

基于迁移学习的LiPON制备工艺模拟优化

吴军君^{1,2}, 王 涛^{1,2}, 王英楷^{1,2}, 王星辉^{1,2}

(1. 福州大学物理与信息工程学院, 福建福州 350000; 2. 福州大学微纳器件与太阳能电池研究所, 福建福州 350000)

摘 要: 不同工艺参数对磁控溅射制备固态电解质薄膜LiPON的物理化学特性有巨大影响,使用机器学习对过程建模,能加强内部原理解,优化参数提升薄膜性能. 迁移学习通过挖掘历史数据集中的信息,提升模型精确度与泛化能力,从而更好地找到良好的工艺参数. 本文以文献中磁控溅射制备LiPON的数据集为例,探究靶基距离、溅射功率、溅射气压对LiPON薄膜的离子电导率的影响. 对比普通机器学习,迁移学习模型在多项误差指标上提升30%以上. 通过模型遍历参数空间,搜寻最佳工艺组合,预测LiPON薄膜的离子电导率为2.04 $\mu\text{S}/\text{cm}$,优于文献中的最优值,方差分析与实际样本证明了该方法具有可行性.

关键词: LiPON; 迁移学习; 机器学习; 工艺优化; 方差分析

基金项目: 国家自然科学基金(No.83417013); 福建省自然科学基金(No.2019J06008, No.2018J01535)

中图分类号: TM912; TP181 **文献标识码:** A **文章编号:** 0372-2112(2023)03-0687-07

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20211241

Transfer-Learning-Based Virtual Process Optimization for LiPON

WU Jun-jun^{1,2}, WANG Tao^{1,2}, WANG Ying-kai^{1,2}, WANG Xing-hui^{1,2}

(1. College of Physics and Information Engineering, Fuzhou University, Fuzhou, Fujian 350000, China;

2. Institute of Micro-Nano Device and Solar Cells, Fuzhou University, Fuzhou, Fujian 350000, China)

Abstract: Different process parameters have a huge impact on the physical and chemical properties of the LiPON thin films synthesized by magnetron sputtering. It has great significance to model the synthesis process for strengthening the understanding of internal principles and improving the properties of the thin films. Transfer learning can improve model accuracy and generalization ability by mining information in historical data sets, so as to better find good process parameters. This paper takes the datasets of LiPON synthesized by magnetron sputtering in literatures as examples to explore the influence of target-substrate distance, sputtering power, and sputtering pressure on the ion-conductivity of LiPON films. Comparing with ordinary machine learning, the transfer learning model improves by more than 30% in multiple error metrics. The built model recommended the optimal parameters combination after traversing parameters space, and the predicted ion-conductivity of LiPON film is 2.04 $\mu\text{S}/\text{cm}$, which is better than the maximum value in the literature. The mapped contour graph of process parameters and performance recommended for a process parameter range, and the performance of film is good and stable within the range. The analysis of variance and actual samples prove that the method is practical.

Key words: LiPON; transfer learning; machine learning; process optimization; analysis of variance

Foundation Item(s): National Natural Science Foundation of China (No.83417013); Natural Science Foundation of Fujian Province (No.2019J06008, No.2018J01535)

1 引言

随着社会的发展,传统的化石燃料日益枯竭,对能源的需求日渐增大. 固态锂离子电池因能量密度高,热稳定性好,寿命长和安全性好备受青睐. LiPON作为最常见的锂离子电池薄膜固态电解质,具有宽的电化学窗口、小的电导率和较高的离子电导率^[1],综合性能优越广

受研究. 磁控溅射是制备LiPON薄膜电解质的最常用工艺. 一方面,靶基距离、溅射功率、基底温度、溅射气压等工艺参数极大地影响着LiPON的物理化学特性,且对应的内部机理尚不清晰^[2];另一方面,LiPON的制备工艺可移植性较差,不同文献报到的类似参数溅射得到的薄膜的离子电导率差异大,通常在 6×10^{-7} S/cm与 3×10^{-6} S/cm

的范围内^[3-9]. 因此, 获取最佳的LiPON制备工艺参数具有一定的挑战. 传统的试错法, 一次实验控制一个变量, 遍历整个参数空间, 耗时耗力. 特别的, 磁控溅射需要高真空, 且LiPON溅射速率较慢, 整体一次实验耗时较长(通常大于12 h). 因此, 寻找LiPON薄膜电解质的最优工艺尤为困难, 亟需寻找一种高效的寻优方法.

机器学习是一种具有高通量的密度泛函数计算方法, 可用于解决涉及大量组合空间或非线性过程的复杂问题, 帮助快速准确建模. 近年来已初步应用于材料制备工艺优化方面, Wei等^[10]结合正交实验设计与支持向量回归, 优化磁控溅射工艺制备P型透明导电薄膜, Banko等^[11]使用深度对抗网络预测优化薄膜的形貌, Han等^[12]使用决策树优化水热反应工艺以提高碳点制备产率.

但是, 由于工艺参数的可移植性较差, 更换设备后, 需要重新获取实验数据以训练机器学习模型, 来寻找新的工艺参数. 迁移学习是一种以机器学习为基础的建模方法, 可以充分挖掘历史数据、相关领域数据中的知识, 来提高机器学习模型的性能, 减少所需的实验数量, 解决数据的稀疏性导致的模型精度不足的问题. 周书恒等^[13]使用迁移学习算法(TradaBoost)建模乙烯裂解炉工艺, 结合模拟数据, 在少量目标域数据的情况下, 取得良好预测精度. Kim等^[14]将差分对抗网络与数据挖掘结合, 通过将SrTiO₃(钛酸锶)制备工艺数据进行迁移, 提高了SrTiO₃制备过程建模的精度. 相比仅使用源实验数据建模, 迁移数据后模型预测精度有较大提升.

据此, 本文以不同文献中的LiPON实验数据集为基础, 结合支持向量回归与Correlation Alignment^[15]迁移学习算法, 对磁控溅射制备LiPON过程建模与虚拟工艺优化, 对比普通机器学习建模方法, 验证迁移学习建模、优化LiPON薄膜制备工艺的可行性, 结果显示结合了迁移学习后模型的预测精度有较大提升, 预测的最佳工艺组合符合实际, 为使用迁移学习优化工艺提供思路.

2 原理

2.1 磁控溅射制备LiPON工艺参数

尽管在相同工艺参数下, 不同磁控溅射设备制备的LiPON薄膜电解质的离子电导率存在差距. 但是, 影响薄膜性能的内部机理是相同的. 且不同设备会有某些相似的参数范围对薄膜性能产生相似的影响, 换言之两者具有相似性^[16].

影响薄膜电解质的离子电导率的溅射工艺参数有许多, 本文在其他工艺参数取常用值的情况下, 研究靶基距离、溅射功率和溅射气压这三个参数对薄膜电解质离子电导率的影响规律, 探究内部机理.

2.2 迁移学习

机器学习是一门交叉学科, 涉及概率论、逼近学、统

计学、凸优化等多种数据处理理论, 能够从大量的数据中寻找内在的规律. 支持向量回归(Support Vector Regression, SVR)^[17]是一种常用来解决非线性回归问题的机器学习算法. 该方法通过核函数将数据映射到高维空间, 然后根据最小化数据到超平面的距离、最大化类别距离的原则, 找到一个超平面, 将高维空间数据分为两类, 最后通过核函数, 得出原空间的回归函数. 相比于其他机器学习算法, 支持向量回归在小样本数据集的情况下具有较好的预测精度, 因此本文选用SVR作为预测模型算法.

一般情况下, 传统机器学习假设训练数据和测试数据来自相同特征空间, 具有相同分布. 但在实际应用中有一定的差异. 不同的应用场景下, 数据的分布不同^[18], 这导致了传统机器学习的预测结果适用性较差, 而重新获取数据建模花费的成本大又. 迁移学习能将以往的知识或者数据进行迁移, 减少需要重新获取的数据量, 提升模型精度, 能够较好地解决以上痛点.

迁移学习按照迁移内容可以分为基于实例、特征迁移、参数和知识的迁移^[19]. 其中, 实例迁移将源域(历史数据或其他数据来源特征空间)数据进行加权后加入到目标域(该研究所在特征空间)^[19]. 实例迁移通常简单高效, 针对材料领域数据样本较少, 历史数据与现存数据具有一定内在联系的情况, 能够很好地利用历史数据, 补充实验样本. 本文采用基于实例的迁移学习算法——Correlation Alignment^[15]对磁控溅射制备LiPON工艺建模.

Correlation Alignment的基本思路是: 通过线性变换对齐协方差矩阵, 来对齐源域数据与目标域数据的分布, 从而将源域的数据映射到目标域中.

算法原理为: 假设源域的不带标签样本 $D_T = \{x_i\}$, $x_i \in R^D$, 目标域不带标签样本 $D_T = \{u_i\}$, $u_i \in R^D$, x_i 和 u_i 都是 D 维特征向量. 假设 u_s, u_t, C_s, C_t 分别为特征向量的均值和协方差矩阵, C_s, C_t 的秩分别为 r_s, r_t . 使用一个线性变换矩阵 A 对 C_s 做变换, 最小化变换后的矩阵 C_s 与 C_t 的欧式距离($\|\cdot\|_F$).

$$\min_A \|C_s - C_t\|_F^2 = \min_A \|A^T C_s A - C_t\|_F^2 \quad (1)$$

引理1 设实数矩阵 X, Y 的秩为 r_x, r_y ($r_x < r_y$), 令对 Y 进行奇异分解, 则 $Y = V_Y \Sigma_Y U_Y^T$, $\Sigma_{Y[1:r]}$ 是 Y 最大的 r 个奇异值, $V_{Y[1:r]}$ 和 $U_{Y[1:r]}$ 分别为左右奇异向量. 那么 $X^* = U_{Y[1:r]} \Sigma_{Y[1:r]} V_{Y[1:r]}^T$ 是 $\min_X \|X - Y\|_F^2$ 的解^[20]. 对 C_s, C_t 做奇异分解:

$$C_s = U_s \Sigma_s U_s^T, C_t = U_t \Sigma_t U_t^T \quad (2)$$

当 $r_s > r_t$ 时, 由分析可得:

$$C_s = C_t = U_{T[1:r]} \Sigma_{T[1:r]} U_{T[1:r]}^T \quad (3)$$

当 $r_s \leq r_t$ 时, 由引理可知:

$$C_s = U_{T[1:r]} \Sigma_{T[1:r]} U_{T[1:r]}^T \quad (4)$$

设 Σ^* 为 Σ 的摩尔-彭斯广义逆矩阵, $r = \min(r_s, r_t)$,

根据 $C_s = A^T C_s A$, 式(2)~式(4), 得:

$$A^T U_S \Sigma_S U_S^T A = U_{T1:r} \Sigma_{T1:r} U_{T1:r}^T \quad (5)$$

令: $E = \Sigma_S^{-\frac{1}{2}} U_S^T U_{T1:r} \Sigma_{T1:r}^{-\frac{1}{2}} U_{T1:r}^T$, 可得:

$$(U_S A^T)^T \Sigma_S (U_S^T A) = E^T \Sigma_S E \quad (6)$$

A^* 代表 A 的最佳解. 映射后的源域数据 D_S^* :

$$D_S^* = D_S \times C_S^{-\frac{1}{2}} \times C_T^{\frac{1}{2}} \quad (7)$$

2.3 误差指标

用 MAE 表示模型平均绝对误差 (mean absolute error)、用 R^2 表示确定系数 (coefficient of determination). 用 MAPE 表示平均百分绝对误差 (average percent absolute error) 评价模型精确度, 如式(8)~式(10)所示, 其中 y_i 为样本真实值, \hat{y}_i 为预测值, \bar{y} 为所有真实值的平均值, n 为样本数量.

$$MAE(y, \hat{y}) = \frac{1}{n} \sum_{i=0}^{n-1} |y_i - \hat{y}_i| \quad (8)$$

$$R^2(y, \hat{y}) = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (9)$$

$$MAPE(y, \hat{y}) = \frac{1}{n} \sum_{i=0}^{n-1} \frac{|y_i - \hat{y}_i|}{\max(\epsilon, |y_i|)} \quad (10)$$

3 建模

3.1 数据处理

引用文献[21]和文献[22]中的磁控溅射 LiPON 实验数据集, 分别作为源域数据 D_S , 目标域数据 D_T . 文献中共 8 个工艺参数, 其中三个变量: 靶基距离/cm、溅射功率/W、溅射气压/Pa, 其他 5 个参数为默认状态. 通过迁移学习, 可将源域和目标域的数据在特征空间分布上进行对齐, 以排除其他工艺参数不同的影响. 源域数据 D_S 的大小为 14, 目标域数据 D_T 大小为 18.

文献[21]和文献[22]三个参数所取值为其他文献中常取值, 水平如表 1 所示. 两篇文献中的工艺参数所取得水平大小相近, 结构相似, 可移植性较高.

表 1 工艺参数水平

影响因素	水平分布				
	水平 1	水平 2	水平 3	水平 4	水平 5
文献[21]靶基距离/cm	7.5	9	11.6	*	*
文献[21]溅射功率/W	100	150	200	250	*
文献[21]溅射气压/Pa	0.5	1	1.5	2	3
文献[22]靶基距离/cm	4	5	6	7	8
文献[22]溅射功率/W	100	150	200	250	*
文献[22]溅射气压/Pa	0.5	1	1.5	2	3

3.2 Correlation Alignment-SVR 建模

将映射后的源域数据与目标域数据用于 SVR 建模, 模型的核函数取高斯核函数 (rbf), 使用训练函数 GridSearchCV^[17] 进行 6 倍交叉验证训练, 得到 SVR 的模型参数为: $C=192$, $\epsilon=0.01$, $\gamma=0.0001$. Correlation Alignment-SVR (CORAL-SVR) 建模流程如算法 1.

算法 1 领域适应算法流程: Correlation Alignment-SVR

- (1) 输入源域数据 D_S , 目标域数据 D_T
- (2) 根据式(2)~式(6)计算 C_S, C_T, A^*, C_S
- (3) 根据式(7)映射后得到的源域为 D_S^*
- (4) 映射后的两组数据 D_S^*, D_T 进行 SVR 模型建模.

3.3 工艺参数优化

想要找到最佳的磁控溅射工艺参数, 就需要遍历整个参数空间得到目标属性值, 但我们无法遍历整个连续的参数空间, 且相近的工艺参数对目标属性的影响的差距微乎其微. 于是, 将每个工艺参数范围等分为 200 个离散点, 其中: 靶基距离 (3~12 cm)、溅射功率 (50~300 W)、溅射气压 (0~4 Pa), 构建大小为 8×10^6 的离散参数空间, 使用上述搭建好的 CORAL-SVR、SVR 模型 (仅使用目标域数据集训练), 遍历整个离散参数空间并做出预测, 得到性能较好的工艺参数组合, 根据参数组合, 以其为中心, 画出等高线图, 确定良好工艺参数范围. 一个完整的优化流程如图 1 所示. 由于本文为虚拟筛选, 并不进行试验验证与迭代优化.




图 1 工艺优化流程

4 结果与讨论

本文对比了人工神经网络 (Artificial neural network, ANN)、SVR、CORAL-SVR 三种模型预测精度, 如表 2 所示, CORAL-SVR 的 MAE、 R^2 和 MAPE 分别为: 0.086、0.87、0.052, 模型的误差最低, 拟合程度良好, 具有相当的可靠性. 如图 2 所示, 在各误差指标上, CORAL-SVR 比 SVR 有较大的提升, 在 MAE、 R^2 、MAPE 上分别优化了 17%、70%、48%. 图 3 表明相比于单纯使用 SVR 或 ANN, CORAL-SVR 的拟合效果更加平滑, 泛化能力更强; 在第二个波峰中 CORAL-SVR 拟合效果更好, 没有出现奇异点, 是由于 CORAL-SVR 算法从源域数据学取知识, 提高拟合效果.

模型预测最佳工艺点如表 2 所示: 靶基距离 6.66 cm,

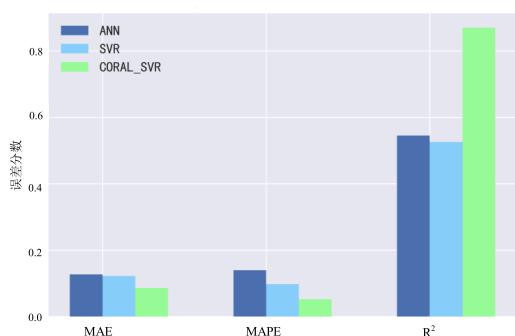




图2 三种算法误差对比图

溅射功率 61.3 W, 溅射气压 3.44 Pa, 预测的 LiPON 薄膜


离子电导率 $2.04 \mu\text{S}/\text{cm}$, 相比于文献中的最大离子电导率 $1.866 \mu\text{S}/\text{cm}$, 具有一定的提升; 同时最佳工艺参数点与文献中的最佳参数点具有一定相似性和差异性: 靶基距离 6 cm, 溅射功率 100 W, 溅射气压 0.5 Pa; 说明迁移学习能帮助模型跳出局部最优, 学习经验之外的知识. CORAL-SVR 预测的等高线如图 4 所示, 说明溅射功率在 50~70 W, 靶基距离在 6~7 cm, 溅射气压在 3~4 Pa, 薄膜可以得到较高的离子电导率, 对比引用文献中样本集, 当溅射功率取 100 W 与 60 W 附近时, 薄膜性能最佳, 且预测离子电导率的值范围与样本集中最佳值相近, 符合实际. 等高线图显示, 当溅射功率取 61.3 W 时, 另外两个参数的推荐的取值范围较广, 正如图 5 方




(a) ANN模型预测图




(b) ANN模型预测值与真实值对比




(c) SVR模型预测图



(d) SVR模型预测值与真实值对比



(e) CORAL_SVR模型预测图



(f) CORAL_SVR模型预测值与真实值对比

图3 ANN、SVR与CORAL-SVR模型拟合效果对比

表 2 误差与预测

误差指标				最佳工艺参数预测			
算法	MAE	R ²	MAPE	靶基距 /cm	溅射功率 /W	溅射气压 /Pa	离子电导 /(μS/cm)预测值
SVR	0.122	0.545	0.098	5.98	100.3	0.503	1.766
CORAL-SVR	0.086	0.870	0.052	6.66	61.3	3.44	2.04
ANN	0.127	0.526	0.140	8	100	3	1.817




图 4 CORAL-SVR 预测等高线图

差分析^[23]所示,溅射功率对LiPON薄膜的离子电导率影响最大,模型的泛化能力得到验证.




图 5 多因素方差分析

5 结论

本文使用迁移学习算法: Correlation Alignment-

SVR (CORAL-SVR) 对磁控溅射 LiPON 薄膜制备工艺进行虚拟优化,相比于传统的试错法,更快速地遍历整个工艺参数空间;对比传统机器学习优化工艺,模型的预测精度更高,拟合效果更佳,避免奇异点出现, CORAL-SVR 的误差指标 MAE、R² 和 MAPE, 分别为: 0.086、0.87、0.052, 相比传统机器学习 SVR 模型分别有: 30%、60%、47% 的优化. 后续使用 CORAL-SVR 对整个离散参数空间进行寻优, 预测的最佳工艺参数点: 靶基距离 6.66 cm, 溅射功率 61.3 W, 溅射气压 3.44 Pa, LiPON 薄膜的离子电导率为 2.04 μS/cm, 优于文献中的最大值. 推荐在溅射功率 50~70 W, 靶基距离在 6~7 cm, 溅射气压在 3~4 Pa 的工艺条件下, 薄膜可以取得较高且稳定的离子电导率. 结果与方差分析以及实际相符合, 证明迁移学习模型性能优秀, 能够促进材料制备工艺的优化. 后续, 随着材料基因工程^[24]的发展, 材料制备相关数据量的增长, 将为使用迁移学习优化材料提供更有力的支撑.


参考文献

- [1] MANI P D, SARAF S, SINGH V, et al. Ionic conductivity of bias sputtered lithium phosphorus oxy-nitride thin films [J]. *Solid State Ionics*, 2016, 287: 48-59.
- [2] 张勤. USC-80U 型乙烯裂解模型化炉与仿真优化[D]. 北京: 北京化工大学, 2009.
ZHANG Q. Modeling Simulation and Optimization of USC-80U Naphtha Pyrolysis Furnace[D]. Beijing: Beijing University of Chemical Technology, 2009. (in Chinese)
- [3] BATES J B, DUDNEY N J, GRUZALSKI G R, et al. Electrical properties of amorphous lithium electrolyte thin films [J]. *Solid State Ionics*, 1992, 53/54/55/56: 647-654.
- [4] BATES J B, DUDNEY N J, GRUZALSKI G R, et al. Fabrication and characterization of amorphous lithium electrolyte thin films and rechargeable thin-film batteries[J]. *Journal of Power Sources*, 1993, 43(1/2/3): 103-110.
- [5] FLEUTOT B, PECQUENARD B, MARTINEZ H, et al. Investigation of the local structure of LiPON thin films to better understand the role of nitrogen on their performance [J]. *Solid State Ionics*, 2011, 186(1): 29-36.
- [6] PARK H Y, NAM S C, LIM Y C, et al. Effects of sputtering pressure on the characteristics of lithium ion conductive lithium phosphorous oxynitride thin film[J]. *Journal of Electroceramics*, 2006, 17(2/3/4): 1023-1030.
- [7] PICHONAT T, LETHIEN C, TIERCELIN N, et al. Further studies on the lithium phosphorus oxynitride solid electrolyte[J]. *Materials Chemistry and Physics*, 2010, 123 (1): 231-235.
- [8] WANG B, CHAKOUMAKOS B C, SALES B C, et al. Synthesis, crystal structure, and ionic conductivity of a polycrystalline lithium phosphorus oxynitride with the γ - Li_3PO_4 structure[J]. *Journal of Solid State Chemistry*, 1995, 115(2): 313-323.
- [9] WANG B, KWAK B S, SALES B C, et al. Ionic conductivities and structure of lithium phosphorus oxynitride glasses[J]. *Journal of Non-Crystalline Solids*, 1995, 183 (3): 297-306.
- [10] WEI L F, XU X J, GURUDAYAL, et al. Machine learning optimization of p-type transparent conducting films [J]. *Chemistry of Materials*, 2019, 31(18): 7340-7350.
- [11] BANKO L, LYSOGORSKIY Y, GROCHLA D, et al. Predicting structure zone diagrams for thin film synthesis by generative machine learning[J]. *Communications Materials*, 2020, 1(1): 1-10.
- [12] HAN Y, TANG B J, WANG L, et al. Machine-learning-driven synthesis of carbon dots with enhanced quantum yields[J]. *ACS Nano*, 2020, 14(11): 14761-14768.
- [13] 周书恒, 杜文莉. 基于迁移学习的裂解炉产率建模[J]. *化工学报*, 2014, 65(12): 4921-4928.
ZHOU S H, DU W L. Modeling of ethylene cracking furnace yields based on transfer learning[J]. *CIESC Journal*, 2014, 65(12): 4921-4928. (in Chinese)
- [14] KIM E, HUANG K, JEGELKA S, et al. Virtual screening of inorganic materials synthesis parameters with deep learning [J]. *Npj Computational Materials*, 2017, 3(1): 1120-1127.
- [15] SUN B C, FENG J S, SAENKO K. Return of frustratingly easy domain adaptation[EB/OL]. (2015-11-17). <https://arxiv.org/abs/1511.05547>.
- [16] LU J D, GAO F R. Process modeling based on process similarity[J]. *Industrial & Engineering Chemistry Research*, 2008, 47(6): 1967-1974.
- [17] PEDREGOSA F, VAROQUAUX G, GRAMFORT A, et al. Scikit-learn: Machine learning in Python [J]. *Journal of Machine Learning Research*, 2011, 12: 2825-2830.
- [18] LU J D, YAO K, GAO F R. Process similarity and developing new process models through migration[J]. *AIChE Journal*, 2009, 55(9): 2318-2328.
- [19] PAN S J, YANG Q. A survey on transfer learning[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2010, 22(10): 1345-1359.
- [20] CAI J F, CANDÈS E J, SHEN Z W. A singular value thresholding algorithm for matrix completion[J]. *SIAM Journal on Optimization*, 2010, 20(4): 1956-1982.
- [21] HAMON Y, DOUARD A, SABARY F, et al. Influence of sputtering conditions on ionic conductivity of LiPON thin films[J]. *Solid State Ionics*, 2006, 177(3/4): 257-261.
- [22] 李林. LiPON 固态电解质与全固态薄膜锂离子电池制备及特性研究[D]. 兰州: 兰州大学, 2018.
LI L. Study of Solid Electrolyte LiPON and all Solid-State Thin-Film Lithium-Ion Batteries' Fabrications and Characteristics[D]. Lanzhou: Lanzhou University, 2018. (in Chinese)
- [23] LARSON M G. Analysis of variance [J]. *Circulation*,

2008, 117(1): 115-121.

- [24] LIU S, SU Y, YIN H, et al. An infrastructure with user-centered presentation data model for integrated management of materials data and services[J]. Computational Materials, 2021, 7: 88.

作者简介



吴军君 男,1995年生于福建省龙岩市,现为福州大学物理与信息工程学院硕士研究生.主要研究方向为机器学习与新能源.
E-mail: 709381781@qq.com



王涛 男,1995年生于甘肃武威,现为福州大学物理与信息工程学院硕士研究生,主要研究方向为机器学习与光伏器件.



王英楷 男,1993年生于福建厦门,硕士研究生,现为福州大学物理与信息工程学院硕士研究生,主要研究方向为新能源与大数据.



王星辉(通讯作者) 男,1986年生于福建三明,现为福州大学物理与信息工程学院教授.主要研究方向为新能源材料与器件及应用.
E-mail: seaphy23@fzu.edu.cn