

DOI: 10.7667/PSPC180610

# 含风电系统断面 TTC 运行规则的极限学习机提取方法

胥威汀<sup>1</sup>, 刘俊勇<sup>2</sup>, 唐权<sup>1</sup>, 邱高<sup>2</sup>, 王云玲<sup>1</sup>, 杨新婷<sup>1</sup>, 李奥<sup>1</sup>

(1. 国网四川省电力公司经济技术研究院, 四川 成都 610041; 2. 四川大学电气信息学院, 四川 成都 610065)

**摘要:** 风电集中接入使得传统方式有效计算极限传输容量存在困难。为此, 提出一种基于差分进化极限学习机的含风电系统输电断面极限传输功率(Total Transfer Capability, TTC)运行规则提取方法。首先基于 K-medoids 聚类方法提取以“风功率-负荷”二维特征表征的典型运行场景, 然后通过随机采样和重复潮流方法生成用于 TTC 运行规则挖掘的知识库。接着采用 RELIEF-F 算法剔除冗余特征并辨识与输电断面 TTC 存在强关联的特征属性, 以削减运行特征的高维度。最终通过将训练数据输入差分进化极限学习机, 从知识库中提取 TTC 运行规则。算例验证表明, 所提方法能够以较高的计算精度及较强的泛化能力实现 TTC 的快速估计。

**关键词:** 风电; 极限传输功率; 数据挖掘; 场景聚类; RELIEF-F 特征筛选; 差分进化极限学习机

## Extreme learning machine-based estimation of total transfer capability of transmission corridors in wind-integrated power systems

XU Weiting<sup>1</sup>, LIU Junyong<sup>2</sup>, TANG Quan<sup>1</sup>, QIU Gao<sup>2</sup>, WANG Yunling<sup>1</sup>, YANG Xinting<sup>1</sup>, LI Ao<sup>1</sup>

(1. Sichuan Electric Power Corporation Power Economic Research Institute, Chengdu 610041, China;

2. College of Electrical Engineering and Information Technology, Sichuan University, Chengdu 610065, China)

**Abstract:** Central integration of wind farm makes it hard to effectively compute Total Transfer Capability (TTC) through traditional way. For this reason, a data mining technique named Differential Evolution Extreme Learning Machine (DE-ELM) is proposed to extract operating rules for the TTC of tie-lines in wind-integrated power systems. Representative operating scenarios are firstly determined by K-medoids clustering under the two-dimensional “wind power-load consumption” feature space. Then knowledge base for TTC operation rule mining is generated by stochastic sampling and repeated power flow. Secondly, to reduce the ultra-high dimensionality of operating features, RELIEF-F algorithm is employed to screen the redundant features and identify the features that are strongly correlated to the TTC. Finally, the TTC operation rules are extracted from the knowledge base by feeding training data into the DE-ELM. Numerical results show that the proposed method can fast estimate TTC with satisfying accuracy and strong generalization.

This work is supported by National Natural Science Foundation of China (No. 51437003) and Science and Technology Project of State Grid Sichuan Electric Power Company (No. SGSCJY00JHJS201700009).

**Key words:** wind power; total transfer capability (TTC); data mining; scenario clustering; RELIEF-F based feature selection; differential evolution extreme learning machine (DE-ELM)

## 0 引言

电网实时运行中, 调度运行人员常常依赖于一系列安全稳定运行规则来判断和维持电力系统安全性。互联电网关键输电断面的极限传输功率(Total

Transfer Capability, TTC)即是其中一种重要运行指标。长期以来, 包括输电断面TTC在内的各类安全稳定运行规则往往是在离线阶段以典型运行工况来计算制定的。然而, 大规模间歇性清洁能源接入电网以后, 电网运行方式具有随机性和不确定性<sup>[1-2]</sup>。为了保证电网稳定性, 只能以保守运行规则来运行, 容易导致弃光弃风, 并且造成电网运行效率下降。

近年来, 大数据与人工智能技术的发展与广泛

基金项目: 国家自然科学基金项目资助(51437003); 国网四川省电力公司科技项目资助(SGSCJY00JHJS201700009)

应用为运行规则精细建模乃至电网智能调度提供了新的技术手段。文献[3]最早提出电力系统精细运行规则的概念,综合利用灵敏度分析与数据挖掘技术建立输电断面TTC的精细规则。在文献[3]的基础上,文献[4]进一步构建了分布式安全特征选择方法,为在线训练学习精细规则提供了技术支撑。文献[5]考虑了间歇性风电对输电断面TTC的影响,使用场景聚类法提取代表场景,针对代表场景分别进行TTC规则挖掘和形成知识库,更好地适应了实时监视风电外送通道安全性的需求。文献[6]应用关联分类法进行电网稳定运行规则提取,由于所提方法引入时间因素,因此所得到的规则不仅能揭示电网稳定运行的强相关影响因素信息,还能提取影响因素变化对系统状态变化的内在关系,从而为调度运行决策提供支持。文献[7]则提出基于人工神经网络ANN的精细运行规则提取方法,相比于线性模型,基于ANN的运行规则在预测精度方面得到提升。与传统规则相比,基于大数据与人工智能技术的精细规则学习建模方法可考虑更精细的电网安全特征状态,对实时运行工况的适应性更强,非线性提取能力更强<sup>[8-9]</sup>。

基于大数据驱动电力系统规则提取与运行决策的思路,本文提出基于差分进化极限学习机的含风电系统输电断面极限传输功率运行规则提取方法。考虑风电出力的不确定性和负荷的时序波动特性,以“风功率-负荷”二维特征表征电网运行工况,基于K-medoids聚类方法实现典型运行工况的提取;在各典型运行工况的基础上,通过随机抽样生成随机运行工况集,利用内嵌暂态稳定性校核的重复潮流方法搜索求取随机运行工况下关键输电断面的极限传输功率,记录随机运行工况及其相应的关键输电断面极限传输功率构成大数据知识库;针对复杂互联电网高维运行特征属性集合,基于RELIEF-F算法实现特征降维,进一步采用差分进化极限学习机在降维特征空间中学习提取输电断面极限传输功率的关联预测规则。在实时运行阶段,可通过两阶段的工况匹配和规则预测,实现输电断面极限传输功率的快速准确估计,从而为电网稳定性监视与控制提供依据。在含风电的New England 39节点系统算例仿真中验证所提方法的有效性。

## 1 时序运行场景聚类

极限传输功率 TTC 是指输电断面受各类电网稳定约束下的最大输电能力,随电网运行工况变化而具有时变性。风电出力的随机性和波动性使得电网运行工况快速变化,基于典型工况计算的 TTC 定

值存在失效风险,可能造成稳定性误判;若采用考虑多种不确定因素影响下的全运行工况集,则极大地增加了运行规则拟合难度。

场景聚类是降低场景维度,提取典型工况的重要手段,在间歇性清洁能源并网旋转备用需求评估<sup>[10]</sup>、无功优化评估<sup>[11]</sup>、风电场选址规划<sup>[12]</sup>等问题中得到成功应用。为了有效提取代表性典型运行工况,采用“风功率-负荷”二维特征表征任一运行工况,利用历史记录的“风功率-负荷需求”数据构成场景全集,基于K-medoids聚类方法<sup>[13]</sup>实现场景聚类和代表性典型场景提取。得到代表性典型场景集后,可针对各个代表性场景分别进行大数据知识库构造和运行规则提取,从而适应输电断面TTC运行规则随“风功率-负荷”变化而改变的实时运行场景。

## 2 大数据知识库构造

### 2.1 断面极限传输功率的重复潮流计算方法

为了提取输电断面极限传输功率 TTC 的运行规则,在知识库构造阶段需针对随机工况进行指定输电断面的极限传输功率计算。TTC 计算方法包括连续潮流方法<sup>[14-15]</sup>和最优潮流方法<sup>[16-17]</sup>。实际运行中,重要输电断面常常受到暂态稳定约束。连续潮流方法一般采用准稳态模型,因而无法考虑断面暂稳约束;对于最优潮流方法,暂稳约束的引入造成模型求解困难,如何提升算法的求解速度与鲁棒性仍有待研究。因此,提出采用面向输电断面传输功率增长的重复潮流二分搜索方法,算法流程如下。

(1) 给定电网初始运行工况,初始化负荷增长因子的二分搜索区间 $[\lambda_s, \lambda_u]$ 。

(2) 取区间中值 $\lambda_L = (\lambda_s + \lambda_u)/2$ ,将 $\lambda_L$ 代入式(1)更新受端负荷需求,同时按式(2)来调整送端发电机出力。

$$\begin{cases} P_{Li} = P_{Li}^0 (1 + \lambda_L k_{Li}) \\ Q_{Li} = Q_{Li}^0 (1 + \lambda_L k_{Li}) \end{cases} \quad (1)$$

$$P_{Gj} = P_{Gj}^0 + \Delta P_L \frac{P_{Gj}^R}{P_G^R} \quad (2)$$

式中: $k_{Li}$ 为受端电网负荷*i*的增长速度因子; $\Delta P_L$ 为受端电网负荷总增量; $P_{Gj}^R$ 是送端电网发电机*j*的有功备用; $P_G^R$ 是送端电网发电机总有功备用,因此有

$$\begin{cases} \Delta P_L = \lambda_L \sum_{i \in L} P_{Li}^0 k_{Li} \\ P_G^R = \sum_{j \in G} P_{Gj}^R \end{cases}$$

(3) 计算负荷-发电同步增长后的电网潮流,考虑断面任一输电线路发生三相短路的故障场景集

合, 逐一进行时域仿真。本文采用式(3)所示发电机模型, 并基于式(4)进行暂态稳定校核。

$$\begin{cases} u_d = x_q i_q - r i_d, u_q = E'_q - x'_d i_d - r i_q \\ T'_{d0} \frac{dE'_q}{dt} = E_f - E'_q - (x_d - x'_d) i_d \\ T'_{q0} \frac{dE'_d}{dt} = -E'_d - (x_q - x'_q) i_q \\ T_J \frac{d\omega}{dt} + D(\omega - 1) = T_m - E'_q i_q + (x_d - x'_d) i_d i_q \\ \frac{d\delta}{dt} = \omega - 1 \end{cases} \quad (3)$$

$$S = 180^\circ - \Delta\delta_{\max} \quad (4)$$

式中:  $\Delta\delta_{\max}$  表示任一仿真时步的最大机组对功角差。若暂态稳定指标  $S$  小于 0 时, 故障后电网判定为失稳; 反之, 故障后电网能保持稳定。

(4) 若当前电网运行工况满足断面故障集的暂稳约束, 则更新二分搜索区间, 令  $\lambda_s = \lambda_L$ ; 否则, 令  $\lambda_u = \lambda_L$ 。

(5) 若区间间隔满足计算精度( $\lambda_u - \lambda_s < \Delta\lambda_{th}$ ), 则得到临界负荷增长因子  $\lambda_{cr} = (\lambda_s + \lambda_u)/2$ , 计算该临界运行工况潮流, 此时断面总传输功率即为初始运行工况的 TTC。

## 2.2 大数据知识库构造

通过本文第 1 节时序场景聚类可得到典型运行工况集合。分别考虑风电出力、同步机出力、负荷需求的不确定性, 针对每一个典型运行工况通过随机抽样生成随机工况:

(1) 对任一典型运行工况, 计算该场景簇的最大偏移半径( $P_{wind}^{\max}, P_{load}^{\max}$ ), 使风电出力和负荷需求分别在 $[-P_{win}^{\max}, +P_{win}^{\max}]$ 和 $[-P_{load}^{\max}, +P_{load}^{\max}]$ 范围内随机波动, 同步机则在 $[80\%, 120\%]$ 倍初始出力的范围内随机波动, 产生随机工况并计算潮流, 记录该工况下节点电压幅值和相角、负荷需求和发电机出力等全部运行特征参数。

(2) 基于第 2.1 节所提的重复潮流方法, 计算典型工况和随机工况下输电断面的极限传输功率。

(3) 以  $F_i^k$  标记第  $i$  个随机工况的第  $k$  个运行特征参数,  $P_i^{TTC}$  为该工况下断面极限传输功率, 以式(5)计算各特征参数和断面 TTC 相对于中心运行场景的参数偏差, 最终以参数偏差量  $F_i$  作为输入特征, 以  $T_i$  作为预测目标, 构成大数据知识库。

$$\begin{cases} F_i = [F_i^1 - F_{OSC}^1, F_i^2 - F_{OSC}^2, \dots, F_i^K - F_{OSC}^K] \\ T_i = P_i^{TTC} - P_{OSC}^{TTC} \end{cases} \quad (5)$$

## 3 RELIEF-F 特征选择

为了尽可能完整地找到对 TTC 含隐式关系的特征, 本文将 SCADA 可采集的数据全部保留, 样本数据集中必然包含大量冗余特征和噪声数据, 进而会导致后续精细规则提取的计算负担大、规则精度下降, 因此对原始样本集进行特征筛选非常必要。

RELIEF-F 是一种滤波式特征选择算法, 不需要依赖后续学习器, 适合用于含冗余特征和噪声数据的样本集的预处理, 其核心思想是对特征区分相邻样本的能力进行评估, 使用评估值来量化特征与目标之间的相关性, 评估值越大说明该特征对预测目标的贡献程度越大, 保留该特征。

在回归问题中, 目标值是一组连续数值, 采用传统的 RELIEF-F 算法并不适用<sup>[18]</sup>。文献[19]提出了 RELIEF-F 应用于回归问题的改进方法: 针对回归问题中传统 RELIEF-F 算法无法获取样本类别信息的难题, 改进 RELIEF-F 算法采用样本之间预测值的距离来构建概率模型。由于该概率模型直接求解存在困难, 考虑使用以下算法进行估计, 进而求取各特征评估值:

图 1 中,  $N_{AP}, N_{AF}(F), N_{APAF}(F)$  分别对应  $P_{diff}^F, P_{diff}^P, P_{diff}^{PIF}$  的近似值, 函数  $f(\cdot)$  表示样本的目标值, 函数  $diff(\cdot)$  和  $d(\cdot)$  分别对应式(6)和式(7)。

$$diff(F, R_i, I_j) = \frac{|\text{value}(F, R_i) - \text{value}(F, I_j)|}{\max(F) - \min(F)} \quad (6)$$

输入: 训练样本, 近邻数  $K$

1. 置  $N_{AP}, N_{AF}(F), N_{APAF}(F), G(F)$  为 0
2. for  $i = 1: m$  do
3. 随机选择样本  $R_i$ ;
4. 找到  $R_i$  的  $K$  个最近邻样本  $I_j (j = 1, 2, \dots, K)$ ;
5. for  $j = 1: k$  do
6.  $N_{AP} = N_{AP} + \text{abs}(f(R_i) - f(I_j)) \times d(i, j)$ ;
7. for  $F = 1$ : 所有特征 do
8.  $N_{AF}(F) = N_{AF}(F) + diff(F, R_i, I_j) \times d(i, j)$ ;
9.  $N_{APAF}(F) = N_{APAF}(F) + \text{abs}(f(R_i) - f(I_j)) \times \dots \times diff(F, R_i, I_j) \times d(i, j)$ ;
10. end;
11. end;
12. end;
13. For  $F = 1$ : 所有特征 do
14.  $G(F) = N_{APAF}(F) / N_{AP} - (N_{AF}(F) - N_{APAF}(F)) / (m - N_{AP})$ ;
15. end

输出: 所有特征评估值

图 1 回归 RELIEF-F 伪代码

Fig. 1 Pseudo code of regression RELIEF-F

$$d(i, j) = \frac{d_1(i, j)}{\sum_{l=1}^k d_1(i, l)}, d_1(i, j) = \exp(-(\frac{\text{rank}(R_i, I_j)}{\sigma})^2) \quad (7)$$

式中:  $\text{rank}(R_i, I_j)$ 是按照近邻  $I_j$ 和选择样本  $R_i$ 的距离大小进行排序的位置序列;  $\sigma$ 是自定义参数, 本文取  $\sigma = 50$ 。

## 4 差分进化极限学习机

### 4.1 ELM 极限学习机

输电断面精细规则提取要求学习器能够较为快速准确构建模型, 并且学习器提取的精细规则要保证较强的泛化能力。ELM 作为近年来提出的一种新型单层前馈网络(Single Layer Feedforward Neural Network, SLFNN)学习算法, 具有训练速度快, 生成网络结构简单, 泛化能力强的优点, 已被广泛应用于电力系统<sup>[20]</sup>, 适合用于输电断面精细规则提取。

ELM 随机生成输入层和隐层之间的权值和阈值矩阵, 以 0 误差逼近样本, 直接通过对隐层和输出层权值进行最小二乘求解。相比误差反向传播算法(Back Propagation, BP), ELM 直接通过解析求解得到前馈网络结构, 不易陷入局部最优, 泛化能力较强。ELM 的具体执行步骤见文献<sup>[20]</sup>, 可由图 2 简单描述。

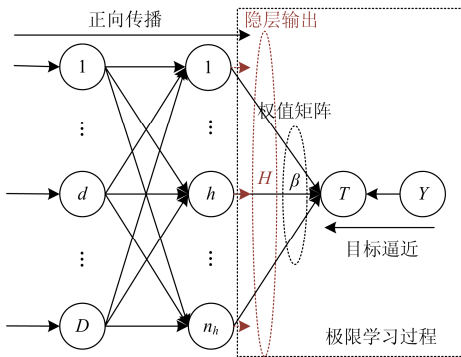


图 2 ELM 求解步骤  
Fig. 2 Procedure of ELM

### 4.2 差分进化极限学习机

ELM 用于输电断面精细规则提取时, 由于电力系统的随机性因素扰动, 可能导致应用于实际预测时的精度下降, 因此, 为了增强 ELM 在不确定性因素影响下的泛化能力, 本文将智能优化算法与 ELM 结合。

相比于其他进化算法, 差分进化(Differential Evolution, DE)算法具有执行简单、收敛速度快和全局搜索性能好等优点<sup>[21]</sup>, 特别适合用于神经网络优

化。DE 的具体执行步骤见文献<sup>[22]</sup>。本文重点说明 DE 应用于 ELM 的具体步骤:

1) 对 SLFNN 输入层到隐层的权值矩阵  $\omega$  和阈值向量  $\mathbf{b}$  进行实数编码, 随机初始化种群。

2) 对输入样本进行 5 折交叉验证, 使用种群内各个体构建 SLFNN 进行 ELM 训练, 将验证集输入 SLFNN 得到预测输出  $\mathbf{T}_{pop}^v = E_{pop}(\mathbf{x}_v)$ , 计算种群适应度, 适应度函数如式(8)所示。

$$\text{fitness}(\text{pop}) = \frac{1}{sv} \sum (\mathbf{T}_{pop}^v - \mathbf{y}_v)^2 \quad (8)$$

式中:  $\text{pop}$  表示当前个体编号,  $E_{pop}(\cdot)$ 表示当前个体构建的 ELM;  $\mathbf{T}_{pop}^v$  表示当前 ELM 的验证集预测输出向量;  $\mathbf{y}_v$  表示当前验证集的目标向量;  $sv$  为验证集的样本数量。

3) 执行 DE 选择、交叉、变异操作。

4) 获取子代, 计算子代个体适应度, 选取最优个体。

5) 是否达到最大进化代数, 是则输出当前最优 ELM, 否则返回步骤 3)直到最大进化代数。

## 5 实验结果与分析

算例采用改进的 3 分区 New England 39 节点系统, 在母线 17 处集中接入风电场, 装机容量为 600 MW, 系统如图 3 所示, 不考虑断面动态辨识<sup>[23]</sup>。本文基于 Matlab-PSAT 软件进行时域仿真, 风机采用 PSAT 提供的经典双馈异步风力发电机(DFIG, Double-Fed Induction Generator)模型。

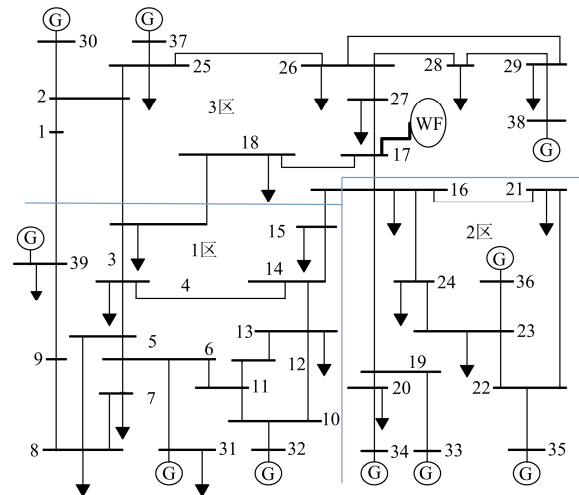


图 3 风电集中接入的 IEEE 39 节点测试系统

Fig. 3 New England 39-bus system with wind farm integration

另外, 平方相关系数(SCC)和均方差(MSE)指标用于衡量 DE-ELM 提取的断面精细规则精度。

### 5.1 样本生成

对于标准算例系统, 由于缺少历史数据, 因而不能直接利用历史记录的“风功率-负荷”时序数据进行场景聚类。为了验证本文所提方法, 采用文献[24]的时序模型来生成“风功率-负荷”时序数据。经过时序模拟得到“风功率-负荷”场景数据后, 进行基于 K-medoids 方法的场景聚类 and 代表性典型场景提取, 得到五类代表性场景中心由表 1 给出。

表 1 基于 K-medoids 聚类得到代表性场景中心

Table 1 Representative operating scenarios by K-medoids clustering

场景	风功率/p.u.	负荷/p.u.	场景描述
1	0.595 7	63.39	对应风电低出力 and 腰荷运行场景
2	0.534 3	31.62	对应风电低出力 and 谷荷运行场景
3	0.661 7	89.30	对应风电低出力 and 峰荷运行场景
4	4.183 1	73.93	对应风电高出力 and 峰荷运行场景
5	4.024 4	32.02	对应风电高出力 and 谷荷运行场景

### 5.2 RELIEFF 特征选择

初始特征空间如表 2 所示。使用 RELIEFF 算法对场景簇 3 中训练样本进行特征选择, 可以得到各特征关于目标值的预测相关性的评估值如图 4 所示。

表 2 初始特征空间

Table 2 Initial features space

目标属性
TTC
初始特征属性
联络线相角差差值
联络线电压差差值
送端区域净有功、无功差值
受端区域净有功、无功差值
各母线电压差值
各节点有功负荷差值
各发电机有功发电量差值
各发电机无功发电量差值
断面总潮流差值
风电有功
总负荷差值




图 4 特征评估值

Fig. 4 Score of features

为了验证特征选择的有效性, 本文选取最优的前 5 个和前 10 个特征以及最差的前 5 个和前 10 个特征输入 DE-ELM, 得到表 3。

表 3 特征选择有效性验证试验结果

Table 3 Results of validation test for feature selection

选入特征	前 5 最优特征	前 10 最优特征	前 5 最差特征	前 10 最差特征
SCC	0.90	0.94	0.60	0.65
训练时间/s	3.27	6.42	6.78	11.85

从表 3 中可以明显看出, 选择最优的特征进入最终 DE-ELM 输入集得到的精细规则精度明显优于选择最差特征进入最终 DE-ELM 输入集得到的精细规则精度。而且, 随着输入集中选择的特征数目增长, 提取到的精细规则精度也随之上升, 训练时间也相对递增, 因此, 有必要通过特征选择筛选出既能保证输电断面精细规则精度又不会花费大量训练时间的特征。

### 5.3 基于 DE-ELM 的断面精细规则提取

根据 5.2 节结果, 本文选择特征评估值最高的前 40 个特征作为最终输入学习器的训练数据, 最终选择的特征空间如表 4 所示。

表 4 最终特征空间

Table 4 Confirmed features

特征名称
各断面联络线相角差值
节点 3,4,7,8,15,16,18,20,21,23-29,39 有功负荷
节点 30-38 发电机有功出力
节点 31-32,34-39 发电机无功出力
风电场有功出力
送端区域净无功
受端区域净无功

通过 DE-ELM 建立场景 3 的断面精细规则, 将该精细规则对测试集 TTC 进行预测, 结果 MSE 为 0.054, SCC 为 0.985 9, 预测值和实际值之间的误差分布如图 5 所示。




图 5 场景簇 3 预测误差直方图

Fig. 5 Prediction error histogram of cluster 3

同样地，对于其他聚类场景，采用本文所提算法也可以准确地提取断面精细规则。基于场景 3 的样本数量，根据聚类场景的覆盖大小按比例进行缩放得到其他场景簇的样本数，同样选取 200 个测试样本测试精细规则的性能。所有场景簇的规则预测性能如表 5 所示，误差分布如图 6 所示。

表 5 本文方法应用于所有场景簇的性能结果

Table 5 Performance of the proposed method applied to all clusters

场景簇编号	MSE	SCC
1	0.063 7	0.987 3
2	0.052 3	0.991 0
3	0.054 1	0.985 9
4	0.052 5	0.986 9
5	0.071 5	0.983 5




图 6 本文方法应用于所有场景簇的测试误差分布

Fig. 6 Prediction error distribution of the proposed method applied to all clusters

可以看出，本文所提方法能够适应不同场景下的输电断面精细规则提取，通过 DE-ELM 构建的精细规则具有较强的泛化能力，能够快速精确地对断面 TTC 进行预测。

### 5.4 算法对比

本节给出了不同算法提取的精细规则应用于场景簇 3 预测时的性能指标，其中输入特征均和 5.3 节保持一致。如表 6 所示。

表 6 不同算法性能对比

Table 6 Performance comparison for the different methods applied to cluster 3

算法名称	MSE	SCC	训练时间/s
ELM	0.068 5	0.980 4	2.48
BPNN	0.072 3	0.978 3	4.86
DE-ELM	0.054 1	0.985 9	35.74

从表 6 中可以看出，相比于传统 BPNN，ELM 具有更快的训练速度和更强的泛化能力，而本文所

提算法训练速度相对较慢，这是由于进行 DE 寻优时所有个体都需要进行 ELM 学习，降低了总体训练速度。但是相比于 BPNN 和 ELM，DE-ELM 具有更高的精度和更强的泛化能力。考虑到精细规则提取可以通过离线的方式进行，而学习器进行在线预测时所需时间基本在毫秒级，采用更高精度的 DE-ELM 更适合本文场景。

## 6 结论

风电等间歇性清洁能源大规模接入电网使得电网实时运行工况具有更大的随机性和不确定性，传统基于典型工况计算制定的安全稳定运行规则存在失效风险，难以保证电网高效和安全的运行需求。为了解决上述问题，本文基于大数据驱动电力系统规则提取与运行决策的思路，提出了含风电系统输电断面极限传输功率运行规则的自适应差分进化极限学习机提取方法。首先以“风功率-负荷”二维特征表征电网运行工况，基于 K-medoids 聚类方法实现典型运行工况的提取；接着在各典型运行工况的基础上，通过随机抽样生成随机运行工况集，利用内嵌暂态稳定性校核的重复潮流方法搜索求取随机运行工况下关键输电断面的极限传输功率，构成大数据知识库；针对复杂互联电网高维运行特征属性集合，基于 RELIEF-F 算法实现特征降维，辨识与输电断面存在强耦合关联的特征属性；最后，采用差分进化极限学习机在降维特征空间中学习提取输电断面极限传输功率的关联预测规则。在实时运行阶段，可通过两阶段的工况匹配和规则预测，实现输电断面极限传输功率的快速准确估计。含风电的 New England 39 节点算例验证了所提方法具有较强的关联拟合能力和非线性泛化能力，能够实现风电外送断面极限传输功率的快速准确估计。

### 参考文献

[1] 朱星阳, 张建华, 刘文霞, 等. 风电并网引起电网电压波动的评价方法及应用[J]. 电工技术学报, 2013, 28(5): 88-98.  
 ZHU Xingyang, ZHANG Jianhua, LIU Wenxia, et al. A evaluation methodology and its application of voltage fluctuation in power network caused by interconnected wind power[J]. Transactions of China Electrotechnical Society, 2013, 28(5): 88-98.

[2] 段贵钟, 秦文萍, 逯瑞鹏, 等. 考虑风电接入与负荷不确定性的静态电压稳定性分析[J]. 电力系统保护与控制, 2018, 46(12): 108-114.  
 DUAN Guizhong, QIN Wenping, LU Ruipeng, et al. Static voltage stability analysis considering the wind

- power and uncertainty of load[J]. *Power System Protection and Control*, 2018, 46(12): 108-114.
- [3] 蒋维勇, 孙宏斌, 张伯明, 等. 电力系统精细规则的研究[J]. *中国电机工程学报*, 2009, 29(4): 1-7.  
JIANG Weiyong, SUN Hongbin, ZHANG Boming, et al. Fine operational rule of power system[J]. *Proceedings of the CSEE*, 2009, 29(4): 1-7.
- [4] 黄天恩, 孙宏斌, 郭庆来, 等. 基于电网运行大数据的在线分布式安全特征选择[J]. *电力系统自动化*, 2016, 40(4): 32-40.  
HUANG Tianen, SUN Hongbin, GUO Qinglai, et al. Online distributed security feature selection based on big data in power system operation[J]. *Automation of Electric Power Systems*, 2016, 40(4): 32-40.
- [5] 刘若凡, 刘俊勇, 刘友波, 等. 风电接入下断面极限传输功率运行规则的场景聚类提取方法[J]. *电力自动化设备*, 2014, 34(10): 69-74.  
LIU Ruofan, LIU Junyong, LIU Youbo, et al. Scenario clustering method for extracting TTC operating rules of transmission corridor with wind power[J]. *Automation of Electric Power Systems*, 2014, 34(10): 69-74.
- [6] 于之虹, 黄彦浩, 鲁广明, 等. 基于时间序列关联分析的稳定运行规则提取方法[J]. *中国电机工程学报*, 2015, 35(3): 519-526.  
YU Zhihong, HUANG Yanhao, LU Guangming, et al. A time series associative classification method for the operation rule extracting of transient stability[J]. *Proceedings of the CSEE*, 2015, 35(3): 519-526.
- [7] 向德军, 王彬, 郭文鑫, 等. 基于人工神经网络的电力系统精细化安全运行规则[J]. *电力系统保护与控制*, 2017, 45(18): 32-37.  
XIANG Dejun, WANG Bin, GUO Wenxin, et al. Fine security rule for power system operation based on artificial neural network[J]. *Power System Protection and Control*, 2017, 45(18): 32-37.
- [8] 张文广, 张越, 孙亚洲, 等. 最小二乘支持向量机联合改进果蝇优化算法的CFB锅炉燃烧优化[J]. *热力发电*, 2016, 45(7): 44-49.  
ZHANG Wenguang, ZHANG Yue, SUN Yazhou, et al. Combustion optimization for CFB boiler based on least square support vector machine and modified fruit fly optimization algorithm[J]. *Thermal Power Generation*, 2016, 45(7): 44-49.
- [9] 李斌, 邓煜, 边禹铭, 等. 基于 TS 模糊神经网络的湿法脱硫效率预测[J]. *热力发电*, 2016, 45(6): 116-119.  
LI Bin, DENG Yu, BIAN Yuming, et al. Prediction of limestone-gypsum wet flue gas desulfurization efficiency based on T-S fuzzy neural network[J]. *Thermal Power Generation*, 2016, 45(6): 116-119.
- [10] 胡斌, 娄素华, 李海英, 等. 考虑大规模光伏电站接入的电力系统旋转备用需求评估[J]. *电力系统自动化*, 2015, 39(18): 15-19.  
HU Bin, LOU Suhua, LI Haiying, et al. Spinning reserve demand estimation in power systems integrated with large-scale photovoltaic power plants[J]. *Automation of Electric Power Systems*, 2015, 39(18): 15-19.
- [11] 明杰, 向红吉, 戴朝华, 等. 大规模风电接入的运行场景无功优化评估[J]. *电网技术*, 2016, 40(9): 2737-2742.  
MING Jie, XIANG Hongji, DAI Chaohua, et al. Operation scenario reactive power optimization assessment with large-scale wind farm integration[J]. *Power System Technology*, 2016, 40(9): 2737-2742.
- [12] 王芑, 刘伟佳, 林振智, 等. 基于场景分析的风电场与电转气厂站协同选址规划[J]. *电力系统自动化*, 2017, 41(6): 20-29.  
WANG Peng, LIU Weijia, LIN Zhenzhi, et al. Scenario analysis based collaborative site selection planning of wind farms and power-to-gas plants[J]. *Automation of Electric Power Systems*, 2017, 41(6): 20-29.
- [13] 王群, 董文略, 杨莉. 基于 Wasserstein 距离和改进 K-medoids 聚类的风电/光伏经典场景集生成算法[J]. *中国电机工程学报*, 2015, 35(11): 2654-2661.  
WANG Qun, DONG Wenlue, YANG Li. A wind power/photovoltaic typical scenario set generation algorithm based on Wasserstein distance metric and revised K-medoids cluster[J]. *Proceedings of the CSEE*, 2015, 35(11): 2654-2661.
- [14] YAN O, SINGH C. Improvement of total transfer capability using TCSC and SVC[C] // *Power Engineering Society Summer Meeting*, July 15-19, 2001, Vancouver, BC, Canada: 944-948.
- [15] 刘焕志, 李扬, 陈霄. 基于连续潮流的输电网可用输电能力计算[J]. *电力自动化设备*, 2003, 23(12): 5-8.  
LIU Zhihuan, LI Yang, CHEN Xiao. Available transfer capability calculation based on continual power flow for transmission network[J]. *Electric Power Automation Equipment*, 2003, 23(12): 5-8.
- [16] FALAGHI H, RAMEZANI M, SINGH C, et al. Probabilistic assessment of TTC in power systems including wind power generation[J]. *IEEE Systems Journal*, 2012, 6(1): 181-190.
- [17] 汪峰, 白晓民. 基于最优潮流方法的传输容量计算研究[J]. *中国电机工程学报*, 2002, 22(11): 35-40.  
WANG Feng, BAI Xiaomin. OPF based transfer capability calculation[J]. *Proceedings of the CSEE*, 2002, 22(11): 35-40.

- [18] 菅小艳, 韩素青, 崔彩霞. 不平衡数据集上的 Relief 特征选择算法[J]. 数据采集与处理, 2016, 31(4): 838-844.  
JIAN Xiaoyan, HAN Suqing, CUI Caixia. Relief feature selection algorithm on unbalanced datasets[J]. Journal of Data Acquisition and Processing, 2016, 31(4): 838-844.
- [19] ROBNIK-SIKONJA M, KONONENKO I. An adaptation of relief for attribute estimation in regression[C] // Fourteenth International Conference on Machine Learning. Morgan Kaufmann Publishers Inc, 1997: 296-304.
- [20] 黄南天, 李富青, 王文婷, 等. 输电线路故障层次化逐步长 Tsallis 小波奇异熵诊断方法[J]. 电力系统保护与控制, 2017, 45(18): 38-44.  
HUANG Nantian, LI Fuqing, WANG Wenting, et al. A method of transmission line faults diagnosis based on Tsallis wavelet singular entropy with hierarchical variable step size[J]. Power System Protection and Control, 2017, 45(18): 38-44.
- [21] 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.
- [22] 董明刚. 基于差分进化的优化算法及应用研究[D]. 杭州: 浙江大学, 2012.  
DONG Minggang. Research on differential evolution-based optimization algorithms and applications[D]. Hangzhou: Zhejiang University, 2012.
- [23] 罗钢, 杨银国, 钱峰. 含风电场的电力系统动态关键输电断面分析[J]. 广东电力, 2016, 29(10): 54-61.  
LUO Gang, YANG Yinguo, QIAN Feng. Dynamic key power transmission sections of power systems integrated with wind farms[J]. Guangdong Electric Power, 2016, 29(10): 54-61.
- [24] 徐芮, 刘俊勇, 刘友波, 等. 考虑负荷聚类分区与分布式发电接入的配电网主次网架规划方法[J]. 电力自动化设备, 2016, 36(6): 48-55.  
XU Rui, LIU Junyong, LIU Youbo, et al. Primary and subordinate distribution network planning considering load clustering partition and DG integration[J]. Electric Power Automation Equipment, 2016, 36(6): 48-55.

收稿日期: 2018-05-22; 修回日期: 2018-09-30

作者简介:

胥威汀(1988—), 男, 工学博士, 高级工程师, 研究方向为能源电力规划和电力系统知识发现; E-mail: mailtott@163.com

唐权(1982—), 男, 工程师, 从事电力系统规划方面的工作和研究;

邱高(1994—), 男, 通信作者, 博士研究生, 从事电力系统知识发现与表征方面研究。E-mail: qiugaoscu@stu.scu.edu.cn

(编辑 许威)