

DOI: 10.7667/PSPC160808

# 采用混合智能算法的含风电电力系统多目标优化调度

杨家然<sup>1</sup>, 王兴成<sup>1</sup>, 隋林涛<sup>2</sup>, 刘先正<sup>1</sup>, 罗晓芬<sup>2</sup>

(1. 大连海事大学, 辽宁 大连 116026; 2. 华能威海发电有限责任公司, 山东 威海 264205)

**摘要:** 为了增强含风电电力系统的安全性和稳定性, 提出一种计及运行风险及备用成本的含风电电力系统环境经济调度新模型。在目标函数中加入了系统运行风险指标和正、负旋转备用成本; 增加了系统可靠性约束条件, 确保了较低的系统运行风险, 并同时获取正、负旋转备用量。采用一种新型高效的场景生成技术来描述风电功率的随机性。基于花授粉算法及差分进化算法提出一种具有时变模糊选择机制的多目标优化算法。将所提模型及求解方法在具有一个并网风电场的4机组系统中进行仿真。分析了各参数变化对系统运行的影响, 并与其他两种启发式智能算法进行比较, 验证了所提模型及算法的可行性和有效性。

**关键词:** 风电功率预测; 场景概率; 花授粉算法; 多目标优化; 电力系统调度

## Multi-objective optimal scheduling of wind integrated power systems with hybrid intelligent algorithm

YANG Jiaran<sup>1</sup>, WANG Xingcheng<sup>1</sup>, SUI Lintao<sup>2</sup>, LIU Xianzheng<sup>1</sup>, LUO Xiaofen<sup>2</sup>

(1. Dalian Maritime University, Dalian 116026, China;

2. HUANENG Weihai Power Generation CO., LTD., Weihai 264205, China)

**Abstract:** In order to enhance the security and stability of power system with wind power, a new environmental and economic dispatch model of power system with wind power considering operation risk and reserve cost is proposed. In the objective function, the system operation risk index and positive and negative spinning reserve cost are joined, and the system reliability constraints are increased, which ensure the system run with the lower risk, and also obtain positive and negative spinning reserve amount. A new and efficient scene generation technique is used to describe the randomness of wind power. A multi-objective optimization algorithm containing time-varying fuzzy selection mechanism based on the flower pollination algorithm and differential evolution algorithm is proposed. The proposed model and solution method are simulated in a 4-unit system with a grid connected wind farm and compared with the other two heuristic algorithms. The effects of various parameters on the system operation are analyzed. The feasibility and effectiveness of the proposed model and algorithm are verified.

**Key words:** wind power forecasting; scenario probability; flower pollination algorithm; multi-objective optimization; power system dispatching

## 0 引言

为应对全球能源危机和环境恶化, 风力发电技术发展迅速, 并网风电场规模日益扩大。由于风电功率具有强烈的间歇性和随机波动性特点, 当风电渗透率达到一定比例必将给电力系统运行增加风险<sup>[1-3]</sup>。

目前, 国内外学者对含风电电力系统优化调度做了大量研究。文献[4]建立了含风电系统的低碳经济调度多目标优化模型, 但未考虑风电并网带来的风险。文献[5]提出了以总燃料耗量、污染气体排放量和购电费用最小为目标的多目标动态优化调度

模型, 但风电功率预测采用确定性模型, 未考虑风电出力的随机性。文献[6]在构建含风电系统优化调度模型时对风电并网导致的成本增加风险加以考虑, 但需要假设风速服从某种概率分布, 存在一定的不客观因素。文献[7]采用随机模拟技术生成场景, 以此在构建含风电系统优化调度模型时处理风电功率的随机性, 但场景生成步骤复杂, 增加了计算量。

针对以上问题, 本文以切负荷惩罚费用期望为风险指标, 同时在目标函数中计及了旋转备用成本, 构建含风电系统优化调度模型。采用一种新型

高效的场景生成技术来描述风电功率的随机性。基于花授粉算法及差分进化算法提出一种具有时变模糊选择机制的多目标优化算法。将本文所提模型及求解方法在具有一个并网风电场的4机组系统中进行仿真。仿真分析了各参数变化对系统运行的影响，并与其他两种启发式智能算法进行比较，验证了所提模型及算法的可行性和有效性。

## 1 随机性描述

基于风电功率区间预测得到其经验累积分布函数，进而产生场景，以下对各步骤作简介。

### 1.1 风电功率区间预测

本文采用文献[8]提出的基于神经网络(Neural Network, NN)的区间预测(Prediction Intervals, PI)，即高低限评估方法(Lower Upper Bound Estimation, LUBE)。PI具有较高的置信水平(PI Confidence Level, PICL)及较窄的宽度，对系统调度决策是有利的，但这两个目标是冲突的，可利用代价函数将两个目标整合为一个评价指标。*PICL*是PI的关键指标，表征了预测值落在高低限之间的概率，其定义为

$$PICL = \frac{1}{N} \sum_{i=1}^N \varepsilon_i \quad (1)$$

$$\varepsilon_i = \begin{cases} 1 & \text{if } y_i \in [L_i, U_i] \\ 0 & \text{if } y_i \notin [L_i, U_i] \end{cases} \quad (2)$$

式中： $N$ 为样本个数； $\varepsilon_i$ 为布尔变量，表征预测值是否在PI范围内； $y_i$ 为*i*时刻的预测值； $L_i$ 为*i*时刻的预测值下限； $U_i$ 为*i*时刻的预测值上限。

一般用归一化区间平均宽度(PI Normalized Average Width, PINAW)作为区间宽度量化指标：

$$PINAW = \frac{1}{N \cdot R} \sum_{i=1}^N (U_i - L_i) \quad (3)$$

式中， $R$ 为PI最大宽度，即预测最大值减最小值。

*PICL*及*PINAW*是区间预测相互冲突的两个优化目标，采用以下综合指标进行PI评价，定义为

$$CWC = PINAW [1 + \gamma(PICL) \cdot e^{-\eta(PICL - \mu)}] \quad (4)$$

$$\gamma(PICL) = \begin{cases} 0 & PICL \geq \mu \\ 1 & PICL < \mu \end{cases} \quad (5)$$

式中： $\mu$ 为预设*PICL*值，为PI硬性约束指标，设定为置信水平 $(1-\alpha)\%$ ； $\eta$ 为*PICL*与 $\mu$ 差值放大倍数。

基于NN的LUBE方法直接输出预测区间的高、低限，而不作任何数据分布假设；由相关性分析确定神经网络输入；通过变异粒子群算法(PSO)优化神经网络结构及权重，计算过程参考文献[9]。

## 1.2 风电功率场景生成

应用1.1节所述LUBE方法产生预测区间序列，用来估计风电功率经验累积分布函数(Empirical Cumulative Distribution Function, ECDF)，步骤如下。

1) 应用LUBE方法产生预测区间，置信水平为5%~95%，增量为5%，共产生19个预测区间。

2) 假设预测误差对称分布，每个预测区间可分成两个分位点表示。置信水平为 $(1-\alpha)\%$ 的预测区间可分成 $(\alpha/2)\%$ 和 $(1-\alpha/2)\%$ 两个分位点表示。

3) 在每个预测时刻*i*，得到 $ECDF_i, i=1, \dots, 24$ 曲线上的两个点 $\{(\alpha/2)\%, ECDF_i[(\alpha/2)\%]\}$ 、 $\{(1-\alpha/2)\%, ECDF_i[(1-\alpha/2)\%]\}$ ，因此19个预测区间共产生38个点。曲线的两个端点(0,0)、(1,1)，此两点表示风电功率标幺值低于0和1的概率分别为0和1。每个预测时刻*i*共得40个离散点。

4) 利用分段3次埃尔米特插值方法，由40个点拟合产生 $ECDF_i$ ，本文所用日前风电功率预测时间分辨率为1小时，因此共产生24个 $ECDF$ 曲线，分别代表24个预测时刻的风电功率概率分布。

5) 应用拉丁超立方抽样产生场景。对每个场景产生一个0-1之间随机数，由 $ECDF_i$ 产生风电功率场景值 $P_i^w, i=1, \dots, 24$ 。

场景数越多预测越精确，为了减少计算量，本文选用同步回代消除(Simultaneous Backward Reduction)技术进行场景削减，以较少数目的场景达到对风电功率预测不确定性的近似。

## 2 基于场景分析的多目标模型

### 2.1 目标函数

计及阀点效应的常规机组燃料成本期望表示为

$$\hat{f}_1 = \sum_{s=1}^{NS} \pi_s f_1(\mathbf{P}_{G,s}) = \sum_{s=1}^{NS} \pi_s \sum_{t=1}^{NT} \sum_{ug=1}^{NG} (a_{ug} + b_{ug} P_{ug,t,s} + c_{ug} P_{ug,t,s}^2 + |d_{ug} \sin(e_{ug} [P_{ug}^{\min} - P_{ug,t,s}])|) \quad (6)$$

$$\mathbf{P}_{G,s} = [P_{1,s} P_{2,s} \dots P_{t,s} \dots P_{NT,s}] \quad (7)$$

$$\mathbf{P}_{t,s} = [P_{1,t,s} P_{2,t,s} \dots P_{ug,t,s} \dots P_{NG,t,s}]^T \quad (8)$$

式中： $\pi_s$ 表示场景*s*的概率； $P_{ug,t,s}$ 表示常规发电机*ug*在*t*时段场景*s*下出力； $NS$ 表示场景个数； $NT$ 表示总调度时段数； $NG$ 表示常规发电机个数； $a_{ug}$ 、 $b_{ug}$ 、 $c_{ug}$ 表示燃料费用系数； $d_{ug}$ 、 $e_{ug}$ 表示阀点效应相关系数； $P_{ug}^{\min}$ 表示常规机组*ug*最小出力。

污染气体排放总量期望可表示为

$$\hat{f}_2 = \sum_{s=1}^{NS} \pi_s f_2(P_{G,s}) = \sum_{s=1}^{NS} \pi_s \sum_{t=1}^{NT} \sum_{ug=1}^{NG} (\alpha_{ug} + \beta_{ug} P_{ug,t,s} + \gamma_{ug} P_{ug,t,s}^2 + \xi_{ug} \exp(\lambda_{ug} P_{ug,t,s})) \quad (9)$$

式中,  $\alpha_{ug}$ ,  $\beta_{ug}$ ,  $\gamma_{ug}$ ,  $\xi_{ug}$ ,  $\lambda_{ug}$  为给定污染气体排放系数。

以切负荷惩罚费用期望(Expected Energy Not Served, EENS)代表运行风险指标, 可表示为<sup>[10]</sup>

$$\hat{f}_3 = \sum_{s=1}^{NS} \pi_s \sum_{t=1}^{NT} VOLL \cdot EENS_{t,s} \quad (10)$$

$$EENS_{t,s} = \frac{\sigma_{net\_d}}{\sqrt{2\pi}} \exp(-USR_{t,s}^2 / (2\sigma_{net\_d}^2)) - 0.168USR_{t,s} \cdot \exp(-0.876USR_{t,s}^2 / \sigma_{net\_d}^2) - 0.144USR_{t,s} \cdot \exp(-0.525USR_{t,s}^2 / \sigma_{net\_d}^2) \quad (11)$$

式中:  $VOLL$  (Value of Lost Load)表示系统切负荷惩罚系数(为单位MW·h中断负荷的费用);  $EENS_{t,s}$ 表示 $t$ 时段场景 $s$ 下的切负荷期望;  $\sigma_{net\_d}$ 为净负荷预测误差的标准方差<sup>[10]</sup>;  $USR_{t,s}$ 表示 $t$ 时段场景 $s$ 下的系统正旋转备用。

旋转备用成本为

$$\hat{f}_4 = \sum_{s=1}^{NS} \pi_s \sum_{t=1}^{NT} (USR_{t,s} \cdot k_U + DSR_{t,s} \cdot k_D) \quad (12)$$

式中:  $DSR_{t,s}$ 表示 $t$ 时段场景 $s$ 下的系统负旋转备用;  $k_U$ 、 $k_D$ 分别表示正、负旋转备用成本系数。

## 2.2 约束条件

$$\sum_{ug=1}^{NG} P_{ug,t,s} + PW_{t,s} = PD_t - EENS_{t,s} \quad (13)$$

式中:  $PW_{t,s}$ 表示风电场在 $t$ 时段场景 $s$ 下的出力;  $PD_t$ 表示 $t$ 时段系统负荷。此式为功率平衡约束。

$$P_{ug}^{\min} \leq P_{ug,t,s} \leq P_{ug}^{\max} \quad (14)$$

式中,  $P_{ug}^{\max}$ 、 $P_{ug}^{\min}$ 分别表示机组 $ug$ 的最大、最小出力限制。此式为机组出力约束。

$$P_{ug,t,s} - P_{ug,t-1,s} \leq RU_{ug} \cdot T_{60} \quad (15)$$

$$P_{ug,t-1,s} - P_{ug,t,s} \leq RD_{ug} \cdot T_{60} \quad (16)$$

式中:  $RU_{ug}$ 、 $RD_{ug}$ 分别表示机组 $ug$ 的上、下爬坡率;  $T_{60}$ 表示一个运行时段, 即60 min。此式为爬坡率约束。

$$\sum_{ug=1}^{NG} \min(P_{ug}^{\max} - P_{ug,t,s}, RU_{ug} \cdot T_{10}) \geq USR_{t,s} \quad (17)$$

$$\sum_{ug=1}^{NG} \min(P_{ug,t,s} - P_{ug}^{\min}, RD_{ug} \cdot T_{10}) \geq DSR_{t,s} \quad (18)$$

式中,  $T_{10}$ 表示10 min。此式为旋转备用约束。

$$EENS_{t,s} \leq EENS^{\max} \quad (19)$$

式中,  $EENS^{\max}$ 为系统切负荷上限, 以系统容量百分比表示。此式为系统可靠性约束。

## 3 多目标优化的帕累托最优原则

为了评价多目标优化问题(Multi-objective Optimization Problem, MOP)解的优劣性, 对于决策向量 $\mathbf{A}$ 、 $\mathbf{B}$ , 在MOP中常用到如下定义。

1) 帕累托(Pareto)占优,  $\mathbf{A} \prec \mathbf{B}$  ( $\mathbf{A}$ 占优 $\mathbf{B}$ )当且仅当:

$$\begin{cases} f_i(\mathbf{A}) \leq f_i(\mathbf{B}), \forall i \in \{1, 2, \dots, N_{obj}\} \\ f_j(\mathbf{A}) < f_j(\mathbf{B}), \exists j \in \{1, 2, \dots, N_{obj}\} \end{cases} \quad (20)$$

式中,  $N_{obj}$ 表示目标函数的个数。

2)  $\mathbf{A}$ 是Pareto最优解, 当且仅当:

$$\neg \exists \mathbf{X} : \mathbf{X} \prec \mathbf{A} \quad (21)$$

式(20)、式(21)均应满足模型约束条件。所有Pareto最优解的集合称Pareto最优解集, Pareto最优解对应的目标函数值称为非劣目标向量, 由所有非劣目标向量形成的区域称为Pareto前沿。

## 4 具有时变模糊选择机制的综合智能算法

基于花授粉算法(Flower Pollination Algorithm, FPA)及差分进化算法(Differential Evolution, DE), 本文提出一种具有时变模糊选择机制(Time Varying Fuzzy Selection Mechanism, TVFSM)的多目标优化算法。由FPA进行泛域搜索并将Pareto最优解集传递给具有TVFSM机制的改进DE算法进行Pareto前沿局部精确搜索, 进而找到最优折衷解(Best Compromise Solution, BCS), 下文以HFA-TVFSM表示此综合算法。

### 4.1 花授粉算法简介

受自然界中植物花朵授粉过程的启发, 学者Xin-she Yang于2012年提出一种新型元启发式群智能优化算法—花授粉算法<sup>[11]</sup>, 实现步骤如下。

1) 初始化参数, 花种群数 $n$ , 选择概率 $\rho$ 。

2) 计算每个解的评价指标, 并求出当前最优解和最优评价指标。

3) 如果选择概率 $\rho > rand$ , 按式(22)更新。

$$\mathbf{X}_i^{iter+1} = \mathbf{X}_i^{iter} + L(\mathbf{g}^* - \mathbf{X}_i^{iter}) \quad (22)$$

式中:  $\mathbf{X}_i^{iter+1}$ 、 $\mathbf{X}_i^{iter}$ 分别表示第 $iter+1$ 代、第 $iter$ 代的解;  $\mathbf{g}^*$ 是全局最优解;  $L$ 是步长, 服从莱维分布, 其计算过程为

$$L = \frac{\mu}{|\nu|^{1/\beta}} \times \frac{\delta_\mu}{\delta_\nu} \quad (23)$$

式中,  $\mu, \nu$  服从正态分布,  $\mu \sim N(0, \delta_\mu^2)$ ,  $\nu \sim N(0, \delta_\nu^2)$ , 且有

$$\begin{cases} \delta_\mu = \left\{ \frac{\Gamma(1+\beta) \times \sin(\pi\beta/2)}{\Gamma[(1+\beta)/2] \times 2^{(\beta-1)/2} \times \beta} \right\}^{1/\beta} \\ \delta_\nu = 1 \end{cases} \quad (24)$$

式中:  $\beta = 3/2$ ;  $\Gamma(\beta)$  是标准的伽马函数。

4) 如果选择概率  $\rho < rand$ , 按式(25)更新。

$$\mathbf{X}_i^{iter+1} = \mathbf{X}_i^{iter} + \eta(\mathbf{X}_j^{iter} - \mathbf{X}_k^{iter}) \quad (25)$$

式中:  $\eta$  是[0,1]上服从均匀分布的随机数;  $\mathbf{X}_j^{iter}$ 、 $\mathbf{X}_k^{iter}$  是相同植物种类的不同花朵。

5) 计算步骤3)或者4)得到的新解对应的评价指标, 若新解的评价指标更优, 则用新解替换当前解, 否则保留当前解。

6) 如果新解对应的评价指标值比全局最优值更优, 则更新全局最优解和全局最优值。

7) 判断结束条件, 若满足, 退出程序并输出最优解及最优评价指标值, 否则, 转步骤3)。

## 4.2 改进差分进化算法简介

本文对DE的选择操作进行改进, 使整个综合算法具有时变模糊选择性, 常规DE的选择操作表示为

$$\mathbf{X}_i^{iter+1} = \begin{cases} \mathbf{U}_i^{iter+1} & \text{if } f(\mathbf{U}_i^{iter+1}) < f(\mathbf{X}_i^{iter}) \\ \mathbf{X}_i^{iter} & \text{else} \end{cases} \quad (26)$$

式中:  $\mathbf{X}_i^{iter+1}$  代表生成的子代种群, 也就是下一代的父向量;  $\mathbf{X}_i^{iter}$  代表父代当代种群;  $\mathbf{U}_i^{iter+1}$  代表试验子代种群;  $f(\bullet)$  代表目标函数。

本文提出对任意一个可行解计算其模糊选择指标(Fuzzy Selection Index, FSI), FSI将可行解的多个目标函数值整合为一个指标, 由  $FSI(\bullet)$  代替(26)式中的  $f(\bullet)$ , 则选择操作表示为

$$\mathbf{X}_i^{iter+1} = \begin{cases} \mathbf{U}_i^{iter+1} & \text{if } FSI(\mathbf{U}_i^{iter+1}) > FSI(\mathbf{X}_i^{iter}) \\ \mathbf{X}_i^{iter} & \text{else} \end{cases} \quad (27)$$

## 4.3 时变模糊选择机制

### 4.3.1 各指标计算

通过隶属函数, 对应每个目标函数为任一可行解赋予隶属值(Member Value, MV), 计算过程为

$$MV_i^{t,s}(f_m) = \begin{cases} 1 & f_m^{t,s} \leq f_m^{\min} \\ \frac{f_m^{\max} - f_m^{t,s}}{f_m^{\max} - f_m^{\min}} & f_m^{\min} \leq f_m^{t,s} \leq f_m^{\max} \\ 0 & f_m^{t,s} \geq f_m^{\max} \end{cases} \quad (28)$$

式中:  $MV_i^{t,s}(f_m)$  表示第  $i$  个可行解在时段  $t$  场景  $s$  下对应的第  $m$  个目标函数隶属值;  $f_m^{\min}$  表示第  $m$  个目标函数最小值;  $f_m^{\max}$  表示第  $m$  个目标函数最大值。

第  $i$  个可行解在第  $t$  时段  $s$  场景下等级排序指标表示为

$$RI_i^{t,s} = \min \{ MV_i^{t,s}(f_1), \dots, MV_i^{t,s}(f_m) \} \quad (29)$$

以  $RI$  作为多目标优化问题可行解的择优标准。通过钟型隶属函数计算模糊选择指标, 如式(30)。

$$FSI_i^{t,s}(c) = \frac{1}{1 + [(RI_i^{t,s} - a_c)/b_c]^K} \quad (30)$$

式中:  $FSI_i^{t,s}(c)$  表示第  $i$  个可行解在第  $t$  时段  $s$  场景第  $c$  分类下的模糊选择指标;  $K$  为函数阶次;  $a_c$  表示第  $c$  模糊分类中心, 此处模糊选择指标为1;  $b_c$  表示第  $c$  模糊分类宽度。

### 4.3.2 4步时变、5类模糊选择机制简介

燃料成本、污染物排放、风险指标、备用成本是相互冲突的4个目标, 明显不存在使4者同时达到最优的解, 即  $RI=1$ 。因此BCS定义为最大限度地满足4个指标的解, 其期望  $RI$  值一般在0.5~0.9, 在BCS邻域内搜索最优解。  $a_c$  设定在0.5~0.9使  $RI$  值在此范围内的解获得较高的  $FSI$  值。

以迭代次数为依据, 将整个改进DE算法迭代过程分成4部分(本文设定最大迭代次数为500), 钟型隶属函数的宽度随迭代的进行不断变窄, 此即为4步时变性, 逐步增加搜索精度。

4步时变、5类模糊选择机制能增加Pareto最优解集的多样性, 增强算法在BCS局部搜索能力, 进而快速找到最优解。每个钟型隶属函数具有不同中心和宽度(共分5类, 以  $c=1, 2, 3, 4, 5$  分别表示), 因此对Pareto解集中的解赋予不同的  $FSI$  值。  $a_c, b_c, K$  设定值见表1。模糊分类由迭代随机数  $rand^{iter}$  决定, 规则为

$$\begin{cases} \text{if } rand^{iter} \leq 0.2 \text{ then } c = 1; \\ \text{if } 0.2 < rand^{iter} \leq 0.4 \text{ then } c = 2; \\ \text{if } 0.4 < rand^{iter} \leq 0.6 \text{ then } c = 3; \\ \text{if } 0.6 < rand^{iter} \leq 0.8 \text{ then } c = 4; \\ \text{if } 0.8 < rand^{iter} \leq 1 \text{ then } c = 5; \end{cases} \quad (31)$$

## 4.4 HFPA-TVFSM 综合算法流程简介

HFPA-TVFSM算法步骤如下。

Step1: 输入机组参数, 负荷预测值, 风电功率场景预测值, 设定FPA、DE总迭代次数分别为  $K, J$ , 种群个体总数为  $L$ 。

表 1 钟型隶属函数参数表

Table 1 Bell curve membership function parameters in the fuzzy selection mechanism

	FSM	C=1	C=2	C=3	C=4	C=5
Step1 (1~100)	$K$	6	6	6	6	6
	$a_c$	0.5	0.6	0.7	0.8	0.9
Step2 (101~200)	$b_c$	0.6	0.6	0.6	0.6	0.6
	$K$	6	6	6	6	6
Step3 (201~300)	$a_c$	0.5	0.6	0.7	0.8	0.9
	$b_c$	0.4	0.4	0.4	0.4	0.4
Step4 (301~500)	$K$	4	4	4	4	4
	$a_c$	0.5	0.6	0.7	0.8	0.9
	$b_c$	0.3	0.3	0.3	0.3	0.3
	$K$	3	3	3	3	3
	$a_c$	0.5	0.6	0.7	0.8	0.9
	$b_c$	0.2	0.2	0.2	0.2	0.2

Step2: 初始化种群  $N_0$ , 种群个体当代Pareto最优解集  $M_0$ , 全局Pareto最优解集  $G$ , 全局极值  $g^*$ 。种群个体  $P_{G,s}^{0,l}$ ,  $l=1, 2, \dots, L$  是个  $NG \times NT$  的矩阵, 如式(7)、式(8), 其中每个元素  $P_{ug,t,s}$  满足机组出力约束, 即式(14), 按式(32)初始化。

$$P_{ug,t,s} = P_{ug}^{\min} + \lambda(P_{ug}^{\max} - P_{ug}^{\min}) \quad (32)$$

式中,  $\lambda$  为  $[0, 1]$  上均匀分布的随机数。

Step3: 计算各目标函数值; 由种群  $N_k$  通过式(20)、式(21)更新当代Pareto最优解集  $M_k$ ; 由  $M_k$  更新全局Pareto最优解集  $G$ , 确定全局极值  $g^*$ 。

Step4: 由选择概率  $\rho$  决定, 按式(22)或式(25)产生试验种群  $E_k$ , 并通过式(20)、式(21)选择、更新  $N_k$ 。

Step5: 检查已更新种群  $N_k$  中个体是否满足各约束条件, 对不满足约束条件的个体进行更正。

Step6:  $k = k + 1$ , 进入step3, 如达到最大迭代次数  $K$ , FPA泛域搜索过程结束, 输出全局Pareto

最优解集  $G$ , 进入改进DE算法精确寻优过程。

Step7: 将  $G$  赋予DE算法初始父种群  $F_0$ 。

Step8: 由  $F_j$  进行变异、交叉操作产生试验种群  $S_j$ , 并由式(28)、式(29)计算  $F_j$ 、 $S_j$  的  $MV$ ,  $RI$  值。

Step9: 由式(31)随机选择模糊分类, 并计算  $F_j$ 、 $S_j$  的  $FSI$  指标, 由式(27)选择、更新  $F_j$ , 并通过占优条件更新全局Pareto最优解集  $G$ 。

Step10:  $j = j + 1$ , 进入Step8, 如达到最大迭代次数  $J$ , 输出全局Pareto最优解集  $G$ , 并由  $RI$  指标确定最优解。

## 5 算例分析

将本文所提模型及求解方法在具有一个并网风电场的4机组系统中进行仿真。该风电场额定功率为110 MW, 各常规机组的最大、最小功率、爬坡率、燃料特性、排放参数及仿真系统的其他参数详见文献[12]。为方便对优化调度结果及其影响因素进行分析, 系统研究周期设定为12 h, 每个时段为1 h, 负荷需求的预测值如表2所示。历史风电功率数据来自国内某风电场, 采用第1节介绍方法产生1000个场景, 然后利用场景削减技术将场景数量减少到10个, 保留的10个场景的概率及出力如表3所示。 $k_U$ 、 $k_D$ 取值都为20 \$(/MW·h),  $EENS^{\max}$ 取1%,  $VOLL$ 取100 \$/MW。

表 2 负荷预测数据

Table 2 Load forecast data

时段	总负荷/MW	时段	总负荷/MW	时段	总负荷/MW
1	360	5	318	9	470
2	307	6	320	10	475
3	305	7	360	11	472
4	312	8	440	12	468

表 3 风电场 10 个预测场景出力及概率

Table 3 Output and probability of 10 wind farm forecast scenarios

场景	1	2	3	4	5	6	7	8	9	10
概率	0.068	0.081	0.108	0.057	0.09	0.081	0.08	0.150	0.091	0.194
时段	风电功率预测值/MW									
1	45.29	49.28	73.46	38.43	48.41	51.44	64.39	58.94	80.78	39.90
2	34.37	50.16	62.87	59.52	44.14	76.95	59.65	46.44	68.80	55.87
3	52.31	42.88	59.20	55.91	35.16	42.45	60.94	48.98	51.78	39.65
4	41.90	49.76	50.39	39.95	42.47	29.56	53.88	34.55	45.08	60.58
5	52.37	58.46	70.91	45.01	48.36	50.02	39.64	27.02	59.16	63.41
6	60.76	68.92	81.39	69.09	85.09	71.83	57.13	49.38	42.99	81.28
7	93.50	92.37	86.56	78.63	94.76	62.78	80.35	60.22	81.07	76.26
8	93.55	88.31	90.19	85.84	70.92	59.28	81.36	66.29	86.53	59.64
9	76.40	79.53	98.03	92.37	51.63	87.82	79.18	73.87	67.79	90.19
10	86.80	93.21	103.6	98.68	80.39	69.36	90.34	52.68	85.35	79.49
11	102.3	99.79	97.54	91.03	82.97	54.93	91.22	63.18	79.60	82.37
12	98.63	101.7	89.61	89.27	79.66	67.24	79.83	42.91	80.70	85.97

本文将目前广泛应用的多目标优化算法：非支配排序遗传算法(Non-dominated Sorting Genetic Algorithm II, NSGA-II)、改进多目标粒子群算法(Improved Multi-objective Particle Swarm Optimization Algorithm, IMOPSO)作为对比算法进行模型求解(最大迭代次数均为500次)。某一调度时段所得，燃料成本—污染气体排放量、燃料成本—备用成本、污染气体排放量—风险指标3个局部Pareto前沿对比如图1—图3所示。明显可看出本文所提算法可得到更优的Pareto前沿，其他局部Pareto前沿对比结果类似，此处不再列出。

3种算法在第一时段关于燃料成本，其迭代收敛过程对比如图4所示。

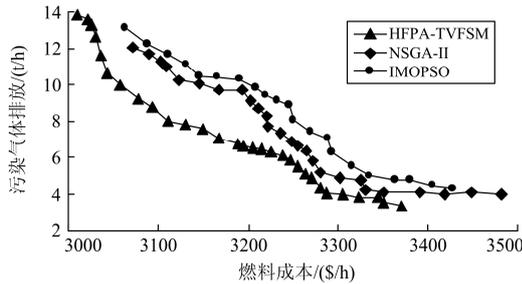


图1 燃料成本-污染排放 Pareto 前沿对比

Fig. 1 Comparison of fuel cost-emission Pareto front

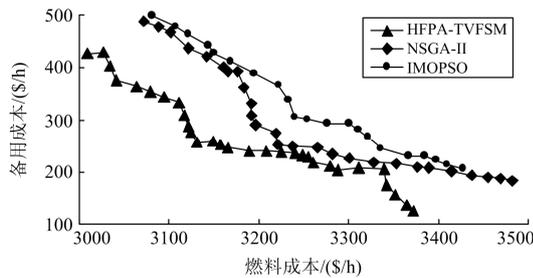


图2 燃料成本-备用成本 Pareto 前沿对比

Fig. 2 Comparison of fuel cost-reserve cost Pareto front

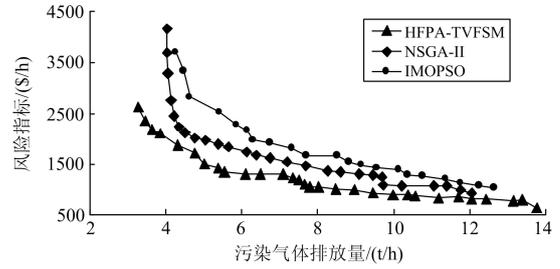


图3 污染排放-风险指标 Pareto 前沿对比

Fig. 3 Comparison of emission-risk index Pareto front

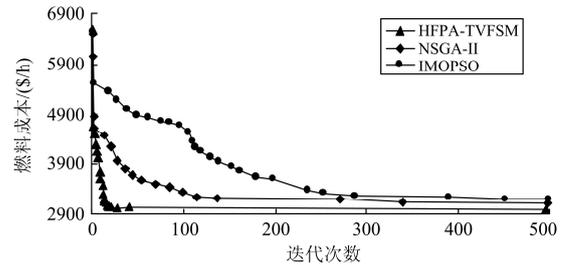


图4 3种算法关于燃料成本的寻优收敛对比

Fig. 4 Convergence comparison of three algorithms on the optimization of fuel cost

由图4可以看出本文所提算法在收敛速度及寻优结果方面均具有明显优势，模糊选择机制促进算法在最优折衷解附近快速收敛。

3种算法的最优折衷解对应第一个调度时段的各目标函数值对比如表4所示。应用HFPA-TVFSM算法12个时段优化调度结果见表5。

表4 最优折衷解第一时段各目标函数值

Table 4 Best compromise solution for the first interval of each objective function

算法	燃料成本/(\$/h)	污染排放/(t/h)	备用成本/(\$/h)	风险指标/(\$/h)	RI
IMOPSO	3102.89	7.35	1278.53	1206.31	0.5302
NSGA-II	3085.73	5.23	1143.79	1156.97	0.5910
HFPA	3026.34	4.01	1080.29	1073.19	0.6589

表5 应用 HFPA-TVFSM 算法的优化调度结果

Table 5 Optimal scheduling results obtained by the HFPA-TVFSM algorithm

时段	$P_1$ /MW	$P_2$ /MW	$P_3$ /MW	$P_4$ /MW	$f_1$ /(\$/h)	$f_2$ /(t/h)	$f_3$ (\$/h)	$f_4$ (\$/h)	USR/MW	DSR/MW
1	65.35	95.23	124.52	35.00	3026.34	4.01	1073.19	1080.29	33.71	20.29
2	55.26	71.60	86.27	35.00	2665.36	2.36	893.88	921.73	27.17	18.89
3	51.50	66.67	112.18	35.00	2647.59	3.68	876.13	916.41	28.01	17.81
4	52.66	67.36	96.40	35.00	2708.03	3.04	903.24	928.65	27.03	19.40
5	53.13	66.19	100.27	35.00	2755.44	3.09	927.15	963.87	26.73	21.46
6	50.84	61.68	91.20	35.00	2770.45	3.01	983.69	989.04	29.12	20.35
7	65.85	72.69	110.20	35.00	3027.01	3.57	1026.46	1153.82	32.27	25.42
8	91.35	124.09	129.92	35.00	3414.09	9.83	1120.03	1326.59	38.14	28.19
9	92.31	124.67	127.83	35.00	3519.29	12.3	1202.37	1419.23	41.49	29.47
10	93.11	131.11	136.29	35.00	3536.80	12.9	1087.62	1436.09	40.48	31.32
11	88.59	128.42	137.62	35.00	3526.29	12.5	993.87	1501.32	44.31	30.75
12	90.48	120.85	135.71	35.00	3503.37	11.9	1035.22	1489.11	44.50	29.96

## 6 结论

1) 提出一种含风电电力系统的环境经济调度新模型, 在目标函数中加入了系统运行风险指标和正、负旋转备用成本。增加了系统可靠性约束条件, 确保了较低的系统运行风险, 并同时获取正、负旋转备用量, 得到最优调度策略。

2) 时变模糊选择机制能赋予每个Pareto最优解不同的FSI指标, 因而能增加Pareto最优解集的多样性, 剔除Pareto解集中的极端点, 增强算法在Pareto前沿局部“挖掘”能力, 进而快速找到最优折衷解。

### 参考文献

- [1] 张新松, 礼晓飞, 王运, 等. 不确定性环境下考虑弃风的电力系统日前调度[J]. 电力系统保护与控制, 2015, 43(24): 75-82.  
ZHANG Xinsong, LI Xiaofei, WANG Yun, et al. Day-ahead dispatching in consideration of wind power curtailments in uncertain environments[J]. Power System Protection and Control, 2015, 43(24): 75-82.
- [2] 黎静华, 文劲宇, 潘毅, 等. 面向新能源并网的电力系统鲁棒调度模式[J]. 电力系统保护与控制, 2015, 43(22): 47-54.  
LI Jinghua, WEN Jinyu, PAN Yi, et al. Robust dispatching mode of electrical power system to cope with renewable energy power[J]. Power System Protection and Control, 2015, 43(22): 47-54.
- [3] 王守凯, 刘达. 风电消纳途径综述[J]. 陕西电力, 2016, 44(7): 15-19.  
WANG Shoukai, LIU Da. Review of wind power accommodation approaches[J]. Shaanxi Electric Power, 2016, 44(7): 15-19.
- [4] 田廓, 姚金雄, 李文辉. 面向清洁能源发电并网的低碳电力系统优化调度模型[J]. 陕西电力, 2016, 44(1): 51-55.  
TIAN Kuo, YAO Jinxiong, LI Wenhui. Power system optimal dispatching model with low-carbon under clean energy generation integration[J]. Shaanxi Electric Power, 2016, 44(1): 51-55.
- [5] CHEN C L, CHEN Z Y, LEE T Y. Multi-area economic generation and reserve dispatch considering large-scale integration of wind[J]. Electric Power Energy Systems, 2014, 55: 171-178.
- [6] 周玮, 孙辉, 顾宏, 等. 计及风险备用约束的含风电场电力系统动态经济调度[J]. 中国电机工程学报, 2012, 32(1): 47-55.  
ZHOU Wei, SUN Hui, GU Hong, et al. Dynamic economic dispatch of wind integrated power systems based on risk reserve constraints[J]. Proceedings of the CSEE, 2012, 32(1): 47-55.
- [7] NIKNAM T, AZIZIPANAH-ABARGHOOEE R, NARIMANI M R. An efficient scenario based programming framework for multi-objective optima micro-grid operation[J]. Applied Energy, 2012, 99: 455-470.
- [8] QUAN H, SRINIVASAN D, KHOSRAVI A. Short term load and wind power forecasting using neural network based prediction intervals[J]. IEEE Transactions on Neural Network Learning System, 2014, 25(2): 303-315.
- [9] FAN S, HYNDMAN R. Short term load forecasting based on a semi-parametric additive model[J]. IEEE Transactions on Power Systems, 2012, 27(1): 134-141.
- [10] 王荣杰, 詹宜巨, 周海峰, 等. 基于差分进化机理优化的 PID 控制的 AVR 系统[J]. 电力系统保护与控制, 2015, 43(24): 108-114.  
WANG Rongjie, ZHAN Yiju, ZHOU Haifeng, et al. PID controlled AVR system based on differential evolution mechanism optimization[J]. Power System Protection and Control, 2015, 43(24): 108-114.
- [11] YANG Xinshe. Flower pollination algorithm for optimization[C] // Unconventional Computation and Natural Computation. Berlin: Springer, 2012: 240-249.
- [12] LIAO G C. A novel evolutionary algorithm for dynamic economic dispatch with energy saving and emission reduction in power system integrated wind power[J]. Energy, 2011, 36(2): 1018-1029.

收稿日期: 2016-06-04; 修回日期: 2016-07-02

作者简介:

杨家然(1984—), 男, 博士研究生, 主要研究方向为新能源并网、预测、调度等; E-mail: yiran\_qqqqqq@qq.com

王兴成(1956—), 男, 通信作者, 教授, 博士生导师, 主要研究方向为鲁棒控制理论、非线性控制、先进控制技术。E-mail: dmuwxc@dlnu.edu.cn

(编辑 葛艳娜)