

基于U-Net的变压器磁场云图预测方法

王艳阳¹, 金亮²

¹天津工业大学天津市电工电能新技术重点实验室, 天津

²河北工业大学省部共建电工装备可靠性与智能化国家重点实验室, 天津

收稿日期: 2022年4月7日; 录用日期: 2022年6月6日; 发布日期: 2022年6月13日

摘要

有限元分析和计算已成为电磁装置或系统性能计算的主要工具, 但由于传统有限元方法求解电磁场时面临建模复杂、计算资源消耗过大等问题, 本文采用了一种U型深度卷积神经网络(U-Net)的磁场云图预测模型。以变压器作为研究对象, 建立变压器电磁耦合有限元模型, 通过改变变压器的几何结构参数、材料和激励信息, 计算得到磁场云图作为神经网络训练的样本数据。为提高网络预测性能, 通过田口法对U-Net模型进行优化, 确定最优模型设置。将U-Net模型预测磁场云图与有限元计算结果对比, U-Net模型预测磁场云图中每个像素点的均方误差在0.3%~0.9%范围内, 能够很好地学习到变压器数据集之间的映射关系, 生成高分辨率的图像, 从而减少了计算时间, 对深度学习在预测磁场云图方向上有很大的实际意义。

关键词

传统有限元方法, 电磁场, U型深度卷积神经网络, 变压器

Transformer Magnetic Field Cloud Map Prediction Method Based on U-Net

Yanyang Wang¹, Liang Jin²

¹Tianjin Key Laboratory of Advanced Technology of Electrical Engineering and Energy, Tianjin Polytechnic University, Tianjin

²The State Key Laboratory of Reliability and Intelligence of Electrical Equipment Co-Constructed by Hebei University of Technology, Tianjin

Received: Apr. 7th, 2022; accepted: Jun. 6th, 2022; published: Jun. 13th, 2022

Abstract

Finite element analysis and calculation have become the main tools for the performance calcula-

tion of electromagnetic devices or systems. However, due to the complex modeling and excessive consumption of computing resources when solving electromagnetic fields by traditional finite element methods. This paper adopts a U-shaped deep convolutional neural network. Network magnetic field cloud map prediction model. Taking the transformer as the research object, the electromagnetic coupling finite element model of the transformer is established. By changing the geometric parameters, materials and excitation information of the transformer, the magnetic field cloud image is calculated as the sample data for neural network training. In order to improve the network prediction performance, the U-Net model is optimized by Taguchi method to determine the optimal model settings. Comparing the U-Net model's predicted magnetic field cloud map with the finite element calculation results, the U-Net model predicts that the mean square error of each pixel in the magnetic field cloud map is in the range of 0.3%~0.9%, which can well learn from the transformer data set. The mapping relationship between the two can generate high-resolution images, thereby reducing the calculation time, which is of great practical significance for deep learning in predicting the direction of the magnetic field cloud map.

Keywords

Traditional Finite Element Method, Electromagnetic Field, U-Shaped Deep Convolutional Neural Network, Transformer

Copyright © 2022 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

电力变压器作为电网中能量转换、传输的核心,其性能的优劣直接影响到电力系统运行的可靠性和经济性。由于变压器长期工作在复杂工况下,受线路条件、温度等因素影响,使变压器各个部件之间的相互作用加剧,很难找到设计参数与优化目标之间的相互映射关系。随着计算机的发展,电工装备的电磁综合性能分析主要通过有限元软件进行求解,通过仿真软件对电工装备进行建模与仿真,利用设计与性能参数之间的关系求得精确解。

传统的电磁场计算方法有时域有限差分法、有限元法、矩量法等[1],为了提高精度,计算时需要进行精细的网格剖分,导致计算量急剧增加、仿真时间过长和计算效率低等问题。随着人工智能的发展,近年来其在图像分类[2]、图像分割[3]和自然语言处理[4]等方面取得了很好的表现。深度学习通过学习数值模拟结果的历史特征实现数值模拟结果的预测与直接生成,可有效代替数值模拟用于细观变压器电磁场分布的分析与研究,极具发展潜力。尤其是卷积神经网络(Convolutional Neural Network, CNN)在图像处理和电气领域中得到了广泛的应用。文献[5]建立了贝叶斯和数据驱动预测方法的融合,提高了对电池剩余使用寿命的预测精度。文献[6]对图像中每个像素点产生一个预测结果,最终输出与输入图像大小相同的预测图,实现了全卷积神经网络(Fully Convolutional Network, FCN)在像素级预测任务上的端到端训练。文献[7]利用有限元方法生成样本数据,作为卷积神经网络的训练样本数据,通过改变不同几何结构来预测变压器磁场分布。文献[8]提出了一种基于条件生成对抗网络模型,其中生成模型和判别模型采用卷积神经网络,以负荷影响因素为输入对负荷数据进行预测。文献[9]采用卷积神经网络预测平面波照射下复杂几何形状散射的电磁场,对多通道端到端卷积神经网络进行改进,加入残差网络结构,加快收敛速度,优化了模型性能,平均相对误差为1.23%。文献[10]提出了一种自编码器结构的卷积神经网络预测

模型, 研究二维单组反应扩散系统, 将不同的仿真参数、边界条件、几何结构和时间作为卷积神经网络的输入, 能够直接预测时间序列的反应扩散系统的浓度分布。文献[11]将圆柱绕流涡激振动的物理模型与深度学习融合, 将物理模型矩阵化之后输入神经网络, 成功地预测了圆柱绕流流场。文献[12]提出了一种基于序列的模块化网络和端到端网络来快速准确地预测电机驱动效率图, 测试集的均方根误差值在 0.75%~1.5% 范围内。文献[13]提出一种深度卷积神经网络的方法, 用于预测锂离子电池的健康状态。文献[14]提出了卷积神经网络的电机轴承故障检测方法, 将 CNN 中的全连接层用卷积层代替, 降低了网络训练过程中的参数, 提高了模型的性能。文献[15]提出了一种卷积神经网络模型, 通过尾流中的速度分布预测圆柱体周围的压力分布。文献[16]提出基于多特征融合的卷积神经网络识别方法, 将植物图像灰度化和图像滤波预处理后, 利用局部二值模式和高斯函数分别对植物图像的局部纹理和边缘信息进行提取, 将提取到的浅层特征与深层特征融合后, 输入卷积神经网络中, 卷积核进一步对特征进行提取, 最大化池化层对特征进行降维, 保留了图像中的关键特征, 提升了特征的丰富性。

采用 U-Net 模型预测电磁装置或系统内磁场分布可以大幅度降低传统有限元对计算资源的需求和时间成本问题。本文以变压器作为研究对象, 在仿真软件中建立变压器二维仿真模型, 通过改变变压器几何结构参数、材料和激励条件, 计算得到磁场云图作为 U-Net 的样本数据。U-Net 模型通过卷积层进行特征提取, 反卷积对输入的特征图进行变换, 采用跳跃连接的方式将反卷积层提取的特征与卷积部分对应的特征进行级联并融合, 使反卷积层提取的结果直接学习卷积层提取到的变压器磁场信息, 实现高分辨的磁场生成, 因此本文对变压器的磁场特性研究具有重要的理论和实践意义。

2. 变压器模型的建立

以一个小型非晶合金单框卷铁芯的变压器作为研究对象, 通过在铁芯上绕制励磁绕组, 制成一个简易的非晶合金变压器样机, 如图 1 所示。变压器的结构和主要参数, 如图 2、表 1 所示。

Table 1. Transformer structural parameters
表 1. 变压器结构参数

标注	结构参数	数值
f	铁心高度/mm	135
d	铁心迭厚/mm	55
c	窗口高度/mm	85
b	窗口宽度/mm	40
f_0	激励频率/Hz	50
N	绕组匝数	60
a	铁心迭厚/mm	25
e	铁心宽度/mm	90
L_m	磁路长度/cm	21.4
A_c	铁心有效截面积/cm ²	12.24
g	重量/g	1882



Figure 1. Transformer prototype

图 1. 变压器样机




Figure 2. The structure of the transformer

图 2. 变压器的结构

3. U 型深度卷积神经网络

U 型深度卷积神经网络由 Ronneberger 等人在 2015 年提出, U-Net 网络结构是典型的编码 - 解码架构的神经网络, 如图 3 所示。U-Net 网络模型是 FCN 模型的改进和延伸, 能够使用较小数量的数据完成端到端的训练。具有多层堆叠结构的深度卷积神经网络在图像预测领域已经处于绝对主导地位。

3.1. 编码器

编码器使用 3×3 的卷积层提取变压器磁场特征, 随后使用池化核大小为 2×2 且滑动步长为 2 的 Max-pooling 对卷积层输出的特征图进行下采样, 使其尺寸减小一半。通过池化层, 可以实现对变压器特征更高层次的抽象表达。将上述操作不断重复, 通过卷积层逐步增大特征图的通道数量, 池化层逐步缩小特征图的尺寸。最后使用一个 3×3 的卷积层进一步提取变压器磁场信息。编码器最后两个卷积层之后还分别添加了一个 Dropout 层, 用于对模型进行正则化, 减少训练过程中网络参数的数量, 有效防止 U-Net 模型发生过拟合, 提高模型的泛化能力。

3.2. 解码器

U-Net 模型解码器部分, 首先采用卷积核大小为 2×2 且滑动步长为 2 的反卷积层, 对特征图进行上采样, 使输出的特征图尺寸增大为原来的 2 倍, 通道数量则减小为原来的一半。随后, 将反卷积层的上采样结果通过跳跃连接与编码器对应层级的特征图进行级联并有效融合, 可以使解码器直接学习编码器部分卷积层提取到的变压器磁场特征, 从而防止多次池化下采样使部分磁场特征丢失而影响磁场的预测精度。最后, 利用一个 3×3 卷积层对融合后的特征图进一步提取磁场信息, 在网络结构末端使用 1×1 的卷积层, 仅改变特征图的通道数量, 而不改变特征图的尺寸。末端的两个卷积层分别采用了 ReLU 激活函数和 Sigmoid 激活函数, 主要作用是对前面网络层提取到的输入信息进行整合。

综上所述, U-Net 模型能够有效提取和融合不同层级的特征, 通过跳跃连接将高级语义特征和低级空间信息进行融合, 修复在卷积层和池化层过程中丢失的图像细节信息, 提高图像预测的细腻度, 得到与输入图像同样大小的特征图。

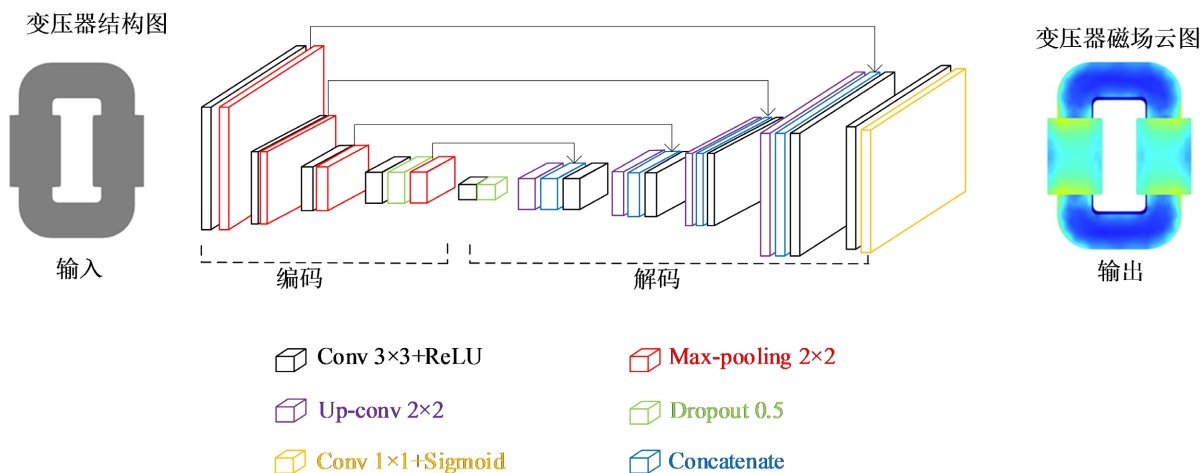


Figure 3. U-Net model structure

图 3. U-Net 模型结构

4. 计算实例

4.1. 数据采集

通过有限元仿真软件建立变压器的三维模型, 考虑到实际中绕组在缠绕到铁芯上时, 绕组与铁芯柱之间会存在气隙, 气隙的大小也会影响变压器磁场分布。因此, 选择铁芯柱与绕组之间气隙大小作为结构变量。通过改变变压器的几何结构变量, 如表 2 所示, 借助有限元分析进行参数化扫描, 在 XZ 平面上获得不同几何结构和参数设置的磁场云图, 作为神经网络训练和验证的样本数据。

Table 2. Transformer structure variable value

表 2. 变压器结构变量取值

结构参数(mm)	取值范围/mm	步长/mm
铁芯柱前后与绕组之间的间隙	0.2~0.5	0.02
铁芯柱左右与绕组之间的间隙	0.3~0.8	0.02

4.2. 数据预处理

为了保证网络训练时收敛加快, 提高模型性能, 需对 U-Net 模型训练前进行图像预处理工作, 消除无关信息, 突出图像特征。由于变压器磁场是 RGB 三通道彩色图像, 需转换为单通道图像, 并将像素值简单缩放归一化到[0, 1]区间, 公式为

$$\hat{x} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (1)$$

式中, x 为图像像素点值, x_{\max} 、 x_{\min} 分别为图像像素的最大与最小值。

在数据预处理之后, 需要对数据集进行划分, 如图 4 所示。图 4(a)为变压器的几何结构图, 图 4(b)为仿真计算后的磁场云图, 每一组数据集都是一一对应, 构成一组神经网络的样本数据。在工频条件下进行时域仿真, 获得变压器几何结构图和磁场云图共 500 组, 随机划分为训练数据集和测试数据集, 其中 400 组用于训练 U-Net 模型, 100 组用于测试 U-Net 预测模型的预测准确性和模型泛化能力。

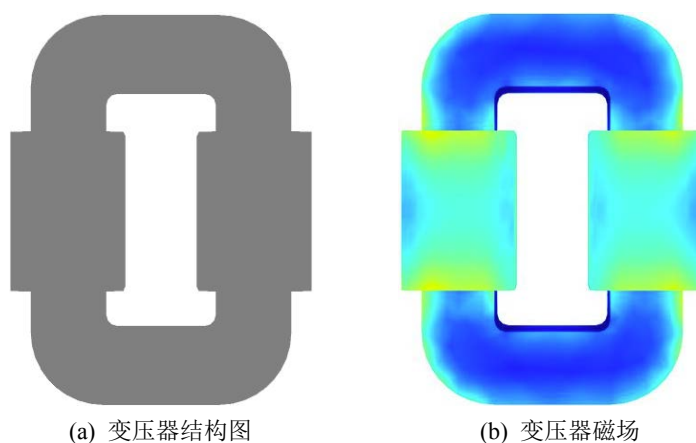


Figure 4. Sample data set of U-Net model
图 4. U-Net 模型的样本数据集

4.3. 评估指标

在预测实验进行对比分析的过程中, 采用均方误差(Mean Square Error, MSE)作为 U-Net 模型的性能指标来评估预测磁场分布的准确性, 其公式为

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^m (\hat{y}_i - y_i)^2 \quad (2)$$

式中, y_i 和 \hat{y}_i 分别为第 i 个样本的真实值和预测值, N 为样本个数。MSE 范围是[0, +∞), 用来衡量预测目标与实际目标之间的偏差, 偏差越小, 说明预测值与真实值越接近, 预测效果越好。

5. 计算结果及分析

5.1. U-Net 模型的超参数调优

根据 U-Net 模型的特点及相关文献, 筛选出对 U-Net 模型预测结果影响较大的 4 个超参数, 分别为训练次数(Epoch)、批处理大小(Batch-size)、Dropout 和学习率(Learning rate)。合适的超参数可以加快模型训练速度、减少训练时间和防止模型过拟合, 使预测精度提高。超参数变量取值, 如表 3 所示。

Table 3. Values of hyperparameter variables**表 3.** 超参数变量取值

模型参数	Epoch	Batch-size	Dropout	Learning rate
取值 1	100	1	0.1	2×10^{-2}
取值 2	150	2	0.3	5×10^{-3}
取值 3	200	4	0.5	2×10^{-4}

使用田口正交实验法对 U-Net 预测模型的 Epoch、Batch-size、Dropout 和 Learning rate 进行超参数调优。选定 $L_9(3^4)$ 正交表并建立实验矩阵, 其中 L 代表正交矩阵, 9 为试验编号, 3 为每个参数变量取值次数, 4 为优化参数数量。正交表及模型预测评估值, 如表 4 所示。

Table 4. Orthogonal table and model prediction result**表 4.** 正交表及模型预测结果

编号	Epoch	Batch-size	Dropout	Learning rate	MSE(%)
1	1	1	1	1	0.62
2	1	2	2	2	0.54
3	1	3	3	3	0.32
4	2	1	2	3	0.59
5	2	2	3	1	0.84
6	2	3	1	2	0.74
7	3	1	3	2	0.46
8	3	2	1	3	0.65
9	3	3	2	1	0.67

由表可知, 编号为 3 时, Epoch 为 100、Batch-size 为 4、Dropout 为 0.5、Learning rate 为 2×10^{-4} , U-Net 模型的预测性能最好。

5.2. U-Net 模型与有限元法性能比较

为了验证 U-Net 模型的性能, 通过随机选择 400 组样本作为训练数据来训练模型, Epoch 为 100, 训练结束时均方误差为收敛到 0.3%, 然后使用 100 组样本作为测试数据集来评估模型的性能, 经 U-Net 模型测试后, 实际值与预测值在每个像素点的均方误差在 0.3%~0.9% 范围内。从测试数据集中选择一组预测结果, 将 U-Net 模型预测的磁场云图与有限元计算结果进行对比, 如图 5 所示。

将有限元结果图与预测的磁场云图进行局部放大后, 如图 6 所示。从图中可以观察到 U-Net 模型在预测变压器磁场时, 在铁芯局部位置误差较高, 但 U-Net 模型中采用的跳跃连接方式将反卷积层提取的特征与卷积部分对应的特征进行级联并融合, 使反卷积层提取的结果直接学习卷积层提取到的变压器磁场信息, 弥补了在不断卷积和池化过程中丢失的细节信息, 因此整体预测磁场云图与有限元计算结果已经非常接近。结果表明, U-Net 模型能够很好地学习到变压器磁场云图数据集之间的映射关系, 生成高分辨率的图像, 在速度上大大优于有限元仿真计算, 极大地减少了计算时间。




Figure 5. Transformer magnetic field cloud map prediction results
图 5. 变压器磁场云图预测结果




Figure 6. Transformer magnetic field cloud map results comparison
图 6. 变压器磁场云图结果对比

6. 结论

本文采用了 U-Net 模型预测变压器的磁场云图, 通过改变变压器几何结构参数、材料和激励条件作为网络模型的输入, 输出变压器的磁场云图。将 U-Net 模型预测磁场云图与有限元仿真计算结果进行对比, 实际值与真实值在每个像素点的均方误差为 0.3%~0.9%范围内, 与有限元计算结果已经非常接近, 实现了变压器磁场云图的高精度预测, 同时降低了有限元的样本计算量和时间成本, 为复杂电工装备电磁性能分析提供了新的科学方法和思路。

参考文献

- [1] 金谋平, 张小林, 王泉. 电磁计算在雷达设计中的应用及需求分析[J]. 电波科学学报, 2020, 35(1): 135-140.

-
- [2] Russakovsky, O., Deng, J., Su, H., *et al.* (2014) ImageNet Large Scale Visual Recognition Challenge. *International Journal of Computer Vision*, **115**, 1-42.
- [3] Ibtehaz, N. and Rahman, M.-S. (2019) MultiResUNet: Rethinking the U-Net Architecture for Multimodal Biomedical Image Segmentation. *Neural Networks*, **121**, 74-87. <https://doi.org/10.1016/j.neunet.2019.08.025>
- [4] 余同瑞, 金冉, 韩晓臻, 等. 自然语言处理预训练模型的研究综述[J]. 计算机工程与应用, 2020, 23(56): 18-28.
- [5] Liao, L. and Ttig Felix, K. (2016) A Hybrid Framework Combining Data-Driven and Model-Based Methods for System Remaining Useful Life Prediction. *Applied Soft Computing*, **44**, 191-199. <https://doi.org/10.1016/j.asoc.2016.03.013>
- [6] Long, J., Shelhamer, E. and Darrell, T. (2015) Fully Convolutional Networks for Semantic Segmentation. 2015 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Boston, 7-12 June 2015, 3431-3440. <https://doi.org/10.1109/CVPR.2015.7298965>
- [7] Khan, A., Ghorbanian, V. and Lowther, D. (2019) Deep Learning for Magnetic Field Estimation. *IEEE Transactions on Magnetics*, **55**, 1-4. <https://doi.org/10.1109/TMAG.2019.2899304>
- [8] 林珊, 王红, 齐林海, 等. 基于条件生成对抗网络的短期负荷预测[J]. 电力系统自动化, 2021, 45(11): 52-60.
- [9] Qi, S., Wang, Y., Li, Y., *et al.* (2020) Two-Dimensional Electromagnetic Solver Based on Deep Learning Technique. *IEEE Journal on Multiscale and Multiphysics Computational Techniques*, **5**, 83-88. <https://doi.org/10.1109/JMMCT.2020.2995811>
- [10] Li, A., Chen, R., Farimani, A.-B., *et al.* (2020) Reaction Diffusion System Prediction Based on Convolutional Neural Network. *Scientific Reports*, **10**, Article No. 3894. <https://doi.org/10.1038/s41598-020-60853-2>
- [11] 孟杨. 圆柱绕流及其涡激振动的物理模型与机器学习相结合方法研究[D]: [硕士学位论文]. 大连: 大连海事大学, 2020.
- [12] Khan, A., Mohammadi, M.-H., Ghorbanian, V., *et al.* (2020) Efficiency Map Prediction of Motor Drives Using Deep Learning. *IEEE Transactions on Magnetics*, **56**, 1-4. <https://doi.org/10.1109/TMAG.2019.2957162>
- [13] 李超然, 肖飞, 樊亚翔, 等. 基于卷积神经网络的锂离子电池 SOH 估算[J]. 电工技术学报, 2020, 35(19): 4107-4119.
- [14] 宫文峰, 陈辉, 张美玲, 等. 基于深度学习的电机轴承微小故障智能诊断方法[J]. 仪器仪表学报, 2020, 41(1): 198-208.
- [15] Ye, S., Zhang, Z., Song, X., *et al.* (2020) A Flow Feature Detection Method for Modeling Pressure Distribution around a Cylinder in Non-Uniform Flows by Using a Convolutional Neural Network. *Scientific Reports*, **10**, Article No. 4459. <https://doi.org/10.1038/s41598-020-61450-z>
- [16] 韩斌, 曾松伟. 基于多特征融合和卷积神经网络的植物叶片识别[J]. 计算机科学, 2021, 48(S1): 113-117.