

文章编号: 1003-1480 (2024) 03-0022-08

神经网络算法在切割索侵彻性能预测中的应用研究

王友, 刘名兴, 尹鑫, 李柠芮, 庞强宏, 雷新宇, 胡强, 先明春

(四川航天川南火工技术有限公司, 四川 泸州, 646000)

摘要: 基于难以通过型面直接准确预测切割索侵彻性能, 以及神经网络算法大力发展的现状, 本文对神经网络算法在切割索侵彻性能预测领域的应用情况进行了综述。在对常用神经网络计算方法进行分析后, 重点对 BP 神经网络和卷积神经网络算法原理及其在切割索性能预测中的应用进行分析梳理和归纳总结, 系统性地对两种神经网络算法的数据集处理、网络搭建模型、参数设置和优缺点进行了剖析, 为切割索性能优化和智能化预测提供支撑。

关键词: 切割索; 侵彻性能; BP 神经网络; 卷积神经网络

中图分类号: TJ45⁺7 **文献标识码:** A **DOI:** 10.3969/j.issn.1003-1480.2024.03.004

Application of Neural Network Algorithm in Prediction of Linear Shaped Charge Penetration Performance

WANG You, LIU Ming-xing, YIN Xin, LI Ning-rui, PANG Qiang-hong, LEI Xin-yu, HU Qiang, XIAN Ming-chun

(Sichuan Aerospace Chuannan Pyrotechnics Technology Co. Ltd., Luzhou, 646000)

Abstract: Based on the status that it is difficult to predict the penetration performance of linear shaped charge directly and accurately through the profile, and the rapid development of neural network algorithm, in this paper, the application of neural network algorithm in the field of linear shaped charge penetration performance prediction was reviewed. After analyzing the common neural network calculation methods, the analysis and summary of the principle of BP neural network and convolutional neural network algorithm, and their application in performance prediction of linear shaped charge were focused on, and the data set processing, network modeling, parameter setting, advantages and disadvantages of the two neural network algorithms were systematically analyzed. The study provides supports for performance improvement and intelligent prediction of linear shaped charge.

Key words: Linear shaped charge; Penetration performance; BP neural network; Convolutional neural network

切割索属于线性分离装置, 其原理是利用聚能效应在高温高压作用下产生高速金属射流以完成对靶板的快速切割, 广泛应用于航空航天等领域, 如座舱盖破裂、级间分离、飞行器自毁系统、逃逸窗口切割分离系统等^[1-2]。上述领域的切割分离既要求切割索可靠地完成切割分离任务, 同时还要求避免线性分离装置工作时对附近的结构造成损毁, 因此对切割索的侵彻性能预测有极高的要求。国内外学者对切割索侵

问题进行了诸多研究, 刘宁等^[3]采用数值仿真和试验的手段研究了聚能切割索切割不同材料铝板的切割效果。杨红伟等^[4]基于 Autodyn 对内装药剂为黑索今的铜切割索侵彻性能差异进行了仿真分析和试验验证。董世康等^[5]采用数值仿真对切割索装药线密度、药型罩夹角、炸高等因素进行了优化。

由于受到型面结构、边界约束和切割对象力学性能等多方面因素影响, 目前国内外切割索侵彻性能预

收稿日期: 2023-11-09

作者简介: 王友 (1989-), 男, 高级工程师, 主要从事线性分离火工品、数值模拟、神经网络算法研究。

通讯作者: 先明春 (1982-), 男, 研究员, 主要从事航天火工技术研究。

引用本文: 王友, 刘名兴, 尹鑫, 等. 神经网络算法在切割索侵彻性能预测中的应用研究[J]. 火工品, 2024(3): 22-29.

测尚未有系统的分析方法,切割索侵彻性能难以运用解析法进行定量分析,多采用数值模拟方法进行研究^[6],但数值模拟方法存在计算时间长、结果不稳定、可靠性不高的问题。而神经网络算法不需要事先知道切割索关键参数同侵彻性能之间映射关系的数学方程,在已有的大量试验数据或者仿真数据基础上通过自身训练、学习内在规律形成特定算法,后续给定切割索型面或者设计参数后可以根据该算法迅速预测出切割索的侵彻性能。并且,通过神经网络算法预测切割索性能仅需数秒甚至更短,极大提升了切割索侵彻性能预测速度,非常适合切割索数字化、智能化发展。

目前在神经网络算法领域,应用到的算法主要包括 BP 神经网络、卷积神经网络、循环神经网络、径向基函数神经网络、生成对抗网络、物理信息神经网络、多模态融合神经网络等^[7]。本文对神经网络算法在切割索侵彻性能预测领域的应用进行研究,总结出适用于工程应用的神经网络算法,为切割索性能优化和智能化预测提供支撑。

1 面向切割索侵彻性能预测的神经网络算法

切割索具有开放性的设计型面,受成型工艺影响型面尺寸难以精确控制,因此并非所有的神经网络算法都适用于切割索侵彻性能预测。从切割索数据集来源、特征处理方式进行分析,BP 神经网络、卷积神经网络、物理信息神经网络、多模态融合神经网络等 4 种神经网络算法比较适用于切割索侵彻性能预测。

1.1 BP 神经网络

BP 神经网络是一种按照误差逆向传播算法训练的多层前馈神经网络,是应用最广泛的神经网络模型之一。从本质上看,BP 神经网络算法以网络误差平方为目标函数,通过梯度下降法进行迭代优化,求取极小值^[8]。

BP 神经网络起源于多层感知器 (Multi-Layer Perceptron, MLP),MLP 由多个节点层组成,每一层全连接到下一层。除了输入节点,每个节点都是一个

带有非线性激活函数的神经元^[8]。BP 神经网络一般由输入层、隐藏层和输出层组成,切割索性能预测的 BP 神经网络结构如图 1 所示^[9]。

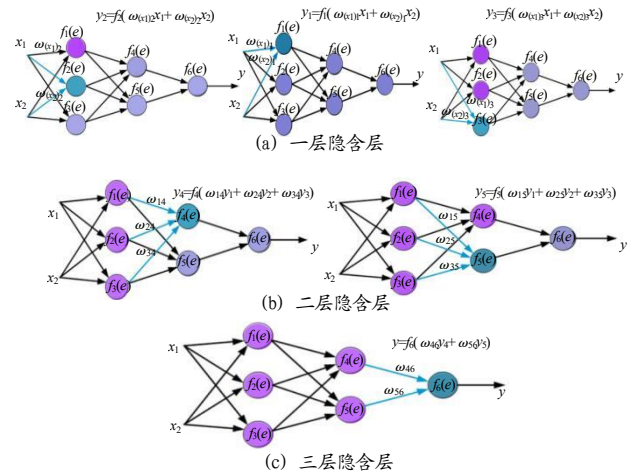


图 1 切割索性能预测 BP 神经网络结构图

Fig.1 BP neural network structure diagram for predicting the performance of linear shaped charge

图 1 为典型的 2-3-1 的 BP 神经网络结构,即输入为 2 个参数,输出为 1 个参数,隐含层为 3 层。其中 x_1 、 x_2 为输入层,即自变量,在切割索性能预测模型中为已知的切割索物理模型参数,如聚能夹角、聚能壁厚、药量等。 y 为输出层,即因变量,在切割索性能预测模型中为侵彻深度。 $f_1(e)$ 、 $f_2(e)$ 和 $f_3(e)$ 为一层隐含层节点, $f_4(e)$ 和 $f_5(e)$ 为二层隐含层节点, $f_6(e)$ 为三层隐含层节点, $\omega_{(x1)1}$ 、 $\omega_{(x2)1}$ 、 $\omega_{(x1)2}$ 等为连接权值。通过隐含层建立输出层和输入层的联系,隐含层激活函数可采用 Sigmoid、Sign、Liner、Unit step、Hyperbolic tangent 等多种函数。若 BP 神经网络模型预测误差大于设定的误差阈值,则将误差值反馈至隐含层,更新隐含层连接权值后重新计算,直至预测误差小于设计的误差阈值。

1.2 卷积神经网络

卷积神经网络具有表征学习能力,是在 BP 神经网络基础上发展而来的一种深度学习模型。切割索卷积神经网络在传统的神经网络中添加了卷积层与池化层,即由输入层、卷积层、池化层、全连接层和输出层组成^[10-11],切割索性能预测的卷积神经网络如图 2 所示。

在切割索性能预测卷积神经网络中,输入为切割索实物型面的二维平面特征或者三维立体特征,通过

卷积层与池化层交叉处理的方式提取空间特征，再将特征图拉伸为一维特征向量，最后输入到全连接神经网络中进行预测。卷积层的主要作用为提取切割索型面的原始数据特征，池化层的作用是在保留数据特征的基础上降低特征维度，从而减少运算量，提高运算效率。




图 2 切割索性能预测卷积神经网络结构图

Fig.2 Convolutional neural network structure diagram for predicting the performance of linear shaped charge

切割索性能预测卷积神经网络是一种对切割索截面几何数据进行空间特征提取来预测侵彻深度的方法，技术路线如图 3 所示。

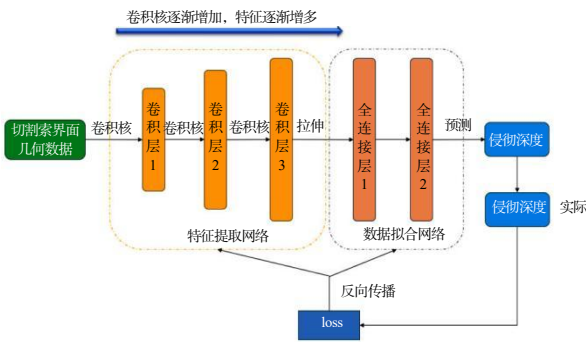


图 3 切割索性能预测卷积神经网络技术路线图

Fig.3 Technical roadmap of convolutional neural networks for predicting the performance of linear shaped charge

首先将截面的扫描数据重组为矩阵形式，然后通过多层卷积和池化处理，逐步提取截面的空间特征，最后采用全连接层来拟合空间特征与侵彻深度的数据映射关系。当网络模型预测出侵彻深度后，采用预测值与真实值的误差损失作为神经网络的损失函数，再将计算得到的损失反向传播到神经网络以更新网络权重，使得网络模型的预测精度逐步提高。

1.3 物理信息神经网络

物理信息神经网络在传统神经网络的基础之上加入了物理信息方程约束，使得神经网络的预测符合方程所描述的物理规律，极大地提高了神经网络预测的精度与泛化性^[12]。在切割索性能预测物理信息神经网络中，需由神经网络自动微分计算出输出变量对

输入变量的偏导数，利用偏导数计算预测结果是否符合物理方程，从而得到物理方程损失。物理方程损失加上原有的数据损失组成了神经网络的总损失，通过总损失来更新神经网络的权重，直至最终预测结果符合物理方程的描述^[13]，如图 4 所示。

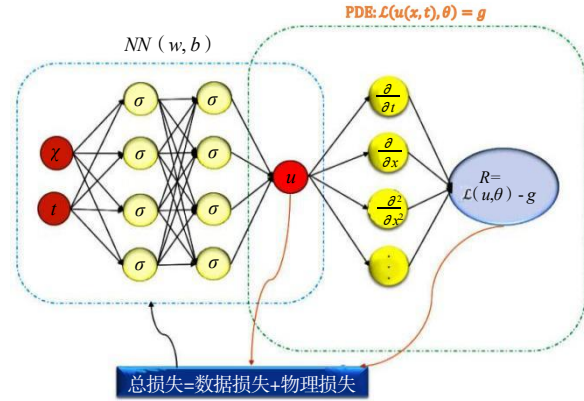


图 4 物理信息神经网络结构图

Fig.4 Physical information neural network structure diagram

切割索性能预测物理信息神经网络是一种提取聚能射流参数特征来预测侵彻深度的方法，具体如图 5 所示。

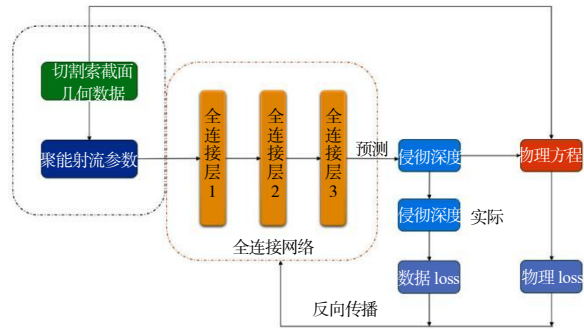


图 5 物理信息神经网络技术路线图

Fig.5 Physical information neural network technology roadmap

首先，对切割索进行聚能射流仿真以获取聚能射流的参数特征，然后，以聚能射流参数为输入建立聚能射流参数与侵彻深度的网络预测模型，最后，将聚能射流参数与侵彻深度的物理方程加入神经网络的约束当中，使预测结果符合物理规律，提高神经网络的预测精度。物理信息神经网络将物理方程的损失加入到网络模型的损失中，与数据损失一起进行反向传播迭代来优化网络权重，逐步提高网络模型的预测精度。

1.4 多模态融合神经网络

不同的存在形式或者信息来源可以称之为一种

模态，由多种模态组成的数据称之为多模态数据^[14]。多模态融合神经网络的输入层具有3种形式：单变量、序列变量和矩阵变量，针对不同的输入层设计不同的神经网络结构，对各变量的输入特征进行处理，最后得到一个综合的预测结果，如图6所示。

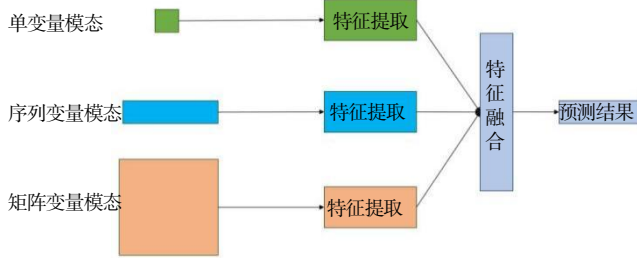


图6 多模态融合神经网络结构图

Fig.6 Structure diagram of multimodal fusion neural network

切割索侵彻性能预测多模态融合神经网络是一种融合空间特征与机理特征来预测侵彻深度的方法，如图7所示。首先，对切割索进行聚能射流仿真以获取聚能射流参数的机理特征，然后，对切割索截面的空间特征进行提取，最后，将所提取的空间特征与机理特征进行特征融合从而预测出侵彻深度。

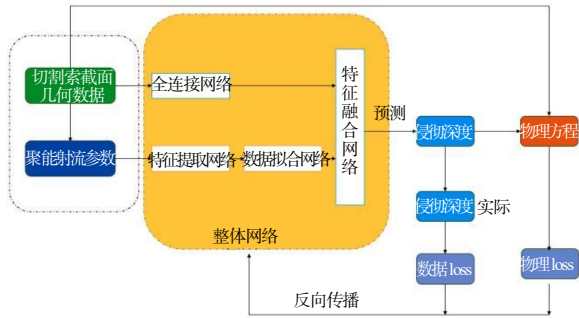


图7 多模态融合神经网络技术路线图

Fig.7 Roadmap of multimodal fusion neural network technology

2 基于神经网络的切割索侵彻性能预测算法设计

物理信息神经网络的构建需要物理信息约束方程，目前切割索侵彻模型尚无统一的物理信息约束方程，而采用有限元法的控制方程又过于复杂，因此难以构建物理信息神经网络算法和多模态融合神经网络算法。BP神经网络算法自适应强，训练简单，适用于输入层参数确定的参数化设计模型性能预测；卷积神经网络算法可以处理切割索实物型面特征，并通过卷积和池化减少特征维度，适用于切割索实物性能

预测。

2.1 BP神经网络算法设计

2.1.1 数据集处理

切割索侵彻靶板模型主要由黑索今、药型罩和靶板构成，典型的切割索设计模型如图8所示。




图8 切割索侵彻模型图

Fig.8 Model diagram of linear shaped charge penetration

图8展示了切割索侵彻靶板模型的主要参数，图8中O为切割索聚能夹角；B为切割索宽度；L为切割索总高度；L1为聚能顶角厚度；L2为药芯厚度；H为炸高。神经网络预测模型拓扑结构如图9所示。




图9 BP神经网络预测模型拓扑结构图

Fig.9 Topological structure diagram of BP neural network prediction mode

除型面几何尺寸外，工程实际应用上还需考虑黑索今体密度 ρ_1 、线密度 ρ_2 、靶板抗拉强度 σ_b 、延伸率 γ 等材料的固有属性。由于切割索成型工艺限制，很难精确地控制各项参数从而获得大量可以表征所有物理参量的试验数据，本文神经网络模型数据集取自有限元计算结果。

2.1.2 网络搭建

BP神经网络搭建包括隐含层输出计算、输出层输出计算、计算网络预测误差、更新权值进行迭代计算等步骤^[15]。

首先根据输入层变量 $X = (X_1, X_2, \dots, X_n)$ 和输出层变量 $Y = (Y_1, Y_2, \dots, Y_m)$ ，确定网络输入层节点数 n 、隐含层节点数 l 、输出层节点数 m 。然后根据输入层变量 X ，输入层和隐含层间连接权值 ω_{ij} 以及隐含层阈值 a ，计算隐含层输出 H 。

$$H_j = f\left(\sum_{i=1}^n \omega_{ij} x_i - a_j\right) \quad j = 1, 2, \dots, l \quad (1)$$

根据隐含层输出 H ，连接权值 ω_{jk} 和阈值 b ，计算 BP 神经网络输出 O ，再根据期望输出 Y 计算网络预测误差 e 。

$$O_k = \sum_{j=1}^l H_j \omega_{jk} - b_k \quad k = 1, 2, \dots, m \quad (2)$$

$$e_k = Y_k - O_k \quad k = 1, 2, \dots, m \quad (3)$$

最后根据网络预测误差 e 更新网络连接权值 ω_{ij} 。

$$\omega_{ij} = \omega_{ij} + \eta H_j (1 - H_j) x(i) \sum_{k=1}^m \omega_{jk} e_k$$

$$i = 1, 2, \dots, n; j = 1, 2, \dots, l \quad (4)$$

$$\omega_{jk} = \omega_{jk} + \eta H_j e_k$$

$$j = 1, 2, \dots, l; k = 1, 2, \dots, m \quad (5)$$

式 (4) ~ (5) 中： η 为学习速率，表征对连接权值的影响修正程度， η 越大对权值的修正越大。最终以预测误差是否达到精度要求来判断迭代算法是否终止，否则返回隐含层输出继续迭代计算。

2.1.3 参数设置

构建切割索 BP 神经网络，需确定输入层、隐含层和输出层的关系，隐含层节点数对 BP 神经网络预测精度有较大影响：节点数太少，BP 神经网络不能建立复杂的映射关系，网络不能很好地学习，需要增加训练次数，训练精度也受影响；节点数太多，训练时间增加，网络容易过拟合，即训练样本预测准确，但是其他样本预测误差较大。一般来讲，确定隐含层节点数可参考以下经验公式^[9]：

$$l < n - 1 \quad (6)$$

$$l < \sqrt{(m+n)} + a \quad (7)$$

$$l \approx \log_2 n \quad (8)$$

式 (6) ~ (8) 中： n 为输入层节点数，即切割

索物理参数的个数； m 为输出层节点数，本文中输出层参数为切割索侵彻深度； a 为 0 ~ 10 之间的常数； l 为隐含层节点数。在实际处理问题时由上述公式来确定 l 的大致范围，然后用试凑法来确定最佳的节点数。

以图 9 为例，若只考虑切割索自身型面参数，则输入层参数包括 O 、 B 、 L 、 L_1 、 L_2 共 5 个参数，即 $n = 5$ ，输出层节点数 $m = 1$ ，则隐含层推荐取值为 $l = 3$ ；若再考虑炸高 H 、体密度 ρ_1 、线密度 ρ_2 、靶板抗拉强度 σ_b 、延伸率 γ 等 5 个参数，即 $n = 10$ ，输出层节点数 $m = 1$ ，则隐含层推荐取值为 $l = 4$ 。隐含层激活函数采用 Sigmoid，函数表达式为：

$$f(x) = \frac{1}{1 + e^{-x}} \quad (9)$$

对于大部分 BP 神经网络问题，预测误差随着隐含层节点数的增加呈现先减少后增加的趋势，因此节点数并不是越多越好。

2.1.4 算法验证

为检测 BP 神经网络预测模型的准确度，选取线密度为 2.7 ~ 4.5 g/m 的铅切割索侵彻 2A14-T6 靶板过程为研究对象，分别采用 BP 神经网络预测法、基于 ANSYS 的有限元分析法和切割索实物侵彻 3 种方法进行侵彻深度的预测和测量，对比结果见图 10。




图 10 预测结果对比图

Fig.10 Comparison of prediction results

从图 10 可以看出，BP 神经网络预测结果同有限元分析预测结果符合性较好，误差在 0.3% ~ 4.1%；对于样本 5，BP 神经网络预测结果同切割索实物侵彻结果误差较大，为 12.2%，其余样本符合性较好，误差在 1.6% ~ 4.8%。这是因为一方面分析数据样本过少，在局部陷入过拟合现象；另一方面实物侵彻数据受线密度波动、型面批次化差异、试验安装状态等影

响，且侵彻深度也有一定的测量误差。

2.1.5 优缺点分析

BP神经网络用于切割索性能预测领域具有以下优势：(1)网络具有良好的自适应性，能够根据不同任务和数据自适应调整权值和阈值，从而提高网络的准确性和泛化能力；(2)网络训练过程简单，容易实现和理解^[6]。但仍存在以下缺点：(1)学习速度慢，需要大量的试验数据或者仿真数据进行训练，如果数据过少或噪声过大，可能会出现过拟合现象；(2)BP神经网络缺乏解释性，且使用梯度下降算法，容易陷入局部最优解，无法达到全局最优解。因此，可引入一定的修正算法，使得BP神经网络更高效、可靠，在准确性和运算效率等方面获得更大提升。

2.2 卷积神经网络算法设计

2.2.1 数据集处理

与BP神经网络不同，卷积神经网络可以直接处理图像数据，利用卷积操作捕捉图像中的局部特征，通过多层卷积和池化操作逐步提取图像的高层次特征，并利用全连接层进行分类或回归预测^[7]。切割索典型实物图像见图11^[18]。




图11 切割索实物型面图

Fig.11 Physical profile drawing of linear shaped charge

以截面尺寸3 mm×3 mm的切割索为例，将切割索图样网格化，单元网格尺寸为0.1 mm×0.1 mm，形成30×30的网格图。切割索型面为二维平面特征，药型罩的轮廓曲线为核心特征，因此药型罩落在网格图中的区域值取1，其余区域为0，最终形成30×30的矩阵图，如图12所示。

在进行切割索图样网格化时需注意，网格大小应能保证可以识别到切割索最小尺寸特征，建议网格尺寸不大于产品实物的最小测量精度。如某切割索聚能顶角厚度为0.25 mm，则网格尺寸为0.01 mm×0.01 mm。




图12 切割索二维特征网格图

Fig.12 2D feature grid diagram of linear shaped charge

2.2.2 卷积处理

图12中的数据无法直接用于计算，需进行卷积处理以提取特征值。卷积本质上是一种数学运算，具体方法是在输入的数据上滑动卷积核，并计算卷积核与输入数据的重叠面积之间的点积，输出结果是表示卷积核对输入数据响应的特征图。卷积计算是卷积层中最基本的运算操作，卷积计算的参数包括输入、权重和偏置，其计算表达式如下^[9]：

$$y_{ij} = f(\sum_{i=1} \sum_{j=1} x_{ij}w_{ij} + b) \quad (10)$$

式(10)中： y_{ij} 为卷积操作的输出； x_{ij} 为卷积操作的输入； w_{ij} 为权重值； b 为偏置； f 为非线性激活函数，激活函数一般采用Sigmoid。

卷积处理是指按照公式(10)用卷积核依次对图12的网络特征图进行卷积运算，卷积核有3×3、5×5等多种尺寸。对于不同的问题，需进行初步运算以选取合适的卷积核数量、尺寸以及偏置大小，常见的卷积核示例如图13所示。

以图13(a)3×3的卷积核对图12的切割索二维特征网络图进行卷积处理，步长为3，得到10×10的一次卷积后网络特征示意图，如图14所示。




图13 卷积核

Fig.13 Convolutional kernel

0	0	0	1	1	3	0	0	0	0
0	0	0	2	1	0	3	0	0	0
0	0	2	1	0	0	2	1	0	0
0	1	2	0	0	0	0	3	0	0
1	2	0	1	1	3	0	0	3	0
2	1	0	2	1	0	3	0	0	3
3	0	1	2	0	0	2	1	0	3
3	0	2	1	0	0	0	3	0	3
3	1	2	0	0	0	0	2	1	3
3	2	1	0	0	0	0	0	3	2

图 14 一次卷积后网络特征示意图

Fig.14 Schematic diagram of network features after one convolution

每个卷积核可以提取出图像中的某一特征，可以通过调整卷积核的大小和数量来调整预测速度和精度。卷积处理可以很大程度上减少特征的数量，有效提取出图像中的局部特征，从而使模型具有一定的平移不变性。卷积层的参数包括卷积核的大小、深度和步长等，卷积核的大小决定了网络可以感知特征的大小，深度则决定了网络可以感知特征的种类，步长决定了特征图的尺寸大小^[20]。

2.2.3 池化处理

池化处理是通过聚集相邻神经元的输出来减少输入的空间维度的层，即进行参数降维。池化处理减少了后续层需要处理的信息，从而提高了网络的计算效率，有助于加快训练过程并提高网络的准确性^[20]。池化处理主要采用最大池化和最小池化两种方式，其数学模型如下：

$$\begin{aligned} y_{\max} &= \max(x_{11}, \dots, x_{ij}) \\ y_{\min} &= \min(x_{11}, \dots, x_{ij}) \end{aligned} \quad (11)$$

式(11)中： x_{ij} 为卷积处理后位于 (i, j) 位置的输入值。最大池化指的是取池化区域内的最大值构建新的网络特征图，最小池化指的是取池化区域内的最小值构建新的网络特征图。根据构建网络大小需选取不同的池化尺寸，如 2×2 、 4×4 等。对图14的网络特征示意图进行 2×2 区域最大池化，得到一次池化后网络特征示意图，如图15所示。

0	2	3	3	0
1	2	0	3	0
2	2	3	3	3
3	2	0	3	3
3	2	0	2	3

图 15 一次池化后网络特征示意图

Fig.15 Schematic diagram of network features after one pooling

2.2.4 全连接层与输出

全连接层获取卷积和池化后的输出特征，将特征降维为一维向量，即将图15中的 5×5 矩阵展开为25

$\times 1$ 的一维向量。经过一个或者多个全连接层的计算，最后由softmax函数实现特征分类，softmax实现“分类器”的效果是一种常用于分类任务的激活函数。

输入数据经过卷积、池化和全连接层后得到输出值，参照BP神经网络参数设置方法得到预测误差。最终以预测误差是否达到精度要求来判断迭代算法是否终止，如不满足要求，根据所求误差更新全连接层的连接权值后重新计算，直至小于设定阈值。

2.2.5 算法验证

为检测卷积神经网络预测模型的准确度，分别采用卷积神经网络预测法、基于ANSYS的有限元分析法和切割索实物侵彻3种方法进行侵彻深度的预测和测量，对比结果见图16。

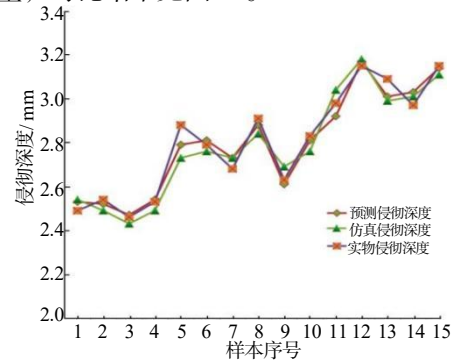


图 16 预测结果对比图

Fig.16 Comparison of prediction results

从图16可以看出，卷积神经网络预测结果同有限元分析预测结果、切割索实物侵彻结果的符合性均较好，误差在0.2%~4.5%，预测结果优于BP神经网络。这是因为BP神经网络数据集源于设计型面，卷积神经网络数据集源于实物型面，可以很大程度上避免过拟合现象和实物型面批次化差异导致的预测误差。

2.2.6 优缺点分析

卷积神经网络用于切割索性能预测领域具有以下优势：(1)可以直接基于切割索实物提取型面特征，具有很强的特征提取能力；(2)可以对图像等信息进行平移不变性处理，能够正确分类处理所有图像；(3)具有良好的模型泛化能力，能够适应各种各样的数据类型；(4)通过多层卷积和池化，减少了网络的空间大小，进一步减少网络的计算量。但仍存在以下缺点：

(1)同BP神经网络一样，缺乏解释性，训练速度较慢，需要大量计算资源；(2)对学习率、卷积核大小

和数量、网络层数等超参数的依赖性较强,需要大量的时间进行参数调整。实际工程运用中可以通过切割索型面分类训练避免以上缺点,即对不同类型的切割索建立不同的卷积神经网络,很大程度上减少训练量和参数调整时间。

3 结束语

本文系统介绍了神经网络算法在切割索性能预测领域的应用,从模型网络结构与技术途径等方面介绍了常用的神经网络算法,并对BP神经网络和卷积神经网络的算法设计进行了详细分析。

BP神经网络模型适用于输入层参数确定的参数化设计模型性能预测,如切割索型面优化,网络结构参数 n 推荐取值为5~8, m 推荐取值为1, l 推荐取值为3或者4。卷积神经网络算法模型可以直接识别切割索实物物理特征,通过多层卷积和池化后可以实现特征降维,适用于切割索实物性能预测。数据集处理网格推荐尺寸为 $0.01\text{ mm} \times 0.01\text{ mm}$,卷积核可选尺寸为 3×3 、 5×5 ,池化层推荐为最大或最小池化。

参考文献:

- [1] Smith F Z. Pyrotechnic shaped charge separation systems for aerospace vehicles[R]. NASA, TM X-1607, 1968.
- [2] 李志强. 火工装置在航天飞行器上应用[J]. 航天返回与遥感, 1997(2): 63-67.
- [3] 刘宁, 渠弘毅, 戈庆明, 等. 聚能切割索切割能力仿真及试验研究[J]. 导弹与航天运载技术, 2020(1): 38-42.
- [4] 杨红伟, 王友, 彭文彬. 铜切割索切割性能差异性分析[J]. 制导与引信, 2019, 40(1): 53-56.
- [5] 董世康, 胡芳友, 崔爱永, 等. 聚能射流侵彻飞机铝合金蒙皮的仿真与试验研究[J]. 振动与冲击, 2019, 38(4): 184-190.
- [6] 陈亚红, 李岩, 吴锦涛, 等. 切割索背向爆炸压力分布研究[J]. 宇航总体技术, 2022, 6(5): 34-39.
- [7] 黄红红, 张丰, 吕良福, 等. 神经网络算法在癫痫预测模型中的应用研究综述[J]. 计算机科学与探索, 2023(11): 1-17.
- [8] XU Xue-bin, QIN Hu, ZHOU Jie. Cyber intrusion detection based on a mutative scale chaotic bat algorithm with back propagation neural network[J/OL]. Security and Communication Networks, 2022:1-14.[2023-11-09]. <https://doi.org/10.1155/2022/5605404>.
- [9] 王小川, 史峰, 郁磊, 等. MATLAB神经网络43个案例分析[M]. 北京: 北京航空航天大学出版社, 2013.
- [10] Goodfellow, I., Bengio, Y., Courville, A. Deep learning (Vol. 1)[M]. Cambridge: MIT Press, 2016.
- [11] Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, L., Wang, G. and Cai, J., 2015. Recent advances in convolutional neural networks[J]. arXiv preprint arXiv: 1512.07108.
- [12] 冯唐思捷, 梁伟. 基于物理信息神经网络的薄壁结构屈曲分析[J]. 力学学报, 2023(11): 2 539-2 553.
- [13] 彭长志, 董旭柱, 阮江军, 等. 基于物理信息神经网络的短间隙流注放电模拟[J]. 高压电器, 2023, 59(9): 90-97.
- [14] 高伟, 汪悦, 宋春涛, 等. 基于多模态融合与图神经网络的用户精准感知系统研究[J]. 邮电设计技术, 2023, 568(6): 30-35.
- [15] 徐为海. 基于BP神经网络的镇江地区土层剪切波速预测[J]. 山西建筑, 2023, 49(18): 77-80.
- [16] 焦明之, 沈中丽, 周扬明, 等. 面向煤矿混合气体检测的神经网络算法研究进展[J]. 工矿自动化, 2023, 49(9): 115-121.
- [17] 刘晔. 基于卷积神经网络的轴承故障诊断及ZYNQ加速实现[D]. 盐城: 盐城工学院, 2023.
- [18] 王亚东. 基于有限元的某线性聚能切割装置失效分析[D]. 北京: 北京理工大学, 2015.
- [19] 杜元帅. 基于卷积神经网络的物体抓取检测研究[D]. 济南: 齐鲁工业大学, 2023.
- [20] 李建成. 基于卷积神经网络的滚动轴承故障诊断研究[D]. 大庆: 东北石油大学, 2023.