



Al 基非晶合金表征参数的支持向量回归分析

徐 燕¹, 张玉凤¹, 高 涵¹, 张 研², 张惠然², 刘永生¹

(1. 上海电力学院 数理学院, 上海 201399;
2. 上海大学 计算机工程与科学学院, 上海 200444)

摘要: 根据一系列 Al 基非晶合金薄带实测数据集, 应用粒子群优化支持向量回归方法(PSO-SVR), 建立一个通过相关表征参数来预测 Al 基非晶合金晶化温度(T_x)的模型。利用该模型对不同类型铝基非晶合金的晶化温度(T_x)进行建模和预测研究, 并与反向传播神经网络(BPNN)预测方法进行比较。结果表明: 基于留一交叉验证法(LOOCV)的 PSO-SVR 模型预测的晶化温度误差要比 BPNN 模型预测的小得多, 这说明模型中所采用的特征参数能很好地描述该系列 Al 基非晶合金的晶化行为和热稳定性。

关键词: Al 基非晶合金; 晶化温度; 支持向量回归; 粒子群优化

中图分类号: TB34

文献标志码: A

非晶合金, 俗称“金属玻璃”, 与金属相比具有长程无序、短程有序的结构, 因而具有独特而优异的物理、化学及力学性能, 使其极具生产应用的优势。其中, Al 基非晶合金是一种高强度低密度的材料, 且 Al 基非晶纳米晶复合材料的比强度与工程陶瓷的接近, 具有很大的应用潜力^[1-3]。这使得近年来快速发展的航空航天以及交通工具的轻型化的需求得以满足。但在晶化过程中金属间化合物的析出会导致复合材料的强度降低, 还会使材料由韧变脆^[4], 因此, Al 基非晶合金的晶化行为值得深入研究^[5], 找出晶化温度与其它相关表征参数之间的关系也很有意义。

LISBOA 等^[6]提出将 Al 基合金分为纳米晶合金、纳米玻璃合金、玻璃合金 3 大类, 并且利用拓扑不稳定参数 λ 来说明晶化初生相与合金类型之间的关系。拓扑不稳定参数 λ 的核心思想是当溶质原子和溶剂原子的体积错配达到一定程度时, 由此引起的应力将导致晶体结构的失稳, 最终形成非晶^[7]。然而, 即使是同一体系的合金, 也很难有确定的 λ 值将 3 种类型的合金分类^[8]。

除了拓扑不稳定参数 λ , 研究者也试图通过其他一些参数来说明相关关系。ZHANG 等^[9]提出可以用体系电负性的偏差 Δe 值来确定 Al 基非晶合金的类型。

JIA 等^[10]提出了一个准等价团簇模型 $(Al_5TM)_x(Al_{10}RE)_y$, 即对于 TM 和 RE 摩尔分数分别为 x 和 y 的 $Al_{100-x-y}TM_xRE_y$ 合金, 参数 $(6x+11y)$ 可以预判 Al-TM-RE 非晶合金的类型。与 λ 一样, 很难找到一个临界 Δe 和 $(6x+11y)$ 来区分合金的晶化类型^[11]。同时, 在同一 Al-TM-RE 系中合金组元间的化学混合焓 ΔH^{mix} 直接反应了异类原子之间相互作用的强弱以及混乱程度, 以往许多工作业已表明 T_x 与 ΔH^{mix} 存在较好的线性关系^[11-12]。但是, 对不同体系的 Al-TM-RE 非晶合金而言, 区分其合金类型的临界 λ' 以及 ΔH^{mix} 值并不是固定的, 而是随 RE 原子的半径和电负性的变化而变化。

对于 Al 基非晶合金中如此复杂的表征参数, 数据挖掘可从大量的、存在噪声的、冗余的和缺损的数据中提取蕴藏其中有用的知识。目前, 关于 Al 基非晶合金晶化行为和热稳定性的研究, 还只是简单地通过图表法去分析它们之间的相关性^[11]。统计分析只能研究同一体系中这些参数与晶化温度之间的关系, 而无法根据这些特征参数去预测 T_x 值。而在不同 Al-TM-RE 系的研究中, 统计方法却不能得到很好的结论。机器学习方法^[13]可以研究不同体系中相关特征参数与 T_x 之间的关系, 而前人在 Al 基费劲合金的研究中则很

基金项目: 上海市教委科研创新资助项目(12ZZ174); 上海市教育发展基金会晨光计划资助项目(12CG63)

收稿日期: 2015-08-11; 修订日期: 2015-11-28

通信作者: 徐 燕, 讲师, 博士; 电话: 18918778925; E-mail: xuyan@shiep.edu.cn

少使用这种方法方法。本文作者则是将 PSO-SVR 方法与 Al 基非晶合金热稳定性研究相结合, 通过特征参数 λ 、 Δe 、 $(6x+11y)$ 、 ΔH^{mix} 、 λ' 等来预测 T_x 值, 为进一步实验提供理论指导, 减少实验的盲目性。

1 原理与方法

1.1 PSO-SVR 方法

20世纪90年代, VAPNIK^[14]在求解分类问题时候提出了支持向量机(Support vector machine, 简称 SVM)理论, 它以统计学习理论中的 VC 维理论和结构风险最小原理为基础, 利用有限的样本信息在模型的复杂性(对特定训练样本的分类精度)和学习能力(无错误地识别任意样本的能力)之间寻求最佳折衷, 以获得最好的分类性能和推广能力。经过不断发展, SVM 已经在解决实际问题中得到了广泛应用^[15-17]。与其他机器学习方法如遗传算法人工神经网络等方法相比, SVM 具有更好的学习能力和泛化能力, 因而引起了人们对这一领域的极大关注。支持向量回归(SVR)是 SVM 的一种延伸, 可以有效地完成非线性拟合^[14, 18-19]。针对不满足线性关系的样本集 $(x_1, y_1), \dots, (x_m, y_m)$, 通过输入空间到输出空间的非线性映射 Φ , 将样本集中的数据 x 映射到高维空间 F , 并在特征空间 F 中用下述函数 $f(x)$ 进行线性回归:

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) k(x, x_i) + b \quad (1)$$

式中: l 为训练样本个数; α_i 和 α_i^* 是拉格朗日乘子; $k(x, x_i) = \Phi(x) \cdot \Phi(x_i)$ 是一个核函数; b 是阈值。本文作者采用径向基核函数, SVR 的详细原理可以参考^[14]。

粒子群优化算法(Particle swarm optimization, PSO)是一种进化计算技术(Evolutionary computation), 它是由 Kennedy 博士和 Eberhart 教授于 1995 提出的^[20], 其设想是模拟鸟群觅食的过程, 每个优化问题的解都是搜索空间中的一只鸟, 即所谓的粒子。所有的粒子都有一个由被优化的函数决定的适应值, 每个粒子还有一个速度以决定它们飞翔的方向和距离, 然后粒子们就跟踪当前的最优粒子在解空间中的搜索。粒子在搜索的过程中会不断地用当前个体值和全局极值来更新自己, 直到找到全局最优解为止。PSO 是一个很好的参数优化工具, 在本实验中, PSO 被用来寻找 SVR 的最优参数(C, γ)。根均方差(E_r)作为适应度函数:

$$E_r = \sqrt{\frac{1}{m} \sum_{i=1}^m (\hat{y}_i - y_i)^2} \quad (2)$$

式中: m 为训练样本数; y_i 和 \hat{y} 分别表示训练样本的实验测量值和预测值。

1.2 泛化性能评估

两个指标, 也就是平均绝对误差(E_{ma})和平均相对误差(E_{map})被用来作为泛化性能评估。它们的公式如下:

$$E_{\text{ma}} = \frac{1}{n} \sum_{j=1}^n |\hat{y}_j - y_j| \quad (3)$$

$$E_{\text{map}} = \frac{1}{n} \sum_{j=1}^n \left| \frac{\hat{y}_j - y_j}{y_j} \right| \quad (4)$$

2 预测模型的建立

本实验中所用实验数据集源自文献[11]。该数据集总共有 66 个数据样本, 包含晶化温度 T_x , 化学混合焓 ΔH^{mix} 、拓扑不稳定参数 λ 、电负性差 Δx 、参数 $(6x+11y)$ 以及用有效原子半径修正后的拓扑不稳定参数 λ' 等 6 维数据向量。相关数据如表 1 所列。

张章等^[11]指出, 非晶合金的晶化过程需要进行原子的扩散, 影响非晶合金热稳定性的主要因素来自两个方面: 电负性和原子尺寸。电负性的大小能反映化学键的强弱和混合热的大小, 而溶剂原子与溶质原子尺寸大小也能影响热稳定好坏, 因此非晶晶化温度 T_x 与其组元密切相关。统计结果表明: 同一 Al-Ni-RE 系非晶合金的 $\lambda'、\Delta H^{\text{mix}}$ 等参数的两个临界值可以将其分为纳米晶、纳米玻璃、玻璃合金三类^[8]。然而, 对于不同体系的 Al-Ni-RE 非晶合金, 却不再有明显的临界值。同时, 统计方法无法通过这些特征参数来计算得出一个确定的 T_x 值, 而只能得到一些相关的线性关系。机器学习方法却可以使用训练样本训练一个模型, 然后通过该模型预测得到一个在一定精度范围内的 T_x 值, 这就很好地解决了统计学习方法无法解决的问题。

在使用实验中所提到的预测方法训练和建模过程中, 以化学混合焓 ΔH^{mix} 、拓扑不稳定参数 λ 、电负性差 Δx 、参数 $(6x+11y)$ 以及用有效原子半径修正后的拓扑不稳定参数 λ' 等五维数据向量为输入变量, 以 T_x 为输出向量进行训练学习。首先, 这 66 条样本数据要进行规范化处理, 未经预处理的样本数据各维特征差异较大, 若直接用于机器学习方法, 将会极大地影响其

表1 Al基非晶晶化温度和相关参数^[11]Table 1 Crystallization temperature T_x and relevant parameters of Al-based amorphous alloys^[11]

Sample No.	Alloy	$ \Delta H^{\text{mix}} /(kJ \cdot mol^{-1} \cdot K^{-1})$	Δe	$6x+11y$	λ	λ'	T_x/K
1	Al _{85.5} Ni ₉ La _{5.5}	14.45	0.1497	114.5	0.0996	0.1273	536.5
2	Al ₈₅ Ni _{9.5} La _{5.5}	14.78	0.1512	117.5	0.1013	0.1305	542.7
3	Al ₈₆ Ni _{8.5} La _{5.5}	14.13	0.1482	111.5	0.0979	0.124	527.3
4	Al ₈₅ Ni ₁₀ La ₅	14.48	0.1483	115	0.0967	0.1275	538.3
5	Al ₈₆ Ni ₇ La ₇	14.98	0.1559	119	0.1115	0.1331	538.1
6	Al _{85.5} Ni ₈ La _{6.5}	15.03	0.155	119.5	0.1087	0.1333	542.9
7	Al ₈₅ Ni ₉ La ₆	15.07	0.1539	120	0.1058	0.1335	545.5
8	Al _{84.5} Ni ₁₀ La _{5.5}	15.09	0.1526	120.5	0.103	0.1338	548.6
9	Al ₈₄ Ni ₁₁ La ₅	15.11	0.1512	121	0.1001	0.134	549
10	Al _{87.5} Ni ₅ La _{7.5}	14.23	0.1532	112.5	0.111	0.1264	527.2
11	Al ₈₇ Ni ₆ La ₇	14.3	0.1526	113	0.1081	0.1266	529.2
12	Al _{86.5} Ni ₇ La _{6.5}	14.37	0.1519	113.5	0.1053	0.1268	529.5
13	Al ₈₆ Ni ₈ La ₆	14.42	0.1509	114	0.1024	0.127	531
14	Al _{84.5} Ni ₁₁ La _{4.5}	14.49	0.1466	115.5	0.0939	0.1277	40.5
15	Al _{85.5} Ni _{9.5} La ₅	14.16	0.1468	112	0.095	0.1243	525.4
16	Al ₈₆ Ni ₉ La ₅	13.83	0.1453	109	0.0933	0.121	516.8
17	Al ₈₆ Ni _{9.5} La _{4.5}	13.53	0.1422	106.5	0.0888	0.118	511.4
18	Al _{86.5} Ni _{8.5} La ₅	13.5	0.1437	106	0.0916	0.1178	508.3
19	Al _{85.5} Ni ₁₀ La _{4.5}	13.86	0.1437	109.5	0.0905	0.1213	517.9
20	Al _{86.5} Ni ₉ La _{4.5}	13.21	0.1407	103.5	0.0871	0.1148	497.6
21	Al ₈₇ Ni ₈ La ₅	13.17	0.1421	103	0.0899	0.1145	493
22	Al ₈₇ Ni ₉ La ₄	12.57	0.1359	98	0.0808	0.1085	478
23	Al ₈₈ Ni ₈ La ₄	11.89	0.1326	92	0.0774	0.102	456
24	Al ₈₉ Ni ₅ La ₆	12.38	0.1409	96	0.0922	0.1076	494.1
25	Al _{85.5} Ni _{9.5} Y ₅	14.24	0.1268	112	0.0819	0.1111	495.4
26	Al ₈₆ Ni ₉ Y ₅	13.91	0.1251	109	0.0802	0.1079	485.1
27	Al ₈₆ Ni _{9.5} Y _{4.5}	13.6	0.1236	106.5	0.0769	0.1062	476.7
28	Al ₈₆ Ni _{8.5} Y _{5.5}	14.2	0.1265	111.5	0.0834	0.1096	471.7
29	Al ₈₆ Ni ₈ Y ₆	14.49	0.1278	114	0.0867	0.1113	481.9
30	Al _{86.5} Ni _{8.5} Y ₅	13.57	0.1234	106	0.0785	0.1046	463.2
31	Al _{86.5} Ni ₉ Y _{4.5}	13.27	0.1219	103.5	0.0752	0.1029	459.1
32	Al ₈₇ Ni ₈ Y ₅	13.23	0.1216	103	0.0768	0.1014	444.9
33	Al _{85.5} Ni ₉ Y _{5.5}	14.53	0.1282	114.5	0.0851	0.1128	481.5
34	Al ₈₆ Ni ₁₀ Y ₄	13.29	0.122	104	0.0737	0.1045	444.5
35	Al ₈₈ Ni ₄ Y ₈	14.2	0.1241	112	0.0928	0.1051	465
36	Al ₈₅ Ni ₁₀ Y ₅	14.56	0.1284	115	0.0836	0.1144	502.3
37	Al ₈₅ Ni ₉ Y ₆	15.15	0.1312	120	0.0901	0.1178	506.7
38	Al ₈₅ Ni ₆ Y ₉	16.79	0.1371	135	0.1095	0.128	557
39	Al ₈₅ Ni ₅ Y ₁₀	17.28	0.1383	140	0.116	0.1314	560
40	Al _{86.5} Ni _{4.5} Y ₉	15.76	0.1314	126	0.1044	0.1183	526
41	Al ₈₅ Ni ₇ Y ₈	16.27	0.1355	130	0.103	0.1246	540.6

续表 1

42	Al ₈₅ Ni ₈ Y ₇	15.72	0.1336	125	0.0966	0.1212	520
43	Al ₈₄ Ni _{7.5} Y _{8.5}	17.19	0.1399	138.5	0.1097	0.1328	557.4
44	Al _{83.5} Ni _{5.5} Y ₁₁	18.75	0.1449	154	0.1276	0.1445	576
45	Al ₈₃ Ni _{9.1} Y _{7.9}	17.51	0.1421	141.5	0.1092	0.1372	560.6
46	Al ₈₇ Ni ₈ Ce ₅	13.19	0.1386	103	0.0808	0.1054	496.2
47	Al _{86.5} Ni ₉ Ce _{4.5}	13.22	0.1374	103.5	0.0789	0.1066	498.9
48	Al ₈₆ Ni ₁₀ Ce ₄	13.25	0.136	104	0.0769	0.1077	497.4
49	Al ₈₇ Ni ₉ Ce ₄	12.58	0.1329	98	0.0735	0.1012	468.2
50	Al ₈₇ Ni _{8.67} Ce _{4.33}	12.77	0.1348	99.65	0.0759	0.1026	486
51	Al _{86.5} Ni _{8.5} Ce ₅	13.52	0.1402	106	0.0825	0.1087	507.3
52	Al ₈₆ Ni ₉ Ce ₅	13.85	0.1418	109	0.0842	0.1119	517.8
53	Al ₈₆ Ni _{9.5} Ce _{4.5}	13.55	0.139	106.5	0.0806	0.1098	516.7
54	Al ₈₇ Ni ₇ Ce ₆	13.76	0.1437	108	0.0881	0.1096	517
55	Al ₈₄ Ni ₁₀ Ce ₆	15.73	0.153	126	0.0983	0.1291	560
56	Al ₈₃ Ni ₁₁ Ce ₆	16.34	0.1559	132	0.1017	0.1356	592
57	Al ₈₅ Ni _{7.5} Ce _{7.5}	15.93	0.1567	127.5	0.1058	0.1289	558
58	Al ₈₄ Ni _{10.67} Ce _{5.33}	15.33	0.1496	122.65	0.0934	0.1263	553
59	Al _{85.5} Ni _{9.5} Ce ₅	14.19	0.1433	112	0.0859	0.1152	537.5
60	Al ₈₆ Ni _{8.5} Ce _{5.5}	14.15	0.1444	111.5	0.0879	0.114	527.4
61	Al ₈₅ Ni ₁₀ Ce ₅	14.5	0.1448	115	0.0876	0.1184	540.6
62	Al _{85.5} Ni ₉ Ce _{5.5}	14.47	0.146	114.5	0.0896	0.1173	541.9
63	Al ₈₆ Ni ₈ Ce ₆	14.43	0.1469	114	0.0915	0.1161	535.1
64	Al ₈₅ Ni ₉ Ce ₆	15.09	0.15	120	0.0949	0.1226	552.8
65	Al ₈₅ Ni ₈ Ce ₇	15.66	0.1546	125	0.1022	0.1268	557.8
66	Al ₈₃ Ni ₁₀ Ce ₇	16.92	0.1606	137	0.109	0.1398	594

预测准确率。在本实验中, 使用简单数据归一化方法进行处理, 之后, 给定的样本数据集被分为两类: 训练集和测试集。这 66 条样本数据被 BPNN 方法和 PSO-SVR 方法进行训练建模, 调整模型的正确性以及预测处理。本文作者使用留一交叉验证法(LOOCV)^[21]划分数据集, 即使用其中 65 条数据为训练集, 剩下的一条数据为测试集, 并且这 66 条数据逐一作为测试集。一旦预测模型训练完成, 测试集将会用来评估这个预测模型。测试集作为这个已完成训练的预测模型的输入, 得到的结果将被计算该模型的预测精度以及泛化能力。

3 结果与分析

表 2 所示为使用 BPNN 及基于 LOOCV 的 PSO-SVR 两种回归方法对 Al 基非晶合金 T_x 进行预测所得的计算结果和误差。

从表 2 中可以看出, 在 PSO-SVR 预测的 66 个样本中, 所有样本的绝对误差都小于 4.2%。其中, 绝大多数样本(52/66=78.8%)的绝对误差小于 2%。而 BPNN 模型的计算结果中, 只有 56.1%(37/66)样本的绝对误差小于 2%, 且最大误差高达 13.4%。在横向比较中, 采用 PSO-SVR 方法时 56.1%(37/66)的样本预测误差比 BPNN 方法预测的要小。该结果表明: 在大多数样本中, PSO-SVR 方法比 BPNN 方法具有更好的预测精度。

图 1 所示为 Al 基非晶合金 T_x 实测值和通过 PSO-SVR 方法以及 BPNN 方法得到的预测值的对比。从图 1 可以直观地看出, 绝大多数样本的 PSO-SVR 预测值都落在最优拟合线上或线的附近, 比 BPNN 方法的预测值更接近实测值。且与实测值相比, BPNN 模型的计算误差普遍明显偏高。这些结果再次表明: 与 BPNN 方法相比, PSO-SVR 方法预测结果更接近实测值, 且具有更高的预测精度以及更好的泛化能力。

表2 Al基非晶 T_x 测量结果与BPNN和基于LOOCV的PSO-SVR预测结果的对比Table 2 Comparison between experimental and predicted values of T_x by using BPNN and PSO-SVR methods

Sample No.	Measured T_x/K	BPNN calculated T_x/K	BPNN calculated error/%	PSO-SVR predicted T_x/K	PSO-SVR predicted error/%
1	536.5	534.4894	-0.37476	533.9733	-0.47096
2	542.7	518.3875	-4.47992	543.4727	0.142381
3	527.3	524.0878	-0.60918	527.976	0.1282
4	538.3	518.6	-3.65967	536.6858	-0.29987
5	538.1	518.4313	-3.65521	544.3015	1.152481
6	542.9	518.3594	-4.52028	548.3925	1.011696
7	545.5	549.2143	0.680898	551.1837	1.041925
8	548.6	550.7982	0.400693	549.2142	0.111958
9	549	553.8573	0.884754	550.2018	0.218907
10	527.2	518.4344	-1.66267	528.3128	0.211077
11	529.2	518.7437	-1.97587	533.4347	0.800208
12	529.5	530.3789	0.165987	535.1028	1.05813
13	531	518.6797	-2.32021	531.8887	0.167363
14	40.5	518.4806	-4.07389	536.7488	-0.69402
15	525.4	518.5953	-1.29515	526.0729	0.128074
16	516.8	516.7362	-0.01235	517.7995	0.193402
17	511.4	519.1844	1.522174	507.9601	-0.67264
18	508.3	519.3172	2.16746	509.1548	0.168168
19	517.9	519.2156	0.254026	516.4953	-0.27123
20	497.6	498.8579	0.252793	499.3851	0.358742
21	493	498.2369	1.062252	504.1403	2.259696
22	478	520.0781	8.80295	479.9181	0.401276
23	456	508.9658	11.61531	461.1855	1.137171
24	494.1	520.4047	5.32376	481.9105	-2.46701
25	495.4	519.6967	4.904461	487.7915	-1.53583
26	485.1	470.4216	-3.02585	481.0526	-0.83434
27	476.7	464.0036	-2.66339	470.0884	-1.38695
28	471.7	481.0706	1.986559	486.1154	3.056053
29	481.9	520.35	7.978834	493.3491	2.375825
30	463.2	511.6179	10.45291	466.7776	0.772366
31	459.1	520.8391	13.44785	450.3824	-1.89885
32	444.9	468.1516	5.226253	459.267	3.229265
33	481.5	492.2102	2.224341	495.7455	2.958567
34	444.5	462.5316	4.056603	463.0392	4.170799
35	465	467.5029	0.538258	480.3146	3.293462
36	502.3	520.06	3.535736	497.4209	-0.97135
37	506.7	510.9562	0.839984	511.804	1.007302
38	557	548.106	-1.59677	545.2034	-2.11788
39	560	559.8067	-0.03452	553.2716	-1.2015
40	526	523.4046	-0.49342	516.8867	-1.73257
41	540.6	518.5844	-4.07244	535.6902	-0.90821

续表2

42	520	518.6781	-0.25421	524.7841	0.920019
43	557.4	555.385	-0.3615	557.1745	-0.04046
44	576	588.8361	2.22849	579.2784	0.569167
45	560.6	566.2152	1.001641	566.7053	1.089065
46	496.2	494.0018	-0.44301	499.6416	0.693591
47	498.9	498.2055	-0.13921	493.9043	-1.00134
48	497.4	499.6407	0.450483	492.5699	-0.97107
49	468.2	481.5227	2.845515	474.2445	1.291008
50	486	510.6611	5.0743	480.7747	-1.07516
51	507.3	519.7297	2.450168	504.0459	-0.64145
52	517.8	519.2328	0.276709	511.529	-1.21109
53	516.7	519.0859	0.461757	503.1045	-2.63122
54	517	519.0984	0.40588	513.4836	-0.68015
55	560	566.3007	1.125125	562.2826	0.407607
56	592	575.3418	-2.81389	574.3901	-2.97465
57	558	568.0218	1.796022	569.1891	2.005215
58	553	563.4254	1.885244	554.462	0.264376
59	537.5	526.6825	-2.01256	521.8741	-2.90714
60	527.4	518.5783	-1.67268	529.7448	0.444596
61	540.6	536.4464	-0.76833	530.1383	-1.9352
62	541.9	518.3689	-4.34233	531.0385	-2.00434
63	535.1	534.6483	-0.08441	530.555	-0.84937
64	552.8	563.2167	1.884352	547.6777	-0.92661
65	557.8	563.374	0.999283	562.6194	0.864001
66	594	581.8342	-2.04811	585.9335	-1.358

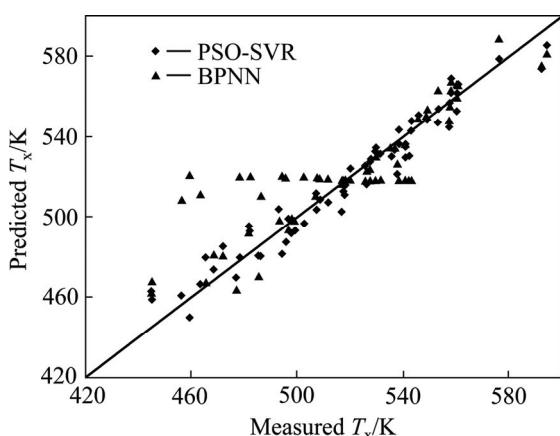


图1 通过PSO-SVR和BPNN得到的预测值与实测值对比图

Fig. 1 Comparison of experimental values vs predicted values by BPNN and PSO-SVR

表3列出了使用BPNN和PSO-SVR两种方法得到的评价指标值。从表3可以看出,PSO-SVR预测结果的 E_f (7.6597 K)、 E_{ma} (6.081 K)和 E_{map} (1.1935%)分别

都比BPNN的($E_f=18.1325$ K、 $E_{ma}=12.6657$ K、 $E_{map}=2.5254\%$)要小得多。这些结果再次表明,在Al基非晶合金数据集上,PSO-SVR与BPNN相比,具有更高的预测精度以及更强的泛化能力。

表3 两种回归方法预测性能的比较

Table 3 Comparison of prediction performance between BPNN and PSO-SVR

Method	E_f /K	E_{ma} /K	E_{map} /%
BPNN	18.1325	12.6657	2.5254
PSO-SVR	7.6597	6.081	1.1935

在不同Al-TM-RE系中,使用统计学方法很难得到确定的化学混合焓 ΔH^{mix} 、拓扑不稳定参数 λ 、电负性差 Δx 、参数 $(6x+11y)$ 以及用有效原子半径修正后的拓扑不稳定参数 λ' 等参数来区分合金的晶化类型。而PSO-SVR方法解决了使用Al基非晶参数不能准确分析其热稳定性的问题。以上结果表明:PSO-SVR能用

于预测 Al 基非晶合金的 T_x 值，并具有很好的预测精度和泛化能力。

4 结论

1) 将机器学习方法与材料研究相结合，根据 Al 基非晶合金的表征参数，采用基于 LOOCV 的 PSO-SVR 预测方法，对不同体系 Al 基非晶合金的 T_x 进行建模和预测研究，并将其预测结果与 BPNN 模型的预测结果进行了比较。其中 PSO-SVR 预测结果的 E_r (7.6597 K)、 E_{ma} (6.081 K) 和 E_{map} (1.1935%) 分别都比 BPNN 的 ($E_r=18.1325$ K、 $E_{ma}=12.6657$ K、 $E_{map}=2.5254\%$) 要小得多。

2) 由于 PSO-SVR 的预测方法比 BPNN 方法具有更高的预测精度和更强的泛化能力，而面向 Al 基非晶合金的数据集的实验结果也同样证明了这个结论。因此，PSO-SVR 预测方法对该方向的物理实验具有一定的指导意义和实用价值。

REFERENCES

- [1] GLORIANT T, GREER A L. Al-based nanocrystalline composites by rapid solidification of Al-Ni-Sm[J]. *Nanostructured Materials*, 1998, 10: 389–396.
- [2] SAHOO K L, SAHU R, GHOSH M, CHATTERJEE S. Studies on crystallization behavior and mechanical properties of Al-Ni-La metallic glasses[J]. *Bulletin of Materials Science*, 2008, 31(3): 433–439.
- [3] 益亮, 戴明华, 胡平, 闫巧云. 6061-T6 铝合金高温本构模型及温成形数值模拟[J]. 中国金属有色学报, 2015, 25(7): 2815–1821.
YING Liang, DAI Ming-hua, HU Ping, YAN Qiao-yun. Thermal constitutive model and numerical simulation of hot forming for 6061-T6 aluminum alloy[J]. *The Chinese Journal of Nonferrous Metals*, 2015, 25(7): 2815–1821.
- [4] ZHONG Zhen-chen, JIANG Xiang-yang, GREER A L. Micro structure and hardening of Al-based nanophase composites[J]. *Materials Science and Engineering A*, 1997, 226: 531–535.
- [5] 李永飞, 王英敏, 耿遥祥, 王传龙, 韩凯明, 羌建兵, 高晓霞, 米少波, 王清, 董闯, 孙继忠. Ni₆₀Nb₄₀ 与 Ni₄₀Nb₆₀ 非晶合金的低温晶化行为[J]. 中国金属有色学报, 2014, 24(10): 2588–2593.
LI Yong-fei, WANG Ying-min, GEN Yao-xiang, WANG Chuan-long, HAN Kai-ming, QIANG Jian-bing, GAO Xiao-xia, MI Shao-bo, WANG Qing, DONG Chuang, SUN Ji-zhong. Low-temperature crystallization behavior of Ni₆₀Nb₄₀ and Ni₄₀Nb₆₀ metallic glasses[J]. *The Chinese Journal of Nonferrous Metals*, 2014, 24(10): 2588–2593.
- [6] LISBOA R D S, BOLFARINI C, BOTTA W J F. Topological instability as a criterion for design and selection of aluminum-based glass-former alloys[J]. *Applied Physics Letters*, 2005, 86(21): 211904.
- [7] EGAMI T, WASEDA Y. Atomic size effect on the formability of metallic glasses[J]. *Journal of Non-Crystalline Solids*, 1984, 64(1/2): 113–134.
- [8] ZHANG Zhang, ZHOU Wei, XIONG Xian-zhong, KONG Ling-tao, LI Jin-fu. Glass forming ability and primary crystallization behavior of Al-Ni-Ce alloys[J]. *Intermetallics*, 2012, 24: 1–6.
- [9] ZHANG Long, ZHANG Fan, YANG Xi, LONG Guan-kui, WU Ying-peng, ZHANG Peng-fei, LENG Kai, HUANG Yi, MA Yan-feng, YU Ao, CHEN Yong-sheng. Porous 3D graphene-based bulk materials with exceptional high surface area and excellent conductivity for supercapacitors[J]. *Scientific Reports*, 2013, 3: 1408.
- [10] JIA Ran, BIAN Xiu-fang, LUE Xiao-qian, SONG Kai-kai, LI Xue-lian. The relationship between viscosity and glass forming ability of Al-(Ni)-Yb alloy systems[J]. *Science China Physics, Mechanics and Astronomy*, 2010, 53(3): 390–393.
- [11] 张章, 熊贤仲, 乙皎皎, 李金富. Al-Ni-RE 非晶合金的晶化行为和热稳定性[J]. 物理学报, 2013, 62(13): 136401.
ZHANG Zhang, XIONG Xian-zhong, YI Jiao-jiao, LI Jin-fu. Crystallization behavior and thermal stability of Al-Ni-RE metallic glasses[J]. *Acta Physica Sinica*, 2013, 62(13): 136401.
- [12] BOER F R, PERRIFOR D G. Cohesion in metals[M]. Netherlands: Elsevier Science Publishers, 1988: 20–35.
- [13] 徐戎, 李落星, 张立强, 朱必武, 卜晓兵. 金属型铸造界面换热系数峰值预测模型的建立和验证[J]. 中国金属有色学报, 2014, 24(4): 950–957.
XU Rong, LI Luo-xing, ZHANG Li-qiang, ZHU Bi-wu, BU Xiao-bing. Development and validation of prediction models of heat transfer coefficient peak value during metal casting process[J]. *The Chinese Journal of Nonferrous Metals*, 2014, 24(4): 950–957.
- [14] VAPNIK V N. The nature of statistical learning theory[M]. New York: Springer-Verlag, 1995: 53–64.
- [15] CAI Cong-zhong, WANG Wan-lu, SUN Li-zhi, CHEN Yu-zong. Protein function classification via support vector machine approach[J]. *Mathematical Biosciences*, 2003, 185(2): 111–122.
- [16] 温玉峰, 蔡从中, 裴军芳, 朱星键, 肖婷婷. R₂O-MO-Al₂O₃-SiO₂ 玻璃配方与热膨系数关系的支持向量回归研究[J]. 功能材料, 2009, 40(1): 66–70.
WEN Yu-feng, CAI Cong-zhong, PEI Jun-fang, ZHU Xing-jian, XIAO Ting-ting. Study on the relationship between thermal expansion coefficient and oxide composition of R₂O-MO-Al₂O₃-SiO₂ system glass via support vector regression approach[J]. *Journal of Functional Materials*, 2009, 40(1): 66–70.

- 66–70.
- [17] ABUOMAR O, NOURANIAN S, KING R, RICKS T M, LACY T E. Comprehensive mechanical property classification of vapor-grown carbon nanofiber/vinyl ester nanocomposites using support vector machines[J]. Computational Materials Science, 2015, 99: 316–325.
- [18] MAJID A, KHAN A, JAVED G, MIRZA A M. Lattice constant prediction of cubic and monoclinic perovskites using neural networks and support vector regression[J]. Computational Materials Science, 2010, 50(2): 363–372.
- [19] OWOLABI T O, AKANDE K O, OLATUNJI S O. Development and validation of surface energies estimator (SEE) using computational intelligence technique[J]. Computational Materials Science, 2015, 101: 143–151.
- [20] CORTES C, VAPNIK V. Support-vector networks[J]. Machine Learning, 1995, 20(3): 273–297.
- [21] PENG Si-hua, XU Qiang-hua, LING Xuefeng-bruce, PENG Xiao-ning, DU Wei, CHEN Liang-biao. Molecular classification of cancer types from microarray data using the combination of genetic algorithms and support vector machines[J]. FEBS Letters, 2003, 555(2): 358–362.

Parameters analysis of Al-based amorphous alloys using support vector regression

XU Yan¹, ZHANG Yu-feng¹, GAO Tian¹, ZHANG Yan², ZHANG Hui-ran², LIU Yong-sheng¹

(1. School of Mathematics and Physics, Shanghai University of Electric Power, Shanghai 201399, China;
 2. School of Computer Engineering and Science, Shanghai University, Shanghai 200444, China)

Abstract: According to the experimental data of Al-based amorphous alloys, a model to predict the crystallization temperature T_x of Al-based amorphous alloys by using particle swarm optimization combined with support vector regression (PSO-SVR) was established. Based on this model, crystallization temperature T_x can be predicted, and then compared with the method of back-propagation neural network (BPNN). The results show that the prediction error is smaller by using PSO-SVR. This means that the crystallization behavior and thermal stability of Al-based amorphous alloys can be well described by the parameters used in PSO-SVR model. Moreover, the PSO-SVR model could provide an important theoretical and practical guidance to the research on Al-based amorphous alloys.

Key words: Al-based amorphous alloy; crystallization temperature; support vector regression; particle swarm optimization

Foundation item: Project(12ZZ174) supported by Innovation Program of Shanghai Municipal Education Commission, China; Project(12CG63) supported by Shanghai Educational Development Foundation of Chenguang Program, China

Received date: 2015-08-11; **Accepted date:** 2015-11-28

Corresponding author: XU Yan; Tel: +86-18918778925; E-mail: xuyan@shiep.edu.cn

(编辑 龙怀中)