

doi:10.6041/j.issn.1000-1298.2022.06.038

基于 PSWE 模型的土壤水盐运移与夏玉米生产效益模拟

张万锋¹ 杨树青¹ 胡睿琦² 鄂继芳¹

(1. 内蒙古农业大学水利与土木建筑工程学院, 呼和浩特 010018; 2. 澳大利亚人工智能研究所, 悉尼 2007)

摘要: 为实现多因素影响下土壤水盐、作物生产效益间的双层递进因果关系模拟, 基于深度学习理论及方法将分级长短期记忆网络(HLSTM)与批标准化多层感知机(BMLP)耦合, 且将 Dropout 与 Adam 优化算法耦合作为面向收敛的改进算法, 构建了递进水盐嵌入神经网络(Progressive salt-water embedding neural network, PSWE)模型。评估了 PSWE 模型的有效性, 并开展了多因素协同秸秆深埋下不同灌水量的土壤水盐及夏玉米生产效益的模拟。结果表明, PSWE 模型具有多因素整体协同性, 有效地模拟了土壤水盐运移规律、夏玉米生产效益及各变量间的内在依存关系。模型平均均方根误差为 0.031, 平均绝对误差为 0.569, 平均决定系数为 0.987。模拟结果表明, 单次灌水 60 mm 的耕作层(0~40 cm)含水率随时间推移持续降低, 单次灌水 135 mm 的耕作层含水率变幅较大, 成熟期二者在秸秆隔层积盐率分别为 49.2% 和 11.2%; 单次灌水 90 mm 和 120 mm 的耕作层含水率保持在 16%~24% 之间, 成熟期二者在大于 40 cm 土层含水率保持平稳, 秸秆隔层有脱盐趋势, 脱盐率为 6.1% 和 5.9%; 夏玉米单次理论灌水量为 89.3~96.8 mm, 耕作层理论含盐量为 1.38~1.55 g/kg。综上, 多因素协同秸秆深埋下适宜灌溉量可实现抑盐提效的目标, PSWE 模型可有效模拟土壤水盐运移和作物生产效益, 为深度学习理论及技术在土壤水盐运移模型上的应用提供参考。

关键词: 水盐运移; 夏玉米; 秸秆深埋; 长短期记忆网络; 批标准化多层感知机

中图分类号: S274; TV93 文献标识码: A 文章编号: 1000-1298(2022)06-0359-11

OSID:



Simulation of Soil Salt-water Migration and Summer Maize Productivity Based on PSWE Model

ZHANG Wanfeng¹ YANG Shuqing¹ HU Ruiqi² E Jifang¹

(1. College of Water Conservancy and Civil Engineering, Inner Mongolia Agricultural University, Huhhot 010018, China
2. Australian Artificial Intelligence Institute, Sydney 2007, Australian)

Abstract: To realize simulation of the two-layer progressive causal relationship of soil salt-water and crop production benefits under the influence of multiple factors, based on deep learning theory and technology, the progressive salt-water embedding neural network (PSWE) model was constructed. In PSWE model, the time serialized data encoder framed by hierarchical long short-term memory (HLSTM) and decoder framed batch-normalized multi-layer perceptron (BMLP) were coupled, and the coupling between Dropout and Adam algorithm was optimized as an improved algorithm for convergence regression. The validity of PSWE model was evaluated, and the dynamic changes of soil water-salt of different irrigation amounts under multi-factors cooperative straw deep burial were simulated, and the production benefit of summer maize was predicted. The results showed that PSWE model had multivariable overall synergy, self-learning habit and high accuracy. PSWE model could effectively describe the law of soil salt-water migration under straw deep burial in Hetao Irrigation District, the internal dependence relationship between summer maize production benefit and various variables. The root mean square error of the PSWE model was 0.031, the mean absolute error was 0.569, and the determination coefficient was 0.987. Through the model simulation, along with the summer maize growth period, the moisture content of treatment of single irrigation 60 mm was reduced continuously in the tillage layer (0~40 cm), and

收稿日期: 2021-07-07 修回日期: 2021-07-30
基金项目: 国家自然科学基金项目(51669019)和国家自然科学基金重点项目(51539005)
作者简介: 张万锋(1985—),男,高级工程师,博士,主要从事农业水土资源利用与水土环境调控研究,E-mail: z.wf123@163.com
通信作者: 杨树青(1966—),女,教授,博士生导师,主要从事农业水土资源利用与水土环境调控研究,E-mail: nmndysq@126.com

affected the summer maize for normal growth, while the change of treatment of 135 mm was larger. In the mature stage, they produced salt accumulation in the straw inter-layer, and the salt accumulation rate was 49.2% and 11.2%. The water content in the tillage layer of single irrigation 90 mm and 120 mm were kept between 16% and 24%. At the end of the growth period, the water content in the soil layer over 40 cm was kept stable. The straw inter-layer showed a trend of desalting, and the desalting rate was 6.1% and 5.9%, respectively. It was suggested that the single irrigation amount should be 89.3 ~ 96.8 mm, and the theoretical salt content of cultivated layer was 1.38 ~ 1.55 g/kg. In conclusion, under multi-factors cooperative straw deep burial, appropriate irrigation amount could achieve the goal of salt suppression effect and improvement of water use efficiency. The PSWE model could effectively simulate soil salt-water migration. The simulation of soil water-salt migration and crop productivity benefit by PSWE model was applicable, which provided a reference for deep learning theory and technology in soil salt-water migration.

Key words: salt-water migration; summer maize; straw buried deep; HLSTM; BMLP

0 引言

河套灌区引黄水量锐减、土壤盐渍化等问题严重制约着灌区农业持续健康发展,如何节水改良盐渍地、提效增产是灌区面临的主要问题^[1-2]。秸秆还田改善土壤通透性^[3],显著提高土壤养分供给强度^[4],减少无效蒸发^[5],促进对降雨入渗的利用,提高水分利用效率^[6-7],与适宜水质结合调控根层盐分,提高作物产量和水分生产力^[8],影响土壤水盐分布^[9]。深入研究多因素协同秸秆还田耕作措施的土壤水盐运移规律,对河套灌区抑盐节水增产具有重要的现实意义。但受大田试验周期长、气候变化复杂等多重因素的影响,秸秆还田措施的水盐运移规律缺乏深入系统研究,采用模型模拟是一种较方便快捷的研究方法。

大多数土壤水盐运移模型模拟及其相关影响因素主要依赖于复杂的物理过程机理^[10],模型求解时往往因边界条件复杂、计算参数众多等原因在应用上受限,且水盐运移的非线性和突变性降低了这些机理模型的准确性和可靠性。SCHINDLER 等^[11]认为,与基于过程的机理模型相比,基于数据驱动的模式更具优势,伴随机器学习理论及技术的发展,此类模型逐渐在模拟土壤水盐运移方面得到认可。前人采用 BP 神经网络模型研究土壤水盐动态变化^[12]和冻土水盐空间变异情况^[13],并基于人工神经网络预测洪水水位^[14]、地下含水层水位^[15]和土壤水盐含量^[16]等的变化,取得了较好的效果。作为机器学习最活跃的深度学习理论及技术,在数据特征学习与表征上更具优势。目前,深度学习在图像识别^[17]、作物产量估算^[18]、土壤养分检测^[19]、气象预报^[20]与疾病诊断^[21]等方面应用较多,但在土壤水盐模拟上的应用较少。

多因素协同秸秆深埋下土壤水盐运移属于夏玉米全生育期的时间序列分析问题,本文以此为切入

点,基于分级长短期记忆网络(Hierarchical long short-term memory,HLSTM)与批标准化多层感知机(Batch-normalized multi-layer perceptron,BMLP)耦合,构建递进水盐嵌入神经网络(Progressive salt-water embedding neural network,PSWE)模型,模拟河套灌区多因素协同秸秆深埋下不同灌溉量的土壤水盐运移及夏玉米生产效益。旨在探明多因素协同秸秆深埋下土壤水盐运动规律,确定适宜灌水量,检验深度学习理论及技术在模拟土壤水盐运移上的有效性,为灌区应用秸秆深埋还田技术调控水资源提供理论依据。

1 材料与方法

1.1 研究区概况

田间试验于2017—2019年每年5月至9月在河套灌区临河区双河镇农业节水示范区开展,该示范区属中温带半干旱大陆性气候,多年平均降雨量156 mm,大多降雨集中在夏秋季,年均蒸发量2 332 mm,春冬季地表返盐严重。供试土壤为粉砂壤土(砂粒、粉粒、粘粒质量比为8:15:2),0~100 cm土体平均容重1.485 g/cm³,平均田间持水率22.57%。

1.2 田间试验设计

田间试验于上一年秋浇前在35 cm土层人工铺设5 cm粉碎玉米秸秆,平整耕地,第2年5月初浅耙压实覆膜种植。秸秆深埋后形成土层依次为:耕作层(0~35 cm)、秸秆隔层(35~40 cm)、心土层(秸秆隔层以下土层)。田间试验设4个灌水水平:单次灌水量60 mm(W1)、90 mm(W2)、120 mm(W3)、135 mm(CK,当地灌水量),共4个处理,3次重复,12个小区,小区面积72 m²,各小区间设2 m保护带,四周用埋深1.2 m聚乙烯塑料膜隔开,顶部留30 cm,防止水肥相互影响,田间管理与当地农户管理一致。夏玉米生育期灌溉3次,用汽油泵从渠

道定量抽取灌溉水,畦灌方式灌溉。供试材料为钧凯 918 玉米,5 月初机械播种,9 月末收获,株距 0.35 m,行距 0.45 m。

1.3 样品采集与分析

(1)土壤含水率及含盐量:在播种前和每次灌水前、后(雨后 2~3 d 内加测一次),用土钻分别在 0~20 cm、20~40 cm、40~60 cm、60~80 cm、80~100 cm 土层取样,测土壤含水率及电导率。采用干燥称量法测土壤含水率,即质量含水率;将土样风干、磨碎、过筛,配制土水质量比 1:5 提取清液,用 DDS-307 型电导率仪测土壤电导率。

(2)夏玉米考种测产及水分利用效率:每个小区随机选取 10 株夏玉米,测量夏玉米穗长、穗粗、百粒质量等产量的相关指标;干燥后称总质量并计算单位面积产量。

作物耗水量 (Evaporation and transpiration of crop, ET) 的计算式为

$$ET = P + I + W_g - D - R - \Delta W \tag{1}$$

式中 ET——作物耗水量,mm

P——生育期降雨量,mm

I——灌溉量,mm

W_g ——地下水补给量,即研究期地下水向上补给土壤水的量,mm

D——渗漏水量,该示范区地下水位较高,地下水补给量远大于渗漏水量,故 D 忽略不计,mm

R——地表径流,该示范区地面平坦,研究期降雨较小,无地表径流,R 可忽略,mm

ΔW ——试验初期到末期土壤储水量的变化量,mm

水分生产率 (Water productivity, WP) 的计算式为

$$WP = Y/ET \tag{2}$$

式中 WP——水分生产率,kg/(hm²·mm)

Y——玉米产量,kg/hm²

大田试验时,灌溉后无法立即取样测土壤含水率,造成模型模拟未能充分反映灌溉后土壤含水率突变的过程。鉴于此,采用水量平衡的方法补算此时段观测点的土壤含水率理论值,分别计算出灌溉后各土层含水率的平均增加值,得到观测点此时的理论含水率,并将其作为一个整体在模型中输入,再调试率定模型。

土壤含水量理论值的计算式为

$$W = 10 \sum_{i=1}^n \rho_i h_i \theta_i \tag{3}$$

式中 W——土壤含水量理论值,mm

θ_i ——第 i 层土壤质量含水率,此处为因灌溉引起的土层 i 含水率的变化量,%

h_i ——不同土层厚度,cm

ρ_i ——土层平均容重

供试土壤各层平均容重分别为:0~20 cm 土层取 1.47 g/cm³,20~40 cm 土层取 1.48 g/cm³,40~60 cm 土层取 1.50 g/cm³,60~100 cm 土层取 1.49 g/cm³。

1.4 PSWE 模型基本原理

使用 Python 编码,在 Pytorch 框架上构建 PSWE 模型,并进行训练、率定。HLSTM 编码器将实测数据时间序列化,将以天为单位记录气象数据(地温、气温、辐射量、CO₂ 浓度、降水量)、灌溉定额、秸秆埋深、生育期时长及土层深度等 9 个变量,作为一个整体嵌入到一个低维度欧几里得空间中(维度为 2 维(含水率、含盐量),隐层维数为 20 维),并学习与分析各变量与土壤水盐含量间的因果关系,最终学习到土壤水盐动态变化。承接 HLSTM 编码器输出的水盐含量,BMLP 解码器分析与学习土壤水盐含量与作物生产效益间的因果关系。HLSTM 编码器与 BMLP 解码器在相互迭代、更新学习的过程中,捕捉多因素在时间序列上的依存关系,并分析多因素对土壤水盐运移及作物生产效益的影响,实现准确模拟。本文使用 $[x_0, x_1, \dots, x_t, \dots, x_T]$ 来表示每个时间点上的变量,每个 x_t 为 m 维的向量(本文中 m = 9)。时间序列化使得 x_t 自然拥有依次生成的性质,基于 n 阶马尔科夫链的夏玉米在各时间点上的各项指标依次发生的概率为

$$P(x_0, x_1, \dots, x_T) \approx \prod_{t=1}^T P(x_t | x_t, x_{t-(n-1)}, \dots, x_{t-1}) \tag{3}$$

式中 x_t ——每个时间点上夏玉米各项指标数据,即模型输入参数

T——夏玉米整个生长周期,d

1.4.1 HLSTM 编码器

在给定时间序列化数据 $[x_0, x_1, \dots, x_T]$,循环神经网络 (Recurrent neural network, RNN) 可对应输出一个序列 $[h_0, h_1, \dots, h_T]$,每次 RNN 运算的激活函数 A 为

$$A_t = \varphi(W_{aa}A_{t-1} + W_{ax}x_t + b_a) \tag{4}$$

式中 W_{aa} 、 W_{ax} ——RNN 中前一个输出值和输入值的权重

b_a ——输入值偏差

φ ——RNN 的激活函数^[22-23],如 S 型函数、正切函数和线性整流函数

RNN 模型输出项 h_t 为

$$h_t = \phi(W_{ha}A_t + b_h) \tag{5}$$

式中 W_{ha} ——权重系数
 b_h ——输出偏差
 ϕ ——输出激活函数,与 φ 可以不同

RNN 随时间序列增加,反向传播梯度会累积到爆炸或消失,限制了模型“记忆”长时间序列上的信息。而基于 HLSTM 模型使用内部逻辑门可有效解决这个问题。与 RNN 相比,HLSTM 构造优势在于内部的 3 个逻辑门:输入门、遗忘门和输出门。输入门负责评估输入数据流能否被用于记忆单元的调整与修改,即将 0~1 间的输入数据和上一层隐藏数据通过 S 型函数合并及归一;再根据模型算法判断信息是否符合规则,若不符合规则就通过遗忘门被舍弃;将归一后的数据输入并结合模型当前时刻 t 节点的状态,得到 t 时刻隐层表达式 o_t 和输出门 t 时刻输出结果 h_t 为

$$o_t = \sigma(\mathbf{x}_t W_o + \mathbf{h}_{t-1} V_o + b_o) \tag{6}$$

$$\mathbf{h}_t = o_t \otimes S_t \tag{7}$$

式中 σ ——S 型激活函数
 W_o 、 V_o ——HLSTM 对应 t 时刻隐层表达式用到的数据学习权重
 b_o ——HLSTM 对应 t 时刻隐层表达式用到的数据输入偏差
 S_t ——HLSTM 对应时间节点 t 的存储状态
 $\otimes$ ——各元素间的相乘运算符号

每个时间节点输出 h_t 与该时间节点对应的土壤水盐含量利用 Huber Loss 函数进行损失量计算,计算式为

$$L_{lstm} = \frac{1}{T} \sum_{t=1}^T \text{Huber_loss}(\mathbf{h}_t, y_{water, salt}) \tag{8}$$

式中 L_{lstm} ——利用 Huber Loss 函数计算土壤水盐含量的损失量
 $y_{water, salt}$ ——田间试验的实测值
 $\text{Huber_loss}(\cdot)$ ——用于计算回归问题带参的分段损失函数,本文采用 L1-Loss 函数计算损失量

利用输入(9 个变量)与输出(作物生产效益)间的更新与映射,最后一个时间节点的隐层输出结果被提取,作为学到整个时间序列上各项指标的嵌入(embedding),即 BMLP 解码器的输入项。

1.4.2 BMLP 解码器

利用批标准化处理^[24]来增强训练迭代,提高 MLP 模型的稳定性,构建批标准化多层感知机(BMLP)。将 HLSTM 编码器模拟的水盐指标作为 BMLP 解码器的输入项,捕获时间序列上多因素的变化信息及其与土壤水盐动态间的因果关系,输出作物生产效益。文中 BMLP 解码器是一种具有双隐

含层的神经网络,层间信息流的精确仿射转换至关重要,BMLP 解码器第 l 隐层 h_l 表达式为

$$\mathbf{h}_l(\mathbf{h}_{l-1}, W_l, b_l) = \mathbf{h}_{l-1}^T W_l + b_l \tag{9}$$

式中 W_l ——BMLP 解码器第 l 层的学习权重
 b_l ——BMLP 解码器第 l 层的偏差
 h_{l-1} —— $l-1$ 层的输出值;当 $l=1$ 时, h_0 为 embedding(水盐嵌入)

BMLP 输入的数据通过层级间的更新规则进行运算,得到最终输出结果。最后一层生产效益的隐层表达与该时间节点上的田间实测产量及水分生产率利用 Huber Loss 进行损失计算,计算式为

$$L_{mlp} = \text{Huber_loss}(\mathbf{h}_l, y_{yield, water - efficiency}) \tag{10}$$

式中 L_{mlp} ——利用 Huber Loss 函数计算夏玉米产量与水分生产率的损失量
 $y_{yield, water - efficiency}$ ——夏玉米产量与水分生产率的实测值

PSWE 模型通过 HLSTM 构造的编码器与 BMLP 构造的解码器耦合所计算的损失对模型整体进行协同更新,从而大幅提高预测精度。本模型最终损失函数计算值 L 为式(8)和式(10)的平均值,即

$$L = \frac{1}{2}(L_{lstm} + L_{mlp}) \tag{11}$$

采用随机梯度(SGD)^[25]作为优化器的神经网络模型在峰值处梯度较平缓,未立即收敛,且神经网络参数学习速率统一。但 PSWE 神经网络模型在训练过程中采用 Adam 优化算法,使其能够更稳定、平滑地收敛。同时,为避免对数据产生过拟合,模型又耦合了 Dropout 优化算法^[26],作为整个模型的收敛算法。

至此,基于递进水盐嵌入神经网络模型(PSWE)构建完成,通过适应性分析,将研究区各变量输入模型,根据 HLSTM 构造的编码器与 BMLP 构造的解码器中获取的双层递进因果关系进行迭代更新,完成对土壤水盐变化及作物生产效益的模拟。PSWE 模型架构如图 1 所示。

2 结果与分析

2.1 PSWE 模型率定与检验

各变量在数值上相差较大,且量纲不相同,若直接参与训练会影响模型学习收敛速率与精度,故训练前对原数据进行规范化预处理,将数据归一化。选取 2 年 360 组实测数据作为 PSWE 模型训练集,在训练过程中表现出较好的误差收敛性能,模型率定结果如图 2~4 所示(因篇幅所限,仅选取 2018 年单次灌水 90 mm 和 120 mm 分别在播种后第 17 天和第 135 天的水盐含量及 2018 年夏玉米生产效益




图 1 递进水盐嵌入神经网络架构

Fig. 1 Schematic of progressive salt-water embedding neural network architecture

率定图为例)。结果表明,土壤含水率均方根误差 (RMSE) 小于 0.031%, 平均绝对误差 (MAE) 小于 0.473%, 决定系数 R^2 大于 0.979; 土壤含盐量 RMSE 小于 0.032 g/kg, MAE 小于 0.566 g/kg, R^2 大

于 0.975; 夏玉米产量 RMSE 为 0.031 kg/hm², MAE 为 0.546 kg/hm², R^2 为 0.983; 水分生产效率 RMSE 为 0.024 kg/(hm²·mm), MAE 为 0.561 kg/(hm²·mm), R^2 为 0.977。




图 2 土壤含水率率定结果

Fig. 2 Model calibration of soil moisture content




图 3 土壤含盐量率定结果

Fig. 3 Model calibration of soil salt content




图 4 夏玉米生产效益率定结果

Fig. 4 Model calibration of summer maize production efficiency

采用 2019 年的实测数据对 PSWE 模型进行检验。作物生育期有实测数据的时间点有 9 个, 选取单次灌水 60、90、120、135 mm 处理在整个生育期 20 ~ 40 cm 土层含水率和含盐量及生产效益的验证图为例, 模型验证结果见图 5 ~ 7。结果表明, 土壤含水率模拟值与实测值拟合程度较好, 虽然土壤含盐量模拟结果相对稍差一些 (可能是土壤蒸发与作物蒸腾过程中水盐间强烈的互动效应, 且盐分的时空变异性远大于水分时空变异性导致), 但仍可有效反映土壤水盐运移及作物生产效益的变化趋势,




图 5 土壤含水率验证结果

Fig. 5 Model checking of soil moisture content




图 6 土壤含盐量验证结果

Fig. 6 Model checking of soil salt content




图 7 夏玉米生产效益验证结果

Fig. 7 Model checking of summer maize production efficiency

模拟结果可以接受。模型检验的平均 RMSE 为 0.031, 平均 MAE 为 0.569, 平均决定系数 R^2 为 0.987。

利用检验后的 PSWE 模型开展模拟试验。模拟土层 0 ~ 100 cm 水盐运移, 每 20 cm 为一层, 共 5 层; 模拟周期为夏玉米生育期, 共计 140 d, 步长为 1 d; 单次灌溉 60 ~ 135 mm, 灌溉 3 次, 初始步长为 5 mm, 最小步长 1 mm, 最大步长为 10 mm (按照当地灌溉时间确定); 气象参数均按照当天平均值输入; 土壤含盐量容许偏差为 0.05 g/kg, 含水率容许偏差 0.05%, 产量容许偏差为 1 kg/hm², 水分生产率容许偏差为 0.001 kg/(hm²·mm)。因模拟图较多, 仅选取灌溉 60、90、120、135 mm 的土壤水盐分布模拟图 (图 8、9)。

2.2 多因素协同秸秆深埋下不同灌水量的土壤质量含水率模拟

多因素协同秸秆深埋下, 不同灌水量的土壤含水率分布模拟结果如图 8 所示。在夏玉米生育期内, 土壤含水率随土层深度的加深而提高, 随生育期推移而降低, 且不同灌水量间存在不同程度的差异。

生育前期, 不同处理耕作层含水率差异不显著, 随生育期推移, 变幅增大。灌溉后耕作层含水率显著增加, 整个生育期出现 3 次峰值, 随蒸发蒸腾作用增强, 土壤含水率逐渐降低。灌溉 90 mm 和 120 mm 时, 耕作层含水率保持平稳, 为 16% ~ 24%; 而灌溉 60 mm 时, 因灌水量较小, 且持续蒸发蒸腾作用及秸秆隔层在一定程度切断毛管, 导致耕作层含水率持续降低, 最低仅为 11.2%, 已逐步影响夏玉米生长; 灌水量为 135 mm 时, 耕作层含水率变幅最大, 灌溉后的耕作层含水率大幅增加, 短时间内减小为 10.3% ~ 26.2%。在夏玉米成熟期, 灌溉 60 mm 的耕作层含水率较灌溉 135 mm 处理降低 27.3%, 而灌溉 90 mm 和 120 mm 的耕作层含水率分别提高 5.7% 和 7.1% ($P < 0.05$)。秸秆隔层含水率随灌水量增加呈先增后减趋势, 同一时间点灌溉 90 mm 和 120 mm 隔层含水率较灌溉 60 mm 和 135 mm 显著提高 ($P < 0.05$), 成熟期二者分别提高 14.3% 和 13.8%, 说明多因素协同秸秆深埋下适宜灌水量可




图 8 生育期内各土层含水率分布

Fig. 8 Distributions of soil moisture content in different soil layers during growth period




图 9 生育期内各土层含盐量分布

Fig. 9 Distributions of soil salt content in different soil layers during growth period

起到蓄水保墒的作用,扩大隔层蓄水容量。随着土层深度增加,心土层含水率有增大趋势,在40~60 cm 土层含水率有小幅波动,特别是灌溉 60mm 处理在该土层含水率持续下降,成熟期下降到不足 20%,且 60 cm 以下土层含水率在成熟期仍有下降趋势;由图 8 可知,灌溉 90mm 和 120 mm 处理的心土层含水率基本维持稳定,受灌溉影响较小,80 cm 以下土层含水率均在 30% 以上;而当地灌水量 135 mm 时心土层含水率有小幅波动,夏玉米生长后期有降低趋势。

2.3 多因素协同秸秆深埋下不同灌水量的土壤含盐量模拟

多因素协同秸秆深埋下,不同灌水量的土壤含

盐量分布的模拟如图 9 所示。多因素协同秸秆深埋和灌水量对土壤含盐量分布影响显著。

整个生育期,不同灌水量处理的耕作层均积盐,灌溉 90 mm 和 120 mm 积盐率较灌溉 60 mm 和 135 mm 显著降低($P < 0.05$)。生育末期灌溉 60 mm 处理的耕作层积盐最多,积盐率为 20.6%;其次是当地灌水量 135 mm 处理,其积盐率为 16.6%;而灌溉 90 mm 和 120 mm 积盐率较小,分别为 8.9% 和 8.3%,二者差异不显著($P > 0.05$)。在秸秆隔层,灌溉 60 mm 整个生育期含盐量逐渐增加,生育末期达到 3.9 g/kg 以上,积盐率达到 49.2%,较其他灌水量处理的隔层积盐显著增多,即使地面灌溉后,仍

然有增大趋势;灌溉 90 mm 和 120 mm 处理的隔层含盐量变化比较平稳,地面灌溉后隔层含盐量下降,持续一段时间后增加,但在生育末期隔层脱盐,脱盐率分别为 6.1% 和 5.9%,二者脱盐率差异不显著 ($P>0.05$);灌溉 135 mm 处理的隔层含盐量随灌溉后大幅降低,持续短时间后又显著增加,生育末期隔层积盐,积盐率达到 11.2%。说明多因素协同秸秆深埋的耕作模式下,过多灌溉或灌溉不足均不能充分发挥隔层抑盐作用,只有在适宜灌水量下,秸秆隔层可减缓土壤水分入渗与蒸发,同时抑制深层土壤返盐,保持根系层(20~40 cm)含盐量变幅较小,生育末期土壤脱盐效果显著。心土层含盐量随灌水量增加存在不同程度的差异。灌溉 60 mm 处理的心土层含盐量在生育期呈逐渐增大趋势,成熟期含盐量达到最大,为 3.5 g/kg,较播种时显著增加心土层含盐量,平均积盐率为 14.7%;灌溉 90 mm 和 120 mm 处理的心土层含盐量变化较平稳,平均积盐率分别为 11.5% 和 11.7%;当地灌溉 135 mm 处理的心土层含盐量变幅较大,地面灌溉后大幅下降,随蒸发蒸腾作用增强而增大,平均积盐率为 12.6%;不同灌溉量的心土层均积盐,随灌水量的增加心土层含盐量变化率表现为先增后减,与耕作层积盐趋势相反。

2.4 夏玉米产量与水分生产率预测

夏玉米产量和水分生产率模拟结果如图 10 所示。由图 10 可知,秸秆深埋下夏玉米产量及水分生产率随灌水量增大均呈先增后降的趋势,但二者达到峰值时的灌水量不同。灌溉区间在 60~89.3 mm 时,水分生产率逐渐增加,在灌水量 89.3 mm 时,达到峰值,为 21.3 kg/(hm²·mm),此时夏玉米产量仍处在增加阶段,未到达最大值;灌溉区间在 89.3~96.8 mm 时,水分生产率开始下降,产量在灌水量 96.8 mm 达到峰值,为 9 191 kg/hm²;当灌溉区间为 96.8~135 mm 时,二者均下降。取二者峰值间的灌水量 89.3~96.8 mm 作为多因素协同秸秆深埋的夏玉米较适宜单次灌水量,并将此灌水量、理论产量、水分生产率及其他相应参数代入模型,反推耕作层理论含盐量为 1.38~1.55 g/kg。

3 讨论

土壤水盐含量、作物生产效益与耕作措施、灌水量、气象条件等多因素间存在复杂的非线性关系,研究多因素间的因果关系对土壤水盐运移及提效增产有着重要的现实意义。刘全明等^[27]基于 BP 神经网络模型模拟区域耕地耕作层的水盐动态,均方根误差在 1.7%~5% 之间;余世鹏等^[28]基于模糊神经算




图 10 不同灌水量时夏玉米产量及水分生产率变化曲线
Fig. 10 Summer maize yields and water productivity under different water irrigation

法建立的水盐最优预测模型有效模拟了中长期水盐动态变化,预测误差降低 30% 以上。本研究基于 HLSTM 与 BMLP 耦合构建了递进水盐嵌入神经网络(PSWE)模型,有效模拟了多因素变量与水盐变化、夏玉米生产效益间的两层递进因果关系,模型整体均方根误差为 0.031,平均绝对误差(MAE)为 0.569,平均决定系数 R^2 为 0.987。PSWE 模型具有较高的精度,可实现河套灌区多因素协同秸秆深埋下 0~100 cm 土层水盐及夏玉米生产效益的模拟。模型训练时发现,随土层深度加深模拟精度有所降低,且土壤含盐量模拟结果相对稍差,这与王钧等^[29]模拟含水率变化趋势类似。可能是因为,一方面模型训练时约束条件较少,未考虑土壤理化性质、渗漏等影响;另一方面蒸发蒸腾过程中土壤水盐间的互馈效应强烈,且盐分时空变异性远大于水分。后期研究可通过这部分因素的改进进一步提高模型模拟与预测的精度。

不同土壤结构、质地均匀性改变了土壤水入渗形式,显著影响土壤水分入渗^[30]。秸秆覆盖耕作措施的土壤水蓄纳随作物生育期推移改变,且作物生长前期蓄水,后期供水^[31],这与本研究结果存在差异。本研究在多因素交互作用下,耕作层土壤含水率随地面灌溉而增大,但不同灌溉量土层的含水率变化趋势不一致。这是因为夏玉米秸秆质地粗糙,深埋后形成秸秆隔层的上下界面与均质土壤(粉砂壤土)的界面存在空隙差,且秸秆内部也存在较多空隙,造成隔层导水率与原土壤存在差异,影响土壤水入渗。另外,因土壤入渗水需先达到秸秆隔层蓄纳水容量才能继续下渗至心土层,导致在隔层与土壤交界面形成的优先流水分短时间内很难进入心土层,引起优先流运移不均匀^[32]。随土壤水入渗,较小灌水量(60 mm)耕作层含水率远低于田间持水率,入渗水分未能充分溶解耕作层盐分,且未达到秸秆隔层的蓄纳量,秸秆隔层未充分湿润。因此,此时入渗水主要消耗在耕作层及部分存蓄在隔层中,无淋盐的作用;随着蒸发作用增强,隔层蓄纳的水分及

耕作层水分蒸散较快,且隔层切断土壤毛管,心土层土壤水未能透过隔层及时补充蒸发消耗,耕作层及隔层含水率持续下降,导致小灌溉量的秸秆隔层逐渐演化成盐库,在夏玉米生育期有积盐趋势。

在多因素影响下,适宜灌溉量(90 mm 或 120 mm)处理的秸秆隔层延长了土壤入渗水在耕作层停蓄时间,可充分湿润耕作层和隔层,提高其含水率,与心土层形成不连续的水分运移架构,当入渗水量超过隔层蓄纳量时,土壤水将运移到心土层,最后形成不连续水分运移通道,入渗趋于稳定,达到部分淋盐效果;蒸发作用下,耕作层土壤水分逐渐减少,心土层土壤水上移补充,但隔层阻断了心土层土壤水分通过毛管上移的通道,切断蒸发补给,抑制深层土壤盐分上移,且隔层储蓄的水分在蒸发作用下逐步释放,补充根系层,从而在一定程度上稀释了土壤溶液,淡化根层。但灌水量较大(常规量 135 mm)时,隔层与心土层形成的不连续水分运移架构被破坏,土壤水在很大程度上自由运移,隔层上下界面与土壤间的导水率差异减小,且随灌水次数增加,不连续水分运移架构进一步破坏,隔层与土壤间导水率差异进一步变小,湿润区优先流与其水分运移很快平衡。因此,灌溉后耕作层含盐量大幅下降;随蒸发蒸腾作用增强,深层土壤水分通过土壤毛管进入耕作层,逐渐补给蒸发,盐分却留在耕作层,导致耕作层积盐,产生了次生盐渍化。研究指出,秸秆夹层能够抑制深层土壤返盐且抑制耕层盐分表聚^[33],这与本研究的结果有差异,这可能因为该研究仅分析秸秆夹层抑盐的作用,未考虑其他影响因素。本研究发现,灌溉 60 mm 处理的耕作层积盐,表层盐分聚集较多,因持续蒸发作用,耕作层水分损失严重,盐分浓度增大;灌溉 90 mm 和 120 mm 的耕作层盐分表聚,抑制心土层返盐,这与李芙荣等^[34]的研究结果类似,此时表聚盐分主要来源是耕作层及灌溉水的盐分,进而在一定程度淡化根系层;另外常规灌溉 135 mm 耕作层表聚大量盐分,造成耕作层次生盐渍化,此时表聚的盐分来源主要是耕层、灌溉水及心土

层的盐分。模拟结果表明,夏玉米生育末期灌溉 60、135 mm 的秸秆隔层积盐,积盐率为 49.2% 和 11.2%,灌溉 90、120 mm 的隔层为脱盐趋势,脱盐率为 6.1% 和 5.9%。模拟结果较实测值偏小,可能是因为模型训练是基于实测数据自身,约束条件较少导致。

水盐胁迫是危害盐渍地作物生长的关键因素,适宜的耕作层含盐量有利于增强作物的耐盐适应性^[26,35],有利于作物生长,且适宜灌水量对作物生理性状及产量会产生积极的影响^[36],这与本研究结果基本一致。本研究结果表明,多因素协同及秸秆深埋下夏玉米适宜单次灌水量为 89.3 ~ 96.8 mm,通过 PSWE 模型反算此时耕作层理论含盐量为 1.38 ~ 1.55 g/kg。说明秸秆深埋耕作模式下,适当减少灌水量及调控耕作层含盐量可提高夏玉米生产效益,过高或过低耕作层水盐含量均不利于作物生长。

4 结论

(1)PSWE 模型将夏玉米生长条件、土壤水盐含量与生产效益作为有机统一体,充分考虑各因素间整体协同效应,学习多因素在时间序列上的自然发展规律,较好地模拟了河套灌区多因素协同秸秆深埋的土壤水盐动态,有效表征三者间双层递进因果关系,学习各变量内在依存联系。模型平均均方根误差为 0.031,平均绝对误差(MAE)为 0.569,平均决定系数 R^2 为 0.987。

(2)多因素协同秸秆深埋下不同灌水量对土壤水盐含量影响显著,灌溉 90 mm 和 120 mm 的耕作层含水率保持在 16% ~ 24% 之间,生育末期隔层脱盐率分别为 6.1% 和 5.9%,而灌溉 60 mm 和 135 mm 的耕作层含水率持续降低或者变幅较大,生育末期隔层积盐率分别为 49.2% 和 11.2%。建议河套灌区秸秆深埋下夏玉米种植的单次灌水量为 89.3 ~ 96.8 mm,耕作层理论含盐量调控为 1.38 ~ 1.55 g/kg。

参 考 文 献

[1] LEI Tingwu, ISSAC S, YUAN Pujin, et al. Strategic considerations of efficient irrigation and salinity control on Hetao plain in Inner Mongolia[J]. Transactions of the CSAE, 2001, 17(1): 48 - 52.

[2] 屈忠义,杨晓,黄永江. 内蒙古河套灌区节水工程改造效果分析与评估[J]. 农业机械学报,2015,46(4): 70 - 76.

QU Zhongyi, YANG Xiao, HUANG Yongjiang. Analysis and assessment of water-saving project of Hetao irrigation district in Inner Mongolia[J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(4): 70 - 76. (in Chinese)

[3] ZHANG Peng, WEI Ting, JIA Zhikuan, et al. Soil aggregate and crop yield changes with different rates of straw incorporation in semiarid areas of Northwest China[J]. Geoderma, 2014, 230/231: 41 - 49.

[4] 梁建财,李瑞平,史海滨,等. 河套灌区覆盖对盐渍土壤养分迁移与分布的影响[J]. 农业机械学报,2016,42(2): 113 - 121.

LIANG Jiancai, LI Ruiping, SHI Haibin, et al. Effect of mulching on transfer and distribution of salinized soil nutrient in Hetao irrigation district[J]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 42(2): 113 - 121. (in Chinese)

[5] 汪可欣,付强,张中昊,等. 秸秆覆盖与表土耕作对东北黑土根区土壤环境的影响[J]. 农业机械学报,2016,47(3): 131 - 137.

- WANG Kexin, FU Qiang, ZHANG Zhonghao, et al. Effects of straw mulching mode and tillage methods on soil environment of root zone in northeast black soil[J]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(3): 131–137. (in Chinese)
- [6] 战秀梅,宋涛,冯小杰,等. 耕作及秸秆还田对辽南地区土壤水分及春玉米水分利用效率影响[J]. 沈阳农业大学学报, 2017, 48(6): 666–672.
- ZHAN Xiumei, SONG Tao, FENG Xiaojie, et al. Effect of tillage and straw application on soil water and water use efficiency of spring maize in southern area of Liaoning[J]. Journal of Shenyang Agricultural University, 2017, 48(6): 666–672. (in Chinese)
- [7] 解文艳,樊贵盛,周怀平,等. 秸秆还田方式对旱地玉米产量和水分利用效率的影响[J]. 农业机械学报, 2011, 42(11): 60–67.
- XIE Wenyang, FAN Guisheng, ZHOU Huaiping, et al. Effect of straw-incorporation on corn yield and water use efficiency in arid farming areas[J]. Transactions of the Chinese Society for Agricultural Machinery, 2011, 42(11): 60–67. (in Chinese)
- [8] BEZBORODOVA G A, SHADMANOV D K, MIRHASHIMOV R T, et al. Mulching and water quality effects on soil salinity and sodicity dynamics and cotton productivity in Central Asia[J]. Agriculture, Ecosystems and Environment, 2010, 138(7): 95–102.
- [9] SARKARS P M, GOSWAMI S B. Soil temperature, water use and yield of yellow sarson (*Brassica napus* L. var. glauca) in relation to tillage intensity and mulch management under rain-fed lowland ecosystem in eastern India[J]. Soil and Tillage Research, 2007, 93(1): 94–101.
- [10] WALKER A P, ZAEHLE S, MEDLYN B E, et al. Predicting long-term carbon sequestration in response to CO₂ enrichment: how and why do current ecosystem models differ[J]. Global Biogeochemical Cycles, 2015, 29(4): 476–495.
- [11] SCHINDLER D E, HILBORN R. Prediction, precaution, and policy under global change[J]. Science, 2015, 347: 953–954.
- [12] 于国强,李占斌,张霞,等. 土壤水盐动态的BP神经网络模型及灰色关联分析[J]. 农业工程学报, 2009, 25(11): 74–79.
- YU Guoqiang, LI Zhanbin, ZHANG Xia, et al. Dynamic simulation of soil water-salt using BP neural network model and grey correlation analysis[J]. Transactions of the CSAE, 2009, 25(11): 74–79. (in Chinese)
- [13] 屈忠义,陈亚新,杨靖宇. 人工神经网络在冻土水盐空间变异与条件模拟中的应用比较[J]. 农业工程学报, 2007, 23(7): 48–52.
- QU Zhongyi, CHEN Yaxin, YANG Jingyu. Application and comparison research of artificial neural network on conditional simulation and space variability of water-salt for frozen earth[J]. Transactions of the CSAE, 2007, 23(7): 48–52. (in Chinese)
- [14] 朱星明,卢长娜,王如云,等. 基于人工神经网络的洪水水位预报模型[J]. 水利学报, 2005, 36(7): 806–811.
- ZHU Xingming, LU Changna, WANG Ruyun, et al. Artificial neural network model for flood water level forecasting[J]. Journal of Hydraulic Engineering, 2005, 36(7): 806–811. (in Chinese)
- [15] EMERY A C J, ANTHONY J R, MARY M P. Aneural network model for predicting aquifer water level elevations[J]. Ground Water, 2005, 43(2): 231–241.
- [16] QI Yanbing, HUO Zailin, FENG Shaoyuan, et al. Prediction of consumptive use under different soil moisture content and soil salinity conditions using artificial neural network models[J]. Irrigation and Drainage, 2018, 67(4): 615–624.
- [17] 沈瑜,苑玉彬,彭静,等. 基于深度学习的寒旱区遥感影像河流提取[J]. 农业机械学报, 2020, 51(7): 192–201.
- SHEN Yu, YUAN Yubin, PENG Jing, et al. River extraction from remote sensing images in cold and arid regions based on deep learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(7): 192–201. (in Chinese)
- [18] 周亮,慕宏伟,马海蛟,等. 基于卷积神经网络的中国北方冬小麦遥感估产[J]. 农业工程学报, 2019, 35(15): 119–128.
- ZHOU Liang, MU Haowei, MA Haijiao, et al. Remote sensing estimation on yield of winter wheat in North China based on convolutional neural network[J]. Transactions of the CSAE, 2019, 35(15): 119–128. (in Chinese)
- [19] 刘兰军,翟永庆,郑俊俊,等. 基于深度学习的土壤氮含量可见/近红外光谱建模[J]. 光谱学与光谱分析, 2020, 40(增刊1): 71–72.
- LIU Lanjun, ZHAI Yongqing, ZHENG Junjun, et al. Visible-near infrared spectroscopy modeling of soil nitrogen content based on deep learning[J]. Spectroscopy and Spectral Analysis, 2020, 40(Supp. 1): 71–72. (in Chinese)
- [20] 马井会,曹钰,俞钟琦,等. 深度学习方法在上海市PM_{2.5}浓度预报中的应用[J]. 中国环境科学, 2020, 40(2): 530–538.
- MA Jinghui, CAO Yu, YU Zhongqi, et al. The application of deep learning method in Shanghai PM_{2.5} prediction[J]. China Environmental Science, 2020, 40(2): 530–538. (in Chinese)
- [21] 王威,李郁,张文娟,等. 深度学习技术在疾病诊断中的应用[J]. 第二军医大学学报, 2018, 39(8): 852–858.
- WANG Wei, LI Yu, ZHANG Wenjuan, et al. Application of deep learning technology in disease diagnosis[J]. Academic Journal of Second Military Medical University, 2018, 39(8): 852–858. (in Chinese)
- [22] CYBENKO G. Approximation by superpositions of a sigmoidal function[J]. Mathematics of Control, Signals, and Systems, 1989, 2: 303–314.
- [23] VINOD N, GEOFFREY E H. Rectified linear units improve restricted boltzmann machines[C] // Proceedings of the 27th International Conference on Machine Learning (ICML–10), 2010: 807–814.
- [24] SERGEY I, CHRISTIAN S. Batch normalization: accelerating deep network training by reducing internal co-variate shift[J]. arXiv:1502.03167, 2015.
- [25] SEBASTIAN R. An overview of gradient descent optimization algorithms[J]. arXiv preprint arXiv:1609.04747, 2016.
- [26] NITISH S, GEOFFREY E H, ALEX K, et al. Dropout: a simple way to prevent neural networks from over-fitting[J]. Journal of Machine Learning Research, 2014, 15(1): 1929–1958.
- [27] 刘全明,陈亚新,魏占民,等. 基于人工智能计算技术的区域性土壤水盐环境动态监测[J]. 农业工程学报, 2006, 22(10): 1–6.
- LIU Quanming, CHEN Yaxin, WEI Zhanmin, et al. Dynamic monitoring of zonal soil water-salt environment based on artificial intelligent technique[J]. Transactions of the CSAE, 2006, 22(10): 1–6. (in Chinese)
- [28] 余世鹏,杨劲松,刘广明,等. 基于模糊神经算法的区域地下水盐分动态预测[J]. 农业工程学报, 2014, 30(18): 142–150.
- YU Shipeng, YANG Jingsong, LIU Guangming, et al. Regional groundwater salinity dynamics forecasting based on neuro-fuzzy algorithm[J]. Transactions of the CSAE, 2014, 30(18): 142–150. (in Chinese)
- [29] 王钧,李广,聂志刚,等. 保护性耕作下土壤水分变化特征模拟研究[J]. 农业机械学报, 2021, 52(1): 263–274.

- WANG Jun, LI Guang, NIE Zhigang, et al. Simulation on variation characteristics of soil water content under conservation tillage[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(1): 263–274. (in Chinese)
- [30] FRANZLUEBBERS A J. Water infiltration and soil structure related to organic matter and its stratification with depth[J]. Soil and Tillage Research, 2002, 66(2): 197–205.
- [31] 贺立恒,高志强,孙敏,等.旱地小麦休闲期不同耕作措施对土壤水分蓄纳利用与产量形成的影响[J].中国农学通报,2012,28(15):106–111.
- HE Liheng,GAO Zhiqiang,SUN Min,et al. Effect of ploughing in leisure period on yield and soil water use efficiency of winter wheat in dryland[J]. Chinese Agricultural Science Bulletin,2012,28(15):106–111. (in Chinese)
- [32] 牛健植,余新晓.优先流问题研究及其科学意义[J].中国水土保持科学,2005,3(3):110–116,126.
- NIU Jianzhi, YU Xinxiao. Preferential flow and its scientific significance[J]. Science of Soil and Water Conservation, 2005, 3(3): 110–116, 126. (in Chinese)
- [33] 张金珠,王振华,虎胆·吐马尔白.具有秸秆夹层状土壤一维垂直入渗水盐分布特征[J].土壤,2014,46(5):954–960.
- ZHANG Jinzhu, WANG Zhenhua, HUDAN Tumarebi. Distribution characteristics of one dimensional vertical infiltration water and salt in layered soil with subsurface straw layer[J]. Soils, 2014, 46(5): 954–960. (in Chinese)
- [34] 李芙蓉,杨劲松,吴亚坤,等.不同秸秆埋深对苏北滩涂盐渍土水盐动态变化的影响[J].土壤,2013,45(6):1101–1107.
- LI Furong, YANG Jinsong, WU Yakun, et al. Effects of straw mulch at different depths on water-salt dynamic changes of coastal saline soil in North Jiangsu Province[J]. Soils, 2013, 45(6): 1101–1107. (in Chinese)
- [35] DELGADO I C, SANCHE Z, RAYA A J. Effects of sodium chloride and mineral nutrients on initial stages of development of sunflower life[J]. Communications in Soil Science and Plant Analysis, 2007, 38(15/16): 2013–2027.
- [36] LIU Wenzhao, LI Yushan. Crop yield response to water and fertilizer in loess tableland of China: a field research[J]. Pedosphere, 1995, 5(3): 259–266.

(上接第310页)

- [7] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278–2324.
- [8] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84–90.
- [9] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J/OL]. arXiv:1409.1556v6,2015. <https://doi.org/10.48550/arxiv.1409.1556>.
- [10] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015: 1–9.
- [11] HE K M, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 770–778.
- [12] IANDOLA F N, HAN S, MOSKEWICZ M W, et al. SqueezeNet: alexnet-level accuracy with 50x fewer parameters and <0.5 MB model size[EB/OL]. (2016–11–04)[2021–07–01]. <https://arxiv.org/abs/1602.07360>.
- [13] HUANG G, LIU Z, WEINBERGER K Q. Densely connected convolutional networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 2261–2269.
- [14] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications[EB/OL]. (2017–04–17)[2021–07–01]. <https://arxiv.org/abs/1704.04861>.
- [15] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 42(8): 2011–2023.
- [16] ALSHAWWA M O, ABUNASTER S S. Classification of apple fruits by deep learning[J]. International Journal of Academic Engineering Research (IJAER), 2020, 3(12): 1–7.
- [17] 张力超,马蓉,张珏鑫.改进的LeNet-5模型在苹果图像识别中的应用[J].计算机工程与设计,2018,39(11):278–283.
- ZHANG Lichao, MA Rong, ZHANG Yaixin. Application of improved LeNet-5 model in apple image recognition[J]. Computer Engineering and Design, 2018, 39(11): 278–283. (in Chinese)
- [18] 杨福增,雷小燕,刘志杰,等.基于CenterNet的密集场景下多苹果目标快速识别方法[J].农业机械学报,2022,53(2):265–273.
- YANG Fuzeng, LEI Xiaoyan, LIU Zhijie, et al. Fast recognition method for multiple apple targets in dense scenes based on CenterNet[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(2): 265–273. (in Chinese)
- [19] 何进荣,石延新,刘斌,等.基于DXNet模型的富士苹果外部品质分级方法研究[J].农业机械学报,2021,52(7):379–385.
- HE Jinrong, SHI Yanxin, LIU Bin, et al. External quality grading method of fuji apple based on deep learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(7): 379–385. (in Chinese)
- [20] JONGCHAN P, SANGHYUN W, JOON-YOUNG L, et al. BAM: bottleneck attention module[EB/OL]. (2018–07–18)[2021–07–01]. <https://arxiv.org/abs/1807.06514>.
- [21] WANG Qilong, WU Banggu, ZHU Pengfei, et al. ECA-Net: efficient channel attention for deep convolutional neural networks[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2018: 11531–11539.
- [22] ZHANG X, ZHOU X, LIN M, et al. ShuffleNet: an extremely efficient convolutional neural network for mobile devices[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2018: 6848–6856.
- [23] MINGXING T, QUOC V L. EfficientNet: rethinking model scaling for convolutional neural networks[J]. Statistics, 2019, 2(97): 1–10.