

叶黎明,施式亮,鲁义,等.融合特征选取与机器学习的煤矿安全生产态势预测[J].湖南科技大学学报(自然科学版),2024,39(4):28-36.doi:10.13582/j.cnki.1672-9102.2024.04.004

YE L M, SHI S L, LU Y, et al. Coal Mine Safety Production Situation Prediction Based on Feature Selection and Machine Learning[J]. Journal of Hunan University of Science and Technology (Natural Science Edition), 2024, 39(4): 28-36. doi: 10.13582/j.cnki.1672-9102.2024.04.004

融合特征选取与机器学习的 煤矿安全生产态势预测

叶黎明^{1,2}, 施式亮^{1,3*}, 鲁义¹, 李贺¹

(1.湖南科技大学 资源环境与安全工程学院,湖南 湘潭 411201;2.福建省核工业二九四大队,福建 福州 350019;
3.湖南科技大学 煤矿安全开采技术湖南省重点实验室,湖南 湘潭 411201)

摘要:为提高煤矿安全态势的预测精度,提出一种基于特征选取与机器学习融合的煤矿安全生产态势预测模型.首先,对1978年—2019年我国煤矿安全生产态势的相关数据进行归一化处理,使用全子集回归和随机森林2种特征选择方法对8种煤矿安全生产态势的影响因素进行组合;然后,运用岭回归、分类与回归树、自适应提升和极端梯度提升4种机器学习算法分别对12种煤矿安全生产态势特征参数组合进行预测,得到48种预测模型,根据各模型的平均判定系数对模型进行初步筛选;最后,综合比较归一化均方误差以及平均绝对百分比误差,得到2组待调优模型,分别对其进行超参数调优,得到最优预测模型.结果表明:最优预测模型的判定系数为0.971,归一化均方误差为0.029,平均绝对百分比误差为5.3%.

关键词:煤矿安全生产态势;特征选取;机器学习;预测

中图分类号:X936 文献标志码:A 文章编号:1672-9102(2024)04-0028-09

Coal Mine Safety Production Situation Prediction Based on Feature Selection and Machine Learning

YE Liming^{1,2}, SHI Shiliang^{1,3}, LU Yi¹, LI He¹

(1. School of Resources, Environment and Safety Engineering, Hunan University of Science and Technology, Xiangtan 411201, China;

2. Geologic Team No. 294 Nuclear Industry of Fujian Province, Fuzhou 350019, China;

3. Hunan Provincial Key Laboratory of Safe Mining Techniques of Coal Mines, Hunan University of Science and Technology, Xiangtan 411201, China)

Abstract: To improve the prediction accuracy of coal mine safety situations, a coal mine safety situation prediction model based on the fusion of feature selection and machine learning is proposed. Firstly, the relevant data of China's coal mine safety production situation from 1978 to 2019 are normalized, and the 8 types of influencing factors of coal mine safety production situation are merged by using full subset regression and random forest feature selection methods. Then, 12 combinations of distinctive characteristics of the coal mine safety production condition are predicted by using 4 machine learning methods, including ridge regression, classification and regression tree, AdaBoost, and XGBoost, then 48 prediction models are obtained. The models are preliminarily screened according to the average judgment coefficient of each model. Finally, by

收稿日期:2022-07-29

基金项目:国家自然科学基金资助项目(51974120;51774135)

*通信作者,E-mail:hnustssl@qq.com

comprehensively comparing the normalized mean square error and the average absolute percentage error, two optimized models are obtained, and their hyperparameters are optimized respectively to obtain the optimal prediction model. Results show that the R^2 of the best optimal prediction model is 0.971, the normalized mean square error is 0.029, and the average absolute percentage error is 5.3%.

Keywords: coal mine safety situation; feature selection; machine learning; prediction

煤矿安全生产关系到作业人员的生命安全和国家公共财产安全.近年来的统计数据显示:2017年—2021年,全国(不含港澳台地区)共发生煤矿事故827起,死亡1430人^[1].严峻的煤矿安全生产形势制约着我国煤矿行业的发展,准确地研判煤矿安全生产态势已成为煤矿事故预防的重要环节,因此,分析煤矿安全态势的发展规律和探究其变化趋势对安全方针和政策的制定具有重要意义.

煤矿生产系统的安全性受到煤炭资源赋存状态、煤矿开采技术条件、法律法规和社会环境等系统自身因素或外部因素的影响,因此,煤矿生产过程中事故的发生具有多因素时空耦合的复杂性^[2-3].目前,针对煤矿安全生产态势预测的相关研究主要围绕表征煤矿安全态势的指标展开,如煤矿事故死亡人数、事故起数与百万吨死亡率等.兰建义等^[4]在拟合1990年—2010年煤矿事故百万吨死亡率的基础上,使用马尔可夫SCGM(1,1)模型对2011年—2013年煤矿事故的数量进行预测;白楠等^[5]构建煤矿事故的灰色预测模型,并基于B/S架构与C语言实现煤矿事故管理与预测的可视化;施式亮等^[6]应用R/S分析法对煤矿事故百万吨死亡率进行预测,结果表明:该方法能较好地反映百万吨死亡率时间序列自身的非线性特征.上述研究大多数是应用数学模型直接对煤矿安全生产态势时间序列的变化特征进行挖掘,而对影响煤矿安全态势指标变化相关因素的研究较少.

由于机器学习能够较好地刻画安全态势指标与各影响因素之间的非线性关系,很多学者基于机器学习算法建立各类安全态势预测模型,为各领域的安全态势预测开辟了新途径.纪俊红等^[7]选取1953年—2018年的人口数量、民用汽车拥有量等6种影响交通事故死亡人数的因素,构建AdaBoost-LightGBM模型预测对应年份的交通事故死亡人数,为道路交通安全态势的预测提供方法支撑;张建荣等^[8]构建塔吊事故预测的随机森林模型,该模型可对塔吊事故等级与类型进行准确预测;KERIM等^[9]使用相间离散小波分析与机器学习模型对土耳其每日建筑事故数量进行预测,经小波分析预处理后,模型的预测精度得到提升.以上研究表明:各类机器学习算法善于处理安全态势预测中各影响因素之间的非线性问题,但在煤矿安全生产态势预测领域的研究与应用较少.

本文融合特征选取与机器学习,建立适用于煤矿安全生产态势预测的模型,并引入线性判定系数(R^2)、归一化均方误差(N_{MSE})与平均绝对百分比误差(M_{APE})综合评估模型的预测性能,以期煤矿安全生产态势预测提供一种新的解决方案.本文工作主要集中在以下2个方面:

1)通过文献调研,收集我国1978年—2019年的8类煤矿安全生产态势影响因素数据,并研究这些影响因素与煤矿安全生产态势之间的非线性关系,使用全子集回归与随机森林2种特征选择方法对这些影响因素组合进行选取,为后续研究奠定基础.

2)利用岭回归(Ridge Regression, RR)、分类与回归树(Classification and Regression Tress, CART)2种传统机器学习算法和自适应提升(Adaptive Boosting, AdaBoost)、极端梯度提升(Extreme Gradient Boosting, XGBoost)2种集成学习算法构建煤矿安全生产态势预测模型,通过特征选择对比、超参数调优找到表现最优的预测模型,并验证本文模型的可行性.

1 数据与方法

1.1 研究数据获取

目前,煤矿安全生产态势统计数据主要包括死亡人数、事故起数、受伤人数与经济损失这4项统计指标.对事故起数而言,仅造成财产损失、不涉及人员伤亡的事故在公布的数据中并无详细记录,进而导致针

对经济损失这一指标的统计难免存在遗漏.国家严厉查处瞒报、谎报煤矿死亡事故的行为^[10],凡涉及人员死亡的煤矿事故历来受到高度重视,在统计中少有疏漏,而受伤人数的统计往往只针对重伤人员,难以做到对伤员情况的全面记录,因此,选择死亡人数作为表征煤矿安全生产态势的预测指标.本文所使用的1978年—2019年我国煤矿事故死亡人数的统计数据来源于文献[11—12]与煤矿安全网.

影响煤矿安全生产态势的因素涵盖煤炭资源赋存状态、煤层自燃倾向性等自然因素,矿井生产方式、开采速度等煤矿开采技术因素和社会经济状况、法律法规等宏观因素.我国各地区之间的煤矿自然条件差异很大,因此自然因素的影响难以量化统一,相关数据的获取也有难度,本文结合前人研究^[13—14]与现有数据,选取国内煤炭消费总量 X_1 (consu)、煤炭占能源消费的比重 X_2 (ratio)、原煤产量 X_3 (yield)、煤炭行业从业人数 X_4 (staff)、国有重点煤矿工作面数量 X_5 (num,含回采工作面与掘进工作面)、大型煤企采煤机械化程度 X_6 (level)、吨煤成本 X_7 (cost)和煤炭价格 X_8 (price)这8项预测因子表征煤矿开采技术因素与宏观因素,数据收集自互联网、国家统计局与BP世界能源评论,近年的吨煤成本源于中煤能源、中国神华等上市煤企年度报告中所披露的数据.1978年—2019年我国煤矿事故死亡人数(toll)及影响因素的部分数据如表1所示.

表1 1978年—2020年我国煤矿事故死亡人数及影响因素(部分数据)

年份	consu/亿 t	ratio/%	yield/亿 t	staff/万	num/个	level/%	cost/(元·t ⁻¹)	price/(元·t ⁻¹)	toll/人
1978	6.277 0	70.3	6.178 6	406.86	7 005	32.52	17.80	19.27	6 001
1979	6.456 2	70.2	6.355 4	410.40	7 372	32.34	20.05	23.02	5 566
1980	6.373 5	69.4	6.201 3	419.20	7 542	37.06	21.54	25.45	5 165
1981	6.322 7	70.2	6.663 2	433.30	7 379	39.77	21.95	25.67	5 162
...
2018	39.745 2	59	36.800 0	283.60	7 221	97.90	215.57	578	333
2019	40.191 5	57.7	38.500 0	256.40	7 372	98.10	220.40	560	316

煤矿事故死亡人数与各量化预测因子的关系如图1所示.由图1可知:煤矿事故死亡人数与煤炭消费总量、煤炭所占能源比重、原煤产量、煤炭行业从业人数、国有重点煤矿工作面数量、大型煤企采煤机械化程度、吨煤成本以及煤炭价格的线性判定系数较低(R^2 的范围为0.123~0.830),煤矿事故死亡人数与以上各因素之间未呈现明显的线性关系.

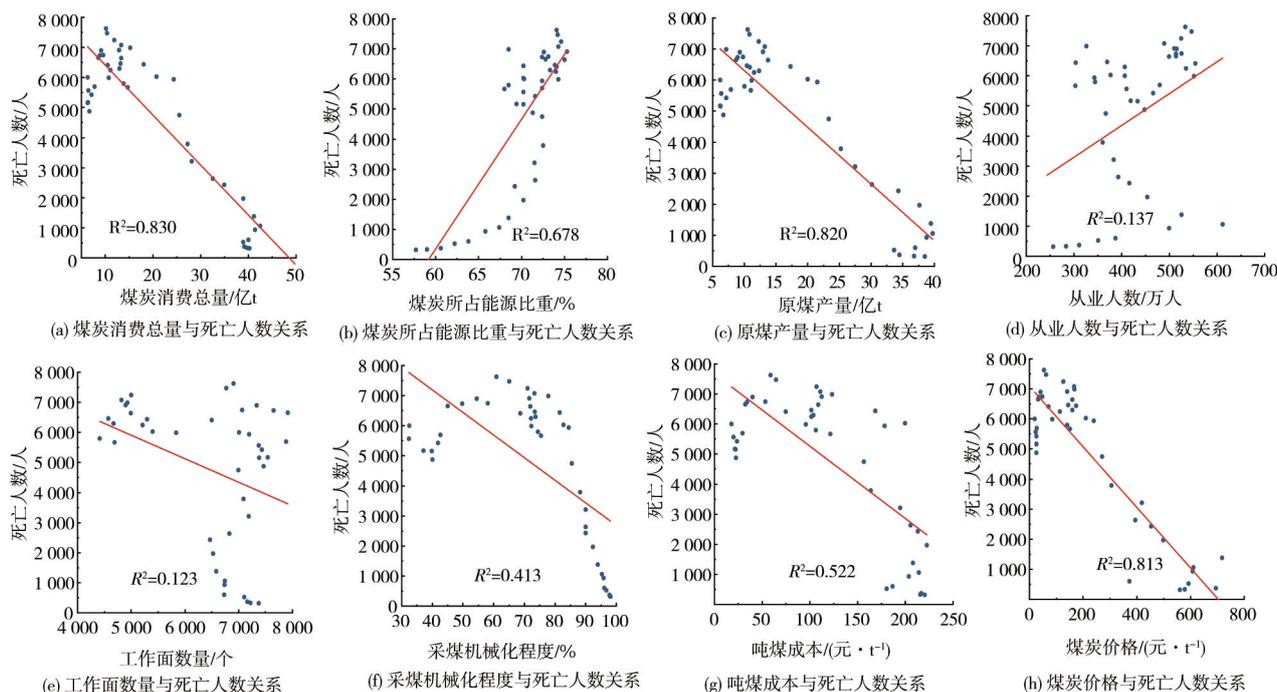


图1 死亡人数与各影响因素线性拟合

1.2 数据归一化处理与数据划分

由于各煤矿安全生产态势的影响因素均为数值型数据,若直接使用原始数据进行分析,高数量级的数据将主导模型的预测结果,势必弱化低数量级因素在模型中的作用.为充分挖掘各因素的特征,消除不同数据量纲对模型精度的影响,对数据进行归一化处理,归一化公式如式(1)所示.

$$y = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \tag{1}$$

式中: y 为归一化所得数据; x 为未归一化的数据; x_{\max} 为数据最大值; x_{\min} 为数据最小值.

在完成数据的归一化处理,对42组数据进行训练集与测试集的划分,训练集与验证集的比例为4:1.

1.3 研究方法

煤矿安全生产态势预测模型建立的流程如图2所示.

1)融合模型初选.不同的煤矿安全生产态势影响因素称为特征参数,采用特征选择算法获取特征参数组合,再将机器学习算法与特征参数组合相结合,建立煤矿安全生产态势的预测模型.对比预测结果与验证集数据,选取 R^2 均值大于等于0.850的算法^[15]以及特征参数组合,得到融合模型.

2)待调优融合模型选取.对初选所得融合模型的 N_{MSE} , M_{APE} 进行计算,在各机器学习算法与不同特征参数组合的融合模型中选取预测精度最高的融合预测模型作为待优化模型^[16-17].

3)融合模型参数调优.对待调优融合模型的超参数进行调优,进一步提升融合模型的预测精度.

4)融合模型预测.使用测试集数据对完成超参数调优的模型进行预测性能的验证,对比分析各项预测精度评价指标,得出最优融合模型.

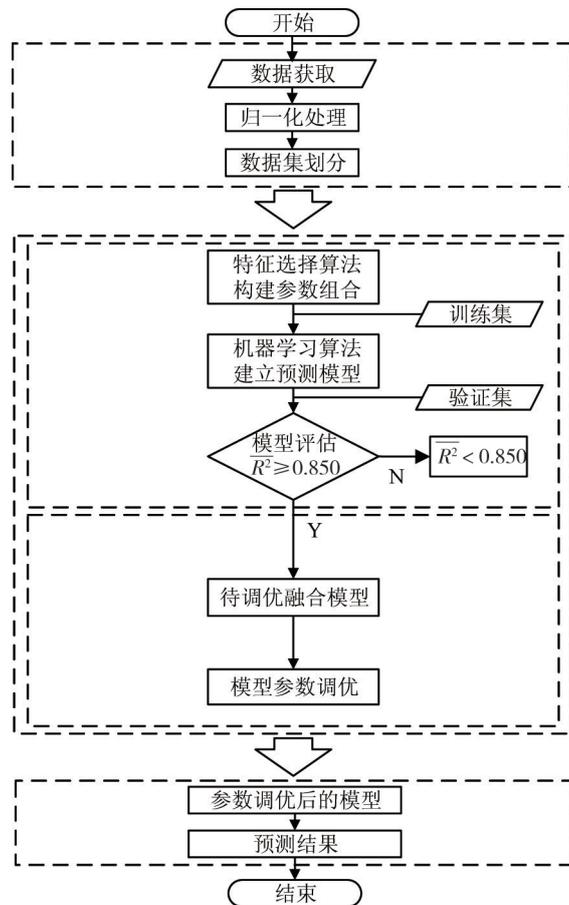


图2 预测模型建立流程

1.4 模型评价指标

本研究采用线性判定系数(R^2)、归一化均方误差(N_{MSE})和平均绝对百分比误差(M_{APE})来评价模型的精度.各指标的计算公式如式(2)~式(4)所示.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2}; \quad (2)$$

$$N_{MSE} = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2}; \quad (3)$$

$$M_{APE} = \frac{1}{n} \sum_{j=1}^n \left| \frac{\hat{y}_j - y_j}{y_j} \right| \times 100\%. \quad (4)$$

式中: n 为数据的数量; \hat{y}_i 为预测值; y_i 为真实值; \bar{y}_i 为真实值的均值.

2 融合预测模型的构建及验证

2.1 特征参数全子集筛选

研究表明:机器学习模型的预测精度并不会随着特征参数个数的增加而上升,而过少的特征参数又将导致模型的预测精度下降,过多的特征参数也将徒增计算成本^[18-20].因此,本文采用全子集回归与随机森林2种特征选择方法,根据组合效果与特征参数的重要性选择一系列特征参数组合,以求达到更好的预测效果.

全子集回归筛选是基于不同特征参数的所有可能的组合方式,对缩减后的特征参数组合通过最小二乘法进行拟合并在所得结果中选择校正 $R^2 > 0.900$ 的模型^[21],各特征选择方法的结果如图3所示.基于全子集回归筛选出的10种特征参数组合如图3a所示.由图3a可知:煤炭占能源消费的比重 X_2 与吨煤成本 X_7 存在于每个组合中,它们可能是煤矿安全生产态势的关键影响因素.

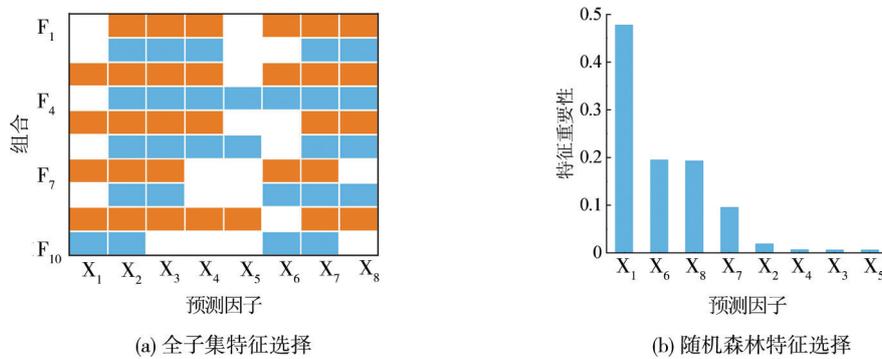


图3 各特征选择方法结果

使用随机森林算法对煤矿安全生产态势的8项特征参数进行轮询,建立预测模型评估准确率的下降幅度^[22-23].下降幅度越大,表示该特征对煤矿安全生产态势预测模型的影响越大,重要性越高.基于随机森林算法的特征参数重要性排序如图3b所示.由图3b可知:选取特征重要性大于0.01的特征参数,特征重要性排序从高到低分别为国内煤炭消费总量 X_1 、大型煤企采煤机械化程度 X_6 、煤炭价格 X_8 、吨煤成本 X_7 和煤炭占能源消费的比重 X_2 .

经全子集回归以及随机森林对8种影响煤矿安全生产态势的特征参数进行不同组合方式的选择,最终的特征参数组合如表2所示.表2中, F_0 为初始参数组合,即将前文所述的8项影响因素不经筛选,直接用于建模; $F_1 \sim F_{10}$ 为全子集回归筛选; F_{11} 为随机森林筛选;“☆”表示该组合选中的特征参数.

表2 煤矿安全生产态势特征参数组合

组合	X ₁	X ₂	X ₃	X ₄	X ₅	X ₆	X ₇	X ₈
F ₀	☆	☆	☆	☆	☆	☆	☆	☆
F ₁		☆	☆	☆		☆	☆	☆
F ₂		☆	☆	☆			☆	☆
F ₃	☆	☆	☆	☆		☆	☆	☆
F ₄		☆	☆	☆	☆	☆	☆	☆
F ₅	☆	☆	☆	☆			☆	☆
F ₆		☆	☆	☆	☆		☆	☆
F ₇	☆	☆	☆			☆	☆	
F ₈		☆	☆			☆	☆	☆
F ₉	☆	☆	☆	☆	☆		☆	☆
F ₁₀	☆	☆				☆	☆	
F ₁₁	☆	☆				☆	☆	☆

2.2 煤矿安全态势预测模型初选

采用4种机器学习算法对煤矿安全生产态势数据集进行学习,其中包括岭回归(RR)、分类与回归树(CART)2种传统机器学习算法,以及自适应提升(AdaBoost)、极端梯度提升(XGBoost)2种集成学习算法。

岭回归(RR)是目前较为流行的3种线性回归正则化方法之一,通过在损失函数中加入惩罚项来控制线性模型的复杂程度,RR虽然会在一定程度上影响回归系数估计的准确性,但能提高估计的稳定性;分类与回归树(CART)是目前决策树算法中最成熟的一类算法,预测时,CART使用最小方差来判定最优划分,确保划分后子集中样本点的均方误差最小,然后将数据集划分成多个子集,利用线性回归建模;自适应提升(AdaBoost)通过将多个基本算法加权组合形成一个强预测器,从而提升预测精度,目前该算法已成功应用于交通事故预测^[7]、采空区自然发火预测^[23]等领域;极端梯度提升(XGBoost)^[24]是Boosting算法的一种,因其具备较强的集合预测能力,超参数调优较简单等优点,被广泛应用于各类分类与回归问题中。

结合12种不同特征参数组合与4种机器学习算法,构建48种煤矿安全生产态势预测模型,其结果如表3所示。

表3 各算法应用各参数组合的结果

参数组合	各机器学习算法判定系数 R^2				各参数组合 R^2 均值
	RR	CART	AdaBoost	XGBoost	
F ₀	0.779	0.441	0.938	0.933	0.773
F ₁	0.785	0.746	0.928	0.898	0.839
F ₂	0.782	0.773	0.924	0.917	0.849
F ₃	0.814	0.884	0.937	0.916	0.888
F ₄	0.758	0.884	0.934	0.916	0.873
F ₅	0.807	0.765	0.925	0.927	0.856
F ₆	0.762	0.786	0.922	0.929	0.850
F ₇	0.811	0.743	0.949	0.919	0.856
F ₈	0.811	0.825	0.947	0.887	0.868
F ₉	0.779	0.610	0.932	0.940	0.815
F ₁₀	0.767	0.763	0.952	0.897	0.845
F ₁₁	0.783	0.782	0.941	0.897	0.851
各算法 R^2 均值	0.787	0.750	0.936	0.915	—

不同算法采用不同特征参数组合时,模型的判定系数 R^2 为 0.441~0.952,2类集成算法的表现均优于传统的机器学习算法,其中自适应提升(AdaBoost)表现最好, R^2 均值为 0.936,其次为极端梯度提升(XGBoost)算法, R^2 均值为 0.915,岭回归(RR)、分类与回归树(CART)这2类传统机器学习算法的 R^2 均

值分别为0.787与0.750。2类集成学习模型对于特征参数的选择并未展现出明显的依赖性,不同特征参数组合下,自适应提升(AdaBoost)的 R^2 为0.922~0.952,极端梯度提升(XGBoost)的 R^2 为0.887~0.940,岭回归(RR)模型对于不同特征参数组合也未表现出明显的依赖性,但其 R^2 数值较低,为0.758~0.814,而分类与回归树(CART)算法在不同特征参数组合下其 R^2 的波动较大, R^2 为0.441~0.884。

由表3可知: R^2 均值不小于0.850的特征参数组合有7种,分别为 $F_3, F_4, F_5, F_6, F_7, F_8, F_{11}$, R^2 均值不小于0.850的机器学习模型有AdaBoost和XGBoost,这2种算法的精度、稳定性与鲁棒性都较为理想。因此,初选煤矿安全生产态势的预测模型为AdaBoost和XGBoost,分别与上述7种特征参数进行组合,共得到14个预测模型。

2.3 煤矿安全态势预测模型优选

对初步选择得到的预测模型的 N_{MSE} 以及 M_{APE} 进行计算,结果如图4所示。图4中每组特征参数所对应的 N_{MSE} 以及 M_{APE} 值越大,则图中的色块就越接近外圆,反之,则接近内圆。图4a可知:自适应提升(AdaBoost)与 F_7 组合模型的 N_{MSE}, M_{APE} 最小;由图4b可知:极端梯度提升(XGBoost)与 F_5 组合模型的 N_{MSE}, M_{APE} 最小。因此,以这2组模型为研究对象,对模型进行超参数寻优。

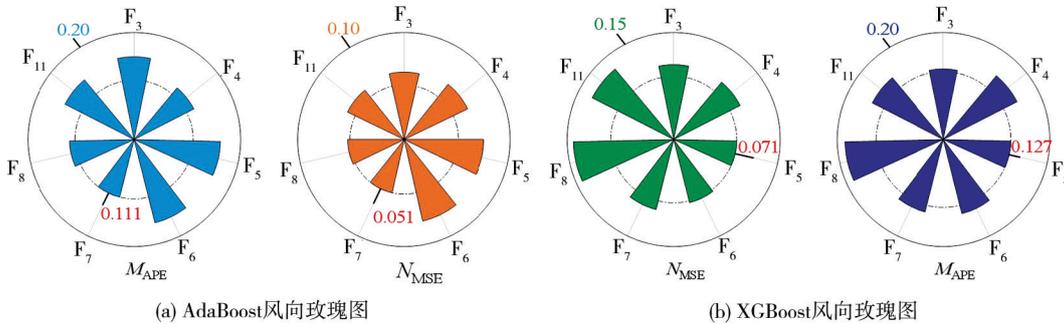


图4 AdaBoost与XGBoost的风向玫瑰图

2.4 优选模型参数调优

调用Python的Scikit-learn库与Hyperopt库,对模型优选所得的AdaBoost- F_7 模型与XGBoost- F_5 模型进行参数寻优。传统的超参数值选取方法是试凑法,此方法的效果好坏往往取决于调参人员的经验。本文在特征筛选的基础上,采用网格搜索(Grid Search, GS)与贝叶斯优化(Bayesian Optimization, BO)的方法分别对AdaBoost- F_7 模型与XGBoost- F_5 模型进行超参数寻优,在一定程度上消除人员经验的影响。由于在Scikit-learn库中不同算法的超参数会存在同名但含义不同的情况,2个模型超参数的含义与寻优结果如表4所示。

表4 超参数寻优结果

模型	寻优参数	参数含义	范围	GS	BO
AdaBoost- F_7	learning_rate	梯度收敛速度	[0.01,0.05,0.10,0.15,0.30,0.50,0.70,1.00]	0.05	0.70
	n_estimators	基分类器提升次数	[75,85,95,105,115,150]	95	105
	loss	更新权重的损失函数	['linear', 'square', 'exponential']	square	square
R^2	—	—	—	0.954	0.958
XGBoost- F_5	n_estimators	弱评估器的数量	[15,30,50,85,100,150]	30	85
	learning_rate	迭代决策树时的步长	[0.1,0.2,0.3,0.4,0.5,1.0]	0.3	0.4
	gamma	复杂度控制项	[0.001,0.005,0.006,0.007,0.010]	0.007	0.006
	max_depth	树的最大深度	[1,2,3,4,5,6,7]	1	5
R^2	—	—	—	0.966	0.955

由表4可知:经过超参数寻优之后,2组模型的预测精度均有一定提升,可以证明超参数寻优的有效性。针对AdaBoost- F_7 模型的参数寻优中BO优化的 R^2 为0.958,而XGBoost- F_5 模型经过参数寻优后的 R^2

达到 0.966,相较于优化前(0.927)提高了 4.2%,XGBoost 模型的参数寻优比 AdaBoost 模型的提升效果更加明显。

2.5 优选模型预测结果

通过验证集的 9 组数据对调优后融合模型的预测性能进行验证,预测结果与实际值的对比情况如图 5 所示,结果评价指标如表 5 所示。由表 5 可知:在验证集上,XGBoost- F_5 模型的 R^2 为 0.971,高于 AdaBoost- F_7 模型的 0.958,XGBoost- F_5 模型的 N_{MSE} , M_{APE} 都优于 AdaBoost- F_7 模型,分别为 0.029, 5.3%。因此,在本实例中 XGBoost- F_5 模型为最优融合预测模型。

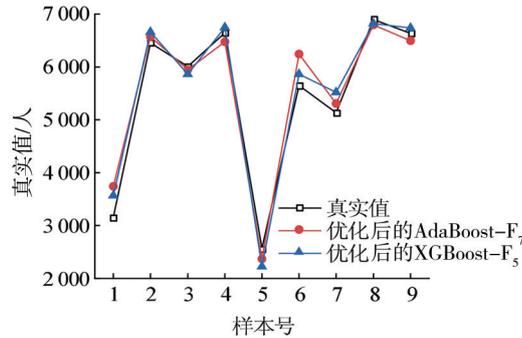


图5 各算法的预测值和实际值

表5 预测结果评价指标

模型	R^2	N_{MSE}	$M_{APE}/\%$
优化后的 AdaBoost- F_7	0.958	0.042	5.5
优化后的 XGBoost- F_5	0.971	0.029	5.3

3 结论

1)使用全子集回归与随机森林这 2 种特征选择算法得到 11 种煤矿安全生产态势影响因素的特征参数组合,其中采用全子集回归得到 10 种,采用随机森林得到 1 种。

2)不同算法与特征参数组合下的 48 种煤矿安全态势预测模型的 R^2 为 0.441~0.952,其中 R^2 均值不小于 0.850 的算法有自适应提升与极端梯度提升; R^2 均值大于 0.850 的特征参数组合有 F_3 , F_4 , F_5 , F_6 , F_7 , F_8 , F_{11} 。

3)经模型的初选、优选与参数寻优,得出 XGBoost- F_5 融合模型为煤矿安全态势预测的最优模型,其 R^2 为 0.971, N_{MSE} 为 0.029, M_{APE} 为 5.3%。

参考文献:

- [1] 李生才,笑蕾.2020 年 11—12 月国内生产安全事故统计分析[J].安全与环境学报,2021,21(1):447-449.
- [2] 吴孟龙,叶义成,胡南燕,等.基于模糊信息粒化的矿业安全生产态势区间预测[J].中国安全科学学报,2021,31(9):119-127.
- [3] 叶黎明,施式亮,鲁义,等.基于 ARIMA 和 XGBoost 算法的煤矿安全态势预测[J].安全,2022,43(2):53-59.
- [4] 兰建义,乔美英,周英.煤矿事故预测的马尔可夫 SCGM(1,1)模型的建立与应用[J].安全与环境学报,2016,16(5):6-9.
- [5] 白楠,金龙哲,詹子娜.基于 B/S 和灰色模型的煤矿事故预测模块设计与实现[J].中国安全生产科学技术,2013,9(3):113-118.
- [6] 施式亮,李润求,念其锋.煤矿安全状况关键指标变化特征的 R/S 分析[J].中国安全科学学报,2012,22(9):79-84.
- [7] 纪俊红,昌润琪,温廷新.基于 GSK-AdaBoost-LightGBM 的交通事故死亡人数预测研究[J].安全与环境工程,2021,28

- (1):24-28.
- [8] 张建荣,张伟,薛楠楠,等.基于随机森林算法的塔式起重机安全事故预测及致因分析[J].安全与环境工程,2021,28(5):36-42.
- [9] KERIM K, ÖMER E, ASLI P G. Accident prediction in construction using hybrid wavelet-machine learning[J]. Automation in Construction, 2022,133:103987.
- [10] 郭玉梅,王高锋.生产安全事故调查处理中若干问题探讨:兼论《生产安全事故报告和调查处理条例》有关规定[J].华北科技学院学报,2015,12(6):66-72.
- [11] 煤炭工业部安全司.中国煤矿伤亡事故统计分析资料汇编:1949—1995年[M].北京:煤炭工业出版社,1998.
- [12] 靳运章.我国煤矿事故特征规律及组合预测模型研究[D].西安:西安科技大学,2016.
- [13] 赵来军,陶悦.城市安全生产影响因素及其预测分析:以上海为例[J].中国安全科学学报,2012,22(6):8-13.
- [14] LIU Q, LIU J, GAO J, et al. An empirical study of early warning model on the number of coal mine accidents in China[J]. Safety Science, 2020,123:104559.
- [15] 徐涵秋,孙凤琴,徐光志.高分五号卫星高光谱 AHSI 和多光谱 VIMI 传感器辐亮度数据的交互对比[J].武汉大学学报(信息科学版),2021,46(7):1032-1043.
- [16] 戴健非,杨鹏,诸利一,等.集成 PCA 和 LSTM 神经网络的浸润线预测方法[J].中国安全科学学报,2020,30(3):94-101.
- [17] 林海飞,周捷,高帆,等.基于特征选择和机器学习融合的煤层瓦斯含量预测[J].煤炭科学技术,2021,49(5):44-51.
- [18] XUE B, HE Y, JING F, et al. Robot target recognition using deep federated learning[J]. International Journal of Intelligent Systems, 2021, 36(12): 7754-7769.
- [19] XUE B, TONG N. Real-world ISAR object recognition using deep multimodal relation learning[J]. IEEE Transactions on Cybernetics, 2020, 50(10): 4256-4267.
- [20] 黄春桃,范东平,卢集富,等.基于深度学习模型的广州市大气 PM_{2.5} 和 PM₁₀ 浓度预测[J].环境工程,2021,39(12):135-140.
- [21] 朱勤,彭希哲,陆志明,等.人口与消费对碳排放影响的分析模型与实证[J].中国人口·资源与环境,2010,20(2):98-102.
- [22] XUE B, YI W, JING F, et al. Complex ISAR target recognition using deep adaptive learning[J]. Engineering Applications of Intelligence, 97: 104025.
- [23] 赵琳琳,温国锋,邵良杉.不平衡数据下的采空区煤自燃 PCA-AdaBoost 预测模型[J].中国安全科学学报,2018,28(3):74-78.
- [24] CHEN T Q, GUESTRIN C. XGBoost: A Scalable Tree Boosting System[C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining,2016:785-794.