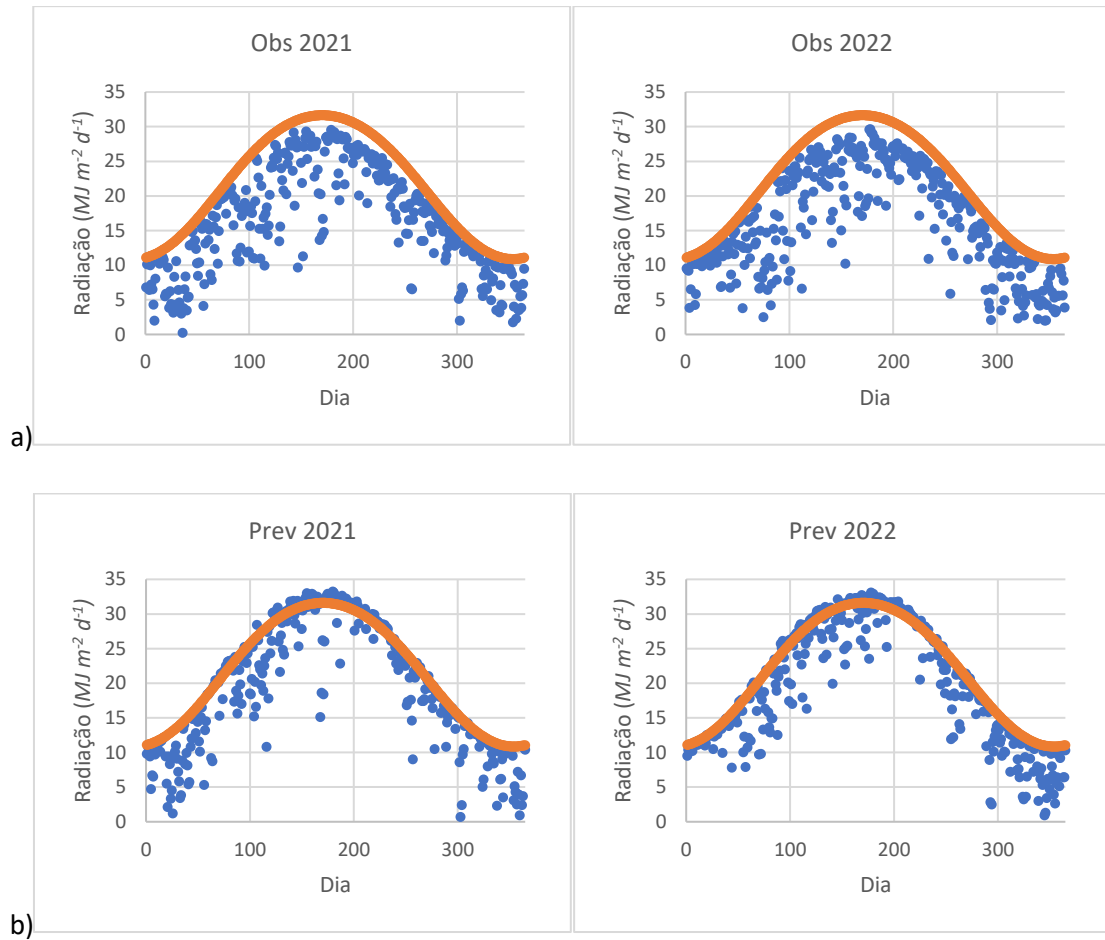


Figura 4.1. Comparação dos valores observados (Obs) a), e previstos (Prev) b), da radiação solar global (R_s) a azul, com os valores da radiação solar de céu limpo (R_{so}) a laranja. Os gráficos contêm a radiação ($\text{MJ m}^{-2} \text{d}^{-1}$) em função do dia do ano.

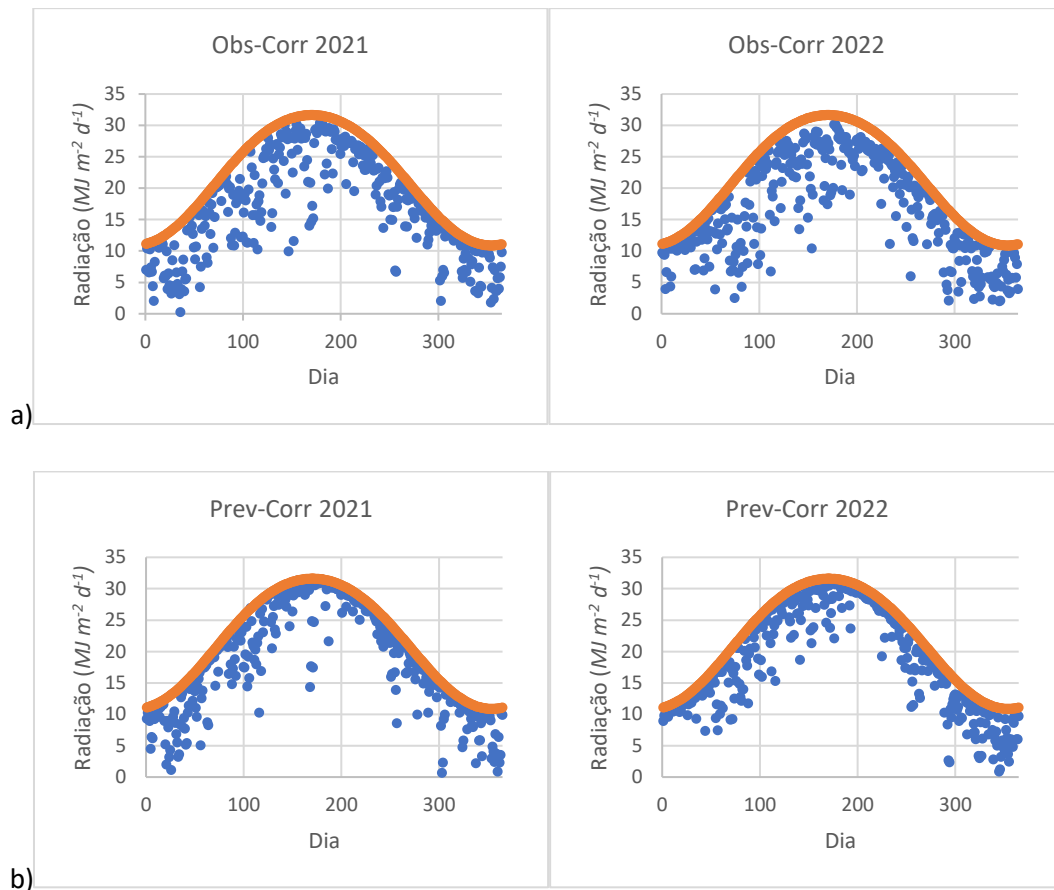


Figura 4.2. Valores observados a) e previstos b) corrigidos (Obs-Corr e Prev-Corr) a azul, comparados com os valores da radiação solar de céu limpo (R_{so}), a laranja. Os gráficos contêm a radiação ($\text{MJ m}^{-2} \text{d}^{-1}$) em função do dia do ano.

Nos dois anos de dados (2021 e 2022), houve 45 dias em que a u_2 observada foi inferior a 0,5 m/s, não denotando um padrão que levasse a suspeitar de avaria ou de falta de manutenção do anemómetro. Assim, verifica-se por análise da u_2 observada que o local tem predominantemente um vento ligeiro a moderado (Allen et al., 1998).

Aquando desta análise verificou-se também que a u_2 prevista foi superior à observada para todos os dias, com uma diferença média de 2,8 m/s, sendo em média a previsão mais do triplo do valor medido. A u_2 , dada a sua variabilidade temporal e espacial, é de difícil previsão (Martins et al., 2017; Paredes et al., 2018). Esta diferença nos valores da u_2 resulta num viés positivo na ET_o calculada com os dados de previsão ($ET_o\text{-Prev}$) em relação à ET_o calculada com os observados ($ET_o\text{-Obs}$): este viés corresponde, em média, a 0,96 mm por dia ($\approx 30\%$ da $ET_o\text{-Obs}$).

Quando comparada a $ET_o\text{-Obs}$ com a ET_o calculada com todos os dados observados exceto a u_2 de previsão, a diferença aumenta para 1,56 mm por dia ($\approx 50\%$ da $ET_o\text{-Obs}$), o que permite por um lado quantificar o impacto do viés no cálculo da ET_o quando os dados de u_2 de previsão são usados e por

outro permite verificar que os erros das restantes variáveis previstas compensam parcialmente os erros dos valores de u_2 previstos, contribuindo para a diminuição da diferença entre os valores da ET_o -Obs e ET_o -Prev (Figura 4.3.).

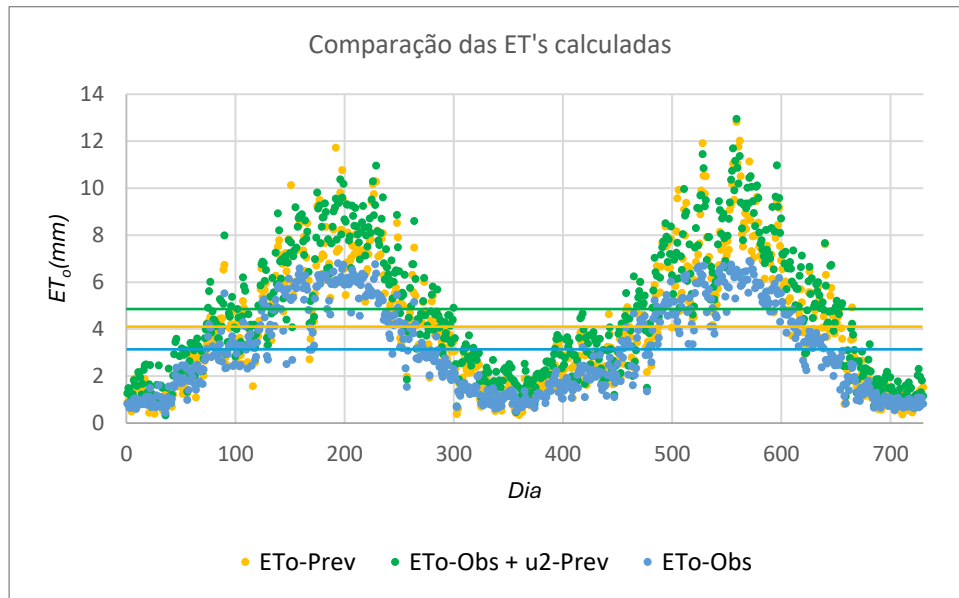


Figura 4.3. Valores diários de ET_o calculados com os dados previstos (ET_o -Prev), observados (ET_o -Obs) e observados mas com a velocidade do vento prevista (ET_o -Obs + u_2 -Prev); e os respetivos valores médios de todo o período.

4.3. Validação direta das previsões

4.3.1. Comparação da distribuição das séries de dados

O Quadro 4.1. apresenta os resultados da comparação das distribuições das séries observadas e geradas pelo modelo de previsão. Os desvios padrão das séries de dados previstos das distintas variáveis são um pouco mais elevados do que os da série das observações com exceção da P. Os desvios padrão da série de dados observados de T_{max} , T_{min} , R_s e P não são significativamente diferentes ($p > 0.05$) dos da série de previsão, tal como os valores médios da P. Os valores da curtose são negativos em ambas as séries para todas as variáveis comparadas (distribuições platicúrticas), à exceção também da P, onde há uma elevada ocorrência de valores extremos em ambas as séries (leptocúrticas), sendo especialmente elevada na série de dados de previsão. Relativamente à simetria, os valores dos dados previstos apresentam uma distribuição semelhante aos valores observados para a T_{max} e HR_{med} , uma distribuição com mais valores abaixo da média para a u_2 e R_s , e uma distribuição com mais valores acima da média para as restantes variáveis.

Quadro 4.1. Comparação da distribuição dos valores diários das diferentes variáveis meteorológicas observadas (Obs) e previstas (Prev).

	T_{max} (°C)		T_{min} (°C)		HR_{med} (%)		u_2 (m s ⁻¹)		R_s (MJ m ⁻² d ⁻¹)		P (mm)		ET_o (mm d ⁻¹)	
	Obs	Prev	Obs	Prev	Obs	Prev	Obs	Prev	Obs	Prev	Obs	Prev	Obs	Prev
Média	25.2	23.4	10.8	9.5	68.2	62.8	1.1	3.9	16.7	18.5	1.4	1.1*	3.2	4.1
Desvio Padrão	7.8	7.9*	4.8	5.1*	16.5	18.4	0.5	1.3	7.8	8.3*	4.7	4.4*	1.9	2.7
Curtose	-0.8	-0.8	-0.2	-0.5	-0.6	-0.7	1.3	0.4	-1.2	-1.2	40.7	104.2	-1.3	-0.4
Simetria	0.3	0.3	-0.3	0.1	-0.1	-0.1	1.0	0.8	-0.01	-0.09	5.7	8.4	0.3	0.6

Nota: Médias e desvios padrão com diferenças não significativas para $\alpha = 0.05$ representadas por *; T_{max} – Temperatura máxima do ar (°C); T_{min} – Temperatura mínima do ar (°C); HR_{med} – Humidade relativa do ar média (%); u_2 – velocidade do vento medida a 2 m de altura (m s⁻¹); R_s – Radiação solar global (MJ m⁻² d⁻¹); P – precipitação (mm); ET_o – Evapotranspiração da cultura de referência (mm d⁻¹).

A comparação anterior permitiu excluir uma diferença significativa entre o valor médio e o desvio padrão da P e concluir que o modelo prevê valores extremos de P com maior frequência do que estes ocorrem, especialmente valores extremos acima da média. Foi então avaliada a qualidade das previsões da P também através da análise qualitativa da ocorrência de P, através de uma matriz de confusão (Quadro 4.2).

O Quadro 4.2. mostra que nos 730 dias analisados, houve 141 com previsão correta de ocorrência de precipitação, ou seja, verdadeiros positivos (VP), 35 falsos positivos (FP), 81 falsos negativos (FN) e 473 dias com previsão correta de ausência de precipitação, ou verdadeiros negativos (VN).

Quadro 4.2. Matriz de confusão da ocorrência de precipitação.

	OBS: P	OBS: NÃO P
PREV: P	141	35
PREV: NÃO P	81	473

De acordo com a anterior análise, todas as métricas apresentam valores favoráveis ao modelo de previsão de precipitação: de realçar a muito elevada especificidade, que indica que o modelo prevê a ausência de precipitação mais de 93% das vezes que não ocorre de facto. Em contraste (Quadro 4.3.), a sensibilidade mostra que o modelo prevê a ocorrência de precipitação 64% das vezes que de facto ocorre, mostrando que o modelo prioriza a previsão correta de ausência de precipitação (VN) sobre a da sua ocorrência (VP).

Quadro 4.3. Métricas de análise da qualidade da previsão da ocorrência de precipitação.

Acurácia (adm.):	0.84
Precisão (adm.):	0.80
Sensibilidade (adm.):	0.64
Especificidade (adm.):	0.93

4.3.2. Análise de correlação

Segundo a análise de correlação (Quadro 4.4., Anexo 6.7.), todas as métricas das variáveis da temperatura máxima e mínima e da R_s são bastante favoráveis ao modelo de previsão: os R^2 , b_0 e NSE elevados evidenciam uma elevada correlação e precisão da sua previsão, assim como os baixos MSE e RMSE indicam que as previsões tendem a ser próximas das respetivas medições. Para estas três variáveis, o RMSE é inferior ao desvio padrão tanto das observações como das previsões, o que demonstra a capacidade do modelo de previsão acompanhar a variabilidade das observações, sendo esta conclusão reforçada pelos NSE próximos de 1.

Quadro 4.4. Análise da correlação entre os valores observados e os previstos.

	T_{max} (°C)	T_{min} (°C)	HR_{med} (%)	u₂ (m s ⁻¹)	R_s (MJ m ⁻² d ⁻¹)	P (mm)	ET_o (mm d ⁻¹)
R²	0.95	0.81	0.78	0.55	0.86	0.27	0.87
b₀	0.93	0.89	0.92	3.24	1.15	0.52	1.31
MSE	6.62	6.51	103	8.83	12.69	20.05	2.26
RMSE	2.57	2.55	10.15	2.97	3.56	4.48	1.50
NSE	0.89	0.72	0.62	-35.07	0.79	0.08	0.37

Nota: A negrito, os valores de R^2 e b_0 dentro do intervalo de aceitação; T_{max} – Temperatura máxima do ar; T_{min} – Temperatura mínima do ar, HR_{med} – Humidade relativa do ar média, u_2 – velocidade do vento medida a 2 m de altura; R_s – Radiação solar global, P – precipitação, ET_o – Evapotranspiração da cultura de referência.

Apesar de apresentarem uma boa correlação, a T_{max} e T_{min} são subestimadas pelas previsões ($b_0 = 0.93$ e $b_0 = 0.89$, respetivamente). Este resultado coincide com o observado para a Galiza por Brands et al. (2011), para previsões diárias, e vai de encontro à subestima da temperatura de superfície verificada por Johannsen et al. (2019) em dados diários para a península ibérica. A subestima da T_{max} difere, no entanto, do reportado noutros estudos realizados em Portugal, onde as previsões sobrestimaram dados diários (Paredes et al., 2018; Soares et al., 2012) e dados mensais na península ibérica (Martins et al., 2017).

As previsões da HR_{med} (Quadro 4.4) também apresentam uma correlação e precisão favoráveis e, apesar de uma pequena tendência para a subestima e um RMSE superior a 10%, este valor também se

encontra abaixo dos desvios padrão desta variável, o que em conjunto com o NSE positivo de 0.62 demonstra que os dados gerados pelo modelo de previsão são um melhor preditor que a média das observações.

As previsões da u_2 (Quadro 4.4), como já discutido, são as menos favoráveis: o modelo de regressão representa apenas 55% da variabilidade (R^2); os dados previstos são muito superiores aos observados, correspondendo em média a 324% (b_0) das observações; o RMSE é muito superior aos desvios padrão desta variável o que, em conjunto com o negativo e muito baixo NSE, demonstra que a média das observações nos dois anos é muito melhor preditor que as previsões. A baixa precisão da previsão da u_2 vai de encontro com o verificado em vários estudos em Portugal, assim como a tendência à sua sobrestima (Paredes et al., 2018; Carvalho, 2014).

A P apresenta também uma baixa correlação entre as previsões e observações de apenas 27% (R^2), uma subestima, com as previsões a corresponderem em média a apenas 52% da magnitude das observações (b_0) e um elevado RMSE. No entanto o ligeiramente positivo NSE (0.08) revela que os dados de previsão modelam a P observada ligeiramente melhor que a média das observações (Quadro 4.4). A baixa correlação da P vai de encontro ao verificado por Cao et al. (2019).

Por último, a ET_o apresenta um coeficiente de correlação favorável, com uma sobrestima da ET_o calculada com os dados de previsão relativamente à ET_o -Obs, um RMSE menor que os desvios padrão e um NSE positivo, o que demonstra alguma capacidade do modelo de acompanhar a variabilidade das observações. No entanto, como já mencionado, a u_2 utilizada no cálculo desta ET_o -Prev é pior preditora que a média das observações nos dois anos, pelo que fez sentido atualizar os valores da ET_o -Prev, utilizando a média da u_2 observada no seu cálculo, ao invés dos valores previstos para cada dia. Foi então utilizada a média da u_2 dos últimos 10 anos (2011-2020), de modo a constituir um volume de dados mais robusto que apenas os 2 anos considerados no estudo, e comparadas novamente a ET_o -Obs com a atualizada ET_o -Prev (ET_o -Prev2).

A substituição da u_2 prevista diária pelo valor médio local da u_2 ($u_{2med} = 1.83$ m/s) aproximou a distribuição da ET_o -Prev2 da ET_o -Obs, como evidenciado pela aproximação de todas as métricas analisadas no Quadro 4.5., apesar da média e desvio padrão da ET_o -Prev2 continuarem diferentes aos de ET_o -Obs para $\alpha = 0.05$ (Quadro 4.5).

Quadro 4.5. Comparação das distribuições da ET_o calculada com os valores observados (ET_o -Obs) com a ET_o calculada apenas com os dados previstos (ET_o -Prev1) e com a ET_o calculada com os valores previstos mas com a velocidade do vento média observada nos últimos 10 anos (ET_o -Prev2).

	ET_o -Obs	ET_o -Prev1	ET_o -Prev2
Média (mm d ⁻¹)	3.2	4.1	3.5
Desvio Padrão (mm d ⁻¹)	1.9	2.7	2.2
Curtose	-1.3	-0.4	-1.0
Simetria	0.3	0.6	0.4

A aproximação das distribuições (Quadro 4.5) refletiu-se também na correlação entre a ET_o -Obs e a ET_o -Prev2 (Quadro 4.6), melhorando substancialmente todas as métricas em relação à ET_o -Prev1: o modelo passou a prever 91% da variabilidade da ET_o -Obs (R^2) e o b_0 desceu para dentro do intervalo de aceitação para esta métrica, reduzindo a sobrestima do modelo, passando a ET_o -Prev2 a ser, em média, 9% superior à ET_o -Obs, ao invés dos 31% da ET -Prev1; a redução do RMSE para cerca de metade e a mais de duplicação do NSE, por sua vez, demonstram que a ET_o -Prev atualizada com a média de 10 anos de u_2 observada modela muito melhor a ET_o -Obs que a anterior. Segundo estes resultados, a ET_o -Prev considerada, e assim referida a partir deste ponto, passa a ser a ET_o calculada com os valores de previsão com exceção da u_2 , substituída pela sua média decenal observada.

Quadro 4.6. Comparação da correlação entre a ET_o calculada com os valores observados (ET_o -Obs) e a ET_o calculada com os valores previstos (ET_o 1). E comparação da correlação entre a ET_o -Obs e a ET_o calculada com os valores previstos mas com a velocidade do vento média observada nos últimos 10 anos (ET_o 2).

	ET_o 1	ET_o 2
R^2	0.87	0.91
b_0	1.31	1.09
MSE	2.26	0.54
RMSE (mm d ⁻¹)	1.50	0.74
NSE	0.37	0.84

Nota: A negrito, os valores de R^2 e b_0 dentro do intervalo de aceitação.

4.4. Validação indireta das previsões: modelação das necessidades de rega

4.4.1. Parâmetros culturais

4.4.1.1. Fases Fenológicas

De acordo com as T_{med} observadas na EMR para o ano de 2020 e as respetivas datas das fases fenológicas reportadas por Aparício (2022), foi estimada a acumulação térmica (GDD) das diversas fases. Os GDD foram então utilizados para extrapolar as datas do ciclo cultural, assim como para estimar o impacto dos dados de previsão nas respetivas datas para os anos de 2021 e 2022. No Quadro

4.7. estão apresentados os GDD para as fases do ciclo de acordo com a FAO (Allen et al., 1998). Esta estimativa considera o período inicial a partir da sementeira.

Quadro 4.7. Graus-dia de desenvolvimento (GDD) de cada um dos períodos do ciclo cultural em 2020 (°C dia).

Período	GDD-Milho	GDD-Sorgo
Inicial	160	250
Crescimento rápido	600	490
Intermédio	920	1180
Final	530	180

$T_b = 8\text{ }^\circ\text{C}$, $T_{cut} = 30\text{ }^\circ\text{C}$

Como referência de comparação, no Quadro 4.8., foram também calculados os dias de cada período e do ciclo completo:

Quadro 4.8. Duração de cada período fenológico e do ciclo completo em 2020.

Período:	Milho(dias)	Sorgo(dias)
Inicial	17	17
Crescimento rápido	47	31
Intermédio	49	65
Final	32	16
Nº Dias ciclo:	145	129

Aplicando os valores presentes no Quadro 4.7 à T_{med} de 2021 e 2022, estimaram-se a duração das respetivas fases fenológicas e data de colheita segundo os dados observados e previstos, como apresentado no Quadro 4.9. Os resultados mostram uma tendência de sobrestima da duração dos períodos fenológicos quando as previsões são utilizadas em vez das observações.

Quadro 4.9. Comparação da duração (dias) de cada período fenológico do milho segundo as observações (Obs) e as previsões (Prev) para cada ano.

Período:	Milho				Sorgo			
	2021		2022		2021		2022	
	Obs	Prev	Obs	Prev	Obs	Prev	Obs	Prev
Inicial	19	21	12	13	18	18	17	19
Crescimento rápido	45	47	40	46	33	36	31	32
Intermédio	55	58	52	58	76	83	68	73
Final	40	36	35	37	16	17	16	16
Nº Dias ciclo:	159	162	139	154	143	154	132	140

Obs – estimativa do ciclo com dados observados; Prev – estimativa do ciclo com dados de previsão

A utilização dos dados de previsão resulta num atraso da colheita: no milho, 3 dias em 2021 e 14 em 2022; no sorgo, 11 dias em 2021 e 8 em 2022. Em proporção, no milho o ciclo observado durou -2% que o previsto para 2021, e -9% para 2022; no sorgo durou -7% para 2021, e -6% para 2022. Esta sobrestima de duração fenológica vai de encontro com a ligeira subestima das T_{max} e T_{min} encontrada na análise de correlação da validação direta das previsões (Quadro 4.4.), sendo a T_{max} prevista em média 7% inferior à observada ($b_o = 0.93$), e a T_{min} 11% inferior ($b_o = 0.89$). Yang et al. (2023) verificaram uma tendência semelhante para a vinha no norte de Portugal e o contrário no centro e sul usando dados do sistema de previsão ECMWF-SEAS5. Esta imprecisão pode dever-se à desadequação do modelo em considerar o já significativo efeito das AC no clima atual, tendo Yang et al. (2017) estimado que as alterações climáticas resultem, na zona do Ribatejo e do Oeste, no aceleração das fases fenológicas e no encurtamento do ciclo do milho em 4% a curto prazo (2021 a 2040) e 8% até 2060, sendo as diferenças obtidas para o milho neste trabalho de 2 e 9%.

4.4.1.2. Coeficientes culturais

Os valores dos $K_{c\ mid}$ foram ajustados às condições meteorológicas local para cada ano (Quadro 4.10.). Com estes valores e as respetivas datas obtidas no ponto anterior, foram então concebidas as curvas de K_c para cada caso (Figura 4.4.) e incluída a informação no modelo de simulação do balanço hídrico do solo ISAREG.

Quadro 4.10. Valores dos coeficientes culturais simples (K_c) ajustados às condições meteorológicas para as culturas selecionadas e anos em estudo quando são usados os dados observados (Obs) e os dados previstos (Prev).

	Milho				Sorgo			
	2021		2022		2021		2022	
	Obs	Prev	Obs	Prev	Obs	Prev	Obs	Prev
K_{cini}	0.3				0.3			
K_{cmid}	1.26	1.23	1.26	1.24	1.13	1.14	1.24	1.14
K_{cend}	0.3				0.45			

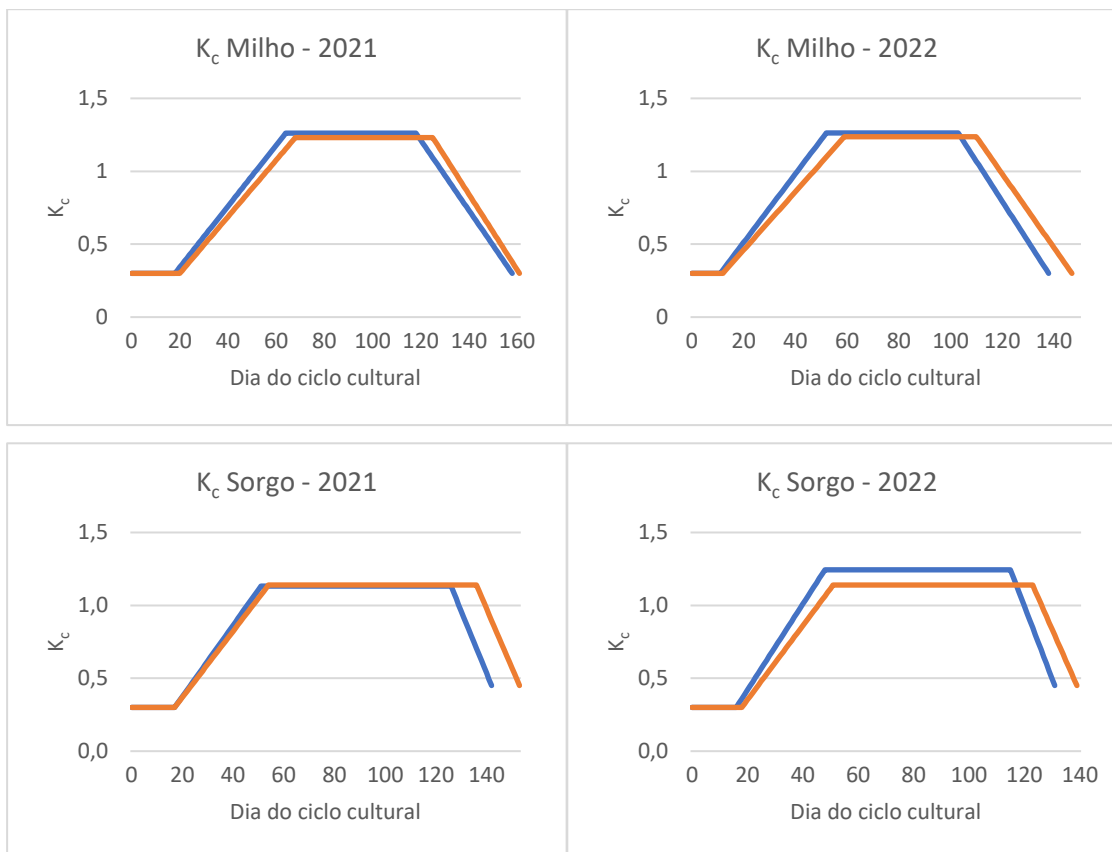


Figura 4.4. Curvas dos coeficientes culturais (K_c) para cada ano e cultura, representadas em função do dia do ciclo cultural, sendo que o dia 0 corresponde à sementeira e o último à colheita. A azul os valores segundo as observações e a laranja segundo as previsões.

As curvas de K_c demonstram mais uma vez a tendência tardia de início de cada fase e da colheita, quando são usados os dados de previsão (Figura 4.4.). É visível também que os dados de previsão resultam numa fase de crescimento rápido mais lenta em todos os casos. Aparenta haver também uma ligeira tendência de $K_{c\text{mid}}$ menor segundo os dados de previsão.

4.4.2. Necessidades de rega

Da simulação do BH no ISAREG resultam, entre outros dados, os dias em que as culturas seriam regadas, assim como os volumes de rega por mês e o conseqüente valor total de rega durante todo o ciclo das culturas (Quadro 4.11.). O modelo calcula também a ET_c acumulada durante o período de rega ($ET_c\text{ ac.}$), o volume perdido por percolação profunda (V. perd.) e a quebra potencial de produção devida ao stress hídrico verificado em função do esquema de rega usado (Q. prod).

Quadro 4.11. Volume regado (mm) por mês e o total regado em cada cultura em cada ano, segundo os dados observados (obs) e previstos (prev). O RMSE mensal entre os dois grupos de dados de cada ano.

	Milho				Sorgo			
	2021		2022		2021		2022	
	Obs	Prev	Obs	Prev	Obs	Prev	Obs	Prev
Mai	10	20	30	40	0	10	0	10
Jun	110	110	160	160	30	30	50	40
Jul	240	210	240	280	200	210	230	240
Ago	200	100	130	200	180	210	200	200
Set	30	20			60	90	30	60
Total	590	460	560	680	470	550	510	550
RMSE	47		41		20		15	

Os resultados apresentados no Quadro 4.11. mostram uma tendência dos dados de previsão resultarem em volumes superiores de rega decorrentes de uma maior ET_0 -Prev, com exceção da cultura do milho em 2021, cuja exceção resulta de menores volumes de rega nos meses de agosto e setembro quando os dados de previsão são usados. Estes resultados demonstram que, em média, quando os dados de previsão são usados para a cultura do sorgo resultam em muito menor erro no volume de rega mensal do que quando os dados de previsão são usados para a cultura do milho, sendo o maior RMSE (mensal) atingido para o milho em 2021 e o menor para o sorgo em 2022.

Para além de maior número de regas e, por consequência, de volumes superiores, os dados de previsão levaram a um início da rega mais precoce em todos os casos simulados (Quadro 4.12.), sendo esta diferença mais notória no caso da cultura do sorgo (12 dias em 2021 e 18 em 2022). O início precoce da rega acompanhado de um término do período de rega mais tardio também em todos os casos, levou a que a utilização de dados de previsão resultasse em períodos de rega mais longos (para o milho: 10 dias em 2021 e 15 em 2022; para o sorgo: 28 dias em 2021 e 24 em 2022). Mais uma vez, a diferença entre os períodos de rega foi superior na cultura do sorgo, estendendo-se o período de rega por quase mais 30 dias nos dados de previsão do que nas observações.

Quadro 4.12. Datas da primeira e última rega e respetiva duração do período de rega (P. de rega, dias) de cada cultura em cada ano, segundo os dados observados (obs) e previstos (prev).

	Milho				Sorgo			
	2021		2022		2021		2022	
	Obs	Prev	Obs	Prev	Obs	Prev	Obs	Prev
1ª rega	30/05	28/05	23/05	17/05	11/06	30/05	15/06	28/05
Últ. rega	01/09	09/09	19/08	28/08	12/09	28/09	05/09	11/09
P. de rega	94	104	88	103	93	121	82	106

Para todos os casos menos o milho em 2021, a ET_c acumulada estimada foi superior quando os dados de previsão foram usados relativamente à utilização dos dados observados (Quadro 4.13.), o que era expectável dada a sobrestima da ET_o -Prev, apesar de parcialmente mitigada pelos tendencialmente inferiores valores de K_c ajustados às condições meteorológicas. Não houve em nenhum dos casos simulados, algum volume significativo perdido por excesso de água na rega uma vez que os calendários foram desenhados com esse objetivo. A drenagem e percolação profunda existente foi devida à precipitação. Em relação à quebra potencial de produção devido ao esquema de rega usado, uma vez que se corta a rega 25 dias antes da colheita, as previsões resultaram em menor quebra potencial de produção na cultura do milho em ambos os anos, mas em maior quebra na cultura do sorgo. No entanto, os gráficos do BH (Figuras 4.5. e 4.6.) demonstram que as quebras de produção estimadas surgem todas do final do ciclo, quando o grão está a secar, pelo que não têm relevância prática. Ao longo do resto dos ciclos não existem mais momentos em que a reserva de água no solo desça abaixo do LRFU, pelo que não será expectável nenhuma quebra de produção nem na utilização de observações nem de previsões.

Quadro 4.13. A ET_c acumulada durante o período de rega (ET_c ac., mm), o volume perdido por drenagem e percolação profunda (V. perd., mm) e a quebra de produção devido ao stress hídrico (Q. prod., %).

	Milho				Sorgo			
	2021		2022		2021		2022	
	Obs	Prev	Obs	Prev	Obs	Prev	Obs	Prev
ET_c ac. (mm)	729	559	666	780	614	684	636	653
V. perd. (mm)	0	0	0	0	0	0	0	0.5
Q. prod (%)	0.2	0	5.4	2.5	0.5	3.5	0.9	4.6

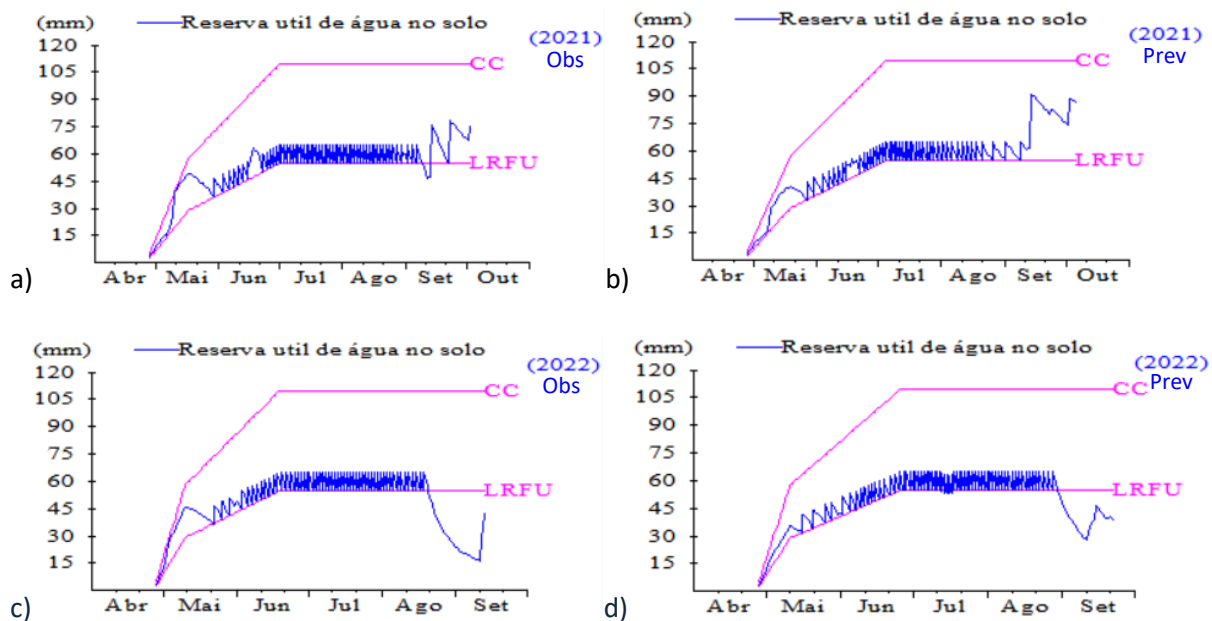


Figura 4.5. Gráficos do balanço hídrico para o Milho, a) e b) em 2021, c) e d) em 2022; a) e c) segundo os dados observados (Obs), b) e d) segundo os previstos (Prev). A rosa a capacidade de campo (CC, mm) e o limite da reserva facilmente utilizável (LRFU, mm) e a azul a reserva de água no solo a cada momento (mm).

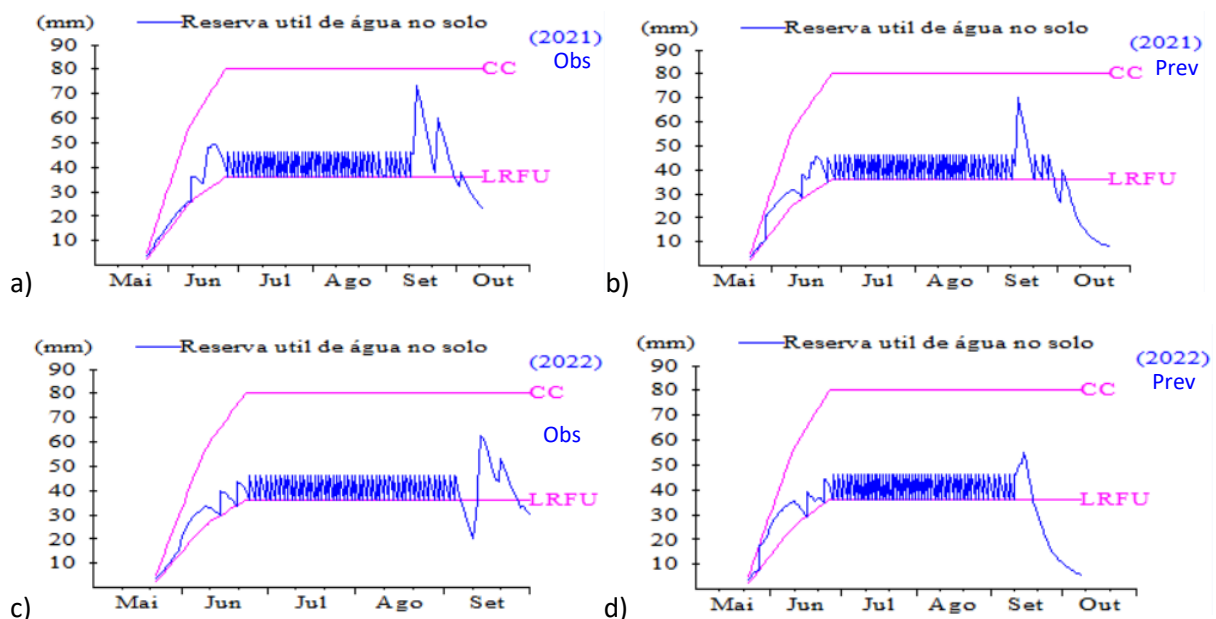


Figura 4.6. Gráficos do balanço hídrico para o Sorgo, a) e b) em 2021, c) e d) em 2022; a) e c) segundo os dados observados (Obs), b) e d) segundo os previstos (Prev). A rosa a capacidade de campo (CC, mm) e o limite da reserva facilmente utilizável (LRFU, mm) e a azul a reserva de água no solo a cada momento (mm).

A condução da rega com os dados Obs resulta num volume de água regado e numa ET_c estimada diferente da realizada com os dados Prev. Estas diferenças foram quantificadas subtraindo o valor calculado segundo as observações ao valor calculado segundo as previsões, tanto para o volume regado (ΔV) como para evapotranspiração cultural (ΔET_c). Esta comparação (Quadro 4.14.) revela que à exceção do milho em 2021, onde o volume regado e a ET_c são superiores quando utilizados os dados

observados em vez dos previstos (ΔV e ΔET_c negativos), as ΔV s são superiores às ΔET_c , especialmente no sorgo em 2022, onde representa mais do dobro. Os valores de $\Delta V / \Delta ET_c$ próximos de 1, no milho em 2022 e no sorgo em 2021, indicam os casos em que as ΔV se deveram mais às ΔET_c do que às diferenças entre a precipitação Obs e Prev (ΔP), por esta se tratar da fonte de água para além da rega no BH. Por sua vez, o valor elevado no sorgo em 2022 aponta para uma previsão da P pouco precisa durante o seu ciclo cultural, tendo sido prevista menos P do que a observada, como descrito para todo o período de dois anos (Quadro 4.4.), o que, associado a um baixo valor da ET_c segundo as Prev ($\Delta ET_c > 0$), leva a que seja aplicada uma dotação mais elevada. Um padrão semelhante foi observado para o caso do milho em 2021, onde, considerando os valores absolutos, houve maior ΔET_c que ΔV , tendo sido necessário regar mais que o previsto. A sobrestima da ET_o -Prev (Quadro 4.6.) levar a maiores volumes de rega foi também verificado por Lorite et al. (2015) na Andaluzia, aplicando previsões até 6 dias ao método FAO-PM.

Quadro 4.14. A relação entre a diferença nos volumes aplicados (ΔV) e a diferença de ET_c ac. (ΔET_c). Onde ΔV é o volume de rega previsto menos o observado; e o ΔET_c é a ET_c acumulada prevista menos a observada.

	Milho		Sorgo	
	2021	2022	2021	2022
ΔV	-130	120	80	40
ΔET_c	-170	114	70	17
$\Delta V / \Delta ET_c$	0.76	1.05	1.14	2.35

É importante notar que a análise da relação entre a ΔV e a ΔET_c informa indiretamente sobre a qualidade da previsão da P em relação à qualidade das restantes previsões (magnitude da ΔET_c). É, no entanto, necessário algum cuidado com as conclusões que se podem retirar, exemplo disso é o resultado obtido para o sorgo em 2022 aparentar ser o pior ($\Delta V / \Delta ET_c = 2.35$), quando na verdade a ΔET_c e a ΔV foram as mais baixas de todas, indicando uma melhor qualidade das previsões como um todo mas destacando a imprecisão da P prevista neste período. O mais baixo RMSE contido no Quadro 4.11. para esta cultura neste período vai de encontro com este resultado, indicando que as previsões atingiram uma condução da rega mensal mais próxima das observações nesta situação.

Além de as previsões tenderem a subestimar a P nos dois anos considerados (Quadro 4.4.), a ocorrência de P é ainda prevista apenas 63.5% das vezes que de facto ocorre (Quadro 4.3.), o que exacerba a sua subestima e a consequente rega em excesso na primavera e no verão, em ocasiões em que chove. Esta subestima é mais um fator contributivo para a sobrestima do volume de rega com as previsões, apoiado pelos valores de $\Delta V / \Delta ET_c$ obtidos (Quadro 4.14.).

A condução da rega adotando o calendário de rega definido de acordo com as simulações do BH realizadas usando os dados de previsão a 3 dias (Quadro 4.15.) levou a que a ET_c ac. fosse superior em todos os casos, menos no milho em 2021, onde a ET_c resultante da utilização das previsões foi mais de 100 mm inferior à resultante da utilização das observações. No caso do volume perdido por drenagem e percolação profunda, no milho em 2021 permaneceu nulo, quer usando os dados observados quer os dados de previsão, mas aumentou nos restantes casos, com destaque para os aumentos de 0 para 35.7 mm no milho em 2022, e de 0 para 24.3 mm no sorgo em 2021. Estas diferenças no volume perdido devem-se às previsões subestimarem a precipitação (Quadro 4.4.), levando a volumes de rega excessivos aquando da sua utilização. A utilização de previsões na cultura do milho em 2021 resultou numa Q. prod de 20%, enquanto nos restantes casos foi essencialmente nula. Esta quebra de produção deverá ocorrer pelo menos parcialmente pois as previsões resultam em stress hídrico a partir do final de julho (Figura 4.7.b)).

Quadro 4.15. A ET_c acumulada durante o período de rega (ET_c ac., mm), o volume perdido por drenagem e percolação profunda (V. perd., mm) e a quebra de produção devido ao esquema de rega usado (Q. prod., %). Para a condução segundo os dados observados (Obs) e o resultado da condução segundo as previsões tendo em conta as condições observadas (R. Prev).

	Milho				Sorgo			
	2021		2022		2021		2022	
	Obs	R. Prev	Obs	R. Prev	Obs	R. Prev	Obs	R. Prev
ET_c ac. (mm)	729	617.1	666	694.5	614	617.3	636	641
V. perd. (mm)	0	0	0	35.7	0	24.3	0	1.6
Q. prod (%)	0.2	20	5.4	0	0.5	0	0.9	0.2

Os resultados do balanço hídrico para as duas culturas são suportados pelas características anteriormente referidas dos dados de previsão a 3 dias (Quadro 4.4.), resultando numa tendência de sobrestima das NR quando os dados de previsão são usados (Figuras 4.7.d) e 4.8. b) e d)).

Os resultados da cultura do milho em 2021 destacam-se mais uma vez por este ser o único caso em que a utilização de previsões resulta em NR inferiores às observações: resultando na redução da ET_c ac. e do V. perd. e no aumento da Q. prod. Isto deve-se ao facto de neste período específico as variáveis previstas resultarem excecionalmente numa ET_c mais baixa que a calculada com as observações (Quadro 4.13.), contrariamente a todos os outros casos, o que leva a que seja regado menos quando seguindo as previsões.

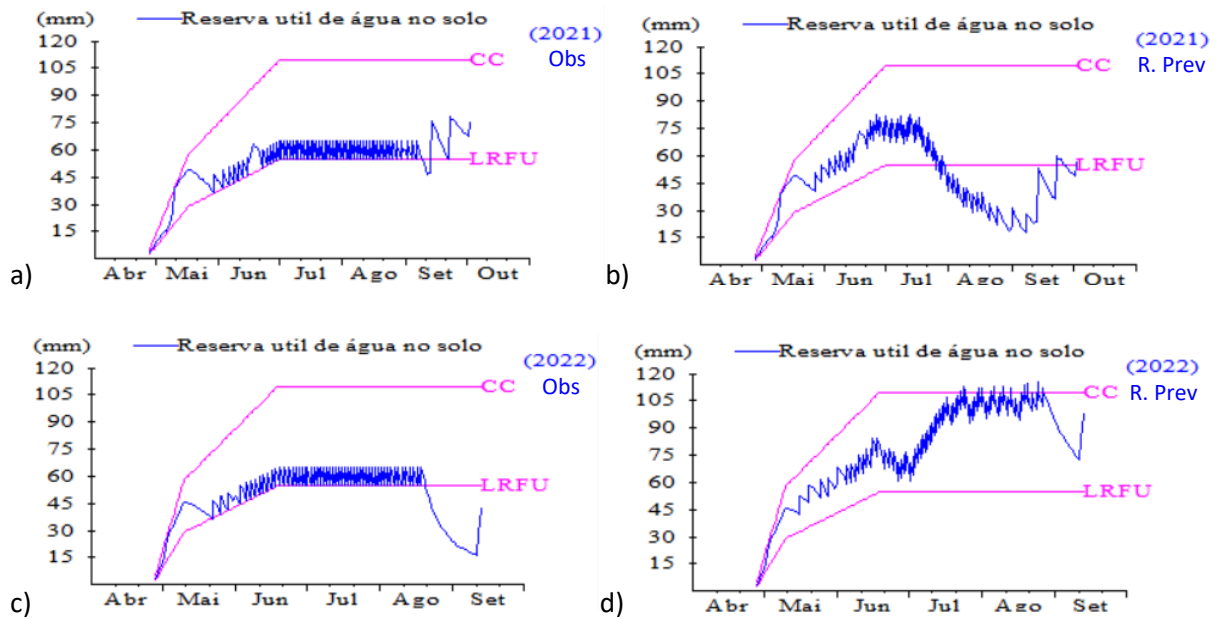


Figura 4.7. Gráficos do balanço hídrico para o milho. segundo as observações (Obs), a) e c), e segundo as previsões tendo em conta as condições observadas (R. Prev), b) e d); em 2021, a) e b), e em 2022, c) e d). A rosa a capacidade de campo (CC, mm) e o limite da reserva facilmente utilizável (LRFU, mm) e a azul a reserva de água no solo a cada momento (mm).

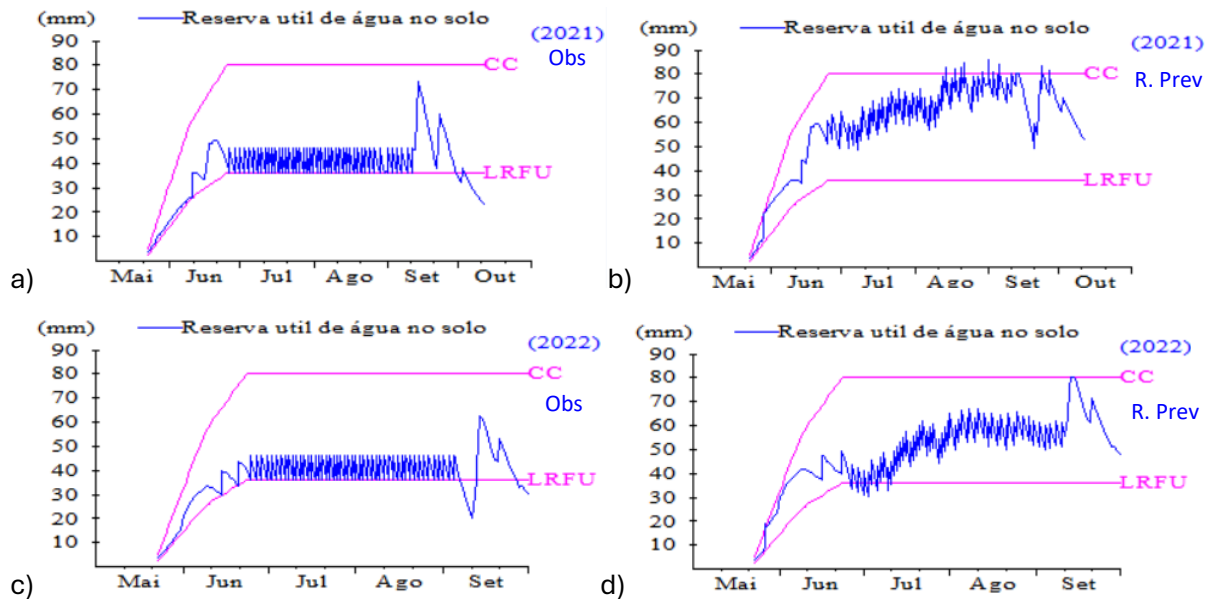


Figura 4.8. Gráficos do balanço hídrico para o sorgo. segundo as observações (Obs), a) e c), e segundo as previsões tendo em conta as condições observadas (R. Prev), b) e d); em 2021, a) e b), e em 2022, c) e d). A rosa a capacidade de campo (CC, mm) e o limite da reserva facilmente utilizável (LRFU, mm) e a azul a reserva de água no solo a cada momento (mm).

Como demonstrado nos gráficos do BH (Figuras 4.7. e 4.8.), o uso das previsões ao invés das observações tende a levar à aplicação de dotações de rega no final do período de maturação, o que

poderá provocar um teor de humidade demasiado elevado no grão aquando da colheita e prejudicar a qualidade da colheita e a rentabilidade do produtor.

A aplicação de maiores volumes de água acarretaria vários custos acrescidos à rega, sendo o principal a energia gasta, mas também os fertilizantes, no caso da aplicação de fertirrega, e a própria água.

O caso (cultura + ano) mais promissor dos quatro estudados foi o sorgo em 2022, no qual as previsões estimaram as regas mensais mais próximas das observações, e resultaram numa produção semelhante aumentando muito pouco o V. perd. As previsões resultaram nalgum benefício para este caso apesar de estimarem um ciclo 8 dias mais longo.

4.4.3. Limitações e perspectivas futuras

O método dos K_c utilizado é um método amplamente validado e robusto em condições climáticas estáveis, especialmente devido à sua simplicidade e ao suporte teórico consolidado (Allen et al., 1998). No entanto, quando consideramos cenários de alterações climáticas, a robustez deste método pode ser limitada por vários fatores: o método pressupõe valores fixos de K_c mas, com as alterações climáticas, podem haver mudanças significativas na radiação solar, temperatura e humidade relativa, que alteram as condições de referência para as quais os K_c foram inicialmente calibrados. Esses desvios podem resultar em sub- ou sobrestima da evapotranspiração real, pelo que é necessário monitorizar continuamente os novos padrões climáticos e atualizar os coeficientes em sua função. O curto período para o qual o estudo foi feito (dois anos) limita ainda a representatividade estatística, pelo que estudos baseados em séries longas, como sugerido por Moreira et al. (2012), são cruciais para compreender ciclos climáticos e tendências de longo prazo.

No sentido de aumentar a robustez do método dos K_c , este poderia ser combinado com modelos dinâmicos baseados em simulações climáticas: por exemplo, incluir modelos que utilizem aprendizado de máquina para prever K_c ajustados automaticamente às condições meteorológicas projetadas (Gu et al., 2020).

A aplicação prática das previsões meteorológicas na calendarização da rega implicará a validação e calibração do modelo ISAREG para as parcelas específicas a que se destina, nomeadamente ao nível do conteúdo da água no solo no momento da sementeira. Neste estudo comparativo, a consideração deste valor como à CC introduziu um erro equivalente em ambos os casos, mas para fins de aplicação prática leva à potencial introdução de um erro inicial que poderá culminar em decisões inadequadas de rega ao longo do ciclo.

Numa perspetiva de aplicação prática, a consideração única das previsões na calendarização da rega, não seria a decisão mais precisa ou lógica, considerando que os respetivos erros associados às

previsões teriam um efeito cumulativo ao longo do ciclo cultural, resultando nas diferenças de duração de cada fase. De modo a minimizar o impacto destes erros ao longo do ciclo, o ideal na prática seria atualizar de 3 em 3 dias os parâmetros culturais (GDD , $K_{c\ mid}$, $Z_{r\ max}$ e p), segundo os dados até aí observados (substituindo as previsões de há 3 dias com as observações diárias desses dias) e calendarizar a rega dos próximos 3 dias segundo a simulação do BH usando as previsões para esses dias. A simulação do BH segundo este método misto toma partido tanto da presença de uma estação meteorológica nas proximidades como da existência de previsões meteorológicas para esta área.

A aplicação deste método misto permitiu otimizar a rega em múltiplos estudos: Abd El Baki et al. (2018) conduziram a rega segundo previsões, atualizando as condições de acordo com as observações a cada 3 dias, o que resultou na redução da aplicação de água e no aumento da produção e rendimento económico de uma cultura de batata-doce no Japão; Glória et al. (2020) mostraram ser possível poupar até 34% do volume de água regada num jardim em Lisboa, ao cruzar previsões com observações num algoritmo de inteligência artificial; Yang et al. (2023) avaliaram o performance de previsões sazonais na estima das fases fenológicas de vinhas em Portugal, recorrendo a previsões mensais sincronizadas com a atualização das condições atuais com as observações, conseguindo prever com 1 a 4 meses de antecedência a floração e o início da maturação.

A utilização combinada de dados observados com dados de previsão deverá levar a melhores resultados, não só por utilizar previsões para o 1º e 2º dia seguinte, e ser de esperar que as previsões sejam tanto melhores quanto mais recentes forem, mas também por não acumular o erro das previsões, ao utilizar as observações como ponto de partida da simulação do BH dos próximos 3 dias. Deste modo, a tendência de regar em excesso verificada nos resultados deverá ser minimizada e a eficiência da rega aumentada. Já o impacto que teria na produção careceria do estudo específico da aplicação da metodologia. Apesar deste método envolver muito mais simulações, a natureza iterativa da metodologia torna o processo altamente automatizável, o que facilita a aplicação prática e contribui para a exequibilidade desta metodologia.

Por fim, para que os agricultores possam tomar partido das previsões é necessária a existência de um organismo ou associação que crie e disponibilize um sistema de informação acessível que permita que a informação chegue aos produtores numa forma facilmente utilizável.

5. Referências bibliográficas

- Abd El Baki, H. M., Fujimaki, H., Tokumoto, I., & Saito, T. (2018). A new scheme to optimize irrigation depth using a numerical model of crop response to irrigation and quantitative weather forecasts. *Computers and electronics in agriculture*, *150*, 387-393.
- Abd El Baki, H. M., Fujimaki, H., Tokumoto, I., & Saito, T. (2018). Optimizing Irrigation Depth Using a Plant Growth Model and Weather Forecast. *Journal of Agricultural Science*, *10*(7).
- Abd El Baki, H. M., Raoof, M., & Fujimaki, H. (2020). Determining irrigation depths for soybean using a simulation model of water flow and plant growth and weather forecasts. *Agronomy*, *10*(3), 369.
- Abreu, J. (2018). *Agrometeorologia - Aplicação da Meteorologia para Maximizar a Produção Agrícola*. Agrobook.
- Allen R.G., Pereira L.S., Howell T.A., Jensen M.E. (2011). Evapotranspiration information reporting: I. Factors governing measurement accuracy. *Agric. Water Manage* *98*(6), 899-920. doi: 10.1016/j.agwat.2010.12.015
- Allen, R. G., Pereira, L. S., Raes, D., & Smith, M. (1998). FAO Irrigation and Drainage Paper No. 56. Crop Evapotranspiration (guidelines for computing crop water requirements). *Food and Agriculture Organisation of the United Nations, Rome*, 300
- Allen, R.G., 2008. Quality assessment of weather data and micrometeorological flux—impacts on evapotranspiration calculation. *J. Agric. Meteorol.* *64* (4), 191–204.
- An-Vo, D. A., Radanielson, A. M., Mushtaq, S., Reardon-Smith, K., & Hewitt, C. (2021). A framework for assessing the value of seasonal climate forecasting in key agricultural decisions. *Climate Services*, *22*, 100234
- Aparício, P. P. (2022). *Distribuição espacial das necessidades de rega das culturas no Perímetro de Rega do Luçefecit com recurso a imagens de satélite com elevada resolução espaço-temporal*. Tese de Mestrado em Engenharia Agronómica. Instituto Superior de Agronomia – Universidade de Lisboa.
- Apipattanavis, S., Bert, F., Podestá, G., & Rajagopalan, B. (2010). Linking weather generators and crop models for assessment of climate forecast outcomes. *Agricultural and forest meteorology*, *150*(2), 166-174.
- Armstrong, R. A. (2014). When to use the Bonferroni correction. *Ophthalmic and Physiological Optics*, *34*(5), 502-508.

- Asuero, A. G., Sayago, A., & González, A. G. (2006). The correlation coefficient: An overview. *Critical reviews in analytical chemistry*, 36(1), 41-59.
- Bartell, C., Bayabil, H. K., Schaffer, B., Tilahun, F., & Getachew, F. (2021). Measuring Leaf Water Potential: AE563/AE563, 10/2021. *EDIS*, 2021(5).
- Beck, H. E., Zimmermann, N. E., McVicar, T. R., Vergopolan, N., Berg, A., & Wood, E. F. (2018). Present and future Köppen-Geiger climate classification maps at 1-km resolution. *Scientific data*, 5(1), 1-12.
- Bittelli, M. (2011). Measuring soil water content: A review. *HortTechnology*, 21(3), 293-300.
- Bouarfa, S., & Zairi, A. (2022). *D2.5 Med-iHub Web Platform Meteorological Service*. Working Paper.
- Brands, S., Taboada, J. J., Cofiño, A. S., Sauter, T., & Schneider, C. (2011). Statistical downscaling of daily temperatures in the NW Iberian Peninsula from global climate models: validation and future scenarios. *Climate Research*, 48(2-3), 163-176.
- Branquinho, S., Rolim, J. and Teixeira, J.L., 2021. Climate change adaptation measures in the irrigation of a super-intensive olive orchard in the south of Portugal. *Agronomy*, 11(8), p.1658.
- Cai, J., Liu, Y., Xu, D., Paredes, P., Pereira, L.S., 2009. Simulation of the soil water balance of wheat using daily weather forecast messages to estimate the reference evapotranspiration. *Hydrol. Earth Syst. Sci.*, 13, 1045-1059, DOI: 10.1016/j.agrformet.2007.04.012. IF – 2.462 CI – 28c.
- Calera, A., Campos, I., Osann, A., D’Urso, G., & Menenti, M. (2017). Remote sensing for crop water management: From ET modelling to services for the end users. *Sensors*, 17(5), 1104.
- Cammalleri, C., Rallo, G., Agnese, C., Ciruolo, G., Minacapilli, M., & Provenzano, G. (2013). Combined use of eddy covariance and sap flow techniques for partition of ET fluxes and water stress assessment in an irrigated olive orchard. *Agricultural Water Management*, 120, 89-97.
- Cao, J., Tan, J., Cui, Y., & Luo, Y. (2019). Irrigation scheduling of paddy rice using short-term weather forecast data. *Agricultural water management*, 213, 714-723.
- Capa-Morocho, M., Ines, A. V., Baethgen, W. E., Rodríguez-Fonseca, B., Han, E., & Ruiz-Ramos, M. (2016). Crop yield outlooks in the Iberian Peninsula: Connecting seasonal climate forecasts with crop simulation models. *Agricultural systems*, 149, 75-87.
- Cardoso, J. V. J. de C. (1965). Os solos de Portugal: sua classificação caracterização e génese. Secretaria de estado da agricultura. Direcção-Geral dos serviços agrícolas. Lisboa.

Carvalho, D., Rocha, A., Gómez-Gesteira, M., & Santos, C. S. (2014). WRF wind simulation and wind energy production estimates forced by different reanalyses: Comparison with observed data for Portugal. *Applied Energy*, 117, 116-126.

Ceglar, A., Toreti, A., 2021. Seasonal climate forecast can inform the European agricultural sector well in advance of harvesting. *Climate and Atmospheric Sci.*, 4(1), 1-8.

Chaterlán Y., León M., Duarte C., López T., Paredes P., and Pereira L.S., 2011. Determination of crop coefficients for horticultural crops in Cuba through field experiments and water balance simulation. In: S. Ortega-Farias and G. Selles (Eds) *Acta Horticulturae* 889, 475-482

Choi, H. S., Schneider, U. A., Rasche, L., Cui, J., Schmid, E., Held, H., 2015. Potential effects of perfect seasonal climate forecasting on agricultural markets, welfare and land use: A case study of Spain. *Agric. Sys.*, 133, 177-189.

Claro, A.M., Fonseca, A., Fraga, H. and Santos, J.A., 2023. Susceptibility of Iberia to Extreme Precipitation and Aridity: A New High-Resolution Analysis over an Extended Historical Period. *Water*, 15(21), p.3840.

CM-Alandroal. (2022). Uniões e Juntas de Freguesia. Acedido a 9 de março de 2023 em: <https://www.cm-alandroal.pt/municipe/freguesias-junta-e-assembleia/>

Coelho CAS, Costa SMS, 2010. Challenges for integrating seasonal climate forecasts in user applications. *Current Opinion in Environmental Sustainability*, 2:317–325, doi 10.1016/j.cosust.2010.09.002

Coronel, E. G., Alesso, C. A., Bollero, G. A., Armstrong, K. L., & Martin, N. F. (2020). Field-specific yield response to variable seeding depth of corn in the Midwest. *Agrosystems, Geosciences & Environment*, 3(1), e20034.

Dari, J., Brocca, L., Quintana-Seguí, P., Escorihuela, M. J., Stefan, V., & Morbidelli, R. (2020). Exploiting high-resolution remote sensing soil moisture to estimate irrigation water amounts over a Mediterranean region. *Remote Sensing*, 12(16), 2593.

Dasberg, S., & Dalton, F. N. (1985). Time domain reflectometry field measurements of soil water content and electrical conductivity. *Soil Science Society of America Journal*, 49(2), 293-297.

De la Rosa, J. M., Conesa, M. R., Domingo, R., Torres, R., & Pérez-Pastor, A. (2013). Feasibility of using trunk diameter fluctuation and stem water potential reference lines for irrigation scheduling of early nectarine trees. *Agricultural Water Management*, 126, 133-141.

DGADR. (2023). *Aproveitamento Hidroagrícola do Lucefecit*. Acedido a 9 de março de 2023 em: https://sir.dgadr.gov.pt/images/conteudos/regadios/outra_inf_relevante/reg_Exploracao2011/Alentejo/Lucefecit.pdf

Dix, M. J., & Aubrey, D. P. (2021). Recalibrating best practices, challenges, and limitations of estimating tree transpiration via sap flow. *Current Forestry Reports*, 7, 31-37.

Dobriyal, P., Qureshi, A., Badola, R., & Hussain, S. A. (2012). A review of the methods available for estimating soil moisture and its implications for water resource management. *Journal of Hydrology*, 458, 110-117.

Doorenbos, J., & Pruitt, W. O. (1977). Guidelines for predicting crop water requirements. FAO Irrig. Drain. Paper 24, 2nd ver. Ed. FAO, Rome 156pp..

Eekhout, J.P. and de Vente, J., 2022. Global impact of climate change on soil erosion and potential for adaptation through soil conservation. *Earth-Science Reviews*, 226, p.103921.

Elshaikh, A. E., Jiao, X., & Yang, S. H. (2018). Performance evaluation of irrigation projects: Theories, methods, and techniques. *Agricultural water management*, 203, 87-96.

Fader, M., Shi, S., von Bloh, W., Bondeau, A., & Cramer, W. (2016). Mediterranean irrigation under climate change: more efficient irrigation needed to compensate for increases in irrigation water requirements. *Hydrology and Earth System Sciences*, 20(2), 953-973.

Falloon, P., & Betts, R. (2010). Climate impacts on European agriculture and water management in the context of adaptation and mitigation—the importance of an integrated approach. *Science of the total environment*, 408(23), 5667-5687.

FAO/UNESCO Soil Map of the World (2024). Acedido a 5 de setembro de 2024 em: <https://www.fao.org/soils-portal/data-hub/soil-maps-and-databases/faounesco-soil-map-of-the-world/en/>

Fereres, E., & Goldhamer, D. (2003). Suitability of stem diameter variations and water potential as indicators for irrigation scheduling of almond trees. *The Journal of Horticultural Science and Biotechnology*, 78(2), 139-144.

Fereres, E., Soriano, M. A. (2007). Deficit irrigation for reducing agricultural water use. *Journal of experimental botany*, 58(2), 147-159.

- Fernández, J. E., & Cuevas, M. V. (2010). Irrigation scheduling from stem diameter variations: a review. *Agricultural and Forest Meteorology*, 150(2), 135-151.
- Fernández, J. E., Palomo, M. J., Diaz-Espejo, A., Clothier, B. E., Green, S. R., Girón, I. F., & Moreno, F. (2001). Heat-pulse measurements of sap flow in olives for automating irrigation: tests, root flow and diagnostics of water stress. *Agricultural Water Management*, 51(2), 99-123.
- Ferreira, A., Rolim, J., Paredes, P., & Cameira, M. D. R. (2022). Assessing Spatio-Temporal Dynamics of Deep Percolation Using Crop Evapotranspiration Derived from Earth Observations through Google Earth Engine. *Water*, 14(15), 2324.
- Ferreira, I., Conceição, N., Pacheco, C. A., & Hausler, M. (2012). Análise de indicadores de desconforto hídrico durante ciclos de stress num olival intensivo no Alentejo. *Simpósio Nacional de Olivicultura*, 6, *Mirandela*, 2012, 21, 217-226.
- Ferreira, M. I., Silvestre, J., Conceição, N., & Malheiro, A. C. (2012). Crop and stress coefficients in rainfed and deficit irrigation vineyards using sap flow techniques. *Irrigation Science*, 30, 433-447.
- Fonseca, A., Andrade, C., & Santos, J. A. (2022). Agricultural Water Security under Climate Change in the Iberian Peninsula. *Water*, 14, 1–18.
- Fonseca, A., Cruz, J., Fraga, H., Andrade, C., Valente, J., Alves, F., Neto, A.C., Flores, R. and Santos, J.A., 2024. Vineyard Microclimatic Zoning as a Tool to Promote Sustainable Viticulture under Climate Change. *Sustainability*, 16(8), p.3477.
- Fraga, H. and Santos, J.A., 2021. Assessment of climate change impacts on chilling and forcing for the main fresh fruit regions in Portugal. *Frontiers in Plant Science*, 12, p.689121.
- Fragoso, R., & Noéme, C. (2014). Impacte económico das alterações climáticas no regadio e definição de medidas de adaptação. Em: Teixeira, J. L., Rolim, J. (Eds). Impacte das alterações climáticas nos sistemas de regadio no Alentejo. ISAPress, pp. 79-104
- Freitas, T.R., Santos, J.A., Silva, A.P., Fonseca, A. and Fraga, H., 2023. Evaluation of historical and future thermal conditions for almond trees in north-eastern Portugal. *Climatic Change*, 176(7), p.89.
- Gerhards, H., Wollschläger, U., Yu, Q., Schiwiek, P., Pan, X., & Roth, K. (2008). Continuous and simultaneous measurement of reflector depth and average soil-water content with multichannel ground-penetrating radar. *Geophysics*, 73(4), J15-J23.

Giménez, L., Petillo, M. G., Paredes, P., & Pereira, L. S. (2016). Predicting maize transpiration, water use and productivity for developing improved supplemental irrigation schedules in western Uruguay to cope with climate variability. *Water*, 8(7), 309.

Ginestar, C., Eastham, J., Gray, S., & Iland, P. (1998). Use of sap-flow sensors to schedule vineyard irrigation. I. Effects of post-veraison water deficits on water relations, vine growth, and yield of Shiraz grapevines. *American Journal of Enology and Viticulture*, 49(4), 413-420.

Girona, J., Mata, M., Del Campo, J., Arbonés, A., Bartra, E., & Marsal, J. (2006). The use of midday leaf water potential for scheduling deficit irrigation in vineyards. *Irrigation Science*, 24, 115-127.

Gloria, A., Dionisio, C., Simões, G., Cardoso, J., & Sebastião, P. (2020). Water management for sustainable irrigation systems using internet-of-things. *Sensors*, 20(5), 1402.

Gu, Z., Qi, Z., Burghate, R., Yuan, S., Jiao, X., & Xu, J. (2020). Irrigation scheduling approaches and applications: A review. *Journal of Irrigation and Drainage Engineering*, 146(6), 04020007.

Gunda, T., Bazuin, J. T., Nay, J., & Yeung, K. L. (2017). Impact of seasonal forecast use on agricultural income in a system with varying crop costs and returns: an empirically-grounded simulation. *Environmental Research Letters*, 12(3), 034001.

Guo, D., Wang, Q. J., Ryu, D., Yang, Q., Moller, P., & Western, A. W. (2022). An analysis framework to evaluate irrigation decisions using short-term ensemble weather forecasts. *Irrigation Science*, 1-17.

Gupta, H. V., & Kling, H. (2011). On typical range, sensitivity, and normalization of Mean Squared Error and Nash-Sutcliffe Efficiency type metrics. *Water Resources Research*, 47(10).

INE (2024). *Estatísticas agrícolas – 2023*. Acedido a 5 de setembro de 2024 em: https://www.ine.pt/xportal/xmain?xpid=INE&xpgid=ine_destaquas&DESTAQUESdest_boui=645504293&DESTAQUESmodo=2

INFOSOLO (2024). Acedido a 5 de setembro de 2024 em: <https://portalgeo.iniav.pt/portal/apps/webappviewer/index.html?id=17574ca60800415dace9a6369ac53208>

IPMA. (2022). Normal Climatológica – Évora / Cidade. Acedido a 17 de julho de 2024 em: <https://www.uc.pt/fcdef/documentosbiblioteca/Bibliotecadigital/Normas>

IPMA. (2024). *Normais Climatológicas*. Acedido a 5 de setembro de 2024 em: <https://www.ipma.pt/pt/oclima/normais.clima/>

- Johannsen, F., Ermida, S., Martins, J. P., Trigo, I. F., Nogueira, M., & Dutra, E. (2019). Cold bias of ERA5 summertime daily maximum land surface temperature over Iberian Peninsula. *Remote Sensing*, 11(21), 2570.
- Khaledian, M. R., Mailhol, J. C., Ruelle, P., & Rosique, P. (2009). Adapting PILOTE model for water and yield management under direct seeding system: The case of corn and durum wheat in a Mediterranean context. *Agricultural water management*, 96(5), 757-770.
- Kim, K. H., Shin, Y., Lee, S., & Jeong, D. (2019). Use of seasonal climate forecasts in agricultural decision-making for crop disease management. *Adaptation to climate change in agriculture: Research and practices*, 173-191.
- Lalić, B., Sremac, A. F., Dekić, L., Eitzinger, J., & Perišić, D. (2018). Seasonal forecasting of green water components and crop yields of winter wheat in Serbia and Austria. *The Journal of Agricultural Science*, 156(5), 645-657.
- Linker, R., & Sylaios, G. (2016). Efficient model-based sub-optimal irrigation scheduling using imperfect weather forecasts. *Computers and electronics in agriculture*, 130, 118-127.
- Lionello, P., Malanotte-Rizzoli, P., Boscolo, R., Alpert, P., Artale, V., Li, L., ... & Xoplaki, E. (2006). The Mediterranean climate: an overview of the main characteristics and issues. *Developments in earth and environmental sciences*, 4, 1-26.
- Lorite, I. J., Ramírez-Cuesta, J. M., Cruz-Blanco, M., & Santos, C. (2015). Using weather forecast data for irrigation scheduling under semi-arid conditions. *Irrigation science*, 33, 411-427.
- Mailhol, J. C., Olufayo, A. A., & Ruelle, P. (1997). Sorghum and sunflower evapotranspiration and yield from simulated leaf area index. *Agricultural water management*, 35(1-2), 167-182.
- Martins, D. S., Paredes, P., Raziei, T., Pires, C., Cadima, J., & Pereira, L. S. (2017). Assessing reference evapotranspiration estimation from reanalysis weather products. An application to the Iberian Peninsula. *International Journal of Climatology*, 37(5), 2378-2397.
- Meteotécnico. (2024). Acedido a 10 de setembro de 2024 em: <https://meteo.tecnico.ulisboa.pt/forecast>.
- Meyners, M. (2012). Equivalence tests—A review. *Food quality and preference*, 26(2), 231-245.
- Morari, F., Zanella, V., Gobbo, S., Bindi, M., Sartori, L., Pasqui, M., ... & Ferrise, R. (2021). Coupling proximal sensing, seasonal forecasts and crop modelling to optimize nitrogen variable rate application in durum wheat. *Precision Agriculture*, 22, 75-98

- Moreira E. E., Mexia J. T., Pereira L. S., 2012. Are drought occurrence and severity aggravating? A study on SPI drought class transitions using loglinear models and ANOVA-like inference. *Hydrol. Earth Syst. Sci.* 16, 3011–3028, doi:10.5194/hess-16-3011-2012
- Moser, B. K., & Stevens, G. R. (1992). Homogeneity of variance in the two-sample means test. *The American Statistician*, 46(1), 19-21.
- Ojo, E. R., Bullock, P. R., L'Heureux, J., Powers, J., McNairn, H., & Pacheco, A. (2015). Calibration and evaluation of a frequency domain reflectometry sensor for real-time soil moisture monitoring. *Vadose Zone Journal*, 14(3), 1-12.
- Oliveira, I. (2011). *Técnicas de Regadio*. 2ª Edição, Vols. 1–2.
- O'Shaughnessy, S. A., Evett, S. R., Colaizzi, P. D., & Howell, T. A. (2012). Grain sorghum response to irrigation scheduling with the time-temperature threshold method and deficit irrigation levels. *Transactions of the ASABE*, 55(2), 451-461.
- Paredes, P., de Melo-Abreu, J. P., Alves, I., & Pereira, L. S. (2014). Assessing the performance of the FAO AquaCrop model to estimate maize yields and water use under full and deficit irrigation with focus on model parameterization. *Agricultural Water Management*, 144, 81-97.
- Paredes, P., Martins, D. S., Pereira, L. S., Cadima, J., & Pires, C. (2018). Accuracy of daily estimation of grass reference evapotranspiration using ERA-Interim reanalysis products with assessment of alternative bias correction schemes. *Agricultural Water Management*, 210, 340-353.
- Paredes, P., Ribeiro, A. F., Pires, C. A., & Pereira, L. S. (2015). Usabilidade de previsões sazonais de ensemble da temperatura e precipitação na modelação da rega e da produção. Aplicação a cevada e milho. *Predictabilidade Sazonal de Secas. Avaliação ao Nível Regional e Agrícola*, 307-332.
- Paredes, P., Rodrigues, G.C., Cameira, MR, Torres M.O., Pereira, LS, 2017. Assessing yield, water productivity and farm economic returns of malt barley as influenced by the sowing dates and supplemental irrigation. *Agric Water Manage* 179, 132-143.
- Paredes, P., Trigo, I., de Bruin, H., Simões, N., & Pereira, L. S. (2021). Daily grass reference evapotranspiration with Meteosat Second Generation shortwave radiation and reference ET products. *Agricultural Water Management*, 248, 106543.
- Páscoa, P., Russo, A., Gouveia, C. M., Soares, P. M., Cardoso, R. M., Careto, J. A., & Ribeiro, A. F. (2021). A high-resolution view of the recent drought trends over the Iberian Peninsula. *Weather and Climate Extremes*, 32, 100320.

Pereira, L. S. (1999). Higher performance through combined improvements in irrigation methods and scheduling: a discussion. *Agricultural Water Management*, 40(2-3), 153-169.

Pereira, L. S. (2004). *Necessidades de Água e Métodos de Rega*. Europa-América. Lisboa, 313 p.

Pereira, L. S., Cordery, I., & Iacovides, I. (2012). Improved indicators of water use performance and productivity for sustainable water conservation and saving. *Agricultural water management*, 108, 39-51.

Pereira, L. S., Paredes, P., Hunsaker, D. J., López-Urrea, R., & Shad, Z. M. (2021). Standard single and basal crop coefficients for field crops. Updates and advances to the FAO56 crop water requirements method. *Agricultural Water Management*, 243, 106466.

Pereira, L.S., Paredes, P., Jovanovic, N., 2020. Soil water balance models for determining crop water and irrigation requirements and irrigation scheduling focusing on the FAO56 method and the dual Kc approach. *Agric Water Manage.* 241, 106357. <https://doi.org/10.1016/j.agwat.2020.106357>

Perondi, D., Fraisse, C. W., Staub, C. G., Cerbaro, V. A., Barreto, D. D., Pequeno, D. N., ... & Pavan, W. (2019). Crop season planning tool: Adjusting sowing decisions to reduce the risk of extreme weather events. *Computers and Electronics in Agriculture*, 156, 62-70.

Peters, K., Breitsameter, L. and Gerowitt, B., 2014. Impact of climate change on weeds in agriculture: a review. *Agronomy for sustainable development*, 34, pp.707-721.

Pôças, I., Calera, A., Campos, I., & Cunha, M. (2020). Remote sensing for estimating and mapping single and basal crop coefficients: A review on spectral vegetation indices approaches. *Agricultural Water Management*, 233, 106081.

Popova Z., Ivanova M., Martins D., Pereira L.S., Doneva K., Alexandrov V., Kercheva M., 2014. Vulnerability of Bulgarian agriculture to drought and climate variability with focus on rainfed maize systems. *Natural Hazards*. DOI: 10.1007/s11069-014-1215-3

Popova, Z., Eneva, S., & Pereira, L. S. (2006). Model validation, crop coefficients and yield response factors for maize irrigation scheduling based on long-term experiments. *Biosystems engineering*, 95(1), 139-149.

Raes, D., Steduto, P., Hsiao, T. C., & Fereres, E. (2012). Crop water productivity, calculation procedure and calibration guidance. AquaCrop version 4.0. reference manual.

Rallo G, González-Altozano P, Manzano-Juárez J, Provenzano G (2017) Using field measurements and FAO-56 model to assess the eco-physiological response of citrus orchards under regulated deficit irrigation. *Agric Water Manage* 180:136–147

Ramos, T. B., Horta, A., Gonçalves, M. C., Pires, F. P., Duffy, D., & Martins, J. C. (2017). The INFOSOLO database as a first step towards the development of a soil information system in Portugal. *Catena*, 158, 390-412.

Rana, G., & Katerji, N. (2000). Measurement and estimation of actual evapotranspiration in the field under Mediterranean climate: a review. *European Journal of agronomy*, 13(2-3), 125-153.

Rawls, W. J., Brakensiek, C. L., & Saxton, K. E. (1982). Estimation of soil water properties. In *Transactions - American Society of Agricultural Engineers* (Vol. 25, Issue 5). <https://doi.org/10.13031/2013.33720>

Raza, A., Razzaq, A., Mehmood, S. S., Zou, X., Zhang, X., Lv, Y., & Xu, J. (2019). *Impact of climate change on crops adaptation and strategies to tackle its outcome: A review*. *Plants*, 8(2), 1–29. <https://doi.org/10.3390/plants8020034>

Rocha, J., Carvalho-Santos, C., Diogo, P., Beça, P., Keizer, J.J. and Nunes, J.P., 2020. Impacts of climate change on reservoir water availability, quality and irrigation needs in a water scarce Mediterranean region (southern Portugal). *Science of the Total Environment*, 736, p.139477.

Rodrigues, G. C. (2022). *Sistemas agrícolas de regadio no aproveitamento hidroagrícola do luçefecit eficiência do uso da água e da energia*. Tese de Mestrado em Engenharia Agronómica. Instituto Superior de Agronomia – Universidade de Lisboa.

Rodrigues, P. (2011). *Influencia do regime hídrico e da rega no comportamento da casta Touriga nacional na região do Dão*. Tese de Doutoramento em Engenharia dos Biosistemas. Instituto Superior de Agronomia – Universidade de Lisboa.

Rodrigues, P.N., T. Machado, L.S. Pereira, J.L. Teixeira, H. El Amami, A. Zairi, 2003. Feasibility of deficit irrigation with center-pivot to cope with limited water supplies in Alentejo, Portugal. In: G. Rossi, A. Cancelliere, L. S. Pereira, T. Oweis, M. Shatanawi, A. Zairi (Eds.) *Tools for Drought Mitigation in Mediterranean Regions*. Kluwer, Dordrecht, pp. 203-222.

Rolim, J., Teixeira, J. L., Catalão, J., & Shahidian, S., 2017. The impacts of climate change on irrigated agriculture in Southern Portugal. *Irrig. Drain.*, 66(1), 3-18.

Rolim, J., Teixeira, J. L., Mendes, P., Catita, C., & Catalão, J. (2014). Cenários de Alteração Climática. In *Impacte Das Alterações Climáticas Nos Sistemas De Regadio Do Alentejo* (pp. 5–30).

Rolim, João., & Teixeira, José. (2008). IrrigRotation, a time continuous soil water balance model. *WSEAS Transactions on Environment and Development*, 4(7), 577-587.

Romero P, Navarro JM, Ordaz PB (2022) Towards a sustainable viticulture: the combination of deficit irrigation strategies and agroecological practices in Mediterranean vineyards. A review and update. *Agric Water Manag* 259:107216

Rosa, R. D., Paredes, P., Rodrigues, G. C., Alves, I., Fernando, R. M., Pereira, L. S., & Allen, R. G. (2012). Implementing the dual crop coefficient approach in interactive software. 1. Background and computational strategy. *Agricultural Water Management*, 103, 8-24.

Rosa, R. D., Ramos, T. B., & Pereira, L. S. (2016). The dual Kc approach to assess maize and sweet sorghum transpiration and soil evaporation under saline conditions: Application of the SIMDualKc model. *Agricultural Water Management*, 177, 77-94.

Roy, A., Narvekar, P., Murtugudde, R., Shinde, V., & Ghosh, S. (2021). Short and Medium Range Irrigation Scheduling Using Stochastic Simulation-Optimization Framework With Farm-Scale Ecohydrological Model and Weather Forecasts. *Water Resources Research*, 57(5), e2020WR029004.

Sangha, L., Shortridge, J., & Frame, W. (2023). The impact of nitrogen treatment and short-term weather forecast data in irrigation scheduling of corn and cotton on water and nutrient use efficiency in humid climates. *Agricultural Water Management*, 283, 108314.

Skendžić, S., Zovko, M., Živković, I.P., Lešić, V. and Lemić, D., 2021. The impact of climate change on agricultural insect pests. *Insects*, 12(5), p.440.

SNIRH. (2023). *Albufeira de Lucefécit (22M/01A)*. Acedido a 9 de março de 2023 em: https://snirh.apambiente.pt/snirh/dadosbase/site/simplex.php?OBJINFO=DADOS&FILTRA_BACIA=23&FILTRA_COVER=920123705&FILTRA_SITE=1627758752

Soares, P. M., Cardoso, R. M., Miranda, P. M., de Medeiros, J., Belo-Pereira, M., & Espirito-Santo, F. (2012). WRF high resolution dynamical downscaling of ERA-Interim for Portugal. *Climate dynamics*, 39, 2497-2522.

Spinoni, J., Vogt, J., & Barbosa, P. (2015). European degree-day climatologies and trends for the period 1951-2011. *International Journal of Climatology*, 35(1).

Stenitzer, E. (1993). Monitoring soil moisture regimes of field crops with gypsum blocks. *Theoretical and applied climatology*, 48, 159-165.

Surendran, U., Sushanth, C. M., Mammen, G., & Joseph, E. J. (2015). Modelling the crop water requirement using FAO-CROPWAT and assessment of water resources for sustainable water resource management: A case study in Palakkad district of humid tropical Kerala, India. *Aquatic Procedia*, 4, 1211-1219.

Teixeira, J. L., & Pereira, L. S. (1992). ISAREG, an irrigation scheduling model. *ICID bulletin*, 41(2), 29-48.

Tilling, A. K., O'Leary, G. J., Ferwerda, J. G., Jones, S. D., Fitzgerald, G. J., Rodriguez, D., & Belford, R. (2007). Remote sensing of nitrogen and water stress in wheat. *Field Crops Research*, 104(1-3), 77-85.

UN-Water. (2020). *The United Nations world water development report 2020: water and climate change*. Acedido a 6 de setembro de 2024 em: <https://unesdoc.unesco.org/ark:/48223/pf0000372985.locale=en>

van Etten, J., de Sousa, K., Aguilar, A., Barrios, M., Coto, A., Dell'Acqua, M., ... & Steinke, J. (2019). Crop variety management for climate adaptation supported by citizen science. *Proceedings of the National Academy of Sciences*, 116(10), 4194-4199.

Varanasi, A., Prasad, P.V. and Jugulam, M., 2016. Impact of climate change factors on weeds and herbicide efficacy. *Advances in agronomy*, 135, pp.107-146.

Vélez-Sánchez, J. E., Balaguera-López, H. E., & Alvarez-Herrera, J. G. (2021). Effect of regulated deficit irrigation (RDI) on the production and quality of pear Triunfo de Viena variety under tropical conditions. *Scientia Horticulturae*, 278, 109880.

Vicente-Serrano, S. M., Peña-Angulo, D., Beguería, S., Domínguez-Castro, F., Tomás-Burguera, M., Noguera, I., ... & El Kenawy, A. (2022). Global drought trends and future projections. *Philosophical Transactions of the Royal Society A*, 380(2238), 20210285.

Westfall, P. H. (2014). Kurtosis as peakedness, 1905–2014. RIP. *The American Statistician*, 68(3), 191-195.

Williams, L. E., & Araujo, F. J. (2002). Correlations among predawn leaf, midday leaf, and midday stem water potential and their correlations with other measures of soil and plant water status in *Vitis vinifera*. *Journal of the American Society for Horticultural Science*, 127(3), 448-454

WMO. (2023). Database of WIS Centres. Acedido a 1 de junho de 2023 em: <https://community.wmo.int/en/activity-areas/wis/database-of-wis-centres>.

Wu Y., Liu T., Paredes P., Duan L., Pereira L.S., 2015. Water use by a groundwater dependent maize in a semi-arid region of Inner Mongolia: evapotranspiration partitioning and capillary rise. *Agric. Water Manage.* 152, 222-232. DOI: 10.1016/j.agwat.2015.01.016.

Yang, C., Ceglar, A., Menz, C., Martins, J., Fraga, H., & Santos, J. A. (2023). Performance of seasonal forecasts for the flowering and veraison of two major Portuguese grapevine varieties. *Agricultural and Forest Meteorology*, 331, 109342.

Yang, C., Fraga, H., Ieperen, W. Van, & Santos, J. A. (2017). Assessment of irrigated maize yield response to climate change scenarios in Portugal. *Agricultural Water Management*, 184, 178–190. <https://doi.org/10.1016/j.agwat.2017.02.004>

Yang, C., Fraga, H., van Ieperen, W., & Santos, J. A. (2020). Assessing the impacts of recent-past climatic constraints on potential wheat yield and adaptation options under Mediterranean climate in southern Portugal. *Agricultural Systems*, 182, 102844. <https://doi.org/10.1016/j.agsy.2020.102844>

Yang, Y., Cui, Y., Luo, Y., Lyu, X., Traore, S., Khan, S., & Wang, W. (2016). Short-term forecasting of daily reference evapotranspiration using the Penman-Monteith model and public weather forecasts. *Agricultural water management*, 177, 329-339.

Zairi, A., El Amami, H., Slatni, A., Pereira, L.S., Rodrigues, P. and Teixeira, J.L. 2000. Irrigation scheduling strategies for horticultural field crops under limited water availability. *Acta Hort.* (ISHS) 537:503-510

Zairi, A., H. El Amami, A. Slatni, L.S. Pereira, P.N. Rodrigues, T. Machado, 2003. Coping with drought: deficit irrigation strategies for cereals and field horticultural crops in Central Tunisia. In: G. Rossi, A. Cancelliere, L. S. Pereira, T. Oweis, M. Shatanawi, A. Zairi (Eds.) *Tools for Drought Mitigation in Mediterranean Regions*. Kluwer, Dordrecht, pp. 181-201.

Zhang, L., Cui, Y., Xiang, Z., Zheng, S., Traore, S., & Luo, Y. (2018). Short-term forecasting of daily crop evapotranspiration using the 'Kc-ETo' approach and public weather forecasts. *Archives of Agronomy and Soil Science*, 64(7), 903-915.

6. Anexos

6.1. Código utilizado para o cálculo do R^2 e do b_0 entre as previsões de cada variável para cada ponto e as observações.

```
1. import pandas as pd
2. import numpy as np
3. from sklearn.linear_model import LinearRegression
4. from sklearn.metrics import r2_score
5. from datetime import datetime, timedelta
6.
7. #definição dos paths para os ficheiros das obs e para a pasta dos pontos prev
8. path_obs = r'path ficheiro das obs.csv'
9. path_prev = r'path da pasta que contém os ficheiros de cada ponto prev'
10.
11. #Criação do dataframe com a primeira coluna com nome das variáveis a calcular
12. r2_b1 = pd.DataFrame({'': ['R_squared', 'Bo']})
13.
14. #importação dos dados obs e e renomeação das variáveis
15. obs = pd.read_csv(path_obs, parse_dates=['Data'], dayfirst=True)
16. obs = obs[['Data', 'Tmax (°C)', 'Tmin (°C)', 'HRmed (%)', 'VVmed (m/s)', 'RS (Mj/m2)', 'P (mm)']]
17. obs.columns = ['Data', 'Tmax', 'Tmin', 'HRmed', 'VVmed', 'RS', 'P']
18.
19. #cálculo ponto a ponto prev
20. for ficheiro in os.listdir(path_prev):
21.     if ficheiro.endswith('.csv'): # considerar apenas ficheiros CSV
22.
23.         #criar path para cada ponto dentro da pasta de prev
24.         path_ficheiro = os.path.join(path_prev, ficheiro)
25.
26.         #excluir linhas indesejadas
27.         dados_ficheiro = pd.read_csv(path_ficheiro, skiprows=[0,1,2,3,4,5,6,8], parse_dates=['Date'],
dayfirst=True)
28.
29.         # Considerar apenas as prev das datas desejadas
30.         dados_ficheiro = dados_ficheiro[(dados_ficheiro['Date'] >= '01-01-2021') &
(dados_ficheiro['Date'] <= datetime.strptime('31-12-2022', '%d-%m-%Y'))]
31.
32.         # considerar apenas as variáveis desejadas relativas ao 3º dia seguinte
33.         dados_ficheiro = dados_ficheiro.iloc[:, [0, 15, 16, 18, 19, 20, 21]]
34.
35.         #mudar as colunas para os mesmos nomes que os obs
36.         dados_ficheiro.columns = ['Data', 'Tmax', 'Tmin', 'HRmed', 'VVmed', 'RS', 'P']
37.
38.         #estabelecer as colunas a comparar
39.         labels_previsoes = ['Tmax', 'Tmin', 'HRmed', 'VVmed', 'RS', 'P']
40.
41.         #comparar variável a variável
42.         for label in labels_previsoes:
43.             coluna = dados_ficheiro[label]
44.
45.             #criação do dataframe para conter dados Obs e Prev
46.             obs_vs_prev = pd.DataFrame({
47.                 'Obs': [],
48.                 'Prev': []
49.             })
50.
```

```

51.     #comparar dia a dia
52.     for linha in coluna:
53.         #obter valores prev e obs do respetivo dia
54.         valor_prev = linha
55.         valor_obs = obs.iloc[l, obs.columns.get_loc(label)]
56.
57.         #criar dataframe com os valores obtidos
58.         dados_a_comparar = pd.DataFrame({
59.             'Obs': [valor_obs],
60.             'Prev': [valor_prev]
61.         })
62.
63.         #adicionar o dataframe dos valores obtidos ao dos dados finais
64.         obs_vs_prev = pd.concat([obs_vs_prev, dados_a_comparar], ignore_index=True)
65.
66.     #alterar o formato dos dados de linha para coluna
67.     x = obs_vs_prev['Obs'].values.reshape(-1,1)
68.     y = obs_vs_prev['Prev'].values.reshape(-1,1)
69.
70.     #fazer regressão linear normal e forçada com os dados alterados
71.     modelo_regressao_forcado = LinearRegression(fit_intercept=False)
72.     modelo_regressao_normal = LinearRegression()
73.     modelo_regressao_forcado.fit(x,y)
74.     modelo_regressao_normal.fit(x,y)
75.
76.     #cálculo métricas
77.     r2 = r2_score(y, modelo_regressao_normal.predict(x))
78.     b0 = modelo_regressao_forcado.coef_[0]
79.
80.     #guardar o nome do ponto
81.     nome_ponto = ficheiro.split('_')
82.     nome_ponto = nome_ponto[2] + '_' + nome_ponto[3].split('.')[0]
83.
84.     #verificar a variável para estruturação da tabela
85.     if label == 'Tmax':
86.         #guardar as métricas da variável num dataframe
87.         novos_dados = pd.DataFrame({'nome_ponto': ['Tmax', r2, b1[0]]})
88.
89.         #unir esse dataframe ao dataframe dos resultados finais
90.         r2_b1 = pd.concat([r2_b1, novos_dados], axis = 1)
91.     else:
92.         #guardar as métricas da variável num dataframe
93.         novos_dados = pd.DataFrame({'': [label, r2, b1[0]]})
94.
95.         #unir esse dataframe ao dataframe dos resultados finais
96.         r2_b1 = pd.concat([r2_b1, novos_dados], axis = 1)
97.
98.     #guardar como csv
99.     r2_b1.to_csv(r'path do local a guardar os resultados, index=False)

```

6.2. Código utilizado na ponderação das variáveis previstas pelo inverso da distância e subsequente comparação com as observações, através do R^2 e b_0 , e análise de significância entre a utilização de múltiplos pontos e de apenas um, através de testes t.

```
1. import pandas as pd
2. import numpy as np
3. from sklearn.linear_model import LinearRegression
4. from sklearn.metrics import r2_score
5. from scipy.stats import ttest_ind
6. import math
7. from datetime import datetime, timedelta
8. import os
9.
10. #definir os paths para os ficheiros das obs e para a pasta dos pontos prev
11. path_obs = r'path para o ficheiro dos dados obs.csv'
12. path_prev = r'path para a pasta com os ficheiros dos dados prev em formato csv'
13.
14.
15. #criação do dataframe final com a primeira coluna contendo as métricas
16. r2_b1 = pd.DataFrame({'': ['R_squared', 'B0']})
17.
18. #extrair o csv que contém as coordenadas dos pontos das obs
19. coord_obs_ficheiro = pd.read_csv(r'path do ficheiro que contem as coordenadas dos pontos')
20.
21. #extrair o csv que contém as coordenadas da EMR
22. coord_obs = {'latitude': math.radians(coord_obs_ficheiro.iloc[0,2]), 'longitude':
    math.radians(coord_obs_ficheiro.iloc[0,1])}
23.
24. #identificação do formato da data
25. obs = pd.read_csv(path_obs, parse_dates=['Data'], dayfirst=True)
26.
27. #extrair as colunas desejadas e renomeá-las
28. obs = obs[['Data', 'Tmax (°C)', 'Tmin (°C)', 'Hrmed (%)', 'Vvmed (m/s)', 'RSG (Mj/m2)', 'P (mm)']]
29. obs.columns = ['Data', 'Tmax', 'Tmin', 'HRmed', 'u2', 'RS', 'P']
30.
31. #criar lista para guardar a distancia entre os pontos e a EMR
32. dist_prev_obs = []
33.
34. #calcular a distância ponto a ponto
35. for ficheiro in os.listdir(path_prev):
36.     if ficheiro.endswith('.csv'): # considerar apenas ficheiros CSV
37.
38.         #criar path para cada ponto dentro da pasta de prev
39.         path_ficheiro = os.path.join(path_prev, ficheiro)
40.
41.         #selecionar células com as coordenadas
42.         extrato_ficheiro = pd.read_csv(path_ficheiro, nrows=4, usecols=[0, 1])
43.
44.         #extrair o nome do ponto
45.         nome_ponto = ficheiro.split('_')
46.         nome_ponto = nome_ponto[2] + '_' + nome_ponto[3].split('.')[0]
47.
48.         #ler coordenadas do ponto e calcular distância à EMR
49.         coord_ficheiro = {nome_ponto: {'latitude': math.radians(extrato_ficheiro.iloc[1,1]), 'longitude':
    math.radians(extrato_ficheiro.iloc[2,1])}}
```

```

50.     dlat = coord_ficheiro[nome_ponto]['latitude'] - coord_obs['latitude']
51.     dlon = coord_ficheiro[nome_ponto]['longitude'] - coord_obs['longitude']
52.     a = math.sin(dlat / 2)**2 + math.cos(coord_obs['latitude']) *
math.cos(coord_ficheiro[nome_ponto]['latitude']) * math.sin(dlon / 2)**2
53.     c = 2 * math.atan2(math.sqrt(a), math.sqrt(1 - a))
54.     raio_terra = 6371000
55.     distancia_pontos = round(raio_terra * c)
56.
57.     #adicionar distância à lista de distâncias
58.     dist_prev_obs.append([nome_ponto, [distancia_pontos]])
59.
60. #ordenar pontos por ordem decrescente de distâncias
61. dist_ordem = sorted(dist_prev_obs, key=lambda x: x[1], reverse=True)
62. dist_prev_obs.clear()
63. dist_prev_obs = dist_ordem
64.
65. #colunas a comparar
66. labels_previsoes = ['Tmax', 'Tmin', 'HRmed', 'u2', 'RS', 'P']
67.
68. #criar lista para guardar prev ponderadas
69. prev_ponderadas = []
70.
71. #criar uma lista para todas as previsões serem guardadas
72. prev_totais = []
73.
74. f = 0 #estabelecer o ficheiro que está a ser visto
75.
76. #calcular a distância ponto a ponto
77. for ficheiro in os.listdir(path_prev):
78.     if ficheiro.endswith('.csv'): # considerar apenas ficheiros CSV
79.
80.         #extrair o nome do ponto
81.         nome_ponto = ficheiro.split('_')
82.         nome_ponto = nome_ponto[2] + '_' + nome_ponto[3].split('.')[0]
83.
84.         #criar path para cada ponto dentro da pasta de prev
85.         path_ficheiro = os.path.join(path_prev, ficheiro)
86.
87.         #excluir linhas indesejadas
88.         dados_ficheiro = pd.read_csv(path_ficheiro, skiprows=[0,1,2,3,4,5,6,8], parse_dates=['Date'],
dayfirst=True)
89.
90.         #considerar apenas as prev das datas desejadas
91.         dados_ficheiro = dados_ficheiro[(dados_ficheiro['Date'] >= '01-01-2021') &
(dados_ficheiro['Date'] <= (datetime.strptime('31-12-2022', '%d-%m-%Y') - timedelta(days =
dias_prev)).strftime('%d-%m-%Y'))]
92.
93.         #extrair colunas das variáveis e dias desejados
94.         dados_ficheiro = dados_ficheiro.iloc[:, [0, 15, 16, 18, 19, 20, 21]]
95.         #mudar variáveis para os mesmos nomes que as obs
96.         dados_ficheiro.columns = ['Data', 'Tmax', 'Tmin', 'HRmed', 'u2', 'RS', 'P']
97.
98.         #criar listas para guardar prev de cada variável em cada ponto
99.         adicionar_tmax = ['Tmax',[]]
100.        adicionar_tmin = ['Tmin',[]]
101.        adicionar_HRmed = ['HRmed',[]]
102.        adicionar_u2 = ['u2',[]]

```

```

103. adicionar_RS = ['RS',[]]
104. adicionar_P = ['P',[]]
105.
106. #ler cada variável
107. for label in labels_previsoes:
108.
109.     #ler cada prev diária
110.     for linha in dados_ficheiro[label]:
111.
112.         #guardar cada prev na respetiva variável
113.         if label == 'Tmax':
114.             adicionar_tmax[1].append(linha)
115.         elif label == 'Tmin':
116.             adicionar_tmin[1].append(linha)
117.         elif label == 'HRmed':
118.             adicionar_HRmed[1].append(linha)
119.         elif label == 'u2':
120.             adicionar_u2[1].append(linha)
121.         elif label == 'RS':
122.             adicionar_RS[1].append(linha)
123.         elif label == 'P':
124.             adicionar_P[1].append(linha)
125.
126.
127. #guardar todas as previsões no respetivo ponto
128. prev_totais.append([nome_ponto])
129. prev_totais[f].append(adicionar_tmax)
130. prev_totais[f].append(adicionar_tmin)
131. prev_totais[f].append(adicionar_HRmed)
132. prev_totais[f].append(adicionar_u2)
133. prev_totais[f].append(adicionar_RS)
134. prev_totais[f].append(adicionar_P)
135. f += 1
136.
137.multiplicar = []
138.
139.#número de pontos na primeira ponderação
140.nr_pontos = 25
141.
142.#ponderar até ao ponto mais próximo
143.while nr_pontos > 0:
144.
145.     #criar lista para guardar prev ponderadas pelo inverso da distância
146.     prev_multiplicadas = []
147.
148.     soma_distancias = 0
149.     for distancia in dist_prev_obs:
150.
151.         #somar o inverso das distâncias
152.         soma_distancias += 1/distancia[1][0]
153.
154.     pnt = 0
155.
156.     #associar cada ponto à respetiva distância
157.     for ponto in prev_totais:
158.
159.         for pt in dist_prev_obs:

```

```

160.
161.     #verificar que o ponto é ponderado com a respetiva distância
162.     if str(ponto[0]) in pt[0]:
163.
164.         #guardar nome do ponto
165.         prev_multiplicadas.append([ponto[0]])
166.         var = 1
167.
168.         #garantir que só se considera 3 variáveis
169.         while var <= 6:
170.
171.             # ponderação de cada prev pelo inverso da distância do respetivo ponto
172.             multiplicar = [ponto[var][0], [elem / pt[1][0] / soma_distancias for elem in ponto[var][1]]]
173.
174.             #guardar valores ponderados
175.             prev_multiplicadas[pnt].append(multiplicar)
176.
177.             var += 1
178.             pnt += 1
179.
180. #adicionar o número de pontos que foi ponderado à lista de ponderações
181. prev_ponderadas.append([nr_pontos])
182.
183. #iterar por cada sub-lista das prev ponderadas correspondentes a cada variável
184. for i in range(1, len(prev_multiplicadas[0])):
185.
186.     #guardar nome da variável ponderada
187.     tipo_dado = prev_multiplicadas[0][i][0]
188.
189.     #soma de prev ponderadas relativas aos mesmos dias
190.     valores = [sum(val) for val in zip(*[sublista[i][1] for sublista in prev_multiplicadas])]
191.
192.     #adicionar prev ponderadas à sublista referente a cada nº de pontos
193.     prev_ponderadas[25-nr_pontos].append([tipo_dado, valores])
194.
195.     nr_pontos -= 1
196.
197. #retirar ponto mais distante que já não será necessário
198. dist_prev_obs.pop(0)
199.
200. #criar dataframe com a primeira coluna com nome das variáveis a calcular
201. tabela = pd.DataFrame({"": ["", 'R_squared', 'B0', 'p-value']})
202.
203. #iterar pela lista de prev ponderadas
204. for item in prev_ponderadas:
205.
206.     #adicionar número de pontos ponderados ao dataframe final
207.     tabela = pd.concat([tabela, pd.DataFrame({item[0]: []})], axis = 1)
208.
209.     #estabelecer var a trabalhar
210.     var = 1 # 1=Tmax, 2=Tmin, 3=HRmed, 4=u2, 5=RS, 6=P
211.
212.     #iterar por variáveis prev ponderadas
213.     for parametro in item[1:]:
214.
215.         #designar valores x e y dos dados obs e prev ponderados
216.         x = np.array(obs[parametro[0]]).reshape(-1, 1)

```

```

217. y = np.array(parametro[1]).reshape(-1, 1)
218.
219.
220. # executar regressões lineares
221. modelo_regressao_forcado = LinearRegression(fit_intercept=False)
222. modelo_regressao_normal = LinearRegression()
223. modelo_regressao_forcado.fit(x,y)
224. modelo_regressao_normal.fit(x,y)
225.
226. #calcular métricas
227. r2 = r2_score(y, modelo_regressao_normal.predict(x))
228. b0 = modelo_regressao_forcado.coef_[0]
229.
230. #executar t-test entre vários pontos e 1 ponto
231. t_stat, p_value = ttest_ind(parametro[1], prev_ponderadas[24][var][1], equal_var=False)
232.
233. #verificar a variável para estruturação da tabela
234. if parametro[0] != 'Tmax':
235.     dados_novos = pd.DataFrame({'': [parametro[0], r2, b0, p_value]})
236.
237.     #inserir resultados no dataframe final
238.     tabela = pd.concat([tabela, dados_novos], axis = 1)
239. else:
240.     #inserir resultados no dataframe final
241.     tabela[item[0]] = [parametro[0], r2, b0, p_value]
242.
243.tabela.to_csv(r'path do local a guardar os resultados', index=False)

```

6.3. Código utilizado no cálculo das métricas de distribuição (metricas1) e correlação (metricas2) na comparação direta.

```
1. #importação das bibliotecas necessárias
2. import pandas as pd
3. from sklearn.linear_model import LinearRegression
4. from sklearn.metrics import r2_score, mean_absolute_error, mean_squared_error
5. from scipy.stats import kurtosis, skew
6. import numpy as np
7.
8.
9. #importar as variáveis obs desejadas e renomeá-las
10. obs = pd.read_csv(r'C:\path do ficheiro das observações.csv')
11. obs = obs[['Tmax (°C)', 'Tmin (°C)', 'Hrmed (%)', 'Vvmed (m/s)', 'RS (Mj/m2)', 'P (mm)', 'ET0 (mm)']]
12. obs.columns = ['Tmax', 'Tmin', 'HRmed', 'VVmed', 'RS', 'P', 'ET0']
13.
14. #importar as variáveis prev desejadas e renomeá-las
15. prev = pd.read_csv(r'C:\path do ficheiro das previsões.csv')
16. prev = prev[['Tmax (°C)', 'Tmin (°C)', 'Hrmed (%)', 'Vvmed (m/s)', 'RS (Mj/m2)', 'P (mm)', 'ET0 (mm)']]
17. prev.columns = ['Tmax', 'Tmin', 'HRmed', 'VVmed', 'RS', 'P', 'ET0']
18.
19. # Criar variáveis para guardar as métricas das obs
20. media_obs = None
21. desv_pad_obs = None
22. curt_obs = None
23. sim_obs = None
24.
25. # Criar variáveis para guardar as métricas das prev
26. media_prev = None
27. desv_pad_prev = None
28. curt_prev = None
29. sim_prev = None
30.
31. #Criar Dataframe com a primeira coluna de variáveis de distribuição a calcular
32. metricas1 = pd.DataFrame({
33. nr_pontos: [' ', 'Media', 'Desvio Padrao', 'Curtose', 'Simetria']
34. })
35.
36. #Criar Dataframe com a primeira coluna de variáveis de correlação a calcular
37. metricas2 = pd.DataFrame({
38. nr_pontos: ['R_squared', 'B0', 'MSE']
39. })
40.
41. #Cálculo das métricas variável a variável
42. for coluna in obs.columns:
43.     obs_valores = obs[coluna]#Obter os valores da coluna respetiva dos dados observados
44.     prev_valores = prev[coluna]#Obter os valores da coluna respetiva dos dados previstos
45.
46.     #calcular métricas da distribuição das observações
47.     media_obs = obs[coluna].mean()
48.     desv_pad_obs = obs[coluna].std()
49.     curt_obs = kurtosis(obs[coluna])
50.     sim_obs = skew(obs[coluna])
51.
52.     #calcular métricas da distribuição das previsões
53.     media_prev = prev[coluna].mean()
54.     desv_pad_prev = prev[coluna].std()
```

```

55. curt_prev = kurtosis(prev[coluna])
56. sim_prev = skew(prev[coluna])
57.
58. #criar dataframes com as métricas obtidas
59. metricas_obs = pd.DataFrame({coluna: ['Obs', media_obs, desv_pad_obs, curt_obs, sim_obs]})
60. metricas_prev = pd.DataFrame({"": ['Prev', media_prev, desv_pad_prev, curt_prev, sim_prev]})
61.
62. #unir os dataframes com os resultados ao dataframe designado às métricas de distribuição
63. metricas1 = pd.concat([metricas1, metricas_obs], axis = 1)
64. metricas1 = pd.concat([metricas1, metricas_prev], axis = 1)
65.
66. # Fazer a regressão linear normal e forçada
67. x = obs[coluna].values.reshape(-1,1)
68. y = prev[coluna].values.reshape(-1,1)
69. modelo_regressao_forcado = LinearRegression(fit_intercept=False)
70. modelo_regressao_normal = LinearRegression()
71. modelo_regressao_forcado.fit(x,y)
72. modelo_regressao_normal.fit(x,y)
73.
74. #cálculo e obtenção das métricas de correlação
75. r2 = r2_score(y, modelo_regressao_normal.predict(x))
76. b0 = modelo_regressao_forcado.coef_[0]
77. mse = mean_squared_error(obs[coluna], prev[coluna])# Calcular MSE
78.
79. #criar dataframe com as métricas obtidas para cada variável
80. metricas_calculo2 = pd.DataFrame({coluna: [r2, b0[0], mse]})
81. #adicionar o dataframe com os resultados ao dataframe designado às métricas de correlação
82. metricas2 = pd.concat([metricas2, metricas_calculo2], axis = 1)
83.
84. # Guardar a tabela como csv
85. metricas1.to_csv(r'C:\path do local a guardar.csv', index=False, sep=',')
86. metricas2.to_csv(r'C:\path do local a guardar.csv', index=False, sep=',')

```

6.4. Coeficiente de correlação (R^2) e desvio médio (B_0) das previsões comparadas com as observações das respectivas variáveis. A negrito, os valores que se inserem nos intervalos de aceitação $R^2 \geq 0.7$ e $0.8 \leq B_0 \leq 1.20$.

Ponto	T_{max}		T_{min}		HR_{med}		u_2		RS		P	
	R^2	b_0	R^2	b_0	R^2	b_0	R^2	b_0	R^2	b_0	R^2	b_0
108_016	0.95	1.06	0.83	1.10	0.78	1.05	0.58	0.30	0.87	0.83	0.24	0.54
108_017	0.95	1.06	0.81	1.07	0.77	1.06	0.55	0.29	0.87	0.83	0.24	0.53
108_018	0.95	1.07	0.81	1.08	0.77	1.05	0.56	0.27	0.87	0.83	0.27	0.57
108_019	0.95	1.07	0.81	1.08	0.78	1.06	0.54	0.28	0.87	0.82	0.28	0.58
109_016	0.95	1.05	0.83	1.08	0.78	1.06	0.58	0.30	0.86	0.83	0.25	0.59
109_017	0.95	1.06	0.81	1.08	0.78	1.06	0.56	0.29	0.86	0.83	0.25	0.56
109_018	0.95	1.06	0.81	1.07	0.78	1.06	0.57	0.30	0.86	0.83	0.27	0.58
109_019	0.95	1.06	0.82	1.07	0.79	1.06	0.54	0.31	0.86	0.83	0.27	0.57
109_020	0.95	1.05	0.82	1.07	0.79	1.07	0.54	0.30	0.86	0.82	0.28	0.59
110_015	0.95	1.05	0.83	1.08	0.78	1.05	0.59	0.30	0.87	0.83	0.26	0.63
110_016	0.95	1.06	0.82	1.08	0.78	1.06	0.57	0.30	0.87	0.83	0.25	0.60
110_017	0.95	1.06	0.81	1.07	0.78	1.06	0.56	0.30	0.87	0.83	0.24	0.56
110_018	0.95	1.07	0.81	1.07	0.78	1.06	0.55	0.29	0.86	0.83	0.27	0.59
110_019	0.95	1.06	0.82	1.07	0.79	1.07	0.52	0.29	0.86	0.82	0.27	0.58
110_020	0.95	1.04	0.82	1.06	0.80	1.08	0.53	0.32	0.86	0.83	0.27	0.59
111_016	0.95	1.06	0.81	1.07	0.77	1.06	0.56	0.29	0.87	0.83	0.26	0.64
111_017	0.95	1.06	0.80	1.06	0.78	1.07	0.56	0.30	0.86	0.83	0.25	0.58
111_018	0.95	1.06	0.80	1.06	0.78	1.07	0.55	0.30	0.86	0.83	0.24	0.56
111_019	0.95	1.05	0.80	1.05	0.79	1.08	0.52	0.31	0.86	0.83	0.26	0.58
111_020	0.95	1.06	0.80	1.05	0.79	1.08	0.49	0.29	0.86	0.82	0.27	0.60
112_016	0.95	1.06	0.78	1.03	0.76	1.07	0.51	0.27	0.86	0.83	0.29	0.67
112_017	0.95	1.06	0.77	1.02	0.77	1.08	0.49	0.27	0.86	0.83	0.27	0.63
112_018	0.95	1.06	0.77	1.02	0.77	1.09	0.48	0.27	0.87	0.83	0.25	0.58
112_019	0.95	1.06	0.77	1.01	0.78	1.09	0.46	0.28	0.87	0.83	0.26	0.57
113_018	0.95	1.07	0.73	0.97	0.75	1.09	0.40	0.24	0.87	0.83	0.29	0.63

6.5a. Coeficiente de correlação (R^2) e desvio médio (B_0) das previsões ponderadas em relação às observações de cada variável.

A negrito, os valores que se inserem nos intervalos de aceitação $R^2 \geq 0.7$ e $0.8 \leq B_0 \leq 1.20$.

Nº Pontos	T_{max}		T_{min}		HR_{med}		u_2		R_s		P	
	R^2	b_0	R^2	b_0	R^2	b_0	R^2	b_0	R^2	b_0	R^2	b_0
25	0.950	0.937	0.813	0.901	0.782	0.922	0.572	3.178	0.867	1.149	0.271	0.508
24	0.950	0.937	0.814	0.899	0.783	0.922	0.572	3.168	0.866	1.149	0.270	0.508
23	0.950	0.937	0.814	0.900	0.783	0.922	0.571	3.169	0.866	1.149	0.270	0.508
22	0.950	0.937	0.813	0.900	0.783	0.922	0.570	3.170	0.866	1.149	0.270	0.509
21	0.950	0.937	0.813	0.900	0.783	0.922	0.570	3.165	0.866	1.149	0.269	0.509
20	0.950	0.937	0.813	0.900	0.783	0.922	0.570	3.167	0.866	1.149	0.268	0.509
19	0.950	0.937	0.813	0.900	0.783	0.922	0.569	3.162	0.866	1.149	0.267	0.508
18	0.950	0.937	0.813	0.900	0.782	0.922	0.570	3.161	0.866	1.149	0.267	0.508
17	0.950	0.937	0.814	0.898	0.782	0.923	0.570	3.157	0.866	1.149	0.266	0.507
16	0.950	0.937	0.813	0.898	0.783	0.923	0.569	3.157	0.866	1.149	0.267	0.507
15	0.950	0.936	0.813	0.898	0.782	0.923	0.569	3.165	0.866	1.149	0.266	0.507
14	0.950	0.937	0.813	0.899	0.782	0.923	0.569	3.156	0.866	1.149	0.266	0.506
13	0.950	0.936	0.812	0.899	0.782	0.922	0.567	3.158	0.866	1.149	0.266	0.507
12	0.950	0.937	0.813	0.898	0.782	0.923	0.567	3.149	0.866	1.149	0.265	0.507
11	0.950	0.936	0.813	0.898	0.783	0.923	0.566	3.148	0.866	1.149	0.265	0.509
10	0.950	0.936	0.814	0.896	0.783	0.924	0.566	3.139	0.865	1.149	0.264	0.510
9	0.950	0.936	0.813	0.896	0.783	0.923	0.564	3.142	0.865	1.149	0.265	0.512
8	0.950	0.936	0.813	0.896	0.782	0.923	0.563	3.150	0.865	1.150	0.264	0.510
7	0.950	0.936	0.813	0.895	0.782	0.924	0.564	3.161	0.865	1.150	0.263	0.511
6	0.950	0.935	0.812	0.895	0.782	0.924	0.562	3.161	0.865	1.150	0.264	0.511
5	0.950	0.935	0.812	0.895	0.781	0.924	0.563	3.164	0.865	1.150	0.263	0.511
4	0.950	0.935	0.812	0.895	0.782	0.924	0.562	3.169	0.865	1.150	0.264	0.513
3	0.949	0.935	0.812	0.894	0.781	0.924	0.560	3.177	0.865	1.151	0.262	0.511
2	0.949	0.934	0.814	0.892	0.781	0.925	0.558	3.204	0.865	1.151	0.264	0.513
1	0.949	0.932	0.812	0.891	0.781	0.924	0.553	3.235	0.864	1.153	0.269	0.519

6.6b. Resultados do teste t entre as previsões ponderadas com cada conjunto de pontos e apenas as previsões do ponto mais próximo.

Nº Pontos	p-value					
	T _{max}	T _{min}	HR _{med}	U ₂	R _s	P
25	0.81	0.58	0.85	0.26	0.87	0.97
24	0.80	0.64	0.88	0.18	0.87	0.97
23	0.81	0.63	0.86	0.20	0.87	0.97
22	0.81	0.61	0.84	0.20	0.88	0.97
21	0.81	0.64	0.85	0.17	0.88	0.97
20	0.81	0.63	0.86	0.18	0.87	0.97
19	0.80	0.61	0.84	0.16	0.87	0.97
18	0.81	0.62	0.87	0.15	0.86	0.97
17	0.81	0.67	0.92	0.13	0.86	0.96
16	0.82	0.67	0.90	0.13	0.87	0.96
15	0.84	0.68	0.93	0.18	0.87	0.96
14	0.83	0.66	0.90	0.13	0.86	0.96
13	0.84	0.65	0.88	0.14	0.87	0.97
12	0.84	0.70	0.91	0.10	0.87	0.97
11	0.84	0.71	0.90	0.10	0.88	0.98
10	0.84	0.79	0.97	0.06	0.88	0.98
9	0.85	0.78	0.94	0.07	0.89	0.99
8	0.85	0.77	0.93	0.10	0.89	0.98
7	0.88	0.81	0.99	0.15	0.90	0.98
6	0.88	0.81	0.95	0.16	0.91	0.98
5	0.90	0.79	0.97	0.18	0.89	0.98
4	0.91	0.83	0.99	0.21	0.90	0.99
3	0.90	0.84	0.96	0.27	0.92	0.98
2	0.94	0.94	0.95	0.55	0.94	0.98
1	1	1	1	1	1	1

6.7. Regressões lineares de cada variável prevista em função da observada e resultantes R^2 .

