

# 基于自适应并联结构神经网络的 交通流量预测

杨启文, 李月, 吴君娜, 陈俊风, 薛云灿

(河海大学 信息学部, 江苏 常州 213022)

**摘要:** 由于现有优化算法在全局优化方面的局限性, 导致神经网络需要多次训练才能获得满意的结果; 为了解决神经网络训练中的一致性问题, 文章提出了一种自适应并联结构神经网络 (APSNN); APSNN 由多个神经网络单元并联组成, 在训练过程中, 采用常规优化算法对各神经网络单元进行训练; 神经网络单元的训练样本由上一级神经网络单元的训练残差构成, 通过训练残差在各神经网络单元中的单向传递, 实现训练残差的逐级减少; 神经网络根据训练残差, 决定是否进行神经网络单元级联和结构扩张, 从而保证训练结果的一致性; 文章对 5 种非线性函数进行了神经网络逼近测试。与 BP 神经网络相比较, APSNN 在 50 次不同初始条件下, 训练精度十分稳定, 具有很好的一致性; 为了实现对交通流量预测, 文章将 APSNN 与 BP 神经网络和小波神经网络进行了对比研究, 结果表明: APSNN 的预测总体标准差均小于 BP 神经网络和小波神经网络, 交通流量的预测偏差较 BP 神经网络和小波神经网络分别降低 2.7% 和 9.7%。

**关键词:** 人工神经; 网络训练; 残差自组织; BP

## Traffic Flow Prediction Based on Neural Network with Adaptive Parallel Structure

YANG Qiwen, LI Yue, WU Junna, CHEN Junfeng, XUE Yuncan

(Information Department, Hohai University, Changzhou 213022, China)

**Abstract:** Due to the limitations of existing optimization algorithms in global optimization, neural networks require multiple trainings to obtain satisfactory results. In order to solve the consistency problem of neural network training, this paper proposes an adaptive parallel structure neural network (APSNN). APSNN consists of multiple neural network units in parallel, and each neural network unit is trained using conventional optimization algorithms during the training process. The training samples of the neural network unit are composed of the training residuals of the previous neural network unit. Through the one-way transmission of training residuals among neural network units, the training residuals are gradually reduced. According to the training residuals, the neural network decides whether to cascade the neural network units and expand the structure, so as to ensure the consistency of the training results. The neural network approximation test is carried out on five nonlinear functions in this paper. Compared with BP neural network, APSNN has very stable training accuracy and good consistency under 50 different initial conditions. In order to realize the prediction of traffic flow, compared with BP neural network and wavelet neural network. The results show that the overall standard deviation of APSNN prediction is smaller than that of BP neural network and wavelet neural network, and the prediction deviation of traffic flow is 2.7% and 9.7% lower than that of BP neural network and wavelet neural network, respectively.

**Keywords:** artificial neural networks; training residual; self-organization; BP

## 0 引言

随着社会的高速发展, 城市交通流量持续增加, 交通拥堵已常态化<sup>[1]</sup>。为了缓解交通拥堵、提高车辆的通行效率, 实现交通智能化, 交通流量的预测显得尤为重要。

由于车辆通行的随机性和复杂性, 导致交通流量模型呈现具有极强的非线性特点, 因此, 通常采用利用非线性映射能力的人工神经网络 (简称为“神经网络”) 来建立交

通流量预测模型, 为智能交通提供决策依据<sup>[2]</sup>。例如, 蒋杰<sup>[3]</sup>、赖锦辉<sup>[4]</sup>等人分别采用蚁群算法和布谷鸟搜索算法来优化 BP 神经网络, 通过提高 BP 神经网络的逼近精度来建立更加精确的交通流量预测模型; Q. Chen, H. J. Yang 以及 W. Du 等人则分别利用粒子群算法<sup>[5]</sup>、遗传算法<sup>[6]</sup>、鲸鱼算法<sup>[7]</sup>来优化小波神经网络 (WNN, wavelet neural network), 建立交通流量预测模型; Dogan 通过长短时深度神经网络 (LSTM, long short-term memory networks) 来预

收稿日期: 2022-09-05; 修回日期: 2022-10-12。

作者简介: 杨启文 (1969-), 男, 湖北黄冈人, 博士, 副教授, 主要从事工业过程建模与控制、智能优化等方向的研究。

陈俊风 (1979-), 女, 江苏镇江人, 博士, 副教授, 主要从事计算智能、大数据分析方向的研究。

薛云灿 (1965-), 男, 江苏常州人, 博士, 教授, 主要从事工业过程建模、系统优化等方向的研究。

引用格式: 杨启文, 李月, 吴君娜, 等. 基于自适应并联结构神经网络的交通流量预测[J]. 计算机测量与控制, 2023, 31(4): 42-48.

测交通流量<sup>[8]</sup>; 在 LSTM 预测模型基础上, Lu 进一步利用 ARIMA 模型组合来提高预测效果<sup>[9]</sup>, 而 Jing 则融合时间卷积神经网络 (TCN, temporal convolutional network), 构建了一种混合神经网络的交通流量预测模型<sup>[10]</sup>。

应用神经网络时, 往往需要进行结构或参数优化, 即神经网络训练。通常采用的训练手段有: 采用试凑法<sup>[11]</sup>, 经验公式法<sup>[12]</sup>, 动态参数自调整法<sup>[13-14]</sup>, 模拟退火算法<sup>[15]</sup>和群智能优化算法<sup>[16]</sup>等方法来优化隐层节点数<sup>[17-18]</sup>; 采用梯度下降搜索法<sup>[19]</sup>、LM (Levenberg-marquardt) 算法<sup>[20]</sup>、层次耦合约束优化算法<sup>[21]</sup>、模拟退火法<sup>[22]</sup>、群智能优化算法<sup>[23-24]</sup>等方法来优化神经元之间的连接权。

但是, 在不同初始条件<sup>[25]</sup>下, 即使采用具有全局优化能力的群智能算法和组合算法, 也不能保证神经网络每次训练都能收敛到全局最优, 从而导致神经网络的训练结果出现了一致性问题<sup>[26-28]</sup>。

为了增强训练结果的一致性、降低训练次数, 提高工程应用的便利性, 本文提出一种自适应并联结构神经网络 (APSNN, adaptive parallel structure neural network), 旨在采用常规优化算法, 通过神经网络的自组织行为, 在训练中实现网络结构自适应和参数优化; 在满足训练精度前提下, 维持训练结果的一致性。同时, 利用 APSNN, 建立交通流量预测模型, 降低预测偏差, 提高预测的平稳性。

### 1 自适应并联结构神经网络

神经网络种类很多, 本文考察常见的前向神经网络。

多层前向神经网络如图 1 所示, 包括输入层、隐藏层和输出层, 除输入层和输出层只有一层外, 隐藏层可以是一层也可以是多层。




图 1 多层前向神经网络

多层前向神经网络, 常通过误差反传机制和梯度信息, 对神经元的连接权进行迭代优化, 这就是流行的误差反传学习算法, 简称 BP (back propagation) 算法, 对应的神经网络亦俗称为 BP 神经网络。BP 算法是一种确定性优化算法, 收敛速度快, 但由于采用单点、惯序的确定性优化模式, 不同的初始条件下会收敛到不同的局部极值。采用群智能优化算法训练神经网络时, 尽管群智能优化算法具有理论上的全局收敛能力, 但由于这类算法属于随机优化算法, 早熟收敛现象一直存在。

因此, 不论是确定性优化算法, 还是随机优化算法, 局部收敛或早熟收敛导致神经网络在不同初始条件下, 训练结果也不尽相同, 训练结果的一致性问题始终存在。

### 1.1 并联网络结构

为了能保持训练结果的一致性, 本文对常规的神经网络进行结构改进, 提出了一种由多个神经网络单元组成的并联网络结构。

如图 2 所示, 神经网络单元  $NN_k$  ( $k=1, 2, \dots, K$ ) 是由常规的前向神经网络 (如图 1 所示) 组成, 所有神经网络单元的输入端并联在一起, 各单元的输出相加后形成神经网络的输出。神经网络单元的级联数量, 在训练过程中, 通过自组织行为自适应确定。




图 2 并联神经网络结构

由于神经网络单元  $NN_k$  的非线性, 并联后的神经网络同样具备非线性特征, 理论上可以实现对任意非线性函数的高精度逼近。

对于如图 1 所示的常规神经网络而言, 只要给定输入和输出样本集  $\{\hat{x}, \hat{y}\}$ , 就可以利用 BP 算法或群智能优化算法进行神经网络训练。但是, 在如图 2 所示的并联结构的神经网络中, 由于有  $K$  个神经网络单元需要训练, 因此, 采用常规的 BP 算法, 需要为每个神经网络单元的提供独立的训练样本集  $\{\hat{x}, \hat{y}_k\}$ , 仅仅给出输入和输出样本集  $\{\hat{x}, \hat{y}\}$ , 无法完成所有并联神经网络单元的训练, 这是并联结构神经网络需要解决的问题。

### 1.2 自组织机制

为了能采用常规的 BP 算法对图 2 所示的并联神经网络进行训练, 实现训练结果的一致性要求, 对神经网络单元进行功能做如下定义。

定义: 后一级神经网络单元  $NN_{k+1}$  作为前一级神经网络单元  $NN_k$  的补偿单元, 在神经网络训练过程中, 对上一级神经网络单元的训练残差进行补偿。

根据上述功能定义, 设第  $k$  级神经网络单元  $NN_k$  的训练残差为  $e_k$ , 当训练残差  $e_k$  不满足精度要求时, 则并联一级神经网络单元  $NN_{k+1}$ , 并将  $\{\hat{x}, e_k\}$  作为神经网络单元  $NN_{k+1}$  的训练样本集。这样, 在神经网络单元的并联过程中, 训练残差将越来越小。当训练残差满足精度要求后, 神经网络的级联扩展结束, 神经网络结构的自适应优化过程停止。

按照上述自组织机制构建的并联神经网络, 只要神经网络单元的级联数不受限制, 理论上都可以满足训练的精度指标, 从而实现训练结果的一致性要求。

例如, 设输入样本为:

$$\hat{x} = \{1, 2, 3, 4\},$$

对应的输出样本为:

$$\hat{y} = \{1, 2, 3, 4\},$$

即输入输出训练样本集为：

$$\{\hat{x}, \hat{y}\} = \{(1, 1), (2, 2), (3, 3), (4, 4)\},$$

将输入输出训练样本集作为第一级神经网络单元  $NN_1$  的训练样本。若训练后的神经网络单元  $NN_1$  在输入样本  $\hat{x}$  作用下的输出为：

$$y_1 = \{0.9, 2.01, 3.05, 3.95\},$$

则第一级神经网络单元  $NN_1$  的训练残差定义为  $e_1 = \hat{y} - y_1$ ，即：

$$e_1 = \{0.1, -0.01, -0.05, 0.05\}.$$

利用训练残差  $e_1$ ，构造下一级神经网络单元  $NN_2$  的训练样本集：

$$\{\hat{x}, e_1\} = \{(1, 0.1), (2, -0.01), (3, -0.05), (4, 0.05)\}.$$

若训练后的神经网络单元  $NN_2$  在样本  $\hat{x}$  输入作用下，输出为：

$$y_2 = \{0.11, -0.011, -0.04, 0.06\},$$

则神经网络单元  $NN_2$  的训练残差为  $e_2 = e_1 - y_2$ ，即：

$$e_2 = \{-0.01, 0.001, -0.01, -0.01\}.$$

这样，神经网络单元  $NN_3$  的训练样本集为：

$$\{\hat{x}, e_2\} = \{(1, -0.01), (2, -0.001), (3, -0.01), (4, -0.01)\}.$$

依此类推，只要将输入输出训练样本集作为第一级神经网络单元的训练样本集，其余各级神经网络单元的训练样本集，均可利用上一级的训练残差进行构建，直到训练残差  $e_k$  满足精度要求为止。

APSNN 的样本构建流程及网络结构自适应流程图分别如图 3 和图 4 所示。




图 3 APSNN 样本构建流程

第一级 ( $k=1$ ) 神经网络单元  $NN_k$  采用输入输出样本集  $\{\hat{x}, \hat{y}\}$  进行训练，下一级神经网络单元  $NN_{k+1}$  是否并联到神经网络结构中，取决于上一级神经网络单元  $NN_k$  的训练残差  $e_k$  是否满足精度要求。下一级神经网络单元  $NN_{k+1}$  的训练样本集，由上一级神经网络单元的训练残差构建。因此，训练残差在神经网络单元的并联扩展过程中会逐级减小。这种自组织行为，不但提高了神经网络的逼近能力精度，而且在一定程度上降低了对优化算法的全局优化能力要求。这样，就无需花过多精力来优选神经网络单元的

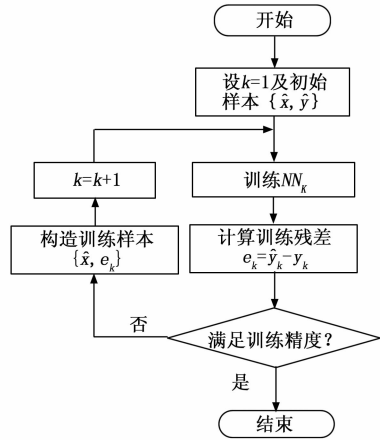


图 4 APSNN 自组织流程图

隐含层、隐节点数，为工程应用带来便利。

## 2 函数逼近测试

为了评价神经网络的训练性能，引入三项指标。

第一项指标是式 (1) 所示的逼近精度，即所有样本均方误差的对数：

$$J_K = \log_{10} \left[ \frac{1}{S} \sum_{i=1}^S e_K(i)^2 \right] \quad (1)$$

式中， $J_K$  为第  $K$  级神经网络单元  $NN_K$  的逼近精度， $S$  为样本数量， $e_K(i) = e_{K-1}(i) - y_K(i)$  为第  $i$  个样本的训练残差， $e_{K-1}(i)$  为神经网络单元  $NN_{K-1}$  第  $i$  个训练残差， $y(i)$  为第  $i$  个输入样本  $\hat{x}(i)$  的神经网络单元输出。

逼近精度的大小能够反映出神经网络的对函数的逼近程度，数值越小，逼近度越高。

第二项指标是式 (2) 所示的逼近精度的总体标准差：

$$\sigma_K = \sqrt{\frac{1}{M} \sum_{m=1}^M [J_K(m) - \bar{J}]^2} \quad (2)$$

式中， $M$  为实验次数， $J_K(m)$  为第  $m$  次实验的逼近精度， $\bar{J}$  为逼近精度均值。

总体标准差反映出数据集在其均值附近的聚集程度。总体标准差越小，说明数据越集中，一致性较好。但考虑到逼近精度  $J_K$  是训练残差的对数运算结果，因此，逼近精度  $J_K$  在不同数量级处的总体标准差，难以反映出训练残差的一致性。故总体标准差仅反映逼近精度在数学意义上的一致性。

第三项指标是达标率，即多次独立实验中满足逼近精度的比例。

达标率可以反映出神经网络在逼近精度及其一致性方面的综合性能。达标率越高，说明满足逼近精度的训练次数越多。从工程应用角度看，达标率越高，需要对神经网络重复训练的次數就越少。因此，达标率更能反映出训练残差在工程意义上的一致性。

### 2.1 函数逼近测试

选取 5 个非线性函数作为测试函数：

$$\begin{cases} f_1(x) = e^{-0.1x^2} \sin(0.5\pi x), & x \in [-6, 6] \\ f_2(x) = 1 + \sin(\pi x/3), & x \in [-5, 5] \\ f_3(x) = e^{-1.9x(x+1)} \sin(10x), & x \in [-0.5, 0.45] \\ f_4(x) = -x(x-1)(x-2)(x-3), & x \in [-2, 2] \\ f_5(x) = 10e^{-0.05(x+10)} \sin((0.03x+0.7)x), & x \in [0, 10] \end{cases} \quad (3)$$

采用 BP 神经网络和本文提出的 APSNN 对上述 5 个非线性函数进行逼近实验。

实验测试中, 设置  $J_K = -4$  作为达标率的精度阈值, 即: 当逼近精度小于  $-4$  时, 认为训练结果达标 (当逼近精度小于精度阈值时, 能够获得满意的逼近效果)。

为了简化 APSNN 中的神经网络单元, 各神经网络单元具有完全相同中间层数、隐节点数  $N$  和激活函数 (sigmoid 函数)。同时, 为了能在相同条件下比较两种神经网络的性能, BP 神经网络采用与 APSNN 完全相同的激活函数。两种神经网络均使用默认的 LM 算法进行训练, 且终止条件也完全相同。

APSNN 自组织规则如下:

- 1)  $J_K = -4$ ;
- 2) 或者并联一级神经网络单元后导致  $J_K$  增大;
- 3) 或者并联的神经网络单元数达到 5 个。

当满足上述 3 个条件中之一时, APSNN 自组织结束; 当上述 3 个条件均不满足时, APSNN 在原有的结构中, 自动并联一级神经网络单元, 实现结构扩张。

实验测试在 Matlab 平台 (软件版本 2018b) 上进行。BP 神经网络和 APSNN 中神经网络单元的训练终止条件均采用相同的默认条件, 且在所有实验测试过程中保持不变。APSNN 第一个神经网络单元的初始连接权与 BP 神经网络的初始连接权均为相同的随机数, 后续并联的神经网络单元连接权为随机数。

针对函数  $f_1(x)$ , 在区间  $[-6, 6]$  内, 按照步长 0.01 进行采样, 形成 121 个采样点的输入输出训练集。

图 5 为 BP 神经网络不同隐节点的 50 次独立训练结果。从逼近精度曲线上看, 逼近精度的均值随着隐节点数的增加而减小 (具体数据见表 1 实验结果)。




图 5 BP 神经网络的逼近精度

但是, 在 50 次独立训练中, 逼近精度值存在着较大的波动。例如  $N=3$  时, 近 50% 的值分布在  $[-1, 0]$  区间内, 40% 分布在  $[-1, -2]$  区间上, 还有 10% 分布在  $[-2, -3]$  区间中。当  $N=7$  时, 逼近精度的一致性有了明显的改善, 数据主要集中在  $[-7, -8]$  区间上 (共有 45 次), 只有 5 次实验结果分散在  $[-3, -6]$  区间上。因此从数据分布的聚集程度上看, 7 个隐节点神经网络训练结果的一致性较好。

表 1 函数  $f_1(x)$  的实验结果

N		3	4	5	6	7
前向神经网络	平均精度	-1.27	-2.62	-3.71	-4.16	-7.11
	总体标准差	0.58	1.55	0.96	1.68	0.99
	达标率/%	0.00	28.00	32.00	50.00	94.00
APSNN	平均精度	-2.47	-4.05	-4.45	-4.91	-7.15
	总体标准差	0.47	0.70	0.44	0.84	0.86
	达标率/%	0.00	54.00	90.00	90.00	100.00
	平均级联数	5.00	3.30	2.06	1.82	1.10

在表 1 所示的实验结果中, 尽管 3 个隐节点 BP 神经网络的总体标准差在数值上要小于 7 个隐节点 BP 神经网络, 但训练残差的均值处在不同数量级。从数据分布上看, 7 个隐节点 BP 神经网络仅有 5 次实验的数据分布“异常”; 另外, 从达标率指标上看, 7 个隐节点 BP 神经网络有 94% 的训练结果满足逼近精度指标要求, 可以被工程接受。因此, 采用达标率来衡量训练结果的一致性更具有工程上的合理性。

图 6 为 APSNN 在不同隐节点数 (此处指神经网络单元的隐节点数) 下 50 次独立训练结果。当  $N=3$  时, 逼近精度近 75% 集中在  $[-2, -3]$  之间, 明显高于 BP 神经网络。当神经网络单元的隐节点数  $N=7$  时, APSNN 与 BP 神经网络的逼近精度曲线非常相似。APSNN 尽管仍有 5 次逼近精度偏离  $[-7, -8]$  区间, 但逼近精度均小于  $-4$ , 而 BP 神经网络则有 3 次逼近精度值大于  $-4$ 。




图 6 APSNN 逼近精度

表 1 的数据对比表明, APSNN 在三项指标方面均优于 BP 神经网络。这种性能改善, 与神经网络单元的残差补偿

机制有着密切的关系。

图 7 是 APSNN 中神经网络单元级联数在 50 次独立实验中的变化情况。当神经网络单元的隐节点数为  $N=3$  时，由于逼近精度无法满足精度要求，根据自组织规则，在训练过程中会自动并联一级神经网络单元，直至并联数量达到上限 5 个。随着神经网络单元的隐节点数的增加，神经网络单元的逼近能力得到提升，需要并联的神经网络单元数越来越少。当神经网络单元的隐节点数为  $N=7$  时，只出现过两次 2 个神经网络单元并联的现象，其余 48 次训练由于达到了精度指标要求，因而只需要一级神经网络单元。此时 APSNN 差不多就退化为一个常规的 BP 神经网络，故二者在相同初始条件下，有 48 次训练结果完全相同。




图 7 APSNN 级联数

表 2~表 5 是 BP 神经网络和 APSNN 逼近函数  $f_2(x) \sim f_5(x)$  的实验结果 (实验样本的采样间隔均为 0.01)。

表 2 函数  $f_2(x)$  的实验结果

N		3	4	5	6	7
前向神经网络	平均精度	-2.25	-2.41	-5.66	-8.14	-7.43
	总体标准差	1.14	1.13	2.52	1.74	1.84
	达标率/%	2.00	0.00	56.00	100.00	98.00
APSNN	平均精度	-3.41	-3.93	-6.09	-8.14	-7.45
	总体标准差	0.58	0.69	2.15	1.74	1.81
	达标率/%	2.00	56.00	96.00	100.00	100.00
	平均级联数	4.88	4.08	1.90	1.00	1.02

表 3 函数  $f_3(x)$  的实验结果

N		3	4	5	6	7
前向神经网络	平均精度	-2.41	-3.64	-5.14	-5.92	-5.30
	总体标准差	1.08	0.84	1.71	2.25	1.30
	达标率/%	0.00	32.00	64.00	74.00	88.00
APSNN	平均精度	-3.67	-4.21	-5.40	-6.13	-5.38
	总体标准差	0.58	0.39	1.51	2.07	1.22
	达标率/%	34.00	78.00	100.00	100.00	98.00
	平均级联数	4.60	2.78	1.68	1.40	1.18

表 4 函数  $f_4(x)$  的实验结果

N		3	4	5	6	7
前向神经网络	平均精度	-2.41	-5.12	-5.36	-6.37	-5.82
	总体标准差	1.84	1.96	2.08	2.10	2.38
	达标率/%	22.00	68.00	72.00	84.00	72.00
APSNN	平均精度	-3.14	-5.36	-5.60	-6.52	-5.99
	总体标准差	1.54	1.63	1.71	1.82	2.16
	达标率/%	26.00	74.00	80.00	86.00	82.00
	平均级联数	3.98	2.10	2.04	1.62	1.80

表 5 函数  $f_5(x)$  的实验结果

N		3	4	5	6	7
前向神经网络	平均精度	-9.70	-9.42	-9.38	-9.51	-9.70
	总体标准差	0.73	0.55	0.47	1.10	1.13
	达标率/%	100.00	100.00	100.00	100.00	100.00
APSNN	平均精度	-9.70	-9.42	-9.38	-9.51	-9.70
	总体标准差	0.73	0.55	0.47	1.10	1.13
	达标率/%	100.00	100.00	100.00	100.00	100.00
	平均级联数	1.00	1.00	1.00	1.00	1.00

实验对比结果与函数  $f_1(x)$  非常相似，APSNN 在 3 项性能指标方面均优于常规的 BP 神经网络。在函数  $f_5(x)$  的实验结果中，当 APSNN 的神经网络单元级联数为 1，APSNN 就等同于常规的 BP 神经网络，二者性能完全相同。

在 APSNN 训练过程中，神经网络根据训练残差的精度要求，通过触发自组织规则，由小到大地搭建神经网络结构，从而实现网络结构的自适应优化。而常规的神经网络结构优化，通常是对神经网络的不同候选结构进行性能评估，从中“挑选”出最优性能指标的网络结构。从二者的不同之处可以看出，常规神经网络结构优化不可避免地对同一结构进行重复评估，而 APSNN 的自组织规则能同时进行参数和结构优化，避免了神经网络单元的冗余评估，降低了优化过程的计算量。

### 3 交通流量预测

为了验证 APSNN 在短时交通流量预测的有效性，APSNN 的神经网络单元采用常规的 BP 神经网络：一个隐藏层、隐节点数为 5，APSNN 级联数上限为 5。选择与文献 [28] 结构完全相同的 BP 神经网络和文献 [29] 结构完全相同的小波神经网络 (WNN) 进行性能对比。为了定量评价 3 种神经网络性能，本文除了采用平均预测精度  $\bar{J}$  以及平均总体标准差  $\bar{\sigma}$  之外，另外还引入一个评价指标：平均绝对百分误差 (MAPE)：

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{d(i) - p(i)}{d(i)} \right| \times 100\% \quad (4)$$

式中， $d(i)$  为真实流量数据， $p(i)$  为预测模型输出的预测数据。

考虑到交通流量与前一时刻的流量有关，本文采用前 4 个采样时刻的流量信息预测下一时刻的交通流量，因此，APSNN 输入层节点数设为 4，输出层节点数为 1。当训练

精度  $J \leq 5$  或者并联新的神经网络单元导致  $J$  增大时, 训练过程中的自组织行为停止, 训练结束。

选取美国明尼苏达州的明尼阿波利斯和圣保罗之间 94 号州际公路 2018 年 9 月 1~30 日的西行数据作为测试数据 (数据源: <https://archive.ics.uci.edu>)。前 25 天的 600 个监测数据 (每小时采集一次交通流量) 作为神经网络的训练样本集; 利用训练好的神经网络, 预测后 5 天的交通流量。

图 8 是 50 次独立测试的预测精度变化曲线。从图中曲线的可以看出, APSNN 和 BP 神经网络的预测精度相近, 大部分预测精度在 5.2 附近, 而 WNN 则在 5.5 附近波动。但是, APSNN 在 50 次独立测试中的预测精度相差不大, 一致性更好, 而 BP 和 WNN 则出现了较大的波动。




图 8 预测精度

为了能更直观地比较预测的一致性, 先计算单次实验中 120 个预测点的总体标准差, 作为每个预测时刻的一致性性能指标, 然后以这个总体标准差作为数据集, 计算 50 次实验中的总体标准差, 作为重复测试的一致性性能指标。

图 9 是 3 种神经网络的在 50 次实验中的总体标准差曲线。APSNN 和 BP 的总体标准差大部分在 400~500 附近, 而 WNN 在 600 附近波动。但 APSNN 在 50 次独立实验中的总体标准差非常平稳, 这意味着 APSNN 不但在重复测试中表现稳定, 而且在每个预测时刻的偏差也比较稳定。而 BP 次之, WNN 最差。




图 9 预测标准差

标。本文提出的 APSNN 在 3 项指标方面均表现优秀。在 MAPE 指标上, APSNN 较 BP 和 WNN 分别降低了 2.7% 和 9.7%。因此, 采用 APSNN 进行交通流量预测, 既能降低预测偏差, 又能保持预测的平稳性。

表 6 交通流量预测结果

神经网络	$\bar{J}$	$\bar{\sigma}$	MAPE
BP	5.421 8	575.118 3	14.949 8
WNN	5.549 0	630.777 8	21.891 1
APSNN	5.203 4	401.437 8	12.177 4

#### 4 结束语

由于现有优化算法的局限性, 神经网络的逼近精度和训练结果的一致性难以保证, 给工程应用带来了不便。本文提出了一种自适应并联结构的神经网络——APSNN。这种神经网络可以利用常规的优化算法, 对神经网络单元进行逐级训练。在训练过程中, 神经网络根据训练残差实现网络结构优化, 确保训练精度及其一致性。

APSNN 的自组织行为是通过神经网络单元的自适应并联扩展实现, 不是对单个神经网络的内部隐含层和隐节点进行增删, 这是本文与神经网络传统优化方案不同的地方。由于目前神经网络单元内部结构固定、隐节点数无法自适应, 这是 APSNN 的不足之处。探索神经网络单元的结构优化, 将是未来要解决的一个问题。

#### 参考文献:

- [1] 刘宜成, 李志鹏, 吕淳朴, 等. 基于动态时间调整的时空图卷积路网交通流量预测 [J]. 交通运输系统工程与信息, 2022, 22 (3): 147-157, 178.
- [2] 王秋平, 舒勤, 黄宏光. 含有误差校正的小波神经网络交通流量预测 [J]. 计算机测量与控制, 2016, 24 (2): 168-170, 181.
- [3] 蒋杰, 张江鑫. 改进 ACO 优化的 BP 神经网络短时交通流量预测 [J]. 计算机仿真, 2021, 38 (7): 97-101, 180.
- [4] 赖锦辉, 梁松. 基于 ACS 优化 BP 神经网络的交通流量短时预测方法 [J]. 计算机工程与应用, 2014 (10): 244-248.
- [5] CHEN Q, SONG Y, ZHAO J. Short-term traffic flow prediction based on improved wavelet neural network [J]. Neural Computing and Applications, 2021, 33 (14): 8181-8190.
- [6] YANG H J, HU X. Wavelet neural network with improved genetic algorithm for traffic flow time series prediction [J]. OPTIK, 2016, 127 (19): 8103-8110.
- [7] DU W, ZHANG Q, CHEN Y, et al. An urban short-term traffic flow prediction model based on wavelet neural network with improved whale optimization algorithm [J]. Sustainable Cities and Society, 2021, 69 (3): 102858.
- [8] DOGAN, ERDEM. LSTM training set analysis and clustering model development for short-term traffic flow prediction [J]. Neural Computing and Applications, 2021, 33 (17): 11175-11188.

表 6 是 3 种神经网络在 50 次独立测试中的 3 项性能指

- [9] LU S, ZHANG Q, CHEN G, et al. A combined method for short-term traffic flow prediction based on recurrent neural network [J]. Alexandria Engineering Journal, 2021, 60 (1): 87-94.
- [10] BI J, ZHANG X, et al. A hybrid prediction method for realistic network traffic with temporal convolutional network and LSTM [J]. IEEE Transactions on Automation Science and Engineering, 2021: 1-11.
- [11] BORS A G, PITAS I. Median radial basis function neural network [J]. IEEE Transactions on Neural Networks, 1996, 7 (6): 1351-1364.
- [12] 高大启. 有教师的线性基本函数前向三层神经网络结构研究 [J]. 计算机学报, 1998 (1): 80-86.
- [13] 李祚泳, 余春雪, 张正健, 等. 基于最佳泛化能力的 BP 网络隐节点数反比关系式的环境预测模型 [J]. 环境科学学报, 2021, 41 (2): 718-730.
- [14] 付琦. 一种基于遗传算法的神经网络结构优化方法 [J]. 制造业自动化, 2015, 37 (14): 71-74.
- [15] 张世睿, 李心科. 基于模拟退火的 BP 网络隐藏层节点估算算法 [J]. 合肥工业大学学报 (自然科学版), 2017, 40 (11): 1489-1491, 1506.
- [16] 宋国平, 张家晨. 基于群体智能技术的人工神经网络结构优化研究 [J]. 重庆理工大学学报 (自然科学版), 2020, 34 (8): 143-148.
- [17] 刘晓洋, 田建艳, 王芳, 等. 基于灰关联-贡献度删减法的神经网络结构优化 [J]. 计算机工程与设计, 2017, 363 (3): 779-783.
- [18] 乔俊飞, 韩红桂. RBF 神经网络的结构动态优化设计 [J]. 自动化学报, 2010, 36 (6): 865-872.
- [19] BENARDOS P G, VOSNIAKOS G C. Optimizing feedforward artificial neural network architecture [J]. Engineering Applications of Artificial Intelligence: The International Journal of Intelligent Real-Time Automation, 2007, 20 (3): 365-382.
- [20] MARQUARDT D W. An algorithm for least-squares estimation of nonlinear parameters [J]. SIAM Journal Applied Mathematics, 1963, 11 (2): 431-441.
- [21] RAJORA, MANIK. An improved approach for solving hierarchically coupled constrained optimization problem in simultaneous optimization of neural network structure and weights [J]. International Journal of Industrial Engineering: Theory Applications and Practice, 2021, 28 (2): 148-161.
- [22] 李来强, 王树林, 李生娟, 等. 基于模拟退火改进的神经网络算法在颗粒碰撞阻尼研究中的应用 [J]. 振动与冲击, 2010, 29 (3): 89-90, 112.
- [23] 胥涯杰, 鲜勇, 李邦杰. 基于 BP 神经网络改进遗传算法的导弹总体参数快速优化方法 [J]. 电光与控制, 2022, 29 (2): 20-24.
- [24] 赵文清, 郭丙旭, 李刚, 等. 基于智能水滴算法优化 Elman 神经网络的光伏电站输出功率预测 [J]. 太阳能学报, 2017, 38 (6): 1553-1559.
- [25] WANG C, WANG Y, YE Z, et al. Credit card fraud detection based on whale algorithm optimized BP neural network [C] // 2018 13th International Conference on Computer Science & Education (ICCSE), 2018: 1-4.
- [26] HU C, ZHAO F. Improved methods of BP neural network algorithm and its limitation [C] // 2010 International Forum on Information Technology and Applications, 2010: 11-14.
- [27] COSTA N, LIMA M D, BARBOSA R. Evaluation of feature selection methods based on artificial neural network weights [J]. Expert Systems with Applications, 2021, 168: 114312.
- [28] ZHANG J S, HU J Y, et al. Neural network with multiple connection weights [J]. Pattern Recognition, 2020, 107: 107481.
- [29] 李会超, 李鸿, 张博. 基于遗传算法优化小波神经网络的短时交通流量预测 [J]. 计算机应用与软件, 2018, 35 (7): 148-152.
- [30] 李会超, 李鸿, 张博. 基于遗传算法优化小波神经网络的短时交通流量预测 [J]. International Journal of Electrical Power & Energy Systems, 2020, 121: 106150.
- [31] 赵会茹, 李娜娜, 郭森, 等. 配电网设备故障停电风险实时评估 [J]. 电力自动化设备, 2014, 34 (11): 89-94.
- [32] 王毅星. 基于深度学习和迁移学习的电力数据挖掘技术研究 [D]. 杭州: 浙江大学, 2019.
- [33] 王辉, 郝丽丽, 黄梅, 等. 基于历史故障信息的配电网设备故障概率建模 [J]. 电力自动化设备, 2020, 40 (3): 76-85.
- [34] ZHANG L, ZHANG D. Evolutionary cost sensitive extreme learning machine [J]. IEEE Transactions on Neural Networks and Learning Systems, 2016, 28 (12): 3045-3060.
- [35] 王慧芳, 曹靖, 罗麟. 电力文本数据挖掘现状及挑战 [J]. 浙江电力, 2019, 38 (3): 1-7.
- [36] 冯斌, 张又文, 唐昕, 等. 基于 BiLSTM-Attention 神经网络的电力设备缺陷文本挖掘 [J]. 中国电机工程学报, 2020, 40 (z1): 1-10.
- [16] GREYTON A, BORGWARDT K, RASCH M, et al. A kernel two-sample test [J]. The Journal of Machine Learning Research, 2012, 13: 723-773.
- [17] 程学珍, 王常安, 李继明, 等. 基于自适应神经模糊 Petri 网的电机故障诊断 [J]. 山东科技大学学报 (自然科学版), 2020, 39 (3): 109-117.
- [18] 卢雪琴. 基于优化神经网络的微电网故障诊断 [D]. 秦皇岛: 燕山大学, 2021.
- [19] 王卓, 王玉静, 王庆岩, 等. 基于协同深度学习的二阶段绝缘子故障检测方法 [J]. 电工技术学报, 2021, 36 (17): 3594-3604.
- [20] CHEN Z Y, GRYLLIAS K, LI W H. Intelligent fault diagnosis for rotary machinery using transferable convolutional neural network [J]. IEEE Transactions on Industrial Informatics, 2020, 16 (1): 339-349.
- [21] QI B, ZHANG P, RONG Z H, et al. Differentiated warning rule of power transformer health status based on big data min-