

# 深度神经模糊系统算法及其回归应用

赵文迪<sup>1,2</sup> 陈德旺<sup>1,2</sup> 卓永强<sup>3</sup> 黄允浒<sup>1,2</sup>

**摘要** 深度神经网络是人工智能的热点,可以很好处理高维大数据,却有可解释性差的不足。通过 IF-THEN 规则构建的模糊系统,具有可解释性强的优点,但在处理高维大数据时会遇到“维数灾难”问题。本文提出一种基于 ANFIS (Adaptive network based fuzzy inference system) 的深度神经模糊系统 (Deep neural fuzzy system, DNFS) 及两种基于分块和分层的启发式实现算法: DNFS1 和 DNFS2。通过四个面向回归应用的数据集的测试,我们发现: 1) 采用分块、分层学习的 DNFS 在准确度与可解释性上优于 BP、RBF、GRNN 等传统浅层神经网络算法,也优于 LSTM 和 DBN 等深度神经网络算法; 2) 在低维问题中, DNFS1 具有一定优势; 3) 在面对高维问题时, DNFS2 表现更为突出。本文的研究结果表明 DNFS 是一种新型深度学习方法,不仅可解释性好,而且能有效解决处理高维数据时模糊规则数目爆炸的问题,具有很好的发展前景。

**关键词** 高维大数据, 深度神经模糊系统, 自适应神经模糊系统, 分层结构, 可解释性

**引用格式** 赵文迪, 陈德旺, 卓永强, 黄允浒. 深度神经模糊系统算法及其回归应用. 自动化学报, 2020, 46(11): 2350–2358

**DOI** 10.16383/j.aas.c200100

## Deep Neural Fuzzy System Algorithm and Its Regression Application

ZHAO Wen-Di<sup>1,2</sup> CHEN De-Wang<sup>1,2</sup> ZHUO Yong-Qiang<sup>3</sup> HUANG Yun-Hu<sup>1,2</sup>

**Abstract** Deep neural network is a hot spot of artificial intelligence, which can deal with high-dimensional big data well, but has the disadvantage of poor interpretability. The fuzzy system constructed by if-then rules has the advantage of strong interpretability, but it will encounter the problem of “the curse of dimension” when dealing with high dimension big data. This paper presents a DNFS (Deep neural fuzzy system) based on ANFIS (Adaptive network based fuzzy inference system) and two heuristic algorithms based on block and layer: DNFS1 and DNFS2. Through the testing of four regression-oriented data sets, we found: 1) DNFS with block and layer learning is superior to BP, RBF, GRNN and other traditional shallow neural network algorithms in accuracy and interpretability, as well as LSTM, DBN and other deep neural network algorithms; 2) In low dimensional problems, DNFS1 has certain advantages; 3) In the face of high dimensional problems, DNFS2 is more prominent. The results of this paper show that DNFS is a new deep learning method, which not only has good interpretability, but also can effectively solve the problem that the number of fuzzy rules explodes when dealing with high-dimensional data, and has a good development prospect.

**Key words** High-dimensional big data, deep neural fuzzy system, adaptive network based fuzzy inference system, hierarchical structure, interpretability

**Citation** Zhao Wen-Di, Chen De-Wang, Zhuo Yong-Qiang, Huang Yun-Hu. Deep neural fuzzy system algorithm and its regression application. *Acta Automatica Sinica*, 2020, 46(11): 2350–2358

1943 年 McCulloch 与 Pitts 首次提出人工神经元数理模型 (MP 模型)<sup>[1]</sup>, 开启了人工神经网络的研究。

收稿日期 2020-03-02 录用日期 2020-06-28

Manuscript received March 2, 2020; accepted June 28, 2020

国家自然科学基金面上项目 (61976055), 智慧地铁福建省高校重点实验室 (53001703, 50013203) 资助

Supported by General Program of National Natural Science Foundation of China (61976055), Key laboratory of Intelligent Metro of Universities in Fujian Province (53001703, 50013203)

本文责任编辑 张军平

Recommended by Associate Editor ZHANG Jun-Ping

1. 福州大学数学与计算机科学学院 福州 350108 2. 福州大学智慧地铁福建省高校重点实验室 福州 350108 3. 广州航海学院海运学院 广州 510725

1. College of Mathematics and Computer Science, Fuzhou University, Fuzhou 350108 2. Key laboratory of Intelligent Metro of Universities in Fujian Province, Fuzhou University, Fuzhou 350108 3. College of Maritime, Guangzhou Maritime University, Guangzhou 510725

1958 年, Rosenblatt 提出感知器 Perceptron<sup>[2]</sup>, 可以自学习实现分类, 引发了第一次神经网络热潮。1969 年, Minsky 和 Papert 出版的 *Perceptrons* 一书指出简单线性感知器的功能有限性, 给予人工神经元网络研究沉重打击, 使得神经网络陷入 10 年低潮期<sup>[3]</sup>。1982 年 Hopfield 提出 Hopfield 模型理论<sup>[4]</sup>, 使人工神经网络的构造和学习有了理论指导, 再次激起学者们对神经网络的研究热情<sup>[5]</sup>。1986 年, Rumelhart 等用 BP 算法解决了 *Perceptrons* 一书中关于神经网络局限性的问题<sup>[6]</sup>, 此后获得了快速发展。但是, 1995 年随着 SVM 及统计学习的兴起<sup>[7]</sup>, 神经网络再次陷入低潮期。2006 年, Hinton 提出深层网络训练中梯度消失问题的解决方案, 并在 *Science* 上发表论文, 正式提出深度学习<sup>[8]</sup>。此后随着 GPU 不断

进步, 计算能力的不断提高, 深度神经网络的应用快速增长。2015年, LeCun等在*Nature*上撰文, 总结了DNN的大量成功应用, 尽管存在可解释性差的不足<sup>[9]</sup>。2017年, Hinton等又提出了胶囊网络(Capsule)<sup>[10]</sup>, 可解释性有所提高, 并在MNIST数据集上取得更好的效果。自此, 深度神经网络(DNN)研究<sup>[11-13]</sup>及应用进入爆发期, 在语音识别、图像处理<sup>[14]</sup>、自然语言处理<sup>[15]</sup>方面取得突破性进展, 带动巨大智能产业应用。

目前, 虽然DNN得到广泛应用并取得良好的效果, 但存在模型计算量庞大、模型验证复杂、可解释性差等缺点。而模糊系统通过一系列IF-THEN规则进行构建, 可解释性较强。1965年, Zadeh教授发表了开创性论文“Fuzzy sets”<sup>[16]</sup>, 标志着模糊系统理论的诞生。1975年, Mamdani基于该理论构建了模糊控制器, 成功应用于锅炉蒸汽机控制<sup>[17]</sup>。1992年Wang证明了模糊系统具有通用逼近性<sup>[18]</sup>, 并与Mendel提出WM方法<sup>[19]</sup>, 可从数据中自动产生出模糊系统, 但缺乏模型参数自学习能力, 1993年, Jang提出自适应神经模糊系统(Adaptive network-based fuzzy inference system, ANFIS)<sup>[20]</sup>, 使模糊系统具有较强的学习能力, 推动了模糊系统的发展。

模糊系统在处理低维小数据时具有较高的精度, 并得到较为广泛的应用<sup>[21]</sup>, 但处理高维大数据时模糊系统往往面临“维数灾难”问题。为适应大数据模糊系统, 目前研究主要采用降维, 减少规则数等方式进行改进, 虽然具有一定可行性, 但模型精度明显下降, 难以真正解决高维问题。

我们认为深度学习不仅仅包括深度神经网络, 也可以由其他系统构建而成。目前以模糊系统为基础构建的深度系统研究还非常少, 基本处于空白阶段<sup>[22]</sup>。结合模糊系统可解释强的特点, 我们提出了一种基于ANFIS的深度神经模糊系统(DNFS), 该系统采用自底向上的方式逐层构造, 通过分块、分层结构降低模型的运算量与复杂度, 不仅可以保持可解释性高的特点, 同时也可提高模糊系统的精度。

## 1 深度神经模糊系统构造

ANFIS在处理高维问题时往往面临“维数灾难”问题<sup>[18]</sup>, 我们采用分层分块结构方式构建DNFS, 将变量划分为若干组分别进行计算来降低数据维度。模型自下而上层层搭建, 以最终目标输出作为各层每个子模糊系统目标输出。本文提出了两种深度神经模糊系统DNFS1, DNFS2, 其基本结构分别如图1、图2所示。

DNFS1基本结构如图1所示, 系统输入为 $(x_1^0, x_2^0, \dots, x_n^0)$ , DNFS1每一层中每3组输入构成该层中一子模糊系统, 相邻两子模糊系统共享一个输入, 保证每个子模糊系统有2~3个输入, 第k层则由 $n_k$ 个子模糊系统 $NF$ 组成。在第1层神经模糊系统设计完毕后, 使用ANFIS方法进行训练(ANFIS方法具体详见文献[20]), 其输出构成第2层神经模糊系统的输入空间, 第2层输出作为第3层输入, 以此类推自底向上搭建, 直至整个DNFS1构造完成, 系统输出即顶层子系统 $NF_1^L$ 输出 $x_1^L$ (该结构设计基于专家经验)。

DNFS2的结构如图2所示。首先, 从输入空间 $(x_1^0, x_2^0, \dots, x_n^0)$ 中顺序选择3组数据 $x_1^0, x_2^0, x_3^0$ 构成DNFS2第1层的输入; 通过ANFIS方法训练第1层的 $NF_1^1$ 后, 得到的新的数据 $x_1^1$ , 基于新的数据与顺序选择的两组尚未进行运算的输入 $x_4^0, x_5^0$ 构成第2层子模糊系统 $NF_1^2$ 的输入; 第3层从尚未进行运算的系统总输入中再顺序选择两组 $x_6^0, x_7^0$ , 与第2层模糊子系统输出 $x_1^2$ 共同构成第3层子模糊系统 $NF_1^3$ 输入, 按此方式, 自底向上逐层搭建。中间第k层, 输入则为上一层子系统 $NF_1^{k-1}$ 输出 $x_1^{k-1}$ 与 $x_{2k}^0, x_{2k+1}^0$ 构成。直至第L层子模糊系统 $NF_1^L$ 完成, 整个DNFS2构造完成, 系统输出即为子模糊系统 $NF_1^L$ 输出 $x_1^L$ (DNFS2偏重降低计算量, 快速运算)。

## 2 DNFS算法

神经网络从信息处理角度对人脑神经元进行抽象, 运算模型由大量神经元相互联接构成, 通过神经元间参数传递、更新完成输入-输出间映射关系。以ANFIS为代表的模糊系统, 从数据中提取规则、完善规则构造输入-输出间映射, 模拟人类推理过程。由于IF-THEN规则便于理解, 使得模糊系统相较神经网络具有更好的可解释性。而以ANFIS为基础的DNFS, 从划分子系统、分块计算角度切入构造深度结构, 局部入手整合规则再推演至整体, 大幅度降低了计算复杂度, 又保证了可解释性。

DNFS算法应用考虑到ANFIS用于定义隶属函数和模糊规则的方法不同, 在DNFS不同子系统中的适用差异, 我们采用试算方式为子系统指定ANFIS聚类方法。本文算法流程如图3所示。

**步骤1.** 数据归一化, 并划分为训练集和测试集。

**步骤2.** 确定每层子系统输入大小。

**步骤3.** 依照DNFS基础结构, 设计第1层(下一层)神经模糊系统 $NF_i^1$  ( $i = 1, 2, \dots, n_1$ )。

**步骤4.** 根据ANFIS的网格划分、减法聚类、模糊C均值三种聚类方法, 按照顺序对每个子模糊系

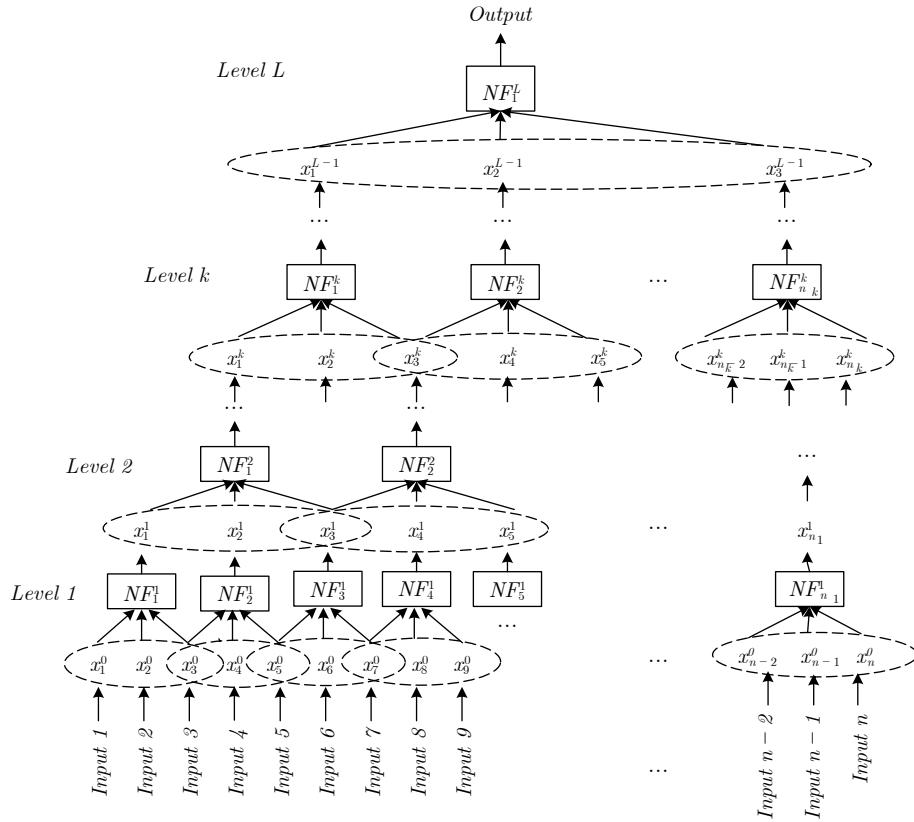


图1 DNFS1 基本结构

Fig.1 Basic structure of DNFS1

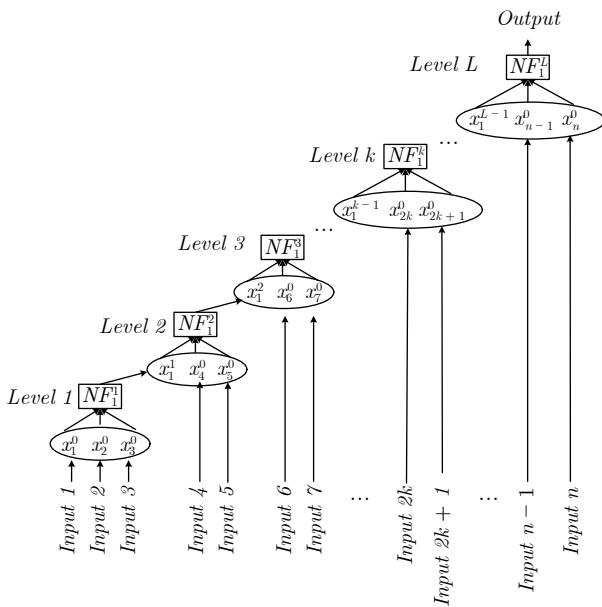


图2 DNFS2 基本结构

Fig.2 Basic structure of DNFS2

统进行训练, 依据训练效果为子模糊系统确定 ANFIS 设置方案(选取参考下文模型打分体系), 通过训练得到子系统模型.

**步骤5.** 重复步骤2~4, 层层构造, 以向上的方向计算DNFS来获得第 $k-1$ 层的输出.

**步骤6.** 假定DNFS的第1层至第 $k-1$ 层都已设计完毕, 接下来设计第 $k$ 层 $NF_i^k$ .

**步骤7.** 令 $k=k+1$ , 重复步骤5~6, 直到第 $L$ 层子系统 $NF_1^L$ 设计完成, 输出 $x_1^L$ 为DNFS系统输出.

### 3 实验

为对提出的DNFS算法进行评价, 我们引入经典浅层神经网络算法BP(Back propagation)、RBF(Radial basis function)、GRNN(General regression neural network), 常用的深度神经网络算法LSTM(Long short-term memory)、DBN(Deep belief networks), 以及ANFIS进行比较. 同时, 选择标准差(STD), 均方根误差(RMSE), 平均绝对误差(MAE)和对称平均绝对百分比误差(SMAPE)四个性能指标进行评估.

$$STD = \sqrt{\frac{1}{n-1} \sum_{i=1}^n |\hat{y}_i - \bar{y}|^2} \quad (1)$$

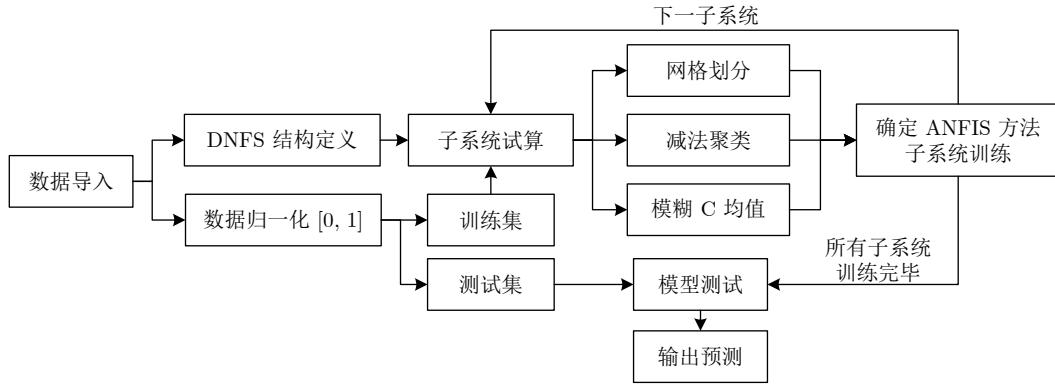


图3 DNFS 算法流程

Fig.3 DNFS algorithm flow

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (2)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (3)$$

$$SMAPE = \frac{1}{n} \sum_{i=1}^n \frac{2|\hat{y}_i - y_i|}{(|\hat{y}_i| + |y_i|)} \times 100\% \quad (4)$$

其中  $n$  为样本个数.  $\hat{y} = \{\hat{y}_1, \hat{y}_2, \dots, \hat{y}_n\}$  为预测值,  $y = \{y_1, y_2, \dots, y_n\}$  为真实值.

表1 简要描述了用于实验的4个数据集的属性(原始数据集由UCI机器学习库获得 <http://archive.ics.uci.edu/ml/datasets.php>),以及各自在DNFS1与DNFS2结构下的深度系统总层数(包含ANFIS模块内部5层结构).其中,SMW数据集包含智能手机检索数据及传感器智能手表检索数据.ONP数据集总结了两年期间Mashable发表的文章的一系列异质特征,预测社交网络分享数量(流行度).SUP数据集关于10 000个超导体及其相关特性,通过从超导体中提取的81个特征,来预测临界温度.BF数据集包含从博客文章中提取的280个数字特征,来预测帖子将收到多少评论,本文截取了部分来训练模型.

数据集中60%数据用于训练,篇幅限制,我们着重展示测试集效果.同时,为便于模型间综合效果评价,我们定义一个评价体系:对每项指标进行排序,以1分为底、以1分为间隔从劣到优进行打分,

模型最终得分为各指标得分之和,得分越高综合性能越好.

### 3.1 SMW 数据集应用

图4展示了SMW数据集下相应的DNFS深度结构(层数不包含子系统ANFIS模块5层结构,下同),图5展示了各算法在测试集中预测效果,其中横轴表示样本标号,纵轴表示算法给出的对应预测输出(下同).表2展示了SMW测试数据集中各算法、各项评价指标及综合得分情况.

从图5上看,各算法总体表现良好.从表2中STD与RMSE指标上看,GRNN与DNFS1差距较小,模型预测值与真实值间的误差起伏波动不大,相对较为稳定.MAE指标上,DNFS2与DNFS1较为靠近,预测误差较小,而在SMAPE上,DBN与GRNN算法也是具有竞争力的预测模型.但总体而言,低维度问题中DNFS1更具优势.

### 3.2 ONP 数据集应用

图6展示了ONP数据集下相应的DNFS深度结构,图7为各算法在测试集中的预测效果,表3展示了ONP测试数据集中各算法各项指标及综合得分情况.

从图7上看,测试过程中BP、ANFIS、DNFS1出现了明显异常值,以ANFIS最为明显,侧面说明了以牺牲模型准确度为代价降低模型复杂度的AN-

表1 实验数据集

Table 1 Experimental data set

项目编号	数据集	输入维度	输出维度	样本数	DNFS1总层数	DNFS2总层数
1	Smartwatch_sens (SMW)	12	1	12 000	15	30
2	Online News Popularity (ONP)	59	1	20 000	25	145
3	Superconductivity (SUP)	81	1	10 000	30	200
4	BlogFeedback (BF)	271	1	15 000	40	675

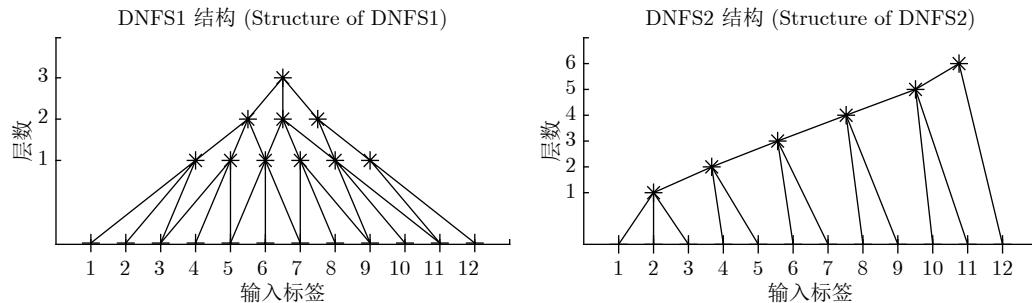


图4 SMW 数据集深度结构  
Fig.4 The deep structure of SMW data set

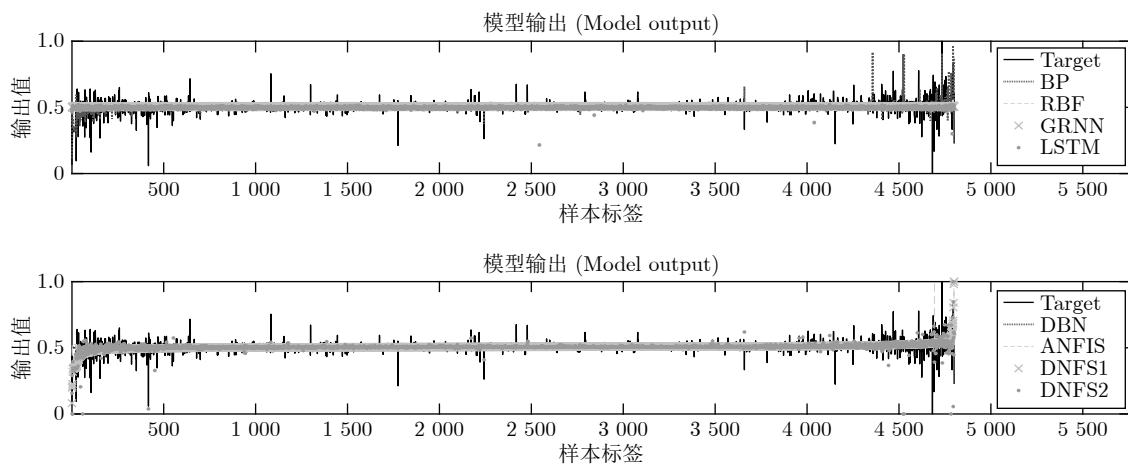


图5 SMW 测试集预测效果  
Fig.5 Prediction effect of SMW test set

表2 SMW 测试集评价指标  
Table 2 Evaluation index of SMW test set

	BP	RBF	GRNN	LSTM	DBN	ANFIS	DNFS1	DNFS2
STD	0.038869	0.038510	0.038441	0.039385	0.038596	0.039398	<b>0.037643</b>	0.040971
RMSE	0.038865	0.038506	0.038437	0.040219	0.038592	0.039397	<b>0.037640</b>	0.040970
MAE	0.017789	0.018355	0.017081	0.020928	0.017088	0.017965	<b>0.016639</b>	0.016834
SMAPE	3.5849 %	3.7368 %	3.4864 %	4.2653 %	3.4872 %	3.6510 %	<b>3.3553 %</b>	3.5535 %
Score	16	16	27	7	21	11	<b>32</b>	14

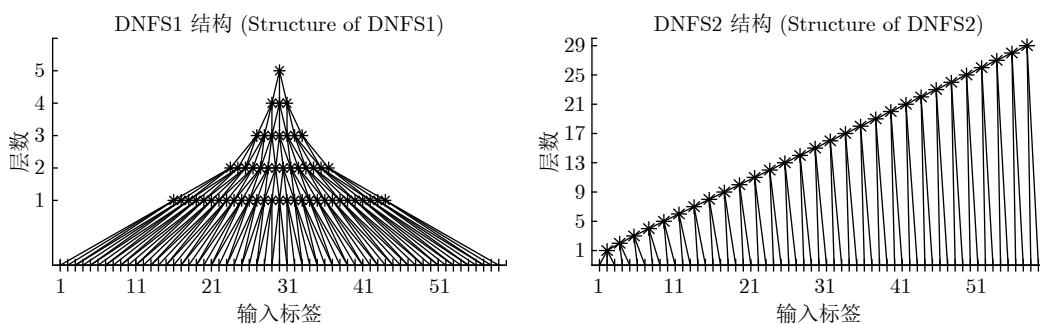


图6 ONP 数据集深度结构  
Fig.6 The deep structure of ONP data set

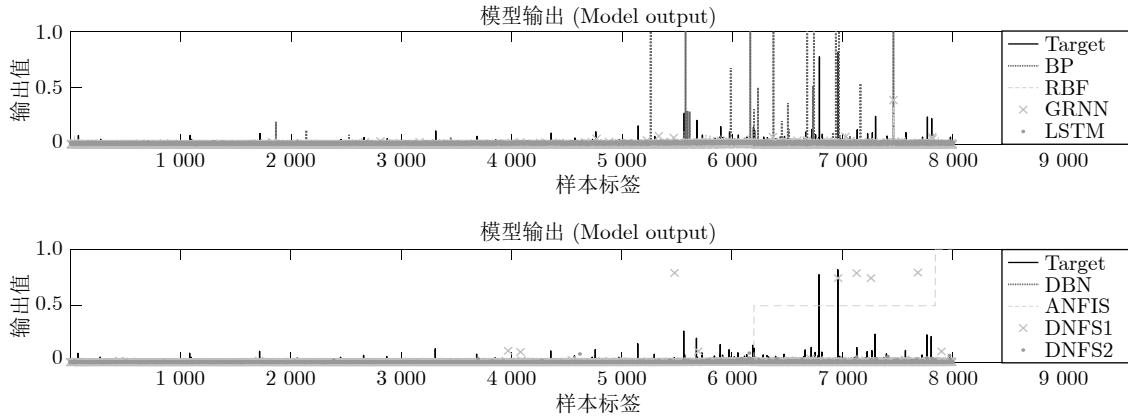


图 7 ONP 测试集预测效果  
Fig.7 Prediction effect of ONP test set

表 3 ONP 测试集评价指标  
Table 3 Evaluation index of ONP test set

	BP	RBF	GRNN	LSTM	DBN	ANFIS	DNFS1	DNFS2
STD	0.040148	0.017565	0.016941	0.016321	0.016217	0.234585	0.025012	<b>0.016195</b>
RMSE	0.040173	0.017567	0.016941	0.018827	0.016216	0.263966	0.025011	<b>0.016195</b>
MAE	0.005824	0.005347	0.004060	0.011639	0.004153	0.123609	0.004400	<b>0.003975</b>
SMAPE	83.1325 %	110.4412 %	<b>77.8989 %</b>	136.6059 %	88.0204 %	106.8444 %	78.3964 %	79.4094 %
Score	12	15	26	13	24	6	18	<b>30</b>

FIS 不利于处理高维问题。在 STD 与 RMSE 上, DBN 与 DNFS2 较小, 模型预测误差波动小, 较为稳定。从 MAE 上看, GRNN 与 DNFS2 差距较小, 而 SAMPE 上看, GRNN 相对较优。总体上看, 随着维度的升高, DNFS1 预测性能在下降, 而 DNFS2 则有所上升。

### 3.3 SUP 数据集应用

图 8 展示了 SUP 数据集下相应的 DNFS 深度结构, 图 9 展示了各算法在 SUP 测试集中的预测效

果, 表 4 展示了 SUP 测试数据集中各算法各项指标及综合得分情况。

从图 9 上看, ANFIS 出现了明显异常值, 而 DBN 则出现了在某一区间内波动的异常情况, 不适合用于解决该数据问题。从表 4 综合评价分值上看, DNFS2 占据了主要优势为该问题理想模型, 其次为 BP 算法。在 STD 与 RMSE 指标上, BP 与 DNFS2 较为接近, 模型误差总体上波动不大。从 MAE 与 SAMPE 上看, BP 与 DNFS2 也具有优势, 预测模型精确度较好。随着维度的进一步增加, DNFS2 优势

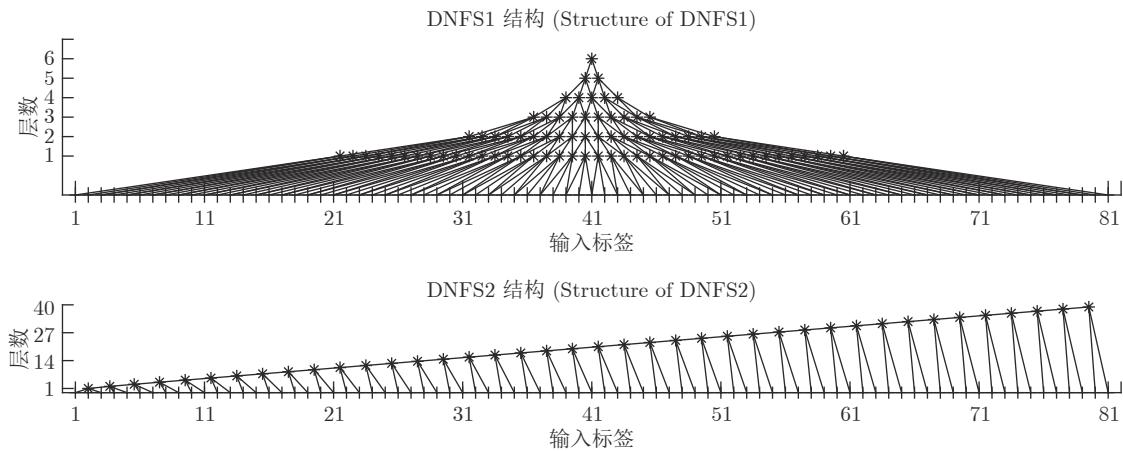


图 8 SUP 数据集深度结构  
Fig.8 The deep structure of SUP data set

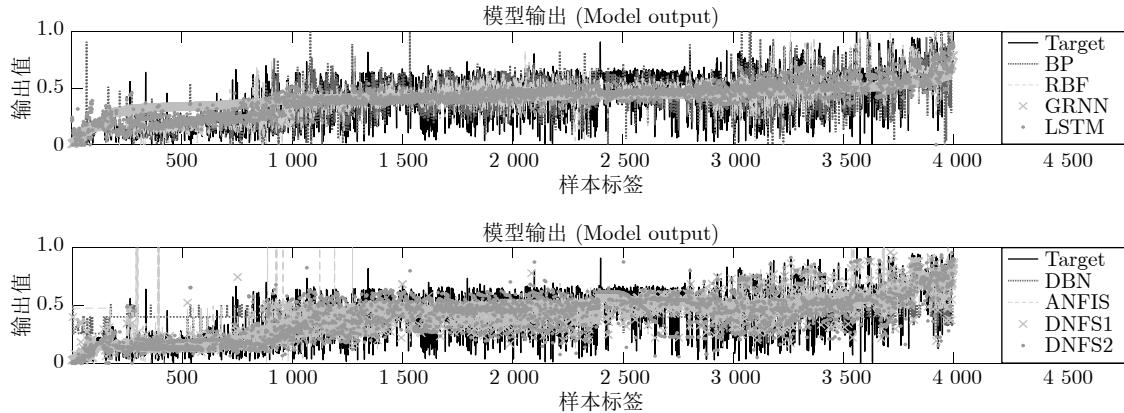


图9 SUP 测试集预测效果  
Fig.9 Prediction effect of SUP test set

表4 SUP 测试集评价指标  
Table 4 Evaluation index of SUP test set

	BP	RBF	GRNN	LSTM	DBN	ANFIS	DNFS1	DNFS2
STD	0.12385	0.13038	0.17493	0.15997	0.21074	0.16866	0.13415	<b>0.12293</b>
RMSE	0.12384	0.13038	0.17527	0.16004	0.21076	0.16972	0.13418	<b>0.12293</b>
MAE	0.08786	0.10038	0.14956	0.12958	0.18245	0.12657	0.10165	<b>0.08735</b>
SMAPE	30.1760 %	32.4668 %	43.0296 %	38.5752 %	51.2832 %	37.7120 %	31.2728 %	<b>28.7900 %</b>
Score	28	23	8	14	4	14	21	<b>32</b>

逐渐显现,不仅在精度上能够超越经典的BP算法,而且预测模型稳定性上也表现良好.

### 3.4 BF 数据集应用

由于BF数据集输入维度较高,相应DNFS深度结构图图线密集,故不再进行展示.图10展示了各算法在BF测试集中的预测效果,表5展示了BF测试数据集中各算法各项指标及综合得分情况.从图10上看,测试过程中BP、ANFIS出现了相当数量的异常值,其中以ANFIS最为明显.普通模糊系统在处理高维问题过程中,往往存在模糊规则数量暴增、模型复杂度指数级增长的问题.为处理高维问题,实验中ANFIS通常以减少模糊规则数量的方式简化模型,但随之带来模型准确度大幅下降、模型预测异常的问题.

从表5上看,总体DNFS2优势明显.从STD、RMSE指标上看,由于BP、ANFIS预测过程中的异常波动,指标数值相对偏高. ANFIS预测模型的大量异常预测,在MAE与SMAPE指标上也得到了体现.随着维度的增加,DNFS2优势显现,与以BP算法为代表的算法存在过拟合情况不同,以IF-THEN规则为基础支撑的DNFS2在保障预测模型精度、稳定性的同时,还能发挥模糊系统可解释性强的特

点,对处理高维大数据建模问题,理解模型的输入输出映射关系具有参考价值.

## 4 结论与展望

通过实验可以看出,DNFS处理高维问题具有一定可行性.与经典的算法相比,DNFS具有以下优势:

1)DNFS以ANFIS作为基础,从数据中学习模糊规则,通过IF-THEN规则完成输入与输出间的映射,便于理解,克服了DNN可解释性差的问题.一旦输出有错误,DNFS可以根据IF-THEN规则溯源,快速找到错误的规则通过调整进行更正.

2)基于分层分块思想,DNFS为模糊系统解决高维大数据问题开辟了新道路,相比于传统模糊系统直接对整个数据集进行处理,模型复杂度大为降低,精度得到了明显提高,适合用于处理大数据,是一种具有潜力的新型深度学习算法.

目前DNFS的研究处于初级阶段,系统的结构与参数有待进一步优化.在今后的工作中,我们将从优化DNFS基本结构、对系统分块组合方式进行深入研究,以进一步提高系统性能.此外,我们还将结合卷积运算,形成DCNFS(Deep convolution neural fuzzy system)以处理图像等计算机视觉问题.

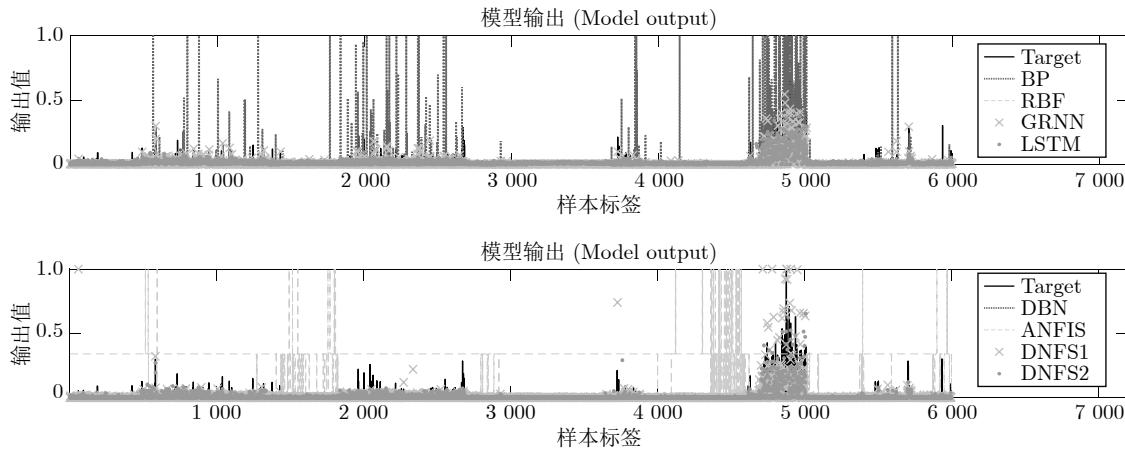


图 10 BF 测试集预测效果  
Fig.10 Prediction effect of BF test set

表 5 BF 测试集评价指标  
Table 5 Evaluation index of BF test set

	BP	RBF	GRNN	LSTM	DBN	ANFIS	DNFS1	DNFS2
STD	0.10900	0.04217	0.04322	0.03355	0.04457	0.09683	0.04465	<b>0.03155</b>
RMSE	0.10973	0.04259	0.04324	0.03398	0.04457	0.33922	0.04466	<b>0.03156</b>
MAE	0.02304	0.01112	0.01120	0.01409	0.01607	0.32630	0.01028	<b>0.00859</b>
SMAPE	54.675 %	76.842 %	81.804 %	96.684 %	102.462 %	142.341 %	64.263 %	<b>54.162 %</b>
Score	12	23	19	21	13	5	19	<b>32</b>

## References

- 1 McCulloch W S, Pitts W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biology*, 1943, **10**(5): 115–133
- 2 Rosenblatt, F. The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 1958, **65**: 386–408
- 3 Minsky M L, Papert S A. Perceptrons. *American Journal of Psychology*, 1969, **84**(3): 449–452
- 4 Hopfield J J. Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences of the United States of America*, 1982, **79**(8): 2554–2558
- 5 Lv Y S, Chen Y Y, Zhang X Q, Duan Y J, Li N Q. Social media based transportation research: The state of the work and the networking. *IEEE/CAA Journal of Automatica Sinica*, 2017, **4**(1): 19–26
- 6 Rumelhart, David E, Hinton, Geoffrey E, Williams, Ronald J. Learning representations by back-propagating errors. *Nature*, 1986, **323**(6088): 533–536
- 7 Cortes C, Vapnik V. Support-vector networks. *Machine Learning*, 1995, **20**(3): 273–297
- 8 Hinton, G. E. Reducing the dimensionality of data with neural networks. *Science*, 2006, **313**(5786): 504–507
- 9 LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*, 2015, **521**(7553): 436–444
- 10 Sabour S, Frosst N, Hinton G E. Dynamic routing between capsules. In: Proceedings of the 31st Conference on Neural Information Processing Systems (NIPS 2017), Long Beach, CA, USA. 2017. 1–11
- 11 Guha A, Ghosh S, Roy A, Chatterjee S. Epileptic seizure recognition using deep neural network. *Emerging Technology in Modelling and Graphics*. Springer, Singapore, 2020. 21–28
- 12 Kantz E D, Tiwari S, Watrous J D, Cheng S. Deep neural networks for classification of lc-ms spectral peaks. *Analytical Chemistry*, 2019, **91**(19): 12407–12413. DOI: 10.1021/acs.analchem.9b02983
- 13 Liu B S, Chen X M, Han Y H, Li J J, Xu H B, Li X W. Accelerating DNN-based 3D point cloud processing for mobile computing. *Science China. Information Sciences*, 2019, **32**(11): 36–46
- 14 Mercedes E, Paoletti. Deep pyramidal residual networks for spectral-spatial hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, **57**(2): 740–754
- 15 Yang H, Luo L, Chueng L P, Ling D, Chin F. Deep learning and its applications to natural language processing. *Deep Learning: Fundamentals, Theory and Applications*. Springer, Cham, 2019. 89–109
- 16 Zadeh, L.A. Fuzzy sets. *Information & Control*, 1965, **8**(3): 338–353
- 17 Mamdani E H, Baaklini N. Prescriptive method for deriving control policy in a fuzzy-logic controller. *Electronics Letters*, 1975, **11**(25): 625–626
- 18 Wang L X. Fuzzy systems are universal approximators. In: Proceedings of the 1992 IEEE International Conference on Fuzzy Systems. San Diego, CA, USA: IEEE, 1992. 1163–1170
- 19 Wang L X, Mendel J M. Generating fuzzy rules by learning from examples. *IEEE Transactions on Systems, Man and Cybernetics*, 1992, **22**(6): 1414–1427
- 20 Jang J S R. ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems Man and Cybernetics*, 1993, **23**(3): 665–685
- 21 Sun B X, Gao K, Jiang J C, Luo M, He T T, Zheng F D, Guo H Y. Research on discharge peak power prediction of battery based on ANFIS and subtraction clustering. *Transactions of China Electrotechnical Society*, 2015, **30**(4): 272–280
- 22 Chen Wei-Hong, An Ji-Yao, Li Ren-Fa, Li Wan-Li. Review on deep-learning-based cognitive computing. *Acta Automatica Sinica*, 2017, **43**(11): 1886–1897  
(陈伟宏, 安吉尧, 李仁发, 李万里. 深度学习认知计算综述. 自动化学报, 2017, **43**(11): 1886–1897)



赵文迪 福州大学数学与计算机科学学院, 智慧地铁福建省高校重点实验室科研助理. 主要研究方向为深度学习, 模糊系统.  
E-mail: wdzhao@aliyun.com  
**(ZHAO Wen-Di** Research assistant of the Key Laboratory of Intelligent Metro of Universities in Fujian Province, College of Mathematics and Computer Science, Fuzhou University. His research interest covers deep learning and fuzzy systems.)



陈德旺 福建省“闽江学者”特聘教授, 福州大学数学与计算机学院教授. 主要研究方向为深度学习, 模糊系统和智能交通系统. 本文通信作者.  
E-mail: dwchen@fzu.edu.cn  
**(CHEN De-Wang** Distinguished professor of “Minjiang Scholars” in Fujian Province, professor at the School of Mathematics and Computers, Fuzhou University. His research interest covers deep learning, fuzzy systems and intelligent transportation systems. Corresponding author of this paper.)



卓永强 广州海航学院海运学院教授. 主要研究方向为船舶运动智能控制, 海上交通系统工程和模糊系统.  
E-mail: zhuoyq@aliyun.com  
**(ZHUO Yong-Qiang** Professor at the Maritime College, Guangzhou Maritime University. His research interest covers intelligent control of ship motion, marine traffic system engineering and fuzzy systems.)



黄允浒 福州大学数学与计算机科学学院博士研究生. 主要研究方向为机器学习, 模糊系统与智能交通系统.  
E-mail: N190310001@fzu.edu.cn  
**(HUANG Yun-Hu** Ph. D. candidate at the College of Mathematics and Computer Science, Fuzhou University. His research interest covers machine learning, fuzzy systems and intelligent transportation systems.)