

MESTRADO EM
GESTÃO DE SISTEMAS DE INFORMAÇÃO

TRABALHO FINAL DE MESTRADO
DISSERTAÇÃO

O Impacte da Inteligência Artificial na Sustentabilidade
Ambiental: Uma Agricultura Sustentável

INÈS FILIPA DUARTE RUSSO

ISEG, NOVEMBRO DE 2020

MESTRADO EM
GESTÃO DE SISTEMAS DE INFORMAÇÃO

TRABALHO FINAL DE MESTRADO
DISSERTAÇÃO

O Impacte da Inteligência Artificial na Sustentabilidade
Ambiental: Uma Agricultura Sustentável

POR INÈS FILIPA DUARTE RUSSO

ORIENTAÇÃO:

PROFESSOR PAULO JORGE DE ALMEIDA GONÇALVES

ISEG, NOVEMBRO DE 2020

*Though the problems of the world are increasingly complex, the solutions remain
embarrassingly simple.*

- Bill Mollison.

AGRADECIMENTOS

À minha família pelo apoio incondicional, pelos valores transmitidos e acima de tudo pela paciência durante estes últimos meses.

Ao meu orientador por me ter acompanhado desde o primeiro até ao último dia, sempre com a mesma dedicação, empenho e uma palavra amiga e motivacional nos momentos mais desafiantes.

Aos entrevistados por terem partilhado com entusiasmo o seu conhecimento e experiência.

E ao ISEG por ter sido uma segunda casa ao longo destes cinco anos. Casa esta, que lembrarei sempre com um enorme carinho.

RESUMO

A agricultura começa a dar os seus primeiros passos nesta quarta revolução industrial, centrada nos dados e na conectividade. As tecnologias emergentes de inteligência artificial (IA) podem aumentar ainda mais os rendimentos, melhorar a eficiência da água, a monitorização dos solos, gerir doenças e pestes, e construir sustentabilidade e resiliência diante das mudanças e inevitáveis surpresas. Para lidar com o aumento da procura e de várias tendências disruptivas com sucesso, a indústria agrícola precisará superar os desafios de uma implementação de conectividade avançada. O presente estudo tem assim as seguintes questões de investigação: 1. Como pode a IA contribuir para uma gestão sustentável da agricultura? 2. Como introduzir o uso de IA na agricultura de uma forma continuada? E tem como objetivos de investigação: 1. Analisar as principais características das ferramentas baseadas em IA que permitem uma gestão sustentável da agricultura; 2. Apresentar os principais fatores limitadores para a adoção de IA na agricultura; 3. Compreender até que ponto o volume de dados é um desafio a nível do bom desempenho das ferramentas de IA; e 4. Relacionar o papel das universidades e empresas e a adoção de IA na agricultura. O método utilizado foi a realização de entrevistas semiestruturadas a peritos nas áreas da agricultura sustentável e das novas tecnologias emergentes de IA. Do estudo, foi possível concluir que a IA contribui para a sustentabilidade da agricultura a três níveis. A nível ambiental, permite que seja feito um planeamento estratégico da agricultura dando assim um apoio à tomada de decisão dos agricultores acerca do uso eficiente dos fatores de produção. A nível económico, observa-se um aumento de eficiência, rentabilidade e produtividade. E a nível dos dados, a IA tem o poder de transformar os dados recolhidos em informação valiosa para o agricultor com precisão e em tempo real. Porém alguns desafios dificultam esta adoção, nomeadamente: a dimensão territorial; a capacidade financeira dos agricultores; a idade mais avançada dos agricultores bem como a sua mentalidade cética e adversa a este tipo de tecnologias; o excesso e diversidade de dados existentes; entre outros abordados no estudo. Também, as empresas e universidades têm um peso importante na medida em que contribuem para que haja uma disseminação maior da informação através dos casos de estudo e da experimentação. Uma compreensão mais profunda dos desafios da inserção de IA no mundo agrícola irá permitir adotar mudanças, aproveitar as oportunidades que ocorrerão e saber retirar vantagem dos potenciais benefícios da IA na agricultura.

Palavras-chave: Sustentabilidade ambiental; agricultura sustentável; inteligência artificial

ABSTRACT

Agriculture begins to take its first steps in this fourth industrial revolution, centered on data and connectivity. Emerging artificial intelligence (AI) technologies can further increase yields, improve water efficiency, monitor soil, manage disease, pests, and build sustainability and resilience in the face of changes and inevitable surprises. To successfully cope with rising demand and several disruptive trends, the agricultural industry will need to overcome the challenges of an advanced connectivity implementation. The present study therefore has the following research questions: 1. How can AI contribute to sustainable management of agriculture? 2. How to introduce the use of AI in agriculture in a continuous way? And as research objectives: 1. Analyze the main characteristics of AI-based tools that allow sustainable management of agriculture; 2. Present the main limiting factors for the adoption of AI in agriculture; 3. Understand to what extent the volume of data is a challenge in terms of the good performance of AI tools; and 4. Relate the role of universities and companies and the adoption of AI in agriculture. The method used was the case study, using semi-structured interviews with experts in the areas of sustainable agriculture and the new emerging AI technologies. From the study, it was possible to conclude that AI contributes to the sustainability of agriculture at three levels. At the environmental level, it allows a strategic planning of agriculture to be carried out, thus supporting farmers' decision-making about the efficient use of production factors. At an economic level, there is an increase in efficiency, profitability, and productivity. And at the data level, AI has the power to transform the collected data into valuable information for the farmer with precision and in real time. However, some challenges hinder this adoption, namely: the territorial dimension, the financial capacity of farmers; the older age of farmers as well as their skeptical and adverse mindset to this type of technologies; the excess and diversity of existing data, among others addressed in the study. Also, companies and universities have an important weight in that they contribute to a greater dissemination of information through case studies and experimentation. A deeper understanding of the challenges of AI insertion in the agricultural world will allow to adopt changes, to take advantage of the opportunities that will occur and to take advantage of the potential benefits of AI in agriculture.

Keywords: Environmental sustainability; sustainable agriculture; artificial intelligence

ÍNDICE

Agradecimentos	iv
Resumo	v
Abstract.....	vi
Lista de figuras	ix
Lista de tabelas	x
Lista de abreviaturas	xi
1. Introdução.....	1
2. Revisão de literatura	3
2.1 Inteligência Artificial.....	3
2.1.1 O Poder da IA	4
2.2 Sustentabilidade e Sustentabilidade Ambiental.....	5
2.2.1 Inteligência Artificial na Sustentabilidade Ambiental.....	5
2.3 Agricultura Sustentável	6
2.3.1 Desafios da Agricultura Moderna.....	7
2.4 Aplicações de IA na Agricultura Sustentável.....	9
2.4.1 Gestão do Solo	9
2.4.2 Gestão das Culturas	9
2.4.3 Gestão da Água	10
2.4.4 Gestão das Ervas Daninhas	10
2.4.5 Gestão das Doenças e Pragas	11
2.5 Desafios e Oportunidades da Adoção de IA na Agricultura.....	12
3. Metodologia.....	15
3.1 Análise Qualitativa.....	15
3.2 Entrevistas a painel de peritos.....	15
3.3 Recolha de Dados	16
3.4 Análise de dados	17
3.5 Validação	18
4. Apresentação de resultados	19
5. Análise e discussão de resultados	21
5.1 Desafios.....	21
5.2 Oportunidades	27
6. Conclusões, Contributos, Limitações e Investigação Futura.....	32
Referências Bibliográficas.....	36
Anexos.....	54

Anexo A – Resumo da Aplicação de IA na Resolução de Problemas Ambientais Gerais.....	54
Anexo B – Definição das principais técnicas de IA.....	55
Anexo C – Resumo da Aplicação de IA na Gestão do Solo e Culturas	56
Anexo D – Resumo da Aplicação de IA na Gestão da Água	57
Anexo E – Resumo da Aplicação de IA na Gestão de Ervas Daninhas	59
Anexo F – Resumo da Aplicação de IA em Robótica Agrícola na Gestão de Ervas Daninhas ..	61
Anexo G – Resumo da Aplicação de IA na Gestão das Doenças	62
Anexo H – Resumo da Aplicação de IA na Gestão de Pragas	63
Anexo I – Guião de Entrevista	64
Anexo J – Códigos e Subcódigos Decorrentes das Entrevistas.....	66
Anexo K – Matriz de Visualização de Códigos em Cada Entrevista no MAXQDA	72

LISTA DE FIGURAS

Figura 1 – Etapas Metodológicas	16
Figura 2 – Resumo da Etapa de Recolha de Dados.....	16
Figura 3 – Resumo da Etapa de Análise de Dados.....	17

LISTA DE TABELAS

Tabela 1 – Desafios da Adoção de Inteligência Artificial na Agricultura	12
Tabela 2 – Oportunidades da Adoção de Inteligência Artificial na Agricultura	13
Tabela 3 – Características das Entrevistas	20
Tabela 4 – Caracterização dos Entrevistados	20

LISTA DE ABREVIATURAS

AGTECH – *Agriculture Technology*

AI – *Artificial Intelligence*

CNN – *Convolutional Neural Network*

CPB – *Colorado Potato Beetle*

DCNN – *Deep Convolutional Neural Networks*

DL – *Deep Learning*

DNN – *Deep Neural Networks*

DT – *Decision Tree*

ELM – *Extreme Learning Machine*

EVI – *Enhanced Vegetation Index*

FAO – *Food and Agriculture Organization of the United Nations*

FL – *Fuzzy-Logic*

GPS – *Global Positioning System*

HANN - *Hybrid Artificial Neural Network*

IA – *Inteligência Artificial*

IoT – *Internet of Things*

LS-SVM - *Least Square Support Vector Machine*

MBB – *Mexican Bean Beetle*

ML – *Machine Learning*

MV – *Machine Vision*

NF-FCM – *Neuro-Fuzzy C-Means Clustering*

NF-SC – *Neuro-Fuzzy Sub-Clustering*

ONU – *Organização das Nações Unidas*

OQDS – *Olive Quick Decline Syndrome*

PAC – *Política Agrícola Comum*

PLSR – *Partial Least Square Regression*

RGB – *Red, Green, Blue*

RNA – *Redes Neurais Artificiais*

SVM – *Support Vector Machine*

TIC – *Tecnologias de Informação e Comunicação*

1. INTRODUÇÃO

De acordo com Bruinsma (2009), e com base nas projeções da Organização das Nações Unidas para a Alimentação e Agricultura (FAO) (FAO, 2017), até 2050, a disponibilidade média de calorias diárias mundial pode subir para 3130 calorias por pessoa. Para que tal seja possível, será necessário que a produção agrícola aumente em cerca de 70% a 100% (no caso de países em desenvolvimento) para lidar com um aumento de 40% da população mundial, até essa data (Goedde *et al.*, 2020). Isto significa que teremos que produzir anualmente mais mil milhões de toneladas de cereais e 200 milhões de toneladas extra de produtos de origem animal (De Clercq, Vats e Biel, 2018).

Assim, o uso das mais recentes soluções tecnológicas, para tornar a agricultura mais eficiente e sustentável, permanece um dos maiores imperativos. A Inteligência Artificial (IA) é uma área interdisciplinar e pode alterar o paradigma da agricultura, para um modo diferente do atual (Panpatte, 2018). As soluções baseadas em IA não apenas permitirão que os agricultores façam mais com menos, como também melhorarão a qualidade e garantirão uma entrada no mercado mais rápida das culturas (Revanth, 2019). Estaremos, deste modo, mais perto da criação de uma agricultura sustentável.

O presente estudo tem assim as seguintes questões de investigação, que irão permitir estudar e identificar o impacto da aplicação de Inteligência Artificial na sustentabilidade ambiental a nível da agricultura:

1. Como pode a IA contribuir para uma gestão sustentável da agricultura?
2. Como introduzir o uso de IA na agricultura de uma forma continuada?

Os objetivos de investigação são os seguintes:

1. Analisar as principais características das ferramentas baseadas em IA que permitem uma gestão sustentável da agricultura;
2. Apresentar os principais fatores limitadores para a adoção de IA na agricultura;
3. Compreender até que ponto o volume de dados é um desafio a nível do bom desempenho das ferramentas de IA; e
4. Relacionar o papel das universidades e empresas e a adoção de IA na agricultura.

Em comparação com outros setores da economia, a implementação de Tecnologias de Informação e Comunicação (TIC) na agricultura, especialmente nas áreas rurais, tem

sido relativamente lenta e tardia devido às circunstâncias económicas e incertezas associadas ao retorno do investimento (Lakshmi e Corbett, 2020). Tradicionalmente, os agricultores deslocam-se aos campos para verificar a situação das suas culturas e tomar decisões com base na experiência acumulada (Saiz-Rubio e Rovira-Más, 2020). Porém, esta abordagem já não é sustentável porque, entre outras razões, alguns campos são muito grandes para serem geridos de forma eficiente de acordo com os três critérios que conduzirão os próximos anos: eficiência, sustentabilidade e disponibilidade (para pessoas) (Saiz-Rubio e Rovira-Más, 2020).

Existe, portanto, a necessidade de intensificar os esforços na adoção de resultados/tecnologias de pesquisa para melhorar a produtividade, a segurança alimentar, o desenvolvimento sustentável e o bem-estar dos agricultores, através da adoção de tecnologias e pacotes de pesquisa superiores (Lawal e Oluyole, 2008). Sendo este um tema recente e pertinente de análise, considera-se útil investigar o fenómeno da digitalização do setor agrícola de forma a contribuir para uma agricultura sustentável.

De modo a atingir os objetivos definidos, recorreu-se à metodologia *mono method qualitative*. Para tal, como fonte de informação para o estudo empírico do projeto realizou-se um conjunto de entrevistas semiestruturadas a peritos nas áreas da agricultura sustentável e das novas tecnologias emergentes de Inteligência Artificial.

Considerou-se maioritariamente o território português como âmbito de análise, tendo, no entanto, tido em conta o caso do território brasileiro.

Este projeto está estruturado em seis partes descritas a seguir:

No primeiro capítulo, a introdução, é transmitido o que é estudado e feito no trabalho de investigação e a razão da escolha do tópico. De seguida, no capítulo dois, é apresentada a revisão de literatura composta por cinco subcapítulos. No terceiro capítulo é desenvolvida a metodologia adotada assim como a sua justificação. No quarto capítulo, apresentação de resultados, será apresentado o que se obteve da recolha e análise de dados. No quinto capítulo, efetua-se uma análise e discussão atenta dos resultados e por fim, no sexto capítulo, conclui-se o projeto respondendo às questões de investigação e objetivos delineados, e apresentando os contributos, limitações e investigação futura.

2. REVISÃO DE LITERATURA

Neste capítulo, começa-se por definir a IA e compreender o poder desta tecnologia nos dias de hoje. Posteriormente explora-se o conceito da sustentabilidade e especificamente da sustentabilidade ambiental e introduz-se algumas aplicações de IA na sustentabilidade ambiental de forma a entender o papel crescente que esta ferramenta tem a nível da sustentabilidade do planeta. O terceiro subcapítulo permite entender o conceito da agricultura sustentável a nível dos seus objetivos e como pode ser uma mais-valia tendo em conta os desafios que a agricultura moderna enfrenta a nível: demográfico, social, económico, ambiental e tecnológico (dados). Assim, no subcapítulo quatro, são detalhadas as principais aplicações de IA na agricultura sustentável que se focam essencialmente: na gestão do solo e das culturas, na gestão da água, na gestão das ervas daninhas e na gestão das doenças e pragas. Por fim, no quinto e último subcapítulo, é apresentado um resumo dos desafios e oportunidades da adoção de IA na agricultura, assim como a relação entre os construtos resultantes da revisão de literatura e as perguntas do guião de entrevista.

2.1 *Inteligência Artificial*

Segundo Li e Du (2017), o Simpósio de *Dartmouth* organizado no verão de 1956 marcou o nascimento da Inteligência Artificial, com John McCarthy (conhecido como o Pai da IA), propondo o termo "Inteligência Artificial" como o nome da nova disciplina transversal. Esta conferência baseou-se “explicitamente na assunção e conjectura de que qualquer assunto do conhecimento poderia ser descrito e reduzido a algo tão preciso e exato que poderia ser simulado por uma qualquer máquina”, como referem Trigo-Guedes e Palma-dos-Reis (2019, p. 2).

A IA pode, portanto, ser pensada como uma simulação da capacidade de pensamento abstrato, criativo e dedutivo, e particularmente da capacidade de aprender, usando a lógica digital e binária dos computadores (Marr, 2019). Os computadores tomam as melhores decisões com base em dados memorizados de experiências passadas e dados estatísticos (Russell e Norvig, 2010). Isso leva-nos a um subdomínio neste campo de IA, a "aprendizagem de máquina" mais conhecido por *machine learning* (ML).

A principal distinção entre abordagens tradicionais e a aprendizagem de máquina é que, no ML, um modelo aprende com exemplos, em vez de ser programado com regras (Rajkomar, Dean e Kohane, 2019). O ML tornou-se tão essencial à IA contemporânea que

os termos "inteligência artificial" e "aprendizagem de máquina" são por vezes usados de forma permutável (Jha *et al.*, 2019).

2.1.1 O Poder da IA

A IA, corretamente projetada e implementada, tem o potencial de se tornar o melhor e “mais incansável servo da humanidade”, libertando os humanos da “escravidão salarial” (Garimella e Fingar, 2018, p. 1). Parece improcedente sugerir que, num futuro próximo, a IA possa superar amplamente a inteligência humana na maioria ou em todas as suas dimensões, tornando-se uma superinteligência (Pueyo, 2019).

A verdade é que para onde a IA nos leva, a que ritmo e em que direção, é incerto e levanta sérias questões sobre o seu potencial impacto nos empregos, na privacidade e na política (Lohr, 2018). De facto, esta quarta e, talvez, última revolução industrial pode ter consequências para quem a quer abraçar e para quem prefere ficar de fora: “independentemente da escolha feita, ninguém poderá escapar da ascensão ameaçadora da IA” (Munoz e Naqvi, 2018, p. 1). Porém, enquanto nos países mais avançados, as pessoas podem temer a perda dos seus empregos devido ao crescimento da IA, nos países com baixo rendimento, as pessoas podem encontrar na IA oportunidades para quebrar o ciclo da pobreza (Lohr, 2018).

A IA está a entrar rapidamente neste mundo pericial, substituindo aos poucos os humanos por um maior poder preditivo, uma maior eficiência e melhores resultados (Goralski e Tan, 2020). No entanto, Harari (2020) afirma que “o homo sapiens não será substituído de uma só vez, mas gradualmente ao longo do tempo, à medida que nos tornamos mais absorvidos pelos sistemas de conhecimento e à medida que a robótica se torna uma parte essencial do nosso corpo e existência humana” (em Goralski e Tan, 2020, p. 2).

Mas, qual será o papel dos humanos, caso as máquinas ultrapassem na globalidade o poder humano? Makridakis (2017) propõe quatro cenários para tentar responder a esta questão: *the optimists* que preveem um cenário utópico no qual os humanos aproveitam a velocidade, as capacidades de memória e a capacidade de partilhar conhecimento dos computadores e do cérebro diretamente conectados à *cloud*; *the pessimits* em que as máquinas ganham o controle efetivo sobre todas as decisões importantes, com pessoas dependentes delas; *the pragmatists* que acreditam que as tecnologias de IA possam ser controladas por meio de "OpenAI" e regulamentação eficaz; e por fim *os doubters* que não acreditam que a IA seja possível e que isso se tornará numa ameaça para a humanidade.

2.2 Sustentabilidade e Sustentabilidade Ambiental

Em 1987, a Brundtland Commission definiu como desenvolvimento sustentável o desenvolvimento que satisfaz as necessidades do presente sem comprometer a capacidade das gerações futuras de satisfazerem as suas próprias necessidades (Keeble, 1987). Este conceito abrange várias áreas, assentando essencialmente num ponto de equilíbrio entre o crescimento económico, a equidade social e a proteção do ambiente (Goodland, 1995).

Morelli (2011) refere-se à sustentabilidade ambiental como atender às necessidades de recursos e serviços das gerações atuais e futuras sem comprometer a saúde dos ecossistemas que as fornecem. A FAO também definiu como uma das principais metas a atingir a nível ambiental: acabar com a fome, alcançar a segurança alimentar e a nutrição melhorada e promover a agricultura sustentável (Nações Unidas, 2015).

A agricultura sustentável envolve, entre outras coisas, construir e manter um solo saudável, minimizar a poluição do ar, da água e do clima, gerir de forma adequada os recursos hídricos e, por último, promover a biodiversidade (Dengel, 2013). Deste modo, será possível atingir o objetivo do desenvolvimento sustentável em relação às necessidades de alimentos e têxteis (Feenstra, 2019). Tal implica que todas as pessoas envolvidas no sistema alimentar, desde produtores, processadores de alimentos, distribuidores, retalhistas a consumidores, podem desempenhar um papel crucial na garantia de um sistema agrícola saudável (Feenstra, 2019).

Com base no relatório da Intel (Brady, 2018), observou-se que decisores empresariais ligados diretamente à sustentabilidade ambiental estão otimistas sobre o poder da IA: 74% dos 200 profissionais inquiridos sobre esta temática concordaram que a IA ajudará a resolver desafios ambientais duradouros. No entanto, os problemas ambientais envolvem geralmente processos complexos que os cientistas ainda não entendem completamente e para os quais temos recursos disponíveis limitados (Goasduff, 2019).

2.2.1 Inteligência Artificial na Sustentabilidade Ambiental

De acordo com Khakurel *et al.* (2018), a IA está incorporada em cinco dimensões de sustentabilidade: social, económica, individual, técnica e, por fim, ambiental. Relativamente a esta última dimensão, os autores acreditam que a IA pode ser uma ferramenta útil para ajudar o ser humano a cuidar melhor do planeta em termos de apoio à gestão de resíduos e/ou poluição, à adoção de veículos autónomos que pode ser um possível ponto de viragem para reduzir as emissões de gases com efeito estufa ou ainda é possível pensar em sistemas de gestão de conhecimento integrados à tecnologia de *deep learning*

(DL) que poderiam ajudar a analisar as imagens de animais capturados por câmaras com sensores de movimento, na natureza. Da revisão de literatura é possível compilar um conjunto de artigos e casos de estudo que destacam a aplicação de IA na resolução de problemas ambientais gerais, como se pode ver no Anexo A.

É notável que a Inteligência Artificial não desempenha apenas um papel crescente no nosso quotidiano, como também pode ser uma ferramenta chave para ajudar a salvar o planeta e torná-lo sustentável (The Guardian, n.d.). De acordo com Rayome (2019), é hoje possível explorar o poder preditivo da IA para criar melhores modelos de processos ambientais orientados a dados, de forma a que seja otimizada a nossa capacidade de estudar tendências atuais e futuras, incluindo a disponibilidade de água, o bem-estar dos ecossistemas e a poluição.

Assim, perceber o potencial da IA para informar a sustentabilidade ambiental e os desafios sociais é a chave para progredir em direção ao objetivo do Desenvolvimento Sustentável, numa corrida apertada com mudanças irreversíveis no nosso planeta (Rayome, 2019). E, um dos grandes objetivos para atingir esta sustentabilidade ambiental tem a ver com a promoção de uma agricultura sustentável.

2.3 Agricultura Sustentável

Em 1995, foram definidos os objetivos da agricultura sustentável num simpósio de três dias intitulado "Agricultura Sustentável e o Projeto de Lei Agrícola de 1995": "(1) manter e aprimorar a qualidade e a produtividade do solo; (2) conservar o solo, a água, a energia, os recursos naturais e o habitat de peixes e animais selvagens; (3) manter e melhorar a qualidade das águas superficiais e subterrâneas; (4) proteger a saúde e a segurança das pessoas envolvidas no sistema alimentar e agrícola; (5) promover o bem-estar dos animais; e (6) aumentar as oportunidades de emprego na agricultura" (Abelson, 1995). Anos mais tarde, Yahya (2018) resumiu os objetivos da agricultura sustentável em três principais: administração ambiental, rentabilidade agrícola e comunidades agrícolas prósperas.

Ao longo do tempo, surgiram várias definições, mas o conceito em torno da sustentabilidade agrícola permanece o mesmo.

Häni, Pintér e Herren (2007) sugerem que a agricultura sustentável adota práticas produtivas, competitivas e eficientes, protegendo e melhorando o meio ambiente e o ecossistema global, bem como as condições socioeconómicas das comunidades locais, alinhadas à dignidade humana. Os autores salientam que não se trata de uma agricultura

sem risco, mas sim de uma agricultura capaz de gerir riscos e manter a sua resiliência diante das mudanças e das inevitáveis surpresas.

Além disso, Bennett *et al.* (2014) afirmam que o caminho em direção a uma agricultura resiliente e sustentável deve atender às necessidades de alimentos e desenvolvimento, da escala local à global, sem destabilizar o sistema terrestre. Os autores sublinham que as políticas e pesquisas para desenvolver uma agricultura resiliente podem melhorar a segurança alimentar e manter um planeta habitável. Também, Delgado *et al.* (2019) partilham da mesma opinião referindo que, embora a definição tradicional de agricultura sustentável se concentre na incorporação de novas práticas que lidam com os serviços do ecossistema, esta nova agricultura sustentável, com foco em tecnologia, transita de um foco de gestão específica do local para a noção de sustentabilidade global.

Assim, a agricultura sustentável pode ser vista como uma condição para aumentar a produção e a qualidade dos produtos agrícolas num nível otimizado sem prejudicar o futuro (Schönfeld, Heil e Bittner, 2018). Tal, pode ser alcançado através do investimento em novas e modernas tecnologias tais como o *big data*, uma vez que pode minimizar o custo e a eficiência dos agricultores e ajuda a alcançar uma agricultura inteligente (Sarker *et al.*, 2019).

Por fim, importa, também, referir que não existe uma definição breve e universalmente aceitável de agricultura sustentável, pois esta é vista com mais frequência como uma filosofia de gestão do que como um método de operação e, como tal, a aceitação ou rejeição de qualquer definição está ligada ao sistema de valores de uma pessoa (Abubakar e Attanda, 2013).

2.3.1 Desafios da Agricultura Moderna

É necessária uma maior compreensão e avaliação dos processos produtivos atuais para focar a produção agrícola em mudanças sociais e económicas que promovam a sustentabilidade (Quintero-Angel e González-Acevedo, 2018). Assim, podemos categorizar em cinco níveis os principais desafios que a agricultura moderna enfrenta: demográfico, ambiental, social, económico e tecnológico.

A nível demográfico, o setor agrícola precisa de garantir alimentos suficientes para uma população global ainda em crescimento (FAO, 2017). De acordo com um relatório recente da ONU, a população mundial de 7,6 mil milhões em 2017 deve crescer para 8,6 mil milhões em 2030, 9,8 mil milhões em 2050 e 11,2 mil milhões em 2100 (United Nations, 2017), um aumento de 13%, 29% e 47%, respetivamente. Por outro lado, os

agricultores fazem parte de uma população cada vez mais envelhecida tornando-se ainda mais difícil para estes se aperceberem dos problemas e conseguirem fornecer soluções certas (Aulbur *et al.*, 2019).

A nível ambiental, o principal problema reside na utilização excessiva de pesticidas (Alix e Capri, 2018). O uso extensivo de fertilizantes, pesticidas e herbicidas, causou uma perda significativa de biodiversidade, uma diminuição da qualidade do solo e a poluição do meio ambiente: nas últimas três décadas, 75% das espécies de insetos foram extintas devido ao uso extensivo destes produtos químicos e o solo tem vindo a perder a sua camada fértil de húmus, o que resulta numa utilização adicional de fertilizantes (Weber, 2019). Estas tendências negativas estão a acelerar o aquecimento global (Sennaar, 2019). Assim, o desafio básico da agricultura sustentável é fazer melhor uso desses recursos internos ao minimizar as entradas externas usadas, regenerando os recursos internos de forma mais eficaz (Coble *et al.*, 2018). Torna-se também fundamental a diminuição do desperdício alimentar (Aulbur *et al.*, 2019). Adicionalmente, a disponibilidade de terras aráveis tende a diminuir em todo o mundo (Milman, 2015), sendo este um desafio crescente na agricultura.

A nível social, aponta-se para o facto de as práticas agrícolas modernas terem mudado consideravelmente em comparação a algumas décadas atrás, o que torna ainda mais difícil para os agricultores explicarem o porquê do que estão a fazer e o que fazem (Bosch, nd.). É de considerar também a falta de conhecimentos e educação formal dos agricultores (Pivoto *et al.*, 2019).

A nível económico, existe uma crescente carga burocrática, o que faz com que os agricultores tenham dificuldades acrescidas para ganhar a vida, devido aos baixos preços dos seus produtos o que leva a que muitos agricultores desistam das suas quintas e os que não desistem tentam expandir e trabalhar com mais eficiência com a finalidade de manter a lucratividade da produção (Rehman *et al.*, 2017). Porém, muitos regulamentos e leis que sobrecarregam os agricultores são onerosos para a economia nacional e, portanto, para o resto da população também (Bosch, nd.).

Por último, tem sido evidente que as tecnologias e as práticas de conservação e regeneração de recursos podem trazer benefícios ambientais e económicos para os agricultores, comunidades e nações, tendo como principal objetivo: obter os maiores rendimentos e lucros económicos possíveis (Rehman *et al.*, 2017). Porém, a tecnologia por si só não resolverá todos os problemas ambientais, pois é necessário que haja também uma abordagem holística, inovação política e um comportamento mais sustentável do

consumidor: as decisões em torno de onde se compra os alimentos e a qualidade e quantidade que se escolhe são cruciais (Weber, 2019). Ademais, o investimento e a adoção de novas tecnologias é um processo lento, uma vez que os agricultores são, por norma, avessos ao risco e precisam de estar convencidos de um retorno claro do investimento para adotar novas tecnologias (Aulbur *et al.*, 2019).

2.4 Aplicações de IA na Agricultura Sustentável

As principais aplicações de Inteligência Artificial na agricultura focam-se essencialmente: na monitorização da cultura e do solo (Elahi *et al.*, 2019); na gestão de ameaças às culturas, como doenças e pragas agravada pela mudança climática, monoculturas e o uso generalizado de pesticidas (Allen, 2018); na melhoria da programação e eficiência da irrigação (Mewes, 2018); e, por fim, na deteção precisa de ervas daninhas nas terras agrícolas, de forma a ajudar a reduzir o uso de pesticidas e proteger o ambiente agrícola (Lin *et al.*, 2017).

O Anexo B propõe uma definição das principais técnicas de IA na agricultura abordadas no estudo.

2.4.1 Gestão do Solo

O solo forma um aspeto crítico da agricultura bem-sucedida, sendo a fonte original dos nutrientes usados no cultivo, que são posteriormente transferidos para as plantas e de seguida para os seres humanos e os animais (Alreshidi, 2019). Uma gestão inadequada do solo leva à perda de colheitas e a uma qualidade degradada das mesmas (Bannerjee *et al.*, 2018). Assim, um conhecimento sólido de vários tipos e condições de solo aumentará o rendimento das culturas e conservará os recursos do solo (água e nutrientes) de forma a que haja um crescimento e desenvolvimento adequado das culturas (Eli-Chukwu, 2019). Recentemente, abordagens de inteligência artificial foram usadas na seleção de propriedades do solo para investigação de salinidade e previsão de humidade do solo (Kouadio *et al.*, 2018).

2.4.2 Gestão das Culturas

A gestão das culturas começa com a sementeira e continua com a monitorização do crescimento, colheita e armazenamento e distribuição das culturas (Alreshidi, 2019). Detetar e prever o estado de saúde das culturas são os princípios para uma proteção sustentável e eficiente das mesmas, incluindo abordagens para a discriminação do *stress* biótico das plantas através do *deep learning* capaz de atingir uma faixa de classificação de 95% a 99% (Pantazi, Moshou e Bochtis, 2020b).

De forma a que as medidas de controle necessárias possam ser tomadas a fim de garantir uma agricultura produtiva e sustentável, é importante que haja uma deteção e identificação precisa e rápida de doenças ou infestação de pragas nas culturas de grão (Patrício e Rieder, 2018). Nesse contexto, é mais do que necessário usar as ferramentas inteligentes da agricultura para atender às múltiplas necessidades sociais que têm vindo a surgir em relação às informações confiáveis sobre produtos agrícolas que, conseqüentemente, são capazes de garantir e avaliar a segurança das culturas e dos alimentos (Pantazi, Moshou e Bochtis, 2020a).

Da revisão de literatura foi possível compilar um conjunto de estudos que destacam a aplicação da IA na gestão do solo e culturas presente no Anexo C.

2.4.3 Gestão da Água

O uso eficiente da água na agricultura é um dos mais importantes desafios agrícolas que as tecnologias modernas estão a ajudar a alcançar (Navarro-Hellín *et al.*, 2016). A gestão inadequada da irrigação e do solo levam à perda de colheitas e à qualidade degradada do solo (Bannerjee *et al.*, 2018). Dessa forma, as máquinas treinadas pela IA, conscientes do padrão climático histórico, da qualidade do solo e do tipo de culturas a serem cultivadas, podem automatizar a irrigação e aumentar o rendimento geral (Dharmaraj e Vijayanand, 2018). Quase 70% dos recursos de água doce do mundo são utilizados para irrigação, essa automação pode economizar água e beneficiar os agricultores (Perea *et al.*, 2018). Pelo que, os processos agrícolas inteligentes e sustentáveis devem concentrar-se em técnicas novas e eficientes para melhorar a produtividade agrícola, que promovem economias consideráveis em termos de consumo de alimentos e água desperdiçada (Alreshidi, 2019).

O Anexo D, apresenta um conjunto de estudos que destacam a aplicação da IA na gestão da água.

2.4.4 Gestão das Ervas Daninhas

As ervas daninhas constituem uma das principais ameaças a todas as atividades agrícolas (Eli-Chukwu, 2019). A erva daninha reduz consistentemente o lucro e a produtividade esperada dos agricultores (Harker, 2001). De facto, com base num relatório observa-se uma redução de 50% no rendimento de grãos secos e milho se a infestação de ervas daninhas não for controlada (Harker, 2001). Há uma perda de cerca de 48% na produção de trigo devido à competição de ervas daninhas (Fahad *et al.*, 2015).

A FAO estima que, coletivamente, pragas, ervas daninhas e doenças causam a destruição de cerca de 40% das culturas, sendo que os danos são causados principalmente por insetos, seguidos de patógenos e ervas daninhas (Panda, 2019). Atualmente, a perda estimada de rendimento devido às ervas daninhas é de 9%, sendo aproximadamente 3,334M de euros o custo de todos os herbicidas utilizados, 41,5% do total de vendas de pesticidas e 40% do custo de todos os produtos químicos aplicados em terras agrícolas na Europa (Pérez-Ortiz *et al.*, 2016). De forma a reduzir o uso de herbicidas, é necessário que haja uma deteção em tempo real das ervas daninhas através de sensoriamento e uma identificação por *machine learning*, possibilitando assim um tratamento específico do local com alta precisão (Pantazi, Moshou e Bocthis, 2020b). Pelo que, métodos modernos de IA estão a ser aplicados, de forma a minimizar a aplicação de herbicida através da gestão adequada e precisa de plantas daninhas (Bannerjee *et al.*, 2018).

Da revisão de literatura é possível compilar um conjunto de estudos que destacam a aplicação de IA na gestão das ervas daninhas como se pode ver no Anexo E e a aplicação de IA em robótica agrícola na gestão de ervas daninhas presente no Anexo F.

2.4.5 Gestão das Doenças e pragas

Detetar e gerir a propagação de pragas e doenças é, também, um dos aspetos mais cruciais da agricultura uma vez que as pragas e doenças representam ameaças existenciais à produção agrícola e causam a perda de mil milhões de dólares todos os anos (Charania e Li, 2020).

As pragas consistem em qualquer criatura viva que seja invasiva ou danifique as culturas, animais ou estruturas humanas, surgindo de forma geral em grandes quantidades, em detrimento dos produtos agrícolas (Alreshidi, 2019). Por conseguinte, torna-se vital controlar e monitorizar estas criaturas pelo meio das tecnologias de IA para evitar doenças graves, incluindo peste e malária, bem como doenças de plantas e animais (Goedde *et al.*, 2020). O reconhecimento de padrões baseado na visão e a utilização de sistemas de DL para identificar plantas e detetar doenças não são conceitos novos (Ampatzidis, 2018). A *machine vision* (MV) e a IA podem ser usadas para distinguir entre uma variedade de doenças com sintomas semelhantes e reduzir o tempo e o custo do diagnóstico (Abdulridha *et al.*, 2018). Por outro lado, a análise de dados agrícolas de *drones* e sensores pode fornecer informações e orientações úteis sobre irrigação, pragas e doenças das culturas e apoiar a aplicação precisa de fertilizantes em tempo real (Lakshmi e Corbett, 2020). Os Anexos G e H apresentam respetivamente um resumo da aplicação de IA na gestão de doenças e pragas.

2.5 Desafios e Oportunidades da Adoção de IA na Agricultura

As seguintes Tabelas 1 e 2, consistem num resumo dos tópicos abordados ao longo da revisão de literatura assim como alguns fatores adicionais. Os elementos encontrados serão usados como base para a construção do guião de entrevista como se pode ver abaixo:

Tabela 1 – Desafios da Adoção de Inteligência Artificial na Agricultura

Variável	Desafios da adoção de IA	Autores	Pergunta
Ambiental	Disponibilidade de terras cultiváveis. - A disponibilidade de terra ajuda a reduzir as restrições de liquidez enfrentadas pelas famílias, reduzir a aversão ao risco e também determinar o ritmo de adoção, uma vez que os grandes proprietários de terra serão, provavelmente, os primeiros a adotar a tecnologia.	Rehman <i>et al.</i> (2017); Milman (2015)	2. Acha que ainda existe uma barreira na adoção de IA por parte do setor agrícola? 2.1 Se sim, qual/quais e porquê?
	Utilização excessiva de pesticidas e fertilizantes	Weber (2019); Alix e Capri (2018)	
	Melhor uso dos recursos internos ao minimizar as entradas externas usadas	Coble <i>et al.</i> (2018)	
Social	Falta de conhecimentos e educação formal	Pivoto <i>et al.</i> (2019); Lawal e Oluyole (2008)	6. A nível social (agricultores), considera que falta algo para entender os desafios e oportunidades destas 'novas' tecnologias de IA? 8. O que considera que falta para que as implementações de IA sejam mais numerosas e continuadas na agricultura?
	Efeitos do ciclo de vida	Aulbur <i>et al.</i> (2019) ; Rehman <i>et al.</i> (2017)	
	Agricultores mais velhos são mais avessos ao risco e céticos em relação aos potenciais benefícios do que os agricultores mais jovens	Aulbur <i>et al.</i> (2019); Castle, Lubben e Luck (2016)	
	Falta de familiaridade e habilidades com a tecnologia	Kumar (2019)	
Influência Social	A influência social influencia positivamente a intenção de adoção de IA	Geli <i>et al.</i> (2019)	7. O que considera que pode influenciar positivamente a intenção de adoção de IA na agricultura?
	A influência social também medeia totalmente a influência da utilidade e facilidade de uso percebidas	Fox <i>et al.</i> (2018)	
Económico	Os agricultores podem abandonar as tecnologias se os benefícios esperados ou retorno do investimento da adoção forem inferiores aos custos prevacentes/vigentes	Geli <i>et al.</i> (2019)	4. Qual considera que seja(m) o(s) principal/principais desafio(s) da adoção de IA na agricultura a nível económico e porquê?
	Altos custos das ferramentas e alto custo inicial associado à implementação da IA	Kumar (2019); Prasad <i>et al.</i> (2018)	
	A mudança de preços dos produtos agrícolas é um fator importante na adoção de tecnologias agrícolas	Rehman <i>et al.</i> (2017)	
	Alto custo dos robôs agrícolas	Popa (2011)	

Variável	Desafios da adoção de IA	Autores	Pergunta	
Dados	Excesso de dados pode levar a que informações valiosas sejam mascaradas pelo ruído.	Saiz-Rubio e Rovira-Más (2020)	5.1 Que tipos de desafios se enfrenta internamente a nível da sua gestão?	2. Acha que ainda existe uma barreira na adoção de IA por parte do setor agrícola? 2.1 Se sim, qual/quais e porquê? 8. O que considera que falta para que as implementações de IA sejam mais numerosas e continuadas na agricultura?
	Dados indisponíveis ou inacessíveis provocando lacunas no conhecimento	Tantalaki e Souravlas (2019)		
	O deficit de confiança impede a recolha e a padronização de dados na escala necessária o que dificulta a adoção da tecnologia	Trendov, Varas e Zeng (2019)		
	Agricultores desejam ser pagos pelos seus dados de valor.	Dongoski (2018)		
	Gestão dos dados gerados e à conversão dos mesmos em informações significativas, valiosas e uteis	Wilbur <i>et al.</i> (2016)	5.2 Considera que o <i>big data</i> é um requisito para a IA? 5.2.1 Para além do <i>big data</i> , haverá outros requisitos? Pode classificar a nível de importância?	
	<i>Big Data</i> é um requisito para IA.	Eli-Chukwu (2019)		
	Requisito de treinar pessoas para interpretar os resultados com o aumento das informações/dados de IA.	Smith (2018)		
	Falta de conectividade digital na recolha dos dados agrícolas			

Fonte: Elaborado pelo Autor

Tabela 2 – Oportunidades da Adoção de Inteligência Artificial na Agricultura

Variável	Oportunidades da adoção de IA	Autores	Pergunta
Ambiental	Uso generalizado e redução do uso de herbicidas e pesticidas	Lakshmi e Corbett (2020); Allen (2018); Lin <i>et al.</i> (2017)	1.2 Se não, qual/quais a(s) principal/principais oportunidade(s) que destaca da utilização de ferramentas inteligentes como a inteligência artificial?
	Maior eficiência no uso da água (irrigação), redução do desperdício de água e aumento do rendimento geral.	Lakshmi e Corbett (2020); Alreshidi (2019); Mewes (2018); Dharmaraj e Vijayanand (2018); Perea <i>et al.</i> (2018);	
	Eficácia - colheitas em maior volume e ritmo mais rápido que os trabalhadores humanos.	Saiz-Rubio e Rovira-Más (2020)	
	Gestão e previsão do estado de saúde das culturas incluindo gestão de ameaças às culturas como doenças e pragas para garantir a qualidade da colheita	Pantazi, Moshou e Bocthis (2020b); Pantazi, Moshou, Bocthis (2020a); Eli-Chukwu (2019); Elahi <i>et al.</i> (2019); Patrício e Rieder (2018); Ampatzidis (2018); Abdulridha <i>et al.</i> (2018); Allen (2018)	
	Monotorização solo e culturas: Previsão das propriedades e humidade do solo de forma a aumentar a qualidade dos solos para o crescimento das culturas.	Bayat <i>et al.</i> (2020); Fernandes <i>et al.</i> (2019); Chatterjee, Dey e Sen (2018); Kouadio <i>et al.</i> (2018); Singh e Vitkar (2018); Matei <i>et al.</i> (2017)	

Variável	Oportunidades da adoção de IA	Autores	Pergunta
Ambiental	Gestão da performance da cadeia de abastecimento	Sharma <i>et al.</i> (2020)	1.2
	Ajuda os agricultores a obter mais da terra enquanto utilizam os recursos de maneira mais sustentável	Soffar (2019)	
	Diminuição dos desperdícios de alimentos	Dongoski (2018)	
Social	Pode criar um efeito de integração a nível social e cultural através dos mecanismos de comunicação que fornece	Trendov, Varas e Zeng (2019)	9. Considera que as pessoas no setor agrícola podem temer a perda dos seus empregos devido ao crescimento da IA ou por outro lado, encontrar na IA oportunidades para quebrar o ciclo da pobreza? Se sim, porquê? Se não, porquê?
	A IA atrairá novas pessoas com diferentes habilidades para carreiras na agricultura nas áreas regionais	RIRDC (2016)	
	Melhorará a qualidade de vida dos agricultores, pois automatizará tarefas como o cultivo de culturas e a monitorização do gado, o que reduzirá a pressão nos períodos de pico e criará mais tempo de lazer.		
Económico	Aumento da produtividade e dos rendimentos de forma a manter a sustentabilidade	Sharma <i>et al.</i> (2020) ; Rehman <i>et al.</i> (2017)	4.1 Qual considera que seja(m) a(s) principal/principais vantagem/vantagens da adoção de IA na agricultura a nível económico e porquê?
	Relação custo-benefício	Eli-Chukwu (2019)	
	A rentabilidade é o maior fator motivacional na utilização de ferramentas de agricultura de precisão	Pivoto <i>et al.</i> (2019)	
	Redução dos custos operacionais e custos de produção	RIRDC (2016)	
Dados	Eficiente na monitorização das informações para encontrar soluções rapidamente	Gupta (2019)	3.1 De que forma as soluções baseadas em IA contribuem para atingir estes objetivos?
	Existem dados suficientes que podem ser treinados para fornecer diagnósticos aperfeiçoados para prever com êxito fenómenos novos e complexos e melhores alertas quando algo é detetado	Rayome (2019) Choudhary <i>et al.</i> (2019) Smith (2018)	
	Melhoria da previsão: capacidade de prever o desenvolvimento de produtos e propriedades agrícolas no espaço e ao longo do tempo.		
	Transformar dados em informações acionáveis por diferentes tipos de análise computacional e exigir diferentes graus de processamento de informações humanas		
	Melhorar a extração de informações de imagens aéreas e de satélite	Sirosh (2018)	
Desempenho	Flexibilidade, alto desempenho, alta precisão, robustez, eficiência e sensibilidade	Fernandes <i>et al.</i> (2020); Raja <i>et al.</i> (2020) ; Eli-Chukwu (2019); Fernandes <i>et al.</i> (2019) ; Matei <i>et al.</i> (2017)	
	Tomar melhores decisões de produção que os humanos em tempo real. Otimização de decisões.	Kumar (2019); Prasad <i>et al.</i> (2018); Milioto, Lottes e Stachniss (2018)	
	Recomendações e <i>insights</i> valiosos para o apoio à decisão dos agricultores	Liakos <i>et al.</i> (2018); Prasad <i>et al.</i> (2018)	

Fonte: Elaborado pelo Autor

3. METODOLOGIA

Tendo como objetivo a resposta às questões de investigação: “como pode a IA contribuir para uma gestão sustentável da agricultura?” e “como introduzir o uso de IA na agricultura de uma forma continuada?”, o presente projeto de investigação consiste num estudo exploratório com uma abordagem qualitativa.

3.1 *Análise Qualitativa*

Recorremos à metodologia *mono method qualitative* de modo a obter diversos insights, opiniões e tendências sobre o problema, o que permitiu desenvolver ideias e aprofundar a raiz do objeto de estudo (Kamasak *et al.*, 2017). Além disso, assumimos uma postura epistemológica no âmbito do interpretativismo. Por fim, entrevistas a um painel de peritos, revelou ser a metodologia mais adequada de forma a atingir os objetivos definidos.

3.2 *Entrevistas a painel de peritos*

A escolha da estratégia prende-se com quatro principais razões: (1) a natureza das questões de investigação; (2) o investigador tem pouco ou nenhum controlo sobre os acontecimentos; (3) o foco do estudo é um fenómeno contemporâneo dentro de um qualquer contexto de vida real (Yin, 2014) e (4) a necessidade de explorar uma situação que não está bem definida (MacNealy, 1997). Uma outra componente a ter em conta é a definição da unidade de análise, sendo que esta está relacionada com os objetivos a alcançar (Yin, 2014). Visto que no presente estudo se pretende compreender o impacto da inteligência artificial no setor agrícola, a unidade de análise definida é a organização.

Para tal, como fonte de informação para o estudo empírico do projeto realizou-se um conjunto de entrevistas semiestruturadas a peritos. Apesar de consumirem algum tempo, o uso de entrevistas pode ajudar a recolher dados válidos e confiáveis, relevantes para as perguntas e objetivos de pesquisa (Saunders *et al.*, 2009). O uso de entrevistas semiestruturadas incide nos seguintes aspetos: o objetivo da pesquisa; a importância de estabelecer um contacto pessoal; a natureza das questões de recolha de dados; e o período necessário e integridade do processo (Saunders *et al.*, 2009).

A realização das entrevistas teve como pressuposto a garantia de confidencialidade dos entrevistados uma vez que os participantes podem sentir-se mais confortáveis em concluir uma entrevista se tiverem alguma garantia de que o pesquisador não revelará as informações fornecidas (Coffelt, 2017). O principal interesse é agregar as informações que

as pessoas fornecem, independentemente da pessoa específica que as forneceu (Coffelt, 2017).

Assim, na Figura 1 apresenta-se o conjunto de procedimentos utilizados para a elaboração deste trabalho, devidamente detalhados a seguir.

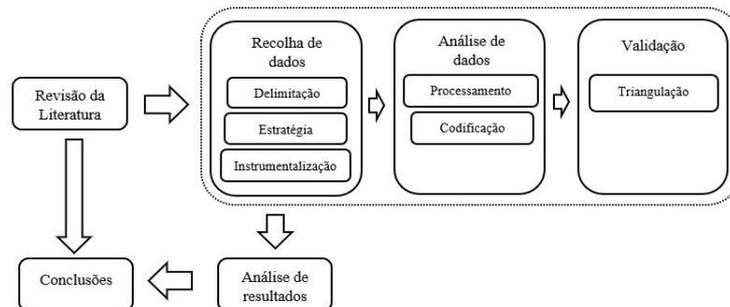


Figura 1 – Etapas Metodológicas
Fonte: Elaborado pelo autor

3.3 Recolha de Dados

A Figura 2 sintetiza as opções dos passos seguidos durante a recolha de dados:

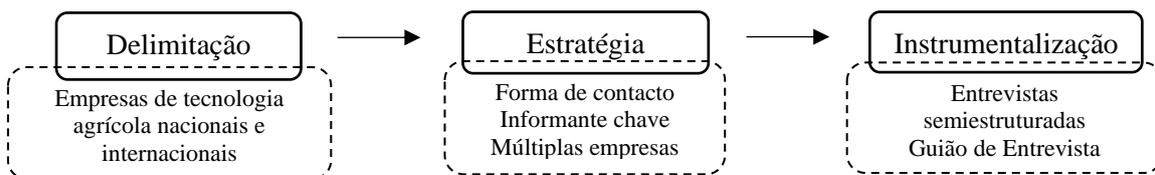


Figura 2 – Resumo da Etapa de Recolha de Dados
Fonte: Elaborado pelo autor

A recolha de dados do presente estudo de investigação envolveu três etapas interligadas entre si e devidamente apresentadas no capítulo 4. : (1) conversa com expert na área de inteligência artificial diretamente ligado à agricultura; (2) análise exploratória dos dados publicados e partilhados nas redes sociais (Facebook e LinkedIn) e páginas de internet (páginas oficiais das empresas de tecnologia agrícola (AgTech)); e (3) entrevistas aos peritos da amostra selecionada.

A recolha de dados foi limitada a empresas de tecnologia agrícola maioritariamente nacionais decorrente do propósito de investigação. As formas de contacto estabelecidas foram o *e-mail* e o LinkedIn. Foi realizada uma única entrevista às empresas de AgTech que aceitaram colaborar na investigação, no qual o entrevistado foi considerado um informante-chave: pessoa considerada conhecedora do funcionamento da organização como um todo (Yin, 2014). As entrevistas foram realizadas virtualmente devido à pandemia Covid-19.

A recolha foi instrumentalizada através de entrevistas semiestruturadas, isto é, embora o investigador tenha uma lista de temas e perguntas a serem abordadas, estas podem variar de entrevista para entrevista (Saunders *et al.*, 2009). Tal significa que algumas perguntas foram omitidas em determinadas entrevistas, considerando um contexto organizacional específico encontrado em relação ao tópico da pesquisa. Por outro lado, a ordem das perguntas variou, dependendo do fluxo da conversa e algumas perguntas adicionais foram colocadas a fim de explorar a pergunta e os objetivos de pesquisa (Saunders *et al.*, 2009). As entrevistas foram conduzidas com base no Anexo I – Guião de Entrevista, que decorreu da revisão de literatura como se pode ver pelas Tabelas 1 e 2, do subcapítulo 2.5. As entrevistas foram gravadas através da respetiva aplicação de videoconferência, Zoom, e por vezes através do gravador do telefone devido a problemas técnicos.

Antes de iniciar as perguntas do guião, foi feita uma breve apresentação pessoal, enquadrando sempre o entrevistado na investigação, apresentando os objetivos e a condução dos trabalhos. Após dar lugar a dúvidas, foi garantida a confidencialidade e a obtenção de autorização de gravação da entrevista. De seguida, foi aplicado o guião semiestruturado e no final de cada entrevista, alguns dados sociodemográficos foram recolhidos.

3.4 Análise de dados

A análise de dados ajuda a definir a direção da recolha de dados e ocorre durante a sua recolha e também depois desta (Saunders *et al.*, 2009). Na Figura 3 estão resumidas as diferentes etapas seguidas na análise de dados:

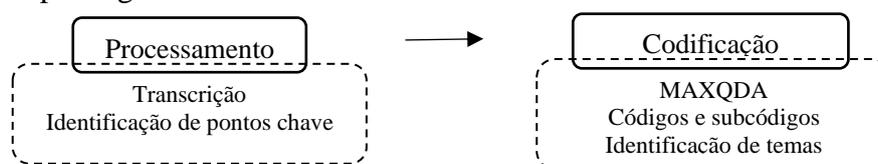


Figura 3 – Resumo da Etapa de Análise de Dados

Fonte: Elaborado pelo autor

Cada entrevista foi gravada em áudio e posteriormente transcrita em documentos de texto MS Word devidamente separados e identificados, mantendo a confidencialidade e o anonimato. É relevante enfatizar que se transcreveu não só o que os entrevistados disseram, mas também a maneira como o disseram, dando indicação do tom em que foi dito e comunicações não verbais (Saunders *et al.*, 2009). Conseqüentemente, devido ao processo demorado da transcrição (cerca de 12 horas para gravações de 1 hora) e a fim de

evitar um acúmulo de gravações áudio e de trabalho associado, as entrevistas foram transcritas à medida que foram realizadas. Em alguns casos, utilizou-se a ferramenta do Google Docs “entrada vocal” de forma a economizar tempo no processo de transposição de texto. É importante também salientar que se realizou uma limpeza de dados, de forma a certificar que a transcrição seja precisa, corrigindo quaisquer erros de transcrição (Saunders *et al.*, 2009).

Posteriormente listou-se os pontos chave para cada entrevista transcrita, de forma a identificar os principais temas que surgiram e explorá-los mais detalhadamente na etapa seguinte: a codificação. O processo de categorização ou codificação dos dados consiste em desenvolver categorias e, subsequentemente, anexar essas categorias a blocos de dados significativos. Estas categorias são denominadas por códigos. Este processo permite examinar e organizar as informações contidas em cada entrevista e em todo o conjunto de dados (Green *et al.*, 2007). Tal permite reconhecer relações entre os dados como também desenvolver e testar proposições, permitindo tirar conclusões e analisar quantitativamente (Saunders *et al.*, 2009). No processo de codificação, as categorias concebidas precisam fazer parte de um conjunto coerente, de modo a que forneçam uma estrutura analítica bem delineada para prosseguir com a sua análise (Saunders *et al.*, 2009).

A codificação foi realizada através do *software* MAXQDA desenvolvido para pesquisa qualitativa. Após gerar os códigos realizou-se a próxima atividade de anexar subcódigos a esses códigos. Isto permitiu identificar os principais temas e padrões ou relacionamentos nos dados reorganizados.

3.5 Validação

De forma a validar os dados recolhidos, procedeu-se à triangulação recorrendo às páginas oficiais das empresas de AgTech. Procurou-se, desta forma, a articulação entre os dados empíricos, autores que tratam da temática estudada e a análise exploratória.

Assim, foi possível observar que as principais áreas de atuação de IA focam-se na: monitorização e otimização do uso de água, energia e fertilizantes; prevenção de doenças, fungos e pragas; recolha e centralização de fatores de produção e qualidade das culturas; e recolha e gestão de dados geográficos. É evidenciado que as soluções fornecidas permitem um aconselhamento técnico especializado em tempo real, com vista ao aumento do rendimento do agricultor, à eficiência da sua exploração, e à redução da lacuna de informação com que o gestor agrícola se depara diariamente na sua tomada de decisão. Foi também possível, através de documentos audiovisuais, observar o funcionamento das

ferramentas de IA nos campos nomeadamente as redes de alerta para prevenção de doenças. Encontrou-se assim consistência entre o observado e a informação fornecida pelos entrevistados.

4. APRESENTAÇÃO DE RESULTADOS

A recolha de dados iniciou-se com (1) uma conversa com o diretor executivo de uma *start-up* posicionada em enfrentar os desafios ambientais usando o poder das imagens de satélite e da inteligência artificial, nomeadamente no setor agrícola. Especializado na área de inteligência artificial e com um entendimento sobre a temática, pareceu pertinente pedir conselhos na forma como conduzir a presente pesquisa e alinhar as expectativas. Esta conversa ocorreu no dia 1 de Junho de 2020 e revelou-se fundamental de imediato, uma vez que permitiu esclarecer o foco da pesquisa. Foi recomendado enfocar o estudo sobre os reais benefícios e oportunidades da IA na agricultura ao invés de uma análise pormenorizada das técnicas especificamente utilizadas, destacando assim unicamente as consequências das mesmas. Posto isto, (2) procedeu-se a uma análise das páginas oficiais de empresas de AgTech, fornecidas através de contactos pessoais do investigador e realizou-se uma triagem com base em algumas características como o uso principal de inteligência artificial e a maturidade da empresa (tempo de existência da empresa e desenvolvimento de projetos). Decidiu-se optar por oito organizações diferentes de forma a estabelecer se os resultados do primeiro caso ocorreriam noutros casos e, como consequência, a necessidade de generalizar a partir dessas descobertas (Yin, 2014). Por conseguinte, pesquisou-se os membros dessas empresas através do LinkedIn e analisou-se a sua experiência bem como a especialização com o propósito de refinar a amostra. Por fim, contactaram-se os potenciais entrevistados mediante a utilização de uma mensagem formatada com uma breve apresentação pessoal, explicando o âmbito do estudo, os objetivos, e pedindo disponibilidade para a marcação de uma entrevista.

Deste modo, a constituição do painel teve como principal requisito que os entrevistados tenham uma boa compreensão das tecnologias emergentes de Inteligência Artificial com um bom entendimento da agricultura sustentável.

É importante salientar que todo o painel de peritos foi contactado através do LinkedIn e/ou por *e-mail* com antecedência de forma a explicar a metodologia e os objetivos do estudo para garantir que o tema se adequava ao seu conhecimento e desta forma assegurar a participação neste estudo. Em alguns casos, a empresa forneceu o contacto da pessoa mais adequada para participar na investigação. Por fim, em algumas

entrevistas, quando pedido, foi fornecido o guião de entrevista antecipadamente para reflexão e preparação de respostas. Relativamente à localização geográfica dos peritos: 7 de Portugal e o último entrevistado proveniente do Brasil.

As entrevistas (3) ocorreram de forma remota devido à situação da pandemia Covid-19 e as respetivas normas de segurança. Em alguns casos, certas perguntas foram finalizadas por *e-mail*, salientando que todos os entrevistados confirmaram total disponibilidade para esclarecer qualquer dúvida em relação às respostas dadas. Ainda, todos os entrevistados permitiram a gravação da entrevista e demonstraram interesse em ler o presente estudo quando finalizado.

Todas as entrevistas, exceto uma, foram realizadas através da aplicação de videoconferência Zoom. A sétima, devido a problemas técnicos, foi efetuada através da aplicação Microsoft Teams. Em média, a duração das entrevistas foi de 45 min.

A Tabela 3 apresenta características relacionadas com as entrevistas.

Tabela 3 – Características das Entrevistas

Entrevistado	Empresa	Tipo de Entrevista	Duração
ENT1	Empresa A	Eletrónica - Zoom	34 min
ENT2	Empresa B	Eletrónica- Zoom	1h 03min
ENT3	Empresa C	Eletrónica - Zoom	36 min
ENT4	Empresa D	Eletrónica- Zoom	1h 13 min
ENT5	Empresa E	Eletrónica - Zoom	42 min
ENT6	Empresa F	Eletrónica - Zoom	24 min
ENT7	Empresa G	Eletrónica - Microsoft Teams	47 min
ENT8	Empresa H	Eletrónica - Zoom	37 min

Fonte: Elaborado pelo autor

Quanto à caracterização do painel de acordo com o sexo, do total dos especialistas, todos eram do sexo masculino. Todas as informações relacionadas com os entrevistados são apresentadas na Tabela 4.

Tabela 4 – Caracterização dos Entrevistados

Entrevistado	Sexo (M-Masculino)	Formação Académica	Especialização	Tempo na Empresa	Cargo	Tempo no Cargo
ENT1	M	Engenheiro Agrónomo; Mestre em Engenharia Rural	Engenharia Rural, Hidráulica e Recursos Hídricos	2 anos	Consultor e Diretor Delegado	2 anos
ENT2	M	Licenciado e Mestre em Engenharia Agronómica	Sistemas Agropecuários; Agricultura de Precisão	2 anos	Consultor Agrícola	2 anos

Entrevistado	Sexo (M-Masculino)	Formação Académica	Especialização	Tempo na Empresa	Cargo	Tempo no Cargo
ENT3	M	Licenciado em Ciência da Computação; Mestre em Administração de Empresas; Pós-graduado em Gestão	Ciência de Dados	4 anos	Sócio/Diretor	4 anos
ENT4	M	Mestre em Matemática e Ciência da Computação; Administração de Empresas, Estratégia e Marketing	Inteligência Artificial; Estratégia	3 anos	Diretor Executivo	3 anos
ENT5	M	Licenciado em Engenharia Agronómica; Mestre em Produção Agrícola Tropical; Doutor em Engenharia Rural; Gestão de Operações Agrícolas.	Agricultura de Precisão; Análises de Sistemas Agrícolas; Modelos de Simulação	7 anos	Docente/Professor	7 anos
ENT6	M	Licenciado em Engenharia Aeroespacial, Aeronáutica e Astronáutica	Empreendedorismo e Criação de Empresas; Criação de <i>Drones</i> Agrícolas; Tecnologias; Inovação	6 anos	Diretor Geral/Responsável	6 anos
ENT7	M	Mestre em Engenharia de Telecomunicações e Informática	Informática	1 ano	Gestor de Projeto	1 ano
ENT8	M	Licenciado em Biologia Vegetal - Fisiologia	Agricultura de Precisão; Tecnologias; Sistemas de Informação Agrícolas; Relvados e Sistemas de Gestão Ambiental	11 anos	Diretor Geral/Gerente	11 anos

Fonte: Elaborado pelo autor

O Anexo J apresenta um resumo do conjunto de códigos que resultaram deste processo, devidamente detalhado, acompanhado de uma matriz de visualização dos códigos em cada entrevista no Anexo K. De forma a suplementar os principais meios de análise dos dados qualitativos discutidos acima, realizou-se uma contagem da frequência em relação aos códigos e subcódigos mencionados pelo total de entrevistados e acrescentou-se também citações dos entrevistados a justificar as suas afirmações.

5. ANÁLISE E DISCUSSÃO DE RESULTADOS

A seguinte análise e discussão dos resultados será feita em duas partes: desafios da IA na agricultura sustentável e oportunidades da IA na agricultura sustentável e de acordo com os três pilares da agricultura sustentável, de forma a manter coerência com o que foi obtido da revisão de literatura, e nomeadamente do resumo do 2.5 permitindo assim identificar relações significativas. Os três pilares referidos foram identificados na revisão de literatura e são: ambiental, económico e social e também a nível dos dados.

5.1 Desafios

A nível ambiental, segundo três entrevistados (ENT1; ENT4 e ENT7), a questão da disponibilidade de terras cultiváveis é um desafio crescente na agricultura. De facto, é dito

que existe a necessidade *“de ter dimensão para se poder tirar proveito do investimento que se faz”* (ENT1) uma vez que quando se tem parcelas pequenas, assim que se quer comprar material novo, torna-se difícil de rentabilizar (ENT4). Isto vai ao encontro do que existe na literatura por Rehman *et al.* (2017) e Milman (2015). Os autores destacam a disponibilidade de terra como sendo uma ajuda para reduzir as restrições de liquidez enfrentadas pelas famílias, reduzir a aversão ao risco e também determinar o ritmo de adoção, uma vez que os grandes proprietários de terra serão, provavelmente, os primeiros a adotar a tecnologia. Este último aspeto é também exposto pelo ENT4. No que toca à aversão ao risco, o ENT7 salienta que *“quando são explorações mais pequenas, o retorno do investimento que têm de fazer nessas tecnologias, às vezes não é imediato, então as pessoas ficam um pouco céticas e preferem continuar a fazer as coisas como têm vindo a fazer”*. Aulbur *et al.* (2019) apontam que os agricultores precisam de estar convencidos de um retorno claro do investimento para adotar novas tecnologias, tal como refere o ENT7 sobre os agricultores que *“pensam que isto é mais uma moda e não veem o benefício real das coisas”*. A parte da dimensão é mais uma vez mencionada pelos ENT2 e ENT6, mas noutras perguntas do guião como mostra a seguinte citação: *“No Norte existem áreas muito pequenas e obviamente nessas áreas muito pequenas é muito difícil pôr lá tecnologia, quer seja inteligência artificial ou outra coisa”* (ENT6).

A nível económico, no que diz respeito à existência de barreiras na adoção, foram inicialmente citados por um lado os custos de acesso das ferramentas tais como os *drones* e todos os custos associados à aquisição destas tecnologias (ENT4). Por outro lado, a mudança dos preços agrícolas foi citada por 60% dos inquiridos como exemplifica a citação seguinte: *“Acontece muito em Portugal, pessoas que estavam muito dedicadas a uma cultura, de repente os preços variam de tal forma que a cultura deixa de ser interessante e passam para outra”* (ENT5). Relativamente à parte do alto custo de acesso e alto custo inicial associado à implementação da IA, os aspetos mencionados pelos entrevistados vão ao encontro do que é dito na literatura por Kumar (2019) e Prasad *et al.* (2018) bem como o alto custo dos robôs agrícolas citado por Popa (2011) como principais desafios económicos. Relativamente à mudança dos preços agrícolas, o entrevistado 3, exemplifica este fator com o caso do Brasil referindo que no país, os grandes produtores *“são produtores de “comodities”, produtos que o valor está fixado para o mercado internacional e você está mais sujeito a essa oscilação do preço que o mercado coloca”*. Realçando que isto *“ajuda ao fenómeno de que a agricultura é mais lenta para adotar a*

inovação porque a competição não é tão grande” uma vez que o “ser um pouco mais ineficiente, não significa a morte do negócio como em outros setores significa!” (ENT3).

De forma a aprofundar a questão económica, quis-se saber especificamente quais os desafios económicos da adoção de IA na agricultura. Observou-se opiniões contrárias. Se, por um lado, a questão dos custos de implementação e das máquinas foi acentuada (ENT1; ENT2; ENT4; ENT6 e ENT7). Por outro lado, 40% dos inquiridos referem a parte económica como não sendo *“de todo o mais importante”* (ENT5). É referido que *“o problema não é económico”* (ENT3) e que *“não vejo a parte de custos de implementação de inteligência artificial como uma coisa por aí além”* (ENT2). Este ponto de vista é fundamentado por serem *“tecnologias que já estão tão disponíveis e quando é trabalhado em grande escala fica bastante acessível”* (ENT7); por se ter *“disponíveis gratuitamente”* dados como as *“imagens de satélite”* e as *“imagens de sentinela”* (ENT5); por haver *“muitos projetos europeus a financiar este tipo de iniciativas e começar a ir por sistemas mais baseados em tecnologia”* (ENT2); e por fim, pelo facto de os serviços poderem ser feitos em *“outsourcing”* fazendo com que seja *“mais vantajoso e menos dispendioso”* (ENT1). Todos estes aspetos, embora não tenham sido mencionados na revisão de literatura, merecem especial atenção por terem sido referidos frequentemente. Existem cada vez mais empresas como a empresa D que desenvolvem o equivalente das medições feitas por “drones” mas utilizando satélite e, em particular, usando dados gratuitos o que permite revender estes serviços aos agricultores a um custo reduzido (ENT4).

A nível social, inicialmente foram identificados quatro principais aspetos tais como a formação escolar, a idade, o ceticismo e adversidade e a mentalidade. Sendo que a questão da formação académica: *“o grande fator limitante para aplicação de inteligência artificial em agricultura é mesmo talvez a parte mais dos experts. Ou seja, a parte académica [...]”* (ENT2) e da mentalidade: *“penso que é o “mindset” do agricultor. Portanto, a mentalidade tem de ser mais empresarial, mais de ir à descoberta, mais de inovação, mais de integração de conhecimento”* (ENT5) foram os mais abordados por 50% dos inquiridos. Posteriormente numa pergunta mais concreta aos desafios sociais, o grau de formação e a mentalidade foram acentuados por respetivamente 75% e 90% dos entrevistados, como sendo elementos fundamentais para a adoção de IA na agricultura: *“sem dúvida que a formação ou a abertura para aprender dessas pessoas é um elemento fundamental”* (ENT7). A falta de educação formal é também apontada na literatura por Lawal e Oluyole (2008) ao invés da mentalidade que não é referida.

Por outro lado, a idade mereceu atenção pela discordância de opiniões. Segundo Aulbur *et al.* (2019) e Castle, Lubben e Luck (2016), agricultores mais velhos são mais avessos ao risco e céticos em relação aos potenciais benefícios do que os agricultores mais jovens. O entrevistado 4 concorda com a afirmação referindo que mais as pessoas são velhas, mais são resistentes à mudança e que os jovens agricultores, os que compram *drones* e serviços, são os que realmente veem a utilidade de todas estas novas tecnologias para otimizar as suas produções. Porém, por experiência própria, o entrevistado 6 diz que *“são pessoas que na realidade, apesar da idade e com muitas dificuldades, adotam sistemas novos e, portanto, não tenho dúvidas que esses também vão adotar coisas de inteligência artificial”*. Assim, observou-se que *“as ferramentas estão pensadas para a utilização generalizada”* (ENT1) e o que é necessário é um *“arranjo” de pessoas capacitadas, agricultores que tenham a sofisticação suficiente para entender, para implementar*” (ENT3). Ou seja, que, apesar das *“pessoas [...] terem sempre resistências à inovação”* (ENT8), a idade não é um fator limitante à adoção de IA no sentido em que *“as coisas são feitas não para serem manobradas por génios, mas para serem de aplicação comum”* (ENT1).

A nível da influência social, Geli *et al.* (2019) acreditam que esta última influencia positivamente a intenção de adoção de IA. Fox *et al.* (2018) acreditam que a influência social também medeia totalmente a influência da utilidade e facilidade de uso percebidas. Do estudo, as empresas, as marcas e universidades aparentam ter um papel fundamental (75%) na disseminação de informação como é exemplificado na seguinte citação: *“[...] passa muito por nós, por empresas como a empresa G, em explicar os benefícios e ir ter com os clientes e explicar em que é que eles vão melhorar e porque é que eles vão melhorar”* (ENT7). Além disso, o trabalho que é feito pelas empresas no que toca à criação de *“exemplos demonstrativos”* (ENT6) permite para um dado cliente analisar a sua produção, os seus gastos e no ano a seguir repetir o mesmo processo, mas com a tecnologia inserida e apresentar uma comparação do retorno e das diferenças (ENT6). É acentuado por 50% dos inquiridos que *“quando partilhamos isto assim com os nossos clientes, eles realmente veem, um caso prático, um caso com valores reais, com uma exploração relativamente do mesmo tamanho, uma cultura relativamente parecida... Quando veem assim a informação mais imediata, mais representativa da realidade deles, vemos que tem uma maior adoção”* (ENT7). Deste modo, os casos de estudo apresentam-se como uma

influência social positiva no que toca à adoção de IA, pois os agricultores têm tendência a adotar as tecnologias se realmente conseguem visualizar os benefícios esperados.

Do diálogo com os entrevistados reteve-se outros aspetos influenciadores para uma adoção mais continuada e universal da IA no setor agrícola. Socialmente foram novamente referidas as questões ligadas à formação académica e à mentalidade. É notado que agricultores com *“formação de Engenharia Agronómica ou de Gestão”* (ENT2) faz com que já tenham *“outra capacidade, não diria de inteligência ou mental, mas têm outro à vontade, já nadam nessa área de forma muito mais natural e percebem os conceitos e percebem o que é que isso pode trazer”* como refere o ENT2. E por outro lado é *“preciso ter produtores abertos a começarem a experimentar”* (ENT6). Além disso, a questão da utilidade percebida por toda a cadeia alimentar (Fox *et al.*, 2018) e não unicamente pelo agricultor é apontada pelo ENT8: *“o que pode ajudar é que essa percepção seja real para o agricultor e para todos os interlocutores. Todos os interlocutores na agricultura, não é só o agricultor.”*

Por fim, os últimos dois fatores influenciadores desta adoção são por um lado a parte económica dos custos que podem representar um desafio uma vez que apesar de existirem sensores (*drones* e satélite), as soluções de análise são por vezes muito caras para pequenas e médias explorações (ENT4). Ou ainda *“a capacidade, muitas vezes, dos agricultores, em termos financeiros de fazerem o investimento”* (ENT7). Por outro lado, as políticas foram bastante (60%) apontadas como sendo um incentivo a uma adoção mais rápida. O ENT5 diz que : *“O que se está a trabalhar neste momento, é para que, através da Política Agrícola Comum (PAC), se verifiquem apoios, que ainda estão a ser estudados como fazê-lo, de forma a que dê os estímulos certos para que a adoção se faça de forma mais acelerada”*.

A nível dos dados, de acordo com Eli-Chukwu (2019), o *big data* é um requisito para IA. Na pesquisa verificou-se por 50% dos entrevistados que *“o big data é fundamental na agricultura”* (ENT5). Este *big data* é visto como uma ajuda para a IA *“porque a inteligência artificial torna-se precisa quanto mais dados existirem”* (ENT8). Porém, o perito em ciência de dados afirma que *“é possível fazer ciência de dados na agricultura com e sem big data”* (ENT3). No entanto, admite que *“a capacidade de lidar com big data vai ser um diferencial bem importante”* porque *“em breve vai precisar do big data, sim, porque são muitos dados. Muita informação”* (ENT3). O que leva a que se necessite *“muito, muito, muito de agrónomos com essa capacidade de análise e de tratamento desses*

dados” (ENT5). Tal como se verifica em Smith (2018) que aponta o requisito de treinar pessoas para interpretar os resultados com o aumento das informações de IA.

Relativamente à quantidade de informação, na literatura notou-se que o excesso de dados representa um desafio pois pode levar a que informações valiosas sejam mascaradas pelo ruído (Saiz-Rubio e Rovira-Más, 2020). A quantidade de dados é referida por 60% dos peritos como se pode verificar na seguinte citação: “[...] *estamos a conseguir medir tanta coisa que às tantas temos toneladas de informação e já nem sabemos o que fazer com ela porque são coisas a mais*” (ENT6). Isto faz com que haja uma necessidade de limpeza dos dados de forma a eliminar ruídos existentes: “[...] *muitas vezes esses dados não estão bem estruturados. Muitas vezes têm muito ruído. Dados a mais. Têm de ser limpos*” (ENT7). Por outro lado, de acordo com o ENT2, devido às “*heterogeneidades de solos*”, às “*diferenças que há de climas de região para região*”, à “*reação das culturas a cada um dos regimes*” o *big data* “*vai ser a parte essencial*” pela simples razão de não ser possível “*espelhar*” um modelo de uma região para “*o mesmo tipo de cultura*” noutra região. Existe assim o desafio de “*tratar os dados e a qualidade dos dados*” (ENT8).

No que toca à gestão dos dados gerados e à conversão dos mesmos em informações significativas, valiosas e úteis (Wilbur *et al.*, 2016), o ENT7 refere o mesmo, relatando em forma de questão que, para além do *big data*, falta a parte de: “*como é que tu trabalhas esse output para ser fácil aos agricultores de porem em prática*” uma vez que “*se não souberes tirar as relações desses dados, se não souberes pôr os dados a funcionar para ti, não é assim tão mais valioso e não te vai ajudar assim tanto*” (ENT7). O que exige a “*capacidade de trabalhar esses dados e tirar dali inteligência artificial e o data mining*” (ENT5). E a respeito da fidedignidade dos dados surge o desafio da falta de ter “*des vérités de terrain*” (ENT4), ou seja, uma base de dados de referência de forma a ver se os modelos previstos correspondem à realidade, como mencionado pelo ENT4. O que leva à necessidade de haver uma “*congregação dos dados numa base de dados comum*” (ENT5) de forma a que todos tenham acesso e que possam ser desenvolvidos modelos cada vez mais competitivos (ENT4). O principal motivo da integração dos dados é exatamente o que é referido na literatura sobre o desafio da indisponibilidade e inacessibilidade dos dados por Tantalaki, Souravlas e Roumeliotis (2019). De acordo com os peritos existe um “*manancial de dados*” (ENT2) que podem ser recolhidos, porém na maioria das vezes são disponibilizados pelos clientes e não de acesso comum (ENT4). O que leva a um problema dito apenas pelo ENT8 sobre a propriedade intelectual dos dados: “*são tudo áreas difíceis de proteger em termos de propriedade intelectual*” pelo que “*as empresas têm muito*

cuidado e pouca margem para grandes investimentos em inovação porque tudo é facilmente copiável e não se pode proteger” (ENT8).

O último desafio referido na literatura é a falta de conectividade digital na recolha dos dados agrícolas (Smith, 2018) representando um problema *“em meio rural muito, muito, muito grande.”* (ENT5). Por outro lado, um aspeto não referido na literatura, tem a ver com o custo ambiental da gestão deste grande volume de dados que está associado ao consumo de eletricidade dos centros de dados (ENT4). O ENT4 refere que uma das coisas mais importantes a fazer é garantir que a produção de eletricidade seja limpa.

5.2 Oportunidades

A nível ambiental, o uso eficiente dos fatores de produção foi apontado por sete dos oito entrevistados como a principal oportunidade da IA na agricultura e a base da sustentabilidade: *“A sustentabilidade tem a ver com o uso eficiente de fatores”* (ENT5). Assim, de acordo com mais de metade dos entrevistados, com a IA, *“[...] pode ser generalizado tudo o que são inputs, desde a fertilização, a aplicação de pesticidas, a utilização da água”* (ENT2). De facto, *“se tu perceberes onde é que, realmente, no teu terreno, há maior necessidade de aplicar fertilizante, não tens de aplicar em todo o lado e só aplicas naquela localização”* (ENT7). Também, a nível da água, a IA permite adequar as dotações de água: *“[...] tu consegues, também, em função da cultura que lá vais pôr adequar as dotações de água [...]”* (ENT1). O que vai ao encontro da literatura, uma vez que um dos principais desafios assenta num melhor uso dos recursos internos ao minimizar as entradas externas usadas (Coble *et al.*, 2018). Efetivamente, a IA permite o uso generalizado e redução do uso de herbicidas e pesticidas (Lakshmi e Corbett, 2020; Allen, 2018; Lin *et al.*, 2017). E por outra parte, as máquinas treinadas pela IA podem automatizar a irrigação e aumentar o rendimento geral (Lakshmi e Corbett, 2020; Dharmaraj e Vijayanand, 2018; Mewes, 2018) de forma a controlar o fluxo de água e, assim, reduzir o desperdício de água, ao monitorizar continuamente o *status* do solo para sustentar a produção agrícola (Singh e Vitkar, 2018). Do estudo, observa-se que este processo *“é muito feito com medições pontuais, medições de condições que depois já se vão modelando com alguma inteligência, vendo modelos e referências, que permitem antecipar necessidades”* (ENT8).

Igualmente, e de encontro à literatura, a IA permite a monitorização da cultura e do solo (Elahi *et al.*, 2019). De facto, é capaz de prever as propriedades e humidade do solo de forma a aumentar a qualidade dos solos para o crescimento das culturas (Bayat *et al.*,

2020; Chatterjee, Dey e Sen, 2018; Kouadio *et al.*, 2018) e assim, “*analisar de forma sistémica o teor de argila que pode variar de um lado para o outro e corrigir essa acidez*” (ENT3). Pelo que “*ao teres a monitorização das condições do solo ao nível do pH, de oxigénio, de arejamento, de água, tu consegues, também, em função da cultura que lá vais pôr adequar as dotações de água e com a qualidade que a água tiver às exigências da cultura e à preservação do solo*” (ENT1), aspeto também mencionado por Fernandes *et al.* (2019) que utilizaram as redes neuronais artificiais (RNA) para prever a matéria orgânica do solo com base no pH, cálcio, magnésio e acidez potencial.

Ainda, e de acordo com 90% dos inquiridos, é possível, “*através da produtividade, ver que há padrões distintos ao longo do terreno que podem indiciar que há carências deste ou daquele elemento*” (ENT1), o que permite “*emendar(es) a mão e atingir(es) depois padrões de qualidade e produtividade superiores*” (ENT1). Através “*de algoritmos e sistemas inteligentes*” (ENT7) é possível criar “*uma rede de alertas*” (ENT7) que diga “*com estas condições meteorológicas, na tua cultura, se estás neste estado fenológico tem cuidado que pode haver este tipo de pestes, ou está propenso a haver este tipo de doenças*” (ENT7) o que permite ao cliente poder “*fazer uma gestão desse tipo de produtos a aplicar*” (ENT7) e ir “*mais direcionado para onde os dados indiquem que existe alguma discrepância, algum problema*” (ENT3). De facto, a IA consegue “[...] *dizer-me com base no histórico de dados que eu tenho anteriores, [...] aconselhar qual será a melhor forma de o fazer*” (ENT2) dando assim “*apoio na tomada de decisão*” (ENT5). Tal vai ao encontro do que Patrício e Rieder (2018) referem sobre a importância de haver uma deteção e identificação precisa e rápida de doenças ou infestantes nas culturas de forma a que as medidas de controle necessárias possam ser tomadas a fim de garantir uma agricultura produtiva e sustentável. Possibilitando assim, de acordo com 40% dos entrevistados e não referido na literatura, um planeamento estratégico da agricultura: “[...] *é assim possível fazer gestão de planeamentos mais antecipados antes da campanha começar*” (ENT8).

A “*IA [...] pode contribuir muito para fazer a correção correta do solo, a gestão correta das pragas*” (ENT3) de forma a que “*não [se] faça uma exaustão do solo*” (ENT3). O “*controlo de infestantes e pragas e doenças é muito mais facilmente gerível, através de inteligência artificial momentânea, ou seja, o reconhecimento por sensores e a aplicação no momento*” (ENT2) e no caso das “*ervas daninhas, são sensores por exemplo de infravermelho que estão instalados nos pulverizadores que registam um sinal e emitem de forma automática para o pulverizador e o pulverizador atua*” (ENT2). Assim como se verifica na literatura, a IA permite uma gestão e previsão do estado de saúde das culturas

incluindo gestão de ameaças às culturas como doenças e pragas para garantir a qualidade da colheita (Pantazi, Moshou e Bocthis, 2020b; Pantazi, Moshou e Bocthis, 2020a; Ampatzidis, 2018)

Relativamente à qualidade da colheita, a IA permite um aumento de eficácia especialmente no que toca a colheitas em maior volume e ritmo mais rápido que os trabalhadores humanos (Saiz-Rubio e Rovira-Más, 2020). No futuro, imaginam-se robôs agrícolas desenvolvidos baseados em inteligência artificial, a efetuar as colheitas, deslocando-se, cortando automaticamente, podando e colhendo (ENT4). Existem também *“semeadores de precisão que com base nessas leituras que nós fazemos [...] chegamos ao fim do ano e ganhamos normalmente meia tonelada que seja por hectare, ganhamos”* (ENT2). Observa-se, também, um aumento de eficiência (Alreshidi, 2019) corroborado por 50% dos entrevistados: *“[...] agora, eu consigo pôr a água certa, consigo pôr o fertilizante certo, e isto vezes não sei quantos mil hectares”* (ENT6) o que faz com que o *“aumento de eficiência é brutal, o aumento de poupança de água por quilo produzido é brutal, de fertilizantes no solo”* (ENT6).

Todos os aspetos acima referidos evidenciam uma vantagem bastante citada nos estudos efetuados sobre o desempenho das técnicas de IA serem capazes de tomar melhores decisões de produção que os humanos, altamente precisas e em tempo real (Raja *et al.*, 2020; Kumar, 2019; Milioto, Lottes e Stachniss, 2018). Além disso, mostra que a inteligência artificial é bastante útil na otimização de decisões, aconselhamento/ apoio à tomada de decisão (Liakos *et al.*, 2018; Kumar, 2019).

A nível económico, a questão do custo-oportunidade é, sem dúvida, a principal vantagem económica apontada no estudo por 75% dos inquiridos. De facto, a *“nível económico é tudo uma relação de custo e oportunidade”* (ENT1) uma vez que *“as coisas têm o custo que têm, desde que me tragam o retorno do capital [...]”* (ENT2) já que o mais importante é que se *“tenha benefícios ambientais, mas que isso não seja um custo para ele [agricultor]”* (ENT8). Esta relação custo-benefício é por sua vez apontada por Eli-Chukwu (2019) na literatura. Do mesmo modo, a rentabilidade é o maior fator motivacional na utilização de ferramentas de agricultura de precisão (Pivoto *et al.*, 2019). Decerto, *“se a tecnologia não melhorar a rentabilidade no fundo [...] não é adotada”* (ENT6). Sharma *et al.* (2020) e Rehman *et al.* (2017) apontam que as ferramentas de Inteligência Artificial na agricultura permitem o aumento da produtividade e dos rendimentos de forma a manter a sustentabilidade. De facto, a sustentabilidade da agricultura através da IA vai permitir

uma agricultura orgânica mais eficiente: um melhor rendimento por hectare e uma melhor eficiência económica, como assinala o ENT4. O ENT7 refere também que *“às vezes não é produzir mais, é produzir o mesmo ou um bocadinho menos, mas que tenhas de ter 1/3 dos inputs e aí a tua produtividade já aumenta bastante”* sendo que *“isso traduz-se em rendimento para o agricultor”* (ENT5). Esta tecnologia permite que se consiga *“pôr a água certa, [...] pôr o fertilizante certo, e isto vezes em não sei quantos mil hectares”* (ENT6) o que leva a *“promover uma melhor produtividade no fim do ano”* (ENT2). É ainda realçado que, *“a agricultura de precisão e a inteligência artificial vêm aumentar imenso a eficiência da exploração”* (ENT6) porque *“ao aumentar a eficiência reduz-se o consumo de fatores de produção e aumenta-se os quilos que se produz, portanto, ao vender os quilos, está-se a ganhar mais [...]”* (ENT6). Assim, *“há um uso mais eficiente dos fatores”* (ENT5), bem como *“um aumento da eficácia”* (ENT2) que é muito referido pelos inquiridos (ENT1; ENT2; ENT4; ENT5; ENT6; ENT7 e ENT8).

Por outro lado, a parte da redução dos custos operacionais e custos de produção (RIRDC, 2016) não foi diretamente referido nesta questão. Sendo apenas dito pelo ENT2 que *“pela via dos custos não é por aí que nós vamos ganhar”* pois *“nós vamos gastar muito mais dinheiro ou pelo menos vamos gastar o mesmo dinheiro que gastávamos antigamente de uma forma convencional”* (ENT2). Porém, na questão das vantagens ambientais, o ENT5 refere que se vai *“gastar menos dinheiro nos custos de produção”* o que vai ao encontro de RIRDC (2016). A última oportunidade económica da IA na agricultura tem a ver com os seguros paramétricos, pormenorizada pelo ENT4 e não falada na literatura. Baseado em inteligência artificial, permite, usando o exemplo do índice de humidade no solo, detetar automaticamente através de satélite, se a quantidade de água numa cultura é suficiente para que a cultura esteja em condições para colheita no próximo mês (por ex.) (ENT4). Caso se verifique falta de água por satélite, o agricultor é automaticamente reembolsado. Isto permite, ao contrário dos seguros clássicos, que o agricultor seja reembolsado diretamente sem a necessidade de um técnico se deslocar para fazer uma análise dos danos e reembolsar consoante o constatado, o que implicaria custos de deslocação e demora no processo de solução (ENT4).

A nível social, do estudo, não foi possível reter nenhuma informação acerca das oportunidades da IA referidas na literatura, sendo apenas dito por 60% dos inquiridos que o agricultor é essencial mesmo com a existência de IA, pois *“[...] é preciso ter sempre alguém a ir validando, a ir confirmando e a ir ajustando”* (ENT6). No entanto, metade dos

entrevistados crê que haverá uma mudança das funções do agricultor com a introdução de IA: “[...] o surgimento de robôs agrícolas permite uma agricultura mais sustentável, mas também exigirá a transformação da profissão de agricultor” (ENT4).

A nível dos dados, “[...] a inteligência artificial consegue “mastigar” toneladas de informação e reduzir aquilo para uma ação que ainda por cima vai aprendendo ao longo do tempo e, portanto, vai melhorando” (ENT6). A IA permite que se faça “[...] também análises foliares e [...] fazer uma série de análises à medida que vais trabalhando” (ENT1). Rayome (2019), Choudhary *et al.* (2019) e Smith (2018) concordam afirmando que a IA permite transformar dados em informações acionáveis e melhorar a capacidade de prever o desenvolvimento de produtos e propriedades agrícolas no espaço e ao longo do tempo. Por outro lado, existem dados suficientes que podem ser treinados para fornecer diagnósticos aperfeiçoados para prever com êxito fenómenos novos e complexos e melhores alertas quando algo é detetado (Smith, 2018). Tal se verifica na citação do ENT1: “o conjunto de dados que possamos recolher são sempre fundamentais [...] pelo menos para a atividade agrícola, para prevermos a produtividade, que é o que nos interessa”. No mesmo contexto, estão a ser realizados trabalhos que consistem em: “sabendo índices vegetativos dos anos anteriores, saber qual é que é a produção dos clientes no final do ano e com isso se tivermos essa informação, lá está, fazer previsões de produção para este ano atual” (ENT7). Também, “existem ceifeiras debulhadoras com equipamentos altamente desenvolvidos que permitem fazer o mapeamento da produtividade à medida que vão fazendo a colheita do milho e esse mapeamento pode e dá indicações bastante boas sobre as condições do solo” (ENT1) por exemplo, “se o solo tem poucos nutrientes ou houve uma falha na aplicação de nutrientes, faz o mapeamento desse local, ou uma zona com problemas de drenagem que a produção não foi nada de especial porque houve problemas de drenagem ou falta de água, na afinação das máquinas de rega” (ENT1). Assim, “todos esses dados são importantes para, na campanha seguinte, se emendar a mão e se tentar contornar o problema” (ENT1).

Por fim, a IA é eficiente na monitorização das informações para encontrar soluções rapidamente (Gupta, 2019). Os sensores das ervas daninhas “são sensores por exemplo de infravermelho que estão instalados nos pulverizadores que registam um sinal e emitem de forma automática para o pulverizador e o pulverizador atua” (ENT2). Começa-se também “a ver máquinas de colheitas de fruta, pequenos frutos que utilizam já imagem e reconhecimento de imagem e processamento de sinal que vão revolucionar completamente

essas operações” (ENT5). Os dados apresentam assim um papel fundamental em melhorar a extração de informações de imagens aéreas e de satélite (Sirosh, 2018).

6. CONCLUSÕES, CONTRIBUTOS, LIMITAÇÕES E INVESTIGAÇÃO FUTURA

De forma a responder à questão de investigação: “como pode a IA contribuir para uma gestão sustentável da agricultura?” foi realizado um estudo com recurso à realização de oito entrevistas exploratórias a especialistas que trabalham diretamente com ferramentas inteligentes de IA na agricultura. Assim, verificou-se que para que a sustentabilidade da agricultura seja atingida é necessário existir um elo de sucesso entre sustentabilidade ambiental e sustentabilidade económica e social. Pelo que, identificou-se e sumarizou-se oportunidades da IA mencionadas e descritas em seguida:

A nível ambiental, conclui-se que a IA dá recomendações e *insights* valiosos para o apoio à decisão dos agricultores acerca da utilização dos fatores de produção de forma mais eficiente, a fim de aumentar o rendimento das culturas e conservar os recursos do solo (água e nutrientes) de modo a que haja um crescimento e desenvolvimento adequado das culturas. Tal permite que seja efetuado um planeamento estratégico das operações na agricultura de forma a antecipar qualquer dano à atividade.

A nível económico, é notável um aumento da eficiência que se traduz num melhor rendimento para o agricultor com a utilização de ferramentas de IA. Esta eficiência é conseguida através do uso eficiente dos fatores de produção, podendo significar que se produza o mesmo ou mais, mas sem danificar os solos com utilização excessiva de fertilizantes, pesticidas, água pelo que a produtividade aumenta bastante. A IA na agricultura permite também uma redução dos custos operacionais e de produção, bem como um aumento da rentabilidade que representa um dos principais fatores na adoção. Por fim, os seguros paramétricos baseados em IA permitem ao agricultor não perder o ano de atividade da noite para o dia e poder ser reembolsado a baixo custo e conforme a conduta de boas práticas.

A nível social conclui-se que o agricultor é um elemento-chave na agricultura e essencial mesmo com a existência e o crescimento das tecnologias emergentes de IA.

A nível dos dados, conclui-se que os dados recolhidos são fundamentais pois permitem que a IA consiga, assim, transformar os diferentes sensores que se colocam no campo, quer sejam sensores no solo, *drones* ou satélites e transformar a informação desses

sensores em informação que seja útil e valiosa para o agricultor. Também tem um papel importante na previsão da produtividade, detetar problemas possibilitantes de estragar a atividade e encontrar soluções rapidamente e de forma eficiente. Assim, é necessário trabalhar o *big data*, a quantidade de dados recolhida e ir melhorando, ao longo do tempo, os modelos de acordo com o feedback dos clientes. Também, com uma capacidade de analisar grandes volumes de informação, a IA permite prever a produtividade das culturas, estimar a matéria orgânica do solo, controlar a gestão de ervas daninhas, pragas e doenças com precisão e em tempo real. Também, as ferramentas de inteligência artificial podem automatizar a irrigação e aumentar o rendimento de forma a controlar o fluxo de água e, assim, reduzir o desperdício, ao monitorizar continuamente o *status* do solo para sustentar a produção agrícola. Atingiu-se assim o primeiro objetivo do estudo: analisar as principais características das ferramentas baseadas em IA que permitem uma gestão sustentável da agricultura.

No que toca à segunda questão de investigação: “Como introduzir o uso de IA na agricultura de uma forma continuada?” procurou-se primeiramente apresentar os principais fatores limitadores para a adoção de IA na agricultura (objetivo 2). E identificou-se, fatores a quatro níveis: ambiental; económico; social; e a nível dos dados.

A nível ambiental, a dimensão territorial foi um fator bastante mencionado e pressupõe-se que, quanto menor a dimensão de terra que se tem, mais difícil será a adoção de tecnologias, nomeadamente de inteligência artificial, pois o retorno do capital investido nessa área será mais difícil de rentabilizar e vice-versa. Não sendo, porém, um fator impeditivo da sua adoção, mas sim um fator de incentivo.

Por outro lado, a nível económico, a capacidade financeira dos agricultores é bastante importante assim como a mudança dos preços agrícolas que pode fazer com que os agricultores desistam das suas atividades. Contudo, existem cada vez mais empresas que desenvolvem o equivalente das medições feitas por “drones” mas utilizando satélite e, em particular, usando dados gratuitos o que permite revender estes serviços aos agricultores a um custo reduzido. Assim, o agricultor tem opção de escolha consoante a sua dimensão (tanto a nível de terras como monetário), sendo que, se for um agricultor pequeno, estão a surgir novas soluções baseadas em satélites grátis, serviços em *outsourcing* e ajudas de projetos europeus. Além disso, a questão dos fundos e apoios disponibilizados também representam uma ajuda e devem ser usados de forma atenta e consciente para que a sua utilização seja rentável. Assim, podemos concluir que mesmo que o fator económico seja

ainda muito importante, cada vez mais o custo da inteligência artificial, dos satélites e dos dados, se vai tornando acessível e adequado às necessidades/características de cada um.

A nível social, o facto de a agricultura ser uma prática tão antiga pode fazer com que a abertura para novas atividades mais mecanizadas seja por vezes encarada de forma cética e adversa por parte dos agricultores. Assim, se o agricultor comum, apesar da idade mais avançada, estiver predisposto a alguma coisa, a correr algum risco, a perceber que tem de haver alguma alteração, a querer sair do regime *standard*, então a adoção será muito mais fácil e rápida. Existe, portanto, a necessidade de pessoas de mente aberta e com um certo grau de formação para poderem entender os desafios e oportunidades da utilização de ferramentas de inteligência artificial na agricultura, porque as aplicações estão feitas para serem *user-friendly* e, portanto, fáceis de manusear. Caso haja essa pré-disposição, interesse pelas tecnologias, a idade não será impeditiva para a sua adoção.

De outro modo, e tendo em mente o terceiro objetivo: “compreender até que ponto o volume de dados é um desafio a nível do bom desempenho das ferramentas de IA”, conclui-se ainda que o *big data* revela-se um requisito à inteligência artificial uma vez que a IA é bastante “gulosa” em dados. De modo que, existe a necessidade de recolher muitos dados de forma a se poder testar e modelar sistemas precisos. A recolha de dados na atividade é fundamental, porém representa um desafio pois, devido ao excesso e diversidade de dados existentes, as informações podem surgir com ruídos e com heterogeneidades. Pelo que, é necessário que os dados sejam tratados e nomeadamente limpos para que possam ser convertidos em informações valiosas e úteis ao agricultor. Por fim, apesar de existirem muitos dados, não estão congregados numa base de dados comum, o que dificulta o seu acesso e torna assim indisponíveis dados de referência ao público. Este último ponto levanta questões relativas à dificuldade de proteção dos dados pelas empresas. A falta de conectividade nos meios rurais impede também essa recolha de dados e os custos ambientais da gestão desses dados são um desafio crescente devido ao consumo de eletricidade não sustentável.

Por fim, de forma a responder à segunda questão de investigação, procurou-se “relacionar o papel das universidades e empresas e a adoção de IA na agricultura” (objetivo 4). Conclui-se assim que as empresas, marcas e universidades têm um peso importante na medida em que contribuem para que haja uma disseminação de informação maior através dos casos de estudo e da experimentação, uma vez que os agricultores têm tendência a adotar as tecnologias se realmente conseguem visualizar os benefícios esperados. Por outro lado, é crucial ter pessoas interessadas e de mente aberta para que esta adoção se faça de

forma mais acentuada e continuada na agricultura. Tanto da parte do agricultor, como de empresários que estejam dispostos a acompanhar o agricultor em todas as etapas do processo de forma a que se crie uma ligação de confiança entre todas as partes em causa da cadeia alimentar. E por último, é necessário que se verifiquem apoios por parte da política agrícola, uma vez que os agricultores europeus são movidos por regulamentos (PAC) e incentivos para passar para o biológico.

A principal limitação teve a ver com o facto das entrevistas terem sido efetuadas remotamente e não presencialmente resultante das normas de segurança devido ao período de confinamento da pandemia Covid-19. Esta situação dificultou o contacto e a proximidade com os entrevistados e interferiu na compreensão das objeções feitas aos tópicos do guião. Vários problemas de ligação dificultaram a comunicação, e por conseguinte, o processo de transcrição. No entanto, acima de todas as dificuldades encontradas, é importante referir a amabilidade, simpatia e disponibilidade de todos os entrevistados que aceitaram positivamente o convite para contribuir para este projeto e que apesar da sobrecarga dos seus trabalhos, se dedicaram para dar o melhor de si e partilharam conhecimento de valor.

Tendo sido abordado no estudo a importância das universidades, entre outros, na divulgação de projetos académicos, de forma a que haja uma maior disseminação de informação e um maior interesse pela área da agricultura, este estudo pode fornecer uma base tanto a nível empresarial, bem como a nível académico para pesquisas futuras.

Seria interessante aprofundar o estudo considerando o lado dos agricultores de forma a entender se vai ou não de encontro às opiniões dos empresários e peritos especializados e realizar então uma análise comparativa. A nível social, seria pertinente detalhar as vantagens da IA no dia-a-dia do agricultor. Para além disso, seria interessante alargar o âmbito do estudo a nível internacional para poder comparar as diferentes realidades. Poder-se-ia ainda explorar outras tecnologias que também ajudam a uma agricultura sustentável como a *internet of things* (IoT), ou complementar a técnica de recolha de dados, a observação, indo ao terreno e analisar o trabalho das ferramentas inteligentes de IA, permitindo assim um contacto mais direto com a realidade além da que se tem digitalmente e através da teoria.

REFERÊNCIAS BIBLIOGRÁFICAS

- Abdulridha, J., Ampatzidis, Y., Ehsani, R. e De Castro, A. I. (2018) Evaluating the performance of spectral features e multivariate analysis tools to detect laurel wilt disease and nutritional deficiency in avocado. *Computers and Electronics in Agriculture*. 155. p. 203-211.
- Abelson, P. H. (1995) Sustainable Agriculture and the 1995 Farm Bill. *Science*. 267. p. 1.
- Abubakar, M. S. e Attanda, M. L. (2013) *The Concept Sustainable Agriculture: Challenges and Prospects*. In Proceedings of the 5th International Conference on Mechatronics (ICOM'13). Kuala Lumpur, Malaysia: IOP. p. 1-5.
- Acharya, U. R., Fujita, H., Oh, S. L., Hagiwara, Y., Tan, J. H., Adam, M. e Tan, R. S. (2018). Deep Convolutional Neural Network for the Automated Diagnosis of Congestive Heart Failure Using ECG Signals. *Applied Intelligence*.
- Alix, A. e Capri, E. (2018) Modern Agriculture in Europe and the Role of Pesticides. In Barceló, D. (Ed.) *Advances in Chemical Pollution, Environmental Management and Protection*. Barcelona, Spain: Elsevier Science Publishing Co Inc. 2. p. 1-22
- Allen, A. (2018) *Emerging technologies in agriculture: regulatory & other challenges*. Melbourne: AgriFutures Australia
- Alreshidi, E. (2019) Smart Sustainable Agriculture (SSA) Solution Underpinned by Internet of Things (IoT) and Artificial Intelligence (AI). *International Journal of Advanced Computer Science and Applications (IJACSA)*. 10(5). p. 93-102.
- Ampatzidis, Y. (2018) *Applications of Artificial Intelligence for Precision Agriculture*. [Online]. Disponível em: <https://edis.ifas.ufl.edu/ae529>. [Acedido: 21 Abril 2020]
- Aulbur, W., Henske, R., Uffelmann, W. e Schelfi, G. (2019) *Farming 4.0: How precision agriculture might save the world*. Munich, Germany: Roland Berger GMBH.

- Bannerjee, G., Sarkar, U., Das, S. e Ghosh, I. (2018) Artificial Intelligence in Agriculture: A Literature Survey. *International Journal of Scientific Research in Computer Science Applications and Management Studies (IJSRCSAMS)*. 7(3). p. 1-6.
- Bannerjee, G., Sarkar, U., Das, S. e Ghosh, I. (2017) A Radial Basis Function Network Based Classifier for Detection of Selected Tea Pests. *International Journal of Advanced Research in Computer Science and Software Engineering*. 7(5). p. 665-669.
- Bayat, H., Asghari, S., Rastgou, M. e Sheykhzadeh, G. R. (2020) Estimating Proctor parameters in agricultural soils in the Ardabil plain of Iran using support vector machines, artificial neural networks and regression methods. *Catena*. 189.
- Bennett, E. M., Carpenter, S. R., Gordon, L. J., Ramankutty, N., Balvanera, P., Campbell, B. M., Cramer, W., Foley, J., Folke, C., Karlberg, L., Liu, J., Lotze-Campen, H., Mueller, N. D., Peterson, G. D., Polasky, S., Rockström, J., Scholes, R. J. e Spierenburg, M. (2014) Toward a More Resilient Agriculture. *The Solutions Journal*. 5(5). p. 65-75.
- Bosch, N. (n.d.) *Challenges of Modern-Day Farming*. [Online]. Disponível em: <https://plentiful-lands.com/challenges-of-modern-day-farming/>. [Acedido: 17 Abril 2020].
- Brady, T. (2018) Intel Study: Applying Emerging Technology to Solve Environmental Challenges. [Online]. Disponível em: <https://newsroom.intel.com/editorials/intel-study-applying-emerging-technology-solve-environmental-challenges/#gs.spdeqa> [Acedido: 13 Janeiro 2020]
- Bruinsma, J. (2009). The Resource Outlook to 2050: By how much do land, water and crop yields need to increase by 2050?. In Proceedings of the FAO Expert Meeting. How to Feed the World in 2050. Food and Agriculture Organization of the United Nations, Economic and Social Development Department. Rome, Italy: FAO. pp. 2-29

- Castle, M. H., Lubben, B. D. e Luck, J. D. (2016) Factors Influencing the Adoption of Precision Agriculture Technologies by Nebraska Producers. *Presentations, Working Papers, and Gray Literature: Agricultural Economics*. 49.
- Charania, I. e Li, X. (2020) Smart farming: Agriculture's shift from a labor intensive to technology native industry. *Internet of Things*. 9. p. 1-15.
- Chatterjee, S., Dey, N. e Sen, S. (2018) Soil moisture quantity prediction using optimized neural supported model for sustainable agricultural applications. *Sustainable Computing: Informatics and Systems*.
- Choudhary, S., Gaurav, V., Singh, A e Agarwal, S. (2019) Autonomous Crop Irrigation System using Artificial Intelligence. *International Journal of Engineering and Advanced Technology*. 8 (5S). p. 46-51.
- Chui, K. T., Lytras, M. D. e Visvizi, A. (2018) Energy sustainability in smart cities: Artificial intelligence, smart monitoring, and optimization of energy consumption. *Energies*. [Online]. 11 (11). Disponível em: <https://scholars.cityu.edu.hk/en/publications/> [Acedido: 28 Novembro 2019]
- Chung, C. L., Huang, K. J, Chen, S. Y., Lai, M. H., Chen, Y. C. e Kuo, Y. F. (2016) Detecting Bakanae disease in rice seedlings by machine vision. *Computers and Electronics in Agriculture*. 121. p. 404-411.
- Coble, K. H., Mishra, A. K., Ferrell, S. e Griffin, T. (2018) Big Data in Agriculture: A Challenge for the Future. *Applied Economic Perspectives and Policy*. 40(1). p. 79-96.
- Coffelt, T. (2017) Confidentiality and anonymity of participants. In M. Allen (Ed.). *The SAGE Encyclopedia of Communication Research Methods*. Thousand Oaks, CA: Sage. 133. p.227-230.

- Cruz, A., Ampatzidis, Y., Pierro, R., Materazzi, A., Panattoni, A., De Bellis, L. e Luvisi, A. (2019) Detection of grapevine yellows symptoms in *Vitis vinifera* L. with artificial intelligence. *Computers and Electronics in Agriculture*. 157. p. 63-76.
- Cruz, A. C., Luvisi, A., De Bellis, L. e Ampatzidis, Y. (2017) X-FIDO: An Effective Application for Detecting Olive Quick Decline Syndrome with Deep Learning and Data Fusion. *Frontiers in Plant Science*. 8 (1741). p. 1-12.
- De Clercq, M., Vats, A. e Biel, A. (2018) Agriculture 4.0: The future of farming technology. The World Government Summit and Oliver Wyman, pp. 1-30.
- DeChant, C., Wiesner-Hanks, T., Chen, S., Stewart, E. L., Yosinski, J., Gore, M. A., Nelson, R. J. e Lipson, H. (2017) Automated Identification of Northern Leaf Blight-Infected Maize Plants from Field Imagery Using Deep Learning. *Phytopathology*. 107 (11). p. 1426-1432.
- Delgado, J. A., Short, N. M., Roberts, D. P. e Vandenberg, B. (2019) Big Data Analysis for Sustainable Agriculture on a Geospatial Cloud Framework. *Frontiers in Sustainable Food Systems*. 3(54). p. 1-13.
- Deluzarche, C. (2019) Deep Learning, le grand trou noir de l'intelligence artificielle. [Online] Disponível em: <https://www.maddyness.com/2019/08/20/ia-deep-learning-trou-noir-intelligence-artificielle/> [Acedido: 21 Junho 2020]
- Dengel, A. (2013) Special Issue on Artificial Intelligence in Agriculture, KI - Künstliche Intelligenz. 27(4), pp. 309–311
- Dharmaraj, V. e Vijayanand, C. (2018) Artificial Intelligence (AI) in Agriculture. *International Journal of Current Microbiology and Applied Sciences*. 7(12). p. 2122-2128.

- Dong, W., Wu, T., Sun, W. e Luo, J. (2018) *Digital mapping of soil available phosphorus supported by AI Technology for precision agriculture*. In Proceedings of the 7th International Conference on Agro-geoinformatics (Agro-geoinformatics'18). Hangzhou, China: IEEE.
- Dongoski, R. (2018) Digital agriculture: enough to feed a rapidly growing world? *EY*. [Online]. 26th April 2018. Disponível em: https://www.ey.com/en_lu/digital/digital-agriculture-data-solutions [Acedido: 5 Abril 2020].
- Dormehl, L. (2019) What is an artificial neural network? Here's everything you need to know. [Online] Disponível em: <https://www.digitaltrends.com/cool-tech/what-is-an-artificial-neural-network/> [Acedido: 21 Junho 2020]
- Ebrahimi, M. A., Khoshtaghaza, M. H., Minaei, S. e Jamshidi, B. (2017) Vision-based pest detection based on SVM classification method. *Computers and Electronics in Agriculture*. 137. p. 52-58.
- Elahi, E., Weijun, C., Zhang, H. e Nazeer, M. (2019) Agricultural intensification and damages to human health in relation to agrochemicals: Application of artificial intelligence. *Land Use Policy*. 83. p. 461-474.
- Eli-Chukwu, N. C. (2019) Applications of Artificial Intelligence in Agriculture: A Review. *Engineering, Technology & Applied Science Research*. 9(4). p. 4377-4383.
- Fahad, S., Hussain, S., Chauhan, B. S., Saud, S., Wu, C., Hassan, S., Tanveer, M., Jan, M. e Huang, J. (2015) Weed growth and crop yield loss in wheat as influenced by row spacing and weed emergence times. *Crop Protection*. 71. p. 101–108.
- FAO (2017) *The future of food and agriculture – Trends and challenges*. Rome: Food and Agriculture Organization of the United Nations.

- Feenstra, G. (2019). What is sustainable agriculture [Online]. Disponível em: <https://asi.ucdavis.edu/programs/ucsarep/about/what-is-sustainable-agriculture> [Acedido: 15 Novembro 2019]
- Ferentinos, K. P. (2018) Deep learning models for plant disease detection and diagnosis. *Computers and Electronics in Agriculture*. 145. p. 311-318.
- Fernandes, M. M. H., Coelho, A. P., Fernandes, C., da Silva, M. F., Bertonha, R. S., de Queiroz, R. F., Furlani, C. E. A. e Fernandes, C. (2020) Estimation of soil penetration resistance with standardized moisture using modeling by artificial neural networks. *Catena*. 189. p. 1-9.
- Fernandes, M. M. H., Coelho, A. P., Fernandes, C., da Silva, M. F. e Marta, C. C. D. (2019) Estimation of soil organic matter content by modeling with artificial neural networks. *Geoderma*. 350. p. 46-51.
- Fox, G., Mooney, J., Rosati, P., Paulsson, V. e Lynn, T. (2018) *Towards an Understanding of Farmers' Mobile Technology Adoption: A Comparison of Adoption and Continuance Intentions*. In Proceedings of the 24th Americas Conference on Information Systems (AMCIS'18). New Orleans, Louisiana, USA: Curran Associates, Inc. p. 1-10.
- Garimella, K., e Fingar, P. (2018). *AI & blockchain*. Tampa, FL: Meghan-Kiffer Press.
- Geli, H., Prihodko, L., Randall, J., Tran, S. C., Cao, H., Misra, S., Boucheron, L., Razzaghi, T., Sandoval, S., Daniel, D., Mora, C. e Arslan, F. (2019) *Climate Adaptive Smart Systems for Future Agricultural and Rangeland Production*. [Online]. August 2019. Disponível em: <https://aces.nmsu.edu/cesfas/documents/artificial-intelligence-in-agriculture---white-paper-with-summary---v6.pdf> [Acedido: 25 Março 2020]

- Ghose, D., Das, U. e Roy, P. (2018) Modeling response of runoff and evapotranspiration for predicting water table depth in arid region using dynamic recurrent neural network. *Groundwater for Sustainable Development*. 6. p. 263-269.
- Goasduff, L. (2019) 3 Barriers to AI Adoption. [Online]. Disponível em: <https://www.gartner.com/smarterwithgartner/3-barriers-to-ai-adoption/> [Acedido: 20 Novembro 2019]
- Goedde, L., Katz, J., Menard, A., e Revellat, J. (2020) Agriculture's connected future: How technology can yield new growth. McKinsey & Company. October, p.1-10.
- Goodland, R. (1995) The Concept of Environmental Sustainability. *Annual Review of Ecology and Systematics*. 26(1). pp.1-24.
- Goralski, M. A. e Tan, T. K. (2020) Artificial intelligence and sustainable development. *The International Journal of Management Education*. 18. p. 1-9.
- Green J., Willis K., Hughes E., Small R., Welch N., Gibbs L. e Daly J. (2007), "Generating best evidence from qualitative research: the role of data analysis." *Australian and New Zealand Journal of Public Health*, Vol. 31 No.6, pp. 545-550.
- Gupta, J. (2019) *The Role of Artificial intelligence in Agricultural Sector*. [Online]. October 2019. Disponível em: <https://customerthink.com/the-role-of-artificial-intelligence-in-agriculture-sector/> [Acedido: 09 Maio 2020].
- Han, L., Haleem, M. S. e Taylor, M. (2015) *A Novel Computer Vision-based Approach to Automatic Detection and Severity Assessment of Crop Diseases*. In Proceedings of the Science and Information Conference (SAI'15). London, UK: The SAI Org. p. 638-644.

- Häni, F. J., Pintér, L. e Herren, H. R. (Eds.). (2007) *Sustainable Agriculture: From Common Principles to Common Practice*. In Proceedings and outputs of the first Symposium of the International Forum on Assessing Sustainability in Agriculture (INFASA). Bern, Switzerland: International Institute for Sustainable Development. p. 1-248.
- Harari, Y. N. (2020) *Homo Deus – História Breve do Amanhã*. 13ª ed. New York, NY: HarperCollins Publishing.
- Harker, K. N. (2001) Survey of yield losses due to weeds in central Alberta. *Canadian Journal of Plant Science*. 81(2). p. 339–342.
- Hoang, N-D. e Bui, D. T. (2017) Slope Stability Evaluation Using Radial Basis Function Neural Network, Least Squares Support Vector Machines, and Extreme Learning Machine.
- Iglinski, H. e Babiak, M. (2017) Analysis of the potential of autonomous vehicles in reducing the emissions of greenhouse gases in road transport. *Procedia Engineering*. 192. p. 353-358.
- Ilie, C., Ploae, C., Melnic, L.V., Cotrumba, R., Gurau, A. M., e Alexandra, C. (2019) Sustainability through the Use of Modern Simulation Methods-Applied Artificial Intelligence. *Sustainability*. 11 (8), pp. 1–19.
- Jha, K., Doshi, A., Patel, P. e Shah, M. (2019) A comprehensive review on automation in agriculture using artificial intelligence. *Artificial Intelligence in Agriculture*. 2. p. 1-12.
- Kamasak, R., Yavuz, M., Kar, A., Baykut, S. (2017) Qualitative methods in Organizational Research: An Example of Grounded Theory Data Analysis. In Christiansen, B., Chandan, H. C. (Eds.). *Handbook of Research on Organizational Culture and Diversity in the Modern Workforce*. United States of America: IGI Global, pp. 23-41.

- Keeble, B. R. (1987) Report of the World Commission on Environment and Development: Our Common Future. United Nations
- Khakurel, J., Penzenstadler, B., Porras, J., Knutas, A. e Zhang, W. (2018) The Rise of Artificial Intelligence under the Lens of Sustainability. *Technologies*. [Online]. 6(4), p. 100. Disponível em: <https://www.mdpi.com/2227-7080/6/4/100> [Acedido: 10 Novembro 2019].
- Kouadio, L., Deo, R. C., Byrareddy, V., Adamowski, J. F., Mushtaq, S. e Nguyen, V. P. (2018) Artificial intelligence approach for the prediction of Robusta coffee yield using soil fertility properties. *Computers and Electronics in Agriculture*. 155. p. 324-338.
- Kumar, V. (2019) The Power of Artificial Intelligence in Agriculture. *Analytics Insight*. [Online]. 16th July 2019. Disponível em: <https://www.analyticsinsight.net/the-power-of-artificial-intelligence-in-agriculture/> [Acedido: 1 Abril 2020].
- Lakshmi, V. e Corbett, J. (2020) *How Artificial Intelligence Improves Agricultural Productivity and Sustainability: A Global Thematic Analysis*. In Proceedings of the 53rd Hawaii International Conference on System Sciences (HICSS'20). Maui, Hawaii: ScholarSpace. p. 5202-5211
- Lawal, J. O. e Oluyole, K. A. (2008) Factors Influencing Adoption of Research Results and Agricultural Technologies among Cocoa Farming Households in Oyo State, Nigeria. *International journal of sustainable crop production (IJSCP)*. 3(5). p. 10-12.
- Li, D. e Du, Y. (2017) Artificial Intelligence with Uncertainty. 2nd ed. [Online]. Beijing, China: CRC Press, Taylor e Francis Group, 9(4), pp. 4377–4383. Disponível em: <https://b-ok.org/book/489485/9f804d> [Acedido: 1 December 2019].
- Liakos, K. G., Busato, P., Moshou, D., Pearson, S. e Bochtis, D. (2018) Machine Learning in Agriculture: A Review. *Sensors*. 18 (2674).

- Lin, F., Zhang, D., Huang, Y., Wang, X. e Chen, X. (2017) Detection of Corn and Weed Species by the Combination of Spectral, Shape and Textural Features. *Sustainability*. 9 (8) p. 1-14.
- Lohr, S. (2018). From Agriculture to Art – the A.I. Wave Sweeps In. *New York Times, Business Day*. [Online]. 21th October. Disponível em: <https://www.nytimes.com/2018/10/21/business/from-agriculture-to-art-the-ai-wave-sweeps-in.html>. [Acedido: 12 Janeiro 2020].
- Ma, B., Li, X., Xia, Y. e Zhang, Y. (2020) Autonomous deep learning: A genetic DCNN designer for image classification. *Neurocomputing journal*. 379. p. 152-161.
- MacNealy, M. S. (1997) Toward better case study research. In *IEEE Transactions on Professional Communication*. 40 (3). pp. 182-196.
- Makridakis, S. (2017) The Forthcoming Artificial Intelligence (AI) Revolution: Its Impact on Society and Firms. *HEPHAESTUS Repository, Neapolis University institutional repository*. 17 January, p. 1-27.
- Marr, B. (2019) *What is AI?* [Online]. Disponível em: <https://www.bernardmarr.com/default.asp?contentID=963> [Acedido: 15 Março 2020]
- Matei, O., Rusu, T., Petrovan, A. e Mihut, G. (2017) *A Data Mining System for Real Time Soil Moisture Prediction*. In Proceedings of the 10th International Conference Interdisciplinarity in Engineering (INTER-ENG'16). Tirgu Mures, Romania: Procedia Engineering. 181. p. 837-844.
- McCool, C., Perez, T. e Upcroft, B. (2017) Mixtures of Lightweight Deep Convolutional Neural Networks: applied to agricultural robotics. *IEEE Robotics and Automation Letters*. 2(3) p. 1344-1351.

- Mewes, J. (2018) Artificial Intelligence And Its Uses In Ag Irrigation. *AgriTech Tomorrow*. (October) Disponível em: <https://www.agritechtomorrow.com/article/2018/10/artificial-intelligence-and-its-uses-in-ag-irrigation/11094> [Acedido: 17 Abril 2020]
- Milioto, A., Lottes, P., Stachniss, C. (2018) *Real-time Semantic Segmentation of Crop and Weed for Precision Agriculture Robots Leveraging Background Knowledge in CNNs*. In Proceedings of the 2018 IEEE International Conference on Robotics and Automation (ICRA'18). Brisbane, Australia: IEEE. p. 2229-2235.
- Milman, O. (2015) Earth has lost a third of arable land in past 40 years, scientists say. *The Guardian*. [Online]. 2nd December. Disponível em: <https://www.theguardian.com/environment/2015/dec/02/arable-land-soil-food-security-shortage> [Acedido: 17 Abril 2020].
- Mohan, A., Parveen, F., Kumar, S. S., Surendran, S., Varughese, T. A. e Nitha, S. (2016). Automatic weed detection system and smart herbicide sprayer robot for corn fields. *Engineering*. 5. p. 55-58.
- Mohanty, S.P., Hughes, D. e Salathé, M. (2016). Using deep learning for image-based plant disease detection. *Frontiers in Plant Science*. 7. p. 1-7.
- Morelli, J. (2011) Environmental Sustainability: A Definition for Environmental Professionals. *Journal of Environmental Sustainability*. [Online]. 1(1), pp. 1–10. Disponível em: <https://www.academia.edu/29505192/> [Acedido: 3 Dezembro 2019]
- Morota, G., Ventura, R. V., Silva, F. F., Koyama, M. e Fernando, S. C. (2018) Big data analytics and precision animal agriculture. *Journal Animal Sciences*. 96(4). p. 1540-1550.
- Munoz, J. M., e Naqvi, A. (Eds.). (2018) *Business Strategy in the Artificial Intelligence Economy*. New York, NY: Business Expert Press.

- Nabavi-Pelesaraei, A., Abdi, R., Rafiee, S. (2014) Neural network modeling of energy use and greenhouse gas emissions of watermelon production systems. *Journal of the Saudi Society of Agricultural Sciences*. 15. p. 38-47.
- Nações Unidas (2015). Conheça os novos 17 Objetivos de Desenvolvimento Sustentável da ONU. [Online]. Disponível em: <https://nacoesunidas.org/conheca-os-novos-17-objetivos-de-desenvolvimento-sustentavel-da-onu/> [Acedido: 03 Janeiro 2020]
- Navarro-Hellín, H., Martínez-del-Rincon, J., Domingo-Miguel, R., Soto-Valles, F. e Torres-Sánchez, R. (2016) A decision support system for managing irrigation in agriculture. *Computers and Electronics in Agriculture*. 124. p. 121-131.
- Nema, M. K., Khare, D. e Chandniha, S. K. (2017) Application of artificial intelligence to estimate the reference evapotranspiration in sub-humid Doon valley. *Applied Water Science*. 7 (7). p. 3903-3910.
- Panda, C. K. (2019) Advances in Application of ICT in Crop Pest and Disease Management. In Egbuna, C. e Sawicka, B. (Eds.) *Natural Remedies for Pest, Disease and Weed Control*. 1st ed. Elsevier Science Publishing Co Inc. p. 235-242.
- Panpatte, D. G. (2018) Artificial Intelligence in Agriculture: An Emerging Era of Research. In proceedings of the 31st Canadian Conference on Artificial Intelligence. [Online]. Anand, India: ResearchGate, pp.1-8. Disponível em: https://www.researchgate.net/publication/328555978_Artificial_Intelligence_in_Agriculture_An_Emerging_Era_of_Research [Acedido: 27 Dezembro 2019].
- Pantazi, X. E., Moshou, D. e Bochtis, D. (2020a) Sensors in agriculture. *Intelligent Data Mining and Fusion Systems in Agriculture*. 1st ed. San Diego, United States: Elsevier Science Publishing Co Inc. p. 1-15.
- Pantazi, X. E., Moshou, D. e Bochtis, D. (2020b) Artificial intelligence in agriculture. *Intelligent Data Mining and Fusion Systems in Agriculture*. 1st ed. San Diego, United States: Elsevier Science Publishing Co Inc. p. 17-101.

- Partel, V., Kakarla, S. C. e Ampatzidis, Y. (2019) Development and evaluation of a low-cost and smart technology for precision weed management utilizing artificial intelligence. *Computers and Electronics in Agriculture*. 157. p. 339-350.
- Patrício, D. I. e Rieder, R. (2018) Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review. *Computers and Electronics in Agriculture*. 153. p. 69-81.
- Perea, R. G., Poyato, E. C., Montesinos, P. e Díaz, J. A. R. (2018) Prediction of applied irrigation depths at farm level using artificial intelligence techniques. *Agricultural Water Management*. 206. p. 229-240.
- Pérez-Ortiz, M., Gutiérrez, P. A., Peña, J. M., Torres-Sánchez, J., López-Granados, F. e Hervás-Martínez, C. (2016) *Machine Learning paradigms for Weed Mapping via Unmanned Aerial Vehicles*. In 2016 IEEE Symposium Series on Computational Intelligence (SSCI'16). Athens, Greece: IEEE. p. 1-8.
- Pivoto, D., Barham, B., Waquil, P. D., Foguesatto, C. R., Corte, V. F. D., Zhang, D e Talamini, E. (2019) Factors influencing the adoption of smart farming by Brazilian grain farmers. *International Food and Agribusiness Management Review*. 22(4). p. 571-578
- Popa, C. (2011) Adoption of Artificial Intelligence in Agriculture. *Bulletin of University of Agricultural Sciences and Veterinary Medicine Cluj-Napoca – Agriculture*. 68(1). p. 284-293.
- Pueyo, S. (2019) Growth, degrowth, and the challenge of artificial superintelligence. *Journal of Cleaner Production*. 197. p. 1731-1736
- Pulido-Rojas, C. A., Molina-Villa M. A. e Solaque-Guzmán L. E. (2016) Machine vision system for weed detection using image filtering in vegetables crops. *Revista Facultad de Ingeniería, Universidad de Antioquia*. 80. p. 124-130.

- Prasad, R., Deo, R. C., Li, Y. e Maraseni, T. (2018) Soil moisture forecasting by a hybrid machine learning technique: ELM integrated with ensemble empirical mode decomposition. *Geoderma*. 330. p. 136-161.
- Quintero-Angel, M. e González-Acevedo, A. (2018) Tendencias and challenges for the assessment of agricultural sustainability. *Agriculture, Ecosystems and Environment*. 254. p. 273-281.
- Raja, R., Nguyen, T. T., Slaughter, D. C. e Fennimore, S. A. (2020) Real-time weed-crop classification and localisation technique for robotic weed control in lettuce. *Biosystems Engineering*. 192. p. 257-274.
- Rajae, T., Ebrahimi, H. e Nourani, V. (2019) A review of the artificial intelligence methods in groundwater level modeling. *Journal of Hydrology journal*. 572. p. 336-351.
- Rajkomar, A., Dean, J. e Kohane, I. (2019) Machine Learning in Medicine. *The New England Journal of Medicine*. 380(14). p. 1347-1358.
- Ramchandran, G., Nagawkar, J., Ramaswamy, K., Ghosh, S., Goenka, A., Verma, A. (2016) Assessing environmental impacts of aviation on connected cities using environmental vulnerability studies and fluid dynamics: an Indian case study. *AI&SOCIETY*. 32. p. 421-432.
- Rayome, A. D. (2019) How AI could save the environment, Tech Republic. [Online] Disponível em: <https://www.techrepublic.com/article/how-ai-could-save-the-environment/> [Acedido: 30 Novembro 2019]
- Rehman, A., Jingdong, L., Khatoon, R., Hussain, I. e Iqbal, M. S. (2017) Modern Agricultural Technology Adoption its Importance, Role and Usage for the Improvement of Agriculture. *Life Science Journal*. 14(2). p. 70-74.

- Rehman, T. U., Mahmud, M. S., Chang, Y. K., Jin, J. e Shin, J. (2019) Current and future applications of statistical machine learning algorithms for agricultural machine vision systems. *Computers and Electronics in Agriculture*. 156. p. 585-605.
- Revanth (2019) Towards Future Farming: How Artificial Intelligence is transforming the Agriculture Industry. [Online]. Disponível em: <https://www.wipro.com/holmes/towards-future-farming-how-artificial-intelligence-is-transforming-the-agriculture-industry/> [Acedido: 16 Outubro 2020]
- Roldán-Serrato, K. L., Escalante-Estrada, J. A. S. e Rodríguez-González, M. T. (2018) Automatic pest detection on bean and potato crops by applying neural classifier. *Engineering in Agriculture, Environment and Food*. 11. p. 245-255.
- Rural Industries Research and Development Corporation (RIRDC) (2016) *Artificial Intelligence*. [Online]. August 2016. Disponível em: <https://www.agrifutures.com.au/wp-content/uploads/publications/16-038.pdf>. [Acedido: 23 Março 2020]
- Russell, S. e Norvig, P. (2010) *Artificial Intelligence: A Modern Approach*. 3rd ed. New Jersey: Pearson Education
- Sahoo, S., Russo, T.A., Elliott, J. e Foster, I. (2017) Machine learning algorithms for modeling groundwater level changes in agricultural regions of the U.S. *Water Resources Research*. 53. p. 3878–3895.
- Saiz-Rubio, V. e Rovira-Más, F. (2020) From Smart Farming towards Agriculture 5.0: A Review on Crop Data Management. *Agronomy*. 10(207). p. 1-21.
- Saunders, M., Lewis, P. e Thornhill, A. (2009), *Research methods for business students*. Pearson education

- Sarker, M. N. I., Wu, M., Chanthamith, B., Yusufzada, S., Li, D. e Zhang, J. (2019) *Big Data Driven Smart Agriculture: Pathway for Sustainable Development*. In Proceedings of the 2nd International Conference on Artificial Intelligence and Big Data Big (ICAIBD). Chengdu, China: IEEE. p. 60-65
- Schönfeld, M. V., Heil, R. e Bittner, L. (2018) Big Data on a Farm – Smart Farming. In Hoeren, T. and Kolany-Raiser, B. (Eds.). *Big Data in Context*. Germany: SpringerBriefs in Law. p. 109-120.
- Sennaar, K. (2019) *AI in Agriculture – Present Applications and Impact*. [Online]. Disponível em: <https://emerj.com/ai-sector-overviews/ai-agriculture-present-applications-impact/> [Acedido: 17 Abril 2020]
- Seyedzadeh, A., Maroufpoor, S., Maroufpoor, E., Shiri, J., Bozorg-Haddad, O. e Gavazi, F. (2020) Artificial intelligence approach to estimate discharge of drip tape irrigation based on temperature and pressure. *Agricultural Water Management journal*. 228.
- Sharma, R., Kamble, S. S., Gunasekaran, A., Kumar, V. e Kumar, A. (2020) A systematic literature review on machine learning applications for sustainable agriculture supply chain performance. *Computers and Operations Research*. 119.
- Shen, Y., Zhou, H., Li, J., Jian, F. e Jayas, D. S. (2018) Detection of stored-grain insects using deep learning. *Computers and Electronics in Agriculture*. 145. p. 319-325.
- Singh, K. K. (2018) *An Artificial Intelligence and Cloud Based Collaborative Platform for Plant Disease Identification, Tracking and Forecasting for Farmers*. In Proceedings of the 7th IEEE International Conference on Cloud Computing in Emerging (CCEM'18). Bangalore, India: IEEE. pp. 49-56.
- Singh, M., e Vitkar, S. (2018) *Automation of Irrigation Monitoring Using Artificial Neural Network*. In Proceedings of the 2nd International Conference on 'Innovative Business Practices and Sustainability in VUCA World'. Mumbai, India: Journal of Business and Management. pp. 43-48.

- Sirosh, J. (2018) *Planet-Scale Land Cover Classification with FPGAs*. In Proceedings of the 24th International Conference on Knowledge Discovery & Data Mining (ACM SIGKDD'18). London, United Kingdom: ACM. pp. 2877-2877.
- Slaughter, D. C., Giles, D. K., Fennimore, S. A. e Smith, R. F. (2008) Multispectral Machine Vision Identification of Lettuce and Weed Seedlings for Automated Weed Control. *Weed Technology*. 22(2). p. 378-384.
- Smith, M. J. (2018) *Getting value from artificial intelligence in agriculture, over the next 10+ years*. In Proceedings of the 8th Australasian Dairy Science Symposium (ADSS'18). Palmerston North, New Zealand: Animal Production Science.
- Soffar, H. (2019) Artificial Intelligence in Agriculture advantages, disadvantages & uses. [Online]. July 2019. Disponível em: <https://www.online-sciences.com/robotics/artificial-intelligence-in-agriculture-advantages-disadvantages-uses/> [Acedido: 09 Maio 2020].
- SwarmFarm (2019) Our Technology. [Online]. Disponível em: <https://www.swarmfarm.com/> [Acedido:13 Maio 2020].
- Tantalaki, N., Souravlas, S. e Roumeliotis, M. (2019) Data-Driven Decision Making in Precision Agriculture: The Rise of Big Data in Agricultural Systems. *Journal of Agricultural & Food Information*. 20(4). p. 344-380.
- The Guardian. (n.d) *AI could be a critical tool to help save the planet*. [Online]. Disponível em: <https://www.theguardian.com/ai-for-earth/2019/apr/30/ai-tech-sustainable-planet> [Acedido: 13 Janeiro 2020]
- Trendov, N. M., Varas, S. e Zeng, M. (2019) *Digital Technologies in Agriculture and Rural Areas - Status Report*. Rome: FAO

- Trigo-Guedes, R. e Palma-dos-Reis, A. (2019) *Ensaio sobre a Sociedade Pós Inteligência Artificial: Potenciais efeitos da sua difusão*. In Proceedings of the 14th Iberian Conference on Information Systems and Technologies (CISTI). Coimbra, Portugal: IEEE. pp. 1–6.
- United Nations (2017) *World population projected to reach 9.8 billion in 2050, and 11.2 billion in 2100*. [Online] Disponível em: <https://www.un.org/development/desa/en/news/population/world-population-prospects-2017.html> [Acedido: 12 Abril 2020].
- Weber, V. (2019) Modern farming is harming the planet. Tech-driven permaculture could heal it. *World Economic Forum*. [Online]. 28th February. Disponível em: <https://www.weforum.org/agenda/2019/02/Modern-farming-agriculture-harming-planet-tech-driven-permaculture-heal/> [Acedido: 16 Março 2020].
- Wilbur, M., Ellsworth, J., Oommen, T., Mohapatra, A. e Thayer, D. (2016) *Systems and Methods for Cloud-Based Agricultural Data Processing and Management*. [Online]. April 2016. Disponível em: <https://patentimages.storage.googleapis.com/9a/75/79/1c53d7193e7470/US9667710.pdf>. [Acedido: 30 Março 2020]
- Yadav, B., Ch, S., Mathur, S. e Adamowski, J. (2017) Assessing the suitability of extreme learning machines (ELM) for groundwater level prediction. *Journal of Water and Land Development*. 32 (1). p. 103–112.
- Yahya, N. (2018) Agricultural 4.0: Its Implementation Toward Future Sustainability. In Yahya, N. *Green Urea For Future Sustainability*. Singapore: Springer. p. 125-145.
- Yin, R. (2014), *Case Study Research: Design and methods*, 5^a Ed. Thousand Oaks, CA, Sage Publications.

ANEXOS*Anexo A – Resumo da Aplicação de IA na Resolução de Problemas Ambientais Gerais*

Autores	Aplicação de IA
Ilie <i>et al.</i> (2019)	Revela os resultados de pesquisas cujo objetivo foi construir, treinar e validar uma RNA capaz de prever o valor do sentimento económico do ano seguinte, usando os valores presentes de quatro indicadores económicos, importantes para alcançar um desenvolvimento mais sustentável.
Chui, Lytras e Visvizi (2018)	Oferecem uma visão sobre sistemas-piloto e protótipos que mostram de que forma a IA pode oferecer apoio crucial no processo de alcançar a sustentabilidade energética em “smart cities”.
Iglinski e Babiak (2017)	Analizam o impacto da utilização da IA na redução das emissões de gases de efeito de estufa do transporte rodoviário através de carros autónomos.
Ramchandran <i>et al.</i> (2016)	Propõe um Índice de Vulnerabilidade Ambiental (EVI) modificado para avaliar o impacto ambiental da aviação nas cidades conectadas.
Nabavi-Pelesaraei, Abdi e Rafiee (2014)	Analizam o impacto da utilização da IA na redução das emissões de gases de efeito de estufa de sistemas de produção de melancia na província de Guilan, no Irão, através da aplicação de RNA.

Fonte: Elaborado pelo autor

Anexo B – Definição das principais técnicas de IA

Técnicas de IA	Definição	Autores
<i>Big Data</i>	Grandes volumes de dados que correspondem às características do <i>big data</i> , ou seja, os 3Vs - volume, velocidade e variedade.	Morota <i>et al.</i> (2018)
<i>Computer Vision (CV)</i>	Compreende métodos e técnicas através dos quais os sistemas de visão artificial podem ser construídos e empregados de maneira razoável em aplicações práticas. É composto essencialmente pelos seguintes estados: aquisição de imagem e processamento de imagem.	Patrício e Rieder (2018)
<i>Convolutional Neural Network (CNN)</i>	É uma das formas de <i>deep learning</i> que tem sido amplamente empregada no reconhecimento de fala e processamento de imagem.	Acharya <i>et al.</i> (2018)
	São muito semelhantes às redes neuronais comuns: são constituídas por neurónios com pesos e vieses aprendíveis. Toda a rede expressa uma única função de pontuação diferenciável: dos pixels da imagem bruta numa extremidade às pontuações da classe na outra. E ainda têm uma função de perda (por exemplo, SVM) na última camada (totalmente conectada).	Dormehl (2019)
<i>Deep Learning</i>	Diferem das redes neuronais convencionais no sentido de que possuem mais nós, meios mais complexos de interconexão de camadas, que exigem forte poder computacional para o seu treino.	Ferentinos (2018)
	Em cada etapa, as respostas "erradas" são eliminadas e enviadas de volta aos níveis a montante para ajustar o modelo matemático. Conforme o tempo passa, o programa reorganiza as informações em blocos mais complexos.	Deluzarche (2019)
<i>Deep Convolutional Neural Network (DCNN)</i>	São sistemas especializados que aproveitam uma quantidade enorme de conhecimentos e dados humanos. Fornecem uma estrutura uniforme de classificação de extração de recursos para libertar humanos da extração problemática de recursos artesanais à custa do <i>design</i> de rede artesanal.	Ma <i>et al.</i> (2020)
<i>Extreme Learning Machine (ELM)</i>	É essencialmente uma única rede neuronal <i>feedforward</i> ; a sua estrutura consiste numa única camada de nós ocultos, onde os pesos entre entradas e nós ocultos são atribuídos aleatoriamente e permanecem constantes durante as fases de treinamento e previsão. Pelo contrário, os pesos que conectam nós ocultos às saídas podem ser treinados muito rapidamente.	Hoang e Bui (2017)
<i>Machine Learning</i>	Também conhecido como aprendizagem estatística, é um subcampo da inteligência artificial dedicado ao estudo de algoritmos de previsão e inferência. Foca-se em aprender a partir de dados.	Morota <i>et al.</i> (2018)
<i>Machine Vision</i>	Combina análise de imagem e técnicas de ML para fornecer inspeção automatizada. As técnicas de MV são rápidas, não destrutivas e objetivas.	Chung <i>et al.</i> (2016)
Redes Neuronais Artificiais (RNA)	Adquirem conhecimento por meio da experiência, podendo reconhecer padrões e fazer inferências, permitindo a estimativa de dados que possuem dependência, como atributos químicos do solo.	Fernandes <i>et al.</i> (2019)
	Consistem em camadas de entrada (<i>input</i>) e saída (<i>output</i>), bem como (na maioria dos casos) uma camada oculta (<i>hidden layer</i>) composta por unidades que transformam o <i>input</i> em algo que a camada de <i>output</i> pode usar.	Dormehl (2019)
	<i>Recurrent neural networks</i> : os dados podem fluir em várias direções. Estas redes "alimentam" as saídas da camada oculta de volta para si mesma. <i>Feedforward neural networks</i> : as informações viajam em apenas uma direção da entrada para a saída.	Rajae, Ebrahimi e Nourani (2019)
<i>Support Vector Machine (SVM)</i>	São classificadores binários capazes de classificar amostras de dados experimentais em duas classes desassociadas. O princípio dos SVMs vem do caso simplificado: as duas classes contabilizadas são linearmente separáveis. Existe um hiperplano capaz de diferenciar todas as amostras de dados em duas classes.	Rehman <i>et al.</i> (2019)
	Pode ser usado para problemas de regressão e classificação, mas é usado principalmente para fins de classificação devido à sua alta precisão na tarefa de classificação.	

Fonte: Elaborado pelo autor

Anexo C – Resumo da Aplicação de IA na Gestão do Solo e Culturas

Autores	Técnica	Vantagens	Limitações
Fernandes <i>et al.</i> (2020)	RNA	Pode estimar com maior precisão a monitorização da resistência à penetração do solo influenciada pela humidade do solo, do que várias regressões lineares e não lineares.	n.d.
Bayat <i>et al.</i> (2020)	SVM, RNA, Método de Regressão	RNAs podem ser uma ferramenta eficiente para recomendar condições do solo relacionadas à gestão relativamente sustentável do solo e um aumento na qualidade do solo para o crescimento das culturas.	São necessárias mais pesquisas para quantificar os efeitos do teor de humidade
Fernandes <i>et al.</i> (2019)	RNA	Podem estimar com alta precisão a matéria orgânica do solo, com base no pH, cálcio, magnésio e acidez potencial. Redução dos custos de análise e redução da quantidade de resíduos químicos gerados.	n.d.
Chatterjee, Dey e Sen (2018)	RNA	Pode prever a humidade do solo em termos de temperatura do solo, ar e humidade relativa. A análise de estabilidade simulada revelou que, na presença de condições climáticas variadas, o modelo ainda é confiável em maior medida e é altamente imune a essas mudanças.	A análise de estabilidade revelou que é necessário um modelo mais preciso e estável para tornar o sistema confiável.
Dong <i>et al.</i> (2018)	Mapeamento digital suportado por CNN	Pode obter consistência fina entre as propriedades do solo para a agricultura de precisão e melhorar efetivamente a eficiência da previsão do fósforo disponível no solo.	O modelo precisa de ser aprimorado para aplicações em ambientes mais complexos.
Prasad <i>et al.</i> (2018)	ELM	Tem o potencial para monitorizar e prever em tempo real a humidade do solo, útil em sistemas de decisão agrícola, agricultura de precisão, alerta precoce de inundações e secas e planeamento adaptativo de recursos hídricos, via aplicações de telemóveis <i>user-friendly</i> .	Altos custos e a precisão da previsão é sensível a fatores meteorológicos e a inconsistências verticais e espaciais da textura do solo.
Kouadio <i>et al.</i> (2018)	ELM	Os mais eficientes em extrair os recursos entre as propriedades de fertilidade do solo e da produção de café, e mais confiáveis para prever a produção de café usando vários <i>inputs</i> . Sendo assim capaz de melhorar o rendimento na agricultura familiar.	n.d.
Matei <i>et al.</i> (2017)	<i>Data Mining</i>	A precisão da previsão de humidade do solo é muito alta. O sistema pode ser usado em tempo real na agricultura como uma plataforma madura e confiável em quaisquer condições geo-climáticas. Permite aos agricultores tomar ações ativas e eficazes para evitar danos às plantações.	Pesquisa incipiente. Aplicar o mesmo algoritmo a mais estações meteorológicas.

Fonte: Elaborado pelo autor

Anexo D – Resumo da Aplicação de IA na Gestão da Água

Autores	Algoritmos de IA	Metodo de evapotranspiração	Outras Tecnologias	Resultados/ Vantagens	Limitações/ Pesquisas Futuras
Seyedzadeh <i>et al.</i> (2020)	RNA, <i>Neuro-Fuzzy Sub-Clustering</i> (NF-SC), <i>Neuro-Fuzzy C-Means Clustering</i> (NF-FCM), LS-SVM.	n.d.	n.d.	Mostrou que sistemas <i>user-friendly</i> que usam IA podem ser um bom substituto para medições em laboratório e em campo, economizando tempo e custo.	Examinar o efeito da irradiação direta em diferentes partes do sistema de irrigação.
Choudhary <i>et al.</i> (2019)	<i>Partial Least Square Regression</i> (PLSR) (ML) e outros algoritmos de regressão	Modelo de evapotranspiração	Sensores para recolha de dados, Implementação de IoT Hardware	Maior eficiência e viabilidade económica. Pode ajudar a aumentar a eficiência da irrigação enquanto diminui o esforço necessário e ajuda na conservação da água em comparação com os métodos atuais de irrigação. Capaz prever a quantidade de água necessária para irrigação, minimizar desperdício e aumentar o rendimento da cultura.	Depende das informações da estação meteorológica para o seu cálculo. Essa dependência pode ser substituída por sensores locais para implementação em áreas rurais e nas regiões áridas onde a água está disponível em quantidade limitada.
Perea <i>et al.</i> (2018)	RNA, <i>Fuzzy Logic</i> (FL), algoritmos genéticos	n.d.	n.d.	n.d.	Quando várias culturas são treinadas juntas, a representatividade do modelo e a precisão das previsões foram consideravelmente piores do que quando cada cultura foi treinada de forma independente
Ghose, Das e Roy (2018)	RNA	Modelagem da resposta do escoamento superficial e evapotranspiração	n.d.	O desenvolvimento do modelo e a sua praticabilidade em regiões áridas são mais económicos e podem ser aplicados ao sistema de planeamento e gestão do abastecimento de água.	n.d.

Autores	Algoritmos de IA	Metodo de evapotranspiração	Outras Tecnologias	Resultados/ Vantagens	Limitações/ Pesquisas Futuras
Singh e Vitkar (2018)	<i>RNA Controller</i>	Modelo de evapotranspiração	Sensores para recolha de dados	O sistema de controle de irrigação económico e orientado a resultados foi alcançado. O ON / OFF da válvula e do sistema de energia é muito baixo e, portanto, é possível economizar muita energia e água, ao monitorizar continuamente o status do solo para sustentar a produção agrícola.	n.d.
Sahoo <i>et al.</i> (2017)	<i>Hybrid Artificial Neural Network (HANN) (ML)</i> e modelos de regressão convencionais	n.d.	n.d.	Ferramenta valiosa para prever mudanças no nível das águas subterrâneas, especialmente em regiões onde é difícil desenvolver um modelo hidrogeológico físico.	Incluir o uso de estatísticas de covariância espacial ou a contabilidade geoestatística multivariada dos parâmetros do modelo para melhorar a previsão dos níveis das águas subterrâneas, levando em consideração as incertezas decorrentes da heterogeneidade espacial e da coerência espacial dos fatores de controle.
Yadav <i>et al.</i> (2017)	ELM, SVM	n.d.	n.d.	O algoritmo ELM é capaz de fazer previsões mensais mais precisas dos níveis de água subterrânea e mostra superioridade em relação aos modelos SVM	Usar modelos de ELM para prever os níveis de água subterrânea em diferentes tempos de entrega e em diferentes localizações geográficas com características físicas variadas.
Nema <i>et al.</i> (2017)	Modelo RNA com uma só camada <i>feed forward</i> . Algoritmo <i>back propagation</i>	Metodo de Penman–Monteith	n.d.	Demonstrou o potencial do poder preditivo da arquitetura da RNA para estimar a evapotranspiração de referência.	n.d.

Fonte: Elaborado pelo autor

Anexo E – Resumo da Aplicação de IA na Gestão de Ervas Daninhas

				Deteção e Classificação				
Autores	Sensores	Cultura	Densidade de Ervas Daninhas	Técnica	Características	Precisão (%)	Vantagens	Limitações
Raja <i>et al.</i> (2020)	Câmara Red, Green, Blue (RGB) Basler 5 MP	Alface	Alta	<i>Machine Vision</i>	<i>Crop Signalling</i>	98,93	Baixo-custo. Tempo real Altamente preciso e robusto	n.d.
Partel, Kakarla e Ampatzidis (2019)	GPU (NVIDIA GTX 1070 Ti)	Pimento e plantas artificiais	n.d.	MV + <i>Deep Learning Neural Network</i>	Segmentação de imagem. Protótipo para <i>sprayer</i> inteligente	Pimento: 71 Geral: 71 <i>Recall</i> : 78	Baixo-custo. Resposta rápida e sistema de spray preciso	Requere rede neuronal mais pesada/mais processamento computacional quando target \approx non-target
Milioto, Lottes e Stachniss (2018)	Câmara RGB + NIR (JAI AD-130 GE)	Beterraba-Sacarina	Baixa	<i>Deep encoder-decoder CNNs</i>	Nenhum recurso artesanal.	95	Precisão, tempo e eficiência de hardware. Resposta em tempo real	Requere grandes quantidades de dados para treino.
McCool, Perez e Upcroft (2017)	Câmara RGB	Base de dados Cenoura	Baixa	DCNNs adaptado	Parâmetros estatísticos de forma e pixel	93,9	<i>Trade-off</i> : tamanho da memória e velocidade contra precisão, ao aprender um conjunto de modelos leves. Melhores resultados do que abordagem tradicional (85,9%)	Velocidade de processamento baixa. Não aplicável num sistema robótico em tempo real.
Mohan <i>et al.</i> (2016)	RGB + ambiente LabVIEW	Milho	Baixa	<i>Machine Vision</i>	Classificação de culturas e ervas daninhas de acordo com as características extraídas da análise <i>wavelet</i> da imagem.	95,89	Robusto contra diferentes condições de luz e espécies de plantas testadas. Tempo real	n.d.

Autores	Sensores	Cultura	Densidade de Ervas Daninhas	Deteção e Classificação			Vantagens	Limitações
				Técnica	Características	Precisão (%)		
Pulido-Rojas, Molina-Villa e Solaque-Guzmán (2016)	RGB + 8MP câmara com processor 2.50GHz e 6GB RAM Processamento de dados	Espinafre	Baixa	<i>Machine Vision, unsupervised learning</i>	Características de baixo nível para detetar ervas daninhas através da classificação binária quando a vegetação é detetada com o intuito de construir um robô movel autónomo para remoção de ervas daninhas	90	Baixo Custo. Alto desempenho e precisão com índices de sensibilidade e especificidade altos	Limitado a tarefas periódicas de remoção de ervas daninhas. Não estimou as posições exatas da planta sendo isso necessário para o funcionamento de um sistema robótico de controle de ervas daninhas.
Slaughter <i>et al.</i> (2008)	Câmara hiper-espectral	Alface	Baixa	<i>Multi spectral Machine Vision</i>	Distinguir alface e três espécies de ervas daninhas para o controle automatizado de ervas daninhas através de espectroscopia de reflectância visível e infravermelho próximo	90,3	Viabilidade da técnica para desenvolver um classificador automatizado específico do local para distinguir alface americana	n.d.

Fonte: Elaborado pelo autor

Anexo F – Resumo da Aplicação de IA em Robótica Agrícola na Gestão de Ervas Daninhas

Robô	Descrição	Vantagens
Bonirob	Usa um tipo de <i>machine learning</i> , chamado <i>decision tree (DT) learning</i> , e mata ervas daninhas, perfurando-as no chão com uma vara	As máquinas têm a capacidade de aprender e reconhecer a partir de muitos exemplos de ervas daninhas, de que tipo de planta se trata e agir consoante a necessidade específica. A grande vantagem aqui é que um único agricultor pode gerir melhor o seu tempo. Além disso, a aplicação precisa de produtos de proteção de culturas melhora significativamente a eficiência, através do tratamento individual de ervas daninhas, podemos reduzir massivamente a quantidade de herbicida usado nas fazendas, melhorando a sustentabilidade e o impacto ambiental da agricultura (SwarmFarm, 2019)
Ecorobotix	Possui uma minúscula unidade movida a energia solar, orientando-se e posicionando-se através de <i>Global Positioning System (GPS)</i> , uma câmara e os seus sensores efetuando aplicações precisas de uma micro dose de herbicida, tendo como estratégia a construção de pulverizadores autónomos dedicados pelo viés de robótica, GPS e IA	
SwarmFarm	Semelhante à Ecorobotix tendo, no entanto, uma compactação consideravelmente menor do que um trator cheio deitando pulverizador. Usa <i>computer vision</i> e IA	
BlueRiver	Podem detetar, identificar e tomar decisões de gestão sobre todas as plantas do campo.	
See & Spray	Usam algoritmos de <i>deep learning</i> que são similares aos usados em <i>face recognition</i> , eliminando até 90% dos volumes de herbicidas pulverizados hoje, enquanto abrem o potencial de usar outros herbicidas que não são apropriados para pulverização de difusão	

Fonte: Elaborado pelo autor

Anexo G – Resumo da Aplicação de IA na Gestão das Doenças

Autores	Técnica	Precisão (%)	Vantagens	Limitações
Shen <i>et al.</i> (2018)	CNN, DCNN	88	Pode detetar e identificar os insetos sob condição de grãos armazenados com ligeira adesão	A capacidade de otimização do modelo foi significativamente reduzida porque o fluxo de informações da rede de criação profunda foi bloqueado. Tamanho do corpo de insetos de grãos armazenados é relativamente pequeno.
Singh (2018)	Deep CNN	95	Rastreio e previsão automatizados de doenças. Nova, escalável e acessível. Baixo custo. Baseado em <i>Cloud</i> . Solução <i>end-to-end</i> .	Requere a inclusão de mais parâmetros e redução de intervenção de peritos.
Ferentinos (2018)	CNN	99,53 (com erro tipo 1 de 0,47%)	Identificação de doenças de plantas por meio de imagens (17 548) simples de folhas de plantas saudáveis ou doentes. Alto nível de desempenho. Baixa potência computacional necessária.	Requer a recolha de um grande número de amostras de treinamento (em termos de espécies e doenças de plantas que podem ser identificadas) e mais robusta em condições reais de cultivo.
Ebrahimi <i>et al.</i> (2017)	ML-SVM	Erro percentual médio inferior a 2,25%	Parasitas das estufas de morangos podem ser classificados e detetados nas imagens das copas das culturas. Controlo em tempo real.	n.d.
Mohanty, Hughes e Salathé (2016)	CNNs	99,35	Alta performance. Primeiro passo para um sistema de diagnóstico de doenças de plantas assistido por <i>smartphone</i> .	Apenas imagens em instalações experimentais (de laboratório), não em condições reais no campo de cultivo
Chung <i>et al.</i> (2016)	MV, SVM	89,7	Capaz de distinguir não-destrutivamente mudas com três semanas saudáveis e infetadas com a doença <i>Bakanae</i> . Menos subjetiva e demorada que exame a olho nu.	n.d.
Han, Haleem e Taylor (2015)	SVM, RNA	Geral SVM: 95 RNA: 53	A abordagem baseada em SVM tem um bom desempenho no reconhecimento de doenças que causam manchas nas folhas do arroz.	n.d.

Fonte: Elaborado pelo autor

Anexo H – Resumo da Aplicação de IA na Gestão de Pragas

Autores	Técnica	Descrição e Resultados
Cruz <i>et al.</i> (2019)	Deep Learning - CNN	Novo sistema a baixo-custo para deteção, de ponta a ponta, de amarelos de videira em videiras vermelhas causadas por fitoplasmas, usando imagens coloridas de recortes de folhas. O sistema possui uma sensibilidade de 98,96% e uma especificidade de 99,40%. O utilizador, envia uma imagem recortada para o sistema e recebe o diagnóstico.
Roldán-Serrato, Escalante-Estrada e Rodríguez-González (2018)	RNA	O sistema deteta automaticamente duas pragas desfolhantes nas culturas de batata e feijão: <i>Mexican Bean Beetle</i> (MBB) e <i>Colorado Potato Beetle</i> (CPB) na fase adulta. Melhores resultados obtidos são: 89% para a deteção de CPB e 88% para a deteção de MBB. Pode ser usado para implementação em robôs ou <i>drones</i> móveis para deteção de pragas em diferentes plantas.
Abdulridha <i>et al.</i> (2018)	DT, <i>Neural Networks</i>	Método de sensoriamento remoto não destrutivo para detetar os abacateiros infetados com murcha de louro (no estágio inicial e tardio). O modelo de redes neuronais relatou maior precisão de classificação (quase 100%) do que os DTs, independentemente do estágio de desenvolvimento. Poderia permitir que os agricultores controlassem esta doença utilizando estratégias de gestão precoce adequadas (por ex:esterilização).
Cruz <i>et al.</i> (2017)	DL, CNN	Programa baseado em visão para detetar sintomas da Síndrome de Declínio Rápido de Olive (OQDS) em folhas de <i>Olea europaea</i> L. infetadas por <i>Xylella fastidiosa</i> . OQDS foi detetado com uma taxa positiva verdadeira de $98,60 \pm 1,47\%$ nos testes.
Bannerjee <i>et al.</i> (2017)	RNA	Solução que emprega o modelo de função de base radial para a identificação de três principais pragas de insetos de chá, a saber: Pulgões, Aranha-vermelha e Thrips. São 31 as camadas ocultas das redes neuronais com uma precisão de deteção de 99,99%. Apesar da alta confiabilidade, deteta apenas três pragas e limita-se apenas ao chá e não a todas as culturas comerciais.
DeChant <i>et al.</i> (2017)	CNN	Sistema capaz de identificar automaticamente lesões de ferrugem das folhas do Norte em imagens adquiridas em campo de plantas de milho com precisão de 96,7% nas imagens dos conjuntos de testes não utilizadas no treinamento.

Fonte: Elaborado pelo autor

Anexo I – Guião de Entrevista

**Inès Russo, estudante de Mestrado de Gestão de Sistemas de Informação do ISEG.
(Permissão para gravar)**

Propósito: Perceber como pode a IA contribuir para uma gestão sustentável da agricultura e como introduzir o uso de IA na agricultura de uma forma continuada.

Introdução [máx 5 mins]

- Apresentação pessoal
- Enquadramento da investigação
- Apresentação dos objetivos da investigação
- Condução dos trabalhos:
- Garantia de confidencialidade
- Obtenção de autorização de gravação da entrevista
- Ficha sumária de identificação do entrevistado: sexo, formação académica, especialização, tempo na empresa, cargo e tempo no cargo.

GUIÃO DE ENTREVISTA

Sexo_

Formação Académica_

Especialização_

Tempo na empresa_

Cargo_

Tempo no cargo_

1. Considera que a agricultura, atualmente, sem a utilização da IA, é sustentável?
 - 1.1 Se sim, como?
 - 1.2 Se não, qual/quais a(s) principal/principais oportunidade(s) que destaca da utilização de ferramentas inteligentes como a inteligência artificial a nível ambiental?
2. Acha que ainda existe uma barreira na adoção de IA por parte do setor agrícola?
 - 2.1 Se sim, qual/quais e porquê?
 - 2.2 Se não, quais as razões pela qual as implementações de IA ainda são lentas na agricultura?
3. Tendo em conta os objetivos da agricultura sustentável: "(1) manter e aprimorar a qualidade e a produtividade do solo; (2) conservar o solo, a água; (3) manter e melhorar a qualidade das águas superficiais e subterrâneas (4) proteger a saúde e

- Uma Agricultura Sustentável
a segurança das pessoas envolvidas no sistema alimentar e agrícola; e por último
(5) aumentar as oportunidades de emprego na agricultura
- 3.1 De que forma as soluções baseadas em IA contribuem para atingir estes objetivos?
4. Qual considera que seja(m) o(s) principal/principais desafio(s) da adoção de IA na agricultura a nível económico e porquê?
- 4.1 Qual considera que seja(m) a(s) principal/principais vantagem/vantagens da adoção de IA na agricultura a nível económico e porquê?
5. O setor agrícola produz uma enorme quantidade de dados que por norma são usados na pesquisa agrícola.
- 5.1 Que tipos de desafios se enfrenta internamente a nível da sua gestão?
- 5.2 Considera que o *Big Data* é um requisito para a IA?
- 5.2.1 Para além do *big data*, haverá outros requisitos? Pode classificar a nível de importância?
6. A nível social (agricultores), considera que falta algo para entender os desafios e oportunidades destas ‘novas’ tecnologias de IA?
7. O que considera que pode influenciar positivamente a intenção de adoção de IA na agricultura?
8. O que considera que falta para que as implementações de IA sejam mais numerosas e continuadas na agricultura?
9. Considera que as pessoas no setor agrícola podem temer a perda dos seus empregos devido ao crescimento da IA ou por outro lado, encontrar na IA oportunidades para quebrar o ciclo da pobreza? Se sim, porquê? Se não, porquê?

Anexo J – Códigos e Subcódigos Decorrentes das Entrevistas

Código	Nota Explicativa	Freq	Citação dos Entrevistados
Q1_SustAgricultura	Sustentabilidade da Agricultura sem a utilização de IA		
Sim	A agricultura consegue ser sustentável sem IA	4	[...] tens o caso daquelas situações em que o teu ambiente envolvente não te permite mesmo que tenhas aplicações de inteligência artificial na atividade de levar a bom termo todas as atividades. (ENT1)
SimMBarr	A IA na agricultura é necessária, mas vai demorar	6	[...] Já existe muito a nível de experimentação, mas a nível da utilização real, não se está ainda no ponto de se estar a usar de uma forma consistente. (ENT6)
Futuro	A IA pode ser o futuro da agricultura	8	[...] A inteligência artificial pode ser o futuro. (ENT4)
Q2_Barreiras	Barreiras/Desafios na adoção de IA na agricultura		
2_DisDimTerras	Disponibilidade/Dimensão das terras	5	[...] quando são explorações mais pequenas, o retorno do investimento que têm de fazer nessas tecnologias, às vezes não é imediato. (ENT7)
2_Sociais	Aspetos Sociais		
FormEsc	Formação Escolar	4	[...] diria que a parte mais complicada é mesmo a parte da formação pessoal. (ENT2)
Idade	Idade dos agricultores	3	[...] tem a ver com essa questão em termos médios, com a idade. (ENT5)
CetAdv	Ceticismo e adversidade por parte dos agricultores	2	[...] as pessoas ficam um pouco cétricas e preferem continuar a fazer as coisas como têm vindo a fazer. (ENT7)
Mentalidade	Mentalidade	4	[...] eu penso que é o “mindset” do agricultor. (ENT5)
2_Cust	Custos	3	[...] O principal obstáculo para a adoção de todas essas técnicas? É o dinheiro. (ENT4)
2_AssisTecn	Assistência técnica	2	[...] Os problemas são fundamentalmente a assistência técnica às coisas. (ENT1)
2_FatExt	Fatores externos		
Precos	Preços	5	[...] é complicado haver pouca flexibilidade para encaixar estas variações [...] há um ano que se calhar não conseguem gerir aqueles preços. (ENT8)
ContMeteo	Condições Meteorológicas	2	[...] Depois há outras variáveis que nós não controlamos, [...] as condições meteorológicas que podem mudar, não digo de um dia para o outro, mas não há dois verões iguais, não há duas primaveras iguais... (ENT1)

Código	Nota Explicativa	Freq	Citação dos Entrevistados
Q3_ContbcaoIAObjtAgAmb	Contribuição da IA para atingir os objetivos da agricultura sustentável a nível ambiental		
3_UsoEficFatores	Uso eficiente dos fatores de produção	3	[...] A sustentabilidade tem a ver com o uso eficiente de fatores. (ENT5)
Água	Adequar as dotações de água	6	[...] tu consegues, também, em função da cultura que lá vais pôr adequar as dotações de água e com a qualidade que a água tiver às exigências da cultura e à preservação do solo. (ENT1)
PestHerbFert	Pesticidas, herbicidas e fertilizantes	5	[...] pode ser generalizada tudo o que são inputs, desde a fertilização, a aplicação de pesticidas, a utilização da água e por aí fora. (ENT2)
3_AumProd	Aumento da produtividade	7	[...] ao longo do tempo as produtividades vão aumentando. (ENT3)
3_AumEfic	Aumento da eficiência	4	Vai haver uma vantagem ambiental porque, [...], conseguimos aumentar a sua eficácia e a sua eficiência. (ENT5)
3_ApTomaDecis	Apoio/Aconselhamento na tomada de decisão	7	[...] dizer-me com base no histórico de dados que eu tenho anteriores, ela [inteligência artificial] aí aconselhar qual será a melhor forma de o fazer. (ENT2)
3_Analises	Análises de grandes volumes de informação	4	[...] podes fazer também análises foliares e podes fazer uma série de análises à medida que vais trabalhando (ENT1)
3_PlanoEstAg	Planeamento estratégico da agricultura	3	[...] e poder fazer a gestão de planeamentos mais antecipados antes da campanha começar [...] (ENT8)
3_GestMon	Gestão e monitorização do solo, água, culturas, pragas, doenças, ervas daninhas	7	[...] podes verificar o teu campo todos os dias e podes ver se está a ficar sem água, se há plantas infestantes a aparecerem, etc. (ENT4)
3_Prev	Previsões	5	[...] um papel de melhorar muitos desses processos [...] até na previsibilidade do que vai acontecer, das tendências de clima, das previsões de clima se calhar serem cada vez mais antecipadas. (ENT8)
3_TransfInfo	Transformação da informação em informação valiosa para o agricultor	4	[...] a inteligência artificial consegue “mastigar” toneladas de informação e reduzir aquilo para uma ação que ainda por cima vai aprendendo ao longo do tempo e, portanto, vai melhorando. (ENT6)
3_PolDesp	Diminuição da poluição e do desperdício	4	[...] evitas a poluição nos lençóis de água subterrâneos com químicos que não são necessários. (ENT7)

Código	Nota Explicativa	Freq	Citação dos Entrevistados
3_AfinacPrecSens	Afinação, precisão, localizado e sensibilidade	2	[...] está tudo muito mais controlado, está tudo muito mais... como é que eu hei de dizer... circunscrito... muito mais localizado! (ENT6)
3_AgPrecis	Agricultura de precisão	6	[...] Então sim a agricultura de precisão ela vai precisar de IA, sem dúvida! (ENT3)
Q4_Economico			
Q4a_DesEconomicos	Desafios e Económicos da adoção de IA na Agricultura		
4a_Custos	Custos de investimento, capacidade financeira	5	[...] é a capacidade, muitas vezes, dos agricultores, em termos financeiros de fazerem o investimento. (ENT7)
4a_NEco	O problema não é económico	3	[...] Eu acho que o problema não é económico. (ENT3)
OutSourc	<i>Outsourcing</i> como uma alternativa à compra de máquinas	2	[...] É mais vantajoso e menos dispendioso e se a máquina avariar não tem o problema de ter de reparar, quem faz o serviço..., o serviço é feito em <i>outsourcing</i> . (ENT1)
FundApoios	Fundos e Apoios	5	[...] o governo, os políticos têm de certa forma tentado a ajudar quando disponibilizam aqueles fundos para a inovação na agricultura. (ENT7) [...] vai muito com os apoios que recebem para melhorias ambientais muitas vezes. (ENT8)
Acess	Acessibilidade das tecnologias de IA	4	[...] São tecnologias que já estão tão disponíveis e quando é trabalhado em grande escala fica bastante acessível. (ENT7)
Q4b_VantEconomicas	Vantagens Económicas da adoção de IA na agricultura		
4b_CustBen	Relação Custo Benefício	6	[...] A nível económico é tudo uma relação de custo e oportunidade. (ENT1)
4b_AumEfici	Aumento da eficiência	5	[...] consigo pôr a água certa, consigo pôr o fertilizante certo, e isto vezes não sei quantos mil hectares, o aumento de eficiência é brutal, o aumento de no fundo poupança de água por quilo produzido é brutal, de fertilizantes no solo... (ENT6)
4b_Seg	Seguros	2	[...] a inteligência artificial vai intervir para fazer um novo tipo de produto agrícola chamado o seguro paramétrico. (ENT4)
Q5_Dados			
5_ImportBD	Importância do <i>Big Data</i>		
FundaEss	Fundamental, essencial	4	[...] o <i>big data</i> é fundamental na agricultura. (ENT5)
NFunda	Não fundamental	1	[...] Acho que é possível fazer sem <i>big data</i> . Mas em breve vai precisar do <i>big data</i> , sim, porque são muitos dados. (ENT3)

Código	Nota Explicativa	Freq	Citação dos Entrevistados
Imp	Importante	2	[...] dados a mais é um problema para nós, mas é importantíssimo para a inteligência artificial (ENT6)
Ajud	Ajuda, é uma parte do trabalho	1	[...] Para a Inteligência artificial, o <i>big data</i> ajuda [...] (ENT8)
Q5a_Desafios	Desafios internos em relação aos dados		
5a_CondMeteo	Condições Meteorológicas	3	[...] o conhecimento das condições meteorológicas em tempo real é fundamental. (ENT1)
5a_CustoAmbMon	Custos ambientais e monetários	2	[...] na agricultura e em imagens de satélite, deparas-te muito, muito rapidamente com grandes volumes de dados e esses grandes volumes de dados têm um custo ambiental. (ENT4)
5a_RecTratDados	Recolha e tratamento dos dados	6	[...] A parte mais complicada é sem dúvida a recolha dos dados, perceber qual é que é a frequência e tentar ganhar o máximo de repetições possível. (ENT2)
QtddDados	Quantidade dos dados	5	[...] estamos a conseguir medir tanta coisa que às tantas temos toneladas de informação e já nem sabemos o que fazer com ela porque são coisas a mais. (ENT6)
IntDados	Integração dos dados numa única base de dados	3	[...] a congregação dos dados numa base de dados comum e depois a capacidade de trabalhar esses dados e tirar dali inteligência artificial e o “data mining” [...]. (ENT5)
LimpDados	Limpeza dos Dados	2	[...] muitas vezes esses dados não estão bem estruturados. Muitas vezes têm muito ruído. Dados a mais. Têm de ser limpos. Muita gente ainda tem de passar por um processo de limpar os dados. (ENT7)
PropIntelect	Propriedade Intelectual	1	[...] muito deste trabalho passa por visualização de dados, disponibilização de dados e isso são tudo áreas difíceis de proteger em termos de propriedade intelectual. (ENT8)
Q5b_OutReq	Outros requisitos à IA além do <i>big data</i>		
5b_Sensores	Sensores e a calibração dos mesmos	4	[...] todos os sensores, todos os inputs necessários que envolvem <i>big data</i> é parte essencial. (ENT7)
5b_ConetRu	Conetividade rural, acesso à internet	2	[...] o “digital gap”, ou seja, o acesso à internet de onde te encontras, pode ser uma limitação. (ENT4)
5b_DispDados	Disponibilidade de dados	7	[...] A inteligência artificial precisa de muitos dados, precisa de realmente muita experimentação. (ENT6)
Q6_Social	Fatores sociais		
6_FormEsc	Formação escolar	6	[...] o grande fator limitante para aplicação de inteligência artificial em agricultura é mesmo talvez a parte mais dos experts. Ou seja, a parte académica, o curso. (ENT2)
6_CetAdv	Ceticismo, adversidade	5	[...] por um lado a questão de culturalmente estas pessoas ligadas à agricultura ainda serem um pouco adversas a este tipo de iniciativas. (ENT7)

Código	Nota Explicativa	Freq	Citação dos Entrevistados
6_IntPessAmb	Interesse pessoal e ambição	2	[...] Tem de estar predisposto a alguma coisa, a correr algum risco, a perceber que tem de haver alguma alteração, a querer sair do regime standard. (ENT2)
6_Conf	Confiança	4	[...] às vezes as pessoas confiarem mais que o caminho é por ali, das estruturas, ou sejam políticas, sejam as organizações a que estão associados. Haver mais confiança e é mais fácil aderir. (ENT8)
6_Desconh	Desconhecimento		
Sim	Existe falta de conhecimento	2	[...] tem um pouco esse problema de adoção por desconhecimento. (ENT7)
Não	Não existe falta de conhecimento	3	[...] eu não acho que falte conhecimento! (ENT3)
6_Ment	Mentalidade	7	[...] aquilo que faz verdadeiramente a diferença, é o empresário. É a mentalidade. (ENT5)
6_Idade	Idade		
Lim	É um fator limitante para adotar IA	3	[...] Quanto mais velhas as pessoas são, mais são resistentes às mudanças. (ENT4)
NLim	Não é um fator limitante para adotar as ferramentas de IA	4	[...] pessoas que na realidade apesar da idade e com muitas dificuldades, mas adotam sistemas novos e, portanto, não tenho dúvidas que esses também vão adotar coisas de inteligência artificial. (ENT6)
Q7e8_InfluenciaGenAdoc	Influencia positiva à adoção de IA e formas de generalizar a sua adoção		
7e8_F Sociais	Fatores sociais		
Form	Pessoas formadas	3	[...] Eu penso que há dois ou três fatores que vão ser chave na adoção. E um deles é a formação. (ENT5)
Ment	Pessoas de mente aberta	4	[...] Há muitos requisitos todos eles pequeninos talvez, por exemplo eu acho que [...] aquela parte social, ser alguém que já tem o “mindset” para isso exatamente. (ENT2)
7e8_CadeiaAlim	Cadeia alimentar	3	[...] o que pode ajudar é que essa perceção seja real para o agricultor e para os interlocutores todos. Todos os interlocutores na agricultura, não é só o agricultor. Há a indústria, há a distribuição, há muitos “players” na agricultura. (ENT8)
7e8_Cust	Custos	4	[...] Os sensores estão aqui (<i>drones</i> , satélite), mas as soluções de análise geralmente são muito caras para pequenas e médias explorações. (ENT4)

Código	Nota Explicativa	Freq	Citação dos Entrevistados
7e8_DissInformac	Pouca disseminação da informação	4	[...] acho que falta pelo menos em Portugal, uma disseminação maior [...] (ENT2)
EmpUniMarc	Importância do papel das empresas, universidades e marcas para a divulgação de informação	6	[...] tem de partir um bocadinho primeiro das universidades e centros de investigação (ENT6) [...] passa muito por nós, por empresas como a empresa G, em pronto, explicar os benefícios e ir ter com os clientes e explicar em que é que eles vão melhorar e porque é que eles vão melhorar (ENT7)
CasosEst	Importância dos casos de estudo e experimentação	4	[...] eles realmente veem, um caso pratico, um caso com valores reais, com uma exploração relativamente do mesmo tamanho, uma cultura relativamente parecida... quando veem assim a informação mais imediata, mais representativa da realidade deles, vemos que tem uma maior adoção. (ENT7)
7e8_Politic	Políticas	5	[...] O que se está a trabalhar neste momento, é para que através da PAC se verifiquem apoios que ainda estão a ser estudados como fazê-lo, de forma a que dê os estímulos certos para que a adoção se faça de forma mais acelerada. (ENT5)
7e8_AcompProt	Acompanhamento, proteção	3	[...] O que falta é um acompanhamento muito mais no local, a implementação seja bem feita e que haja essa divulgação. (ENT2)
7e8_MaoObra	Mão de obra	3	[...] Eu acho que os recursos são muito escassos porque o mercado tem uma procura muito grande para esses recursos. (ENT3)
Q9_PapelAgIA	O papel do agricultor com o crescimento da IA		
9_PerdaEmp	Perda de empregos		
Alguns	Alguns empregos/atividades podem ser substituíveis	6	[...] as pessoas fazem os trabalhos mais mecanizáveis ou substituíveis, essas estão em risco, sem dúvida. (ENT3)
Não	Não, a IA vem ajudar	5	[...] há muita falta de mão-de-obra hoje em dia para várias operações que são insubstituíveis. (ENT2)
9_AgricEss	O agricultor é essencial mesmo com a existência de IA	5	[...] é preciso ter sempre alguém a ir validando, a ir confirmando e a ir ajustando. (ENT6) [...] podemos atacar as doenças com um <i>drone</i> dirigido a uma determinada zona, mas tem sempre o homem por detrás. (ENT1)
9_MdcFuncoes	Mudança das funções do agricultor com a introdução de IA	4	[...] vai é ter funções diferentes. Vai fazer coisas diferentes... (ENT5) [...] o surgimento de robôs agrícolas que permite uma agricultura mais sustentável, mas que também exigirão a transformação da profissão de agricultor. (ENT4)

Fonte: Elaborado pelo autor

Anexo K – Matriz de Visualização de Códigos em Cada Entrevista no MAXQDA

