

中图法分类号: TN929.5 文献标识码: A 文章编号: 1006-8961(XXXX)XX-0001-14

论文引用格式: Lu Jun, Wu Shangrong, Sun Shize, Xu Xiangyu, Gong Gangjun, Liu Xiangjun. Joint optimization of semantic communication for power image monitoring[J/OL]. Journal of Image and Graphics, XXXX: 1-14. DOI: 10.11834/jig.260071. (陆俊, 吴尚容, 孙仕泽, 许祥宇, 龚钢军, 刘向军. 语义通信联合优化的电力图像监测[J/OL]. 中国图象图形学报, XXXX: 1-14. DOI: 10.11834/jig.260071.) [DOI: 10.11834/jig.260071]

语义通信联合优化的电力图像监测

陆俊, 吴尚容, 孙仕泽, 许祥宇, 龚钢军, 刘向军

华北电力大学电气与电子工程学院, 北京昌平 102206

摘要: 目的 电力图像监测主要分为传输与识别过程, 传统监测方法未从语义层面考虑将二者进行联合优化, 使得传输过程中目标语义信息无法充分提取, 进一步导致了图像识别率偏低。针对电力图像受噪声干扰导致监测效率低下问题, 提出一种基于语义通信联合优化的端到端电力图像监测方法。方法 首先, 在语义通信框架下设计轻量化卷积自编码器(convolutional autoencoder, CAE)传输模型, 并引入基于通道注意力机制模块, 使得模型更关注电力语义特征。其次, 以 vision transformer(ViT)为主体架构设计 ViT 识别模型, 提出注意力引导的卷积编码模块, 使得模型更好的理解电力图像局部语义特征。级联上述模型得到 CAE-ViT 模型, 作为电力图像监测框架, 并基于所提框架的参数空间扩展与语义优化方向设计联合训练方法, 实现语义通信联合优化的电力图像监测。结果 实验采用中国电力线路绝缘子数据集(chinese power line insulator dataset, CPLID)和电力线路资产巡检数据集(inspection power line asset dataset, InsPLAD)进行验证, 与对比方法相比, 本文方法在低信噪比(-10dB~10dB)条件下电力图像监测识别率提高了4%~26%, 验证了所提方法有效性。结论 本文提出的方法在复杂电磁环境无线信道中更具鲁棒性, 且进一步提升了电力图像的监测效率, 为电力图像监测实际应用部署提供了有益的技术借鉴。

关键词: 语义通信; 电力图像监测; 语义图像传输; 电力图像识别; 复杂电磁环境; 联合训练; 语义优化方向

Joint optimization of semantic communication for power image monitoring

Lu Jun, Wu Shangrong, Sun Shize, Xu Xiangyu, Gong Gangjun, Liu Xiangjun

College of Electrical and Electronic Engineering, North China Electric Power University, Changping District, Beijing 102206, China

Abstract: With the rapid advancement of smart grid construction and intelligent power inspection technology, power image monitoring has become a core technical means for equipment fault detection, line state assessment and power operation safety supervision. Power inspection images collected by wireless terminal devices contain key semantic information such as insulator state, line asset distribution and equipment operating conditions, which directly determines the accuracy and efficiency of subsequent intelligent recognition and fault diagnosis. However, traditional power image monitoring and transmission schemes adopt separated processing modes of signal transmission and target recognition, which lack joint optimization design at the semantic level of image features. Most conventional methods merely focus on the optimization of pixel-level image transmission quality or shallow feature extraction, failing to fully mine, retain and transmit the core semantic features unique to power images during wireless channel transmission. In complex electromagnetic operation environments of power systems, wireless transmission channels are susceptible to random noise interference, signal attenuation and channel fading, which easily cause the loss of effective power semantic information, blurring of key target features and confusion

收稿日期: 2026-01-29; 修回日期: 2026-07-06

基金项目: 国家电网有限公司总部管理科技项目(5700-202499326A-1-3-ZB);

Supported by: Project Supported by the headquarters of State Grid Corporation of China manages scientific and technological projects (5700-202499326A-1-3-ZB).

of background information. These inherent defects ultimately lead to low target recognition accuracy, poor anti-interference performance and unsatisfactory overall monitoring efficiency of existing power image monitoring technologies, severely restricting the reliable application of intelligent inspection equipment in complex power operation scenarios. Aiming at the low monitoring accuracy and poor noise resistance capability of traditional power image monitoring methods under low signal-to-noise ratio (SNR) and complex electromagnetic interference conditions, this paper proposes an end-to-end power image monitoring method based on semantic communication joint optimization, which integrates semantic feature transmission and intelligent target recognition into a unified framework to break the performance bottleneck of separated traditional schemes. In terms of methodological design, this paper constructs a novel end-to-end joint optimization framework centering on semantic communication and power image intelligent recognition. Firstly, against the traditional transmission model's defect of ignoring semantic feature priority, a lightweight convolutional autoencoder (CAE) transmission model is constructed under the complete semantic communication framework. To solve the problem of ineffective extraction and loss of key power semantic features in the transmission process, a channel-based attention mechanism module is embedded into the CAE transmission model. This module can adaptively assign weight coefficients to different channel features, suppress the interference of invalid background noise features, and force the model to focus on extracting and retaining core power semantic features such as power line contours, insulator structures and equipment defect characteristics, thereby realizing semantic-aware optimized transmission of power images. Secondly, aiming at the insufficient local semantic feature perception capability of mainstream recognition models for power images, a vision transformer (ViT) based intelligent recognition backbone model is designed. On the basis of the standard ViT architecture, an attention-guided convolutional coding block module is innovatively proposed and embedded into the recognition network. This module combines the local feature extraction advantages of convolution and the global semantic modeling capability of transformer, effectively compensating for the deficiency of pure ViT models in capturing fine-grained local semantic features of power images, and significantly improving the model's understanding and discrimination ability of subtle defect features and power equipment semantic information. On this basis, the CAE transmission model and the improved ViT recognition model are organically integrated to build a unified CAE-ViT power image monitoring framework. To further realize deep coupling and global optimization of transmission and recognition links, a targeted joint training strategy is designed according to the parameter space expansion characteristics and semantic feature optimization direction of the proposed framework. This training method synchronously optimizes the transmission coding parameters and recognition network parameters, eliminates the feature mismatch problem caused by separate training of transmission and recognition models, and finally achieves semantic communication joint optimization for full-process power image monitoring. To verify the feasibility, robustness and superiority of the proposed method in complex noise interference scenarios, comprehensive comparative experiments are conducted on two authoritative public power image datasets, namely the chinese power line insulator dataset (CPLID) and the inspection power line asset dataset (InsPLAD). The experimental test scenarios cover a typical low SNR range from -10dB to 10dB, which simulates the actual complex electromagnetic noise interference environment of field power inspection. A variety of mainstream existing power image monitoring and recognition methods are selected as baseline comparison schemes for horizontal performance evaluation. The experimental results demonstrate that compared with all comparative methods, the proposed semantic communication joint optimization method achieves a significant improvement in power image monitoring and recognition accuracy, with the overall recognition rate increased by 4% to 26% under low SNR conditions. The performance improvement is more obvious in extreme low-noise environments, which fully proves that the proposed method can effectively resist wireless channel noise interference, retain key power semantic information stably, and avoid feature loss and recognition failure caused by channel distortion. In conclusion, the proposed CAE-ViT joint optimization method exhibits excellent channel robustness and semantic feature retention capability in complex electromagnetic wireless transmission environments. It fundamentally solves the problems of insufficient semantic feature extraction, serious feature loss and low recognition accuracy existing in traditional separated power image monitoring schemes, and greatly improves the overall intelligent monitoring efficiency and environmental adaptability of power image inspection. This method provides an effective and feasible technical solution for high-precision and high-reliability power image monitoring under complex working conditions, and offers a valuable theoretical reference and engineering application basis for the popularization and deployment of intelli-

gent power inspection, power equipment fault diagnosis and smart grid visual monitoring systems in complex electromagnetic scenarios.

Key words: Semantic Communication; Power Image Monitoring; Semantic image transmission; Power image recognition; Complex electromagnetic environment; Joint Training; Semantic Optimization Direction

论文引用格式: Lu Jun, Wu Shangrong, Sun Shize, Xu Xiangyu, Gong Gangjun, Liu Xiangjun. Joint optimization of semantic communication for power image monitoring[J/OL]. Journal of Image and Graphics. DOI: 10.11834/jig. 260071. (陆俊, 吴尚容, 孙仕泽, 许祥宇, 龚钢军, 刘向军. 语义通信联合优化的电力图像监测[J/OL]. 中国图象图形学报. DOI: 10.11834/jig. 260071.)

0 引言

电力图像监测系统的高效稳定运行直接关系到电网供电的安全性、稳定性与可靠性。电力图像监测通常涵盖图像数据的采集、处理、传输与识别等环节,其中,图像传输与识别过程的可靠性和鲁棒性是制约整体监测效率的核心因素(Shi等,2019)。随着智能化、可视化巡检模式的不断推进,以无人机搭载高清成像设备为代表的非接触式巡检方式逐渐成为电力图像监测的主要方式(Shao等,2020),通过结合深度学习技术对监测图像中的目标进行精准识别与分类(Hu等,2025),可以显著提升巡检的智能化水平与工作效率。然而,在电力图像传输过程中易受复杂电磁环境的噪声干扰,导致图像重建精度下降,从而对后续识别任务的准确性产生连锁影响;此外,电力图像识别任务通常面临背景复杂、光照条件变化显著以及缺陷样本数量有限等问题,传统识别方法在特征表征能力与分类精度方面仍存在一定局限性,整体识别性能有待进一步提升。

本文相关研究主要包括电力图像识别、语义图像传输以及语义联合优化等方面。

在电力图像识别方面,Zhang等人(2023)在YOLOv7模型中引入金字塔结构提升对绝缘子及缺陷识别能力;Song等人(2023)提出一种改进的粒子群优化支持向量机方法,利用双层级联形态学改进的种子区域生长实现目标分割并通过粒子群算法优化参数,实现对绝缘子正常与缺陷状态的识别;Li等人(2025)提出结合条带注意力模块与卷积网络的改

进transformer方法,通过引入对比学习提升复原效果,从而增强后续绝缘子定位与缺陷检测的准确性;Gao等人(2025)提出了一种轻量级检测框架LCFM-Net,实现了电网维护中自动化高精度绝缘子缺陷检测;Liang等人(2023)提出基于结构化剪枝的检测方法,通过hardswish激活函数、锚框聚类及稀疏训练剪除冗余通道,实现高精度实时性的绝缘子检测;Nie等人(2025)提出了一种基于YOLOv8-RFL模型的输电线路绝缘子缺陷检测方法,保证检测精度的同时提高模型的计算效率和实时性。

在语义图像传输方法方面,近年来6G相关语义通信和深度学习算法的相互交叉融合使得面向电力任务的高效图像传输成为可能(Yu等,2025)。Bourtsoulatzé等人(2019)首次提出了图像端到端深度联合信源信道编码架构(deep joint source-channel coding, DJSCC),实现了低信噪比下图像传输的高抗噪性能;Fu等人(2025)提出利用生成对抗网络实现图像语义的纠错器,并通过监督学习引入混合自动重传请求技术,提升图像语义传输的可靠性;Zhang等人(2023)提出一种新的基于语义域资源的多址技术,称为模分多址,证明模分多址比传统多址技术获得更多性能提升;Li等人(2026)提出了一种基于SwinTransformer的无线图像传输语义通信系统,可以在单个系统模型下自适应工作于不同的信道状态和传输速率。

在语义联合优化方面,Huang等人(2025)提出了一种针对语义图像传输的数字深度联合源信道编码新框架,该框架通过联合优化数字源和信道编码减少了端到端失真;Chen等人(2026)针对通感算协同网络,提出了一种基于语义通信框架的联合优化方法;Li等人(2024),提出一种将AI架构引入无线传输收发方案的联合优化方法,提升了语义编码和传输的系统性能;Zhao等人(2024)提出一种三阶段算法,解决多用户概率语义通信网络中联合传输与计算资源优化的问题。

以上研究内容有效的推进了图像传输与识别的发展;但在电力图像监测特定任务场景中尚存在一

定技术局限,主要表现为:(1)图像监测方法中传输与识别任务通常被视作两个独立模块,电力图像识别方法都是基于清晰图像,电力信道场景常面临复杂电磁环境噪声影响,未考虑传输和识别的联合训练,使得现有监测方法对含噪图像识别呈现出弱鲁棒性;(2)现有语义图像传输与语义联合优化方法多为传输模块内部或与资源模块间的联合优化,未从语义层面考虑传输模块与任务模块的联合优化,使得目标任务语义信息未能充分提取,降低了语义任务的整体性能。

1 CAE-ViT 电力图像监测方法

1.1 CAE-ViT 电力图像监测框架

所设计的 CAE-ViT 电力图像监测框架如图 1 所

示。该框架由终端采集侧、通信信道侧与平台侧组成。其中,终端采集侧部署卷积自编码器(convolutional autoencoder, CAE)语义编码器;平台侧部署语义解码器、vision transformer (ViT) 识别模型。基本思想是,考虑电力图像传输过程中对电力语义特征的重点提取需求,因此设计基于通道注意力机制的 CAE 语义编码器,完成对电力图像的语义提取与信源信道联合编码。经过信道传输的信息送入 CAE 语义解码器,考虑电力图像识别需要提高设备区域局部感知能力,设计由注意力引导的卷积编码块(block),从而构成 ViT 识别模型,完成对电力图像辨识监测。与现有图像监测方法不同的是,为了提取更适配监测识别任务的语义特征,采用了联合训练方法,从而提升所提方法的整体监测效率。




图1 CAE-ViT 电力图像监测框架

Fig. 1 CAE-ViT power image monitoring framework

1.1.1 终端采集侧

首先,设终端侧采集得到电力图像 x ,然后采用基于通道注意力机制的CAE语义编码器,提取电力图像的语义特征,并进行联合信源信道编码,该过程可表示为:

$$y = F(x; \omega_F) \quad (1)$$

式中, y 表示编码后语义信息, F 表示基于CAE编码器的语义信源信道编码处理函数, ω_F 表示CAE编码器可训练参数。

1.1.2 通信通道侧

随后,经过CAE编码器编码后的语义信息 y 通过信道传输到平台侧,在此过程会受到信道噪声的影响,因此在接收端的数据标识为 $\hat{y}$,该过程可表示为:

$$\hat{y} = H(y; n) \quad (2)$$

式中, $H(\cdot)$ 表示信道传输过程, n 表示噪声,通常为高斯噪声或瑞利噪声等噪声。

1.1.3 平台侧

相应地,平台侧将CAE语义解码器解码后的数据标识为 $\hat{x}$ 。之后,将 $\hat{x}$ 进行数据映射转换为可供ViT编码器处理的基本数据单元 T^i 。

$$D_i = P(\hat{x}; \omega_p) = [T^0; T^1; T^2; \dots, T^N] \quad (3)$$

式中, D_i 代表由基本数据单元构成的二维序列; P 代表数据映射过程; ω_p 代表数据映射过程可训练参数; T^0 位于 D_i 的首行,作为全局语义信息标签。

其次,将 D_i 输入ViT编码模块,利用注意力引导的卷积编码块对 D_i 内部特多行征基本数据单元进

行信息交互,得到包含多层次的语义信息标签 $\hat{T}^0$ 。

$$\hat{T}^0 = V(D_i; \omega_v) \quad (4)$$

式中, V 代表ViT编码过程, ω_v 代表可训练ViT编码器参数,在训练过程中上述所有模型参数均采用适配任务的语义优化方向。

最后, $\hat{T}^0$ 输入分类模块得到识别结果 r 。

1.2 CAE传输模块

电力图像监测传输过程极易受到复杂电磁环境干扰,导致以比特级重构为目标的语法通信在低信噪比条件下传输效率和任务性能下降,而语义通信通过对电力图像进行语义信息提取,并采用联合信源信道编码方式,有效减少冗余信息,增强系统在复杂信道条件下的鲁棒性;此外,传输模块发送端通常部署于无人机等边缘采集终端,受限算力与硬件资源,难以支撑大规模模型和高复杂度计算(Liu等, 2023)。因此,设计语义通信框架下的轻量化CAE传输模块,实现电力图像语义特征的高效提取与可靠传输。




图2 CAE框架图

Fig. 2 Architecture of convolutional autoencoder

基于上述需求,电力图像监测系统设计了基于CAE的语义传输模型,其结构如图2所示。在该模型中,第一层卷积层后引入了基于通道注意力机制的squeeze-and-excitation(SE)模块,作为语义提取模块。首先,通过卷积层从原始电力图像中提取语义

信息,并映射为更具辨识度的语义特征表示,如公式(5)所示。

$$z_0 = F_1(x; \omega_{F_1}) \quad (5)$$

式中, F_1 代表第一卷积层处理函数; ω_{F_1} 代表第一卷积层权重, z_0 代表第一卷积层编码输出。

考虑到电力图像传输具有与常规图像不同的特点,尤其是对电力设备关键区域的关注,SE模块模块进一步对提取到的特征进行通道划分,并通过池化操作对每个通道进行特征聚合。随后,模块通过全连接层学习分配每个通道的权重系数,从而对电力图像中关键区域的语义信息重点提取,使得模型能够更加有效地关注和传输电力图像中更具代表性的语义特征;

$$z_1 = G(z_0^1, \dots, z_0^n) \quad (6)$$

$$z_2 = S[C_2(C_1(z_1))] \quad (7)$$

$$z_3 = z_0 \cdot z_2 \quad (8)$$

式中, G 代表平均池化处理函数, z_1 代表其输出; C_1 、 C_2 代表全连接层处理函数; S 代表 sigmoid 处理函数, z_2 代表其输出; z_3 代表 SE 模块输出。

第二层与第三层卷积层作为联合信源信道编码模块,通过逐步加深卷积核层数与通道,不仅进一步去除冗余信息增强模型的表达能力,还有助于增强数据的鲁棒性;CAE 解码器采用与编码器端对称的卷积层结构,对受噪声干扰后的语义信息进行解码。

在轻量化设计方面,所设计的 CAE 模型相较于传统自编码器,避免了在特征学习过程中由于全连接层引起的计算效率低下问题。当前主流的抗噪传输模型如 swin transformer,其计算复杂度和模型大小明显高于 CAE,尤其在图像分辨率较高时,需要大量计算资源,这使得其在实际应用中的部署具有较大的挑战。为此,本文模型仅在终端侧部署轻量化的 CAE 编码器,该编码器采用卷积核大小 $k=5$,卷积池化层数为 $L=3$,具有较小的内存占用和计算资源开销,适合部署于无人机等边缘终端设备(Li 等, 2024)。

1.3 ViT 识别模块

1.3.1 基本架构

所提电力图像监测方法的识别模型采用 ViT

(DosoViTskiy 等, 2020)作为主体架构。ViT 能够利用其自注意力机制捕捉数据块中不同区域之间的细微关系,从而对语义信息进行进一步挖掘和学习,使得语义信息在识别时得到了更精准的表达,从而提高图像的识别精度。




图3 ViT 识别流程图

Fig. 3 ViT module framework diagram

标准 transformer 接收一维词元嵌入序列作为输入,为处理经 CAE 解码后的二维数据,将三通道数据 $\hat{x}$ 展平为单通道并分成 N 个数据块 x_p ,将数据块展平后通过可训练线性投影映射至 L 维空间(公式 9)得到 D 。

$$D = [x_p^1 E; x_p^2 E; \dots, x_p^N E] \quad (9)$$

$$= [T^1; T^2; \dots, T^N]$$

式中, E 代表二维数据序列线性投影至固定维度 L 的过程, T^i 代表第 i 个数据块映射后向量,作为 ViT 编码模块的基本数据单元。

然后,设一维长度为 L 的可学习嵌入分类向量 T^0 ,作为全局数据的语义辨识标签,并添加在二维序列 D 的首部,得到 D_i 作为 ViT 编码模块输入。

1.3.2 注意力引导的卷积编码模块

ViT 编码模块通常由多个标准块堆叠构成。每个标准块主要由子模块多头自注意力机制(multi-head self attention, MHSA)(Vaswani 等, 2017)与前馈神经网络(multi-layer perceptron, MLP)交替构成。然而,标准块只对全局进行提炼,缺乏对局部关键区域的细微感知,因此在标准块基础上,设计注意力引导的卷积编码块(后续简称 block),如图 4 所示。

设上一个 block 的输出 u_0 经过层归一化规范化处理后得到 u_1 ,输入卷积层用于提取局部特征得到 u_2 ;之后,输入 MHSA 层,进行全局语义信息交互并

表1 传输模型大小对比

Table 1 Comparison of different noise reduction model

模型	sizes	
	模型大小	传输速率(毫秒/幅)
CAE	1.7MB	2.5
AE	1.2MB	1.9
SwinTransformer	120.4MB	10.2




图4 注意力引导的卷积编码块(block)结构图

Fig. 4 ViT coding module structure diagram

生成注意力权重矩阵 u_3 ; 其次, 将卷积操作输出的特征与注意力权重矩阵进行逐元素相乘, 实现注意力加权卷积得到 u_4 。通过这种方式, 卷积操作会更加关注重要区域, 结合了ViT的全局自注意力和卷积网络的局部感知能力, 模型能够更好地理解图像中的全局和局部特征, 适用于电力图像这类具有明显局部特征的任务。

$$u_2 = E(u_1; \omega_E) \quad (10)$$

$$u_3 = M(u_2; \omega_M) \quad (11)$$

$$u_4 = u_2 \otimes u_3 \quad (12)$$

$$u_5 = u_0 + u_4 \quad (13)$$

式中, E 代表其输出 E 代表卷积处理函数; M 代表MHSA层处理函数; u_5 代表残差连接输出。

具体地, D_i 输入 ViT 编码器后, T^0 在每一个 block 中不断从全局与局部提取其余 T^i 的信息, 最终编码输出语义辨识标签 T^0 , 进行分类得到识别结果 r 。

2 CAE-ViT的联合训练

2.1 联合训练框架

现有的电力图像监测方法通常采用分离训练模式进行传输和识别的优化。具体而言, 传输模型以图像重构质量为目标, 最小化重构损失函数优化模型参数。然后, 将重构图像输入识别模型, 并通过识别损失函数优化识别模型参数。该分阶段建模策略通过提升图像重建质量, 进而提高噪声环境下的识别准确率, 如图 5(a) 所示。然而, 分离训练模式未

能充分考虑电力图像监测过程传输模型与识别模型的协同优化。因此, 设计了一种端到端的电力图像监测联合训练方法, 如图 5(b) 所示。

2.2 联合训练方法

(1) 定义输入与标签

首先, 设训练样本对 (x, s_i) 来自数据集分布, 其中 x 为输入图像, $s_i \in \{1, 2, \dots, c\}$ 为对应标签; CAE 语义传输过程由 $f_c(\cdot)$ 表示, 其参数由 $\theta_c \in \Theta_c$ 表示, Θ_c 代表 CAE 模块参数空间, $\hat{x}$ 为 CAE 模块输出; ViT 识别过程由 $f_v(\cdot)$ 表示, 其参数由 $\theta_v \in \Theta_v$ 表示, Θ_v 代表 ViT 模块参数空间, $\hat{s}_i$ 为 ViT 模块第 i 个图像预测标签。

(2) 联合训练损失函数

电力图像监测的最终目标是提升识别任务可靠性, 而分离训练在识别寻优过程只限制于 ViT 参数空间 Θ_v 中, 因此本文考虑将识别寻优参数空间扩展至 (Θ_c, Θ_v) , 显然 Θ_v 属于 (Θ_c, Θ_v) 的一个子集, 故分离与联合训练的目标损失函数最优极小值 L_v^* 与 L_j^{opt} 关系为 $L_j^{\text{opt}} \leq L_v^*$ 。

因此, 联合训练将 CAE 与 ViT 两个模型级联后, 采用联合交叉损失熵损失函数 L_j , 满足上述参数空间扩展条件, 如公式 (14) 所示。

$$\begin{aligned} L_j &= - \sum_{i=1}^c s_i \log(\hat{s}_i) \\ &= - \sum_{i=1}^c s_i \log(f_v(\hat{x}; \theta_v)) \\ &= - \sum_{i=1}^c s_i \cdot \log(f_v(f_c(x; \theta_c); \theta_v)) \end{aligned} \quad (14)$$


为了保证模型的稀疏性, 在交叉熵损失的基础上采用 L1 范数正则化损失设计了联合训练模型损失函数 L , 如公式 (15) 所示。

$$L = - \sum_{i=1}^c s_i \log(\hat{s}_i) + \lambda \sum(\theta_c, \theta_v) \quad (15)$$

L1 正则化具有稀疏化特性, 对于 CAE 模块, L1 正则化能够将部分权重压缩为 0, 使模型聚焦于更少且更关键的语义特征, 从而降低带宽需求并减少冗余信息, 提升抗噪能力; 同时, L1 正则化有助于减少 ViT 模型的复杂度, 筛选出更重要的语义信息, 防止过拟合, 增强模型的泛化能力与鲁棒性。

2.3 联合训练的语义优化方向

分离训练中 CAE 语义传输最优参数 θ_c^* 是由重构损失决定的, θ_c^* 可能会把模型能力集中在对重构



((a) separate training mode; (b) joint training mode)

图5 分离训练与联合训练框架对比

Fig. 5 Comparison of separate training and joint training frameworks

有利但对识别不利的语义表征上,如果CAE模块提取的特征对识别任务语义信息保留不充分,后续分类器即便训练到最优仍存在受限问题;联合训练则纠正了分离方案中CAE模块参数的语义方向,允许 θ_c 朝着有利于降低识别损失的语义方向调整,从而选择更适合识别任务的语义特征。因此,联合训练通过选择更合适的语义信息,直接优化最终目标,避免优化过程中语义优化方向不一致带来的目标偏移问题。

分离与联合训练优化方向对比示意如图所示,若干圆圈代表等损失线,虚线圈代表重建损失,实线圈代表识别损失,点 (θ_c, θ_v) 处代表CAE与ViT模型参数初始化点;虚线箭头代表分离训练的语义优化方向,CAE模型首先按重建类语义方向迭代至点 (θ_c^*, θ_v) 处;随后 θ_c^* 保持固定,箭头按着识别类优化方向迭代至点 (θ_c^*, θ_v^*) 处。然而,CAE模型参数优化方向为重建语义方向且固定,使得模型参数忽略识别类语义信息的保留,因此未能达到识别损失的最优极值点。




图6 分离与联合训练优化方向对比示意图

Fig. 6 Comparison diagram of disjoint and joint training optimization directions

实线箭头代表联合训练的优化方向,模型参数从初始化开始。由于CAE-ViT模型整体参数未受限且优化方向为识别类语义方向,使得模型在训练过程中提升识别类语义信息的保留能力,从而得到最优极值点的模型参数 $(\theta_c, \theta_v)^{opt}$ 。

3 实验分析

3.1 实验设置

实验配置了 i5-13400fCPU, 8GB RAM 和 GTX5060 的硬件环境, 软件环境为 Python3.8。

实验采用的原始图像包含两个公开数据集: 中国输电线路绝缘子数据集(chinese power line Insulator dataset, CPLID), 共 848 幅图像(Tao 等, 2018); 电力线路资产巡检数据集(inspection power line asset dataset, InsPLAD)(Silva 等, 2023)共 810 幅图像。将数据集按 8:2 的比例随机划分为训练集和测试集, 并实施了数据增强处理: 以 70% 的概率添加动态模糊和高斯噪声, 以 80% 的概率进行亮度变换并在 $[-15^\circ, 15^\circ]$ 范围内执行随机旋转操作最终扩充后的数据集包含 4869 幅图像, 其中训练集 4107 幅, 测试集 762 幅。识别类别包括: 正常绝缘子(normal)、缺陷绝缘子(broekn)。该数据集覆盖了不同光照条件、目标遮挡、尺度变化以及多样化拍摄角度的真实应用场景, 具有较强的代表性。

3.2 参数优化性能分析

本节在信噪比为 0db 的高斯噪声下开展参数优化性能分析实验。

(1) CAE 卷积核参数




图7 不同卷积核大小下识别率的变化

Fig. 7 Change in recognition rate under different convolutional kernel sizes

由图7可知, 选取1到9的奇数大小卷积核进行测试, 其中随着卷积核增大, 识别率先大幅提升, 后有较大幅度减小。在卷积核大小由1增加到5时, 识别率从70%提升到95%, 这是由于随着卷积核的增大, 较大的感受野能够更充分地捕捉局部空间结构

信息, 在强噪声干扰下, 能够更有效提取语义特征从而提升识别模型的判别能力; 当卷积核大小由5增加到9时, 识别率从94.90%降至90.08%, 这说明过大的卷积核在增强局部上下文的同时, 还可能引入了无关区域的干扰信息, 导致提取的语义特征变得模糊, 从而影响模型判别能力。因此, 选取卷积核参数为5作为CAE模型参数。

(2) ViT模块参数

对ViT模块性能产生影响的主要参数有2.2.1节中提到的数据块大小 P 、特征映射维度 L 以及2.2.2节中提到的注意力引导的卷积编码块(block)个数 m 。本文选取4种常见且效果较好的参数搭配方案进行识别率指标对比。

表2 不同参数方案下模型对比实验结果

Table. 1 Comparison experiment results of the model under different parameter schemes

参数方案	P	L	m	Acc/%	模型大小/MB
本文参数	16	768	12	94.90	393
参数方案1	32	768	12	88.71	400
参数方案2	16	1024	24	95.12	1228
参数方案3	32	1024	24	92.61	1230

由表2可知, 本文参数与方案1的区别为数据块大小不同, 本文选取 $P=16$ 识别率达到94.90%, 方案1选取 $P=32$ 识别率仅有88.71%, 这是因为较小的数据块大小 P 能够使模型更精细地保留数据局部结构信息, 使得ViT模块接收面对噪声扰动的数据后仍能准确提取关键语义特征。因此本文选取 $P=16$ 作为本文参数。

同理, 本文参数与方案2的区别为映射维度和block个数。本文参数选取普通配置 $L=768, m=12$ 识别率为94.90%, 方案2选取高级配置 $L=1024, m=24$ 识别率为95.12%, 这说明更高的映射维度与block个数能够提取到更丰富的语义信息, 但是二者性能非常接近, 且更高的映射维度与block个数会导致模型占用增加, 以及需要更多的计算资源, 因此选定 $L=768, m=12$ 作为ViT模型参数。

(3) L1 正则化参数

本节开展L1正则化参数对比实验, λ 取值偏大会过度压缩权重导致特征大量失效; 偏小则难以有

效抑制过拟合并实现特征稀疏化。因此本文选取范围为0.01至0.00001区间。

表3 L1正则化参数实验结果
Table. 3 Experimental results of L1 regularization parameter

λ	Acc/%
无	93.98
0.01	93.91
0.001	94.01
0.0001	94.90
0.00001	93.86

由表3可知, λ 取0.01时,取值过高导致部分重要参数也被强行减小导致识别率降低;随着取值从0.001到0.0001,识别率开始上升说明, λ 取0.0001时达到最佳平衡状态;取值进一步降低后,识别率也随之降低,说明正则化对模型的约束能力过弱。

(4) CAE-ViT消融实验

CAE-ViT消融实验结果如表4所示。由本文方案与消融方案1对比可知,基于通道自注意力机制的SE模块有效侧重提取了电力语义特征,从而提高模型识别率;与消融方案2对比结果可知,所设计的注意力引导的卷积block,相较于标准块增加了对电力图像的重要局部感知能力,从而进一步提高识别率;与消融方案3对比结果可知,联合训练策略的识别结果优于分离策略。

表4 CAE-ViT各模块消融实验结果
Table. 4 Ablation experiment results of CAE-ViT modules

模型方案	CAE模型	ViT模型	训练方式	Acc/%
本文方案	含SE模块	block	联合	94.90
消融方案1	无SE模块	block	联合	93.02
消融方案2	含SE模块	标准block	联合	92.32
消融方案3	含SE模块	block	分离	92.91

3.3 联合训练的性能对比

本节基于不同信噪比下的加性高斯白噪声(additive white gaussian noise, AWGN)与瑞利噪声(Rayleigh)干扰,将模型按不同方式训练并对比识别率指标。本文采用的训练方式为2.3节中所述的联

合训练方式,标识为“联合训练模式”;对比为CAE与ViT分离模式,标识为“分离训练模式”。

(1)模型联合训练效果对比




图8 不同训练模式的识别率性能对比(AWGN)
Fig. 8 Comparison of recognition performance under different training modes(AWGN)

如图8所示,随着高斯噪声信噪比的增加,两种训练方式的识别率均逐渐上升,各个信噪比下联合训练的联合模型识别率均高于分离训练模型,这是由于联合训练使得模型在端到端训练过程中,实现参数协同优化,从而使得语义提取的特征更适配于识别任务的需求。尤其是在低信噪比-10db下尤为明显:联合训练模型识别率为92.62%,分离模型识别率为88.61%,前者比后者高出约4%的指标,这说明联合训练策略在强噪声干扰条件下对鲁棒性的提升效果更为明显,也进一步验证了联合训练在噪声环境下对于特征提取能力和任务适配性的增强作用。

瑞利噪声下的识别率对比结果如图9所示,进一步验证了联合训练模型的可靠性与鲁棒性。




图9 不同训练模式的识别率性能对比(Rayleigh)
Fig. 9 Comparison of recognition performance under different training modes(Rayleigh)

(2) 识别结果可视化

图 10 代表信噪比为 0db 的高斯噪声下, 不同训练方式的识别可视化对比结果。选取的可视化图片 (a)-(d) 代表光线充足、背景简单场景; (e)-(h) 代表光线充足、背景复杂场景; (i)-(l) 代表光线不足、背景复杂场景。

联合训练模式 分离训练模式




图 10 识别结果可视化对比

Fig. 10 Visualize and compare the identification results

如图 10 所示, 绝缘子破损处已由红圈标出, 识别结果在左上角 (红色代表识别错误)。由图 (a)-(d) 对比可知, 在光线充足的简单背景下二者均成功识别出破损绝缘子; 由图 (e)-(h) 对比可得, 在复杂背景下, 联合模型成功识别出破损绝缘子, 而分离模型识别错误; 由图 (i)-(l) 对比可得, 在光线较暗的情形下, 联合模型成功识别出破损绝缘子, 而分离模型识别错误。因此可知 CAE-ViT 模型在多种复杂环境下均表现出更强的鲁棒性, 有效提升了模型在实际复杂场景中的监测可靠性。

3.4 性能对比验证

本节基于电路图象监测场景, 在不同信噪比下开展识别率 (Acc)、精准率 (Precision)、F1 分数 (F1-score) 与召回率 (Recall) 指标对比实验。其中, 第一种对比算法由传统算法 JPEG 与典型电力图像识别模型 ResNet (Liu 等, 2024) 组成 JPEG+ResNet 模型; 第二种为语义传输模型 DJSCC 与识别模型 ViT 组成 DJSCC-ViT 模型; 第三种组合为语义传输模型 Swin-Transformer (Fu 等, 2025)-ViT 模型; 第四种为 CAE 模型与卷积神经网络 (convolutional neural networks, CNN) 组成 CAE+CNN 模型。

(1) AWGN 噪声

由图 11 可知, 从 -10db 到 10db 的高斯噪声条件下, 本文模型识别率从 92.61% 提升至 95.58%, 而 SwinTransformer+ViT 模型识别率从 76.81% 提升至 94.25%。随着信噪比的提升, 二者的监测识别性能均有不错表现, 但在低信噪比 -10db 至 0db 下本文模型优势明显, 且由表 1 与表 5 可知, CAE 模型更适合部署在设备侧, 且所提方法运行速率更快; 同理, 本文方法相较于 DJSCC+ViT 模型识别率提升约 7.23%~13.14%; 相较于 JPEG+ResNet 模型提升约 8.21%~32.72%; 本文方法与 CAE+CNN 模型对比可知, ViT 识别模型相较于 CNN 模型性能更佳且稳定。




图 11 AWGN 干扰下识别率对比
Fig. 11 Comparison of recognition rates under AWGN interference

且随着信噪比降低,本文方法优势愈加明显,说明本文方法通过联合优化策略统一语义优化方向后,在较恶劣噪声条件下仍能保证较高的监测效率。

表 5 不同方案运行速率
Table. 5 Operating speeds of different schemes

模型方案	运行速率(毫秒/幅)
本文方法	27.3
DJSCC+ViT	29.7
JPEG+ResNet	18.1
SwinTransformer+ViT	35.2

信噪比为 0db 的高斯噪声下, Precision、Recall 与 F1-score 的对比实验结果表 6 所示。从表中数据可得,所提方法各项指标均具有一定优势。

表 6 AWGN 干扰下对比实验结果
Table. 5 Comparison experiment results under AWGN interference

模型方案	Precision/%	Recall/%	F1-score/%
本文方法	95.12	92.13	93.56
DJSCC+ViT	90.02	86.32	87.75
JPEG+ResNet	75.63	70.61	72.56
SwinTransformer+ViT	92.01	88.32	89.51

(2) Rayleigh 噪声
为进一步验证本文方法的性能,在更加复杂的 Rayleigh 乘性噪声干扰下开展对比实验。




图 12 Rayleigh 干扰下识别率对比
Fig. 12 Comparison of recognition rates under Rayleigh interference

由图 12 可得,模型性能与对比情况在 AWGN 与 Rayleigh 两种噪声干扰下表现相似,本文模型从 -10db 到 10db 的瑞利噪声条件下,识别率从 92.01% 提升至 94.83%。由图 12 与图 13 对比可得, CAE-ViT 模型虽然在更为复杂的 Rayleigh 噪声干扰下识别率有小幅降低,但依然能保证在 90% 以上,并且在各个信噪比情况下明显优于对比模型的识别率。

信噪比为 0db 的瑞利噪声下, Precision、Recall 与 F1-score 的对比实验结果表 7 所示。

表 7 Rayleigh 干扰下对比实验结果
Table. 6 Comparison experiment results under Rayleigh interference

模型方案	Precision/%	Recall/%	F1-score/%
本文方法	95.03	91.19	93.21
DJSCC+ViT	89.72	86.14	87.01
JPEG+ResNet	75.26	69.94	71.96
SwinTransformer+ViT	91.23	88.29	89.86

4 结 论

本文提出了一种基于基于语义通信联合优化的电力图像监测方法。首先,终端采集侧获取电力图像,并送入 CAE 语义编码器进行语义提取与信源信道编码,然后数据通过通信信道侧上传至平台侧,随后进行 CAE 解码,解码完成数据输入 ViT 识别模块,最后以识别类语义为优化方向,构建了 CAE-ViT 联

合优化模型。实验表明,相比传统方法,本文提出的模型在电力复杂电磁环境无线信道状态下具有鲁棒性,且进一步提升了电力图像的监测效率,为电力图像监测工程实际应用部署提供了有益的技术借鉴。

此外,未来的研究方向:1)将进一步考虑结合传输损失的联合优化研究,在保证下游任务识别性能的同时尽量降低传输损失,以进一步提升所提方法整体性能;2)开展平台侧轻量化研究,进一步提升方法整体的轻量化性能。

参考文献(References)

- Bengio Y, Courville A and Vincent P. 2013. Representation Learning: A Review and New Perspectives. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(8): 1798-1828 [DOI: 10.1109/TPAMI.2013.50]
- Bourtsoulatz E, Kurka D B and Gündüz D. 2019. Deep Joint Source-Channel Coding for Wireless Image Transmission. *IEEE Transactions on Cognitive Communications and Networking*, 5(3): 567-579 [DOI: 10.1109/TCCN.2019.2919589]
- Chen J, Dou G Q, Jiang Y, Zhu Y. 2026. Joint optimization of semantic communication reliability in integrated sensing-communication-computing network based on regional awareness. *Journal on Communications*, 47(1): 41-53 (陈津, 窦高奇, 蒋妍, 朱尧. 2026. 基于区域感知的通感算协同网络语义通信可靠性联合优化. *通信学报*, 2026, 47(1): 41-53)
- Cui H Y, Han Y, Zhang X, Wang C and Liu C. 2023. Image restoration method of motion-blurred insulator based on improved U-Net generative adversarial network. *Power System Technology*, 47(6): 2594-2604 (崔昊杨, 韩奕, 张驯, 王莞, 刘诚. 2023. 基于改进 U-Net 结构生成对抗网络的运动模糊绝缘子图像复原方法. *电网技术*, 47(6): 2594-2604) [DOI: 10.13335/j.1000-3673.pst.2022.0175]
- DosoViTskiy A, Beyer L, Kolesnikov A, Weissenborn D, Zhai X H and Unterthiner T, et al. 2020. An image is worth 16x16 words: transformers for image recognition at scale[EB/OL]. <https://doi.org/10.48550/arXiv.2010.11929> [DOI: 10.48550/arXiv.2010.11929]
- Fu H Y, Wang X, Li Y K, Shi Z and Yang G H. 2025. Image semantic HARQ retransmission technology based on generative adversarial networks. *Mobile Communications*, 49(7): 61-67 (符颢议, 王旭, 李永康, 施政, 杨光华. 2025. 基于生成对抗网络的图像语义 HARQ 重传技术. *移动通信*, 49(7): 61-67)
- Gao Y, Jiang C and Liu Y. 2025. Lightweight Feature Mining Network Research Based on LCFMNet for Detection of Defects in Insulators. *IEEE Access*, 13: 185637-185644 [DOI: 10.1109/ACCESS.2025.3623952]
- Hu J, Zhang R M and Lian B Q. 2025. BSGAN-GP: class-balanced driven semi-supervised image recognition model. *Journal of Image and Graphics*, 30(1): 95-109 (胡静, 张汝敏, 连炳全. 2025. BSGAN-GP: 类别均衡驱动的单监督图像识别模型. *中国图象图形学报*, 30(1): 95-109) [DOI: 10.11834/jig.230881]
- Huang J, Yuan K, Huang C and Huang K. 2025. D²-JSCC: Digital Deep Joint Source-Channel Coding for Semantic Communications. *IEEE Journal on Selected Areas in Communications*, 43(4): 1246-1261 [DOI: 10.1109/JSAC.2025.3531546]
- Li D X, Wang X H, Li L and Ji Z X. 2024. An automatic deep learning system for analysis and processing of power UAV inspection images: architecture design and key technologies. *Electric Power Information and Communication Technology*, 22(4): 38-54 (李道兴, 王晓辉, 李黎, 季知祥. 2024. 面向电力无人机巡检图像分析处理的自动化深度学习系统: 架构设计与关键技术. *电力信息与通信技术*, 22(4): 38-54) [DOI: 10.16543/j.2095-641x.electric.power.ict.2024.04.05]
- Li L H, Yang L L and Ren X R. 2024. Design of AI-based end-to-end semantic coding transmission scheme. *Mobile Communications*, 48(5): 2-7+14 (李立华, 杨琳琳, 任欣然. 2024. 基于 AI 的端到端语义编码传输方案设计. *移动通信*, 2024, 48(5): 2-7+14)
- Li P, Chang L, Qin F F, Meng Q W and Chen J M. 2025. Power insulator motion-blurred image restoration network based on improved Transformer structure. *Power System Technology*, 49(6): 2623-2631 (李鹏, 常乐, 覃发富, 孟庆伟, 陈继明. 2025. 基于改进 Transformer 结构的电力绝缘子运动模糊图像复原网络. *电网技术*, 49(6): 2623-2631) [DOI: 10.13335/j.1000-3673.pst.2024.0674]
- Li X, Lai X B, Wang B Z and Shen B. 2026. Performance optimization of wireless image transmission semantic communication system based on Swin Transformer. *Journal of Huazhong University of Science and Technology (Natural Science Edition)*, 54(3): 50-60 (李旋, 赖雪冰, 王辩铮, 申滨. 2026. 基于 Swin Transformer 的无线图传语义通信系统性能优化. *华中科技大学学报(自然科学版)*, 54(3): 50-60) [DOI: 10.13245/j.hust.240469]
- Liang S, Liu D D and Ji T Y. 2023. Overhead transmission line insulator detection algorithm based on fine-tuned structured pruning. *Electric Power Information and Communication Technology*, 21(11): 1-6 (梁爽, 刘丹丹, 季堂煜. 2023. 基于微调式结构化剪枝的架空输电线路绝缘子检测算法. *电力信息与通信技术*, 21(11): 1-6) [DOI: 10.16543/j.2095-641x.electric.power.ict.2023.11.01]
- Liu C Y, Wu Y Q and Liu J J. 2023. Research progress of power line detection methods in UAV aerial images. *Journal of Image and Graphics*, 28(10): 3025-3048 (刘传洋, 吴一全, 刘景景. 2023. 无人机航拍图像中电力线检测方法研究进展. *中国图象图形学报*, 28(10): 3025-3048) [DOI: 10.11834/jig.220432]
- Liu J F, Fan Y F, Song Y N, Ming Y D and Xia N H. 2025. Transformer winding fault diagnosis based on improved continuous variational mode decomposition, deep residual network and magnetic

- flux leakage signal. *Power System Technology*, 49 (10): 4428-4437 (刘建锋, 范一凡, 宋伊宁, 明远东, 夏能弘. 2025. 基于改进连续变分模态分解和深度残差网络及漏磁信号的变压器绕组故障诊断. *电网技术*, 49 (10): 4428-4437 [DOI: 10.13335/j.1000-3673.pst.2024.1262])
- Nie K, Li Z, Gao W H, Li C Z, Liu Y P and Li Q Q. 2025. Power insulator defect detection method based on YOLOv8-RFL model. *Power System Technology*, 49 (9): 3948-3957 (聂凯, 李泽, 高文豪, 李诚真, 刘永鹏, 李清泉. 2025. 基于 YOLOv8-RFL 模型的电力绝缘子缺陷检测方法. *电网技术*, 49 (9): 3948-3957 [DOI: 10.13335/j.1000-3673.pst.2024.1119])
- Shao G W, Liu Z, Fu J, Tan J Y, Chen Y and Zhou L W. 2020. Research progress on UAV inspection technology for overhead transmission lines. *High Voltage Engineering*, 46 (1): 14-22 (邵瑰玮, 刘壮, 付晶, 谈家英, 陈怡, 周立玮. 2020. 架空输电线路无人机巡检技术研究进展. *高电压技术*, 46 (1): 14-22 [DOI: 10.13336/j.1003-6520.hve.20191227002])
- Vieira e Silva A L B, de Castro Felix H, Simões F P M, Teichrieb V, dos Santos M, Santiago H, et al. 2023. InsPLAD: a dataset and benchmark for power line asset inspection in UAV images. *International Journal of Remote Sensing*, 44 (23): 7294-7320 [DOI: 10.1080/01431161.2023.2283900]
- Shi J C, Hu Z W, He D M and Xie Z Y. 2019. Identification method of power line channel transmission characteristics based on deep learning. *Power System Technology*, 43 (12): 4283-4290 (史建超, 胡正伟, 贺冬梅, 谢志远. 2019. 基于深度学习的电力线信道传输特性识别方法. *电网技术*, 43 (12): 4283-4290 [DOI: 10.13335/j.1000-3673.pst.2019.1527])
- Song L, Liang Q, Chen H, Hu H, Luo Y and Luo Y. 2023. A New Approach to Optimize SVM for Insulator State Identification Based on Improved PSO Algorithm. *Sensors*, 23 (1): 272 [DOI: 10.3390/s23010272]
- Tao X, Zhang D, Wang Z, Liu X, Zhang H and Xu D. 2020. Detection of power line Insulator defects using aerial images analyzed with convolutional neural networks. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 50 (4): 1486-1498 [DOI: 10.1109/TSMC.2018.2871750]
- Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez A N, et al. 2017. Attention Is All You Need//*Proceedings of the 31st International Conference on Neural Information Processing Systems*. Red Hook: Curran Associates: 5998-6008 [DOI: 10.48550/arXiv.1706.03762]
- Yu P, Li C C, Feng L, Guo S Y, Li W J and Qiu X S. 2025. Key technologies and application prospects of 6G intelligent communication in new power systems. *Electric Power Information and Communication Technology*, 23 (12): 16-28 (喻鹏, 李超超, 丰雷, 郭少勇, 李文璟, 邱雪松. 2025. 6G 智能通信在新型电力系统中的关键技术与应用前景. *电力信息与通信技术*, 23 (12): 16-28 [DOI: 10.16543/j.2095-641x.electric.power.ict.2025.12.02])
- Zhang H, Dai Y, Li H and Koniusz P. 2019. Deep Stacked Hierarchical Multi-Patch Network for Image Deblurring. In: 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Long Beach, CA, USA, pp. 5971-5979 [DOI: 10.1109/CVPR.2019.00613]
- Zhang J R, Wei X, Zhang L X, Chen Y N and Lu J. 2024. Improved YOLO v7 for insulator detection and location. *Computer Engineering and Applications*, 60 (4): 183-191 (张剑锐, 魏霞, 张林鎭, 陈燕楠, 卢杰. 2024. 改进 YOLO v7 的绝缘子检测与定位. *计算机工程与应用*, 60 (4): 183-191)
- Zhang L, Song M, Guo H, Sun Y and Wang X. 2025. Insulator Defect Detection via a Residual Denoising Diffusion Mechanism. *Materials*, 18(8): 1738 [DOI: 10.3390/ma18081738]
- Zhang P, Xu X, Dong C, Niu K, Liang H T and Liang Z J. 2023. Model division multiple access for semantic communications. *Frontiers of Information Technology & Electronic Engineering*, 24 (6): 801-812 [DOI: 10.1631/FITEE.2300196]
- Zhao Z, Yang Z, Chen M, Zhang Z and Poor H V. 2024. A joint communication and computation design for probabilistic semantic communications. *Entropy*, 26(5): 394 [DOI: 10.3390/e26050394]

作者简介

陆俊,男,副教授,主要研究方向:信息处理、电力系统通信。

E-mail: lujun@ncepu.edu.cn

吴尚容,男,硕士研究生,主要研究方向:语义通信、机器学习。E-mail: 1007678431@qq.com

孙仕泽,男,硕士研究生,主要研究方向:语义通信、机器学习。E-mail: 1931918482@qq.com

许祥宇,男,硕士研究生,主要研究方向:语义通信、机器学习。E-mail: 1538738314@qq.com

龚钢军,男,教授,主要研究方向:电力系统通信、能源电力信息安全。E-mail: gonggangjun@126.com

刘向军,通信作者,女,副教授,主要研究方向:电力系统通信。E-mail: Lxjun@ncepu.edu.cn