

控制与决策

Control and Decision

随机权神经网络增量构造学习方法研究进展

代伟, 南静

引用本文:

代伟,南静. 随机权神经网络增量构造学习方法研究进展[J]. *控制与决策*, 2023, 38(8): 2231–2242.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2023.0429>

您可能感兴趣的其他文章

Articles you may be interested in

基于分类特征约束变分伪样本生成器的类增量学习

Class incremental learning based on variational pseudo-sample generator with classification feature constraints

控制与决策. 2021, 36(10): 2475–2482 <https://doi.org/10.13195/j.kzyjc.2020.0228>

基于地标特征和元学习方法推荐最适用优化算法

Recommending best suitable metaheuristic based on landmarking feature and meta-learning approach

控制与决策. 2021, 36(5): 1223–1231 <https://doi.org/10.13195/j.kzyjc.2019.0993>

一种基于池计算的宽度学习系统

A broad learning system based on reservoir computing

控制与决策. 2021, 36(9): 2203–2210 <https://doi.org/10.13195/j.kzyjc.2019.1729>

基于卷积长短期记忆神经网络的城市轨道交通短时客流预测

Metro short-term traffic flow prediction with ConvLSTM

控制与决策. 2021, 36(11): 2760–2770 <https://doi.org/10.13195/j.kzyjc.2020.0501>

基于改进堆叠自动编码器的循环冷却水系统工艺介质温度预测控制方法

Predictive control method of process medium temperature in circulating cooling water system based on improved stacked auto encoders

控制与决策. 2020, 35(12): 2835–2844 <https://doi.org/10.13195/j.kzyjc.2019.0694>

随机权神经网络增量构造学习方法研究进展

代伟^{1,2†}, 南静^{1,2}

(1. 中国矿业大学 人工智能研究院, 江苏 徐州 221116;

2. 中国矿业大学 信息与控制工程学院, 江苏 徐州 221116)

摘要: 随机权神经网络(random weight neural network, RWNN)在解决数据定性和定量分析方面具有强大的潜力,其最显著的特征是隐含层参数随机生成. 这一特征使得RWNN相比于基于梯度下降优化微调节点参数的神经网络具有诸多优势,如结构简单、易于实现和低人工干预等. RWNN的隐含层和输入层之间的参数是在一个固定区间内随机生成,而隐含层和输出层之间的输出权值则通过解析法进行求解. 增量构造方法从一个小的初始网络开始,逐渐添加新的隐含层节点以提升模型品质,直到满足预期性能目标. 基于此,重点从基础理论、增量构造学习方法和未来开放研究方向等方面切入,全面综述增量RWNN的研究进展. 首先介绍RWNN的基本结构、理论和分析;进一步重点介绍RWNN在增量构造学习方法上的各种改进及应用;最后指出RWNN增量构造学习未来开放的研究方向.

关键词: 随机权神经网络; 增量构造学习方法; 前馈神经网络; 随机方法; 数据分析; 无限逼近性

中图分类号: TP183

文献标志码: A

DOI: 10.13195/j.kzyjc.2023.0429

引用格式: 代伟, 南静. 随机权神经网络增量构造学习方法研究进展[J]. 控制与决策, 2023, 38(8): 2231-2242.

Recent advances in incremental learning methods for random weight neural network

DAI Wei^{1,2†}, NAN Jing^{1,2}

(1. Artificial Intelligence Research Institute, China University of Mining and Technology, Xuzhou 221116, China;

2. School of Information and Control Engineering, China University of Mining and Technology, Xuzhou 221116, China)

Abstract: Random weight neural network (RWNN) has strong potential for solving qualitative and quantitative data analysis problems, and its most prominent feature is the random generation of parameters in the hidden layer. This feature makes RWNN has many advantages over neural networks based on gradient descent optimization for fine-tuning node parameters, such as simple structure, easy implementation, and low human intervention. The parameters between the hidden layer and the input layer of RWNN are randomly generated from a fixed interval, while the output weights between the hidden layer and the output layer are solved using an analytical method. The incremental construction method starts from a small initial network and gradually adds new nodes to the hidden layer to improve the quality of the model until the expected performance goal is met. This paper provides a comprehensive review of the research progress of incremental RWNN by focusing on basic theory, incremental construction learning method, and future open research directions. First, the basic structure, theory and analysis of RWNN are introduced, and the improvements and applications of RWNN in the incremental construction learning methods are further highlighted. Finally, future open research questions and promising directions of RWNN are pointed out.

Keywords: random weight neural network; incremental construction learning method; feedforward neural network; random methods; data analysis; universal approximation property

0 引言

数据的高维性和大规模性已逐渐成为机器学习从方法到应用的主要挑战^[1-3],神经网络因具有挖掘和分析数据的强大能力被用于从数据中学习,

以实现模式识别和非线性回归(预测)模型等建模任务^[4-6]. 目前,神经网络是机器学习中应用最为广泛的建模工具. 近年来,基于梯度下降训练的神经网络依靠其堆叠式网络结构的强大数据特征提取能力,

收稿日期: 2023-04-07; 录用日期: 2023-06-09.

基金项目: 国家自然科学基金面上项目(61973306); 江苏省自然科学基金优秀青年基金项目(BK20200086).

责任编辑: 杨涛.

†通讯作者. E-mail: weidai@cumt.edu.cn.

在自然语言处理、自动驾驶以及图像分析等多个领域表现出强大的模型泛化能力^[7-9]。然而,训练神经网络往往是一个非凸目标函数优化过程,其涉及局部极小值和鞍点,这对基于梯度下降的训练方法是极大的挑战^[10]。此外,模型复杂度、学习效率以及硬件可实现性等要素也是基于神经网络的数据分析与建模方法应该着重考虑的问题。在大数据时代,深入挖掘扁平结构(单隐含层)神经网络的表达能力和应用潜力至关重要,其能够以最小的建模消耗找到令人满意的解决方案,同时在其优化过程中具有强大的最优性保证^[11-14]。

受灵长类动物大脑神经表征中随机连接的启发,具有简单和快速特性的随机方法被引入神经网络学习中,其以随机非迭代方法代替梯度下降训练网络参数^[15-16]。随机权神经网络(random weight neural network, RWNN)是单隐含层前馈神经网络与随机学习方法相结合的一类学习模型,其本质思想是通过使用随机化来构建隐含层参数,将输入映射至有利于网络学习的高维特征空间,进而采用标准线性优化方法求解隐含层至输出层权值^[17],从而避免对网络参数进行非凸优化求解。不同于基于梯度下降训练的(深度)神经网络,随机权神经网络依靠两步范式训练模型,即随机分配神经网络的隐含层参数(输入权重和偏置),并通过使用最小二乘法来评估输出权重。文献^[18]的结果表明,这种随机建模的方法能够实现更快的训练速度和可接受的模型性能。

当前,无限逼近性和泛化性两方面的理论研究结果证明了随机权神经网络具有巨大潜力^[19-20]。同时,文献^[21]基于实验验证了RWNN对满足Lipschitz条件的近似函数仍有良好的逼近性。基于上述研究,随机权神经网络成为神经网络的研究热点,并成功应用于工业过程软测量、故障诊断和关键参数预测等数据建模与分析任务^[22-26]。

尽管现有文献^[10,27-28]对RWNN及其应用进行了总结与展望,但对其增量构造方法即增量RWNN(incremental RWNN, IRWNN)的成果鲜有报道。众所周知,深度神经网络能够从数据中获得高级语义的核心原因是其堆叠式的网络结构,显然,具有堆叠结构的IRWNN可以大大提高模型性能,并有助于解决更复杂的建模任务。同时,分布式联邦学习能够保证建模过程的数据隐私性,将联邦学习和IRWNN相融合具有很好的应用前景。同理,将当前人工智能前沿技术嵌入IRWNN将有利于提升IRWNN的可解释性和泛化能力。

考虑到当前IRWNN及其学习方法分散于各类科技文献中,缺少全面的梳理和呈现,本文对IRWNN过去几十年的主要进展和关键突破进行全面综述,重点从随机权神经网络、增量构造学习方法和未来开放的研究方向等方面进行总结。第1节简要介绍传统随机权神经网络的定义与基础理论,深入分析随机权神经网络特性,并总结梳理学习方法在网络结构、网络稳定性、隐含层节点参数有效性3个方面存在的问题。第2节对近年来增量构造方法下的随机权神经网络的相关研究和发展脉络进行梳理,介绍当前先进的约束增量随机构造学习方法。第3节讨论增量随机权神经网络的研究方向和挑战。第4节总结全文。

1 随机权神经网络

自感知模型时期以来,随机性被引入人工神经网络。受生物神经系统的启发,Rosenblatt^[29]设计了一个包含3个单元感知模型,在该模型中任意两个单元之间的连接都是随机的。Rosenblatt观察到,这种具有随机连接单元的系统可以在特定约束条件下对特定刺激做出特定响应。在先驱工作的启发下,Pao等^[30]提出了随机向量函数链接网络(random vector functional link network, RVFLN);同年,Schmidt等^[31]提出了另一种具有随机权重的单层前馈神经网络(feedforward neural network with random weight, FNNRW),两者的网络结构如图1和图2所示。

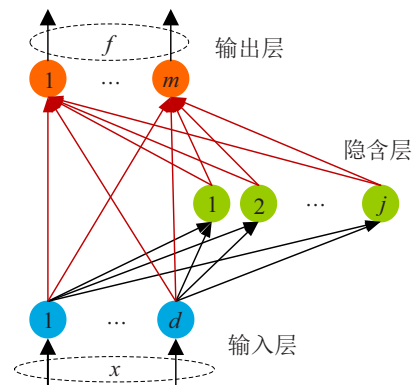


图1 RVFLN网络结构




图2 FNNRW网络结构

RVFLN和FNNRW的模型数学表达分别为

$$f_{RVFLN} = \sum_{j=1}^m \beta_j x_j + \sum_{i=1}^L \beta_i g_i(w_i^T x + b_i), \quad (1)$$

$$f_{FNNRW} = \sum_{i=1}^L \beta_i g_i(w_i^T x) + \beta_{L+1}. \quad (2)$$

其中: x 表示输入数据矩阵, m 表示输入数据维数, x_j 表示第 j 维输入数据, β_j 表示第 j 个输入到输出层间的权值, L 表示隐含层节点个数, w_i 和 b_i 分别表示第 i 个隐含层节点与输入层之间的输入权值和偏置, g_i 表示第 i 个隐含层节点的激活函数, β_i 表示第 i 个隐含层节点与输出层之间的输出权值, T 表示矩阵转置.

结合数学表达式和网络结构可知, 在训练过程中, 两种网络都使用随机方法分配隐含层节点参数, 但与FNNRW不同, RVFLN在输入层与输出层之间带直链部分. 此外, RVFLN通过Moore-Penrose伪逆来获得隐含层与输出层之间的输出权值, 而FNNRW则是通过使用Fisher方法来确定这部分权值. 进一步地, Pao等^[17]的研究结果表明, RVFLN中大多数连接权重是不重要的, 故没有必要反复调整所有连接权重. 此外, 学者们也证明了RVFLN具有无限逼近性^[18]. 鉴于高效的随机构造特性, 两种随机网络已被成功应用于机器视觉^[32]、模式识别^[33-34]、过程工

业^[35-36]和类脑智能^[37]等诸多领域.

受上述研究启发, 超限学习机被提出^[38], 其被视为一种具有随机权重的通用前馈神经网络^[27]. 此外, 经过理论分析, 这种神经网络的收敛性得到了保证^[39]. 在过去的十几年中, 关于这类网络产生了大量的研究成果, 包括在线版本^[40]、集成版本^[41]、鲁棒版本^[42]、深度版本^[43]、增量版本^[44]、迁移版本^[45]、双端版本^[46]、稀疏贝叶斯版本^[47]、层次结构版本^[48]、随机投影版本^[49]、树结构版本^[50]以及并行结构版本^[51]. 上述成果不仅推动了这种神经网络的发展, 还提高了其的实际应用性.

此后, 学者们也提出了几个新的名称来描述这类神经网络, 如随机权值网络^[52]、具有随机权值的神经网络^[53]、随机权值神经网络^[54]、具有随机权的前馈网络^[55]等. 综上所述, 以上述3种网络为典型代表, 利用随机化方法生成隐含层参数, 并在后续的学习中保持不变, 只更新输出层参数的一类前馈神经网络, 从本质上讲, 它们的思想及其训练机制都是相同的, 仅仅在细节上略有不同, 因此可将其统称为随机权神经网络(random weight neural network, RWNN).

特别地, 本文对上述随机权神经网络中应用最广的3种网络结构进行对比分析, 具体如表1所示.

表1 不同网络结构训练方法对比

网络结构	隐节点参数	效率	运算复杂度
直链+隐层	w_i, b_i	相关实验与理论结果表明, 直链连接能够提高模型泛化性, 因此效率最高	约 $O(M^2(2 + L^2) + 2M)$
单隐层	w_i, b_i	虽然缺少直链连接, 但隐层节点参数对数据进行线性映射, 一定程度上提升了数据的可分性, 进而提升模型的泛化性	约 $O(L^2 M^2 + 2M)$
隐层+独立偏置节点	w_i	与单隐层结构相似, 但根据隐节点参数可知, 其线性映射较弱, 故效率最低	约 $O(M^2(1 + L) + L)$

1.1 随机权神经网络理论基础

随机权神经网络可以看作是一类特殊的前馈神经网络, 其隐含层之间的节点参数是从一定的范围内随机选择, 而输出层权值通过求解线性方程组获得^[56-61]. 随机权神经网络相关理论与训练机制可以描述为如下形式.

对于给定的任意 N 个训练样本 $\{(x_i, y_i)\}, i = 1, 2, \dots, N, x_i \in R^n, y_i \in R^m$, 假设随机权神经网络的隐含层中包含 L 个隐含层节点, 那么其网络输出可以用如下数学形式表示:

$$f_L(x) = \sum_{i=1}^L \beta_i g_i(w_i^T x + b_i). \quad (3)$$

其中: β_i 表示第 i 个隐含层节点到输出层间的权值; w_i 和 b_i 分别表示第 i 个隐含层节点与输入层之间的

输入权值和偏置; g_i 表示第 i 个隐含层节点的激活函数, 一般选用 sigmoid 函数. 这里定义 e 为当前网络的预测误差, 则模型输出与实际输出满足如下数学形式:

$$Y = H\beta + e. \quad (4)$$

其中: $Y = [y_1, y_2, \dots, y_N]_{N \times m}$ 表示样本标签, $H = [g_1, g_2, \dots, g_L]_{N \times L}$ 表示隐含层矩阵, $\beta = [\beta_1, \beta_2, \dots, \beta_L]_{L \times m}$ 表示输出权值.

随机权神经网络训练和测试步骤可概括如下:

- step 1: 从区间 $[-1, 1]$ 内为 L 个节点随机分配输入权值和偏置;
- step 2: 计算网络隐含层矩阵;
- step 3: 基于式(4)计算网络输出权值;
- step 4: 利用测试集对训练后的模型进行测试.

1.2 模型特性

随机神经网络采用随机非迭代方式训练网络节点参数,有效避免了梯度下降训练的效率低、收敛慢、耗时和局部极小值等问题.近年来,RWNN的研究主要围绕网络结构优化、网络稳定性、参数有效性3个关键问题展开.

1) 网络结构优化. RWNN的传统训练方法在建模前需要人工固定网络拓扑结构,但由于缺少对数据的知识认知,很难保证网络拓扑结构与建模任务相匹配.实际上,网络尺寸过大、结构过松弛会导致模型过度泛化,而网络结构过小、结构过紧致则会引起模型学习能力不足. Kwok等^[61]证明了从一个小网络开始,然后逐步增加隐含层节点的增量构造学习方法可以有效解决该问题,但由于其构造过程缺乏合理的监督约束,难以保证网络拓扑结构的高效性.

2) 网络稳定性. RWNN隐含层参数的随机化范围是固定的(通常为 $[-1, 1]$),但相关理论表明^[62-63],以这种固定范围来随机化节点参数难以适合所有建模任务,会导致模型性能的不稳定.因此,如何解决RWNN节点参数随机范围问题还有待研究.此外,有关研究成果表明^[64],激活函数与网络稳定性有关,但对于不同建模任务的激活函数选择仍然缺乏明确的理论指导.

3) 隐含层参数有效性. RWNN所有隐含层参数都是随机获得,尽管有随机范围的存在,但单纯的随机类似于从无限大空间内随意选择节点参数,这种方法很难保证节点参数的有效性,如何解决这一问题以保证节点参数与建模任务之间的高适配度还有待研究.此外,由于没有节点参数的迭代调整,随机神经网络可能无法获得学习参数的高阶语义,这种非反馈机制的影响还有待研究.

由于网络参数的随机性和无调整学习策略显著降低了计算复杂度,进而使得具有快速和易实现特性的RWNN被广泛应用于各个领域,如非线性系统辨识^[65-66]、机器视觉^[67-68]、电力系统^[69-71]、过程工业^[72-73]和医疗诊断^[74-76]等.在这些应用中,RWNN很好地解决了基于梯度下降学习方法所遇到的内存不足、建模耗时和过拟合等问题.尽管在过去几十年中,RWNN的研究取得了大量成果,但以下3个问题值得考虑.

1) RWNN的隐含层节点数量配置带有盲目性,缺少理论指导.在大多数RWNN现有的工作中,很少对隐节点数量的选择与配置进行理论分析,几乎所有的都是以实验方法进行试错确定.尽管一些研究结

果表明,当使用大量隐含层节点时,RWNN的性能往往是稳定和可接受的,但网络的冗余性和复杂度也会相应增加.因此,RWNN及其变体并没有从根本上解决这一问题.

2) RWNN的后续发展可与生物学习相结合.研究人员发现,人类大脑中的神经元也使用随机机制进行学习.由于人工神经网络最初受到人类大脑机制的启发,探究RWNN与生物学习之间的潜在联系具有重要意义.

3) RWNN中具有随机性的隐含层如何构造信息丰富、功能多样、消耗低的特征空间,从而获得良好的性能模型,这一问题需要进行深入探究与分析.此外,是否可以将随机森林等现有理论与RWNN中的随机性和稳定性等相联系起来,以获得更多的研究思路.

2 增量构造学习方法

随机神经网络的固有缺陷使得模型拓扑结构难以确定,剪枝法、正则化法和构造法是解决这一问题的3种主流方法.其中:剪枝法需先构建大尺寸模型再压缩,效率低且硬件资源消耗大^[77];正则化法通过惩罚系数来平衡目标函数值与模型结构约束以提升模型性能,但其惩罚系数往往需要交叉验证或人为调节等耗时方法进行确定^[78];构造法从一个小尺寸网络开始,逐步添加隐含层节点,使网络性能提升直到满足任务要求^[79].相比于其他两种方法,构造法往往会找到具有相同表达能力但网络拓扑结构较紧致的模型,且效率更高.因此,构造法被引入随机神经网络,以实现网络拓扑结构的自主动态构建.在增量构造方法下,诸多学者们在增量随机构造和增量约束随机构造两个方面取得了大量研究成果.

2.1 增量随机构造学习方法

随着构造法的引入,大量学者开始致力于随机神经网络的增量研究^[80],即IRWNN,其以逐点增量方式为网络添加隐含层节点(如图3所示),并从固定区间随机生成该节点所需隐含层参数(输入权值和偏置)且保持不变;然后,利用解析法求解隐含层和输出层之间的输出权值;最后,计算整个网络的残差,重复上述步骤直到满足期望目标为止. IRWNN的构建过程可描述为如下定理.

定理1^[79] 假设 $\text{span}(\Gamma)$ 在 L_2 空间中是稠密的,且当 $b_g \in R^+$ 时, $\forall g \in \Gamma, 0 < \|g\| < b_g$.假设 g_L 使得 $\langle e_{L-1}, g_L \rangle^2 / \|g_L\|^2$ 最大, $\beta_L = \langle e_{L-1}, g_L \rangle / \|g_L\|^2$,则有 $\lim_{L \rightarrow \infty} \|f - f_L\| = \lim_{L \rightarrow \infty} \|e_L\| = 0$.




图3 增量学习网络结构

基于增量随机构造学习的IRWNN研究成果主要集中在提高学习效率和改善网络结构两个方面。

1) 学习效率. IRWNN主要以逐点增量方式构造网络隐含层,并通过求解一组线性方程组获得隐含层与输出层之间的权值.基于随机概率可知,随机构造隐含层节点时不可避免产生冗余、无效或低效节点.为此,在每次增量学习过程中可生成多个隐含层节点,构造候选节点池,并从候选节点池中选择能够实现残余误差最大减小的隐含层节点添加到网络中,以提升模型精度^[81].网络增量构造过程中,由于新增节点势必会对原有网络产生影响,容易导致网络结构冗余,为此,奇异值分解被引入网络中^[82],以评估隐含层中节点的重要性,进而对网络结构进行修剪,达到降低结构冗余和提升泛化性的目的.然而,由于需要增量迭代求解输出权值,其在复杂任务建模时极其消耗计算资源,故存在资源有限条件下实际应用难的问题.为此,Barron凸优化方法被引入隐含层节点的输出权重中,以实现逐步计算,进而构造出收敛速度更快和网络结构更紧致的模型^[83].进一步地,随着增量构造网络残差会逐渐变小且下降不明显,进而导致收敛速度变慢,文献[84]以两次连续迭代之间的残差作为网络收敛指标,基于西电规则建立了网络结构快速紧致增量随机方法.

2) 网络结构.当数据具有高维度、大容量和高动态特性时,如何快速更新网络模型以适应数据快速变化实现持续学习对IRWNN是一个挑战.为此,一种随数据变化而模型结构动态更新的宽度学习系统被提出^[85],其主要特点是:当处理新数据或新任务而需要增加隐含层节点时,基于动态逐步更新算法可对网络模型参数进行增量更新,无需重构整个网络.为了避免该算法在学习过程中出现过度拟合并提高模型的泛化能力,文献[86]通过对其稳定性和泛化性能进行研究分析,基于拉普拉斯分布信息提出了新的正则

化动态更新算法,以控制网络复杂性.由于动态结构通常需要增加节点数量来提高网络性能,使得其面临大尺寸模型风险,易增加建模时间,为此,文献[87]通过构造奇偶节点之间的函数关系,建立了一种基于奇节点参数的偶节点参数增量更新算法,有效地提高了模型构建效率.进一步地,文献[88]通过对随机方法矢量化过程的分析,基于左/右投影矢量建立2-D动态更新随机权方法,以提升该类方法对二维数据的处理能力.

2.2 约束增量随机构造学习方法

鉴于IRWNN中随机化网络参数引发的节点质量问题,如何约束随机过程以保证增量节点符合建模任务需求引起了广泛研究.为此,文献[63]通过实验验证了在输入数据和隐含层节点参数之间存在某种关系,这种关系有利于网络的快速构造.进一步地,具有数据依赖性的不等式监督机制被提出以约束节点参数的选择过程^[89],即随机配置网络(stochastic configuration networks, SCN).特别地,SCN采用3种不同的更新方法计算网络输出权值,分别为:1)仅计算新增隐含层节点的输出权值,并保持先前节点的输出权值不变;2)利用线性优化方法计算指定移动窗口尺寸内的输出权值,即更新部分输出权值;3)利用线性优化方法更新全部输出权值,得到输出权值的全局最优解.在此基础上,文献[90]通过分析残差收敛规律,提出紧致增量约束以监督隐含层参数生成过程.此外,基于对激活函数的非线性特征和数据输入空间的深入分析,文献[91]构建了近似非线性目标函数,以实现隐含层参数的迭代更新,进而防止冗余和低质节点.在上述这些约束增量构造学习方法中,SCN是被研究最广和最深的,其网络结构如图4所示. SCN的构造过程可用定理2进行描述.

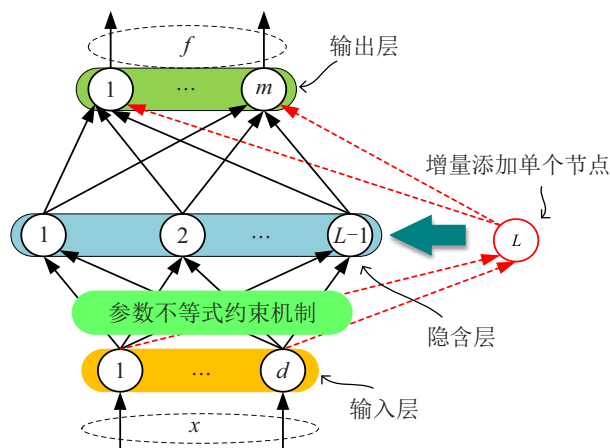


图4 SCN网络结构

定理2^[89] 假设 $\text{span}(\Gamma)$ 在 L_2 空间中是稠密的,

且当 $b_g \in R^+$ 时, $\forall g \in \Gamma, 0 < \|g\| < b_g$. 给定 $0 < r < 1$ 非负实数列 $\{\mu_L\}$ 满足 $\lim_{L \rightarrow \infty} \mu_L = 0$ 和 $\mu_L \leq (1 - r)$, 目标函数 $f: R^d \rightarrow R^m$, 其中 d 和 m 分别表示输入样本的维度和模型输出的维度. 假设已构建好一个带有 $L - 1$ 个隐含层节点的随机配置网络, 那么其输出 $f_{L-1}(x) = \sum_{j=1}^{L-1} \beta_j g_j(w_j^T x + b_j)$. 若新增节点 L 满足最大化如下公式:

$$\begin{cases} \xi_L = \sum_{q=1}^m \xi_{L,q} \geq 0, \\ \xi_{L,q} = \frac{\langle e_{L-1,q}^T \cdot h_L \rangle^2}{h_L^T \cdot h_L} - (1 - r - \mu_L) \|e_{L-1,q}^T\|^2, \\ q = 1, 2, \dots, m, \end{cases} \quad (5)$$

同时 $\beta_L = \langle e_{L-1}, g_L \rangle / \|g_L\|^2$, 那么有 $\lim_{L \rightarrow \infty} \|f - f_L\| = \lim_{L \rightarrow \infty} \|e_L\| = 0$.

SCN 学习过程可总结为: 1) 隐含层参数的配置: 随机分配输入权重和偏置以满足约束 (5), 然后生成新的隐含层节点并将其添加到当前学习模型中; 2) 输出权重的评估: 利用 3 种方法确定当前网络模型的输出权重.

约束增量随机构造学习方法的相关研究成果主要集中在如下几个方面.

1) 鲁棒约束. 在实际工业过程数据的获取过程中, 由于复杂的测量环境、传感器故障、数据传输/记录错误以及各种未知的量测干扰等因素, 数据存在不同程度的噪声和异常值, 进而导致模型泛化性不足. 文献 [92] 将核密度估计引入监督机制约束过程中, 提出鲁棒约束以提升网络对非正常数据的对抗能

力; 文献 [93] 基于贝叶斯推理建立数据自适应推断超参数以解决数据不确定性问题; 文献 [94] 通过融合拉普拉斯和混合高斯分布构建稀疏化约束, 进而建立轻量化网络结构模型. 上述方法从多个方面提升了约束随机权网络的鲁棒性.

2) 块增量和并行策略. 神经网络建模过程的轻量化有助于提升网络建模速度, 特别是在处理复杂建模问题时. 鉴于点增量的低效率, 块增量以及点块混合并行增量的监督约束被提出以提高网络构建效率 [95-96]. 同时, 文献 [97] 通过同时训练多个不同目标函数的基约束模型, 进而对模型输出进行融合以提高模型性能.

3) 正则化. 过拟合问题是神经网络建模过程中不可避免的难题, 如何有效缓解这一问题以提升网络的泛化性能对约束随机网络极其重要. 文献 [98] 融合隐含层节点伯努利分布和 Dropout 技术来修正网络输出目标函数, 并通过建立输出误差反馈项来动态调整网络参数, 进而保证隐含层各节点随机性和独立性. 为了改善隐含层随机映射导致网络空间非线性分布问题, 文献 [99] 以流形正则化为保持器建立局部信息保持监督约束, 以降低数据冗余和深入挖掘神经网络结构特性, 进而提高模型泛化性.

4) 分布式学习. 为了实现分布式数据分析任务, 文献 [100] 建立了一种分布式随机配置网络, 采用并行交替方向乘法提出了网络模型分布式协同学习范式, 属于一种去中心化的分布式学习模式. 针对中心化的分布式学习模式, 为了避免直接汇聚多方数据导致建模存在隐私泄露风险问题, 文献 [101] 提出一种基于随机配置网络的横向联邦增量学习方法

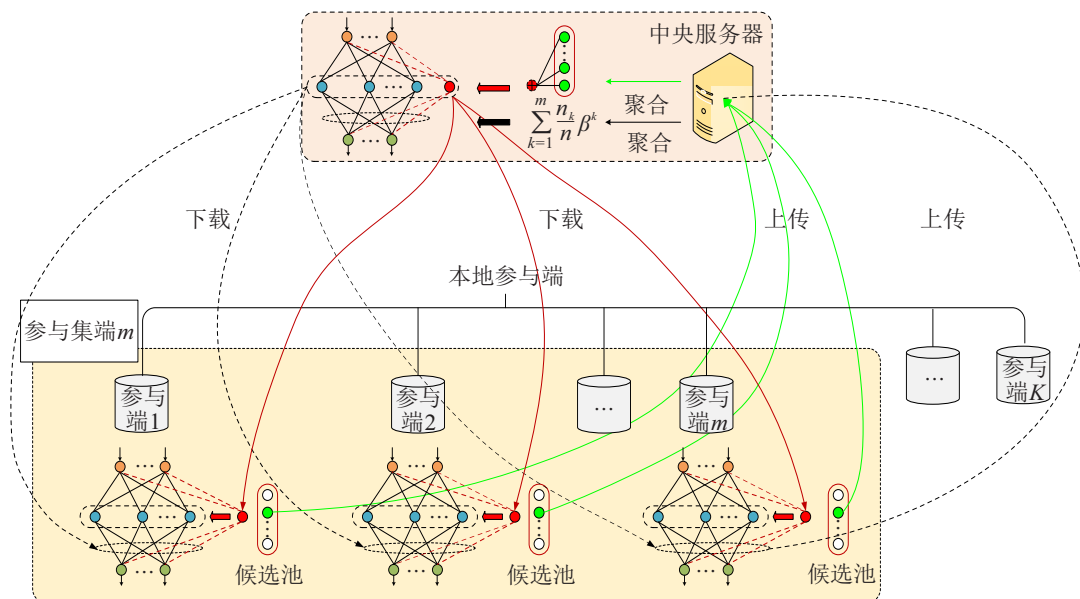


图 5 面向数据隐私与安全的增量构造学习架构

(FSCN, 学习架构如图5所示), 其针对边端数据集具有相同特征空间和不同样本空间的应用场景, 以随机配置网络构建边端模型, 通过建立联邦增量学习方法, 实现了数据隐私安全下的分布式协同建模. 此外, 考虑数据规模及计算资源限制, FSCN为随机参数的配置分别设计了速度优先和质量优先的参数选择策

略, 为解决数据安全下的分布式协同自组织建模问题提供了灵活方案.

近年来, 基于约束增量随机构造学习的RWNN已经被广泛应用于很多领域, 如图像处理^[102-103]、过程工业^[104-105]和类脑智能^[106]等. 随机神经网络增量构造方法总结和分析如表2所示.

表2 随机神经网络增量构造方法总结与分析

构造方法	研究方向	优点与不足
增量随机构造	学习效率 ^[81-84]	优点: 提升网络建模速度 不足: 处理大样本建模任务消耗高
	网络结构 ^[85-88]	优点: 动态快速处理大样本建模任务 不足: 网络结构存在大量冗余
约束增量随机构造	鲁棒约束 ^[92-94]	优点: 提升网络抗干扰能力 不足: 网络对数据的敏感性高
	块增量和并行策略 ^[95-96]	优点: 提升网络构建效率 不足: 块增量会引起节点冗余
	正则化 ^[98-99]	优点: 防止网络出现过拟合 不足: 提升网络复杂性
	分布式学习 ^[100-101]	优点: 边云协同以提高网络学习能力, 保护数据隐私与安全 不足: 难以应对具有不同特征的分布式建模任务

3 未来的研究方向与挑战

在传统RWNN学习方法中, 隐含层权重和偏置是随机选择的, 并且输出层权重利用解析法获得, 因此RWNN可以实现比基于梯度下降方法更快的学习速度, 已被广泛应用于多种实际场景. 然而, 它存在着一些问题, 如网络结构固定、随机化节点参数效率低、随机范围缺乏指导和隐含层节点冗余等. 为解决上述问题, 学者们从增量随机构造学习方法(如IRWNN)和约束增量随机构造学习方法(如SCN)两个方面开展了随机神经网络的研究, 本文也是基于这两大方向进行综述. 此外, 研究表明, 将深度学习与RWNN相结合可以大大提高深度学习的计算效率以及RWNN的模型性能^[107-108].

以下研究方向值得进一步深入研究:

1) 可解释性. 尽管IRWNN克服了RWNN网络拓扑结构固定、节点参数效率低以及结构冗余等问题, 但仍有一个本质问题没有解决, 即随机导致模型黑箱和网络结构随机分布. 文献[109]从空间几何角度对黑箱化问题进行了可视化, 但其构建的约束增量学习方法缺少理论指导且紧致性不足. 尽管如此, 其仍为可解释性随机神经网络的研究奠定了一定基础. 基于此项研究, 研究者可以通过建立“模型引导”来提升随机神经网络模型结果的可解释性和建模过程的理论性.

2) 泛化性. 尽管实验结果表明了IRWNN有良好的泛化性, 进而使其能够在实践中部署应用, 然而解

释为什么会出现这种情况以及计算泛化性的振荡界仍然是一个悬而未决的研究问题.

3) 鲁棒性. IRWNN鲁棒学习方法使用的假设前提是观察数据噪音服从高斯分布, 所构建模型的误差也服从高斯分布, 即在观测数据区域内, 误差会集中在零均值附近. 然而, 诸多实际数据受到各种干扰影响, 离群点难以避免, 含离群点的数据统计特性表现为其数据分布形状具有厚重的尾巴, 即厚尾分布特性, 有别于理想的高斯分布形状. 高斯分布难以刻画厚尾噪声分布, 特别是面对观测数据具有非对称厚尾分布特性时, 容易导致建模出现非常大的偏差, 给网络模型参数估计的精度和无偏性带来巨大难题.

4) 深度模型结构. 尽管深度学习和RWNN相融合的可行性已被证明^[110-111], 但仍然存在一个问题, 即深度结构下RWNN随机产生的隐含层节点参数是否还具有有效性. 此外, 文献[112]指出了充分理解神经网络深度和扁平化之间权衡的重要性, 证明了扁平化小于或等于 $(n + 4)$ 的深度完全连接线性整流函数网络(rectified linear unit, ReLU)可以近似于任何 n 维 R 空间中的勒贝格可积函数, 这也说明权衡深度与扁平化之间的关系有助于设计更加合理的网络拓扑结构方案.

5) 工业应用. 工业信息基础设施通常为分布式DCS控制系统, 其以安全、可靠、稳定为特点, 但存储和运算能力有限, 难以应对复杂结构的数据模型与数据分析任务. 因此, 如何在有限资源下构建轻量高

效随机神经网络数据驱动模型,最大限度地推动人工智能驱动的数据建模技术的应用落地和释放数据价值,已经成为随机神经网络在工业领域应用研究的一个热点方向。

4 结语

本文对增量构造下RWNN的研究工作进行了概述,基于增量随机构造学习方法和约束增量随机构造学习方法介绍了IRWNN的进展情况;在此基础上,分析总结了IRWNN研究的主要挑战和未来还需进一步开展的研究,包括可解释性、鲁棒性、深度模型结构和工业应用等。

参考文献(References)

- [1] Wang M, Fu W J, He X N, et al. A survey on large-scale machine learning[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2022, 34(6): 2574-2594.
- [2] Ding X F, Wang C, Choo K K R, et al. A novel privacy preserving framework for large scale graph data publishing[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2021, 33(2): 331-343.
- [3] Chen Y W, Zhou L D, Pei S W, et al. KNN-BLOCK DBSCAN: Fast clustering for large-scale data[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2021, 51(6): 3939-3953.
- [4] 程旗, 李捷, 高晓利, 等. 基于深度稀疏低秩分解的深度神经网络轻量化方法[J]. *控制与决策*, 2023, 38(3): 751-758.
(Cheng Q, Li J, Gao X L, et al. Lightweight method of deep neural network based on deep sparse low rank decomposition[J]. *Control and Decision*, 2023, 38(3): 751-758.)
- [5] 王进花, 岳亮辉, 曹洁, 等. 基于随机变分推理贝叶斯神经网络的发电机轴承故障诊断[J]. *控制与决策*, 2023, 38(4): 1015-1021.
(Wang J H, Yue L H, Cao J, et al. Fault diagnosis of generator bearing based on Bayesian neural network of stochastic variational reasoning[J]. *Control and Decision*, 2023, 38(4): 1015-1021.)
- [6] Chu Y D, Fei J T, Hou S X. Adaptive global sliding-mode control for dynamic systems using double hidden layer recurrent neural network structure[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, 31(4): 1297-1309.
- [7] Fetanat M, Stevens M, Jain P, et al. Fully Elman neural network: A novel deep recurrent neural network optimized by an improved Harris Hawks algorithm for classification of pulmonary arterial wedge pressure[J]. *IEEE Transactions on Biomedical Engineering*, 2022, 69(5): 1733-1744.
- [8] Zhou C, Wang S D, Wang Z X, et al. Absorption attenuation compensation using an end-to-end deep neural network[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 1-9.
- [9] Mou L C, Ghamisi P, Zhu X X. Deep recurrent neural networks for hyperspectral image classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(7): 3639-3655.
- [10] Scardapane S, Wang D H. Randomness in neural networks: An overview[J]. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 2017, 7(2): e1200.
- [11] Peng J X, Li K, Irwin G W. A new Jacobian matrix for optimal learning of single-layer neural networks[J]. *IEEE Transactions on Neural Networks*, 2008, 19(1): 119-129.
- [12] Huang G B, Chen Y Q, Babri H A. Classification ability of single hidden layer feedforward neural networks[J]. *IEEE Transactions on Neural Networks*, 2000, 11(3): 799-801.
- [13] Setiono R, Hui L C K. Use of a quasi-Newton method in a feedforward neural network construction algorithm[J]. *IEEE Transactions on Neural Networks*, 1995, 6(1): 273-277.
- [14] Wu X, Różycki P, Wilamowski B M. A hybrid constructive algorithm for single-layer feedforward networks learning[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2015, 26(8): 1659-1668.
- [15] Wang D H. Editorial: Randomized algorithms for training neural networks[J]. *Information Sciences*, 2016, 364/365: 126-128.
- [16] Broomhead D, Lowe D. Multivariable functional interpolation and adaptive networks[J]. *Complex Systems*, 1988, 2(3): 321-355.
- [17] Pao Y H, Park G H, Sobajic D J. Learning and generalization characteristics of the random vector functional-link net[J]. *Neurocomputing*, 1994, 6(2): 163-180.
- [18] Igel'nik B, Pao Y H. Stochastic choice of basis functions in adaptive function approximation and the functional-link net[J]. *IEEE Transactions on Neural Networks*, 1995, 6(6): 1320-1329.
- [19] Leshno M, Lin V Y, Pinkus A, et al. Multilayer feedforward networks with a nonpolynomial activation function can approximate any function[J]. *Neural Networks*, 1993, 6(6): 861-867.
- [20] Sanger T D. Optimal unsupervised learning in a single-layer linear feedforward neural network[J]. *Neural Networks*, 1989, 2(6): 459-473.
- [21] Husmeier D. Neural networks for conditional probability estimation: Forecasting beyond point predictions[C]. London: Springer, 1999.
- [22] Li J P, Hua C C, Yang Y N. Output space transfer-based MIMO RVFLNs modeling for estimation of blast furnace molten iron quality with missing indexes[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021,

- 70: 1-10.
- [23] 周平, 张丽, 李温鹏, 等. 集成自编码与PCA的高炉多元铁水质量随机神经网络建模[J]. 自动化学报, 2018, 44(10): 1799-1811.
(Zhou P, Zhang L, Li W P, et al. Autoencoder and PCA based RVFLNs modeling for multivariate molten iron quality in blast furnace ironmaking[J]. Acta Automatica Sinica, 2018, 44(10): 1799-1811.)
- [24] 贺敏, 汤健, 郭旭琦, 等. 基于流形正则化域适应随机神经网络的湿式球磨机负荷参数软测量[J]. 自动化学报, 2019, 45(2): 398-406.
(He M, Tang J, Guo X Q, et al. Soft sensor for ball mill load using DAMRRWNN model[J]. Acta Automatica Sinica, 2019, 45(2): 398-406.)
- [25] Dai Q J, Zhang G, Fang Z, et al. SAR target recognition with modified convolutional random vector functional link network[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1-5.
- [26] Gao R B, Du L, Suganthan P N, et al. Random vector functional link neural network based ensemble deep learning for short-term load forecasting[J]. Expert Systems with Applications, 2022, 206: 117784.
- [27] Cao W P, Wang X Z, Ming Z, et al. A review on neural networks with random weights[J]. Neurocomputing, 2018, 275: 278-287.
- [28] Zhang L, Suganthan P N. A survey of randomized algorithms for training neural networks[J]. Information Sciences, 2016, 364/365: 146-155.
- [29] Rosenblatt F. The perceptron: A probabilistic model for information storage and organization in the brain[J]. Psychological Review, 1958, 65(6): 386-408.
- [30] Pao Y H, Takefuji Y. Functional-link net computing: Theory, system architecture, and functionalities[J]. Computer, 1992, 25(5): 76-79.
- [31] Schmidt W F, Kraaijveld M A, Duin R P W. Feedforward neural networks with random weights[C]. Proceeding of 11th IAPR International Conference on Pattern Recognition. The Hague, 2002: 1-4.
- [32] Zhang L, Suganthan P N. Visual tracking with convolutional random vector functional link network[J]. IEEE Transactions on Cybernetics, 2017, 47(10): 3243-3253.
- [33] Dai Q J, Zhang G, Fang Z, et al. SAR target recognition with modified convolutional random vector functional link network[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1-5.
- [34] Cui W, Zhang L, Li B, et al. Received signal strength based indoor positioning using a random vector functional link network[J]. IEEE Transactions on Industrial Informatics, 2018, 14(5): 1846-1855.
- [35] Xu K K, Li H X, Yang H D. Kernel-based random vector functional-link network for fast learning of spatiotemporal dynamic processes[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2019, 49(5): 1016-1026.
- [36] Scardapane S, Wang D H, Uncini A. Bayesian random vector functional-link networks for robust data modeling[J]. IEEE Transactions on Cybernetics, 2018, 48(7): 2049-2059.
- [37] Zhang Y K, Guo R Q, Peng Y, et al. An auto-weighting incremental random vector functional link network for EEG-based driving fatigue detection[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-14.
- [38] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: Theory and applications[J]. Neurocomputing, 2006, 70(1/2/3): 489-501.
- [39] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: A new learning scheme of feedforward neural networks[C]. 2004 IEEE International Joint Conference on Neural Networks. Budapest, 2005: 985-990.
- [40] Liang N Y, Huang G B, Saratchandran P, et al. A fast and accurate online sequential learning algorithm for feedforward networks[J]. IEEE Transactions on Neural Networks, 2006, 17(6): 1411-1423.
- [41] Liu N, Wang H. Ensemble based extreme learning machine[J]. IEEE Signal Processing Letters, 2010, 17(8): 754-757.
- [42] Deng W Y, Zheng Q H, Chen L. Regularized extreme learning machine[C]. 2009 IEEE Symposium on Computational Intelligence and Data Mining. Nashville, 2009: 389-395.
- [43] Tissera M D, McDonnell M D. Deep extreme learning machines: Supervised autoencoding architecture for classification[J]. Neurocomputing, 2016, 174: 42-49.
- [44] Huang G B, Chen L, Siew C K. Universal approximation using incremental constructive feedforward networks with random hidden nodes[J]. IEEE Transactions on Neural Networks, 2006, 17(4): 879-892.
- [45] Chen Z Y, Wang S Q, Shen Z Q, et al. Online sequential ELM based transfer learning for transportation mode recognition[C]. 2013 IEEE Conference on Cybernetics and Intelligent Systems. Manila, 2014: 78-83.
- [46] Yang Y M, Wang Y N, Yuan X F. Bidirectional extreme learning machine for regression problem and its learning effectiveness[J]. IEEE Transactions on Neural Networks and Learning Systems, 2012, 23(9): 1498-1505.
- [47] Luo J H, Vong C M, Wong P K. Sparse Bayesian extreme learning machine for multi-classification[J]. IEEE Transactions on Neural Networks and Learning Systems, 2014, 25(4): 836-843.
- [48] He Y L, Geng Z Q, Xu Y, et al. A hierarchical structure of extreme learning machine (HELM) for high-dimensional datasets with noise[J]. Neurocomputing, 2014, 128: 407-414.
- [49] Gastaldo P, Zunino R, Cambria E, et al. Combining ELMs

- with random projections[J]. *IEEE Intelligent Systems*, 2013, 28(6): 46-48.
- [50] Wang R, He Y L, Chow C Y, et al. Learning ELM-Tree from big data based on uncertainty reduction[J]. *Fuzzy Sets and Systems*, 2015, 258: 79-100.
- [51] Dokeroglu T, Sevinc E. Evolutionary parallel extreme learning machines for the data classification problem[J]. *Computers & Industrial Engineering*, 2019, 130: 237-249.
- [52] He Y L, Wang X Z, Huang J Z. Fuzzy nonlinear regression analysis using a random weight network[J]. *Information Sciences*, 2016, 364/365: 222-240.
- [53] Lu J, Zhao J W, Cao F L. Extended feed forward neural networks with random weights for face recognition[J]. *Neurocomputing*, 2014, 136: 96-102.
- [54] Ji J, Jiang H C, Zhao B, et al. Crucial data selection based on random weight neural network[C]. 2015 IEEE International Conference on Systems, Man, and Cybernetics. Hong Kong, 2016: 1017-1022.
- [55] Cao F L, Jing L, Chu J J, et al. Leukocyte image segmentation using feed forward neural networks with random weights[C]. Proceedings of 11th International Conference on Natural Computation. Zhangjiajie, 2016: 736-742.
- [56] Huang G B. An insight into extreme learning machines: Random neurons, random features and kernels[J]. *Cognitive Computation*, 2014, 6(3): 376-390.
- [57] He Y L, Wang X Z, Huang J Z. Fuzzy nonlinear regression analysis using a random weight network[J]. *Information Sciences*, 2016, 364/365: 222-240.
- [58] Wan W G, Zhou Z H, Zhao J W, et al. A novel face recognition method: Using random weight networks and quasi-singular value decomposition[J]. *Neurocomputing*, 2015, 151: 1180-1186.
- [59] Li J Y, Chow W, Igel'nik B, et al. Comments on stochastic choice of basis functions in adaptive function approximation and the functional-link net[J]. *IEEE Transaction Neural Networks*, 1997, 8(2): 452-454.
- [60] Pao Y H, Phillips S M. The functional link net and learning optimal control[J]. *Neurocomputing*, 1995, 9(2): 149-164.
- [61] Kwok T Y, Yeung D Y. Objective functions for training new hidden units in constructive neural networks[J]. *IEEE Transactions on Neural Networks*, 1997, 8(5): 1131-1148.
- [62] Li M, Wang D H. Insights into randomized algorithms for neural networks: Practical issues and common pitfalls[J]. *Information Sciences*, 2017, 382/383: 170-178.
- [63] Dudek G. Generating random weights and biases in feedforward neural networks with random hidden nodes[J]. *Information Sciences*, 2019, 481: 33-56.
- [64] Zhang L, Suganthan P N. A comprehensive evaluation of random vector functional link networks[J]. *Information Sciences*, 2016, 367/368: 1094-1105.
- [65] Samal D, Dash P K, Bisoi R. Modified added activation function based exponential robust random vector functional link network with expanded version for nonlinear system identification[J]. *Applied Intelligence*, 2022, 52(5): 5657-5683.
- [66] Zhang X F, Ma H B, Zuo W C, et al. Adaptive control of discrete-time nonlinear systems using ITF-ORVFL[J]. *IEEE/CAA Journal of Automatica Sinica*, 2019, 9(3): 556-563.
- [67] Chakravorti T, Satyanarayana P. Classification of power quality disturbances using adaptive variational mode decomposition based random vector functional link network[C]. Proceedings of the 2019 IEEE Region 10 Symposium. Kolkata, 2020: 721-726.
- [68] Fan L Y, Sun W Y, Feng G R. Image steganalysis via random subspace fisher linear discriminant vector functional link network and feature mapping[J]. *Mobile Networks and Applications*, 2019, 24(4): 1269-1278.
- [69] Pan J H, Fan J S, Dong A D, et al. Random vector functional link network optimized by jaya algorithm for transient stability assessment of power systems[J]. *Mathematical Problems in Engineering*, 2020, 2020: 1-9.
- [70] Qiu X H, Suganthan P N, Amaratunga G A J. Ensemble incremental learning Random Vector Functional Link network for short-term electric load forecasting[J]. *Knowledge-Based Systems*, 2018, 145: 182-196.
- [71] Priyadarshini L, Dash P K, Dhar S. A new exponentially expanded robust random vector functional link network based MPPT model for local energy management of PV-battery energy storage integrated microgrid[J]. *Engineering Applications of Artificial Intelligence*, 2020, 91: 103633.
- [72] Zhang L, Zhang X G, Chen H, et al. A robust temperature prediction model of shuttle kiln based on ensemble random vector functional link network[J]. *Applied Thermal Engineering*, 2019, 150: 99-110.
- [73] Jiang Y, Zhou P, Yu G. Multivariate molten iron quality modeling based on improved incremental random vector functional-link networks[J]. *IFAC-PapersOnLine*, 2018, 51(21): 290-294.
- [74] Song Y D, Crowcroft J, Zhang J X. Automatic epileptic seizure detection in EEGs based on optimized sample entropy and extreme learning machine[J]. *Journal of Neuroscience Methods*, 2012, 210(2): 132-146.
- [75] Shi L C, Lu B L. EEG-based vigilance estimation using extreme learning machines[J]. *Neurocomputing*, 2013, 102: 135-143.
- [76] Termenon M, Graña M, Barrós-Loscertales A, et al. Extreme learning machines for feature selection and classification of cocaine dependent patients on structural MRI data[J]. *Neural Processing Letters*, 2013, 38(3): 375-387.

- [77] Li H H, Zhang J G, Li Z H, et al. Improvement of Min-entropy evaluation based on pruning and quantized deep neural network[J]. *IEEE Transactions on Information Forensics and Security*, 2023, 18: 1410-1420.
- [78] Hofmann M, Mäder P. Synaptic scaling — An artificial neural network regularization inspired by nature[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 33(7): 3094-3108.
- [79] Islam M M, Sattar M A, Amin M F, et al. A new constructive algorithm for architectural and functional adaptation of artificial neural networks[J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, 2009, 39(6): 1590-1605.
- [80] Liu D R, Chang T S, Zhang Y. A constructive algorithm for feedforward neural networks with incremental training[J]. *IEEE Transactions on Circuits and Systems I: Fundamental Theory and Applications*, 2002, 49(12): 1876-1879.
- [81] Lan Y, Soh Y, Huang G B. Random search enhancement of error minimized extreme learning machine[C]. *Proceedings of the European Symposium on Artificial Neural Networks*. Belgium, 2010: 327-332.
- [82] Teoh E J, Tan K C, Xiang C. Estimating the number of hidden neurons in a feedforward network using the singular value decomposition[J]. *IEEE Transactions on Neural Networks*, 2006, 17(6): 1623-1629.
- [83] Wu D M, Wang X L, Wu S C. A hybrid framework based on extreme learning machine, discrete wavelet transform, and autoencoder with feature penalty for stock prediction[J]. *Expert Systems with Applications*, 2022, 207: 118006.
- [84] Zhou P, Jiang Y, Wen C Y, et al. Improved incremental RVFL with compact structure and its application in quality prediction of blast furnace[J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(12): 8324-8334.
- [85] Chen C L P, Liu Z L. Broad learning system: An effective and efficient incremental learning system without the need for deep architecture[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(1): 10-24.
- [86] Jin J W, Philip Chen C L, Li Y T. Robust broad learning system for uncertain data modeling[C]. 2018 *IEEE International Conference on Systems, Man, and Cybernetics*. Miyazaki, 2019: 3524-3529.
- [87] Huang P Q, Chen B. Bidirectional broad learning system[C]. *Proceedings of 7th International Conference on Industrial Engineering and Applications*. Bangkok, 2020: 963-968.
- [88] Dai W, Zhang R, Wang Q J, et al. Two-dimensional broad learning system for data analytic[J]. *IEEE Transactions on Artificial Intelligence*, 2021, 2(6): 594-607.
- [89] Wang D H, Li M. Stochastic configuration networks: Fundamentals and algorithms[J]. *IEEE Transactions on Cybernetics*, 2017, 47(10): 3466-3479.
- [90] Wang Q J, Dai W, Lin P, et al. Compact incremental random weight network for estimating the underground airflow quantity[J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(1): 426-436.
- [91] Dudek G. A constructive approach to data-driven randomized learning for feedforward neural networks[J]. *Applied Soft Computing*, 2021, 112: 107797.
- [92] Wang D H, Li M. Robust stochastic configuration networks with kernel density estimation for uncertain data regression[J]. *Information Sciences*, 2017, 412/413: 210-222.
- [93] Wu R Z, Lv B Y, Dai C M, et al. Bayesian stochastic configuration networks for robust data modeling[J]. *Concurrency and Computation: Practice and Experience*, 2022, 34(1): e6495.
- [94] Lu J, Ding J L. Mixed-distribution-based robust stochastic configuration networks for prediction interval construction[J]. *IEEE Transactions on Industrial Informatics*, 2020, 16(8): 5099-5109.
- [95] Dai W, Li D P, Zhou P, et al. Stochastic configuration networks with block increments for data modeling in process industries[J]. *Information Sciences*, 2019, 484: 367-386.
- [96] 代伟, 李德鹏, 杨春雨, 等. 一种随机配置网络的模型与数据混合并行学习方法[J]. *自动化学报*, 2021, 47(10): 2427-2437.
(Dai W, Li D P, Yang C Y, et al. A model and data hybrid parallel learning method for stochastic configuration networks[J]. *Acta Automatica Sinica*, 2021, 47(10): 2427-2437.)
- [97] Zhang C L, Ding S F, Zhang J, et al. Parallel stochastic configuration networks for large-scale data regression[J]. *Applied Soft Computing*, 2021, 103: 107143.
- [98] Li W, Zeng Z Q, Qu H Q, et al. A novel fiber intrusion signal recognition method for OFPS based on SCN with dropout[J]. *Journal of Lightwave Technology*, 2019, 37(20): 5221-5230.
- [99] 南静, 宁传峰, 建中华, 等. 基于随机配置网络的轻量级人体行为识别模型[J]. *控制与决策*, 2023, 38(6): 1541-1550.
(Nan J, Ning C F, Jian Z H, et al. A lightweight model for human activity recognition using stochastic configuration networks[J]. *Control and Decision*, 2023, 38(6): 1541-1550.)
- [100] Ai W, Wang D H. Distributed stochastic configuration networks with cooperative learning paradigm[J]. *Information Sciences*, 2020, 540: 1-16.
- [101] Dai W, Ji L L, Wang D H. Federated stochastic configuration networks for distributed data analytics[J]. *Information Sciences*, 2022, 614: 51-70.
- [102] Li M, Wang D H. 2-D stochastic configuration networks for image data analytics[J]. *IEEE Transactions on*

- Cybernetics, 2021, 51(1): 359-372.
- [103] Li W T, Tao H, Li H, et al. Greengage grading using stochastic configuration networks and a semi-supervised feedback mechanism[J]. Information Sciences, 2019, 488: 1-12.
- [104] Xie J, Zhou P. Robust stochastic configuration network multi-output modeling of molten iron quality in blast furnace ironmaking[J]. Neurocomputing, 2020, 387: 139-149.
- [105] 王前进, 杨春雨, 马小平, 等. 基于随机配置网络的井下供给风量建模[J]. 自动化学报, 2021, 47(8): 1963-1975.
(Wang Q J, Yang C Y, Ma X P, et al. Underground airflow quantity modeling based on SCN[J]. Acta Automatica Sinica, 2021, 47(8): 1963-1975.)
- [106] Pang L P, Guo L, Zhang J, et al. Subject-specific mental workload classification using EEG and stochastic configuration network (SCN)[J]. Biomedical Signal Processing and Control, 2021, 68: 102711.
- [107] Hu M H, Heng Chion J, Suganthan P N, et al. Ensemble deep random vector functional link neural network for regression[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2022, 53(5): 2604-2615.
- [108] Ganaie M A, Tanveer M. Ensemble deep random vector functional link network using privileged information for Alzheimer's disease diagnosis[J]. IEEE/ACM Transactions on Computational Biology and Bioinformatics, DOI: 10.1109/TCBB.2022.3170351.
- [109] 南静, 代伟, 袁冠, 等. 一种空间几何角度最大化的随机增量学习模型及应用[J]. 自动化学报, 2022, 49(6): 1283-1294.
(Nan J, Dai W, Yuan G, et al. A stochastic incremental learning model with maximizing spatial geometry angle and its application[J]. Acta Automatica Sinica, 2022, 49(6): 1283-1294.)
- [110] Shi Q S, Katuwal R, Suganthan P N, et al. Random vector functional link neural network based ensemble deep learning[J]. Pattern Recognition, 2021, 117: 107978.
- [111] Shi Q S, Hu M H, Suganthan P N, et al. Weighting and pruning based ensemble deep random vector functional link network for tabular data classification[J]. Pattern Recognition, 2022, 132: 108879.
- [112] Lu Z, Pu H M, Wang F C, et al. The expressive power of neural networks: A view from the width[J/OL]. 2017, arXiv: 1709.02540.

作者简介

代伟(1984—), 男, 教授, 博士生导师, 从事智能与数据驱动的复杂工业过程建模、运行优化控制理论等研究, E-mail: weidai@cumt.edu.cn;

南静(1992—), 男, 博士生, 从事随机神经网络、神经网络轻量化以及工业过程软测量等研究, E-mail: jingn@cumt.edu.cn.



特邀专家 代伟, 中国矿业大学教授、博士生导师、人工智能研究院副院长, 江苏省自动化学会理事, 分别于2009年和2015年在东北大学信息学院和流程工业综合自动化国家重点实验室获硕士和博士学位, 从事“复杂工业过程运行优化与运行控制”科学与应用研究。入选国家重大人才工程青年学者、江苏省优秀青年、江苏省“青蓝工程”优秀青年骨干教师、IEEE高级会员。近年来, 以第1通讯作者发表学术论文70余篇, 出版学术专著2部, 专利转化4项。相关研究成果获教育部自然科学二等奖, 中国自动化学会自然科学一等奖、二等奖, 辽宁省专利奖一等奖, 煤炭青年科技奖, 中国产学研合作创新奖, 江苏省科学技术三等奖等10余项科研奖励。

专家寄语 一批批东大人勇立潮头、勇挑重担、勇毅精进, 百年辉煌的岁月见证了东大的不懈努力和卓越成就, 百年风雨, 功勋卓越, 百年树人, 英才辈出, 在这个历史性的时刻, 祝愿母校新百年再谱华章, 再创辉煌!