

数据论文

基于机器学习和第一性原理计算的
Janus 材料预测*张桥¹⁾ 谭薇¹⁾ 宁勇祺¹⁾ 聂国政¹⁾ 蔡孟秋²⁾
王俊年¹⁾ 朱慧平³⁾ 赵宇清^{1)4)†}

1) (湖南科技大学物理与电子科学学院, 智能传感器与新型传感器材料湖南省重点实验室, 湘潭 411201)

2) (湖南大学物理与微电子科学学院, 长沙 410082)

3) (中国科学院微电子研究所, 硅器件中心重点实验室, 北京 100029)

4) (中国科学院半导体研究所, 超晶格国家重点实验室, 北京 100083)

(2024 年 9 月 11 日收到; 2024 年 10 月 14 日收到修改稿)

寻找尺寸小、稳定性高和易操控的纳米磁结构——磁斯格明子 (magnetic skyrmion), 是发展下一代高密度、高速度和低能耗非易失性信息存储器件核心存储单元的关键。磁性斯格明子根据其拓扑产生机制, 可以由非中心对称结构诱导的 DMI (Dzyaloshinskii-Moriya interaction) 作用项产生。二维 Janus 结构具有两个不同面的原子层, 可以形成垂直内建电场, 打破中心空间反演对称性。因此寻找具有本征磁性的二维 Janus 材料是研究新型磁存储的基础。本文基于晶体材料数据库 Materials Project 中的 1179 种六角晶系 ABC 型 Janus 材料数据, 以其元素组分信息为特征描述符, 构建了随机森林、梯度提升决策树、极端梯度提升和极端随机树等四种机器学习模型, 基于上述模型对晶格常数、形成能和磁矩分类进行了预测, 并采用十折交叉验证法对模型进行了评估。梯度提升决策树在磁矩分类预测显示出最高的精度和泛化能力。最后, 基于上述模型对尚未发现的 82018 种二维 Janus 材料进行了预测, 筛选得到 4024 种具有热稳定性的高磁矩结构, 并基于第一性原理的方法对其中随机抽样的 13 种高磁矩结构进行了计算验证。本研究为二维 Janus 材料磁矩分类和高通量筛选训练了有效的机器学习模型, 加速了二维 Janus 结构磁性的探索。本文数据集可在 <https://doi.org/10.57760/sciencedb.j00213.00072> 中访问获取。

关键词: 机器学习, 二维 Janus 材料, 磁矩, 第一性原理计算**PACS:** 02.60.Cb, 81.05.Zx, 75.20.-g, 71.15.Mb**DOI:** 10.7498/aps.73.20241278**CSTR:** 32037.14.aps.73.20241278

1 引言

自 2004 年以来, 超薄的二维 (2D) 材料石墨烯^[1]、过渡金属硫化物 (TMDs)^[2]、过渡金属碳化物/氮化物 (MXenes)^[3] 及二维金属卤化物钙钛矿^[4] 的

先后发现^[5], 为谷电子学、自旋电子学以及铁电^[6-8] 等新奇物理特性的研究提供了广泛的平台, 并在光电、传感、非易失性铁电和铁磁存储领域引起了巨大的关注。其中铁电和铁磁耦合而成的多铁材料的设计是实现下一代新型逻辑存储的重要途径之一, 其存储原理为: 在 2D 材料中发现的具有本征受拓

* 国家自然科学基金 (批准号: 12204166)、湖南省自然科学基金 (批准号: 2024JJ5132) 和湖南科技大学科研启动基金 (批准号: E51996) 资助的课题。

† 通信作者。E-mail: yqzhao@hnu.edu.cn

扑保护的磁斯格明子, 磁斯格明子通过铁电极化的翻转来调控其类型, 从而实现逻辑态的存储. 而本征磁斯格明子通常是由中心反演对称性破缺的结构诱导的 DMI (Dzyaloshinskii–Moriya interaction) 项产生的, 因此中心反演对称性破缺的体系是探索磁斯格明子的前提条件^[9]. 二维 Janus 结构的上下两面为不同元素组成的原子层, 上下两层原子电负度的差异使其在垂直方向具有大的内建电场, 打破空间反演对称性, 在物理和化学性质上呈现出不对称性. 几个到十几个原子层厚度的二维 Janus 材料具有显著的量子限域效应, 作为一种典型的量子效应, 其与材料的组成、结构、化学键和电子结构等因素紧密相关^[10–13], 二维 Janus 材料因其独特的结构在压电传感器、催化剂^[14]、生物医学领域和能源存储等领域显示了广泛的应用前景^[15,16]. 特别是具有大的磁晶各向异性、高磁矩和本征磁拓扑的磁性 Janus 体系, 是发展新一代赛道级磁存储的重要候选者^[2,6,17–20].

传统的实验试错方法在新材料探索中昂贵且耗时, 而基于第一性原理计算的高通量筛选虽降低了实验和研发的周期及成本, 但对于复杂结构的大体系则面临算力大、时间成本高等一系列瓶颈^[21,22]. 近年来, 随着机器学习 (ML) 在凝聚态物理及微电子研究中的兴起^[23,24], 研究人员能够通过模型快速从海量未知体系中筛选出满足所需物理性质的体系, 显著减少了周期及成本, 随后, 通过第一性原理计算进行理论研究, 验证模型预测的准确性. 机器学习与第一性原理计算的结合^[25–27], 大幅提升了材料研究的速度和精确度, 推动了新材料的快速发现和开发.

当前, 国内外科研工作者已经采用机器学习和第一性原理计算方法对 Janus 材料及其异质结的物理和化学性质开展了研究. Huang 等^[28] 利用机器学习结合密度泛函理论方法研究了 Janus 材料活性点位的局部偶极矩对单原子催化剂催化活性的显著影响, 发现活性点位的局部偶极矩是调节催化活性的关键因素, 为设计高性能催化剂提供了新策略. Chaney 等^[29] 利用密度泛函理论和机器学习方法研究了 Janus 异质结 Mo/WXY ($X, Y = S, Se, Te$) 表面锂的吸附和扩散, 探讨了二维 Janus 过渡金属硫化物的结构不对称性对电子性质的影响, 并对比了 Janus 与常规 TMDs 结构的差异, 从而为锂的吸附和扩散机制提供了机理解释. Yan 等^[30]

通过替换不同过渡金属的二维铁磁 Janus MXenes 材料, 显示其基态铁磁源与磁性原子 d 轨道电子的直接交换, 并基于机器学习的方法筛选出铁磁性的材料, 为自旋电子器件开发提供了新策略. 尽管上述研究中, 基于机器学习的方法对 Janus 材料性质的挖掘取得了重要进展, 但对于六角晶系 Janus 结构的磁预测仍有待探索. 此外, 如何通过特征工程及超参数优化进一步提高模型的准确性也面临着挑战. 因此, 研究和发展基于六角晶系 Janus 体系的高效且准确的磁预测模型为二维铁磁家族的扩展提供了平台, 并将为凝聚态物理及微电子等领域带来新的突破, 对自旋电子器件的发展具有重要意义.

本文基于材料的元素组分信息, 训练了四种针对六角晶系 ABC 型 Janus 结构的机器学习模型. 用于预测 Janus 材料的晶格常数、形成能和磁矩分类. 通过模型的高通量筛选, 发现了 4024 种未被探索的高磁矩六角晶系 Janus 材料. 最后, 基于第一性原理的计算, 进一步验证了模型筛选的可靠性, 为未来实验上制备上述高磁矩的 Janus 材料提供了理论依据. 工作流程如图 1 所示.




图 1 机器学习结合基于密度泛函理论 (DFT) 发掘高磁矩 Janus 材料步骤

Fig. 1. Steps for discovering high magnetic moment Janus materials by combining machine learning with density functional theory (DFT).

2 数据及研究方法

2.1 数据获取、分析及预处理

本文从 Materials Project 数据库^[31]中提取 1179 种二维六角晶系 ABC 型 Janus 材料作为数据集, 图 2(a) 和图 2(b) 分别为二维六角晶系 Janus 材料原子结构的侧视图和俯视图. 中间层紫色原子

是 B 原子, 上下两层分别为半径大小不同的绿色 A 和黄色 C 原子层. 由于 A 和 C 原子的电负度不同, 因此沿 c 轴方向会产生内置电场, 打破空间反演对称性. 该数据集包含材料的化学成分信息 (元素、化学配比)、晶体空间群、晶格常数、形成能和总磁矩等.




图 2 六角晶系 ABC 型 Janus 材料原子结构的 (a) 侧视图和 (b) 俯视图

Fig. 2. (a) Side view and (b) top view of atomic structures of hexagonal ABC-type Janus materials.

图 3 展示了数据集中二维 Janus 结构数量随晶格常数、形成能及总磁矩变化的分布情况. 图 3(a) 显示, 数据集中 Janus 结构的晶格常数 a, b 的分布主要在 4 Å 和 8 Å 附近, 具有两个显著峰值, 表明数据集中面内晶格较为集中. 图 3(b) 显示晶格常

数 c 主要分布在 3—10 Å 的范围内, 在 3—7 Å 处具有显著峰值, 而少数二维 Janus 结构的 c 值大于 10 Å, 这可能是模型中考虑了真空层的厚度所导致^[32]. 图 3(c) 显示大部分 Janus 结构的形成能低于 0 eV, 表明上述结构是热稳定的, 仅小部分是不稳定的. 图 3(d) 显示大部分材料的总磁矩主要集中在 0— $0.25\mu_B$ 的狭窄区间, 只有少数具有较高的磁矩. 上述特征表明, 数据集中的大部分 Janus 结构是热稳定的, 且具有较低的磁矩. 以上数据集中目标属性的特征对于机器学习算法的选择、超参数调试具有重要作用.

对数据集进行初步分析后, 接下来执行数据预处理步骤. 首先, 在六角晶系 ABC 型 Janus 材料中, 晶格常数 a (Lattice a) 和 b (Lattice b) 的数值始终一致, 因此在模型训练中, 将晶格常数 a 和 b 合并为一个变量 (Lattice $a=b$), 以简化预测任务. 此外, 模型训练仅考虑晶格常数 a 和 b 小于 10 Å 的样本, 通过排除这些样本来减少噪声, 防止异常值对模型训练的干扰, 从而提高模型性能. 对于晶格常数 c (Lattice c), 也采取了相同的操作.

其次, 添加磁分类标签, 将目标属性总磁矩分为低磁矩 ($0\mu_B$ — $0.25\mu_B$)、中磁矩 ($0.25\mu_B$ — $3.5\mu_B$)、




图 3 数据集中二维 Janus 材料的 (a) 晶格常数 a 和 b , (b) 晶格常数 c , (c) 形成能和 (d) 总磁矩的分布

Fig. 3. The distribution of (a) lattice constants a and b , (b) lattice constant c , (c) formation energy and (d) total magnetic moment of the dataset of 2D Janus materials.

高磁矩材料 ($> 3.5\mu_B$), 标签分类为 0/1/2, 每一类材料的数量分别为 899, 214 及 66 个. 通过将磁矩分为三个组别, 可以更好地捕捉不同磁矩类别之间的差异, 为进一步的材料发现和研究提供更详细的信息和指导.

本研究中, 模型训练的数据集按照 9:1 的比例, 划分为训练集和测试集. 选择 90% 的数据作为训练集能够为模型提供充足的样本量进行学习, 确保模型充分捕捉数据中的模式和特征, 从而提高其拟合能力和预测性能. 此外, 为了在分类学习中保持训练集和测试集中各类别样本比例平衡, 采用分层抽样策略. 在模型训练过程中, 使用 SMOTEENN (SMOTE and edited nearest neighbours) 采样步骤^[33]. SMOTEENN 结合了 SMOTE 的过采样和 ENN 的欠采样, 这种方法首先对数据集应用 SMOTE 技术, 对少数类样本进行过采样, 生成新的少数类样本, 然后对过采样后的数据集应用 ENN 技术, 通过删除噪声和边界样本进行欠采样. 本研究提供一种综合方法来同时处理少数类样本不足和噪声样本问题. 这种方法提高了数据的质量和代表性, 使得模型能够更准确地学习和预测, 从而在实际应用中表现出更好的性能.

2.2 特征生成及改进

本文采用 Matminer^[34] 的元素数据和化学计量组成特征器—ElementFraction, 生成了 22 组仅含材料组成信息的元素属性统计描述符 (magpie). 每组元素属性统计描述符包括: 最小值 (min)、最大值 (max)、范围 (range)、平均值 (mean)、平均偏差 (ave_dev)、众数 (mode), 共计得到了包含元素组分信息的 132 个描述符.

对每种 Janus 结构构建一个 3×3 大小的矩阵, 将 magpie 统计的 22 个元素属性分别以主对角线为元素本身的属性值, 非主对角线则是原子 i 和 j 之间元素性质之和 (如基态磁矩和与轨道电子数有关的属性) 或其比值 (其余属性) 的形式构建材料的二维元素属性矩阵特征, 得到 22 组 3×3 型元素属性矩阵描述符^[35]. 随后, 将每组元素属性矩阵按行展平并拼接, 最终获得 198 种特征描述符.

通过将特征数量从 132 个提高到 198 个, 不仅丰富了材料的描述信息, 还引入了元素间相互作用的特征, 从而提高了模型的学习能力和预测准确

性. 这样的方法能够更全面地捕捉材料的复杂性, 提高模型在实际应用中的表现. 补充材料图 S1 (online), 表明了各模型在训练过程中比较重要的特征.

2.3 机器学习模型、训练及超参数优化

本研究采用了四种机器学习算法: 基于 Sklearn 库^[36] 的随机森林 (random forest, RF)、梯度提升决策树 (gradient boosting decision tree, GBDT)、极端随机树 (extremely randomized trees, ET), 以及基于专用的 XGBoost 库^[37] 的极端梯度提升算法 XGBoost, XGB). XGB 是一种高效的梯度提升算法, 具有分块训练、自动处理缺失值、正则化防止过拟合等优化功能. 此外, 上述四种算法能有效处理高维度和复杂特征交互的数据, 具有快速计算和高精度预测的优势. 对于回归任务, 上述四种算法使用均方误差 (mean squared error, MSE) 作为损失函数, 并通过拟合优度 (R^2)、平均绝对误差 (mean absolute error, MAE) 和均方根误差 (root mean squared error, RMSE) 来评估其性能. 对于分类任务, RF 和 ET 使用基尼不纯度 (Gini impurity) 作为评估准则, 而 GBDT 和 XGB 则采用对数损失 (log-loss) 函数作为评估准则. 分类任务的性能评估指标包括准确率 (accuracy)、精确率 (precision)、召回率 (recall) 和 F1 分数 (F1 score). 上述评价指标的引入, 能够系统地比较和分析不同算法在分类和回归任务中的表现, 为模型选择提供了科学依据.

在机器学习的分类与回归任务中, 虽然 RF, GBDT, XGB 和 ET 使用的基本算法结构和超参数类型相同, 但这些超参数的调整重点因任务性质的不同而有所区别. 分类任务侧重于提高算法的泛化能力和准确预测类别, 而回归任务则强调预测值的精确度和误差的控制. 对于上述四种算法, 树的数量 ($n_estimators$)、最大深度 (max_depth) 以及最大特征数 ($max_features$) 是共通的关键参数, 影响模型的学习能力和复杂性. 在分类任务中, RF 算法与 ET 算法的叶节点上所需的最小样本数 ($min_samples_leaf$) 及内部节点再划分所需的最小样本数 ($min_samples_split$) 是特别重要的; 而对于 GBDT 和 XGB, 样本子集比例 ($subsample$) 和最小化损失的增益 (γ) 的作用亦如此, 这些参数降低模型对训练数据的噪声敏感性, 减少模型的深度, 提

表 1 不同训练任务中机器学习最优模型的超参数

Table 1. The hyperparameters of the optimal machine learning models in various training tasks.

模型	超参数
GBDT(磁矩分类)	learning_rate = 0.01603011, max_depth = 5, n_estimators = 272, subsample = 0.69895067
GBDT(形成能)	learning_rate = 0.02, max_depth = 6, n_estimators = 353, subsample = 0.93030056
ET(晶格常数 a 和 b)	max_depth = 10, max_features = 0.60, n_estimators = 100, min_samples_leaf = 2, min_samples_split = 4
XGB(晶格常数 c)	learning_rate = 0.02, n_estimators = 300, max_depth = 5, subsample = 0.8, colsample_bytree = 0.49613519

高对数据变化的适应能力,防止过拟合、欠拟合及提升泛化能力.另一方面,对于回归任务,RF和ET算法所需的最大特征数(max_features)及XGB与GBDT算法所需的每棵树所采样的特征比例(colsample_bytree)和学习率(learning_rate)是特别重要的,这些超参数的精确调整可以帮助模型找到更好的局部最优解,加速模型训练,减少对训练数据的依赖,从而降低过拟合的可能性.因此,虽然共通参数为模型提供了基础结构,但是特定任务相关的参数调整是优化性能、提高精确度和防止过拟合的关键.

本研究采用贝叶斯超参数搜索技术^[38],在超参数优化过程中,每次迭代都基于贝叶斯统计预测各参数组合的潜在性能,优先评估那些最有可能提升模型表现的参数组合.这种策略通过持续更新概率模型,并根据获得的性能数据优化搜索策略,有效地识别出最佳参数配置.通过在十折交叉验证中综合评估各参数组合的表现,在最终迭代中选出表现最优的超参数配置,显著提升了模型的预测精度和泛化能力.不同学习任务中最优算法模型的超参数见表1.

2.4 第一性原理计算

本文采用基于DFT的第一性原理计算方法^[39,40],通过维也纳从头计算模拟包(Vienna *ab initio* simulation package, VASP)进行结构优化和静态计算.电子交换关联能由Perdu-Burke-Ernzerhof(PBE)泛函描述.布里渊区中采用 $5 \times 5 \times 5$ k 点网格进行优化和自洽,平面波截断能量设置为500 eV.每个原子上所受力的收敛阈值设置为 -0.1 eV/Å,能量收敛标准为 1×10^{-6} eV.为了描述局域化电子之间的库仑排斥力,对含有d, f轨道电子的强关联体系设置了有效场库仑相互作用参数Hubbard U.所有的计算中,原子的初始磁矩设置为零,通过原子尺度的结构优化和静态计算,提

取二维Janus结构中的原子磁矩并与模型预测结果对比,验证模型预测可靠性.

3 结果与讨论

3.1 晶格常数

本研究对晶格常数的模型训练分为两类:一类是针对晶格常数 a 和 b 的训练,另一类是针对晶格常数 c 的训练.为了全面评估这两个部分的模型性能,使用十折交叉验证评估模型.此方法不仅能够评估模型的稳定性,还能有效防止过拟合.表2展示了四种模型分别对上述两类任务在测试集上的平均评估指标.

表 2 晶格常数预测

Table 2. Prediction of lattice constants.

模型	Lattice $a = b$			Lattice c		
	MAE	RMSE	R^2	MAE	RMSE	R^2
RF	0.5485	0.8104	0.7375	0.6491	1.0001	0.6872
GBDT	0.4477	0.7350	0.7829	0.6679	0.9924	0.6923
XGB	0.5427	0.7968	0.7462	0.5953	0.9474	0.7186
ET	0.3469	0.6808	0.8137	0.6534	1.0103	0.6817

对于晶格常数 a 和 b 的预测,ET模型表现最佳,其MAE为0.3469, RMSE为0.6808及 R^2 评分达到了0.8137.这表明ET模型在完成训练晶格常数 a 和 b 的任务时具有较高的准确性和稳定性.在晶格常数 c 的预测中,XGB模型表现最佳,其MAE为0.5953, RMSE为0.9474及 R^2 评分为0.7186.图4(a)和图4(b)分别展示了最优模型ET和XGB在晶格常数 a , b 和 c 的预测任务里,在十折交叉验证过程中样本集上所有真实值与预测值拟合程度的散点图.

从上述数据可以看出,晶格常数 c 预测的性能评估低于晶格常数 a 和 b .这主要是由于Materials Project数据库中晶格常数 c 的标准不一致,并未




图 4 晶格常数预测: 最优模型在十折交叉验证中的散点图 (a) Lattice $a = b$ 预测任务最优模型: 极端随机树; (b) Lattice c 预测任务最优模型: 极端梯度提升

Fig. 4. Prediction of lattice constants: scatter plots for the optimal models in ten-fold cross-validation: (a) The optimal model for the lattice $a = b$ prediction task: ET; (b) the optimal model for the lattice c prediction task: XGB.

阐明是否包含真空层厚度. 如果考虑了真空层厚度, 其晶格会比体相的实际晶格 c 大很多, 而往往在具有大的晶格常数 c 的 Janus 体系中, 真空层可能被包含在其中. 这就导致数据集中的晶格 c 比实际晶格要大得多. 特别是在高晶格常数 c 的材料中, 大多增加了真空层, 导致 c 值显著偏大. 这种处理方式增加了数据分布的极端性和复杂性, 使得数据的统计特性存在显著差异和额外的变异性, 进一步加剧了数据的复杂性, 从而增加了模型的学习难度, 导致晶格常数 c 的预测效果略低于晶格常数 a 和 b .

3.2 形成能

本文分别采用了 RF, GBDT, XGB 和 ET 四种算法训练二维 Janus 材料形成能的预测模型, 并对模型性能进行了评估. 表 3 展示了十折交叉验证过程中各模型在测试集上的平均评估指标 MAE, RMSE 及 R^2 . 图 5(a)–(d) 展示了各模型在十折交叉验证过程中样本集上所有真实值与预测值拟合程度的散点图.

表 3 形成能预测: 四种机器学习模型的评价指标
Table 3. The prediction of formation energy: Evaluation metrics of four machine learning models.

模型	MAE	RMSE	R^2
RF	0.1054	0.1697	0.8671
GBDT	0.0798	0.1411	0.9070
XGB	0.0959	0.1533	0.8930
ET	0.1120	0.1701	0.8657

评价指标结果表明, GBDT 模型表现最为优异, 具有最低的 MAE 和 RMSE, 以及最高的 R^2

评分, 其 MAE 为 0.0798, RMSE 为 0.1411, 且 R^2 评分达到了 0.9070. 尽管 XGB 在 MAE, RMSE, R^2 指标上也表现良好, 但总体上仍稍逊于 GBDT. 散点图直观地展示了 GBDT 模型在十折交叉验证过程中样本集上所有真实值与预测值之间良好的拟合程度, 大多数样本点都分布在对角线上. 综上所述, 基于 GBDT 训练的形成能模型在各项性能评估指标上表现更优异, 能有效建立二维 Janus 材料的元素组分信息与形成能之间的映射关系, 保证了预测结果的准确性.

3.3 磁矩分类

为了评估磁矩分类模型的性能, 对四种模型进行了十折交叉验证, 并使用宏平均 (macro-averaging) 方式对每个类别单独计算评价指标, 然后对所有类别的结果取平均, 以确保每个类别的表现都得到公平的评估. 这种方法在类别不平衡的情况下, 能够对模型性能提供更加全面和真实的评价. 其在十折交叉验证过程中各模型在测试集上的平均评估指标如表 4 所列. 图 6(a)–(d) 直观展示了各模型在十折交叉验证过程中所有预测值和真实值的混淆矩阵图.

上述评价指标结果显示, GBDT 模型在准确率、精确率、召回率和 F1 分数上均展现出优越性, 表明其能更有效地识别和分类复杂数据集中的类别. 相比之下, RF 和 ET 虽然在处理高维数据时稳健, 但在某些类别的识别上存在误判, 这可能会影响在实际应用中对未知样本的预测效果. XGB 虽然处理速度快, 适合大规模数据, 但其对异常数




图 5 形成能预测: 四种模型在十折交叉验证上的散点图 (a) 随机森林; (b) 梯度提升决策树; (c) 极端梯度提升; (d) 极端随机树
Fig. 5. Prediction of formation energy: Scatter plots for four models in ten-fold cross-validation: (a) RF; (b) GBDT; (c) XGB; (d) ET.

据的敏感性可能在未探测的数据集上造成性能波动. 因此, GBDT 由于较强的泛化能力和稳定的性能表现, 成为寻找高磁矩 Janus 材料最具潜力的模型.

表 4 磁矩分类预测: 四种机器学习模型的评价指标
Table 4. Prediction of magnetic moment classification: Evaluation metrics of four machine learning models.

模型	Accuracy	Precision	Recall	F1 score
RF	0.8770	0.8459	0.7636	0.7862
GBDT	0.8948	0.8498	0.8182	0.8263
XGB	0.8762	0.8398	0.7697	0.7883
ET	0.8795	0.8392	0.7778	0.7965

3.4 高通量材料生成及第一性原理计算

以数据集中二维六角晶系的 ABC 型 Janus 结构为基础, 在元素周期表中对 A, B 和 C 包含的所有元素随机替换, 生成了 82018 种尚未发现的 ABC 型二维 Janus 材料, 上述结构不属于原数据集.

将上述各部分评价性能最好的模型用于预测 82018 种二维六角晶系 Janus 材料的晶格常数、形成能和磁矩. 模型共预测出 4204 种包含晶格信息

并具有热稳定和高磁矩的结构. 为了进一步验证其可靠性, 本文从高通量筛选结果中随机挑选了 13 种涵盖了不同元素的二维 Janus 结构并结合第一性原理的研究, 计算其晶格常数、形成能和磁矩. 图 7 分别为 ErFeTb, FeNO, HoRuSr, DyOsSr, EuSbSr, HoIrSr, LiUZn, PuSZn, GdKU, LuNbTi, GdHfSe, NaTbZn 及 HoNpSr 共 13 种二维 Janus 原子结构的侧视图. 优化后的晶格常数、形成能和磁矩如表 5 所列. 补充材料表 S1 ([online](#)) 给出了 13 种未优化结构的形成能和磁矩.

根据上述结果, 优化后的 13 种二维六角晶系 Janus 结构的形成能均为负值, 表明上述 Janus 体系是热力学稳定的. 此外, 基于第一性原理的研究表明, 所有 13 种 Janus 结构均具有磁性, 理论计算与机器学习模型的预测值一致. 其中 ErFeTb, HoRuSr, DyOsSr, EuSbSr, HoIrSr, PuSZn, GdKU, GdHfSe, NaTbZn 和 HoNpSr 的单原子磁矩超过 $3\mu_B$, 如表 5 所列. 上述具有高磁矩的原子主要属于锕系金属 (如 Pu, Np) 和稀土元素 (如 Tb, Gd, Dy). 上述元素因为未填满的 f 轨道电子的净磁矩贡献诱导了磁性. 这表明含有锕系金属和稀土元素

的化合物是设计高磁矩六角晶系 ABC 型 Janus 材料的有力候选. 补充材料 S1 ([online](#)) 为基于机器

学习模型预测的 13 种未优化的 Janus 结构, 结合第一性原理计算的形成能和磁矩.




图 6 磁矩分类预测: 四种模型在十折交叉验证上的混淆矩阵 (a) 随机森林; (b) 梯度提升决策树; (c) 极端梯度提升; (d) 极端随机树

Fig. 6. Prediction of magnetic moment classification: Confusion matrices for four models in ten-fold cross-validation: (a) RF; (b) GBDT; (c) XGB; (d) ET.




图 7 13 种二维六角晶系 Janus 原子结构的侧视图

Fig. 7. Side view of atomic structures of 13 two-dimensional hexagonal Janus materials.

表 5 13 种结构优化后的六角晶系 ABC 型

Janus 材料的晶格常数、形成能和磁矩

Table 5. Optimized lattice constants, formation energies, and magnetic moments of 13 two-dimensional hexagonal ABC-type Janus materials.

Formula	Lattice constants		Formation energy/eV	$ \mu /\mu_B$		
	$a = b/\text{\AA}$	$c/\text{\AA}$		A	B	C
ErFeTb	3.35	18.25	-2.02	2.51	3.03	6.24
FeNO	2.92	15.00	-11.87	1.17	0.08	0.47
HoRuSr	4.90	18.79	-6.66	3.79	0.02	0.05
DyOsSr	4.18	18.87	-6.89	4.89	0	0.13
EuSbSr	5.43	18.69	-5.53	6.85	0.01	0.05
HoIrSr	4.58	18.79	-7.24	3.72	0	0.05
LiUZn	2.89	18.13	-0.44	0	1.65	0.01
PuSZn	4.52	18.13	-6.75	5.61	0.10	0.01
GdKU	7.46	18.13	-2.39	7.33	0	2.96
LuNbTi	3.02	18.13	-1.76	0.02	0.28	1.67
GdHfSe	5.03	18.93	-8.46	7.33	0.34	0.02
NaTbZn	4.65	18.69	-1.87	0.02	6.00	0
HoNpSr	3.69	18.46	-1.80	3.81	4.38	0.08

4 结 论

本研究基于材料的元素组分信息, 构建了包含 22 组元素属性的矩阵特征, 每组特征通过行展开, 生成了 198 种特征描述符. 针对六角晶系 ABC 型 Janus 材料的晶格常数、形成能和磁矩分类, 对四种机器学习模型 (RF, GBDT, XGB, ET) 采用了贝叶斯超参数优化和十折交叉验证方法进行训练, 并得到了在各自任务中表现最佳的模型 (晶格常数 $a = b$: ET; 晶格常数 c : XGB; 形成能: GBDT 及磁矩分类: GBDT). 通过对数据集中六角晶系结构进行元素替换, 生成了 82018 种尚未发现的六角晶系 ABC 型 Janus 材料. 应用上述训练的机器学习模型, 筛选出了 4024 种结构稳定且具有高磁矩的六角晶系 Janus 材料. 鉴于算力的限制, 随机选

择了 13 种结构结合第一性原理进行计算验证, 得到了 10 种优化后热力学稳定且单原子磁矩超过 $3\mu_B$ 的 Janus 材料, 研究表明, 含有稀土和铜系金属元素的化合物是设计高磁矩 Janus 材料的有力候选, 进一步验证了机器学习模型预测二维六角晶系 Janus 材料磁性的可靠性。

数据可用性说明

支撑本研究成果的数据集可在科学数据银行 <https://doi.org/10.57760/sciencedb.j00213.00072> 中访问获取。

参考文献

- [1] Novoselov K S, Geim A K, Morozov S V, Jiang D, Zhang Y, Dubonos S V, Grigorieva I V, Firsov A A 2004 *Science* **306** 666
- [2] Zhang Z W, Lang Y F, Zhu H P, Li B, Zhao Y Q, Wei B, Zhou W X 2024 *Phys. Rev. Appl.* **21** 064012
- [3] Liu B, Feng X X, Long M Q, Cai M Q, Yang J L 2022 *Phys. Rev. Appl.* **18** 054036
- [4] Xiong X J, Zhong F, Zhang Z W, Chen F, Luo J L, Zhao Y Q, Zhu H P, Jiang S L 2024 *Acta Phys. Sin.* **73** 137101 (in Chinese) [熊祥杰, 钟防, 张资文, 陈芳, 罗婧澜, 赵宇清, 朱慧平, 蒋绍龙 2024 物理学报 **73** 137101]
- [5] Zhao Y Q, Liu Z S, Nie G Z, Zhu Z H, Chai Y F, Wang J N, Cai M Q, Jiang S L 2021 *Appl. Phys. Lett.* **118** 173104
- [6] Lang Y F, Zou D F, Xu Y, Jiang S L, Zhao Y Q, Ang Y S 2024 *Appl. Phys. Lett.* **124** 052903
- [7] Liao C S, Ding Y F, Zhao Y Q, Cai M Q 2021 *Appl. Phys. Lett.* **119** 182903
- [8] Tan W, Zhang Z W, Zhou X Y, Yu Z L, Zhao Y Q, Jiang S L, Ang Y S 2024 *Phys. Rev. Mater.* **8** 094414
- [9] Liang J H, Wang W W, Du H F, Hallal A, Garcia K, Chshiev M, Fert A, Yang H X 2020 *Phys. Rev. B* **101** 184401
- [10] Zhang S Q, Xu R Z, Luo N N, Zou X L 2021 *Nanoscale* **13** 1398
- [11] Dai C Y, He P, Luo L X, Zhan P X, Guan B, Zheng J 2023 *Sci. China Mater.* **66** 859
- [12] Wang P, Zong Y X, Wen H Y, Xia J B, Wei Z M 2021 *Acta Phys. Sin.* **70** 026801 [王盼, 宗易昕, 文宏玉, 夏建白, 魏钟鸣 2021 物理学报 **70** 026801]
- [13] Ren K, Wang K, Zhang G 2022 *ACS Appl. Electron. Mater.* **4** 4507
- [14] Peng Z L, Huang J X, Guo Z G 2021 *Nanoscale* **13** 18839
- [15] Zhang L, Yang Z J F, Gong T, Pan R K, Wang H D, Guo Z N, Zhang H, Fu X 2020 *J. Mater. Chem. A* **8** 8813
- [16] Vafaezadeh M, Thiel W R 2022 *Angew. Chem. Int. Edit.* **61** e202206403
- [17] Mukherjee T, Kar S, Ray S 2022 *J. Mater. Res.* **37** 3418
- [18] Li C Q, An Y K 2022 *Phys. Rev. B* **106** 115417
- [19] Zhang L, Zhao Y, Liu Y Q, Gao G Y 2023 *Nanoscale* **15** 18910
- [20] Xu L J, Wan W H, Peng Y R, Ge Y F, Liu Y 2024 *Ann. Phys.* **536** 2300388
- [21] Gao Z Y, Mao G Y, Chen S Y, Bai Y, Gao P, Wu C C, Gates I D, Yang W J, Ding X L, Yao J X 2022 *Phys. Chem. Chem. Phys.* **24** 3460
- [22] Liu H, Sun J T, Liu M, Meng S 2018 *J. Phys. Chem. Lett.* **9** 6709
- [23] Nelson J, Sanvito S 2019 *Phys. Rev. Mater.* **3** 104405
- [24] Belot J F, Taufour V, Sanvito S, Hart G L 2023 *Appl. Phys. Lett.* **123** 042405
- [25] Miyazato I, Tanaka Y, Takahashi K 2018 *J. Phys.: Condens. Matter* **30** 06L
- [26] Lu S H, Zhou Q H, Guo Y L, Zhang Y H, Wu Y L, Wang J L 2020 *Adv. Mater.* **32** 2002658
- [27] Ma X Y, Lyu H Y, Hao K R, Zhao Y M, Qian X F, Yan Q B, Su G 2021 *Sci. Bull.* **66** 233
- [28] Huang T, Yang Z X, Li L, Wan H, Leng C, Huang G F, Hu W Y, Huang W Q 2024 *J. Phys. Chem. Lett.* **15** 2428
- [29] Chaney G, Ibrahim A, Ersan F, Çakır D, Ataca C 2021 *ACS Appl. Mater. Interfaces* **13** 36388
- [30] Yan X H, Zheng J M, Zhao X, Zhao P J, Guo P, Jiang Z Y 2024 *Phys. Status Solidi Rapid Res. Lett.* **18** 2300468
- [31] Jain A, Ong S P, Hautier G, Chen W, Richards W D, Dacek S, Cholia S, Gunter D, Skinner D, Ceder G, Persson K A 2013 *APL Mater.* **1** 011002
- [32] Chen P Y, Lam C H, Edmondson B, Posadas A B, Demkov A A, Ekerdt J G 2019 *J. Vac. Sci. Technol. A* **37** 050902
- [33] Khushi M, Shaikat K, Alam T M, Hameed I A, Uddin S, Luo S, Yang X, Reyes M C 2021 *IEEE Access* **9** 109960
- [34] Ward L, Dunn A, Faghaninia A, Zimmermann N E, Bajaj S, Wang Q, Montoya J, Chen J, Bystrom K, Dylla M, Chard K, Asta M, Persson K A, Snyder G J, Foster I, Jain A 2018 *Comp. Mater. Sci.* **152** 60
- [35] Chen J, Song Y Y, Li S Z, Que Z X, Zhang W B 2023 *Sci. China Technol. Sci.* **1** 011002
- [36] Pedregosa F, Varoquaux G, Gramfort A, Michel V, Thirion B, Grisel O, Blondel M, Prettenhofer P, Weiss R, Dubourg V, Vanderplas J, Passos A, Cournapeau D, Brucher M, Perrot M, Duchesnay E 2011 *J. Mach. Learn. Res.* **12** 2825
- [37] Ester M, Kriegel H P, Xu X 2023 *Geogr. Anal.* **55** 207
- [38] Wu J, Chen X Y, Zhang H, Xiong L D, Lei H, Deng S H 2019 *J. Electron. Sci. Technol.* **17** 26
- [39] Ma Q Y, Wan W H, Ge Y F, Li Y M, Liu Y 2022 *J. Magn. Magn. Mater.* **605** 172314
- [40] Yin W J, Tan H J, Ding P J, Wen B, Li X B, Teobaldi G, Liu L M 2021 *Mater. Adv.* **2** 7543

DATA PAPERS

Prediction of magnetic Janus materials based on machine learning and first-principles calculations^{*}

Zhang Qiao¹⁾ Tan Wei¹⁾ Ning Yong-Qi¹⁾ Nie Guo-Zheng¹⁾
 Cai Meng-Qiu²⁾ Wang Jun-Nian¹⁾ Zhu Hui-Ping³⁾ Zhao Yu-Qing^{1)4)†}

1) (*Hunan Provincial Key Laboratory of Intelligent Sensors and New Sensor Materials, School of Physics and Electronics, Hunan University of Science and Technology, Xiangtan 411201, China*)

2) (*School of Physics and Microelectronics, Hunan University, Changsha 410082, China*)

3) (*Key Laboratory of Silicon Device Center, Institute of Microelectronics, Chinese Academy of Sciences, Beijing 100029, China*)

4) (*State Key Laboratory of Superlattices, Institute of Semiconductors, Chinese Academy of Sciences, Beijing 100083, China*)

(Received 11 September 2024; revised manuscript received 14 October 2024)

Abstract

Discovering compact, stable, and easily controllable nanoscale non-trivial topological magnetic structures, such as magnetic skyrmions, is the key to developing next-generation high-density, high-speed, and low-energy non-volatile information storage devices. Based on the topological generation mechanism, magnetic skyrmions can be generated through the Dzyaloshinskii–Moriya interaction (DMI) caused by breaking space-reversal symmetry. Two-dimensional (2D) non-centrosymmetric Janus structure can generate vertical built-in electric fields to break spatial inversion symmetry. Therefore, seeking for 2D Janus material with intrinsic magnetism is fundamental to develop the novel chiral magnetic storage technologies. In this work, we combine detailed machine learning techniques and first-principle calculations to investigate the magnetism of the unexplored 2D Janus material. We first collect 1179 2D hexagonal ABC-type Janus materials based on the Materials Project database, and use elemental composition as feature descriptors to construct four machine learning models: random forest (RF), gradient boosting decision trees (GBDT), extreme gradient boosting (XGB), and extra trees (ET). These algorithms and models are constructed to predict lattice constants, formation energy, and magnetic moment, via hyperparameter optimization and ten-fold cross-validation. The GBDT exhibits the highest accuracy and best prediction performance for magnetic moment classification. Subsequently, the collected data of 82018 yet-undiscovered 2D Janus materials, are input into the trained models to generate 4024 high magnetic moment 2D Janus materials with thermal stability. First-principles calculations are employed to validate random sample of 13 Janus materials with high magnetic moment. This study provides an effective machine learning framework for classifying the magnetic moments and screening high-throughput 2D Janus structures, thereby accelerating the exploration of their magnetic properties.

Keywords: machine learning, two-dimensional Janus materials, magnetic moment, first-principles calculations

PACS: 02.60.Cb, 81.05.Zx, 75.20.-g, 71.15.Mb

DOI: [10.7498/aps.73.20241278](https://doi.org/10.7498/aps.73.20241278)

CSTR: [32037.14.aps.73.20241278](https://cstr.cn/32037.14.aps.73.20241278)

^{*} Project supported by the National Natural Science Foundation of China (Grant No. 12204166), the Natural Science Foundation of Hunan Province, China (Grant No. 2024JJ5132), and the Scientific Research Start-up Fund of Hunan University of Science and Technology, China (Grant No. E51996).

[†] Corresponding author. E-mail: yqzhao@hnu.edu.cn



基于机器学习和第一性原理计算的Janus材料预测

张桥 谭薇 宁勇祺 聂国政 蔡孟秋 王俊年 朱慧平 赵宇清

Prediction of magnetic Janus materials based on machine learning and first-principles calculations

Zhang Qiao Tan Wei Ning Yong-Qi Nie Guo-Zheng Cai Meng-Qiu Wang Jun-Nian Zhu Hui-Ping
Zhao Yu-Qing

引用信息 Citation: *Acta Physica Sinica*, 73, 230201 (2024) DOI: 10.7498/aps.73.20241278

在线阅读 View online: <https://doi.org/10.7498/aps.73.20241278>

当期内容 View table of contents: <http://wulixb.iphy.ac.cn>

您可能感兴趣的其他文章

Articles you may be interested in

基于机器学习的无机磁性材料磁性基态分类与磁矩预测

Classification of magnetic ground states and prediction of magnetic moments of inorganic magnetic materials based on machine learning

物理学报. 2022, 71(6): 060202 <https://doi.org/10.7498/aps.71.20211625>

外加电磁场下周期性体系的第一性原理计算方法

First-principles calculation method for periodic system under external electromagnetic field

物理学报. 2023, 72(23): 237102 <https://doi.org/10.7498/aps.72.20231313>

机器学习加速搜寻新型双钙钛矿氧化物光催化剂

Machine learning accelerated search for new double perovskite oxide photocatalysis

物理学报. 2022, 71(17): 177101 <https://doi.org/10.7498/aps.71.20220601>

二维材料 XTe_2 ($X = Pd, Pt$)热电性能的第一性原理计算

Thermoelectric transport properties of two-dimensional materials XTe_2 ($X = Pd, Pt$) via first-principles calculations

物理学报. 2021, 70(11): 116301 <https://doi.org/10.7498/aps.70.20201939>

原子尺度构建二维材料的第一性原理计算研究

First principles calculation of two-dimensional materials at an atomic scale

物理学报. 2021, 70(2): 027301 <https://doi.org/10.7498/aps.70.20201636>

蛋白质计算中的机器学习

Machine learning for *in silico* protein research

物理学报. 2024, 73(6): 069301 <https://doi.org/10.7498/aps.73.20231618>