

doi: 10.7690/bgzdh.2023.03.008

基于 LLSO-MKELM 算法的观瞄故障诊断

王文傲¹, 李英顺¹, 张杨², 匡博琪², 隋欢欢²

(1. 沈阳工业大学化工过程自动化学院, 辽宁 辽阳 111003; 2. 沈阳顺义科技有限公司技术部, 辽宁 沈阳 110027)

摘要: 针对装甲车辆的观瞄系统, 提出一种基于多核极限学习机 (multi kernel extreme learning machine, MKELM) 的故障诊断模型。利用分级粒子群优化算法 (level-based learning swarm optimizer, LLSO) 优化模型参数, 利用采集历史数据进行仿真实验。结果表明: MKELM 有更好的诊断准确度, 并且 LLSO 可解决 MKELM 相对较多的参数带来的训练速度较慢的问题; 与经典的粒子群算法 (particle swarm optimization, PSO) 相比, LLSO 有着更快的优化速度, 证明了 LLSO-MKELM 可用于观瞄系统故障诊断, 并且有着良好的训练速度和准确度。

关键词: 故障诊断; 观瞄系统; 多核极限学习机; 分级粒子群优化算法; 装甲车辆

中图分类号: TJ07 文献标志码: A

Fault Diagnosis of Observation-aiming Based on LLSO-MKELM Algorithm

Wang Wenao¹, Li Yingshun¹, Zhang Yang², Kuang Boqi², Sui Huanhuan²

(1. School of Chemical Process and Automation, Shenyang University of Technology, Liaoyang 111003, China;

2. Technology Department, Shenyang Shunyi Technology Co., Ltd., Shenyang 110027, China)

Abstract: A fault diagnosis model based on multi-kernel extreme learning machine (MKELM) is proposed for the observation-aiming system of armored vehicles. The parameters of the model are optimized by the level-based learning swarm optimizer (LLSO) algorithm, and the simulation experiments are carried out by using the collected historical data. The results show that MKELM has better diagnostic accuracy, and LLSO can solve the problem of slow training speed caused by relatively more parameters of MKELM. Compared with the classical particle swarm optimization (PSO), LLSO-MKELM has a faster optimization speed, which proves that LLSO-MKELM can be used for fault diagnosis of the observation-aiming system, and has a good training speed and accuracy.

Keywords: fault diagnosis; observation-aiming system; MKELM; LLSO algorithm; armored vehicle

0 引言

观瞄系统, 是指为实施观察、瞄准、跟踪等目的的各种相互作用、相互依赖的设备的总称。作为现代武器系统必不可少的重要组成部分, 武器系统的“眼睛”, 观瞄系统的状态将直接关系到装甲车辆在战场上的生存能力。使用故障诊断系统即时对观瞄系统的故障进行诊断定位对保障装甲车辆的战训能力, 节约维修经费有重大意义。

随着近些年我军机械化、信息化的程度不断提高, 装甲车辆观瞄系统的故障诊断作为提升全军技术水平的一个重点得到了发展。文献[1]引入 D-S 证据理论融合多种专家系统提高了故障诊断的准确度; 文献[2]引入粗糙集理论的改进 DMI 属性约简算法结合故障树解决专家系统难以获取经验知识的问题; 文献[3]结合故障树与专家系统构建故障诊断系统提高了搜索效率。

但这些方法都存在模型构建需要人力花费大量

精力分析数据、随机故障较为突出、诊断结果精确度不够以及必须由人类专家提供故障现象与故障原因之间模糊关系等缺点, 而且难以利用随着全军技术水平的提高而迅速增加的大量数据。近些年随着计算机技术的进步, 机器学习技术得到了很大发展, 利用各种各样的机器学习算法被应用到故障诊断技术中, 如支持向量机^[4]、深度森林^[5]、循环神经网络^[6]等。在各种机器学习算法中由 Huang 等^[7]提出的极限学习机 (extreme learning machine, ELM) 以其高效的训练效率和优秀的泛化性能受到了关注。

ELM 被用于多个领域的故障诊断当中, 例如轴承^[8-9]、齿轮箱^[10-11]、变压器^[12-13]、光伏设备^[14]等, 在这个过程中 ELM 也得到了很大发展, 出现了诸如局部感知野极限学习机^[15]、异常鲁棒极限学习机^[16]、稀疏贝叶斯极限学习机^[17]等多种不同变体。观瞄系统的故障诊断需要利用来自车长周视镜、炮长瞄准镜、夜视仪、测距仪等多个部件的大量数据, 由于多核极限学习机 (MKELM) 具有高维模式识别

收稿日期: 2022-11-13; 修回日期: 2022-12-28

基金项目: 辽宁省“兴辽英才计划”项目(XLYC1903015)

作者简介: 王文傲(1995—), 男, 辽宁人, 硕士, 从事设备故障检测及诊断技术研究。E-mail: 610296847@qq.com。

能力, 以及相对其他算法具有构造简单、学习速度快、人工参与少、泛化性能强等特点, 笔者用其构建故障诊断模型, 并用分级粒子群优化算法(LLSO)对 MKELM 的参数进行优化, 以进行快速准确的故障诊断。

1 KELM

如图 1 所示, ELM 是一种单隐层前馈网络, 采用随机设置隐含层参数然后求解广义逆矩阵的方法得出输出权重向量。

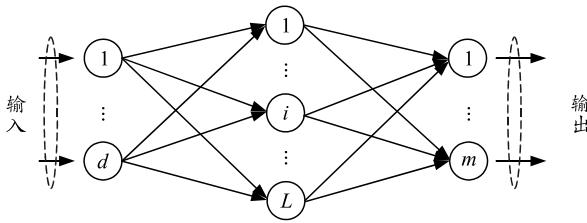


图 1 ELM 模型

极限学习机与传统反向传播神经网络(backpropagation, BP)相比, 最大的优势在于不需要经过不断反复迭代更新得出各层网络连接权值的BP 神经网络。ELM 作为一种正向传播网络在给定隐藏层节点数之后, 能够直接求解 Moore-Penrose 广义逆矩阵获得网络权值而无需反复迭代更新, 从而获得了优秀计算速度, 同时这种求取神经网络权值的方法还给了 ELM 优秀的泛化性能。ELM 基本原理可表示为:

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T} \quad (1)$$

式中: \mathbf{H} 为隐含层输出矩阵; \mathbf{T} 为训练集数据; $\boldsymbol{\beta}$ 为输出权重向量。通过求解 \mathbf{H} 的 Moore-Penrose 广义逆矩阵 \mathbf{H}^\dagger 可得到:

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^\dagger \mathbf{T} \quad (2)$$

为了式子能取得更稳定的泛化性, 一般采取的做法是将正则化系数 C 添加在 $\mathbf{H}\mathbf{H}^T$ 对角线上, 计算 $\boldsymbol{\beta}$ 为:

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^T (I/C + \mathbf{H}\mathbf{H}^T)^{-1} \mathbf{T} \quad (3)$$

再结合模式识别中的核函数理论, Huang 等^[18]提出了核极限学习机(kernelextreme learning machine, KELM), 核函数理论的中心思想是通过映射将低维空间中的函数计算转化为高维空间中的内积, 使得高维空间中的问题可以通过低维空间中的运算来求解, 运用该方法能够有效避免随着计算维数增加计算量指数增加的问题。具体运用到 ELM 上时, 使其可不知隐藏层特征映射的确切维数时, 通过计算核函数内积的方式得出输入到输出的映射

关系。

KELM 便是将核函数理论运用到 ELM 上发展出的, 该算法与传统 ELM 算法的主要区别在于使用核函数映射取代了的传统 ELM 网络中输入到输出的随机映射, 避免了传统 ELM 中由于通过随机选取获得隐藏层参数的方法导致回归和分类性能不稳定的问题。

$$\mathbf{Q}_{\text{ELM}} = \mathbf{H}\mathbf{H}^T : \mathbf{Q}_{\text{ELM}}_{i,j} = h(x_i) \cdot h(x_j) = K(x_i, x_j) \quad (4)$$

式中: \mathbf{Q} 为核函数矩阵; $K(\cdot)$ 为核函数。

$$\mathbf{H}\mathbf{H}^T = \mathbf{Q}_{\text{ELM}} = \begin{bmatrix} K(x_1, x_1) & \cdots & K(x_1, x_N) \\ \vdots & & \vdots \\ K(x_N, x_1) & \cdots & K(x_N, x_N) \end{bmatrix} \quad (5)$$

得到:

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^T (I/C + \mathbf{Q}_{\text{ELM}})^{-1} \mathbf{T} \quad (6)$$

由于不同核函数有各自不同的性质, 为特定任务选取合适的核函数需要花费很多精力, 并且单个核函数的性质很可能无法满足任务的需求, 于是 Liu 等^[19]将多个核函数进行线性组合提出了 MKELM。

2 LLSO-MKELM

2.1 LLSO 算法

2017 年提出的 LLSO 可有效地搜索大规模问题的全局最优解^[20]。如图 2 所示, LLSO 有 2 个主要思想, 即基于等级的学习(level-basedlearning, LL)策略和典范选择。社会学习粒子群优化(social learning-particle swarm optimization, SL-PSO)算法^[21]中的粒子根据其适应值进行排序, 然后使用 LL 策略将其分为 NL 个级别。较好的粒子具有较高的等级, 其对应的等级具有较小的下标。如果 L_i 代表第 i 级, L_1 是包含最佳粒子的最高等级。高等级的粒子可能包含更多有用的信息, 可以用来指导低等级的粒子搜索全局最优区域。假设粒子群的大小为 NP , 每级的粒子数为 LS , 那么总级数就是 $NL = NP/LS$, 维度为 D 。首先, 粒子群按适合度升序排序; 然后将粒子群分为 NL 级; 最后, L_i 级($2i \leq NL - 1$)的粒子通过向 L_i 至 L_{i-1} 级的粒子学习来更新。

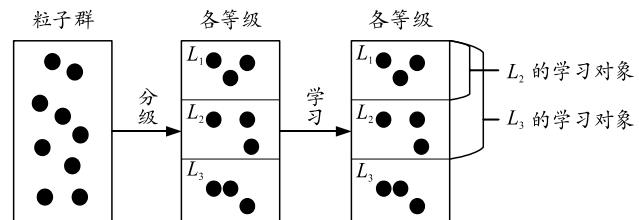


图 2 LLSO 算法

低级粒子需向高级粒子学习。一个关键问题是如何在高等级上选择 2 个典范。典范选择策略提供了一种选择典范的方法，并考虑了粒子的探索和利用，这是大规模优化的 2 个关键评价指标。 L_i 的典范选择过程总结如下：1) 随机选择 rl_1 和 rl_2 ，其中 $rl_1, rl_2 \in [1, i-1]$ ；2) 如果 $rl_1 > rl_2$ ，交换它们的值；3) 随机选择 k_1 和 k_2 ， $k_1, k_2 \in [1, LS]$ ；4) 返回水平 rl_1 中的第 k_1 个粒子 (X_{rl_1, k_1}) 和水平 rl_2 中的第 k_2 个粒子 (X_{rl_2, k_2})。在学习过程中，典范 X_{rl_1, k_1} 和 X_{rl_2, k_2} 将指导 L_i 级中的粒子进化。因此，LLSO 中的更新粒子 $X_{i,j}$ 的情况如下：

$$v_{i,j}^{(n+1)} = r_1 \times v_{i,j}^{(n)} + r_2 \times (X_{rl_1, k_1}^{(n)} - X_{i,j}^{(n)}) + \phi \times r_3 \times (X_{rl_2, k_2}^{(n)} - X_{i,j}^{(n)}); \quad (7)$$

$$X_{i,j}^{(n+1)} = X_{i,j}^{(n)} + v_{i,j}^{(n)}. \quad (8)$$

式中： $X_{i,j}$ 是 L_i 中的第 j 个粒子； $v_{i,j}$ 是其速度； X_{rl_1, k_1} 和 X_{rl_2, k_2} 是由典范选择策略决定的；参数 r_1 、 r_2 和 r_3 是在 $[0, 1]$ 范围内随机选择的； ϕ 是一个控制参数，决定了第二典范的影响，其值也在 $[0, 1]$ 范围内。

L_i 中的粒子包含了粒子群中的最佳解，所以它们直接进入下一代粒子群。在 LLSO 算法中，适应值优良的粒子被保留下学习，适应值不佳的粒子探索更优的取值，这在保持了粒子多样性的同时加速了粒子的收敛，提高了对参数进行优化的速度。

由于 LLSO 中保持了粒子群优化算法的简单性，LLSO 计算的时间复杂度非常简单。首先，它对粒子群进行排序需要 $O(NP\log(NP)+NP)$ ，并将粒子群划分为每一代的 NL 级别。除了第一级的粒子直接进入下一代外，更新所有等级的粒子需要 $O(NP\times D)$ 。在空间复杂度方面，LLSO 需要的空间比 PSO 少得多，因为它不为每个粒子存储个人最优位置，这需要 $O(NP\times D)$ 空间。总之，与经典的粒子群优化算法相比，LLSO 在时间和空间上都保持较高的计算效率。

2.2 LLSO-MKELM

MKELM 相对 KELM 参数量大大增加，其训练效果会受这些参数的影响。利用 LLSO 方法对 MKELM 参数进行优化，可以提高 MKELM 训练速度和效果稳定性。

使用 LLSO 方法优化 MKELM 的流程如下：

输入：粒子群大小 NP 、等级数 NL 、每级粒子数 LS 、控制参数 ϕ 、最大优化次数 MAX_FES 。

输出：核函数参数、核函数组合权重和正则化系数 C 。

第 1 步：LLSO 粒子群随机初始化。每个粒子由正则化系数和核函数参数组成；

第 2 步：计算每个粒子的适应度值。利用粒子的相关变量构造 MKELM；

第 3 步：更新低等级粒子群，按照预定的迭代次数重复第 2 步和第 3 步；

第 4 步：将上述步骤中生成的 MKELM 最优粒子输入到实验数据中，以获得所提方法的预测精度。

利用 LLSO 进行具体的优化流程如图 3 所示。

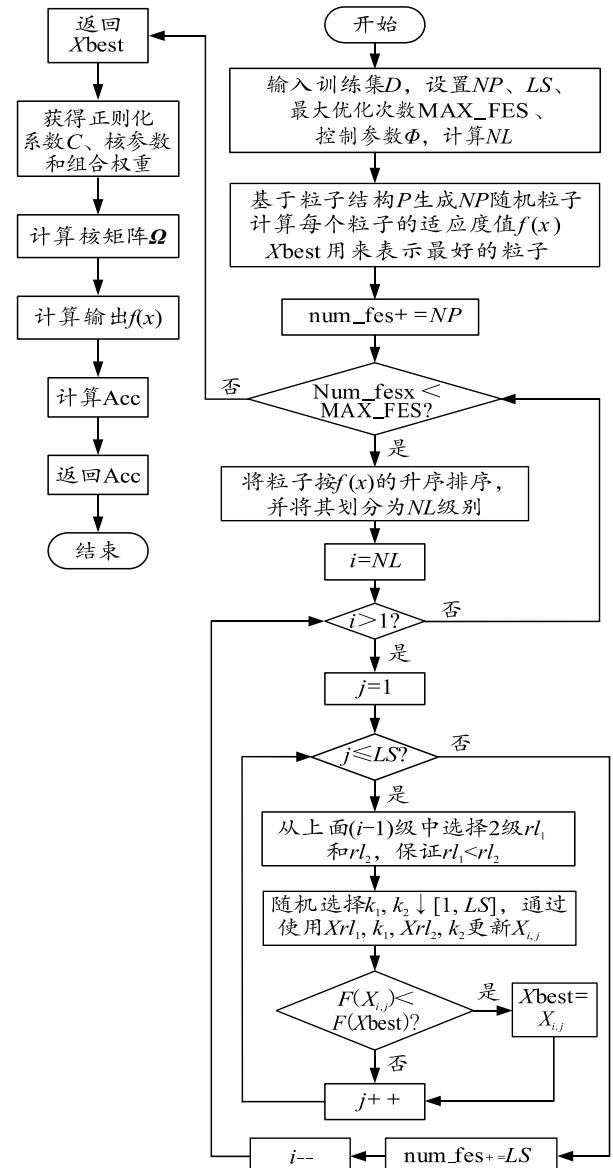


图 3 LLSO-KELM 流程

3 基于 LLSO-MKELM 的故障诊断设计

基于 LLSO-MKELM 模型的故障诊断设计如图 4 所示。

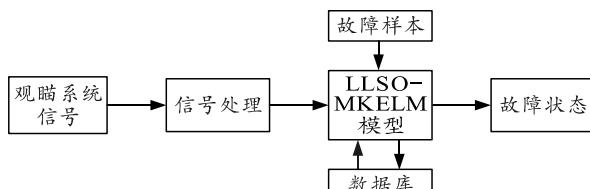


图 4 故障诊断

- 1) 对来自观瞄系统的信号进行处理, 滤除其中的噪声。
- 2) 使用故障样本数据对 LLSO-KELM 模型进行训练和学习, 将优化训练得到的网络参数存放于数据库中。将参数储存在数据库中可以按照检测的不同车型车辆选择对应的最优模型, 并且储存起来的模型参数还可用予将来对模型的改进中。
- 3) 处理后信号送入训练好的模型进行推理。

- 4) 在故障样本进行推理后, 标记输出值最大的输出神经元, 该输出神经元的编号即是对应故障的编号。

4 仿真实验过程及结果

使用 Matlab 对利用 LLSO-MKELM 构建的模型进行仿真实验并与使用 PSO 算法与 SL-PSO 优化的模型进行对比, 仿真结果如图 5 所示。

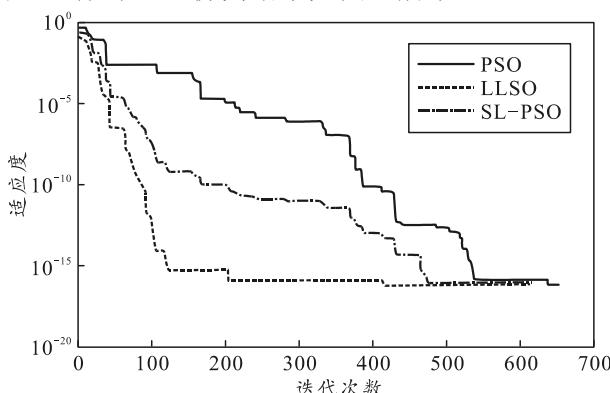


图 5 LLSO 与 PSO 对比

从上图可见, 与 PSO 和 SL-PSO 相比, 使用 LLSO 优化 MKELM 有着更高的训练速度且准确度也略有优势。

随后将 MKELM 模型与使用不同核函数的 KELM 模型进行对比, 结果如表 1 所示。

表 1 MKELM 与其他核函数对比 %

核函数	精度	核函数	精度
MKELM	96.37	多项式核	86.63
RBF 核	92.50	小波核	93.88
线性核	68.12		

从上表中可见, MKELM 相比使用单个核函数的 KELM 有着更好的分类精度。

5 结论

笔者结合 MKELM 较高的分类准确度和较好的泛化性能以及 LLSO 优化算法的优化速度快、空间和时间复杂度低等优势, 提出了基于 LLSO 改进的 MKELM 的故障诊断模型, 可以应用于观瞄系统的故障诊断中。与使用单个核函数的 KLEM 相比新的模型有着更好的分类准确度; 相比使用传统的 PSO 算法优化, 使用 LLSO 算法可以在准确度几乎不变的情况下显著降低训练时间。

参考文献:

- [1] 李英顺, 江山青, 陈悦峰, 等. D-S 证据融合的坦克火控系统混合故障诊断[J]. 火炮发射与控制学报, 2020, 41(1): 104–108.
- [2] 李英顺, 陶加云, 徐亚平, 等. 基于改进 DMI 与故障树以及 IFR 的故障诊断专家系统设计[J]. 自动化技术与应用, 2016, 35(10): 89–94.
- [3] 江山青, 李英顺, 张银图. 基于故障树和规则的火控系统故障诊断专家系统[J]. 兵工自动化, 2019, 38(4): 40–44.
- [4] 李英顺, 张童鑫, 伊泉剑. 一种基于改进支持向量机的炮控系统故障诊断方法[J]. 自动化与仪器仪表, 2019(7): 155–160.
- [5] 郭莹莹, 张磊, 肖成, 等. 基于改进深度森林算法的风电机组故障诊断技术研究[J]. 可再生能源, 2019, 37(11): 1720–1725.
- [6] 刘云, 尹传环, 胡迪, 等. 基于循环神经网络的通信卫星故障检测[J]. 计算机科学, 2020, 47(2): 227–232.
- [7] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: Theory and applications[J]. Neurocomputing, 2005, 70(1): 489–501.
- [8] 董治麟, 郑近德, 潘海洋, 等. 一种时移多尺度排列熵与 ELM 相结合的滚动轴承故障诊断方法[J/OL]. 机械科学与技术: 1–7[2021-09-01]. <https://doi.org/10.13433/j.cnki.1003-8728.20200252>.
- [9] 李可, 熊檬, 宿磊, 等. 基于改进深层极限学习机的故障诊断方法[J]. 振动、测试与诊断, 2020, 40(6): 1120–1127, 1232.
- [10] 刘文翰. 函数型数据分析研究及其在齿轮箱的故障诊断和发动机的寿命预测[D]. 包头: 内蒙古科技大学, 2020.
- [11] 张文兴, 刘文翰, 王建国. FPCA 和径向基极限学习机的齿轮箱故障检测方法[J]. 机械科学与技术, 2020, 39(12): 1872–1876.
- [12] 王春明, 朱永利. 基于 NSGA2 优化正则极限学习机的变压器油色谱故障诊断[J]. 高压电器, 2020, 56(9):

- 210–215.
- [13] 魏巍, 马心怡, 薛鹏. 免疫粒子群优化核极限学习机变压器故障诊断[J]. 长春工业大学学报, 2020, 41(5): 430–435.
- [14] 孙莉, 李静, 李继云, 等. 基于稀疏贝叶斯极限学习机的光伏电站设备故障诊断研究[J]. 太阳能学报, 2020, 41(8): 221–226.
- [15] HUANG J H, YU Z L, CAI Z Q, et al. Extreme learning machine with multi-scale local receptive fields for texture classification[J]. Multidimensional Systems and Signal Processing, 2017, 28(3): 995–1011.
- [16] ZHANG K, LUO M X. Outlier-robust extreme learning machine for regression problems[J]. Neurocomputing, 2015, 151: 1519–1527.
- [17] LUO J H, VONG C M, WONG P K. Sparse Bayesian

(上接第 8 页)

- [40] 段尊雷, 任光, 李烨. 基于深度信念网络的轮机实操智能评估方法[J]. 大连海事大学学报, 2017, 43(3): 89–94.
- [41] 李波, 雉浩然, 田琳宇, 等. 基于 DBN 效能拟合的舰艇编队作战效能敏感性分析[J]. 航空学报, 2019, 40(12): 156–166.
- [42] 戚宗峰, 王华兵, 李建勋. 基于深度学习的雷达侦察系统作战能力评估方法[J]. 指挥控制与仿真, 2020, 42(2):

(上接第 22 页)

- 1) 首先在文件导入时, 截取文件流转化为字符串;
- 2) 在字符串中找出加密时加入的特殊符号, 将特殊符号之间的字符串取出, 并且使用 cmsB64_decode 将分段文件解密, 放入字符数组中;
- 3) 将指针移动到下一个特殊符号之后, 将特殊长度的字符串解密, 拼接到上一个字符数组后面;
- 4) 重复第 3)步的步骤, 将所有的加密文件全部解密, 并拼接;
- 5) 完成后, 将拼接完成的字符串送入之前截取流的程序中, 进入后续的备份文件校验及系统中的存储;
- 6) 校验成功, 解密结束。

5 结束语

结果表明: 博通平台的家庭网关配置文件分段加密方法, 可靠性高。如果不知道加密分段长度和

- extreme learning machine for multi-classification[J]. IEEE transactions on neural networks and learning systems, 2014, 25(4): 836–843.
- [18] HUANG G B, WANG D H, LAN Y. Extreme learning machines: a survey[J]. International Journal of Machine Learning and Cybernetics, 2011, 2(2): 107–122.
- [19] LIU X W, WANG L, HUANG G B, et al. Multiple kernel extreme learning machine[J]. Neurocomputing, 2015, 149: 253–264.
- [20] YANG Q, CHEN W N, DENG J D, et al. A level-based learning swarm optimizer for large-scale optimization[J]. IEEE Transactions on Evolutionary Computation, 2017, 22(4): 578–594.
- [21] CHENG R, JIN Y C. A social learning particle swarm optimization algorithm for scalable optimization[J]. Information Sciences, 2015, 291: 43–60.
- *****
- [22] 杨洋, 刘永鹏, 于家傲, 等. 运用深度信念网络的雷达干扰效能评估[J]. 空军预警学院学报, 2020, 34(5): 356–359.
- [23] 张笑楠. 基于 CapsNet 的无人机群智能化效能评估方法研究[D]. 北京: 国防科技大学, 2018.
- [24] 李妮, 李玉红, 龚光红, 等. 基于深度学习的体系作战效能智能评估及优化[J]. 系统仿真学报, 2020, 32(8): 1425–1435.
- *****

加入的特殊符号, 就无法解密配置文件, 能够很好地提高网关系统的安全性, 保护用户隐私, 满足用户要求。

参考文献:

- [1] 林杨. 光纤复合相线配网施工新技术[J]. 电力系统通信, 2011, 32(3): 1–4.
- [2] 潘锋. 基于混合加密算法的测发控系统无线通讯加密研究[J]. 自动化技术与应用, 2019, 38(11): 72–78.
- [3] 欧阳斌. 接入网 GPON 光模块设计的研究[D]. 哈尔滨: 哈尔滨工业大学, 2010: 55.
- [4] 刘亮, 权冀川, 姜伟杰, 等. 基于信息行为的网络信息服务质量和评估模型[J]. 兵工自动化, 2022, 41(6): 35–40.
- [5] 霍恒浩, 石鹏飞, 王敏文, 等. 基于改进序列二次规划的非线性控制分配[J]. 兵工自动化, 2022, 41(8): 74–80.
- [6] 邢晓溪. 基于 GPON 技术的小区接入网应用分析[J]. 电子产品世界, 2016(10): 55–56, 60.
- [7] 魏浩. 千兆无源光网络 (GPON) 网元管理系统 (EMS) 的模块设计与实现[D]. 北京: 北京交通大学, 2011: 67.