

文章编号:1005-0523(2015)01-0093-06

基于果蝇优化灰色神经网络的年电力负荷预测

傅军栋,刘晶,喻勇

(华东交通大学电气与电子工程学院,江西 南昌 330013)

摘要:年电力负荷预测的准确性对电力系统的经济效益和社会效益具有重要作用。灰色神经网络(GNN)是一种创新的智能计算方法,在实际中广泛应用。尤其在预测问题方面具有极大的潜力。作为一种新型的启发式和进化算法,果蝇优化算法(FOA)具有易理解和快速收敛到全局最优解的优点。为提高预测性能,提出一种以GNN为基础的年电力负荷预测模型,使用FOA自动确定GNN模型的相应参数值,提高模型的稳定性和预测精度。通过利用中国的年用电量为例,计算结果表明,GNN结合FOA(GNN-FOA)优于GNN,广义回归神经网络(GRNN),最小二乘支持向量机(LSSVM)和回归模型等其他替代方法。

关键词:年度电力负荷预测;灰色神经网络;果蝇优化算法;优化问题

中图分类号:TM715

文献标志码:A

电力负荷预测水平已成为衡量电力系统运行管理现代化的标志之一^[1]。它是制定发电计划和输电方案的主要依据,对合理安排机组启停、确定燃料供应计划、进行能量交易等具有重要意义,其预测精度的高低直接影响到电力系统运行的安全性、经济性。由于一些因素,如政治环境、人类活动和经济政策的复杂的和非线性的关系使得它非常难以准确预测年电力负荷。为提高电力负荷预测的准确性,学者和从业者提出了许多方法,如时间序列的技术和回归模型。然而,由于非线性拟合能力较差,这些预测方法难以实现较高的预测精度。近年来,许多人工智能的预测技术已在年电力负荷预测中应用,以提高预测的准确性。邵玉林^[2]提出了一种基于粒子群优化方法的组合预测方法,它可以提高预测的稳定性和可靠性。夏非等^[3]提出了采用径向基函数神经网络(RBFNN)中长期负荷预测模型,计算结果表明,该模型具有较高的预测精度和稳定性。Abou等^[4]提出了人工神经网络(ANN)技术长期峰值负荷预测,这种基于埃及的电力网络历史数据的应用。贺晓等^[5]提出了一种小波神经网络方法来预测中长期用电负荷,并且这种方法可以提高预测精度。李如琦等^[6]提出了一种启发式支持向量机算法模型,并且该方法可以提供更准确的预测结果。这些方法从某种程度上都提高了电力负荷预测的精度。

拟采用果蝇优化算法^[7]结合灰色神经网络的预测模型进行年电力负荷预测。

1 果蝇优化灰色神经网络(GNN-FOA)模型的预测方法

1.1 灰色神经网络(GNN)预测模型

灰色神经网络预测方法是灰色预测方法和人工神经网络方法相结合的算法^[8],即保留灰色预测方法中“累加生成”和“累减还原”运算,不再求参数,而是由BP神经网络^[9-10]来建立预测模型和求解模型参数。

n 个参数的灰色神经网络模型的微分方程式表达为

$$\frac{dy_1}{dt} + ay_1 = b_1y_2 + b_2y_3 + \cdots + b_{n-1}y_n \quad (1)$$

收稿日期:2015-01-04

作者简介:傅军栋(1972—),男,副教授,主要研究方向电力系统,建筑电气与智能化。

式中: y_2, \dots, y_n 为系统输入参数; y_1 为系统输出参数; $a, b_1, b_2, \dots, b_{n-1}$ 为微分方程式的系数。

利用这种灰色神经网络进行负荷预测的算法如下。

- 1) 对电力负荷的原始数据序列进行“累加生成”运算,得到累加序列。
- 2) 利用BP神经网络能够拟合任意函数的优势解决累加序列并非指数规律的问题。训练BP神经网络逼近累加数据序列 Y 。
- 3) 利用现有已经训练好的BP神经网络进行预测,输出累加序列的预测值。
- 4) 将累加数据的预测值进行“累减还原”运算,得到电力负荷的原始数据序列预测值。

1.2 果蝇优化算法(FOA)

果蝇优化算法(fruit fly optimization algorithm, FOA)是由潘文超教授于2011年提出的一种基于果蝇觅食行为推演出寻求全局优化的新方法^[7]。这是一种交互式进化计算方法,通过模仿果蝇群体发现食物的行为,FOA能够达到全局最优。在实际中FOA已经被应用于许多领域,包括交通事件^[11],外贸出口预测^[12],模拟滤波器的设计^[13]等。依照果蝇搜寻食物的特性,将其归纳为以下几个重要步骤。

- 1) 参数初始化:FOA的主要参数为最大迭代次数 $\max gen$,种群规模 $sizepop$,初始果蝇群的位置(X_axis, Y_axis)和随机飞行距离 F_r 。
- 2) 种群初始化:赋予果蝇个体利用嗅觉搜寻食物之随机方向与距离。
- 3) 种群评价:首先,由于无法得知食物的位置,需要计算果蝇到原点的距离($Dist$)。再计算气味浓度判定值(S)此值为距离的倒数。通过将气味浓度判断值(S)代入气味浓度判断函数(或称为适应度函数),求出果蝇个体位置的气味浓度($Smell$)。并找出群体中气味浓度值最大的果蝇个体。
- 4) 选择操作:保留最大气味浓度值和 x, y 坐标,此时,果蝇通过视觉飞往的最大浓度值的位置。进入迭代寻优,重复实施步骤2)~3),并判断味道浓度是否优于前一迭代味道浓度,若是则执行步骤4)。若味道浓度不再优于先前迭代的味道浓度值,或迭代次数达到最大,循环结束。

1.3 GNN-FOA 预测模型

GNN-FOA 预测模型的程序结构框图如图1所示。采用果蝇优化算法(FOA)为灰色神经网络(GNN)模型参数 a, b_1 和 b_2 进行迭代动态微调,使模型侦测能力提高,并获得最佳的GNN模型参数以进行预测。详情如下。

- 1) 参数初始化。在果蝇优化算法的参数设定上,随机初始化果蝇群体位置区间 $X_axis, Y_axis \in [-50, 50]$,迭代的果蝇寻食的随机飞行距离区间 $F_r \in [-10, 10]$,种群规模 $sizepop = 20$,而迭代次数 $\max gen = 100$ 。
- 2) 初始进化。设置初始迭代次数为0,设定果蝇个体 i 寻食随机飞行方向 $rand()$ 和飞行距离。其中 $rand()$ 表示任意值产生函数。在GNN-FOA程序中,使用两个变量 $[X(i,:), Y(i,:)]$ 来描述果蝇个体 i 的飞行距离。分别设

$$\begin{cases} X(i,:) = X_axis + 20 \times rand() - 10 \\ Y(i,:) = Y_axis + 20 \times rand() - 10 \end{cases} \quad (2)$$

- 3) 初步计算和数据预处理。计算果蝇个体 i 距离原点的距离 $Dist_i$ 和气味浓度判断值 S_i 。其中

$$\begin{cases} Dist_i = (X_i^2 + Y_i^2)^{1/2} \\ S_i = 1/Dist_i \end{cases} \quad (3)$$

在GNN-FOA程序中,使用 $D(i,1), D(i,2), D(i,3)$ 来表示 $Dist_i$,用 $(S(i,1), S(i,2), S(i,3))$ 表示 S_i 。将 S_i 输入到GNN预测模型进行年电力负荷预测。在GNN-FOA程序中,参数 a, b_1 和 b_2 由 $(S(i,1), S(i,2), S(i,3))$ 表示,分别设

$$\begin{cases} D(i,1) = (X(i,1)^2 + Y(i,1)^2)^{0.5} \\ D(i,2) = (X(i,2)^2 + Y(i,1)^2)^{0.5} \\ D(i,3) = (X(i,3)^2 + Y(i,1)^2)^{0.5} \end{cases} \quad (4)$$

$$\begin{cases} S(i,1)=1/D(i,1) \\ S(i,2)=1/D(i,2) \\ S(i,3)=1/D(i,3) \end{cases} \quad (5)$$

$$\begin{cases} a=0.3+3S(i,1) \\ b1=0.3+3S(i,2) \\ b2=0.3+3S(i,3) \end{cases} \quad (6)$$

通过年负荷预测结果,气味浓度值 $Smell_i$ (或称为适应度函数)便可计算出来。该气味浓度 $Smell_i$ 通过均方差(RMSE)来表征网络输出预测值与实际值之间的误差。

4) 产生种群后代。种群后代通过果蝇算法步骤2)~3)生成,然后输入到GNN模型中,重新计算气味浓度值,迭代加一,置 $gen = gen + 1$ 。

5) 循环结束。当达到最大迭代次数时,停止条件满足,并获得GNN模型的最佳参数。若否,则返回执行步骤2)。

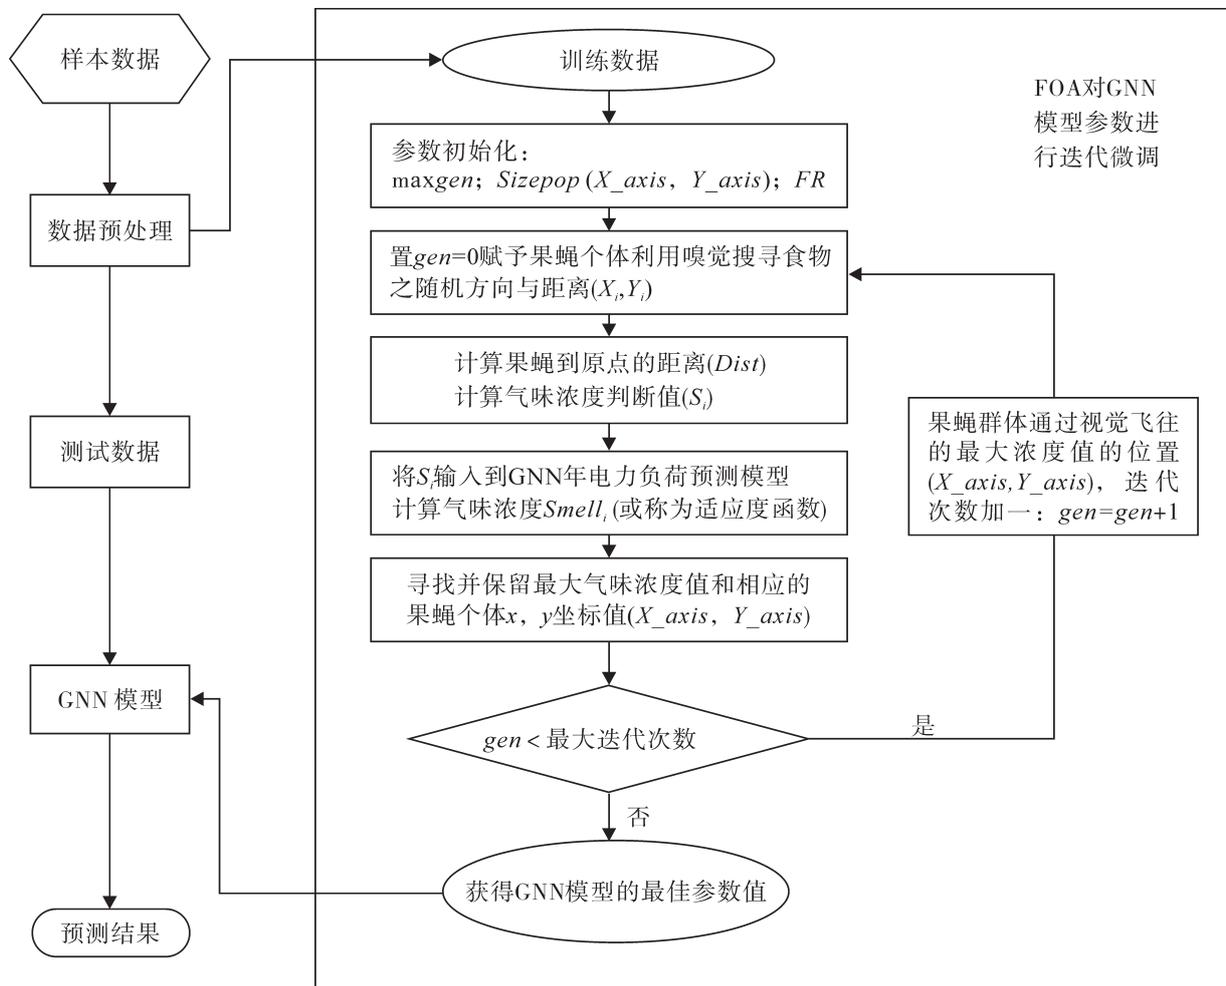


图1 GNN-FOA预测模型的程序结构图

Fig. 1 Diagram of the procedure structure of the GNN-FOA forecasting model

2 算例仿真

2.1 样本数据预处理

样本数据选自中国1987—2011年的年用电量^[14],如表1所示。在计算之前,需要对样本数据进行归一

化处理,用下式使得样本数据统一规范在0~1的范围内。

表1 中国1987—2011年年用电量

Tab. 1 Annual electricity consumption of China from 1978 to 2011

10⁹ kWh

年份	用电量	年份	用电量	年份	用电量	年份	用电量	年份	用电量
1978	246.53	1985	411.90	1992	759.27	1999	1 230.52	2006	2 858.80
1979	282.02	1986	451.03	1993	842.65	2000	1 347.24	2007	3 271.18
1980	300.63	1987	498.84	1994	926.04	2001	1 463.35	2008	3 454.14
1981	309.65	1988	547.23	1995	1 002.34	2002	1 633.15	2009	3 703.22
1982	327.92	1989	587.18	1996	1 076.43	2003	1 903.16	2010	4 199.90
1983	351.86	1990	623.59	1997	1 128.44	2004	2 197.14	2011	4 690.00
1984	377.89	1991	680.96	1998	1 159.84	2005	2 494.03	—	—

2.2 比较模型的选择

选定几种其他电力负荷预测模型的年电力负荷预测结果来比较。从表1中,可以看出,每年的电力负荷呈近似线性上升的趋势。因此,选择回归模型、GNN模型、LSSVM模型和广义回归神经网络(GRNN)模型与GNN-FOA预测模型做比较。GRNN是一种基于核回归标准统计方法的径向基函数(RBF)神经网络,在性能上,它具有优异的逼近能力和学习速度。在GRNN模型中只有一个参数需要确定。

实验环境包括Matlab2010a,GRNN工具箱,自行编写的MATLAB程序和英特尔(R)酷睿(TM)i3-380M的CPU、2 GB内存、320 GB硬盘和Windows 7旗舰版操作系统的计算机。

2.3 FOA为GNN模型确定的参数结果

在GNN-FOA模型中,GNN模型的3个参数值由FOA动态调整。如图2所示是参数优化的果蝇群体飞行路线。可以看到,果蝇群体飞行路线是相对平稳的,而且果蝇群体是直线飞行至食物位置的。因此,果蝇群体能快速而准确地寻找到食物的位置。GNN-FOA在搜索最佳参数时的迭代均方根误差(RMSE)如图3所示。

经过100代迭代寻优,可以看出,在25代坐标为(728,747)处收敛,此时参数 a 、 b_1 和 b_2 最优值均为0.3029。

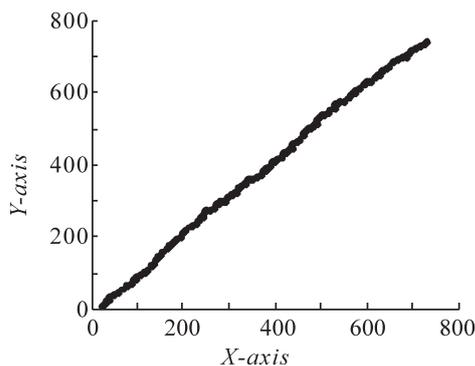


图2 果蝇群体参数寻优飞行路线图

Fig. 2 The fruit fly swarm flying route for parameter optimization

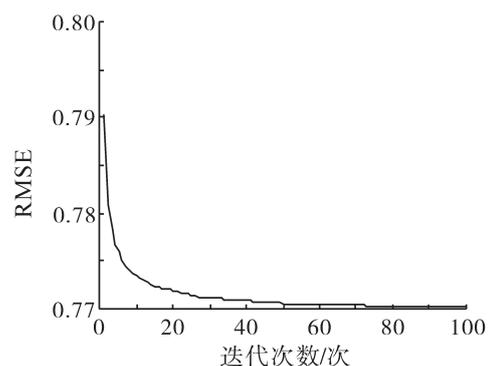


图3 GNN-FOA模型寻最佳参数的均方根误差

Fig.3 The iterative RMSE trend of the GNN-FOA model in search of optimal parameters

2.4 预测结果与分析

根据FOA算法调整GNN模型参数的结果, a 、 b_1 和 b_2 均被选定为0.3029。在GNN模型中,参数 a 、 b_1 和 b_2 分别为0.5037、0.5264和0.5283。在LSSVM模型中,参数 σ 和 C 分别为5和10。其中, σ 为核函数参数; C 为惩罚因子。在GRNN模型中,参数 σ 为0.2。其中, σ 为光滑因子。

GNN-FOA,GNN,LSSVM,GRNN和回归模型的数据训练的时间是分别为9,6,13,14 s和8 s。这5个模

型在训练数据的处理上,训练时间是不同的。GNN-FOA模型与另外4个模型相比,需要每一代都调整一次参数。但是,在训练时间上,GNN-FOA模型仍具有极快的速度,它比GRNN模型快了5 s。

表2中列出了GNN-FOA,GNN,LSSVM,GRNN和回归模型的年电力负荷预测结果。这5中模型预测结果的相对误差如图4所示。从表2和图4中可以获取这5种预测模型的预测结果与实际值之间的误差。一般,最大相对误差是否在 $[-3\%,+3\%]$ 和最小相对误差是否在 $[-1\%,1\%]$ 的范围内是评价一个预测模型的标准。首先,GNN-FOA模型年电力负荷预测点的相对误差均在 $[-3\%,3\%]$ 范围内,并且最大和最小相对误差分别为2008年的2.72%,和2009年的-0.727%。GNN模型有1个预测点的相对误差超出了 $[-3\%,3\%]$ 的范围,即2008年的3.195%。有1个预测点的相对误差即2007年的-0.98%在 $[-1\%,1\%]$ 的范围之内。LSSVM模型有2个预测点的相对误差超过 $[-3\%,3\%]$ 的范围,即2008年的3.13%和2009年4.412%。所有预测点的相对误差均超过 $[-1\%,1\%]$,其中最大相对误差为2009年4.412%,最小相对误差为2011年-1.863%。GRNN模型有3个预测点的相对误差超过 $[-3\%,3\%]$,即2006年3.355%、2007年3.664%、2009年3.509%,所有预测点的相对误差均超过 $[-1\%,1\%]$ 。回归模型有4个预测点的相对误差超过 $[-3\%,3\%]$,即2008年7.354%,2009年3.017%,2010年-3.11%,2011年3.477%。仅有一个预测点的相对误差在 $[-1\%,1\%]$ 内,即2007年-0.410%。其中回归模型2008年的相对误差7.354%是5个模型所有预测点相对误差中最大的点。

表2 GNN-FOA,GNN,LSSVM,GRNN和回归模型的预测结果

Tab.2 Forecasting results of GNN-FOA, single GNN, LSSVM, GRNN and regression model 10^9 kWh

年份	实际值	GNN-FOA	GNN	LSSVM	GRNN	回归模型
2006	2 858.80	2 912.43	2 921.64	2 914.43	2 954.72	2 794.15
2007	3 271.18	3 205.35	3 238.87	3 180.73	3 151.32	3 257.77
2008	3 454.14	3 548.17	3 564.49	3 562.55	3 522.79	3 708.16
2009	3 703.22	3 676.28	3 775.81	3 866.61	3 833.16	3 591.50
2010	4 199.90	4 276.82	4 299.85	4 282.43	4 277.11	4 068.92
2011	4 690.00	4 627.68	4 555.87	4 602.62	4 572.24	4 853.09

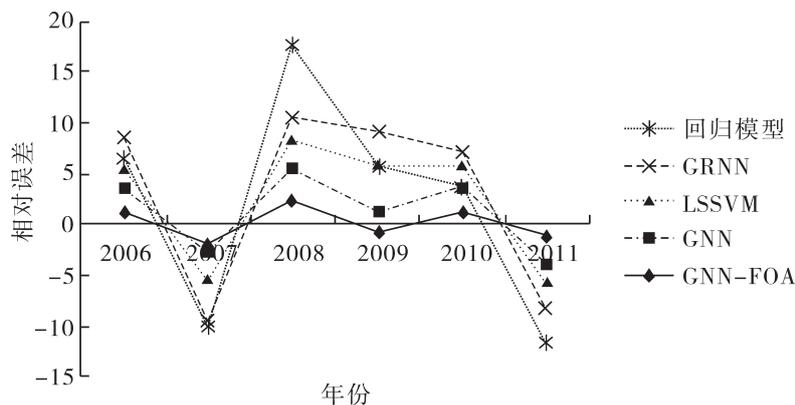


图4 GNN-FOA,GNN,LSSVM,GRNN和回归模型预测结果的相对误差

Fig. 4 The relative errors of the forecasting results for different forecasting models

在此,采用平均绝对百分比误差(MAPE),均方差(MSE)和平均绝对误差(AAE)来评估不同预测模型的预测能力^[15]。

5种模型的平均绝对百分比误差(MAPE),均方差(MSE)和平均绝对误差(AAE)的比较如表3所示。可以看出,与另外4个模型相比,GNN-FOA模型的MAPE,MSE和AAE值要小得多,预测性能更佳。回归模型的MAPE,MSE和AAE值最大,预测精度最低,非线性拟合能力较差。与GRNN模型相比,LSSVM模型的

MAPE值较小,MSE和AAE值却较大。因此,此处无法确定这两个模型在年电力负荷预测方面孰优孰劣。

表3 GNN-FOA,GNN,LSSVM,GRNN和回归模型的MAPE,MSE和AAE值

Tab. 3 The values of MAPE, MSE and AAE for GNN-FOA, single GNN, LSSVM, GRNN and regression model

参数	GNN-FOA	GNN	LSSVM	GRNN	回归模型
MAPE/%	1.749	2.263	2.682	2.692	3.273
MSE	4429	8403	10695	10210	20853
AAE	0.0171	0.0202	0.0265	0.0261	0.0333

综上,GNN-FOA模型极大地缩小了预测值与实际值之间的差距,在年电力负荷预测问题中性能优于GNN、LSSVM、GRNN和回归模型。

3 结束语

随着“坚强智能电网”的建设和分布式可再生能源带来的发电容量的不断增加,准确的电力负荷预测能有效指导中国能源政策的重要实现。然而,年电力负荷与其影响因素的非线性关系使得电力负荷的预测变得复杂。因此,如何提高年电力负荷的预测准确性是值得研究的。GNN已广泛应用于实际各种领域,GNN已广泛应用于实际各种领域,果蝇优化算法(FOA)是一种新型的易于理解的群智能算法。与其他启发式算法相比,它大大缩短了程序代码并能迅速达到全局最优。文中用结合了GNN和FOA的GNN-FOA模型来预测年电力负荷。为验证所提出的方法,将GNN-FOA模型与GNN,LSSVM,GRNN和回归模型进行比较预测。结果表明,GNN-FOA与其他替代预测模型在年电力负荷预测精度方面拥有显著优势,该算法是可行的。

参考文献:

- [1] 史杰. 负荷预测对电网安全运行的重要性[J]. 企业改革与管理, 2014(5):109.
- [2] 邵玉林. 改进粒子群算法在电力负荷组合预测中的应用研究[D]. 衡阳:南华大学,2013.
- [3] 夏非,范莉,苏浩益. 基于粗糙集理论和启发式径向基函数神经网络的中长期电力负荷预测模型[J]. 电力系统保护与控制, 2012(16):21-26.
- [4] ABOU EL-ELA A. A Long-term load forecasting and economical operation of wind farms for Egyptian electrical network[J]. Electr Power Syst Res. 2009,79:1032-1037.
- [5] 贺晓,刘爱国,孙蕾,等. 基于小波神经网络的中长期电力负荷预测[J]. 陕西电力,2012(2):4-8+22.
- [6] 李如琦,苏浩益,王宗耀,等. 应用启发式最小二乘支持向量机的中长期电力负荷预测[J]. 电网技术,2011(11):195-199.
- [7] PAN W T. A new fruit fly optimization algorithm: Taking the financial distress model as an example[J]. Knowledge-Based System, 2012,26(1):69-74.
- [8] 程鹏,韦雅君,李金颖,等. 基于改进的并联灰色神经网络模型在电力需求预测中的应用[J]. 广东电力,2011,24(8):13-16.
- [9] 黄招娣,应宛月,余立琴,等. 基于PSO的神经网络优化证券投资组合法研究[J]. 华东交通大学学报,2013,30(2):42-46.
- [10] 张利华,马钧钊,勒国庆,等. 基于BP神经网络的仓储烟草霉变预测[J]. 华东交通大学学报, 2013,30(3):13-16.
- [11] 史亚东,陆健,陆陆军. 基于RFID技术和FOA-GRNN理论的高速公路道路关闭交通事件对车辆影响的判断模型[J]. 武汉理工大学学报, 2012,34(3):63-68.
- [12] 许智慧,王福林,孙丹丹. 基于FOA-RBF神经网络的外贸出口预测[J]. 数学的实践与认识,2012, 42(13):16-21.
- [13] 肖正安. 基于果蝇优化算法的模拟滤波器设计[J]. 湖北第二师范学院学报,2012,29(2):26-29.
- [14] 中国国家统计局. 中国能源统计年鉴2011[M]. 北京: 中国统计出版社, 2011.
- [15] 陈昊,王玉荣. 一种负荷预测模型预测能力的评价标准[J]. 电力需求侧管理,2010(6):24-26.

(下转第104页)

- [11] XU KAI, LIU YANFEI, SEN P C. A new resonant gate drive circuit utilizing leakage inductance of transformer [C]//Proceedings of IEEE Industrial Electronics, Paris, France:IEEE, 2006:1933–1937.

A Constant-current Source Drive Circuit for Power Transistors

Yuan Yisheng, Zhu Benyu, Luo Feng

(School of Electrical and Electronic Engineering, East China Jiaotong University, Nanchang 330013, China)

Abstract: This study proposes a constant current source drive circuit with a full-bridge structure and dual power sources, which achieves the drive on-off with positive or negative voltage. The constant drive current is obtained by the inductance current at short circuit state. Regulating the charge and discharge time can obtain different level driving current, thus improving efficiency for power switches. The discontinued current of the inductance reduces the on-state losses of power transistors. The working principle, switching logic, and inductance's design as well as the power losses are then elaborated. The Boost circuit test shows that the circuit efficiency has increased by more than 1% with the proposed drive circuit compared to traditional drive circuit.

Key words: constant-current drive; power transistor; full-bridge structure; discontinued inductance current

(责任编辑 姜红贵)

(上接第 98 页)

Annual Electric Load Forecasting Based on Gray Neural Network with Fruit Fly Optimization Algorithm

Fu Jundong, Liu Jing, Yu Yong

(School of Electrical and Electronic Engineering, East China Jiaotong University, Nanchang 330013, China)

Abstract: The accuracy of annual electric load forecasting plays an important role in economic and social benefits of electric power systems. The Gray Neural Network is an innovative computing approach, which has found wide application in reality. As a novel meta-heuristic and evolutionary algorithm, the fruit fly optimization algorithm has the advantages of being easy to understand and fast convergence to the global optimal solution. Therefore, to improve the forecasting performance, this paper proposes a GNN-based annual electric load forecasting model that uses FOA to automatically determine the appropriate values of the parameters for the GNN model to improve the forecasting accuracy and stability of the model. By taking the annual electricity consumption of China as an instance, the computational result shows that the GNN combined with FOA outperforms other alternative methods, namely the single GNN, the generalized regression neural network, the least squares support vector machine (LSSVM) and the regression model.

Key words: annual electric load forecasting; gray neural network; fruit fly optimization algorithm; optimization problem

(责任编辑 姜红贵)