

文章编号: 2095-4980(2025)03-0272-06

FCNN 提升电大尺寸目标优化设计中 RCS 计算速度

杨远鹏, 王文卓, 郑生全, 方重华*

(中国舰船研究设计中心 海洋装备电磁效应及安全全国重点实验室, 湖北 武汉 430064)

摘要: 为在电大尺寸目标降低雷达散射截面(RCS)的优化设计过程中提升计算目标 RCS 的速度, 采用启发式算法对电大尺寸目标进行低 RCS 优化设计时, 使用电磁仿真软件计算过的模型结果训练一个多层全连接神经网络(FCNN)。优化过程中, 当已计算的模型数量足以完成对神经网络的训练后, 使用训练好的神经网络改进电磁仿真计算。利用神经网络计算速度较电磁仿真更快的特点, 实现提升电大尺寸目标低 RCS 优化设计速度。在本文所选的电大尺寸模型和使用模拟退火法进行优化设计的条件下, 采用多层全连接神经网络改进电磁仿真计算, 使模型的低 RCS 优化设计速度有明显提升, 消耗时间从超过 300 h 缩减到约 140 h。

关键词: 全连接神经网络(FCNN); 雷达散射截面平均值; 数据集; 回归计算; 加速计算

中图分类号: TN95; O441.4

文献标志码: A

doi: 10.11805/TKYDA2023265

FCNN improving the speed of RCS calculation in the optimization design of electrically large size target

YANG Yuanpeng, WANG Wenzhuo, ZHENG Shengquan, FANG Chonghua*

(National Key Laboratory of Electromagnetic Effect and Security on Marine Equipment, China Ship Development and Design Center, Wuhan Hubei 430064, China)

Abstract: To increase the speed of calculating the Radar Cross Section(RCS) in the optimization design process for reducing the RCS of electrically large targets, a multi-layer Fully Connected Neural Network(FCNN) is trained using the results of models calculated by electromagnetic simulation software when employing heuristic algorithms for low-RCS optimization design of electrically large targets. During the optimization process, once the number of calculated models is sufficient to complete the training of the neural network, the trained neural network is employed to improve electromagnetic simulation calculations. Leveraging the faster computational speed of neural networks compared to electromagnetic simulations, the optimization design speed for low-RCS of electrically large targets is enhanced. Under the conditions of the electrically large target model selected in this paper and the optimization design using the simulated annealing method, the use of a multi-layer fully connected neural network to improve electromagnetic simulation calculations significantly increases the speed of low-RCS optimization design, reducing the required time from over 300 h to approximately 140 h.

Keywords: Fully Connected Neural Network(FCNN); mean radar scattering cross-sectional area; dataset; regressive calculation; accelerated computing

随着对计算电磁学的不断深入研究, 传统的电磁仿真和计算技术逐渐趋于完善, 一些新技术与计算电磁学中的传统电磁计算相结合的研究也得到了发展。随着对神经网络的研究不断深入, 利用神经网络对传统的电磁仿真计算方法进行改善, 成为具有巨大前景的一种研究方向。在求解泊松方程的问题上, SHAN T 等^[1]使用卷积神经网络以三维的静电问题为例进行了计算; 在前向散射问题上, GUO Rui 等^[2]的研究阐明了神经网络在改进体积分方程中迭代过程的可行性; 在吸收边界条件的计算问题上, YAO 等^[3]使用长短时记忆神经网络替换吸收边界。这些研究都体现了神经网络用于电磁仿真计算加速方面的巨大前景^[4], 证明了利用神经网络可改进电磁仿

收稿日期: 2023-09-17; 修回日期: 2023-11-07

*通信作者: 方重华 email: Scienc7research@skiff.com

真计算的部分过程的可行性。计算目标物体的雷达散射特性是计算电磁学中的重要研究方向，并具有巨大的应用价值^[5-11]。在神经网络可改进计算前向散射和后向散射的情况下，ZHANG等^[12]构建了Electromagnetic-FCNN(EM-FCNN)网络，使用超参数调整模型表面粗糙度控制神经网络的模型输入，并用神经网络替代仿真计算中的积分方程，实现高速散射场的计算。

EM-FCNN网络在计算RCS时，使用超参数控制出现最优解的概率，但不能直接给出最优的模型。在EM-FCNN的基础上，本文改进神经网络的输入方式，选择使用电大尺寸模型的网格数据而非点云的中心点，减少了超参数的使用，可直接得到优化后的模型。本文的研究目的是结合神经网络，提升使用启发式算法对某一电大尺寸目标进行低RCS优化设计的速度。对于电大尺寸目标的低RCS优化过程，使用启发式算法往往需要对模型进行多次计算。如果每次计算的模型差异较小，在硬件水平有限的情况下，利用神经网络可分布式、硬件要求低的优势^[13-15]，使用多层神经网络形成与传统方式不同的电磁仿真计算方法计算目标物体的RCS，可在保证一定的计算精确度的同时显著节省计算所需时间。本文选取一个电大尺寸的舰船缩比模型^[16]作为低RCS优化计算目标，利用Python-cst联合仿真程序建立所需的数据集，并训练了一个4层的全连接神经网络(FCNN)。使用该神经网络模型在经过一定量数据训练后，可较好地提升对本文选用的电大尺寸舰船缩比模型的低RCS优化的速度。

1 仿真模拟内容

对电大尺寸目标进行低RCS优化设计时，需对模型的细节部分进行反复调整，寻找平均RCS最小的模型。采用提升模型RCS值计算速度的方法缩短优化周期，将电大尺寸目标的优化过程分为两部分：采用启发式算法，先进行一部分常规的电磁仿真计算获取一定量数据，并将目标物体的模型数据作为输入，对应的RCS值作为输出训练神经网络；之后，将训练好的神经网络用于后续部分的模型RCS值的计算。

1.1 物理模型

目标模型为图1所示的引用自亚琛工业大学的一个电大尺寸的舰船缩比模型，该模型形状灵感来自真实巡逻艇的形状，可用于纯RCS测量和其他雷达相关的测量。模型总长度为600 mm，最宽处宽度为120 mm，高度最大值为254 mm。使用常用的商用电磁计算软件(Computer Simulation Technology, CST)微波工作室中的积分求解器进行基于多层快速多极子算法的电磁仿真计算。仿真计算RCS值的条件设定为：俯仰角 0° ；方位角 $0\sim 360^\circ$ ，步长为 1° ；频率选择典型X波段8~12 GHz中的一个代表单频点12 GHz，使用单站计算方式。仿真计算所用硬件为CPU：Intel(R) Core(TM) i7-12700H CPU@2.30 GHz；Memory：16 GB；GPU：None。




Fig.1 Ship reduction model with electric large size and its three-view drawing

图1 本文使用的电大尺寸舰船缩比模型及三视图

1.2 理论模型

目标物体的模型数据与其RCS值在确定了仿真条件后具有一一对应的关系，因此可使用神经网络，以模型数据为输入、RCS值为输出，将二者间的映射关系进行回归拟合。反向前馈(Back Propagation, BP)神经网络对于拟合非时域的离散数据间的回归关系具有较好的效果^[17-29]，而长短期记忆神经网络依赖数据集的时序特性^[30]，因此本文选择基于BP神经网络中的FCNN，用于拟合物理模型中面元数据与其对应的RCS值之间的关系。显然，在确定了模型和RCS值的计算方式后，模型的面元数据矩阵与储存其RCS值的矩阵间具有确定的映射关系。

选择舰船模型的上层建筑作为需要尽心优化设计的区域，每次优化时，只对上层建筑中的任一面元的端点，进行空间距离不超过10 mm的位移修改，所得的新目标物体视作与初始目标物体相似的目标模型。在优化次数少于400次时，使用传统的电磁仿真计算方法对获得的新目标物体进行电磁仿真计算，将每一次优化获得的目标物体的网格数据和对应的RCS值存入数据集，用于神经网络的训练。

构建一个多层 FCNN 改进传统的电磁仿真，计算目标物体的 RCS。图 2 为具有 3 层隐藏层的 FCNN 结构示意图，输入层中共有 1 083 个神经元对应面元矩阵；其中每层隐藏层都具有 1 024 个神经元；输出层则具有 360 个神经元对应于需要计算的 RCS 值。神经网络的输入数据为目标物体的网格数据，输出数据为目标物体的 RCS 值。本文只考虑单频点情况，频率不作为神经网络的输入数据进行训练，单个神经网络只针对固定频点下的目标物体进行计算。

表 1 为不同激活函数和隐藏层层数对损失函数的影响。根据表 1，本文选择使用的隐藏层层数及激活函数如表 2 所示，表 2 中第 1 列的 1~4 表示第 1 层到第 4 层。

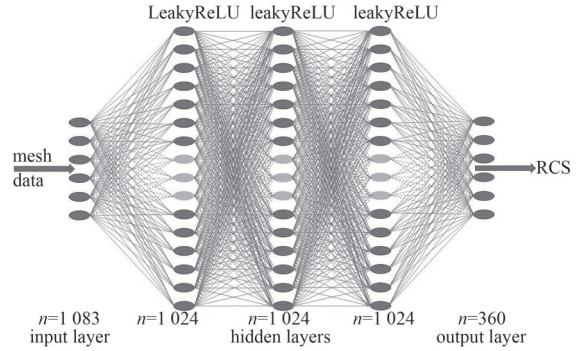


Fig.2 Schematic diagram of a fully connected neural network structure with three hidden layers

图 2 具有 3 层隐藏层的全连接神经网络结构示意图

表 1 不同激活函数和隐藏层层数对损失函数的影响

Table1 Influence of different activation functions and the number of hidden layers on the loss function

number of hidden layers	activation function	train loss/%
4	eLU	13.478 8
4	seLU	12.706 9
4	LeakyReLU	8.267 8
3	LeakyReLU	8.799 8
5	LeakyReLU	8.245 4

表 2 神经网络隐藏层神经元数量

Table2 The number of neurons in the hidden layer of the neural network

No.	number of neurons	activation function
1	1 024	LeakyReLU
2	1 024	LeakyReLU
3	1 024	LeakyReLU
4	1 024	LeakyReLU

2 仿真模拟结果

图 3(a)~(c)为分别使用 300 组、400 组、500 组模型数据作为输入，RCS 值作为输出数据对神经网络进行训练后，神经网络计算的目标物体 RCS 值与使用电磁仿真软件进行电磁仿真计算的 RCS 值对比图。从图 3(a)~(b)的对比可以看出，神经网络经过 400 组不同数据训练后，对于特定的模型可具有较好的计算能力；从图 3(b)~(c)的对比可以看出，神经网络的训练量从 400 增加至 500 提升不明显。




Fig.3 Comparison diagram of model RCS value calculated by simulation and by neural network

图 3 仿真计算与神经网络计算模型 RCS 值对比图

图 4 为神经网络计算的 RCS 值与电磁仿真计算的 RCS 值的差值条形统计图，从图中可以看出，误差呈正态分布的状态。通过图 3~图 4，不难看出经过训练的神经网络对于大体相似的电大尺寸目标，具有可接受的计算精确度。

图 5 为使用不同优化范围的数据集对神经网络进行训练后，神经网络的计算精确度的对比结果。图 5(a)采用从原始的数据集中筛选出面元端点位移距离小于 5 mm 的目标物体样本，并通过随机产生的新的符合面元端点位移距离小于 5 mm 的目标物体样本补充数据集，总量 400 个；图 5(b)采用优化设计过程中获取的面元端点位移距离最大变化范围为 10 mm 的数据集对全连接神经网络进行训练，经过训练后，均使用面元端点位移距离最大变化范围为 10 mm 的数据集中的测试集进行计算精确度的测试。从图 5 中可以看出，面元端点的位移距离改变后，训练神经网络不会产生明显的差异。




Fig.4 Model RCS difference distribution between the calculated value of neural network and of simulation
图 4 模型 RCS 值神经网络计算值与仿真计算值的差值分布柱形图




Fig.5 Comparison of the calculation effect of a neural network trained with different maximum variation data
图 5 使用不同最大变化量数据进行训练的神经网络计算效果对比

对于经过训练的神经网络，导入本文所使用的电大尺寸目标模型的面元数据进行一次计算所花费的时间少于 1 s，而对同一个模型使用商用电磁仿真软件进行计算则耗时约 20 min。因此在进行电大尺寸目标的低 RCS 优化过程中使用神经网络对电磁仿真计算进行改进，配合使用启发式算法进行最优化设计时，对目标物体的计算次数超过 400 次后，采用神经网络改进电磁仿真计算，能够明显提升计算速度。表 3 列出了使用传统的电磁仿真计算配合启发式算法进行优化和使用神经网络改进电磁仿真计算配合启发式算法进行优化的耗时对比。

由表 3 可知，计算总次数的量越大，使用神经网络改进电磁仿真计算的优势越明显。在使用模拟退火法进行优化时，本文所选的待优化目标所需的总计算次数为 1 000 次。本文使用全连接神经网络对电大尺寸目标在低 RCS 优化设计过程中的 RCS 值的计算进行加速，可使整个优化过程的耗时由 333.3 h 缩减到约 140 h。通过在电大尺寸目标的低 RCS 优化设计过程中使用全连接神经网络，可节省优化设计过程中计算目标 RCS 所需时间。

表 3 电磁仿真计算与神经网络改进电磁仿真计算消耗时间对比

Table3 Comparison of time consumption between EM simulation calculation and neural network improved calculation

	only simulation	simulation and neural network
simulation times	1 000	400
neural network calculation times	0	600
aggregate calculation times	1 000	1 000
training time/h	0	6
simulation time/h	333.3	133.3
neural network calculation time/h	0	0.2
aggregate calculation time/h	333.3	139.5

因此，FCNN 用于对传统的电磁仿真计算进行改进，在需要对相似的模型进行大量重复计算时具有广阔的应用前景。

3 结论

本文提出的使用 FCNN 提高电大尺寸目标在优化设计过程中的 RCS 计算速度的方法, 只能针对特定目标的优化设计任务。当更待优化设计目标时, 需重新使用传统的电磁仿真计算方法积累数据重新训练合适的神经网络。与传统的电磁仿真计算相比, FCNN 所需的硬件条件明显降低, 计算速度显著提高。在使用启发式算法低 RCS 值的目标优化工作中, 使用神经网络改进电磁仿真计算可显著提高计算效率, 便于下一步工作。

参考文献:

- [1] SHAN Tao,DANG Xunwang,LI Maokun,et al. Study on a 3D Possion's equation solver based on deep learning technique[C]// 2018 IEEE International Conference on Computational Electromagnetics(ICCEM). Chengdu, China: IEEE, 2018: 1–3. doi:10.1109/COMPEN.2018.8496657.
- [2] GUO Rui,SHAN Tao,SONG Xiaoqian,et al. Physics embedded deep neural network for solving volume integral equation:2–D case[J]. IEEE Transactions on Antennas and Propagation, 2022,70(8):6135–6147. doi:10.1109/TAP.2021.3070152.
- [3] YAO Heming,JIANG Lijun. Enhanced PML based on the long short term memory network for the FDTD method[J]. IEEE Access, 2020(8):21028–21035. doi:10.1109/ACCESS.2020.2969569.
- [4] LI Shuangyang,LAI Shengjian.LIU Jinhao,et al. A MLP based FDTD method[J]. Journal of Computer and Communications, 2021,8(12):279–284. doi:10.4236/jcc.2020.812022.
- [5] CHEN Yanjun,CHENG Zhigang,WU Jie,et al. Characteristic analysis for dual–induction logging response in highly deviated wells and horizontal wells[C]// 2016 Progress in Electromagnetic Research Symposium(PIERS). Shanghai, China: IEEE, 2016: 3359–3363. doi:10.1109/PIERS.2016.7735316.
- [6] CHEN Yanjun,PAN Quan,WANG Quan,et al. A method of multi–target tracking based on information utility in wireless sensor networks[J]. Computer Simulation, 2009,26(7):149–153.
- [7] CHEN Yanjun,PAN Quan,YE Gangqiang,et al. Ant colony genetic routing algorithm for wireless sensor networks[J]. Journal of Hunan University Natural Sciences, 2009,36(7):46–51.
- [8] CHEN Yanjun,PAN Qinyi,LIANG Yan,et al. Decentralized collaborative self–organization algorithm based on information content[J]. Control Theory and Applications, 2011,28(10):1391–1398.
- [9] CHEN Yanjun,PAN Quan,LIANG Yan,et al. Adaptively dynamic collaborative self–organization algorithm based on IDSQ[J]. Control and Decision, 2011,26(3):393–396,401.
- [10] CHEN Yanjun,LIANG Xinhua,PAN Quan,et al. A particle filter track–before–detect algorithm based on two–stage measurement update[J]. Journal of Sensors and Actuators, 2015,28(1):115–120. doi:10.3969/j.issn.1004–1699.2015.01.020.
- [11] CHEN Yanjun.PAN Quan,WANG Zheng. Performance optimization and simulation based on target tracking in wireless sensor networks[J]. Journal of Sensors and Actuators, 2015,28(4):544–550. doi:10.3969/j.issn.1004–1699.2015.04.016.
- [12] ZHANG Xu,WAN Jianxin,LIU Zhouyang,et al. RCS optimization of surface geometry with physics inspired neural networks[J]. IEEE Journal on Multiscale and Multiphysics Computational Techniques, 2022(7):126–134. doi:10.1109/JMMCT.2022.3181606.
- [13] WEI Zhun,CHEN Xudong. Physics–inspired convolutional neural network for solving full–wave inverse scattering problems[J]. IEEE Transactions on Antennas and Propagation, 2019,67(9):6138–6148. doi:10.1109/TAP.2019.2922779.
- [14] 潘光松. 基于深度学习的雷达低空小目标自动识别技术研究[D]. 成都:电子科技大学, 2022. (PAN Guangsong. Research on automatic recognition technology of radar low–altitude small target based on deep learning[D]. Chengdu, China: University of Electronic Science and Technology of China, 2022.) doi:10.27005/d.cnki.gdzku.2022.000201.
- [15] MASSA A,MARCANTONIO D,CHEN X D,et al. DNNs as applied to electromagnetics, antennas, and propagation—a review[J]. IEEE Antennas and Wireless Propagation Letters, 2019,18(11):2225–2229. doi:10.1109/LAWP.2019.2916369.
- [16] IHF–Boat. A measurement standard for polarimetric RCS imaging[S/OL]. (2013–07–09). <https://www.ihf.rwth-aachen.de/en/research/research-topics/further-research-topics/rcs-measurements/ihf-boat>.
- [17] XU Kuiwen,WU Liang,YE Xiuzhu,et al. Deep learning–based inversion methods for solving inverse scattering problems with phaseless data[J]. IEEE Transactions on Antennas and Propagation, 2020,68(11):7457–7470. doi:10.1109/TAP.2020.2998171.
- [18] HUGHES T W,WILLIAMSON I A D,MINKOV M,et al. Wave physics as an analog recurrent neural network[J]. Science Advances, 2019,5(12):eaay6946. doi:10.1126/sciadv.aay6946.
- [19] WANG Yuanchao,LI Mingtao,PAN Zhichen,et al. Pulsar candidate classification with deep convolutional neural networks[J]. Research in Astronomy and Astrophysics, 2019,19(9):119–128. doi:10.1088/1674–4527/19/9/133.
- [20] ALEJANDRO P,ALVARO S,IVAN G,et al. Fast computation by MLFMM–FFT with NURBS in large volumetric dielectric

- structures[J]. Electronics, 2021,10(13):1560. doi:10.3390/electronics10131560.
- [21] YUN S,HAN D,CHUN S,et al. CutMix:regularization strategy to train strong classifiers with localizable features[C]// 2019 IEEE/CVF International Conference on Computer Vision(ICCV). Seoul,Korea:IEEE, 2019:6022–6031. doi:10.1109/ICCV.2019.00612.
- [22] CHOE J, LEE S, SHIM H. Attention-based dropout layer for weakly supervised single object localization and semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 43(12): 4256–4271. doi: 10.1109/TPAMI.2020.2999099.
- [23] CHOE J,SHIM H. Attention-based dropout layer for weakly supervised object localization[C]// 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). Long Beach,CA,USA:IEEE, 2019:2214–2223.
- [24] DONG Xuanyi,ZHENG Liang,MA Fan,et al. Few-example object detection with model communication[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019,41(7):1641–1654. doi:10.1109/TPAMI.2018.2844853.
- [25] HAN Sheng, YANG Fan, JIANG Hui, et al. Statistical analysis of infrared thermogram for CNN-based electrical equipment identification methods[J]. Applied Artificial Intelligence, 2022,36(1):2004348. doi:10.1080/08839514.2021.2004348.
- [26] WANG X L,GIRSHICK R,GUPTA A,et al. Non-local neural networks[C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City,UT,USA:IEEE, 2018:7794–7803. doi:10.1109/CVPR.2018.00813.
- [27] YUAN Deran, XIE Xiaochun, GAO Gao, et al. Advances in hyperspectral image classification with a bottleneck attention mechanism based on 3D-FCNN model and imaging spectrometer sensor[J]. Journal of Sensors, 2022(1): 7587157-1–16. doi: 10.1155/2022/7587157.
- [28] 刘鑫尧,秋勇涛,皇甫雅帆,等. 基于星座图和卷积神经网络的射频指纹识别[J]. 太赫兹科学与电子信息学报, 2022,20(5): 458–463. (LIU Xinyao,QIU Yongtao, HUANGFU Yafan, et al. Radio frequency fingerprint identification based on constellation and convolutional neural network[J]. Journal of Terahertz Science and Electronic Information Technology, 2022,20(5):458–463.) doi:10.11805/TKYDA2020091.
- [29] MOHAMMED A A H, CHEN J. Retracted: cleanup sketched drawings: deep learning-based model[J]. Applied Bionics and Biomechanics, 2022(1):2238077. doi:10.1155/2023/9891841.
- [30] YANG Yuanpeng, SHI Xinyang, WANG Qingyao, et al. Enhancement of electromagnetic scattering computation acceleration using LSTM neural networks[J]. Electronics, 2023,12(18):3900. doi:10.3390/electronics12183900.

作者简介：

杨远鹏(1998–)，男，在读硕士研究生，主要研究方向为电大尺寸目标雷达散射特性研究。email:2535024883@qq.com.

王文卓(1992–)，男，硕士，工程师，主要研究方向为电磁屏蔽性能研究。

郑生全(1970–)，男，硕士，研究员，主要研究方向为强电磁脉冲耦合预测。

方重华(1980–)，男，博士，高级工程师，主要研究方向为水面目标雷达散射特性研究。