

〈红外应用〉

基于红外图像与深度学习的 EMS 低压设备 实时断面状态校核方法

戴月明¹, 杨陆锋², 童雄敏²

(1. 国网浙江省电力有限公司永康市供电公司, 浙江 永康 321300;

2. 永康市光明送变电工程有限公司, 浙江 永康 321300)

摘要: 能源管理系统 (energy management system, EMS) 低压设备实时断面状态校核, 是电力设备维护中的难点。基于红外图像与深度学习的 EMS 低压设备实时断面状态校核方法, 利用种子区域生长法分割红外焦平面图像中, EMS 低压设备实时断面的红色分量与绿色分量, 确定 EMS 低压设备异常区域; 提取异常区域目标形状的不变矩, 结合 EMS 低压设备支路开断前后各支路的有功功率之差, 作为实时断面状态校核的特征向量; 构建基于深度神经网络的直流潮流模型, 在该模型内输入特征向量, 输出实时断面状态潮流计算结果, 分析异常区域实时断面状态潮流是否越限, 完成实时断面状态校核。实验证明: 该方法可有效确定 EMS 低压设备的异常区域; 该方法可精准校核设备实时断面状态的潮流, 确保设备检修的安全性; 应用该方法后, 可有效提升线路合格率与电压合格率。

关键词: 红外焦平面图像; 深度学习; EMS 低压设备; 实时断面; 状态校核

中图分类号: TM711

文献标识码: A

文章编号: 1001-8891(2024)12-1464-07

Real-time Section State Verification Method of Energy Management System Low Voltage Equipment Based on Infrared Image and Deep Learning

DAI Yueming¹, YANG Lufeng², TONG Xiongmin²

(1. State Grid Zhejiang Yongkang Power Supply Company, Yongkang 321300, China;

2. Yongkang Guangming Electric Power Transmission & Transformation Co. Ltd., Yongkang 321300, China)

Abstract: Real-time cross-sectional state verification of low-voltage equipment in an energy management system (EMS) is difficult in the maintenance of power equipment. Based on infrared images and deep learning, a real-time cross-sectional state verification method for low-voltage EMS equipment was proposed. The seed region growth method segments the red and green components of the real-time cross-section of the EMS low-voltage equipment in the infrared focal plane image to determine the abnormal area of the EMS low-voltage equipment. The invariant moment of the target shape in the abnormal area is extracted, and the difference in the active power of each branch before and after the disconnection of the EMS low-voltage equipment branch is used as the feature vector of the real-time section state check. A DC power flow model based on a deep neural network is constructed. The feature vector was input into the model, and the real-time section-state power flow calculation results were the output. The real-time section state power flow in abnormal areas was analyzed to determine if it was outside the limit, and a real-time section state check was completed. Experiments show that this method can determine the abnormal area of EMS low-voltage equipment. In addition, this method can accurately check the power flow of the real-time section state of the equipment to ensure the safety of equipment maintenance. Applying this method can improve the line qualification rate and voltage qualification rate.

收稿日期: 2021-11-24; 修订日期: 2024-10-17.

作者简介: 戴月明 (1982-), 男, 浙江兰溪人, 工程师, 本科, 主要从事电网调度工作。E-mail: tuoxuan310857@163.com

基金项目: 中国电力科学研究院有限公司“高比例新能源电力系统长时间尺度功率平衡能力研究”(5100-202055391A-0-0-00)。

Key words: infrared focal plane image, deep learning, EMS low voltage equipment, real-time section, state of the check

0 引言

EMS 低压设备检修,属于电力系统调度运行的结构性优化问题,为确保电力系统运行的安全性,便需合理规范地安排设备检修计划。检修计划是否合理^[1],可通过安全校核进行衡量^[2-3]。调度人员可根据安全校核结果展开辅助决策与裕度评估的求解,制定安全可靠的检修计划,确保检修的安全性,改善EMS 低压设备断面的裕度。安全校核中,校核实时断面状态至关重要,直接影响安全校核稳定分析的精度^[4],同时也影响检修计划的安全性。EMS 低压设备运行的繁琐程度越来越高,因此,对实时断面状态校核的效率与精度要求也越来越严苛^[5]。

在这一领域,相关学者提出了一些智能化判断方法,应俊等人通过分析拓扑类型与更新方式,设计校核框架,提升校核灵活性^[6],但该方法校核速度较慢;梁辰等人先聚类分割图像,搜索图像像素量与边界点,重新分割图像获取异常区域,依据设备使用与未使用状态,建立设备状态指标,通过融合数个指标,实现状态校核,提升校核速度^[7],但该校核精度较低。红外热成像技术具有安全性高与响应快等特点^[8],红外焦平面图像在分析电力设备故障时具备较大优势;深度学习能够在海量数据内有效提取非线性特征,在线求解速度较快^[9],具备较优的泛化能力。

为此研究基于红外图像与深度学习的 EMS 低压设备实时断面状态校核方法,先确定异常区域,仅对异常区域展开实时断面校核,提升校核速度与精度。

1 EMS 低压设备实时断面状态校核方法

本文利用红外图像检测 EMS 低压设备异常区域,提取异常区域目标形状的不变矩,结合 EMS 低压设备支路开断前后各支路的有功功率之差作为实时断面状态校核的特征向量,依据该特征向量通过深度学习校核实时断面状态,判断 EMS 低压设备异常区域检修是否安全。

1.1 基于红外焦平面图像的异常状态检测方法

使用热像仪通过种子区域生长法分割红外图像红色与绿色分量,获取 EMS 低压设备异常区域^[10-11]。该热像仪的具体参数如表 1 所示。

种子区域生长法内种子区域选择非常关键,通过融合局部最高温点和形态学梯度法选择种子区域,令原始红外焦平面图像是 $K(z)$,膨胀后的 $K(z)$ 是 $K_d(z)$,腐蚀后的 $K(z)$ 是 $K_e(z)$;结构元素是 b , $K(z)$ 与 b 所在

范围分别是 E_K 、 E_b 。

表 1 热像仪参数

Table 1 Parameters of the thermal imager	
Parameter	Numerical value
Resolution	640 pixel×480 pixel
Temperature measurement range	-20℃ to 1200℃
Infrared sensitivity	≤0.05℃ at 30℃
Thermal sensitivity	0.03℃
Frame rate	30 frames/s
Visible light camera	Yes
Data Storage	Internal storage 4GB
Battery life	5 h
Dimensions	140 mm×80 mm×190 mm
Accessory	Battery, charger, software

膨胀与腐蚀的定义如下:

$$\begin{cases} K_d(x,y)=\max\left\{K(x-i,y-j)+\right. \\ \left. b(i,j)\middle|(x-i)(y-j)\in E_K,(i,j)\in E_b\right\} \\ K_e(x,y)=\min\left\{K(x+i,y+j)-\right. \\ \left. b(i,j)\middle|(x+i)(y+j)\in E_K,(i,j)\in E_b\right\} \end{cases}$$

(1)

式中: (x,y) 为红外图像像素点。

基本形态学梯度的表达式如下:

$$g(x,y)=K_d(x,y)-K_e(x,y)$$

(2)

局部最高温点都是可能的异常点,设第 n 个局部最高温点是中心的区域 E_n 如下:

$$E_n=\{(x,y)/R(x,y)>\beta_R R(x_n,y_n)\&G(x,y)>\beta_G G(x_n,y_n)\}$$

(3)

式中: (x,y) 的红色、绿色分量值是 $R(x,y)$ 、 $G(x,y)$; $R(x,y)$ 与 $G(x,y)$ 的系数是 β_R 、 β_G ,同时 $0<\beta_R<\beta_G<1$;局部最高温点的红色、绿色分量值是 $R(x_n,y_n)$ 、 $G(x_n,y_n)$ 。

设形态学梯度阈值是 θ_g ,如果 E_n 内包含像素点,且符合 $g(x,y)>\theta_g$, $(x,y)\in E_n$, 那么将 E_n 当成种子区域。

确定 E_n 后,需获取种子生长条件,实现异常区域提取, $R(x,y)$ 内种子生长条件获取步骤如下:

步骤 1: 获取 E_n 的边缘,将其当成初始种子点

(x_0, y_0) ;

步骤2: 衡量 (x_0, y_0) 3×3 邻域中的像素点是否符合如下条件:

$$\begin{cases} E_s < \delta_R \\ E_m < \theta_R \end{cases} \quad (4)$$

式中: 阈值是 δ_R 、 θ_R 。

如果符合, 那么将 (x, y) 当成新的种子点。

步骤3: 对 (x, y) 继续步骤2的操作, 以不再获取符合式(4)条件的像素点为结束生长条件, 获取最终红色分量种子区域 I_{SR} 。同理, 获取最终绿色分量种子区域 I_{SG} , 融合 I_{SR} 与 I_{SG} 得到的交集即 EMS 低压设备异常区域 $H(x, y)$ 。

1.2 基于深度学习的实时断面状态校核方法

通过构建深度神经网络的直流潮流模型, 输出 EMS 低压设备异常区域实时断面状态的潮流计算结果, 依据潮流计算结果, 分析断面是否越限^[12], 为实时断面状态调整提供参考意见, 改善 EMS 低压设备异常区域潮流分布, 提升断面潮流输送能力。

1.2.1 构建特征向量

基于深度神经网络的直流潮流模型, 实现潮流计算的前提是: 构建特征向量, 将其作为输入样本, 进而输出潮流计算结果 Y_{out} 。

提取 $H(x, y)$ 内目标形状的不变矩特征作为特征向量, $H(x, y)$ 的 $(p+q)$ 阶矩与 $(p+q)$ 阶中心矩的公式如下:

$$v_{pq} = \sum x^p y^q H(x, y) \quad (5)$$

$$u_{pq} = \sum (x - x')^p (y - y')^q H(x, y) \quad (6)$$

式中: $H(x, y)$ 的重心坐标是 (x', y') 。

规范化后的 u_{pq} 为:

$$\eta_{pq} = \frac{u_{pq}}{u_{00}^r} \quad (7)$$

式中: $r = (p+q)/2 + 1$ 。

比例因子 k 与 $(p+q)$ 均影响不变矩, 则建立一个改进的不变矩, 公式如下:

$$\psi^* = \left[(\eta_{pq} - \eta_{qp})^2 + 4\eta_{11}^2 \right] / (\eta_{pq} - \eta_{qp})^2 \quad (8)$$

不变矩特征受噪声影响较小, 存在较优的稳定性^[13], 因此可将 ψ^* 作为特征向量。

为提升实时断面状态校核精度, 需考虑 EMS 低压设备异常区域的多方面特征, 因此将 H 内支路开断前后每条支路的有功功率之差 ΔP_{al} 也当成特征向量, 公式如下:

$$\Delta P_{al} = P_{al}^{before} - P_{al}^{after} \quad (9)$$

式中: 支路开断前、后每条支路有功功率是 P_{al}^{before} 、

P_{al}^{after} ; 求解 ΔP_{al} 过程中, 每个节点负荷均选均值。

综上所述, 建立了输入特征向量 $X_{in} = [\psi^*, \Delta P_{al}]$ 。

1.2.2 直流潮流模型设计

深度神经网络包含多层神经元, 在训练完成的直流潮流模型内输入 X_{in} , 获取输出特征向量 Y_{out} , 计算公式如下:

$$Y_{out} = f_{\lambda}^{(c)} \left[\dots f_{\lambda}^{(1)} (X_{in}) \right] \quad (10)$$

$$f_{\lambda}^{(\sigma)} (X^{\sigma-1}) = s(W^{\sigma} X^{\sigma-1} + h^{\sigma}) \quad (11)$$

式中: 第 σ 层神经元的前馈传递函数是 $f_{\lambda}^{(\sigma)}$; 输入是 $X^{\sigma-1}$; 神经网络层数是 c , $\sigma = 1, 2, \dots, c$; 需优化参数是 $\lambda = \{W, h\}$; 权重是 W^{σ} ; 偏移向量是 h^{σ} ; 激活函数是 s 。

确定直流潮流模型后, 能够直接对 EMS 低压设备异常区域实时断面状态校核展开潮流计算, 分析是否存在越限线路, 衡量该实时断面状态是否能够确保 EMS 低压设备安全运行。

1.2.3 直流潮流模型训练方法

该模型利用 s 与 W 、 h 连接各层神经元, 用于获取输入至输出的非线性关系, 训练的目的是获取输出和已知值间尽量一致的 W 、 h 。将最小损失函数当成目标函数, 通过学习算法计算目标函数的 W 、 h 。因此, 直流潮流模型训练主要是确定学习算法、损失函数与激活函数。

通过小批量梯度下降法计算模型的 W 、 h , 加快数据分析效率^[14]。将均方差函数当成损失函数, 可直接体现模型的拟合效果, 公式如下:

$$L(y', \hat{y}) = \frac{1}{2} \sum_{\mu=1}^t (\hat{y}_{\mu} - y'_{\mu})^2 \quad (12)$$

式中: 训练真值是 y' ; 模型求解值是 \hat{y} ; y' 与 \hat{y} 的维

度为 t ; 最优化目标是 $\min L(y', \hat{y})$ 。

针对 W 与 h 的更新公式如下:

$$W_{ij'}^{(\sigma, T+1)} = W_{ij'}^{(\sigma, T)} - \gamma \frac{1}{\rho} \sum_{\mu=r}^{r+\rho} \frac{\partial L}{\partial W_{ij'}^{(\sigma, T)}} \quad (13)$$

$$h_i^{(\sigma, T+1)} = h_i^{(\sigma, T)} - \gamma \frac{1}{\rho} \sum_{\mu=r}^{r+\rho} \frac{\partial L}{\partial h_i^{(\sigma, T)}} \quad (14)$$

式中: 更新 T 次后的权重是 $W_{ij'}^{(\sigma, T)}$; 神经元编号是 i' 、 j' ; 更新 T 次后的偏移向量为 $h_i^{(\sigma, T)}$; 学习速率为 γ ; 样本起始序号为 r ; 终止样本序号为 $r+\rho$; 样本数量为 ρ 。

为缓解各参数间的依赖关系, 提升模型泛化能力,

选择 ReLU 作为激活函数, 公式如下:

$$\text{ReLU}(X_{\text{in}}) = \max(0, X_{\text{in}}) \quad (15)$$

ReLU 当成激活函数情况下, W 的更新公式为:

$$\begin{aligned} o(\zeta) &= (Y_t - y_t) \\ o(\sigma) &= o(\sigma+1)W(\sigma) \circ \max(0, Y_\sigma) \\ oW^\sigma &= o(\sigma+1)^T Y_\sigma / \rho \end{aligned} \quad (16)$$

式中: 通过式(13)与式(14)右边第二项获取参数 o ; 因小批量梯度下降法导致的 W 的改变量是 oW^σ ; 转置为 T , $\zeta \in T$; Hadamard 乘积是 “ \circ ”, 作用为两个矩阵的元素一一相乘。

通过离差标准化方法归一化处理 X_{in} 与 Y_{out} , 将 X_{in} 与 Y_{out} 统一至相同尺度, 可降低数值对模型学习准确性的影响^[15], 处理公式如下:

$$X_{\text{in}} = \begin{cases} (X_{\text{in}} - X_{\text{in,min}}) / (X_{\text{in,max}} - X_{\text{in,min}}), & \text{if } X_{\text{in,max}} - X_{\text{in,min}} \neq 0 \\ X_{\text{in,min}} / X_{\text{in,max}}, & \text{if } X_{\text{in,max}} - X_{\text{in,min}} = 0, X_{\text{in,max}} \neq 0 \\ X_{\text{in}}, & \text{if } X_{\text{in,max}} - X_{\text{in,min}} = 0, X_{\text{in,max}} = 0 \end{cases} \quad (17)$$

$$Y_{\text{out}} = \begin{cases} (Y_{\text{out}} - Y_{\text{out,min}}) / (Y_{\text{out,max}} - Y_{\text{out,min}}), & \text{if } Y_{\text{out,max}} - Y_{\text{out,min}} \neq 0 \\ Y_{\text{out,min}} / Y_{\text{out,max}}, & \text{if } Y_{\text{out,max}} - Y_{\text{out,min}} = 0, Y_{\text{out,min}} \neq 0 \\ Y_{\text{out}}, & \text{if } Y_{\text{out,max}} - Y_{\text{out,min}} = 0, Y_{\text{out,max}} = 0 \end{cases} \quad (18)$$

式中: 训练样本输入的特征向量的最大、最小值为 $X_{\text{in,max}}$ 、 $X_{\text{in,min}}$; 输出潮流的最大、最小值为 $Y_{\text{out,max}}$ 、 $Y_{\text{out,min}}$ 。

2 实验分析

以某区域电网为实验对象, 利用本文方法校核该区域电网内 EMS 低压设备实时断面状态, 分析本文方法校核实时断面状态的效果。

本文方法中设置很多超参数, 其中红色、绿色分量系数直接影响异常区域确定精度, 学习速率直接影响实时断面状态校核精度, 为提升异常区域确定精度需选择最佳的红色、绿色分量系数, 为提升实时断面状态校核效果需选择最佳的学习速率, 将 F1-Score(F1) 作为衡量本文方法异常区域确定准确性的指标, F1-Score 属于精确率与召回率的调和平均值, 可对方法的精确率与召回率展开综合判断, F1 值与异常区域确定精度成正比, 不同红色、绿色分量系数时, 本文方法在确定异常区域时的 F1 值测试结果如图 1 所示。

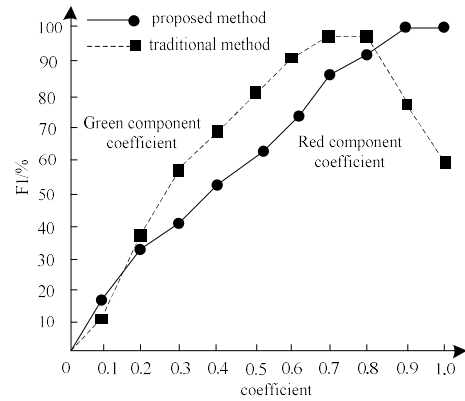


图 1 F1 值测试结果

Fig.1 F1 value test results

由图 1 可知, 随着红色分量系数的增长, 本文方法确定异常区域时的 F1 值呈提升趋势, 当系数为 0.9~1.0 时, F1 值达到最高; 绿色分量系数的不断提升, F1 值呈先增长后下降的趋势, 当系数为 0.7~0.8 时, F1 值达到最高。实验证明: 当红色分量系数为 0.9~1.0, 绿色分量系数为 0.9~1.0 时, 根据对比方法, 得出绿色系数的最优区间, 本文方法确定 EMS 低压设备异常区域时的 F1 值最高, 说明此时的异常区域确定精度最高。

利用 AUC 面积衡量不同学习速率 γ 下, 本文方法校核实时断面状态的精准性, AUC 属于 ROC 曲线下的面积, ROC 曲线横轴为假正例率 (false positive rate, FPR), 纵轴为真正例率 (true positive rate, TPR); AUC 面积越大, 本文方法实时断面状态校核精度越高, 不同学习速率下的 AUC (area under the curve) 测试结果如图 2 所示。




图 2 AUC 测试结果

Fig.2 AUC test results

由图 2 可知, 随着 γ 的增长, 本文方法校核实时断面状态时的 AUC 面积呈先增大后减小的变化, 当 γ 为 0.01 时, AUC 面积最大, 说明此时本文方法校核实时断面状态的精度最高。

在该区域电网内随机选择一个存在异常的 EMS 低压设备, 该设备内共包含 38 条支路, 利用本文方法确定该 EMS 低压设备的异常区域, 确定结果如图 3 所示。

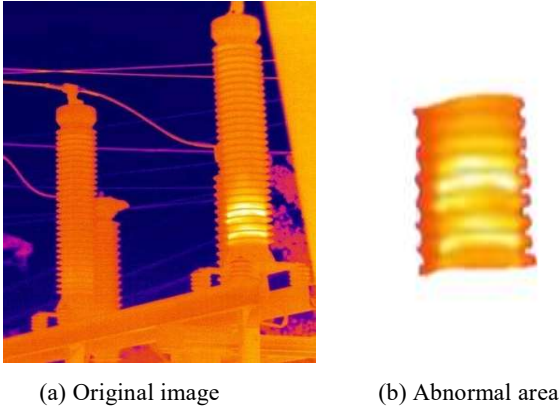


图 3 异常区域确定结果

Fig.3 Abnormal region-determined results

由图 3 得知, 本文方法可有效确定 EMS 低压设备的异常区域, 为后续实时断面状态校核缩小校核范围, 减少校核计算量, 加快校核速度。

异常区域确定后, 利用本文方法校核该区域的实时断面状态, 异常区域内共涉及 12 条支路, 利用本文方法计算各支路潮流, 并分析潮流是否越限完成异常区域校核, 潮流计算结果如表 2 所示。

由表 2 可知, 本文方法可有效计算各支路的潮流, 且计算结果与实际潮流相差较小, 最大误差仅有 0.32 kW; 根据潮流计算结果可知, 支路 1 与支路 4 存在越限情况, 需及时调整这两条支路的实时断面状态, 确保 EMS 低压设备异常区域检修的安全性。

表 2 潮流计算结果

Table 2 Flow calculation results			
Branch road number	Branch road control active power limit/ kW	Actual tidal flow/kW	Calculated power flow/ kW
1	82	96.23	96.11
2	120	94.19	94.25
3	120	87.05	87.05
4	120	132.34	132.02
5	120	86.68	86.71
6	76	39.27	39.38
7	76	43.66	43.53
8	82	55.84	55.77
9	76	39.47	39.47
10	120	58.33	58.26
11	120	57.23	57.21
12	120	53.92	53.98

在该区域电网内随机选择一个 EMS 低压设备, 并在该设备内随机选择 10 条负载率大于 72%的支路, 利用本文方法校核这些支路的实时断面状态, 校核结果如图 4 所示。

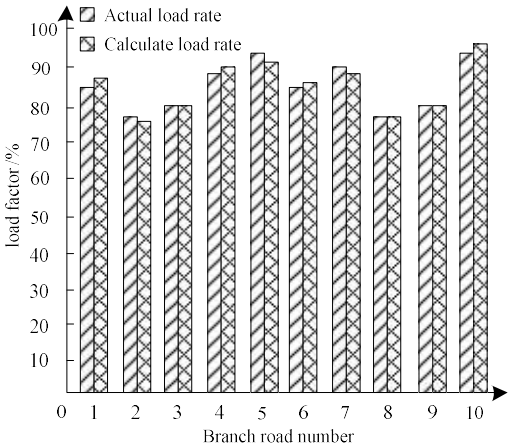


图 4 校核结果

Fig.4 Check results

由图 4 可知, 本文方法可有效校核各支路的负载率, 本文方法获取负载率结果与实际负载率相差较小, 各支路负载率均超过 72%, 说明各支路均未出现越限情况, 无需调整各支路的实时断面状态, 这些支路通过安全校核, 符合 EMS 低压设备检修的安全要求。

在该区域电网内随机选择一个 EMS 低压设备, 测试该设备应用本文方法前一天内的负荷变化曲线, 测试结果如图 5 所示。




图 5 负荷变化曲线

Fig.5 Load variation curves

由图 5 可知, 应用本文方法前后, 一天内负荷变化趋势基本相同, 在用电高峰期即时间段为 08:00–10:00、20:00–22:00 时, 应用本文方法前的负荷超过有功限额, 出现越限情况, 应用本文方法后的

负荷在各个时间段内均未超过有功限额,始终未出现越限情况。实验证明:应用本文方法后,可有效确保EMS低压设备负荷始终低于有功限额,保证检修的安全性。

进一步分析应用本文方法前后EMS低压设备的运行效果,测试时间为一周,测试结果如图6所示。

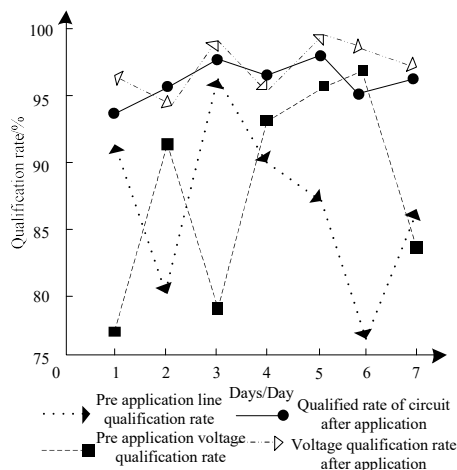


图6 应用前后线路、电压合格率测试结果

Fig. 6 Test results of front and rear line and voltage

由图6可知,在不同天数下,应用本文方法后的线路、电压合格率均高于应用前,且应用前的线路、电压合格率波动幅度显著高于应用后的波动幅度。实验证明:应用本文方法后,可有效提升EMS低压设备的线路合格率与电压合格率。

3 结论

针对EMS低压设备实时断面状态校核,是电力设备维护中的难点。对此,本文研究了一种基于红外图像与深度学习的EMS低压设备实时断面状态校核方法,通过构建深度神经网络的直流潮流模型,输出EMS低压设备异常区域实时断面状态的潮流计算结果,校核可为发电计划与检修计划等提供计算服务,工作人员可根据实时断面状态精准把握检修计划的安全性,为此研究基于红外图像与深度学习的EMS低压设备实时断面状态校核方法,精准校核实时断面状态,分析是否出现越限情况,若存在越限,则需及时调整实时断面状态,确保EMS低压设备检修的安全性。实验结果表明,本文方法能有效地保证EMS低压装置总负载不超过有功限制,从而保障了检修的安全。

参考文献:

[1] 张旭,陈云龙,王仪贤,等.基于潮流断面修正的含风电电网无功-电压分区方法[J].电力自动化设备,2019,39(10):48-54.

ZHANG Xu, CHEN Yunlong, WANG Yixian, et al. Reactive power-voltage partitioning of power grid with wind power based on correction of power flow section[J]. *Electric Power Automation Equipment*, 2019, 39(10): 48-54.

[2] 高旭,马迎新,王可,等.基于连通状态矩阵的智能变电站安措校核方法[J].电力自动化设备,2019,39(7):195-202.

GAO Xu, MA Yingxin, WANG Ke, et al. Verification for security measures of smart substation based on communication state matrix[J]. *Electric Power Automation Equipment*, 2019, 39(7): 195-202.

[3] 吴迪,王正风,刘航.全时间维度调度计划安全校核的设计与应用[J].中国电力,2020,53(5):48-55.

WU Di, WANG Zhengfeng, LIU Hang. Design and application of full-time dimension dispatching schedule safety check[J]. *Electric Power*, 2020, 53(5): 48-55.

[4] 程雄,唐应玲,申建建,等.电力市场环境大规模水电站群月度交易电量分解与校核方法[J].中国电机工程学报,2020,40(8):2514-2525.

CHENG Xiong, TANG Yingling, SHEN Jianjian, et al. Decomposition and checking method for large-scale hydropower plants monthly trading energy in electricity market[J]. *Proceedings of the CSEE*, 2020, 40(8): 2514-2525.

[5] 黄国栋,杨军峰,丁强,等.基于电量裕度的中长期电量安全校核方法[J].电力系统保护与控制,2020,48(2):115-121.

HUANG Guodong, YANG Junfeng, DING Qiang, et al. Medium and long-term electric quantity security check method based on power quantity margin[J]. *Power System Protection and Control*, 2020, 48(2): 115-121.

[6] 应俊,蔡月明,杜红卫,等.配电网模型二次校核方法[J].电力系统自动化,2019,43(7):185-191.

YING Jun, CAI Yueming, DU Hongwei, et al. Secondary verification method of distribution network model[J]. *Automation of Electric Power Systems*, 2019, 43(7): 185-191.

[7] 梁辰,孙建文,王兰玉,等.应用聚类证据理论实现变电站保护压板状态校核[J].电网技术,2020,44(6):2343-2349.

LIANG Chen, SUN Jianwen, WANG Lanyu, et al. Application of clustering and evidence theory to checking the status of substation protection platen[J]. *Power System Technology*, 2020, 44(6): 2343-2349.

[8] 刘齐,王茂军,高强,等.基于红外成像技术的电气设备故障检测[J].电测与仪表,2019,56(10):122-126.

LIU Qi, WANG Maojun, GAO Qiang, et al. Fault detection of electrical equipment based on infrared imaging technology[J]. *Electrical Measurement & Instrumentation*, 2019, 56(10): 122-126.

[9] 周毓敏,邓韦斯,吴云亮,等.基于深度学习的断面约束概率快速预警方法[J].南方电网技术,2020,14(9):45-52.

ZHOU Yumin, DENG Weisi, WU Yunliang, et al. Fast probabilistic

- pre-warning method for transmission capacity constraints based on deep learning[J]. *Southern Power System Technology*, 2020, **14**(9): 45-52.
- [10] 王有元, 李后英, 梁玄鸿, 等. 基于红外图像的变电设备热缺陷自调整残差网络诊断模型[J]. *高电压技术*, 2020, **46**(9): 3000-3007.
- WANG Youyuan, LI Houying, LIANG Xuanhong, et al. Self-adjusting residual network diagnosis model for substation equipment thermal defects based on infrared image[J]. *High Voltage Engineering*, 2020, **46**(9): 3000-3007.
- [11] 周正钦, 冯振新, 周东国, 等. 基于扩展 Meanshift 电气设备发热故障区域提取方法[J]. *红外技术*, 2019, **41**(1): 78-83.
- ZHOU Zhengqin, FENG Zhenxin, ZHOU Dongguo, et al. Fault region extraction of electrical equipment in infrared image by using an extended mean shift method[J]. *Infrared Technology*, 2019, **41**(1): 78-83.
- [12] 蔡晖, 陈倩, 刘宇, 等. 苏州同里新能源小镇的交/直流混合配电网潮流计算方法研究[J]. *电力电容器与无功补偿*, 2020, **41**(2): 110-115.
- CAI Hui, CHEN Qian, LIU Yu, et al. Study on power flow calculation method for AC/DC hybrid distribution network of Tongli new-energy town in Suzhou[J]. *Power Capacitor & Reactive Power Compensation*, 2020, **41**(2): 110-115.
- [13] 吴桂联, 张林垚, 林婷婷, 等. 不同运行模式下区域综合能源系统多能潮流计算方法[J]. *电力系统及其自动化学报*, 2019, **31**(7): 95-104.
- WU Guilian, ZHANG Linyao, LIN Tingting, et al. Calculation method for multi-energy power flow in district-level integrated energy system in different operation modes[J]. *Proceedings of the CSU-EPSS*, 2019, **31**(7): 95-104.
- [14] 王红壮, 刘天琪, 何川, 等. 基于改进脆弱线路辨识的关键输电断面确定方法[J]. *现代电力*, 2020, **37**(3): 294-302.
- WANG Hongzhuang, LIU Tianqi, HE Chuan, et al. Key transmission section determination method based on improved vulnerable line identification[J]. *Modern Electric Power*, 2020, **37**(3): 294-302.
- [15] 唐建兴, 杨君军, 马覃峰, 等. 考虑自动装置控制策略的故障后潮流快速计算方法[J]. *南方电网技术*, 2020, **14**(5): 51-58.
- TANG Jianxing, YANG Junjun, MA Qinfeng, et al. Rapid power flow calculation method after fault considering control strategy of automatic equipment[J]. *Southern Power System Technology*, 2020, **14**(5): 51-58.