

铝合金微观组织的智能预测模型

周志敏 王 倩 王泽凯 谢正喜

(东北大学材料科学与工程学院)

摘 要 提出了由多个 NALU 算法层构建适于铝合金微观组织智能预测的神经网络模型,简述了 NALU 算法的基本原理和模型,阐述了以局部晶粒特征表示的微观组织预测的建模和训练方法,将 RMSProp 与 Adam 优化算法相结合,并合理调整学习速率,可训练出满意的预测模型。以铝合金铸造为例,考虑合金元素、工艺条件和设备参数等 26 个影响因素,以包含 18 个局部晶粒特征的微观组织参数为目标,建立了包括输入和输出神经元数分别为(26,32)、(32,28)、(28,23)、(23,18)的 4 个 NALU 层的神经网络,模型训练后的均方误差达到 0.000 6。任选 8 组不同条件的铝合金平均晶粒尺寸的预测误差小于 9%,适于微观组织的智能预测及新合金设计。研究表明,用多个 NALU 层构建合金微观组织与性能的智能预测模型是可行的,用局部晶粒特征对铝合金微观组织形貌特点的较细致表达的智能预测可以用多层 NALU 神经网络模型来实现。

关键词 深度学习;神经网络;NALU 算法;智能预测

中图分类号 TG111.7;TG113.1

文献标志码 A

DOI:10.15980/j.tzzz.2022.04.002

开放科学(资源服务)标识码(OSID):



Intelligent Model for Predicting the Microstructure of Aluminum Alloys

Zhou Zhimin, Wang Qian, Wang Zekai, Xie Zhengxi

(School of Materials Science and Engineering, Northeastern University)

Abstract: A neural network model with multi-layer NALU algorithm for the prediction of microstructures of aluminum alloys was carried out. The principle and model of NALU algorithm were explained in detail, and the approaches of modeling and training for the prediction with local grain characteristics were introduced. A satisfying model can be trained with the combination of both optimization algorithm RMSProp and Adam, and appropriate adjustment of learning rate. Taking aluminum alloy casting as instance, 26 input factors including alloying elements, processing conditions as well as equipment parameters were concerned, and microstructure parameters containing 18 local grain characteristics were targeted. Hence a neural network model containing 4 layers of NALU algorithm was established with (26,32)、(32,28)、(28,23)、(23,18) as the number of input/output neurons. The mean square error for the trained network model reaches 0.000 6. Prediction error of average grain size of 8 groups of aluminum alloys under different conditions is less than 9%, suitable for intelligent prediction of microstructures and design of new aluminum alloys. The results indicate that it is feasible to construct an intelligent prediction model for the microstructure and properties of alloys by multiple-layer NALU. Multi-layer NALU neural network model can realize the intelligent prediction for exquisite expression of aluminum alloy microstructure by local grain characteristics.

Key Words: Deep Learning, Neural Network, NALU Algorithm, Intelligent Prediction

合金的组织、性能及其制备过程存在高度的非线性规律,因此对其成分、工艺及微观组织之间的关系及相互作用机理的全面准确的描述很困难,给新型合金设计与研发带来很大挑战。2011 年,美国提出了“材料基因组计划”,主要是结合材料领域已取得的成果来提高从发现、研发、生产直至最终应用的全过程的速度^[1],自此,材料基因工程迅速成为国内外关注的课题^[2]。一般

认为,此项技术任务是探究材料的结构、工艺或配方与材料性能之间的关系,应包括 3 大技术要素,即高通量材料计算、高通量材料试验和材料数据库。近年来,人工智能(artificial intelligence, AI)技术的发展对材料基因工程的研究起到极大促进作用,为新型材料设计及其性能预测开辟了新的途径。

机器学习(Machine learning, ML)和深度学习

收稿日期:2021-07-10

第一作者简介:周志敏,男,1964 年出生,教授,沈阳(110819),E-mail:zmzhou@imp.neu.edu.cn

引用格式:周志敏,王倩,王泽凯,等. 铝合金微观组织的智能预测模型[J]. 特种铸造及有色合金,2022,42(4):404-408.

ZHOU Z M, WANG Q, WANG Z K, et al. Intelligent model for predicting the microstructure of aluminum alloys[J]. Special Casting & Nonferrous Alloys, 2022, 42(4):404-408.

(Deep learning, DL)是人工智能领域的两个基本概念。机器学习是一类利用多个非线性信息处理层来完成监督或者无监督的特征提取和转化、模式分析和分类等任务的技术。21世纪初,机器学习发展进入“深度学习”阶段^[3,4],并于2006年开始作为一个基本概念被广泛接受和使用^[3~8],通过多层表示来对数据之间的复杂关系进行建模和计算,包括神经网络、人工智能、图模型、最优化、模式识别和信息处理的交叉领域,在信号和信息处理等领域都产生了巨大影响,使人工智能产生了重大突破。

神经网络模型在描述复杂问题方面有明显的优势,可以根据大量的样本数据建立起变量之间的复杂关系,越来越受到材料研究者的关注,且在诸多方面都有实际应用^[9,10],如微观组织性能^[11~13]、铸造^[14,15]、轧制^[16~18]以及其他成形过程的分析和优化等^[19~22]。早期的应用主要是以按照误差逆向传播(Back propagation, BP)算法训练的多层前馈网络为代表的传统神经网络模型,在数据规模较小时表现出较好的建模灵活性和较精确的预测。然而, BP网络存在明显的不足,其隐层数不能太多,应用范围受限。近年来,深度学习的发展使得卷积神经网络、图神经网络、图卷积神经网络、生成对抗网络等性能良好的典型网络模型得到了充分发展和完善,在图像识别和图像处理等方面表现出优异的性能,并获得了广泛应用,深度学习算法也在材料研究领域获得应用^[7,8]。此外,近年来也出现了一些较具发展潜力的轻型智能算法,如由谷歌旗下的深度思考公司、牛津大学和伦敦大学学院的研究人员提出的神经算术逻辑单元(Neural arithmetic logic units, NALU)算法等^[8,23]。

目前,在材料领域应用较多的是传统神经网络模型,且多是输出变量较少的简单情况,对深度学习以及NALU等新算法的讨论及应用还相对较少。本课题采用NALU算法建立铝合金半连续铸造组织的智能预测模型,探讨对包含较多参量的局部晶粒特征进行智能预测的可行性,可为工艺优化、组织预测及合金设计提供合理的建模方法。

1 模 型

1.1 NALU 算法

通常,神经网络模型均不具备系统的数值外推能力,即不能对超出训练样本涵盖范围的情况进行预测。NALU算法具有较好的数值外推能力,在解决此问题方面有较好的潜力。该算法建立在神经累加器(Neural accumulator, NAC)算法的基础之上,并对复杂的数学运算具备强大的学习功能^[23]。

(1)NAC 算法

NAC是一个简单的具备加法和减法学习能力的神经网络单元,是线性层的一种特殊情况,其变换矩阵 $\mathbf{W}$ 仅由-1、0和1这3个数值组成,也就是说,它的输出是输入矢量的线性组合,可防止网络层在将输入映射到输出时发生数字表示比例的改变。

$\mathbf{W}$ 取值的限制使网络学习变得十分困难,因此,实际采用有利于梯度下降法进行学习的连续可微形式:

$$\mathbf{W} = \tanh(\hat{\mathbf{W}}) \odot \text{sigmoid}(\hat{\mathbf{M}}) \quad (1)$$

式中, $\hat{\mathbf{W}}$ 和 $\hat{\mathbf{M}}$ 为标准(无约束)的可训练参数矩阵,初值可由函数随机赋值。

(2)NALU 算法

NALU主要承担加减法运算,NALU在此基础上扩展为乘除运算,通过增加一个门控单元来自动学习是选择乘法还是加减法运算,组合起来便可学习所有的算术运算。

NALU由两个NAC单元组成,第1个NAC计算累加向量 $\mathbf{a}$,用于存储加法和减法运算的结果:

$$\mathbf{a} = \mathbf{W} \mathbf{x} \quad (2)$$

式中, $\mathbf{x}$ 为输入参量。第2个NAC在对数空间运行,学习乘法和除法,结果存于 $\mathbf{m}$:

$$\mathbf{m} = \exp[\mathbf{W} \ln(|\mathbf{x}| + \epsilon)] \quad (3)$$

式中, ϵ 是一个小数,可取 10^{-10} ,以防计算中出现 $|\mathbf{x}|=0$ 的情况。这样,NALU算法可写作如下形式:

$$\mathbf{y} = \mathbf{g} \odot \mathbf{a} + (1 - \mathbf{g}) \odot \mathbf{m} \quad (4)$$

式中, $\mathbf{y}$ 为输出参量; $\mathbf{g}$ 为门控单元:

$$\mathbf{g} = \text{sigmoid}(\mathbf{G} \mathbf{x}) \quad (5)$$

式中, $\mathbf{G}$ 是标准的可训练参数矩阵。

利用式(1)~式(5)算法可以构建神经网络的一个NALU层。实际应用时,可将包含不同神经元的多个NALU层组合在一起,即可建立针对复杂过程的神经网络模型。

1.2 训练模型

多层NALU模型可以采用python语言编码,在不同的软件平台和构架上实现,如当前比较流行的pytorch、keras和tensorflow等,本课题选择pytorch进行编码实现。

一般在训练模型时,最重要的是选择合适的损失函数、优化算法和学习速率。

损失函数(loss function)是训练要达到的目标,反映了预测值与实际值之间的误差。选择如下形式的均方误差损失函数:

$$f_{\text{loss}}(\mathbf{y}_p, \mathbf{y}_t) = \frac{1}{n} \sum_{i=1}^n (\mathbf{y}_{p,i} - \mathbf{y}_{t,i})^2 \quad (6)$$

式中, $\mathbf{y}_{p,i}$ 和 $\mathbf{y}_{t,i}$ 分别表示预测值和真实值,下标 i 表示

输出向量的分量号。

训练过程采用的优化算法是寻找使损失函数最小化的算法,从而获得网络的最佳可训练参数矩阵。Pytorch 中常用的 4 种优化器是随机梯度下降法(Stochastic gradient descent,SGD)、动量梯度下降算法(Momentum)、前向均方根梯度下降算法(Root mean square propagation,RMSProp)、自适应矩估计(Adaptive moment estimation,Adam)。其中,SGD、Momentum、RMSProp 和 Adam 依次序后者为前者的改进算法。SGD 是初级优化算法,在随机选择梯度时会引入噪声,影响权值更新的方向,且不能克服局部最优解问题,因此,改进型的优化算法 RMSProp 和 Adam 是目前最为常用的算法。

学习速率与所选择的优化器以及训练过程有关。一般在训练刚开始时可选择较大的学习速率,以加快训练的进程;当训练到一定程度时应适当降低学习速率。

1.3 微观组织预报模型

合金成分、工艺条件和设备条件是决定铝合金凝固组织的主要因素。选择的主要输入参数共 26 个,其中包括 14 个合金元素:Si、Mg、Fe、Ti、Sr、Mn、Cu、Zr、Zn、Ni、V、In、Mo 和 Cr;6 个铸造工艺参数:浇注温度、铸造速度、冷却水量、电磁场频率、线圈电流、电磁场强度;主

要设备参数:结晶器直径;5 个主要处理参数:固溶温度、固溶时间、变形量、时效温度、时效时间。预测参数为局部晶粒特征参数,共 18 个,分别包括铸锭中部和边部的 5 个晶粒尺寸以及晶粒间距,主要反映晶粒的形貌和分布特征。

根据上述条件,网络结构选择 4 个 NALU 层,其中各层的输入和输出神经元数分别为(26,32)、(32,28)、(28,23)、(23,18),其中,第 1 层的输入神经元个数等于输入参量的数目,后续层的输入与其前一层的输出神经元数相等;最后一层的输出神经元数等于组织特征参数的数目,前面几层的输出神经元数依据第 1 层输入和最后一层输出确定。模型建立之后,在 Pytorch 平台上进行训练,即得预测微观组织的神经网络模型。

本课题采用了 RMSProp 和 Adam 两种优化方法,并对其预测结果进行了比较。

2 模拟结果与讨论

以铝合金半连续铸造为例进行讨论。利用图像采集和分析软件将金相照片上的信息转为样本数据的输出参数,并与输入相关参数一起存于 csv 格式的 excel 文件,并压缩成 gz 格式(如 mydata.csv.gz),样本数据的列表格式见表 1,此格式文件可在训练时快速打开,

表 1 训练样本的输入/输出参量的列表格式

Tab.1 Format list of input/output parameters for the training samples

合金成分				工艺参数			结晶器 直径/mm	晶粒尺寸及晶粒间距/ μm					
Si	Mg	Fe	...	浇注温 度/ $^{\circ}\text{C}$	铸造速度/ ($\text{mm} \cdot \text{min}^{-1}$)	...		中部 1 号晶粒	2-1 距离	2 号晶粒	3-1 距离	3 号晶粒	...
0.21	1.25	0.40	...	710.0	25.0	...	40.0	30.03	31.27	32.51	30.34	30.65	...
9.00	0.20	0.10	...	710.0	40.0	...	40.0	21.29	22.17	23.05	21.51	21.73	...
6.93	0.49	0.02	...	710.0	40.0	...	50.0	44.07	45.89	47.71	44.52	44.98	...
7.00	0.50	0.20	...	710.0	40.0	...	250.0	148.83	154.98	161.13	150.37	151.91	...
0.00	1.50	0.00	...	730.0	75.0	...	350.0	618.56	644.12	669.68	624.95	631.34	...
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮

数据可快速调用。

NALU 是出现时间不久且发展还不完善的算法,训练时容易产生损失函数值异常波动或者非数值的情况,选择合适的优化方法和学习速率可以防止此类问题的产生。训练过程表明,RMSProp 优化方法可采用较大的学习速率,但因其算法特点易产生计算被零除的问题,所以,在训练过程中需不断降低学习速率,且达到一定训练步后会导致训练过程无法继续,此时改用 Adam 方法可继续训练,而且会减小损失函数的值,提高模型的精度;而全程采用 Adam 优化方法,中途无需修改学习速率,最终也能取得较好的训练精度。

采用了两种训练方法:第 1 种训练方法是开始时采用 RMSProp 优化算法,学习速率较高,取 0.003,训练

至 32 000 步;之后学习速率调整为 0.000 1,训练达到 151 000 步;最后,选择 Adam 优化算法继续训练,本研究训练至 940 000 步,损失函数值在 0.000 4~0.001 7 之间波动。第 2 种训练方法全程采用 Adam 优化算法,学习速率为 0.000 1,训练至 1 999 000 步之后,出现损失函数值异常波动。两种方法训练过程中损失函数值的变化见图 1。很显然,第 1 种方法效率和精度优于第 2 种,但训练过程中需调整学习速率,最后改用 Adam 优化算法有助于进一步提高精度;而采用 Adam 优化算法,全程无需调整学习速率,便于计算,但学习速率不能太大,由此导致训练步数增加和效率降低。

训练是分段进行的,每次训练一定步数,若损失函数值不满足要求,则后续训练在前一步基础上继续,除




图1 两种训练方法的损失函数值随训练步的变化

Fig.1 Variation of loss function value with training steps by each training method

验证样本是重新从样本数据中随机抽取外,其他训练条件保持不变。验证样本的改变是在后续个别训练步出现损失函数值增大的原因,见图1。此外,应防止过训练,这是因为当训练达到一定程度,继续增加训练步不但不能提高精度,反而会使预测性能变差。最佳训练结果是:第1种方法247 000步损失函数值达到0.000 6,第2种方法1 002 000步损失函数值达到0.001 0。

任意选取8组不同条件(见表2)的铝合金半连续铸造条件,对两种训练方法的效果进行比较。模型1的预测结果见表3,对平均晶粒尺寸预测的误差小于9%;模型2的预测结果见表4,预测误差小于11%。可见,模型2的预测精度和训练效率不如模型1。

表2 铝合金半连续铸造参数

(浇注温度为710.0℃、铸造速度为40.0 mm/min)

Tab.2 Parameters of semi-continuous casting aluminum alloy						冷却水量/ (L·min ⁻¹)	结晶器直 径/mm
$w_B/\%$							
Si	Mg	Fe	Sr	V	In		
9.00	0.20	0.10	0.03	0.00	0.00	30.0	40.0
9.00	0.20	0.10	0.03	0.00	0.00	30.0	40.0
9.00	0.20	0.10	0.04	0.00	0.00	30.0	40.0
9.00	0.20	0.10	0.04	0.00	0.00	30.0	40.0
9.00	0.20	0.10	0.04	0.00	0.00	30.0	40.0
7.00	0.50	0.05	0.00	0.50	0.30	40.0	250.0
7.00	0.50	0.10	0.00	0.50	0.30	40.0	250.0
7.00	0.50	0.15	0.00	0.50	0.30	40.0	250.0

表3 模型1对平均晶粒尺寸的预测误差

Tab.3 Prediction errors of average grain size by model 1					
中部/ μm		误差/%	边部/ μm		误差/%
实际值	预测值		实际值	预测值	
21.99	21.16	-3.76	14.51	14.31	-1.36
21.58	21.16	-1.93	14.24	14.31	0.51
20.94	20.27	-3.19	13.82	13.79	-0.23
20.48	20.27	-1.02	13.52	13.79	1.98
20.05	20.27	1.10	13.23	13.79	4.22
138.95	137.21	-1.25	91.71	91.22	-0.53
142.53	153.76	7.88	94.07	102.20	8.64
149.64	152.03	1.60	98.76	101.21	2.48

由表3可见,其中模型1中部和边部的最大预测误差分别为7.88%和8.64%,能够满足实际应用的要求。

表4 模型2对平均晶粒尺寸的预测误差

Tab.4 Prediction errors of average grain size by model 2					
中部/ μm			边部/ μm		
实际值	预测值	误差/%	实际值	预测值	误差/%
21.99	22.56	2.58	14.51	14.82	2.15
21.58	22.56	4.53	14.24	14.82	4.09
20.94	20.22	-3.46	13.82	13.25	-4.14
20.48	20.22	-1.29	13.52	13.25	-2.01
20.05	20.22	0.82	13.23	13.25	0.13
138.95	145.58	4.77	91.71	96.99	5.76
142.53	155.72	9.26	94.07	104.15	10.71
149.64	158.90	6.19	98.76	106.49	7.82

但从智能预测角度,此误差稍大,主要源自两方面原因:一是训练目标数较多,即表1中铸锭中部和边部的晶粒尺寸及晶粒间距,共18个参量;二是表3中的实际值是图像处理软件直接根据晶粒形貌统计的平均晶粒尺寸,而预测值则是根据各条件下计算得到的18个局部晶粒特征参量通过换算得到的。

模型的输入参量为26个,输出参量为18个,输入/输出约为1.4。较小的比例不利于训练出高预测精度的神经网络模型,而本研究取得的误差小于9%,这得益于NALU算法良好的外推性能。另外,输出参量包含了晶粒形貌的局部特征参量,不仅能反映出局部晶粒的尺寸,而且由局部晶粒间距还可反映出晶粒的形貌和分布特征,这比单纯的平均晶粒直径反映出的结构信息更多。当然,输出参量还可包括更多细致的特征,如第二相及其分布等。

即使合金成分、工艺条件、设备条件都相同,微观组织的局部特征也不统一,这是产生误差的主要原因之一。因此,优化样本数据中的局部晶粒特征参量的具体选取和测量方法对提高模型训练精度具有重要作用,有待进一步研究。

本课题提出的铝合金微观组织预报模型及训练方法同样适用于其他材料特性的建模,对于建立高质量的组织性能预报模型具有普适性。同时,所建立的智能模型与优化相结合,可用于铝合金制备与加工过程的优化以及新型铝合金的智能化设计。建议采用在遗传算法基础上发展起来的差分进化算法,计算结果更稳定。

3 结 论

(1)由多个NALU算法层构成的神经网络模型适用于铝合金组织性能的智能预测。

(2)RMSProp和Adam优化算法相结合加之学习速率的合理调整,是多层NALU神经网络模型的高效训练方法。

(3)用局部晶粒特征可以实现对铝合金微观组织形貌和分布特点较细致的表达,可以用多层NALU神经

网络对其与合金元素、工艺条件和设备参数之间的复杂关系进行建模和训练,训练后的均方误差达到 0.000 6,对 8 组任选的不同铸造条件的铝合金平均晶粒尺寸预测的误差小于 9%,适于微观组织的预测与新合金设计。

参 考 文 献

- [1] HOLDREN J P. Materials genome initiative for global competitiveness[R]. The National Science and Technology Council, Washington DC: USA, 2011.
- [2] 宿彦京,付华栋,白洋,等. 中国材料基因工程研究进展[J]. 金属学报, 2020, 56(10): 1 313-1 323.
- [3] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back propagating errors[J]. Nature, 1986, 323 (6 088): 533-536.
- [4] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313 (5 786): 504-507.
- [5] LAASRAOUI A, JONAS J J. Prediction of temperature distribution, flow stress and microstructure during the multipass hot rolling of steel plate and strip[J]. ISIJ International, 1991, 31(1): 95-105.
- [6] GOODFELLOW I, BENGIO Y, COURVILLE A. Deep Learning (深度学习)[M]. 赵申剑,黎或君,符天凡,等译. 北京:人民邮电出版社, 2017.
- [7] 周志敏. 基于深度学习的合金设计与预报方法[J]. 特种铸造及有色合金, 2019, 39(5): 493-496.
- [8] 周志敏,刘永利. 材料学的多尺度模拟与应用[M]. 北京:科学出版社, 2020.
- [9] SHA W, EDWARDS K L. The use of artificial neural networks in materials science based research[J]. Materials & Design, 2007, 28 (6): 1 747-1 752.
- [10] 樊新民,孔见. 人工神经网络在材料科学研究中的应用[J]. 材料导报, 2002, 16(4): 28-30.
- [11] HASSAN A M, ALRASHDAN A, HAYAJNEH M T, et al. Prediction of density, porosity and hardness in aluminum-copper-based composite materials using artificial neural network[J]. Journal of Materials Processing Technology, 2009, 209(2): 894-899.
- [12] POWAR A, DATE P. Modeling of microstructure and mechanical properties of heat treated components by using artificial neural network[J]. Materials Science & Engineering, 2015, A628: 89-97.
- [13] REDDY N S, PANIGRAHI B B, HO C M, et al. Artificial neural network modeling on the relative importance of alloying elements and heat treatment temperature to the stability of α and β phase in titanium alloys[J]. Computational Materials Science, 2015, 107: 175-183.
- [14] 李朝霞. 人工神经网络及其在铸造工业中的应用[J]. 铸造, 2000, 49(1): 31-35.
- [15] 黄松林,崔建忠. 基于人工神经网络的铝合金铸锭裂纹倾向预测[J]. 中国有色金属学报, 2008, 18(9): 1 699-1 705.
- [16] GUDUR P P, DIXIT U S. A neural network-assisted finite element analysis of cold flat rolling[J]. Engineering Applications of Artificial Intelligence, 2008, 21(1): 43-52.
- [17] BAGHERIPOOR M, BISADI H. Application of artificial neural networks for the prediction of roll force and roll torque in hot strip rolling process[J]. Applied Mathematical Modelling, 2013, 37 (7): 4 593-4 607.
- [18] 王秀梅,吕程. 轧制力预报中的神经网络和数学模型[J]. 东北大学学报(自然科学版), 1999, 20(3): 319-321.
- [19] DUTTA P, PRATIHAR D K. Modeling of TIG welding process using conventional regression analysis and neural network-based approaches[J]. Journal of Materials Processing Technology, 2007, 184(1): 56-68.
- [20] KANTI K M, RAO P S. Prediction of bead geometry in pulsed GMA welding using back propagation neural network[J]. Journal of Materials Processing Technology, 2008, 200(1-3): 300-305.
- [21] 潘江峰,钟约先,袁朝龙. 基于遗传算法和神经网络技术的板料拉深成形参数优化[J]. 锻压技术, 2006(6): 44-46.
- [22] 苏娟华,张文琼,李丽春. 基于多目标遗传算法优化板料拉深成形工艺参数[J]. 机械设计与制造, 2009(8): 128-130.
- [23] TRASKYZ A, HILLY F, REEDY S, et al. Neural Arithmetic Logic Units[A]. Proceedings of the 32nd International Conference on Neural Information Processing Systems[C]. New York, USA, 2018.

(编辑:彭瑾)

一体化压铸成形工艺与装备 列入国家重点研发计划

日前,国家科技管理信息系统公共服务平台公布了 44 个国家重点研发计划重点专项 2022 年度项目申报指南征求意见稿。其中,“高性能制造技术与重大装备”重点专项中的“一体化承载式车身压铸成形工艺与装备”入选。

研究内容:研究新型免热处理高强韧压铸铝合金材料性能调控机理;突破多材料一体化车身多目标优化设计、超大型复杂薄壁铸件模具/工艺、大型车身一体化压铸件与环境件连接等关键技术;研发新能源乘用车一体化结构件及其压铸成形工艺;研制超大型智能压铸成套装备,在新能源乘用车下车体等实现示范应用。

考核指标:新型免热处理高强高塑压铸铝合金材料抗拉强度 ≥ 270 MPa,屈服强度 ≥ 135 MPa,伸长率 $\geq 12\%$;完成铝合金压铸下车体开发,对应传统钢板冲焊件减重不少于 10%;完成超大型智能压铸装备开发,压铸单元最大锁模力(T) $\geq 10\ 000$ t,最短建压时间 ≤ 28 ms;完成一体化下车体压铸件智能化示范产线建设,设计产能 10 万件/年,下车体压铸件产品合格率 $\geq 90\%$ 。技术成熟度 ≥ 8 级;制定相关团体、行业或国家技术标准 ≥ 3 项。

(摘自压铸周刊)