



研究与开发

基于多层感知机模型的天线方位角诊断

陈向荣

(中国移动通信集团福建有限公司, 福建 福州 350001)

摘要: 作为影响移动通信质量的关键因素, 天线方位角的准确性将直接影响网络优化质量。提出一种基于多层感知机的天线方位角诊断方法, 将方位角分为 12 个区间类别, 每个类覆盖 30° 范围, 即 $[0, 30^\circ)$ 记为类别 0, ..., $[330^\circ, 360^\circ)$ 记为类别 11, 利用多层感知机算法识别天线方位角的区间, 自动识别天线方位角的角度范围, 为网络优化 (网优) 工程师判断实际的网络覆盖问题提供了有效的数据支撑, 在核查天线性能方面极大地减少了工作量, 降低了人工成本。实验结果表明, 该方法能够有效快速判别天线方位角区间类别, 识别准确率达到了 92.6%, 高于随机森林和逻辑回归分类算法的分类准确率。

关键词: 天线方位角; 多层感知机; 反向传播算法; 神经网络; 网络优化

中图分类号: TP391

文献标识码: A

doi: 10.11959/j.issn.1000-0801.2021061

Antenna azimuth diagnosis based on multi-layer perceptron model

CHEN Xiangrong

China Mobile Communications Group Fujian Co., Ltd., Fuzhou 350001, China

Abstract: Antenna azimuth was seen as a key factor in the quality of mobile communications, and its accuracy will directly affect the quality of network optimization. An antenna azimuth diagnosis method was proposed based on multi-layer perceptron. The azimuth was divided into 12 interval classes, each class covered a range of 30° , that was, $[0, 30^\circ)$ was recorded as class 0, ..., $[330^\circ, 360^\circ)$ was recorded as class 11. The multi-layer perceptron algorithm was used to identify the range of the antenna azimuth angle and automatically identify the angle range of the antenna azimuth angle, which provided effective data support for the network optimization engineer to determine the actual network coverage problem, and greatly reduced workload and labor cost in verifying antenna performance. Experimental results show that the method can effectively and quickly discriminate the antenna azimuth interval class, and the recognition accuracy reaches 92.6%, which is higher than the classification accuracy of random forest and logistic regression classification algorithms.

Key words: antenna azimuth angle, multi-layer perceptron, back propagation algorithm, neural network, network optimization

1 引言

随着移动互联网的高速发展,通过移动蜂窝网络接入互联网的用户数持续增长,用户对移动网络的需求日益增大,访问网络的数据量也随之高速增长,而且用户对网络质量的要求逐步提升。保障一个良好的网络环境,提高用户使用感知,成为移动网络优化工作的重中之重,这给网络优化的工作效率和质量的保证带来了巨大的挑战。在移动网络优化工作中,天线方位角的严重偏差将会很大程度上影响到网络优化效果和网络服务质量,作为日常网络优化基础数据的天线方位角,其准确性与否将直接导致网络优化质量的好坏。

当前,天线工参的数据大多依赖人工通过罗盘、坡度仪等工具进行测量,数据的准确性与工作人员的测量技术的熟练度和细心程度有很大的关系,时常出现数据的漏报和误报情况。过分依赖人工的检测,既无法保障测量数据的实时性,测量效率也很低。天线方位角作为天线工参中极为重要的一部分信息,核查的方法主要是通过工程优化人员到达基站现场,利用指南针贴近天线下方沿进行方位角读取测量并手工记录,同时,结合室外天线、RRU (radio remote unit) 和室内 BBU (base band unit) 的线缆连接查询,最终完成小区的天线覆盖方向确认,而对于铁塔和壁挂类型的天线方位角的测量,则由持有登高证的工作人员对天线方位角进行确认,由此,天线方位角的测量和确认工作需要投入大量的人工成本,且数据的准确性和及时性无法保障。随着网络规模的日益增大以及多制式多频段多层网络的出现,持有登高证的工作人员核查天线方位角的工作量急剧增加,人工测量的方法已极大地影响网络维护、网络优化等工作的效率及质量,进而降低了用户使用网络感知,也增加了用户的投诉概率。如何利用大数据挖掘技术手段,实现天线方位角自动采集及异常预警,是当下亟须解决的问题。

随着大数据技术的日趋成熟,越来越多深度学习的方法应用到网络智能优化的场景中。在移动通信网络优化中,已具有大量的基础设施(如基站、交换机和传输设备等)的运行维护数据,还有 OTT (over the top) 应用的数据(如位置、时间和内容等)。本文将方位角分为 12 个区间,每个区间覆盖 30° 范围,即“0”表示 $[0, 30^\circ)$,“1”表示 $[30^\circ, 60^\circ)$, ..., “11”表示 $[330^\circ, 360^\circ)$ 。结合运行维护和 OTT 数据,利用分类算法预测天线方位角的区间类别,实现方位角的智能诊断预警,对天线方位角进行智能核查,为及时发现网络问题和网络质量优化提供有效的数据支撑。智能分类方法主要包括决策树、随机森林、支持向量机 (support vector machine, SVM) [1-3]、贝叶斯网络[4-5]、专家系统[6-7]、模糊理论[8-10]、神经网络[11-13]、极限学习机[14]等。然而,随着神经网络技术的日趋成熟,已经提出了很多较好的神经网络模型,Rumelhart 等[15]于 1986 年提出了多层感知机模型的反向传播 (back propagation, BP) 算法。多层感知机 (multi-layer perceptron, MLP) 神经网络是目前研究最多,应用最广的模型[16],多层感知机属于前向神经网络[17]。本文利用多层感知机的 BP 算法对天线方位角区间类别进行识别,并与基于随机森林和多元逻辑回归算法的分类结果进行对比,结果显示,基于多层感知机的天线方位角智能分类效果较好,能够精确识别天线方位角的区间范围,为天线方位角的异常诊断预警提供有效的数据支撑。

2 多层感知机

2.1 多层感知机模型结构

多层感知机最主要的特点是有多个神经元,因此也叫深度神经网络 (deep neural network, DNN)。第一层称为输入层,最后一层称为输出层,中间层称为隐层,其中,隐层的数量和输出神经元的个数可根据具体应用进行选择。



3 层感知机的网络结构如图 1 所示。




图 1 3 层感知机的网络结构

图 1 中输入层有 P 个神经元，其激励函数为恒等函数；隐层有 Q 个神经元，其神经元激励函数为常用的 Sigmoid 函数；输出层有 L 个神经元（处理单元），其神经元激活函数（变换函数）为线性函数。 $x_1, x_2, \dots, x_P$ 表示输入层的输入； b_1, b_2 表示不同节点的偏置值；权向量 $\omega = [\omega_{11}, \omega_{12}, \dots, \omega_{P+1,Q}]^T$ 表示连接输入层和隐层各神经元的 $(P+1) \times Q$ 维权值；权向量 $v = [v_{11}, v_{12}, \dots, v_{L,Q+1}]^T$ 表示连接隐层和输出层各神经元的 $L \times (Q+1)$ 维权值； $y_1, y_2, \dots, y_L$ 表示输出。多层感知机的流程分为前向传播过程和反向传播过程，其中，前向传播过程是指信息从第一层逐层进行传递，计算方法如下：

$$y_c = \sum_{j=0}^{Q+1} v_{cj} S\left(\sum_{i=0}^N \omega_{ji} x_i\right) \quad (1)$$

其中， $c=1, 2, \dots, L$ ， $S(\cdot)$ 表示常用的函数，即：

$$S(z_i) = \frac{1}{1 + e^{-z_i}}, i=1, 2, \dots, Q+1 \quad (2)$$

前向传播即网络处于学习阶段，其学习过程为：首先，根据当前各层的权向量的值，对每个样本（即输入）作前向计算；然后，计算该网络的输出结果与期望值的差值，并与限定值进行比较，若小于限定值，则学习过程结束，否则反向传播逐层调整权向量值的大小，直到差值小于限定值。由此，多层感知机神经网络有以下几个优点：

- 对于具有高度非线性问题，多层感知机神经网络能够以任意精度逼近任何非线性连续函数；
- 具有很强的容错性和很快的处理速度，因为在神经网络中信息是分布存储和并行处理的；
- 具有较好的泛化能力，因为神经网络在训练时，可以从输入和输出的数据中发现规律性的特征，并逐层调整各权值大小，具有较强的自学习和自适应能力；
- 具有较强的数据融合能力，多层感知机神经网络可以同时处理定量特征变量和定性特征变量；
- 无须考虑各个子系统间的解耦问题，MLP 神经网络并没有明确限定隐层的数量和输出层神经元的个数，可根据实际应用选择相应的层数和输出层神经元的个数，因此对于单变量系统和多变量系统有通用的描述方式。

2.2 BP 算法

BP 神经网络的学习过程由信号的正向传播过程与误差的反向传播过程组成。正向传播过程是输入信号通过隐层和输出层节点的处理计算得到的网络实际输出值进一步与期望输出值进行对比，计算它们的差值，将其作为误差，若误差不在限定范围内，则转入学习过程的另一个阶段，即误差的反向传播过程。误差的反向传播过程是指将计算的误差通过隐层向输入层逐层地进行反传，并将误差分摊给各层的所有单元，以此作为调整各层权向量的值的根据，并反复地进行该过程。各层权向量的值不断修正的过程，即 BP 神经网络的学习过程。在输出的误差值减小到限定范围内或迭代的次数达到限定学习的次数时，BP 神经网络的学习过程将会停止。

由此，BP 神经网络算法是把样本集学习与训练的问题转化为代价函数的无约束最优化问题。

对于本文的 3 层感知神经网络, 设该网络从 $(P+1)$ 维输入空间 $\mathfrak{R}^{P+1}$ 到 L 维输出空间 $\mathfrak{R}^L$ 的非线性映射为: $G: y = g(x)$, 其中 $x = [x_1, x_2, \dots, x_p]^T$ 为扩展的输入向量, $y = [y_1, y_2, \dots, y_L]^T$ 为输出向量。图 1 中的 3 层感知神经网络所对应的非线性映射 G 可收敛于在闭区间内的连续函数或非线性映射, 这在参考文献[18-19]中得到了证明。假定训练样本集为 $\{x^i, d^i\}_{i=1}^P$, 且存在映射 $M: d^i = m(x^i)$, 则感知神经网络对该训练样本集进行学习, 即寻找最优的各层网络权值, 且在一定代价函数的条件下, 非线性映射 G 是映射 M 的最优逼近, 常用的代价函数表达式如下:

$$F(\omega, \nu) = \frac{1}{2P} \sum_{i=1}^P \sum_{k=1}^L (d_k^i - y_k^i)^2 \quad (3)$$

则上述最优化问题为: 求使得代价函数到最小所对应的最优权向量 ω^{opt} 和 ν^{opt} 的值, 即:

$$F(\omega^{\text{opt}}, \nu^{\text{opt}}) = \min_{\omega, \nu} F(\omega, \nu) \quad (4)$$

对于 3 层感知神经网络的隐层网络, 一般采用 SBPM 算法调整权值。对于输出层网络, 本文采用 Kalman 滤波算法[20-21]调整权值。

BP 神经网络的学习过程主要有 4 个步骤。

步骤 1 组成输入模式并由输入层通过隐层向输出层的正向传播过程, 即 BP 神经网络中的正

向传播的过程。

步骤 2 计算网络实际输出值与期望值的差值, 并作为误差, 若误差不在限定范围内, 则误差信号由输出层通过隐层向输入层逐层反向传播, 从而调整各层权值的“误差反向传播”过程。

步骤 3 由“正向传播”与“误差反向传播”反复进行的网络“记忆训练”过程。该过程主要是不断更新各层权向量, 直到找到最优权向量 ω^{opt} 和 ν^{opt} 的值。

步骤 4 网络趋向收敛即网络的总体误差趋向极小值的“学习收敛”过程。

在训练阶段中, 训练实例重复通过网络, 同时修正各个权值, 改变各层权值的目的是最小化训练集误差。继续网络训练直到此过程一直进行到网络输出的误差值减小到限定范围内或迭代的次数达到限定学习的次数时停止训练。因此, 训练的终止条件可以为使网络收敛到最小的误差, 也可以是设定的最大重复次数。本文 BP 算法的具体流程如图 2 所示。

3 数据实验与分析

3.1 实验设计

本文针对东南某省份 2018 年 1 月—6 月的 OTT 数据和实际测量的天线方位角进行训练和测试, 共计 26 854 条数据。首先利用测量的方位角




图 2 BP 算法流程



值将方位角方向划分为 12 个区间, 每个区间覆盖 30° 范围, 进而构建分类标签; 然后对数据进行栅格化处理; 为了验证模型的预测效果, 将数据集分为训练集和测试集两部分, 其中训练集数据占比 70%, 共计 18 798 条数据。最后, 利用多层感知机深度神经网络算法, 对训练数据集构建模型, 并对测试集的方位角的方向类别进行分类预测。将预测结果与真实标签进行对比验证, 评估模型效果。本文基于多层感知机的神经网络的天线方位角诊断流程如图 3 所示。

3.2 数据预处理

每个小区的 OTT 特征数据存在一定的差异性, 其值的大小范围并不完全相同, 且有的小区上报的采样点数量较多, 有的则较少。为了能够将每个小区的特征数据转化为一条训练数据, 则需要对每个小区的数据进行处理。首先对于各小区 OTT 数据特征中和正常数据差别很大的少量异常数据, 利用孤立森林 (isolation forest, IF) 算法进行识别并剔除; 然后以小区经纬度为中心点构建大栅格, 以距离小区经度或纬度的最大距离乘以 2 作为大栅格的长度。对于每个小区 900 个特征变量 (不包含标签字段) 的一条数据, 即 30×30 的栅格, 也可以看作大小为 30×30 的图像。将大栅格按照 30×30 划分成一个个小的栅格, 并给每个栅格填充此栅格中分布采样点的 RSRP 平均值, 由于每个小区的 RSRP 峰值并不相等, 所以本文不采用常规的归一化方法, 而是对每个小

区单独进行处理。针对每个小区的栅格数据, 将每个栅格的平均 RSRP, 除以最大的栅格平均 RSRP, 将栅格列表中的平均电平值数据单独取出, 并组成向量, 在 900 个栅格中, 发现共有 87 个栅格有采样点分布。由于神经网络激活函数对处理数据的范围有要求, 且在梯度下降的过程中, 如果每个维度的数据分布不同, 使用相同的学习率很难迭代到最优值。因此本文将栅格化的数据进行了归一化处理。

对于标签变量, 本文将小区工参中的方位角按照正北方向为 0° , 并以顺时针方向计算, 对方位角方向划分为 12 个区间, 每个区间覆盖 30° 范围, 即“0”表示 $[0, 30^\circ)$, “1”表示 $[30^\circ, 60^\circ)$, ..., “11”表示 $[330^\circ, 360^\circ)$, 以此构建天线方位角分类标签。数据预处理流程如图 4 所示。




图 4 数据预处理流程

3.3 实验结果分析

本文基于预处理后的训练数据集利用多层感知机的反向传播算法构建天线方位角诊断模型, 并对测试数据集进行分类预测, 得到准确率为 92.6%, 分类准确性较高。为了与本文基于多层感知机模型的天线方位角分类效果进行对比, 这里还分别利用了常用的分类算法随机森林和逻辑回




图 3 基于多层感知机的神经网络的天线方位角诊断流程

归两种算法对相同的数据集进行训练和测试,得到准确率分别为 68.7%和 73.4%。为了更清晰地了解 12 类方位角基于多层感知机模型的预测效果,本文利用混淆矩阵计算各类别的查准率 (Precision)、查全率 (Recall) 以及 $F1$ 得分 ($F1$ -score), 从而对基于多层感知机深度神经网络算法预测的每类的结果进行了评估。评估结果见表 1。

表 1 基于多层感知机的天线方位角预测的评价指标

类别	评价指标		
	查准率	查全率	$F1$ 得分
0	88.22%	84.51%	0.863 3
1	94.94%	96.03%	0.954 8
2	83.46%	88.04%	0.856 9
3	85.09%	87.45%	0.862 5
4	91.67%	87.92%	0.897 5
5	88.91%	80.33%	0.844 0
6	83.07%	86.89%	0.849 4
7	93.86%	94.97%	0.944 1
8	87.45%	87.45%	0.874 5
9	88.15%	89.20%	0.886 7
10	97.03%	95.89%	0.964 6
11	86.70%	87.12%	0.869 1

其中, 查准率 $\text{Precision} = \text{TP}/(\text{TP}+\text{FP})$, TP 表示真正例, 即被模型预测为正的样本, FP 表示假正例, 即被模型预测为正的负样本, 查全率 $\text{Recall} = \text{TP}/(\text{TP}+\text{FN})$, FN 表示假负例, 即被模型预测为负的正样本, $F1$ 得分 $F\text{-score} = 2 \times \text{Precision} \times \text{Recall} / (\text{Precision} + \text{Recall})$ 。

由表 1 可知, 将天线方位角分为 12 个区间, 并利用多层感知机深度神经网络算法, 对方位角进行诊断预测, 整体效果较好, 其中预测最差的类别为 5 (即方位角区间为 $[150, 180^\circ)$), 准确率为 88.91%, 召回率为 80.33%, $F1$ 得分为 0.844 0, 召回率略低, 但比随机森林和逻辑回归两种算法的整体准确率都要高很多, 预测最好的类别为 10

(即方位角区间为 $[300, 330^\circ)$), 准确率为 97.03%, 召回率为 95.89%, $F1$ 得分为 0.964 6。

4 结束语

本文基于多层感知机深度神经网络的方法对天线方位角的范围进行分类判别, 分类准确率较高。结果表明, 将天线方位角分为 12 个类别, 利用多层感知机的模型能够精准地预测天线方位角的范围类别。该方法已在东南某省份大数据平台上完成部署, 并对现网的天线方位角进行诊断, 取得了较好成果, 该方法能够快速精准地识别异常天线方位角范围, 为无线网络优化工作提供了有效的数据支撑。

为了更精准地核查效果, 下一步将针对天线方向角的合理性给出建议值, 在判断天线方位角是否偏移的同时考虑判断天线俯仰角是否偏移。

参考文献:

- [1] BENMAHAMED Y, TEGUAR M, BOUBAKEUR A. Application of SVM and KNN to Duval Pentagon 1 for transformer oil diagnosis[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2017, 24(6): 3443-3451.
- [2] ZHENG H B, LIAO R J, GRZYBOWSKI S, et al. Fault diagnosis of power transformers using multi-class least square support vector machines classifiers with particle swarm optimization[J]. IET Electric Power Applications, 2011, 5(9): 691-696.
- [3] 张溶芳, 许丹丹, 王元光, 等. 机器学习在物联网虚假用户识别中的运用[J]. 电信科学, 2019, 35(7): 136-144.
ZHANG R F, XU D D, WANG Y G, et al. Application of machine learning in the fake user identification of IoT[J]. Telecommunication Science, 2019, 35(7): 136-144.
- [4] 白翠粉, 高文胜, 金雷, 等. 基于 3 层贝叶斯网络的变压器综合故障诊断[J]. 高电压技术, 2013, 39(2): 330-335.
BAI C F, GAO W S, JIN L, et al. Integrated diagnosis of transformer faults based on three-layer Bayesian network[J]. High Voltage Engineering, 2013, 39(2): 330-335.
- [5] ROLIM J G, MAIOLA P C, BAGGENSTOSS H R. Bayesian networks application to power transformer diagnosis[C]//Proceedings of 2007 IEEE Lausanne Power Tech. Piscataway: IEEE Press, 2007: 999-1004.
- [6] LIN C E, LING J M, HUANG C L. An expert system for transformer fault diagnosis using dissolved gas analysis[J]. IEEE Transactions on Power Delivery, 1993, 8(1): 231-238.
- [7] 师瑞峰, 史永锋, 牟军, 等. 油中溶解气体电力变压器故障



- 诊断专家系统[J]. 电力系统及其自动化学报, 2014, 26(12): 49-54.
- SHI R F, SHI Y F, MU J, et al. Power transformer fault diagnosis expert system with dissolved gas analysis in oil[J]. Proceedings of the CSU-EPSA, 2014, 26(12): 49-54.
- [8] ATALAR F, KUNTMAN A. Diagnosis of power transformers faults using fuzzy logic method[C]//Proceedings of 2016 National Conference on Electrical, Electronics and Biomedical Engineering (ELECO). [S.l.:s.n.], 2016: 28-32.
- [9] NITU M C, ACIU A M, NICOLA C I. Power transformer fault diagnosis using fuzzy logic technique based on dissolved gas analysis and furan analysis[C]//Proceedings of 2017 International Conference on Optimization of Electrical and Electronic Equipment (OPTIM) & 2017 Intl Aegean Conference on Electrical Machines and Power Electronics (ACEMP). [S.l.:s.n.], 2017: 184-189.
- [10] 章坚武, 黄佳森, 周迪. 基于模糊理论与关联规则的入侵检测模型[J]. 电信科学, 2019, 35(5): 59-69.
- ZHANG J W, HUANG J S, ZHOU D. Intrusion detection model based on fuzzy theory and association rules[J]. Telecommunication Science, 2019, 35(5): 59-69.
- [11] SUN Y J, ZHANG S, MIAO C X, et al. Improved BP neural network for transformer fault diagnosis[J]. Journal of China University of Mining and Technology, 2007, 17(1): 138-142.
- [12] ZHANG Y J, CHEN E K, GUO P J, et al. Application of improved particle swarm optimization BP neural network in transformer fault diagnosis[C]//Proceedings of 2017 Chinese Automation Congress (CAC). Piscataway: IEEE Press, 2017: 6971-6975.
- [13] ZHANG Y, DING X, LIU Y, et al. An artificial neural network approach to transformer fault diagnosis[J]. IEEE Transactions on Power Delivery, 1996, 11(4): 1836-1841.
- [14] 苑津莎, 张利伟, 王瑜, 等. 基于极限学习机的变压器故障诊断方法研究[J]. 电测与仪表, 2013, 12(1): 21-26.
- YUAN J S, ZHANG L W, WANG Y, et al. Study of transformers fault diagnosis based on extreme learning machine[J]. Electrical Measurement & Instrumentation, 2013, 12(1): 21-26.
- [15] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors[J]. Nature, 1986, 323(6088): 533-536.
- [16] KRUSE R, BORGELT C, KLAWONN F, et al. Multi-layer perceptrons[M]. London: Springer London, 2013: 47-81.
- [17] CHOUDHARI C, JAINK V. An optimum decision making in cognitive radio via fuzzy neural network[J]. Inter J. Engineer, 2012, 1(5): 1-7.
- [18] HECHT-NIELSEN R. Theory of the backpropagation neural network[C]//Proceedings of International 1989 Joint Conference on Neural Networks. Piscataway: IEEE Press, 1989: 593-605.
- [19] FUNAHASHI K I. On the approximate realization of continuous mappings by neural networks[J]. Neural Networks, 1989, 2(3): 183-192.
- [20] KALMAN R E, BUCY R S. New results in linear filtering and prediction theory[J]. Journal of Basic Engineering, 1961, 83(1): 95-108.
- [21] GODARD D. Channel equalization using a Kalman filter for fast data transmission[J]. IBM Journal of Research and Development, 1974, 18(3): 267-273.

[作者简介]



陈向荣 (1974—), 男, 中国移动通信集团福建有限公司工程师, 主要研究方向为新技术在无线网络优化领域的应用。