

基于交替粒子群 BP 网络的电力系统短期负荷预测

唐承娥

(广西大学电气工程学院 南宁 530004) (广西职业技术学院机械与汽车技术系 南宁 530226)

摘要 短期负荷预测是电力系统正常运行的关键环节,合理的发电计划依靠准确的负荷预测,因此提出交替粒子群算法来优化 BP 网络模型以预测电力短期负荷。针对依靠先前的经验来确定 BP 神经网络的权值缺少理论依据的问题,采用交替粒子算法优化 BP 神经网络权值,以减少通过神经网络预测模型求解电力短期负荷预测带来的误差。实验证明,经过优化的 BP 神经网络预测模型比传统的 BP 神经网络预测模型的误差更小,更加接近实际电力负荷。

关键词 粒子群算法, BP 神经网络, 短期负荷, 交叉操作

中图分类号 TP18 文献标识码 A

Short-term Load Forecasting of Power System Based on Alternating Particle Swarm BP Network

TANG Cheng-e

(School of Electrical Engineering, Guangxi University, Nanning 530004, China)

(Department of Mechanical and Automotive Systems, Guangxi Vocational and Technical College, Nanning 530226, China)

Abstract Short-term load forecasting is a key link in the normal operation of power system. Based on accurate load forecasting, an alternating particle swarm optimization algorithm was proposed to optimize the BP network model to predict short-term load in this paper. In order to determine the weight of the BP neural network, the weights of the BP neural network were optimized by using the alternating particle algorithm to reduce the error caused by the neural network prediction model to solve the short term load forecasting. The experimental results show that the optimized BP neural network prediction model is less accurate than the traditional BP neural network prediction model and closer to the actual power load.

Keywords Particle swarm optimization, BP neural networks, Short term load, Cross operation

1 引言

电力部门在制定符合实际的发电计划时需要精准预测电力系统的短期负荷。预测精度与经济效益密切相关,是电力市场或者部门安排调度规划、供电需求计划、购销计划等项目的决策依据。短期负荷预测方法包括灰色系统法、指数平滑法、时间序列法以及回归分析法。文献[1]利用时间序列法来预测短期负荷并取得了良好的效果。20 世纪初智能技术快速发展,许多学者将人工神经网络(ANN)应用到短期负荷预测中,取得了一些良好性能的成果^[2-5]。人工神经网络受人脑高效处理信息的启发,从而具有人脑的一些特点——并行处理功能和存储记忆功能以及对于任意复杂的非线性函数模型都能任意逼近,在工程领域具有很强的实用效果。虽然学者把人工神经网络应用到短期负荷预测取得了一些成果,但是未充分弥补人工神经网络的一些不足(收敛慢、陷入局部极小值等)进而影响预测精度,因此选择合适的神经网络模型并弥补上述缺点,就会取得不错的效果;此外,神经元之间的权值训练也将直接影响预测模型的精度。文献[6-9]利用误差方向传播(Back Propagation, BP)算法^[10-13]预测短期负荷, BP 算

法存在收敛慢、不易收敛全局最优值、迭代时间过长等不足,从而影响该模型的预测精度。

根据鸟群活动规律及觅食等行为,学者提出一种群体智能算法^[14-15],该算法具有收敛快且易于编程实现等优点,在许多领域得到了广泛应用^[16]。近年来,虽然采用 PSO 算法求解预测短期负荷比遗传算法有效,但提出的算法存在收敛慢且易陷入局部最优等缺点,其原因在于在粒子更新位置的过程中没有保持多样性且更新方式过于简便,从而导致粒子进化停止及群体中的粒子单一化。

本文为了弥补 BP 神经网络和粒子群(PSO)算法的缺点,利用遗传算法交叉和变异等的进化优点,提出交替粒子群优化算法,依据遗传算法交叉和变异等操作指导群体中粒子位置的信息更新,分别给出了粒子的相似度的概念,定义粒子能量的表达方式,两者都是自适应变化的,主要涉及迭代次数、群体进化程度、粒子进化速度。进化过程通过排序策略来选取粒子以保证群体的多样性,若当前粒子的相似度阈值小于距离最近的两个粒子的相似度,则针对其中一个粒子采取变异操作。定义了快速计算最优权值的策略:遍历矩阵。本文利用交替粒子群算法优化 BP 神经网络模型权值,提出了

一种交变粒子群神经网络预测模型用于电力系统短期负荷预测,提高了预测的精度。实验对比结果证明了该算法的有效性。

2 交变粒子群 BP 网络预测模型

2.1 短期负荷预测模型

短期负荷是一个非线性变化且复杂的问题,涉及各种因素:负荷特性、用电时段、供电计划和天气变化等。它是具有周期性、非线性且随机的控制过程^[11],一般有 3 个周期性变化:季节性、一周(7 天)和 1 天(24h),一般以两个周期性变化或者单个周期性变化为研究对象。周期性是电力系统负荷的明显特征,本文根据 BP 神经网络的预测模型,利用交变粒子群优化神经网络权值,进而利用本预测模型预测电力系统的短期负荷。

2.2 交变粒子群 BP 网络算法

2.2.1 算法参数设定

假设 BP 网络输入层神经元个数为 n ,隐含层神经元个数为 h ,输出层神经元为 m ,设定 E 是每次训练输出值与设定输出值之间的误差。利用交变粒子群算法求解 BP 神经网络的权值,设粒子群规模为 N ,每条粒子代表一个 BP 神经网络节点的权值,任意两个粒子 P_p 和 P_q (其中 $p, q \in \{0, 1, 2, \dots, N-1\}$) 的差 $P_p - P_q$ 或和 $P_p + P_q$ 仍代表一个 BP 神经网络节点的权值, BP 网络的欲寻优变量为两个权值矩阵 $[t_{ij}]$ 和 $[V_{ki}]$ 以及两个阈值向量 $[v_{k0}]$ 和 $[t_{i0}]$, $[t_{ij}]$ 表示隐含层第 i 个神经元与输出层第 j 个输入神经元之间的权值; $[V_{ki}]$ 是输出层第 k 个神经元与隐含层第 j 个神经元之间的权值; $[v_{k0}]$ 表

$$energy(P_i) = \frac{0.6 * \sum_{j=1}^{dim} same(P_{ibest}(j), P_{gbest}(j)) + 1.4 * \sum_{k=1}^{dim} same(X_i(k), V_i(k))}{2 * dim} \quad (4)$$

其中, $same(x, y) = \begin{cases} 0, & \text{if } x=y \\ 1, & \text{if } x \neq y \end{cases}$, $energy(P_i) \in [0, 1]$ 。粒子能量大小体现粒子搜索能力的强弱,涉及到粒子的当前状态和群体的当前最优位置。

定义 2 若 $currGen$ 是目前的迭代次数, $MAXGEN$ 是最大迭代次数,粒子能量的上界及下界分别为 $eIni$ 与 $eFin$,则群体中粒子 P_i 的能量阈值的概念如下:

$$Threshold(P_i) = \left[\frac{(MAXGEN - CurGen * speed(P_i(curGen)))}{MAXGEN} \right]^e * (eIni - eFin) + eFin \quad (5)$$

其中, $speed(P(k)_i) = P_{ibest}(k) / P_{ibest}(k-1)$, e 是给定的常量,用于控制粒子的能量阈值的变化趋势。 P_i 的能量阈值与算法迭代次数及粒子速度 V_i 有关。可以看出,在进化过程中粒子的能量不断变化,若粒子当前的能量阈值大于粒子的能量,则利用式(6)、式(7)对当前粒子的速度和位置执行变异操作,由此加入新的信息来增加粒子能量,其搜索范围扩大。

$$V_i(k) = mutation(V_i(k)) \quad (6)$$

$$X_i(k) = mutation(X_i(k)) \quad (7)$$

示输出层的第 k 个神经元的阈值; $[t_{i0}]$ 表示隐含层第 i 个神经元的阈值。粒子适应值为两粒子 P_p 与 P_q 之间的最短距离,定义如下:

$$d_{pq} = \sum_{i=1}^h \sum_{j=1}^n [t_{ij}(p) - t_{ij}(q)]^2 + \sum_{k=1}^m \sum_{i=1}^h [t_{ki}(p) - t_{ki}(q)]^2 + \sum_{i=1}^h [t_{i0}(p) - t_{i0}(q)]^2 + \sum_{k=1}^m [v_{k0}(p) - v_{k0}(q)]^2 \quad (1)$$

2.2.2 算法进化模型

在传统粒子群算法中,单个粒子的运动行为受粒子当前位置、经历过的位置、当前群体的最佳位置及速度(动量项)影响。因此标准粒子速度的表达形式包括 3 项:速度、最优解、群体最优解,三者相互交叉更新粒子的速度和位置。粒子速度和位置的变换公式如下:

$$V_i(k+1) = V_i(k) \otimes P_{gbest} \otimes P_{ibest} \quad (2)$$

$$X_i(k+1) = X_i(k) \otimes V_i(k+1) \quad (3)$$

其中,符号 \otimes 表示交叉操作。由式(2)、式(3)得出结论:群体中每一个粒子都围绕其当前个体最优解或者全局最优解运动。该模型与标准的粒子群算法具有相同的优点:收敛速度快、计算消耗时间少。但是在进化过程中粒子的速度会快速接近零,即粒子的当前状态速度和位置相同,使算法易于陷入局部最优。为了避免算法陷入局部最优,给出两个定义:粒子能量和粒子能量阈值。粒子能量阈值自适应变化,主要是根据进化过程中粒子的速度变化而定,确保算法在起始阶段不陷入局部最优解,在后期则加强局部搜索的精细化能力。

定义 1 假设 P_i 是一个粒子, X_i 和 V_i 分别表示粒子的当前位置与速度, P_{ibest} 和 P_{gbest} 分别表示当前个体的最优位置和群体中的最优位置。当前粒子的能量计算公式如下:

上述进化模型在进化过程中不能保持群体的多样性,为了避免搜索能力减弱和进化质量下降,给出了粒子相似度和粒子相似度阈值的定义,利用排序策略来保证群体粒子的多样性。粒子之间的同化(相似)程度用粒子相似度来度量,用两粒子之间的最优位置的距离来定义粒子的相似度。

定义 3 假设 P_i, P_j 表示两个粒子,其相似度计算公式如下:

$$similarity(P_i, P_j) = \frac{\sum_{k=1}^{dim} same(P_{ibest}(k), P_{jbest}(k))}{dim} \quad (8)$$

其中, dim 表示求解问题的维数。

定义 4 若 $MAXGEN$ 表示最大迭代次数,粒子相似度阈值的上下界为 $[sIni, sFin]$,那么粒子相似度阈值如下:

$$simiThreshold(curGen) = \left[\frac{(MAXGEN - currGEN * s)}{MAXGEN} \right]^s * (sIni - sFin) + sFin \quad (9)$$

其中, $currGEN$ 是当前的迭代次数, s 为给定常量,用于控制粒子相似度的阈值每次进化的幅度。

当前群体中粒子之间距离的下界由粒子相似度阈值给定,其根据迭代次数而随机自适应变化。在算法运行的起始

阶段, 给定粒子相似度阈值的初始值较大, 这样就可以使粒子在搜索空间中得到均匀分布, 搜索范围得到充分扩大; 当群体不断迭代进化, 相似度阈值将慢慢减小, 算法能够搜索到全局最优位置, 通过加强搜索最优位置的范围, 算法最优解的精度得到明显提高。为了不减弱群体粒子的多样性, 在群体进化过程中, 群体中的所有粒子根据适应度值的大小来排序, 两个相邻的粒子的相似度小于给定的相似度阈值, 选择最优解比较差的粒子做变异操作, 如式(10)所示。

$$P_{ibest}(k+1) = mutation(P_{ibest}(k+1)) \quad (10)$$

此操作能够给群体中的粒子引入新的指导信息, 引导粒子搜索未曾搜索过的空间, 避免算法过早收敛和早熟。

为了降低算法的复杂度, 本文给出了基于遍历矩阵的求解粒子适应度的方法。对于给定的 n 个神经网络权值, 定义矩阵 T 为:

$$T = \begin{bmatrix} t_{1,s_1} & t_{1,s_2} & \cdots & t_{1,s_n} \\ t_{2,s_1} & t_{2,s_2} & \cdots & t_{2,s_n} \\ \vdots & \vdots & \vdots & \vdots \\ t_{m,s_1} & t_{m,s_2} & \cdots & t_{m,s_n} \end{bmatrix} \quad (11)$$

其中, $s_i \in J; t_{jk}$ 表示神经网络的输入值, 即权值 j 在第 k 次操作中的训练数, $1 \leq i \leq n, 1 \leq j \leq m$ 。

粒子的相似度表示粒子的适应度值, 根据 T 的定义和对预测模型的具体分析, 对于给定的输入权值, 可根据式(12)遍历矩阵 T 来求得。

$$t_{i,j} = \begin{cases} t_{1,1}, & \text{if } i=1, j=1 \\ t_{1,j-1} + t_{1j}, & \text{if } i=1, j \neq 1 \\ t_{i-1,1} + t_{i,1}, & \text{if } i \neq 1, j=1 \\ t_{i-1,j} + t_{i,j}, & \text{if } t_{i-1} > t_{i,j-1} \\ t_{i,j-1} + t_{i,j}, & \text{if } t_{i-1} < t_{i,j-1} \end{cases} \quad (12)$$

根据 $t_{m,n}$ 可以优化 BP 网络的最优权值和阈值。

交变粒子群 BP 网络模型示意如图 1 所示。

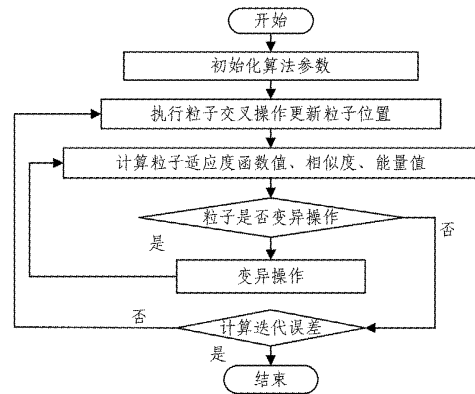


图 1 交变粒子群 BP 网络算法流程

3 实例验证

为了验证本文算法预测电力系统短期负荷的实用性, 采用广西某电力部门于 2016 年 5 月 2 日—2016 年 6 月 25 日的历史数据建模、训练并验证本文提出的预测模型, 编程环境为 Matlab7.0。为方便神经网络的计算, 第一步对负荷数据 x 进行初步处理:

$$x' = \frac{x-a}{x-b}$$

其中, x 表示电力负荷值; a 和 b 分别为 x 的最小值和最大值。本文采用均方误差 E 作为评价指标, E 的计算公式如下:

$$E = \sqrt{\frac{1}{24} \sum_{i=1}^{24} \left(\frac{y-y'}{y} \right)^2}$$

其中, y' 为负荷值的预测值, y 为实际负荷值。本例中粒子数量 $N=100; c_1 = c_2 = 2, \omega$ 从 0.95 线性变化到 0.45; $MAX-GEN=1000, popNum = 70, s = 1.50, e = 1.35, eIni = 0.45, eFin = 0.10, SIni = 0.85, sFin = 0.05$ 。具体计算结果如图 2、图 3 所示。由此可见, 交变粒子群 BP 网络预测模型的精度比 BP 神经网络的预测精度更高, 计算速度快且运行时间少。




图 2 两种电荷预测模型的预测数据与实际负荷对比图

- [18] PEROZZI B, AL-RFOU R, SKIENA S. DeepWalk: online learning of social representations[C]// ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2014:701-710.
- [19] RAO D, YAROWSKY D, SHREEVATS A, et al. Classifying latent user attributes in twitter[C]// International Workshop on Search and Mining User-Generated Contents. ACM, 2010: 37-44.
- [20] SCHLER J, KOPPEL M, ARGAMON S, et al. Effects of Age and Gender on Blogging[J]. Frontiers of Information Technology & Electronic Engineering, 2006, 274(s1/2):199-205.
- [21] TANG C, ROSS K, SAXENA N, et al. What's in a name: a study of names, gender inference, and gender behavior in face book[M]// Database Systems for Advanced Applications. Springer Berlin Heidelberg, 2011: 344-356.
- [22] TANG J, QU M, WANG M, et al. LINE: Large-scale Information Network Embedding [C] // International Conference on World Wide Web. ACM, 2015: 1067-1077.
- [23] XIAO C, ZHOU F, WU Y. Predicting audience gender in online content-sharing social networks[J]. Journal of the Association for Information Science and Technology, 2013, 64 (6): 1284-1297.

(上接第 135 页)




图 3 两种电荷预测模型的预测数据误差对比图

结束语 粒子群优化算法(PSO)是一种模拟鸟群行为的优化算法,该算法简单易实现且参数少,被广泛应用于数值优化、参数调优等多种领域。但该算法也存在早收敛及收敛过慢、易求局部最优值而不是全局最优值等缺点。本文针对粒子群算法的缺点,引入交叉操作来更新粒子的位置,利用变异操作以及设定粒子能量值和阈值来保持粒子的多样性,保证算法不过早收敛和陷入局部最优;并提出交互粒子群算法,利用该算法优化 BP 网络预测模型并应用于短期负荷预测,采用电力部门历史负荷数据来验证该预测模型的有效性及精度。实验结果表明采用本文提出的预测模型预测的短期电力负荷的精度较高。

参 考 文 献

- [1] 刘晨晖. 电力系统负荷预报理论和方法[M]. 哈尔滨:哈尔滨工业大学出版社,1987.
- [2] XIE K G, LI C Y, ZHOU J Q. Research of the combination forecasting model for load based on artificial neural network [J]. Proceedings of the CSEE, 2002, 22(7): 85-89.
- [3] YOU Y, SHENG W X, WANG S A. Short-term load forecasting using artificial immune network[J]. Proceedings of the CSEE, 2003, 23(3): 26-30.
- [4] ZHENG G, LIU B, ZHOU Y, et al. Short-term load forecasting based on neural network[J]. Journal of Xi'an University of Technology, 2002, 18(2): 126-130.
- [5] TAI N L, HOU Z J. New short-term load forecasting principle with the wavelet transform fuzzy neural network for the power systems[J]. Proceedings of the CSEE, 2004, 24(1): 24-29.
- [6] YOU Y, SHENG W X, WANG S A. The study and application of the electric power system short-term load forecasting using a new model[J]. Proceedings of the CSEE, 2002, 22(9): 15-18.
- [7] JIANG Y. Short-term load forecasting using a neural network based on fuzzy clustering[J]. Power System Technology, 2003, 27(2): 45-49.
- [8] YAO L X, YAO J X, LI B Q, et al. Short-term load forecasting using neural network based on competitive learning classification [J]. Power System Technology, 2004, 28(10): 45-48.
- [9] MCCLELLAND J L, RUMELHART D E. Parallel distributed processing [M]. Cambridge: MIT Press, 1986.
- [10] LARSEN E V, MILLER N W, NILSSON S L, et al. Benefits of GTO-based compensation systems for electric utility applications[J]. IEEE Trans on Power Delivery, 1992, 7 (4): 2056-2061.
- [11] CEN W H, LEI Y K, XIE H. The application of the electric power system short-term load forecasting using artificial network and genetic algorithm[J]. Automation of Electric Power Systems, 1997, 21(3): 29-32.
- [12] DING J W, SUN Y M. Short-term load forecasting using a neural network based on chaos learning algorithm[J]. Automation of Electric Power Systems, 2000, 24(2): 32-35.
- [13] YANG Q Y, SUN J G, ZHANG J Y, et al. A Hybrid Discrete Particle Swarm Algorithm for Open-Shop Problems[C]// Proceedings of the 6th International Conference on Simulated Evolution And Learning (SEAL 2006). Hefei, China, LNCS 4247, 2006: 158-165.
- [14] VAN DEN BERGH F. An Analysis of Particle Swarm Optimizers[D]. Department of Computer Science, University of Pretoria, Pretoria, South Africa, 2002.
- [15] RAMESHKUMAR K, SURESH R K, Mohanasundaram K M. Discrete Particle Swarm Optimization (DPSO) Algorithm for Permutation Flowshop Scheduling to Minimize Makespan[C]// Proc. ICNC 2005. LNCS 3612, 2005: 572-581.
- [16] LIAN Z G, GU X S, JIAO B. A similar particle swarm optimization algorithm for permutation flowshop scheduling to minimize makespan[J]. Applied Mathematics and Computation, 2006, 175 (1): 773-785.