基于 SVM-MOPSO 混合智能算法的配电网分布式电源规划

刘煌煌[1]，雷金勇[2]，蔡润庆[1]，陈 钢[3]，杨振纲[4]，刘前进[1]

（1.华南理工大学电力学院，广东 广州 510640；2.南方电网科学研究院有限责任公司，广东 广州 510080；
3.南方电网综合能源有限公司，广东 广州 510075；4.中国南方电网有限责任公司，广东 广州 510623）

摘要：针对分布式电源(Distributed Generation，DG)并网给电力系统带来的随机扰动，综合考虑配电网运行效益，计及风光时序特性，以经济性、电能质量及环保性为目标，搭建了机会约束规划模型。采用混合智能算法求解，即基于支持向量机(Support Vector Machine，SVM)算法模拟优化变量到目标函数以及约束条件映射的不确定性函数，运用多目标粒子群算法(Multi-Objective Particle Swarm Optimization，MOPSO)求解模型，得出 Pareto 非劣决策集并给出典型解及理想解。算例结果表明，该规划方法考虑到 DG 的随机性特征、时序特性和并网概率分布，能提高算法执行效率，证明了所提方法的合理性和有效性，且 Pareto 前沿的引入，给决策者充分选择空间，更具有工程性。

关键词：分布式电源规划；时序特性；混合智能算法；支持向量机模拟；多目标粒子群算法

Distributed generation planning in distribution network based on hybrid intelligent algorithm by SVM-MOPSO

LIU Huang-huang[1], LEI Jin-yong[2], CAI Run-qing[1], CHEN Gang[3], YANG Zhen-gang[4], LIU Qian-jin[1]

(1. College of Electric Power, South China University of Technology, Guangzhou 510640, China; 2. Electric Power Research Institute of China Southern Power Grid, Guangzhou 510080, China; 3. China Southern Power Grid Synthetic Energy Co., Ltd, Guangzhou 510075, China; 4. China Southern Power Grid Co., Ltd, Guangzhou 510623, China)

Abstract: Regarding stochastic disturbance in power system brought by grid-connected distributed generation (DG), generally considering operational effectiveness, along with timing characteristics of wind speed and sunlight intensity, taking economy, power quality and environmental efficiency as goals, the optimization model of stochastic chance-constrained programming is built. The hybrid intelligent algorithm is used, which simulates the uncertainty functions based on support vector machine (SVM) and solves the model by multi-objective particle swarm optimization (MOPSO), and then the Pareto non-inferior decision set is obtained. Simulation results show that the planning model can fully take into account randomness, timing characteristics and grid-connected probability distribution of DG, and improve the efficiency of the algorithm, then verify the rationality and validity of the proposed approach. Moreover, the introduction of Pareto front gives fully choices to policymakers and possesses more engineering value.

Key words: distributed generation planning; timing characteristics; hybrid intelligent algorithm; support vector machine simulation; multi-objective particle swarm optimization

中图分类号： TM715 文献标识码：A 文章编号： 1674-3415(2014)10-0046-09

0 引言

分布式电源(Distributed Generation，DG)规划是智能配电网建设的一项关键技术[1]。配电网大量接入 DG 会使其潮流发生改变，影响网络的正常运行，而位置和容量是决定 DG 并网对电力系统影响程度的两个重要因素。因此，如何科学地进行选址定容是 DG 规划阶段中必须面临的问题，对保证配电网安全稳定、经济可靠地运行具有重要意义[2-5]。

文献[6]考虑了含投资成本、网损、静态电压稳定性三个目标的多目标优化，并采用基于目标序列排序矩阵评价个体适应度及小生境技术的多目标遗传算法进行求解；文献[7]以功率损耗和电压分布作为目标，利用改进的多目标和声搜索评估 DG 定址定容对配电系统最优发展的影响。文献[8]建立了 DG 与配电网的协调规划框架，在目标中引入 DG 环境效益奖励因子。

基金项目：广东省战略性新兴产业核心技术攻关项目(2012A032300001)

文献[9]基于不同类型 DG 的负荷、时序特性及环保性能建立微网 DG 规划模型，以投资、燃料、网络损耗费用和环境赔偿费用最小为目标函数，采用随机潮流判断规划方案是否满足潮流约束及计算网损。文献[10]提出了对经济、技术和环境属性在内的冲突性及竞争性的目标函数进行优化的静态模糊多目标模型，利用模糊数来研究系统负荷需求、电力价格、DG 运行成本以及投资成本的不确定性；文献[11]构建了多目标风电场接入的输电线路与电网联合优化规划模型，并在此基础上提出了随机模拟、神经元网络和非劣排序遗传算法 II(Non-dominated Sorting Genetic Algorithm II，NSGA-II)相结合的混合智能算法。

文献[6-8]从配网的实际出发，考虑了多目标情况下的 DG 规划，但未考虑 DG 的随机性特征；文献[9-11]以随机潮流、模糊数以及混合智能算法表示 DG 的随机性特性，但随机潮流优化时间过长，模糊数难以准确反映 DG 的随机特征，基于神经网络的混合智能算法在网络训练中收敛速度慢，拟合时间长。综合以上考虑，本文提出了一种考虑 DG 随机性的多目标规划方法。该方法引入了机会约束规划模型，以 DG 的经济性指标（含网损成本、运行成本、购电成本及政府补贴）、电能质量指标、环保性指标作为目标函数，并在规划过程中考虑了 DG 的时序特性，以多元联合概率分布函数表示多种 DG 的概率分布，同时引入了支持向量机算法并结合随机模拟技术对含随机变量的不确定性函数进行拟合，采用多目标粒子群算法求得 Pareto 非劣解集并运用理想点法求出典型规划方案。

1　DG 模型

1.1 风机模型

目前一般认为风速 v 服从 Weibull 分布[12]：

$$f(v)=\frac{k}{c}\left(\frac{v}{c}\right)^{k-1}\exp\left[-\left(\frac{v}{c}\right)^{k}\right] \tag{1}$$

其中，c 和 k 分别为尺度参数和形状参数，可以根据现场实测风速的历史数据采用最小二乘法辨识。风力发电机输出功率 P_{WPG} 与风速 v 之间的函数关系可近似描述为[13]

$$p_{\mathrm{WPG}}=\begin{cases}0 & v<v_{\mathrm{ci}}\text{或 } v\ge v_{\mathrm{co}}\\ \dfrac{v^3-v_{\mathrm{ci}}^3}{v_{\mathrm{r}}^3-v_{\mathrm{ci}}^3}P_{\mathrm{r}} & v_{\mathrm{ci}}\le v<v_{\mathrm{r}}\\ P_{\mathrm{r}} & v_{\mathrm{r}}\le v<v_{\mathrm{co}}\end{cases} \tag{2}$$

式中：P_{r} 为风电发电机的额定功率；v_{r}、v_{ci}、v_{co} 分别为额定风速、切入风速和切出风速。若风电机组中含有足够的电容器自动投切装置并采用恒功率因数控制策略，则潮流计算中通常把风机简化为 PQ 节点处理且无功功率为 $Q_{\mathrm{WPG}}=P_{\mathrm{WPG}}\cdot\tan\varphi$，式中 φ 为功率因数角。

1.2 光伏发电模型

太阳辐照度可近似看成 Beta 分布，其概率密度分布为[14]

$$f\left(\frac{r}{r_{\max}}\right)=\frac{1}{B(\alpha,\beta)}\left(\frac{r}{r_{\max}}\right)^{\alpha-1}\left(1-\frac{r}{r_{\max}}\right)^{\beta-1} \tag{3}$$

式中：$r_{\max}$(W/m^2)为该时段内太阳最大辐照度；α、β 为 Beta 分布的形状参数。光伏发电系统输出有功功率可以通过光照强度计算[15]

$$P_{\mathrm{p}}=P_{\mathrm{STC}}\frac{I_{\mathrm{ING}}}{I_{\mathrm{STC}}}[1+K(T-T_{\mathrm{r}})] \tag{4}$$

式中：P_{p} 是光伏发电的输出功率；P_{STC} 是标准测试条件下(1 kW/m^2，光伏电池温度：25 ℃)光伏发电的输出功率；I_{ING} 是实际光照强度，可以通过太阳辐照度求出；I_{STC} 是标准测试光照强度；K 是温度系数；T 是光伏模块温度(一般近似等于环境温度)；T_{r} 是参考温度。

综上，太阳能电池方阵输出功率 P_{p} 的概率密度函数为

$$f(P_{\mathrm{p}})=\frac{\Gamma(\alpha+\beta)}{R_{\mathrm{SOLAR}}\Gamma(\alpha)\Gamma(\beta)}\left(\frac{P_{\mathrm{p}}}{R_{\mathrm{SOLAR}}}\right)^{\alpha-1}\left(1-\frac{P_{\mathrm{p}}}{R_{\mathrm{SOLAR}}}\right)^{\beta-1} \tag{5}$$

式中，R_{SOLAR} 为太阳能电池方阵最大输出功率。对于太阳能电池方阵，一般采用恒功率因数控制方式。为了避免给系统造成无功负担，一般取功率因数为 1，此时，$Q_{\mathrm{SOLAR}}=0$。

1.3 考虑风光时序特性的联合概率分布

考虑风光随机性联合概率分布函数可表示为

$$F(v,r')=\int_{-\infty}^{v}\int_{-\infty}^{r'}f(v,r')\mathrm{d}v\mathrm{d}r' \tag{6}$$

式中，$f(v, r')$为风光联合概率密度函数，关于 v 的边缘密度函数为

$$f_v(v)=\int_{-\infty}^{+\infty}f(v,r')\mathrm{d}r'=\frac{k}{c}\left(\frac{v}{c}\right)^{k-1}\exp\left[-\left(\frac{v}{c}\right)^{k}\right] \tag{7}$$

关于 r'的边缘密度函数为

$$f_{\mathrm{r}}(r')=\int_{-\infty}^{+\infty}f(v,r')\mathrm{d}v=\frac{1}{B(\alpha,\beta)}\left(\frac{r}{r_{\max}}\right)^{\alpha-1}\left(1-\frac{r}{r_{\max}}\right)^{\beta-1} \tag{8}$$

以某地区典型年的风光数据为统计样本进行拟合分析，即可以得出考虑风光时序特性的联合概率密度函数曲面的大致形状。

2 基于机会约束规划的 DG 规划模型

2.1 DG 规划的数学模型

2.1.1 目标函数

(1) 经济性指标

本文主要从网损、运行、购电及政府补贴四个方面考虑 DG 并网的经济性指标。

$$C_{\text{all}} = C_{\text{L}} + C_{\text{DG}} + C_{\text{pur}} - C_{\text{gov}} \tag{9}$$

式中：C_{all} 为经济总成本；C_{L} 为配电网损成本；C_{DG} 为 DG 的运行总成本；C_{pur} 为购电成本；C_{gov} 为政府补贴。

网络损耗成本的表达式为

$$C_{\text{L}} = C_{\text{e}} \sum_{i=1}^{l} R_i \frac{P_{\text{L}i}^2 + Q_{\text{L}i}^2}{V_i^2} T_{\text{L max\_}i} \tag{10}$$

式中：C_{e} 为单位电价，元/kW·h；l 为总支路数；$T_{\text{Lmax\_}i}$ 为支路 i 的年最大负荷损耗小时数；R_i 为支路 i 的电阻；$P_{\text{L}i}$ 为支路 i 传输的有功功率；$Q_{\text{L}i}$ 为支路 i 传输的无功功率；V_i 为支路 i 的末端节点电压。

本文假设 DG 并网所需的燃料均为可再生能源，故燃料费用为零[17]。此时，DG 的运行总成本表达式为[18]

$$C_{\text{DG}} = \sum_{j=1}^{M_{\text{DG}}} P_{\text{Gen}} C_{\text{eDG}} T_{\text{DGmax}} \tag{11}$$

式中：P_{Gen} 是风力发电机组输出的额定有功功率；C_{eDG} 为 DG 的单位电量成本；T_{DGmax} 是 DG 的最大发电小时数；M_{DG} 为接入配电网的 DG 总个数。

DG使购电出现了除常规电源外的另一种选择。因此，本文将 DG 的供电费用和配电网规划后网损下降的部分作为购电节约的成本加入目标函数中。购电成本的表达式为[18]

$$C_{\text{pur}} = C_{\text{e}}(P_{\text{LA}} - P_{\Sigma\text{DG}} - \Delta P_{\text{loss}}) T_{\text{Lmax}} \tag{12}$$

式中：P_{LA} 为电网总容量；$P_{\Sigma\text{DG}}$ 为 DG 的总有功输出；ΔP_{loss} 为规划前后的有功网损之差；T_{Lmax} 为最大负荷年利用小时数。

政府补贴的表达式为

$$C_{\text{gov}} = \sum_{i=1}^{M_{\text{DG}}} C_{\text{eg\_}i} S_{\text{DG}i} \tag{13}$$

式中：$C_{\text{eg\_}i}$ 是第 i 种 DG 单位电量的政府补贴；$S_{\text{DG}i}$ 是第 i 种 DG 的容量。

(2) 电能质量指标

电能质量指标考虑了节点电压偏差，即计算首节点电压与电网其他节点电压差中的最大值，表达式为

$$\Delta V = \max\left|V_i - V_0\right|,\ i = 1, \cdots, N \tag{14}$$

式中：N 为节点总数；V_i、V_0 分别代表第 i 个节点及首节点的电压幅值。

(3) 环保性指标

DG 并网可以减少发电量和网损降低引起的两部分污染气体排放。本文将安装和未安装 DG 时，第 i 种污染气体(CO_2，SO_2，NO_X 等)排放量的比值定义为 DG 的环境效益 $EIRI_i$，表达式为[19]

$$EIRI_i = \frac{PE_{i\text{DG}}}{PE_{i\text{DG}0}} \tag{15}$$

式中，$PE_{i\text{DG}}$ 和 $PE_{i\text{DG}0}$ 分别代表安装和未安装 DG 时，第 i 种污染气体的排放量，且采用式(16)~式(17)计算：

$$PE_{i\text{DG}} = EG_{\text{A}}(AE)_i + \sum_{k=1}^{H}(EDG)_k (AE)_{ik} \tag{16}$$

$$PE_{i\text{DG}0} = EG_{\text{A}0}(AE)_i \tag{17}$$

其中：$(EG)_{\text{A}0}$ 和 $(EG)_{\text{A}}$ 分别为未装和安装 DG 时，传统发电机的总有功出力（本文认为未装 DG 时，配电网有功由传统发电机提供，安装 DG 后，配电网除 DG 外的有功缺额由传统发电机提供）；$(AE)_j$ 为传统发电机单位出力时，排放出第 i 种污染气体的量；$(AE)_{ik}$ 为第 k 台 DG 产生单位有功出力时释放的第 i 种污染气体的量；$(EDG)_k$ 为第 k 台 DG 的有功出力；H 为 DG 的台数。

由于发电厂向大气中排放多种污染气体，因此，定义包含所有污染气体的综合指标可定义为

$$EIRI = \sum_{i=1}^{NP}(EI)_i (EIRI)_i \tag{18}$$

式中：$(EI)_i$ 为第 i 种污染气体的权重因子；NP 为污染气体总的种类。$(EI)_i$ 满足关系式 $0 \le (EI)_i \le 1$ 和 $\sum_{i=1}^{NP}(EI)_i = 1$。

2.1.2 约束条件

(1) 等式约束

考虑了功率平衡方程

$$\begin{cases} P_{i-1}-R_{i-1}(P_{i-1}^2+Q_{i-1}^2)/U_{i-1}^2-P_{li}+P_{\mathrm{DG}i}-P_i=0 \\ Q_{i-1}-X_{i-1}(P_{i-1}^2+Q_{i-1}^2)/U_{i-1}^2-Q_{li}+Q_{\mathrm{DG}i}-Q_i=0 \end{cases} \tag{19}$$

式中：P_i 和 Q_i 分别为节点 i 的有功和无功注入量；U_i 为节点 i 的电压幅值；$P_{\mathrm{DG}i}$ 和 $Q_{\mathrm{DG}i}$ 分别为 DG 注入节点 i 的有功和无功功率。

(2) 不等式约束

不等式约束考虑了节点电压限制、DG 容量限制、节点接入 DG 功率限制、并网节点个数限制、节点接入同种 DG 类型个数限制以及线路传输功率限制。

$$\begin{cases} V_{i\min}\le V_i\le V_{i\max} \\ 0<S_{\Sigma\mathrm{DG}}<S_{\mathrm{L}} \\ 0\le P_{\mathrm{DG}i}\le P_{i\max} \\ \sum_{i=1}^{N_{\mathrm{nod}}-1}U_{ij}-D_j\le 0 \\ \sum_{j=1}^{D_j}U_{ij}-1\le 0 \\ P_l-P_{l\max}\le 0, l=1,\cdots,N \end{cases} \tag{20}$$

式中：$V_{i\max}$ 和 $V_{i\min}$ 分别为 V_i 的上下限；$S_{\Sigma\mathrm{DG}}$ 为全网允许接入的 DG 总容量；S_{L} 为电网负荷总容量的 10%；$P_{\mathrm{DG}i}$ 为节点 i 安装的 DG 有功容量；$P_{i\max}$ 为节点 i 允许安装的 DG 最大有功容量；U_{ij} 代表在 i 节点安装第 j 种 DG 的个数；N_{nod} 为节点数；D_j 为第 j 种 DG 安装最大节点数。P_l、$P_{l\max}$ 分别为支路 l 的传输功率和传输功率上限。

2.2 基于机会约束规划模型的 DG 规划模型

机会约束规划(Stochastic Chance-constrained Programming，SCCP)[16]的显著特点是约束条件至少以一定的置信水平成立，其实质上是决策者考虑所作决策在最不利的情况下发生时可能不满足约束条件而采取的一种原则，即允许所作决策在一定程度上不满足约束条件，只要求该决策使约束条件成立的概率不小于某一置信水平，而目标函数值通常采用悲观估计法得出。

机会约束规划模型通常表示为

$$\begin{aligned} &\max f_{\mathrm{av}} \\ &\text{s.t.} \\ &\Pr o(h_k(x,\eta)=0)>\alpha_1,\ \ (k=1,2,3...) \\ &\Pr o(\mathrm{g}_k(x,\eta)\le 0)>\alpha_2,\ \ (k=1,2,3...) \\ &\Pr o(f(x,\eta)>f_{\mathrm{av}})>\beta \end{aligned} \tag{21}$$

上述模型表示目标函数的置信水平至少为 β，且等式约束条件 $h(x,\eta)$的置信水平至少为 α_1，不等式约束条件 $g(x,\eta)$满足的置信水平为 α_2 的情况下，f_{av} 所能取得的极大值。

对于 DG 规划模型，式(21)中：f_{av}=[C_{all}, ΔV, $EIRI$]，$h(x,\eta)$为式(19)，$g(x,\eta)$为式(20)。

3　混合智能算法求解 DG 规划模型

3.1 随机模拟技术及支持向量机

随机模拟技术通过计算机模拟一些具有确定概率分布的样本，并利用样本数据的验证统计实现对具体指标的评估。虽然随机模拟技术只能得到统计结果而非精确结果，但是在实际应用中，随机模拟技术却是用来解决传统数学方法难以或者无法解决的问题（如机会约束规划模型）的有效工具[20]。

支持向量机(Support Vector Machine，SVM)是以 Vapnik 创建的统计学习理论(Statistical Learning Theory，STL)为基础的一种新颖的机器学习方法[21]。传统的统计学习算法只是追求经验风险的最小化，容易导致“过学习”，泛化能力差。而 SVM 以训练误差作为优化问题的约束条件、置信范围值作为优化目标，基于结构风险最小准则，在高维特征空间中求解凸优化问题，得到全局最优解，泛化能力强。同时，SVM 调整参数少且模型结构由最能提供信息特征的支持向量点反映，可以有效降低建模的复杂性。本文通过随机模拟产生输入输出数据作为训练样本，得到 SVM 的回归拟合模型以逼近不确定函数。SVM 拟合的具体流程如图 1 所示。

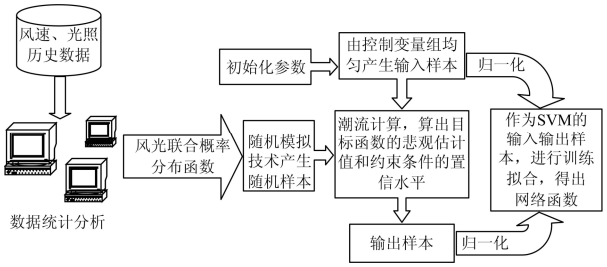

图 1 SVM 拟合流程图

Fig. 1 Fitting flow diagram of SVM

3.2 多目标粒子群算法及理想点法选择策略

粒子群算法(Particle Swarm Optimization，PSO)最早由 Kennedy 和 Eberhart 源于对鸟类捕食行为的研究提出[22-23]。PSO 算法用位置、速度和适应度三项指标表示粒子的特征。多目标粒子群算法(Multi-Objective Particle Swarm Optimization，MOPSO)以具有最优适应值粒子组的位置期望值作为全局最优位置[24]，个体最优粒子则根据拥挤距离在该粒子的最优适应值组中以一定概率随机选取或者取该粒子的最优适应值组的位置期望值。粒子在解空间的运动，通过跟踪个体极值和群体极值更新

个体位置，从而实现个体在可解空间中的寻优，最终得到的粒子群即为多目标模型的 Pareto 前沿。

粒子群算法在解决多目标上具有明显的优势，实际应用表明，只要策略选择适当，各粒子能够以不同的方向不断逼近 Pareto 前沿，最终求得的非劣决策集具有良好的分布性。但是如何按实际对某个目标的偏好程度在非劣解集中进行工程选择也是研究过程中的重点。为此，本文决定采用理想点法对求得的非劣解集进行筛选。

理想点指的是由各目标最优解所形成的目标函数向量组，理想点并不一定处于 Pareto 前沿上。理想点法是以求得的 Pareto 边沿到理想点的最小距离为目标求得工程应用解的选择策略。但在实际运用中，理想点法未考虑到多个目标之间的量纲问题，当存在多个目标量纲不同时，理想点法得到的解无法反映工程的需要。考虑到多个目标的实际需要，本文决定对各个目标函数值按照其量纲进行归一化，并对每个维距离进行加权处理（所取权重可按照实际运行中对某个目标的偏好程度设定）。综合考虑以上因素，理想点法选择策略的优化模型建立如下

$$\min d = \alpha_1 \left| f - f_{1\min} \right| + \alpha_2 \left| f - f_{2\min} \right| + \cdots + \alpha_n \left| f - f_{n\min} \right|$$

$$\sum_{k=1}^{n} \alpha_k = 1, \quad f \subseteq \gamma \tag{22}$$

式中：$f_{k\min}$ 为第 k 个目标的最优解($k = 1, 2, \cdots, n$)；α_k 为第 k 个目标函数的选择系数，默认为 $1/n$；γ 为求得的 Pareto 前沿；n 为目标函数个数。

3.3 混合智能算法

在利用 MOPSO 算法求解机会约束规划问题时，需要利用抽样技术对随机函数进行估算，即通过多次潮流计算得到多种 DG 出力情况下的各个目标函数值，进而由随机模拟和大数原理得出其置信水平。但是估计值是否贴近实际取决于仿真的次数，而大量的仿真将导致优化时间剧增；此外，在 MOPSO 算法中，初始化时要用到随机模拟技术来实现检验解的可行性，并在每一次迭代过程中也需利用它检验每个粒子的可行性，当粒子数目和迭代次数很大时，利用随机模拟进行估计非常耗时。

在实际应用中，算法的执行效率是一个不容忽视的问题。而 SVM 在函数逼近中已取得很好的效果，本文在使用 MOPSO 求解多目标优化模型前，首先利用 SVM 技术对模型的输入输出分别进行了函数拟合，并将训练好的网络参数直接用于 MOPSO 粒子适应度求解，节省了大量的随机模拟仿真耗时。算法具体流程图如图 2 所示。本文所提出的混合智能算法步骤如下：

(1) 由 Homer 软件得出风速、光照强度的时序数据，根据式(1)，式(3)采用最小二乘辨识法的概率分布函数的参数，并随机抽样得出随机样本。

(2) 输入网络参数和算法参数，由控制变量组（DG 并网节点位置及其容量）分类均匀产生 SVM 输入样本 X，对于每组输入样本 X，分别用随机模拟技术得出目标函数组的悲观估计值 F_{eva} 及约束条件满足的置信水平 β，以此作为 SVM 的输出样本。

(3) 对输入样本和输出样本进行归一化处理，并利用 SVM 训练拟合，得出输入与输出的网络函数 $F(X)$。

(4) 设定 MOPSO 的初始化参数，初始化粒子位置 X_1 和速度 v_1，检验是否越限，同时离散化初始位置，令迭代次数 $t = 1$。

(5) 以具有最优适应值粒子组的位置期望值作为全局最优位置 X_{t_gbest}，并计算每个粒子的拥挤距

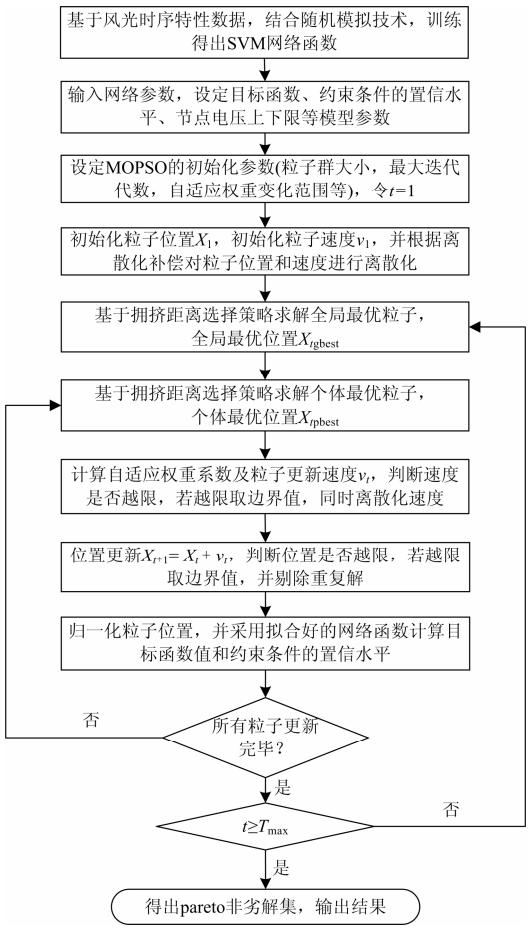

图 2 基于 SVM-MOPSO 的混合智能算法流程图

Fig. 2 Flow chart of the hybrid intelligent algorithm based on SVM-MOPSO

离，个体最优粒子则根据拥挤距离在该粒子的最优适应值组中以一定概率随机选取或者取该粒子的最优适应值组的位置期望值 X_{t_pbest}。

(6) 根据当前迭代代数求解自适应惯性权重系数，由个体最优位置 X_{t_pbest}，全局最优位置 X_{t_gbest} 求解各个粒子速度 v_t，更新粒子位置 $X_{t+1}=X_t+v_t$，检验是否越限并离散化，剔除重复解。

(7) 用(3)得出的 SVM 网络函数 $F(X)$求解满足目标函数置信水平下的目标函数值 F_{eva} 以及约束条件的置信水平 β_t，检验约束条件的置信水平 β 是否满足初始设定($\beta \geq \beta_{set}$)，若不满足，保持粒子原始位置不变 $X_{t+1}=X_t$。

(8) 若 $t \geq T_{max}$(T_{max} 为最大迭代代数)，算法结束，否则返回到(5)。

4　算例分析

采用 IEEE-33 节点配电系统，基于中国气象科学数据共享网的月平均气象数据（包括风速、光照强度及温度），由 Homer 软件模拟离散得出广东某地区（经纬度为东经 117°04′，北纬 23°42′）一年的风光数据如图 3(a)、图 3 (b)所示，全年月平均温度数据见图 3(c)。

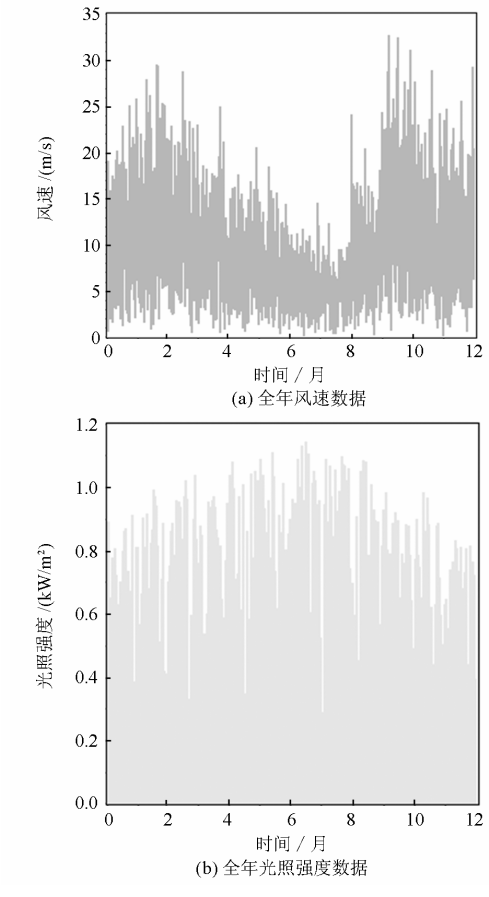

(a) 全年风速数据

(b) 全年光照强度数据

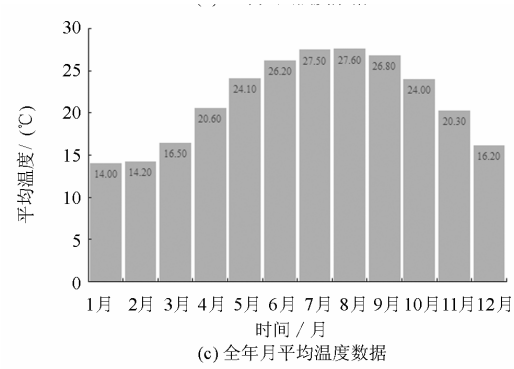

(c) 全年月平均温度数据

图 3 广东某地区全年风光及温度数据

Fig. 3 Annual data of wind, sunlight and temperature in an area of Guangdong province

考虑到该地区的负荷水平及风光储量分布情况，本文拟在 5 个节点并入风、光电源，其中 3 个为风力发电，2 个为光伏发电。风机采用 Generic 通用型，设置容量优化步长为 100 kW，其技术参数如下：切入风速 v_{ci} 为 4 m/s，切出风速 v_{co} 为 25 m/s，额定风速 v_r 为 14 m/s；采用最小二乘法对数据统计拟合分析，风速分布曲线的形状参数 k 为 1.99，尺度参数 c 为 10.64 m/s；光伏发电板单片功率为 1 kW，设置容量优化步长设为 100 kW。风能发电最大容量取 500 kW，光伏发电最大容量取 500 kW，节点电压标幺值的上下限约束分别为 1.07 和 0.93。

SVM 采用径向基核函数，设置目标函数置信水平 $\beta_1=\beta_2=\beta_3=0.90$，约束条件置信水平 $\alpha=0.99$，粒子群大小为 200，经过 100 代优化，得出目标函数值的 Pareto 分布曲面如图 4 所示。由图 4 结果可看出本文算法求得的 Pareto 前沿面具有良好的分布性。

根据理想点法在求得的非劣解集中选择最优解，设定 α_k=1/3，也可按实际工程需求，设置合适的 α_k 值求得相应的适应于实际运行的最优解。表 1 为按 α_k 值的均匀变化选择的典型规划解，其中，方案 1 为推荐理想点规划解。

为验证优化算法的有效性，在同等条件下采用 NSGA_II 求解模型，所得结果与本文算法结果对比，后者求得的 Pareto 前沿面具有更显著的分布性和最优性，见图 5 和表 2。

另外，分别利用随机模拟技术、混合智能算法 1(BP-MOPSO)以及混合智能算法 2(SVM-MOPSO)进行拟合求解，三种算法结果对比如表 3 所示。

进一步改变模型的目标函数置信水平和约束条件置信水平，采用拟合效果更好的混合智能算法 2 进行求解，得到优化结果见表 4 所示。

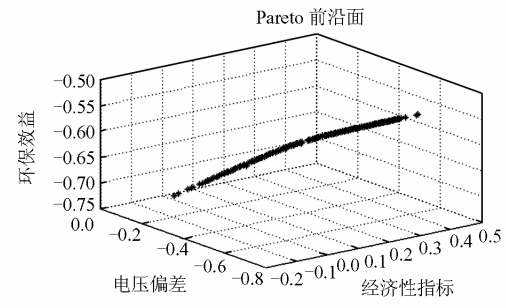

图 4　Pareto 前沿面

Fig. 4 Frontier of Pareto

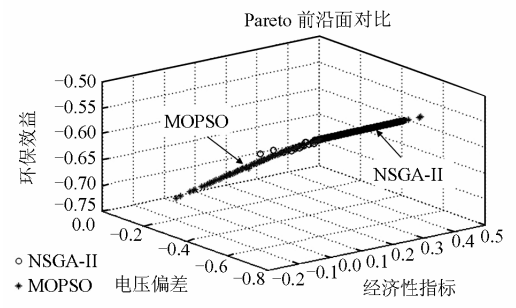

图 5　Pareto 前沿面对比

Fig. 5 Contrast of Pareto frontier

表 1 Pareto 分布的典型规划解

Table 1 Typical planning solution of Pareto distribution

规划方案	DG 并网节点及容量					规划目标		
	风电			光电		经济指标/万元	电压偏差/kV	环保指标
方案 1（理想点规划解）	13(400)	7(300)	22(400)	19(400)	8(400)	656.97	1.392 0	0.947 6
方案 2	14(400)	8(300)	20(400)	19(400)	7(400)	676.51	1.387 6	0.947 7
方案 3	15(400)	10(300)	22(400)	19(400)	8(400)	708.38	1.380 0	0.948 0
方案 4	15(400)	12(300)	21(400)	21(400)	9(400)	738.58	1.373 5	0.948 7
方案 5	17(400)	14(300)	21(400)	19(400)	8(400)	767.67	1.362 4	0.948 5

注：各方案中“( )”外为 DG 规划候选节点编号；“( )”内为 DG 规划容量，单位 kW。

表 2 两种算法理想点规划解的比较

Table 2 Comparison of ideal point planning solution between two algorithms

算法	DG 并网节点及容量					规划目标		
	风电			光电		经济指标/万元	电压偏差/kV	环保指标
NSGA-II	14(400)	7(300)	22(400)	19(400)	7(300)	724.06	1.380 8	0.948 1
MOPSO	13(400)	7(300)	22(400)	19(400)	8(400)	656.97	1.392 0	0.947 6

表 3 不同算法 DG 规划结果对比

Table 3 Contrast of DG planning results based on different algorithms

算法	理想点规划解		规划目标			拟合时间/s	规划计算时间/s
	风电	光电	经济指标/万元	电压偏差/kV	环保指标		
随机机会约束规划算法	11(500),24(400),11(500)	15(300),9(400)	810.56	1.406 7	0.970 2	——	6 582.97
混合智能算法 1(BP-MOPSO)	16(400),22(200),12(0)	11(200),27(400)	795.26	1.164 4	0.950 0	10.30	1 175.51
混合智能算法 2(SVM-MOPSO)	13(400),7(300),22(400)	19(400),8(400)	656.97	1.392 0	0.947 6	0.54	339.74

表 4 不同置信水平的 DG 规划结果对比

Table 4 Planning results comparison of difference confidence levels

α	β	DG 并网节点及容量		规划目标		
		风电	光电	经济指标/万元	电压偏差/kV	环保指标
0.99	0.90	13(400),7(300),22(400)	19(400),8(400)	656.97	1.392 0	0.947 6
0.99	0.95	7(300),13(400),22(400)	8(400),19(400)	657.31	1.395 4	0.951 2
0.99	0.99	7(300),13(400),22(400)	8(400),19(400)	768.00	1.426 5	0.950 0

由表 3 可以看出，本文算法避免了在 PSO 寻优迭代过程中对每一代的每个粒子都进行潮流计算，只需在为回归拟合模型产生训练样本时进行较少的潮流计算，混合智能算法 1 计算时间由 6 582.97 s

缩短到 1 175.51 s，而混合智能算法 2 的仅为 339.74 s，分别减少到原先的17.86%和 5.16%，大大提高了求解效率。在训练拟合模型时，BP 神经网络的训练时间比 SVM 算法的要长，分别为 10.30 s 和 0.54 s，将优化结果进行比较，可知 SVM 算法回归拟合的精度跟速度都比 BP 神经网络更好。

从表 4 可以看出，当模型中的目标函数置信水平增加而约束条件置信水平不变时，求解到优化方案的优化目标值随之变大，倾于保守。

5　结论

本文从配电网实际运行要求入手，以经济性指标、电能质量指标以及环保性指标为目标函数，基于机会约束规划理论，搭建了多目标配电网风光并网规划模型，并考虑时序特性建立了风光联合概率分布，提出随机模拟、SVM 算法和 MOPSO 相结合的混合智能算法。算例分析结果表明，本文所提模型和方法能有效节约规划成本，改善电压分布，同时具有良好的环保效益，算法合理有效。

为提高算法的工程实用性，本文还引入了目标函数和约束条件的置信水平，同时基于 Pareto 前沿技术，采用 MOPSO 求解多目标优化问题，算法执行效率高，求得的非劣解集具有较好的分布性和最优性，不失一般性，采用了理想点法选择策略，决策人员可以采用主观偏好确定各目标的权重系数，得到合适的规划结果。为降低算法规模，本文尚未考虑负荷变动的影响，对于考虑负荷变动下的 DG 规划问题，尚待进一步研究。

参考文献

[1] 邓威, 李欣然, 李培强, 等. 基于互补性的间歇性分布式电源在配网中的优化配置[J]. 电工技术学报, 2013, 28(6): 216-225.
DENG Wei, LI Xin-ran, LI Pei-qiang, et al. Optimal allocation of intermittent distributed generation considering complementarity in distributed network[J]. Transactions of China Electrotechnical Society, 2013, 28(6): 216-225.

[2] 付丽伟, 王守相, 张永武, 等. 多类型分布式电源在配电网中的优化配置[J]. 电网技术, 2012, 36(1): 79-84.
FU Li-wei, WANG Shou-xiang, ZHANG Yong-wu, et al. Optimal selection and configuration of multi-types of distributed generators in distribution network[J]. Power System Technology, 2012, 36(1): 79-84.

[3] 于青, 刘刚, 刘自发, 等. 基于量子微分进化算法的分布式电源多目标优化规划[J]. 电力系统保护与控制, 2013, 41(14): 66-72.
YU Qing, LIU Gang, LIU Zi-fa, et al. Multi-objective optimal planning of distributed generation based on quantum differential evolution algorithm[J]. Power System Protection and Control, 2013, 41(14): 66-72.

[4] 李亮, 唐巍, 白牧可, 等. 考虑时序特性的多目标分布式电源选址定容规划[J]. 电力系统自动化, 2013, 37(3): 1-7.
LI Liang, TANG Wei, BAI Mu-ke, et al. Multi-objective locating and sizing of distributed generators based on time-sequence characteristics[J]. Automation of Electric Power Systems, 2013, 37(3): 1-7.

[5] 庄园, 王磊. 分布式电源在配电网络中优化选址与定容的研究[J]. 电力系统保护与控制, 2012, 40(20): 73-78.
ZHUANG Yuan, WANG Lei. Research of distributed generation optimal layout and capacity confirmation in distribution network[J]. Power System Protection and Control, 2012, 40(20): 73-78.

[6] 刘学平, 刘天琪, 王剑. 基于小生境的配电网多目标分布式电源规划[J]. 电网技术, 2010, 34(10): 126-130.
LIU Xue-ping, LIU Tian-qi, WANG Jian. Niche-based multi-objective distributed generators planning in distribution network[J]. Power System Technology, 2010, 34(10): 126-130.

[7] NEKOOEI K, FARSANGI M M, NEZAMABADI-POUR H, et al. An improved multi-objective harmony search for optimal placement of DGs in distribution systems[J]. IEEE Trans on Smart Grid, 2013, 4(1): 557-567.

[8] 麻秀范, 崔换君. 改进遗传算法在含分布式电源的配电网规划中的应用[J]. 电工技术学报, 2011, 26(3): 175-181.
MA Xiu-fan, CUI Huan-jun. An improved genetic algorithm for distribution network planning with distributed generation[J]. Transactions of China Electrotechnical Society, 2011, 26(3): 175-181.

[9] 徐迅, 陈楷, 龙禹, 等. 考虑环境成本和时序特性的微网多类型分布式电源选址定容规划[J]. 电网技术, 2013, 37(4): 914-921.
XU Xun, CHEN Kai, LONG Yu, et al. Optimal site selection and capacity determination of multi-types of distributed generation in microgrid considering environment cost and timing characteristics[J]. Power System Technology, 2013, 37(4): 914-921.

[10] 曾鸣, 张鲲, 周飞. 基于多目标静态模糊模型的分布式电源规划[J]. 电网技术, 2013, 37(4): 954-959.
ZENG Ming, ZHANG Kun, ZHOU Fei. Distributed generation planning based on multi-objective static fuzzy model[J]. Power System Technology, 2013, 37(4):

954-959.

[11] 王茜, 张粒子. 采用 NSGA-II 混合智能算法的风电场多目标电网规划[J]. 中国电机工程学报, 2011, 31(19): 17-21.
WANG Qian, ZHANG Li-zi. Multi-objective transmission planning associated with wind farms applying NSGA-II hybrid intelligent algorithm[J]. Proceedings of the CSEE, 2011, 31(19): 17-21.

[12] BOWDEN G J, BARKER P R, SHESTOPAL V O, et al. The Weibull distribution function and wind power statistics[J]. Wind Engineering, 1983, 7(2): 85-98.

[13] 马溪原, 吴耀文, 方华亮, 等. 采用改进细菌觅食算法的风/光/储混合微电网电源优化配置[J]. 中国电机工程学报, 2011, 31(25): 17-25.
MA Xi-yuan, WU Yao-wen, FANG Hua-liang, et al. Optimal sizing of hybrid solar-wind distributed generation in an islanded microgrid using improved bacterial foraging algorithm[J]. Proceedings of the CSEE, 2011, 31(25): 17-25.

[14] 张美霞, 陈洁, 杨秀, 等. 考虑风光和负荷随机性的微网三相潮流计算[J]. 中国电机工程学报, 2013, 33(13): 101-107.
ZHANG Mei-xia, CHEN Jie, YANG Xiu, et al. Three-phase power flow calculation for microgrid with volatile wind power, photovoltaic power and load[J]. Proceedings of the CSEE, 2013, 33(13): 101-107.

[15] 丁明, 王波, 赵波, 等. 独立风光柴储微网系统容量优化配置[J]. 电网技术, 2013, 37(3): 575-581.
DING Ming, WANG Bo, ZHAO Bo, et al. Configuration optimization of capacity of standalone PV-wind-diesel-battery hybrid microgrid[J]. Power System Technology, 2013, 37(3): 575-581.

[16] CHARNES A, COOPER W W. Chance-constrained programming[J]. Management Science, 1959, 6(1): 73-79.

[17] 丁明, 王敏. 分布式发电技术[J]. 电力自动化设备, 2004, 24(7): 31-36.
DING Ming, WANG Min. Distributed generation technology[J]. Electric Power Automation Equipment, 2004, 24(7): 31-36.

[18] 叶德意, 何正友, 臧天磊. 基于自适应变异粒子群算法的分布式电源选址与容量确定[J]. 电网技术, 2011, 35(6): 155-160.
YE De-yi, HE Zheng-you, ZANG Tian-lei. Siting and sizing of distributed generation planning based on adaptive mutation particle swarm optimization algorithm[J]. Power System Technology, 2011, 35(6): 155-160.

[19] CHIRADEJA P, RAMAKUMAR R. An approach to quantify the technical benefits of distributed generation[J]. IEEE Trans on Energy Conversion, 2004, 19(4): 764-773.

[20] 江岳文, 陈冲, 温步瀛. 含风电场的电力系统机组组合问题随机模拟粒子群算法[J]. 电工技术学报, 2009, 24(6): 129-137.
JIANG Yue-wen, CHEN Chong, WEN Bu-ying. Particle swarm research of stochastic simulation for unit commitmen in wind farms integrated power system[J]. Transactions of China Electrotechnical Society, 2009, 24(6): 129-137.

[21] VAPNIK V. The nature of statistical learning theory[M]. New York: Springer, 1995.

[22] 路志英, 葛少云, 王成山. 基于粒子群优化的加权伏罗诺伊图变电站规划[J]. 中国电机工程学报, 2009, 29(16): 35-41.
LU Zhi-ying, GE Shao-yun, WANG Cheng-shan. Substation location planning of the weighted voronoi diagram based on particle swarm optimization algorithm[J]. Proceedings of the CSEE, 2009, 29(16): 35-41.

[23] 叶承晋, 黄民翔. 基于改进粒子群算法的分布式电源经济性最优规划[J]. 电力系统保护与控制, 2012, 40(19): 126-132.
YE Cheng-jin, HUANG Min-xiang. Distributed power optimally economical planning based on modified discrete particle swarm optimization algorithm[J]. Power System Protection and Control, 2012, 40(19): 126-132.

[24] 刘文颖, 谢昶, 文晶, 等. 基于小生境多目标粒子群算法的输电网检修计划优化[J]. 中国电机工程学报, 2013, 33(4): 141-148.
LIU Wen-ying, XIE Chang, WEN Jing, et al. Optimization of transmission network maintenance scheduling based on niche multi-objective particle swarm algorithm[J]. Proceedings of the CSEE, 2013, 33(4): 141-148.

收稿日期：2013-07-25

作者简介：

刘煌煌（1987-），男，硕士研究生，研究方向为电力系统规划、电力系统运行保护与控制；E-mail：liuhh1688@163.com

雷金勇（1982-），男，博士，高级工程师，从事新能源、分布式电源和微电网方面的研究工作；

蔡润庆（1988-），男，通信作者，硕士研究生，研究方向为电力系统规划、电力系统运行与控制。E-mail: cairunqingabc@163.com