



团 体 标 准

T/CES XXX-XXXX

电力设备巡检图像智能编解码技术导则

Technical Guidelines for Intelligent Coding and Decoding
Technology in Image-Based Power Grid Equipment Inspection

XXXX-XX-XX 发布

XXXX-XX-XX 实施

中国电工技术学会 发布

目 次

前 言	2
1 范围	3
2 规范性引用文件	3
3 术语和定义	3
4 符号、代号和缩略语	6
5 章节导航	7
6 技术要求	7
6.1 图像质量和格式要求	7
6.2 编解码技术框架总览	8
6.3 电力专属格式数据格式	8
6.4 编码规则	9
6.5 解码方法	10
7 模型预训练与微调	10
7.1 模型架构	11
7.2 模型预训练	11
7.3 模型微调	11
8 测试与评价	11
8.1 测试对象	11
8.2 评价指标	11
9 模型部署	12
9.1 模型部署适配	12
9.2 推理加速与性能优化	12
9.3 镜像化部署与服务化管理	13
附 录 A（技术性） 数据结构设计格式表	15
附 录 B（资料性） 评价指标标准参考	17

前 言

本文件按照 GB/T 1.1—2020《标准化工作导则 第1部分：标准化文件的结构和起草规则》给出的规则起草。

请注意本文件的某些内容可能涉及专利，本文件的发布机构不承担识别这些专利的责任。

本文件由中国电工技术学会提出。

本文件由中国电工技术学会标准工作委员会能源智慧化标工组归口。

本文件起草单位：

本文件主要起草人：

本文件为首次发布。

电网设备巡检的图像智能编解码技术导则

1 范围

本文件规定了电网设备巡检中电力专用图像的智能编解码总体技术要求,包括数据格式、编码方法、解码策略及安全保障措施。

本文件适用于电网设备巡检场景下图像智能编解码系统的开发、应用及评估,涵盖一次设备和二次设备。

本文件支持多种图像采集手段,特别适用于无人机巡检环境,能够满足不同设备类型和巡检场景下对编码效率与图像质量的综合需求。

2 规范性引用文件

下列文件中的内容通过文中的规范性引用而构成本文件必不可少的条款。其中,注日期的引用文件,仅该日期对应的版本适用于本文件。不注日期的引用文件,其最新版本(包括所有的修改单)适用于本文件。

GB/T 2900.1-2008	电工术语 基本术语
GB/T 5271.34	信息技术 词汇 第 34 部分: 人工智能 神经网络
DL/T 283.1-2018	电力视频监控系统及接口技术要求
T/CES 276-2024	电力人工智能样本存储技术要求
T/CES 278-2024	面向电力行业的图像检测识别系统技术要求
IEEE 1857.11	神经网络图像编码标准

3 术语和定义

下列术语和定义适用于本文件。

3.1

电力专属格式数据 power-specific data format

针对电网设备巡检需求设计的专用数据格式,包括头部信息、图像数据块、元数据块和扩展块,以优化存储、传输及处理效率。

3.2

深度学习神经网络 deep learning neural networks

一种通过多层神经网络进行特征学习和模式识别的机器学习方法,通常用于图像处理、语音识别等任务。

3.3

端到端编解码 end-to-end codec

一种基于深度学习的图像或视频压缩方法,通过神经网络直接学习数据压缩和解码映射关系,而无需手动设计传统的压缩模块,在智能电网设备巡检等应用场景中,端到端编解码能够优化数据的压缩率,同时确保关键信息的高保真恢复,从而提升数据传输和存储效率。

3.4

哈希校验码 hash checksum

一种深度学习模型,特别适用于处理图像数据,通过卷积层提取图像特征。一种用于验证数据完整性的方法,通过生成数据的唯一指纹来检查数据是否被篡改。

3.5

数据头部信息 data header information

存储文件标识、版本号、哈希校验码等元数据,确保数据完整性和快速解析。

3.6

图像数据块 image data block

存储图像的特征信息,包括分辨率、色深、压缩方式及二进制图像数据。

3.7

元数据块 metadata block

存储巡检时间戳、设备 ID、环境参数、故障标注信息等，便于数据管理和分析。

3.8

扩展块 extension block

用于存储未来扩展数据，包括动态量化、自适应压缩策略以及多模态数据融合信息。

3.9

潜在空间表示 latent space representation

通过深度学习模型对数据进行压缩后的抽象表示，通常用于数据的高效存储和传输。

3.10

动态量化 dynamic quantization

通过可学习的量化步长调整数据精度，以提高编码灵活性。

3.11

自适应压缩策略 adaptive compression strategy

根据数据的特征自动调整压缩策略，以提高压缩效率和质量。

3.12

层级索引存储结构 hierarchical index storage structure

一种通过多层次结构组织数据的方法，通常用于提高数据检索效率。

3.13

神经网络特征映射 neural network feature mapping

指神经网络模型通过各层网络对输入数据进行的特征提取与转换过程，用于捕捉数据的潜在规律。

3.14

信号噪声 signal noise

在信号传输过程中，由于环境干扰、设备问题等产生的无用信息，可能影响信号的质量。

3.15

语义分割 semantic segmentation

利用深度学习方法识别电力设备的关键区域（如线路、接头），确保高质量编码与存储。

3.16

边缘计算 edge computing

指数据处理在数据来源端（如设备、传感器）进行，而不是将所有数据传输到远程服务器进行处理的计算模式。

3.17

端侧编码 edge-side encoding

在边缘计算设备上进行图像特征提取与压缩，以减少数据传输压力。

3.18

帧间特征学习 inter-frame feature learning

通过分析连续帧之间的差异，只编码变化部分，以提高视频数据的压缩效率。

3.19

通道空间混洗上下文模型 channel space shuffling context model

是一种用于优化图像或视频压缩的方法。它通过重新排列通道数据来减少冗余，并结合上下文建模来预测当前数据，从而提高压缩效率和编码效果。

3.20

目标区域优化 target region optimization

针对关键巡检区域使用高精度量化算法，提升重点部位的信息恢复质量。

3.21

熵编码 entropy coding

一种无损压缩方法，通过编码出现概率较低的数据项，来提高压缩率。

3.22

算术编码 arithmetic coding

一种高效的熵编码方法，通过将整个数据流映射到一个数字范围内来进行编码。

3.23

- 多级解码模式 multi-level decoding mode**
指在解码过程中，根据不同需求分级进行解码，从而在解码速度和图像质量之间进行权衡。
- 3.24 **端云协同 edge-cloud collaboration**
指在边缘设备和云计算平台之间进行任务和资源的合理分配，优化计算和存储性能。
- 3.25 **数字水印 digital watermark**
一种用于保护版权或确保数据完整性的方法，通过在数据中嵌入不可见的信息来防止篡改。
- 3.26 **对抗样本 adversarial samples**
由生成对抗网络（GAN）等方法生成的具有欺骗性的样本，旨在测试模型的鲁棒性或用于攻击目的。
- 3.27 **预训练 pretraining**
指在大规模电网巡检场景数据集上先训练一个神经网络模型，使其学习通用特征，再在特定任务上进行微调，以提升模型适应性。
- 3.28 **微调 fine-tuning**
在预训练模型的基础上，针对特定任务优化模型参数，使其适应特定数据集或应用场景。
- 3.29 **端到端训练 end-to-end training**
指从输入到输出直接训练整个神经网络，而无需单独设计中间步骤，使模型优化更高效。
- 3.30 **注意力机制 attention mechanism**
一种神经网络机制，能够自动关注图像中的重要区域，提高模型的特征提取能力，减少无关信息对编码的影响。
- 3.31 **模型剪枝 infrared image**
使用红外传感器采集的图像，主要用于检测设备温度异常、过热或故障等情况。
- 3.32 **可见光图像 visible light image**
普通光学相机拍摄的图像，可用于电网设备巡检中的视觉检测和分析。
- 3.33 **计算资源占用 computational resource usage**
指模型运行时消耗的计算资源，如 GPU 使用率、内存占用等，直接影响边缘设备的部署能力。
- 3.34 **泛化性 generalization ability**
指编解码算法在不同巡检场景下的适应性，即在不同数据上仍然能够保持较好的压缩与恢复质量。
- 3.35 **黑盒攻击 black-box attack**
攻击者不掌握模型内部结构，仅通过输入和输出尝试攻击模型。
- 3.36 **模型加固 model hardening**
通过混淆、加密、访问控制等方法提高模型对攻击的防护能力。
- 3.37 **高并发 high concurrency**
指系统需要同时处理大量请求的能力，通常涉及线程管理、负载均衡等。
- 3.38 **模型加固 model hardening**
通过混淆、加密、访问控制等方法提高模型对攻击的防护能力。
- 3.39

负载均衡 load balancing

在大规模并发处理场景下，使用多实例部署和集群扩展策略，确保解压缩系统的高效运行。

3.40

模型量化 model quantization

降低神经网络计算精度（如从 FP32 降至 FP16 或 INT8）以减少计算量和内存占用。

3.41

算子优化 operator optimization

针对特定硬件优化神经网络计算算子，以提高运行效率。

3.42

容器化技术 containerization

使用 Docker 等工具将应用及其依赖封装在一个独立的环境中，提升部署便捷性和可移植性。

3.43

推理服务 inference service

通过 API 或远程调用提供模型推理的云端或本地服务。

3.44

灰度发布 gray release

在新版本发布时，采用小流量阶段性上线方式，逐步扩大范围，确保系统稳定性和兼容性。

3.45

感知损失 perceptual loss

基于神经网络特征空间计算的图像重建误差评估方法。不同于传统的像素级损失函数（如均方误差），感知损失通过比对图像在预训练神经网络中高层特征的差异，衡量重建图像与原始图像在视觉感知上的相似程度，更贴近人眼主观质量判断。

4 符号、代号和缩略语

下列符号、代号和缩略语适用于本文件。

CNN：卷积神经网络，用于特征提取和编码（Convolutional Neural Network）

NPU：神经网络处理单元，用于加速 AI 计算（Neural Processing Unit）

GAN：生成对抗网络，用于优化图像解码质量（Generative Adversarial Network）

SHA256：安全哈希算法 256 位，用于生成固定长度的哈希值，确保数据完整性（Secure Hash Algorithm 256-bit）

CRC32：循环冗余校验 32 位，用于检测数据传输或存储中的错误（Cyclic Redundancy Check 32-bit）

INT8：8 位整数，用于模型量化以减少计算和存储需求（8-bit Integer）

Huffman：哈夫曼编码，一种无损数据压缩算法，通过可变长度编码减少数据存储需求（Huffman Coding）

AES-256：哈夫曼编码，一种无损数据压缩算法，通过可变长度编码减少数据存储需求（Huffman Coding）

TensorRT：NVIDIA 推出的高性能深度学习推理优化库，用于加速模型推理（NVIDIA TensorRT）

GPU：图形处理单元，用于并行计算和加速深度学习任务（Graphics Processing Unit）

RAW：原始图像格式，存储未经压缩或处理的图像数据（Raw Image Format）

JPEG：联合图像专家组制定的有损图像压缩标准，广泛用于数字图像存储（Joint Photographic Experts Group）

Bpp：每像素比特数，衡量图像数据的压缩比率（Bits per Pixel）

PSNR：峰值信噪比，用于衡量图像压缩质量（Peak Signal-to-Noise Ratio）

SSIM：结构相似性指数，评估压缩图像与原始图像的视觉质量（Structural Similarity Index Measure）

MSSSIM：结构相似性指数，评估压缩图像与原始图像的视觉质量（Structural Similarity Index Measure）

LPIPS：基于深度学习的感知图像相似性度量方法（Learned Perceptual Image Patch Similarity）

CUDA：NVIDIA 开发的并行计算平台和编程模型，用于 GPU 加速计算（Compute Unified Device Architecture）

ASIC：专用集成电路，针对特定任务优化的高效硬件（Application-Specific Integrated Circuit）

Ubuntu 18.04: 基于 Debian 的 Linux 发行版, 广泛用于服务器和开发环境 (Ubuntu 18.04)
 glibc 2.27: GNU C 标准库, 为 Linux 系统提供底层函数支持 (GNU C Library 2.27)
 Docker: 容器化平台, 实现应用程序的跨平台部署与管理 (Docker)
 SDK: 软件开发工具包, 包含开发应用程序所需的工具和库 (Software Development Kit)
 FP16: 16 位浮点数格式, 可减少深度学习计算和存储需求 (16-bit Floating Point)
 API: 应用程序编程接口, 定义软件组件间的交互方式 (Application Programming Interface)
 Kubernetes: 容器编排平台, 用于管理和调度容器化应用 (Kubernetes)
 Docker Swarm: Docker 的集群管理工具, 实现容器的负载均衡和扩展 (Docker Swarm)
 JPEG2000: 基于小波变换的图像压缩标准, 支持有损和无损压缩 (Joint Photographic Experts Group 2000)
 HEVC: 高效视频编码标准, 支持高压比图像与视频编码 (High Efficiency Video Coding)

5 章节导航

本文件共 9 分章, 各章节主要内容如下:

第 1 章明确了本文件的总体内容和适用范围, 明确了本文件的目标和实施对象。
 第 2 章罗列了编写本文件所依据的规范性引用文件, 为后续章节提供基础支撑。
 第 3 章详细说明了本文件中涉及的主要术语和定义, 统一相关技术表述。
 第 4 章列举了本文件中所用的符号、代号和缩略语, 便于阅读理解。
 第 6 章系统描述了电力图像数据的专用格式与编解码技术要求, 包括数据结构定义、压缩编码策略、解码重建方法及安全性设计。重点解决电力巡检数据在传输与存储过程中的标准化、高压比与高保真需求, 确保系统在效率、安全与一致性方面的工程可落地性。
 第 7 章详细阐述了图像编解码模型的架构设计、预训练策略与微调机制, 提出面向电力场景的差异化优化路径。通过深度神经网络结合语义分割与注意力机制, 实现对关键设备区域的精准识别与高保真压缩, 兼顾非关键区域的数据冗余控制, 提升整体图像处理性能与任务适配能力。
 第 8 章阐述了模型的评测方法, 包括评估模型性能的各类指标、测试数据和评测方法, 确保模型在实际应用中的高效性与适用性。
 第 9 章阐述了模型在实际应用中的部署方法, 包括硬件环境与操作系统的适配、自主可控能力的支持, 以及网络安全与数据隐私保护等关键内容。同时, 结合推理加速、容器化部署与服务化推理等技术手段, 提升模型部署的效率、稳定性和安全性, 确保其在电力业务场景中的可靠运行。

6 技术要求

为满足电网设备巡检中对图像处理的高精度、实时性和安全性的要求, 本文件提出一种面向电力图像的智能图像编解码总体技术架构。该架构以深度学习神经网络为主要技术路径, 通过端到端建模实现图像压缩与重构的智能化处理, 提升图像数据的编码效率与质量。

考虑到智能图像编解码技术发展迅速, 除基于深度学习的方法外, 本文件亦预留对其他智能算法 (如图神经网络、变换学习算法等) 的兼容空间。本文件制定中强调算法适应性与工程可落地性, 鼓励根据实际场景灵活选用技术路径, 以保障整体系统的可持续性与扩展性。

6.1 图像质量和格式要求

为保证智能图像编解码系统在电网设备巡检场景中的应用效果, 图像采集与输入数据应满足以下质量与格式要求:

- 图像类型: 本文件所引入的智能编解码适用于可见光图像的编解码处理, 不适用于红外图像或其他非可见光成像数据;
- 图像分辨率: 输入图像的分辨率应不高于 80 兆像素 (80MP), 以平衡图像细节保留与处理效率, 满足高精度巡检任务需求;
- 色彩深度与通道数: 图像应采用 8 位色深, 3 通道 RGB 模式, 确保图像色彩信息完整性, 便于后续智能识别与分析;

- d) 图像格式兼容性：本文件所引入的编解码不限制图像的文件封装格式，支持 JPEG、PNG 等常见格式的输入数据，以提高系统的灵活性与兼容性。但建议优先选用具备无损或高质量压缩特性的格式，以减少初始图像信息的损失。

以上质量与格式要求为本文件引入的智能编解码模型提供了统一且可控的数据输入基础，确保系统性能稳定、输出结果可靠。

6.2 编解码技术框架总览

相较于传统图像压缩标准（如 JPEG、JPEG2000、HEVC 等），本文件引入基于深度神经网络的端到端编解码架构，具备更优压缩效率、更强语义表达能力与更高安全鲁棒性，尤其适用于电网巡检中对高分辨率、关键区域保真与低延迟处理的综合要求。

本文件引入的智能编解码采用基于深度学习神经网络的端到端图像编解码架构，覆盖图像预处理、特征提取、压缩编码、解码重建及后处理等关键环节。整体技术框架如下：

- 图像预处理：包括图像校准、分辨率归一化、色彩标准化等，提升输入数据一致性，便于后续建模处理；
- 特征提取与编码：通过深度卷积神经网络提取图像潜在语义特征，结合语义分割识别关键设备区域，并采用变换压缩策略进行编码；
- 解码与还原：解码模块根据压缩潜在特征还原高保真图像，利用多尺度与注意力机制增强关键区域重建精度；
- 鲁棒性优化：结合误码检测、自适应重构与对抗训练机制，提升系统在复杂电网巡检环境下的容错与泛化能力；
- 实时性设计：支持低延迟处理框架，并结合端云协同技术，实现边缘设备快速响应与云端高精度解码的协同处理；
- 准确性保障：重点优化关键设备、故障区域的信息保留策略，提升系统输出的识别准确率与决策支持能力。

本框架具备良好的可扩展性，能够适应电力巡检场景中对图像编解码的高质量、高效率与高安全性要求。

6.2.1 图像预处理模块

为提升图像数据的输入质量与一致性，在编码前应进行图像预处理。典型操作包括图像尺寸归一化、色彩空间标准化、图像锐化、去噪处理等，以降低原始图像中存在的伪差异，提高模型对设备和故障区域的判别能力。

6.3 电力专属格式数据格式

电力巡检图像需采用具有针对性的专用数据格式，以适应电网设备巡检对图像精度、时效性及数据安全的综合要求。合理的数据结构设计可有效优化存储空间、提高传输效率，并增强系统的安全防护能力。

本文件所提出与推荐的智能图像编解码方法，基于端到端的深度学习神经网络模型，针对典型电力巡检场景进行模型训练和优化，满足高精度、低延迟的处理需求，提升系统对复杂工况下图像信息的表达与还原能力。

6.3.1 数据结构设计

电力专属格式数据应按照如下内容进行设计：

- 头部信息：包含文件标识、版本号、哈希校验码等元数据，确保数据完整性，具体结构规范见附录 A.1；
- 图像数据块：采用深度卷积神经网络（CNN）端到端编码，存储图像特征、分辨率、色深及压缩方式，具体结构规范见附录表 A.2；
- 元数据块：记录时间戳、设备 ID、巡检环境参数、故障标注信息及潜在空间表示，具体结构规范见附录表 A.3；
- 扩展块：预留动态量化、自适应压缩策略字段，支持多模态数据融合，提高巡检图像的适应性，具体存储方式规范见附录表 A.4。

6.3.2 数据结构校验与优化

为了确保数据在存储和传输过程中既完整又能高效处理，本文件引入了一系列优化的校验与存储机制：

- a) 采用 SHA256+CRC32 双重校验，在数据传输和存储环节提供额外的安全保障，降低数据损坏或篡改的风险，由此确保了数据传输与存储的完整性；
- b) 借助层级索引存储结构，结合神经网络特征映射，提高数据检索的速度，使查询更高效；
- c) 应用基于深度学习的误码检测，减少因传输误码导致的数据损坏，提高数据恢复质量。

6.3.2.1 应用场景及设备

为满足电力图像智能编解码的应用需求，本文件适用范围涵盖以下电网设备及巡检场景：

- a) 一次设备：包括高压、中压、低压输电线路、线缆及变电站主要设备的图像数据；
- b) 二次设备：涵盖变电站继电保护装置、自动化控制设备及各类传感器图像数据；
- c) 采集方式：支持无人机巡检、地面巡检等多种图像采集手段，确保系统对不同设备类别及环境的编码与解码能力；
- d) 系统兼容性：保证智能编解码模型适用于一次与二次设备图像的高效处理，满足多样化巡检需求。

6.3.2.2 电网场景特性优化

电网巡检通常涉及高动态场景，环境复杂多变，易受到极端天气（如强风、雨雪、雾霾）以及电磁干扰等因素影响。因此，图像编解码过程需进行针对性优化，增强模型在不同场景下的稳定性与鲁棒性，确保数据在传输与解码过程中的完整性和可用性。具体方法包括提升算法对信号噪声的抵抗能力、增强模型对突发编码错误的处理能力，以及根据巡检任务特征优化压缩策略，提升整体系统性能。主要优化模块包括：

- a) 端到端处理：通过神经网络联合优化编码与解码过程，提高巡检数据的压缩率和重建质量；
- b) 关键区域识别：应用语义分割方法识别电力设备、故障点等关键区域，实现分区域压缩策略，保障重要信息质量；
- c) 自适应编码：基于帧间变化检测，仅存储变化信息，提升在动态环境中的压缩效率与实时性；
- d) 端侧智能处理：支持在无人机、巡检机器人等边缘设备上实时计算和预处理，提高系统响应能力，减少传输负担；
- e) 环境适应性增强：针对电磁干扰、强光/背光、低照度等极端条件进行图像增强与鲁棒性训练，确保编解码系统具备良好的泛化能力与适应性。

6.4 编码规则

基于端到端的智能编码技术可在优化压缩率的同时提升巡检数据的传输与存储效率，并确保关键区域的细节完整性。

6.4.1 基于深度学习的编码模型

深度学习方法在编码技术中的应用，可以显著提高编码效率和适应性，确保在不同场景下保持高质量的编码表现。以下几种关键策略进一步提升了编码性能：

- a) 端侧编码：使用深度卷积神经网络提取图像特征，并将图像压缩至潜在空间表示；
- b) 关键区域增强：通过图像语义分割技术，生成二进制掩模图，提升电力设备和故障点的编码精度；
- c) 帧间特征学习：计算相邻帧潜在空间表示的变化差异，仅编码变化信息，提高视频流压缩效率；
- d) 通道空间混洗上下文模型：优化通道信息分布，提高数据压缩率与模型表达能力。

6.4.2 编码参数优化

针对电网巡检的特殊需求，编码策略需在提高压缩比的同时保持图像质量。为此，可以优化编码参数并引入以下关键技术：

- a) 端到端量化策略：采用非对称 INT8 量化，针对每层网络权重和激活值进行独立动态范围校准；
- b) 目标区域优化：关键区域采用高精度量化，背景区域进行低精度压缩；
- c) 动态量化策略：通过可学习量化步长自适应调整权重，提高数据编码灵活性；

- d) 熵编码优化：结合上下文感知熵编码，优化 Huffman/算术编码策略。

6.5 解码方法

在电网巡检过程中，端到端解码不仅能提升图像的实时处理能力，还能确保关键区域的信息准确恢复，进而提高巡检结果的可靠性和精准度。

6.5.1 多级解码模式

考虑到不同巡检任务的需求，解码方式需要具备一定的灵活性，以平衡图像质量与处理速度。具体策略包括：

- a) 快速预览解码：针对大规模数据筛查，优先采用低分辨率图像重建方式，提高故障筛查效率；
- b) 高精度解码：利用多尺度解码器，在重要设备区域采用高分辨率重建，增强细节呈现能力；
- c) 对抗训练优化：借助生成 GAN 网络，优化解码图像的视觉一致性，使图像更符合实际巡检需求。

6.5.2 实时解码优化

为满足电网巡检对实时性的要求，解码策略应在保证解码质量的前提下尽量减少延迟，提高计算效率。关键优化措施包括：

- a) 低延迟解码：改进计算流程，使解码时间保持在 50ms 以内，确保边缘设备能够快速响应；
- b) 端云协同：充分利用云计算和边缘计算的优势，在解码过程中合理分配计算任务，提高处理能力；
- c) 自适应解码：结合注意力机制，依据巡检任务需求动态调整解码精度，从而优化存储与计算资源的分配。

6.5.3 安全要求

电网设备巡检图像数据涉及电力系统核心资产信息，具有高度敏感性。为保障图像数据的机密性、完整性与可用性，本文件提出如下安全保障机制：

- a) 数据加密保护：采用 AES-256 高级加密标准对图像数据在存储与传输环节进行加密处理，防止数据在传输过程中被截获或泄露；
- b) 访问权限控制：通过端侧认证机制与分级权限管理系统，确保图像数据仅被授权用户访问，杜绝非授权操作，降低信息泄露风险；
- c) 防伪与篡改检测：结合基于哈希签名的数字水印技术，在图像数据中嵌入不可见身份标识，支持数据篡改识别与追溯，增强数据可信度；
- d) 对抗样本防护：引入基于生成对抗网络（GAN）的对抗样本检测机制，防范图像识别系统受到恶意攻击，提升系统的稳健性与安全性；
- e) 数据完整性校验：采用 SHA-256 哈希函数和 CRC32 冗余校验码对图像数据进行双重完整性校验，保障图像在存储与传输过程中的一致性与可靠性；
- f) 高可用性与容灾机制：引入数据冗余备份与边缘-云协同恢复策略，确保在设备异常或网络故障场景下，图像数据依然可用并支持系统的持续稳定运行；
- g) 安全审计与日志追踪：系统应具备安全访问日志记录与异常行为监控能力，实现对敏感图像数据访问行为的可追溯与问责。

通过上述多层次的安全设计，保障了图像数据在电网设备巡检过程中的全生命周期安全，为智能图像编解码系统在关键基础设施领域的可靠部署与运行提供基础保障。

7 模型预训练与微调

本文件所适配的电力图像的智能编解码模型采用深度学习方法，通过预训练与微调提升模型的适应性与泛化能力。预训练阶段使用大规模电力巡检图像数据，以增强模型对关键区域的识别能力，而微调阶段则针对特定任务优化模型参数，提高压缩效率和解码质量。

7.1 模型架构

在电网巡检任务中，既要实现数据的高效压缩，也要保证关键信息能够精准恢复。因此，本文件提出了一种基于深度学习的模型架构，该架构结合端侧编码与中心端解码，以提高数据传输与重建的质量。其主要组成部分如下：

- a) 端侧编码网络：利用 CNN 网络提取电力设备的关键特征，如线缆和接头等，并进行高效压缩；
- b) 中心端解码网络：采用多尺度解码器，并结合注意力机制优化关键区域的还原效果，确保巡检数据的完整性；
- c) 端到端训练：通过联合优化编码器和解码器，使模型能够适应不同巡检任务的压缩与恢复需求，提高任务执行的适配度。

7.2 模型预训练

为了增强模型在电网巡检任务中的适应能力，本文件采用预训练方法来优化特征提取效果。核心优化策略包括：

- a) 多样化数据集：收集涵盖不同天气、光照和巡检场景（如变电站、输电线路、配电设备等）的无人机巡检图像，提高模型的泛化能力；
- b) 深度学习与注意力机制结合：利用深度神经网络学习特征，同时引入注意力机制增强关键区域的识别能力，减少信息丢失；
- c) 关键区域增强：结合语义分割与帧间变化分析，使电网设备的核心部件（如变压器接头、电缆连接点等）在编码过程中得到更高保真的处理。

7.3 模型微调

为了进一步提升模型在电网巡检任务中的实用性与适应性，本文件提出了差异化优化策略，针对关键与非关键区域在压缩质量、计算资源与传输延迟上的不同需求，进行精细化参数调整，确保系统性能在多维目标下取得最佳平衡。具体包括：

- a) 差异化压缩策略：结合语义分割与设备识别模型，系统将图像区域分为关键与非关键两类。
 - 1) 对于关键区域（如故障点、连接器、线缆等），采用高码率、低失真压缩，保留图像细节，确保故障识别与后续分析的准确性；
 - 2) 对于非关键区域，则采用更高压缩比编码策略，适度牺牲感知质量，以换取传输与存储效率。在极低码率场景下，模型通过主观视觉感知优化与客观指标（指标可参考附录表 B.1）之间的动态平衡，最大程度保留人眼敏感区域的关键信息。
- b) 针对二次设备关键区域标定：由于二次设备结构复杂且局部细节关键，建议通过关键区域的标定辅助模型训练和强化，以提升关键区域的编码质量及图像还原效果。这一措施与上述关键区域与非关键区域的差异化压缩策略相辅相成，确保在整体压缩效率与细节保真之间实现最佳平衡。
- c) 硬件加速优化：结合 TensorRT 推理引擎，在 GPU 部署环境中加速模型前向计算，并通过剪枝与量化技术减少模型体积与运行延迟，提高在边缘设备上的实时处理能力。
- d) 端云协同部署：针对边缘端与云端解码环境差异，微调模型结构与参数配置，实现端侧轻量部署与云侧高精度重建的协同优化，支持巡检场景下的实时响应与精细化分析。

8 测试与评价

智能图像编解码系统的性能测试主要包括编码质量、计算效率、模型稳定性等方面。通过对比不同编解码方案，确保算法在电网巡检场景下的适用性。

8.1 测试对象

- a) 测试算法：电力图像专属智能编解码算法、标准 JPEG 压缩、Raw Data。
- b) 测试数据：选取输电线路、变电站、配电设备的巡检图像，涵盖红外、可见光等多模态数据。

8.2 评价指标

- a) 客观指标：使用 PSNR、SSIM、LPIPS 等图像质量指标评估压缩性能，具体见附录表 B.1。

- b) 性能指标：
 - 1) 编码速度：处理速度不低于 5 张/秒（500 万像素）；
 - 2) 计算资源占用：GPU 使用率 $\leq 70\%$ ，满足边缘设备部署要求；
 - 3) 额外指标性能指标项。（见附录表 B.2）。
- c) 泛化性：
 - 1) 经过编解码后，图像不得出现明显损坏；
 - 2) 计算资源占用：GPU 使用率 $\leq 70\%$ ，满足边缘设备部署要求。

9 模型部署

9.1 模型部署适配

9.1.1 硬件适配

在模型部署过程中，硬件适配是确保压缩与解压缩软件高效运行的关键环节。不同硬件平台在架构、算力及指令集方面存在差异，因此需要针对具体设备进行优化配置，以提升系统的兼容性和运行效率。本部分对端侧和中心端的硬件适配要求进行说明。

- a) 端侧设备适配：在无人机等端侧设备上部署压缩软件时，应首先评估目标硬件的计算能力和加速设备支持情况，确保其能够满足压缩算法的优化需求。同时，需要验证数据处理和传输流程，以保证整体性能的最优实现；
- b) 中心端设备适配：在中心端运行解压缩软件时，应评估目标平台的 AI 加速能力，包括 GPU、NPU、ASIC 等计算单元，并确认其对相关硬件加速库（CUDA、TensorRT）的兼容性。合理利用硬件加速资源，可进一步提升解压缩效率和模型推理性能。

9.1.2 操作系统适配

在模型部署过程中，操作系统的兼容性对于软件的正常运行至关重要。不同操作系统版本可能存在差异，特别是在依赖库、内核版本和软件源等方面。因此，确保目标操作系统与部署的软件兼容，并且能够支持压缩和解压缩任务的执行，是部署过程中的重要环节。具体如下：

- a) 压缩软件适配：在部署压缩软件时，应确认目标操作系统的版本及其内核、软件源、依赖库等的兼容性，确保安卓系统（用于无人机端）能够满足所需 SDK 运行的需求；
- b) 解压缩软件适配：对于解压缩软件，应确保 Ubuntu 18.04（glibc 2.27）操作系统能够与 SDK 兼容，以保证解压缩任务的正常运行；

同时，系统在操作系统环境下的数据处理过程中，严格遵循国家网络安全相关标准，数据传输过程中采用符合国家密码规范的数据加密机制，存储访问具备权限控制与操作日志审计功能，切实保障关键图像及模型数据在无人机与平台间传输过程中的安全性与可追溯性。

9.1.3 安全性与隐私保护

在电力巡检数据的部署和处理过程中，数据安全和隐私保护是不可忽视的关键问题。尤其是在处理敏感电力图像数据时，保障数据的安全性与模型的防护至关重要。具体如下：

- a) 数据安全：在部署过程中，特别是涉及敏感电力图像数据时，应确保数据在存储、传输和计算过程中的保密性。建议使用加密技术保护数据，防止数据泄露或被未授权访问；
- b) 模型安全：在部署大规模模型时，应考虑到反向工程、黑盒攻击等潜在的安全威胁。采取加密技术和模型加固等安全措施，以确保模型及数据处理的安全性。

9.2 推理加速与性能优化

9.2.1 高并发需求

在电网巡检任务中，解压缩软件需要同时处理大量请求，尤其是在高并发场景下，系统的响应能力和稳定性会直接影响业务的连续性。因此，在实际部署过程中，合理管理计算资源、优化并发处理能力，成为确保系统高效运行的关键。

为此，可以采取以下措施：

- a) 线程与资源调度优化：在推理阶段，根据硬件配置合理调整线程数量、进程管理及协程调度，避免单一资源过载影响整体性能，提高任务处理效率；
- b) 分布式架构扩展：面对大规模并发请求，可以采用负载均衡、多实例部署以及集群扩展等方法，使系统具备更好的伸缩性，确保即使在高负载状态下仍能保持稳定运行。

9.2.2 模型量化

在处理大型电力图像数据时，压缩和解压缩软件对计算资源的需求较高，因此通过优化模型，尤其是采用量化技术来减少计算负担，是提升性能和减少资源占用的重要手段。合理应用量化技术能够显著提高推理效率，同时保持较高的精度。具体如下：

- a) 量化技术应用：对于大型电力图像数据处理，采用模型量化技术可以有效减小模型大小，提高推理吞吐量，降低硬件资源占用。特别是在 GPU、NPU 等硬件加速支持下，量化技术能够显著优化性能；
- a) 硬件适配：不同硬件平台对量化精度的支持程度有所不同。因此，应根据目标硬件的特性，测试并评估量化对模型精度和性能的影响，选择最适合的量化策略，确保在优化性能的同时，保持精度的平衡。

9.2.3 推理框架优化

推理框架的选择与优化对于系统性能至关重要，特别是在利用硬件加速的情况下，合理选择并优化推理框架能够充分发挥硬件平台的计算能力。本节将讨论如何根据硬件平台的不同特性，优化推理框架以提升系统性能。具体如下：

- a) 推理引擎选择：根据硬件平台的不同特性，选择合适的推理引擎，充分利用硬件加速资源，提高推理性能；
- b) 算子优化：为了进一步提升推理效率，应针对硬件特性编写优化算子库，特别是在 GPU 或 NPU 平台上，应进行定制化优化，以实现最佳的计算性能。

9.3 镜像化部署与服务化管理

9.3.1 镜像化部署

为了简化压缩与解压缩软件在不同硬件和操作系统环境下的部署与管理，建议采用容器化技术进行封装。通过镜像化部署，能够确保软件在不同计算环境中的一致性与可移植性，尤其是在使用 GPU 加速的硬件环境下。具体如下：

- a) 容器化技术应用：为简化压缩与解压缩软件的部署，建议采用容器化技术进行镜像封装。容器化可以统一打包所需的依赖库、配置和模型文件，确保跨平台的兼容性并提高部署效率。在使用 GPU 加速时，可以结合 NVIDIA Docker 等工具，利用 GPU 资源进一步优化计算性能；
- b) 镜像内容配置：容器镜像中应包含所需的推理框架、依赖库、模型文件及相关配置，确保在不同硬件平台上的兼容性，并避免部署过程中的依赖不一致问题。

9.3.2 模型服务化（第二层次条的标题）

为增强软件的可扩展性和复用性，服务化部署已成为提升系统性能和支持多应用接入的关键。通过服务化接口，外部应用可以方便地调用压缩与解压缩服务，提高了系统的灵活性与可维护性。具体如下：

- a) 服务化接口：为便于外部应用调用，压缩与解压缩软件应通过服务化接口对外提供推理服务。服务化架构使得不同应用能够便捷地接入压缩与解压缩功能，增强软件的可扩展性和复用性；
- b) 服务管理与动态扩展：在复杂电网巡检任务中，为了确保系统能应对高并发请求，建议采用容器化管理方式来提升灵活性和可扩展性。建议使用 Kubernetes 和 Docker Swarm 等编排类工具，进行动态调整计算资源，使得模型能够支持自动扩容和负载均衡，且能使多个实例能够协同工作，从而优化整体系统性能。

9.3.3 版本管理与灰度发布

在软件持续更新过程中，合理的版本控制策略可以降低系统升级带来的潜在风险。通过版本化管理和灰度发布的方式，能够逐步推送新功能，避免大规模变更对业务的影响，确保软件的兼容性和平稳过渡。具体策略包括：

- a) 版本控制：采用严格的软件版本管理方案，明确每个版本的更新内容，确保回滚机制完善；
- b) 灰度测试：在发布新版本或优化方案时，先在小范围内进行试运行，观察新版本在真实环境中的稳定性，再逐步推广到全量用户，降低大规模故障的风险。

附录 A
(技术性)
数据结构设计格式表

A.1 数据头部信息字段表 (Header)

头部信息包含文件标识、版本号、哈希校验码等基础元信息，旨在实现数据的快速识别和解析。本文件的电力专属格式数据的头文件具体字段设计见表 B.1。

表 A.1 头部信息字段表

字段名称	类型	描述
magic_number	uint32	数据标识，用于快速识别文件类型。
version	uint16	数据结构版本号，支持向后兼容性。
header_size	uint16	头部信息的长度，便于解析器快速跳转。
checksum	uint32	数据校验码，用于验证数据完整性。
data_offset	uint64	图像数据块的起始位置。

A.2 图像数据块结构表 (Image Data Block)

图像数据块采用深度卷积神经网络 (CNN) 进行端到端编码，存储图像的特征信息、分辨率、色深以及压缩方式，确保图像核心内容的高效存储，同时支持多种图像类型的处理。

本文件的电力专属格式数据的图像数据块具体结构见表 B.2。

表 A.2 图像数据块结构表

字段名称	类型	描述
image_type	uint8	图像类型标识 (如, 0: 可见光, 1: 红外等)。
width	uint16	图像宽度 (像素数)。
height	uint16	图像高度 (像素数)。
color_depth	uint8	色深 (例如 8 位、16 位)。
compression_type	uint8	压缩类型 (如, 0: 无压缩, 1: 专用压缩)。
image_data	byte[]	图像内容的二进制数据。

A.3 元数据块结构表 (Metadata Block)

元数据块包含时间戳、设备 ID、巡检环境参数、故障标注信息及潜在空间表示，用于存储核心图像内容，支持多种图像类型。它能够提供关键的巡检数据和设备信息，便于数据分析和故障定位。

本文件的电力专属格式数据的元数据块具体结构见表 B.3。

表 A.3 元数据块结构表

字段名称	类型	描述
timestamp	uint64	时间戳，UTC 时间格式 (毫秒)。

device_id	string	巡检设备唯一标识符。
location	float[3]	地理位置信息（经度、纬度、高度）。
sensor_params	map<string, string>	传感器相关参数键值对。
anomaly_flag	uint8	异常标志位（0：无异常，1：异常）。
元数据块应支持对数据进行压缩，以减小传输开销，提升效率。 注 1：元数据块中的异常标记字段用于快速定位巡检中发现的设备问题，确保及时处理。		

A.4 扩展块对存储形式表（Header）

扩展块用于预留动态量化、自适应压缩策略等字段，以便未来支持多模态数据融合和巡检图像的适应性增强。扩展块的设计考虑了未来的灵活性，允许对新型数据格式或自定义信息的扩展。
本文件的电力专属格式数据的扩展块存储具体方式见表 B.4。

表 A.4 扩展块结构采用键值对存储方式表

键（Key）	值类型	描述
key	string	扩展字段的键。
value	variant	扩展字段的值，支持多种类型（int、string 等）。
扩展字段需要具备良好的灵活性，以支持不同类型的数据（如整数、字符串等）。此外，扩展块应预留足够的空间，以适应未来的数据增长需求，例如新增热成像深度图、多模态数据等。 同时，为了增强系统的开放性，扩展块还需支持用户自定义字段，使第三方设备厂商可以根据需求添加特定信息，提升数据兼容性。 注 1：安全加密标记字段可用于记录加密算法和密钥相关信息，以确保数据传输和存储过程的安全性，防止未授权访问。		

附录 B (资料性) 评价指标标准参考

B.1 编解码画质评价标准

图像编解码过程中，压缩画质是重要的评估标准。本文件采用 PSNR（峰值信噪比）、MSSSIM（多尺度结构相似度）、SSIM（结构相似性指数）以及主观评价（肉眼观察）等指标，全面评估压缩效果。每个指标从不同角度反映图像质量，并提供定量结果，帮助优化压缩算法。

附录中列出了各项评估指标的定义、公式及实际意义，便于理解和比较不同算法的压缩效果。这些客观指标为算法性能评估与图像质量优化提供了有效依据。参考评估指标见表 B.1。

表 B.1 图像压缩质量评价指标及语义

指标名称	指标语义	评价标准
Bpp	Bits per pixel, 码点, 每个像素的比特数, Bpp 的大小与图像体积成正比。	一般压缩后 Bpp 越小代表体积越小。
PSNR	PSNR 国际标准, 用于评价图像相似度。可简单地由均方差 MSE 进行定义。该指标的单位是 dB, 值越大代表图片质量越高。	一般 PSNR 大于 35dB 为优秀。
MSSSIM	MSSSIM 是一种衡量两幅图像相似程度的结构相似性指标, 分别从亮度、对比度、结构化三方面度量图像的相似性。	MSSSIM 值越大, 表示压缩后的重构图与原始人眼观感越接近。
SSIM	SSIM 是一种综合考虑亮度、对比度和结构等因素来评估重构图像与原始图像之间的相似度的指标。越大代表图像越相似。	SSIM 值的范围为 0 至 1, 值接近 1 时, 表示重构质量较好。
主观评价	顾名思义, 是直接通过肉眼来判断, 压缩前后的图片之间的差异。因为大多数的图片最终是给人看的, 因此该指标在图片压缩领域也是非常常用。	

B.1.1 Bpp 计算公式

计算公式如下：

$$BPP = \frac{S}{W \times H}$$

其中：

- a) S 代表图像文件大小, 单位为 bit;
- b) W 代表了图像宽度, 单位为像素;
- c) H 代表了图像的高度, 单位为像素。

B.1.2 PSNR 计算公式

计算公式如下：

$$PSNR = 10 \cdot \log_{10} \left(\frac{R^2}{MSE} \right)$$

其中：

- a) R 是图像的最大可能像素值；
 b) MSE 是原始图像与压缩图像之间差异的平均值，其计算公式如下：

$$MSE = \frac{1}{N} \sum_{i=1}^N \left(I_{\text{orig}}(i) - I_{\text{compressed}}(i) \right)^2$$

其中：

- 1) N 是图像的最大可能像素值；
 2) $I_{\text{orig}}(i)$ 和 $I_{\text{compressed}}(i)$ 分别是原始图像和压缩图像在第 i 个像素的位置上的值。

B.1.3 SSIM 计算公式

计算公式如下：

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)}$$

其中：

- a) x 和 y 是两幅图像的局部区域；
 b) μ_x 和 μ_y 分别是图像 x 和 y 的均值；
 c) σ_x^2 和 σ_y^2 分别是图像 x 和 y 的方差；
 d) σ_{xy} 是 x 和 y 之间的协方差；
 e) c_1 和 c_2 是常数，通常设置为 $c_1 = (K_1 L)^2$ 和 $c_2 = (K_2 L)^2$ ，其中 L 是图像的动态范围， $K_1 = 0.01, K_2 = 0.03$ ；

B.1.3 MSSIM 计算公式

MSSIM 是 SSIM 的扩展，计算过程较复杂，通常是分块计算每一块的 SSIM，再求其平均值。MSSSIM 的计算公式如下：

$$MSSSIM = \prod_{i=1}^M SSIM_i^{w_i}$$

其中：

- a) $SSIM_i$ 是第 i 个子区域的 SSIM 值；
 b) w_i 是权重系数，通常取决于子区域的重要性，也就是根据像素所表达的画面信息的重要性来决定。

B.2 编解码性能标准

编解码性能直接影响压缩算法的实用性和工程应用价值。本文件通过多个关键指标对图像压缩性能进行量化评估，包括压缩与恢复时间、压缩比、智能识别结果差异、运行稳定性以及硬件资源使用率。这些指标综合衡量算法的效率、稳定性和资源消耗，为优化压缩方案提供数据支持。

附录中列出了各项指标的定义、评价标准及其适用范围，以便明确性能评估的具体要求。相关内容见表 B.2。

表 B.2 图像压缩性能评价标准及语义

指标名称	指标语义	参考评价标准
------	------	--------

压缩时间	图像压缩所需耗时。	500W 像素输入，8 核机器，5 张/每秒。
恢复时间	恢复压缩图像所需耗时。	500W 像素输入，8 核机器，5 张/每秒。
压缩比	压缩图像与原图大小进行对比，从而形成压缩比。	JPEG 95 图像质量输入，压缩率 90%； JPEG 80 图像质量输入，压缩率 80%。
智能识别结果差异	恢复图像智能识别与原图智能识别结果对比。	对比差异小于 5%。
运行稳定性	主机、程序的健康运行时长。	保证设备 30*24 小时无故障。
硬件资源使用率	算法运行过程所在使用的硬件资源情况，包括 CPU、内存等使用率。	

T/CES XXX—XXXX
