

Proposta de um Sistema Inteligente de Previsão de Colheita de Cogumelos

Intelligent Mushroom Harvest Prediction System Proposal

Jorge Costa ^a, Frederico Branco ^{a,b}, José Martins ^{a,b}, Fernando Moreira ^c, Manuel Au-Yong-Oliveira ^d, Manuel Pérez-Cota ^e, Miguel Ramón González Castro ^e, María Díaz Rodríguez ^e

^aUniversity of Trás-os-Montes e Alto Douro, Vila Real, Portugal

^bINESC TEC and UTAD, Vila Real, Portugal

^c3IJP, REMIT, University Portucalense, Porto, Portugal

^dGOVCOPP, Department of Economics, Management, Industrial Engineering and Tourism, University of Aveiro, Aveiro, Portugal

^eInformatics Department, University of Vigo, Vigo, Spain

jorge_costa20@hotmail.com, fbranco@utad.pt, jmartins@utad.pt, fmoreira@upt.pt, mao@ua.pt, mpcota@uvigo.es, miguelrgc@telefonica.net, maridiaz@uvigo.es

Resumo — As organizações do setor agroindustrial, atualmente têm apostado cada vez mais no desenvolvimento de sistemas tecnológicos, que permitem a informatização de todos os seus processos. Recentemente os métodos e técnicas de visão por computador têm sido muito utilizadas para monitorização e inspeção durante o período de produção e colheita, permitindo detetar problemas antecipadamente e com isto, melhorar a qualidade dos produtos. No setor da produção de cogumelos um dos aspetos mais importantes, e talvez mais preponderantes, é poder prever a sua produção. Com este propósito é proposto um Sistema Inteligente de Previsão de Colheita de Cogumelos (SIPCC), baseado em técnicas e métodos de visão por computador e Redes Neurais Artificiais (RNA). Este trabalho expõe uma arquitetura de um SIPCC a nível funcional e técnica, complementada com a apresentação e análise de dados que demonstram a sua viabilidade.

Palavras Chave - Agricultura de Precisão; Sistema de Informação; Visão por Computador; Processamento Digital de Imagem; Redes Neurais Artificiais.

Abstract — Organizations of the agro-industrial sector, are now increasingly investing in the development of technological systems that allow the computerization of all its processes. Recently the methods and techniques of computer vision have been widely used for monitoring and inspection during the production and harvesting, allowing detect problems early and thus, improve the quality of products. In the field of mushroom production one of the most important aspects, and perhaps most prevalent, is to be able to predict its production. To this end it is proposed an Intelligent System Mushroom Harvest Forecast (SIPCC), based on techniques and methods of computer vision and Artificial Neural Networks (ANN). This paper presents an architecture of a SIPCC functional and technical level, complemented with the analysis and presentation of data demonstrating its viability.

Keywords - Precision Agriculture; Information System; Computer Vision; Digital Image Processing; Artificial Neural Networks.

I. INTRODUÇÃO

Os Sistemas de Informação (SI) são o ponto fulcral de uma organização, permitem uma ligação entre todos os departamentos de uma empresa desde o colaborador com a tarefa mais simples até aos gestores, permitem criar fluxos de trabalho automatizados para dar resposta às necessidades da organização, criando a informação necessária como pilar chave para o sucesso [1] [2] [3] [4]. Na área da agricultura tem havido um grande investimento no desenvolvimento de SI, que permitem obter a informação preponderante que permite aumentar a competitividade entre organizações concorrentes [5] [3] [6].

Muitas organizações já possuem incorporados no seu SI, sistemas baseados em visão por computador e Processamento Digital de Imagem (PDI) que permitem obter informação em diferentes espaços temporais das suas produções como também nas colheitas. Como é necessário, cada vez mais, ter em consideração às necessidades dos clientes, é fundamental, aproveitar os métodos já usados para controlo, para fazer uma previsão das colheitas [7]. O objetivo deste trabalho de investigação é apresentar no setor agroalimentar de produção de cogumelos, em particular, da produção da espécie *Agaricus bisporus*, um sistema tecnológico de previsão de colheita que permita saber antecipadamente o tipo de produto que poderá ser colhido e que possa satisfazer as encomendas em função da qualidade especificada nas fichas técnicas de produto dos clientes.

Ao longo do presente artigo vai ser tratado a partir da secção dois um estado da arte sobre o tema, caracterização do problema com os objetivos que se pretendem e apresentação e especificação de uma possível arquitetura de um Sistema Inteligente de Previsão de Colheita de Cogumelos (SIPCC), na terceira e quarta secções, apresentação de testes e análise de resultados e na quinta e ultima secção as respetivas conclusões.

II. ENQUADRAMENTO TEÓRICO

A. Agricultura de Precisão

A Agricultura de Precisão (AP) atualmente é um conceito muito importante para o desenvolvimento e expansão do agronegócio a nível mundial. A necessidade constante de uma maior produtividade e consequentemente na obtenção de qualidade nos produtos na área da agroindústria, exige que produtores agrícolas utilizem cada vez mais equipamentos tecnológicos para monitorização das suas produções, que permitem obter informações do estado atual do seu desenvolvimento e identificar possíveis problemas das mesmas. Com este sistema é possível obter informações, que permitem ao produtor tomar decisões para um melhoramento das produções e uma rápida atuação na resolução dos problemas num espaço temporal adequado. Deste modo tornam-se mais competitivos no mercado, enquanto que aqueles que não usam a tecnologia a seu favor acabam por perder capacidade tornando-os menos competitivos [8].

Assim poder-se-á definir a AP como um sistema de cultura que visa a gestão dos espaços de produção, com o objetivo de melhorar o rendimento económico da atividade agrícola, quer pelo aumento da produtividade e/ou qualidade, quer pela redução dos custos de produção, reduzindo também o seu impacto ambiental e riscos associados. Na prática, segundo Braga and Pinto [9] o que marca a diferença na AP é realmente a variabilidade espacial da produtividade e dos recursos em que é considerado um sistema tecnológico, onde é dada uma grande importância aos recursos, dos fatores de produção e da produtividade conjuntamente com a qualidade, de forma a garantir uma melhor performance física económica e ambiental das áreas de exploração agroindustrial.

B. Visão por Computador

A Visão por Computador é uma área de pesquisa muito recente e tem sido muito relevante na AP, permite efetuar a extração de informação significativa de imagens digitais através de equipamentos adequados, ou seja, permite fazer a identificação e análise de objetos contidos em imagens através de processos específicos, as imagens funcionam como entrada de dados e como saída a interpretação parcial ou total da mesma [10]. Estas imagens podem ser capturadas pelos mais variadíssimos equipamentos, como câmaras fotográficas, vídeos, sensores entre outros dispositivos. A identificação e manipulação destes objetos permite obter informação para automatizar as tomadas de decisões mediante um problema.

Normalmente este método apresenta a capacidade de fazer o reconhecimento em imagens através da aplicação de técnicas e algoritmos que permitem extrair e apresentar a informação relevante e pretendida. O método de Visão por Computador inclui o modo como é feita a captura da imagem, o processamento e análise das mesmas, com esta técnica é possível detetar e isolar um determinado objeto de referência pretendido.

Na aplicação deste conceito, é necessário obter imagens que são a matéria de suporte deste método, para tal é necessário o uso de equipamento tecnológico como sensores e câmaras para a aquisição das imagens, estes são escolhidos em função do tipo de objeto ou amostra que se pretende detetar e analisar incluindo o tipo de imagem que se pretende captar. A área da agricultura

tem abrangido uma grande parte destes estudos, é na AP onde é necessário ter disponível um conjunto de sensores específicos para obtenção das imagens necessárias, são utilizados sensores baseados na espectroscopia de refletância ou seja em medidas de reflexão da radiação eletromagnética, são usados também sensores de infravermelhos, dos quais infravermelho próximo, *Near Infrared* (NIR), infravermelho de ondas curtas, *Short Wave Infrared* (SWIR) e sensores térmicos para deteção de transpiração e redução de CO₂ nas plantas [11].




Figura 1: Esquema de um típico sistema de visão por computador (adaptado de Zhang, et al. [7])

Este sistema (Figura 1), apresenta uma estrutura típica que permite fazer a captura das imagens para serem analisadas usando a tecnologia de Visão por Computador, sendo constituída por cinco componentes básicos: iluminação, a câmara com o filtro adequado, um tabuleiro de captura, um computador para processamento da imagem e um motor que faz movimentar o tabuleiro permitindo captar imagens de várias amostras [12]. O processamento da imagem é o ponto mais importante, através da aplicação de algoritmos específicos é retirada a informação relevante para o utilizador. Estes algoritmos podem ser aplicados em função das características que apresenta a imagem, como a cor, textura, forma, geometria ou padrão [13].

C. Técnicas de Previsão por Computador

A previsão é para múltiplas áreas de atividade um fator que pode trazer mais valias na modelação e definição dos produtos ou recursos, levando ao crescimento das organizações. Existem alguns métodos ou algoritmos de previsão, com base estatística e de inteligência artificial, como possível abordagem para a determinação de resultados futuros. Os métodos estatísticos, como a Regressão Linear Múltipla e Alisamento Exponencial são técnicas matemáticas bem desenvolvidas, mas dependem de uma modelação matemática complexa, e não são tão suscetíveis a variações rápidas das variáveis. Os métodos de inteligência artificial dos quais a Lógica de *Fuzzy* e as Redes Neurais Artificiais (RNA), permitem uma forma mais fácil e eficaz de lidar com a incerteza dos valores que as variáveis possam apresentar, tendo estes métodos, sido bem aceites pela comunidade científica [14].

O SIPCC irá ter como suporte um conjunto de dados, que não apresentam linearidade entre si devido às características do produto em estudo. Por este motivo entende-se que pela grande capacidade de modelação de dados dispersos, comprovado por trabalhos realizados na previsão de gastos de energia elétrica

[10], a RNA será o método mais adequado a aplicar neste contexto.

D. Integração do Sistema

O grupo Sousacamp, que é constituído maioritariamente por empresas do ramo agroalimentar, tendo como atividade principal a produção de cogumelos frescos, dos quais o cogumelo branco (*Agaricus bisporus*) sendo a espécie mais importante dos cogumelos comestíveis [15]. O seu mercado principal é a Península Ibérica, encontrando-se, atualmente, em expansão para outras zonas geográficas, tais como: Norte de África e América Latina, produzindo elevadas quantidades todos os dias e com colheitas feitas em função de condições específicas exigidas pelos clientes como diferentes calibres (diâmetro do cogumelo em mm) [6].

Devido à sua rápida produção e características específicas, é difícil obter um método que faça o seu controlo produtivo e posterior previsão de colheita. De modo a poderem dar respostas face às encomendas dos vários clientes, a previsão em função do desenvolvimento temporal da produção é feita por técnicos especializados de uma forma manual, levando a margens de erro dispersas, podendo causar problemas de incumprimento com os clientes.

A empresa possui um modelo de negócio que é suportado por uma arquitetura de um SI que abrange todos os setores, dos quais a gestão de produção contendo o subcomponente de gestão de colheita. Pretende-se desenvolver um artefacto (SIPCC) que integre com os sistemas existentes. A produção constante de cogumelos requiere o recurso a sistemas automáticos de controlo, que criem o ambiente favorável para a produção, como sistemas de controlo de temperatura, ventilação e humidade. Existem etapas na produção de cogumelos que são difíceis de serem automatizadas como a colheita e a previsão da mesma. É com o intuito de começar a automatizar a forma de previsão e posterior colheita, que se pretende apresentar um sistema automatizado de previsão de colheita, em que no componente de gestão de produção, se pretende apresentar um subcomponente de previsão de colheita integrado com os subcomponentes já existentes (Figura 2).




Figura 2: Fluxo produtivo de cogumelos com a proposta do subcomponente de Previsão Inteligente de colheita (adaptado de [6])

E. Arquitetura Geral do Sistema Inteligente de Previsão de Colheita de Cogumelos

A Arquitetura do SIPCC tem como base um conjunto de requisitos obtidos através das necessidades dos utilizadores para que o sistema forneça os resultados pretendidos. Neste caso, o que se pretende obter é a representação geral de uma arquitetura que demonstre as várias camadas que o sistema irá ter em função dos requisitos definidos. Esta é constituída por quatro camadas (Figura 3): a) obtenção da imagem, onde o sistema capta as imagens; b) armazenamento e processamento das imagens; c) após o processamento das imagens fazer uma recolha e

processamento dos dados pretendidos; d) obtenção da previsão. Cada uma destas camadas são especificadas através de diagramas, e através desta arquitetura será demonstrado que o sistema está integrado na arquitetura geral do sistema de informação através da gestão de produção.

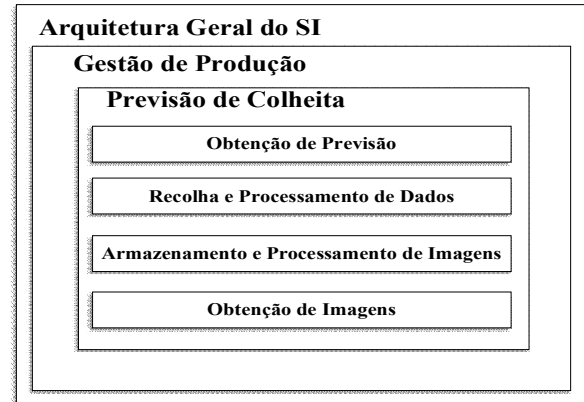


Figura 3: Arquitetura geral do Sistema Inteligente de Previsão de Colheita de Cogumelos

De modo a demonstrar a interação do sistema com o utilizador são utilizados os Casos de Uso da *Unified Modeling Language* (UML). Neste caso pretende-se demonstrar como o utilizador poderá interagir com o sistema (funcionalidades do sistema) e dar uma visão externa do sistema. Como se pode observar, são definidos dois atores, Técnico de Previsão e Técnico de Colheita, estes são os utilizadores indicados que devem interagir com o sistema diretamente, através dos vários casos de uso definidos: Adquirir imagem; Autenticar; Armazenar imagens; Processar imagens; Processamento e análise de dados; Obter previsão (Figura 4).

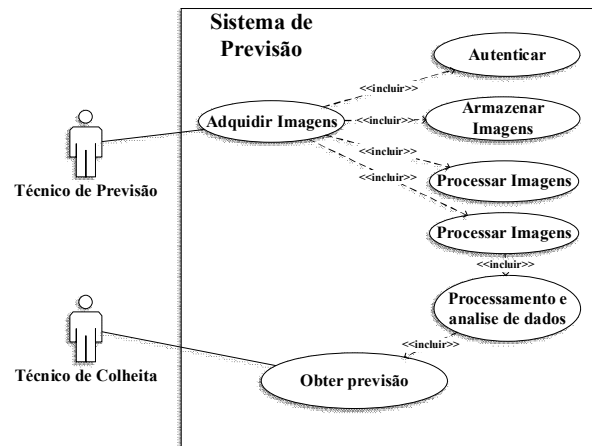


Figura 4: Diagrama de casos de uso do SIPCC

F. Arquitetura do Sistema Físico de Captura de Imagem

Para se efetuar a captura de imagens que vão servir de suporte de informação para o SIPCC, é necessário implementar uma estrutura física adaptada aos níveis metálicos instalados nas salas de produção. A produção é efetuada em salas com

ambiente controlado e cada sala contém duas secções com 14 níveis divididos em duas filas (Figura 6).

O presente sistema de produção não pode ser alterado, sem incorrer em fortes investimentos, os quais não são exequíveis para esta e outras empresas do ramo. O objetivo é adaptar o sistema de captura de imagens à estrutura existente e que implique o mínimo de modificações necessárias.

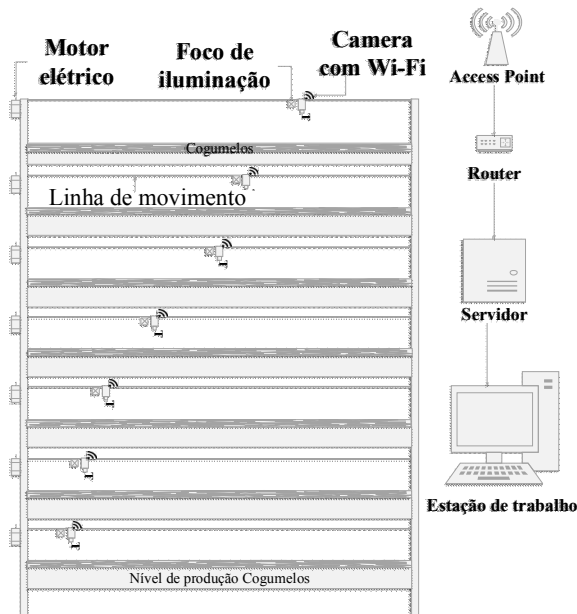


Figura 5: Estrutura física do sistema de captura de imagens

Após ponderação das condicionantes estruturais impostas, é apresentada a arquitetura do sistema físico para a obtenção das imagens (Figura 5), que contém todo o equipamento tecnológico necessário e a sua localização.

Cada nível de produção contém uma câmara, ou sensor digital, com sistema Wireless fixado a uma linha de movimento, em que esta poderá ser movimentada por um motor elétrico programado para deslocamento da câmara ao longo do nível, com paragens estipuladas, de acordo com a total cobertura na captura das imagens. Cada câmara poderá ser regulada manualmente ou poderão ser introduzidas calibrações automáticas de modo a obter a resolução adequada para a obtenção da imagem nas medidas corretas. Também contém um foco de iluminação, que permite ter iluminação constante para a captura de imagens nítidas. Como cada câmara possui tecnologia *Wireless*, tem a possibilidade de estarem conectadas a um *access point* que permite fazer a ligação por Internet Protocol (IP) a um servidor para armazenamento de imagens e estas serem acedidas por uma estação de trabalho para serem processadas.

Como um dos pressupostos é a menor interferência possível com a estrutura, optou-se pelo uso mínimo de cablagens e materiais que gerem calor que poderiam alterar o ambiente das salas e afetar a produção.

III. IMPLMENTAÇÃO E TESTES

Para efetuar os métodos experimentais, para avaliar a viabilidade da aplicação SIPCC, foram usadas as instalações da unidade de produção de cogumelos situada em Vila Real, do Grupo Sousacamp. Nesta unidade são produzidos dois tipos de cogumelos, o Champignon de Paris (cogumelo branco) e o Marron (cogumelo castanho) (Figura 6). Neste estudo só foi considerado para testes o cogumelo branco.



Figura 6: Sala de produção de cogumelos

Estes tipos de cogumelos são produzidos em salas preparadas para o efeito, estas salas são devidamente esterilizadas e é induzido um ambiente controlado, com temperatura, humidade e pressão adequados para criar as condições ideais para uma produção constante.

A. Recolha e Processamento de Imagens e Extração de Informação

Como o sistema de previsão proposto é baseado em Visão por Computador e processamento digital de imagem, como proposto (Figura 5), foi necessário criar um método que fosse capaz de fazer a captação das imagens de uma forma homogênea, simulando o cenário da arquitetura física proposta. Cada nível está dividido em 13 secções, sendo capturada uma imagem, utilizando um ponto fixo em cada secção. A área da imagem está representada a preto na Figura 7.




Figura 7: Esquema de um nível dividido em 13 secções com a especificação da área da imagem capturada (quadrado preto)

Em função da área de cada secção e a área abrangida por cada imagem capturada, concluiu-se que era necessário a captura de 30 imagens com o equipamento utilizado para cobrir toda a área de cada secção. Como referido o processamento das imagens é um dos processos mais importantes incorporados no sistema inteligente. As imagens capturadas vão ser submetidas a um processamento (aplicação de algoritmos), para fazer a identificação dos respetivos cogumelos (objetos). Para o

processamento das imagens capturadas foi utilizado o software Matlab r2017b, recorrendo às funções e métodos disponibilizado pelo mesmo. Os cogumelos foram identificados através da sua forma (círculos), mas devido à sua pigmentação quase nula, geralmente apresentam cor branca homogênea, é difícil fazer corretamente a identificação individualizada de cada um. Atendendo às condicionantes, para obter o máximo de precisão, procedeu-se de acordo com o fluxograma da Figura 8: (i) conversão em escala cinzenta (preto e branco) de todas as imagens em escala RGB; (ii) segmentação da imagem (transformação da imagem em binário), neste ponto já se pode ver uma separação dos cogumelos (realce dos objetos a identificar) do resto do conteúdo da imagem; (iii) aplicação de dois filtros, um para eliminação de ruídos e outro para fazer uma pequena erosão (limpeza) em torno dos cogumelos para que estes fiquem mais definidos; (iv) caso os cogumelos fiquem com uma definição aceitável avança-se para o passo seguinte, senão tem que se fazer uma calibração dos filtros; (v) aplicar uma função que vai realizar a identificação final dos cogumelos através de círculos (Figura 9), permitindo obter o número de cogumelos identificados e o calibre através do raio e centro de cada um, em pixels.

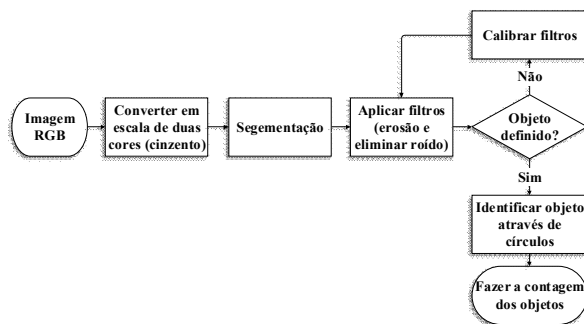


Figura 8: Fluxograma do processamento das imagens e extração da informação




Figura 9: Detecção dos cogumelos, à direita imagem segmentada e à esquerda a imagem RGB

Como se pode verificar, a taxa de identificação, aplicando este conjunto de funções é satisfatória, visto que se consegue detetar um total de 56 cogumelos (calibres de 30 a 60 mm) com uma margem de erro mínima. Alguns erros estão demonstrados a azul, na Figura 9, devido ao elevado nível de calibração dos filtros, que eliminam o ruído e efetuam a erosão, surgindo erradamente algumas identificações.

B. Técnica Usada para Previsão – Redes Neurais Artificiais

Devido à dificuldade em obter os dados, uma das alternativas estudadas e a mais indicada para o tipo de problema proposto

como visto anteriormente, é o uso de Redes Neurais Artificiais (RNA) baseadas em padrões de reconhecimento para aprendizagem. Atendendo à capacidade das RNA de resolverem os mais variados tipos de problemas complexos, e a capacidade de trabalhar com dados de uma grande discrepância nomeadamente de variáveis que não apresentam nenhuma relação entre si (não linearidade) e a sua estrutura robusta, é o mais aconselhado para este tipo de problema ao permitir a obtenção de resultados que comprovam a viabilidade do desenvolvimento de um sistema de colheita baseado em RNA [16].

A lógica de uma RNA é a simulação de um neurónio biológico, contém múltiplas unidades de processamento que são os neurónios e funciona da seguinte forma (Figura 10): recebe valores de entrada, conhecidas por variáveis de entrada (X_i), estas entradas são ponderadas por pesos sinápticos (W_i) que é um valor associado a cada entrada e onde é introduzido o bias (b_i), limiar de ativação que normalmente é um valor constante; todos os valores ponderados são somados inicialmente e este valores (μ_i) são transferidos para a função de ativação ($f(\cdot)$), que vai gerar a saída pretendida (y_i) [14].




Figura 10: Esquema de uma Rede Neural Artificial

Neste caso para o desenvolvimento da RNA pretendida foi usado o software Matlab r2017b, usando a Neural Network Toolbox (NNTool). Existem vários tipos de RNA e estes são aplicados mediante o tipo de problema e o tipo de resultado que se quer obter. Neste estudo o tipo de rede adotada foi do tipo *Feed-forward backpropagation* com três camadas (camadas de entrada, escondida e saída), devido ao tipo de dados com que se vai trabalhar.

Para a recolha de dados foram usados 30 casos que correspondem a 30 níveis de produção (Figura 7), 24 casos (níveis) com 312 secções foram utilizados para treino da RNA e 7 casos (níveis) com 91 secções para a validação da mesma. No total foram recolhidas 806 imagens, uma em cada secção, assumindo-se que o crescimento dos cogumelos é praticamente homogêneo em toda a área, em função da área da secção e da área abrangida para a captura da imagem, conclui-se que o número de cogumelos identificados após o processamento da imagem (ponto A da secção III) foi multiplicado por 30 (Figura 7), para garantir o número aproximado real de cogumelos em cada secção.

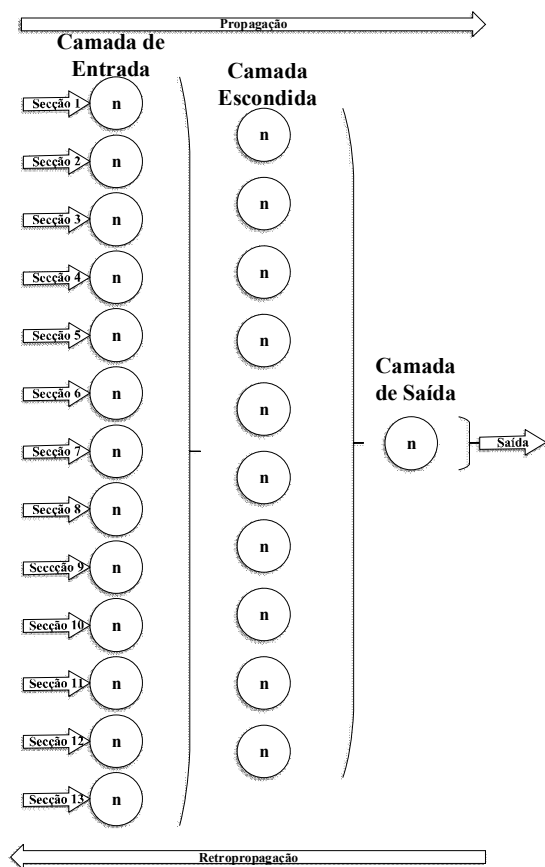


Figura 11: Arquitetura da RNA implementada.

O desenvolvimento do cogumelo até à colheita demora, em média, 4 semanas, e por isso, foram definidos dois intervalos de tempo para a recolha de dados, um na segunda semana de produção, que originou o vetor de entrada (matriz de 24x13) e, o segundo, na semana 3 que originou o vetor alvo (matriz de 1x24), que são os resultados que se pretende que a rede atinja, originado a RNA representada pela arquitetura da Figura 11. Após o treino da rede obteve-se um output que corresponde aos totais em Kg de cada nível. Para validação da rede procedeu-se de igual forma, só sendo necessário a utilização dos dados recolhidos da semana 2 referente aos 7 casos (matriz de 13x7).

IV. ANÁLISE DOS RESULTADOS

Após a implementação, treino e aplicação de testes da RNA, obteve-se um conjunto de resultados, que foram apresentados pela rede, através de um vetor output_previsao1 (vetor de saída, matriz de 1x24) na camada de saída, que se refere aos valores gerados pela rede após o treino, e um vetor output_errors (matriz 1x24), que se refere à margem de erros apresentados pela mesma mediante o treino, este erro é calculado através da diferença dos valores do vetor semana3 e vetor previsao1_output (Tabela I).

TABELA I: RESULTADOS APRESENTADOS PELA REDE APÓS O TREINO DA RNA

| | | | | Total real em Kg | 7625,00 | |
|--------|-------|-------------------|------------------|------------------|-------------------------|---------|
| Níveis | | Quantidades em KG | previsao1_output | previsao1_errors | | |
| | 1 | 330,0 | 437,25 | -107,25 | Total em Kg da previsão | 8076,54 |
| | 2 | 372,0 | 380,01 | -8,01 | Erro total em Kg | 451,54 |
| | 3 | 320,0 | 431,88 | -111,88 | Erro médio em Kg | 18,81 |
| | 4 | 206,0 | 208,61 | -2,61 | Percentagem de erro | 5,9% |
| | 5 | 296,0 | 279,99 | 16,01 | | |
| | 6 | 346,0 | 333,84 | 12,16 | | |
| | 7 | 426,0 | 424,44 | 1,56 | | |
| | 8 | 362,0 | 365,14 | -3,14 | | |
| | 9 | 410,0 | 346,34 | 63,66 | | |
| | 10 | 442,0 | 440,87 | 1,13 | | |
| | 11 | 284,0 | 277,99 | 6,01 | | |
| | 12 | 265,0 | 305,11 | -40,11 | | |
| | 13 | 233,0 | 413,67 | -180,67 | | |
| | 14 | 363,0 | 449,60 | -86,60 | | |
| | 15 | 279,0 | 271,60 | 7,40 | | |
| | 16 | 328,0 | 333,89 | -5,89 | | |
| | 17 | 415,0 | 414,89 | 0,11 | | |
| | 18 | 247,0 | 251,14 | -4,14 | | |
| | 19 | 220,0 | 231,41 | -11,41 | | |
| | 20 | 160,0 | 193,36 | -33,36 | | |
| | 21 | 230,0 | 244,46 | -14,46 | | |
| | 22 | 317,0 | 273,60 | 43,40 | | |
| | 23 | 320,0 | 315,80 | 4,20 | | |
| 24 | 454,0 | 451,65 | 2,35 | | | |

Nota: Os valores da previsao1_errors, são valores negativos e positivos devido ao tipo de função de ativação aplicada na RNA.

Como se pode observar através da Tabela I, entre o total em Kg de cogumelos identificados (Total real em Kg), que é igual ao total do conjunto de valores introduzidos na rede, como alvo pretendido que a rede atingisse no seu treino e o total de valores (output) apresentado após a rede treinada (Total em Kg da previsão) representa um erro total de 451,54 Kg, o que indica que houve um erro médio em 18,81 Kg por secção, sendo equivalente a uma percentagem de erro de 5,9% perante os 24 casos utilizados para treino, esta percentagem foi calculada entre quantidade total em Kg e o erro total. Perante estes resultados pode-se concluir que os valores obtidos pelo treino da rede são satisfatórios, obtendo um erro de 18.81 Kg por secção, o que na realidade e, em função das previsões feitas pelos técnicos de colheita, é considerado um erro mínimo e aceitável.

TABELA II: RESULTADOS APRESENTADOS APÓS TESTAR A RNA

| | Níveis | | | | | | |
|-------------------------|---------|---------|--------|--------|---------|---------|---------|
| | 1 | 2 | 3 | 4 | 5 | 6 | 7 |
| Quantidade em Kg | 244 | 226 | 176 | 172 | 256 | 240 | 414 |
| previsao1_outputs_teste | 399,93 | 403,1 | 424,9 | 387,2 | 400,33 | 448,65 | 452,16 |
| Erro | -155,93 | -177,12 | -248,9 | -215,2 | -144,33 | -208,65 | -38,159 |
| Total real em Kg | 1728 | | | | | | |
| Total em Kg da previsão | 2916,3 | | | | | | |
| Erro total em Kg | 1188,3 | | | | | | |
| Erro médio em Kg | 169,756 | | | | | | |
| Percentagem de erro | 68,77 % | | | | | | |

Nota: Os valores Erro, são valores negativos e positivos devido ao tipo de função de ativação aplicada na RNA.

Os resultados apresentados após fazer o teste da rede utilizando os 7 casos restantes, como se pode analisar na Tabela II, a diferença de erro entre a quantidade real (Total real em Kg), e a quantidade prevista (Total em Kg da previsão) pela rede, já apresentou um erro médio muito maior de 169,75 Kg por secção, sendo o erro menor só no caso 7 e apresentando uma percentagem de erro de entre quantidade real total e o erro total dos valores de previsão de 68,77%. Isto leva a concluir que seriam necessários mais casos tanto para treino da rede como para testes.

V. CONCLUSÕES

Os sistemas inteligentes de previsões tecnológicos são cada vez mais uma área de interesse a ter em consideração pelas organizações, pelos benefícios que estes podem trazer, funcionando como alavancagem de um crescente investimento na área agroindustrial. Pelo facto destes sistemas acolherem uma grande quantidade de dados, que podem ser de diferentes fontes, a sua implementação torna-se um caso complexo e que requer um maior investimento.

Na primeira fase, com base na análise funcional, é proposta uma arquitetura do sistema, SIPCC, de forma simples e compreensível, devido à pormenorização e especificação de todos os processos base relevantes, para que este pudesse ser implementado. A segunda fase, que consistiu na construção da RNA, para obter a previsão de colheita, os dados obtidos foram muito fiáveis, uma vez que o output (previsão) obtido da RNA foi muito satisfatório, obtendo-se quantidades em Kg muito próximas de quantidades analisadas de dados históricos.

Futuramente pretende-se melhorar o método de recolha de dados (imagens) e o seu posterior processamento de forma a obter uma melhor performance da RNA. Neste estudo só foram analisados calibres de cogumelos (30 mm a 60 mm), mas tem-se como finalidade expandir este método ao resto dos calibres produzidos.

REFERÊNCIAS

- [1] R. K. Rainer, C. G. Cegielski, I. Splettstoesser-Hogeterp, and C. Sanchez-Rodriguez, *Introduction to information systems*: John Wiley & Sons, 2013.
- [2] F. Branco, R. Gonçalves, J. Martins, and M. P. Cota, "Decision Support System for the Agri-food Sector—The Sousacamp Group Case," in *New Contributions in Information Systems and Technologies*, ed: Springer, 2015, pp. 553-563.
- [3] F. Branco, J. Martins, R. Gonçalves, J. Bessa, and A. Costa, "A decision support platform for IT infrastructure management: The university of Trás-os-Montes e Alto Douro services of information and communications case study," in *Information Systems and Technologies (CISTI), 2015 10th Iberian Conference on*, 2015, pp. 1-7.
- [4] R. Gonçalves, J. Martins, F. Branco, M. R. G. Castro, M. P. Cota, and J. Barroso, "A new concept of 3D DCS interface application for industrial production console operators," *Universal Access in the Information Society*, vol. 14, pp. 399-413, 2015.
- [5] A. Z. Abbasi, N. Islam, and Z. A. Shaikh, "A review of wireless sensors and networks' applications in agriculture," *Computer Standards & Interfaces*, vol. 36, pp. 263-270, 2014.
- [6] F. A. S. Branco, "Uma proposta de arquitetura de sistema de informação para as empresas agroalimentares do setor de produção de cogumelos: O caso Grupo Sousacamp," PhD, School of Science and Technology, University of Trás-os-Montes e Alto Douro, Vila Real, 2014.
- [7] B. Zhang, W. Huang, J. Li, C. Zhao, S. Fan, J. Wu, *et al.*, "Principles, developments and applications of computer vision for external quality inspection of fruits and vegetables: A review," *Food Research International*, vol. 62, pp. 326-343, 2014.
- [8] M. R. Borth, J. C. Iacia, H. Pistori, and C. F. Ruviaro, "A visão computacional no agronegócio: Aplicações e direcionamentos," *7º Encontro Científico de Administração, Economia e Contabilidade (ECAECO)*, 2014.
- [9] R. Braga and P. A. Pinto, "Agricultura de precisão: Adopção & principais obstáculos," 2011.
- [10] M. Marengoni and S. Stringhini, "Tutorial: Introdução à visão computacional usando opencv," *Revista de Informática Teórica e Aplicada*, vol. 16, pp. 125-160, 2009.
- [11] L. Jorge and R. Y. Inamasu, "Uso de veículos aéreos não tripulados (VANT) em agricultura de precisão," *Embrapa Instrumentação-Capítulo em livro científico (ALICE)*, 2014.
- [12] H. H. Wang and D. W. Sun, "Correlation between cheese meltability determined with a computer vision method and with Arnott and Schreiber tests," *Journal of Food Science*, vol. 67, pp. 745-749, 2002.
- [13] Y. Zhao, L. Gong, Y. Huang, and C. Liu, "A review of key techniques of vision-based control for harvesting robot," *Computers and Electronics in Agriculture*, vol. 127, pp. 311-323, 2016.
- [14] S. Chemetova, P. Santos, and M. Ventim-Neves, "Load forecasting as a computational tool to support smart grids," in *Information Systems and Technologies (CISTI), 2017 12th Iberian Conference on*, 2017, pp. 1-6.
- [15] J. E. Sanchez, L. Mejia, and D. J. Royse, "Pangola grass colonized with *Scytalidium thermophilum* for production of *Agaricus bisporus*," *Bioresource technology*, vol. 99, pp. 655-662, 2008.
- [16] A. J. Freitas Leal, E. Pereira Miguel, F. H. Rojo Baio, D. de Carvalho Neves, and U. A. Severino Leal, "Redes neurais artificiais na predição da produtividade de milho e definição de sítios de manejo diferenciado por meio de atributos do solo," *Bragantia*, vol. 74, 2015.