

基于极限学习机的配电网重构

吴登国, 李晓明

(武汉大学 电气工程学院, 湖北 武汉 430072)

摘要: 为使配电网重构有功功率损耗最小, 提出一种基于极限学习机的神经网络重构模型来反映配电网负荷模式与开关状态之间的非线性关系。将配电网负荷模式作为输入、网损最小时的开关状态作为输出, 利用所提模型网络结构简单、学习速度快的优势进行配电网重构。引入统计学习理论中的结构风险最小化准则来改进基于经验风险最小化的极限学习机, 使经验风险和置信范围最小, 从而使实际风险最小, 减小期望误差。通过 2 个典型算例对配电网重构进行仿真研究, 并对基于支持向量机、BP 神经网络和基于经验风险最小化的极限学习机重构模型进行比较, 结果表明所提模型在保持学习速度快的同时, 泛化性能更高。

关键词: 配电网重构; 最小化网损; 极限学习机; 结构风险; 经验风险; 模型; 配电; 风险

中图分类号: TM 727

文献标识码: A

DOI: 10.3969/j.issn.1006-6047.2013.02.008

0 引言

配电网重构是配电自动化系统的重要组成部分, 是配电调度控制的重要依据, 通过改变配电系统中的分段开关、联络开关的组合状态来改变网络拓扑, 实现预定的目标。配电网重构的优化目标有: 最小化系统有功功率损耗、负荷平衡、供电恢复或其中几项的组合^[1]。配电网重构是一个有约束的多目标大规模非线性组合优化问题, 通过重构可将负荷转移, 以平衡负荷, 消除变压器和线路过载, 提高供电可靠性和电压质量, 降低网损, 提高配电网的经济性, 是实现优质、可靠和经济运行的重要手段。

据统计, 总发电量的 5%~13% 损耗在配电网络上^[2], 因此以最小化网损为目标的配电网重构具有重要的意义。目前关于减小网损的算法主要有启发式方法、数学优化理论和人工智能方法等。数学优化方法如分支定界法^[3]、单回路优化法^[4]等, 可以得到不依赖于配电网初始结构的全局最优解, 但属于“贪婪”搜索算法, 计算时间很长, 而且随着维数的增多将导致严重“组合爆炸”问题, 不能处理复杂的大规模的电力系统。启发式方法有最优流模式法^[5]和支路交换法^[6]等, 这些方法虽然加快了速度, 但每次系统负荷改变都需要重新计算潮流搜索寻优, 有时只能使系统达到次最优状态。人工智能方法主要有模拟退火法、神经网络法^[1,7-8]、遗传算法、专家系统等^[9]。文献[1,7-8]利用神经网络来描述负荷模式和最优网络结构之间的映射关系。神经网络利用其强大的非线性学习能力, 通过对训练样本的学习, 能够根据输入的负荷模式给出对应的最优网络结构类别, 不需要进行潮流计算, 可以在很短的时间得出结果。但

它以经验风险最小化为原则, 其精度取决于样本, 因完整的样本难以获得, 需要较长的时间来训练样本, 容易出现过学习, 难以保证泛化性能, 且训练结果不稳定。

极限学习机 ELM(Extreme Learning Machine)是 2006 年由新加坡南洋理工大学黄广斌教授提出的一种新的单隐层前向神经网络 SLFNs(Single-hidden Layer Feed-forward neural Networks)的学习机^[9-10]。ELM 保证网络具有结构简单、学习速度快的同时, 利用 Moore-Penrose 广义逆求解网络权重, 获得较小的权重范数, 避免了基于梯度下降学习方法而产生的诸多问题, 如局部极小迭代次数过多、性能指标及学习率的确定等, 可获得良好的网络泛化性能。ELM 可用以反映配电网负荷模式与配电网最优结构之间的非线性关系, 已在多个领域得到了应用^[11-14]。但是 ELM 仍是基于经验风险最小化原理, 在样本数量有限情况下会导致过学习问题, 而且训练结果不稳定。

本文结合统计学习理论中的结构风险最小化原则来改进 ELM, 提高其泛化能力, 并将其应用于配电网重构, 与 ELM、BP 神经网络和支持向量机 SVM(Support Vector Machine)^[15]等方法比较其性能。

1 ELM 基本原理

研究证实, 对于 N 个不同实例的有限集, 一个最多只需要 N 个隐层节点的具有非线性连续激励函数的 SLFNs, 就可以无误差地逼近这 N 个实例^[16-17]。基于此, 黄广斌提出的 ELM 算法如下。

给定 N 个学习样本矩阵 $(\mathbf{x}_i, \mathbf{y}_i)$, ELM 对应连续的目标函数 $f(\mathbf{x}_i)$, 向量 $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in \mathbf{R}^n$, 向量 $\mathbf{y}_i = [y_{i1}, y_{i2}, \dots, y_{im}]^T \in \mathbf{R}^m, i = 1, 2, \dots, N$, 且给定所构造网络的 L 个单隐层节点和隐层节点激励函数 $g(\mathbf{x}_i)$, 则存在 $\beta_i, \mathbf{w}_i$ 和 b_i , 使 SLFNs 能以 0 误差逼近这 N 个样本, 则 ELM 模型由数学表示为:

$$f(x_j) = \sum_{i=1}^L \beta_i g_i(x_j) = \sum_{i=1}^L \beta_i g(w_i \cdot x_j + b_i) = t_j \quad (1)$$

应用于二分类的 ELM 数学模型为:

$$f(x_j) = \text{sign} \left(\sum_{i=1}^L \beta_i g_i(x_j) \right) = \text{sign} \left(\sum_{i=1}^L \beta_i g(w_i \cdot x_j + b_i) \right) = t_j \quad (2)$$

其中, $j=1, 2, \dots, N$; 网络输入权重向量 $w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$, 表示输入节点与第 i 个隐含层节点连接权重; b_i 表示第 i 个隐含层节点的阈值; $w_i \cdot x_j$ 表示向量 w_i 和 x_j 的内积, 隐含层节点参数 w_i 和 b_i 随机在 $[-1, 1]$ 之间产生; 网络输出权重向量 $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$, 表示第 i 个隐含层节点与输出节点连接权重; $i=1, 2, \dots, L$ 。

由矩阵来表示 N 个式(1)为:

$$H\beta = T \quad (3)$$

$$H(w_1, \dots, w_L, b_1, \dots, b_L, x_1, \dots, x_N) =$$

$$\begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \dots & g(w_L \cdot x_1 + b_L) \\ \vdots & \dots & \vdots \\ g(w_1 \cdot x_N + b_1) & \dots & g(w_L \cdot x_N + b_L) \end{bmatrix}_{N \times L}$$

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m}, \quad T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m} \quad (4)$$

由文献[11]定义, H 为网络隐含层输出矩阵。由于 $L \ll N$, H 为非方阵, 当任意给定 w_i 和 b_i 时, 由 Moore-Penrose 广义逆定理, 求得唯一解 H^{-1} , 则 β 为:

$$\beta = H^{-1}T \quad (5)$$

由线性最小二范数与式(4), 可获得矩阵 H 为:

$$H = \min_H \| HH^{-1}T - Y \| \quad (6)$$

其中, $Y = [y_1, y_2, \dots, y_N]$ 。

由矩阵 H 及式(5)可得到解 β , 从而可确定 ELM 网络参数, 完成 ELM 网络如图 1 所示。由图 1 可见, ELM 网络参数(隐含层节点数 L 、激励函数 $g(x)$ 和任意 w_i, b_i, x 泛指任意输入参数)只需一次设定, 无需迭代调整, 网络训练速度得到极大提高。




图 1 ELM 网络
Fig.1 ELM network

2 结构风险最小化的 ELM

由统计学习理论知, 实际风险包括经验风险和置信范围。在有限的样本下, 置信范围越大, 实际风险与经验风险之间的差别也越大, 这就是机器学习会出现过学习的原因。神经网络学习应同时考虑经验风险和置信范围最小, 从而使实际风险最小, 此即结构风险最小化准则。数学约束优化模型可表示为:

$$\min J = \frac{1}{2} \|\beta\|^2 + \frac{1}{2} \gamma \|\epsilon\|^2 \quad (7)$$

$$\text{s.t.} \quad \sum_{i=1}^L \beta_i g(w_i \cdot x_j + b_i) - y_j = \epsilon_j \quad j=1, 2, \dots, N \quad (8)$$

其中, $\frac{1}{2} \|\beta\|^2$ 表示结构风险最小化中由边缘距离最大化原则得到, γ 是规则项常数, 误差的平方和 $\|\epsilon\|^2$ 代表拟合的精度。

将式(7)、(8)条件极值问题转化为 Lagrange 函数求解:

$$l(\beta, \epsilon, \alpha) = \frac{1}{2} \|\beta\|^2 + \frac{\gamma}{2} \|\epsilon\|^2 - \sum_{j=1}^N \alpha_j [\beta_i g(w_i \cdot x_j + b_i) - y_j - \epsilon_j] = \frac{1}{2} \|\beta\|^2 + \frac{\gamma}{2} \|\epsilon\|^2 - \alpha(H\beta - Y - \epsilon) \quad (9)$$

其中, $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_N]$, $\alpha_j \in \mathbf{R}^m$ ($j=1, 2, \dots, N$) 代表 Lagrange 乘子。

式(9)分别对 β, ϵ 和 α 求偏导, 并令其为 0, 可得最小化条件:

$$\begin{cases} \frac{\partial l}{\partial \beta} = \beta^T - \alpha H = 0 \\ \frac{\partial l}{\partial \epsilon} = \gamma \epsilon^T + \alpha = 0 \\ \frac{\partial l}{\partial \alpha} = H\beta - Y - \epsilon = 0 \end{cases} \quad (10)$$

由式(10)得:

$$\begin{cases} \alpha = -\gamma(H\beta - Y)^T \\ \beta = \left(\frac{I}{\gamma} + H^T H \right)^{-1} H^T Y \end{cases} \quad (11)$$

其中, I 为单元阵。

式(11)中只含有一个 $L \times L$ ($L \ll N$) 矩阵的逆操作, 所以计算 β 的速度非常快。

3 基于 ELM 的配电网模型重构

配电网多采用辐射型、环式或网格式结构方式, 正常运行时以开环方式运行, 联络开关一般处于断开状态。网损最小的配电网重构数学模型为:

$$\min f = \sum_{i=1}^b k_i r_i \frac{P_i^2 + Q_i^2}{U_i^2} \quad (12)$$

$$\text{s.t.} \quad h(K, M) = 0 \quad (13)$$

$$I_i \leq I_{\max} \quad (14)$$

$$U_{j\min} \leq U_j \leq U_{j\max} \quad (15)$$

$$K \in T \quad (16)$$

其中, b 为支路数; k_i 为开关 i 的状态变量, 是 0-1 离散量, 0 代表打开, 1 代表闭合; r_i 为支路 i 的电阻; P_i, Q_i 为支路 i 末端流过的有功功率和无功功率; U_i 为支路 i 末端的节点电压; 等式(13)为潮流方程, K 为控制变量, 即网络开关状态变量, M 为状态变量, 包括 P, Q, U 等运行参数矢量; I_i 和 $I_{\max}$ 为支路 i 的电流和

最大电流限值; U_{jmin} 和 U_{jmax} 为节点电压 U_j 的下限和上限值。

以网损最小化为目标的配电网重构,由于开关很多,难以用常规的数学模型直接建立负荷与网损最小时的开关状态之间的关系。神经网络可以反映配电网负荷模式与最优结构之间的非线性关系,可以将配电网负荷模式作为输入、相应的网损最小时的开关状态作为输出。

对于一个配电网,当每段负荷母线的负荷大小都为确定的负荷水平时就组成了一个负荷模式。若整个配电网有负荷母线 n 条,负荷划分为 p 个水平,假定每条母线负荷变化不受其他因素影响,那么负荷模式就有 p^n 个。若配电网开关有 m 个,则 ELM 输入向量 $\mathbf{x}_i$ 为 n 维,输出 $\mathbf{y}_i$ 为 m 维。每一个输出分量与配电网中的一个开关相对应,用一组二进制数据来表示,0 表示打开,1 表示闭合。负荷水平可按表 1 划分,表中负荷值为占峰值的百分数。

表 1 配电网负荷水平分类

Tab.1 Load levels of distribution grid

负荷水平	负荷值/%
1	≤ 40
2	41~50
3	51~60
4	61~70
5	71~80
6	81~90
7	≥ 91

从配电网全部的负荷模式中确定网损最小时的开关拓扑结构,然后随机选取一定数量分别作为训练集和测试集,对 ELM 网络进行训练和测试,将输出的开关状态与最优拓扑对比,验证网络的性能。具体重构流程如下。

a. 根据配电网结构找出所有的负荷模式,选取一定数量的训练集($\mathbf{X}, \mathbf{Y}$)和测试集($\mathbf{X}', \mathbf{Y}'$), $\mathbf{X}$ 和 $\mathbf{X}'$ 代表输入的负荷模式集, $\mathbf{Y}$ 和 $\mathbf{Y}'$ 代表输出的开关状态集。

b. 选择 ELM 的隐含层节点数组合 L_s , 结构风险最小化规则项常数集合 γ_s , 激励函数 $g(\mathbf{x})$ 选择 RBF 函数:

$$G(\mathbf{w}_i, b_i, \mathbf{x}) = g(b_i \parallel \mathbf{x} - \mathbf{w}_i \parallel)$$

(17)

c. 训练 ELM, 运用交叉验证法选取最优 L 和 γ , 得到 ELM 最优网络模型,若未达到要求,则改变集合 L_s 和 γ_s ,重新训练,直至达到要求。

d. 保存最优 ELM 网络模型,在不改变配电网的情况下,根据当前负荷模式,可快速地输出网损最小时的开关组合状态。

4 实验仿真

ELM 程序采用黄广斌教授个人主页上的 ELM

程序^[18],将结构风险最小化的 ELM 在 MATLAB7.0 环境下进行编程仿真测试,实验电脑配置为 Windows XP, Intel(R) Pentium(R) Dual 1.60 GHz, 1 G 内存。训练和测试的样本根据支路交换法原理^[6]通过 VC++ 6.0 编程实现,得到各种负荷模式下的网损最小时的开关组合。支路交换法首先计算初始潮流和网损,利用潮流计算的结果将负荷用恒定电流表示,每次闭合两端电压差最大的联络开关形成一个环网,选择打开环网中一个分段开关,使配电网恢复为辐射网,从而实现负荷转移,达到负荷均衡和降低网损的目的。配电网重构的关键在于根据当前的负荷模式,找到合适的开关,改变网络结构,达到网损最小。

4.1 算例 1

选取文献[7]中的 12.66 kV 的典型配电网三馈线试验网络,如图 2 所示,含有 16 个母线节点(B1, B2, ..., B16), 13 个母线负荷分段开关(S1, S2, ..., S13), 初始断开的 3 个联络开关(T14, T15, T16)。网络参数如表 2 所示,表中负荷为接在母线末端的峰值负荷。该网络为环状结构,辐射状运行。




图 2 配电网典型三馈线试验网络
Fig.2 Typical experimental distribution grid with three feeders

表 2 三馈线 16 节点网络支路、负荷数据
Tab.2 Branch and load data of a 3-feeder 16-bus grid

起始 母线	阻抗/ $(\Omega \cdot \text{km}^{-1})$		负荷(母线末端)		长度/ km	类型
	R	X	P/MW	Q/Mvar		
1-2	0.2024	0.3891	2.10	0.92	1.25	1
2-3	0.2024	0.3891	1.75	0.87	0.75	1
3-4	0.2024	0.3891	1.25	0.65	2.16	1
2-5	0.2024	0.3891	1.10	0.52	2.50	2
6-7	0.2024	0.3891	1.28	0.76	1.05	2
7-8	0.2024	0.3891	1.65	0.78	1.00	2
8-9	0.2024	0.3891	1.30	0.78	0.98	2
7-10	0.2024	0.3891	0.94	0.56	0.79	3
8-11	0.2024	0.3891	1.45	0.59	2.10	1
12-13	0.2024	0.3891	1.42	0.68	1.50	2
13-14	0.2024	0.3891	1.98	0.79	0.98	3
14-15	0.2024	0.3891	1.45	0.67	0.89	3
13-16	0.2024	0.3891	1.08	0.45	1.50	3
4-15	0.2024	0.3891	—	—	1.18	
5-11	0.2024	0.3891	—	—	1.58	
4-15	0.2024	0.3891	—	—	1.25	

根据表 1 将负荷水平划分为 7 类,共有负荷模式

7¹³ 种,但 ELM 网络无法训练这么庞大的负荷模式。为克服此困难,由文献[7]知,表现出不同峰值时间的母线负荷具有不同的特征,如居民用电、商业用电、工业用电等,分别用 1、2 和 3 表示,并对算例 1 中的负荷类型进行分类,如表 2 所示。通常,类似的负荷特征具有相似的变化趋势,配电网络中不同的负荷类型只需要取其中一种就可反映整个配电网的变化情况。即使负荷具有混合类型特征,神经网络也能够识别。因此,将其类型特征考虑进去,对于母线负荷划分为 p 个水平的配电网,其负荷水平组合降为 p^3 个。算例 1 中,其负荷水平组合为 $7^3=343$ 种,且此组合与系统大小无关。仍由文献[7]知,实际中,通过基于负荷组合训练得到的大量系统最优拓扑结构是相似的,因此可以得到较少的系统统一的拓扑结构,并且远小于开关数量。

首先在 7³ 个负荷水平组合模式下,随机选择 3500 个负荷组合,由支路交换法得到相应的最优拓扑结构。将其中 3000 个负荷模式和其相应的网损最小时的开关组合,作为 ELM 的训练集合,另外 500 个模式作为测试集合。ELM 网络的输入为包含 13 个分量的向量,输出为 16 个分量组成的开关状态。激励函数选为 RBF 高斯核函数,隐含层节点数组合 $L_s=[5,10,15,20,30,35,50]$,规则项常数 $\gamma_s=[500,100,50,10,1,0.1,0.01]$,共有 $7\times7=49$ 种集合,采用循环程序将每一种组合代入到 ELM 中,进行交叉验证参数寻优。

经过实验,可得结构风险最小化的 ELM 最优参数组合为: $L=62,\gamma=0.1$,测试结果与支路交换法计算的结果差异 14 次,差异率为 2.8%,满足实际需求。若将测试的结果与实际结果作比较,一致时为 0,差异时为 1,则实际结果和测试结果误差如图 3 所示。最后将出现差异的测试模式用 PSASP 程序进行网损计算分析,仅 6 个模式也即只有 1.2% 的模式比支路交换法得到的结果略大,其他模式结果与支路交换法接近或略小。因此,基于结构风险最小化的 ELM 比支路交换法重构的效率更高,错误率更低。




图 3 测试误差结果
Fig.3 Result of test error

另外分别采用基于经验风险最小化的 ELM、SVM 和 BP 神经网络对上述配电网进行重构,训练和测试样本不变,各种方法均在调试的最优情况下进行,性能比较结果如表 3 所示。可见,与 SVM

表 3 各种方法的性能比较

Tab.3 Comparison of performance among different methods

重构方法	测试正确率/%	训练时间/s
结构风险最小化的 ELM	97.2	0.4684
经验风险最小化的 ELM	90.0	0.3571
SVM	93.0	79.9429
BP 神经网络	91.0	31.2665

和 BP 神经网络相比,基于结构风险最小化的 ELM 不仅泛化性能更好,而且速度是它们的几十倍以上,适合于大规模实时控制;与基于经验风险最小化的 ELM 相比,其测试正确率大幅提高,速度也基本相当。

4.2 算例 2

选取美国 PG & E 的 69 节点配电系统^[19],如图 4 所示,需要重构的配电系统有 73 条支路,初始断开 5 个联络开关:T11-66、T13-20、T15-69、T27-54、T39-48(数据表示节点连接编号),构成树形配电网络,系统参数在此略去,详见文献[19]。




图 4 美国 69 节点配电网
Fig.4 69-bus distribution grid of America

将负荷水平划分为 7 类,采用算例 1 中的压缩负荷模式的方法,同样先用支路交换法得到 ELM 的负荷模式学习样本 3500 个,分别选取其中 2000 个和 3000 个作为训练样本,另外均选取 500 个作为测试样本,并用基于经验风险最小化的 ELM、SVM 和 BP 神经网络来进行网损最小化重构比较,用以检验基于结构风险最小化的 ELM 重构性能。如表 4 所示,增加训练样本情况下,虽然各种方法都可以降低重构错

表 4 4 种方法的重构性能比较

Tab.4 Comparison of reconfiguration performance among four methods

训练样本数	重构方法	测试正确率/%	训练时间/s
2000	结构风险最小化的 ELM	95.8	1.3362
	经验风险最小化的 ELM	87.4	1.1624
	SVM	95.0	163.6295
	BP 神经网络	91.0	67.8346
3000	结构风险最小化的 ELM	97.6	1.7361
	经验风险最小化的 ELM	90.0	1.3952
	SVM	97.0	240.3685
	BP 神经网络	92.0	83.4011

误率,提高泛化性能,实现全局逼近最优,但 SVM 和 BP 神经网络训练时间则明显增加很多,而基于结构风险最小化的 ELM 训练时间只比基于经验风险最小化时稍长一点。

5 结论

本文将结构风险最小化准则应用于新型的 ELM 神经网络,根据负荷模式对配电网进行网损最小化重构,避免了使用传统的启发式方法每次负荷变化带来的繁复迭代寻优,并与 SVM、BP 神经网络和基于经验风险最小化的 ELM 的配电网重构效果进行比较,克服传统神经网络学习速度慢的问题,泛化性能更好,速度也与基于经验风险最小化的 ELM 基本相当。ELM 随着训练样本的增加,重构效果更好,然而需要通过其他启发式方法获得大量且覆盖面广的学习样本作为支持,并且随着网络结构的改变而需要重新训练。

参考文献:

- [1] 金丽成,邱家驹. 基于 CMAC 神经网络的配网重构模型[J]. 浙江大学学报:工学版,2004,38(6):784-788.
JIN Licheng, QIU Jiaju. Model of distribution power network re-configuration based on CMAC neural network[J]. Journal of Zhejiang University: Engineering Science, 2004, 38(6): 784-788.
- [2] BARAN M E, WU F F. Network reconfiguration in distribution systems for loss reduction and load balancing[J]. IEEE Trans on Power Delivery, 1989, 4(2): 1401-1407.
- [3] MERLIN A, BACK H. Search for a minimum loss operating spanning tree configuration for an urban power distribution system[C]//Proceeding of Fifth Power Systems Computation Conference(PSCC). Cambridge, UK: [s.n.], 1975: 1-18.
- [4] FAN Jiyuan, ZHANG Lan, MCDONALD J D. Distribution network reconfiguration: single loop optimization[J]. IEEE Trans on Power Systems, 1996, 11(3): 1641-1647.
- [5] SHIRMOHAMMADI D, HONG H W. Reconfiguration of electric distribution networks for resistive line losses reduction[J]. IEEE Trans on Power Delivery, 1989, 4(2): 1492-1498.
- [6] CIVANLAR S, GRAINGER J J, YIN H, et al. Distribution feeder reconfiguration for loss reduction[J]. IEEE Trans on Power Delivery, 1988, 3(3): 1217-1223.
- [7] KIM H, YUNSEOK K. Artificial neural-network based feeder re-configuration for loss reduction in distribution systems[J]. IEEE Trans on Power Delivery, 1993, 8(3): 1356-1366.
- [8] 赵传辉. 基于神经网络的配电网综合节能降损技术[D]. 济南: 山东大学, 2011.
ZHAO Chuanhui. Integrated energy conservation and loss reduction of distribution network based on neural network[D]. Ji'nan: Shandong University, 2011.
- [9] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006, 70(1-3): 489-501.
- [10] HUANG G B, SIEW C K. Extreme learning machine: RBF network case[C]//Proceedings of the Eighth International Conference on Control, Automation, Robotics and Vision. Kunming, China: IEEE, 2004: 1029-1036.
- [11] 常玉清, 李玉朝, 王福利, 等. 基于极限学习机的生化过程测量建模[J]. 系统仿真学报, 2007, 19(23): 5587-5590.
CHANG Yuqing, LI Yuchao, WANG Fuli, et al. Soft sensing modeling based on extreme learning machine for biochemical process[J]. Journal of System Simulation, 2007, 29(23): 5587-5590.
- [12] ZHU Q Y, QIN A K, SUGANTHAN P N, et al. Evolutionary extreme learning machine[J]. Pattern Recognition, 2005, 38(2): 1759-1763.
- [13] 黄宴委, 吴登国, 李竣. 基于极限学习机的结构健康监测恢复[J]. 计算机工程, 2011, 37(16): 241-243.
HUANG Yanwei, WU Dengguo, LI Jun. Lost data recover research of structural healthy monitoring system based on extreme learning machine[J]. Computer Engineering, 2011, 37(16): 241-243.
- [14] 张弦, 王宏力. 基于贯序正则极端学习机的时间序列预测及其应用[J]. 航空学报, 2011, 32(7): 1302-1308.
ZHANG Xian, WANG Hongli. Time series prediction based on sequential regularized extreme learning machine and its application[J]. Acta Aeronautica ET Astronautica Sinica, 2011, 32(7): 1302-1308.
- [15] 刘蔚, 韩祯祥. 基于支持向量机的配电网重构[J]. 电力系统自动化, 2005, 29(7): 48-52.
LIU Wei, HAN Zhenxiang. Distribution system reconfiguration based on the support vector machine[J]. Automation of Electric Power Systems, 2005, 29(7): 48-52.
- [16] HUANG Guangbin, BABRI H A. Upper bounds on the number of hidden neurons in feedforward networks with arbitrary bounded nonlinear activation functions[J]. IEEE Trans on Neural Networks, 1998, 9(1): 224-229.
- [17] HUANG Guangbin. Learning capability and storage capacity of two hidden-layer feedforward networks[J]. IEEE Transactions on Neural Networks, 2003, 14(2): 274-281.
- [18] HUANG Guangbin. MATLAB codes of ELM algorithm[EB/OL]. [2011-05-19]. http://www3.ntu.edu.sg/home/egbhuang/ELM_Codes.htm.
- [19] 李鹏飞. 基于人工智能的配电网故障恢复重构研究[D]. 南京: 南京理工大学, 2008.
LI Pengfei. Study of service restoration reconfiguration in distribution system based on artificial intelligence[D]. Nanjing: Nanjing University of Science & Technology, 2008.

作者简介:

吴登国(1983-),男,河南南阳人,博士研究生,研究方向为配电网自动化技术、电机智能控制等(E-mail: wdg198371@126.com);

李晓明(1955-),男,湖北应城人,教授,博士研究生导师,博士,研究方向为电力系统运行与控制、电力电子技术在电力系统中的应用、配电网自动化等(E-mail: xmli@whu.edu.cn)。

(下转第 56 页 continued on page 56)

- [7] 许诺,黄民翔. 原对偶内点法与定界法在无功优化中的应用[J]. 电力系统及其自动化学报,2000,12(3):26-30.
- XU Nuo,HUANG Minxiang. Application of primal-dual interior point method and branch-bound method in reactive power optimization[J]. Proceedings of the CSU-EPSA,2000,12(3):26-30.
- [8] 范宏,韦化. 基于扰动 KKT 条件的原始-对偶内点法和分支定界法的最优潮流研究[J]. 电力自动化设备,2004,24(5):5-9.
- FAN Hong,WEI Hua. Study on optimal power flow based on primal-dual interior point algorithm under perturbed KKT conditions and branch and bound method[J]. Electric Power Automation Equipment,2004,24(5):5-9.
- [9] 石韦,韦化,白晓清. 含离散变量的大规模电力系统无功优化[J]. 电力自动化设备,2007,27(3):41-45.
- SHI Wei,WEI Hua,BAI Xiaoqing. Reactive power optimization in large-scale power systems with discrete variables[J]. Electric Power Automation Equipment,2007,27(3):41-45.
- [10] BOURBEAU B,CRAINIC T G,GENDRON B. Branch and bound parallelization strategies applied to a depot location and

container fleet management problem[J]. Parallel Computing, 2000,26(1):27-46.

- [11] GENDRON B,CRAINIC T G. Parallel branch and bound algorithms:survey and synthesis[J]. Operations Research,1994,42(6):1042-1066.
- [12] MEZMAZ M,MELAB N,TALBI E G. An efficient load balancing strategy for grid-based branch and bound algorithm[J]. Parallel Computing,2007,33(4-5):302-313.
- [13] 王锡凡,杜正春,方万良. 现代电力系统分析[M]. 北京:科学出版社,2006:121-123.

作者简介:

王 云(1988-),男,江西南昌人,博士研究生,主要研究方向为电力系统稳定与控制、配电网无功优化;

江全元(1975-),男,湖北黄冈人,教授,博士,主要研究方向为电力系统稳定与控制、牵引供电品质、分布式发电与集中式可再生能源发电(E-mail:jyq@zju.edu.cn)。

Reactive power optimization based on primal-dual interior point method and branch & bound algorithm for distribution network and its parallel implementation

WANG Yun,JIANG Quanyuan

(College of Electrical Engineering,Zhejiang University, Hangzhou 310027, China)

Abstract: The primal-dual interior point method and the branch & bound algorithm are integrated and applied in the reactive power optimization, and a parallel branch & bound strategy is proposed, which adopts asynchronous communication and master-slave control mode. In parallel, each machine of the parallel platform with distributed memory generates the decision tree and executes the branch & bound operation for its own process. Results of two tests show that, the parallel strategy balances the load well, improves the computational efficiency effectively and obtains an excellent speedup ratio.

Key words: reactive power; optimization; interior point method; branch and bound; parallel computing; models

(上接第 51 页 continued from page 51)

Distribution grid reconfiguration based on extreme learning machine

WU Dengguo, LI Xiaoming

(School of Electrical Engineering, Wuhan University, Wuhan 430072, China)

Abstract: To minimize the active power loss of distribution grid reconfiguration, a neural network reconfiguration model based on the extreme learning machine is proposed, which reflects the nonlinear relationship between the load pattern and the switch state of distribution grid. Having simple network structure and fast training speed, the model takes the load pattern as its input and outputs the switch states to reconfigure the distribution grid with minimum active power loss. The structural risk minimization rule of the statistical learning theory is introduced into the extreme learning machine based on the empirical risk minimization to minimize the empirical risk and confidence interval. The actual risk is thus minimized and the expectation error is decreased. Simulative research is carried out for two typical cases of distribution network reconfiguration with different reconfiguration models: support vector machine, BP neural network and extreme learning machine. Results show that the proposed model has both better generalization performance and faster training speed.

Key words: distribution grid reconfiguration; minimized grid loss; extreme learning machine; structural risk; empirical risk; models; electric power distribution; risks