



基于 DBN-Softmax 的电力通信网络带宽预测

李佳, 丛犁, 姜华, 胡杨, 徐梦

(国网吉林省电力有限公司信息通信公司, 吉林 长春 130021)

摘要: 随着电力通信网的变化, 电力通信网承载业务数据呈指数级增长, 对电力通信网的处理能力提出了更高要求。为保障通信网的服务质量, 针对目前网络带宽分配不合理现象, 提出基于深度置信的电力通信网络带宽预测算法, 该算法通过由限制玻尔兹曼机构成的深度置信网络获取能够完美表达网络带宽的特征, 实现对电力通信网规划阶段带宽的合理预测。实验结果表明, 与传统神经网络算法相比, 所提算法在预测精度和稳健性方面更具有优势, 可以提高电力通信网的承载能力, 为电力系统的安全稳定运行提供有力的保障。

关键词: 电力通信网; 深度置信; 机器学习; 带宽预测

中图分类号: TN913.7

文献标识码: A

doi: 10.11959/j.issn.1000-0801.2020155

Bandwidth prediction of power communication network based on DBN-Softmax

LI Jia, CONG Li, JIANG Hua, HU Yang, XU Meng

Information and Communication Company, State Grid Jilin Electric Power Co., Ltd., Changchun 130021, China

Abstract: With the change of the power communication network, the data of the bearer service of the power communication network has increased exponentially, which puts higher requirements on the processing capability of the power communication network. In order to guarantee the service quality of communication network, aiming at the current unreasonable distribution of network bandwidth, a bandwidth prediction algorithm based on deep confidence for power communication network was proposed. The deep confidence network formed by the Boltzmann machine was used to obtain the characteristics that could perfectly express the network bandwidth, and the reasonable prediction of the bandwidth of the power communication network planning stage was realized. The implementation results show that the proposed algorithm is more accurate and robust than neural network. It has the advantage of improving the carrying capacity of the power communication network and providing a powerful guarantee for the safe and stable operation of the power system.

Key words: power communication network, deep confidence, machine learning, bandwidth prediction

1 引言

电力通信网是支撑电网安全、稳定、可靠运行

的重要基础,也是智能电网建设的重要基础,为电力系统实现自动化、现代化、商业化、智能化提供强有力的保障。截至 2018 年年末,吉林通信网基本建成



OTN 光传输网, 以 10E 链路为主、覆盖全公司业务系统的高速数据传输网络。电力系统的蓬勃发展, 对电力通信的需求不断提高, 尤其是在通信系统的容量、传输速度及抗干扰能力等方面都实现质的飞跃^[1]。

当前电力通信网承载通信业务繁多, 主要包括但不局限于行政电话、视频会议、数据采集与监视控制系统、继电保护、能量管理系统、电力调度等, 相较于电力通信业务接入的速度, 电力通信网的可靠性研究显得极为缓慢。如何结合大数据提高电网管理效率, 增强电网的可靠性, 是亟待解决的问题^[2]。

加强对电力通信网带宽的预测, 根据预测的数据进行带宽分配和数据传输, 是提高可靠性的有效手段。电力通信网带宽预测的主要办法是利用数学模型对带宽预测问题进行分析, 模型的选择在预测环节起到至关重要的作用, 如果没有合理的建模方法, 那么预测效果会大大降低。带宽时间预测是常用的预测方法, 如回归分析、自回归移动平均和卡尔曼滤波等, 这些方法均是线性模型, 依靠估测模型的输入输出带宽, 实现对系统带宽的最优估计。但是并未考虑网络的动态性, 对网络带宽的实时预测精确不高, 导致预测精度不准确, 并不适用电力通信系统的非线性现象^[3]。人工神经网络的非线性时间序列模型, 进行分布式的学习和训练, 通过调节内部各层级节点层级关系和代价值, 预测网络带宽情况, 具有一定的稳健性和容错能力, 但该算法本身存在过学习与欠学习、易收敛到局部极小点等问题, 限制了该方法的实际应用^[4]。

为了解决这些问题, 本文提出一种基于深度置信网 (deep belief network, DBN) 的电力通信带宽预测算法, 该算法通过深度网络获取能够完美表达数据的特征, 从而使得分类或预测更容易, 本文对该方法的可行性进行验证。

2 深度置信网的相关原理

2.1 限制玻尔兹曼机

限制玻尔兹曼机 (restricted Boltzmann ma-

chine, RBM) 模型是借鉴了由水分子所构造的物理系统而实现的, 是一种随机神经网络模型^[5], 如图 1 所示。RBM 是一个层内节点无连接、层间全连接且对称无反馈的模型。可视层 v 表示输入数据, 其节点数设为 n ; 隐层 h 可视为一个特征提取器, 设其节点数设为 m ; W 是可视层和隐层间的连接权重。在给定可视节点条件下, RBM 中隐藏节点的分布可以是任意的指数族分布, 反之亦然。




图 1 RBM 的模型表示

2.2 Softmax 分类器

一般深度置信网络的顶层分类器有 3 种选择: 逻辑回归 (logistic regression, LR) 分类器、Softmax 回归 (Softmax regression) 分类器、线性分类器^[6]。单个 LR 分类器只能处理二分类问题, 有一定局限性, 而网络带宽预测是多分类问题, 故本文选择 Softmax 分类器, 该分类器以多项式分布为模型建模, 可以将该分类器泛化到多分类情况^[7]。

假设训练数据集 $\{(x^{(1)}, y^{(1)}), \dots, (x^{(m)}, y^{(m)})\}$ 已知, 其中数据的特征 $x^{(i)} \in R^{n+1}$, 即 x 的维度为 $n+1$, 由于 Softmax 为多分类器, 故其输出数据 $y^{(i)} \in \{1, 2, 3, \dots, k\}$ 。分类识别目标是预估每个输入特征 x 的每一种分类结果的概率, 所以, 损失函数 $h_\theta(x)$ 的形式如式 (1):

$$h_\theta(x^{(i)}) = \begin{bmatrix} p(y^{(i)}=1|x^{(i)}, \theta) \\ p(y^{(i)}=2|x^{(i)}, \theta) \\ \vdots \\ p(y^{(i)}=k|x^{(i)}, \theta) \end{bmatrix} = \frac{1}{\sum_{j=1}^k e^{\theta_j^T x^{(i)}}} \begin{bmatrix} e^{\theta_1^T x^{(i)}} \\ e^{\theta_2^T x^{(i)}} \\ \vdots \\ e^{\theta_k^T x^{(i)}} \end{bmatrix} \quad (1)$$

其中, $\theta_1, \theta_2, \dots, \theta_k \in R^{n+1}$ 是模型的参数, Softmax 回归的代价函数如式 (2) 所示, 其中 $\sigma\{\}$ 是一个二值函数, 当括号内表达式为真时其值为 1, 反之则值为 0。

$$J(\theta) = -\frac{1}{m} \left[\sum_{i=1}^m \sum_{j=1}^k \sigma\{y^{(i)} = j\} \log \frac{e^{\theta_j^T x^{(i)}}}{\sum_{l=1}^k e^{\theta_l^T x^{(i)}}} \right] \quad (2)$$

实际问题中希望 Softmax 分类器能够使得输出的误差最小, 即将上述的代价函数最小化。由于 $J(\theta)$ 的最小化问题目前还没有闭式解法, 常用梯度下降法和 L-BFGS 通过迭代找到最优解, 梯度公式如式 (3):

$$\nabla_{\theta_j} J(\theta) = -\frac{1}{m} \sum_{i=1}^m \left[x^{(i)} \left(\sigma\{y^{(i)} = j\} - p(y^{(i)} = j | x^{(i)}; \theta) \right) \right] \quad (3)$$

在本文中, 通常将式 (3) 加权重衰减项, 使用式 (4):

$$\nabla_{\theta_j} J(\theta) = -\frac{1}{m} \sum_{i=1}^m \left[x^{(i)} \left(\sigma\{y^{(i)} = j\} - p(y^{(i)} = j | x^{(i)}; \theta) \right) \right] + \lambda \theta_j \quad (4)$$

2.3 深度置信网

深度置信网 (DBN) 由若干个限制玻尔兹曼机 (restricted Boltzmann machine, RBM) 堆叠而

成, 可以理解是一个复杂的有向无环图, 堆叠的 RBM 以及对应的 DBN-Softmax 模型如图 2 所示。相较于神经网络的优势, 可通过深度网络获取能够完美表达数据的特征, 从而使得预测更简单^[8-9]。

图 2 (a) 为独立的 RBM, 底层 RBM 的输出作为下一个 RBM 的输入, 直到顶层分类器, 则可得到图 2 (b) 所示的 DBN 模型。在堆叠的 RBM 顶层加回归分类器即可得到一个完整的深度神经网络模型, 实现对数据的预测功能。

3 基于深度置信网的带宽预测算法

本文提出了基于深度置信网的电力通信网带宽预测方法, 由若干个限制玻尔兹曼机堆叠而成的 DBN 和 Softmax 分类器预测模型, 不同的 DBN 的网络深度, 带宽预测准确率不同, 该方法将以往带宽数据在预处理后直接作为深度网络结构的输入, 构造训练样本, 算法结构如图 3 所示。输入 X 可以用 $N \times O$ 表示, O 代表时间序列, N 为每个时间节点上的带宽值, N 的个数代表所需建立预测模型的先验知识。输入数据应该预处理, 所以本算法先将选取的数据做归一化处理, 再将其输入分类结构中, 网络深度和网络节点个数对预测精度也有很大影响, 其选取结果和仿真结果会在第 4 节讨论。




图 2 堆叠的 RBM 以及对应的 DBN-Softmax 模型




图3 基于深度置信网的电力通信网预测算法结构

4 电力通信网带宽预测仿真与分析

本节将对上文介绍的基于深度置信网的电力通信带宽预测算法进行仿真分析,模型参数的选择对实验的最终预测结果有着至关重要的影响,所以先分析模型网络深度和网络节点对预测准确性的影响。

在本次实验中,使用式(5)模拟时间序列:

$$S(t)=\cos\left(\frac{t}{25}\right)\sin\left(\frac{t}{100}\right)+\frac{t}{1000}+1, t \in[0,2100] \quad (5)$$

实验采用不同深度的 DBN-Softmax 结构对网络带宽进行预测,讨论预测正确率随深度的变化。为了简化网络,每个隐层选取相同的节点数,将每层节点数设置为 128,实验结果见表 1,当网络深度为 3 时,预测准确率最高,所以 DBN-Softmax 设置为 3 层。其次选择网络隐层节点数,神经元数量分别设置为 16、32、64、128 进行实验,实验结果见表 2,结果表明神经元数量选定为 64 时,预测准确性最高。

表 1 网络深度的影响

深度	预测准确率	训练时间/s
1	0.931	16.354 2
2	0.934	44.219 6
3	0.940	74.500 5
4	0.936	99.097 5

表 2 网络节点数的影响

节点数	预测准确率	训练时间/s
16	0.788	27.841 0
32	0.820	37.723 6
64	0.836	60.973 2
128	0.821	75.844 6

本实验中设置网络深度为 3,网络节点数为 64,测试集样采用式(5)所示序列,0~2 000 的数据用来训练,2 000~2 100 的数据用来预测,图 4 为原始数据曲线和预测数据曲线。




图4 原始数据曲线和预测数据曲线

图4(a)和图4(b)横坐标代表模拟生成数据序号,纵坐标代表模拟生成数据数值。在假定1-12月每月网络运行稳定的前提下,利用基于深度置信网的预测算法对网络带宽值进行预测,图5为实际带宽与预测带宽的比较,实验结果表明,该算法可以很好地预测电力通信网带宽。




图5 实际带宽与预测带宽的比较

为了定量地描述预测准确度,本文利用式(6)

加以描述说明。

$$\text{NMES} = \frac{\sum_{i=1}^M (y_i - \hat{y}_i)^2}{M\sigma^2} \quad (6)$$

其中, y_i 是实际带宽数据值, $\hat{y}_i$ 是带宽预测数据, M 是预测数据个数, σ^2 是数据的方差。为了对比其他算法在预测精度上的优势,设置网络深度为3,网络节点数为64,与传统神经网络进行对比实验,以均方误差为评价标准,实验结果见表3。

表3 神经网络与DBN-Softmax预测精度对比

网络	第一组	第二组	第三组
神经网络	0.087 6	0.085 0	0.079 8
DBN-Softmax	0.062 5	0.067 2	0.058 9

由表3可得, DBN-Softmax 预测算法优于神经网络算法,可以更好地应用在电力网络预测中。

5 结束语

电力通信网预测是电力未来发展的重要课题,准确地预测对提高电力通信网可靠性有重要的意义。本文提出一种基于深度置信网的带宽预测算法即 DBN-Softmax,实验结果表明,相较于神经网络预测算法,有更高的预测精度,有效地提升电力通信网络带宽预测的能力,从而可以减轻通信业务激增对电力通信网的压力,保障电力通信的可靠性。

参考文献:

- [1] 黄志才. 电力通信网可靠性研究[J]. 中国新通信, 2015, 17(18): 28-29.
HUANG Z C. Research on reliability of electric power communication network[J]. China New Communication, 2015, 17(18): 28-29.
- [2] 张俊宇. 电力通信网可靠性研究[J]. 通讯世界, 2016, 15(13): 140.
ZHANG J Y. Research on reliability of electric power communication network[J]. Communication World, 2016, 15(13): 140.
- [3] 郝治理, 刘春生, 周青松. 用于干扰对消的稀疏约束卡尔曼滤波算法[J]. 空军工程大学学报, 2020(2): 13-16.
HAO Z L, LIU C S, ZHOU Q S. Sparsely constrained Kalman filter algorithm for interference cancellation [J]. Journal of Air Force Engineering University, 2020(2): 13-16.



- [4] 涂锦, 冷正兴, 刘丁毅. 基于EMD和神经网络的非线性时间序列预测方法[J]. 统计与决策, 2020(8): 21-26.
TU J, LENG Z X, LIU D Y. Nonlinear time series prediction method based on EMD and neural network [J]. Statistics and Decision, 2020 (8): 21-26.
- [5] ZOU X Y. Deep learning 学习笔记整理系列[EB]. 2013.
ZOU X Y. Deep learning study notes sorting series [EB]. 2013.
- [6] CHEN H, MURRAY A F. Continuous restricted Boltzmann machine with an implementable training algorithm[J]. IEE Process.-Vision. Image Signal Process, 2003, 150(3): 153-158.
- [7] 景亚鹏. 基于深度学习的欺骗性垃圾信息识别研究[D]. 上海: 华东师范大学, 2014: 25-26.
JING Y P. Research on deceptive spam recognition based on deep learning [D]. Shanghai: East China Normal University, 2014: 25-26.
- [8] 张春霞, 姬楠楠, 王冠伟. 受限波尔兹曼机[J]. 工程数学学报, 2015(2): 159-173.
ZHANG C X, JI N N, WANG G W. Restricted boltzmann[J]. Journal of Engineering Mathematics, 2015 (2): 159-173.
- [9] 尹宝才, 王文通, 王立春. 深度学习研究综述[J]. 北京工业大学学报, 2015(1): 48-59.
YIN B C, WANG W T, WANG L C. Summary of deep learning research[J]. Journal of Beijing University of Technology, 2015(1): 48-59.

[作者简介]



李佳(1991-), 女, 国网吉林省电力有限公司信息通信公司工程师, 主要从事通信网络运行工作。



丛犁(1984-), 女, 博士, 国网吉林省电力有限公司信息通信公司高级工程师, 主要从事通信网运行管理工作。



姜华(1985-), 男, 国网吉林省电力有限公司信息通信公司工程师, 主要从事通信网调度管理工作。



胡杨(1988-), 男, 国网吉林省电力有限公司信息通信公司工程师, 主要从事通信网调度工作。



徐梦(1993-), 女, 国网吉林省电力有限公司信息通信公司助理工程师, 主要从事通信网络检修工作。