

基于 RIME-CNN-SVR 模型的麦田土壤水分反演

王 然，赵建辉^{*}，杨会巾，李 宁

(1. 河南大学计算机与信息工程学院，开封 475004；2. 河南省大数据分析处理重点实验室，开封 475004；3. 河南省空间信息处理工程研究中心，开封 475004；4. 河南大学交叉学科高等研究院，开封 475004)

摘 要：土壤水分监测对于农业生产和作物产量预估具有重要意义。近年来深度学习技术在土壤水分反演领域得到广泛应用，但大多侧重于模型结构增强和优化，对模型超参数优化研究探索不足。该研究提出了一种基于霜冰优化算法（rime optimization algorithm, RIME）的卷积神经网络（convolutional neural network, CNN）超参数优化模型，结合极化分解技术来校正植被对土壤水分反演精度的影响，以提高冬小麦农田土壤水分反演性能。首先利用 RIME 优化 CNN 超参数以构建 RIME-CNN 模型，然后使用 RIME-CNN 模型对特征参数进行自适应提取和挖掘，之后对这些特征参数进行正则化处理并输入到支持向量回归（support vector regression, SVR）模型，构建 RIME-CNN-SVR 模型进行土壤水分估算。为验证所建 RIME-CNN-SVR 模型的有效性，利用合成孔径雷达（synthetic aperture radar, SAR）数据结合光学遥感数据，在河南省开封市冬小麦农田区进行试验验证和精度分析。结果表明，该方法在不增加模型结构复杂性和可学习参数的前提下，显著提升了模型的预测性能，决定系数可达 0.72，均方根误差为 2.78%，平均绝对误差为 2.20%。该研究可为农业生产提供一个更为准确、可靠的土壤水分监测手段。

关键词：土壤水分；卷积神经网络；支持向量回归；霜冰优化算法；极化分解；合成孔径雷达

doi: 10.11975/j.issn.1002-6819.202312157

中图分类号：S157

文献标志码：A

文章编号：1002-6819(2024)-15-0094-09

王然，赵建辉，杨会巾，等. 基于 RIME-CNN-SVR 模型的麦田土壤水分反演[J]. 农业工程学报, 2024, 40(15): 94-102.

doi: 10.11975/j.issn.1002-6819.202312157 <http://www.tcsae.org>

WANG Ran, ZHAO Jianhui, YANG Huijin, et al. Inversion of soil moisture in wheat farmlands using the RIME-CNN-SVR model[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2024, 40(15): 94-102. (in Chinese with English abstract) doi: 10.11975/j.issn.1002-6819.202312157 <http://www.tcsae.org>

0 引 言

作为农业生产的关键因素，土壤水分在农业水资源管理、作物产量预测和旱情监测中发挥着重要作用^[1-2]。目前，主要通过站点监测和遥感监测 2 种方式获取土壤水分。站点监测可以精确获取农田地表土壤水分，但受站点分布稀疏、地表异质性且成本高等限制，难以实现大规模监测。相比之下，遥感监测以其高宽幅和低成本的优势，已成为土壤水分获取的重要方式。微波遥感对地表有一定穿透力，且不易受天气影响，弥补了光学遥感在土壤水分监测中的不足。特别是合成孔径雷达（synthetic aperture radar, SAR）以其全天候、全天时、高分辨率的特性，在土壤水分动态监测方面展现出独特优势，已被广泛应用于土壤水分反演研究^[3-4]。

在植被覆盖区，雷达信号受植被干扰较大，植被对微波信号的影响可能超过土壤水分对回波信号的影响，因此，校正地表植被影响在土壤水分反演中至关重要^[5-8]。植被影响校正方法主要有 2 种：1) 利用植被散射理论模型如密歇根微波冠层散射模型和水云模型，定量估算植被散射在总散射中的比例^[9-10]，但由于植被结构复杂且地表通常由多种植被构成，理论模型难以精确校正植被影响；2) 使用极化分解技术来滤除植被体散射分量，具体来说，极化分解能够分解极化散射矩阵或散射向量，从而识别和量化各种散射机制，区分植被内部与地表的散射贡献，减少植被的影响，提高土壤水分反演的准确性和稳定性^[11-12]。WANG 等^[13]从全极化相干矩阵中去除体散射分量，获得了地表散射分量，然后比较了 3 种基于模型的极化分解方法在不同作物覆盖地表的土壤水分反演中的潜力，结果显示不同分解方法的性能取决于作物类型和物候阶段，揭示了不同极化分解方法的适用性和局限性，为农田地表土壤水分反演领域提供了重要参考。HAJNSEK 等^[14]运用全极化 L 波段 SAR 数据，对 Freeman-Durden 分解的 3 个分量模型进行了改进，成功分离出植被和地面散射分量，并对不同作物类型在整个生长周期中的分解和反演性能进行了深入研究，其结果显示每种作物类型的土壤水分可以分为 3~5 个不同的水分等级，为未来研究方向提供了一种视角。

收稿日期：2023-12-20 修订日期：2024-03-06

基金项目：国家自然科学基金项目（42101386）；河南省高等学校重点科研项目（22A520021）；河南省科技攻关计划项目（222102110439, 23102211043, 242102210113）；自然资源部南方丘陵区自然资源监测监管重点实验室开放基金课题（NRMSSHR2022Z01）；开封市科技计划重点研发专项（22ZDYF006）

作者简介：王然，研究方向为农田土壤水分反演。

Email: wrang@henu.edu.cn

※通信作者：赵建辉，博士，副教授，研究方向为 SAR 图像处理。

Email: jhzhaoh@henu.edu.cn

近年来，深度学习技术，尤其是卷积神经网络（convolutional neural networks, CNN）在土壤水分反演中得到了广泛应用。HEGAZI 等^[15]使用 Sentinel-1 数据，通过构建 CNN 模型，分析和理解大量数据，挖掘出数据的深层特征，实现了土壤水分含量的精准预测，证明了 CNN 模型在处理回归预测问题时的优势。然而，为发挥 CNN 的最大潜力并确保模型的预测准确性，还需要关注一些关键细节。CNN 内部的一些参数被称为超参数，主要包括卷积核的大小、迭代次数、批处理大小等。CNN 的预测性能在很大程度上取决于超参数的设置，不合适的超参数设置可能会导致网络训练过程中出现梯度消失、网络收敛速度慢等问题，严重影响网络性能和模型训练效率。因此，如何选择合适的超参数，以优化网络性能和提高模型训练效率，是目前 CNN 研究中的关键问题。SU 等^[16]提出了霜冰优化算法（rime optimization algorithm, RIME），该算法通过模拟冰霜的软霜和硬霜生长过程，构建软霜搜索策略和硬霜穿刺机制，实现优化方法中的探索和开发行为，具有更强的优化能力和更快的学习效率。

为研究植被对土壤水分反演精度产生的影响，本文选取河南省开封市部分冬小麦种植区为研究区域，基于全极化 RADARSAT-2 SAR 数据和 Sentinel-2 光学遥感数据，开展冬小麦农田土壤水分反演。首先使用极化分解技术校正冬小麦植株对雷达后向散射系数的影响，去除植被体散射分量；其次使用多种极化分解模型提取相应的极化特征参数，丰富极化 SAR 特征空间信息；然后为消除冗余特征提升模型性能，使用互信息法（mutual information, MI）对所提取的特征参数进行优选，获得与土壤水分相关性更高的特征参数；最后提出了基于霜冰优化算法的卷积神经网络模型进行特征的深度提取，然后结合使用支持向量回归（support vector regression, SVR），构建 RIME-CNN-SVR 模型进行土壤水分反演。

1 研究区与数据集

1.1 研究区概况

研究区位于中国河南省开封市，面积约为 400 km²。该地区位于河南省东部、黄河下游南岸之滨，属于温带大陆性季风气候，土壤多为黏土和壤土，适宜多种农作物生长。研究区的农作物主要为冬小麦和玉米，采用冬小麦和夏玉米轮作模式，冬小麦一般在 10 月播种，次年 6 月收获。本文选取返青期、拔节期和成熟期的冬小麦覆盖区开展土壤水分反演研究。

1.2 数据集

1.2.1 遥感数据集

1) RADARSAT-2 数据：选用 3 景全极化 RADARSAT-2 影像，影像获取时间分别为 2020 年 3 月 15 日、2020 年 4 月 8 日和 2020 年 5 月 26 日。其产品类型为单视复数影像（single look complex, SLC），成像模式为精细四极化。RADARSAT-2 数据预处理过程主要包括轨道校正、辐射定标、多视、极化相干矩阵生成、

Refined Lee 滤波及地形校正等。

2) Sentinel-2 数据：根据 RADARSAT-2 影像的获取时间，选用与 RADARSAT-2 影像获取时间相近且无云的 3 景 L2A 级别的 Sentinel-2 光学遥感影像，获取时间分别为 2020 年 3 月 18 日、2020 年 4 月 12 日和 2020 年 5 月 22 日。由于研究期间研究区冬小麦生长状态在几天内变化不大，因此使用这 3 景准同步光学遥感影像来近似观测 RADARSAT-2 卫星过境当天研究区的植被生长状态。

1.2.2 实测数据集

在 RADARSAT-2 卫星过境期间进行野外实地测量。本研究采样点位置如图 1 所示。




图 1 研究区采样点位置分布

Fig.1 Location distribution of sampling points in the study area

实测数据包括土壤水分信息、采样点的经纬度信息以及冬小麦植株的物候期和高度。

1) 土壤水分信息：对于每个采样点，使用带有 3.8 cm 长探头的 TDR350 土壤水分仪测量 5 次农田表层土壤体积含水率，任意 2 次测量的空间距离不低于 20 m。然后取 5 次土壤水分值的平均值作为本采样点的最终土壤水分值。表 1 展示了实测土壤含水率详细信息。

表 1 土壤含水率统计			
Table 1 Statistics of soil moisture			
指标	建模集	验证集	总样本
Index	Calibration dataset	Validation dataset	All samples
样本量 Sample size	750	30	780
最小值 Minimum/%	0.16	0.92	0.16
平均值 Mean/%	6.13	5.39	5.68
中位数 Medium/%	4.83	4.47	4.66
最大值 Maximum/%	25.00	27.26	27.26

2) 经纬度信息：使用室外手持式 UG905 定位器定位每个采样点的经纬度坐标，定位精度为 1~3 m，并使用 WGS84 坐标系统进行记录，以确保与地理信息系统的兼容性。

3) 植株状态信息：为表征冬小麦的生长状态，测量

并记录了每个采样点的冬小麦植株物候期信息和高度。冬小麦物候期处于返青期、拔节期和成熟期,植株高度在 16.4~87.0 cm 之间。

3 次地面实测共收集 60 组数据。深度学习模型的训练依赖于大量的数据集,因为这些模型通常包含大量的参数和复杂的结构,使得它们对数据特征的捕捉能力极强。当面对小规模数据集时,容易出现过拟合现象。为了避免深度学习模型在小规模数据集上容易发生的过拟合问题,对实测数据集进行了以下预处理和数据增强,以增强数据的代表性和模型的泛化能力。首先将实测数据集平均分为 2 个子集,每个子集含 30 组数据。第 1 个子集通过特定的方法进行了数据增强,被选中用于数据增强的数据集符合以下条件:1) 根据实地采样点位置,尽量选择采样点周边都是农田的点;2) 土壤水分值的范围尽量宽泛,包含的数值尽量多样化。数据增强的步骤如下:以 1 个采样点为中心,在其周围的正方形范围内提取样本,距离采样点大约 2 个像素(约为实地 20 m)。然后,不同的特征参数设置不同的阈值,筛选出与采样点的样本值之间的差距在阈值之内的样本数据。这样的筛选方法可以获取与采样点相邻且相似的样本数据,在更准确地描绘该特定位置附近的样本情况的同时增强了数据集。最终将数据集从 30 组增强至 750 组。在这 750 组数据中,70% 用于训练深度学习模型,剩余 30% 用于测试模型性能。此外,最初的 60 组数据中未用于扩充的另外 30 组样本,用于评估模型的精度和可靠性。

2 研究方法

2.1 基于极化分解技术的植被影响校正

使用 Freeman-Durden 分解将体散射的贡献从极化相干矩阵中去除,从而在原始 SAR 信号中分离出地表散射分量。由于在冬小麦覆盖区,二次散射能量的占比较少,为简化表面散射分量的计算过程和土壤水分反演过程,参考文献[17-18],忽略二次散射的贡献。然后,基于极化相干矩阵和极化协方差矩阵的转换关系,以及协方差矩阵和后向散射系数的转换关系,由此可得到水平极化、

垂直极化和交叉极化下的地表后向散射系数,分别如式(1)~式(3)所示。

$$\sigma_{HH_sur}^0 = \frac{TS_{11} + TS_{12} + TS_{12}^* + TS_{22}}{\sqrt{2}} \quad (1)$$

$$\sigma_{VV_sur}^0 = \frac{TS_{11} - TS_{12} - TS_{12}^* + TS_{22}}{\sqrt{2}} \quad (2)$$

$$\sigma_{HV_sur}^0 = \frac{TS_{33}}{2} \quad (3)$$

式中*代表共轭,TS为表面散射分量,TS_{ij}表示TS矩阵的第*i*行和第*j*列元素,σ_{HH_{-sur}}⁰、σ_{VV_{-sur}}⁰和σ_{HV_{-sur}}⁰分别为水平极化下、垂直极化下和交叉极化下的地表后向散射系数。

不同极化方式下后向散射系数对地表的散射特性的敏感性不同,因此采用极化比更全面地描述地表的散射特征:水平极化与垂直极化散射系数比(σ_{HH_{-sur}}⁰/σ_{VV_{-sur}}⁰)、垂直极化与交叉极化散射系数比(σ_{VV_{-sur}}⁰/σ_{HV_{-sur}}⁰)和水平极化与交叉极化散射系数比(σ_{HH_{-sur}}⁰/σ_{HV_{-sur}}⁰)。

2.2 特征参数提取

全极化 SAR 数据包含了丰富的极化特征信息。为充分挖掘并利用这些信息,采用多种极化分解技术对 RADARSAT-2 数据进行极化分解,获得多种极化特征参数,丰富 SAR 数据的原始特征空间。使用 H/A/α 分解、Freeman-Durden 分解、Yamaguchi 分解、六分量分解和七分量分解 5 种极化分解模型共提取出 26 个极化特征分解参数,如表 2 所示。

植被指数是基于地物在特定波长范围内的反射率经过计算处理后得到的,其目的是凸显植被的某些独特属性或特征。本研究根据研究区的实际植被条件,筛选出 4 种能够反映植被生长特性的植被指数,包括归一化植被指数(normalized differential vegetation index, NDVI)、水分胁迫指数(moisture stress index, MSI)、融合植被指数(fusion vegetation index, FVI)和归一化水体指数(normalized differential water index, NDWI),计算式见文献[19-22]。

表 2 本研究所用的极化分解参数

Table 2 Polarization decomposition parameters in this study

分解方法 Decomposition method	极化参数 Polarization parameters	物理描述 Physical description
H/A/α	H, A, α λ ₁ , λ ₂ , λ ₃	散射熵, 反熵, 平均散射角 相干矩阵特征值
Freeman	Free_Sur, Free_Dbl, Free_Vol	表面散射, 二次散射, 体散射
Yamaguchi	Yama_Sur, Yama_Dbl, Yama_Vol, Yama_Hel	表面散射, 二次散射, 体散射, 螺旋体散射
六分量	Six_Sur, Six_Dbl, Six_Vol, Six_Hel, Six_Od, Six_Cd	表面散射, 二次散射, 体散射, 螺旋体散射, 定向偶极子散射, 复合偶极子散射
七分量	Seven_Sur, Seven_Dbl, Seven_Vol, Seven_Hel, Seven_Od, Seven_Cd, Seven_Md	表面散射, 二次散射, 体散射, 螺旋体散射, 定向偶极子散射, 复合偶极子散射, 混合偶极子反射

2.3 特征参数优选

当使用机器学习技术进行回归拟合时,挑选合适的训练数据至关重要。冗余的输入数据可能会影响网络的收敛性能,对模型的学习效果产生负面影响^[23-24]。因此,

本研究在选择训练数据时,以特征与土壤水分之间的相关性为基础进行筛选,使用互信息(mutual information, MI)方法选取与土壤水分相关性较高的特征参数作为模型输入,以提高模型的预测准确性。为使互信息的量化

结果更加直观和易于比较, 采用归一化互信息 (normalized mutual information, NMI), 使得 NMI 的值范围被限制在 $[0,1]$ 之间, NMI 的值越接近 1, 表明 2 个变量之间的相互信息量越大, 即当知道其中一个变量的信息时, 可以获得另一个变量更多的信息^[25]。

通过上述的预处理和分析, 共选取 36 个特征参数, 使用 MI 定量评估特征参数与土壤水分的相关性, 选择出与土壤水分相关性较高的特征参数作为土壤水分反演模型输入的最佳特征组合。


2.4 RIME-CNN-SVR 模型建立

为提高 CNN 模型的回归预测性能, 首先采用 RIME 算法优化 CNN 模型的超参数。这些超参数包括各卷积层卷积核的数量 (N)、卷积核的大小 (K)、批处理大小、初始学习率及 L2 正则化系数。RIME 算法通过软霜搜索策略在初期进行广泛的参数探索, 并通过硬霜穿刺机制在后期精确调整, 确定高性能的超参数组合。这种策略结合使得算法在全局搜索与局部调整之间保持平衡。整个优化过程使用土壤水分预测值和实际值均方误差 (mean square error, MSE) 作为适应度函数, 以此确定

搜索过程, 确保找到能最小化 MSE 的最优超参数。

然后, 利用求得的最优超参数组合建立 CNN 模型。其中, 为避免出现由集合数据特征的减少而导致回归预测精度的降低的问题, 本研究从网络中删除池化层。深度学习中的最大问题之一是梯度消失, 当使用 Tanh、Sigmoid 和其他饱和激励函数时, 梯度消失问题尤为严重, 这使得训练网络的收敛速度变慢。ReLU 函数凭借其线性和非饱和形式克服了梯度消失问题^[26]。同时, 训练速度远快于 Tanh 函数和 Sigmoid 函数, 因此本文选择 ReLU 函数作为激活函数。

SVR 技术^[27] 能够解决回归预测问题。鉴于 SVR 展现出的稳健性、稀疏性以及对小样本的适应性, 本文选择 SVR 作为回归预测工具。首先, 通过 CNN 模型深度提取特征, 从输入数据中获取高级特征表示, 使模型能够自动捕获数据的关键特征。然后, 使用 SVR 对这些特征进行训练, 基于学习特征与目标值之间的关系实现回归预测。本文构建的 RIME-CNN-SVR 网络架构如图 2 所示, 其中 c_x 、 m_x 和 n_x 由 RIME 算法计算得出, 分别表示卷积核的数量和大小。



注: Conv2D 为卷积层, N 为卷积核数量, K 为卷积核大小, $C_1 \sim C_4$ 为卷积核大小取值, $[m_1 \sim m_4, n_1 \sim n_4]$ 为卷积核数量取值, SVR 为支持向量回归模型。
Note: Conv2D is the convolution layer, n is the number of convolution kernels, K is the size of convolution kernels, $C_1 \sim C_4$ is the values of convolution kernel size, $[m_1 \sim m_4, n_1 \sim n_4]$ is the values of convolution kernel number, and SVR is a support vector regression model.

图 2 RIME-CNN-SVR 模型架构示意图
Fig.2 Schematic of structure of the RIME-CNN-SVR model

采用 3 个指标评估反演精度, 分别是决定系数 (R^2)、均方根误差 (root mean square error, RMSE) 和平均绝对误差 (mean absolute error, MAE), 其计算方法见文献^[28-30]。

3 结果与分析


3.1 植被对雷达后向散射的影响

图 3 展示了不同极化方式下总的后向散射系数和去除体积散射分量之后的地表后向散射系数与土壤水分的时间序列间关系。从图 3 可以看出, 总体而言, 随着冬小麦的生长, 不同极化方式下总的雷达后向散射系数与土壤水分的相关性逐渐减低。其中, HH 极化下的总的后向散射系数与土壤水分的相关性最大。2020 年 3 月 15 日的 HH 极化下的总的后向散射系数与土壤水分间决定系数为 0.41; HV 极化下的总的后向散射系数与土壤水分的相关性最低, 2020 年 5 月 26 日的 HV 极化下的总的后向散射系数与土壤水分间决定系数仅为 0.25。去

除体积散射分量后, 不同极化方式下雷达后向散射系数与土壤水分间决定系数均增大。这是因为总的后向散射系数主要受作物的物候期和土壤水分的影响, 而地面散射分量主要受土壤水分的影响。其中, HH 极化下的地表后向散射系数与土壤水分间的决定系数最高。

3.2 相关性分析结果

使用 MI 进行相关性分析, 并对特征参数与土壤水分的相关性进行了排序。本文选择了相关性最强的前 18 个特征参数作为模型的输入, 其排序从高到低分别为: NDWI、FVI、 $\sigma_{HH_sur}^0$ 、 $\sigma_{VV_sur}^0$ 、MSI、Six_Od、H、NDVI、Six_Cd、Free_Sur、Seven_Cd、Free_Vol、 λ_3 、 $\sigma_{HH_sur}^0 / \sigma_{VV_sur}^0$ 、 $\sigma_{HV_sur}^0$ 、 $\sigma_{VV_sur}^0 / \sigma_{HV_sur}^0$ 、 A 和 Yama_Vol (表 3)。由表 3 可以看出, 4 个植被指数与土壤水分存在较高的相关性。这是因为 400~2 500 nm 的波段对农作物生理状态的敏感反应。在农业应用中, 红波段、近红外波段以及短波红外波段常被用于研究植被的生物指标。这些指标与植被的生长状况以及土壤水分有着紧密的关联。



注：虚线为拟合线， $\sigma_{HH_sur}^0$ 、 $\sigma_{VV_sur}^0$ 和 $\sigma_{HV_sur}^0$ 分别为水平极化下、垂直极化下和交叉极化下的地表后向散射系数。

Note: Dotted lines are fitted lines, $\sigma_{HH_sur}^0$, $\sigma_{VV_sur}^0$ and $\sigma_{HV_sur}^0$ are the surface backscattering coefficients under horizontal polarization, vertical polarization and cross polarization, respectively.

图3 不同极化方式下总后向散射和地表后向散射与土壤体积含水率实测值间关系

Fig.3 Relationships between full backscattering and ground backscattering and measured soil moisture under different polarization modes

表3 特征参数与土壤水分的相关性分析排序

Table 3 Ranking of feature parameters based on correlation between it and soil moisture

编号 No.	特征参数 Characteristic parameters	物理描述 Physical description	NMI
1	NDWI	归一化差异水分指数	0.55
2	FVI	融合植被指数	0.53
3	$\sigma_{HH_sur}^0$	地表后向散射系数 (HH 极化)	0.52
4	$\sigma_{VV_sur}^0$	地表后向散射系数 (VV 极化)	0.51
5	MSI	水分胁迫指数	0.51
6	Six_Od	定向偶极子散射	0.49
7	H	极化熵	0.48
8	NDVI	归一化差异植被指数	0.48
9	Six_Cd	复合偶极子散射 (六分量分解)	0.47
10	Free_Sur	表面散射	0.45
11	Seven_Cd	复合偶极子散射 (七分量分解)	0.44
12	Free_Vol	体散射 (Freeman 分解)	0.41
13	λ_3	特征值	0.40
14	$\sigma_{HH_sur}^0 / \sigma_{VV_sur}^0$	地表后向散射系数极化比 (HH 与 VV)	0.40
15	$\sigma_{HV_sur}^0$	HV 极化地表后向散射系数	0.38
16	$\sigma_{VV_sur}^0 / \sigma_{HV_sur}^0$	地表后向散射系数极化比 (VV 与 HV)	0.37
17	A	反熵	0.37
18	Yama Vol	体散射 (Yamaguchi 分解)	0.37

当农作物因土壤水分异常 (如水分过高或过低) 而受到影响时, 这种变化可通过植被指数来捕获。值得注意的是, 经过极化分解去除体积散射分量之后的地表后向散射系数与土壤水分相关性也较高, 体现了在植被覆盖区进行土壤水分反演时植被影响校正的必要性。

3.3 网络训练参数结果

经过 RIME 优化之后的 CNN 结构为: 卷积层 1 的卷积核大小为 [4,4], 数量为 13; 卷积层 2 的卷积核大小为 [3,3], 数量为 35; 卷积层 3 的卷积核大小为 [2,2], 数量为 81; 卷积层 4 的卷积核大小为 [2,2], 数量为 86; 批大小为 178; 最佳初始学习率为 0.05; 最佳 L2 正则化系数为 9.7×10^{-3} , 以防止过拟合, 保证模型在复杂数据集上的泛化能力。具体 RIME-CNN-SVR 的超参数设置信息见表 4。

表 4 RIME-CNN-SVR 网络超参数设置

Table 4 Hyperparameterization design of RIME-CNN-SVR networks

编号 NO.	超参数 Hyperparameter	取值 Values
1	批大小	178
2	最佳初始学习率	0.05
3	最佳 L2 正则化系数	9.7×10^{-3}
4	卷积层 1 卷积核的数量和大小	13@4×4
5	卷积层 2 卷积核的数量和大小	35@3×3
6	卷积层 3 卷积核的数量和大小	81@2×2
7	卷积层 4 卷积核的数量和大小	86@2×2

3.4 土壤含水率反演

3.4.1 去除植被散射贡献前后土壤水分反演

采用未经数据增强的 30 组实测数据验证土壤水分反演精度，4 种模型均使用了相同的特征参数组合作为输入数据。这些实测数据直接反映了模型在实际应用场景中的表现。为探究去除植被影响前后的土壤含水率估算性能，首先将未去除植被散射的总后向散射系数作为模型的输入数据进行建模分析，4 种模型的估算结果如图 4 所示。之后将去除植被散射的地表后向散射系数作为特征参数，再次进行建模分析，4 种模型的估算结果如图 5 所示。对比可知，去除植被体散射后验证集 RIME-CNN-SVR 模型 R^2 和 RMSE 分别为 0.72 和 2.78%。与去除植被散射前相比， R^2 提高了 0.09，RMSE 减少了 1.26%，说明去除植被影响后土壤含水率的估计效果更好。




图 4 去除植被影响前土壤水分预测结果

Fig.4 Soil moisture prediction results before removing vegetation

3.4.2 极端值对土壤水分估算性能影响分析

通过分析图 5 可以看到，这 4 种模型在估算土壤含水率时，都表现出了一定程度的高估现象，散点的分布在 1:1 线上方居多。结果中出现的不同模型在估计土壤水分值时普遍存在高估的趋势，CHEN 等^[31]在研究冬小麦覆盖农田的地表土壤含水率反演时也有一致的结论。造成这一现象的原因可能是实地采样点中，土壤水分含量处于极高或极低范围的样本相对较少。这种样本分布的偏斜导致模型在这些关键区域的拟合能力不足，特别

是对极端土壤含水率的估计，因此机器学习方法在这些范围内的土壤水分估计易出现明显的偏差。




图 5 去除植被影响后土壤水分预测结果

Fig.5 Soil moisture prediction results after removing vegetation

为探究极端值对土壤含水率估算精度的影响，本研究设置了一组对比试验，从数据集中剔除了土壤含水率低于 1% 及高于 15% 的样本，以便减少极端样本模型预测能力的影响，结果如图 6 所示。




图 6 去除极端值后土壤水分预测结果

Fig.6 Soil moisture prediction results after removing extreme points

对比图 5 和图 6，可以看出分布在 1:1 线上方的散点有所减少，同时精度也有一定提升。这一结果表明，数据集中的极端值是导致土壤水分估计普遍偏高的重要因素之一。剔除极值数据后，模型在常规水分值区域的拟合性能得到一定改善，表现出更高的预测准确性。其中本文所提 RIME-CNN-SVR 模型仍然在 4 种模型中表现最好， R^2 和 RMSE 分别为 0.78 和 1.53%，与剔除极值数据前相比， R^2 提高了 0.06，RMSE 减少了 1.25 个百分点，

证明了所提模型在常规土壤水分范围内具有更高的预测准确性,同时也验证了所提模型在不同土壤水分情况下均具有良好的稳健性和适应性。

3.5 研究区土壤水分反演结果

在构建的4个模型中,RIME-CNN-SVR模型表现出最佳的土壤水分估算精度。基于此,本研究选择其作为最佳的土壤水分反演模型,并将其应用于研究区的所有冬小麦覆盖区像元,完成不同时相的土壤水分空间制图。为凸显土壤水分分布图上的冬小麦农田区域,首先对研究区内的建筑物、道路、河流和其他作物种植区等非冬小麦农田区域进行了分类,并将这些区域填充为白色像素^[32]。研究区土壤水分反演结果如图7所示。从图中可以看到,2020年3月15日的土壤含水率反演结果整体

较高,土壤体积含水率的均值为11.33%,这与实测水分值也较为吻合。实测数据中,该日期的土壤水分均值也是最高,为9.09%。这是因为该日期的冬小麦正处于成长期关键阶段,在此生长阶段中作物对水分的需求较高,农田中灌溉活动较多,因此该日期的土壤含水率比其他日期要高。同时,由于研究区内不同农田之间存在灌溉的时间、方式和强度等差异,这导致了该日期内土壤湿度表现出显著差异。随着冬小麦的生长发育,该地区的作物供水主要依赖于自然降水。在研究区域内降雨均匀的情况下,冬小麦生长后期土壤水分的空间变化较小,土壤水分值逐渐下降,这在2020年4月8日和5月26日的土壤水分反演结果中也得到充分体现。这也进一步验证了该方法在研究区土壤含水率反演工作中的有效性。




图7 研究区土壤水分反演结果

Fig.7 Inversion results of soil moisture in the study area

4 结 论

本文针对植被对土壤水分反演精度产生负面影响的问题,使用极化分解技术进行植被影响校正,提出了一种深度学习模型超参数优化策略,构建了具备最优超参数选择能力的RIME-CNN-SVR模型,以提高冬小麦农田土壤水分反演性能。结合使用SAR遥感数据、光学遥感数据和实测数据,对所建RIME-CNN-SVR模型进行了精度分析和稳健性验证。主要结论如下:

1) 在植被覆盖区,雷达信号易受植被干扰,影响土壤水分反演精度,在土壤水分反演过程中校正植被影响至关重要。采用极化分解技术能够有效削弱植被的干扰效应,从而提高地表后向散射系数与土壤水分的相关性,增强土壤水分反演的准确性。

2) 在土壤水分反演模型中,特征参数冗余会对反演结果准确度产生负面影响。采用MI算法进行特征优选,能够有效剔除冗余特征参数,提高模型训练性能。

3) 实测水分数据集中的极端值会对土壤含水率估算精度产生较大影响。剔除极值数据后,水分反演模型在常规水分值范围的拟合性能得到一定改善,表现出更高的预测准确性。

4) 与CNN、RIME-CNN和CNN-SVR模型相比,本文提出的RIME-CNN-SVR模型具有更高的反演精度,验证集其决定系数为0.72,均方根误差为2.78%,平均绝对误差为2.20%。使用RIME-CNN-SVR模型进行了研究区冬小麦农田土壤水分空间制图,验证了该方法在冬小麦农田土壤水分反演中的有效性和适用性,为农业地

区的土壤水分遥感监测工作提供了有益参考。

本文研究期间研究区主要农作物是冬小麦,作物类型较为单一,本文所提方法在不同作物覆盖区域的有效性尚未得到验证。未来计划在包含多种作物的复杂农田区域开展土壤水分反演研究,进一步探讨并优化在多作物农田环境中的土壤水分反演方法。

[参 考 文 献]

- [1] 王梦迪,何莉,刘潜,等.基于小麦冠层无人机高光谱影像的农田土壤含水率估算[J].农业工程学报,2023,39(6):120-129. WANG Mengdi, HE Li, LIU Qian, et al. Estimating soil moisture contents of farmland using UAV hyperspectral images of wheat canopy[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2023, 39(6): 120-129. (in Chinese with English abstract)
- [2] ZHU L J, WALKER J P, YE N, et al. Roughness and vegetation change detection: A preprocessing for soil moisture retrieval from multitemporal SAR imagery[J]. Remote Sensing of Environment, 2019, 225: 93-106.
- [3] 赵建辉,张晨阳,闵林,等.基于特征选择和GA-BP神经网络的多源遥感农田土壤水分反演[J].农业工程学报,2021,37(11):112-120. ZHAO Jianhui, ZHANG Chenyang, MIN Lin, et al. Retrieval for soil moisture in farmland using multi-source remote sensing data and feature selection with GA-BP neural network[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2021, 37(11): 112-120. (in Chinese with English abstract)

- [4] ZAKHAROV I, KAPFER M, HORNUNG J, et al. Retrieval of surface soil moisture from Sentinel-1 time series for reclamation of Wetland sites[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 13: 3569-3578.
- [5] 马红章, 孟庆涛, 刘素美. TAU-OMEGA 遥感辐射模型改进与参数化[J]. *农业工程学报*, 2024, 40(11): 292-298.
MA Hongzhang, MENG Qingtao, LIU Sumei. Improvement and parameterization of the TAU-OMEGA radiation model[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2024, 40(11): 292-298.
- [6] ATTEMA E P W and ULABY F T. Vegetation modeled as a water cloud[J]. *Radio Science*, 1978, 13(2): 357-364.
- [7] 王思楠, 李瑞平, 吴英杰, 等. 基于模型平均法的表层土壤含水率多模型综合反演[J]. *农业工程学报*, 2022, 38(5): 87-94.
WANG Sinan, LI Ruiping, WU Yingjie, et al. Multi-model comprehensive inversion of surface soil moisture based on model averaging method[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2022, 38(5): 87-94.
- [8] ULABY F T, SARABANDI K, MCDONALD K Y L E, et al. Michigan microwave canopy scattering model[J]. *International Journal of Remote Sensing*, 1990, 11(7): 1223-1253.
- [9] 蔡庆空, 李二俊, 陶亮亮, 等. PROSAIL 模型和水云模型耦合反演农田土壤水分[J]. *农业工程学报*, 2018, 34(20): 117-123.
CAI Qingkong, LI Erjun, TAO Liangliang, et al. Farmland soil moisture retrieval using PROSAIL and water cloud model[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2018, 34(20): 117-123.
- [10] SHI H T, YANG J, LI Pingxiang, et al. Soil moisture estimation using two-component decomposition and a hybrid X-Bragg/Fresnel scattering model[J]. *Journal of Hydrology*, 2019, 574: 646-659.
- [11] WANG R, ZHAN J H, YANG H J, et al. Inversion of Soil Moisture on Farmland Areas Based on SSA-CNN Using Multi-Source Remote Sensing Data[J]. *Remote Sensing*, 2023, 15(10): 2515.
- [12] 谭丞轩, 张智韬, 许崇豪, 等. 无人机多光谱遥感反演各生育期玉米根域土壤含水率[J]. *农业工程学报*, 2020, 36(10): 63-74.
TAN Chengxuan, ZHANG Zhitao, XU Chonghao, et al. Soil water content inversion model in field maize root zone based on UAV multispectral remote sensing[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2020, 36(10): 63-74.
- [13] WANG H Q, MAGAGI R and GOITA K. Comparison of different polarimetric decompositions for soil moisture retrieval over vegetation covered agricultural area[J]. *Remote Sensing of Environment*, 2017, 199: 120-136.
- [14] HAJNSEK I, JAGDHUBER T, SCHON H, et al. Potential of estimating soil moisture under vegetation cover by means of PolSAR[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2009, 47(2): 442-454.
- [15] HEGAZI E H, YANG Linbo and HUANG Jingfeng. A convolutional neural network algorithm for soil moisture prediction from Sentinel-1 SAR images[J]. *Remote Sensing*, 2021, 13(24): 4964.
- [16] SU H, ZHAO D, HEIDARI A A, et al. RIME: A physics-based optimization[J]. *Neurocomputing*, 2023, 532: 183-214.
- [17] WANG H Q, MAGAGI R and GOITA K. Potential of a two-component polarimetric decomposition at C-band for soil moisture retrieval over agricultural fields[J]. *Remote Sensing of Environment*, 2018, 217: 38-51.
- [18] XIAO T F, XING M F, HE B B, et al. Retrieving soil moisture over soybean fields during growing season through polarimetric decomposition[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2020, 14: 1132-1145.
- [19] 王大成, 王纪华, 靳宁, 等. 用神经网络和高光谱植被指数估算小麦生物量[J]. *农业工程学报*, 2008, 24(增刊 2): 196-201.
WANG Dacheng, WANG Jihua, JIN Ning, et al. ANN-based wheat biomass estimation using canopy hyperspectral vegetation indices[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2008, 24(Supp.2): 196-201. (in Chinese with English abstract)
- [20] 赵祥, 王锦地, 刘素红. 耦合辐射传输模型的植被含水量遥感改进监测[J]. *红外与毫米波学报*, 2010, 29(3): 185-189.
ZHAO Xiang, WANG Jindi, LIU Suhong. Modified monitoring method of vegetation water content based on coupled radiative transfer model[J]. *Journal of Infrared and Millimeter Wave*, 2010, 29(3): 185-189. (in Chinese with English abstract)
- [21] 赵建辉, 张蓓, 李宁, 等. 基于 Sentinel-1/2 遥感数据的冬小麦覆盖地表土壤水分协同反演[J]. *电子与信息学报*, 2021, 43(3): 692-699.
ZHAO Jianhui, ZHANG Bei, LI Ning, et al. Cooperative inversion of winter wheat covered surface soil moisture based on sentinel-1/2 remote sensing data[J]. *Journal of Electronics and Information*, 2021, 43(3): 692-699. (in Chinese with English abstract)
- [22] MCFEETERS S K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features[J]. *International Journal of Remote Sensing*, 1996, 17: 1425-1432.
- [23] 王雅婷. 基于 SVR 的鄂尔多斯风沙滩地区土壤水分遥感反演方法研究[D]. 西安: 长安大学, 2019.
WANG Yating. Remote Sensing Retrieval of Soil Moisture in Ordos Blown-sand Region Based on SVR[D]. Xi'an: Chang'an University, 2019. (in Chinese with English abstract)
- [24] KHUSHABA R N, Al-Ani A, Al-Jumaily A. Differential evolution based feature subset selection[C]//International Conference on Pattern Recognition, IEEE, 2008.
- [25] HU Q H, GUO M Z, YU Daren, et al. Information entropy for ordinal classification[J]. *Science China Information Sciences*, 2010, 53: 1188-1200.
- [26] GUO J, BAI Q, GUO W, et al. Soil moisture content estimation in winter wheat planting area for multi-source sensing data using CNNR[J]. *Computers and Electronics in Agriculture*, 2022, 193: 106670.

- [27] VAPNIK V, GOLOWICH S, SMOLA A. Support vector method for function approximation, regression estimation and signal processing[J]. *Advances in Neural Information Processing Systems*, 1996,9:281-287.
- [28] 白杰, 牛铮, 毕恺艺, 等. 高光谱激光雷达植被叶片方向反射特性及对叶绿素反演的影响[J]. *光谱学与光谱分析*, 2023, 43(5): 1598-1605.
BAI Jie, NIU Zheng, BI Kaiyi, et al. Bi-directional reflection characteristic of vegetation leaf measured by hyperspectral lidar and its impact on chlorophyll content estimation[J]. *Spectroscopy and Spectral Analysis*, 2023, 43(5): 1598-1605. (in Chinese with English abstract)
- [29] YE W, MA T, JIN Z L, et al. CBTA: A CNN-BiGRU method with triple attention for winter wheat yield prediction[J]. *Journal of Applied Remote Sensing*, 2024, 18(1): 014507-014507.
- [30] HAN D, WANG P, TANSEY K, et al. Improving wheat yield estimates by integrating a remotely sensed drought monitoring index into the simple algorithm for yield estimate model[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 10383-10394.
- [31] CHEN L, XING M, HE B, et al. Estimating soil moisture over winter wheat fields during growing season using machine-learning methods[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2021, 14: 3706-3718.
- [32] LI H P, LU J, TIAN G X, et al. Crop classification based on GDSSM-CNN using multi-temporal RADARSAT-2 SAR with limited labeled data[J]. *Remote Sensing*, 2022, 14(16): 3889.

Inversion of soil moisture in wheat farmlands using the RIME-CNN-SVR model

WANG Ran , ZHAO Jianhui^{*} , YANG Huijin , LI Ning

(1. School of Computer and Information Engineering, Henan University, Kaifeng 475004, China; 2. Henan Key Laboratory of Big Data Analysis and Processing, Henan University, Kaifeng 475004, China; 3. Henan Province Engineering Research Center of Spatial Information Processing, Henan University, Kaifeng 475004, China; 4. Academy for Advanced Interdisciplinary Studies, Henan University, Kaifeng 475004, China)

Abstract: Soil moisture is one of the most influencing factors on the crop growth in agricultural production, particularly for the water management, yield estimation, drought monitoring and precision irrigation. Therefore, it is very necessary to rapidly and accurately detect the soil moisture. Fortunately, deep learning techniques have been widely applied into the soil moisture inversion in recent years. However, much efforts have been focused mainly on the optimization of model structures. It is still lacking to explore the hyperparameter settings of the models. In this study, an optimization strategy was proposed for a convolutional neural network (CNN) model using rime optimization (RIME), in order to improve the performance of soil moisture inversion in winter wheat farmlands. The polarization decomposition was also combined to correct the impact of vegetation on the accuracy of soil moisture inversion in the vegetation-covered areas. The reason was that the vegetation was negatively correlated with the soil moisture inversion. The RIME was then employed to optimize the hyperparameters of CNN, in order to form the RIME-CNN model. Subsequently, the RIME-CNN model was utilized to adaptively extract the feature parameters. Soil moisture was then estimated to regularize and feed into the feature parameters using support vector regression (SVR). Additionally, the wealth polarization characteristics were contained in fully polarized data. Various techniques were employed to perform the polarization decomposition on the RADARSAT-2 data. As such, the wide ranges of characteristic parameters were acquired after polarization. The original feature space of SAR data was further enriched to eliminate the data redundancy for the convergence of the network. Mutual information (MI) was also used to optimize the characteristic parameters. Synthetic aperture radar (SAR) and optical remote sensing data were used to invalidate the efficacy of the RIME-CNN-SVR model in the soil moisture inversion of the winter wheat farmlands. The results showed that: 1) The high accuracy of soil moisture inversion was achieved to improve the correlation between surface backscatter coefficient and soil moisture. Therefore, the polarization decomposition was effectively weakened the interference of vegetation. Among them, there was the highest correlation between the surface backscatter coefficient under HH polarization and soil moisture. 2) The MI was employed to optimize the feature. The unnecessary feature parameters were effectively reduced the data redundancy. The performance of network training was enhanced for the high accuracy of soil moisture inversion. 3) The RIME-CNN-SVR model was obtained in the higher inversion accuracy, compared with the CNN, RIME-CNN and CNN-SVR models, in which the determination coefficient was 0.72, the root mean square error (RMSE) was 2.78%, and the mean absolute error was 2.2%. At the same time, the RIME-CNN-SVR model was also feasible and suitable for the inversion of soil moisture in the winter wheat fields. The finding can also provide the accurate and reliable means of soil moisture monitoring for agricultural production.

Keywords: soil moisture; convolutional neural network; support vector regression; rime optimization algorithm; polarimetric decomposition; synthetic aperture radar