

中文摘要

随着风电资源的迅速发展，世界各国对风电技术的研究也不断走向深入。风能资源的随机性，造成风电功率的波动性与间歇性，给大规模风电接入电力系统带来困难。表现在当风电功率变化时，风电很有可能给连接处的电网带来谐波污染、电压波动及闪变问题；也会给发电和运行调度计划的制定带来很多困难，同时不利于电力系统旋转备用和运行成本的降低，以及风电穿透功率的提高。因此，需要对风电功率进行预测。

本文对风电功率预测的现状研究进行了全面总结，分析了现状研究中存在的不足。在此基础上对现有神经网络进行了改进，构建了基于智能优化方法的多层前向神经网络。根据网络隐含层节点特性构建神经网络的结构基因，对基本蚁群算法进行了改进以确定结构基因。根据神经网络的权值和阈值的特点，构建参数基因，并利用改进的粒子群算法确定参数基因。经过测试，与传统预测方法相比，改进后的神经网络提高了预测的精度，更能适应风能的随机性和风电功率预测的广谱性。

关键词：粒子群 蚁群 风电 功率 预测 神经网络

ABSTRACT

With the development of the wind power, the studies on the wind power technique are deepened all over the word. Due to random of wind energy resources, the fluctuations and intermittent in wind power make difficult for large-scale wind power accessing to power system, especially, when the wind power changes, wind power is likely to bring harmonic pollution, voltage fluctuation and flicker problem to grid connection, and bring a lot of problems for power generation and scheduling plan. It is not conducive to spinning reserve of power system, lowering operating costs and improvement of wind power penetration. So the wind power prediction is necessary.

In this paper, the studies on wind power prediction in existence is comprehensively summarize and their defects are analyzed. On the basis of the existing neural network methods, the improvements are made, multi-layer forward neural network based on intelligent optimization is established. According to the characteristic of the hidden layer nodes, the structural gene is conceived and is computed by the improced ant colony algorithm. In the light of the trait of the network connection weights and thresholds, the parameter gene is designed and is calculated by the particle swarm optimization. It is shown that compared with the traditional prediction strategy, the improved neural network improves the forecast accuracy, which is more adapt to wind power prediction.

KEYWORDS: Particle Swarm Optimization ; Ant Colony Algorithm; Wind Power; Power; Forecast; Neural network

目 录

第一章 绪论	1
1.1 引言	1
1.2 风电功率预测的国内外研究现状	2
1.3 课题的研究内容和意义	3
1.4 论文的框架结构	3
第二章 用于风电功率预测的神经网络模型	4
2.1 BP神经网络基本原理	4
2.2 传统BP神经网络用于风电功率预测存在的不足	6
2.3 风电功率预测模型的改进	7
第三章 基于蚁群算法的隐含层节点数的动态调整	9
3.1 蚁群算法概述	9
3.2 蚁群算法的仿生学理论基础	9
3.3 基本蚁群算法	11
3.3.1 基本蚁群算法对真实蚁群觅食特性的继承与发展	11
3.3.2 基本蚁群算法的原理	12
3.3.3 基本蚁群算法的数学模型	13
3.3.4 基本蚁群算法的具体实现	15
3.3.5 现有的一些基本蚁群算法的改进方法	17
3.3.5.1 蚁群系统	17
3.3.5.2 最大最小蚂蚁系统	18
3.3.5.3 嵌入确定性搜索的连续域蚁群算法	19
3.3.5.4 基于密集非递阶的连续交互式蚁群算法	21
3.4 网络结构基因的构建	22
3.5 网络结构基因的确定	23
第四章 基于粒子群算法的网络连接权值和阈值的动态调整	27
4.1 粒子群算法概述	27
4.2 粒子群算法的仿生学理论基础	27
4.3 基本粒子群算法	28
4.3.1 基本粒子群算法原理及数学模型	28

4.3.2 基本粒子群算法的具体实现.....	29
4.3.3 基本粒子群算法速度更新方程机理分析.....	30
4.3.4 粒子群优化算法的改进.....	31
4.4 网络参数基因的构建和确定.....	31
第五章 风电功率预测的模型实现及算例研究.....	34
5.1 算法实现.....	34
5.2 算例.....	36
第六章 结论.....	53
参考文献.....	54
发表论文和科研情况说明.....	63
致 谢	64

第一章 绪论

1.1 引言

我国风力资源十分丰富，按照陆地上空 10 m 高度可供利用的风能资源计算，我国实际可开发风能资源总量为 253GW^[1]。理论上，50m 高度的风能资源总量是 10m 高度的 2 倍，那么我国陆地上 50 m 高度可利用的风力资源将达到 500GW^[2-4]。现在大型风机的高度可达百米，这个高度可利用的风能更大。一般认为，海上的风力资源是陆地上的 3 倍以上，那么我国海上风力资源也会超过 500GW。可见我国的风力资源是丰富的，远远超过总量为 378GW 的可利用水能资源。

同时，风电资源在环境保护、占地投资、利用率、资源分布等诸多方面具有众多优势。

环境保护方面，风电是可再生的能源，不消耗任何燃料，也不产生二氧化碳，不污染环境，并且在风区大规模建设风电后，会使当地的风力减弱，从而缓解大风扬沙的天气，遏制沙尘暴的发生。特别是在我国新疆、甘肃、宁夏、内蒙古等风口地区建设风电，会减缓西北的风势，相应增强了东南的风势，使东南方的暖湿气流北移，增加北方的降雨量。

占地投资方面，风电机组建在海滩和浅海中以及西北荒漠地区，均不占耕地，即使在个别地方需占耕地，也只需建一个基础；单台风机投资不大，建设规模可大可小，投资有灵活性。建设周期方面，单机建设工期不超过半年，单个机组装上就能发电。

利用率方面，在海滩和浅海建风电，年利用小时可达 3 000 h 以上；在西北风力资源好的地方，年利用小时也接近 3 000 h；并且国内的许多风电场，风力大多在下午 3 时后增大，而到后半夜开始减弱，这正好接近电网负荷曲线。

资源分布方面，我国风电资源具有良好的时空分布特性。从时间上看，我国冬、春两季风大，风电功率偏高，而对水电资源而言是枯水期，水电资源偏低；夏、秋两季风小，相应风电功率偏低，而对水电资源而言是丰水期，水电可以多发，从而风电和水电可以互补。从空间上看，近海和海滩上的风力资源丰富，从渤海、黄海到台湾海峡等都有很好的风力资源可以利用，而沿海地区正是我国经济发展快的地方，电力需求旺盛。在这些地方建设大型风电，可以在一定程度上缓解当地的电力供应问题。

综上所述，风电具有上述优势，可以为我国解决能源供应、二氧化碳排放等

问题，实现可持续发展，做出重大的贡献。我国的风能储量、可开发的装机容量具有商业化、规模化发展的潜力^[5]，近几年我国风电一直保持着 50%左右的年增长速度^[6-7]。

与此同时，风电技术在世界范围内，已经呈现出加速发展的大趋势^[8]。技术上，国外风电机组已达到兆瓦级。如美国主流 1.5MW，丹麦主流 2.0~3.0 MW，在 2004 年的汉诺威工博会上 4.5 MW 的风电机组也已面世。可变桨翼和双馈电机的采用，使机组更能适应风速的变化，大大提高了效率。近年来又发展了无齿风机等，进一步提高了安全性和效率。装机容量上，世界平均装机容量每年以近 30%的速度递增。按照德国风电发展计划，到 2010 年，风电电量将占总发电量的 12.5%；到 2050 年，将占到 50%。丹麦的风电电量 2003 年占全国总发电量的 18%，规划到 2030 年，风电将占总发电量的 50%。西班牙、英国和法国也加快了风电的发展。

随着风电资源的迅速发展，风电技术引入电网后对电网带来的诸多影响也相应得到深入和全面的研究，如引入风力技术后的电力系统最大输电能力计算^[9-10]、配电系统潮流计算^[11-13]等等。风能资源的随机性，造成风电功率的波动性与间歇性，给大规模风电接入电力系统带来困难^[14-19]。表现在当风电功率变化时，风电很有可能给连接处的电网带来谐波污染、电压波动及闪变问题^[20-35]；也会给发电和运行调度计划的制定带来很多困难，同时不利于电力系统旋转备用以及运行成本的降低，不利于风电穿透功率的提高^[36-43]。因此，已有文章对风电功率预测进行了研究。

1.2 风电功率预测的国内外研究现状

现有的大量研究对风电场的风速以及风电功率进行了预测，如参考文献[44]综合了时间序列法和神经网络法，提出滚动式权值调整的时序神经网络法，对风速进行了预测；参考文献[48]对风速样本进行了预处理，提高了风速预测的准确性；参考文献[49]用自回归滑动平均方法建立起具有一定功率谱密度特性的风速模型，充分反映了风速变化的统计规律和相关特性；参考文献[50]提出考虑机组间尾流效应的风速模型，描述了考虑风电场内风速变化的风电场输出功率；参考文献[51]采用实测风速校正的方法，描述了特定场址的短期风速变动规律；参考文献[55]对风电场风速信号进行了非平稳建模。但是进行风速预测只能借助风速——风电功率曲线得出风电场发电功率，而事实上厂家提供的风速——风电功率曲线并不能够很好的描述风电机组的输入输出关系^[56]。

参考文献[56]拟合出了最大概率的风速——功率曲线，但是曲线只能适用于

特定机组，不具有普遍适用性，并且忽略了风速之外的影响风电功率的气象因素，造成了预测误差的根本性存在。参考文献[60]根据风速、风向、气温、气压、湿度等数值天气预报数据，通过BP神经网络对风电功率进行了较好的预测；但是未能摆脱BP神经网络所固有的麻痹现象，由于目标函数的复杂性，它必然会在神经元输出接近0或1的情况下，出现一些平坦区，在这些区域内，权值误差改变很小，使训练过程几乎停滞。

1.3 课题的研究内容和意义

本文在总结现有研究的基础上，选用基于智能优化方法的神经网络对风电功率进行了预测。

本文的研究意义在于，在前人研究成果的基础上，采用智能优化方法优化神经网络参数，以适应风电功率预测随机性和广谱性的特点。为今后风电功率预测技术的发展提出一条可供参考的途径。

1.4 论文的框架结构

论文主体共分为六个部分。在绪论部分中，对课题的背景、现状、发展趋势以及本文所做的研究内容和意义作了概括性的介绍。第二章中，介绍了神经网络的相关概念，针对风电功率预测的特点，系统地阐述了预测网络的构建方法。第三章中，分析基本蚁群算法的仿生学原理，介绍基本蚁群算法的数学模型、实现方法；总结了现有的对基本蚁群算法的改进方法，并在此基础上，对基本蚁群算法进行了改进，使之适用于神经网络结构基因的确定。第四章中，分析基本粒子群算法的机制和原理，介绍基本粒子群优化算法数学模型和实现方法，对算法进行了深入的社会行为分析，并阐述了改进后的标准粒子群算法，在此基础上对算法进行了进一步改进，使之适用于参数基因的确定。第五章中，说明算法的实现方法并给出程序框图，利用测试数据对程序测试结果进行分析，证实了所提出方法的可行性。第六章中，对本方法作出结论性的阐述，并对该方法中尚存在的不足之处作了分析，为今后的研究提供参考。

第二章 用于风电功率预测的神经网络模型

2.1 BP神经网络基本原理

人工神经网络理论是 20 世纪 80 年代在国际上迅速发展起来的一个前沿研究领域。近年来，更是掀起了一股人工神经网络研究、开发、应用的热潮。人工神经网络理论的应用已渗透到各个领域，并在智能控制、模式识别、计算机视觉、自适应滤波和信号处理、非线性优化、自动目标识别、生物医学工程等方面取得了显著成效。BP 神经网络模型是人工神经网络的基本模型之一^[61]。

下面本文从神经元模型与网络结构、网络训练机制来说明 BP 神经网络基本原理。

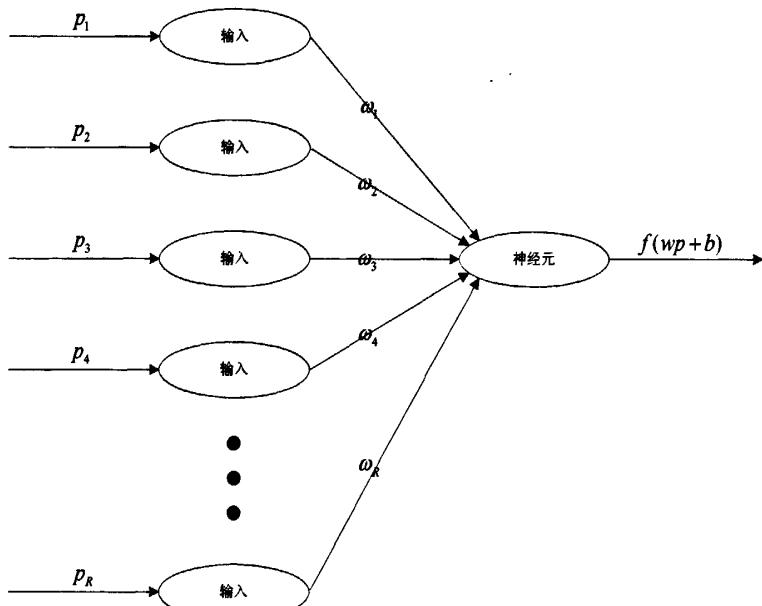


图 2-1 神经元模型

图 2-1 给出一个基本的 BP 神经元模型，它具有 R 个输入，每个输入都通过一个适当的权值 ω 和下一层相连，网络输出可表示为 $a = f(wp + b)$ ，其中 f 表示输入/输出关系的传递函数。

BP 神经网络结构通常有一个或多个隐含层，隐含层的神经元通常采用 log-sigmoid 型函数 `logsig()`、tansigmoid 型函数 `tansig()` 以及纯线形函数 `purelin()`，这些传递函数均是单调递增函数。输出层的神经元采用线性传递函数。隐含层的非线性传递函数神经元可以学习输入输出之间的线性和非线性关系，输出

层的线性传递函数神经元是为了拓宽网络输出。如果需要限定网络输出，则可以采用 S 传递函数（如 logsig（）等）。

BP 神经网络训练机制是沿表现函数下降最快的方向，即负梯度方向，来修正网络的权值和阈值。

设 X_j 为 BP 网络第 k 代的权值和阈值矩阵， g_j 为表现函数的梯度， a_j 为学习速率，则有：

$$X_{k+1} = X_k - a_j g_j \quad (2-1)$$

设三层 BP 网络，输入层节点 x_l 、隐含层节点 y_m 、输出层节点 z_n ，输入层节点与隐含层节点间的网络权值为 ω_{ml} ，隐含层节点与输出层节点间的网络权值为 ω_{nm} 。则有：

隐含层节点输出为

$$y_m = f(\sum_l \omega_{ml} x_l - b_m) = f(net_m) \quad (2-2)$$

输出层节点输出为

$$z_n = f(\sum_m \omega_{nm} y_m - b_n) = f(net_n) \quad (2-3)$$

设输出层节点期望值为 t_n ，误差函数为

$$\begin{aligned} D &= \frac{1}{2} \sum_n (t_n - z_n)^2 \\ &= \frac{1}{2} \sum_n (t_n - f(\sum_m \omega_{nm} y_m - b_n))^2 \\ &= \frac{1}{2} \sum_n (t_n - f(\sum_m \omega_{nm} (f(\sum_l \omega_{ml} x_l - b_m)) - b_n))^2 \end{aligned} \quad (2-4)$$

误差函数对隐含层与输出层的权值求导

$$\frac{\partial D}{\partial \omega_{nm}} = \sum_k \frac{\partial D}{\partial z_k} \times \frac{\partial z_k}{\partial \omega_{nm}} = \frac{\partial D}{\partial z_n} \times \frac{\partial z_n}{\partial \omega_{nm}} \quad (2-5)$$

$$\frac{\partial D}{\partial z_n} = \frac{1}{2} \sum_k [-2(t_k - z_k) \times \frac{\partial z_k}{\partial z_n}] = -(t_n - z_n) \quad (2-6)$$

$$\frac{\partial z_n}{\partial \omega_{nm}} = \frac{\partial z_n}{\partial net_n} \times \frac{\partial net_n}{\partial \omega_{nm}} = f'(net_n) \times y_m \quad (2-7)$$

则有

$$\begin{aligned} \frac{\partial D}{\partial \omega_{nm}} &= -(t_n - z_n) \times f'(net_n) \times y_m \\ &= \delta_n \times y_m \end{aligned} \quad (2-8)$$

其中输出层节点误差为

$$\delta_n = -(t_n - z_n) \times f'(net_n) \quad (2-9)$$

误差函数对输入层与隐含层的权值求导

$$\frac{\partial D}{\partial \omega_{ml}} = \sum_n \sum_m \frac{\partial D}{\partial z_n} \times \frac{\partial z_n}{\partial y_m} \times \frac{\partial y_m}{\partial \omega_{ml}} \quad (2-10)$$

$$\frac{\partial D}{\partial z_n} = \frac{1}{2} \sum_k [-2(t_k - z_k) \times \frac{\partial z_k}{\partial z_n}] = -(t_n - z_n) \quad (2-11)$$

$$\frac{\partial z_n}{\partial y_m} = \frac{\partial z_n}{\partial net_n} \times \frac{\partial net_n}{\partial y_m} = f'(net_n) \times \omega_{nm} \quad (2-12)$$

$$\frac{\partial y_m}{\partial \omega_{ml}} = \frac{\partial y_m}{\partial net_m} \times \frac{\partial net_m}{\partial \omega_{ml}} = f'(net_m) \times x_l \quad (2-13)$$

则有

$$\begin{aligned} \frac{\partial D}{\partial \omega_{ml}} &= \sum_l (-(t_n - z_n)) \times f'(net_n) \times \omega_{nm} \times f'(net_m) \times x_l \\ &= -\sum_l \delta_n \times \omega_{nm} \times f'(net_m) \times x_l \\ &= \delta_m x_l \end{aligned} \quad (2-14)$$

其中隐含层节点误差为

$$\delta_m' = -\sum_l \delta_n \omega_{nm} \times f'(net_m) \quad (2-15)$$

设权值修正值为 $\Delta\omega_{ml}$ 和 $\Delta\omega_{nm}$, 因 $\Delta\omega_{ml}$ 和 $\Delta\omega_{nm}$ 均正比于误差函数沿梯度下降, 则有

$$\begin{aligned} \omega_{nm}(k+1) &= \omega_{nm}(k) + \Delta\omega_{nm} \\ &= \omega_{nm}(k) + \eta \frac{\partial D}{\partial \omega_{nm}} \\ &= \omega_{nm}(k) + \eta \delta_n \times y_j \end{aligned} \quad (2-16)$$

$$\begin{aligned} \omega_{ml}(k+1) &= \omega_{ml}(k) + \Delta\omega_{ml} \\ &= \omega_{ml}(k) + \eta \frac{\partial D}{\partial \omega_{ml}} \\ &= \omega_{ml}(k) + \eta \delta_m' \times x_l \end{aligned} \quad (2-17)$$

由此, 即完成了权值的修正。阈值的修正方法与权值相同, 本文不再赘述。

2.2 传统BP神经网络用于风电功率预测存在的不足

风能具有随机性, 因此风电功率预测具有广谱的预测结果, 这就需要选用全局预测性能良好的多层前馈型神经网络。而且, 神经网络需要融合风电场的尾流效应、空气密度等因素^[62-63], 内部机制复杂。而多层前馈型神经网络能够在实质

上实现从输入到输出的映射功能，而且数学理论已证明它具有实现任何复杂非线性映射的功能。网络能通过学习带正确答案的实例集自动提取“合理的”求解规则，即具有自学习能力；网络具有一定的推广、概括能力。

现有研究中，BP 神经网络以其思路清晰，结构严谨，工作状态稳定，可操作性强等特点，根据风速、风向、气温、气压、湿度等数值天气预报数据，对风电功率进行了较好的预测^[60]；但是，预测过程中发现 BP 神经网络存在以下几个缺陷：

网络隐含层结构的确定尚无一种统一而完整的理论指导，一般只能由经验选定，而网络的结构直接影响网络的逼近能力及推广性质。网络过大，在训练中效率不高，而且还会由于过拟合造成网络性能脆弱，容错性下降，浮点溢出；而太小的网络可能根本不收敛。在风电功率预测过程中，网络结构人为性较大，缺乏规则指导。

网络对权值和阈值的修正是沿负梯度方向进行的，对初始权值的选择依赖性强，容易陷入局部最优。预测过程中，初始点如果更靠近局部最优点，而不是全局最优点，就不会得到正确的结果。因此预测中需要选取多个初始点进行训练，来保证训练结果的全局最优性。

网络存在着学习率与稳定性之间固有的矛盾，同样造成修正网络权值和阈值的负梯度下降法训练速度缓慢。线性系统中，学习率过大导致训练过程不稳定，相反学习率过小又会导致训练时间过长。在非线性系统中，这个问题更加突出。而风电功率预测即属于非线性问题，很难选择好学习的速率。

因此，风电功率预测需要对 BP 神经网络进行改进。本文在多层前馈神经网络的基础上，引入智能优化方法解决上述存在的问题，即分别采用蚁群算法确定隐含层节点个数，采用粒子群算法确定网络的权值和阈值。下面对本文采用的多层前馈神经网络的网络结构进行介绍，隐含层节点个数的确定和网络的权值和阈值的确定分别在第三章和第四章中进行介绍。

2.3 风电功率预测模型的改进

神经网络的信息处理功能不仅取决于神经元的输入输出特性，而且与网络的拓扑结构、神经元之间的连接强度和神经元的阀值有关。因而，神经网络模型要加强自身的适应和学习能力，应该知道如何合理地自组织网络的拓扑结构，自行调整网络的权值和阈值等。综上，对传统 BP 神经网络改进如下：

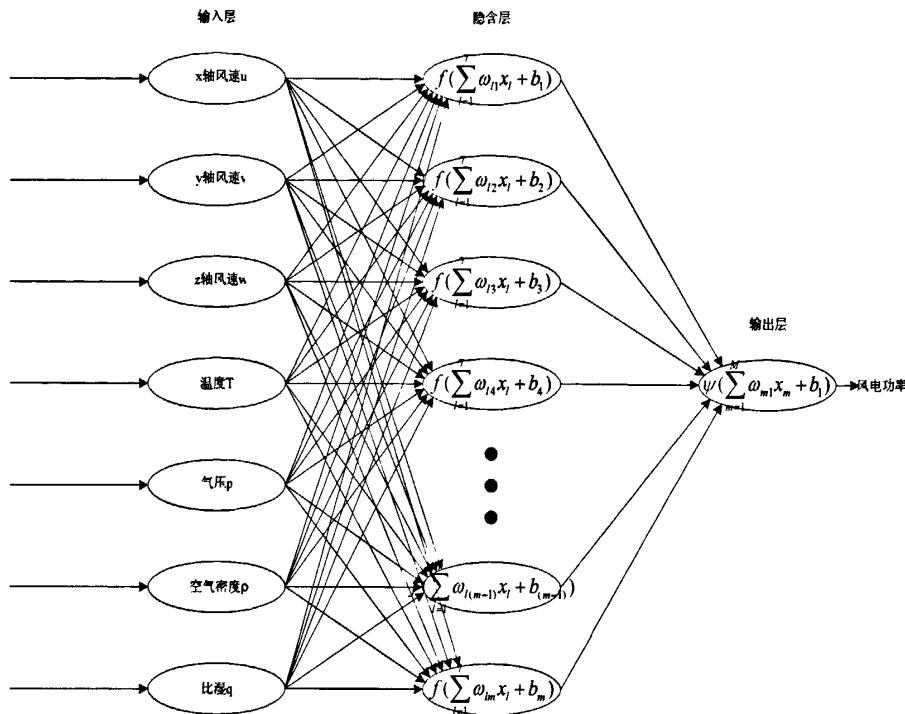


图 2-2 风电功率预测神经网络

网络中隐含层节点定义为最多 M 个，其最终取值不再由人工逐一筛选，而是由蚁群算法优化得出，蚂蚁个数定义为 I 个，蚁群算法叠代次数取 T 次。网络中权值和阈值逐一定义为 ω_{im} 和 b_m ，其调整不再遵循负梯度方向，而是引入粒子群优化算法优化得出，粒子个数取 J ，粒子群算法叠代次数取 S 。数值天气预报提供速度沿 x 、 y 、 z 三个方向的分量 u 、 v 、 w ，温度 T ，气压 p ，空气密度 ρ 以及比湿 q 等数据共 7 维，因此输入层需 $L=7$ 个节点；输出结果为风电功率值，输出层只有 1 个输出节点；学习样本的数量定义为 K 个，测试样本数量定义为 C 个。

第三章 基于蚁群算法的隐含层节点数的动态调整

3.1 蚁群算法概述

意大利学者 Dorigo M 等人受蚁群系统以自组织模式交互作用的启发，在 1996 年的《IEEE Transactions On Systems, Man, and Cybernetics-Part B》上发表了《Ant system: optimization by a colony of cooperating agents》的论文，标志着蚁群算法（Ant Colony Algorithm, ACA）的诞生^[64-65]。1998 年，Dorigo M 组织在比利时布鲁塞尔召开了第一届蚁群算法国际研讨会（ANTS' 98），随后每隔两年都要在布鲁塞尔召开一次蚁群算法国际研讨会。2000 年，Gutjahr W J 发表了题为《A graph-based ant system and its convergence》的学术论文，成功地证明了蚁群算法的收敛性。同年，Dorigo M 和 Bonabeau E 等在国际顶级学术杂志《Nature》上发表了蚁群算法研究综述，将这一研究推向国际学术界的前沿。近年来，蚁群算法的研究成果曾多次在国际顶级学术杂志《Nature》发表，《Future Generation Computer Systems》（Vol. 16, No. 8）和《IEEE Transactions on Evolutionary Computation》（Vol. 6, No. 4）分别于 2000 年和 2002 年出版了蚁群算法特刊。蚁群算法已经成功的求解了著名的旅行商问题（Traveling Salesman Problem, TSP）^[66]、二次分配问题（Quadratic assignment Problem, QAP）^[67]、Job-Shop 调度问题（Job-Shop Scheduling Problem, JSSP）^[68]以及离散优化问题（Discrete Optimization）^[69]等。

作为一种模仿蚂蚁群体行为的智能化算法，蚁群算法引入了分布式计算机制、正反馈并行机制，具有较强的鲁棒性、易于与其他方法结合等优点。目前蚁群算法已经渗透到多个应用领域，从离散问题到连续问题，从一维静态优化问题到多维动态优化问题，蚁群算法都表现出优异的性能和广阔的发展前景，成为国内外学者竞相关注的研究热点和课题。

3.2 蚁群算法的仿生学理论基础

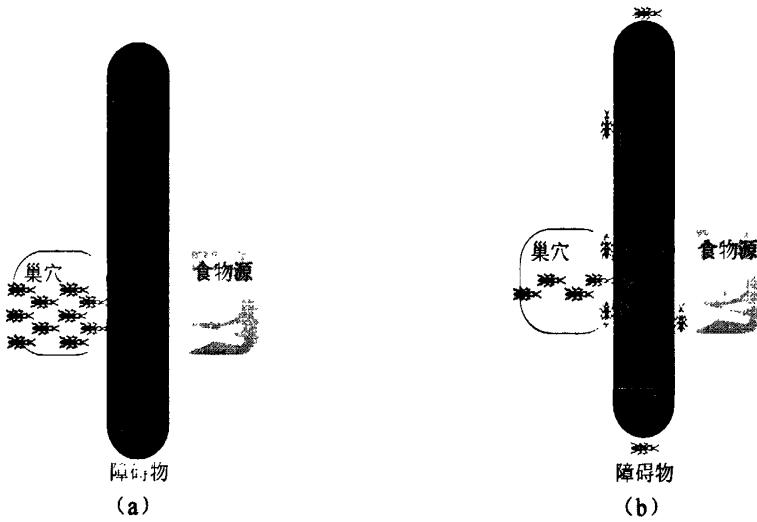
研究群居性昆虫行为的科学家发现，蚂蚁在外出活动时，可以很快地在目的地和巢穴之间找出一条最短路径。每只蚂蚁的智能并不高，看起来没有集中的指挥，但它们在群落一级上以自组织模式进行合作。在许多场合中尽管这些合作很

简单，但它们却能协同工作找到距离食物最短的路径。

仿生学家进行了大量的研究表明，蚁群之所以表现出复杂有序的行为，个体之间的信息交流与相互协作起着重要的作用。蚂蚁会分泌一种叫做“信息素”（Pheromone）或“迹”（Trail）的化学物质，蚂蚁的许多行为受信息素的调控。蚂蚁寻找最短路径的过程是一个交互式的过程，蚂蚁同一群体中的个体之间是通过在其所经过的路径上留下“信息素”来进行信息传递，从而能够相互协作，完成复杂的任务。

蚂蚁在运动过程中，在它所经过的路径上留下“信息素”，而且蚂蚁在运动过程中能够感知“信息素”。同一个蚁群中后来的蚂蚁遇到“信息素”时，不仅能检测出“信息素”的存在及其量的多少，而且还可以根据“信息素”的浓度来指导自己对前进方向的选择，蚂蚁倾向于朝着“信息素”浓度大的方向运动，并且自身留下的“信息素”会对原有的“信息素”进行加强。于是路径的长短及经过蚂蚁的多少就对一条路径上残余“信息素”的浓度产生影响，反过来“信息素”的强弱又指导着其它蚂蚁的前进方向。因此，某一路径上走过的蚂蚁越多，则后来者选择该路径的概率就越大。蚂蚁的这种选择路径的过程被称为蚂蚁的自催化行为（Autocatalytic Behavior），而蚁群这样的集体行为实际上就构成了一种学习的信息正反馈机制，即增强型学习系统（Reinforcement Learning System）。蚂蚁之间通过这种信息交流寻求通向食物的最短路径^[70-72]。

蚁群觅食活动中寻找最短路径的整个过程如图 3-1 所示。



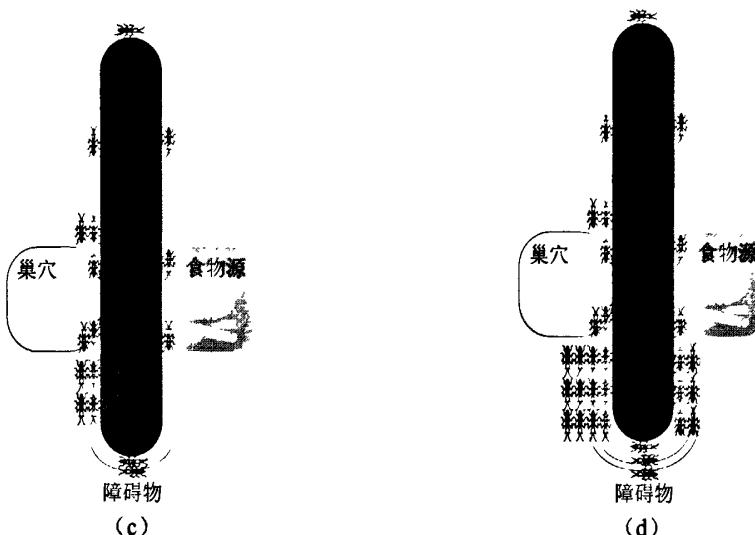


图 3-1 蚁群觅食寻找最短路径示意图

如图 3-1 (a) 所示, 从蚂蚁巢穴到食物源之间存在一个障碍物, 绕过障碍物的路径共有上下两条, 初始状态下“上路径”和“下路径”都没有蚂蚁爬过, 两条路径都没有信息素残留。图 3-1 (b) 中蚂蚁会按照相同的概率挑选一条路径觅食, 因此“上路径”和“下路径”上的蚂蚁数量差不多。由于“下路径”的长度小于“上路径”的长度, 单位时间内通过“下路径”的蚂蚁数量大于通过“上路径”的蚂蚁数量, 则在“下路径”上面遗留的信息素浓度比较高, 因为蚂蚁倾向于朝着信息素浓度高的方向移动, 所以选择“下路径”的蚂蚁随之增多, 如图 3-1 (c) 所示。于是, 蚁群的集体行为表现出一种信息正反馈现象, 即最短路径上走过的蚂蚁越多, 则后来的蚂蚁选择该路径的概率就越大, 蚂蚁个体之间就是通过这种信息的交流达到寻找巢穴和食物源之间最短路径的目的, 如 3-1 (d) 所示。

从中可以看出蚁群行为具有以下典型特征: 能够感知“信息素”, 能够检测出“信息素”的存在及其浓度, 并根据“信息素”的浓度来指导自己对前进方向的选择; 能释放自己的信息素; 所遗留的信息素数量会随时间而逐步减少。蚁群算法正是模拟蚁群行为的这些特征, 成为了当今解决组合优化问题的一个重要方法。

3.3 基本蚁群算法

3.3.1 基本蚁群算法对真实蚁群觅食特性的继承与发展

基本蚁群算法是利用蚁群觅食的群体智能解决复杂优化问题的典型例子, 对真实蚁群的觅食特性进行充分的继承^[66]:

真实蚂蚁在经过的路径上释放“信息素”，来影响蚁群中的后继蚂蚁，且“信息素”随着时间推移逐渐挥发，来减小历史遗留信息对后来的蚂蚁的影响。同样，人工蚂蚁改变其所经过路径上存储的数字化信息素 τ ， τ 反映了人工蚂蚁当前解和历史解的性能状态，而且可被后继人工蚂蚁读写。 τ 同样具有挥发特性，它像真实的信息量挥发一样使人工蚂蚁逐渐忘却历史遗留信息，在选择路径时不局限于以前人工蚂蚁所存留的经验。

真实蚂蚁要寻找一条从巢穴到食物源的最短路径。人工蚂蚁要寻找一条从源节点到目的节点间的最短路径。两种蚂蚁都只能在相邻节点间一步步移动，直至遍历完所有节点。

真实蚂蚁和人工蚂蚁从某一节点到下一节点的移动都是利用状态转移概率实现的。

另一方面，为获取令人满意的性能，蚁群算法在真实蚁群觅食特性的基础上，进行了有效的改进^[66]：

人工蚂蚁增加了记忆能力，可以记住曾经走过的路径或访问过的节点，提高了算法的效率。

人工蚂蚁选择路径的时候并不是完全盲目的，受到问题空间特征的启发，按一定算法规律有意识地寻找最短路径（如在旅行商问题中，可以预先知道下一个目标的距离）。

人工蚂蚁生活在离散时间的环境中，即问题的求解规划空间是离散的。

3.3.2 基本蚁群算法的原理

在基本蚁群算法中，一个有限规模的人工蚁群，通过相互协作搜索出待优化问题的最优解。根据问题约束条件，每只人工蚂蚁从初始状态出发建立一个可行解或是解的一个组成部分。在建立解决方案过程中，每只人工蚂蚁都搜集关于解的特征和其自身行为的信息，并且使用这些信息来修改信息素浓度、能见度因数等参数，为后继蚂蚁求解提供依据。人工蚂蚁既能共同的行动又能独立的工作，表现出了相互协作的状态；它们之间不能直接通讯，而通过信息素进行信息交换。

人工蚂蚁使用正反馈并行机制搜索可行解。每只人工蚂蚁在解空间中独立地搜索可行解，当它们碰到一个还没有人工蚂蚁走过的路口时，就随机挑选一条路径前行，同时释放出与路径长度有关的信息素。路径越短，信息素的浓度就越大。当后继的人工蚂蚁再次碰到这个路口的时候，以相对较大的概率选择信息素较多的路径，并在“行走路线”上留下更多的信息素，影响后继蚂蚁，形成正反馈机制。随着算法的推进，代表最优解路上的信息素逐渐增多，选择它的蚂蚁也逐渐增多，其他路径上的信息素却会随着时间的流逝而逐渐消减，最终整个蚁群在

正反馈的作用下集中到代表最优解的路线上，也就找到了最优解。在整个寻优过程中，单只人工蚂蚁的选择能力有限，但人工蚁群具有高度的自组织性，通过信息素交换路径信息，形成集体自催化行为，找到最优路径。

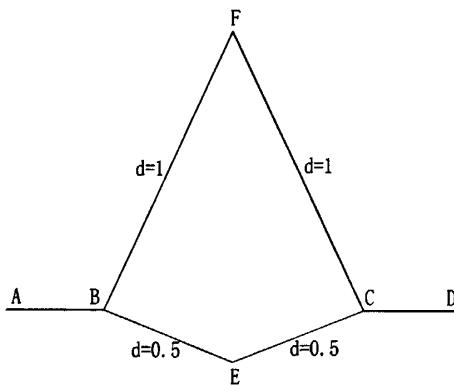
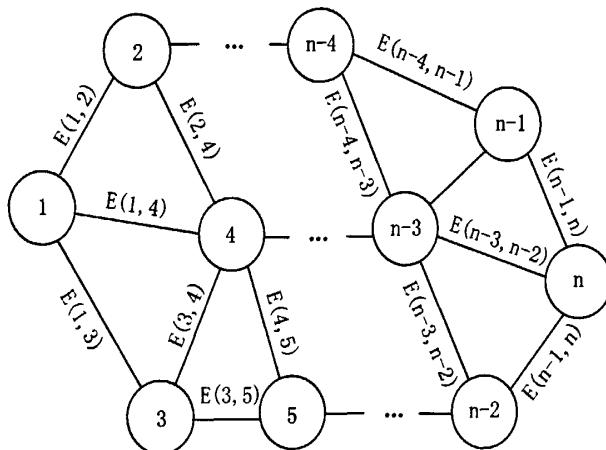


图 3-2 人工蚁群觅食寻找最短路径示意图

以图 3-2 简化模型说明，路径 BF, CF 长度 d 为 1，BE, CE 长度 d 为 0.5。假设在每个单位时间内有 30 只蚂蚁从 A 来到 B，有 30 只蚂蚁从 D 来到 C，每只蚂蚁单位时间内行进路程为 1，蚂蚁在行进过程中在单位时间内留下 1 个浓度单位的信息素，在一个单位时间内恰好完全挥发。 $t=0$ 时，分别有 30 只蚂蚁到达 B 点和 C 点，由于此前路径上没有信息素，它们随机地选择路径，在 BF、BE、CE、CF 上各有 15 只蚂蚁。 $t=1$ 时，分别有 30 只蚂蚁到达 B 和 C 点，在 B 点的蚂蚁发现在 BF 上的信息素浓度为 15，BE 上信息素浓度为 30（是由 15 只 BE 走向和 15 只 EB 走向的蚂蚁共同留下的），因此选择 BE 路径的蚂蚁数的期望值是选择 BF 蚂蚁数的 2 倍。所以，20 只蚂蚁选择 BE，10 只蚂蚁选择 BF。C 点也发生同样的情况。这个过程一直持续下去，直到所有人工蚂蚁最终选择最短路径 BEC（或 CEB）。

3.3.3 基本蚁群算法的数学模型

基本蚁群算法是用来解决著名的 TSP 问题而提出的。由于 TSP 问题是最基本的组合优化问题，常被用来验证一些算法，而且其他问题往往可借鉴 TSP 问题的求解模型而得到解答，因此本文引用基本蚁群算法^[66]解决 TSP 问题的过程，对蚁群算法中的信息素浓度、状态转移概率等相关公式进行简要说明。

图 3-3 n 个城市路径连接示意图

如图 3-3 所示，图中带有编号的 n 个圆圈表示 n 个城市， $E(i, j)$ ($1 \leq i \leq n, 1 \leq j \leq n$) 表示第 i 个城市和第 j 个城市之间的路径。TSP 问题是找到一条只经过每个城市一次且回到起点的最短路径的回路，使旅行费用最低。根据推销商与携带信息素的蚂蚁的相似性，可以作如下假设：

- ① 令每个城市随机分布多只蚂蚁，蚂蚁总数为 M ；
- ② 在周游的过程中，信息素释放在所走过的每一条路径 $E(i, j)$ 上，令 $\tau_{ij}(t)$ 表示某一时刻 t 在路径 $E(i, j)$ 上的信息素浓度，即单位长度上所含有信息素的数量；
- ③ 蚂蚁以某一概率从第 i 个城市向另一个先前没有到达过的第 j 个城市前进，这个概率是两个城市之间路径长度和该路径上信息素浓度的函数；
- ④ 蚂蚁直到一次周游完成后，才允许游走已经访问过的城市（可由禁忌表来控制）；
- ⑤ 在时刻 t 每只蚂蚁都要选择下一个要去的城市，并在 $t+1$ 时刻到达该城市，这个过程称为蚁群算法的一次迭代。

显然，每经过一次循环，蚁群中的每只蚂蚁都完成了一次符合规则的旅行。

此时，信息素的浓度按照下式修正

$$\tau_{ij}(t+n) = \rho \tau_{ij}(t) + \Delta \tau_{ij} \quad (3-1)$$

$$\Delta \tau_{ij} = \sum_{a=1}^{Num} \Delta \tau_{ij}^a \quad (3-2)$$

$$\Delta \tau_{ij}^a = \begin{cases} \frac{Q}{L_a} L_{ij}, & \text{如果第 } a \text{ 只蚂蚁在时间区间 } (t, t+n) \text{ 走过路径 } E(i, j); \\ 0, & \text{否则} \end{cases} \quad (3-3)$$

其中， ρ 表示信息素残留系数， $(1-\rho)$ 表示在时间区间 $(t, t+n)$ 内信息素的挥发程度，以避免路径上信息素数量的无限制增加；

$\Delta \tau_{ij}^a$ 表示第 m 只蚂蚁经过路径 $E(i, j)$ 后，该路径上的信息素浓度增量；

Q 表示蚂蚁完成一次旅行后，释放出的信息素的总量；

L_{ij} 表示城市 i 与城市 j 之间的路径长度；

L_a 表示第 m 只蚂蚁完成一次旅行后走过路径的总长度。

按照假设③，对先前没有蚂蚁走过的多条路径，蚂蚁是随机进行选择；对于先前有蚂蚁走过的多条路径，蚂蚁则是按某一转移概率进行选择的，这个转移概率是路径上信息素浓度和两个城市之间能见度的函数，下面如下定义第 m 只蚂蚁从城市 i 向城市 j 运动的转移概率

$$P_{ij}^a(t) = \begin{cases} \frac{[\tau_{ij}(t)]^\alpha [\eta_{ij}]^\beta}{\sum_{s \in Node} [\tau_{is}(t)]^\alpha [\eta_{is}]^\beta}, & \text{如果 } j \in Node \\ 0, & \text{否则} \end{cases} \quad (3-4)$$

其中， η 表示能见度因数，它等于城市之间距离的倒数；

α 表示信息素浓度相对重要指数；

β 表示能见度因数相对重要指数；

$Node$ 表示与城市 i 直接相连且蚂蚁还没有游走过的城市的集合。

这样，蚂蚁按照式 (3-1) ~ (3-3) 更新路径上的信息素浓度，按照式 (3-4) 进行概率计算，通过多次循环迭代后，收敛到所有蚂蚁都沿着同一条路径运动，即可认为蚁群找到了一条符合规则的最优路径。

3.3.4 基本蚁群算法的具体实现

基本蚁群算法的实现步骤为^[66]

第 1 步：初始化参数。时间 $t = 0$ ，循环次数 $N_c = 0$ ，设置最大循环次数 $N_{c\max}$ ，令路径 (i, j) 的初始化信息量 $\tau_{ij}(t) = const$ ，初始时刻 $\Delta\tau_{ij}(0) = 0$ 。

第 2 步：将 m 只蚂蚁随机放在 n 个城市上。

第 3 步：循环次数 $N_c \leftarrow N_c + 1$ 。

第 4 步：令蚂蚁禁忌表索引号 $k = 1$ 。

第 5 步： $k = k + 1$ 。

第 6 步：根据状态转移概率公式 (3-4) 计算蚂蚁选择城市 j 的概率， $j \in \{C - tabu_k\}$ 。

第 7 步：选择具有最大状态转移概率的城市，将蚂蚁移动到该城市，并把该城市记入禁忌表中。

第 8 步：若没有访问完集合 C 中的所有城市，即 $k < m$ ，跳转至第 5 步；否

则，转第 9 步。

第 9 步：根据式（3-1）~（3-3）更新每条路径上的信息量。

第 10 步：若满足结束条件，循环结束输出计算结果；否则清空禁忌表并跳转到第 3 步。

基本蚁群算法的算法框图如图 3-4 所示。

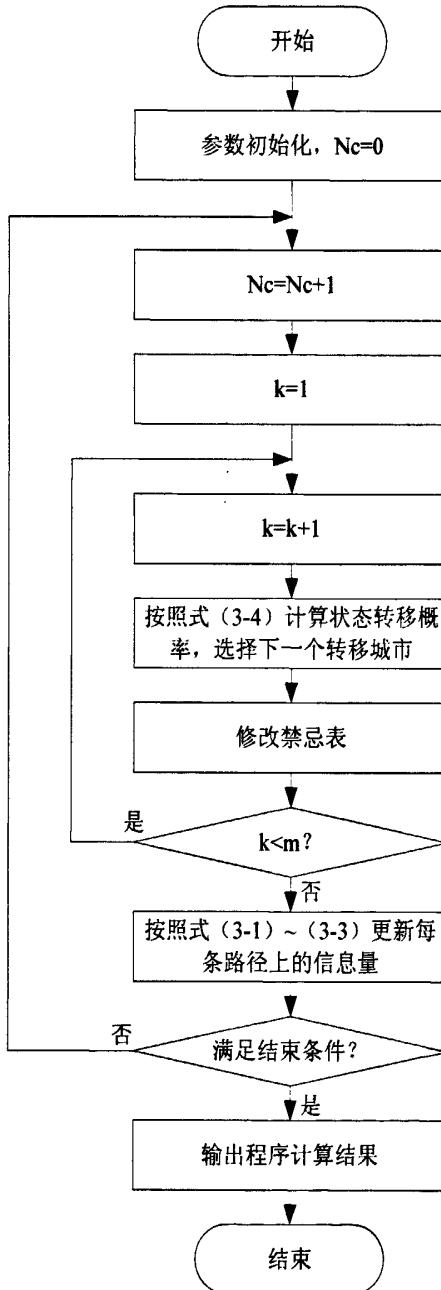


图 3-4 基本蚁群算法程序框图

3.3.5 现有一些基本蚁群算法的改进方法

在提出用于确定结构基因的蚁群算法之前，先介绍现有的基本蚁群算法的改进办法，以便为确定结构基因提供指导和参考。

首先介绍基本蚁群算法中存在的不足，主要体现在

(1) 基本蚁群算法机理较复杂，基本蚁群算法求解旅行商问题时间复杂度为 $O(N_c \cdot n^2 \cdot m)$ ，计算量较大，造成收敛时间较长。

(2) 基本蚁群算法容易出现局部收敛，即搜索进行到一定程度后，所有蚂蚁搜索到的解完全一致，不再对空间进行进一步搜索，无法发现全局最优解。

(3) 基本蚁群算法在本质上是离散的，仅适用于组合优化问题，对于连续优化问题（函数优化）无法直接应用，使算法的应用范围受到限制。

为此，已有许多针对上述缺陷的改进算法，并应用到不同领域。下面简要总结以下四种有代表性的改进方法。

3.3.5.1 蚁群系统

为提高解的质量和收敛速度，从而改进算法的性能，Dorigo, Gambardella等人在基本蚁群算法的基础上提出了 Ant-Q 模型，并进而发展完善为蚁群系统模型（Ant Colony System, ACS）^[73]。为解决基本蚁群算法在构造解过程中，选择的随机性造成的算法收敛速度慢的问题，蚁群系统在每一次循环中仅让最短路径上的信息量作更新，且以较大的概率选中信息量最大的路径，充分利用学习机制，强化最优信息的反馈。为实现上述改进，蚁群系统模型改进了蚂蚁的状态转移规则和全局更新规则，并新增了对各条路径信息量调整的局部更新规则：首先蚂蚁采用局部信息对路径上的信息量进行调整，来寻找最佳路径；在所有进行寻优的蚂蚁结束路径的搜索后，采用全局信息加强已发现的最好路径上的信息量。下面作具体说明^[73-75]。

1. 蚁群系统的状态转移规则

蚁群系统采用了自适应伪随机概率选择规则（Pseudo-Random Proportional Rule）。每当蚂蚁要选择向某一个城市转移时，就产生一个在[0, 1]范围内的随机数 q ，与基本蚁群算法不同的是，确定蚂蚁转移方向的方法不是唯一的，而是根据这个随机数的大小来确定的。通过自适应伪随机概率选择规则，蚁群系统实现了随机性选择和确定性选择相结合，能够在搜索过程中动态调整状态转移概率，有效的避免了停滞现象。

设定 $J_k(i)$ 是第 k 只蚂蚁在访问到城市 i 后尚需访问的城市集合， q 为一个在区间[0, 1]内的随机数， q_0 是一个算法参数 ($0 \leq q_0 \leq 1$)。

当 $q \leq q_0$ 时, 蚂蚁 k 按照式 (3-5) 选择下一个城市

$$j = \arg \max_{s \in J_k(i)} \{ [\tau(i, s)]^\alpha [\eta(i, s)]^\beta \} \quad (3-5)$$

当 $q > q_0$ 时, 蚂蚁 k 根据式 (3-6) 确定向下转移的目标城市:

$$P_{ij}^k = \begin{cases} \frac{[\tau(i, j)]^\alpha \cdot [\eta(i, j)]^\beta}{\sum_{s \in J_k(i)} [\tau(i, s)]^\alpha \cdot [\eta(i, s)]^\beta} & j \in \text{allowed}_k \\ 0 & \text{其他} \end{cases} \quad (3-6)$$

2. 蚁群系统全局更新规则

在蚁群系统中, 全局更新不再用于所有的蚂蚁, 而是只对每一次循环中最优的蚂蚁使用。更新规则如式 (3-7) 和式 (3-8)

$$\tau(i, j) \leftarrow \rho \cdot \tau(i, j) + (1 - \rho) \cdot \Delta \tau(i, j) \quad (3-7)$$

$$\Delta \tau(i, j) = \begin{cases} \frac{1}{L_{gb}} & (i, j) \text{ 为全局最优路径且 } L_{gb} \text{ 是最短路径} \\ 0 & \text{其他} \end{cases} \quad (3-8)$$

其中, L_{gb} 为蚁群当前循环中所求得的最优路径长度; ρ 为信息素残留系数。

3. 蚁群系统局部更新规则

在蚁群系统中, 局部更新规则常用 Ant-Q 强化学习的蚁群算法, 即在所有的蚂蚁完成一次转移后执行

$$\tau(i, j) \leftarrow \rho \cdot \tau(i, j) + (1 - \rho) \cdot \Delta \tau(i, j) \quad (3-9)$$

$$\Delta \tau(i, j) = \gamma \cdot \max_{s \in J_k(j)} \tau(j, s) \quad (3-10)$$

其中的 $J_k(j)$ 表示第 k 只蚂蚁在访问到城市 j 后尚需访问的城市集合。

Dorigo, Gambardella 等人的实验结果表明与基本蚁群算法相比, 蚁群系统模型具有一般性, 而且更有利于全局搜索。

3.3.5.2 最大最小蚂蚁系统

为避免将蚂蚁搜索行为集中到最优解的附近使算法过早收敛而出现早熟现象, 德国学者 Stutzle T 和 Hoos H H 提出最大-最小蚂蚁系统 (MAX-MIN Ant System, MMAS) [76]。最大-最小蚂蚁系统已经成为解决 TSP、QAP 等离散域优化问题的最好蚁群算法之一, 很多对蚁群算法的改进算法都渗透着最大-最小蚂蚁系统的思想。

最大-最小蚂蚁系统中, 全局更新不再用于所有的蚂蚁, 而是只对每一次循环中最优的蚂蚁使用, 即各个蚂蚁在一次循环后, 只有找到最短路径的蚂蚁才能够在其经过的路径上释放信息素, 从而更好地利用了历史信息, 以加快收敛速度。更新规则如式 (3-11) 和式 (3-12)

$$\tau_{ij}(t+n) = (1-\rho) \cdot \tau_{ij}(t) + \Delta \tau_{ij}^{\min} \quad (3-11)$$

$$\Delta \tau(i, j) = \frac{Q}{L} \quad L = \min(L_k), k = 1, 2, \dots, m \quad (3-12)$$

最大-最小蚂蚁系统中，将各条路径上的信息量限制在区间 $[\tau_{\min}, \tau_{\max}]$ 之内，超出这个范围的值将被限制为信息量允许值的上下限，这样可以有效地避免某条路径上的信息量远大于其他路径而造成的所有蚂蚁都集中到同一条路径上，从而避免算法过早收敛于局部最优解。更新规则如式（3-13）。

初始化信息量 $\tau_{ij}(t) = c$ 设为最大值 τ_{\max} ，并将 $\tau_{ij}(t)$ 限定在 $[\tau_{\min}, \tau_{\max}]$ 之间。

$$\tau_{ij}(t) = \begin{cases} \tau_{\max} & \tau_{ij}(t) > \tau_{\max} \\ \tau_{ij}(t) & \tau_{ij}(t) \in [\tau_{\min}, \tau_{\max}] \\ \tau_{\min} & \tau_{ij}(t) < \tau_{\min} \end{cases} \quad (3-13)$$

3.3.5.3 嵌入确定性搜索的连续域蚁群算法

为使蚁群算法应用于连续域，我国学者杨勇等人提出嵌入确定性搜索的连续域蚁群算法^[77]。嵌入确定性搜索的连续域蚁群算法中，蚂蚁个体通过局部随机搜索寻找食物源，然后利用信息素交换信息，决定全局转移方向。全局随机搜索的蚂蚁承担搜索陌生新食物源的任务，本质上也是一种随机性搜索算法。亦即首先进行确定性局部搜索以改善寻优性能，加快收敛速率；然后进行全局搜索，利用信息素浓度和能见度因数确定蚂蚁的移动方向。

设优化函数为 $\max Z=f(X)$ ， m 只蚂蚁随机分布在定义域内，每只蚂蚁都有一个半径为 r 的邻域。并且在自己的领域内进行搜索。当所有蚂蚁完成局部搜索后，蚂蚁个体根据信息素浓度和能见度因数在全局范围内进行移动，完成一次循环后，更新信息素浓度。

（1）局部搜索

局部搜索是指每只蚂蚁在自己的邻域空间内进行随机搜索。设新的位置点为 X' ，如果新的位置值比原来的目标函数值大，则取新位置，否则取原来的目标函数值。局部搜索是在半径为 r 的区域内进行的，且 r 随迭代次数的增加而减小。更新规则如式（3-14）。

$$X_i(t) = \begin{cases} X'_i & f(X'_i) > f(X_i) \\ X_i & f(X'_i) \leq f(X_i) \end{cases} \quad (3-14)$$

（2）全局搜索

全局搜索是指每只蚂蚁都经过一次局部搜索后，选择停留在原地、转移到其他蚂蚁的邻域或进行全局随机搜索。设 $Act(i)$ 为第 i 只蚂蚁选择的动作， f_{avg} 为 m 只蚂蚁的目标函数平均值，则更新规则如式（3-15）。

$$Act(i) = \begin{cases} \text{全局随机搜索} & f(X_i) < f_{avg} \cap q < q_0 \\ \text{停留在原地或转移到其他蚂蚁邻域} & \text{其他} \end{cases} \quad (3-15)$$

其中, $Act(i)$ 停留在原地或转移到其他蚂蚁邻域, 遵循以下转移规则

$$p(i, j) = \frac{\tau(j)e^{\frac{d_{ij}}{T}}}{\sum \tau(j)e^{\frac{d_{ij}}{T}}} \quad (3-16)$$

$$d_{ij} = f(X_i) - f(X_j) \begin{cases} < 0 & \text{当 } i \neq j \\ = 0 & \text{当 } i = j \end{cases} \quad (3-17)$$

式 (3-16) 为第 i 只蚂蚁向其他目标函数值更大的蚂蚁 j 的邻域移动的概率, 其中系数 T 的大小决定了这个概率函数的斜率。

蚂蚁向某个信息素浓度高的地方移动时, 可能会在转移路途中一个随机地点发现新的食物源, 称为有向随机转移。第 i 只蚂蚁向第 j 只蚂蚁的邻域转移的全局更新规则如式 (3-18)。

$$X_i = \begin{cases} X_j & \rho < \rho_0 \\ \alpha X_j + (1-\alpha) X_i & \rho \geq \rho_0 \end{cases} \quad (3-18)$$

其中, $0 < \rho < 1$, $\rho_0 > 0$, $\alpha > 1$ 。

(3) 信息素浓度更新规则

全局搜索结束后, 要对信息素浓度进行更新。设有 n 只蚂蚁向蚂蚁 j 处移动 (包括有向随机搜索), 信息素浓度更新规则如式 (3-19)。

$$\begin{aligned} \tau(j) &= \beta \tau(j) + \sum_{i=1}^n \Delta \tau_i \\ \Delta \tau_i &= \frac{1}{f(X_i)} \end{aligned} \quad (3-19)$$

其中, 遗忘因子 $0 < \beta < 1$ 。

(4) 嵌入确定性搜索

为克服随机性搜索算法存在着求解效率较低、求解结果较分散等缺点, 嵌入确定性搜索的连续域蚁群算法使用确定性搜索中的步长加速法, 只利用函数信息而不需要利用导数信息, 甚至不要求函数连续, 具有适用面较广, 易于编程, 避免复杂计算的特点。

步长加速法包括探测性搜索和模式性移动两部分。首先依次沿坐标方向探索, 称之为探测性搜索; 然后经此探测后求得目标函数的变化规律, 从而确定搜索方向并沿此方向移动, 称之为模式移动。重复以上两步, 直到探测步长小于充分小的正数 ε 为止。

嵌入确定性搜索的蚁群算法, 是在局部搜索时以一定的概率利用步长加速法进行确定性搜索。局部搜索规则如式 (3-20)。

$$R = \begin{cases} \text{用步长加速法进行局部确定性搜索} & v < v_0 \\ \text{按公式 (3-14) 进行局部随机搜索} & \text{其他} \end{cases} \quad (3-20)$$

其中, v 是随机数且 $0 < v < 1$; v_0 是算法系数且 $0 < v_0 < 1$ 。

3.3.5.4 基于密集非递阶的连续交互式蚁群算法

为使蚁群算法思想更好的应用于连续域, Dero J 等人提出了基于密集非递阶的连续交互式蚁群算法 (Continuous Interacting Ant Colony Algorithm, CIACA) [78]。该算法通过修改蚂蚁信息素的留存方式和蚂蚁的行走规则, 并运用信息素交流和直接通信两种方式来指导蚂蚁寻优。

为描述蚁群从环境中接受“信息流”的方式, Wilson E D 于 1988 年提出了“密集非递阶” (Dense Hierarchy) 的概念。“蚁群信息传递的层次结构具有特殊性, 可称之为非递阶结构, 即较高层次单元的性质在一定程度上影响着较低的一层, 而被较高层次影响后的较低层次单元会反过来影响较高层次”。每只蚂蚁都可在任意时刻与其他蚂蚁进行联络, 而蚁群中的信息流是通过两种通信通道传输的, 即基于信息素轨迹交流通信通道和蚂蚁个体间直接通信通道。这里的通信通道是指信息素的存放地, 可用来传递多种信息。由于信息通道中信息素在系统中的交流方式、驻留方式、更新方式不同, 信息通道具有众多种类。

Bilchev G A 等率先提出将基于信息素轨迹交流通信通道思想用于求解连续域优化问题。基于信息素轨迹交流通信通道在交流方式上, 当蚁群中某只蚂蚁留下一定量的信息素后, 其他后继蚂蚁都能觉察到该信息素的存在; 在驻留方式上, 某一时间段内信息素将被一直保留于蚁群系统之中; 在更新方式上, 由于挥发作用, 信息素随着时间的推移而更新。

基于信息素轨迹交流通信通道在求解连续域优化问题中, 每只蚂蚁在其搜索空间内的节点上释放浓度与其所搜索到的目标函数值成正比的信息素, 这些含有信息素的节点能够被蚁群中的所有个体察觉, 并逐渐消失。蚂蚁根据路径距离和路径上的信息量来决定是否选择这些信息节点。蚂蚁会向着含有信息素的节点集云的重心 G_i 移动, 而重心 G_i 位置依赖于第 i 个节点上第 j 只蚂蚁的能见度 ω_{ij} 。处于含有信息素的节点上的蚂蚁并不直接地向其集云的重心移动。事实上, 每只蚂蚁都有在蚁群中均匀分布的参数调整范围以及一个允许范围内的随机距离, 都以随机距离为度量向着其重心位置移动。设 n 表示节点数目; x_i 表示第 i 个节点的位置; δ 表示蚁群中两只蚂蚁间的平均距离; θ_i 表示第 i 个节点上的信息量; δ_{ij} 表示从第 j 只蚂蚁到第 i 个节点之间的距离, 则有

$$G_j = \sum_{i=1}^n \left(\frac{x_i \omega_{ij}}{\sum_{j=1}^n \omega_{ij}} \right) \quad (3-21)$$

$$\omega_{ij} = \frac{\delta}{2} \cdot e^{-\theta_i \cdot \delta_j} \quad (3-22)$$

蚂蚁个体间直接通信通道在交流方式上，信息的发出与接受，是一对一的，通信通道的范围是“点对点”式的；在驻留方式上，某一时间段内信息可以以“记忆”的形式保存在蚁群系统中；在更新方式上，所存储的信息是静态的。

蚂蚁个体间直接通信通道在求解连续域优化问题中，以目标函数值为信息，每只蚂蚁都能直接给另一只蚂蚁发送信息，即通信通道的范围是“点对点”式的；蚂蚁可将已经接收到或将要接收到的信息存储到栈中，而栈中的信息可被随机读取。信息接收者会将发送者所发送来的信息与其自身的信息相比较，以决定它是否要向信息发送者的位置移动。最终位置将出现在一个以信息发送者为中心、信息接收者范围为半径的超球体内，然后信息接收者将信息进行压缩并将其随机发送给另一只蚂蚁。基于信息素轨迹交流通信通道和蚂蚁个体间直接通信通道没有并发机制，所以容易实现，本文不再赘述。

国内外，蚁群算法的改进研究成果很多，除前面提到的四种方法、还有基于信息素扩散的蚁群算法、基于去交叉局部优化策略的蚁群算法、多态蚁群算法、基于模式学习的小窗口蚁群算法、基于混合行为蚁群算法、带聚类处理的蚁群算法、基于云模型理论的蚁群算法、具有感觉和知觉特征的蚁群算法、具有随机扰动特性的蚁群算法、基于信息熵的改进蚁群算法等。本文不再赘述。

3.4 网络结构基因的构建

为表征隐含层节点的有无，如下定义结构基因：

$$G = \begin{bmatrix} g_{11} & g_{12} & \cdots & g_{1M} \\ \cdots & \cdots & \cdots & \cdots \\ \cdots & \cdots & \cdots & \cdots \\ g_{i1} & g_{i2} & \cdots & g_{iM} \end{bmatrix} \quad (0 < m \leq M) \quad (3-23)$$

当 $G_i(i, m)=1$ 时，表示第 m 维结构基因 $G_i(i, m)$ 对应的第 m 维隐含层节点存在；当 $G_i(i, m)=0$ 时，表示第 m 维结构基因 $G_i(i, m)$ 对应的第 m 维隐含层节点不存在。可见 $G_i(i, m)$ 采用二进制编码， $\sum_{m=1}^M G_i(i, m)$ 为网络隐含层节点的实际个数。

3.5 网络结构基因的确定

蚁群算法应用于确定本文的隐含层节点，与其在解决路径寻优中的应用存在一定的差别：将每个结构基因 $G_t(i, m)$ 视为一个路径点，蚂蚁在该路径点可选择的路径有且只有两条，即“0”路径和“1”路径。每只蚂蚁根据结构基因 $G_t(i, m)$ 的取值（0 或 1），在相应的路径上释放一定的信息素；用于获取误差最小的风电功率预测网络输出，因此以网络输出与学习样本均方差作为路径长度；信息素浓度的更新要避免对信息素浓度相对重要性参数 α 、能见度因数相对重要性参数 β 的依赖；能见度因数的构建要与结构基因二进制特性相适应。

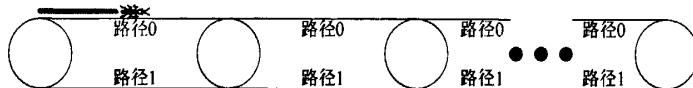


图1

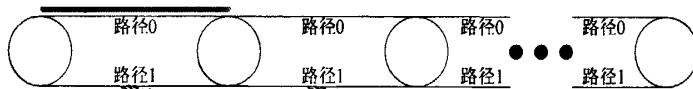


图2



图3

图 3-5 蚁群算法求解结构基因示意图

基于上述考虑，本文对原有蚁群算法进行了变异，即通过采用新的办法确定信息素浓度、能见度因数以及转移概率，来确定结构基因的取值。

信息素浓度 τ 是表征过去信息的载体，而能见度因数 η 则是表征未来信息的载体，它们直接影响到蚁群算法的全局收敛性和求解效率，因此下面首先分别讨论。

按照基本蚁群算法的信息素浓度的概念，在借鉴现有蚁群算法改进方法的基础上，为确保信息素浓度与结构基因二进制特性相适应，分别构建对于第 $t+1$ ($0 < t < T$) 代，第 i ($0 < i \leq I$) 只蚂蚁，第 m 个隐含层节点“0”路径和“1”路径上信息素如下

$$\begin{aligned} \tau_{i(t+1)}^0(m) &= \begin{cases} \rho \cdot \tau_u^0(m) + \frac{Q}{D_t(i)} & \text{当 } G_t(i, m) = 0 \\ \rho \cdot \tau_u^0(m) & \text{当 } G_t(i, m) = 1 \end{cases} \\ \tau_{i(t+1)}^1(m) &= \begin{cases} \rho \cdot \tau_u^1(m) & \text{当 } G_t(i, m) = 0 \\ \rho \cdot \tau_u^1(m) + \frac{Q}{D_t(i)} & \text{当 } G_t(i, m) = 1 \end{cases} \end{aligned} \quad (3-24)$$

其中， ρ 为信息素残留系数，反映了蚂蚁个体之间相互影响的强弱，对蚁群算法的收敛性能影响非常大。为防止信息素无限积累， ρ 取值范围在 $[0, 1]$ 。 ρ 与迭代次数 T ，近似成正比。如果 ρ 很大，路径上的残留信息占主导地位，信息正反馈作用相对较弱，搜索的随机性增强，因而蚁群算法的收敛速度很慢。如果 ρ 较小，信息正反馈作用占主导地位，搜索的随机性减弱，导致收敛速度快，但易于陷入局部收敛。经过试验本文取 $\rho = 0.5$ 。

Q 为常量，表示蚂蚁在经过路径上所释放的信息素的总量。 Q 越大，蚂蚁在已遍历路径上信息素的累积越快，因而加强了蚁群搜索时的正反馈性，有助于算法的快速收敛。经过试验本文取 $Q = 10$ 。

$D_t(i)$ 表示蚂蚁所走过的路径的长度，为第 t 次迭代下第 i 只蚂蚁产生的网络输出与学习样本的均方差。

需要说明的是，基本蚁群算法中，只要蚂蚁爬过第 m 个节点，则第 m 个节点上的信息素浓度就会增加。但在上述结构基因取值问题中，当蚂蚁第一次选择路径时，路径上的信息素浓度和能见度因数相同，因此蚂蚁选择路径是随机进行的，当完成一次循环后，即使得到的结构基因不满足约束条件，路径上的信息素浓度还是会增加，这样一旦信息素浓度相对重要性参数 α 、能见度因数相对重要性参数 β 选择不合适，就会使这些不合适路径的转移概率有较大地增加，最终导致算法不能快速收敛，甚至发散。

为杜绝上述问题的出现，本文在基本蚁群算法的基础上作出以下改进：在所有蚂蚁开始爬行前，将各个路径上的信息素浓度进行保存；当所有蚂蚁完成一次爬行后，计算出网络误差，如果满足约束条件则对路径信息素浓度按式（3-24）进行修正，反之，则认为本次蚂蚁爬行是无效的，仍保存原来的路径信息素浓度。这样便可以减少对 α 、 β 的依赖，并加快算法的收敛。

按照基本蚁群算法的能见度因数的概念，在借鉴现有蚁群算法改进方法的基础上，为确保能见度因数与结构基因二进制特性相适应，构建第 $t+1$ ($0 < t < T$) 代，第 i ($0 < i \leq I$) 只蚂蚁，第 m 个隐含层节点“0”路径和“1”路径上能见度因数如下

$$\eta_{i(t+1)}^0(m) = \begin{cases} \frac{\min_{i=1}^I(D_t(i))}{D_t(i)} & \text{当 } G_t(i, m) = 0 \\ \frac{D_t(i) - \min_{i=1}^I(D_t(i))}{D_t(i)} & \text{当 } G_t(i, m) = 1 \end{cases}$$

$$\eta_{i(t+1)}^1(m) = \begin{cases} \frac{\sum_{i=1}^I D_t(i) - \min(D_t(i))}{D_t(i)} & \text{当 } G_t(i, m) = 0 \\ \frac{\min(D_t(i))}{D_t(i)} & \text{当 } G_t(i, m) = 1 \end{cases} \quad (3-25)$$

通过上述方法构建能见度因数，即可实现：当前路径下误差越小，该路径下能见度因数越接近 1，另外一条路径的能见度因数越接近 0，该路径下状态转移概率越高，选择该路径的概率越大。而当前路径下误差为最小误差，该路径下能见度因数为 1，另外一条路径的能见度因数为 0，状态转移概率会随之提高。亦即第 i 只蚂蚁在第 m 个节点，若第 t 代下结构基因 $G_t(i, m) = 0$ 即第 m 个节点不存在，则第 $t+1$ 代“0”路径上能见度因数为第 t 代下所有蚂蚁爬行后产生的最小误差与第 t 代下第 i 只蚂蚁爬行后产生的误差之比；若第 t 代下结构基因 $G_t(i, m) = 1$ 即第 m 个节点存在，则第 $t+1$ 代“1”路径上能见度因数为第 t 代下所有蚂蚁爬行后产生的最小误差与第 t 代下第 i 只蚂蚁爬行后产生的误差之比。

对于第 $t+1$ ($0 < t < T$) 代，第 i ($0 < i \leq I$) 只蚂蚁，第 m 个隐含层节点“0”路径和“1”路径上转移概率 $P_i(t+1)$ 分别为

$$P_{i+1}(m) = \begin{cases} \frac{[\tau_{i(t+1)}^0(m)]^\alpha \cdot [\eta_{i(t+1)}^0(m)]^\beta}{\tau_{i(t+1)}^0(m) \cdot \eta_{i(t+1)}^0(m) + \tau_{i(t+1)}^1(m) \cdot \eta_{i(t+1)}^1(m)} & \text{当 } G_t(i, m) = 0 \\ \frac{[\tau_{i(t+1)}^1(m)]^\alpha \cdot [\eta_{i(t+1)}^1(m)]^\beta}{\tau_{i(t+1)}^0(m) \cdot \eta_{i(t+1)}^0(m) + \tau_{i(t+1)}^1(m) \cdot \eta_{i(t+1)}^1(m)} & \text{当 } G_t(i, m) = 1 \end{cases} \quad (3-26)$$

其中，信息素浓度相对重要性参数 α 反映蚂蚁在运动过程中所积累的信息量在指导蚁群搜索中的相对重要程度。 α 越大，蚂蚁选择以前走过路径的可能性就越大，搜索的随机性减弱； α 越小，易使蚁群算法过早陷入局优。经过试验本文取 $\alpha = 2$ 。

能见度因数相对重要性参数 β 反映除能见度因数在指导蚁群搜索过程中的相对重要程度，这些启发式信息表现为寻优过程中先验性、确定性因素。 β 越大，蚂蚁在局部点上选择局部最短路径的可能性越大，虽然加快了收敛速度，但减弱了随机性，易于陷入局部最优。经过试验本文取 $\beta = 2$ 。

对于第 $t+1$ ($0 < t < T$) 代，第 i ($0 < i \leq I$) 只蚂蚁，第 m 个隐含层节点结构基因为

$$G_{i+1}(i, m) = \begin{cases} G_t(i, m) & \text{当 } r \leq P_i(t+1) \\ 1 - G_t(i, m) & \text{当 } r > P_i(t+1) \end{cases} \quad (3-27)$$

其中 r 为 (0, 1) 之间的随机数。

结构基因的确定是通过多个候选解组成的群体进化过程实现的，所以蚂蚁的

数目 I 对收敛性会产生影响。蚂蚁数量 I 大, 相对处理问题的规模大, 会提高蚁群算法的全局搜索能力和稳定性, 但数量过大导致大量曾被搜索过的路径上的信息量变化趋于平均, 信息正反馈作用减弱, 随机性增强, 收敛速度减慢。反之, 蚂蚁数量 I 小, 相对处理问题的规模小, 会使从来未被搜索到的解上的信息量减小到接近于 0, 全局搜索的随机性减弱, 虽然收敛速度加快, 但会使算法的稳定性变差, 出现过早停滞现象。经过试验, 本文取 $I=16$

需要说明的是, 蚁群算法参数空间庞大并且各参数之间关联性强, 因此至今还没有完善的理论来确定使蚁群算法求解性能最佳的最优组合参数。本文参数的取值是通过试验反复试凑得到的。

第四章 基于粒子群算法的网络连接权值和阈值的动态调整

4.1 粒子群算法概述

James Kennedy 和 Russell Eberhart 受鸟群、鱼群等自然生物群体（swarm）群体行为的启发，在 1995 年的 IEEE International Conference On Neural Networks 和 6th international Symposium On Micromachine and Human Science 上分别发表了“Particle swarm optimization” 和 “A new optimizer using particle swarm theory”的论文，标志着粒子群优化（Particle Swarm Optimization, PSO）算法的诞生^[79-80]。

与第三章中的蚁群算法类似，粒子群优化算法同样是一种群体智能（swarm intelligence），粒子群优化由于其算法简单，易于实现，无需梯度信息，参数少等特点在连续优化问题和离散优化问题中都表现出良好的效果，特别是因为其天然的实数编码特点适合于处理实优化问题。近年来成为国际上智能优化领域研究的热门，算法的收敛性，算法的结构和性能改善，包括参数分析、拓扑结构、粒子多样性保持、算法融合和性能比较等算法理论都已得到深入的研究。粒子群优化算法最早应用于非线性连续函数的优化和神经元网络的训练，后来也被用于解决约束优化问题、多目标优化问题、动态优化问题等。在非线性规划、数据分类、数据聚类、模式识别、流程规划、信号处理、电信 QoS 管理、生物系统建模、机器人控制、同步发电机辨识、车辆路径、新产品组合投入、广告优化、决策支持、约束布局优化以及仿真和系统辨识等方面，都表现出良好的应用前景。

4.2 粒子群算法的仿生学理论基础

生物学家认为，自然界中许多生物体，具有一定的群体行为，如为避免天敌、寻找食物、优化温度等环境参数，鸟类和鱼类有规律的调节它们的物理运动。通常群体行为可以由几条简单的规则进行建模。虽然每个个体具有非常简单的行为规则，但是群体行为却非常复杂。为探索自然界生物的群体行为，许多生物学家相继对鸟群或者鱼群的群体性行为进行了大量研究，并在计算机上构建其群体模型，进行了计算机模拟仿真。

Reynolds 和 Heppner，在 1987 年和 1990 年发表的论文中都关注了鸟群群体行动中蕴涵的美学。他们发现，鸟仅仅是追踪它有限数量的邻居，但最终的整体

结果是整个鸟群好像在一个中心的控制之下，即复杂的全局行为是由简单规则的相互作用引起的。例如，一群鸟在随机搜寻食物，如果这个区域里只有一块食物，那么找到食物的最简单有效的策略就是搜寻目前离食物最近的鸟的周围区域。他们认为，一种不可预知的鸟类社会行为中的群体动态学能够使大规模的鸟群在飞行中改变方向、散开或者重组队形。但在这些早期的研究中，他们把重点都放在了鸟群个体间距的处理上，也就是让鸟群中的个体之间保持最优的距离^[81-82]。

1975 年，生物社会学家 wilson E O 根据对鱼群的研究，在论文中提出：“由于食物资源具有不规则性和分散性，至少在理论上，鱼群的个体成员能够明显受益于群体中其他个体在寻找食物的过程中的发现和以前的经验，并且益处远远超过了个体之间的竞争所带来的消耗^[83]”。这说明，同种生物之间信息的社会共享能够带来益处，这是粒子群算法的基础。

Kennedy 和 Eberhart 对 Hepper 模仿鸟群的模型进行了修正，以使粒子能够飞向解空间，并在最好解处降落，从而得到了粒子群优化算法。

4.3 基本粒子群算法

4.3.1 基本粒子群算法原理及数学模型

粒子群优化算法中，以粒子（particle）或主体（agent）表示鸟，以粒子的位置向量表示搜索空间中问题的解。每个粒子都有自己的位置和速度（决定飞行的方向和距离），还有一个取决于被优化函数的适应值。各个粒子逐步逼近当前的最优粒子，在解空间中搜索。每次迭代的过程不是完全随机的，如果找到较好解，将会以此为依据来寻找下一个解。

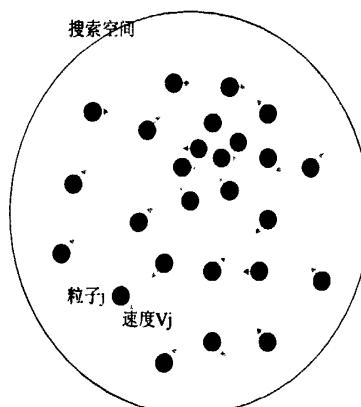


图 4-1 粒子群算法基本原理示意图

具体地，令粒子群优化算法随机初始化为一群粒子的位置向量，在每一次迭代中，粒子都会更新以下两个极值：一个就是粒子本身所找到的最好解，叫做个

体极值点（用 $pbest$ 表示其位置）；全局版粒子群优化算法中的另一个极值点是整个种群目前找到的最好解，称为全局极值点（用 $gbest$ 表示其位置），而局部版粒子群优化算法中的另一个极值点是用其中一部分作为粒子的邻居，所有邻居中的最好解称为局部极值点（用 $lbest$ 表示其位置）。在找到这两个最优解后，粒子根据如下的式（4-1）和式（4-2）来更新自己的速度和位置。

粒子 i 的信息可以用 D 维向量表示，位置表示为 $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})^T$ ，速度为 $V_i = (v_{i1}, v_{i2}, \dots, v_{iD})^T$ ，其他向量类似。则速度和位置更新方程为

$$v_{id}^{k+1} = v_{id}^k + c_1 rand_1^k (pbest_{id}^k - x_{id}^k) + c_2 rand_2^k (gbest_d^k - x_{id}^k) \quad (4-1)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \quad (4-2)$$

v_{id}^k 是粒子 i 在第 k 次迭代中第 d 维的速度；

c_1, c_2 是加速系数（或称学习因子），分别调节向全局最好粒子和个体最好粒子方向飞行的最大步长，若太小则粒子可能远离目标区域，若太大则会导致突然向目标区域飞去，或飞过目标区域。合适的 c_1, c_2 可以加快收敛且不易陷入局部最优，通常令 $c_1 = c_2 = 2$ 。 $rand_1, rand_2$ 是 $[0,1]$ 之间的随机数； x_{id}^k 是粒子 i 在第 k 次迭代中第 d 维的当前位置； $pbest_{id}$ 是粒子 i 在第 d 维的个体极值点的位置（即坐标）； $gbest_d$ 是整个群在第 d 维的全局极值点的位置。为防止粒子远离搜索空间，粒子的每一维速度 v_d 都会被钳位在 $[-v_{d\max}, +v_{d\max}]$ 之间， $v_{d\max}$ 太大，粒子将飞离最好解，太小将会陷入局部最优。假设将搜索空间的第 d 维定义为区间 $[-x_{d\max}, +x_{d\max}]$ ，则通常 $v_{d\max} = kx_{d\max}$ ， $0.1 \leq k \leq 1.0$ ，每一维都用相同的设置方法。

局部版粒子群优化算法是以群体内部分成员组成邻域进行粒子群优化计算。局部版组成邻域的方式有两种，一种是索引号相邻的粒子组成邻域，另一种是位置相邻的粒子组成邻域。局部版通过保持多个吸引子来避免早熟，假设每一个粒子在大小 l 的邻域内定义为一个集合

$$N_i = \{pbest_{i-l}, pbest_{i-l+1}, \dots, pbest_{i-1}, pbest_i, pbest_{i+1}, \dots, pbest_{i+l-1}, pbest_{i+l}\} \quad (4-3)$$

从 N_i 中选出最好的，将其位置作为 $lbest$ 代替公式中的 $gbest$ ，其他与全局版粒子群优化算法相同。实验表明，局部版比全局版收敛慢，但不容易陷入局部最优。

4.3.2 基本粒子群算法的具体实现

基本粒子群优化算法的流程如下：

第 1 步：初始化。初始搜索点的位置 x_i^0 及其速度 v_i^0 通常是在允许的范围内随机产生的，每个粒子的 $pbest$ 坐标设置为其当前位置，且计算出其相应的个体极值（即个体极值点的适应度值），而全局极值（即全局极值点的适应度值）就是个体极值中最好的，记录该最好值的粒子序号，并将 $gbest$ 设置为该最好粒子

的当前位置。

第 2 步：计算每个粒子的适应值。

第 3 步：对于每个粒子，将其适应值与所经历过的最好位置的适应值进行比较，如果更好，则将其作为粒子的个体历史最优值，用当前位置更新个体历史最好位置。

第 4 步：对每个粒子，将其历史最优适应值与群体内或邻域内所经历的最好位置的适应值进行比较，若更好，则将其作为当前的全局最好位置。

第 5 步：更新粒子。用式（4-1）和式（4-2）对每一个粒子的速度和位置进行更新。

第 6 步：检验是否符合结束条件。如果当前的迭代次数达到了预先设定的最大次数（或达到最小错误要求），则停止迭代，输出最优解，否则转到第二步。

一般将结束条件设定为一个足够好的适应值或达到一个预设的最大迭代代数。

4.3.3 基本粒子群算法速度更新方程机理分析

从粒子的速度更新方程可以看到，基本粒子群优化算法中，粒子的速度主要由前次迭代中自身的速度、自我认知部分、社会经验部分等三部分构成。前次迭代中自身的速度是粒子飞行中的惯性作用，是粒子能够进行飞行的基本保证；自我认知部分表示粒子飞行中考虑到自身经验，向自己曾经找到过的最好点靠近；社会经验部分表示粒子飞行中考虑到社会经验，向邻域中其他粒子学习，使粒子在飞行时向邻域内所有粒子曾经找到过的最好点靠近。由此可见，速度更新方程的第一项对应多样化（diversification）的特点，第二项、第三项对应于搜索过程的集中化（intensification）特点，以此实现多样化和集中化之间的均衡^[84]。

Kennedy 通过神经网络训练的实验研究了粒子飞行时的行为，在实验中将粒子的速度更新公式分别取以下四种情况^[85]：

- (1) 完全模型（Full model）：即按照原始速度更新方程进行速度更新。
- (2) 仅含个体极值模式（Cognition-only）：即速度更新时只考虑速度更新方程第 1 项和第 2 项。
- (3) 仅含全局极值模式（Social-only）：即速度更新时只考虑速度更新方程第 1 项和第 3 项。
- (4) 剔除自身影响模式（Selfless）：即速度更新时只考虑速度更新方程第 1 项和第 3 项，并且邻域不包括粒子本身。在只有社会经验的模型中，如果粒子自身取得的历史最好解就是邻域最好解，那么粒子还是会被自身取得的历史最好解所吸引，这容易引起效果上的混淆，“无私”情形可以彻底去掉自身认知的影

响，因此需要考虑剔除自身影响模式。

上述速度更新模型按照达到规定误差所需的迭代次数从少到多依次为：仅含全局极值模式<剔除自身影响模式<完全模型<仅含个体极值模式。由此可见，对于简单问题，仅含全局极值模式可以最快达到收敛，这是因为粒子间的社会信息的共享导致进化速度加快。而仅含个体极值模式收敛最慢，这是因为不同的粒子间缺乏信息交流，没有社会信息的共享，导致找到最优解的概率变小。

但是，需要说明的是，收敛速度不是优化效果的唯一评价指标。特别是对于复杂的问题，仅含全局极值模式中，粒子群体易过早收敛，从而陷于局优；仅含个体极值模式，易造成群体很难收敛，进化速度过慢。相对而言，完全模型是较好的选择。

4.3.4 粒子群优化算法的改进

为改善算法收敛性能，Shi 和 Eberhart 在 1998 年的论文中引入了惯性权重的概念^[86]，将速度更新方程修改为式（4-4）所示

$$v_{id}^{k+1} = \omega v_{id}^k + c_1 rand_1^k (pbest_{id}^k - x_{id}^k) + c_2 rand_2^k (gbest_d^k - x_{id}^k) \quad (4-4)$$

其中， ω 成为惯性权重，其大小决定了对粒子当前速度继承的多少，合适的选择可以使粒子具有均衡的探索能力（Exploration）和开发能力（Exploitation）。基本粒子群优化算法是惯性权重 $\omega=1$ 的特殊情况。

目前，对于粒子群优化算法的研究大多以带有惯性权重的粒子群优化算法为对象进行分析、扩展和修正^[87-96]，因此带有惯性权重的粒子群优化算法被称为标准粒子群优化算法。

4.4 网络参数基因的构建和确定

将网络中需要优化的连接权值和阈值组成一个 $W = 8M + 1$ 维向量，定义为网络的参数基因。对于 J 个粒子，构成 $J * W$ 维向量

$$X = \begin{bmatrix} \omega_{11,1} & \cdots & \omega_{M1,1} & \cdots & \omega_{16,1} & \cdots & \omega_{M6,1} & \omega_{1n,1} & \cdots & \omega_{Mn,1} & b_{1,1} & \cdots & b_{M,1} & b_{n,1} \\ \cdots & & & & & & & & & & & & & & & \\ \omega_{11,J} & \cdots & \omega_{M1,J} & \cdots & \omega_{16,J} & \cdots & \omega_{M6,J} & \omega_{1n,J} & \cdots & \omega_{Mn,J} & b_{1,J} & \cdots & b_{M,J} & b_{n,J} \end{bmatrix} \quad (4-5)$$

其中 J 是个整型参数。若 J 过小，陷入局优的可能性很大。若 J 过大，算法的优化能力很好，但计算时间大幅增加。并且当群体数目增长至一定水平时，再增长将不再有显著的作用。当 $J=1$ 的时候，粒子群优化算法变为基于个体搜索的技术，一旦陷入局优，将不可能跳出。

参数基因均为实数编码，粒子群算法天然的实数编码特点适合于处理该实优化问题。

根据粒子群优化算法的思想，参数基因的确定可以视为一个由 J 个粒子组成的群体在 W 维搜索空间中以一定的速度飞行，每个粒子在搜索时，考虑到了自己搜索到的历史最好点和群体内其它粒子的历史最好点，在此基础上进行位置的变化。

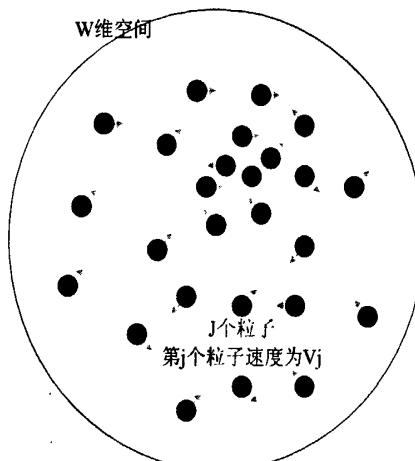


图 4-2 粒子群算法求解参数基因示意图

第 j 个粒子的位置表示为

$$X(j,:) = [\omega_{11}, \dots, \omega_{M1}, \dots, \omega_{16}, \dots, \omega_{M6}, \omega_{1n}, \dots, \omega_{Mn}, b_1, \dots, b_M, b_n] \quad (1 \leq j \leq J) \quad (4-6)$$

第 j 个粒子的速度表示为

$$v(j) = [v_{j1}, v_{j2}, \dots, v_{jD}] \quad (1 \leq j \leq J) \quad (4-7)$$

第 j 个粒子的速度更新方程为

$$v_j^{s+1} = \omega v_j^s + c_1 r_1 (p_{j1}^s - x_j^s) + c_2 r_2 (p_{g1}^s - x_j^s) \quad (1 \leq d \leq D) \quad (4-8)$$

其中， c_1 、 c_2 为加速系数，使粒子具有自我总结和向群体中优秀个体学习的能力，从而向群体内或邻域内最优点靠近。 c_1 、 c_2 一般相等，并且范围在 0 和 4 之间。本文取 $c_1 = c_2 = 2$ 。

r_1 、 r_2 为在 $[0,1]$ 内均匀分布的随机数。

p_{jd} 为粒子的个体极值， p_{gd} 为粒子的全局极值。

ω 为惯性权重，表征粒子对当前速度的继承特性，平衡算法的探索能力和开发能力。较大的惯性权重使粒子在自己原来的方向上具有更大的速度，从而在原方向上飞行更远，具有更好的探索能力；较小的惯性权重使粒子继承了较少的原方向的速度，从而飞行较近，具有更好的开发能力。

为同时保证初始阶段粒子的全局探测能力和寻优后期粒子的局部开发能力，本文使 ω 作指数曲线衰减：

$$\omega = \omega_e + (\omega_s - \omega_e) \times e^{-\frac{es}{s}} \quad (4-9)$$

其中 ω_s 、 ω_e 分别为 ω 的初始值和终值，本文分别取 0.9 和 0.2； c 为指数曲线的控制系数，可以通过 c 来调节指数曲线的衰减速度。

第 j 个粒子的位置更新方程为

$$x_{jd}^{s+1} = x_{jd}^s + v_{jd}^{s+1} \quad (1 \leq d \leq D) \quad (4-10)$$

需要说明的是，粒子的每一维速度 v 都会被钳位在 $[-v_{\max}, +v_{\max}]$ 之间，最大速度 v_{\max} 决定粒子在一次迭代中最大的移动距离。增大 v_{\max} ，有利于粒子找到更好的区域，避免局部收敛，探索能力增强，但是粒子容易飞过最好解。减小 v_{\max} ，开发能力增强，但是容易陷入局优，导致搜索的失败。

第五章 风电功率预测的模型实现及算例研究

5.1 算法实现

算法的具体实现步骤为

第1步：初始化参数。

第2步：归一化学习样本和测试样本。

第3步： I 只蚂蚁逐个选择结构基因，共形成 I 组结构基因。

第4步：根据第*i*组结构基因，构建神经网络，并逐个计算 K 个样本的网络输出。

第5步：在第*i*个神经网络中，计算第*s*次迭代第*j*个粒子的 K 个样本网络输出的均方差。

第6步：根据均方差更新第*s*次迭代第*j*个粒子个体极值。

第7步： $j \leftarrow j+1$ 跳转至第5步，直至 J 个粒子下网络输出的均方差全部计算完成。

第8步：根据均方差更新第*s*次迭代的全局极值。

第9步：更新 J 个粒子的速度 $v(j)$ 、位置 $X(j,:)$ 。

第10步： $s \leftarrow s+1$ 跳转至第5步，直至 S 次迭代全部计算完成。

第11步：判断粒子群算法是否收敛。若收敛，第*i*组结构基因下的误差取收敛误差；否则取*s*次迭代中的最大误差。

第12步： $i \leftarrow i+1$ 跳转至第5步，直至 I 次迭代全部计算完成。

第13步：判断蚁群算法是否收敛。若蚁群算法和粒子群算法均收敛，根据 $G(l,:)$ 和 $X(l,:)$ 构建神经网络并利用测试样本测试神经网络误差；否则根据 $D(i)$ 更新信息素浓度、能见度因数、状态转移概率，进行第*t+1*次迭代。

程序框图如图5-1所示。

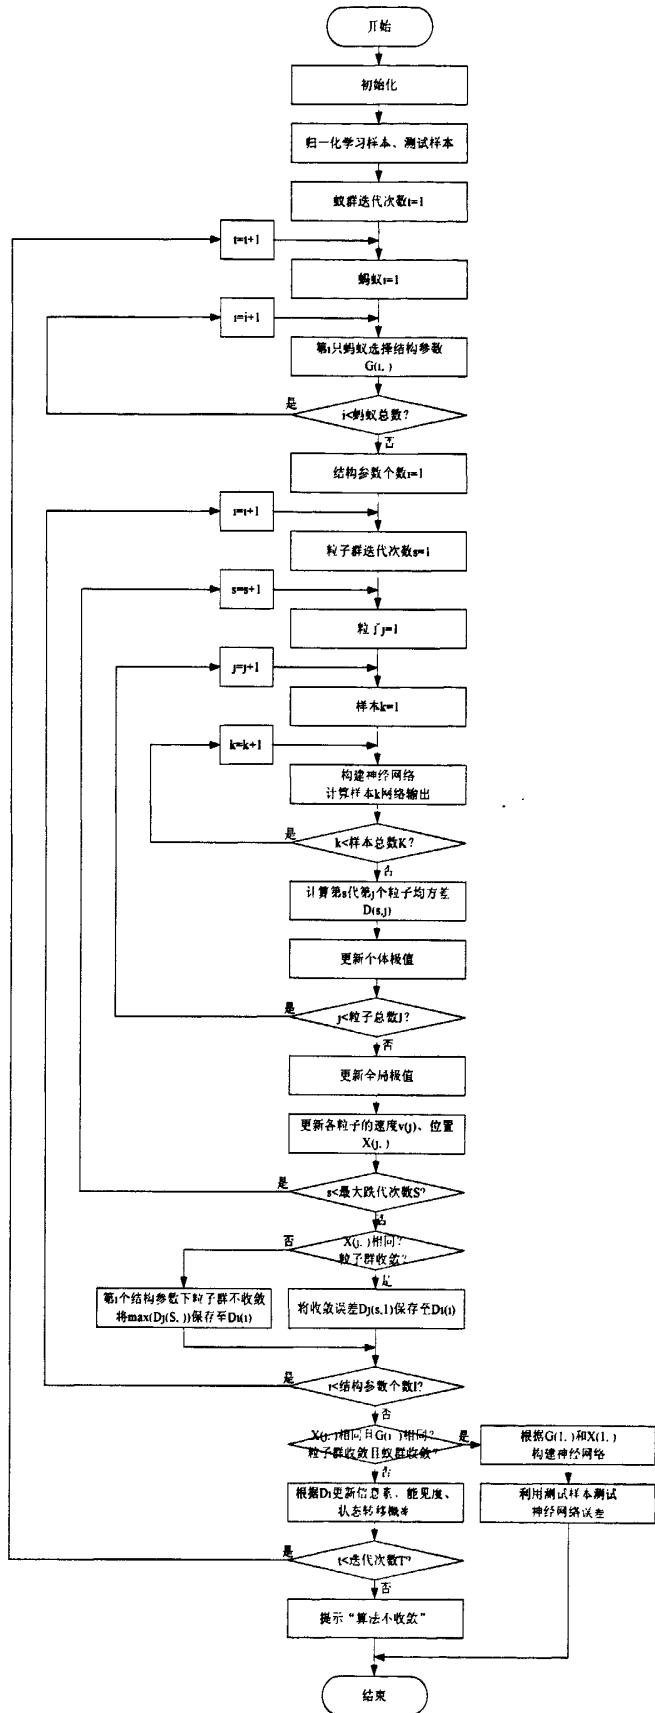


图 5-1 程序框图

5.2 算例

算法中参数的初始值如表 5-1 所示。

表 5-1 算法中参数的初始值

蚁群算法迭代次数 T	500
蚂蚁总数 I	16
信息素残留系数 ρ	0.5
释放的信息素总量 Q	10
信息素浓度相对重要性参数 α	2
能见度因数相对重要性参数 β	2
粒子群算法迭代次数 S	100
粒子总数 J	20
惯性权重初值 ω_s	0.9
惯性权重终值 ω_e	0.2
粒子群加速系数 C_1, C_2	0.8
误差精度 err	0.00%
粒子速度最大值 v_{\max}	1
粒子速度最小值 v_{\min}	-1
隐含层神经元最大个数 M	50

测试样本分别为 2008 年 1 月 1 日、4 月 1 日、7 月 1 日、10 月 1 日的整点风电功率输出值，学习样本采用了预测时点在 2007 年同时点前后各 15 天的数值天气预报数据和风电场输出功率数据，如表 5-2~表 5-5 所示。

表 5-2 2008 年 1 月 1 日功率预测结果

预测时间	实际功率 标幺值	07年 12月15日- 1月15日 学习样本 BP 网络	07年 12月15日- 1月15日 BP 网络	07年 12月15日- 1月15日 学习样本 本文	07年 12月15日- 1月15日 预测结果 本文 预测功率 绝对误差
		预测功率	绝对误差	预测功率	绝对误差
0	0.920	0.771	-0.15	1.208	0.29
1	0.934	0.783	-0.15	1.093	0.16
2	0.832	0.793	-0.04	1.007	0.17
3	0.724	0.583	-0.14	0.812	0.09
4	0.628	0.481	-0.15	0.602	-0.03
5	0.535	0.547	0.01	0.378	-0.16
6	0.435	0.236	-0.20	0.474	0.04
7	0.481	0.311	-0.17	0.498	0.02
8	0.557	0.526	-0.03	0.671	0.11
9	0.788	0.939	0.15	0.755	-0.03
10	0.515	0.457	-0.06	0.357	-0.16
11	0.276	0.105	-0.17	0.263	-0.01
12	0.806	0.626	-0.18	0.803	0.00
13	0.848	0.789	-0.06	0.892	0.04
14	0.424	0.200	-0.22	0.602	0.18
15	0.486	0.530	0.04	0.472	-0.01
16	0.617	0.929	0.31	0.555	-0.06
17	0.682	0.831	0.15	0.482	-0.20
18	0.788	0.773	-0.01	0.796	0.01
19	0.882	1.103	0.22	0.889	0.01
20	0.995	0.825	-0.17	1.158	0.16
21	0.999	0.982	-0.02	0.952	-0.05
22	0.982	1.135	0.15	0.921	-0.06
23	1.000	0.805	-0.20	0.871	-0.13

图 5-2 为 1 月 1 日风电功率预测曲线与风电功率实际曲线图。BP 神经网络预测结果的均方根误差为 15.3, 本文预测结果的均方根误差为 11.9%。

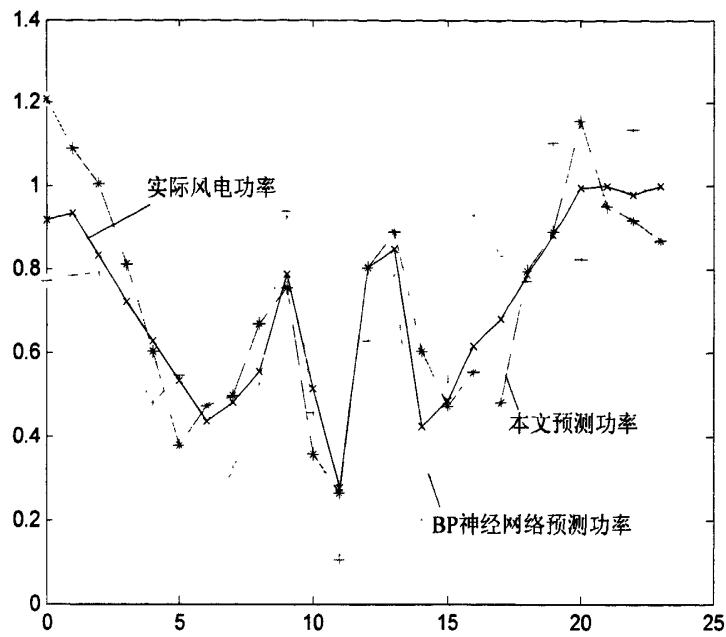


图 5-2 1月1日风电功率曲线图

表 5-3 2008 年 4 月 1 日功率预测结果

预测时间	实际功率 标幺值	07 年 3 月 15 日- 4 月 15 日 学习样本 BP 网络 预测功率	07 年 3 月 15 日- 4 月 15 日 BP 网络 预测结果 绝对误差	07 年 3 月 15 日- 4 月 15 日 学习样本 本文 预测功率	07 年 3 月 15 日- 4 月 15 日 本文 预测结果 绝对误差
0	0.420	0.297	-0.29	0.361	-0.14
1	0.734	0.851	0.16	0.647	-0.12
2	0.532	0.601	0.13	0.526	-0.01
3	0.724	0.894	0.24	0.809	0.12
4	0.628	0.645	0.03	0.751	0.20
5	0.535	0.624	0.17	0.465	-0.13
6	0.435	0.507	0.17	0.415	-0.05
7	0.481	0.551	0.14	0.405	-0.16
8	0.357	0.462	0.30	0.314	-0.12
9	0.488	0.551	0.13	0.475	-0.03
10	0.315	0.300	-0.05	0.345	0.10
11	0.476	0.502	0.05	0.469	-0.02
12	0.306	0.245	-0.20	0.299	-0.02
13	0.448	0.388	-0.13	0.413	-0.08
14	0.624	0.556	-0.11	0.580	-0.07
15	0.486	0.489	0.01	0.549	0.13
16	0.617	0.611	-0.01	0.445	-0.28
17	0.682	0.703	0.03	0.577	-0.15
18	0.788	0.722	-0.08	0.808	0.03
19	0.882	0.916	0.04	0.729	-0.17
20	0.795	0.740	-0.07	0.804	0.01
21	0.899	0.844	-0.06	0.914	0.02
22	0.682	0.588	-0.14	0.689	0.01
23	0.900	0.766	-0.15	0.980	0.09

图 5-3 为 4 月 1 日风电功率预测曲线与风电功率实际曲线图。BP 神经网络预测结果的均方根误差为 14.4，本文预测结果的均方根误差为 11.6%。

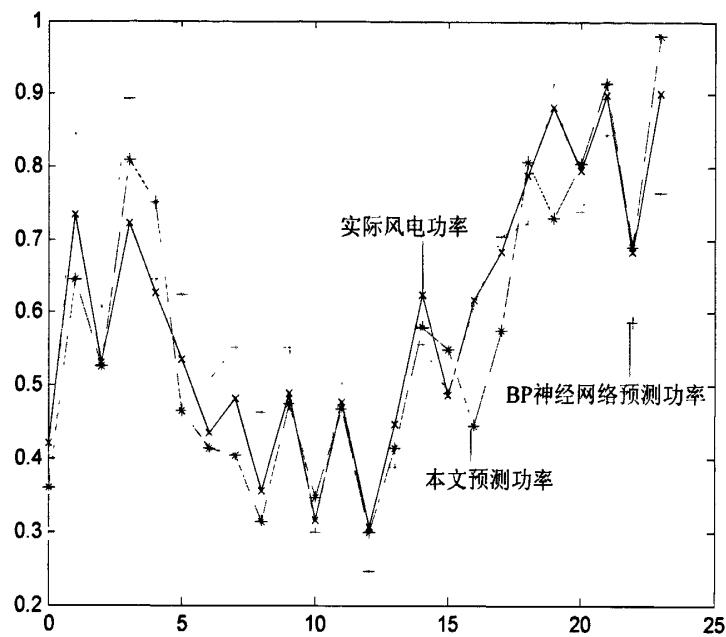


图 5-3 4月1日风电功率曲线图

表 5-4 2008 年 7 月 1 日功率预测结果

预测时间	实际功率 标幺值	07年	07年	07年	07年
		6月15日- 7月15日 学习样本	6月15日- 7月15日 BP网络	6月15日- 7月15日 学习样本	6月15日- 7月15日 本文
	BP网络 预测功率	预测结果 绝对误差	本文 预测功率	预测结果 绝对误差	
0	0.920	0.955	0.04	0.911	-0.01
1	0.934	0.772	-0.17	0.794	-0.15
2	0.832	0.918	0.10	0.728	-0.12
3	0.724	0.907	0.25	0.735	0.01
4	0.628	0.658	0.05	0.722	0.15
5	0.535	0.485	-0.09	0.560	0.05
6	0.435	0.453	0.04	0.460	0.06
7	0.481	0.540	0.12	0.469	-0.03
8	0.357	0.374	0.05	0.344	-0.04
9	0.388	0.347	-0.11	0.364	-0.06
10	0.315	0.298	-0.05	0.331	0.05
11	0.276	0.288	0.04	0.275	-0.01
12	0.306	0.308	0.01	0.318	0.04
13	0.348	0.358	0.03	0.324	-0.07
14	0.424	0.503	0.19	0.466	0.10
15	0.486	0.524	0.08	0.451	-0.07
16	0.617	0.600	-0.03	0.744	0.21
17	0.682	0.623	-0.09	0.625	-0.08
18	0.788	0.601	-0.24	0.764	-0.03
19	0.882	1.113	0.26	0.705	-0.20
20	0.695	0.704	0.01	0.553	-0.21
21	0.599	0.878	0.46	0.492	-0.18
22	0.882	0.832	-0.06	0.921	0.04
23	0.500	0.454	-0.09	0.336	-0.33

图 5-4 为 7 月 1 日风电功率预测曲线与风电功率实际曲线图。BP 神经网络预测结果的均方根误差为 15.2, 本文预测结果的均方根误差为 12.4%。

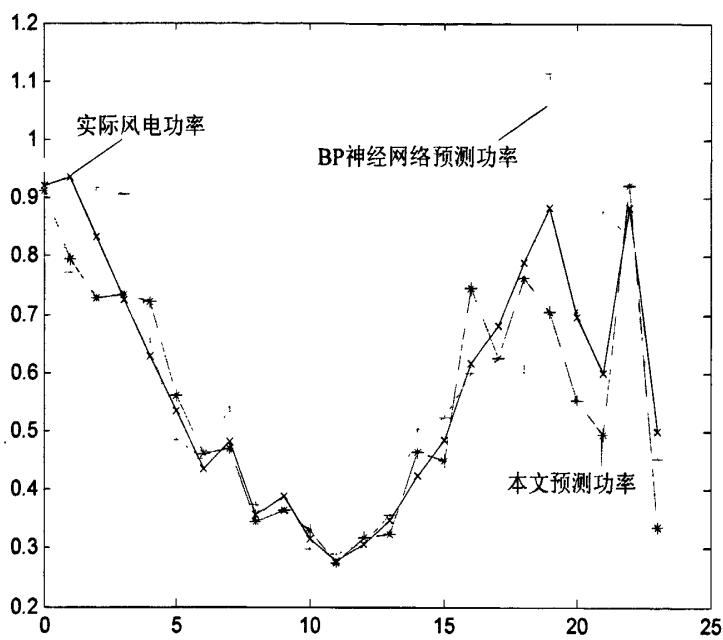


图 5-4 7月1日风电功率曲线图

表 5-5 2008 年 10 月 1 日功率预测结果

预测时间	实际功率 标幺值	07 年 9 月 15 日- 10 月 15 日 学习样本 BP 网络 预测功率	07 年 9 月 15 日- 10 月 15 日 BP 网络 预测结果	07 年 9 月 15 日- 10 月 15 日 学习样本 本文 预测功率	07 年 9 月 15 日- 10 月 15 日 本文 预测结果 绝对误差
		绝对误差	预测功率	绝对误差	
0	0.520	0.252	-0.52	0.602	0.16
1	0.734	0.594	-0.19	0.818	0.11
2	0.632	0.749	0.19	0.624	-0.01
3	0.824	0.836	0.01	0.804	-0.02
4	0.628	0.623	-0.01	0.642	0.02
5	0.535	0.546	0.02	0.509	-0.05
6	0.435	0.454	0.04	0.439	0.01
7	0.481	0.585	0.21	0.507	0.05
8	0.357	0.314	-0.12	0.331	-0.07
9	0.488	0.456	-0.07	0.497	0.02
10	0.315	0.283	-0.10	0.326	0.04
11	0.476	0.507	0.06	0.458	-0.04
12	0.506	0.484	-0.04	0.512	0.01
13	0.348	0.396	0.14	0.399	0.15
14	0.694	0.664	-0.04	0.682	-0.02
15	0.486	0.463	-0.05	0.418	-0.14
16	0.617	0.813	0.32	0.497	-0.20
17	0.482	0.464	-0.04	0.411	-0.15
18	0.788	0.752	-0.05	0.900	0.14
19	0.682	0.644	-0.06	0.753	0.10
20	0.895	0.915	0.02	1.023	0.14
21	0.699	0.639	-0.09	0.908	0.30
22	0.882	0.808	-0.08	0.844	-0.04
23	0.600	0.589	-0.02	0.620	0.03

图 5-5 为 10 月 1 日风电功率预测曲线与风电功率实际曲线图。BP 神经网络预测结果的均方根误差为 15.4, 本文预测结果的均方根误差为 11.1%。

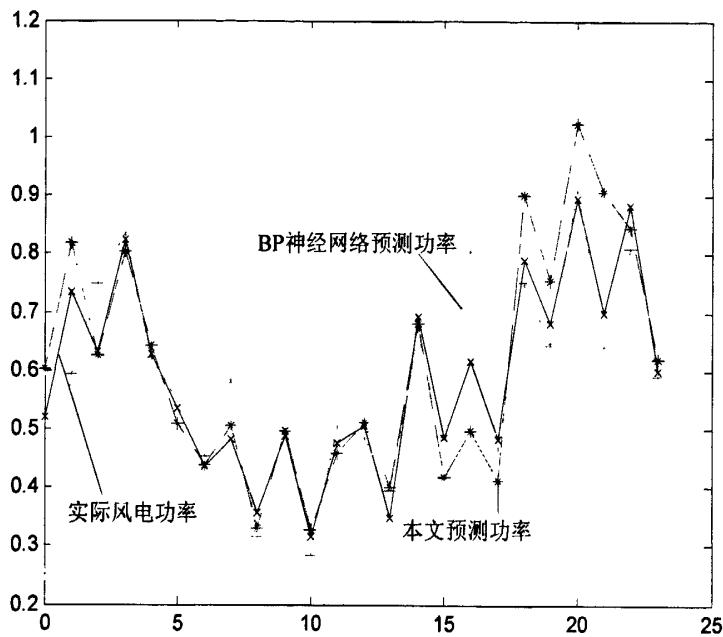


图 5-5 10月1日风电功率曲线图

上述对不同季节的典型日进行风电功率预测结果表明：基于蚁群和粒子群算法优化的神经网络，能够较好的预测风电场输出功率，预测曲线与实测曲线变化规律基本一致，预测结果的均方根误差总体比较稳定，与 BP 网络预测 15.1% 的均方跟误差相比，本文误差值在 11.8%，有更好的预测结果。

为验证学习样本的充分性，本文再次以预测时点在 2005 年至 2007 年同时点前后各 10 天的数值天气预报数据和风电场输出功率数据为学习样本，测试 2008 年 1 月 1 日、4 月 1 日、7 月 1 日、10 月 1 日 24 时点的风电功率输出，如表 5-6~表 5-9 所示。

表 5-6 2008 年 1 月 1 日功率预测结果

预测时间	实际功率 标幺值	05 年-07 年 12 月 20 日- 1 月 10 日 学习样本 BP 网络 预测功率	05 年-07 年 12 月 20 日- 1 月 10 日 BP 网络 预测结果	05 年-07 年 12 月 20 日- 1 月 10 日 学习样本 本文 预测功率	05 年-07 年 12 月 20 日- 1 月 10 日 本文 预测结果 绝对误差
		绝对误差	预测功率	预测功率	绝对误差
0	0.920	0.965	0.05	1.140	0.22
1	0.934	0.917	-0.02	1.103	0.17
2	0.832	0.928	0.10	0.948	0.12
3	0.724	0.702	-0.02	0.869	0.15
4	0.628	0.485	-0.14	0.699	0.07
5	0.535	0.542	0.01	0.500	-0.03
6	0.435	0.264	-0.17	0.555	0.12
7	0.481	0.366	-0.11	0.596	0.12
8	0.557	0.617	0.06	0.637	0.08
9	0.788	0.979	0.19	0.727	-0.06
10	0.515	0.427	-0.09	0.503	-0.01
11	0.276	0.124	-0.15	0.369	0.09
12	0.806	0.677	-0.13	0.920	0.11
13	0.848	0.850	0.00	0.915	0.07
14	0.424	0.337	-0.09	0.634	0.21
15	0.486	0.599	0.11	0.496	0.01
16	0.617	0.969	0.35	0.471	-0.15
17	0.682	0.770	0.09	0.544	-0.14
18	0.788	0.783	0.00	0.802	0.01
19	0.882	1.169	0.29	0.806	-0.08
20	0.995	0.967	-0.03	1.178	0.18
21	0.999	1.009	0.01	1.014	0.01
22	0.982	1.186	0.20	0.921	-0.06
23	1.000	0.769	-0.23	1.058	0.06

图 5-6 为 1 月 1 日风电功率预测曲线与风电功率实际曲线图。BP 神经网络预测结果的均方根误差为 14.3，本文预测结果的均方根误差为 11.4%。

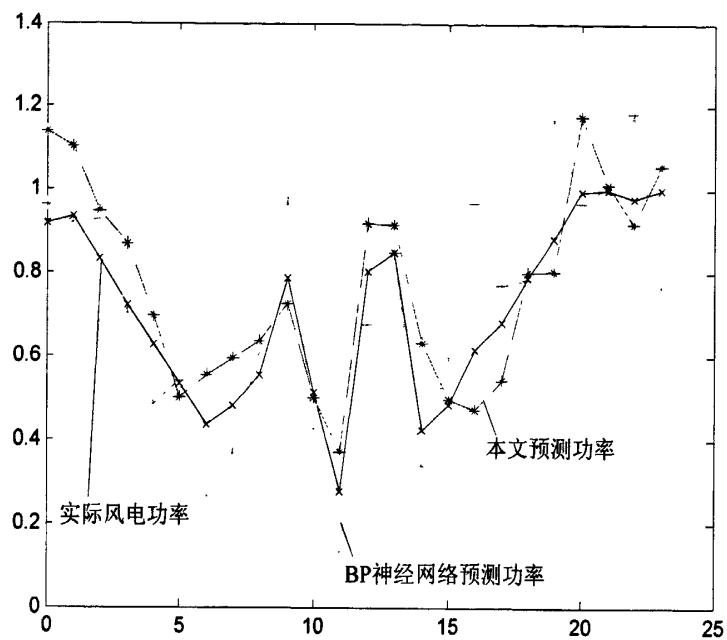


图 5-6 1月1日风电功率曲线图

表 5-7 2008 年 4 月 1 日功率预测结果

预测时间	实际功率 标幺值	05 年-07 年	05 年-07 年	05 年-07 年	05 年-07 年
		3 月 20 日- 4 月 10 日 学习样本	4 月 10 日 BP 网络	4 月 10 日 学习样本	4 月 10 日 本文
0	0.420	0.263	-0.16	0.466	0.05
1	0.734	0.930	0.20	0.547	-0.19
2	0.532	0.766	0.23	0.466	-0.07
3	0.724	1.090	0.37	0.663	-0.06
4	0.628	0.832	0.20	0.736	0.11
5	0.535	0.648	0.11	0.388	-0.15
6	0.435	0.639	0.20	0.353	-0.08
7	0.481	0.574	0.09	0.345	-0.14
8	0.357	0.605	0.25	0.224	-0.13
9	0.488	0.713	0.23	0.421	-0.07
10	0.315	0.345	0.03	0.358	0.04
11	0.476	0.533	0.06	0.447	-0.03
12	0.306	0.247	-0.06	0.352	0.05
13	0.448	0.475	0.03	0.465	0.02
14	0.624	0.566	-0.06	0.638	0.01
15	0.486	0.679	0.19	0.547	0.06
16	0.617	0.609	-0.01	0.451	-0.17
17	0.682	0.754	0.07	0.559	-0.12
18	0.788	0.868	0.08	0.865	0.08
19	0.882	0.923	0.04	0.701	-0.18
20	0.795	0.862	0.07	0.851	0.06
21	0.899	0.962	0.06	0.962	0.06
22	0.682	0.712	0.03	0.770	0.09
23	0.900	0.858	-0.04	1.095	0.19

图 5-7 为 4 月 1 日风电功率预测曲线与风电功率实际曲线图。BP 神经网络预测结果的均方根误差为 15.0, 本文预测结果的均方根误差为 10.6%。

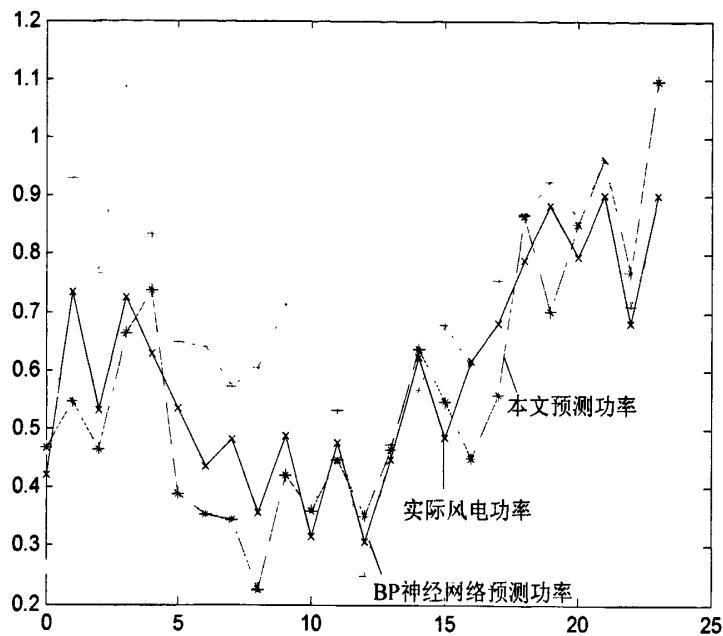


图 5-7 4月 1 日风电功率曲线图

表 5-8 2008 年 7 月 1 日功率预测结果

预测时间	实际功率 标幺值	05 年-07 年 6 月 20 日- 7 月 10 日 学习样本 BP 网络 预测功率	05 年-07 年 6 月 20 日- 7 月 10 日 BP 网络 预测结果	05 年-07 年 6 月 20 日- 7 月 10 日 学习样本 本文 预测功率	05 年-07 年 6 月 20 日- 7 月 10 日 本文 预测结果 绝对误差
		预测功率	绝对误差	预测功率	绝对误差
0	0.920	1.103	0.18	0.885	-0.04
1	0.934	0.718	-0.22	0.915	-0.02
2	0.832	0.885	0.05	0.664	-0.17
3	0.724	1.029	0.31	0.597	-0.13
4	0.628	0.797	0.17	0.700	0.07
5	0.535	0.516	-0.02	0.597	0.06
6	0.435	0.536	0.10	0.447	0.01
7	0.481	0.617	0.14	0.425	-0.06
8	0.357	0.469	0.11	0.330	-0.03
9	0.388	0.404	0.02	0.394	0.01
10	0.315	0.414	0.10	0.344	0.03
11	0.276	0.360	0.08	0.266	-0.01
12	0.306	0.445	0.14	0.316	0.01
13	0.348	0.494	0.15	0.317	-0.03
14	0.424	0.653	0.23	0.407	-0.02
15	0.486	0.649	0.16	0.422	-0.06
16	0.617	0.775	0.16	0.757	0.14
17	0.682	0.670	-0.01	0.669	-0.01
18	0.788	0.661	-0.13	0.904	0.12
19	0.882	1.078	0.20	0.533	-0.35
20	0.695	0.649	-0.05	0.546	-0.15
21	0.599	0.895	0.30	0.284	-0.32
22	0.882	0.981	0.10	0.959	0.08
23	0.500	0.434	-0.07	0.370	-0.13

图 5-8 为 7 月 1 日风电功率预测曲线与风电功率实际曲线图。BP 神经网络预测结果的均方根误差为 15.4%，本文预测结果的均方根误差为 12.3%。

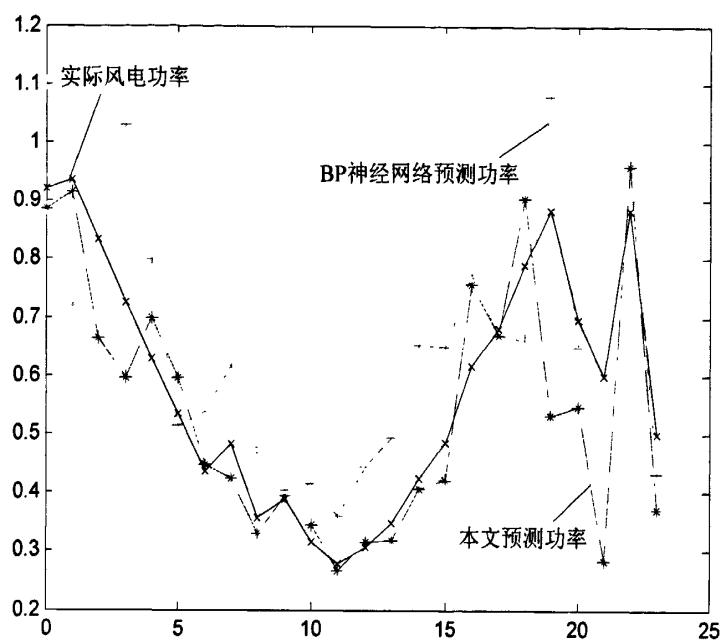


图 5-8 7月1日风电功率曲线图

表 5-9 2008 年 10 月 1 日功率预测结果

预测时间	实际功率 标幺值	05 年-07 年 9 月 20 日- 10 月 10 日 学习样本 BP 网络 预测功率	05 年-07 年 9 月 20 日- 10 月 10 日 BP 网络 预测结果	05 年-07 年 9 月 20 日- 10 月 10 日 学习样本 本文 预测功率	05 年-07 年 9 月 20 日- 10 月 10 日 本文 预测结果 绝对误差
		BP 网络 预测功率	绝对误差	预测功率	绝对误差
0	0.520	0.157	-0.36	0.806	0.29
1	0.734	0.597	-0.14	0.914	0.18
2	0.632	0.875	0.24	0.576	-0.06
3	0.824	0.851	0.03	0.829	0.01
4	0.628	0.727	0.10	0.734	0.11
5	0.535	0.603	0.07	0.587	0.05
6	0.435	0.548	0.11	0.498	0.06
7	0.481	0.769	0.29	0.491	0.01
8	0.357	0.287	-0.07	0.410	0.05
9	0.488	0.524	0.04	0.603	0.12
10	0.315	0.303	-0.01	0.380	0.07
11	0.476	0.557	0.08	0.487	0.01
12	0.506	0.538	0.03	0.589	0.08
13	0.348	0.527	0.18	0.378	0.03
14	0.694	0.688	-0.01	0.771	0.08
15	0.486	0.457	-0.03	0.550	0.06
16	0.617	0.911	0.29	0.467	-0.15
17	0.482	0.460	-0.02	0.543	0.06
18	0.788	0.896	0.11	0.933	0.14
19	0.682	0.766	0.08	0.828	0.15
20	0.895	1.132	0.24	1.018	0.12
21	0.699	0.860	0.16	0.911	0.21
22	0.882	0.742	-0.14	0.951	0.07
23	0.600	0.606	0.01	0.623	0.02

图 5-9 为 10 月 1 日风电功率预测曲线与风电功率实际曲线图。BP 神经网络预测结果的均方根误差为 15.5%，本文预测结果的均方根误差为 11.3%。

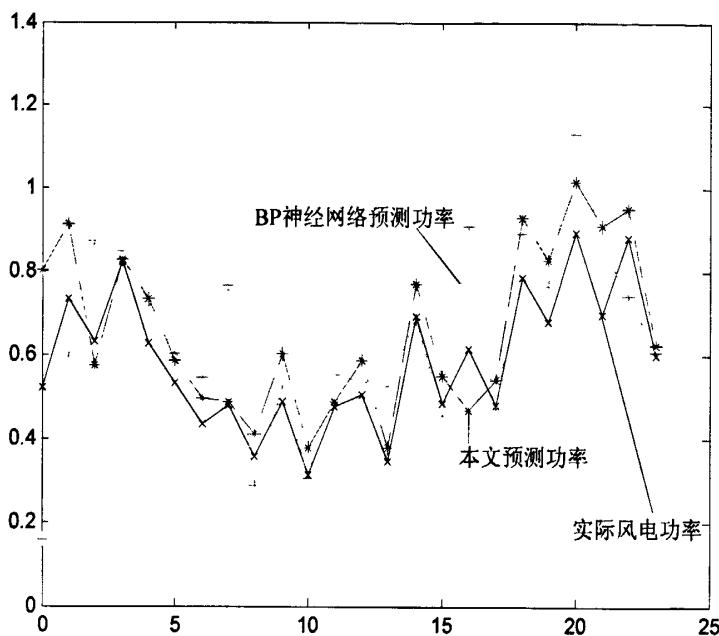


图 5-9 10月1日风电功率曲线图

上述以预测时点在 2005 年至 2007 年同时点前后各 10 天的数值天气预报数据和风电场输出功率数据为学习样本的均方根误差为 11.4%，与以预测时点在 2007 年同时点前后各 15 天的数值天气预报数据和风电场输出功率数据为学习样本的预测相比，预测误差稳定，因此学习样本具备充分性。

第六章 结论

我国的风能储量、可开发的装机容量具有商业化、规模化发展的潜力，近几年我国风电一直保持着 50%左右的年增长速度。风电能源可以为我国解决能源供应、二氧化碳排放等问题，实现可持续发展，做出重大的贡献。而风电技术作为一个新兴领域，需要大量深入的研究，风电功率预测即是其中一项重要内容。

1、根据风电功率预测的特点，构建了多层前馈神经网络结构，并提出引入智能优化方法优化网络隐含层节点个数、网络的权值和阈值的方法，来改进现有的人工神经的风电功率预测，提高了预测的精度。

2、针对现有神经网络预测方法中，隐含层节点个数不能自动优化选择，需要人工逐一筛选的现状，提出以二进制编码表征隐含层节点的有无。在深入分析现有的蚁群算法改进方法的基础上，对蚁群算法加以改进，重新定义二进制下的信息素浓度和能见度因数的更新机制，从而利用蚁群算法更加科学的确定改进人工神经网络隐含层节点数。

3、现有神经网络预测方法采用 BP 神经网络，存在着固有的局限性，如学习率与稳定性之间存在固有的矛盾、学习过程受初始点影响很大等等。针对这一情形，提出将神经网络的权值和阈值组成矩阵，定义为粒子群算法中粒子的位置向量，并对速度更新的惯性权重赋以指数衰减，提高了全局探测能力和局部寻优能力，提高了粒子群优化环节的计算速度。

4、完成了算法的具体实现。通过实际算例测试，证明了基于蚁群和粒子群算法的风电功率预测策略与传统神经网络预测风电功率方法相比，预测精度得到进一步提高。

在研究过程中，本文提出的方法需要继续如下后续工作：

(1) 优化网络隐含层节点个数、网络的权值和阈值过程中，改进的蚁群算法和粒子群算法的参数的选择，尚没有充分理论依据作指导，需要从大量的试验中获取足够的经验来取得。

(2) 在前馈神经网络中引入改进的蚁群算法和粒子群算法等智能优化算法后，算法的复杂性造成算法的收敛速度仍有待提高，需要在后续研究中进一步完善。

参考文献

- [1] 杨秀媛, 梁贵书. 风力发电的发展及其市场前景[J]. 电网技术, 27 (7) :78-79.
- [2] Kaimal J C. Horizontal velocity spectra in an unstable surface layer [J]. Journal of the Atmospheric Sciences, 1978, 35 (1) :18-24.
- [3] Kitagawa T, Nomura T. A wavelet-based method to generate artificial wind fluctuation data[J]. Journal of Wind Engineering and Industrial Aerodynamics, 2003, 91 (7) :943-964 .
- [4] Singh S, Bhatti T S, Kothari D P. A review of wind-resource-assessment technology[J]. Journal of Energy Engineering, 2006, 132:8-14.
- [5] 雷亚洲, 王伟胜, 印永华, 戴慧珠. 风电对电力系统运行的价值分析 [J]. 电网技术, 26 (5) :10-14.
- [6] 王晓蓉, 王伟胜, 戴慧珠. 我国风力发电现状和展望[J]. 中国电力, 2004, 37 (1) :81-84.
- [7] Dobesch H, Chen Shenbin, Tran H V, et al. The wind energy potential in Jilin Province, China[J]. Journal of Natural Resources, 2005, 20 (5) :684-689.
- [8] Ackermann T , Soder L . An overview of wind energy-status 2002[J] . Renewable and Sustainable Energy Reviews , 2002 , 6 (1-2) :67-128.
- [9] 王成山, 孙玮, 王兴刚. 含大型风电场的电力系统最大输电能力计算 [J]. 电力系统自动化, 2007, 31 (2) :17-31.
- [10] 王成山, 王兴刚, 孙玮. 含大型风电场的电力系统概率最大输电能力快速计算[J]. 中国电机工程学报, 2008, 28 (10) :56-62.
- [11] 王成山, 郑海峰, 谢莹华, 等. 计及分布式发电的配电系统随机潮流计算[J]. 电力系统自动化, 2005, 29 (24) :39-44.
- [12] Wang Chengshan, Maliki Guindo. Three-phase unbalanced radial distribution power flow analysis with wind farms considered. Automation of Electric Power Systems, 2006, 30 (16) :21-26.
- [13] 王守相, 江兴月, 王成山. 含风力发电机组的配电网潮流计算. 电网

- 技术, 2006, 30 (21) :42-61.
- [14] Amora M A B, Bezerra U H. Assessment of the effects of wind farms connected in a power system[C]. Power Tech Proceedings, IEEE Porto, 2001.
 - [15] Ha L T, Kumar T. Investigation of power loss and voltage stability limits for large wind farm connections to a sub-transmission network[C]. IEEE Power Engineering Society General Meeting, 2004.
 - [16] Chai C, Lee W J, etc. System impact study for the interconnection of wind generation and utility system[J]. IEEE Transactions on Industry Applications, 2005, 41 (1) :163-168.
 - [17] Piwko R, Miller N, etc. Integrating large wind farms into weak power grids with long transmission lines[C]. Transmission and Distribution Conference and Exhibition:Asia and Pacific, IEEE/PES, 2005.
 - [18] 迟永宁, 刘燕华, 王伟胜, 等. 风电接入对电力系统的影响[J]. 电网技术, 2007, 31 (3) ; 77-81.
 - [19] Dai Huizhu, Wang Weisheng, Chi Yongnin. Recent wind power integration study in china[J]. Power system Technology, 31 (20) :16-23.
 - [20] Gredes G, Santjer F. Power quality of wind turbines and their interaction with the grid[C]. Proceedings of 1994 European Wind Energy Conference, Thessaloniki, Greece, 1994:1112-1115.
 - [21] Thiringer T. Power quality measurements performed on a low-voltage grid equipped with two wind turbines[J]. IEEE Transactions on Energy Conversion, 1996, 11 (3) :601-606.
 - [22] Ladakakos D P, Ioannides G M, Koulouvari I M. Assessment of wind turbines impact on the power quality of autonomous weak grids[C]. Proceedings of 8th International Conference on Harmonics and Quality of Power, Athens, Greece, 1998:900-905.
 - [23] Balcell J, Gonzalez D. Harmonics due to resonance in a wind power plant[C]. Proceedings of the 8th International Conference on Harmonics and Quality of Power system. Greece:[s.n.], 1998 (2) :896-899.
 - [24] Dokopoulos S P, Dimonlias S C, Manousaridis M I et al. Improvement of power quality in a grid with wind turbines using inductive storage[J]. Wind

- Engineering, 1999, 23 (4) :215-224.
- [25] Achermann T, Garner K, Gardiner A. Embedded wind generation in weak grids-economic optimization and power quality simulation [J]. Renewable Energy, 1999, 18 (2) :205-221.
- [26] Thiringer T, Dahlberg J. Periodic pulsations from a three-bladed wind turbine[J]. IEEE Transactions on Energy Conversion, 2001, 16 (2) :128-133.
- [27] Thiringer T, Petru T, Liljegren C. Power quality impact of a sea located hybrid wind park[J]. IEEE Transactions on Energy Conversion, 2001, 16 (2) :123-127.
- [28] Chen Z, Spooner E. Grid power quality with variable speed wind turbines[J]. IEEE Transactions on Energy Conversion, 2001, 16 (2) :148-154.
- [29] Sorensen P, Hansen AD, Rosas d PAC. Wind models for simulation of power fluctuations from wind farms[J]. Journal of Wind Engineering and Industrial Aerodynamics, 2002, 90 (12-15) :1381-1402.
- [30] 席晶, 李海燕, 孔庆东. 风电场投切对地区电网电压的影响[J]. 电网技术, 32 (10) :58-62.
- [31] Papadopoulos P M, Papathanassiou A S, Tentaerakis T S et al. Investigation of the flicker emission by grid connected wind turbines[C]. Proceedings of the 8th International Conference on Harmonics and Quality of Power, Athens, Greece, 1998:1152-1157.
- [32] Moreno V C, Duarte A H, Garcia U J. Propagation of flicker in electric power networks due to wind energy conversions systems[J]. IEEE Transactions on Energy Conversion, 2002, 17 (2) :267-272.
- [33] Larsson A. Flicker emission of wind turbines during continuous operation[J]. IEEE Transactions on Energy Conversion, 2002, 17 (1) :I14-I18.
- [34] Larsson A. Flicker emission of wind turbines caused by switching operation[J]. IEEE Transactions on Energy Conversion, 2002, 17 (1) :I19-I23.
- [35] 孙涛, 王伟胜, 戴慧珠, 杨以涵. 风力发电引起的电压波动和闪变[J]. 电

- 网技术 27 (12) :62-70.
- [36] Kaldellis J K, Skulatos D, Kladuchos A. Wind energy penetration in electrical grids of small and medium size islands [C]. Proceedings of the 3th International Conference on Environmental Science and Technology. Lesvos, Grece:[s.n.], 1993:511.
 - [37] Kaldellis J K. Evaluating the maximum wind energy penetration limit for weak electrical grids[C] . 2001 European Wind Energy Conference. Copenhagen, Denmark:[s.n.], 2001.
 - [38] 雷亚洲, 王伟胜, 印永华, 等. 一种静态安全约束下确定电力系统风电准入功率极限的优化方法[J]. 中国电机工程学报, 2001, 21(6):25-28.
 - [39] 申洪, 梁均, 戴慧珠. 基于电力系统暂态稳定分析的风电场穿透功率极限计算[J]. 电网技术, 2002, 26 (8) :8-11
 - [40] 雷亚洲, 王伟胜, 印永华, 等. 基于机会约束规划的风电穿透功率极限计算[J]. 中国电机工程学报, 2002, 22 (5) :32-35.
 - [41] Yang J M, Wu J, Dong P. Maximal wind energy caption control with passivity based control[J]. Acta Energiae Solaris Sinica , 2003 , 24 (5) :724-728.
 - [42] 郑国强, 鲍海, 陈树勇. 基于近似线性规划的风电场穿透功率极限优化的改进算法[J]. 中国电机工程学报, 2004, 24 (10) :68-71.
 - [43] Dong Ping, Cheng Kawai-Eric, Guo Pan. Performance analysis of different wind farm capacities to power grid[J]. Control Theory&Applications, 25 (2) :377-382.
 - [44] 杨秀媛, 肖洋, 陈树勇. 风电场风速和发电功率预测研究[J]. 中国电机工程学报, 25 (11) :1-5.
 - [45] Alexiadis M, Dokopoulos P, Sahsamanoglou H et al . Short term forecasting of wind speed and related electrical power[J]. Solar Energy, 1998, 63 (1) :61-68.
 - [46] Torres J L, Garcia A, Blas M D, et al . Forecast of Hourly Average Wind Speed with ARMA Models in Navarre (Spain) [J]. Solar Energy, 2005, 79:65-77.
 - [47] Potter C W, Negnevitsky M . Very short-term wind forecasting for tasmanian power generation[J]. IEEE Transactions on Power Systems,

- 2006, 21 (2) :965-972.
- [48] 吴兴华, 周晖, 黄梅. 基于模式识别的风电场风速和发电功率预测[J]. 继电器, 36 (1) :27-32.
- [49] 李东东, 陈陈. 风力发电系统动态仿真的风速模型[J]. 中国电机工程学报, 25 (21) :41-44.
- [50] 曹娜, 赵海翔, 任普春, 戴慧珠. 风电场动态分析中风速模型的建立及应用[J]. 中国电机工程学报, 27 (36) :68-72.
- [51] 王耀南, 孙春顺, 李欣然. 用实测风速校正的短期风速仿真研究[J]. 中国电机工程学报, 28 (11) :94-100.
- [52] Bossanyi E A. Short-term wind prediction using Kalman filters[J]. Wind Engineering, 1985, 9 (1) :1-8.
- [53] Kamal L, Jafri Y Z. Time series models to simulate and forecast hourly averaged wind speed in Wuetta, Pakistan[J]. Solar Energy, 1997, 61 (1) :23-32.
- [54] Sfetsos A. A comparison of various forecasting techniques applied to mean hourly wind speed time series[J]. Renewable Energy, 2000, 21 (1) :23-35.
- [55] 潘迪夫, 刘辉, 李燕飞. 基于时间序列分析和卡尔曼滤波算法的风电场风速预测优化模型[J]. 电网技术, 32 (7) :82-86.
- [56] 郎斌斌, 穆钢, 严干贵, 崔扬, 王晓波, 郑太一. 联网风电机组风速—功率特性曲线的研究[J]. 电网技术, 32 (12) :70-74.
- [57] Kariniotakis G, Stavrakakis G, Nogaret E. Wind power forecasting using advanced neural network models[J]. IEEE Transactions Energy Conversion, 1996, 11 (4) :762-767.
- [58] Li Shu-hui, Wunsch D C, Giesselmann M G, et al. Using neural networks to estimate wind turbine power generation[J]. IEEE Transactions on Energy Conversion, 2001, 16 (3) :276-282.
- [59] Barbounis T G, Theocharis J B, Alexiadis M C, et al. Long-term Wind Speed and Power Forecasting Using Local Recurrent Neural Network Models[J]. Transactions on Energy Conversion, 2006, 21 (1) :273-284.
- [60] 范高锋, 王伟胜, 刘纯. 基于人工神经网络的风电功率短期预测系统[J]. 电网技术, 32 (22) :72-76.
- [61] Hagan M T, Menhaj MB. Training feed forward networks with Marquart

- algorithm[J]. IEEE Transactions on Neural Networks, 1994, 5(6):989-993.
- [62] 陈树勇, 戴慧珠, 白晓民, 等. 尾流效应对风电场输出功率的影响[J]. 中国电力, 1998, 31(11):28-31.
- [63] Neff D E, Meroney R N. Mean wind and turbulence characteristics due to induction effects near wind turbine rotors[J]. Journal of Wind Engineering and Industrial Aerodynamics, 1997, 69-71:413-422.
- [64] Dorigo M, Maniezzo V, Colorni A. Ant system:optimization by a colony of cooperating agents[J]. IEEE Transactions on Systems, Man, and Cybernetics-Part B, 1996, 26(1):29-41.
- [65] Dorigo M, Bonabeau E and Theraulaz G. Ant algorithms and stigmergy[J]. Future Generation Computer Systems, 2000, 16:851-871.
- [66] Dorigo M, Gambardella L M. Ant colony system:a cooperative learning approach to traveling salesman problem[J]. IEEE Transactions on Evolutionary Computation, 1997, 1(1):53-66.
- [67] Maniezzo V and Colorni A. The ant system applied to the quadratic assignment problem[J]. IEEE Transactions on Knowledge Data Engineering, 1999, 11(5):769-778.
- [68] Colorni A, Dorigo M, Maniezzo V, et al. Ant system for job-shop scheduling[J]. Belgian J Oper Res Statist Comput Sci, 1994, 34(1):34-53.
- [69] Dorigo M, Caro G D, Gambardella L M. Ant algorithms for discrete optimization[J]. Artificial Life, 1999, 5(2):137-172.
- [70] Deneubourg J L, Goss S, Franks N et al. The blind leading the blind: modeling chemically mediated army ant raid patterns[J]. Journal of Insect Behavior, 1989, 2:719-725.
- [71] Bonabeau E, Dorigo M, Theraulaz G. Inspiration for optimization from social insect behavior[J]. Nature, 2000, 406(6):39-42.
- [72] Michael J B K, Jean-Bernard B, Laurent K. Ant-like task and recruitment in cooperative robots[J]. Nature, 2000, 406(31):992-995.
- [73] Gambardella L M, Dorigo M. Ant-Q:a reinforcement learning approach to the traveling salesman problem[C]. Proceedings of the 12th International Conference on Machine Learning, Tahoe City, July 9-12, 1995. CA:Morgan Kaufman, c1995, 252-260.

- [74] Dorigo M , Gambardella L M . A study of some properties of Ant-Q[C]. Proceedings of the 4th International Conference on Parallel Problem Solving from Nature , Berlin , September 22-27 , 1996. Berlin:Springer Verlag, c1996, 656-665.
- [75] Dorigo M, Luca M. The Ant-Q:algorithms applied to the nuclear reload problem[J]. Annals of Nuclear Energy, 2002, 29(12): 1455-1470.
- [76] Stutzle T, Hoos H H. MAX-MIN ant system[J]. Future Generation Computer Systems, 2000, 16(9):889-914.
- [77] 杨勇, 宋晓峰, 王建飞等. 蚁群算法求解连续空间优化问题[J] . 控制与决策, 2003, 18 (5) :573-576.
- [78] Dreо J, Siarry P. Continuous interacting ant colony algorithm based on dense heterarchy . Future Generation Computer systems[J], 2004 , 20(5):841-856.
- [79] Kennedy J, Eberhart R C. Particle Swarm Optimization:Proceedings IEEE International Conference on Neural Networks [C]. Piscataway, NJ:IEEE Service Center, 1995:1942-1948.
- [80] Eberhart R C, Kennedy J. A new optimizer using particle swarm theory. Proceedings on 6th International Symposium on Micromachine and Human Science[C]. Piscataway, NJ:IEEE Service Center, 1995:39-43.
- [81] Reynolds C W . Flocks, herds and schools: A distributed behavioral model[J]. Computers and Graphics. 1987, 21(04) :25-34.
- [82] Heppner F, Grenander U. A stochastic nonlinear model for coordinated bird flocks[M] . The Ubiquity of Chaos . Washington DC:AAAS Publications. 1990.
- [83] wilson E O. Sociobiology: The New Synthesis[M]. 1975.
- [84] Fukuyama Y. Fundamentals of particle swarm techniques [A]. Lee K Y, El-Sharkawi M A . Modern Heuristic Optimization Techniques With Applications to Power Systems[M]. IEEE Power Engineering Society , 2002. 45~51.
- [85] Kennedy J. The particle swarm:social adaptation of knowledge [C] . IEEE Int. Congress on Evolutionary Computation. Piscataway, NJ:IEEE Service Center, 1997:303-308.

- [86] Shi Y, Eberhart R. A modified particle swarm optimizer[C]. IEEE Int. Congress on Evolutionary Computation. Piscataway, NJ:IEEE Service Center. 1998:69-73.
- [87] Eberhart R C , Shi Y . Particle swarm optimizatioon: developments. applications and resources[C]. IEEE Int. Congress on Evolutionary Computation . Piscataway , NJ:IEEE Service Center , 2001:81-86.
- [88] Eberhart R C, Shi Y. Tracking and optimizing dynamic systems with particle swarms[C] . IEEE Int . Congress on Evolutionary Computation. Piscataway, NJ:IEEE Service Center. 2001:94-100.
- [89] Shi Y, Eberhart R. Fuzzy adaptive particle swarm optimization[C] . IEEE Int. Congress on Evolutionary Computation. Piscataway, NJ:IEEE Service Center, 2001:101-106.
- [90] Hu X, Eberhart R. Solving constrained nonlinear optimization problems with particle swarm optimization[C] . The 6th world multiconference on systemics, cybernetics and informatics. 2002.
- [91] Hu X , Eberhart R . Muhiobjective optimization using dynamic neighborhood particle swarm optimization[C] . IEEE Int. Congress on Evolutionary Computation . Piscataway , NJ:IEEE Service Center , 2002:1677-1681.
- [92] Hu X, Eberhart R, Shi Y. Swarm intelligence for permutation optimization: a case study of n-queens problem[C] . IEEE swarm intelligences symposium. Piscataway, NJ:IEEE Service Center, 2003:243-246.
- [93] Hu X, Shi Y, Eberhart R. Recent advances in particle swarm[C] . IEEE Int. Congress on Evolutionary Computation. Piscataway, NJ:IEEE Service Center. 2004:90-97.
- [94] El-Gallad A I, El-Hawary M E, Sallam A A. Swarming of intelligent particles for solving the nonlinear constrained optimization problem[J]. Engineering intelligent systems for electrical engineering and communications, 2001, 9(3):155-163.
- [95] Angeline P J . Using selection to improve particle swarm optimization[C] . IEEE Int . Congress on Evolutionary

- Computation. Piscataway, NJ:IEEE Service Center, 1998:84-89.
- [96] Angelie P J . Evolutionary optimization versus particle swarm optimization:philosophy and performance defferences [C] . Proceedings of the 7th Annual Conference on Evolutionary Programming. Gemany:Springer, 1998:601-610.

发表论文和科研情况说明

发表的论文:

- [1] 孟庆霖, “配电网络缺陷管理系统的工作流设计与实现”, 《继电器》, 2006 年 10 月
- [2] 孟庆霖, “工作流闭环系统的设计与实现”, 《华北电力技术》, 2006 年 11 月
- [3] 孟庆霖, “基于 OHSMS 的配电网络危险源点预控策略”, 《电力职工教育培训》, 2006 年 10 月

参与的科研项目:

参与配电网络缺陷管理系统的工作流设计与实现。

致 谢

本论文的工作是在我的导师王成山教授的悉心指导下完成的，从论文的选题到每一个研究阶段直至论文的撰写及修改都得到了王老师悉心的指导和帮助。王老师渊博的学识、严谨的学风、丰富的经验使本人受益匪浅；王老师谦逊诚恳、踏踏实实、平易近人的作风，为人师表的风范，更是本人今后工作和学习的楷模。在此谨向恩师致以最崇高的敬意和诚挚的谢意。

同时，本院其他老师对我的科研工作和论文提出了诸多宝贵意见，在此表示衷心地感谢！

课题的研究中得到了谷鑫、周凤争等同学的帮助，在此同样表示真挚地感谢！

感谢公司领导和同事对我的大力支持和帮助。

最后，我要深深地感谢我的父亲和母亲。完成学业是父亲临终前的遗愿，母亲也给予我极大的支持。此外，我的亲人和朋友，也为我的学业提供了很多帮助和支持，在此也同样表示真挚地感谢！