

多结构参数集成学习的设施黄瓜病害智能诊断

高荣华, 李奇峰^{*}, 孙 想, 顾静秋, 彭 程

(1. 北京农业信息技术研究中心/北京市农林科学院, 北京 100097; 2. 国家农业信息化工程技术研究中心, 北京 100097; 3. 农业农村部农业信息技术重点实验室, 北京 100097; 4. 北京市农业物联网工程技术研究中心, 北京 100097)

摘 要: 单一特征已不能很好的描述作物病害典型特征, 而生长环境参数(土壤温湿度、pH 值、空气温湿度等)与病害密切相关, 多结构数据学习向量化与特征最优组合能够有效提升病害诊断准确性。该研究以黄瓜白粉病、角斑病、炭疽病、菌核病 4 种病害 50 个样本为实例, 融合结构化作物生长环境参数与非结构化图像特征, 通过智能化物联网, 对实时采集到的环境参数进行监测、分析, 并将其与图像特征融合, 构建多结构病害特征最优组合模型。试验结果表明, 样本识别率在 79.4%~93.6%, 对比卷积神经网络图像识别率, 卷积神经网络由于需要对病害图像数据进行降维, 后台识别时间较高; 深度迁移学习的图像识别方法, 需要大量图像数据输入深度网络学习, 而现实中病害图像数量不足以满足深度学习要求, 因此识别率会因为样本不充分而降低; 该方法借助少量图像数据, 同时结合环境与专家知识资源, 采用多结构参数集成学习的方法进行病害识别, 在较少识别时间的基础上确保识别的准确性。

关键词: 图像识别; 智能系统; 病害; 多结构参数; 学习向量化; 智能诊断

doi: 10.11975/j.issn.1002-6819.2020.16.020

中图分类号: TP391

文献标志码: A

文章编号: 1002-6819(2020)-16-0158-08

高荣华, 李奇峰, 孙想, 等. 多结构参数集成学习的设施黄瓜病害智能诊断[J]. 农业工程学报, 2020, 36(16): 158-165.

doi: 10.11975/j.issn.1002-6819.2020.16.020 <http://www.tcsae.org>

Gao Ronghua, Li Qifeng, Sun Xiang, et al. Intelligent diagnosis of greenhouse cucumber diseases based on multi-structure parameter ensemble learning[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2020, 36(16): 158-165. (in Chinese with English abstract) doi: 10.11975/j.issn.1002-6819.2020.16.020 <http://www.tcsae.org>

0 引 言

互联网与多媒体技术的发展, 使得以图像等为载体的多媒体信息在设施农业中迅速增加, 以多种方式进行信息交换的多种媒介具有集成性、交互性等特点^[1-5]。当前知识传播方式越来越具有多源、多形态、多属性等特性, 这些从不同渠道获取的不同形态的媒体信息描述共同的知识, 使得信息的产生、发展、传播跨越互联网等多种信息来源, 跨越从不同渠道获取的文本、图像等多种信息形态, 因此, 如何从形态多变、分布零散、属性复杂的海量媒体资源中对有价值的知识进行获取和表达成为亟待解决的问题。

环境、病害图像、病害知识等多结构参数数据在作物生产、保护方面的智能诊断研究已取得显著成果^[6-8], Scott 等^[9]在英国植保生物学信息技术大会上, 提出利用数据库、分类学、多媒体等技术, 实现植病流行病学模拟与预测模型、植病诊断与管理专家系统, 实现了结合多媒体与文本知识的智能诊断, 但仅是逐步递推的诊断过程; Chesmore 等^[10]通过对图像的特征提取实现真菌诊断,

但因受光照、遮挡影响造成特征提取不准确而导致诊断不具有鲁棒性。Brahimi 等^[11]对 9 种西红柿叶片病害进行分析, 获得较好的识别效果。

日本九州佐贺县的全自动蔬菜工厂^[12], 实现蔬菜安全的监管, 作物生长周期比较漫长, 保存了大量的多媒体数据, 但对于如何有效融合多媒体数据与其他结构数据, 提取有价值信息, 还没有相关研究。联邦农业教育研究所对小麦品种的水肥条件、品种特性、产量品质、抗病虫害等能力进行评估, 利用计算机辅助诊断系统为农民提供病害防治服务^[13-15], 但没涉及图像等非结构化知识数据, 完全依靠专家知识模型进行诊断, 不具备较好的智能性。随着“物联网+大数据+互联网”模式在农业信息化中的发展, 越来越多的研究者将图像处理和机器视觉技术引入农作物病害识别诊断中, 取得了大量研究成果^[16-18]。

中国多媒体技术分析诊断在各领域研究已取得一定成果^[19-22], 利用多媒体技术开发了各种农作物病虫害诊断咨询系统^[23-24], 将各类病虫害症状、形态和病理特性可视化、图形化, 将复杂的病虫害识别与诊断过程简单化, 如郭小清等^[25]利用多尺度识别模型构建了番茄叶部病害图像识别系统, 识别率为 89.2%; 刘洋等^[26]在手机端开发了植物病害叶片检测系统, 实现葡萄病害叶片共 38 类 26 种病害在线识别; 马浚诚等^[27]基于图像和深度学习技术, 构建了温室黄瓜病害识别系统, 在图像分割的基础上, 有效识别黄瓜霜霉病、白粉病。

收稿日期: 2020-04-20 修订日期: 2020-07-05

基金项目: 国家自然科学基金(61771058); 北京市自然科学基金(4172025)

作者简介: 高荣华, 副研究员, 研究方向为农业多媒体数据分析。

Email: gaorh@nercita.org.cn

^{*}通信作者: 李奇峰, 副研究员, 研究方向为农业信息化。

Email: liqf@nercita.org.cn

农业专家系统方面，将多媒体技术与物联网、数据库管理、人工智能、农业专家系统、知识库、推理机等技术相结合，开发智能诊断支持系统^[28-30]，如基于物联网的荔枝专家诊断系统^[31]、多媒体水稻病害专家系统^[32]等已被广泛应用到农业生产中，并产生巨大的效益。中国农业大学采用多媒体、超媒体与人工智能等技术，研制开发“北京蔬菜生产管理与植保辅助诊断系统”与“植物害虫图文信息与鉴定辅导系统”，推动多媒体技术在农业生产信息化中的应用。

上述的农业智能诊断系统，多数仍停留在对专家知识的推理或单一的多媒体特征识别与特征匹配方面，很少涉及到多结构、多形态、多参数数据^[33]。单一特征不能很好的描述病害的典型特征，蔬菜的病害与其生长环境参数（土壤温湿度、pH 值、空气温湿度等）、种植参数密切相关。

本文以设施黄瓜病害智能诊断为实例，融合结构化生长环境参数与非结构化图像特征，提出一种多结构参数集成学习的设施黄瓜病害智能诊断技术，以图像视觉特征与环境特征之间的典型相关性分析为基础，对实时采集到的环境参数进行监测、分析，并将其与图像特征融合，分析黄瓜典型病害相关性，实现不同环境参数下，设施黄瓜易发病害的智能诊断分析。

1 多结构参数数据分析

1.1 数据多路径分组传输

传感器密集分布的实时嵌入式设施农业物联网，通过无线传感器节点，实时采集作物生长环境中各种影响因子的数据信息、图像等，并将数据发送给计算资源，计算资源根据实体信息做出决策^[34-36]，而不同结构数据，由于单一的传输协议不能很好地适应异构的数据结构，传输过程中更容易受到噪声或干扰的影响。

为确保所接收的多结构数据正确可靠，本文基于多媒体传感器网络感知模型，提出一种多路径分组传输方法保证多结构数据传输可靠性，采集得到的多源异构数据不像传统多路径方法那样对每份数据沿多条路径传输，而是首先将数据按照不同数据类型（土壤温湿度、土壤 pH 值、空气温湿度等）分组，确保每组内的数据段等长，且分别赋予不同组标识：组 0, ... 组 N。在感知节点和汇聚节点之间构建多条路径，将不同类型、不同结构的数据组沿多条路径同时传输，提高吞吐量与数据传输的可靠性。如图 1 所示，将采集到的多结构数据进行分组标识后，通过多路径对同类型的数据参数进行传输。




图 1 物联网实时数据传输流程

Fig.1 Real-time data transmission flow of internet of things

假设无线多媒体传感节点组为 M_i ，在多路径数据传输中，数据源节点组根据应用的期望可靠性以及信道传输状况，将采集数据进行分组并沿着多条路径输出。采集数据通过感知节点向基站发送数据前，首先对采集数据按照结构类型分组描述，节点组内包括节点 ID、数据类型、数据分组字节大小 $size(data)$ 等字段。每组数据输出时间为 T_i ，

$$T_i = H_i V_i + (H_i + 1) [size(data) / f_{\min}]$$

$$= \sum_{i=0}^{H_i} V_i + \sum_{i=1}^{H_i+1} [size(data) / f(M_i)] \quad (1)$$

式中 V_i 是从采集数据到输出数据的各段路径所允许的数据传输速率， H_i 为第 i 组数据从采集节点到输出节点最多所允许的链路值。

$$H_i = \lfloor \frac{P_i - S_i}{V_i} \rfloor | i = 0, 1, \dots, N \quad (2)$$

式中 S_i 与 P_i 分别为第 i 组数据的采集节点数值与输出节点数值， $f(M_i)$ 定义为第 i 组路径上各节点数据处理速率，且 f_{\min} 为各节点数据处理最小速率。

$$f_{\min} = \min \{f(M_{i1}), f(M_{i2}), \dots, f(M_{iH_i+1})\} \quad (3)$$

$f(M_{i1}), f(M_{i2}), \dots, f(M_{iH_i+1})$ 分别为第 1 个节点到第 $H_i + 1$ 个节点的数据处理速率，计算得到分组后数据传输的时间为

$$T = \max \{T_0, T_1, \dots, T_N\} \quad (4)$$

通过分组传输，可以避免数据丢失，并节省传输时间，有效提高数据采集的准确性。

1.2 数据关联分析

多结构参数的一个重要特点是数据之间存在复杂多样的关联性，这种关联性能较好的提高智能诊断的正确性。由于多结构参数中蕴含着多种多样的数据，同模态数据中存在着关联，如文本（专家知识）与文本，图像（病害特征）与图像等，存在内容上的关联；不同模态的数据，如图像与文本间存在跨模态关联，连续固定的环境参数会产生作物在图像上的可视化内容。多结构数据间存在着结构关联，尽管关联类型多样，但不同类型的关联关系不能统一量化表达，无法进行有效病害预测。如图 2 所示，文本（专家知识）、图像、种植环境实时数据等异构互补的媒体形态共同表达了黄瓜白粉病，通过构建映射关系，将异构模态信息映射到共享子空间，在一个表达框架下直接对异构数据进行相似性度量，从而推断未知异构数据的关联关系。

多结构参数具有多源异构的特性，传统图遍历方法导致对其访问的效率比较低，本文提出一种集成式多结构参数索引结构，以文本（专家知识）、图像（非结构化数据）、种植环境（结构化数据）构成的黄瓜病害描述为例，选取其中的几种典型病害，定义病害模型函数 $f_i (i = 1, 2, \dots)$ ，并将描述其病害的专家知识、病害图像、种植环境信息定义为 $f_i (i = 1, 2, \dots)$ 的子函数，分别为 f_i^T, f_i^M, f_i^N ，子函数之间的

关联关系为 $\Omega(f_i^T, f_i^M, f_i^N)$, 病害模型 f_i 与多结构参数 f_i^T, f_i^M, f_i^N 之间的映射关系 C , 其中每种不同结构的参数体均与病害模型存在关联关系, 即 $C(f_i, \Omega) = \{\text{病害类别}\}$ 。当输入数据为黄瓜病害类别时, 通过匹配病害类别与多结构参数之间的关联关系函数, 分别从文本、图像、结构化的环境数据内搜索与病害类别匹配内容, 最后以多种结构展现的形式, 从文字、视图多角度描述黄瓜病害, 实现数据的快速读取、病害种类的智能诊断。

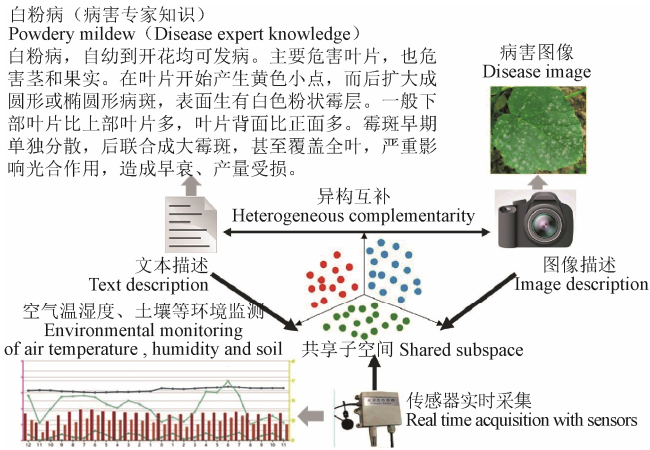


图2 多结构参数一致性表达

Fig.2 Consistent representation of multi-structural parameters

2 多结构数据集成学习的病害智能诊断方法

为掌握不同生长 (如开花期、结果期) 对生长环境的需求, 采用周期性自动采集的方式汇聚空气温度、湿度和土壤温度、湿度的数据, 采用连续特定时间采集方式汇聚作物生长监控与病害图像数据, 从而造成结构化环境数据与非结构化多媒体数据采集时间、数据类型不同, 需要融合“环境+图像+病害知识 (文本)”, 分析推理病害特点以实现病害种类的准确描述, 及时获得病害类型、营养缺失种类等信息, 避免因贻误最佳病害防治时机而导致损失。

2.1 多结构数据学习向量化与特征最优组合

本文以设施黄瓜白粉病、角斑病、炭疽病、菌核病等典型病害为例, 研究多类别融合的学习向量化神经网络算法, 将输入层“环境实时物联网数据、作物病害图像数据、专家知识文本数据”三类不同类别数据特征进行融合, 如图3。

每种类别输出数据均对应着各自的属性值与诊断值:

实时环境数据集 $X = \{x_1, x_2, \dots, x_n\}$, 属性集 (环境对作物生长的影响) $G = \{g_1, g_2, \dots, g_n\}$, 诊断集 $A = \{a_1, a_2, \dots, a_n\}$ 。

病害图像数据集 $M = \{m_1, m_2, \dots, m_n\}$, 属性集 (图像特征与病害种类的关系) $T = \{t_1, t_2, \dots, t_n\}$, 诊断集 $B = \{b_1, b_2, \dots, b_n\}$ 。

专家知识文本数据集 $P = \{p_1, p_2, \dots, p_n\}$, 属性集 (不同生育期对环境参数的要求), 诊断集 $C = \{c_1, c_2, \dots, c_n\}$ 。

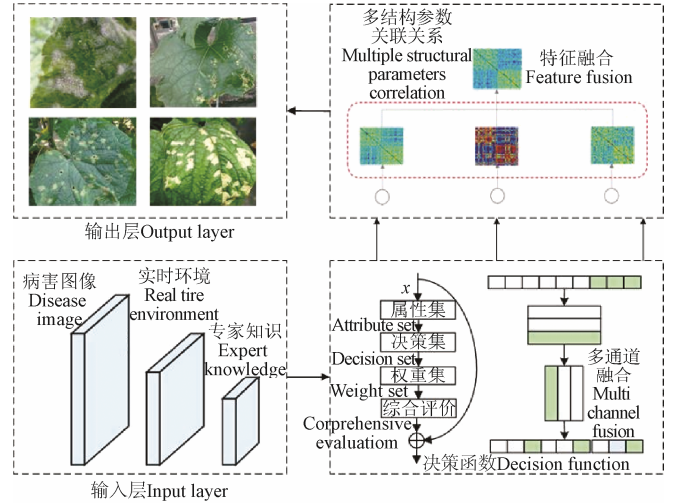


图3 多类别学习向量量化与特征最优组合

Fig.3 Multi class learning vector quantization and optimal combination of features

其中 $n=1, 2, \dots, N$, N 为环境数据集、病害图像数据集、专家知识数据集的个数。

其中诊断集 A, B, C 分别对应着一种数据类别数据的诊断 $Q = \{q_1, q_2, \dots, q_n\}$ 方案。

诊断方案包含的设施黄瓜病害种类集合为: $S = \{S_1, S_2, \dots, S_n\}$, 与 3 种数据类别诊断方案所占的权重集合

$$\omega = \{\omega_1, \omega_2, \dots, \omega_m\} \quad \sum_{j=1}^m \omega_j = 1, 0 < \omega_j < 1 \quad (5)$$

定义 $A = (a_{ij})_{m \times n}$ 为诊断矩阵, 其中 a_{ij} 表示方案 q_i 在病害种类 S_j 下的值, $i = 1, 2, \dots, m$; $j = 1, 2, \dots, n$, m 为诊断方案个数, n 为病害种类个数, 则组合权重向量为

$$W^* = \alpha_1 W_1 + \alpha_2 W_2 + \dots + \alpha_l W_l \quad (6)$$

式中 $\alpha_1, \alpha_2, \dots, \alpha_l$ 为不同权重向量的比例系数, $\alpha_k \geq 0, k = 1, 2, \dots, l$, 且满足 $\sum_{k=1}^l \alpha_k^2 = 1$,

$W_k = (\omega_{k1}, \omega_{k2}, \dots, \omega_{kn})^T$ 为组合赋权系数向量, 运用最优组合权重求出各方案的综合评价, 其中第 i 个方案的综合评价值为

$$D_i(W_k) = \sum_{j=1}^n b_{ij} \omega_j \quad i = 1, 2, \dots, m \quad (7)$$

$b_{ij} = (a_{ij} - a_j^{\min}) / (a_j^{\max} - a_j^{\min})$, a_j^{\max} , a_j^{\min} 分别方案 q_i 在病害种类 S_j 下的最大值与最小值, 若 $D_p > D_q$, 则说明方案 p 优于方案 q 。

对不同识别方案多属性综合评价值的离差平方作为 $D_i(W_k)$ 分散程度的度量, 定义第 i_1 个诊断方案综合评价与第 i_2 个诊断方案评价值的离差为

$$V_{i_1 i_2}(W_k) = D_{i_1}(W_k) - D_{i_2}(W_k) = \sum_{j=1}^n (b_{i_1 j} - b_{i_2 j}) \omega_{kj}, i_1, i_2 = 1, 2, \dots, m \quad (8)$$

根据组合权重向量，确定 m 个识别方案的总的离差平方和最大值，通过离差平方和与最大值判断得到多结构数据最优组合。

2.2 数据训练

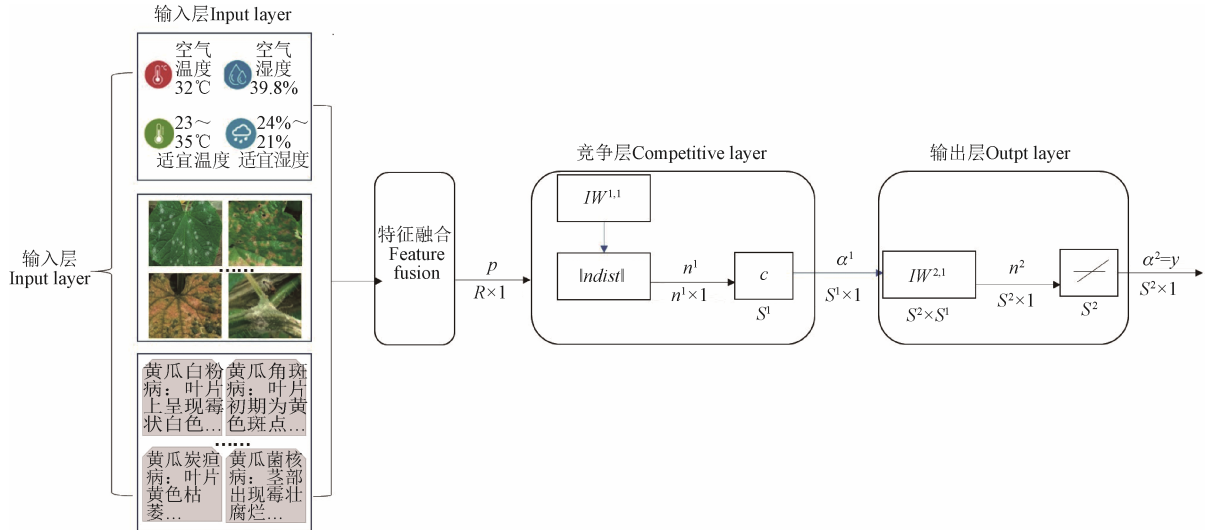
本文以黄瓜白粉病、角斑病、炭疽病、菌核病 4 种病害为样例，采用设施温湿度传感器实时采集 4 种病害发生时连续一个月空气温湿度值 3 000 条；采用手持式 SONY 相机拍摄 4 种病害叶片图像，每种病害图像数量如表 1 所示，图像大小为 $1\,536 \times 1\,152$ 像素，图像格式为 JPG；采用网络爬虫技术，爬取 4 种病害的专家知识文本描述内容，每种病害包含 3 条专家知识。4 种病害的 3 类结构的病害特征描述均经过了人工识别，确保类别标签的可靠性。

将上述 3 类数据作为输入层，计算连续一个月内的平均空气温湿度、提取病害图像的纹理与 sobel 特征、提取专家知识关键词，利用 2.1 节中多结构数据学习向量化与特征最优组合方法，计算每类特征的属性集进行特征融合，对融合后的特征进行学习训练，如图 4。

表 1 病害数据集

Table 1 Disease data sets

病害种类 Disease types	环境数据 Environmental data/条	图像数据 Image data/张	文本数据 Text data
白粉病	3 000	4 789	①发病初期为白色病斑 ②上部/背部白色病斑比下部/正面多 ③早期病斑单独分散，后期联合成片
角斑病	3 000	3 896	①初期叶片背面产生多角形水渍状病斑 ②真叶上出现茶色小点 ③后期病斑周围黄变，形成黄色晕环
炭疽病	3 000	6 214	①叶边缘出现半圆形淡褐色病斑 ②病斑上有橙黄色点状胶质物 ③茎蔓与叶柄病斑椭圆形或长圆形，黄褐色，稍凹陷
菌核病	3 000	2 812	①瓜脐部成水浸状病斑，软腐，表面长满棉絮状菌丝体 ②茎部有退色水浸状病斑，呈淡褐色，病茎软腐 ③病症呈现白色棉絮状菌丝体，茎表皮和髓腔内形成坚硬菌核，植株枯萎



注： R 是输入层的特征维数， p 为 R 维的输入模式； S^1 为竞争层神经元个数； $IW^{1,1}$ 为输入层与竞争层之间连接权重系数矩阵； $\|ndist\|$ 为输入介质， n^1 为竞争层神经元的输入， α^1 为竞争层神经元输出， c 为竞争层输出值； $IW^{2,1}$ 为竞争层与线性输出层之间的连接权重系数矩阵； S^2 为线性层神经元个数， n^2 为线性输出层神经元输入； α^2 为线性输出层神经元输出； y 为输出值。

Note: R is the characteristic dimension of the input layer, p is the input mode of R dimension; S^1 is the number of neurons in the competitive layer; $IW^{1,1}$ is the connection weight coefficient matrix between input layer and competition layer; $\|ndist\|$ is the input medium, n^1 is the input of competitive layer neurons, α^1 is the output of competitive layer neurons, c is the output value of competitive layer; $IW^{2,1}$ is the connection weight matrix between the competitive layer and the linear output layer; S^2 is the number of neurons in the linear layer, n^2 is the input of linear output layer neurons; α^2 is the output of neurons in linear output layer; y is the output value.

图 4 3 类不同结构黄瓜典型病害数据训练

Fig.4 Data training of three different cucumber diseases

$$\begin{aligned}
 n^1 &= \|IW^{1,1} - p\| \\
 \alpha^1 &= \text{comper}(n^1) \\
 n^2 &= LW^{2,1}d \\
 \alpha^2 &= \text{pureltn}(n^2)
 \end{aligned} \quad (9)$$

上述 4 种病害的 3 类数据特征，初始化输入层与竞争层间的权重 $W_j^1(0)$ ，其中 $W_j^1(0) \in IW^{1,1}$ ，确定初始学习速率 η 与训练次数 t_m ，设置 4 个输出层神经元，计算竞争神

经元与输入向量 $x = (x_1, x_2, \dots, x_R)^T$ 的距离并得到获胜神经元

$$j^* = \|X - IW_{j^*}^{1,1}\| = \min \|X - IW_j^{1,1}\|, j = 1, 2, \dots, m \quad (10)$$

根据病害种类分类正确与否调整获胜神经元权值，对输出层 4 种类别神经元进行再次学习，得到黄瓜病害种类白粉病 $[1\,0\,0\,0]$ 、角斑病 $[0\,1\,0\,0]$ 、炭疽病 $[0\,0\,1\,0]$ 、菌核病 $[0\,0\,0\,1]$ 。

2.3 多结构数据集成学习诊断

与单一文本数据因果推理不同, 本文将其他形式的数据转换为文本形式(自然语言或形式化语言), 然后利用基于文本的因果推理技术, 实现多结构参数融合的因果推理。为多结构数据建立统一事件表示模型和方法, 令各不同结构数据单元的特征空间表示方式: 文本表示为矢量, 图像表示为矩阵, 同一多媒体中的图像、文本可以通过多任务稀疏表示、流行对齐、深度学习等机器学习方法, 映射到一个共享的新特征空间中, 避免多媒体信息必须转换为文本模式的困难和稳步模式本身的限制; 同时, 在同一模态媒体数据因果推理模型基础上, 利用部分媒体之间具有同源性和对应性, 把分立的单一模态媒体因果推理模型组合成异构的多结构参数因果推理模型。

不同类型数据之间存在语义鸿沟, 建立语义关联, 将数据转化到同一个空间中, 利用平行向量场的流行对其进行对齐, 保持不同类型数据流行上的度量, 在流行对齐过程中, 不同类型数据之间的语义关系投影到潜在的语义空间中, 语义关联随之确定下来, 然后在对齐后的流行上做因果推理。

3 试验仿真与分析

作物的生长发育与温室环境因子密不可分, 生长发育进程明显受到温度的影响, 而病害发生又与温湿度有较大联系。将采集到的海量实时数据进行分析, 提取有价值知识, 本文通过在线监测生产环境的气候因子、土壤理化性质因子, 结合设施黄瓜生理生态特点, 精准把握农药和肥料施用时机、施用量、灌溉时机和灌溉量, 减少农药、肥料施用量, 避免环境污染; 通过在线监测生产环境的气候因子, 加强冻害、涝害和病虫害灾害预警功能, 及时采取应对措施, 建立灾害预警系统, 减少损失。

病害智能诊断构建需要大量且描述准确的诊断知识, 主要来源于植保专家、植保专业技术人员和各种资料。对知识进行特征提取, 将其标准化, 如黄瓜霜霉病可以表示如下:

蔬菜作物: 黄瓜

发病时期: 成株期

发病部位: 叶片

病害症状: 病斑形状(多角形); 病斑大小(严重时病斑大连片); 发病部位(多从中下部叶发病); 病斑颜色(浅黄色至褐色); 病部特征物质(潮湿时有紫黑色霉层)。

诊断知识赋值方法: 病害的特征症状对病害诊断作用大小不同, 其权重值不同, 使用评估学中的多比例法获取权重值。

设任一病害特征症状分值集合为 Y , $Y = \{Y_1, Y_2, Y_3, \dots, Y_t\}$, 具备该症状可能的致病概率为 ω_j , 第 i 种病害的 j 个症状的致病概率为且 ω_j , 其中

$$\sum_{j=1}^t \omega_j = 1。$$

诊断知识概念化: 构建病害诊断知识可以定义如下。

令作物 $V = \{V_1, V_2, \dots, V_f\}$, 各种病害为 $A = \{a_1, a_2, \dots, a_n\}$, 发病时期 $T = \{T_1, T_2, \dots, T_x\}$, 发病部位 $P = \{P_1, P_2, \dots, P_k\}$, 病症 $S = \{S_1, S_2, \dots, S_m\}$; 典型病症 $S' = \{S'_1, S'_2, \dots, S'_r\}$, $SA_i = \{S_{i1}, S_{i2}, \dots, S_{it}\}$ 表示第 i 个症状, 其中 $i = 1, 2, \dots, n$ 。其中 $S' \subset S$, $SA_i \subset S$, 在 SA_i 集合上定义函数 $\omega_i = f(SA_i)$ 表示第 i 种病害任一症状的致病概率, 其中 $\omega_j \in \omega_i$, 构建的系统计算出任一病害的发病概率,

$$\omega_0 = \sum_{j=1}^t \omega_j \chi_j \text{ 系数}$$

$$\chi_j = \begin{cases} 1 & \text{用户所选病症与系统中病症描述相同} \\ 0 & \text{用户所选病症与系统中病症描述不同} \end{cases}$$

依上述定义和用户所选症状匹配后, 进行计算, 将 ω_0 与条件阈值 E 进行比较, 如果 $\omega_0 > E$, 则系统会按照概率由大到小进行排序, 对符合条件的所有病害进行显示。

采用正反向混合推理方式, 深入诊断的病症信息搜索及权重值的计算使用最佳优先搜索法作为搜索策略, 对北京市房山蔬菜示范园区内 13 个大棚, 随机取样黄瓜病害图像 20 000 张, 由 5 名专家(包括植保技术人员)对黄瓜霜霉病、白粉病、枯萎病、灰霉病、立枯病、根腐病、猝倒病等典型病害进行诊断, 分析得到不同温湿度环境下, 易患病害的种类, 如表 2 所示, 同时选取典型的 4 种进行多结构参数集成学习的病害诊断, 具体识别情况如表 3,

表 2 环境与病害种类的关系

Table 2 Relationship between environment and diseases

湿度 Humidity/%	温度 Temperature/℃			
	10~20	>20~25	>25~32	>32~33
25~45	白粉病	/	/	/
75~85	霜霉病、菌核病、 细菌性缘枯病、 猝倒病	细菌性角斑 病、霜霉病、 蔓枯病、霜霉 病、立枯病、 根腐病、细菌 性缘枯病	/	/
≥85	菌核病、细菌性 缘枯病、猝倒病	蔓枯病、灰霉 病、炭疽病、 立枯病、根腐 病、细菌性缘 枯病	黑星病、疫病、 红粉病、细菌 性缘枯病	/
>90	细菌性叶枯病、 猝倒病、细菌性 缘枯病	灰霉病、炭疽 病、立枯病、 根腐病、细菌 性缘枯病	黑星病、疫病、 枯萎病、红粉 病、细菌性缘 枯病	白绢病、 细菌性缘 枯病

表 3 中, 环境参数为连续半个月内的物联网采集的温室内的环境温湿度参数, 以每一分钟采集一次数据为例, 一天获取到的温湿度信息为 4 213 条, 由于传输过程

中的参数丢失且去掉一些冗余数据，连续半个月的环境参数在 5 000 多条与 6 000 多条之间；图像样本为连续半个月人工采样的数据，同一样本源数据方向、角度、时间不同，分别采集了霜霉病图像 3 452 幅，白粉病 4 332 幅，枯萎病 2 895 幅，角斑病 4 213 幅，炭疽病 2 341 幅；每类病害均对应若干条专家知识描述，将其组合得到每种病害的专家知识描述的数量；本文选取 50 个样本作为测试样例，利用多结构参数集成学习的方法对病害种类进行诊断，样本识别率 79.4%~93.6%，其中白粉病由于图像特征明显、且环境与病害关系明确，识别率比较高，枯萎病病害特征与炭疽病图像特征具有相似性，所以识别率与其他病害识别率相比较低。

表 3 4 种病害具体识别情况
Table 3 Identifications situation of four kinds diseases

病害类型 Disease type	环境 参数/条 Environmental parameters	图像 数量/幅 Image number	专家知识 描述/条 Knowledge description	测试样 本数 Test samples size	样本 识别率/% Recognition rate
白粉病 Powdery mildew	64 572	4 332	3 112	50	93.6
角斑病 Keratoderma	61 245	4 213	2 834	50	82.1
炭疽病 Anthracnose	60 913	2 341	2 865	50	85.2
菌核病 Sclerotinia sclerotiorum	54 678	2 895	2 421	50	79.4

为验证本文算法的鲁棒性，分别选取卷积神经网络、深度迁移学习下的单纯图像识别技术应用在上述 5 种黄瓜典型病害识别，识别效果对比如表 4。

表 4 识别效果对比分析
Table 4 Comparison of recognition results

病害 类型 Disease type	卷积神经网络 Convolution neural network		深度迁移学习 Deep transfer learning		本文方法 This paper	
	识别率 Recognition rate/%	时间 Time/s	识别率 Recognition rate/%	时间 Time/s	识别率 Recognition rate/%	时间 Time/s
白粉病 Powdery mildew	90.1	19.7	93.2	20.5	93.6	15.2
角斑病 Keratoderma	79.5	14.9	81.7	16.8	82.1	14.8
炭疽病 Anthracnose	80.9	17.3	83.2	18.5	85.2	16.1
菌核病 Sclerotinia sclerotiorum	75.4	16.9	78.1	19.7	79.4	15.6

通过试验分析，卷积神经网络图像识别方法，识别率与本文方法相近，但是由于需要对病害图像数据进行降维与分析工作，所以后台识别时间高于本文方法；深度迁移学习的图像识别方法，需要大量的图像数据输入深度学习网络进行学习，而现实中病害图像的数量不足以满足深度学习的要求，因此识别率会因为样本的不充分而降低；本文方法借助少量图像数据，

同时结合环境与专家知识资源，采用多结构参数集成学习的方法进行病害识别，在较少识别时间的基础上确保识别的准确性。

4 结 论

随着蔬菜复种指数的增加，病虫害发生越来越严重，且冬暖棚及温室等保护为设施蔬菜生长发育创造适宜的小气候条件同时，也给蔬菜病害交叠发生提供了条件，使得病害防治越来越难。

本文以黄瓜白粉病、角斑病、炭疽病、菌核病 4 种病害样本数据为实例，融合结构化作物生长环境参数与非结构化图像等多结构数据，通过智能化的物联网，对实时采集到的环境参数进行监测、分析，并将其与图像特征融合，研究多结构数据学习向量化与特征最优组合，实现对设施黄瓜在不同环境参数下，易发典型病害的智能诊断分析，样本识别率 79.4%~93.6%，同时结合环境与专家知识资源，通过子空间映射解决了不同模态数据特征异构性问题，在较少识别时间的基础上确保识别的准确性。

[参 考 文 献]

[1] 杨易, 郭同强, 庄越挺, 等. 基于综合推理的多媒体语义挖掘和跨媒体检索[J]. 计算机辅助设计与图形学学报, 2009(9): 1307-1314.
Yang Yi, Guo Tongqiang, Zhuang Yueting, et al. Cross-media retrieval based on synthesis reasoning model[J]. Journal of Computer-aided Design & Computer Graphics, 2009(9): 1307-1314. (in Chinese with English abstract)

[2] Zhai X H, Peng Y, Xiao J G. Learning cross-media joint representation with sparse and semi-supervised regularization[J]. IEEE Transactions on Circuits & Systems for Video Technology, 2014, 24(6): 965-978.

[3] Duan Y, Peng L, Tai H Y, et al. The application of computer multimedia technology in agriculture[J]. Applied Mechanics & Materials, 2014, 687-691: 2438-2441.

[4] Pomar J, Hidalgo I. An intelligent multimedia system for identification of weed seedlings[J]. Computers & Electronics in Agriculture, 1998, 19(3): 249-264.

[5] Zhang H, Wang X S, Jiang L T, et al. Near color recognition based on residual vector and SVM[J]. Multimedia Tools and Applications, 2019, 79(4): 35313-35328.

[6] Zhang Y, Yan W, Yang B, et al. Estimation of rice yield from a C-band radar remote sensing image by integrating a physical scattering model and an optimization algorithm[J]. Precision Agriculture, 2019, 21(3): 245-263.

[7] Zhuang Y T, Yang Y, Wu F. Mining semantic correlation of heterogeneous multimedia data for cross-media retrieval[J]. IEEE Transactions on Multimedia, 2008, 10(2): 221-229.

[8] Li L, Xie S, Ning J, et al. Evaluating green tea quality based on multi-sensor data fusion combining hyperspectral imaging and olfactory visualization systems[J]. Journal of the science of food and agriculture, 2019(99): 1787-1794.

[9] Scott P R, Harris K M. Information dissemination techniques and their importance to crop protection [C]. Crop Protection Information: An International Perspective International Crop Protection Information Workshop Held at Cab International. 1989.

[10] Chesmore D, Bernard T, Inman A J, et al. Image analysis for the identification of the quarantine pest tilletia indica[J]. Eppo Bulletin, 2003, 33(3): 495-499

- [11] Brahimi M, Boukhalfa K, Moussaoui A. Deep learning for tomato diseases: Classification and symptoms visualization[J]. *Applied Artificial Intelligence*, 2017, 31(4): 299-315.
- [12] 朱逸芬. 多媒体技术及其在农业工程中的应用[M]. 北京: 清华大学出版社, 1999.
- [13] Jose A. Fernandez G, Shawn K, et al. Wheat ear counting infield conditions: high throughput and low-cost approach using RGB images[J]. *Plant Methods*, 2018, 2018(1): 22.
- [14] Michalewicz Z, Schmidt M, Michalewicz M, et al. Case study: An intelligent decision support system[J]. *IEEE intelligent systems*, 2005, 20(4): 44-49.
- [15] Michael P, Jonathan A, Darren M, et al. Deep learning for multi-task plant phenotyping[C]. *IEEE International Conference on Computer Vision Workshops (ICCVW)*. Venice Italy, 2018: 2055-2063.
- [16] Angelin A F, Silva F, Barbosa L, et al. Voids identification in rubberized mortar digital images using K-Means and Watershed algorithms[J]. *Journal of Cleaner Production*, 2017, 164: 455-464.
- [17] Sabzi S, Gilandeh Y A, Mateos G G. A new approach for visual identification of orange varieties using neural networks and metaheuristic algorithms[J]. *Information Processing in Agriculture*, 2018, 5: 162-172.
- [18] Yasin O, Lav R K, Peters R T. Economical thermal-RGB imaging system for monitoring agricultural crops[J]. *Computers and Electronics in Agriculture*, 2018, 147: 34-43.
- [19] Gu X, Wang S T, Xu M. A new cross-multidomain classification algorithm and its fast version for large datasets[J]. *Acta Automatica Sonica*, 2014, 40(3): 531-547.
- [20] 姚青, 张超, 王正, 等. 分布式移动农业病虫害图像采集与诊断系统设计及试验[J]. *农业工程学报*, 2017, 33(1): 184-191.
Yao Qing, Zhang Chao, Wang Zheng, et al. Design and experiment of agricultural diseases and pest image collection and diagnosis system with distributed and mobile device[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2017, 33(1): 184-191. (in Chinese with English abstract)
- [21] 谢忠红, 徐焕良, 黄秋桂, 等. 基于高光谱图像和深度学习的菠菜新鲜度检测[J]. *农业工程学报*, 2019, 35(13): 277-284.
Xie Zhonghong, Xu Huanliang, Huang Qiugui, et al. Spinach freshness detection based on hyperspectral image and deep learning method[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2019, 35(13): 277-284. (in Chinese with English abstract)
- [22] 徐杨, 王晓峰, 何清漪. 物联网环境下多智能体决策信息支持技术[J]. *软件学报*, 2014, 25(10): 2325-2345.
Xu Yang, Wang Xiaofeng, He Qingyi. Internet of things based information support system for multi-agent decision[J]. *Journal of Software*, 2014, 25(10): 2325-2345. (in Chinese with English abstract)
- [23] 乔虹, 冯全, 张芮, 等. 基于时序图像跟踪的葡萄叶片病害动态监测[J]. *农业工程学报*, 2018, 34(17): 175-183.
Qiao Hong, Feng Quan, Zhang Rui, et al. Dynamic monitoring of grape leaf disease based on sequential images tracking[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2018, 34(17): 175-183. (in Chinese with English abstract)
- [24] 刘树文, 王庆伟, 何东健, 等. 基于模糊神经网络的葡萄病害诊断系统研究[J]. *农业工程学报*, 2006, 22(9): 152-155.
Liu Shuwen, Wang Qingwei, He Dongjian, et al. Grape disease diagnosis system based on fuzzy neural network[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2006, 22(9): 144-147. (in Chinese with English abstract)
- [25] 郭小清, 范涛杰, 舒欣. 基于改进 Multi-Scale AlexNet 的番茄叶部病害图像识别[J]. *农业工程学报*, 2019, 35(13): 162-169.
Guo Xiaoqing, Fan Taojie, Shu Xin. Tomato leaf diseases recognition based on improved Multi-Scale Alex Net[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2019, 35(13): 162-169. (in Chinese with English abstract)
- [26] 刘洋, 冯全, 王书志. 基于轻量级 CNN 的植物病害识别方法及移动端应用[J]. *农业工程学报*, 2019, 35(17): 194-204.
Liu Yang, Feng Quan, Wang Shuzhi. Plant disease identification method based on lightweight CNN and mobile application[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2019, 35(17): 194-204. (in Chinese with English abstract)
- [27] 马骏诚, 杜克明, 郑飞翔, 等. 基于卷积神经网络的温室黄瓜病害识别系统[J]. *农业工程学报*, 2018, 34(12): 186-192.
Ma Juncheng, Du Keming, Zheng Feixiang, et al. Disease recognition system for greenhouse cucumbers based on deep convolutional neural network[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2018, 34(12): 186-192. (in Chinese with English abstract)
- [28] Guo W W, Gui F C, et al. Research and application of maize precision intelligence spatial decision support system[J]. *Journal of Anhui Agricultural Sciences*, 2010, 11(6): 147-151, 188.
- [29] 胡永强, 宋良图, 张洁, 等. 基于稀疏表示的多特征融合害虫图像识别[J]. *模式识别与人工智能*, 2014, 27(11): 985-992.
Hu Yongqiang, Song Liangtu, Zhang Jie, et al. Pest image recognition of multi-feature fusion based on sparse representation[J]. *Pattern Recognition and Artificial Intelligence*, 2014, 27(11): 985-992. (in Chinese with English abstract)
- [30] 毛罕平, 吴雪梅, 李萍萍. 基于计算机视觉的番茄缺素神经网络识别[J]. *农业工程学报*, 2005, 21(8): 106-109.
Mao Hanping, Wu Xuemei, Li Pingping. Recognition of tomato nutrient deficiency using artificial neural network based on computer vision[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2005, 21(8): 106-109. (in Chinese with English abstract)
- [31] 余国雄, 王卫星, 谢家兴, 等. 基于物联网的荔枝园信息获取与智能灌溉专家决策系统[J]. *农业工程学报*, 2016, 32(20): 144-152.
Yu Guoxiong, Wang Weixing, Xie Jiaxing, et al. Information acquisition and expert decision system in litchi orchard based on internet of things[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2016, 32(20): 144-152. (in Chinese with English abstract)
- [32] 黄双萍, 孙超, 齐龙, 等. 基于深度卷积神经网络的水稻穗瘟病检测方法[J]. *农业工程学报*, 2017, 33(20): 177-184.
Huang Shuangping, Sun Chao, Qi Long, et al. Rice panicle blast identification method based on deep convolution neural network[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*,

- 2017,33(20): 177-184. (in Chinese with English abstract)
- [33] 杨炳儒, 樊广全, 陈泓婕. 一类基于信息挖掘的智能决策支持系统的结构模型. 模式识别与人工智能, 2003, 16(2): 225-229.
Yang Bingru, Fan Guangquan, Chen Hongjie. A new structure of idssim-intelligent decision support system based on information mining[J]. Pattern Recognition and Artificial Intelligence, 2003, 16(2): 225-229. (in Chinese with English abstract)
- [34] John H. Artificial intelligence: Implications for the future of work[J]. American Journal of Industrial Medicine, 2019, 62(4): 917-926.
- [35] Rakesh R S, Pabitra M K, Tirtharaj D. Neural network based automated detection of link failures in wireless sensor networks and extension to a study on the detection of disjoint nodes[J]. Journal of Ambient Intelligence & Humanized Computing, 2019, 10(2): 593-610.
- [36] Yu J T, Yu Z, Ding M L, et al. Research on the tenacity survivability of wireless sensor networks[J]. Journal of Ambient Intelligence & Humanized Computing, 2019(8):12-15.

Intelligent diagnosis of greenhouse cucumber diseases based on multi-structure parameter ensemble learning

Gao Ronghua, Li Qifeng^{*}, Sun Xiang, Gu Jingqiu, Peng Cheng

(1. Beijing Research Center for Information Technology in Agriculture, Beijing Academy of Agriculture and Forestry Sciences, Beijing 100097, China; 2. National Engineering Research Center for Information Technology in Agriculture, Beijing 100097, China; 3. Key Laboratory for Information Technologies in Agriculture, Ministry of Agriculture and Rural Affairs, Beijing 100097, China; 4. Beijing Engineering Research Center of Agricultural Internet of Things, Beijing 100097, China)

Abstract: Identification of plant disease has been becoming a significant issue on the pattern recognition and image processing in intelligent agriculture. However, the conventional single feature cannot clarify the typical characteristics of crop diseases, due to the various parameters of growth environment, including the soil temperature and humidity, pH value, air temperature and humidity, all are closely related to the plant disease. Recently, the vectorization of multi-structured data learning, and the optimal combination of features can provide a new way to effectively improve the accuracy of disease diagnosis. Taking 50 samples and four types of cucumber diseases as examples, including powdery mildew, fusarium wilt, keratoderma, and sclerotinia sclerotiorum, this study aims to establish an optimal combination model for multi structure of plant disease, using integrated learning of in situ environmental parameters via intelligent Internet of Things. The specific collected data can be 4332 of powdery mildew, 4213 of keratoderma, 234 of anthracnose, and 2895 of fusarium wilt. Each kind of disease was corresponding to several descriptions of expert knowledge, which were combined with the number of expert knowledge description for each disease. Based on the perception model of multimedia sensor networks, a multi-path packet transmission method was proposed to ensure the reliability of multi-structure data transmission. The collected multi-source heterogeneous data was grouped and transmitted along multiple paths, in order to reduce data loss and transmission time, while improve the accuracy of data acquisition. The heterogeneous modal information was then mapped on the shared subspace, while the similarity of heterogeneous data was directly measured under a framework. Furthermore, the relationship of unknown heterogeneous data was derived using the integrated index system of multi structure parameters. A learning vector quantization neural network algorithm was used for the multi-fusion category by fusing the structural environmental parameters of crop growth, and unstructured image features. Three types of data features in the input layer were fused to establish semantic association, including the *real-time environment Internet of things data*, *crop disease image data* and *expert knowledge text data*. A method of multi-structure parameter ensemble learning was used to diagnose disease types, where the recognition rate of samples was 79.4% to 93.6%. Specifically, the recognition rate of powdery mildew was relatively high, due to its obvious image features and clear relationship between environment and disease. The identification rate of fusarium wilt was lower than that of other diseases, because of the similar disease characteristics and anthracnose image features, with emphasis on the expert knowledge description of *leaf spot*. In order to verify the robustness of the proposed algorithm, a convolutional neural network and simple image recognition technology based on deep transfer learning were selected to carry out experimental analysis on the above-mentioned four typical cucumber diseases. The experimental results show that in the convolution neural network image recognition method, the recognition rate was similar to that of the proposed method, but the recognition time of background was higher than that of the method, due possibly to reduce the dimension of disease image data. Normally, the deep transfer learning method requires many image data inputs into the network for learning, whereas, the actual number of disease images cannot be enough to meet the requirements of deep learning. That is why the recognition rate can be reduced due to the insufficient samples. The intelligent diagnosis technology of cucumber diseases was established based on multi-structural parameters ensemble learning, and thereby to serve as a sound basis for the correlation analysis between image features and environment parameters. Combined with the environmental and expert knowledge resources, the subspace mapping was used to deal with the heterogeneity of different modal data, further to ensure the accuracy of identification based on less identification time.

Keywords: image recognition; intelligent system; diseases; multi-structure parameter; learning direction quantification; intelligent decision