北京林业大学学报
JOURNAL OF BEIJING FORESTRY UNIVERSITY

基于ChatGPT的科尔沁沙地杨树人工林健康评价

郭艳荣 王懿祥 海龙 张志东 刘磊 杨宏伟 刘洋

Health assessment of poplar plantations in the Horqin Sandy Land, Inner Mongolia of northern China based on ChatGPT

Guo Yanrong, Wang Yixiang, Hai Long, Zhang Zhidong, Liu Lei, Yang Hongwei, Liu Yang

引用本文:
郭艳荣, 王懿祥, 海龙, 张志东, 刘磊, 杨宏伟, 刘洋. 基于ChatGPT的科尔沁沙地杨树人工林健康评价[J]. 北京林业大学学报, 2025, 47(7):117–128. doi: 10.12171/j.1000–1522.20250014
Guo Yanrong, Wang Yixiang, Hai Long, Zhang Zhidong, Liu Lei, Yang Hongwei, Liu Yang. Health assessment of poplar plantations in the Horqin Sandy Land, Inner Mongolia of northern China based on ChatGPT[J]. Journal of Beijing Forestry University, 2025, 47(7):117–128. doi: 10.12171/j.1000–1522.20250014

在线阅读 View online: https://doi.org/10.12171/j.1000–1522.20250014

您可能感兴趣的其他文章
Articles you may be interested in

科尔沁沙地杨树水分利用策略
Strategies on water utilization of poplar in Horqin Sandy Land of northern China
北京林业大学学报, 2018, 40(5): 63–72. https://doi.org/10.13332/j.1000–1522.20170430

基于机器学习的落叶松毛虫发生面积预测模型
Studies on prediction models of *Dendrolimus superans* occurrence area based on machine learning
北京林业大学学报, 2017, 39(1): 85–93. https://doi.org/10.13332/j.1000–1522.20160205

基于Landsat TM数据的大兴安岭盘古林场森林健康评价
Forest health assessment of Pangu Forest Farm based on Landsat TM in Great Xing’an Mountains of northeastern China
北京林业大学学报, 2021, 43(4): 87–99. https://doi.org/10.12171/j.1000–1522.20200067

机器学习技术在风景园林中的应用进展与展望
Application progress and prospect of machine learning technology in landscape architecture
北京林业大学学报, 2021, 43(11): 137–156. https://doi.org/10.12171/j.1000–1522.20200313

应用遥感技术评价森林健康的路径和方法
Pathway and method of forest health assessment using remote sensing technology
北京林业大学学报, 2021, 43(9): 1–13. https://doi.org/10.12171/j.1000–1522.20210107

机器学习算法在森林生长收获预估中的应用
Applications of machine learning algorithms in forest growth and yield prediction
北京林业大学学报, 2019, 41(12): 23–36. https://doi.org/10.12171/j.1000–1522.20190356

DOI:10.12171/j.1000−1522.20250014

基于 ChatGPT 的科尔沁沙地杨树人工林健康评价

郭艳荣[1]　王懿祥[2]　海　龙[3]　张志东[4]　刘　磊[1]　杨宏伟[3]　刘　洋[1]
（1. 内蒙古农业大学林学院，内蒙古 呼和浩特 010019；2. 浙江农林大学环境与资源学院，浙江 杭州 311300；3. 内蒙古自治区林业科学研究院，内蒙古 呼和浩特 010010；4. 河北农业大学林学院，河北 保定 071000）

摘要:【目的】现有森林健康评价方法在处理复杂多维数据时存在局限性，难以准确反映森林健康的真实状况。针对这个问题，本研究提出一种结合 ChatGPT 大语言模型与机器学习算法的新型评价框架，以优化森林健康评价方法，并探索影响科尔沁沙地杨树（*Populus* spp.）人工林健康的关键指标。**【方法】**基于地面调查数据与森林景观照片，构建了包含 15 个指标的综合健康评价体系，利用 ChatGPT 模型通过 few-shot 学习实现健康等级预测，并结合 YOLOv5 提取图像视觉特征进一步优化健康评估结果，同时采用 *K* 均值聚类自动划分森林健康等级。此外，通过 DeepSeek 大语言模型、模糊综合评价法以及 8 种机器学习模型对 ChatGPT 预测结果进行交叉验证和比较，并利用 SHAP 分析方法识别影响森林健康的主导因子。**【结果】**科尔沁沙地杨树人工林健康等级所占比例依次为中健康（53.3%）> 不健康（21.7%）> 亚健康（20.7%）> 健康（4.3%），森林整体处于中健康状态。DeepSeek 模型的预测准确率为 76.1%；ChatGPT 的预测结果与传统方法（模糊评价法）无显著差异（$p = 0.29$）；8 种机器学习模型中，随机森林分类模型的验证准确率最高，达到 84.2%。研究识别出林分平均高和土壤有机碳密度为影响森林健康的主要指标。**【结论】**本研究构建的基于 ChatGPT 与多源数据融合的森林健康评价方法科学可靠，能够有效提升森林健康等级划分的准确性和解释性，为干旱半干旱地区人工林健康监测与管理提供了新思路。

关键词：杨树人工林；森林健康评价；森林经营；ChatGPT；DeepSeek；机器学习；变量重要性；SHAP
中图分类号：S750　　**文献标志码：**A　　**文章编号：**1000−1522(2025)07−0117−12
引文格式：郭艳荣，王懿祥，海龙，等. 基于 ChatGPT 的科尔沁沙地杨树人工林健康评价［J］. 北京林业大学学报，2025，47(7)：117−128. Guo Yanrong, Wang Yixiang, Hai Long, et al. Health assessment of poplar plantations in the Horqin Sandy Land, Inner Mongolia of northern China based on ChatGPT［J］. Journal of Beijing Forestry University, 2025, 47(7): 117−128.

Health assessment of poplar plantations in the Horqin Sandy Land, Inner Mongolia of northern China based on ChatGPT

Guo Yanrong[1]　Wang Yixiang[2]　Hai Long[3]　Zhang Zhidong[4]　Liu Lei[1]　Yang Hongwei[3]　Liu Yang[1]
(1. College of Forestry, Inner Mongolia Agricultural University, Hohhot 010019, Inner Mongolia, China;
2. College of Environment and Resources, Zhejiang A & F University, Hangzhou 311300, Zhejiang, China;
3. Inner Mongolia Academy of Forestry, Hohhot 010010, Inner Mongolia, China;
4. College of Forestry, Hebei Agricultural University, Baoding 071000, Hebei, China)

Abstract: ［**Objective**］ Conventional forest health assessment methods face limitations when handling complex, high-dimensional data, making it difficult to accurately reflect the true state of forest health. To address the issue, this paper proposes a novel assessment framework integrating the ChatGPT large language model with machine learning algorithms to improve forest health assessment and identify key indicators affecting the health of poplar (*Populus* spp.) plantations in the Horqin Sandy Land, Inner Mongolia of

收稿日期: 2025−01−14　**修回日期:** 2025−03−10
基金项目: 内蒙古自治区科技计划项目（2021GG0370）。
第一作者: 郭艳荣，博士，讲师。主要研究方向：林分级森林健康评价。Email: gyr163@163.com　地址：010019 内蒙古呼和浩特学苑东街 275 号内蒙古农业大学林学院。
责任作者: 刘洋，副教授。主要研究方向：森林生长模型模拟。Email: liuyangvip@hotmail.com　地址：同上。
本刊网址: http://j.bjfu.edu.cn; http://journal.bjfu.edu.cn

northern China. [**Method**] A comprehensive health evaluation system comprising 15 indicators was developed using field survey data and forest landscape images. The ChatGPT model was applied for health level prediction via few-shot learning. YOLOv5 was used to extract visual features from images to enhance assessment accuracy. *K*-means clustering was employed to automatically classify forest health levels. Additionally, the predictions from ChatGPT were cross-validated and compared using the DeepSeek large language model, a fuzzy comprehensive evaluation method, and eight machine learning models, respectively. SHAP analysis was used to identify the main factors affecting forest health. [**Result**] The proportions of forest health levels in poplar plantations were as follows: moderate health (53.3%) > unhealthy (21.7%) > sub-healthy (20.7%) > healthy (4.3%), indicating an overall moderately healthy forest condition. The prediction accuracy of DeepSeek model was 76.1%. No significant difference was observed between the results of ChatGPT and the traditional fuzzy evaluation method (p = 0.29). Among the eight machine learning models, the random forest classifier achieved the highest validation accuracy of 84.2%. Stand mean height and soil organic carbon density were identified as the main factors influencing forest health. [**Conclusion**] The proposed ChatGPT-based evaluation approach, integrated with multi-source data, is scientifically reliable and effectively enhances both the accuracy and interpretability of forest health classification. This method provides a new pathway for monitoring and managing the health of plantations in arid and semi-arid regions.

Key words: poplar plantation; forest health assessment; forest management; ChatGPT; DeepSeek; machine learning; variable importance; SHAP

森林经营的宗旨是实现森林可持续经营，而提升森林健康程度是实现这一目标的重要途径。森林健康通常是指在特定的经营目标下，生物和非生物因子处于动态平衡状态，不会对森林资源的当前稳定性及未来森林可持续经营构成威胁。健康的森林不仅为人类提供能源、木材和食物，还提供储存碳，承载生物多样性和调节气候等服务[1]。我国是世界上人工林面积最大的国家，人工林面积达 6 200 万 hm^2，约占我国森林总面积的 31.8%[2]。科尔沁沙地是我国面积最大的沙地，生态环境十分脆弱，治理该区的沙化问题主要依赖于杨树(*Populus* spp.)。杨树是我国干旱半干旱地区主要造林树种，在防风固沙[3]、涵养水源[4]等方面发挥着重要作用。因此，杨树人工林的健康问题对于科尔沁沙地生态修复至关重要，健康的杨树人工林是持续发挥生态系统功能的基础，也是维持该区域森林生态系统可持续发展的重要环节。此外，提升杨树人工林健康程度还是实现我国双碳目标的重要途径，对杨树人工林健康状况进行合理的评价，可为科尔沁沙地减弱沙化问题提供基础数据，并为合理的杨树人工林经营措施提供科学依据。

近年来，森林健康评价指标体系的研究已取得显著进展，但由于评价区域和评价对象的不同，所使用的评价方法也存在较大差异。目前，森林健康评价的方法主要可分为以下 5 类。第一类是主观赋权法，包括层次分析法和专家打分法。例如：徐梅等[5]在分析侧柏(*Platycladus orientalis*)人工林健康状况时，采用层次分析法构建了由 10 个指标组成的评价体系；董灵波等[6]也使用熵值−层次分析法构建了大兴安岭地区盘古林场单木尺度健康评价模型。专家打分法则是早期学者们进行森林健康常用的方法。然而，主观赋权法高度依赖先验知识，且基于研究者的主观经验对指标进行权重赋值，忽视了指标间的相互影响关系。第二类属于客观赋权法，包括粗糙集法、灰色关联度法和主成分分析法。例如：刘素芝等[7]采用粗糙集理论方法分析了湖南省大围山自然保护区 8 个次生林群落和 2 个人工林健康状况，其评价结果不依赖专家经验。张德成等[8]在评价辽东山区落叶松中龄林涵养水源效益时，采用了灰色关联度法；赵金满等[9]运用主成分分析法计算了塞罕坝自然保护区华北落叶松(*Larix gmelinii*)和樟子松(*Pinus sylvestris*)人工林健康指数。客观赋权法根据指标的关联度或原始数据信息客观赋权，但没有充分考虑到各参评要素对评价的重要程度。第三类是主客观相结合赋权法，主要有模糊综合评价法。例如：郭艳荣等[10]、王忠春[11]使用模糊综合评价法分别实现了内蒙古中部山地油松(*Pinus tabuliformis*)人工林、长白山区金沟岭林场林分级森林健康评价。尽管主客观相结合赋权法结合了两者的优点，但同一评价对象若使用不同权重赋值方法，仍可能会导致评价结果不一致的问题。第四类是综合评价法。虽然对不同的森林类型进行评价时应选择合适的评

价方法[12], 但由于森林生态系统的复杂性, 即使同一森林类型采用单一的评价方法也很难对健康状况进行客观评价, 目前有关森林健康评价多采用多个方法综合进行评价。然而, 综合评价法需要合理选择和确定评价指标及权重, 若指标体系不科学可能会影响评价结果, 且在处理高维、多变量数据时存在很大的困难。第五类是结构方程模型方法。例如: 曹小玉等[13]采用此方法对杉木(*Cunninghamia lanceolata*)纯林、杉木混交林及天然次生林的森林健康状况进行了评价。该方法利用因果关系建模, 可用于揭示指标之间的复杂关系和赋权, 但需要大量的样本数据支持, 前期数据采集成本高。

综上所述, 现阶段每种森林健康评价方法均存在一定的缺陷, 可能导致评价结果不够科学。因此, 如何找出一种客观、合理、准确且成本低的方法来评价科尔沁沙地杨树人工林的健康状况, 已成为一个亟待解决的科学问题。鉴于此, 本研究将基于 ChatGPT 大语言模型对科尔沁地区杨树人工林进行综合健康评价, 并利用 DeepSeek 大语言模型、模糊评价法及机器学习算法对 ChatGPT 预测的森林健康进行对比验证。通过这种方法, 本研究旨在探索一种更精准的评估手段, 以期为科尔沁地区杨树人工林的健康程度评估提供新的思路, 并为该区域森林可持续经营的理论研究提供参考依据。

1　基于 ChatGPT 的森林健康评价

1.1　研究区概况和数据来源

科尔沁沙地是中国最大的沙地, 位于西辽河冲积平原, 总面积约 5.6 万 km^2。杨树作为该区域的重要造林树种, 因其生长快、效益高、用途广等优势, 已成为人工造林的核心树种, 对当地生态建设与环境治理具有重要作用。

在对科尔沁沙地杨树人工林踏查的基础上, 于 2023 年 7 月在科尔沁沙地的南缘、西缘共设置不同龄组(幼龄林、中龄林、近熟林、成熟林)杨树人工林临时标准地 64 块, 标准地面积大小为 0.09 ~ 0.20 hm^2。记录每块样地经纬度、海拔、坡度、坡向等环境因子, 对直径 > 5 cm 乔木进行每木检尺调查, 并测定树高, 记录树种名称。每块样地调查结束后, 计算样地的平均直径(D_g), 并在树高曲线(树高曲线的具体绘制方法请参考文献 [14])上查定每块样地的林分平均树高(H_D)。依据 D_g、H_D(误差不超过 ± 5%)选取 3 株干形中等的树木作为标准木, 依据标准木的年龄估算林分平均年龄(具体方法参见文献 [15])。在每块样地沿对角线设置 3 个 2 m × 2 m 具有代表性的样方, 记录灌木的种类、调查灌木层的盖度、株数、地径、高度等; 在每个 2 m × 2 m 的样方内设置 1 m × 1 m 的样方, 调查草本层种类、盖度和高度。2024 年 7 月在科尔沁沙地的腹地设置不同龄组杨树人工林临时标准地 28 块, 调查内容与 2023 年样地调查内容相同。

在每块样地的 4 个角设置土壤取样点, 并挖取土壤剖面(30 cm × 30 cm × 30 cm), 去除土壤表层的枯枝落叶, 按 0 ~ 10 cm、10 ~ 20 cm 分两层采集土样, 每块样地共采集 8 份土壤样品(4 次重复)。将每块样地同一深度的土样混合, 得到两个不同深度的土样, 通过孔径 2 mm 筛, 去除可见的植物杂质和小石子, 将所采土样装入无菌塑料袋中待测。同时在每个样地的 4 个样方内挖剖面, 用环刀自上到下选取 0 ~ 10 cm、10 ~ 20 cm 土样, 测定土壤容重。土壤容重的测定采用烘干法[16]。土壤的有机碳含量使用重铬酸钾容量法–外加热法测定[16]。

1.2　评价指标

1.2.1　评价指标的选择

评估结果的科学性和准确性在很大程度上取决于评估指标体系的完备程度。在选择评估指标时, 必须遵循客观性、全面性和可操作性这 3 个原则[9]。首先, 指标的选择应充分考虑被调查对象的特性以及林分的实际状况, 确保能够客观地反映森林的特性。其次, 指标体系应结合前人的研究成果, 尽可能完整地涵盖森林的各个方面, 但同时要避免指标之间的重复, 着重选择那些对森林健康具有关键影响的指标。最后, 所选指标应便于在实际调查中获取, 计算过程应简单明了, 以便为后续研究提供清晰的指导, 并能够在实践中得到广泛推广应用。

基于上述原则, 本文以科尔沁沙地杨树人工林为研究对象, 借助 ChatGPT 进行指标体系的构建。例如, 通过设置提示词 “根据上述 3 个原则(将上述 3 个原则传给 ChatGPT), 基于森林健康和森林生态学知识, 搜索国内外文献, 且要求文献真实存在, 请提供一套用于森林健康评价的指标体系, 并按重要性排序” 。结合内蒙古自治区地方标准 DB15/T 3386—2024《森林健康监测与评价技术规程》, 最终选择生产力、组织结构、生态脆弱性和抵抗力 4 类属性的 15 个指标。具体指标见表 1。

1.2.2　评价指标的计算

基于树木胸径和树高, 采用二元立木材积方程[17](式 1)计算材积, 将各林木的材积合计后除以样地面积得到林分单位面积蓄积量(m^3/hm^2)。

$$V = 0.000\,041\,960\,698 D^{1.909\,459\,5} H^{1.041\,389\,2} \quad (1)$$

式中: V 为单木株材积, D 为胸径, H 为树高。

表 1 森林健康状况评价指标体系

Tab. 1 Evaluation index system for forest health status

序号	评价指标	属性	序号	评价指标	属性
1	林分平均胸径	生产力指标（6个）	9	灌木盖度	生态脆弱性指标（4个）
2	林分平均高		10	草本盖度	
3	林分蓄积量		11	草本的Simpson指数	
4	土层厚度		12	枯枝落叶层厚度	
5	腐殖质厚度		13	天然更新	抵抗力指标（3个）
6	土壤有机碳密度		14	病虫害	
7	株数密度	组织结构指标（2个）	15	火险等级	
8	群落结构				

由于表层 0 ~ 20 cm 土层含有大部分的生物活性碳[18]，尤其在温带棕色针叶林土壤中，它可以储存高达 57% 的总土壤碳[19]。因此，本文只估算了表层 0 ~ 10 cm、10 ~ 20 cm 土壤有机碳密度。土壤有机碳密度的计算方法为

$$D_{SOC} = \sum_{i=1}^{n} \rho_i C_i D_i (1-\theta_i) \times 10^{-1} \quad (2)$$

式中：D_{SOC} 为 0 ~ 20 cm 土层深度的土壤有机碳密度（Mg/hm^2），ρ_i 为第 i 层土壤容重（g/cm^3），C_i 是第 i 层有机碳含量（g/kg），D_i 是第 i 层土层深度（cm），θ_i 为第 i 层 > 2 mm 的砾石体积百分比，n 为土层数。

本文所选物种多样性指标为草本的 Simpson 指数。

$$D = 1 - \sum p_i^2 = 1 - \sum (N_i/N)^2 \quad (3)$$

式中：p_i 为草本第 i 种的个体所占所有种的个体总数的比例，N_i 为草本样方内第 i 物种的个体数；N 为样方内所有种的个体总数。

本文通过主要树种、郁闭度、海拔、平均枝下高 4 个亚指标确定火险等级。根据燃烧的难易程度，将主要树种分为难燃类（等级为 1）、可燃类（等级为 2）和易燃类（等级为 3）[20]。在本研究中，所有树种均为可燃类。郁闭度越大，林内的光线减弱，湿度增大，不易燃烧；海拔越高，温度越低，林木越不易燃烧；林木平均枝下高较低时，遇到地表火，极易引起林冠火[21]，本研究中郁闭度、海拔、平均枝下高的火险等级依据表 2 确定。

基于 4 个亚指标的火险等级，通过公式（4）计算各样地的综合指数[21−22]后，由表 3 查出研究区各样地的燃烧等级。

$$R = X_1 + X_2 + X_3 + X_4 \quad (4)$$

式中：R 表示综合指数，X_1、X_2、X_3 和 X_4 分别表示主要树种、林分郁闭度、海拔和林木平均枝下高的火险等级。

使用 R 语言 summary 函数和 psych 包中的 describe 函数对森林健康评价原始数据集进行描述性统计分析（表 4）和 Spearman 相关性分析。

表 2 森林防火等级

Tab. 2 Forest fire prevention levels

等级	1	2	3	4	5
郁闭度	> 0.6	0.5 ~ 0.6	0.4 ~ 0.5	0.3 ~ 0.4	0.1 ~ 0.3
海拔/m	> 1 400	800 ~ 1 400	< 800		
平均枝下高/m	> 2.5	2.0 ~ 2.5	1.5 ~ 2.0	1.0 ~ 1.5	< 1

表 3 燃烧等级

Tab. 3 Combustion levels

燃烧等级	1	2	3	4	5
综合指数 R	≤ 4	4 ~ 8	8 ~ 12	12 ~ 16	16 ~ 20
描述	不燃	难燃	可燃	易燃	强燃

1.3 基于 ChatGPT 的森林健康等级划分

本研究以科尔沁地区杨树人工林的 15 个评价指标（包括林分平均胸径、林分平均高、林分蓄积量、土层厚度、腐殖质厚度、土壤有机碳密度、株数密度、群落结构、灌木盖度、草本盖度、Simpson 指数、枯枝落叶层厚度、天然更新、病虫害和火险等级）为基础，结合人工拍摄和无人机拍摄的森林景观照片，利用基于 Transformer 架构的 ChatGPT 模型进行综合健康评价。ChatGPT 经过大量文本与数据训练，具备类比与归纳能力。在本研究中，基于 few-shot 学习原理，ChatGPT 在少量带标签数据引导下对 92 个样地的结构化文本进行分类预测，其机理可类比为嵌入空间中的语义映射，将变量与健康等级之间的非线性关系转化为语言模型中的分类任务。

具体而言，该模型是一个结合了数据预处理、特征提取和多变量相关性分析的分类模型。数据预处理包括对缺失值变量使用中位数填充，采用 Z-score 标准化方法进行数据归一化以均衡不同尺度变量的影响，以及利用箱型图识别并剔除异常值。特征提

表 4　森林健康状况评价指标描述性统计

Tab. 4　Descriptive statistics of evaluation indicators for forest health status

变量	样本量	平均值	标准差	最小值	第一四分位数	中位数	第三四分位数	最大值
林分平均胸径/cm	92	12.6	4.4	5.6	9.2	12.1	15.7	23.8
林分平均高/m	92	13.9	4.5	5.1	10.5	14.1	17.6	22.6
林分蓄积量/($m^3 \cdot hm^{-2}$)	92	100.5	66	9.5	40.9	86.7	158.2	214.9
土层厚度/cm	92	58.1	14	22.3	47.6	58.1	67.6	98.3
腐殖质厚度/cm	92	58.1	14	22.3	47.6	58.1	67.6	98.3
土壤有机碳密度/($Mg \cdot hm^{-2}$)	92	62.8	11.6	37	53.7	61.6	70.8	91.5
株数密度/(株数·hm^{-2})	92	1 093	370	271	832	1 105	1 341	1 988
群落结构	92							
灌木盖度/%	92	5	2.9	1	2.8	4	7	10
草本盖度/%	92	17.7	7.7	5	11	17	25	30
Simpson指数	92	7.3	3.7	1.4	4.4	7.4	10.4	13.4
枯枝落叶层厚/cm	92	4	1.7	0.5	2.8	4.2	5.3	7.2
天然更新等级	92	2	0.8	1	1	2	3	3
病虫害等级	92	2	0.8	1	1	2	3	3
火险等级	92	2.9	1.4	1	2	3	4	5

取阶段，提示 ChatGPT “结合森林健康和森林生态学知识，对 15 个指标进行重要性排序，并识别变量之间的潜在关系，以便准确构造复合变量（森林健康指数）”。模型的核心思想是通过 Bootstrap 抽样法生成多个子数据集，在每个子数据集上训练决策树，并通过多数投票法预测因变量。因变量的预测是通过将各变量转化为健康指数实现的，相应的提示词为“请根据所有特征预测森林健康等级”，这使得模型能够综合考虑所有特征，从而提高泛化能力。此外，利用机器学习中的 *K* 均值聚类实现健康等级的自动划分。

图像数据用于补充变量信息，通过视觉特征优化健康评估结果。在数据建模过程中，通过 YOLOv5 目标检测模型提取图片中的视觉特征，输出株数密度、树木外观、病虫害和火烧迹象 4 个指标的置信度，用于后续的健康评估。通过对每块样地进行综合分析和分类，确保分类的准确性和科学性。最终，将 92 块样地的森林健康等级划分为 4 类，即 “1”（健康）、“2”（亚健康）、“3”（中健康）和 “4”（不健康）。

2　多方法的比较验证

本文采用 DeepSeek 大语言模型、模糊评价法和机器学习法，对基于 ChatGPT 的科尔沁沙地杨树人工林健康等级评价结果进行比较验证。

2.1　DeepSeek 大语言模型

DeepSeek 大语言模型对森林健康等级的评价方法与 ChatGPT 相同，此处不再重复赘述。

2.2　模糊评价法

模糊评价法的具体应用可参照郭艳荣等[10]的研究，其利用模糊综合评价法对内蒙古中部山地油松人工林进行了森林健康评价。鉴于篇幅限制，本文不再详细展开。

2.3　机器学习法

2.3.1　机器学习模型概述

本文采用了 8 种机器学习方法：*K* 近邻分类（KNeighbors classifier）、逻辑回归（logistic regression）、多层感知分类（MLP classifier）、决策树分类（decision tree classifier）、随机森林分类（random forest classifier）、自适应提升分类（AdaBoost classifier）、自助法袋装分类（bagging classifier）以及轻量级梯度提升机（LightGBM）模型。其中，*K* 近邻分类模型通过测量样本之间的距离，将未知样本归类为其最近的 *K* 个邻居中最常见的类别，是一种不依赖概率分布的非参数方法[23]。逻辑回归模型则利用对数几率函数建模，将自变量的线性组合输入到 Sigmoid 函数中，将结果映射到 [0, 1] 区间，表示样本属于某一类别的概率，并采用最大似然估计法优化模型参数[24]。多层感知分类模型通过多个包含激活函数的隐藏层对输入数据进行非线性变换，并利用反向传播算法调整权重以最小化预测误差，从而实现复杂模式的分类[25]。决策树分类模型基于树结构，利用信息增益等准则递归选择最优特征，将数据划分为子集，并构建一系列可解释的判断规则以实现分类[26]。随机森林分类模型是一种基于决策树的

集成学习算法，通过集成多个弱分类器来提高模型的泛化能力、鲁棒性和预测精度[27]。自适应提升分类模型是一种提升算法，通过在每轮迭代中训练一个弱分类器，并根据其预测错误率调整样本权重，使后续的弱分类器更加关注先前难以正确分类的样本，最终将多个弱分类器按其性能加权组合为一个强分类器，从而显著提高整体预测精度[28]。自助法袋装分类模型通过对原始训练集进行自助采样生成多个子集，分别训练多个基分类器，并通过投票或平均集成预测结果，以降低模型的方差，并提升不稳定学习算法的泛化性能[29]。轻量级梯度提升机模型是基于梯度提升框架的高效实现，采用基于叶子生长的策略和直方图优化技术，适合大规模数据和高维特征，具有训练速度快、精度高的特点[30]。这些方法涵盖了不同的算法原理和应用场景，能够为研究提供多角度的分析和验证。

2.3.2 机器学习模型预测性能的评价指标

本文采用准确率、精确率、召回率、F_1 值和 AUC 值来评估 8 种机器学习分类模型的预测性能。准确率(A)是指所有样本中预测正确的比例，反映了模型整体的分类准确程度。精确率(P)关注的是预测为正类的样本中实际为正类的比例，衡量了模型预测正类的准确性。召回率(R)则是指所有实际正样本中被正确预测的比例，反映了模型对正类的识别能力。F_1 值是精确率和召回率的调和平均，皆在评估分类模型的效果，取值范围为 [0, 1]，值越接近 1 表示模型性能越好。这些指标通过混淆矩阵计算得出，其中通常将关注的类定义为正类，其余为负类。

$$A = \frac{T_P + T_N}{T_P + T_N + F_P + F_N} \times 100\% \tag{5}$$

$$P = \frac{T_P}{T_P + F_P} \times 100\% \tag{6}$$

$$R = \frac{T_P}{T_P + F_N} \times 100\% \tag{7}$$

$$F_1 = \frac{2PR}{P + R} \times 100\% \tag{8}$$

式中：T_P 表示正确分类为正类的样本数，T_N 表示正确分类为负类的样本数，F_P 表示错误分类为正类的样本数，F_N 表示错误分类为负类的样本数。

除上述公式(5)～(8)的评价指标，本文还采用受试者工作特征曲线(receiver operating characteristic curve，ROC 曲线)及其下的面积(AUC 值)作为综合评价指标来衡量模型的预测性能。ROC 曲线通过混淆矩阵中的参数绘制而成，具体是通过逐步增大分类阈值，计算真阳性率(R_{TP})和假阳性率(R_{FP})。其中，$R_{TP} = T_P/(T_P + F_N)$，表示正确分类为正类的比例；$R_{FP} = F_P/(F_P + T_N)$，表示错误分类为正类的比例。AUC 值衡量 ROC 曲线下的面积，其值越接近 1，表明模型的性能越好。

3 森林健康的指标重要性排序

本文通过 SHAP 值对 8 种机器学习分类模型中的最优分类模型的森林健康影响因素进行解释分析，以增强模型的可解释性。SHAP 值主要用于量化每个特征对模型预测的贡献。其核心思想是：首先计算某一特征加入模型时的边际贡献，接着评估该特征在不同特征组合中的边际贡献变化，最终通过求取所有边际贡献的均值来确定该特征的 SHAP 值。

假设第i个样本为x_i，第i个样本的第j个特征为x_{ij}，特征的边际贡献为C_{ij}，边的权重为w_i，其中$f(x_{ij})$为x_{ij}的 SHAP 值。例如，第i个样本的第 1 个特征的 SHAP 值计算为

$$f(x_{i1}) = C_{i1}w_1 + \cdots + C_{i1}w_n \tag{9}$$

模型对该样本的预测值为y_i，整个模型的基线(通常是所有样本的因变量的均值)为y_{base}，那么 SHAP value 服从以下等式。

$$y_i = y_{base} + f(x_{i1}) + f(x_{i2}) + \cdots + f(x_{is}) \tag{10}$$

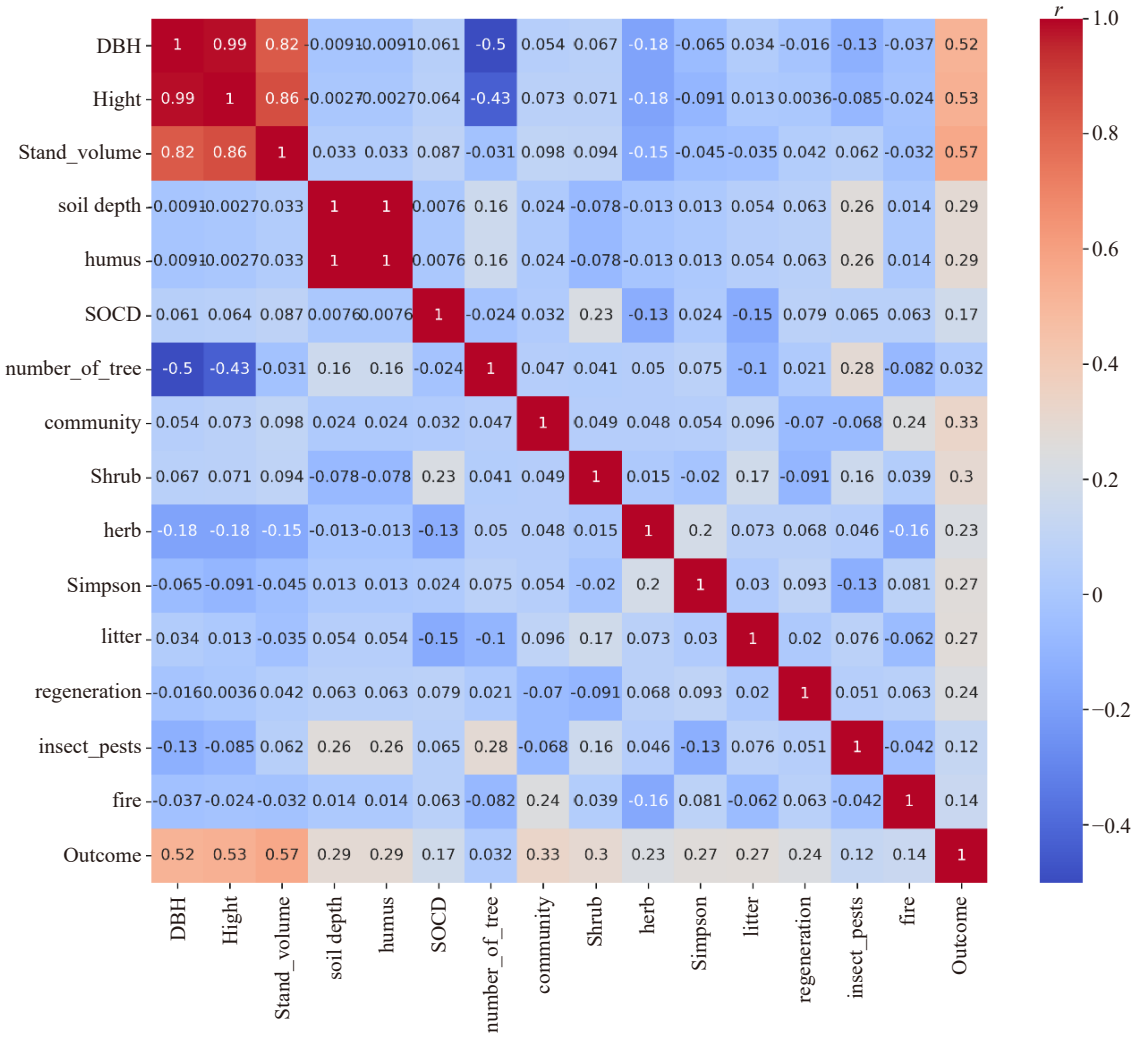
式中：$f(x_{i1})$就是第i个样本中第 1 个特征对最终预测值 y_i 的贡献值，每个特征的 SHAP 值反映了以该特征为条件时模型预测的变化，解释了实例的平均模型预测与实际预测之间的差异。当$f(x_{i1}) > 0$，说明该特征提升了预测值，反之，说明该特征降低了预测值。

传统方法(如随机森林分类模型)只能反映特征的重要程度，但无法明确该特征对预测变量的具体影响力。而 SHAP 值的最大优势在于能够量化样本中每一个自变量对因变量的影响力，并明确其影响的正负性。本文所有的数据分析采用 Python v.3.13.1[31]完成。

4 结果与分析

4.1 森林健康与各指标的相关性

基于 Spearman 相关分析，森林健康状况与多种评价指标存在显著相关性(图 1)。其中，生产力指标(如林分平均胸径、平均高和蓄积量)与森林健康呈显著正相关(相关系数分别为 0.52、0.53 和 0.57)，表明林分生产力是森林健康的重要驱动因素。此外，土壤生产力指标(土层厚度和腐殖质厚度)与森林健康的相关系数均为 0.29，进一步强化了土壤质量对森林健康的贡献。在组织结构指标中，群落结构(相



DBH 为林分平均胸径，Hight 为林分平均高，Stand_volume 为林分蓄积量，soil depth 为土层厚度，humus 为腐殖质厚度，SOCD 为土壤有机碳密度，number_of_tree 为株数密度，community 为群落结构，Shrub 为灌木盖度，herb 为草本盖度，Simpson 为 Simpson 指数，litter 为枯枝落叶层厚，regeneration 为天然更新，insect_pests 为病虫害，fire 火险等级，Outcome 为森林健康。

图 1　森林健康状况与影响因素间的 Spearman 相关系数

Fig. 1　Spearman correlation coefficients between forest health status and influencing factors

关系数为 0.33)表现出较高的正相关性，说明生态系统的复杂性对森林健康具有积极作用；而株数密度(相关系数为 0.032)的相关性较弱，可能单独难以反映健康状况。生态脆弱性指标(如草本盖度和灌木盖度，相关系数均为 0.23)以及 Simpson 指数(相关系数为 0.27)与森林健康呈正相关，显示植被多样性和覆盖度在降低生态脆弱性方面的作用。在抵抗力指标中，天然更新(相关系数为 0.24)对森林健康的贡献较为突出，而病虫害(相关系数为 0.12)和火险等级(相关系数为 0.14)虽然对健康有负面影响，但相关性较弱。综合来看，生产力、组织结构和生态系统抵抗力的综合作用对森林健康的维持具有关键作用。

4.2　基于 ChatGPT 的科尔沁沙地杨树人工林健康评价

将 92 个样地的 15 个变量格式化为文本输入，以便 ChatGPT 能够识别数据模式(即让 ChatGPT 学习 92 个样地的数据模式)。通过 few-shot learning 提供部分标注数据，利用 ChatGPT 进行分类预测，并结合 YOLOv5 提取图像视觉特征以优化评估结果。基于 ChatGPT 构建的综合健康评价模型得出的结果显示，各健康等级样地占全部样地的比例依次为中健康(53.3%) > 不健康(21.7%) > 亚健康(20.7%) > 健康(4.3%)。这表明科尔沁沙地杨树人工林整体处于中健康状态(图 2a)。此外，随着土壤有机碳密度的降低，林分健康等级逐渐下降(图 2b)。在科尔沁沙地，健康的森林群落结构类型较完整，而群落结构越简单，森林健康状况越差(图 2c)。

4.3　多方法比较验证

4.3.1　DeepSeek 模型和模糊评价法

在保持与 ChatGPT 相同的提示词、样地变量输入以及 few-shot learning 配置的基础上，DeepSeek 模型的预测准确率为 76.1%，且在预测“健康”与

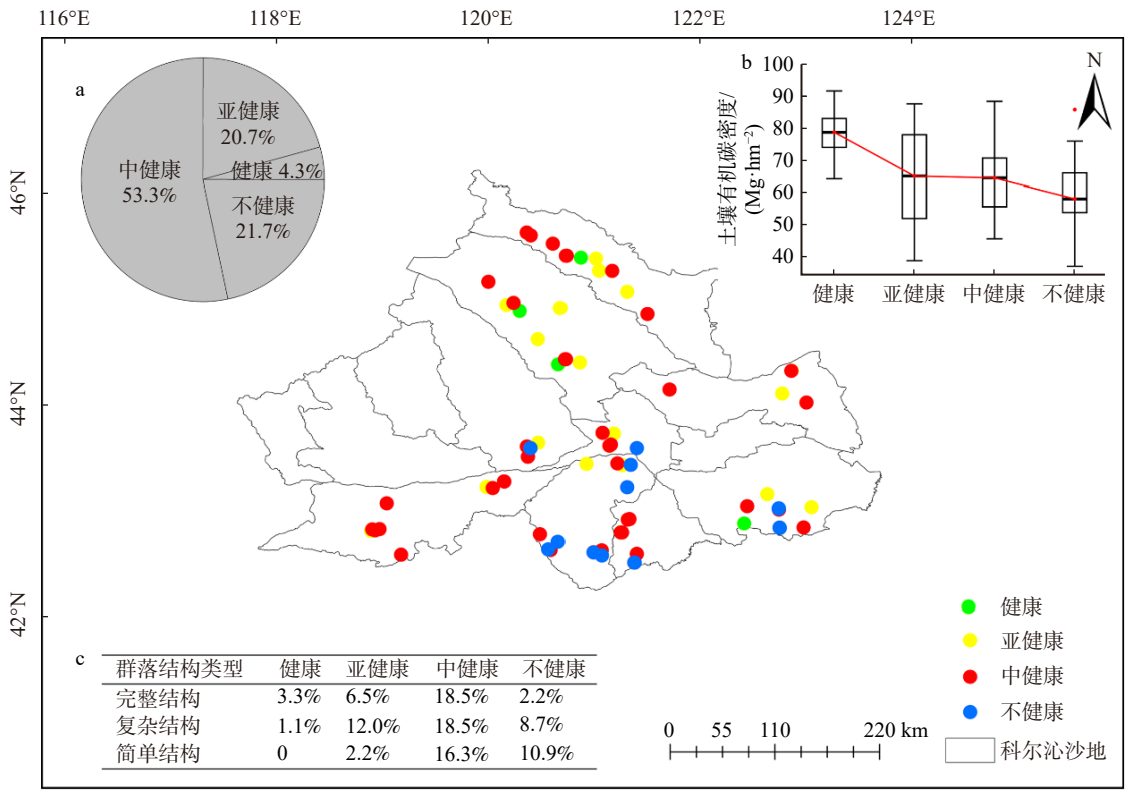


图 2 科尔沁沙地杨树人工林样地森林健康等级分布

Fig. 2 Distribution of forest health levels in poplar plantation plots in the Horqin Sandy Land

“亚健康”等级上表现出更高的分类一致性(kappa 系数为 0.69)。同时，本文还采用森林健康评价的典型方法模糊评价法对科尔沁沙地杨树人工林的健康等级进行计算，并与 ChatGPT 预测的森林健康等级进行比较。由于本文的健康等级数据不满足正态分布，因此采用非参数 Wilcoxon 秩和检验来比较二者之间的差异性。结果显示，两种方法得到的 92 块样地健康等级的差异性不显著($p = 0.29$, $p > 0.05$)，这进一步证实了利用 ChatGPT 预测的森林健康等级的准确性。

4.3.2 8 种机器学习模型

为了评估不同机器学习方法在森林健康状态验证中的表现，本文采用十折交叉验证法对 8 种算法进行了比较(表 5)。结果显示：随机森林模型表现最为出色，其准确率达到 84.2%，F_1 值为 80.6%，显著高于其他模型(表 5 和图 3)。逻辑回归和多层感知分类模型的综合表现分别位列第二和第三，准确率分别为 73.7% 和 68.4%。相比之下，轻量级梯度提升机和自适应提升分类模型的表现较差，尤其是轻量级梯度提升机，其准确率仅为 52.6%，精确率和 F_1 值均为最低水平。

从 ROC 曲线来看，随机森林模型的曲线显著高于对角线，且 AUC 值最大，表明其分类能力较强(图 4)。*K* 近邻分类和逻辑回归模型的 AUC 值分别为 0.59 和 0.62，说明它们在评价指标上也具有一定

表 5 8 种机器学习模型评价指标

Tab. 5 Evaluation indicators of 8 machine learning models

模型	准确率/%	精确率/%	召回率/%	F_1值/%
*K*近邻分类	63.2	70.1	63.2	64.7
逻辑回归	73.7	78.2	73.7	70.5
多层感知分类	68.4	71.9	68.4	65.8
决策树分类	63.2	60.9	63.2	61.2
随机森林分类	84.2	77.6	84.2	80.6
自适应提升分类	63.2	39.9	63.2	48.9
自助法袋装分类	57.9	60.9	57.9	56.5
轻量级梯度提升机	52.6	32.2	52.6	39.9

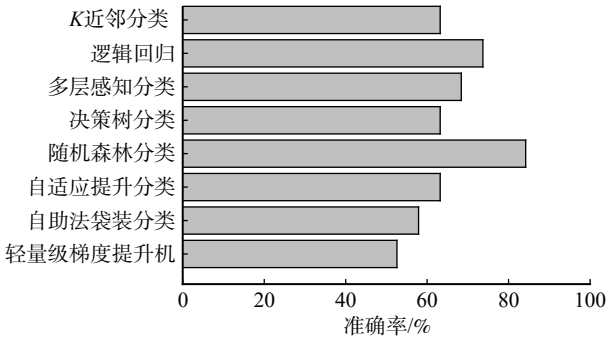


图 3 8 种机器学习模型对森林健康预测的准确率

Fig. 3 Accuracy of eight machine learning models for predicting forest health

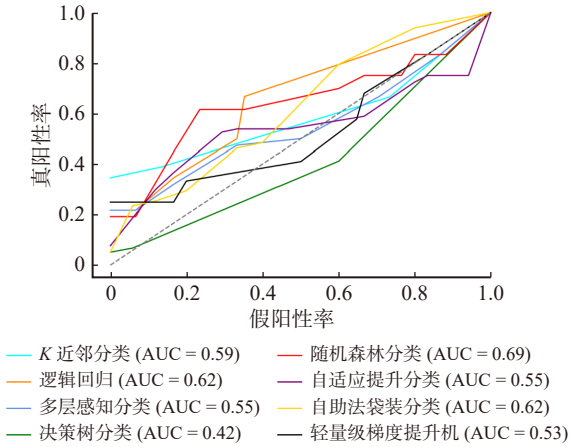


图 4　8 种机器学习模型对森林健康预测的 ROC 曲线

Fig. 4　ROC curves for predicting forest health using eight machine learning models

竞争力。然而，决策树和轻量级梯度提升机模型的 AUC 值仅为 0.42 和 0.53，表明其预测能力较弱。综合考虑，随机森林分类模型因其较高的准确率和稳健的分类性能，被选为本研究区森林健康状态验证的最佳模型。经过交叉验证，随机森林分类模型的预测结果与 ChatGPT 大语言模型的结果一致，这进一步证明了 ChatGPT 对森林健康状况的划分是准确的，其采用的综合健康评价模型是可行的。

4.4　森林健康的指标重要性排序

林分平均高和土壤有机碳密度被识别为关键变量，其特征值在所有变量中占据显著地位，表明它们对生态系统的健康状况具有较高的重要性。此外，林分蓄积量和更新的特征值也显示出较高的敏感性，这些变量分别反映了森林结构和更新能力的显著影响。草本盖度、枯枝落叶层厚度以及火险等级等因素的重要性指标处于中等水平，表明它们对森林健康评估具有一定影响，但不及前述变量显著。Simpson 指数、土层厚度和病虫害的特征值较低，提示这些变量在健康状态预测中的贡献相对有限（图 5a）。

森林健康状态的分类进一步揭示了各指标的重要性分布。林分平均高和土壤有机碳密度在健康、亚健康、中健康和不健康 4 种分类中均表现出较高的贡献值，尤其在不健康和中健康状态下贡献突出，表明这些指标在不同生态健康状态之间发挥了关键调节作用。林分蓄积量和枯枝落叶层厚度在亚健康和中健康类别中的占比相对较大，反映了它们在维持森林生态平衡中的重要作用。草本盖度和群落结构在各健康类别中的表现相对平衡，提示其在多状态生态系统中具有稳定性。病虫害对不健康状态的贡献微弱，表明该指标虽有影响，但不足以作为主导变量（图 5b）。

5　讨　　论

森林健康受到多维度因素的综合影响，其中生产力指标在健康评价中扮演了重要角色。林分平均胸径、林分平均高和林分蓄积量的显著正相关性表明，生产力较高的林分能够更好地维持健康水平，这一发现与国内外研究一致。例如，Liu 等[15]在大兴安岭地区研究中发现，林分生产力与碳密度变化密切相关，表现为正向非线性关系。此外，立地质量（如土层厚度和腐殖质厚度）的正相关性强调了土壤在生态系统健康中的基础性作用，这与 Crowther 等[18]关于土壤碳与森林健康关系的研究结论一致。生态脆弱性指标（如草本盖度、灌木盖度和 Simpson 指数）表现出适度的正相关性，说明植被多样性和覆盖率在缓解生态系统脆弱性方面具有重要意义。这与 Barron 等[32]研究提出的物种多样性提升生态系统服

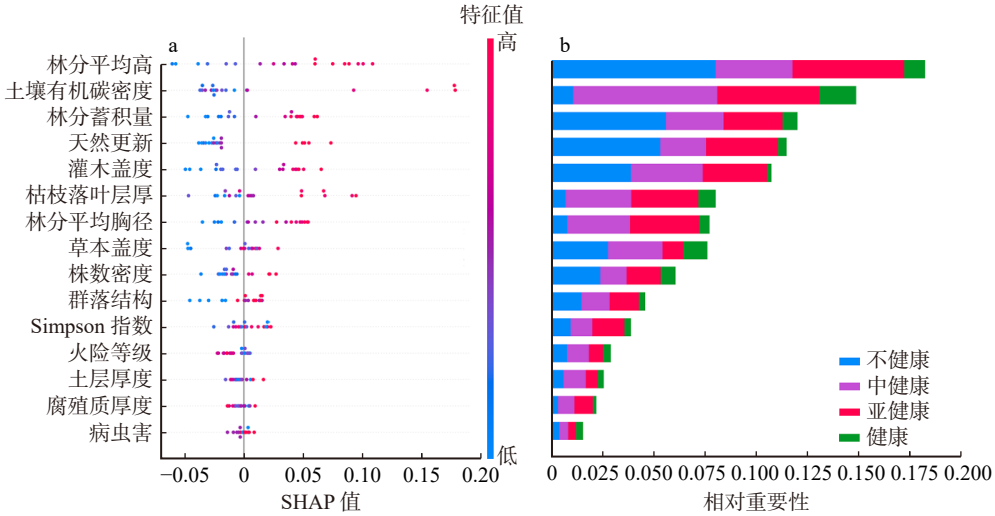


图 5　科尔沁沙地杨树人工林健康评价指标的相对重要性

Fig. 5　Relative importance of evaluation indicators for forest health of poplar plantations in the Horqin Sandy Land

务功能的观点相呼应。同时，天然更新能力作为抵抗力指标对健康的促进作用，表明增强更新能力是维持森林生态功能的关键途径，这与 Jobbágy 等[19]关于更新潜力对生态平衡的研究结果一致。在未来的研究中，可进一步强化这部分工作，拓展基于机器学习模型的相关性识别与解释路径，提升变量相关性解释力和模型的生态解释性。

科尔沁沙地杨树人工林健康的样地仅占 4.3%，这一结果表明研究区整体森林健康状况不理想，反映了区域生态环境的脆弱性及外部干扰（如干旱、土壤退化和病虫害）的显著影响。区域生态系统的脆弱性使人工林面临持续的环境压力，与众多研究对干旱半干旱地区人工林健康状况的评价结果一致。例如，Jobbágy 等[19]指出，土壤碳分布及其与气候和植被的关系对于生态系统的功能维持至关重要，而这些关键要素在半干旱区域常受到显著限制。科尔沁沙地杨树人工林不健康和亚健康总占比 42.4%，这一结果显示杨树人工林已出现不同程度的退化现象。然而，本文结果进一步显示科尔沁沙地中健康占比 53.3%，表明该区杨树人工林整体处于中健康状态。在水分相对短缺的沙地区域，杨树人工林整体能够达到中健康状态，究其原因可能是杨树人工林的根系分布特征决定的，杨树人工林在雨季主要利用浅层土壤水，在旱季主要利用深层土壤水和地下水，该策略保证了杨树人工林在应对干旱环境的适应性表现[4]。另一个可能的原因是与研究区人工林的经营管理模式有关。由于早期造林目标主要集中于生态恢复和沙地治理，杨树人工林的健康管理较少关注多样性、更新能力和结构稳定性等更复杂的生态功能[9]。在亚健康和不健康样地中，占比合计为 42.4%，进一步凸显了人工林在沙地生态环境中的经营面临着困难。已有研究表明，不健康和亚健康状态的主要成因包括病虫害频发、火险等级较高以及土壤条件的退化[18]。特别是在沙地地区，由于植被覆盖稀疏且水分利用效率低下，森林更易受到气候极端事件的冲击。因此，在健康管理策略中，需针对不同健康等级采取分区管理措施。例如，对于亚健康样地，可通过适度间伐降低竞争强度，同时改良土壤条件以提高健康水平。而对于不健康样地，则应重点加强干扰控制（如病虫害防治）并促进天然更新。

研究还表明，基于 ChatGPT 构建的综合健康评价模型在健康等级划分上能够客观反映林分健康现状。这说明其在多维数据整合和优化分析方面具有显著优势。这一方法的引入为森林健康评价开辟了新方向，尤其是在数据复杂且传统方法难以处理的情境下。然而，模型的长远应用需要与区域长期监测数据相结合，以确保预测结果的稳定性和可靠性。此外，还需探讨将人工智能模型与深度学习技术结合的可能性，以动态捕捉森林健康变化的趋势。综合来看，森林健康评价不仅为当前研究区的管理提供了科学依据，也为其他区域的人工林健康评估提供了参考。未来工作应进一步探索影响健康状态的驱动因子间的相互作用，开发适应性强，可推广的健康评价体系，并在生态脆弱区的人工林经营中实施更科学的健康管理策略。

随机森林分类模型在森林健康状况分类任务中性能优越，其准确率达到 84.2%，F_1 值为 80.6%，高于其他 7 种机器学习模型。可能的原因有两点。其一，该方法独特的集成学习机制和对数据复杂性的鲁棒性。这一发现与现有文献的研究结果一致，例如 Herrera[33]在滑坡检测中的研究表明随机森林能够有效处理复杂的地理和环境数据，具有较强的泛化能力。其二，森林健康评价中涉及的评价指标之间存在复杂的非线性关系，例如土壤有机碳密度和枯枝落叶厚度对健康状况的共同作用。随机森林能够捕捉和处理这些非线性和交互效应复杂的关系，从而提供更精确的预测。

在森林生态系统中，林分平均高和土壤有机碳密度是杨树人工林健康主要的驱动因子，表明它们对维持生态系统稳定性具有核心作用。这一发现与 Lundberg 等[34]基于 SHAP 值的解释模型研究结果一致。林分平均高是反映林木生长状态和林分竞争强度的重要指标。科尔沁沙地作为一个气候干旱、土壤贫瘠的区域，森林的生长高度直接受到水分和养分供应的限制。较高的林分平均高通常表明个体树木具备较强的资源竞争能力，光合作用效率较高，从而能够积累更多的生物量，促进碳固定和生态功能的提升。土壤有机碳密度是评估土壤肥力和健康的重要指标，对森林生态系统的生产力和碳循环具有直接影响。土壤有机碳不仅提高了土壤的水分保持能力，还为植物根系和微生物提供了稳定的养分来源，有助于维持土壤生物多样性和生态系统功能的稳定性[18]。科尔沁沙地的土壤有机碳积累主要依赖于森林植被的落叶和枯枝层的输入，这些有机物质在土壤微生物的作用下分解并形成腐殖质，从而改善土壤结构和水分渗透性。今后可进行适宜的林分管理措施如生物炭添加，也可以显著提高土壤有机碳的存储能力，进一步提升森林健康水平[35]。未来可通过优化种植密度、实施土壤改良措施（如生物炭施用）以及合理规划间伐周期，有效促进科尔沁沙地杨树人工林的健康和可持续发展。

6 结　　论

本文以科尔沁沙地杨树人工林为研究对象，借助 ChatGPT 大语言模型的优势，充分提取原始数据信息并克服人为因素的影响，对其森林健康状况进行了评价。结果表明，研究区森林整体处于中健康状态。ChatGPT 大语言模型能够较为客观地反映研究区的健康现状，这表明该方法具有科学合理性，为森林健康评价提供了一种全新的思路。通过与 8 种机器学习模型的对比验证，进一步证明了随机森林分类算法在预测森林健康方面的有效性。同时，利用 SHAP 模型进行特征解释分析，识别出林分平均高和土壤有机碳密度是影响森林健康的关键因素。模型可解释性的增强和预测性能的提升，对降低机器学习在森林健康诊断中的误判率具有重要的应用价值。

本研究虽构建并验证了基于 ChatGPT 与多源数据融合的森林健康评价方法，但该方法仍存在一定不确定性：一方面，所选 15 项指标主要基于现有文献与区域标准，未能完全涵盖森林健康的多维内涵，部分生态功能与长期动态过程可能被低估；另一方面，样地分布与样本量限制了模型的泛化能力，预测结果需在更广阔的时空尺度和长期监测数据中进一步验证。

鉴于本文侧重方法研究，后续可将该方法推广至不同生态区并验证。进而依托其通用框架开发基于机器学习的实时监测系统，动态跟踪森林健康变化趋势，为森林管理者提供实时预警和决策支持工具。同时探索深度学习算法在森林健康评价中的应用潜力，并构建多源信息融合的综合数据库，以提升模型对大尺度、长时间序列数据的适应能力。

参　考　文　献

[1] 靳姗姗, 夏霁晖, 谢沛铮, 等. 太行山南麓 3 种典型人工林健康评价 [J]. 水土保持研究, 2024, 31(5): 295−303.
Jin S S, Xia Q H, Xie P Z, et al. Assessment of health of three forest plantations in the southern foot of Taihang Mountain[J]. Research of Soil and Water Conservation, 2024, 31(5): 295−303.

[2] 郎明翰, 张日升, 凡胜豪, 等. 科尔沁沙地南缘樟子松人工林碳汇及对气候因子的响应 [J]. 水土保持学报, 2024, 38(4): 236−245.
Lang M H, Zhang R S, Fan S H, et al. Carbon sequestration fuction of *Pinus sylvestris* var. *mongolica* plantation and its respones to climate factors on the southern edge of Horqin Sandy Land[J]. Journal of Soil and Water Conservation, 2024, 38(4): 236−245.

[3] 张华, 李锋瑞, 张铜会, 等. 科尔沁沙地人工杨树林生态服务效能评价 [J]. 应用生态学报, 2003, 14(10): 1591−1596.
Zhang H, Li F R, Zhang T H, et al. Evaluation of ecological services of *Populus simonii* forest in Heerqin Sandy Land[J]. Chinese Journal of Applied Ecology, 2003, 14(10): 1591−1596.

[4] 杨爱国, 付志祥, 王玲莉, 等. 科尔沁沙地杨树水分利用策略 [J]. 北京林业大学学报, 2018, 40(5): 63−72.
Yang A G, Fu Z X, Wang L L, et al. Strategies on water utilization of poplar in Horqin Sandy Land of northern China[J]. Journal of Beijing Forestry University, 2018, 40(5): 63−72.

[5] 徐梅, 关庆伟. 徐州侧柏人工林健康评价研究 [J]. 西南林业大学学报, 2014, 34(2): 39−43.
Xu M, Guan Q W. Health assessment of *Platycladus orientalis* plantation in Xuzhou[J]. Journal of Southwest Forestry University, 2014, 34(2): 39−43.

[6] 董灵波, 刘兆刚. 森林健康评价及其多尺度转换方法 [J]. 南京林业大学学报 (自然科学版), 2021, 45(3): 206−216.
Dong L B, Liu Z G. Foresy health assessments and multi-scale conversion methods[J]. Journal of Nanjing Forestry University (Natural Sciences Edition), 2021, 45(3): 206−216.

[7] 刘素芝, 何小东, 李建军. 基于知识粒度的森林生态系统健康评价指标赋权方法 [J]. 生态学杂志, 2014, 33(4): 1082−1088.
Liu S Z, He X D, Li J J. The method of attribute weight in forest ecosystem health evaluation based on knoeledge granularity[J]. Chinese Journal of Ecology, 2014, 33(4): 1082−1088.

[8] 张德成, 殷鸣放, 魏进华. 用灰色关联度法评价森林涵养水源生态效益——以辽东山区主要森林类型为例 [J]. 水土保持研究, 2007, 14(4): 96−99.
Zhang D C, Yin M F, Wei J H. Benefits estimating of forest ecosystem water-feeding with gray correlation method in Liaoning Province eastern mountainous area[J]. Research of Soil and Water Conservation, 2007, 14(4): 96−99.

[9] 赵金满, 韩馨悦, 程瑞明, 等. 塞罕坝自然保护区华北落叶松和樟子松人工林健康评价 [J]. 南京林业大学学报 (自然科学版), 2024, 48(3): 199−206.
Zhao J M, Han X Y, Cheng R M, et al. Health assessment of *Larix gmelinii* var. *principis-rupprechtii* and *Pinus sylvestris* var. *mongolica* plantations in Saihanba Nature Reserve[J]. Journal of Nanjing Forestry University (Natural Sciences Edition), 2024, 48(3): 199−206.

[10] 郭艳荣, 铁牛, 张秋良, 等. 内蒙古中部山地油松人工林健康评价研究—以蛮汉山油松人工林为例 [J]. 干旱区资源与环境, 2012, 26(2): 145−150.
Guo Y R, Tie N, Zhang Q L, et al. Forest health assessment on *Pinus tabulaeformis* plantation in the mountainous region of central Inner Mongolia: a case of *Pinus tabulaeformis* plantation in Manhan Mountain[J]. Journal of Arid Land Resources and Environment, 2012, 26(2): 145−150.

[11] 王忠春. 林分级森林健康评价研究 [D]. 北京: 北京林业大学, 2010.
Wang Z C. Forest health assessment at stand scale[D]. Beijing: Beijing Forestry University, 2010.

[12] 王秋燕, 陈鹏飞, 李学东, 等. 森林健康评价方法综述 [J]. 南京

林业大学学报 (自然科学版), 2018, 42(2): 177−183.
Wang Q Y, Chen P F, Li X D, et al. Review of forest health assessment methods[J]. Journal of Nanjing Forestry University (Nature Sciences Edition), 2018, 42(2): 177−183.

[13] 曹小玉, 委霞, 赵文菲, 等. 基于结构方程模型的森林健康评价 [J]. 生态学杂志, 2021, 40(8): 2635−2647.
Cao X Y, Wei X, Zhao W F, et al. Evaluation of forest health based on structural equation model[J]. Chinese Journal of Ecology, 2021, 40(8): 2635−2647.

[14] 孟宪宇. 测树学 [M]. 北京: 中国林业出版社, 2006.
Meng X Y. Forest measurement[M]. Beijing: China Forestry Publishing House, 2006.

[15] Liu Y, Trancoso R, Ma Q, et al. Carbon density in boreal forests responds non-linearly to temperature: an example from the Greater Khingan Mountains, northeast China[J]. Agricultural and Forest Meteorology, 2023, 338: 109519.

[16] 鲍士旦. 土壤农化分析 [M]. 北京: 中国农业出版社, 2000.
Bao S D. Soil and agricultural chemistry analysis[M]. Beijing: China Agriculture Press, 2000.

[17] 刘琪璟. 中国立木材积表 [M]. 北京: 中国林业出版社, 2017.
Liu Q J. Tree volume tables of China[M]. Beijing: China Forestry Publishing House, 2017.

[18] Crowther T W, Todd-Brown K E O, Rowe C W, et al. Quantifying global soil carbon losses in response to warming[J]. Nature, 2016, 540(7631): 104−108.

[19] Jobbágy E G, Jackson R B. The vertical distribution of soil organic carbon and its relation to climate and vegetation[J]. Ecological Applications, 2000, 10(2): 423−436.

[20] 李艳梅, 王静爱, 雷勇鸿, 等. 基于承灾体的中国森林火灾危险性评价 [J]. 北京师范大学学报 (自然科学版), 2005, 41(1): 92−96.
Li Y M, Wang J A, Lei Y H, et al. Risk assessment of forest fire based on hazard bearing body (forest tree composition) in China[J]. Journal of Beijing Normal University (Natural Sciences Edition), 2005, 41(1): 92−96.

[21] 鲁绍伟, 余新晓, 刘凤芹, 等. 北京八达岭林场森林燃烧性及防火措施研究 [J]. 北京林业大学学报, 2006, 28(3): 109−114.
Lu S W, Yu X X, Liu F Q, et al. Forest fuel combustibility and methods for fire prevention at the Badaling Forestry Center, Beijing[J]. Journal of Beijing Forestry University, 2006, 28(3): 109−114.

[22] 郭艳荣. 内蒙古中部山地油松人工林健康评价研究 [D]. 呼和浩特: 内蒙古农业大学, 2011.
Guo Y R. Forest health assessment of *Pinus tabulaeformis* plantation in the mountainous region in central Inner Mongolia[D]. Hohhot: Inner Mongolia Agricultural University, 2011.

[23] Cover T, Hart P. Nearest neighbor pattern classification[J]. IEEE Transactions on Information Theory, 1967, 13(1): 21−27.

[24] Hosmer D W, Lemeshow S. Applied logistic regression [M]. New York: John Wiley & Sons, Inc. , 2000.

[25] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back-propagating errors[J]. Nature, 1986, 323(6088): 533−536.

[26] Quinlan J R. Induction of decision trees[J]. Machine Learning, 1986, 1(1): 81−106.

[27] Hatwell J, Gaber M M, Azad R M A. CHIRPS: explaining random forest classification[J]. Artificial Intelligence Review, 2020, 53(8): 5747−5788.

[28] Freund Y, Schapire R E. A decision-theoretic generalization of on-line learning and an application to boosting[J]. Journal of Computer and System Sciences, 1997, 55(1): 119−139.

[29] Breiman L. Bagging predictors[J]. Machine Learning, 1996, 24(2): 123−140.

[30] Ke G, Meng Q, Finley T, et al. Lightgbm: a highly efficient gradient boosting decision tree[J]. Advances in Neural Information Processing Systems, 2017, 30: 3149−3157.

[31] Python Software Foundation. Python language reference, version 3.13. 1[EB/OL]. [2025−02−10]. https://www.python.org.

[32] Barron S, Sheppard S R J, Condon P M. Urban forest indicators for planning and designing future forests[J]. Forests, 2016, 7(9): 208.

[33] Herrera H M. Landslide detection using random forest classifier[D]. Delft: Delft University of Technology, 2019.

[34] Lundberg S, Lee S I. A unified approach to interpreting model predictions[J]. Advances in Neural Information Processing Systems, 2017, 30: 4765−4774.

[35] Li Y, Hu S, Chen J, et al. Effects of biochar application in forest ecosystems on soil properties and greenhouse gas emissions: a review[J]. Journal of Soils and Sediments, 2018, 18(2): 546−563.

（责任编辑 吴 娟
责任编委 张会儒）