

文章编号: 1000-8152(2009)10-1075-06

求解PMU多目标优化配置问题的非劣排序微分进化算法

彭春华, 孙惠娟, 郭剑峰

(华东交通大学 电气与电子工程学院, 江西南昌 330013)

摘要: 为实现电网完全可观测, 同时保证PMU(同步相量测量单元)的安装数目尽量少, 且系统的 $N-1$ 量测可靠性尽量高, 笔者提出了一种混合算法, 对电网中PMU进行多目标优化配置. 在此算法中, 通过将Pareto非劣排序操作与微分进化算法有机融合, 并对个体的排挤机制和变异策略进行改进以克服进化早熟和搜索不均匀的问题, 设计出了一种新的非劣排序微分进化算法对模型进行求解, 并采用模糊集理论提取出最优折中解. 最后以IEEE39母线系统为例进行了PMU多目标优化配置, 结果表明该方法可简单快速地实现全局多目标寻优, 找到更多更合理的PMU优化配置方案, 能得到准确而完整的Pareto最优前沿.

关键词: 多目标优化; PMU配置; 非劣排序; 微分进化; 模糊集

中图分类号: TM711 **文献标识码:** A

Non-dominated sorting differential evolution algorithm for multi-objective optimal PMU placement

PENG Chun-hua, SUN Hui-juan, GUO Jian-feng

(School of Electrical & Electronics Engineering, East China Jiaotong University, Nanchang Jiangxi 330013, China)

Abstract: For a power grid to be completely observable when employing a minimal number of placed phasor measurement units(PMU) to achieve the highest reliability of the $N-1$ measurements, we propose a new hybrid algorithm to optimize this PMU multi-objective placement problem. In this algorithm, the Pareto non-dominated sorting mechanism is integrated with the differential evolution algorithm; meanwhile the individual crowding mechanism and the mutation strategy are improved to cope with the premature convergence and the search bias. Moreover, fuzzy set theory is employed to extract the best compromise non-dominated solution. Both the Pareto-optimal solution and the desired Pareto front can be rapidly found by the proposed algorithm. This is demonstrated by the results in the application to the IEEE 39-bus systems.

Key words: multi-objective optimization; PMU placement; non-dominated sorting; differential evolution; fuzzy set

1 引言(Introduction)

近年来, 作为广域量测系统(WAMS)的核心组件, 基于全球定位卫星系统(GPS)技术和离散傅立叶变换(DFT)原理的同步相量测量单元(PMU)发展非常迅速^[1]. PMU能够提供统一时空坐标下的高精度电压和电流相量量测, 可显著改善电力系统量测可观测性和状态估计精度, 提高系统监控的实时性和准确性^[2]. 但根据目前情况, 对大电网中所有母线节点都安装PMU是不现实的. 从经济性和技术性等方面考虑, 如何用尽量少的PMU进行最合理的安装配置以实现全网各节点的完全可观测及量测冗余度最大化将具有很大的现实意义. 然而, PMU安装数量尽量少和量测冗余度尽量高是两个相互冲突的

目标, 对于这类多目标优化问题, 传统的解决方法是由决策者根据各目标的重要程度或偏好进行排序, 通过加权的方法使之转化为单目标优化问题, 然后采用单目标优化算法进行求解. 这种方法主要缺点是权值设定的客观合理性难以保证, 且对权值过分依赖, 导致解的稳定性和多样性不足, 有很大的局限性. 文献[3]对综合PMU配置数量最少化和量测冗余度最大化的多目标优化问题进行了研究, 通过非劣解排序遗传算法(NSGA)求取Pareto最优前沿. 由于NSGA存在运算速度慢、最优解多样性差和易早熟等缺陷, 限制了该方法的应用. 此外, 文中根据被重复观测的母线数来评价量测冗余度, 计算过程复杂且难以反映现实PMU故障情况.

基于上述分析,本文提出以简捷通用的 $N-1$ 可靠性检验来对PMU量测冗余度进行科学评价,并综合考虑PMU安装数目和量测冗余度之间的密切相关性,以实现全网完全可观测为前提,以PMU安装数尽量少和量测冗余度尽量高为原则建立PMU多目标优化配置数学模型,并提出一种新的基于Pareto非劣排序的微分进化算法对模型进行求解,从而得到PMU多目标优化配置方案的Pareto最优非劣解集.

2 PMU配置多目标优化问题(Multi-objective optimal problem of PMU placement)

2.1 多目标优化问题描述(Description of multi-objective optimal problem)

在工程实践中的优化问题大多是多目标优化问题(MOP),以在一组约束条件下的最小化多目标问题为例,多目标优化问题数学描述如下:

$$\begin{aligned} \min & f_i(X), i = 1, 2, \dots, N_{\text{obj}}, \\ \text{s.t.} & \begin{cases} X = (x_1, x_2, \dots, x_d) \in \mathbb{R}^d, \\ g_j(X) \leq 0, j = 1, 2, \dots, J, \\ h_k(X) = 0, k = 1, 2, \dots, K. \end{cases} \end{aligned} \quad (1)$$

其中: $f_i(X)$ 为目标函数, X 为 d 维决策向量, N_{obj} 为目标函数个数, $g_j(X)$ 为不等式约束函数, $h_k(X)$ 为等式约束函数.

MOP中各目标的度量标准往往不一致,且可能会相互制约,即改进其中某个目标值常会以损害其他目标为代价,因此一般不存在使所有目标函数都同时达到最优的绝对最优解,而只能在多目标之间进行协调和折衷处理,使各目标都尽可能达到最优.为了客观地评价多目标问题解的优劣性,在MOP中常用到如下定义:

对于决策向量 A, B :

1) Pareto占优(Pareto dominance): $A \prec B$ (A 占优 B)当且仅当

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

2) Pareto最优(Pareto optimal)或Pareto非劣(Pareto non-dominated): 解 A 是Pareto最优解(非劣解)当且仅当

$$\neg \exists X \in \mathbb{R}^d : X \prec A, \quad (3)$$

所有 Pareto 最优解的集合称 Pareto 最优解集(Pareto optimal set), 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(Pareto front). 因此,对MOP的求解

实际上是设法找到尽可能多的Pareto最优解,且对应的各目标向量在Pareto前沿中能均匀分布,以使得决策者的可选择域更大.

2.2 PMU多目标优化配置模型(Multi-objective optimal model of PMU placement)

本文中PMU优化配置目标对于一确定的 n 节点电网,以实现全网完全可观测为前提,使得PMU配置数目尽量少而冗余量测节点数 r 尽量多.

在此采用网络拓扑方法对电网可观测性进行分析.从图论的角度,可将电网看成是一个由诸多节点和边构成的拓扑图,分别对应于电网中母线和支路的集合.在电网中,若节点安装有PMU,则其电压相量及其关联支路的电流相量就可被直接测量;若节点虽未安装PMU,但其电压及其支路电流可根据基尔霍夫电流定律(KCL)和欧姆定理,利用相关节点和支路上已知的电压及电流相量计算获得,则称可被虚拟测量.在网络拓扑中,如果PMU直接测量节点以及虚拟测量节点能够涵盖全网所有节点,则说明该电网完全可观测^[4].

由此可推导出如下3项电网节点拓扑可观测性判据:

判据 1 若某节点安装有PMU,则该节点可观测,且该节点的各邻接节点也可观测;

判据 2 若某节点为可观测零注入节点的邻接节点,且该零注入节点的其他所有邻接节点均可观测,则该节点也可观测;

判据 3 若某零注入节点的所有邻接节点均可观测,则该零注入节点也可观测.

将网络拓扑信息用一个节点邻接关系矩阵(BM)和一个零注入节点数组(ZA)来表达,而PMU配置方案可用一个数组PA来表示.对于一个 n 节点电网, BM设计成一具有对角对称性的 $n \times n$ 阶矩阵, ZA和PA皆设计成一 n 维数组,矩阵BM和数组ZA, PA均采用二进制编码,构造如下:

$$\begin{cases} BM_{ij} = \begin{cases} 1, \text{节点}i\text{与节点}j\text{相邻接,} \\ 0, \text{节点}i\text{与节点}j\text{不邻接,} \end{cases} \\ ZA_i = \begin{cases} 1, \text{节点}i\text{为零注入节点,} \\ 0, \text{节点}i\text{不为零注入节点,} \end{cases} \\ PA_i = \begin{cases} 1, \text{节点}i\text{配置PMU,} \\ 0, \text{节点}i\text{未配置PMU,} \end{cases} \\ i = 1, 2, \dots, n, j = 1, 2, \dots, n. \end{cases} \quad (4)$$

电网中各节点的可观测性同样可用一个 n 维的二进制编码数组 $OA = OA_1, OA_2, \dots, OA_n$ 来表达,可得形式如式(5)的函数:

$$\begin{cases} OA = f_{\text{obs}}(PA, BM, ZA), \\ OA_i = \begin{cases} 1, & \text{节点}i\text{可观测}, \\ 0, & \text{节点}i\text{不可观测}, \end{cases} \\ i = 1, 2, \dots, n. \end{cases} \quad (5)$$

对于某一PMU配置方案, 通过反复调用上述拓扑可观测性判据对系统的所有节点进行可观测性判断和循环扫描, 系统可观测范围将会迅速扩散, 可观测节点数目逐渐增多, 若最终能够使得系统的所有节点均可观测, 则说明该PMU配置方案能实现电网完全可观测。

此外, 本文借鉴电力系统中广泛应用的 $N - 1$ 可靠性检验原则提出如下定义: 如果当所配置的全部PMU中任意一个出现故障时, 均能保持可观测的节点, 称之为冗余量测节点. 对于一个 n 节点电网, 若采用某PMU配置方案可存在 r 个冗余量测节点, 则该方案的 $N - 1$ 量测冗余度定义为: $D_r = r/n$. 则根据式(4)和式(5), PMU多目标优化配置模型为

$$\begin{cases} \min f_1 = \sum_{i=1}^n PA_i, \\ \min f_2 = n - r, \\ \text{s.t. } OA_i = 1, i \in \{1, 2, \dots, n\}. \end{cases} \quad (6)$$

寻求一种能准确高效地找到该模型Pareto最优解集的多目标优化算法是研究的关键所在。

3 非劣排序微分进化算法设计(NSDE algorithm design)

3.1 Pareto 非劣排序与选择(Pareto non-dominated sorting and selection)

传统的多目标优化算法主要是采用有加权、约束等方法, 将多目标问题转换为单目标优化问题进行简化求解, 具有很大的局限性. 近年来, 多目标进化算法(multi-objective evolutionary algorithms, MOEA)因其不需准确衡量各目标间的权重关系, 而是利用其强大的全局搜索能力找到最优解集的特点已成为研究热点, 其中最有效也是最常用的MOEA之一是NSGA-II算法, 它改进了常规的非劣排序遗传算法(NSGA)^[5], 采用Pareto非劣解快速排序、精英保留策略、以及基于解的排序等级和拥挤距离的选择算子, 使算法性能得到很大提高. 目前, NSGA-II算法已成功应用于诸多工程优化设计问题^[6,7], 其算法流程及Pareto非劣解排序操作过程可参考文献^[8].

在同一Pareto非劣排序等级中, 个体的拥挤距离越大, 说明其所处的区域越稀疏, 则该区域内的个体越有价值, 在进化选择过程中越应被保留。

在NSGA-II算法中正是根据这一原则进行选择操作的. 若设个体B的前后相邻两个个体分别为A和C, 在NSGA-II算法中, 个体B的拥挤距离(稀疏度) $D_c(B)$ 计算式定义如下:

$$D_c(B) = \sum_{i=1}^{N_{\text{obj}}} |f_i(A) - f_i(C)|. \quad (7)$$

其中 $f_i(A)$ 与 $f_i(C)$ 分别为个体A和C在第 i 个目标函数上的值. 而对于边界个体, 其拥挤距离定义为无穷大, 以保证边界个体无条件被选取进入下一代。

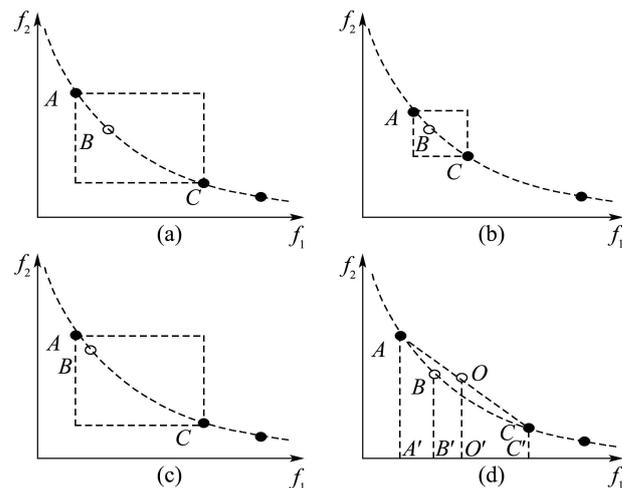


图 1 拥挤距离计算示意

Fig. 1 Crowding distance calculation

此计算式虽然简单快速, 但存在较大局限性. 以如图1所示的两目标优化问题为例, A, B和C为同一Pareto非劣排序等级内的个体, 按式(7)得出个体B的拥挤距离即为虚线四边形的长与宽之和. 很明显, 个体B在图1(a)中的稀疏度要优于图1(b)与图1(c), 然而按此计算方法只能判断出个体B在图1(a)中比在图1(b)中稀疏度更好, 但不能区分出个体B在图1(a)与图1(c)中的稀疏度差别. 这样就会使得一些稀疏度很好个体可能被淘汰, 而一些稀疏度并不好的个体却可能被保留下来, 导致随着进化代数的增加, 解的多样性和分布性劣化, 难以均匀而准确地收敛到Pareto前沿。

为此, 如图1(d)所示, 设个体A和C的中心点为O, 本文将处于A和C之间的个体B的拥挤距离 $D_c(B)$ 计算式改进为

$$D_c(B) = \sum_{i=1}^{N_{\text{obj}}} (|f_i(A) - f_i(C)| - |f_i(B) - f_i(O)|) = \sum_{i=1}^{N_{\text{obj}}} (|f_i(A) - f_i(C)| \times 0.5 + \dots \min[|f_i(A) - f_i(B)|, |f_i(B) - f_i(C)|]). \quad (8)$$

其中 $f_i(B)$ 与 $f_i(O)$ 分别为个体 B 和邻域中心 O 在第 i 个目标函数上的值。

式(8)能综合反映出个体 B 的稀疏度既与其在各目标函数上的邻域大小(用 $|f_i(A) - f_i(C)|$ 表示)有关, 又与分布均匀程度(用个体距邻域中心的距离 $|f_i(B) - f_i(O)|$ 表示)有关。即随着 $|f_i(A) - f_i(C)| \uparrow$ 或 $|f_i(B) - f_i(O)| \downarrow$, 则 $D_c(B) \uparrow$ 。采用式(8)能很容易判断出个体 B 在图1(a)中的稀疏度要优于图1(c)。

此外, 由于NSGA-II算法采用的是遗传算法的交叉和变异机制, 而遗传算法本身存在收敛不稳定、速度慢和容易早熟等缺陷, 因此NSGA-II算法同样也常存在着这些不足。基于此, 本文将引入微分进化操作替代NSGA-II算法中的遗传操作, 发展出了非劣排序微分进化(non-dominated sorting differential evolution, NSDE)算法。

3.2 微分进化算法(Differential evolution algorithm)

微分进化算法(DEA)是一种简单有效的智能优化计算方法, 该算法直接采用实数运算, 不需进行编码和解码操作, 收敛速度快, 稳定性好, 对各种非线性函数适应性强, 在诸多优化问题的求解过程中, 其性能被证明要优于遗传算法、粒子群优化、自适应模拟退火算法等其他算法^[9~11]。DEA流程的详细描述可参考文献[9], 此处不再赘述。在微分进化中, 若种群规模为 N_p , 对于第 G 代的每个目标个体向量 $X_{i,G}$, 一般可根据实际效果按式(9)、式(10)或式(11)等方式进行变异操作产生中间个体 $Y_{i,G+1}$:

$$Y_{i,G+1} = X_{r_3,G} + F \cdot (X_{r_1,G} - X_{r_2,G}), \quad (9)$$

$$Y_{i,G+1} = X_{\text{best},G} + F \cdot (X_{r_1,G} - X_{r_2,G}), \quad (10)$$

$$Y_{i,G+1} = X_{i,G} + F \cdot (X_{\text{best},G} - X_{i,G}) + F \cdot (X_{r_1,G} - X_{r_2,G}). \quad (11)$$

式中: $i, r_1, r_2, r_3 \in \{1, 2, \dots, N_p\}$, r_1, r_2 和 r_3 均随机选取, 且 $i \neq r_1 \neq r_2 \neq r_3$; $X_{\text{best},G}$ 为第 G 代的最佳个体向量; 变异尺度因子 F 为 $[0,2]$ 间的实常数。

根据各式的结构原理, 式(9)到式(11)分别命名为DE/rand/1、DE/best/1、DE/local-to-best/1等, 以区分微分进化中不同的变异策略。通过反复比较, 本文最终采用在式(10)中引入随机扰动因子得到式(12)所示的变异策略, 结果证明效果更好:

$$Y_{i,G+1} = X_{\text{best},G} + (F + 0.001 \cdot R) \cdot (X_{r_1,G} - X_{r_2,G}), \quad (12)$$

其中 R 为 $[0,1]$ 间的随机数。

然后, 通过式(13)进行交叉操作, 由目标个体向

量 $X_{i,G}$ 和中间个体向量 $Y_{i,G+1}$ 的分量交叉组合出一个下代候选个体 $Z_{i,G+1}$, 从而使种群保持多样性:

$$\begin{aligned} X_{i,G} &= (x_{i,1}, x_{i,2}, \dots, x_{i,d}), \\ Y_{i,G+1} &= (y_{i,1}, y_{i,2}, \dots, y_{i,d}), \\ Z_{i,G+1} &= (z_{i,1}, z_{i,2}, \dots, z_{i,d}), \end{aligned} \quad (13)$$

$$z_{i,j} = \begin{cases} x_{i,j}, & R_j > C_R, \\ y_{i,j}, & \text{其他}. \end{cases}$$

其中: $j \in \{1, 2, \dots, d\}$, R_j 为 $[0,1]$ 间的随机数, 交叉概率因子 C_R 为 $[0,1]$ 间的实常数。

3.3 NSDE算法流程(NSDE algorithm procedure)

针对PMU多目标优化配置问题, 本文基于上述改进的Pareto非劣排序与微分进化算法设计的NSDE优化算法流程如下:

初始父种群 P_1 由随机产生的 m 个各不相同的长度为 n 的二进制编码(1代表该位置配置PMU, 0代表不配置)个体组成, 初始子种群 S_1 为空。根据式(6)计算 P_1 中所有个体的各目标函数值, 对于不能实现全网完全可观测的个体, 其冗余量测节点数 r 直接用一个惩罚性的负数(如-100)表示。然后进行以下循环迭代过程:

当进化代数 $g \leq G_{\max}$ 时:

Step 1(种群混合) 将子种群 S_g 与父种群 P_g 混合成一个更大规模的临时种群 M_g , 为了保持种群的个体多样性, 应检验临时种群中是否有重复的个体, 若有则对该重复个体进行局部变异, 直至种群中的个体各不相同, 并由式(6)计算所有新生个体的各目标函数值。

Step 2(Pareto非劣排序) 按Pareto非劣排序策略, 比较种群 M_g 中各个体的目标函数值, 找出当前种群的Pareto非劣个体集合, 作为 $P_s(1)$, 然后将 $P_s(1)$ 中所有个体从当前种群中移出, 在剩余个体群中再找出新的Pareto非劣个体集合, 作为 $P_s(2)$, 依此类推, 直到所有个体都完成分级排序。然后, 按式(8)计算出各级中各个体的拥挤距离。

Step 3(父种群更新) 在一个空种群中按先后顺序依次填充入 $P_s(1), P_s(2), \dots$, 直到若进一步填充 $P_s(i)$ 后则种群规模将超过 m 时, 则改为对 $P_s(i)$ 中的个体按拥挤距离由大到小逐个填充, 直到种群规模正好等于 m 时则停止填充, 即形成新的父种群 P_{g+1} 。

Step 4(种群更新) 1) 锦标赛选优: 从 P_{g+1} 中按排序等级值越小越优先、同一等级则拥挤距离越大越优先的原则, 采用随机锦标赛的形式产生优选种群, 优选种群规模一般设置为父种群规模的一半左右。

2) 微分进化: 对以上优选种群采用3.2节中的DE变异和交叉机制, 得到新的子种群 S_{g+1} . 由于个体为二进制编码, 本文在此对式(12)得到的 $Y_{i,G+1} = (y_{i,1}, y_{i,2}, \dots, y_{i,d})$, 按“若 $y_{i,j} > 0.5$ 则 $y_{i,j} = 1$, 否则 $y_{i,j} = 0$ ”的原则进行编码校核.

Step 5 $g = g + 1$, 进入下一次循环.

最终得到的父种群即为多目标优化问题的Pareto最优解集.

3.4 最优折衷解(Best compromise solution)

实际运行中, 最终实施的方案一般只有一个, 因此决策者需要从Pareto最优解集中选取出一个最优折衷解. 在此, 可根据模糊集理论来确定最优折衷解^[12]. 每个Pareto解中各目标函数对应的满意度可用模糊隶属度函数来表示, 定义如下:

$$h_i = \begin{cases} 1, & f_i \leq f_i^{\min}, \\ \frac{f_i^{\max} - f_i}{f_i^{\max} - f_i^{\min}}, & f_i^{\max} > f_i > f_i^{\min}, \\ 0, & f_i \geq f_i^{\max}, \end{cases} \quad (14)$$

$i = 1, 2, \dots, N_{obj}.$

其中: f_i 为目标函数, N_{obj} 为目标函数个数, f_i^{\max} 和 f_i^{\min} 分别表示第 i 个目标函数的最大和最小值, h_i 为0或1时则分别代表对第 i 个目标函数值完全不满意或完全满意.

然后, 可采用式(15)求得Pareto解集中各解的标准化满意度为

$$h = \frac{1}{N_{obj}} \sum_{i=1}^{N_{obj}} h_i. \quad (15)$$

最后通过比较, 自动选取出具有最大 h 值的Pareto最优解作为最优折衷解.

4 算例及分析(Example and analysis)

为验证本文方法的有效性, 在此IEEE39母线系统(图2)为例进行PMU多目标优化配置. 取最大迭代次数为300、初始种群规模为100、变异尺度因子 F 为0.85、交叉概率因子 C_R 为0.5, 采用NSDE算法进行优化求解, 可一次性找到能综合实现PMU安装数尽量少和冗余量测节点数尽量多两目标的一系列Pareto最优解, 限于篇幅, 表1中仅列出了部分PMU多目标优化配置方案(其中 N_{pmu} , r 和 h 分别表示PMU数、 $N - 1$ 冗余量测节点数和标准化满意度).

从表1中可看出, 在全网完全可观测的前提下, 要提高量测冗余度, 则必须以增加PMU为代价. 对于IEEE39母线系统, 要实现全网完全可观测至少需要安装8个PMU, 此时冗余量测节点数为6; 若要完全实现全网 $N - 1$ 量测可靠性, 即冗余量测节点达

到100%, 则至少需要安装17个PMU. 各方案的优越性还可通过标准化满意度来评估, 当资金允许情况下, 应选择满意度尽可能高的PMU配置方案, 可提高每台PMU的性价比. 通过比较表1中各Pareto最优解的标准化满意度值, IEEE39母线系统的PMU配置最优折衷方案可选择(7, 8, 10, 12, 16, 18, 20, 22, 23, 25, 26, 29, 30). 可见, 本文的多目标优化方法可较大幅度地改善PMU优化配置方案选择的合理性和灵活性, 便于决策者根据实际情况需要选择最合适的配置方案.

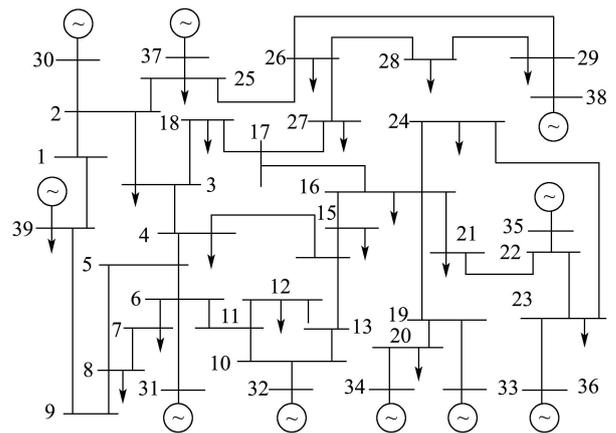


图2 IEEE39母线系统

Fig. 2 IEEE 39-bus system

表1 PMU多目标优化配置方案(IEEE39母线系统)

Table 1 The multi-objective optimal placement scheme of PMU(IEEE 39-bus system)

N_{pmu}	r	h	PMU配置方案
8	6	0.500	3,8,13,16,20,23,25,29
9	13	0.551	3,6,10,16,20,23,25,29,30
10	18	0.571	2,3,6,10,16,20,23,25,29,39
11	24	0.606	2,7,8,10,12,16,18,20,23,25,29
12	29	0.626	2,7,8,10,12,16,18,20,23,25,26,29
13	33	0.631	7,8,10,12,16,18,20,22,23,25,26,29,30
14	36	0.621	7,8,10,12,16,18,20,22,23,25,26,29,30,34
15	37	0.581	7,8,10,12,16,18,20,22,23,25,26,29,30,34,38
16	38	0.540	3,7,8,12,13,16,20,21,23,25,26,29,30,34,36,37
17	39	0.500	2,3,7,8,12,13,16,20,21,23,25,26,29,34,36,37,38

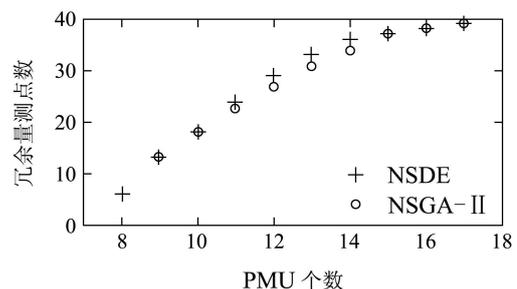


图3 Pareto前沿对比

Fig. 3 Comparison of Pareto fronts

为评价算法的性能改进,本文还采用了流行的NSGA-II算法对IEEE39母线系统进行多目标优化求解.在此,其最大迭代次数和初始种群规模依旧定为300和100,遗传操作的交叉概率取0.95,变异概率为0.05.最终得到的Pareto前沿如图3所示,图中Pareto前沿上的每个点,一般都对应着很多个Pareto最优解(即PMU配置方案).可见,NSGA-II算法没能找到采用最少PMU(8个)实现全网完全可观测的方案,并且在PMU安装数目为11,12,13,14时,均没能找到冗余量测节点最多的Pareto最优解.此外,上述计算过程皆是以MATLAB7.1为仿真环境(计算机为奔腾双核2.8 GHz,1 GB内存),NSGA-II与NSDE算法的运行时间分别为155 s与110 s.可见,相比于NSGA-II算法,采用本文提出的NSDE算法能更加快速、准确而完整地得到Pareto前沿.

5 结论(Conclusion)

本文提出的NSDE算法是将Pareto非劣排序操作与微分进化算法进行有机融合,并对进化过程中个体的排挤机制和变异策略进行了有效改进.对于在保证全网完全可观测的前提下,综合考虑了PMU安装数目和 $N-1$ 量测可靠性的电网PMU多目标优化配置问题的求解,该算法体现出优越的性能,可简单地实现全局多目标寻优,找到大量的Pareto最优解,得到准确而完整的Pareto前沿.所产生的PMU多目标优化配置方案灵活多样,合理可行,对于相关决策者根据实际情况进行科学选择具有现实的指导意义.此外,如何应用NSDE算法求解更多目标的PMU优化配置问题以及其他工程领域优化问题,值得进一步探讨和研究.

参考文献(References):

- [1] MILOSEVIC B, BEGOVIC M. Voltage-stability protection and control using a wide-area network of phasor measurement[J]. *IEEE Transactions on Power Systems*, 2003, 18(1): 121 – 127.
- [2] BI T S, QIN X H, YANG Q X. A novel hybrid state estimator for including synchronized phasor measurements[J]. *Electric Power Systems Research*, 2008, 78(8): 1343 – 1352.
- [3] MILOSEVIC B, BEGOVIC M. Nondominated sorting genetic algorithm for optimal phasor measurement placement[J]. *IEEE Transactions on Power Systems*, 2003, 18(1): 69 – 75.
- [4] MONTICELLI A, WU F F. Network observability theory[J]. *IEEE Transactions on Power Apparatus and Systems*, 1985, 4(5): 1042 – 1048.
- [5] SRINIVAS N, DEB K. Multi-objective function optimization using non-dominated sorting genetic algorithms[J]. *Evolutionary Computation*, 1995, 2(3): 221 – 248.
- [6] MITRA K, GOPINATH R. Multi-objective optimization of an industrial grinding operation using elitist nondominated sorting genetic algorithm[J]. *Chemical Engineering Science*, 2004, 59(2): 385 – 396.
- [7] SARKAR D, MODAK J M. Pareto-optimal solutions for multi-objective optimization of fed-batch bioreactors using nondominated sorting genetic algorithm[J]. *Chemical Engineering Science*, 2005, 60(2): 481 – 492.
- [8] DEB K, PRATAP A, AGARWAL S, et al. A fast and elitist multi-objective genetic algorithm: NSGA-II[J]. *IEEE Transactions on Evolutionary Computation*, 2002, 6(2): 182 – 197.
- [9] STORN R, PRICE K. Differential evolution—a simple and efficient heuristic for global optimization over continuous space[J]. *Global Optimization*, 1997, 11(4): 341 – 359.
- [10] 张贵军, 王信波, 俞立, 等. 求解高维多模优化问题的自适应差分进化算法[J]. *控制理论与应用*, 2008, 25(5): 862 – 866. (ZHANG Guijun, WANG Xinbo, YU Li, et al. Adaptive differential evolution for high-dimension multimodal optimization problems[J]. *Control Theory & Applications*, 2008, 25(5): 862 – 866.)
- [11] SANDRA P, THIEMO K. Differential evolution and particle swarm optimisation in partitioned clustering[J]. *Computational Statistics & Data Analysis*, 2006, 50(5): 1220 – 1247.
- [12] FARINA M, AMATO P. A fuzzy definition of “optimality” for many-criteria optimization problems[J]. *IEEE Transactions on Systems, Man and Cybernetics, Part A*, 2004, 34(3): 315 – 326.

作者简介:

彭春华 (1973—), 男, 博士, 副教授, 主要从事电力系统及其自动化方向的研究, E-mail: chinapch@163.com;

孙惠娟 (1982—), 女, 硕士, 助教, 主要从事电力监测与通信方面的研究, E-mail: hjsun@4y.com.cn;

郭剑峰 (1974—), 男, 硕士研究生, 主要从事电力系统及其自动化方向的研究, E-mail: jxxyguo@21cn.com.