

文章编号:1000-582x(2001)02-0068-04

铝锂合金高温变形流变应力的人工神经网络模型

刘雪峰, 汪凌云

(重庆大学材料科学与工程学院, 重庆 400044)

摘要: 对所获试验数据采用数理统计方法建立合金材料的高温塑性变形稳态流变应力模型, 其精度较低, 同时建模过程复杂且工作量大。以 Gleeble-1500 热模拟试验机得到的实验数据为基础, 根据 BP 人工神经网络算法原理, 建立了 1420 Al-Li 合金高温塑性变形稳态流变应力与应变速率和变形温度对应关系的预测模型。结果表明, 神经网络用于稳态流变应力建模是可行的, 模型计算值与实测值的偏差 < 5%, 较好地反映了实际变形过程的特征。

关键词: 铝锂合金; 高温塑性变形; 流变应力; 神经网络

中图分类号: TG 335.5; Q 954.52

文献标识码: A

合金材料在高温变形时常会出现稳态流变特征, 即在一定变形温度和应变速率条件下, 当真应变 ϵ 超过一定值后, 真应力 σ 并不随应变量的继续增大而发生明显变化。通常都是对所获试验数据采用数理统计方法建立合金材料的高温塑性变形稳态流变应力模型, 但由于影响稳态流变应力的因素很多, 用上述方法建立的数学模型与复杂的真实变形情况有时相差甚远, 模型精度受到变形条件的限制, 而且建模过程复杂, 工作量大, 而基于神经网络进行的系统建模可以弥补这一本质上的不足。由于后者建模时无须对研究对

象作任何假设, 模型能够以其良好的映射逼近能力逼近真实的变形过程^[1-3]。文中利用 1420 合金高温压缩试验的实际测量数据, 根据 BP 算法原理, 建立了 Al-Li 合金高温塑性变形的稳态流变应力模型。

1 试验及结果

1.1 试验材料与方法

试验材料为 1420Al-Li 合金, 其化学成分 (wt%) 见表 1, 其余为 Al。

表 1 1420 Al-Li 合金的化学成分 %

牌号	Cu	Mg	Si	Li	Fe	Zr	Na	Ti	H
1420	0.05	5.44	0.013	2.15	0.02	0.12	0.0004	0.05	0.6×10^{-6}

该合金采用 IM 法进行熔炼和铸造。在熔剂保护下进行熔化和精炼, 氩气保护气氛水冷模浇注成 $\phi 405$ mm \times 1200 mm 的圆锭。经 455 $^{\circ}$ C、12 h 均匀化退火处理后, 从中取样加工成直径为 8 mm、长为 12 mm 的小圆柱形试样, 其两端加工有储存润滑剂 (75% 石墨 + 25% 机油, 质量分数) 的浅槽, 以减少试样与压头之间的摩擦。试样在 Gleeble-1500 热加工模拟试验机上进行等温恒应变速率压缩试验, 变形后立即水淬。变形

过程全部由计算机控制并自动采集有关数据, 同时绘制出试验材料的真应力-应变曲线。1420 Al-Li 合金试验的变形温度 t ($^{\circ}$ C) 为: 300, 350, 400, 450, 500; 应变速率 $\dot{\epsilon}$ (s^{-1}) 为: 0.001, 0.01, 0.1, 1.0, 10.0, 30.0; 变形程度为 0~0.7。

1420 Al-Li 合金的等温恒应变速率压缩试验规范列于表 2, 其中 T 表示该变形条件下的数据用作训练样本, C 表示该变形条件下的数据用作检测样本。

· 收稿日期: 2000-06-21

基金项目: 航天工业总公司国防军工配套研制项目 (703-14-2)

作者简介: 刘雪峰 (1970-), 男, 重庆人, 重庆大学博士生。从事材料制备过程的数值模拟与优化研究。

表2 试验的变形条件

$t/^\circ\text{C}$	$\dot{\epsilon}/\text{s}^{-1}$					
	0.001	0.01	0.1	1.0	10.0	30.0
300	C	T	C	T	C	T
350	T	C	T	C	T	C
400	C	T	C	T	C	T
450	T	C	T	C	T	C
500	C	T	C	T	C	T

1.2 试验结果

1420 Al-Li 合金在各具体变形温度和应变速率条件下实测稳态流变真应力值($\epsilon = 0.3613$)及进入稳态流变阶段对应的真应变值分别如表3和表4所示。

表3 1420 合金不同压缩变形条件下实测稳态真应力值 MPa

$\dot{\epsilon}/\text{s}^{-1}$	$t/^\circ\text{C}$				
	300	350	400	450	500
0.001	69.91	38.79	9.08	10.53	6.23
0.01	116.84	80.44	42.14	18.20	18.18
0.1	184.83	105.82	81.88	55.55	32.08
1.0	192.97	147.98	119.71	88.59	57.46
10.0	207.34	183.87	141.26	106.78	73.74
30.0	260.97	215.96	163.76	144.13	108.70

表4 1420 合金不同压缩变形条件下进入稳态流变对应的真应变值

$\dot{\epsilon}/\text{s}^{-1}$	$t/^\circ\text{C}$				
	300	350	400	450	500
0.001	0.024 4	0.019 5	0.012 2	0.011	0.010
0.01	0.046 4	0.043 6	0.032 2	0.026 9	0.015
0.1	0.101 3	0.080 6	0.040	0.034 2	0.017 1
1.0	0.136 7	0.095 2	0.056 2	0.041 0	0.036 6
10.0	0.143 5	0.102 5	0.064 2	0.046 5	0.041 5
30.0	0.158 6	0.125 6	0.073 1	0.054 2	0.043 9

2 算法的基本原理

2.1 基本原理

设BP算法的网络结构有3层:在输入层有 n 个输入向量; l 个隐含层;在输出层有 m 个输出向量,输入层结点、隐含层结点和输出层结点分别用下标 i, h, j 表示;由输入结点 i 到隐含层的 h 结点的权值用 w_{ih} 表示;由隐含层结点 h 到输出层结点 j 的权值用 w_{hj} 表示。

对于输入数据 x , 设其目标输出为 d , 而实际输出

为 y_0 。为了训练网络,由 $[x^k, y^k]$ 组成训练样本模式对,上标 k 表示训练对的序号,对每一个样本模式对进行如下的正向传播和反向传播处理。

1) 正向前馈计算

当输入第 k 个数据 $x(k)$ 时,隐含层结点 h 的总输入(加权和)为:

$$S_h(k) = \sum_i x_i(k) \cdot W_{ih} \quad (1)$$

采用 S 型作用函数处理输入与输出的关系,隐含层结点 h 的输出为:

$$y_h(k) = \frac{1}{1 + e^{-\sum_i x_i(k) \cdot W}} \quad (2)$$

相应地,输出层结点 j 的输出为:

$$y_j(k) = \frac{1}{1 + e^{-\sum_i y_i(k) \cdot W}} \quad (3)$$

如果用 k 个输入的所有输出结点的误差平方总和作为网络训练指标,则有:

$$J(W) = \frac{1}{2} \sum_k \sum_j [d_j(k) - y_j(k)]^2 \quad (4)$$

由于转移函数(S型函数)是连续可微的,很显然, $J(W)$ 也是每个权值的连续可微函数。

2) 误差反向传播修正各层权值

采用梯度规则,由 J 对各个 W 求导,可以求得使 J 最小的梯度,作为调整权值的反向。

① 由隐含层到输出层的权值 w_{hj} 的调整:

$$\Delta W_{hj} = -\eta \frac{\partial J(W)}{\partial W_{hj}} = \eta \sum_k \delta_j(k) \cdot y_h(k) \quad (5)$$

$$\delta_j(k) = [d_j(k) - y_j(k)] \cdot f'(S_j(k)) \quad (6)$$

② 由输入层到隐含层的权值的调整:

$$\Delta W_{ih} = -\eta \frac{\partial J(W)}{\partial W_{ih}} = \eta \sum_k \delta_h(k) \cdot x_i(k) \quad (7)$$

$$\delta_h(k) = \sum_j W_{hj} \cdot \delta_j(k) \cdot f'(S_h(k)) \quad (8)$$

在实际应用时,常用当前误差对权值进行调整,这样,式(5)和式(7)中对 k 的求和项就可省掉,同时,为了加速网络的训练速度,改善其收敛性,在权值调整时附

加一个冲量项。于是,权值调整公式为对输出层:

$$\Delta W_{hj}(k+1) = \eta \delta_j(k) \cdot y_h(k) + \alpha \cdot \Delta W_{hj}(k) \quad (9)$$

对输入层:

$$\Delta W_{ih}(k+1) = \eta \delta_h(k) \cdot x_i(k) + \alpha \cdot \Delta W_{ih}(k) \quad (10)$$

其中, α 为冲量因数,或称为惯性因子, η 为学习因子,一般 $\alpha = 0.6 \sim 0.95$, $\eta = 0.45 \sim 0.90$ 。

2.2 BP 算法的软件实现

BP 算法实际上是求误差函数的极小值,它通过多个学习样本的反复训练并采用最速下降算法,使得权值沿误差函数的负梯度方向改变,并收敛于最小点,根据 BP 算法原理,在计算机上基于 MATLAB 语言开发了相应的可实现程序,其程序框图如图 1 所示。

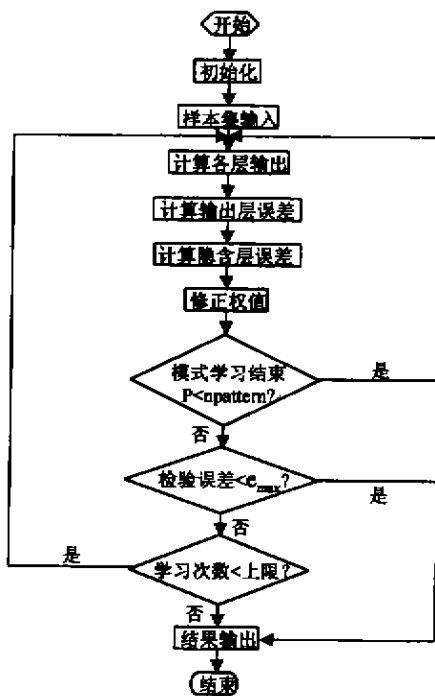


图 1 BP 算法程序框图

3 稳态流变应力模型的建立

3.1 网络模型的优化设计

本文中,稳态流变应力的神经网络模型结构为一个输入层、一个输出层和一个隐层。根据合金高温压缩变形的特点,稳态流变应力是变形温度和应变速率的函数,所以,网络模型的输入层有 2 个输入向量,它们是变形温度 t 和应变速率 $\dot{\epsilon}$; 输出层只有一个输出

量即稳态流变应力值 σ ; 隐含层神经元数取为 5^[4], 见图 2。




图 2 神经网络结构

3.2 数据预处理

采集了 1420Al-Li 合金高温压缩变形时的变形程度、变形温度和应变速率等数据,并考虑到对实际变形过程进行建模训练时,所采集的实测数据通常会存在各种干扰因素,因此,为使所建模型具有泛化能力,把所采集的数据分为了训练集和测试集。

同时,根据 BP 网络输入输出范围的要求,按式 (11) 对期望输出值和输入层参数进行量纲为一的归一化处理,使各特征变量在 $[0.1, 0.9]$ 范围内取值,避免网络模型迭代计算时数值过于集中在某些神经元和权值上而降低模型的解算精度。

$$S_n = \frac{0.8(S - S_{\min})}{S_{\max} - S_{\min}} + 0.1 \quad (11)$$

式中: S —网络的输入参数 $t, \dot{\epsilon}$ 和输出参数 σ ; S_{\min} , S_{\max} —分别为相应数据 S 的最大值和最小值。

3.3 BP 算法的改进

传统的 BP 算法存在学习时间长、网络收敛慢的缺点,为了使计算过程减少平坦区的迭代次数、加速收敛、防止振荡,局部最小时迅速退出不灵敏区,在传统的 BP 算法的基础上做了如下改进:

采取批处理的方式来修正网络模型的连接权值,即在所学习样本都输入后计算系统的总误差,若系统误差不满足要求则修正权值,以保证系统误差在学习过程中总是向减小的方向变化,并加快系统的收敛速度。此外,计算时选取 $(-1, +1)$ 内的权值作为权值初始化范围。

3.4 计算结果与分析

对数据进行归一化预处理后,用基于 MATLAB 语言自行编制的 BP 算法程序进行了计算,模型预测结果 ($\epsilon = 0.3613$) 如表 5 所示,图 3 将人工神经网络预测值(见表 5)和实测值(见表 3)进行了比较。

表5 1420合金不同压缩变形条件下
稳态流变应力模型预测值 MPa

$\dot{\epsilon}/s^{-1}$	$t/^\circ C$				
	300	350	400	450	500
0.001	71.20	38.68	9.06	9.99	5.92
0.01	115.80	79.43	41.94	18.45	18.65
0.1	184.65	105.89	82.40	55.47	32.89
1.0	194.11	147.78	120.06	87.11	58.79
10.0	206.40	182.22	141.30	108.02	72.30
30.0	260.99	217.21	162.10	142.35	106.64




图3 稳态流变应力神经网络预测值和实测值比较

由上面的结果可以看出,所建的网络模型在计算稳态流变应力时,误差在5%以内,完全能够满足工程

计算和实际变形的要求,而传统的统计模型计算误差达到10%。

4 结论

笔者应用BP神经网络建立了1420Al-Li合金高温压缩变形时的稳态流变应力模型。从研究结果可以看出,该方法是有用的、可行的。基于神经网络的数学模型能够对训练数据进行充分学习,并能对未知的输出结果进行精确的预测。

参考文献:

- [1] CHUN M S, BIGLOU J. Using networks to predict parameters in the hot working of aluminum alloys[J]. Journal of Materials Processing Technology, 1999, 86: 245-251.
- [2] ROBERTS S M, KUSIAK J. Prediction of damage evolution in gorged aluminum metal matrix composites using a neural network approach[J]. Journal of Materials Processing Technology, 1998, 80-81: 507-512.
- [3] KORCZAK P, DYJA H. Using neural network models for predicting mechanical properties after hot plate rolling processes[J]. Journal of Materials Processing Technology, 1998, 80-81: 481-486.
- [4] ZURADA J M. Introduction to Artificial Neural Systems [M]. New York: West Publishing Company, 1992. 10.

Artificial Neural Networks Models for Flow Stress during High Temperature Plastic Deformation of Al-Li Alloy

LIU Xue-feng, WANG Ling-yun

(College of Material Science and Engineering, Chongqing University, Chongqing 400044, China)

Abstract: Using gained experimental data to develop the models of stable flow stresses at high temperature plastic deformation by statistical methods for alloy materials, precision of the models is poor and at the same time the processes of modeling are complicated with great workload. On the basis of the data obtained on Gleeble-1500 Thermal Simulator, the predicting models for the relation between stable flow stress during high temperature plastic deformation and deformation strain, strain rate and temperature for 1420 Al-Li alloy have been developed with BP Artificial Neural Network method. The results show that the model on basis of BPNN is practical and it reflects the real feature of the deforming process. It states that the difference between the real value and the output of the model is in order of 5 percent.

Key words: Al-Li alloy; high temperature plastic deformation; flow stress; neural networks

(责任编辑 李胜春)