

## 深度学习驱动的智能电网运行图像数据压缩技术

夏 信<sup>1</sup>, 何传亮<sup>1</sup>, 吕英杰<sup>2</sup>, 王守志<sup>2</sup>, 张 博<sup>2</sup>, 陈 晨<sup>3</sup>, 陈海鹏<sup>4\*</sup>, 李美萱<sup>5\*</sup>

- (1. 国家电网公司电力线通信应用技术实验室 北京智芯微电子科技有限公司, 北京 102200;
2. 北京电科智芯科技有限公司, 北京 100192;
3. 吉林大学仪器与电气工程学院, 吉林 长春 130026;
4. 东北电力大学 电气工程学院, 吉林 吉林 132012;
5. 吉林工程技术师范学院 量子信息技术交叉学科研究院, 吉林 长春 130052)

**摘 要:** 随着智能电网的快速发展,用于监视电网运行状况的测量设备大规模投入,其产生的海量运行图像等监视数据由于规模大、维度高、数据冗余等问题难以得到有效利用。为了进一步提高电力大数据的分析应用能力,文中提出一种基于深度学习的电网运行图像数据压缩方法,考虑电网图像监视数据在时序上的耦合关联,通过卷积神经网络对电网运行图像数据进行压缩,有效减少了电网运行图像数据的冗余度。与其他方法相比,基于卷积神经网络的图像数据压缩模型不依赖于人工的数据特征提取和工程经验,可以直接以电网中采集到的原始图像数据的灰度函数作为模型的输入,将数据的特征提取和分类合二为一,实现电网运行图像数据的高效、便捷压缩。通过仿真进行了文中所提方法有效性的验证,结果表明,与其他神经网络相比,所提方法在电网图像压缩效率及压缩精度中具有较强优势。

**关键词:** 智能电网; 深度学习; 数据驱动; 卷积神经网络; 图像压缩

**中图分类号:** TP391.4 **文献标志码:** A **DOI:** 10.3788/IRLA20220097

## Image data compression technology of smart grid operation based on deep learning

Xia Xin<sup>1</sup>, He Chuanliang<sup>1</sup>, Lv Yingjie<sup>2</sup>, Wang Shouzhi<sup>2</sup>, Zhang Bo<sup>2</sup>, Chen Chen<sup>3</sup>, Chen Haipeng<sup>4\*</sup>, Li Meixuan<sup>5\*</sup>

- (1. State Grid Laboratory of Power Line Communication Application Technology, Beijing Smart-Chip Microelectronics Technology Co., Ltd, Beijing 102200, China;
2. Beijing Electric Power Science & Smart Chip Technology Company Limited, Beijing 100192, China;
3. College of Instrumentation and Electrical Engineering, Jilin University, Changchun 130026, China;
4. Department of Electrical Engineering, Northeast Electric Power University, Jilin 132012, China;
5. Institute for Interdisciplinary Quantum Information Technology, Jilin Engineering Normal University, Changchun 130052, China)

**Abstract:** With the rapid development of smart grids, large-scale investment in measurement equipment for monitoring the operation of power grids, the monitoring data such as massive operation images generated by them is difficult to be effectively utilized due to problems such as large scale, high dimension and data redundancy. In order to further improve the analysis and application ability of power big data, this paper proposes a power grid operation image data compression method based on deep learning. Considering the coupling correlation of power

收稿日期:2022-01-21; 修订日期:2022-03-23

基金项目:北京智芯微电子科技有限公司实验室开放基金项目

作者简介:夏信,男,高级工程师,硕士,主要从事电力系统人工智能芯片、计量芯片安全应用技术方面的研究。

通讯作者:陈海鹏,男,副教授,硕士生导师,博士,主要从事人工智能算法在电力系统中应用等方面的研究。

李美萱,女,讲师,博士,主要从事多光谱关联成像技术、光学系统设计与制造方面的研究。

grid image monitoring data in time series, the power grid operation image data is compressed through convolutional neural network, effectively reducing the redundancy of power grid operation image data. Compared with other methods, the image data compression model based on convolutional neural network does not rely on manual data feature extraction and engineering experience, and can directly use the grayscale function of the original image data collected from the power grid as the input of the model, and the data The feature extraction and classification are combined into one, to achieve efficient and convenient compression of power grid operation image data. The effectiveness of the method proposed in this paper is verified by simulation. The results show that the proposed method has strong advantages in power grid image compression efficiency and compression accuracy compared with other neural networks.

**Key words:** smart grid; deep learning; data-driven; convolutional neural network; image compression

## 0 引言

近年来,我国电网的规模不断扩大,智能化水平显著提高。与以往的电网相比,智能电网覆盖了更为广泛的通信、监视和自动化设备,可以有效保证运行调度人员对于电网运行的监测和控制能力,实现电网的实时可观、可控性。在新型电力系统的背景下,分布式电源、电力电子设备和新型负荷的大规模接入,使得电网的波动性、随机性愈演愈烈<sup>[1]</sup>。为了保证对电网的安全稳定运行,需要对电力系统中的设备进行实时监测。然而,电力系统中部署的监测设备往往具有较高的采样频率,使得采集到的数据规模十分庞大,尤其是电力设备的运行监测图像等图类数据,将引起存储空间和传输带宽不足等问题。另外,由于数据冗余等问题的存在,上述采集到的数据也往往难以得到高效的利用,给电网的数据分析带来不便。为了解决上述问题,相关的专家学者对数据压缩技术应用于电网大数据进行了广泛的研究和探讨。

数据压缩技术是在保证数据信息不丢失的基础上,对数据量进行缩减操作,从而达到减少硬件存储空间,同时提高数据传输、存储及处理效率的一种方法<sup>[2]</sup>,其在电力大数据处理中得到了广泛的应用。在电力系统数据压缩领域,传统的处理方法有离散傅里叶变换(Discrete Fourier Transform, DFT)和快速傅里叶变换(Fast Fourier Transform, FFT)<sup>[3-4]</sup>。通过傅里叶变换处理后,电网的数据可以得到大幅度的缩减。除此之外,有部分学者基于数据编码的方法进行电网数据的压缩,参考文献[5]在数据压缩过程中考虑了智能电表负荷数据的传输要求,与传统方案相比,所提出的传输方案在性能表现上有明显的优势。参考

文献[6]基于2阶泰勒公式的预测模型,通过实际值与预测值的残差编码实现对电网监视数据的无损压缩。上述方法针对电网中的一维时序数据,取得了较好的压缩效果。在电网的图像数据压缩方面,参考文献[7]通过张量 Tucker 分解技术为基础,结合配电室内设备间的温度信息相关性提出一种针对电网友红外图像监测的数据压缩方法。随着压缩传感(Compressive Sensing, CS)技术的发展,部分学者提出基于压缩感知的数据压缩模型,参考文献[8]采用压缩感知技术,针对电力系统图像采集系统设计了一套图像采集与重建模型,实现了针对电网图像的高效压缩与重构。参考文献[9]针对电力设备红外图像采集过程中出现的分辨率降低和模糊现象,提出了一种压缩感知盲超分辨率改进方法,结合图像在变换中稀疏的先验知识,实现了图像的超高清重构。上述方法均较好地实现了电力系统中的数据压缩问题,然而上述基于编码或数据变换的处理方法效率相对较低,在面对多维、异构的电网数据时难以适应。

在图像数据压缩领域,基于深度学习技术的技术也取了一些进展,参考文献[10]基于深度神经网络,提出了一种用于输电线路巡检图像数据的快速压缩模型,在保证精度的前提下减小了模型的规模和计算量。参考文献[11]提出了一种基于深度学习框架的电气设备图像压缩感知与重建技术,有效减少了电气设备图像的采样率,提高了图像的重建质量。参考文献[12]将模型压缩技术与卷积神经网络结合,通过深度可分离卷积替换传统卷积,并引入通道注意力机制,实现电力巡航无人机的高精度、高速避障。参考文献[13]通过嵌入压缩激励结构和密集连接结构改进卷积神经网络,实现了电力设备图像的模型构建。

参考文献 [14] 基于残差双重注意机制网络, 实现了电力图像数据的高效压缩与重建。传统的数据压缩方法大多从信息冗余度的角度出发, 为尽可能减少信息冗余而设计编码算法, 处理流程复杂且效率低下。而深度学习方法是一种实现输入到输出的“黑盒式”关系函数, 由大量简单的处理单元组成而成, 并通过非线性、并行分布处理方式将网络输入向输出端进行传递, 可以拟合数据之间的隐含关系, 实现由少量信息到较多信息的直接映射, 在处理数据压缩问题时, 与传统的压缩方法相比具有极高的处理效率。

针对以上问题, 文中将卷积神经网络引入到电网的图像数据压缩问题中, 所提基于卷积神经网络的电网图像数据压缩模型不依赖于人工的数据特征提取和工程经验, 处理流程简单, 且能达到较高的数据压缩效率。该模型以电网采集到的原始图像数据的灰度函数作为网络的输入, 将数据的特征提取和分类合二为一, 输出即为压缩后的图像数据, 可以实现电网运行时序图像数据的高效、便捷压缩。

### 1 基于深度学习的电网数据压缩

卷积神经网络 (Convo Neural Networks, CNN) 是一类包含卷积计算且具有深度结构的前馈神经网络, 文中通过构建 CNN 网络结构, 用于进行电网运行图像数据的压缩。压缩的本质是基于电网时序运行图像数据之间的关联信息和冗余度, 通过 CNN 的训练与拟合, 将时序运行图像数据中的冗余信息进行去除, 从而使实现对电网运行图像数据的高效压缩。

#### 1.1 电网运行数据的关联关系

对于电网的时序运行数据而言, 连续采集的运行图像数据之间存在着一定的关联性, 即相同位置、邻近时刻的像素之间存在着一定的相关性, 如图 1 所示。




图 1 时序数据的关联性

Fig.1 Correlation of time series data

此外, 图像数据中位置相近的像素之间也存在相似性, 假设采样图像数据的灰度函数为  $g(x, y)$ , 则其中各行各列像素的自相关公式为:

$$R_x(k, 0) = \frac{\sum_{x=1}^M \sum_{y=1}^N [g(x, y) - u_g][g(x+k, y) - u_g]}{\sum_{x=1}^M \sum_{y=1}^N [g(x, y) - u_g]^2} \quad (1)$$

$$R_y(0, l) = \frac{\sum_{x=1}^M \sum_{y=1}^N [g(x, y) - u_g][g(x, y+l) - u_g]}{\sum_{x=1}^M \sum_{y=1}^N [g(x, y) - u_g]^2} \quad (2)$$

式中:  $M, N$  分别为行列数;  $u_g$  为图像数据的灰度平均值。在相邻时刻, 图像数据之间的互相关函数可以通过下式进行计算:

$$h(k, l) = \iint (g_i(x+l, y+k) - u_i)(g_i(x, y) - u_i) dx dy \quad (3)$$

通过计算图像数据自身的自相关函数和图像数据之间的相关性函数, 可以对图像数据中像素的关联特征进行提取, 对具有相同特征的像素进行去除处理, 从而实现图像数据压缩的目的。

#### 1.2 CNN 的结构

图 2 展示了 CNN 模型的整体结构, 在 CNN 模型中, 共包括卷积层、池化层、全连接层和 Softmax 层。卷积、池化层用于数据的特征分析; 而全连接、Softmax 层则用于数据的特征分类。




图 2 卷积神经网络的结构

Fig.2 Structure of a convolutional neural network

在卷积中, 卷积核按固定步长对数据遍历运算。每次运算时, 卷积核与相应数据进行相乘、求和, 并得到 logits 值, 然后卷积核移动一个步长, 继续执行运算并遍历整个数据, 卷积的运算操作如下:

$$y'_j = \sum_{i=1}^M x'_i * k'_{ij} + b'_j \quad (4)$$

式中:  $y'_j$  为  $l$  层第  $j$  个运算后的 logits 值;  $M$  为输入特征图个数;  $x'_i$  为  $l$  层  $i$  个输入特征图;  $*$  为卷积运算符;

$k_{ij}$  为  $l$  层与第  $i$  个输入特征图卷积的第  $j$  个卷积核;  
 $b_i$  为  $l$  层的第  $j$  个偏置。

卷积运算后,通过 Sigmoid 激活函数对每个 logits 值进行非线性变换。之后进一步进行池化以减少网络内部的参数和计算量。文中采用最大值池化,以局部接受域的最大值作为输出。其计算公式为:

$$p_j^l = \max_r \{a_j^{l-1}\} \quad (5)$$

式中:  $p_j^l$  为  $l$  层第  $j$  个池化结果;  $r$  为池化域;  $a_j^{l-1}$  为  $l$  层第  $j$  个输出特征图。

在对数据进行卷积和池化后,进一步通过全连接层和 Softmax 层实现数据的分类。全连接层将池化层的输出处理为多维特征向量; Softmax 层则用于特征的分类,其公式可表示为:

$$p(y = k|x; \theta) = \frac{\exp(\theta_k^T x)}{\sum_{j=1}^K \exp(\theta_j^T x)} \quad (6)$$

式中:  $y$  为类别标签,  $y \in \{1, 2, \dots, K\}$ ;  $p(y=k|x; \theta)$  为  $x$  属于类别  $k$  的概率;  $\theta$  为训练参数。

损失函数用于衡量模型的输出和期望之间的差距,文中采用交叉熵损失函数,其数学表达式如下:

$$L(\theta) = -\frac{1}{m} \left[ \sum_{i=1}^m \sum_{k=1}^K I\{y_i = k\} \log \frac{\exp(\theta_k^T x)}{\sum_j \exp(\theta_j^T x)} \right] \quad (7)$$

式中:  $m$  为样本个数;  $I\{\cdot\}$  为指示函数,其值为真时,函数值为 1, 否则为 0。

为了保证模型精准,就要减少模型的损失函数,文中通过反向传播算法实现优化,其公式如下:

$$\theta^* = \arg \min L(f(x; \theta), y) \quad (8)$$

式中:  $\theta^*$  为最优参数;  $L(\cdot)$  为损失函数;  $f(\cdot)$  为模型输出值;  $y$  为模型目标值。

### 1.3 基于 CNN 的数据压缩模型构建

在基于 CNN 的电网运行数据压缩模型中,其本质是通过计算图像数据中自身像素之间的相似性和时序图像数据之间像素的相似性,通过设置相应阈值,对像素进行保留和去除,从而实现图像数据的压缩。首先,获取时序运行图像数据及其灰度函数作为初始样本。然后将样本分为训练集,验证集和测试集。其中训练集用于模型训练,验证集用于调整网络参数,测试集用于验证效果。基于 CNN 的电网运行数据压缩的整体流程如图 3 所示。

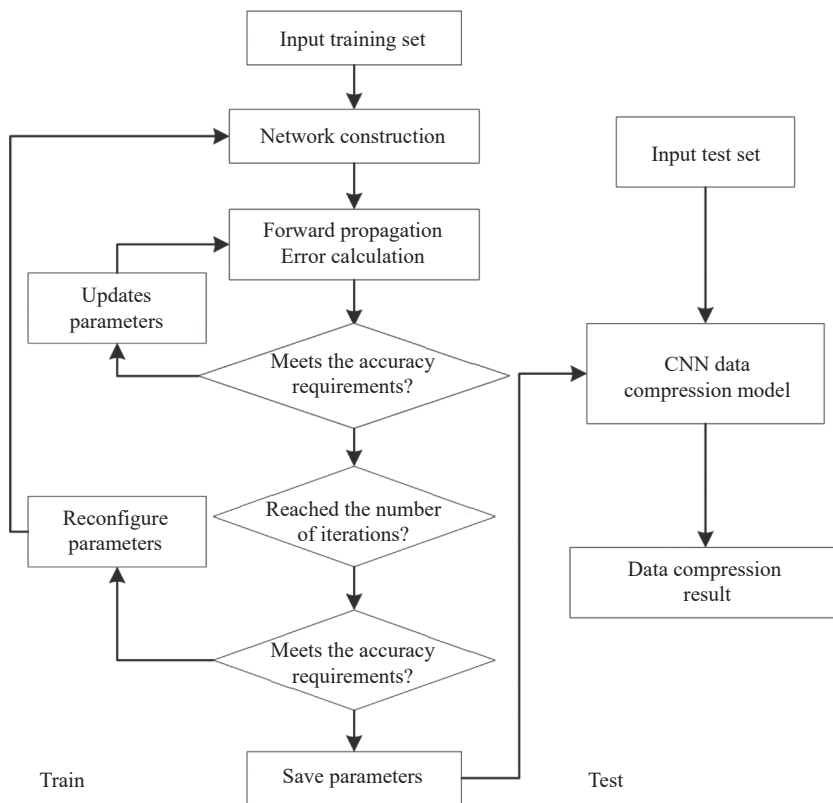


图 3 基于 CNN 的电网数据压缩流程图

Fig.3 Flow chart of data compression of power grid based on CNN

在模型训练过程中,首先根据初始的超参数构建神经网络模型,然后通过网络的前向传播计算网络误差,并判断网络误差是否能够满足设置的精度要求,若不满足则通过反向传播对网络参数进行更新,重新构建网络模型并继续进行精度和迭代次数的判断,当满足要求后通过验证集的样本进行精度确定,如果精度达到要求则完成最优模型的构建,反之则重新配置网络,重复操作直至满足要求。在进行网络测试时,将测试集数据输入到已训练好的 CNN 中,就可以直接输出数据压缩的结果。

## 2 实验结果与分析

为了验证所提基于 CNN 数据压缩模型的有效性和优越性,以某区域电网部署的图像采集设备在 24 h 内采集的连续图像数据为样本,按照 8 : 1 : 1 的比例分割为训练集,验证集和测试集,进行模型的构建及数据压缩测试。所用的深度学习模型基于 Python 中的 Keras 深度学习框架,硬件设备为处理器为 AMD Ryzen 7 4800 H, 2.9 GHz, 内存 16 G, 固态硬盘 256 G 的个人笔记本电脑。

### 2.1 模型参数选择

构建深度学习模型时,选择合适的超参数对模型

的性能至关重要。如网络的卷积层数、卷积层的卷积核数目及大小等,因此需要对 CNN 模型的超参数进行实验,选择能够使模型的性能相对较优的参数值,文中最终选取的最优超参数结果如表 1 所示。

表 1 CNN 的优化超参数结果

Tab.1 Optimized hyperparameters results of CNN

| Parameter type                 | Value        |
|--------------------------------|--------------|
| Optimizer                      | Adam         |
| Batch size                     | 64           |
| Number of convolutional layers | 3            |
| Number of convolution kernels  | (32, 64, 64) |
| Learning rate                  | 0.4          |

### 2.2 数据压缩结果

根据表 1 所确定的最优网络超参数进行 CNN 的模型搭建,通过训练集,对搭建好的模型进行训练,并使用验证集进行验证。值得注意的是,像素的去除阈值  $N$  会对所提模型的压缩精度产生影响,去除阈值  $N$  越高,像素越容易被保留,表 2 展示了不同阈值  $N$  情况下,对各项数据进行压缩后的平均精度及压缩比例,其中,平均精度采用峰值信噪比指标进行计算<sup>[15]</sup>。

表 2 数据压缩精度情况

Tab.2 Data compression accuracy

|                   | $N=0.3$ | $N=0.4$ | $N=0.5$ | $N=0.6$ | $N=0.7$ | $N=0.8$ |
|-------------------|---------|---------|---------|---------|---------|---------|
| Compression ratio | 87.38%  | 84.22%  | 80.34%  | 77.45%  | 60.23%  | 55.31%  |
| Average precision | 66.33%  | 68.62   | 74.16%  | 90.35%  | 91.73%  | 93.56%  |

从表 2 的结果可看出, $N=0.6$  于 CNN 的电网时序运行数据压缩模型既能保证较好的数据压缩效果,又能保持较高的压缩比例。图 4 展示了一组经过文中所提方法处理后的图像数据压缩结果。

此外,为了验证 CNN 在处理时序数据压缩方面与其他模型的优势,选择人工神经网络 (Artificial Neural Network, ANN), 深度置信网络 (Deep Belief Network, DBN) 进行对比,对上述采集的样本数据分别进行压缩处理,分析各方法的效率和精度,如表 3 所示。由此可以看出,文中所采用的 CNN 算法具有更高的准确度,与 ANN 相比提升了 9.41%,与 DBN 相比提升了 4.02%。这得益于 CNN 强大的特征提取

能力。此外,CNN 的训练效率相较于两种对比方法也有一定的提升,与 ANN 相比缩短了 411 s,与 DBN




图 4 基于 CNN 处理前后的电网图像数据压缩结果

Fig.4 Results of image compression in power grid before and after processing based on CNN

表 3 不同模型的对比结果

Tab.3 Comparison results of different models

| Index             | ANN    | DBN    | CNN    |
|-------------------|--------|--------|--------|
| Average precision | 82.32% | 87.71% | 91.73% |
| Training time/s   | 1682   | 1533   | 1271   |

相比缩短了 262 s, 这是因为 CNN 在图像数据处理中能够更好地对数据特征进行挖掘和处理, 因此具有更好的训练表现。

### 3 结 论

文中提出了一种基于深度学习的电网数据压缩方法, 该方法通过卷积神经网络实现对电网时序运行数据的压缩, 且不需要对数据进行复杂的预先处理, 适用性强, 可有效解决电网运行数据中存在的冗余问题。后续的研究将考虑采用具有时序数据处理能力的深度学习模型, 进一步深度挖掘电网的图像数据在不同时间节点之间的耦合关联, 以期进一步提高数据压缩的效率和精度。

#### 参考文献:

[1] Chen W J, Zhao G L. Key technologies and equipment of new power system with new energy as the main body [J]. *Global Energy Internet*, 2022, 5(1): 1. (in Chinese)

[2] Jia Y Q. Research on sequence and spatial data compression technology based on deep learning[D]. Harbin: Harbin Institute of Technology, 2021. (in Chinese)

[3] Chen S W, Gao C Y, Hu C. Adaptive waveform data compression based on similarity segmentation and resampling [J]. *Journal of Electronic Measurement and Instrumentation*, 2019, 33(4): 178-185. (in Chinese)

[4] Wang Y Z, Sun L Q. Application of data compression technology in ship power monitoring system [J]. *Journal of Shanghai Institute of Ship Transportation Science*, 2020, 43(1): 55-60. (in Chinese)

[5] Unterweger A, Engel D. Resumable load data compression in smart grids [J]. *IEEE Transactions on Smart Grid*, 2015, 6(2):

919-929.

[6] Chen Y, Wang Y L. Lossless data compression scheme of intelligent distribution network monitoring system [J]. *Guangdong Electric Power*, 2021, 34(5): 90-98. (in Chinese)

[7] Zhao H S, Feng J H, Ma L B. Data compression of distribution network infrared image monitoring based on tensor Tucker decomposition [J]. *Power System Technology*, 2021, 45(4): 1632-1639. (in Chinese)

[8] Ye J X. Research on image acquisition and reconstruction of power system based on compressed sensing[D]. Wuhan: Hubei University of Technology, 2020. (in Chinese)

[9] Zhao H S, Liu B C, Wang L J, et al. Blind super resolution method for infrared images of power equipment based on compressed sensing[J/OL]. *Power System Technology*, (2022-01-12) [2022-01-24]. (in Chinese)

[10] Zhao H H, Jiang Y, Lin R, et al. Research on acceleration and compression of transmission line inspection image detection model [J]. *Guangdong Electric Power*, 2020, 33(9): 123-128. (in Chinese)

[11] Wang Z H. Research on compressed sensing and reconstruction of electrical equipment images under the framework of deep learning[D]. Wuhan: Hubei University of Technology, 2021. (in Chinese)

[12] Peng J S, Sun L X, Wang L, et al. ED-YOLO electric power inspection UAV obstacle avoidance target detection algorithm based on model compression [J]. *Journal of Instrumentation*, 2021, 42(10): 161-170. (in Chinese)

[13] Tang N Y, Cai L, Zhu T, et al. Construction of image recognition model for power equipment based on deep learning [J]. *Automation and Instrumentation*, 2020(12): 54-57. (in Chinese)

[14] Wu Y F, Li F S, Yu T, et al. Power data compression and high-precision reconstruction based on residual dual attention mechanism network[J/OL]. *Power System Technology*, (2022-1-15)[2022-01-24]. (in Chinese)

[15] Zhang S Q, Yang F B, Wang X X. Ghost imaging optimization method based on autoencoding neural network [J]. *Electronic Measurement Technology*, 2021, 44(21): 77-83. (in Chinese)