刘斌，王柏，司振江，等. 基于SSA-DELM算法的黑土地保护性耕作土壤温度预测[J]. 水利水电技术(中英文)，2025，56(10)：257-276. DOI：10.13928/j.cnki.wrahe.2025.10.020

LIU Bin，WANG Bai，SI Zhenjiang，et al. Prediction of soil temperature based on SSA-DELM algorithm for conservation tillage in black soil[J]. Water Resources and Hydropower Engineering，2025，56(10)：257-276. 10.13928/j.cnki.wrahe.2025.10.020

基于SSA-DELM算法的黑土地保护性耕作土壤温度预测

刘　斌[1,2]，王　柏[1,2,3]，司振江[1]，黄　彦[1,2,3]，蒋骁童[1,2]，郝　利[1,2]

(1. 黑龙江大学 水利电力学院，黑龙江 哈尔滨　150006；2. 黑龙江省水利科学研究院，黑龙江 哈尔滨　150080；3. 农业农村部东北节水农业重点实验室，黑龙江 哈尔滨　150080)

摘　要：【目的】农田耕作层土壤温度的精准预测分析对农业生产具有重要现实意义。为有效、准确分析缺乏实测条件的黑土地保护性耕作农田土壤温度的变化特征，【方法】基于极限训练机算法(ELM)，引入自编码器算法(AE)构建深度极限训练机(DELM)，利用麻雀搜索算法(SSA)进行改进，构建了SSA-DELM混合模型，利用气象因子数据，对免耕无秸秆覆盖(NT0)和免耕秸秆全覆盖(NTS)两种耕作条件下不同深度土壤温度进行预测，并与ELM、RF和SSA-RF模型进行对比。【结果】结果显示，SSA-DELM模型在两种耕作条件下土壤温度预测结果决定系数(R^2)分别为0.996和0.998，平均绝对误差(*MAE*)分别为0.16和0.1，均方根误差(*RMSE*)分别为0.29和0.16，纳什效率系数(*NSE*)为0.999和0.999，性能指数(*PI*)为0.051和0.056，最大残差(Max*E*)均小于0.25，平均运行时间分别为17.2 s和17.6 s。【结论】结果表明，相较于其他模型，SSA-DELM模型的预测精度、泛化能力和预测效率更优，预测误差较小，在两种不同耕作条件下均能满足土壤温度预测需求，具有良好的稳定性和抗干扰能力，可为农业生产决策提供可靠的数据支持。

关键词：土壤温度；保护性耕作；神经网络；麻雀搜索算法；深度学习；数值模拟；地下水；黑土地

DOI：10.13928/j.cnki.wrahe.2025.10.020　　**开放科学(资源服务)标志码(OSID)：**

中图分类号：S152.8　　**文献标志码：**A　　**文章编号：**1000-0860(2025)10-0257-20

听语音 聊科研 与作者互动

Prediction of soil temperature based on SSA-DELM algorithm for conservation tillage in black soil

LIU Bin[1,2]，WANG Bai[1,2,3]，SI Zhenjiang[1]，HUANG Yan[1,2,3]，JIANG Xiaotong[1,2]，HAO Li[1,2]

(1. College of Water Resources and Electricity，Heilongjiang University，Harbin　150006，Heilongjiang，China；2. Heilongjiang Provincial Institute of Water Resources Science and Research，Harbin　150080，Heilongjiang，China；3. Northeast Key Laboratory of Water-saving Agriculture，Ministry of Agriculture and Rural Development，Harbin　150080，Heilongjiang，China)

收稿日期：2024-07-12；**修回日期：**2024-10-07；**录用日期：**2024-10-08；**网络出版日期：**2024-10-21

基金项目：国家自然科学基金项目(52079050)

作者简介：刘　斌(2001—)，男，硕士研究生，主要从事农业水土资源研究。E-mail：sl27012024@163.com

通信作者：王　柏(1980—)，男，正高级工程师，博士，主要从事水土资源高效利用基础理论与应用技术研究。E-mail：wangbai1980@163.com

司振江(1959—)，男，正高级工程师，博士，主要从事农业节水技术，农业生态环境修复等研究。E-mail：si_ zj@163.com

©Editorial Department of Water Resources and Hydropower Engineering. This is an open access article under the CC BY-NC-ND license.

Abstract：[Objective] Accurate prediction and analysis of soil temperature in the tillage layer of farmland is of great practical significance for agricultural production, in order to effectively and accurately analyze the characteristics of soil temperature change in the farmland of conservation tillage of black soil lacking in real measurement conditions. [Methods] Based on the Extreme Limit Training Machine (ELM) algorithm, the Self-Encoder Algorithm (AE) was introduced to form the Depth Extreme Limit Training Machine (DELM), which was improved by using the Sparrow Search Algorithm (SSA), and a hybrid SSA-DELM model was constructed to predict soil temperatures at different depths under two types of no-tillage no-straw cover (NT0) and no-tillage full straw cover (NTS) tillage conditions by utilizing the data of meteorological factors, and then predict soil temperatures at different depths under no-tillage no-straw cover (NTS). Soil temperature was predicted and compared with ELM, RF and SSA-RF models. [Results] The results showed that the coefficient of determination (R^2) of the SSA-DELM model was 0.996 and 0.998, the mean absolute error (*MAE*) was 0.16 and 0.1, the root mean square error (*RMSE*) was 0.29 and 0.16, and the coefficients of Nash′s efficiency (*NSE*) were 0.999 and 0.999 for the prediction of soil temperatures under two types of tillage conditions, respectively. Performance Index (*PI*) was 0.051 and 0.056, the maximum residual error (Max*E*) was less than 0.25, and the average running time was 17.2 s and 17.6 s, respectively. [Conclusion] Compared with other models, the prediction accuracy, generalization ability and prediction efficiency of SSA-DELM model were better than other models, and the prediction error was very low, and it could satisfy the two different tillage conditions under the soil temperature prediction needs, has good stability and anti-interference ability, and can provide certain data support for agricultural production decision-making.

Keywords：soil temperature; conservation tillage; neural network; sparrow search algorithm; deep learning; numerical simulation; groundwater; black soil

0　引　言

东北黑土区作为世界三大黑土区之一，是我国重要的粮食产地，在保障农业生产的同时保护土地资源是当下农业研究的重要课题。近年来，由于保护不当或无保护开垦引发土壤肥力流失、土壤退化情况日益严重，严重制约了农业生产发展[1-3]。保护性耕作通过减少土壤耕作次数以及进行秸秆覆盖，能够增加土壤有机质、改善土壤结构、影响土壤微生物群落构成及活性，对于受损土壤层的修复具有积极意义，是实现农业可持续发展的重要途径[4-6]。土壤温度作为农业决策过程中重要的陆面变量，不仅影响着土壤理化性质，还直接影响着植物的物候阶段，如农作物的萌发、根系生长和开花等。土壤温度的周期性变化，是在气温、辐射、日照时数等气象因子的影响下，土壤与大气发生能量交换而产生的[7-8]。DAVIDSON 等[9]的研究中，阐述了土壤温度、微生物活动以及温室气体之间的复杂反馈机制，土壤温度的变化对于微生物活动具有直接影响，其与碳动力学以及温室气体的排放建立了错综复杂的关系，秸秆覆盖对土壤温度变化所产生的影响间接改变了微生物的呼吸速率，改变二氧化碳释放量，在影响气候变化的同时反馈农业生产过程，提示了土壤温度变化对农业生产的多方面影响。王敏等[10]探究了不同覆盖方式对土壤水温作用以及玉米生长的影响，秸秆覆盖下耕作层温度与传统耕作方式有很大不同，土壤温度的变化影响着作物的生育期时间，也因此在一定程度上影响着农田作物产量。冯浩等[11]探究了覆盖对土壤温度以及夏玉米植株生长和产量的影响，证明了覆盖改变了土壤温度的变化特征。齐智娟等[12]研究了东北寒区黑土地保护性耕作对土壤水热变化动态的影响，并进一步探究了养分吸收和产量的关联，表明覆盖阻碍了大气与土壤之间的水热交换，导致土壤水热变化特征产生了变化。在实行保护性耕作的条件下，由于不同的耕作覆盖方式改变了近地面下垫面的性质，影响着土壤与大气之间的热交换，使得耕作层土壤温度的变化特征产生改变，同时影响着农业生产过程[13-14]。稳定准确地监测土壤温度，实现土壤温度变化特征的有效分析，对农业生产安排具有重要的指导意义。

传统土壤温度测量主要是在土壤中多深度、多点设置热电偶、电阻温度计等探测器，这种方式测量成本较高，费时费力，同时受到区域小气候的影响，土壤温度在大区域内具有很强的时空异质性，在大部分缺乏实测条件的区域，无法实现对土壤温度的精准监测。一些研究人员通过建立多元线性回归方程的方式进行土壤温度预测，但是简单的回归模型在复杂非线性问题中存在不足，难以实现良好的预测精度。随着先进模型和技术的开发，以机器学习为代表的数据驱动模型得到了广泛关注[15-17]。LIU 等[18]提出了一种混合模型 ANFIS-MSG，该模型将自适应神经模糊推理系统与优化方法相结合来预测土壤温度，将该模型与其他几个模型进行了比较，证明了其在土壤温度预测方面的有效性。同样，李清亮等[19]进行了极限梯度提升和长短期记忆网络相融合的土壤温度预测研

究，得到了较高的准确度，但是受采集数据限制，仅针对 5 cm 深度进行试验，缺乏对不同土壤深度温度预测性能的探究。总之，随着混合模型以及先进算法的发展，此类预测模型被越来越多的研究人员应用到土壤温度的预测中，在应用中展现出了良好的性能。但将此类方法应用于保护性耕作条件下的耕作层土壤温度预测的相关研究较少，进行秸秆覆盖后，下垫面性质的改变也改变了气象因子与土壤温度间的特征关联，产生了更多的噪声影响。传统机器学习模型的预测误差较大，而深度学习多隐含层的架构有利于特征去噪，在很多领域应用中取得了较好的效果[20-22]。在此背景下，本文基于极限训练机(ELM)模型，通过自编码器(AE)算法进行优化，堆栈形成深度极限训练机(DELM)模型，同时利用麻雀搜索算法(SSA)进行优化，提高了模型泛化能力和预测精度，形成混合模型(SSA-DELM)，用于土壤温度反演，对免耕无秸秆覆盖(NT0)及免耕秸秆全覆盖(NTS)两种常用的保护性耕作方式下不同深度处土壤温度进行预测，评估预测误差。将结合深度学习的土壤温度预测方法应用于黑土地保护性耕作地区，旨在实现对缺乏实测条件的保护性耕作地区土壤温度精准监测，为农业生产安排决策提供理论依据。

1　材料与方法

1.1　研究区概述

本文研究地点位于黑龙江省水利科学研究院水利科技试验研究中心(126°36′E，45°43′N)。该地属于温带大陆性季风气候，为季节性冻土区。该试验站多年平均气温-4～5 ℃，无霜期 130～140 d，年均降水量 400～650 mm。试验区位于东北典型黑土带，试验土壤质地为壤土，于 2019 年开始进行秸秆还田与不同耕作方式相结合的试验。试验地为旱作土地，主要作物为玉米。免耕无秸秆覆盖处理在秋收后不进行耕翻，移走全部秸秆；免耕秸秆全覆盖处理同样在秋收后不进行耕翻，将全部秸秆粉碎后覆盖于地表。

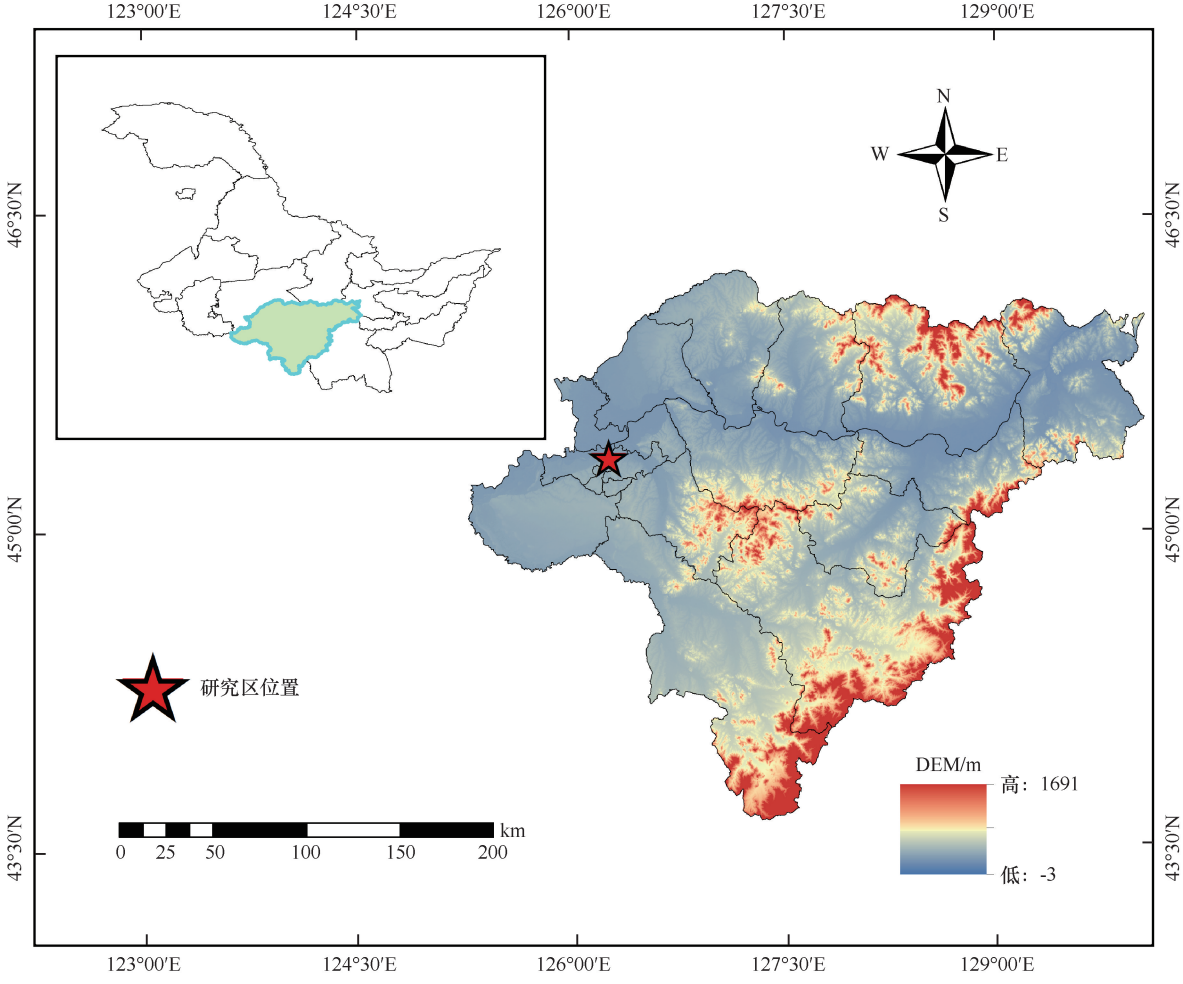

图 1　研究区位置示意

Fig. 1　Schematic location of the study area

图 2　试验处理以及温度采集设施

Fig. 2　Experimental processing as well as temperature acquisition facilities

1.2　数据来源

土壤温度采用土壤温度自动监测系统及配套的 PT100 温度传感器定点测量土壤剖面温度，精度 0.1 ℃，采样时间间隔为 1 h(见图 2)。在土壤冻结期前，将土壤温度传感器沿土体垂直方向分层埋设(5 cm、10 cm、20 cm、30 cm、40 cm、50 cm)，连续监测记录。气象数据来源于试验区内设置的气象站监测数据。

1.3　数据处理与分析

本研究数据集选取时间跨度为 2020 年 11 月 3 日至 2022 年 4 月 30 日，时间尺度为逐小时的土壤温度数据(包括 5 cm、10 cm、20 cm、30 cm、40 cm、50 cm 深度土层)和气象因子数据(包括气温、风速、辐射、日照时数、水汽压)，将样本中自 2020 年 11 月 3 日至 2021 年 11 月 3 日的数据作为训练集(共计 8784 个)，将 2021 年 11 月 4 日至 2022 年 4 月 30 日的数据作为测试集(共计 4272 个)。对数据的预处理包括对少量缺失值进行填补、相关性特征分析和归一化处理。

对于机器学习模型而言，其模型建立过程依赖于输入特征与目标之间的关联性，在学习输入特征进行回归分析的映射过程中，数据间的关联程度影响着机器学习过程中的收敛难度与速度，较差的相关度降低了模型对特征的敏感度，在一定程度上增加回归预测的难度，导致模型难以取得满意的准确度。利用统计学手段判断输入特征与目标之间的相关度，是机器学习模型建立过程中的关键步骤[23-24]。基于 Spearman 相关系数的输入特征分析在机器学习领域中得到了广泛应用。Spearman 相关系数可以反应变量间在变化趋势方向以及强度之间的关联，尤其是在变量间存在非线性关系时，能够很好地描述其变化关系[25-26]。据此，本研究计算了两种耕作方式下各土层温度与气象因子间的 Spearman 相关系数，对数据集中实测土壤温度数据与气象因子数据进行相关性分析，以此判断耕作方式的改变是否会对土壤温度预测过程产生影响。结果表明，随着土层深度的增加，各气象因子与土壤温度的相关度产生了不同程度的改变。在 NT0 条件下，相关性较强的气温、辐射和水汽压三个气象因子，从 5 cm 深度到 50 cm 深度处，与土壤温度之间的相关系数分别降低了 10%、39%和 8%，气象因子中的日照时数在 30 cm 处开始，出现了由正相关变为负相关的情况，在 NTS 条件下，气温、辐射和水汽压三个气象因子，随着深度的增加，相关系数减小的情况更为显著，从 5 cm 深度到 50 cm 深度处，与土壤温度之间的相关系数则分别降低了 22%、62%和 20%。比较两种不同耕作方式下土壤温度与气象因子间的相关系数，就气象因子中的风速而言，在 NT0 条件下各深度处均为正相关，而在 NTS 条件下 40 cm 和 50 cm 深度处出现了负相关的情况。就气温、辐射和水汽压三个气象因子而言，NTS 条件下各土层土壤温度相关度明显低于 NT0 条件，相关系数均出现了不同程度的减小，在 50 cm 深度处，其相关系数分别减小了 15%、44%和 13%。就气象因子中的日照时数而言，对比 NTS 条件与 NT0 条件，除了相关系数的减小，由正相关转变为负相关的情况也更早地出现在 20 cm 深度处。数据间相关性的变化，影响着模型对输入特征映射关系的判断，耕作方式的改变在改变土壤温度变化特征的同时，也影响着气象因子与土壤温

度间的关联性，是构建机器学习模型过程中的重要影响因素。为了直观地判断 Spearman 相关系数的变化，绘制相关性热图如图 3、图 4 所示。

数据处理和统计利用 Office 2019 和 SPSS 26.0 进行，利用 MATLAB 进行模型预测分析，通过 Origin2024b 和 Python3.9 制图。

1.4　预测模型构建以及优化算法

1.4.1　ELM 极限训练机

极限训练机(ELM)是由 HUANG 等[27-28]在 2004 年提出的一种前馈神经网络，在 ELM 中，输入权值和隐含层偏差被随机初始化给定，输出权值矩阵利用广义逆(MP)计算得到。典型的单隐含层前馈神经网络结构如图 1 所示，由输入层、隐含层和输出层组成，输入层与隐含层、隐含层与输出层神经元间全连接。其中，输入层有 n 个神经元，对应 n 个输入变量，隐含层有 l 个神经元；输出层有 m 个神经元，对应 m 个输出变量。

1.4.2　DELM 深度极限训练机

ELM 是一种求解单隐含层前馈神经网络的算法，具有较快的学习速率，但因为 ELM 是单隐含层结构，因此在对较多数量、较高维度的数据进行求解时，很难捕捉到有效的特征，效率会下降，因此，引入自动编码器 AE(Auto Encoder)，AE 经过训练后可将输入复制到输出[29-31]。将 AE 的思想应用到 ELM 中，使 ELM 的输入数据同样被用于输出，即输出 $\boldsymbol{Y}=\boldsymbol{X}$，与 ELM 相结合，组成深度极限训练机(DELM)。作为自编码器的极限训练机 ELM-AE 网络结构如图 5 所示。

在此基础上将多个 ELM 进行组合形成 DELM。相较于 ELM，DELM 能够更全面地捕捉数据之间的映射关系，更清晰地学习到数据的特征，且 DELM 不需要进行反向调优，能够大大减少消耗时间。DELM 网格结构如图 6 所示。

1.4.3　SSA 麻雀搜索算法

“麻雀搜索算法(Sparrow Search Algorithm，SSA)”是 2020 年由薛建凯等[32]提出的群智能优化搜索算法，该算法是受到自然界中麻雀群体觅食和反捕食行为的启发，具有良好的全局寻优能力，收敛速度快，稳定性高。

对于麻雀的两种行为定义如下。

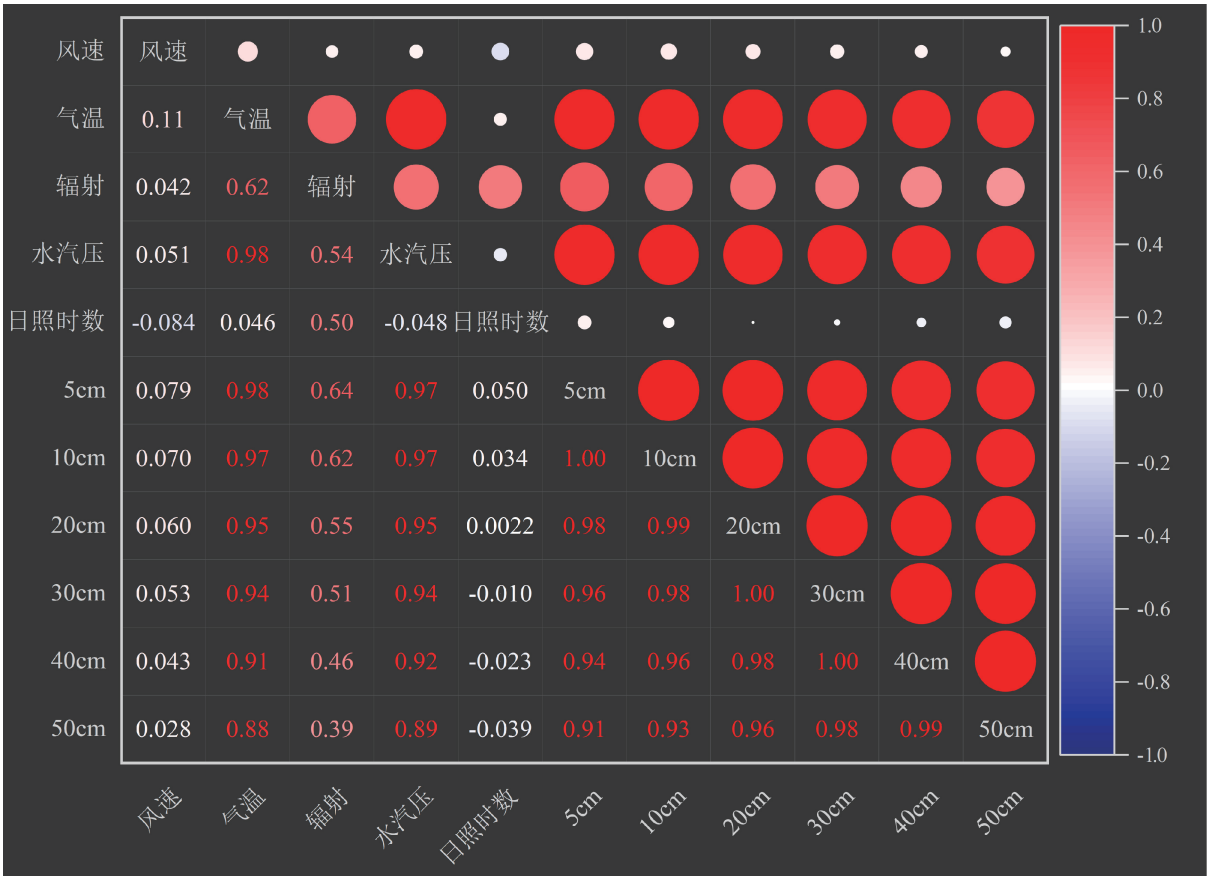

图 3　NT0 条件下相关性热图

Fig. 3　Correlation thermogram at NT0 conditions

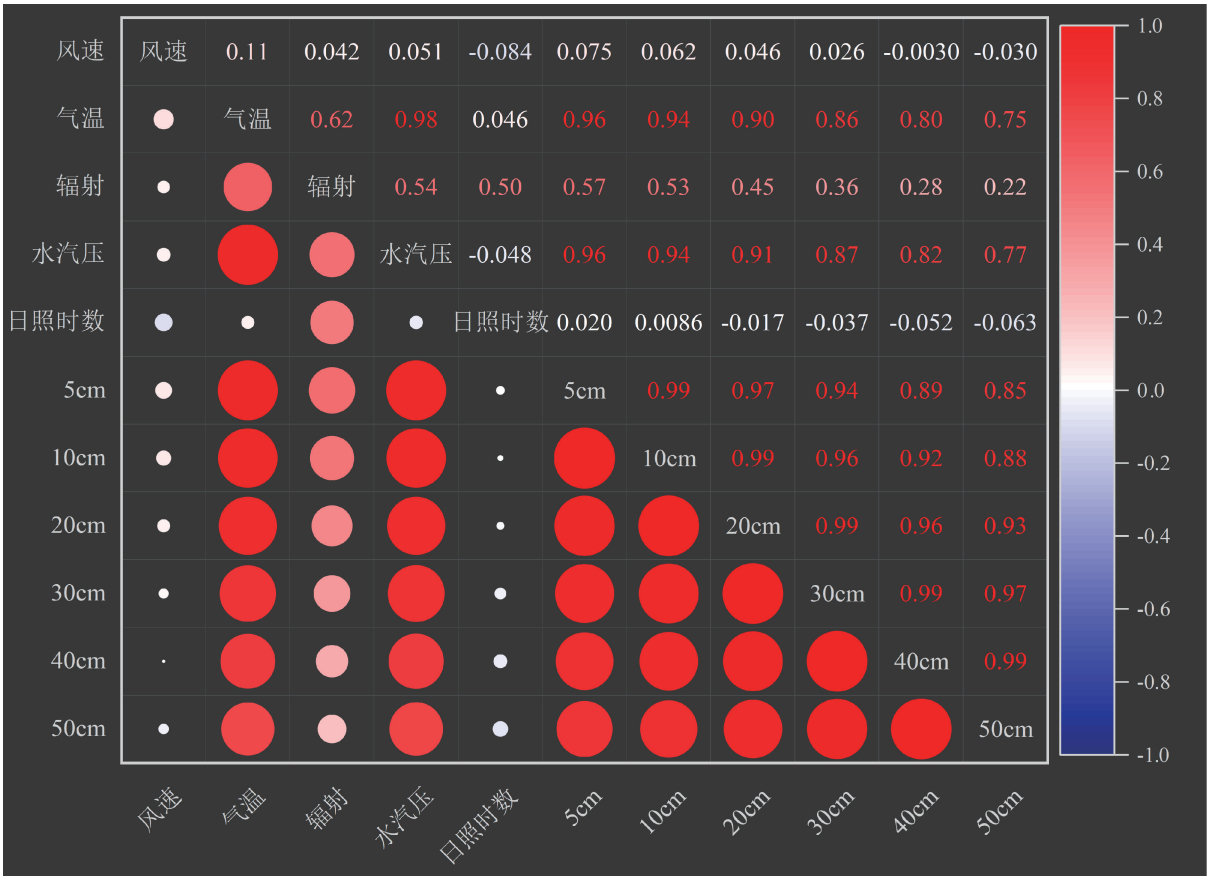

图 4　NTS 条件下相关性热图

Fig. 4　Correlation heatmap under NTS conditions

觅食：麻雀中分为探索者和追随者，能够寻找较好食物的麻雀(适应度函数较高)为探索者，其余麻雀为追随者，受到探索者所在方向的影响。

反觅食：麻雀群体中一定比例的麻雀会进行侦察，当发现捕食者来临时会做出相应的行为。

在麻雀搜索算法中，假设有 n 只麻雀，将被分为三种身份，即发现者、跟从者和警戒者，在本算法中，适应度值更高的麻雀被视为发现者，发现者在麻雀群体中占有主导地位，负责为整个群体寻找食物，并提供食物的方位和拥有食物的区域。跟从者会持续监控发现者，一旦发现者找到食物，跟从者会立即抢夺食物。并且，麻雀能够在发现者和跟从者之间切换。警戒者负责对觅食区域周围进行监视，当觅食区域周围有捕食者出现时，警戒者会即刻预警，预警信号超过预警阈值时，会向种群发送信号，此时整个种群会在发

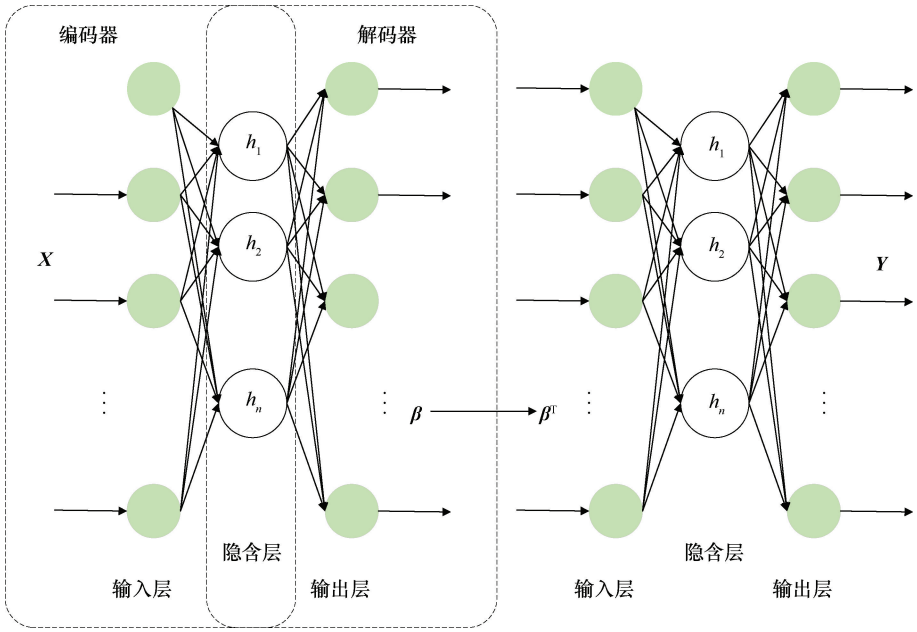

图 5　ELM-AE 结构

Fig. 5　Structure of ELM-AE

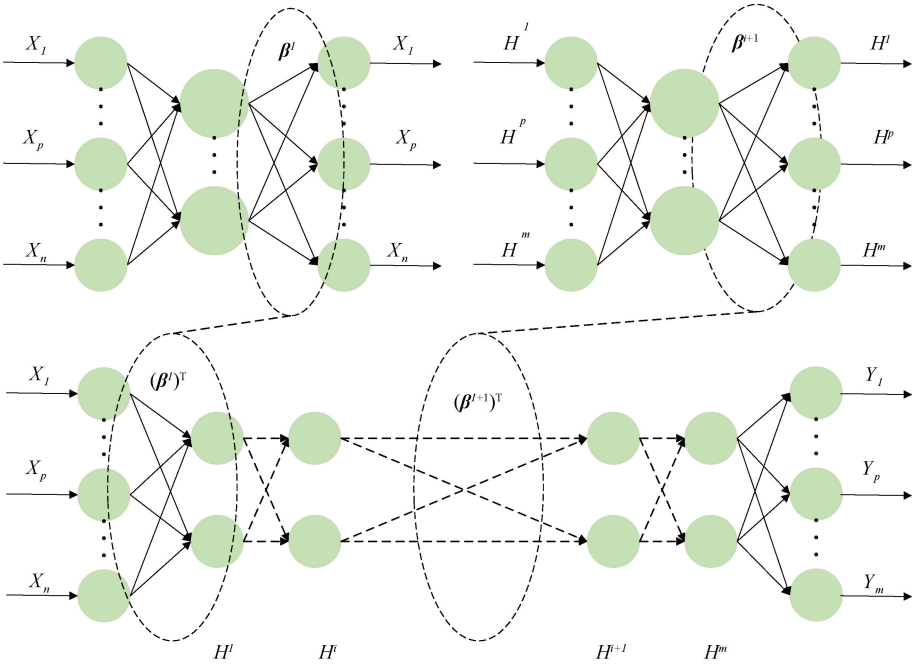

图 6　DELM 结构示意

Fig. 6　DELM structure

现者的带领下移动寻找下一个觅食地点[33-35]。

据此，在每次迭代中，发现者位置更新策略公式为

$$X_{i,j}^{t+1}=\begin{cases}X_{i,j}^{t}\cdot\exp\left(\dfrac{-i}{\alpha\cdot \mathrm{iter}_{\max}}\right) & \text{if } R_2<ST\\ X_{i,j}^{t}+Q\cdot\boldsymbol{L} & \text{if } R_2\geqslant ST\end{cases}\tag{1}$$

式中，t 为当前的迭代次数；i 和 j 表示第 i 只麻雀、第 j 维的值；$iter_{\max}$ 为迭代次数最大值；α 为一个随机数，取值范围为(0，1]；R_2($R_2\in[0,1]$)和 ST($ST\in[0.5,1.0]$)分别代表预警值和安全阈值；Q 为一个随机数，服从正态分布；$\boldsymbol{L}$ 为 1×d 的矩阵，其中的所有元素都为 1。

当 $R_2<ST$ 时，这表明周围环境安全，可以进行搜索。而当 $R_2\geqslant ST$ 时，这表明一些麻雀已经发现了危险，将立即发出信号，麻雀种群迅速移动到安全区域。

跟从者位置更新策略公式为

$$X_{i,j}^{t+1}=\begin{cases}Q\cdot\exp\left(\dfrac{X_{\mathrm{worst}}^{t}-X_{i,j}^{t}}{i^2}\right) & \text{if } i>n/2\\ X_P^{t+1}+\left|X_{i,j}^{t}-X_P^{t+1}\right|\cdot\boldsymbol{A}^{+}\cdot\boldsymbol{L} & \text{otherwise}\end{cases}\tag{2}$$

式中，X_{worst}^{t} 为第 t 代某一个体所处的最差位置坐标，即适应值最低；X_P^{t+1} 为一次迭代后所处的最好位置坐标；$\boldsymbol{A}$ 为全部元素为 1 的矩阵，该矩阵中每个数值随机选取为 1 或 -1，并且满足 $\boldsymbol{A}^{+}=\boldsymbol{A}^{\mathrm{T}}(\boldsymbol{A}\boldsymbol{A}^{\mathrm{T}})^{-1}$；当 $i>n/2$ 时，表示第 i 个跟从者需前往其他区域觅食，当 $i\leqslant n/2$ 时，跟从者到达最佳觅食位置。

警戒者位置更新策略公式为

$$X_{i,j}^{t+1}=\begin{cases}X_{\mathrm{best}}^{t}+\beta\times\left|X_{i,j}^{t}-X_{\mathrm{best}}^{t}\right|, & \text{if } f_i>f_g\\ X_{i,j}^{t}+K\times\left(\dfrac{\left|X_{i,j}^{t}-X_{\mathrm{worst}}^{t}\right|}{(f_i-f_w)+\varepsilon}\right), & \text{if } f_i=f\end{cases}\tag{3}$$

式中，X_{best}^{t} 表示第 t 代时警戒者寻找到的最优位置；β 为步长控制参数，是一个服从正态分布的随机数；K 同样是一个随机数，表示麻雀移动的方向，并也作为步长控制系数，$K\in[-1,1]$；此时 f_i 表示当前麻雀个体适应值；f_g 和 f_w 分别表示当前麻雀种群内个体最优和最差适应度值；ε 为一个趋近但不等于 0 的常数，以避免零除法误差。

其中，警戒者的初始位置在种群中随机生成，约占种群总数的 10%~20%。当 $f_i>f_g$ 表示当前麻雀个体的位置处于种群的边缘，需要接近种群中心。X_{best} 代表了种群中心的位置，并且在其周围很安全。当 $f_i=f_g$，表示位置在种群中间的麻雀个体察觉到了危险，需要远离危险地区。

1.4.4　SSA-DELM 优化模型构建

引入 AE 与 ELM 形成 ELM-AE 后，由多个 ELM-AE 作为无监督学习基本单元组合而成 DELM。DELM 的初始权重和偏置参数由随机初始化的方式生成，而模型的预测效率很大程度上取决于初始权重的选取，因此模型的预测能力具有较大的波动性。采用 SSA 对 DELM 进行改进，通过将输入数据经过多个隐含层的非线性变换，得到高层次的抽象特征表示，然后将这些特征输入到输出层进行回归预测，利用 SSA 算法对这个高维空间进行划分和优化。SSA 算法通过一系列随机向量实现搜索空间的划分，在每次迭代中，SSA 算法对每个随机向量进行扰动和优化，从而在整个搜索空间中搜索最优解，优化 DELM 的权重和偏置参数，以最小化误差。

通过 SSA 与 DELM 融合形成 SSA-DELM 模型，提升模型收敛速度，避免陷入局部最优解的情况，提

高了模型预测效果的稳定性与泛化能力。

1.5　误差评价指标

在创建模型并在数据集上测试之后，利用不同的评价指标评估它们的性能非常重要。为此，在本研究中计算了以下误差评价指标，包括决定系数 R^2、平均绝对误差 *MAE*、均方根误差 *RMSE*、归一化均方根误差 *NRMSE*、最大残差 Max*E*、相对均方根误差 *RRMSE*、相关系数 *CC*、标准差 *SD*、纳什-萨特克利夫效率系数 *NSE* 和性能指数 *PI* 等[32]。公式如下

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(Y_i - Y_i^*)^2}{\sum_{i=1}^{n}(Y_i - \overline{Y_i})^2} \tag{4}$$

$$MAE = \frac{1}{n}\sum_{1}^{n}|Y_i - Y_i^*| \tag{5}$$

$$RMSE = \sqrt{\sum_{1}^{n}\frac{(Y_i - Y_i^*)^2}{n}} \tag{6}$$

$$\mathrm{Max}E = \mathrm{Max}(Y_i - Y_i^*) \tag{7}$$

$$NRMSE = \frac{RMSE}{[\mathrm{Max}(Y_i) - \mathrm{Min}(Y_i)]} \tag{8}$$

$$RRMSE = \frac{RMSE}{\overline{Y_i}} \tag{9}$$

$$CC = \frac{\sum_{1}^{n}(Y_i - \overline{Y})(Y_i^* - \overline{Y^*})}{\sqrt{\sum_{1}^{n}(Y_i - \overline{Y})^2}\sqrt{\sum_{1}^{n}(Y_i^* - \overline{Y^*})^2}} \tag{10}$$

$$SD = \sqrt{\frac{\sum_{i=1}^{n}(Y_i - \overline{Y_i})^2}{n}} \tag{11}$$

$$NSE = 1 - \frac{\sum_{i=1}^{n}(Y_i - Y_i^*)^2}{\sum_{i=1}^{n}(Y_i - \overline{Y_i})^2} \tag{12}$$

$$PI = \frac{RRMSE}{\sqrt{R^2 + 1}} \tag{13}$$

式中，Y_i 为真实值；Y_i^* 为预测值；$\overline{Y_i}$ 为真实值平均值；$\overline{Y_i^*}$ 为预测值平均值。

2　结果与分析

2.1　模型验证与结果评价

构建数据集，输入特征包括风速、气温、辐射、日照时数和水汽压5个天气因子；分别将2种耕作条件下(免耕无秸秆覆盖 NT0、免耕秸秆全覆盖 NTS)6个深度处(5 cm、10 cm、20 cm、30 cm、40 cm、50 cm)土壤温度作为输出。将数据集中自2020年11月3日至2021年11月3日的数据作为训练集，2021年11月4日至2022年4月30日的数据作为测试集来判断模型的泛化能力。为了进一步评估本文构建的SSA-DELM混合模型的适应能力，将数据集分别输入到独立 ELM、RF 模型和 SSA-RF 混合模型中，与SSA-DELM模型预测结果进行对比分析。

通过以上模型测试集预测值与真实值对比可以发现：在免耕无秸秆覆盖条件下，在对浅层土壤温度的预测中，ELM 模型容易受到数据噪声的影响，温度的预测值出现了异常波动，与真实值出现偏差，而其余三个模型均具有较好性能，能够较为准确地分析土壤温度在气象因子影响下的变化。但是在对20 cm及以下土层温度预测中，除SSA-DELM模型以外的三个模型预测能力均出现明显下降，主要是在温度由逐渐下降转为逐渐上升的时期，不能准确地识别这种变化趋势的改变。在免耕秸秆全覆盖条件下，ELM、RF 和 SSA-RF 模型的预测精度较差，不能准确地分析土壤温度变化特征和趋势，这主要是由于秸秆覆盖对下垫面性质的改变，使得气象因子与土壤温度的关联发生改变[37-38]，这三种模型对特征的识别能力存在不足，尤其是在土壤温度发生较大波动变化时，无法准确地识别其映射关系。而SSA-DELM模型在不同耕作条件下、不同土壤深度处的温度预测中均展示出了很高的精度，能够全面地学习到特征之间的映射关系，捕捉到数据特征，具有很强的抗噪声能力和泛化能力，拟合能力优于其余模型。以上模型测试集拟合值与真实值对比如图7、图8所示。

2.2　预测误差分析

为直观分析模型预测结果的准确性，分别计算模型预测结果 R^2 如图9所示。

对NT0和NTS两种耕作条件下不同土壤深度处温度进行预测，RF 模型预测结果 R^2 分别为0.847和0.535，SSA-RF 模型预测结果 R^2 分别为0.88和0.641，ELM 模型预测结果 R^2 分别为0.706和0.434，SSA-DELM模型预测结果 R^2 分别为0.996和0.998。

在对NT0条件下的土壤温度预测中，对于5 cm和10 cm深度处的土壤温度预测，四种模型均具有较好的预测能力。在20 cm处开始，RF、SSA-RF 和 ELM 模型的预测能力均出现了明显的下降，其中ELM模型的预测能力下降尤为明显。但 SSA-DELM

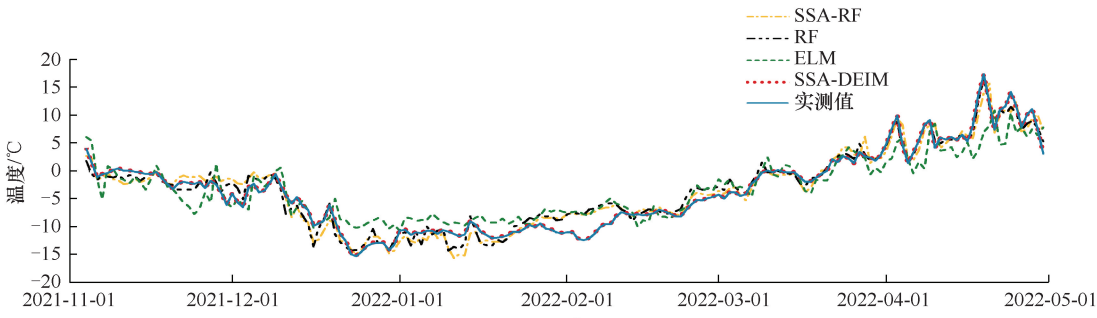

(a) 5 cm

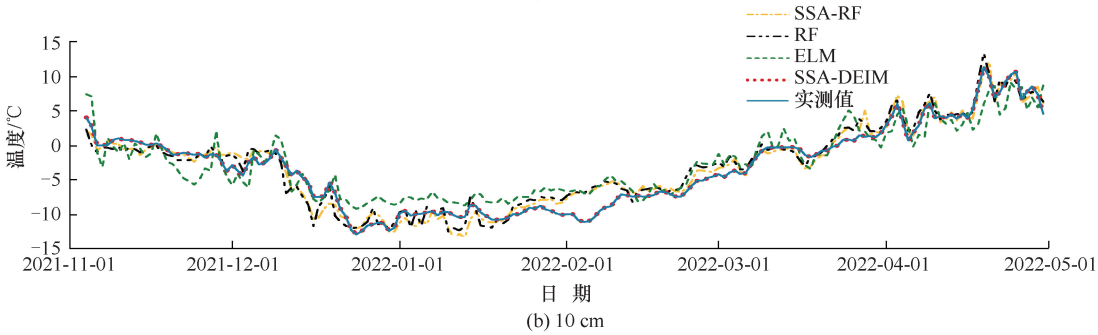

(b) 10 cm

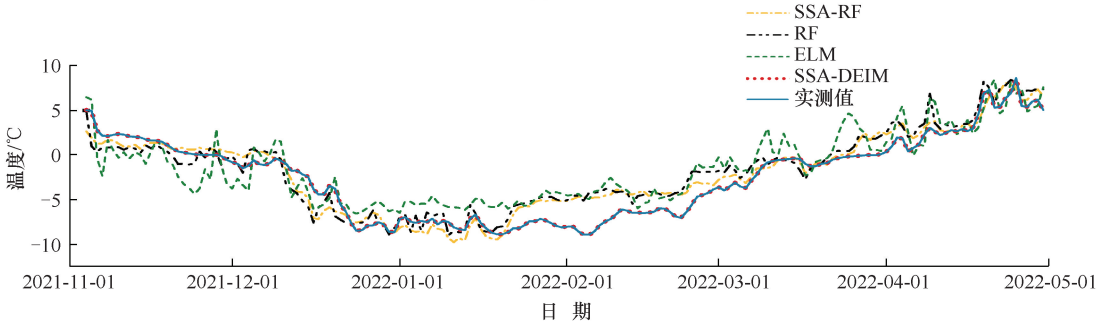

(c) 20 cm

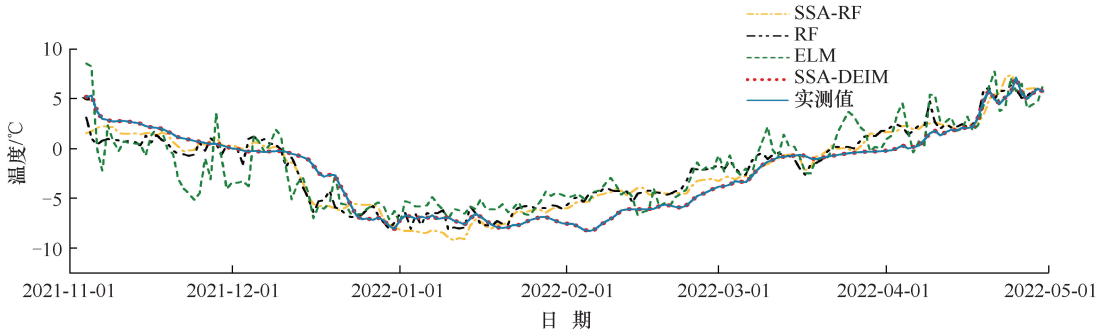

(d) 30 cm

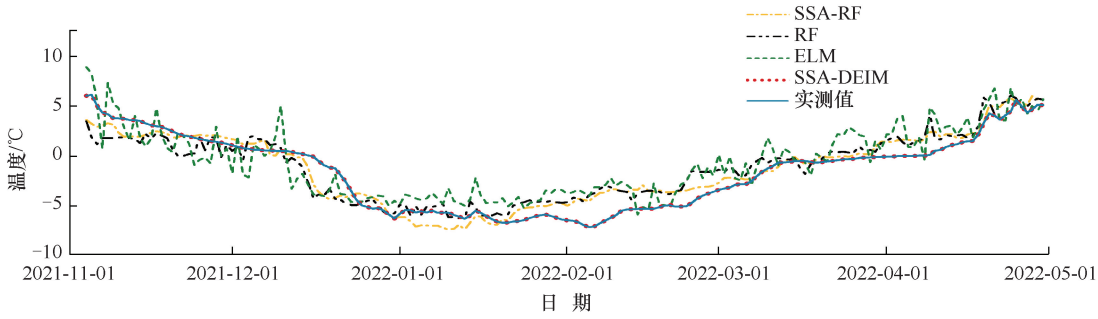

(e) 40 cm

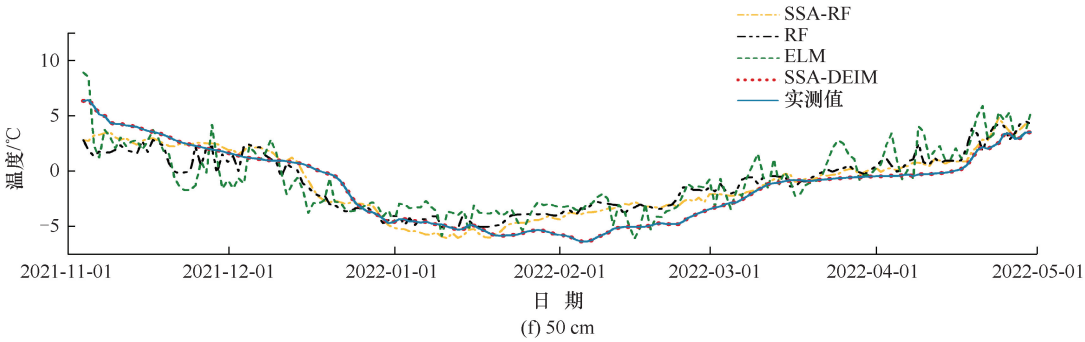

(f) 50 cm

图 7　免耕无秸秆覆盖条件下拟合情况对比

Fig. 7　Comparison of fitting under no-tillage and no straw mulch conditions

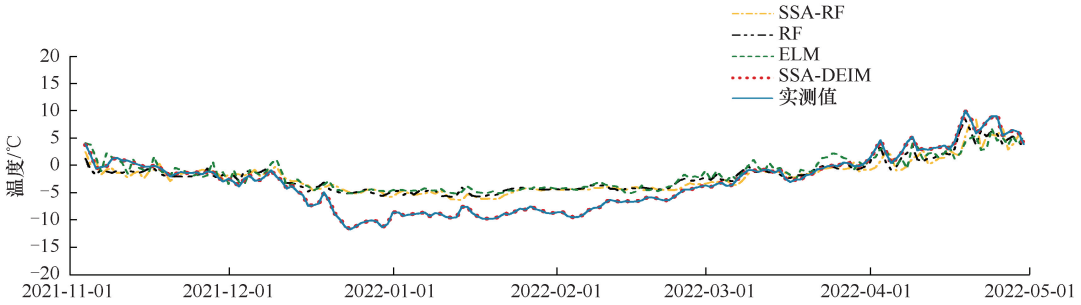

(a) 5 cm

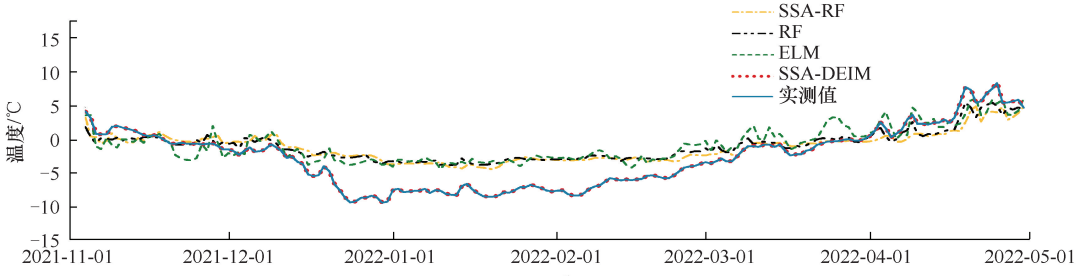

(b) 10 cm

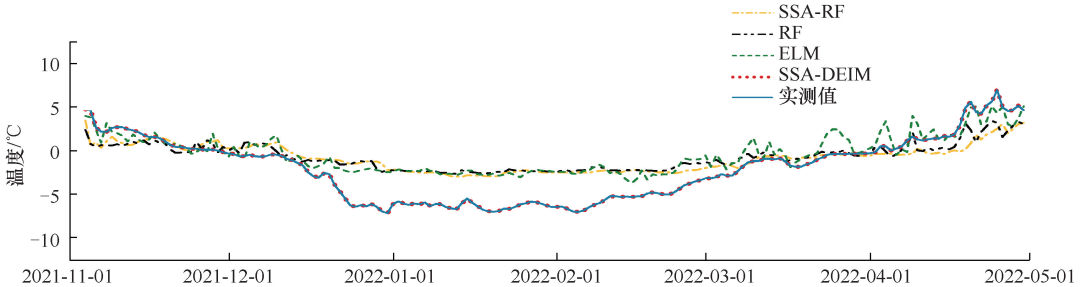

(c) 20 cm

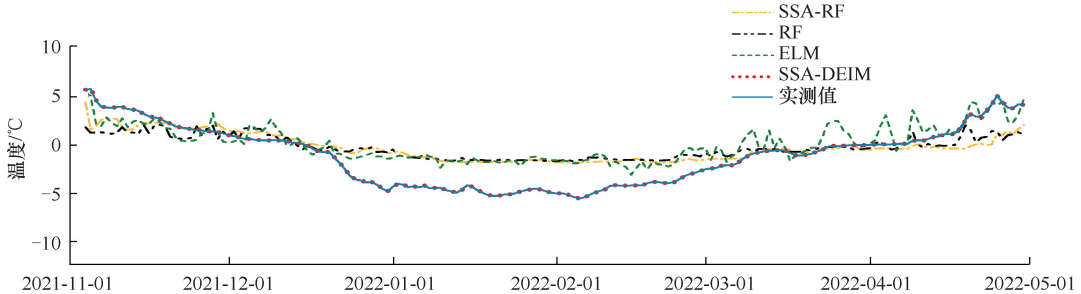

(d) 30 cm

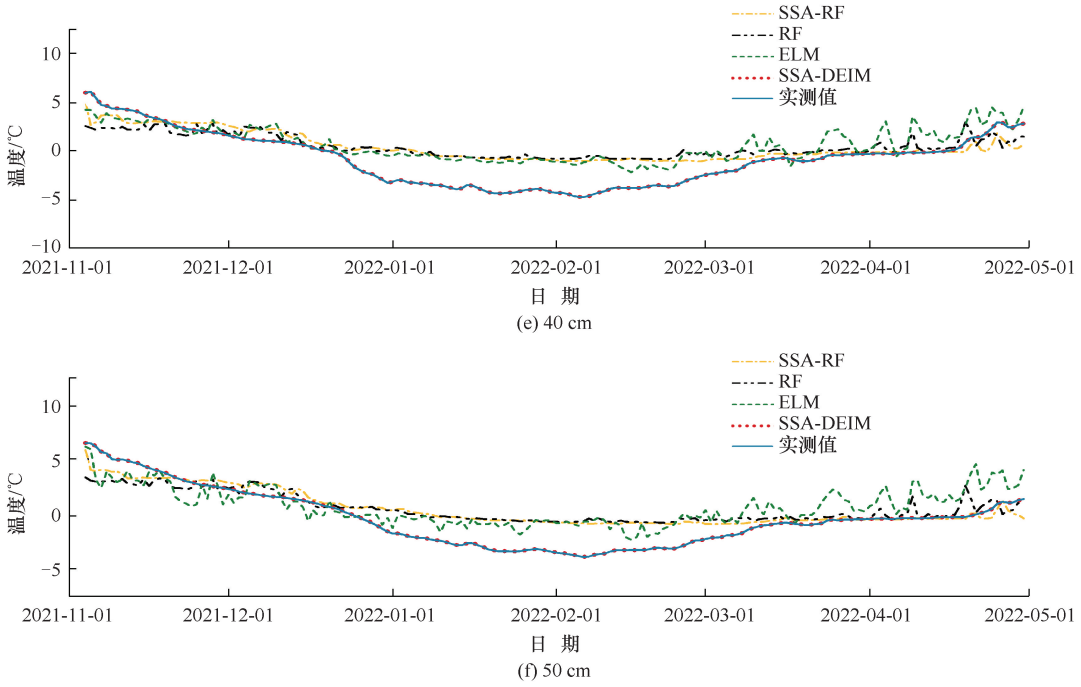

图 8　免耕秸秆全覆盖条件下拟合情况对比

Fig. 8　Comparison of fitting under no-tillage straw full cover condition

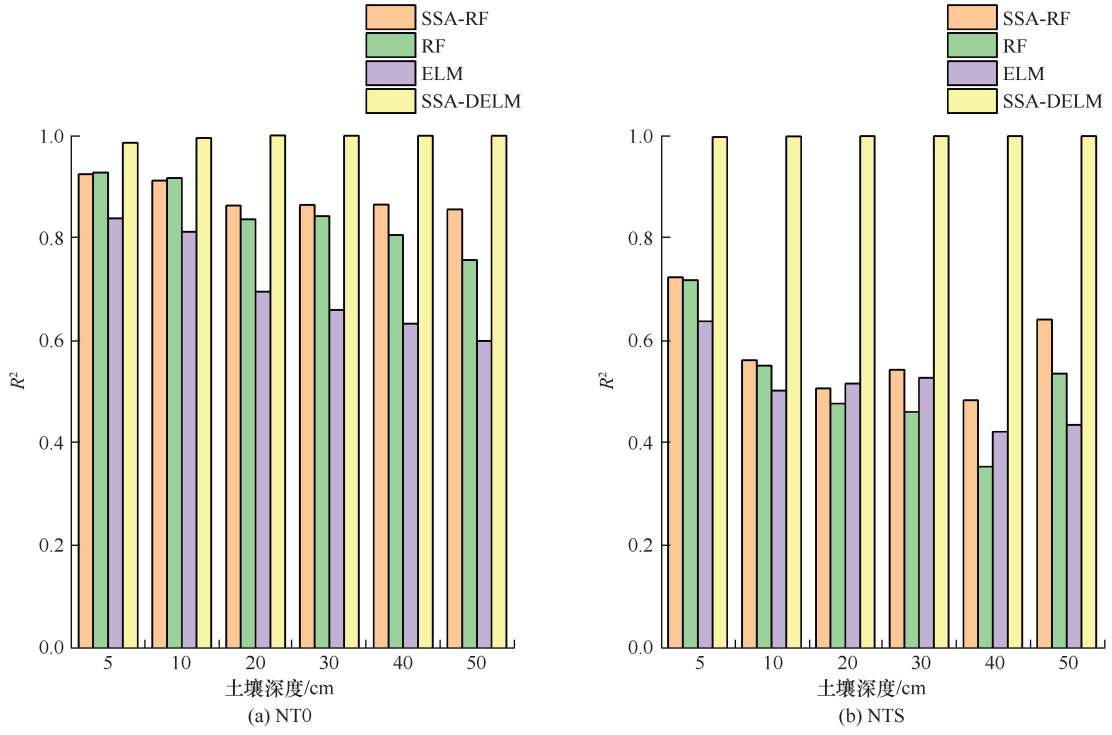

图 9　决定系数 R^2 对比

Fig. 9　Comparison of coefficient of determination R^2

模型在不同深度处均保持较高的预测精度，在 5 cm 和 10 cm 深度处的土壤温度预测结果的 R^2 相较于 RF、SSA-RF 和 ELM 模型分别提高了 7.4%、7.9%和 20.1%，而对 20 cm 及以下深度处的土壤温度预测结果的 R^2 则分别提高了 23.6%、16%和 55.2%；在对 NTS 条件下的土壤温度预测中，RF、SSA-RF 和 ELM 模型的预测能力均出现了明显下降，尤其是在 10 cm 深度处开始，这三个模型预测精度较差，而 SSA-

DELM 模型仍保持着良好的预测能力，显著优于其余三者，预测结果的 R^2 相较于 RF、SSA-RF 和 ELM 模型分别提高了 86.7%、55.9%和 130%。

计算 NT0 和 NTS 两种耕作条件下四种拟合模型预测结果的 *MAE* 和 *RMSE* 值分别如表 1 和表 2 所列。通过表 1 和表 2 结果可以看出，在 NT0 条件下，SSA-RF 和 RF 模型预测结果的 *MAE* 和 *RMSE* 相近，均优于 ELM，其中 SSA-RF 略优于 RF，而 SSA-DELM 模型预测结果的误差相较于其余三者出现了显著降低，与三者中表现最佳的 SSA-RF 模型相比，*MAE* 降低了 87.3%，*RMSE* 降低了 82.1%，相较于改进前的 ELM 模型，*MAE* 和 *RMSE* 分别降低了 92.1%和 88.4%。而在 NTS 条件下，SSA-RF 和 RF 模型的误差出现了明显升高，*MAE* 分别升高了 39.1% 和 49.6%，*RMSE* 分别升高了 38% 和 42.6%，可以发现这两种模型的预测效率很大程度上受耕作方式改变的影响，而 ELM 和 SSA-DELM 模型的 *MAE* 和 *RMSE* 值仅出现了极小的波动，这表明耕作方式的改变对这两种模型的预测能力影响很小。其中 SSA-DELM 模型在耕作方式发生改变的情况下仍具有较好的预测精度，平均 *MAE* 和平均 *RMSE* 仅为 0.1 和 0.16，与其余三者中预测精度最高的 SSA-RF 相比，*MAE* 和 *RMSE* 分别降低了 94.7%和 93.4%，相较于改进前的 ELM，*MAE* 和 *RMSE* 分别降低了 92.6%和 93.8%。

表 1　绝对平均误差 *MAE* 对比

Table 1　Comparison of absolute mean errors *MAE*

耕作方式	土壤深度/cm	SSA-RF	RF	ELM	SSA-DELM
NT0	5	1.57	1.53	2.36	0.47
	10	1.41	1.39	2.21	0.26
	20	1.37	1.50	2.19	0.07
	30	1.24	1.35	2.07	0.07
	40	1.13	1.36	1.94	0.07
	50	1.04	1.35	1.79	0.06
NTS	5	2.22	2.22	2.56	0.19
	10	2.389	2.39	2.66	0.13
	20	2.09	2.15	2.07	0.08
	30	1.66	1.82	1.74	0.07
	40	1.61	1.81	1.77	0.06
	50	1.24	1.43	1.71	0.06

NRMSE、*RRMSE*、*NSE* 和 *PI* 的对比结果如图 10—图 13 所示，其中越小的 *NRMSE* 和 *RRMSE* 值表示模型的预测误差越小；*NSE* 的取值范围是从 1 到负无穷，其值越接近 1，表示模型具有更高的可信程度，而其接近 0 则表示总体结果具有一定的可信

表 2　均方根误差 *RMSE* 对比

Table 2　Root Mean Square Error *RMSE* Comparison

耕作方式	土壤深度/cm	SSA-RF	RF	ELM	SSA-DELM
NT0	5	2.07	2.03	3.24	0.92
	10	1.81	1.76	2.64	0.43
	20	1.70	1.85	2.52	0.10
	30	1.56	1.66	2.42	0.10
	40	1.40	1.66	2.28	0.11
	50	1.30	1.66	2.14	0.10
NTS	5	2.77	2.78	3.16	0.31
	10	2.98	3.00	3.16	0.19
	20	2.58	2.64	2.53	0.14
	30	2.10	2.24	2.10	0.11
	40	2.02	2.21	2.09	0.09
	50	1.60	1.77	1.96	0.10

程度，但是具有较大的过程误差，其值一旦低于 0 则表示模型预测结果不可信；*PI* 作为性能指数，较低的 *PI* 值代表着更好的预测性能，反之代表模型预测性能较差。分析 *NRMSE* 和 *RRMSE* 的计算结果，能够发现 SSA-DELM 模型的土壤温度预测误差很低，在 NT0 条件下，SSA-DELM 模型在 5 cm 深度处 *NRMSE* 和 *RRMSE* 的值分别为 0.03 和 0.26，相较于其余三个模型，比 *NRMSE* 值最低的 SSA-RF 模型降低了 55.6%，*RRMSE* 值最低的 RF 模型降低了 54.7%，随着深度的增加，除 SSA-DELM 模型以外的三个模型预测误差均出现了不同程度的增长，在 50 cm 深度处，对比三者中 *NRMSE* 和 *RRMSE* 值最低的 SSA-RF 模型，SSA-DELM 模型的预测误差值则分别降低了 92.1%和 92.3%；而当耕作条件改为 NTS 时，除 SSA-DELM 模型以外三者预测误差均出现了明显的变化，其中预测性能最好的 SSA-RF 模型，其 *NRMSE* 和 *RRMSE* 不同深度处平均值分别由 0.09 和 0.73 增长为 0.17 和 1.86，但对应的，SSA-DELM 模型的 *NRMSE* 和 *RRMSE* 不同深度处平均值则分别保持在 0.01 和 0.1。在对 *NSE* 值的分析中，在 NT0 条件下，所使用的模型 *NSE* 值均大于 0.6，证明预测结果具有较高的可信程度，并且过程误差在可接受范围内，其中 SSA-DELM 模型的 *NSE* 值均大于 0.99，证明不仅其总体结果具有很高的可信度，并且过程误差也很小；在 NTS 条件下，SSA-DELM 模型的 *NSE* 值仍保持在 0.99 以上，但以外的三个模型的 *NSE* 值均产生了较大变化，在 10 cm 深度处开始均小于 0.6，即总体结果具有一定的可信程度，但是过程误差较大。SSA-DELM 的 *PI* 值在两种耕作条件下不同深度处均低于 0.2，对比其他模型，NT0 条件下预测性能差距较小，在从 5 cm 深度处到 50 cm 深度处的过

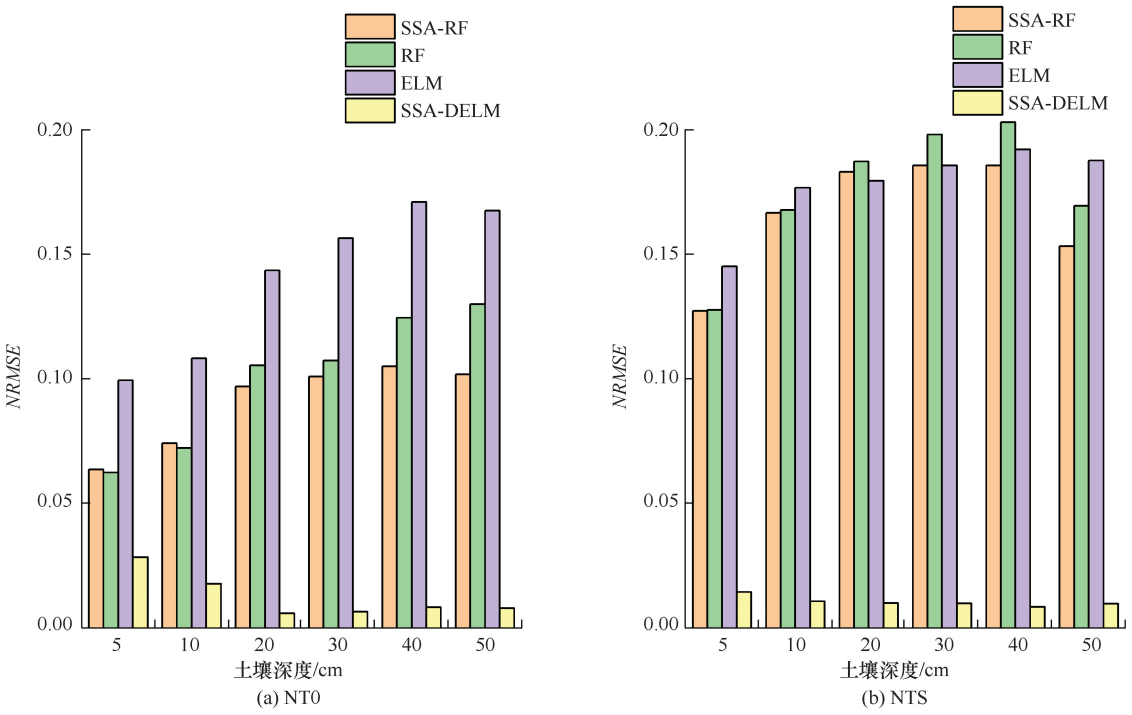

图 10　归一化均方根误差 *NRMSE* 对比

Fig. 10　Comparison of Normalized Root Mean Square Error *NRMSE*

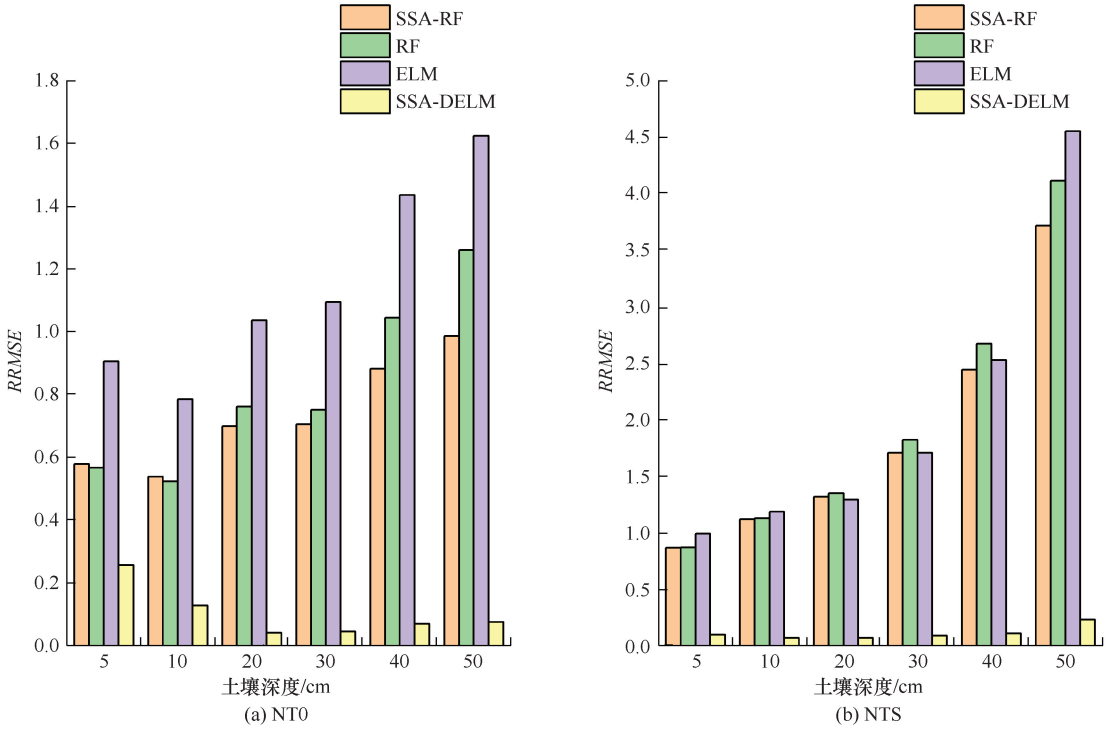

图 11　相对均方根误差 *RRMSE* 对比

Fig. 11　Comparison of Relative Root Mean Square Error *RRMSE*

程中，*PI* 相差最小值由 0.16 增长为 0.67，而在 NTS 条件下预测性能差距增大，从 5 cm 深度处到 50 cm 深度处的过程中，*PI* 相差最小值由 0.42 增长为 1.95。构建的 SSA-DELM 模型误差值远低于其他模型，并且随着耕作方式和土壤深度的改变，仍保持很低的预测误差和较好的预测性能。

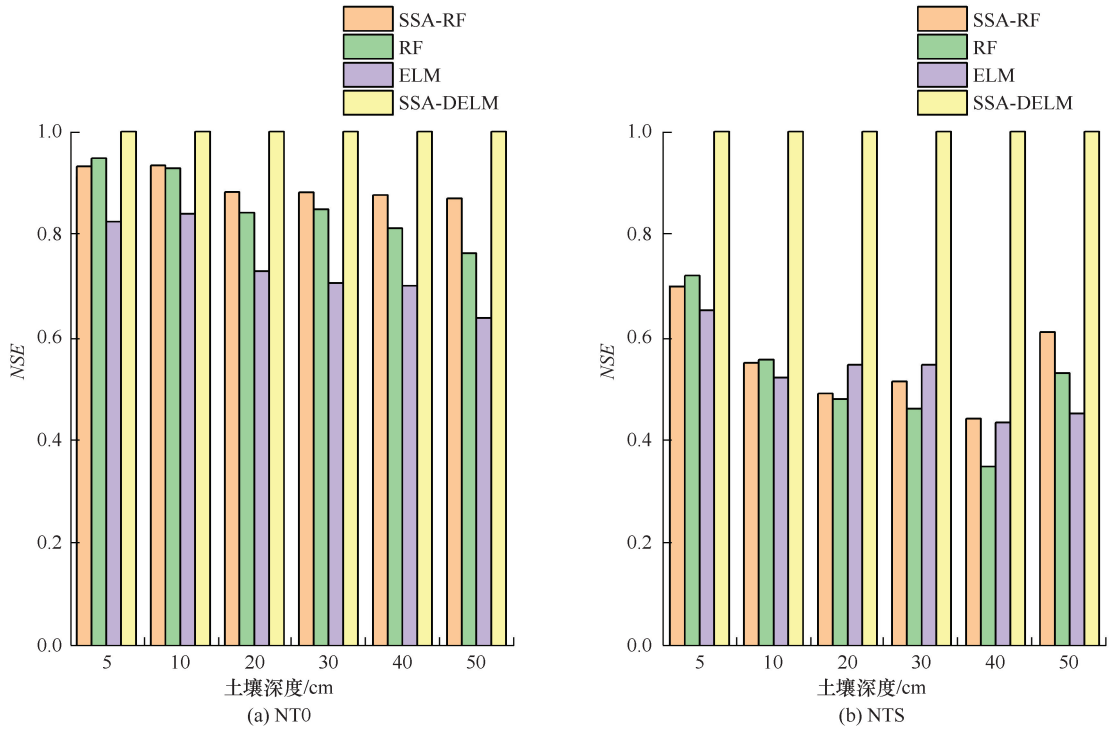

图 12　纳什效率系数 *NSE* 对比

Fig. 12　Comparison of Nash Efficiency Coefficients *NSE*

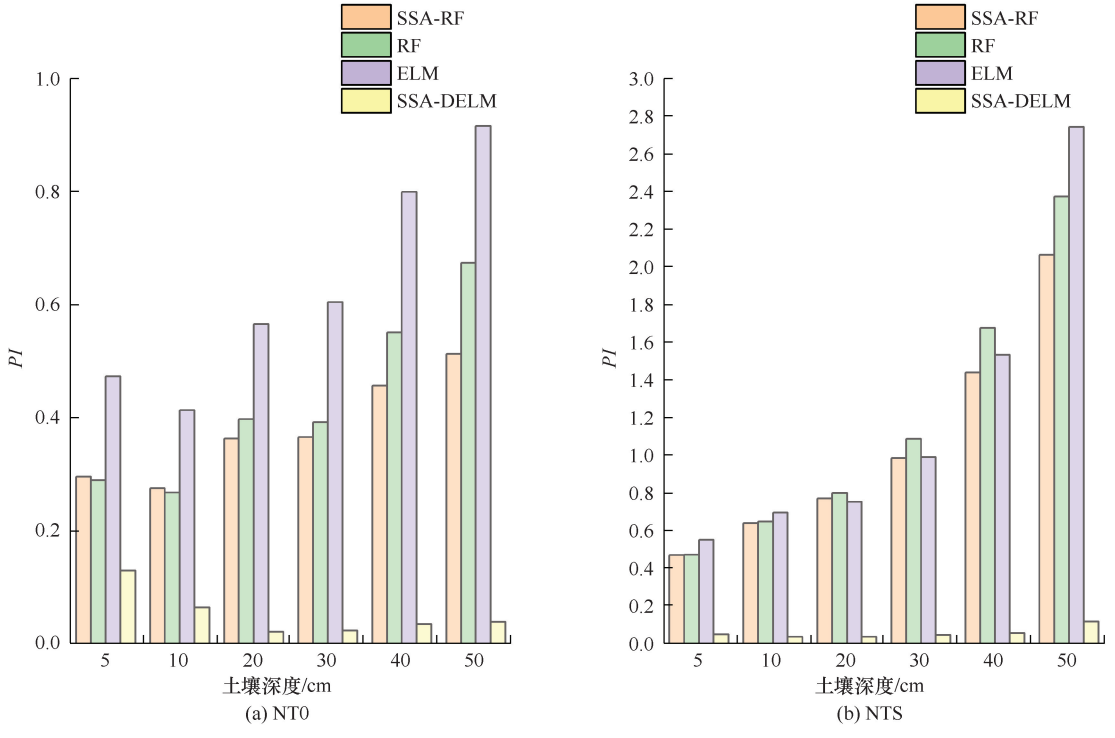

图 13　性能指数 *PI* 对比

Fig. 13　Comparison of Performance Index *PI*

表 3 中为 Max$E$ 的计算结果，通过表 3 能够发现，SSA-DELM 模型预测过程中出现的最大残差远低于其他模型，这意味着其预测结果中没有出现误差很大的异常值，也证明了其具有更加稳定和准确的预测能力。

为更好地观察预测值与真实值之间的匹配程

表 3　最大残差 Max$E$ 对比

Table 3　Comparison of Maximum Residual Max$E$

耕作方式	土壤深度/cm	SSA-RF	RF	ELM	SSA-DELM
NT0	5	4.33	3.74	10.31	0.21
	10	3.40	4.18	5.39	0.10
	20	3.27	3.98	4.56	0.07
	30	3.88	4.71	5.95	0.02
	40	3.23	4.25	3.81	0.02
	50	3.65	4.51	4.26	0.02
NTS	5	5.50	3.25	5.68	0.16
	10	5.26	3.40	3.95	0.13
	20	4.75	3.83	2.62	0.08
	30	4.18	4.53	2.39	0.04
	40	3.44	3.72	1.90	0.03
	50	2.42	3.43	3.30	0.03

度，比较模型预测精度，在图 14、图 15 中分别绘制了两种耕作方式下的预测泰勒图。通过泰勒图可以直观看到 SSA-DELM 模型的预测能力优于其他模型，预测值与真实值间匹配程度很高，在两种耕作条件下均具有良好的适用性。

在实际应用中，除了模型的预测精度以外，预测模型运行的时间也是一个重要的参考指标，通常希望能够在较短的时间里完成预测目标。因此，在拟合预测过程中记录模型平均运行时间如表 4 所列。从中可见改进前的 ELM 和 RF 模型运行所需时间较少，而改进后的 SSA-RF 和 SSA-DELM 模型的运行时间都有所增加，这主要是由于麻雀搜索算法的迭代过程耗时较长，因此延长了模型的训练时间。其中 SSA-DELM 模型的运行时间虽然有所增加，但增加幅度较小，依然具有较快的预测速度。

3　结果讨论

通过以上分析表明，构建 SSA-DELM 模型在不同耕作方式土壤温度预测中具有良好的表现。朱成杰等[39]利用高光谱数据对土壤温度进行预测，该模型的回归系数为 0.963，构建改进 SVR 模型的高光谱数据来源于无植被覆盖的裸露土壤，没有考虑种植农作物或进行秸秆覆盖的情况，并且其预测深度仅为 2 cm，尽管该模型精度接近于本研究中模型的精度，但该模型在农业实际应用中适用性较差。汪靖阳等[40]在河北省石家庄市进行了土壤温度时间序列预测，虽然 LSTM 神经网络模型精度与本研究所开发模型精度相近，但该模型在对时均土壤温度预测中，时间跨度仅为 15 d，远小于本试验的 178 d，较短的时间跨度所覆盖的天气类型较少，未能考虑到霜降、降雪等天气状况，天气类型较单一，虽然模型的精度较高，但并不具有代表性。本研究中所采用的时间跨度能够覆盖多数常见的天气情况，并且包含了土壤温度变化趋势发生改变的时期，相比之下适用范围更广。WANG 等[41]开发了一种嵌入式土壤温度预测模型，对瑞士两个站点的土壤温度进行了预测，并且与其他四种机器学习模型进行了比较，取得了较好的预测精度，但是该模型的输入数据只有土壤温度数据，对土壤温度的预测依赖于时间序列，未考虑到气象因素对土壤温度的影响，且预测时间最长仅为 24 h，其实用性有待进一步发展。FARHANGMEHR 等[42]采用一维 CNN 模型尝试了利用气象因子预测土壤温度，该模型分析正常和炎热天气条件下的预测性能，但该模型所探究的最大土层深度仅为 7 cm，远小于本研究中的最大深度 50 cm，不能实现对耕作层土壤温度的充分监测，无法满足农业实际需要。ALIZAMIR 等[43]开展了通过四种不同模型预测土壤温度的研究，其中 ELM 模型取得了最佳的预测效果，在对浅层土壤温度的预测中，仅使用空气温度作为输入就取得了较好的效果，但在对深层土壤温度预测时需要引入辐射等气象因子信息以获得较好的预测精度，受限于独立 ELM 模型结构的局限性以及输入特征的选取，相较于本研究的 SSA-DELM 模型，预测精度较差，且未能考虑到保护性耕作条件下秸秆覆盖对土壤温度变化特征的影响，无法适用于此类地区。同时，本文所构建的模型仍存在不足，在模型构建过程中没有引入地理位置信息，不能避免不同地区气候特征差异的影响，在后续的研究中应尝试将地理位置信息引入到模型的构建过程中。

4　结　论

本文为实现对不同耕作条件下土壤温度的精准预测，构建了混合模型 SSA-DELM，得到如下重要结论。

(1)分别对免耕无秸秆覆盖(NT0)和免耕秸秆全

表 4　模型运行时间对比

Table 4　Comparison of model run times

项　目	SSA-RF		RF		ELM		SSA-DELM	
耕作方式	NT0	NTS	NT0	NTS	NT0	NTS	NT0	NTS
平均运行时间/s	963.7	1 057.4	6.3	6.6	13.9	14.4	17.2	17.6

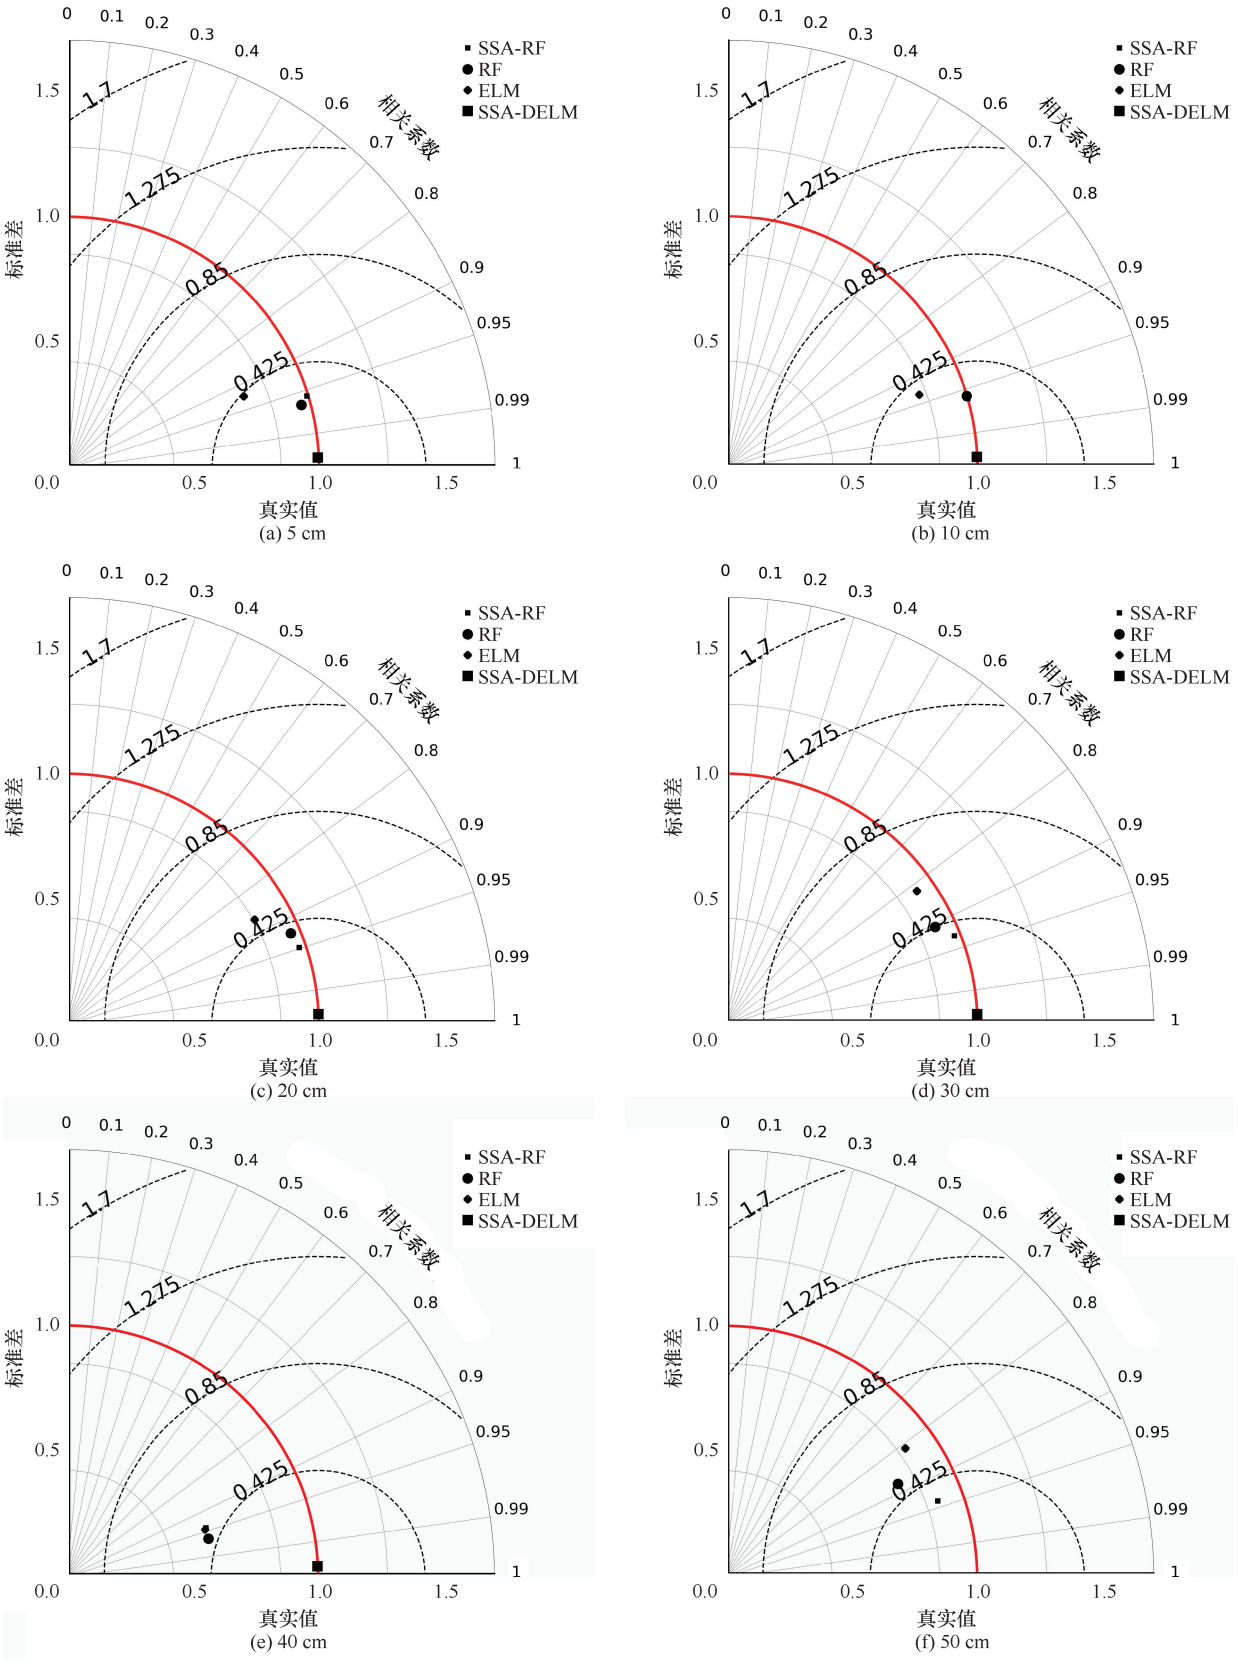

图 14　免耕无秸秆覆盖条件下泰勒图

Fig. 14　Taylor's map under no-tillage and no straw mulch conditions

覆盖(NTS)两种耕作条件下 5 cm、10 cm、20 cm、30 cm、40 cm 和 50 cm 六个深度处土壤温度进行预

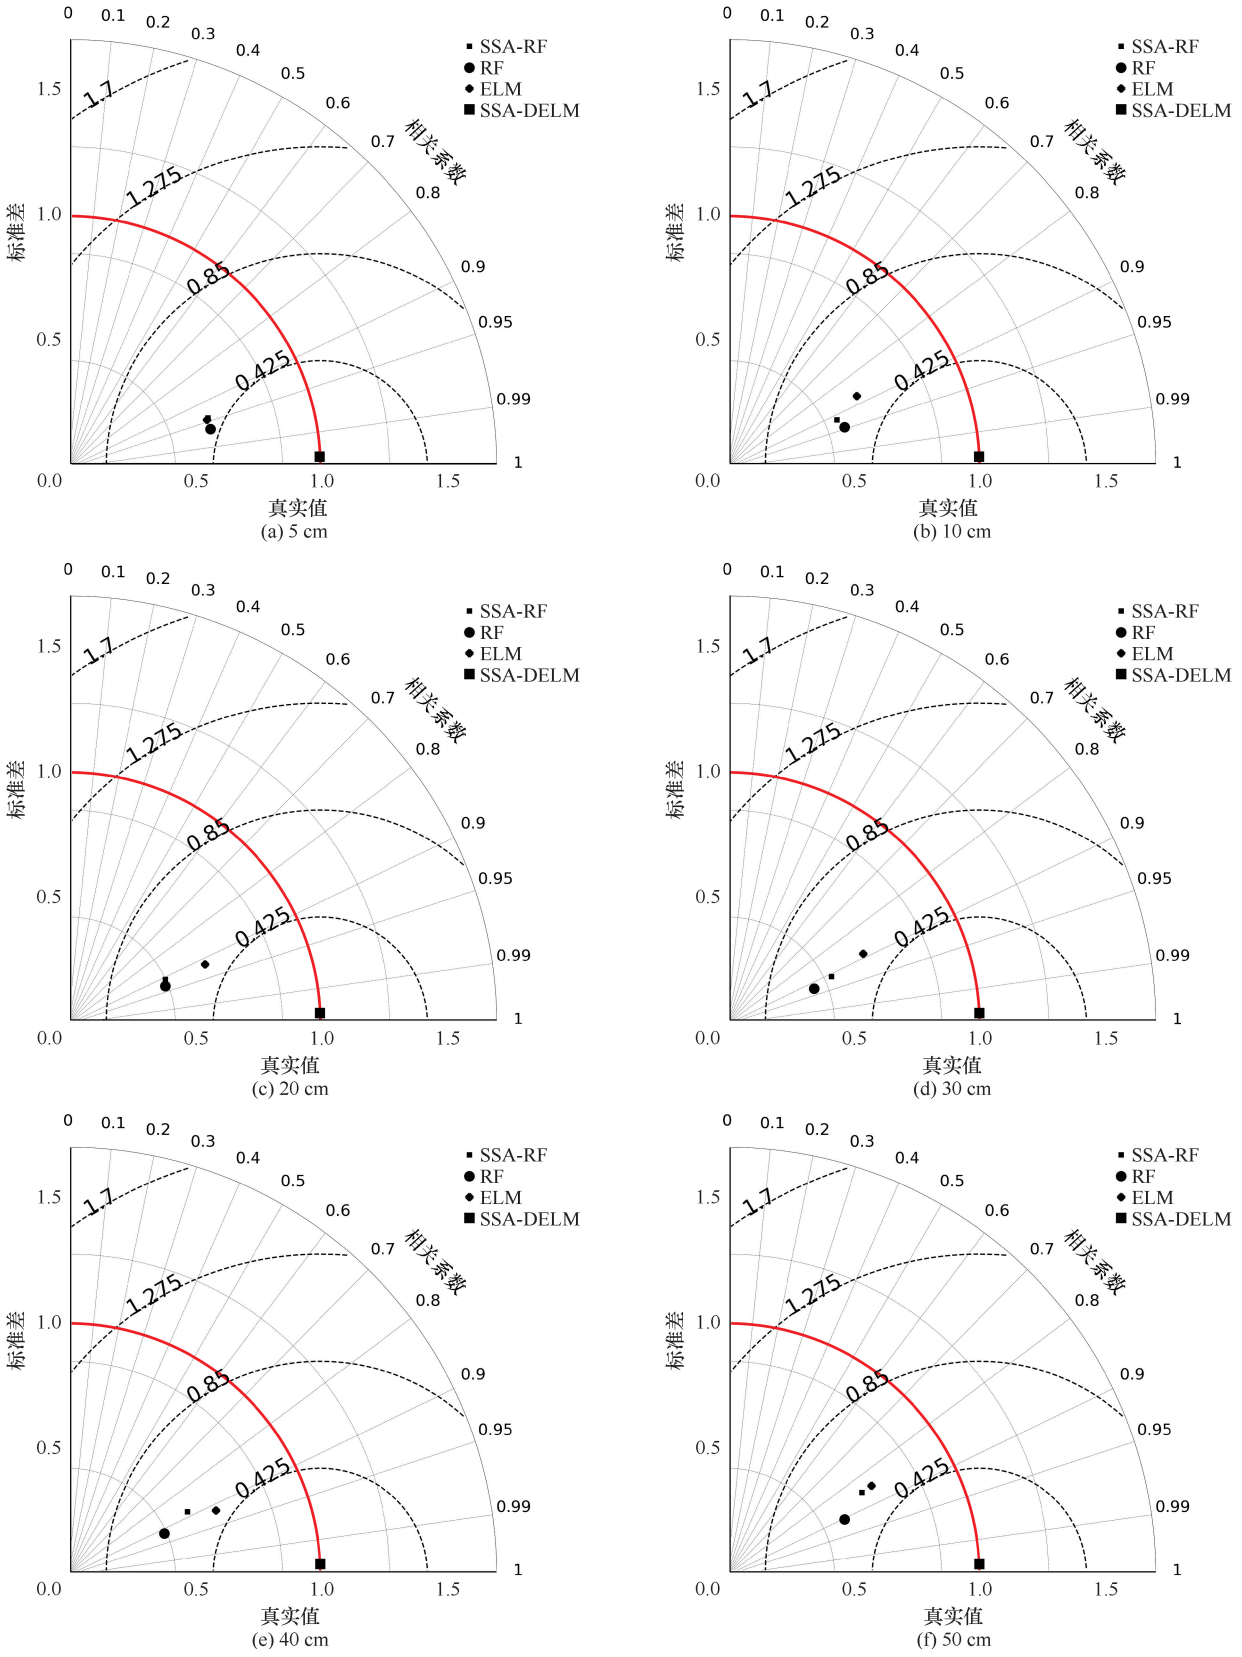

图 15　免耕秸秆全覆盖条件下泰勒图

Fig. 15　Taylor diagram under no-tillage straw full cover conditions

测，分析了其预测误差。混合模型 SSA-DELM 具有良好的准确性和稳定性，在对免耕无秸秆覆盖和免耕

秸秆全覆盖两种保护性耕作条件下的土壤温度预测中均表现出了很好的性能，具有良好的预测精度和较高的预测效率。

(2)对比独立的极限训练机(ELM)和随机森林(RF)模型以及利用SSA改进的SSA-RF混合模型发现，SSA-DELM模型对不同时期、不同耕作方式下以及不同土壤深度处的温度预测误差显著低于另外三者，具有良好的泛化能力。

(3)在未进行数据噪声处理的情况下，模型具有很强的抗噪声能力和适应性，预测误差较低，能够满足实际需求，为缺乏实测条件地区的保护性耕作农田土壤温度预测提供了新的途径，为东北黑土区农业生产决策提供一定的数据支持。

参考文献(References)：

[1] 马守义，谢丽华，朱广石. 黑土地保护性耕作技术的思考[J]. 玉米科学，2018，26(1)：116-119.
MA Shouyi，XIE Lihua，ZHU Guangshi. Reflections on conservation tillage technology in black soil[J]. Corn Science，2018，26(1)：116-119.

[2] 梁爱珍，张延，陈学文，等. 东北黑土区保护性耕作的发展现状与成效研究[J]. 地理科学，2022，42(8)：1325-1335.
LIANG Aizhen，ZHANG Yan，CHEN Xuewen，et al. Study on the development status and effectiveness of conservation tillage in the Northeast Black Soil Region[J]. Geoscience，2022，42(8)：1325-1335.

[3] 刘继龙，王志卓，曹晓强，等. 黑土区坡耕地土壤侵蚀及水分利用效率对不同覆盖耕作模式的响应[J]. 排灌机械工程学报，2024，42(8)：826-834.
LIU Jilong，WANG Zhizhuo，CAO Xiaoqiang，et al. Responses of soil erosion and water use efficiency of sloping farmland in black soil region to different mulch tillage modes[J]. Journal of drainage and irrigation machinery engineering(JDIME)，2024，42(8)：826-834.

[4] 何家帅，李新美，魏跃鹏，等. 长期深耕秸秆还田配施生物炭对砂姜黑土团聚体及小麦-玉米产量的影响[J]. 农业工程学报，2024，40(7)：161-171.
HE Jiashuai，LI Xinmei，WEI Yuepeng，et al. Effects of long-term deep plowing and straw return with biochar application on sand-ginger black soil aggregates and wheat-corn yield[J]. Journal of Agricultural Engineering，2024，40(7)：161-171.

[5] 王子龙，滕怀溟，姜秋香，等. 雪被去除对东北农田黑土水溶性盐分含量的影响[J]. 南水北调与水利科技(中英文)，2024，22(4)：697-707.
WANG Z L，TENG H H，JIANG Q X，et al. Effects of snow removal on water-soluble salt content of farmland black soil in Northeast China[J]. South-to-North Water Transfers and Water Science & Technology，2024，22(4)：697-707.

[6] 刘继龙，陈俊丰，曹晓强，等. 黑土区玉米生理生长特性及产量对不同秸秆覆盖与施肥量的响应[J]. 排灌机械工程学报，2024，42(6)：627-632.
LIU Jilong，CHEN Junfeng，CAO Xiaoqiang，et al. Physiological growth characteristics and yield of maize in black soil areas in response to different straw mulches and fertilizer application rates[J]. Journal of drainage and irrigation machinery engineering(JDIME)，2024，42(6)：627-632.

[7] 冯秀藻，陶炳炎. 农业气象学原理[M]. 北京：气象出版社，1991.
FENG Xiuzao，TAO Bingyan. Principles of Agricultural Meteorology[M]. Beijing：Meteorological Press，1991.

[8] 段若溪，姜会飞. 农业气象学(修订版)[M]. 北京：气象出版社，2013.
DUAN Ruoxi，JIANG Huifei. Agricultural Meteorology(Revised Edition)[M]. Beijing：Meteorological Press，2013.

[9] DAVIDSON E A，JANSSENS I A. Temperature sensitivity of soil carbon decomposition and feedbacks to climate change[J]. Nature，2006，440：165-173.

[10] 王敏，王海霞，韩清芳，等. 不同材料覆盖的土壤水温效应及对玉米生长的影响[J]. 作物学报，2011，37(7)：1249-1258.
WANG Min，WANG Haixia，HAN Qingfang，et al. Soil water temperature effects of mulching with different materials and their influence on corn growth[J]. Journal of Crops，2011，37(7)：1249-1258.

[11] 冯浩，刘匣，余坤，等. 不同覆盖方式对土壤水热与夏玉米生长的影响[J]. 农业机械学报，2016，47(12)：192-202.
FENG Hao，LIU Xia，YU Kun，et al. Effects of different mulching methods on soil hydrothermal and summer corn growth[J]. Journal of Agricultural Machinery，2016，47(12)：192-202.

[12] 齐智娟，宋芳，张忠学，等. 保护性耕作对寒地黑土土壤水热效应与玉米产量的影响[J]. 农业机械学报，2022，53(12)：380-389.
QI Zhijuan，SONG Fang，ZHANG Zhongxue，et al. Effects of conservation tillage on soil hydrothermal effect and corn yield in cold black soil[J]. Journal of Agricultural Machinery，2022，53(12)：380-389.

[13] 王娜，王璐，宋昌海，等. 秸秆还田对不同地区土壤温度的影响研究现状分析[J]. 农业科学研究，2023，44(4)：21-25.
WANG Na，WANG Lu，SONG Changhai，et al. Analysis of the current research on the effect of straw return on soil temperature in different regions[J]. Agricultural Science Research，2023，44(4)：21-25.

[14] 赵强，吴从林，罗平安，等. 冻融期东北农田土壤温度和水分变化规律及影响因素分析[J]. 冰川冻土，2020，42(3)：986-995.

ZHAO Qiang, WU Conglin, LU Pingan, et al. Analysis of the change rules and influencing factors of soil temperature and moisture in farmland in Northeast China during freezing and thawing period[J]. Glacial Permafrost, 2020, 42(3): 986-995.

[15] ALIZAMIR M, KISI O, AHMED A N, et al. Advanced machinelearning model for better prediction accuracy of soil temperatureat different depths[J]. PLOS ONE, 2020, 15(4): e0231055.

[16] 李沙，刘冬梅，孙辉. 西南亚高山森林土壤表层温度变化特征及拟合模型[J]. 西北林学院学报，2013，28(3)：34-39.
LI Sha, LIU Dongmei, SUN Hui. Characteristics of soil surface temperature change and fitting model in alpine forests of Southwest Asia[J]. Journal of Northwest Forestry College, 2013, 28(3): 34-39.

[17] 耿庆田，赵杨，李清亮，等. 基于注意力机制的 LSTM 和 ARIMA 集成方法在土壤温度中应用[J]. 吉林大学学报(工学版)，2023，53(10)：2973-2981.
GENG Q T, ZHAO Y, LI Q L, et al. An integrated method of LSTM and ARIMA based on attention mechanism in soil temperature[J]. Journal of Jilin University(Engineering Edition), 2023, 53(10): 2973-2981.

[18] PENGHUI L, EWEES A A, BEVAZTAS B H, et al. Metaheuristic optimization algorithms hybridized with artificial intelligence model for soil temperature prediction: Novel model[J]. IEEE Access, 2020, 8: 51884-51904.

[19] 李清亮，蔡凯旋，耿庆田，等. 极限梯度提升和长短期记忆网络相融合的土壤温度预测[J]. 光学精密工程，2020(10)：028.
LI Qingliang, CAI Kaixuan, GENG Qingtian, et al. Soil temperature prediction by fusion of extreme gradient boosting and long and short-term memory networks[J]. Optical Precision Engineering, 2020(10): 028.

[20] 吐尔逊·买买提,赵梦佳，宁成博，等. 基于深度极限学习机的柴油机尾气排放预测[J]. 科学技术与工程，2021，21(36)：15646-15654.
TURSUN Baimaiti, ZHAO Mengjia, NING Chengbo, et al. Diesel exhaust emission prediction based on deep limit learning machine[J]. Science, Technology and Engineering, 2021, 21(36): 15646-15654.

[21] 王鑫，吴际，刘超，等. 基于 LSTM 循环神经网络的故障时间序列预测[J]. 北京航空航天大学学报，2018，44(4)：772-784.
WANG Xin, WU Ji, LIU Chao, et al. Fault time series prediction based on LSTM recurrent neural network[J]. Journal of Beijing University of Aeronautics and Astronautics, 2018, 44(4): 772-784.

[22] 王增平，赵兵，纪维佳，等. 基于 GRU-NN 模型的短期负荷预测方法[J]. 电力系统自动化，2019，43(5)：53-58.
WANG Zengping, ZHAO Bing, JI Weijia, et al. Short-term load forecasting method based on GRU-NN model[J]. Power System Automation, 2019, 43(5): 53-58.

[23] GAO L Y, WU W G. Relevance assignation feature selection method based on mutual information for machine learning[J]. Knowledge-Based Systems, 2020, 209: 106439.

[24] DONG Y X, XIAO L. Enhancing wind power generation prediction using relevance assessment-based transfer learning[J]. Knowledge-Based Systems, 2024, 303: 112417.

[25] THAKKAR A, LOHIVA R. Fusion of statistical importance for feature selection in Deep Neural Network-based Intrusion Detection System[J]. Information Fusion, 2023, 90: 353-363.

[26] JIANG J F, ZHANG X Y, YUAN Z. Feature selection for classification with Spearman's rank correlation coefficient-based self-information in divergence-based fuzzy rough sets[J]. Expert Systems with Applications, 2024, 249: 123633.

[27] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006, 70(1-3): 489-501.

[28] 王俊，席芳，周川，等. 基于 BES-ELM 的风电机组故障诊断[J]. 排灌机械工程学报，2023，41(10)：1023-1029.
WANG Jun, XI Fang, ZHOU Chuan, et al. Wind turbine fault diagnostic model based on BES-ELM[J]. Journal of Drainage and Irrigation Machinery Engineering, 2023, 41(10): 1023-1029.

[29] 徐睿，梁循，齐金山，等. 极限学习机前沿进展与趋势[J]. 计算机学报，2019，42(7)：1640-1670.
XU Rui, LIANG Xun, QI Jinshan, et al. Frontier advances and trends in extreme learning machines[J]. Journal of Computing, 2019, 42(7): 1640-1670.

[30] 马萌萌. 基于深度学习的极限学习机算法研究[D]. 青岛：中国海洋大学，2016.
MA Mengmeng. Research on Extreme Learning Machine Algorithm Based on Deep Learning[D]. Qingdao: Ocean University of China, 2016.

[31] 冯禹，崔宁博，龚道枝，等. 基于极限学习机的参考作物蒸散量预测模型[J]. 农业工程学报，2015，31(S1)：153-160.
FENG Yu, CUI Ningbo, GONG Daozhi, et al. Reference crop evapotranspiration prediction model based on extreme learning machine[J]. Journal of Agricultural Engineering, 2015, 31(S1): 153-160.

[32] XUE J K, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems ence & Control Engineering An Open Access Journal, 2020, 8(1): 22-34.

[33] 马晨佩，李明辉，巩强令，等. 基于麻雀搜索算法优化支持向量机的滚动轴承故障诊断[J]. 科学技术与工程，2021，21(10)：4025-4029.
MA Chenpei, LI Minghui, KONG Qiangling, et al. Optimized

support vector machine based on sparrow search algorithm for rolling bearing fault diagnosis[J]. Science, Technology and Engineering, 2021, 21(10): 4025-4029.

[34] 陈颖，刘峥莹，肖春艳，等. 基于麻雀搜索算法的土壤重金属X射线荧光光谱重叠峰解析[J]. 光谱学与光谱分析，2021，41(7)：2175-2180.
CHEN Ying, LIU Zhenying, XIAO Chunyan, et al. Analysis of overlapping peaks in X-ray fluorescence spectra of soil heavy metals based on sparrow search algorithm[J]. Spectroscopy and Spectral Analysis, 2021, 41(7): 2175-2180.

[35] 杨康，李蓝青，李艺丰，等. 一种新型分布式光伏出力区间预测方法[J]. 发电技术，2024，45(4)：684-695.
YANG K, LI L Q, LI F Y, et al. A novel distributed photovoltaic output interval prediction method[J]. Power Generation Technology, 2024, 45(4): 684-695.

[36] GHIMIRE S, NGUYEN-HUY T, AL-MUSAYLH M S, et al. A novel approach based on integration of convolutional neural networks and echo state network for daily electricity demand prediction[J]. Energy, 2023, 275: 127430.

[37] DU C, LI L L, EFFAH Z. Effects of straw mulching and reduced tillage on crop production and environment: A review[J]. Water, 2022, 14(16): 2471.

[38] MING J, ZHAO Y G, WU Q B, et al. Soil temperature dynamics and freezing processes for biocrustal soils in frozen soil regions on the Qinghai-tibet plateau[J]. Geoderma, 2022, 409: 115655.

[39] 朱成杰，汪正权. 基于SPA-GA-SVR模型的土壤水分及温度预测[J]. 中国农村水利水电，2024(1)：30-36.
ZHU Chengjie, WANG Zhengquan. Soil moisture and temperature prediction based on SPA-GA-SVR model[J]. China Rural Water Conservancy and Hydropower, 2024(1): 30-36.

[40] 汪靖阳，郄志红，吴天齐，等. 土壤温度时间序列预测的LSTM神经网络研究[J]. 河北农业大学学报，2021，44(5)：119-125.
WANG Jingyang, QIE Zhihong, WU Tianqi, et al. Research on LSTM neural network for soil temperature time series prediction[J]. Journal of Hebei Agricultural University, 2021, 44(5): 119-125.

[41] WANG X Z, LI W H, LI Q L. A new embedded estimation model for soil temperature prediction[J]. Scientific Programming, 2021, 2021(1): 5881018.

[42] FARHANGMEHR V, COBO J H, MOHAMMADIAN A, et al. A convolutional neural network model for soil temperature prediction under ordinary and hot weather conditions: Comparison with a multilayer perceptron model[J]. Sustainability, 2023, 15(10): 7897.

[43] ALIZAMIR M, KISI O, AHMED A N, et al. Advanced machine learning model for better prediction accuracy of soil temperature at different depths[J]. PLOS ONE, 2020, 15(4): e0231055.

（责任编辑　王海锋）