

用改进遗传算法优化的带钢卷取温度预报模型

孙铁军^{1,2,3}, 杨卫东^{1,3}, 程艳明^{2†}, 段风云⁴, 弭洪涛²

(1. 北京科技大学 自动化学院, 北京 100083; 2. 北华大学 电气信息工程学院, 吉林 吉林 132021;

3. 北京科技大学 钢铁流程先进控制教育部重点实验室, 北京 100083; 4. 北华大学 信息技术与传媒学院, 吉林 吉林 132013)

摘要: 由于热轧带钢卷取温度控制过程存在强非线性, 经典数学模型难以精确描述, 我们采用遗传神经网络建立了卷取温度预报模型, 并且通过改进的遗传算法优化了神经网络的权值. 其中, 提出了重新进化的思想, 用“返祖”操作找回丢失的较优模式并将其耦合至下一代种群中, 极大的提高了算法的收敛速度; 分析了“种群解的空间跨度”和“基因段距离”对种群多样性的影响, 用“优生”操作来推动算法从平面到多维空间的立体式搜索, 以勘探和挖掘出更广、更优的寻优区间, 并在种群进化后期, 强力驱动算法收敛于全局最优. MFC(微软基类库)仿真结果表明: 该卷取温度预报模型的收敛速度快、精度高, 满足实时在线的控制要求, 预报精度在 $\pm 10^\circ$ 范围之内, 能为卷取温度的前馈补偿控制提供可靠的参考数据, 从而为进一步提高卷取温度的控制精度提供了新的途径.

关键词: 卷取温度; 遗传算法; 返祖; 基因段距离; 优生

中图分类号: TP273 文献标识码: A

Improved genetic algorithm for optimizing prediction model of strip coiling temperature

SUN Tie-jun^{1,2,3}, YANG Wei-dong^{1,3}, CHENG Yan-ming^{2†}, DUAN Feng-yun⁴, MI Hong-tao²

(1. School of Automation and Electrical Engineering, University of Science and Technology Beijing, Beijing 100083, China;

2. School of Electric and Information Engineering, Beihua university, Jilin Jilin 132021, China;

3. Key Laboratory for Advanced Control of Iron and Steel Process (Ministry of Education),
University of Science and Technology Beijing, Beijing 100083, China;

4. Institute of Information Technology and Media, Beihua University, Jilin Jilin 132013, China)

Abstract: Because of the high nonlinear features in the process of the hot rolled strip coiling temperature, it is difficult to use classical methods to build up an accurate mathematical model; we in this paper build for the strip coiling temperature a prediction model based on genetic neural network, and optimize the weights of the neural network through the improved genetic algorithm. In this scheme, we introduce the idea of re-evolution and employ the ‘atavism’ operation to retrieve the superior operation mode that has been lost and couple it into the next generation of population, to increase the convergence speed of the algorithm. We also analyze the impact on population diversity from the ‘space spans of population solution’ and the ‘gene segment distance’. Moreover, we use ‘Eugenics’ operation to extend the algorithm search from a plan to a solid space to explore and excavate a broader, superior optimization interval. In the later section of the evolution process, the algorithm is highly driven to converge to the global optimum. Simulation results of MFC (Microsoft Foundation Classes) show that this prediction model of strip coiling temperature is with the advantage of fast convergence and high precision, satisfying the requirements of the real-time online control with a prediction accuracy within the range of $\pm 10^\circ$. Thus, it can provide with reliable reference data in the feedforward compensation control for coiling temperature, and offers a new way to further enhance the control precision of coiling temperature.

Key words: coiling temperature; genetic algorithm; atavism; gene segment distance; eugenics

1 引言(Introduction)

卷取温度控制是热轧带钢生产中最重要的一环之一, 它不仅对热轧带钢最终的性能有极大的影响, 而且还是带钢能否顺利卷取、安全下线的决定性因素.

如何提高卷取温度的控制精度, 是热连轧领域所关注的重要问题之一.

图1为某钢厂1780 mm卷取温度控制工艺流程示意图. 整个系统由水冷粗调区、水冷精调区和空冷区

组成. 辊道长108 m, 辊道上下均布置由电磁阀控制的喷水集管; 其中, 粗调区设置48对喷水集管, 精调区设置12对喷水集管; 粗调区控制方式为集管开闭可调但流量不可调, 精调区控制方式为集管开闭及流量均可调. 在精轧机末架位置设置精轧后测温仪, 在卷取机入口处设置卷取测温仪. 品种不同的带钢, 在精轧机组的终轧温度一般为810°C~910°C, 而卷取温度要求在600°C~650°C; 这就需要在100多米的输出辊道上, 通过设置高冷却效率的喷水装置, 在5 s~15 s的时间内, 使带钢温度下降200°C~300°C.

目前热连轧主要依靠经典的数学模型来对卷取温度进行控制, 命中率不理想. 近些年来, 很多学者相继提出了新的控制策略或参数优化方法, 以图进一步提高卷取温度的控制精度. 如文献[1]提出了变结构PI迭代学习方法对层流冷却过程进行设定控制, 使卷取温度控制在可接受的范围内. 但该方法通用性较差, 带钢规格改变后, 头几块钢的卷取温度命中率低, 从而使该方法的应用范围受到限制. 文献[2]将神经网络和案例推理技术相结合, 提出了混合智能参数辨识方法. 该方法极大的提高了带钢卷取温度的预报精度, 但该方法只是将离线辨识参数应用于在线, 在线模型的预报精度有时得不到保证.

本文旨在探索将先进的控制方法和优化算法应用于卷取温度控制的相关环节, 以图进一步提高卷取温度的控制精度. 在设计基于BP(error back propagation network)遗传神经网络的卷取温度预报模型时, 用包含“优生”和“返祖”操作的改进遗传算法, 保证了模型的精度和实时性. 本文的目标是将卷取温度的在线实时预报精度控制在±10°C 范围之内, 为卷取温度的前馈补偿控制提供可靠的参考数据. 通过仿真来观察和验证所应用的先进控制方法和优化算法在该温度预报模型中所取得的效果.

2 优化 BP 神经网络权值的基本遗传算法的实现(The realization of the basic genetic algorithm to optimize the weights of BP neural network)

2.1 BP神经网络(BP neural network)

由于BP神经网络, 即误差反向传播网络, 具有并行计算、分布式信息存贮、容错能力强、非线性映射功能及具备自适应学习功能等一系列优点, 因而很适合应用于强非线性、大时滞系统的控制中.

本文将影响卷取温度最为显著的5个参数: 精轧机出口温度、实际卷取温度、水冷区平均速度、电磁阀开阀数、带钢厚度作为BP神经网络的主输入模式向量; BP神经网络的结构设计为输入节点数为5; 隐层层数为1; 隐层节点数为8; 输出节点数为1. 图2为主输入模式BP神经网络的结构图.

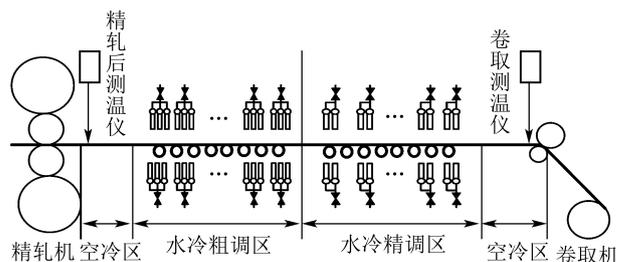


图 1 卷取温度控制工艺流程示意图
Fig. 1 Process control of coiling temperature

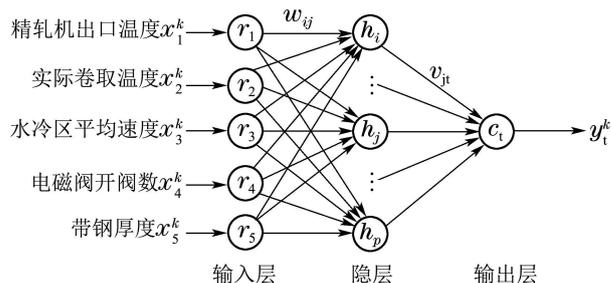


图 2 BP神经网络结构图

Fig. 2 BP neural network structure diagram

BP神经网络为有导师学习, 权值调整采用批处理方式; 取某钢厂卷取目标温度分别为730°C, 520°C, 610°C, 710°C, 680°C, 厚度分别为4.5 mm, 5.5 mm, 7.0 mm, 17.5 mm, 3.0 mm的12块钢, 每块钢取10个点, 即训练样本、测试样本各为120组输入模式向量.

2.2 遗传算法(Genetic algorithm)

遗传算法(genetic algorithm, GA)是一种模拟物种进化过程的最优化计算方法, 可以使神经网络具有更快的收敛性以及较强的学习能力. 用GA优化神经网络的权值, 主要是以适应度函数为依据, 把每一代种群中好的基因通过选择、交叉和变异等操作, 传送到下一代种群中; 在不断地迭代过程中, 最终得到最佳的权值矢量(问题的最优解).

2.3 适应度函数的设计(The design of fitness function)

GA的优点之一是基本不利用外部信息, 仅利用个体的适应度在全局范围内搜索; 适应度函数的选取是否合理, 将直接影响算法的收敛速度及是否收敛在全局最优解.

在本算法中, 采用批处理方式, 设 E_k 为给网络提供模式对 (X_k, D_k) 时输出层上的代价函数

$$E_k = \sum_{t=1}^q (d_t^k - y_t^k)^2 / 2, \quad (1)$$

整个模式训练集上的全局代价函数为

$$E = \sum_{k=1}^m E_k. \quad (2)$$

其中: 网络输入模式向量 $X_K=(x_1^k, x_2^k, \dots, x_i^k, \dots,$

x_n^k); 网络希望输出向量 $D_K=(d_1^k, d_2^k, \dots, d_t^k, \dots, d_q^k)$; 网络输出向量 $Y_K=(y_1^k, y_2^k, \dots, y_t^k, \dots, y_q^k)$.

2.4 基本GA的选择、交叉和变异操作(Selection, crossover and mutation of the basic GA)

基本GA的选择操作保证了种群进化向最优解逼近的趋势, 交叉操作保证了最优解的产生, 变异操作保证了搜索范围的全局覆盖.

选择算子采用轮盘赌选择, 由Roulette()函数来实现; 为了防止算法过早地收敛于局部最优解, 该函数总是保证: ① 种群中适应度最小的10个个体随机地保留2个, 无条件地进入下一代种群. ② 适应度高的个体进入下一代种群的数量不会超过个体总数量的5%.

交叉概率设为0.8, 由Crossover()函数来实现交叉操作; 该函数总是能保证: ① 对种群个体按适应度大小进行排序, 只有两个个体的编号相差大于5时, 才有可能进行交叉操作. ② 具有自动调整功能, 根据进化状态, 自动实现单点交叉与双点交叉的交替变化.

变异概率设为0.006, 由mutation()函数来实现变异操作; 该函数总是能保证: ① 排序前五名的个体不进行变异操作. ② 动态调整变异算子, 根据进化状态, 自动实现单点变异和双点变异的交替变换.

3 改进GA的操作——优生、返祖(Operations of improved GA-eugenics, atavism)

近些年来, 许多学者围绕GA的收敛性和种群多样性问题做了大量的工作, 提出了各种进化策略和设计思想; 如文献[3]提出了双精英协同进化策略, 文献[4]提出了利用已评价个体的相似度去估计未评价个体适应度的设计思想, 文献[5]提出了一种基于精英集进化的个体选择方法, 文献[6]提出了一种基于GA和粒子群算法的混合优化策略. 但以上这些算法终究只是在种群的正常进化过程中所采取各种策略, 在设计理念上明显受到自然界生物自然进化思想的束缚, 对由于种群进化过程中的盲目性、随机性而引起的退化现象明显应对措施不足, 对克服GA收敛速度慢和易陷于局部最优等缺点的效果终究有限. 基于此, 本文在进化策略上另辟蹊径, 提出了一种基于重新进化思想的改进遗传算法; 通过“返祖”操作去找回丢失的较优模式, 并将其耦合至下一代种群, 意图进一步提高算法收敛速度; 利用“优生”操作, 从平面空间到多维空间来推动算法在更广、更优的区域进行立体式搜索, 以使GA的搜索能力得到飞跃式的提升.

3.1 种群多样性的空间表示(Spatial representation of population diversity)

定义1 若种群规模为 L , 个体有 T 个基因段, 即 $a^i = [a^{i(1)} a^{i(2)} \dots a^{i(T)}]$, $i \in \{1, 2, \dots, L\}$, 每个基因段的有效长度为 m , 即 $b_j = [b_{m-1} b_{m-2} \dots b_0]$,

$j \in \{1, 2, \dots, T\}$, 每个基因段取值上、下限分别为 $B_{\text{right}}^l, B_{\text{left}}^l$, $l \in \{1, 2, \dots, T\}$, 种群解的空间规模

可表示为 $J = \frac{\sum_{c=1}^L (|B_{\text{right}}^c| + |B_{\text{left}}^c|)}{L}$; 将种群解的空间等分为 N 等份, 其空间跨度为 $K = \frac{J}{N}$, 则种群空间分布可表示为

$$F = [f^1 f^2 \dots f^n], \quad (3)$$

其中 $(n-1)K \leq f^n \leq n \times K$, $n \in \{1, 2, \dots, N\}$.

从定义1可以看出 F 为 n 维行向量, 每一个向量均表示了种群个体解的和值在空间的分布. 对于第 s 代的个体, $a_s^i = [a_s^{i(1)} a_s^{i(2)} \dots a_s^{i(t)}]$, $i \in \{1, 2, \dots, T\}$, 其空间分布可表示为 $F_s^i = \sum_{j=1}^T a_s^{i(j)}$; 其中, $a_s^{i(j)} = \sum_{x=1}^{m-1} (b_x^{s(i(j))} \times 2^x)$, 其必位于 F 的某一空间上. 显然, F_s^i 在 F 上分布越均匀, 保持种群多样性的可能性越大.

种群空间分布反映了算法搜索空间在平面空间的遍历性, 对种群的多样性作出了全面的解析. 但对于具有 T 个基因段的任意两个个体的比较, 则应从 T 维空间来进行考虑. 基于此, 引入“基因段(DNA)距离”的概念.

定义2 若种群规模、性质如定义1所示, 对第 s 代的任意两个个体 $a_s^p = [a_s^{p(1)} a_s^{p(2)} \dots a_s^{p(T)}]$, $a_s^q = [a_s^{q(1)} a_s^{q(2)} \dots a_s^{q(T)}]$, 其中 $p, q \in \{1, 2, \dots, L\}$, 其基因段(DNA)距离可表示为

$$\sigma(p, q) = \frac{\sum_{y=1}^T (a_s^{p(y)} - a_s^{q(y)})^2}{T}. \quad (4)$$

由定义2可知, 基因段(DNA)距离 $\sigma(p, q)$ 是任意两个个体在 T 维空间的偏差, 此值越大, 说明两个个体在空间的分布越远. 利用 $\sigma(p, q)$, 即可评价种群多样性的优劣, 又可用来确定两个个体是否进行交叉, 从而避免了无效的操作, 极大的提高了算法的收敛速度, 对模型的在线应用可以起到决定性的作用.

3.2 优生(Eugenics)

优生起源于英国, 意思为“健康遗传”, 主要是研究如何用有效手段降低胎儿缺陷发生率. 其主要的内容是控制先天性疾病新生儿, 以达到逐步改善和提高人群遗传素质的目的.

3.2.1 阶段性跨度淘汰法(The stage span elimination method)

在GA的选择操作中, 无论选取何种选择算子, 如轮盘赌或随机遍历抽样, 都不可避免的存在把潜在的最优解淘汰掉, 保留许多局部最优解, 从而产生遗传的欺骗问题. 因此在产生新一代种群时, 要考虑优生问题, 即要保证新的种群在全局范围内搜索最佳的

权值矢量.

基于定义1, 本文提出了“阶段性跨度淘汰法”来对经过选择操作而被选中的个体进行诊断. 所谓阶段性, 是指将种群进化分为4个阶段; 所谓跨度是指在前3个进化阶段, 依次将整个解的空间规模分别等分为若干等份. 在不同的进化阶段, 新的种群要保证在每一个等分空间都要有一个体与之相对应, 若无法满足此条件, 则淘汰多余的适应度低的个体, 父代种群要重新进行变异操作, 直到满足此条件为止; 进化到第4个阶段后, 则主要以变异操作来保证搜索范围的全局覆盖. 图3为“阶段性跨度淘汰法”示意图.

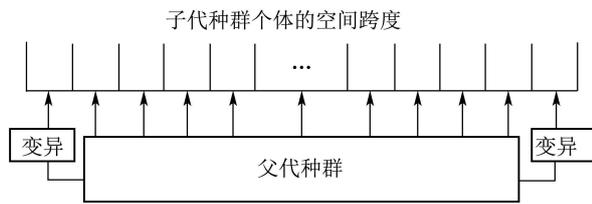


图 3 阶段性跨度淘汰法示意图

Fig. 3 Sketch of stage span elimination method

种群进化阶段的划分依据, 主要是从算法总体进化趋势方面来考虑. 若算法收敛条件为指定进化代数 N , 则种群进化的阶段分为 $\frac{N}{8}$ 代, $(\frac{N}{8} + 1) \sim \frac{N}{4}$ 代, $(\frac{N}{4} + 1) \sim \frac{N}{2}$ 代, $(\frac{N}{2} + 1) \sim N$ 代. 若算法收敛条件为指定精度, 则应计算出模型离线训练时收敛的平均进化代数, 记为 N^* , 再按上述规则进行阶段的划分. 解的空间跨度大小的划分, 主要是从算法的计算复杂度方面来考虑. 通常若种群规模为 L , 则对应种群进化的前3个阶段, 解的空间跨度分别为将解的空间规模等分 $\frac{L}{2}, \frac{2}{5}L, \frac{L}{5}$ 等份.

3.2.2 DNA鉴定法(DNA identification method)

基于定义2, 本文提出了“DNA鉴定法”来对任意两个个体在多维空间的距离进行计算. 所谓“DNA鉴定法”, 就是将相应的个体二进制码串依据编码规则分段解码后, 再利用最小二乘法求解两个个体的空间距离. 若个体甲编码为 $(b_{1823} \cdots b_{117} \cdots b_0)_2$, 个体乙编码为 $(b'_{1823} \cdots b'_{117} \cdots b'_0)_2$, 设:

$$A[57] = [\sum_{i=1792}^{1815} b_i \times 2^i, \sum_{i=1760}^{1783} b_i \times 2^i, \cdots, \sum_{i=32}^{55} b_i \times 2^i, \sum_{i=0}^{23} b_i \times 2^i], \quad (5)$$

$$B[57] = [\sum_{i=1792}^{1815} b'_i \times 2^i, \sum_{i=1760}^{1783} b'_i \times 2^i, \cdots, \sum_{i=32}^{55} b'_i \times 2^i, \sum_{i=0}^{23} b'_i \times 2^i], \quad (6)$$

$$C[57] = [(A[0] - B[0])^2, \cdots, (A[56] - B[56])^2]. \quad (7)$$

则

$$\Delta D = \frac{C[0] + C[1] + C[2] + \cdots + C[56]}{T}, \quad (8)$$

其中: A, B 为父代种群两个个体的染色体编码数组, C 为中间数组, ΔD 为个体甲、乙的DNA距离.

3.2.3 “优生”在算法设计中的应用思路(Use of ‘eugenics’ in algorithm design)

“优生”概念的提出, 为考量整个种群在平面空间的分布和任意两个个体在多维空间的距离提供了直观、高效的方法. 在遗传神经网络温度预报模型中, 使用“阶段性跨度淘汰法”主要是从保持种群多样性方面考虑, 拓展搜索空间, 使算法能够在更广、更优的区域寻优. 使用“DNA鉴定法”主要是从两方面考虑: ①由 ΔD 来判断两个个体的远、近亲的关系, 可以避免产生大量无谓交叉操作, 优化进化环境, 加快算法收敛速度; ②在算法接近收敛时, 利用 ΔD 来最大限度的控制进化方向, 防止“退化”现象的产生, 强力驱动算法跳出局部区域, 迅速向全局最优方向挺进.

3.3 “返祖”操作(‘Atavism’ operation)

返祖现象是一种特殊的遗传现象, 是指人类的个体身上出现了人类祖先具有而现代人身上已消失了的解剖生理特征. 在GA的种群进化过程中, 由于选择操作的随意性、变异操作的不确定性, 以及算法自身存在的随机漫游和退化等问题, 所有这些原因都极有可能将上一代种群中潜在的最佳解给淘汰掉, 从而影响算法的收敛速度、精度, 以至于算法收敛于局部最优解或收敛速度很慢, 满足不了实时在线控制的要求.

本文提出了新的遗传操作“返祖”, 以图进一步提高算法的精度和收敛速度. 所谓“返祖”操作, 即种群“加权阶梯式”重新进化的过程. 在种群进化的过程中, 应根据子代与父代的代价函数的差值的累积和值 ΔE 来判断种群向指定精度逼近的趋势; 若 ΔE 增长缓慢, 取权值 $k = 1$, 即将该阶段初始种群中被淘汰的个体全部选入新的种群, 重新开始进化; 若 ΔE 基本不变, 说明算法已陷入局部最优解而停止进化, 此时应进行“返祖”操作, 取权值 $0 < k < 1$, 即再回到前 $n \times k$ 代 (n 为 ΔE 的累积代数), 将该代种群中被淘汰的个体全部选入新的种群, 重新开始进化; 若 ΔE 平稳增长, 说明算法向设定精度收敛的趋势明显, 取权值 $k = 0$, 即不需进行“返祖”操作. 在“返祖”操作开始的第一代, 且仅在第一代, 多个个体参与交叉操作取代正常交叉操作, 以保证较优模式最大限度的耦合到下一代种群. 由于加权, 从种群进化代数来看, 每次返祖操作跨度是不同的, 呈现阶梯式的形状, 即所谓的“加权阶梯式返祖”. 图4为加权阶梯式返祖示意图.

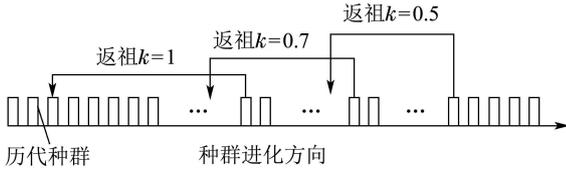


图4 “加权阶梯式返祖”示意图

Fig. 4 Sketch of weighted stepped Atavism

4 基于遗传神经网络的温度预报模型(Prediction model of strip coiling temperature based on genetic algorithm neural network)

4.1 BP神经网络结构设计方案(Design of BP neural network structure)

由于BP神经网络输入输出层的节点数主要由待解决的实际问题所决定,因此网络结构设计的核心任务是隐层结构的设计,即如何确定隐层层数和各隐层节点数.目前针对这一问题,还没有严格的理论依据作为指导.从实际结果来看,增加隐层层数,可以提高网络的逼近精度,但增加了计算复杂度;隐层节点数太少,算法可能不收敛,网络容错性差;隐层节点数太多,训练时间长,网络泛化性差.从研究成果来看,对于隐层结构设计,大致可分为以下几种方法:试凑法、直接定型法、修剪法、增长法、遗传算法优化等,各种方法各有利弊,本文采用直接定型法,隐层层数判别公式为^[7]

$$G \leq \text{int}\left(\frac{Y(K-1)-(X-1)}{2}\right), \quad (9)$$

其中: G 为隐层层数; Y 为输出层节点数; K 为训练样本数; X 为输入层节点数.

隐层节点数判别公式为^[8]

$$L > \frac{M(P-1)}{N+M-1-P}, \quad (10)$$

其中: L 为隐层节点数; N 为输入层节点数; M 为输出层节点数; P 为学习模式系数.

4.2 GA参数选择的探讨(Study on the parameters of GA)

GA参数的选择包括种群规模 N 、算法收敛条件的设置、交叉算子 p_c 和变异算子 p_m 的设定、进化阶段 d 的划分、解的空间规模等分系数 r 和“返祖”加权系数 k 的确定等.其中 N 影响到GA的整体性能和效率;收敛条件决定了GA的最终精度; p_c, p_m, d, r, k 影响到GA的收敛性和种群进化的多样性,是极其重要的参数.

目前,对GA参数的设置还缺乏相应的理论作为指导,考虑在线应用对实时性的要求,本文给出了如下参数设置: $N = 50, p_c = 0.8, p_m = 0.006$;算法的收敛条件为指定精度; d, r, k 的选择方法在前文均已给

出.

4.3 温度预报模型的实现(Implementing temperature prediction model)

本文建立了基于改进GA和基本GA的2个温度预报模型.将初始种群中个体的二进制码串解码,用得到的权值、阈值,按批处理方式,依次计算每个个体的均方差,若有1个个体的均方差达到预设精度,则程序结束,该个体经解码后所得到的值即为温度预报模型的权值、阈值,程序结束;否则,继续进行GA的优化操作,直到在新的种群中至少有一个个体经过解码,按批处理方式,其均方差达到预设精度,则该种群中的最佳个体经解码后的所得到的值即为温度预报模型的权值、阈值,程序结束.图5为改进GA程序流程图.

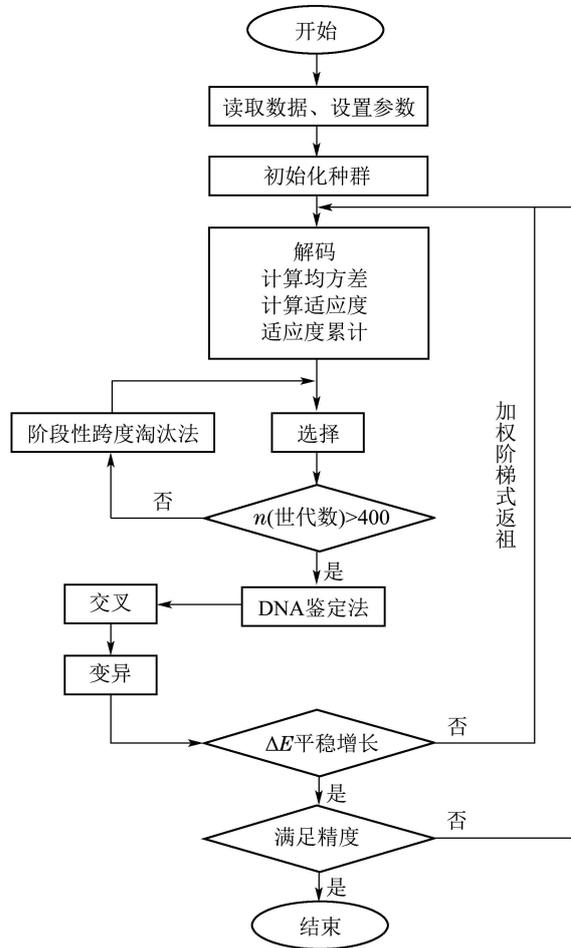


图5 改进遗传算法程序流程图

Fig. 5 Improved genetic algorithm program flow chart

程序运行结果表明,基本GA的温度预报模型,种群在3600代时停止进化,温度预报精度在 $\pm 20^\circ\text{C}$;基于改进GA的温度预报模型,算法在种群进化到800代时收敛,温度预报精度在 $\pm 10^\circ\text{C}$,该模型即可应用于在线温度预报.由此可以看出,改进GA收敛速度快,系统预报精度高,使温度预报模型的在线应用具有极强的“韧性”成为可能;而基本GA收敛速度慢,系统预报精度低,不具备在线应用的可能.

5 仿真(Simulations)

本文使用 Microsoft 公司提供的 MFC (微软基类库), 编写了仿真程序, MFC 是放置 Windows API 函数的面向对象包装的 C++ 类库. 图 6 是种群 1~800 代最大、最小、平均适应度仿真图形. 算法能否在指定的精度范围内收敛, 关键在于均方差函数要随着种群的进化不断地减小, 并且没有反弹. 图 7 为基本 GA 和改进 GA 种群在 540~560 代最佳个体均方差比较示意图.

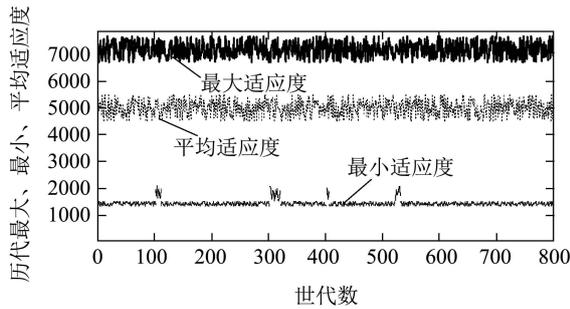


图 6 1~800 代最大、最小、平均适应度

Fig. 6 Maximum, minimum and average fitness of 1~800 generations

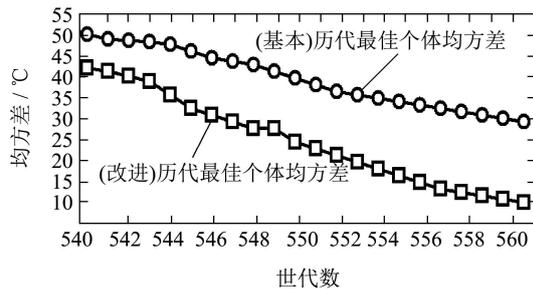


图 7 种群 540~560 代最佳个体均方差比较示意图

Fig. 7 Variance comparison between the best individuals of 540~560 generations of population

表 1 为基本 GA 和改进 GA 种群在 41~50 代最佳个体均方差对比表. 从表 1 可知, 在种群进化初期, 由于应用了“优生”和“返祖”操作, 改进 GA 收敛速度似乎较慢; 但从图 7 可知, 在种群进化的中、后期, 改进 GA 收敛速度较基本 GA 明显加快, 这是改进 GA 强大的全局搜索能力和避免无谓交叉操作的必然结果.

表 2 为种群进化到 400 代时, 基本、改进 GA 最佳个体的预测温度误差对比表. 从表中可以看出, 在种群进化中期, 两种算法的进化程度相当, 预测温度曲线和实际温度曲线差距较大, 离算法预设的精度还有很大的差距.

图 8 为种群进化到 800 代时, 基本、改进 GA 最佳个体的预测温度与实际温度的比较示意图. 从图 8 中可以看出, 改进 GA 预测温度曲线和实际温度曲线达到了很好的拟合, 预测温度误差在 $\pm 10^\circ\text{C}$ 范围之内, 满足设定的精度要求, 算法收敛; 而基本 GA 预测温度曲线和 400 代比较, 变化不是很大, 说明算法收敛速度很慢, 预测温度误差在 $\pm 40^\circ\text{C}$ 范围之内.

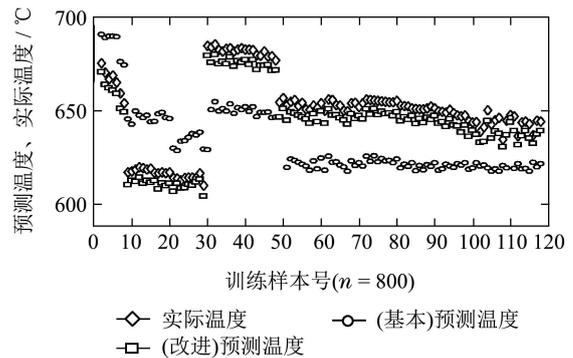


图 8 预测温度和实际温度比较示意图 ($n = 800$)

Fig. 8 Comparison between the predicted temperatures and the actual temperatures ($n = 800$)

表 1 种群 41~50 代最佳个体均方差对比表

Table 1 Variance comparison between the best individuals of 40~60 generations of population ($^\circ\text{C}$)

算法	世代数									
	41	42	43	44	45	46	47	48	49	50
基本 GA	475.9	474.7	470.5	468.2	459.7	452.9	447.7	440.6	437.5	430.6
改进 GA	500.3	499.8	494.6	489.2	482.3	479.2	478.5	474.3	456.9	450.7

表 2 预测温度误差对比表 ($n = 400$)

Table 2 Errors comparison of the predicted temperatures ($n = 400$) ($^\circ\text{C}$)

算法	样本号									
	10	20	30	40	50	60	70	90	100	120
基本 GA	± 56.4	± 53.2	± 48.9	± 53.3	± 47.5	± 48.3	± 43.7	± 53.2	± 50.1	± 49.1
改进 GA	± 56.8	± 49.3	± 49.6	± 46.7	± 55.6	± 41.2	± 48.7	± 47.3	± 53.2	± 46.6

图9为种群进化到3600代时,基本GA最佳个体的预测温度与实际温度的比较示意图.从图9可知,种群进化到3600代时,预测温度误差达到 $\pm 20^{\circ}\text{C}$ 范围之内;此后,种群不再进化,即种群在进化过程中丢失了潜在的最佳解,而使算法收敛于局部最优.由此可以看出,基本GA由于在种群进化过程中会产生许多无谓的交叉操作,使算法收敛速度极慢,并产生所谓的“欺骗”问题,使预报温度误差较大.

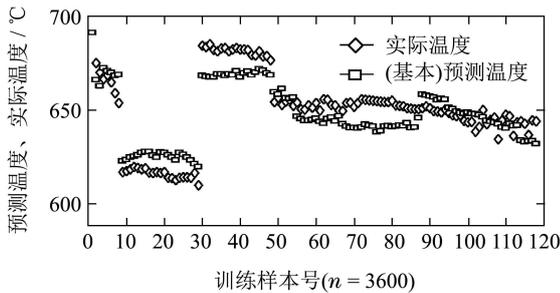


图9 基本遗传算法预测温度、实际温度示意图($n = 3600$)

Fig. 9 Temperature predicted by the basic genetic algorithm and the actual temperature ($n = 3600$)

表3为种群进化代数数为整百代数时,改进GA最佳个体的预测温度最大误差统计表.从表3中可以清晰的看出预测温度逼近实际温度的过程.如在第200代时,温度预报最大误差为 $\pm 92^{\circ}\text{C}$;第400代时,温度预报最大误差为 $\pm 58^{\circ}\text{C}$;第800代时,温度预报最大误差为 $\pm 10^{\circ}\text{C}$,算法收敛.由此表明,改进GA收敛速度极快,并且收敛于全局最优解.

表3 改进GA历代最佳个体的预测温度最大误差表

Table 3 Maximum errors of temperature prediction of the best individuals of past generations of improved GA ($^{\circ}\text{C}$)

算法	世代数							
	100	200	300	400	500	600	700	800
改进GA	± 123	± 92	± 67	± 58	± 34	± 22	± 14	± 10

在主输入模式离线方式下训练出的模型,称之为“主模型”.为保证模型在线的预报精度,本文提出了“随机动态输入模式”神经网络温度预报模型.

所谓“随机动态输入模式”是指在保留主输入模式中的精轧机出口温度、实际卷取温度、水冷区平均

速度的基础上,随机选取其它2个影响卷取温度的参数,作为BP神经网络的输入模式.表4为由程序设定的2组随机动态输入模式.

表4 随机动态输入模式

Table 4 Random dynamic input mode

第1组随机动态输入模式	第2组随机动态输入模式
精轧机出口温度	精轧机出口温度
实际卷取温度	实际卷取温度
水冷区平均速度	水冷区平均速度
带钢宽度	冷却水水温
冷却水压力	环境温度

当主模型在线预报的温度,每100点有5点以上低于预设的精度时,此时应启动两组“随机动态输入模式”温度预报模型的训练;当其中一组模型精度满足要求,则将其切换为在线的温度预报模型,称之为“副模型”,同时将主模型切换为离线;若两组模型的精度都不满足要求,则再启动两组“随机动态输入模式”温度预报模型的训练;如此循环,直至将满足精度要求的那一组模型切换为在线为止;同时应随时计算已变为离线的主模型的预报精度,若其已满足精度要求,则无条件将其切换为在线.

编写GetOnLineTestData()函数来获取2000组输入模式向量做为主模型在线测试样本集.卷取温度预报模型在运行时,检测到主模型在482~582点的区间,共有5点的预报温度误差大于 $\pm 10^{\circ}\text{C}$,立即启动了“随机动态输入模式”副模型的训练;副模型在种群进化到719代时收敛于 $\pm 10^{\circ}\text{C}$,用时3.8s,并立即将其切换为在线温度预报模型,从720点开始预报卷取温度.

表5为720~840点的主、副模型预报温度的误差对比表.从表5中可以看出,在线的副模型预报温度误差在 $\pm 10^{\circ}\text{C}$ 以内,而离线的主模型在740,741,807,833点的预报误差大于 $\pm 10^{\circ}\text{C}$.在960点时,主模型的离线预测已满足精度要求,又无条件切换为在线温度预报模型.由此可以看出,对于强耦合、强非线性的时变系统,在线应用模型一定要有极强的“韧性”,才能保证相应的精度要求.本文提出的神经网络“随机动态输入模式”在线切换的方法就很好的解决了这个问题.

表5 主、副模型温度预报误差对比表

Table 5 Comparison between temperature prediction errors of principal and deputy model ($^{\circ}\text{C}$)

模型	样本号									
	720	730	740	741	670	780	800	807	833	840
主模型	8.2	-5.6	-11.2	12.5	-3.6	-6.7	5.6	12.9	11.6	8.2
副模型	-7.1	4.5	7.6	4.3	2.7	3.4	-2.7	6.8	-7.7	3.1

6 讨论与结论(Discussion and conclusions)

智能进化算法是一类具有全局优化性能的启发式搜索算法, 主要包括: GA、粒子群优化算法(particle swarm optimization, POS)、蚁群优化算法(ant colony optimization, ACO)、模拟退火算法(simulated annealing algorithm, SAA)等. 由于传统神经网络训练算法所存在的固有缺陷, 如易陷入局部最优、收敛速度慢等, 许多学者用智能进化算法来优化神经网络, 取得了较好的效果, 但仍存在不足之处. 如文献[9]提出了一种基于分期变异的POS算法, 很好的解决了种群多样性的问题, 但计算复杂度相对提高; 文献[10]提出了一种基于改进ACO算法来优化神经网络的权值, 其通过引入信息素平滑机制来最大限度的改善了ACO算法的搜索性能, 但由于种群进化后期缺乏强有力的驱动机制, 算法收敛于全局最优的能力还有待于进一步提高.

本文通过用包含“优生”和“返祖”操作的改进GA优化BP神经网络的权值、阈值, 建立了带钢热连轧卷取温度预报模型; 首次提出了重新进化的概念, 极大的提高了算法的收敛速度; 为了较好的保持种群的多样性, 在进化的初、中期用“阶段性跨度淘汰法”来保持种群的解在空间的均匀分布; “DNA鉴定法”随时判断种群个体之间的多维空间距离, 既避免了大量的无谓“交叉”操作, 又在算法接近收敛时形成强有力的驱动机制, 使算法跳出局部范畴而迅速收敛于全局最优; 仿真结果表明, 经该算法优化后的BP神经网络对不同的训练样本均有较好的映射功能, 因此网络具有很好的泛化能力. 由于该温度预报模型收敛速度快, 预报精度高, 满足实时在线控制的要求, 预报温度的误差在 $\pm 10^{\circ}\text{C}$ 以内, 因此能为卷取温度的前馈补偿控制提供可靠的参考数据, 为进一步提高卷取温度控制的精度提供了新的思路和途径.

参考文献(References):

- [1] 片锦香, 柴天佑, 李界家. 变结构PI迭代学习及在层流冷却过程中的应用 [J]. 仪器仪表学报, 2013, 34(11): 2478 – 2483.
(PIAN Jinxiang, CHAI Tianyou, LI Jiejia. Variable structure PI iterative learning and its application in laminar cooling process [J]. *Chinese Journal of scientific instrument*, 2013, 34 (11): 2478 – 2483.)
- [2] 片锦香, 柴天佑. 层流冷却过程混合智能参数辨识 [J]. 控制理论与应用, 2008, 25(5): 934 – 937.
(PIAN Jinxiang, CHAI Tianyou. Hybrid intelligent parameter identification of the laminar cooling process [J]. *Control Theory & Applications*, 2008, 25(5): 934 – 937.)
- [3] 刘全, 王晓燕, 傅启明, 等. 双精英协同进化遗传算法 [J]. 软件学报, 2012, 23(4): 765 – 775.
(LIU Quan, WANG Xiaoyan, FU Qiming, et al. Double elite coevolutionary genetic algorithm [J]. *Journal of Software*, 2012, 23(4): 765 – 775.)
- [4] 巩敦卫, 陈健, 孙晓燕. 新的基于相似度估计个体适应值的交互遗传算法 [J]. 控制理论与应用, 2013, 30(5): 558 – 566.
(GONG Dunwei, CHEN Jian, SUN Xiaoyan. Novel interactive genetic algorithm for estimating individual fitness based on similarity [J]. *Control Theory & Applications*, 2013, 30 (5): 558 – 566.)
- [5] 巩敦卫, 陈健. 基于精英集选择进化个体的交互式遗传算法 [J]. 电子学报, 2014, 42(8): 1538 – 1544.
(GONG Dunwei, CHEN Jian. Interactive genetic algorithm with selecting individual using elite set [J]. *Electronic Journal*, 2014, 42(8): 1538 – 1544.)
- [6] 金敏, 鲁华祥. 一种遗传算法与粒子群优化的多子群分层混合算法 [J]. 控制理论与应用, 2013, 30(10): 1231 – 1238.
(JIN Min, LU Huaxiang. A multi-subgroup hierarchical hybrid of genetic algorithm and particle swarm optimization [J]. *Control Theory & Applications*, 2013, 30(10): 1231 – 1238.)
- [7] 付英, 曾敏, 李兴源. 隐含层人工神经网络电压安全评估的影响 [J]. 电力系统自动化, 1996, 20(11): 13 – 16.
(FU Ying, ZENG Min, LI Xingyuan. Effects of hidden layer artificial neural network voltages security assessment [J]. *Automation of Electric Power Systems*, 1996, 20(11): 13 – 16.)
- [8] 刘耦耕, 李圣清, 肖强晖. 多层前馈神经网络结构研究 [J]. 湖南师范大学自然科学学报, 2004, 27(1): 26 – 30.
(LIU Ougeng, LI Shengqing, XIAO Qianghui. Research on a structure of multi-layer forward artificial neural network [J]. *Journal of Natural Science of Hunan Normal University*, 2004, 27(1): 26 – 30.)
- [9] 涂娟娟. POS优化神经网络算法的研究及其应用 [D]. 镇江: 江苏大学, 2013.
(TU Juanjuan. *Research on learning algorithm of neural network optimized with POS and its application* [D]. Zhenjiang: Jiangsu University, 2013.)
- [10] 卢金鑫. 基于蚁群算法的整型权值神经网络的研究与实现 [D]. 杭州: 杭州电子科技大学, 2012.
(LU Jinxin. *Research and implementation of integer weights neural network based on ant colony algorithm* [D]. Hangzhou: Hangzhou Dianzi University, 2012.)

作者简介:

孙铁军 (1970–), 男, 博士研究生, 主要研究方向为轧钢过程优化、建模及预测控制在热轧中的应用等, E-mail: 1468148218@qq.com;

杨卫东 (1952–), 男, 教授, 博士生导师, 主要研究方向为带钢连轧计算机控制、智能优化控制理论在过程控制中的应用等, E-mail: ywd1952@126.com;

程艳明 (1973–), 男, 博士, 主要研究方向为复杂系统的建模与控制、应用非线性控制及数值方法等, E-mail: mychengniu @163.com;

段风云 (1963–), 女, 高级实验师, 主要研究方向为工业网络控制、工业过程控制及智能控制等, E-mail: 452258276@qq.com;

弭洪涛 (1964–), 男, 教授, 研究方向为工业网络控制、带钢热连轧精轧机组AGC控制等, E-mail: 17207527@qq.com.