

基于常规测井与可解释机器学习的深部煤系地层煤层识别与含煤性评价

李向东, 刘 阳

安徽理工大学地球与环境学院, 安徽 淮南

收稿日期: 2026年6月22日; 录用日期: 2026年7月29日; 发布日期: 2026年8月5日

摘 要

针对深部煤系地层中薄煤层、夹研发育及纵向变化快造成的煤层边界识别和层段含煤性评价问题, 基于某盆地东部某区块多井常规测井资料与已有解释结果, 建立煤层概率识别和含煤性评价流程。模型输入包括AC、CAL、DEN、CNL、GR、RD、RS、SP和PE共9条常规曲线, 以已有解释结论构建煤/非煤标签, 采用类别加权L2正则化逻辑回归和留一井验证评价井间适用性; 在单点特征基础上, 进一步采用11个采样点的滑动窗口提取均值和标准差, 以表征纵向上下文。结果表明, 单点模型总体AUC为0.9867、召回率为0.9601; 窗口模型总体AUC和召回率分别为0.9931和0.9668, 但精确率有所下降, 说明邻域统计有助于减少漏判, 同时会扩大待复核范围。传统阈值法对典型煤层响应较为保守, 概率模型则更适合筛选薄层、边界和响应不典型层段。通过概率分级、连续厚度约束、短间隔合并及井径质量复核, 可将深度点输出转化为层段含煤性评价依据。该流程用于常规解释基础上的概率复核和层段量化, 不能替代人工综合解释。

关键词

深部煤系地层, 煤层识别, 含煤性评价, 常规测井, 逻辑回归, 滑动窗口

Coal Seam Identification and Coal-Bearing Evaluation in Deep Coal Measures Based on Conventional Logging and Interpretable Machine Learning

Xiangdong Li, Yang Liu

文章引用: 李向东, 刘阳. 基于常规测井与可解释机器学习的深部煤系地层煤层识别与含煤性评价[J]. 矿山工程, 2026, 14(5): 1201-1208. DOI: 10.12677/me.2026.145118

Abstract

Thin coal seams, abundant partings and rapid vertical variations complicate coal-boundary identification and interval-scale coal-bearing evaluation in deep coal measures. Multi-well conventional logs and existing interpretations from an eastern block of a sedimentary basin were used to establish a probabilistic workflow. Nine logs (AC, CAL, DEN, CNL, GR, RD, RS, SP and PE) were used as predictors. Coal and non-coal labels were derived from existing interpretations, and class-weighted L2-regularized logistic regression was assessed by leave-one-well-out validation. Means and standard deviations within an 11-sample sliding window were further introduced to represent vertical context. The point model achieved an overall AUC of 0.9867 and recall of 0.9601. The context model increased AUC and recall to 0.9931 and 0.9668, respectively, while precision decreased, indicating fewer missed coal responses but a broader review range. The conventional threshold method remained conservative for typical coal responses, whereas probability output was more suitable for screening thin seams, boundaries and atypical intervals. Probability grading, continuity constraints, short-gap merging and borehole-quality checks were combined to support interval-scale coal-bearing evaluation. The workflow is intended for probabilistic review rather than as a replacement for integrated manual interpretation.

Keywords

Deep Coal Measures, Coal Seam Identification, Coal-Bearing Evaluation, Conventional Logging, Logistic Regression, Sliding Window

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

深部煤系地层通常具有煤层厚度小、夹矸发育、煤与泥质或灰质围岩频繁互层等特点,煤层边界和层段含煤性在纵向上变化较快。常规测井曲线对煤层有较为明确的响应基础——典型煤层常表现为低密度、高声波时差、高补偿中子和较高电阻率,但在泥质夹层、井径扩大、矿物组分变化或曲线质量不均一的井段,这些响应会发生重叠。因此,煤层解释不仅要识别典型煤层点,还需将深度点的判断转化为累计煤厚、含煤系数、单层厚度和夹矸发育程度等层段尺度指标。

前人在煤系地层沉积背景、煤储层测井响应和煤体结构评价方面已做了不少工作。相关沉积演化研究表明,煤系地层受海陆过渡相沉积控制,岩性组合和煤层发育具有明显的非均质性[1];煤岩气储层及煤系气研究进一步指出,煤层厚度、岩性组合和储盖配置是认识深部煤系地层的重要基础[2]-[5]。在测井评价方面,电阻率、密度、井径、声波时差和自然伽马等曲线已被用于煤层物性、煤体结构和煤储层特征分析[6]-[10]。近年来,随机森林等机器学习方法也逐渐引入煤体结构识别和测井分类研究,为多曲线综合解释提供了新途径[11]。

需要说明的是, 机器学习并不天然优于常规测井解释。对于煤层这类测井响应相对明确的对象, 若仅用传统阈值自动生成标签, 再以相同曲线训练模型, 很容易陷入对已有规则的重复拟合。本文将机器学习的作用限定为辅助工具: 一是利用多条曲线共同约束煤层概率, 降低单一阈值在曲线重叠区的局限性; 二是通过留井验证检验模型在井间的稳定性; 三是将深度点的煤层概率转化为层段含煤性指标。这样处理后, 模型输出不作为唯一解释结论, 而是与已有解释结果和测井响应机理共同构成含煤性评价的依据。

基于上述考虑, 本文选取某盆地东部某区块多井的处理后测井资料和已有煤层解释结果, 构建类别加权逻辑回归模型, 开展深部煤系地层煤层识别与含煤性评价。研究重点并非重新证明常规曲线能够识别典型煤层, 而是在已有解释成果约束下建立可复核、可解释并可转换为层段指标的评价流程。单点模型用于刻画各深度点的综合响应, 滑动窗口模型用于检验上下文信息的增量作用, 整体技术路线见图 1。




Figure 1. Workflow for coal seam identification and coal-bearing evaluation

图 1. 煤层识别与含煤性评价技术路线

2. 方法与评价流程

2.1. 资料基础与评价对象

研究资料来自某盆地东部某区块的多井处理后测井数据。为保证模型输入与解释目标相互独立, 本文仅使用 AC、CAL、DEN、CNL、GR、RD、RS、SP 和 PE 共 9 条常规测井曲线作为输入变量; 已有综合解释中的煤层与非煤层结论仅用于构建标签和检验方法, 不参与模型训练。评价重点放在方法流程、总体识别能力及地质适用边界。

煤层标签依据已有综合解释结论建立。考虑到煤层样本相对稀少, 模型训练采用类别加权, 并在井级分组条件下完成数据填补、标准化和验证。已有解释用于形成方法评价基准, 但其并非独立岩心验证, 因此模型输出仅表示对现有煤层解释结论的概率逼近。

2.2. 测井响应分析

煤层与非煤层的测井响应差异是建立模型的地质基础。典型煤层通常表现为低密度、高声波时差、较高中子响应和相对较高电阻率, 该组合响应与煤层物性和含流体特征的常规认识一致[12]。不同测井变量对煤层与非煤层的稳健区分程度见图 2。该图用于说明多曲线联合输入的依据, 不作为单曲线阈值的替代。

自然伽马对煤层、炭质泥岩和泥质夹层的响应存在重叠, 井径变化与围岩影响还可能削弱单曲线判别的稳定性。因此, 本文采用多曲线联合输入, 由模型综合表达各变量的条件贡献, 并将单曲线响应作为地质合理性检查而非唯一判据。




Figure 2. Robust separation indices of logging variables between coal and non-coal samples
图 2. 煤层与非煤层测井变量稳健差异指数

2.3. 模型构建

考虑到研究井数有限且相邻深度采样点相关性较强, 本文选用结构简洁、参数可解释的逻辑回归作为主模型[13], 并将随机森林等非线性模型作为方法讨论中的参照[14]。设标准化后的测井特征向量为 $\mathbf{x}$, 模型输出煤层概率 $p = 1 / (1 + \exp[-(\mathbf{w} \cdot \mathbf{x} + b)])$, 其中 $\mathbf{w}$ 为特征权重, b 为截距。输入曲线的缺失值仅用训练井中位数填补, 并按训练井均值和标准差进行标准化, 避免测试井信息进入训练过程。

由于煤层样本比例较低, 训练时采用类别加权策略, 使煤层和非煤层在损失函数中具有相近贡献。模型采用 L2 正则化, 学习率为 0.08, 迭代 3200 次, 正则化系数为 0.02。分类阈值取 0.5, 同时保留连续概率曲线。单点模型的变量贡献采用标准化回归系数解释, 系数符号反映条件效应方向, 绝对值用于比较相对贡献; 此类解释需与变量相关性和单变量响应共同判断[15]。

验证方式采用留井验证, 即每次选取一口井作为测试井, 其余井作为训练井, 循环完成全部测试后汇总总体指标。该方式比随机深度点划分更为严格, 因为同一井内相邻采样点高度相关, 随机划分会高估模型的实际泛化能力。评价指标包括准确率、精确率、召回率、F1 值、特异度、平衡准确率和 AUC。为检验机器学习结果的增量价值, 设置传统阈值法作为对比: $DEN < 1.8$ 、 $AC > 300$ 且 $CNL > 30$ 时判为煤层。该阈值组合仅作为保守型常规响应基准, 不代表人工解释的全部过程。

2.4. 上下文特征构建

单点特征不能直接描述煤层与围岩在纵向上的连续变化。为引入邻域信息, 本文以目标深度点为中心设置 11 个采样点的滑动窗口。在 0.1 m 采样间隔下, 该窗口覆盖目标点上下各约 0.5 m。对 9 条曲线分别计算窗口均值和标准差, 并与 9 个原始单点值共同构成 27 维输入。均值用于表征邻域总体响应, 标准差用于表征煤层边界、夹矸和曲线突变。

窗口统计在每口井内部独立计算, 不跨越井界; 井段两端采用实际可用邻点计算。窗口特征构建后仍采用留一井验证, 缺失值填补和标准化参数仅由当前训练井估计。该设置保证测试井标签和统计参数

不进入模型训练, 同时允许比较单点模型与上下文模型在同一验证框架下的差异。

2.5. 含煤性指标

在深度点煤层识别结果基础上, 进一步计算层段含煤性指标。累计煤厚 H_c 为评价井段内连续煤层采样点厚度之和, 评价厚度 H 为该井段顶底深度差, 含煤系数 $K_c = H_c/H$ 。将连续煤层点合并为单层煤, 统计煤层层数和最大单层煤厚; 当相邻煤层之间非煤间隔不超过 0.5 m 时, 将其作为夹矸或薄非煤夹层参与夹矸比例计算。上述指标可将点状识别结果转换为便于井间比较的层段尺度结果。

预测累计煤厚和含煤系数不是对已有解释结果的替代。模型输出按概率和层段连续性分级使用: $P < 0.50$ 记为非煤响应; $0.50 \leq P < 0.80$ 列为待复核层段; $P \geq 0.80$ 列为高置信度煤层响应。连续厚度不足 0.3 m 的孤立响应不直接形成煤层结论, 相邻候选层段间非煤间隔不超过 0.2 m 时可合并复核。最终边界仍需结合原岩性解释、传统阈值结果、井径质量以及 GR、DEN、AC、CNL 和电阻率曲线综合确定。

2.6. 概率输出应用流程

实际应用时, 首先检查曲线完整性和井径异常, 再获得逐点煤层概率。概率低于 0.50 的井段一般不进入煤层复核; 0.50~0.80 的井段优先检查薄煤层、夹矸及边界过渡; 概率不低于 0.80 且与传统阈值或原解释一致的连续井段, 可作为高置信度响应。对模型与阈值法不一致的层段, 应回到原始曲线判断其是否受井径扩大、围岩效应或解释边界影响。

完成层段复核后, 再计算累计煤厚、含煤系数和煤层层数。概率值仅表示样本在当前模型和训练资料条件下接近煤层标签的程度, 可用于安排复核优先级和比较井间相对变化, 不能解释为煤质等级、资源丰度或最终地质结论。跨区应用时应重新校准概率阈值和层段合并规则。

3. 方法验证与应用分析

3.1. 总体识别性能

留一井验证表明, 9 曲线单点模型的总体 AUC 为 0.9867、召回率为 0.9601, 说明模型能够较完整地筛选已有解释中的煤层响应。由于训练采用类别加权, 模型更强调减少煤层漏判, 部分炭质泥岩、泥质夹矸及曲线异常段也可能进入候选范围。因此, 总体准确率不作为主要判断依据, 0.5 阈值下的二元结果亦不能直接等同于最终煤层边界。

井间响应差异提示, 模型性能受煤层样本稀缺、非煤样本占比高、测井曲线重叠以及井眼条件变化共同影响。概率曲线的主要用途是统一复核尺度和提示疑似层段, 而不是依据单一分类结果替代人工解释。

3.2. 上下文特征的作用

引入 11 点滑动窗口后, 模型总体 AUC 提高至 0.9931, 召回率提高至 0.9668, 但精确率有所下降, 主要指标的相对变化见图 3。该结果表明, 邻域均值和标准差能够增强连续煤层及边界过渡带的响应, 同时也会把更多相邻非煤点纳入候选层段。

因此, 窗口模型更适合用于生成较完整的复核范围, 而不宜仅凭二元分类结果扩大煤层厚度。含煤性指标应优先依据经层段复核的单点概率结果计算, 窗口输出则作为薄层连续性和边界敏感性的补充证据。

3.3. 与传统阈值法的关系

传统阈值法对低密度、高声波时差和高中子等典型煤层响应更为保守, 误判相对较少, 但对薄煤层、边界煤层及响应不典型层段更容易漏判。两类逻辑回归模型提高了候选层段的覆盖程度, 同时增加了人

工复核工作量。三种方法的总体性能关系见图 3。

机器学习在本文中的定位是补充常规判煤规则。传统阈值法与高概率模型结果一致的连续井段可优先确认；阈值法未识别而模型概率较高的井段列为重点复核对象；模型单独识别出的零散响应则结合连续厚度和井径质量剔除或降权。该流程强调概率分级和人工复核，不以单一精度指标判定方法优劣。




Figure 3. Overall performance comparison of different identification methods

图 3. 不同识别方法总体性能对比

3.4. 测井变量贡献及地质解释

单点模型的变量贡献显示，AC、GR 和 CNL 对概率输出具有较强影响，SP 和电阻率曲线提供补充信息。AC 和 CNL 的贡献方向与煤层高声波时差、较高中子响应相一致；GR 的条件贡献总体反映较高自然伽马会降低煤层概率，但其与炭质泥岩和泥质夹层仍存在响应重叠，不能独立作为稳定判据。

密度曲线的独立贡献相对有限并不意味着其缺少地质意义。多变量模型中的系数反映其他变量受控条件下的增量作用，密度响应可能已被声波、中子和光电吸收等相关曲线共同表征。因此，变量解释需要结合图 2 所示的单变量区分程度、曲线相关性和煤层测井响应机理综合判断。

3.5. 概率输出与含煤性评价

含煤性评价不直接采用模型预测煤厚的绝对值，而是按照“概率分级 - 连续性检查 - 传统解释复核 - 层段指标计算”的顺序实施。高置信度连续响应优先核对边界，中等概率或方法间不一致的层段进入重点复核，孤立且厚度不足的响应不形成煤层结论。完成复核后，再计算累计煤厚、含煤系数和煤层层数等层段指标。

该处理可避免高召回、低精确率条件下候选层段对煤厚和含煤系数的直接放大。层段指标的作用是统一描述经复核后的煤层发育程度，而不是输出未经解释确认的资源量或煤质结论。

综合已有解释、传统阈值法和模型概率，可将多种证据一致的连续响应作为高置信度煤层候选，将概率中等或方法间不一致的层段作为待复核对象。图 4 以 M-3 井代表性井段示意关键曲线、原岩性解释、

传统阈值结果、单点模型概率和二元分类结果的并列使用方式。该图用于说明层段复核过程，不用于报告逐井煤厚或含煤系数。




Figure 4. Integrated logging interpretation of a representative interval in well M-3
图 4. M-3 井代表性井段综合测井解释成果

4. 讨论

常规测井曲线能够有效识别典型煤层，这是本文方法成立的前提。若任务仅是识别响应清晰的煤层点，传统阈值和人工解释更直接；当任务扩展到井间一致的概率表达、边界层段复核和含煤性指标计算时，多曲线模型才具有补充价值。机器学习并未在所有评价指标上优于传统阈值法，尤其在扩大候选范围后精确率受到影响，不能表述为对常规解释的替代。

逻辑回归结构透明、参数可解释，对少井资料的要求相对较低。11 点窗口将纵向邻域信息引入模型后，AUC 和召回率有所提高，但精确率下降，说明上下文信息既可平滑薄层边界，也可能把夹矸、炭质泥岩和边界围岩纳入候选层段。窗口宽度决定平滑尺度：窗口过小难以反映连续性，过大则可能跨越薄层组合。本文采用约 1.0 m 窗口仅用于敏感性比较，不能据此认定该尺度在其他地区同样最优。

煤层概率较高但已有解释为非煤的井段，可能来自炭质泥岩或薄夹矸的相似响应、井径扩大造成的曲线异常，或者已有解释采用了较保守的边界。单点模型和窗口模型均不能区分上述原因，窗口模型还会因邻域统计把边界响应向围岩延伸。因此，概率结果应与井径、曲线组合和层段连续性共同复核，并在计算煤厚前执行最小厚度和短间隔合并规则。

从深度点分类转向层段含煤性评价，需要把概率、连续性和地质解释结合起来。本文提出的三级概率规则用于安排复核优先级：高置信度层段优先核对边界，待复核层段重点检查薄煤和夹矸，孤立低厚

度响应不进入最终煤厚统计。该流程可减少假阳性对含煤系数的直接放大, 但阈值仍属于当前样本条件下的操作规则, 应用于其他区块前需重新验证。

受资料条件限制, 本文没有独立的沉积相、体系域或层序位置标签, 因而不能对模型性能与沉积相或层序位置进行分组统计, 也不能证明模型在不同地质背景下具有相同适用性。现有留一井结果仅反映当前资料范围内的井间迁移效果。后续研究需引入经过独立解释的沉积相和层序位置资料, 分析不同岩性组合、煤层边界位置及井眼条件下的误差分布, 并采用跨区验证重新确定概率阈值、窗口尺度和层段合并规则。

5. 结论

(1) 典型煤层总体表现为高声波时差、低密度、较高中子响应和相对较高电阻率, 自然伽马在煤层与非煤层之间存在重叠。多曲线联合输入有助于降低单一阈值受围岩和夹矸影响产生的不稳定性。

(2) 9 曲线单点逻辑回归模型在留一井验证下的总体 AUC 和召回率分别为 0.9867 和 0.9601; 11 点窗口模型的 AUC 和召回率分别提高至 0.9931 和 0.9668, 但精确率有所下降。上下文信息可减少漏判, 也会扩大待复核范围。

(3) AC、GR 和 CNL 是影响单点模型概率输出的主要变量, SP 和电阻率曲线提供补充信息。变量贡献总体符合煤层测井响应认识, 但多变量系数受曲线相关性影响, 需要与单变量响应和地质机理共同解释。

(4) 将煤层概率按非煤、待复核和高置信度三级表达, 并结合最小连续厚度、短间隔合并、传统阈值和井径质量复核, 可将深度点结果转化为层段含煤性评价依据。由于缺少独立沉积相和层序标签, 模型的地质适用边界仍需通过跨区资料进一步验证。

参考文献

- [1] 范萌萌, 袁珍, 李文厚, 等. 鄂尔多斯盆地延安地区本溪组高分辨率层序地层与沉积特征[J]. 西北大学学报(自然科学版), 2024, 54(6): 1050-1064.
- [2] 刘翰林, 邹才能, 尹帅, 等. 中国煤系气形成分布、甜点评价与展望[J]. 天然气工业, 2024, 44(10): 1-21.
- [3] 赵喆, 徐旺林, 赵振宇, 等. 鄂尔多斯盆地石炭系本溪组煤岩气地质特征与勘探突破[J]. 石油勘探与开发, 2024, 51(2): 234-247, 259.
- [4] 刘新社, 黄道军, 虎建玲, 等. 鄂尔多斯盆地中东部地区石炭系本溪组煤岩气储层特征[J]. 天然气工业, 2024, 44(10): 51-62.
- [5] 张正涛, 费世祥, 罗文琴, 等. 鄂尔多斯盆地东部本溪组煤岩气储集层评价及甜点区优选[J]. 新疆石油地质, 2025, 46(3): 263-272.
- [6] 葛祥, 李涛. 煤层物性测井评价方法初探[J]. 测井技术, 2003, 27(2): 129-131, 177.
- [7] 孟召平, 刘珊珊, 王保玉, 等. 晋城矿区煤体结构及其测井响应特征研究[J]. 煤炭科学技术, 2015, 43(2): 58-63, 67.
- [8] 付玉通, 张伟, 李永臣, 等. 鄂东南地区深部煤层气煤体结构测井评价研究[J]. 中国煤炭, 2017, 43(9): 31-34, 47.
- [9] 梅放, 康永尚, 李喆, 等. 中高煤阶煤层煤体结构识别测井法适用性评价研究[J]. 煤炭科学技术, 2019, 47(7): 95-107.
- [10] 李松林, 逢建东, 金力钻, 等. 煤体结构测井评价在煤层气开发中的应用[J]. 测井技术, 2021, 45(2): 173-178.
- [11] 肖航, 张占松, 郭建宏, 等. 基于随机森林结合地球物理测井资料的煤体结构识别方法及应用[J]. 科学技术与工程, 2021, 21(24): 10174-10180.
- [12] 高笑琳. 煤层气测井响应特征的识别与评价[J]. 价值工程, 2021, 40(18): 180-181.
- [13] Hosmer, D.W., Lemeshow, S. and Sturdivant, R.X. (2013) Applied Logistic Regression. 3rd Edition, Wiley. <https://doi.org/10.1002/9781118548387>
- [14] Breiman, L. (2001) Random Forests. *Machine Learning*, 45, 5-32. <https://doi.org/10.1023/a:1010933404324>
- [15] Molnar, C. (2020) Interpretable Machine Learning. Lulu Press.