

基于深度置信网络的用电量预测方法研究

单新文¹, 李萌¹, 陶晔波¹, 夏元轶¹, 许坤洋², 查易艺¹

(1. 国网江苏省电力有限公司信息通信分公司, 江苏 南京 210024;

2. 江苏电力信息技术有限公司, 江苏 南京 210024)

摘要:随着智能电网的快速发展和社会总用电量的不断攀升,对用电量进行精准的预测对于保持电网安全稳定运行和提升社会效益具有重要意义。传统方法依赖众多的特征数据,且在预测方法选择上存在诸多缺陷,造成预测精度较差等问题。文中基于获取到的大量的用电量大数据,建立基于受限玻尔兹曼的深度置信网络模型对用电量数据进行预测,选择平均相对误差以及互相关系数等量化指标对预测模型进行评价,随后提出基于可视化的模型动态训练策略,对深度置信网络预测模型进行动态训练。基于现场实例对所提方法进行验证,结果表明,基于深度置信网络和可视化调整的用电量预测方法的综合准确率可达97.05%,相对于传统的支持向量机、神经网络以及长短时记忆网络等预测算法具有更高的准确率,对于电力协调分配和电力设备运维检修具有重要意义。

关键词:用电量预测;受限玻尔兹曼机;深度置信网络;可视化调整

中图分类号:TP39;TN99

文献标识码:A

文章编号:1673-629X(2021)0177-06

Research on Electricity Consumption Forecasting Method Based on Deep Belief Network

SHAN Xin-wen¹, LI Meng¹, TAO Ye-bo¹, XIA Yuan-yi¹, XU Kun-yang², CHA Yi-yi¹

(1. Information and Communication Company, State Grid Jiangsu Electric Power Co., Ltd.,

Nanjing 210024, China;

2. Jiangsu Electric Power Information Technology Co., Ltd., Nanjing 210024, China)

Abstract: With the rapid development of smart grids and the continuous increase of total electricity consumption in society, accurate forecasting of electricity consumption is of great significance for maintaining the safe and stable operation of the grid and improving social and economic benefits. Traditional methods rely on numerous feature data, and there are many defects in the selection of prediction methods, resulting in problems such as poor prediction accuracy. Based on the large amount of electricity consumption big data obtained, a deep belief network model based on Restricted Boltzmann was established to predict electricity consumption data and select quantitative indicators such as average relative error and cross-correlation coefficient to evaluate the prediction model. At the same time, a visualization-based model dynamic training strategy is proposed to dynamically train the deep belief network prediction model. The proposed method is verified based on field examples, and the results show that the comprehensive accuracy rate of the power consumption forecasting method based on deep belief networks and visual adjustments can reach 97.05%, which is compared with traditional support vector machines, neural networks and long and short-term memory networks. The prediction algorithm has higher accuracy rate, which is of great significance for the coordinated distribution of power and the operation and maintenance of power equipment.

Key words: electricity consumption forecasting; restricted Boltzmann machine; deep belief network; visual adjustment

0 引言

智能电网的快速发展,使得电网的可扩展性和可持续性特征日益凸显,而用电量预测问题是电网可扩展性和可持续性的重要部分。用电量预测问题根据预测时间的长短通常可以划分为:超短期预测、短期预测、中期预测和长期预测。在实际应用中,基于智能算

法研究用电量的短期预测和中期预测是目前研究的热点,同时对于电力协调分配、设备运维检修等等具有重要意义。具体的,文献[1]利用互信息理论分析各个产业用电量与社会经济变量之间的关联关系,之后基于随机森林方法对各个产业的用电量进行单独预测,从而实现社会总用电量的预测。该文献对主要产业的

收稿日期:2020-09-09

基金项目:国家电网公司科技项目(B310ED193NPU)

作者简介:单新文(1991-),男,硕士,工程师,研究方向为电力信息化建设运维。

用电量进行预测,之后得到全社会用电,方法需要分类统计各个产业用电量的数据,数据较难精确获取,且随机森林方法存在的过拟合问题也较难解决^[2]。文献[3]利用套索算法选择影响因素,之后利用高斯过程回归进行预测。文献[4]在进行预测时考虑温度梯度的变化,量化分析了温度对用电量的影响。文献[5]利用了长短时记忆网络对短期用电量数据进行预测,相对于 BP 神经网络算法具有更高的准确性。然而,利用 LSTM(long short term memory, LSTM)算法进行预测无法彻底解决误差偏移的问题^[6]。同样利用 LSTM 方法对用电量进行预测的还有文献[7]提出的融合收敛较差映射和 LSTM 融合的用电量预测方法。文献[8]考虑了温度的对用电数据的影响,采用 LSTM 作为预测模型实现预测,该文献同样没有解决误差偏移的问题。随着四表合一工程的推进^[9],文献[10]针对单个用户的用电量进行预测,预测过程中考虑电、水、气三表的数据,采用支持向量机作为预测模型,然而,支持向量机的核函数选择问题以及全局寻优问题没有得到很好的解决。文献[11]提出从时序的用电数据中提取多个静态特征与时间序列数据一起作为预测模型的输入数据实现预测。文献[12]利用灰色关联分析对数据进行预处理,利用 BP 神经网络作为预测模型,实现用电量的预测,然而该方法尽管计算方便,但 BP 神经网络却忽略了用电量时间上的序列特征。文献[13]利用 K 向量近邻方法选择与带预测日期相似的场景,并基于模糊 C 均值法进行聚类以此来获得预测结果。然而,这种依赖于历史场景的预测方法,缺乏对时序数据全过程变化规律的考虑。为了解决上述问题,该文提出了基于深度置信网络模型和可视化调整的用电量预测方法。

首先,对采集到的海量用电量实测数据进行清洗,补全缺失的数据,剔除异常数据;之后构建基于深度置信网络的预测模型,利用海量数据训练网络,获得用电量预测结果;选择平均相对误差和互相关系数综合评价预测结果的准确率,进一步的,基于可视化技术,实时监控实际值与预测值之间的变化情况,并以此作为进一步训练的依据。

1 数据清洗

用电量监测数据通常来源于电力调度中心,然而,在实际应用中,由于数据存储、人工误操作等等问题,会导致出现数据丢失以及奇异值、极值等异常数据等问题^[14-16]。这些异常数据的存在将极大影响预测的准确率,因此,需要在进行预测之前对异常数据进行处理,主要包括数据补缺以及异常数据处理等两个部分。

1.1 数据补缺

数据补缺主要针对数据丢失的情况,即补充那些在数据采集、存储以及取用过程中丢失的值。对于数据补缺而言,即是用一个新的数据去补充一个没有的数据,因此,应该选用较为保守的方法进行,以达到在补全过程中最大程度保留原始数据信息特征的目的。由于用电量数据通常是平稳序列,且呈现较好的周期性,所以本研究使用三次样条插值对确实数据进行补充。基于一个实际的案例,进行数据补缺之后的结果如图 1 所示,图中圆形为原始数据,星形为补全的数据。由图中所示,基于三次样条插值可以实现对缺失数据的有效补缺。




图 1 数据补缺示意图

1.2 异常数据处理

除了对缺失数据进行补充之外,对于由于电磁干扰、数据传输异常等导致的奇异值,也需要通过相应的方法进行去除,以提高预测的准确性,本研究中利用信号处理过程中常用的 3δ 法对异常数据进行识别^[17]。 3δ 异常数据识别方法的原理为:若一个信号序列呈正态分布,其偏离正态分布中心过远(超过 3δ ,其中 δ 为正态分布的方差)的数据可视为奇异值予以剔除。从概率角度来看,即将距离数据分布中心最远的 0.3% 的数据视为奇异值予以剔除,仅保留原 99.7% 的数据。通常的,用样本的标准差 S 替换 δ 。基于 3δ 的异常数据处理法的步骤为:

- (1) 计算用电量监测数据序列中两个连续测量点之间的差值的正态分布参数:均值与标准差;
- (2) 用样本的均值和标准差对原始的用电量监测数据序列中的每个数据监测值进行判断;
- (3) 当监测数据与均值之间的差值大于三倍的标准差时,则该点为异常点;
- (4) 用异常点前后各一周监测数据的均值替代该异常数据。

基于一个实际的案例,进行异常数据处理之后的结果如图 2 所示,图中圆形为原始数据,星形为剔除异常值之后补充的数据。由图中所示,基于 3δ 的异常数据处理法可以对极大值、极小值这些异常数据进行有效的处理。




图2 异常数据处理示意图

2 深度置信网络

2.1 受限玻尔兹曼机

受限玻尔兹曼机 (restricted Boltzmann machine, RBM) 是深度置信网络的基本单元,其是一种可用随机神经网络解释的概率图模型^[18-20]。受限玻尔兹曼机与传统的神经网络不同,其没有隐藏层结构,仅由输入层和输出层两层构成,两层之间的神经元双向全连接,输入层和输出层相互影响,通过权重连接,每一层的任意两个神经元都相互独立。受限玻尔兹曼机的网络结构如图3所示,其中,可视层 v 由显元 v_i 组成,藏层 h 由隐元 h_j 组成。




图3 RBM 网络结构

基于能量模型定义 RBM 模型,定义状态 (v, h) 的能量为:

$$E_{\theta}(v, h) = - \sum_{i=1}^{n_v} a_i v_i - \sum_{j=1}^{n_h} b_j h_j - \sum_{i=1}^{n_v} \sum_{j=1}^{n_h} h_j w_{j,i} v_i \quad (1)$$

其中, $\theta\{W_{j,i}, a_i, b_j\}$ 为模型的参数, $W_{j,i}$ 为显元 i 和隐元 j 之间的连接权重; a_i 和 b_j 分别为显元 i 和隐元 j 的偏置。进一步,定义状态 (v, h) 的联合概率分布为:

$$P_{\theta}(v, h) = \frac{1}{Z_{\theta}} e^{-E_{\theta}(v, h)} \quad (2)$$

其中, $Z_{\theta} = \sum_{v, h} e^{-E_{\theta}(v, h)}$ 为归一化因子。

在 RBM 中,第 j 隐元的激活概率为:

$$P(h_j = 1 | v) = \text{sigmoid}(b_j + \sum_{i=1}^{n_v} w_{j,i} v_i) \quad (3)$$

第 i 个显元激活概率为:

$$P(v_i = 1 | h) = \text{sigmoid}(a_i + \sum_{j=1}^{n_h} w_{j,i} h_j) \quad (4)$$

其中, $\text{sigmoid}()$ 为神经网络的激活函数,在获取实际的监测数据之后,训练 RBM 以调整参数 θ ,使得该参数控制下的 RBM 表示的概率分布尽可能与训练数据

的分布相符,最大化如下似然可达到训练 RBM 的目的。

$$\ln L_{\theta, S} = \ln \prod_{i=1}^{n_s} P(v^i) = \sum_{i=1}^{n_s} \ln P(v^i) \quad (5)$$

其中, S 为训练样本集合; n_s 为训练样本个数。通常采用随机梯度上升法求解式(5),如式(6)所示:

$$\frac{\partial \ln L_{\theta, S}}{\partial \theta} = - \sum_h P(h | v) \frac{\partial E(v, h)}{\partial \theta} + \sum_{v, h} P(v, h) \frac{\partial E(v, h)}{\partial \theta} \quad (6)$$

式中:

$$\begin{aligned} \sum_{v, h} P(v, h) \frac{\partial E(v, h)}{\partial \theta} &= \sum_v \sum_h P(v) P(h | v) \frac{\partial E(v, h)}{\partial \theta} = \\ \sum_v P(v) \sum_h P(h | v) \frac{\partial E(v, h)}{\partial \theta} \end{aligned} \quad (7)$$

在训练过程中,计算 $\sum_h P(h | v) \frac{\partial E(v, h)}{\partial \theta}$ 、 $\sum_h P(h | v) \frac{\partial E(v, h)}{\partial a_i}$ 以及 $\sum_h P(h | v) \frac{\partial E(v, h)}{\partial b_j}$ 即可完成训练。

2002 年, Hinton 提出对比散度 (contrastive divergence, CD) 算法用于快速计算 RBM, 计算时, 首先将显元向量映射到隐元, 然后用隐元重构显元向量, 再将显元向量映射到隐元, 重复执行以上步骤 k 次即可^[21-22]。

2.2 深度置信网络

深度置信网络 (deep belief network, DBN) 是一种典型的深度学习模型,其通过构建多个中间层来组合输入向量特征,通过训练获取更精确的高层特征,以便更好地提取数据特征实现准确预测^[23]。深度置信网络由多个受限玻尔兹曼机以及分类输出层组成,通过逐层训练每一个受限玻尔兹曼机以及分类输出层来实现分类或预测的功能^[24]。DBN 的网络结构图及训练流程如图4所示。




图4 DBN 网络结构图及训练流程

在训练时,基于对比散度方法对每一层独立的进行贪婪训练获取权重,经过训练之后,每一层 RBM 的

参数均已达到最优,然而,对于整个 DBN 网络而言,此时的参数并不是最优的。所以需要利用相应的方法将输出结果与实际真实值之间的误差传递到网络中,即每个 RBM 中,并根据这些误差修正每一个 RBM,最终寻找到全局最优解。

3 基于深度置信网络的用电量预测模型

3.1 预测模型

通过设置不同的输入和输出,可以将深度置信网络用于分类以及预测等不同问题。在进行分类时,输入为特征数据,输出为对应的标签,而在进行预测是,则设置输入为已知数据,输出为待预测数据,通过从监测数据集中通过滑动窗口截取样本数据来进行训练。基于深度置信网络的用电量预测模型的结构如图 5 所示。如图所示,用电量预测模型由 k 个 RBM 和 1 个 BPNN 组成,输入数据长度为 n ,输出数据长度为 m ,具体的选取过程为:将 t 时间之前的 n 个数据作为输入数据, t 时间之后的 m 个数据为待预测数据,从用电量监测数据中通过移动 t 时间节点截取多个 $\{x_{t-n}, \dots, x_t\}$ 输入;输出: x_{t+1}, \dots, x_{t+m} 数据对作为样本数据,用于对 DBN 进行训练。在完成训练之后,将当前时间节点之前的 n 个数据作为 DBN 的输入即可实现对未来 m 个时间节点用电量的预测。




图 5 基于深度置信网络的用电量预测模型的结构

3.2 模型评价指标

为了更好地评价预测模型的性能,同时为了对比所提方法与传统方法的优劣,本研究选择平均相对误差和互相关系数作为预测模型准确性评价的指标^[25-26]。

平均相对误差表示预测值与真实值之间的相对误差,计算公式为:

$$MAPE = \left| \frac{G_{\text{实际值}} - G_{\text{预测值}}}{G_{\text{实际值}}} \right| \times 100\% \quad (8)$$

互相关系数表征在信号处理中,用互相关来衡量两个时间序列 $X(t)$ 和 $Y(t)$ 在两个不同时刻 t_1, t_2 的取值之间的相似程度,通常可以用于在长序列中寻找

一个特定的短序列。在数理统计中,互相关用来两个随机序列的相关性。

$$CC(X, Y) = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}[X] \text{Var}[Y]}} \quad (9)$$

3.3 基于可视化的模型训练策略

在利用基于深度置信网络的预测模型对用电量进行预测时,预测模型的准确性直接取决于训练样本的个数,当训练样本足够多时,深度置信网络将可以更好的挖掘潜在的用电量变化规律,从而实现精准的预测,然而,样本越多训练所需的算力也呈现指数级增加。此外,RBM 层数的数量以及 RBM 每层节点数量等都会对模型准确性产生影响,因此,同样需要进行大量的算力来参训练^[27]。为了满足算力的要求,在传统预测过程中,并不会在每次预测时均进行训练,而是通过设定固定的训练周期来进行,或是通过计算相应的量化指标来决定是否重新训练。第一种通过设定训练周期的方式是一种主观性较强的方式,训练周期过大将导致准确性显著下降,训练周期过短将导致算力浪费。第二种通过计算量化指标的方法很难兼顾多个方面,而且无法很好的解决震荡误差问题。因此,文中提出基于可视化的模型训练策略,具体的,在计算平均相对误差和互相关系数等量化指标的同时,绘制预测值与真实值的曲线,即使当量化指标不发生剧烈波动时,曲线如果出现明显的震荡误差,也对模型进行重新训练,从而保证模型的准确性。

4 实例验证

选取某地区从 2012 年 11 月 1 日至 2013 年 5 月 24 日的 200 天的用电量数据作为样本数据训练深度置信网络,输入数据长度为 28,输出数据长度为 7,即每次预测 7 个节点的数据。在对数据进行清洗之后,利用最大最小值归一化方法对原始数据进行归一化,以便预测模型更好的挖掘特征。深度置信网络的输入节点为 28,输出节点为 7,使用 BPNN 作为最终的分类输出函数,使用 13 个 RBM 作为特征挖掘器,权重学习率设置为 0.1,偏置项学习率为 0.1,初始动量为 0.6,激活函数选择 sigmoid 函数。基于 MATLAB 平台进行训练,训练完成之后,对 2013 年 5 月 24 日到 2013 年 6 月 23 日的数据进行预测,预测结果如图 6 圆形标记所示,同时,为了验证预测模型的效果,文中将基于 DBN 的预测模型与支持向量机、BP 神经网络以及长短时记忆网络进行对比,并绘制选择的每种方法的预测数据曲线,如图 6 中三角形、正方形和星形标记所示。进一步的,分别计算 DBN、SVM、BPNN 以及 LSTM 这四种方法的平均相对误差和互相关系数,如表 1 所示。




图6 不同预测方法的预测曲线

表1 不同预测方法的平均相对误差和互相关系数

| 预测方法 | 平均相对误差/% | 互相关系数 |
|------|----------|----------|
| DBN | 2.95 | 0.741 5 |
| SVM | 12.63 | -0.458 8 |
| BPNN | 8.78 | 0.601 1 |
| LSTM | 6.97 | 0.157 3 |

根据图6以及表1中的计算结果可知,DBN方法的平均误差为2.95%,即准确率可达97.05%,相对于其他方法的准确率更高。考虑到反映相关性情况的互相关系数可知,DBN方法的预测结果与实际结果具有较好的相关性,相对于其他方法的准确性更高。

在上述案例中,预测结果没有出现显著的变化,而在另一个地区的案例中,在进行预测时,随着预测时间的增加,出现了预测值在真实值周围出现震荡的情况,实际值与预测值的曲线如图7所示,其中方形为原始数据,圆形为预测结果。




图7 预测结果的周期性震荡

由图7可以看出,在前期的预测中,预测值较为准确,随着预测时间的增加,预测值在真实值上下震荡,且震荡幅度有变大的趋势,而通过计算量化指标可知,此时的平均相对误差仅为4.06%,而互相关系数为0.914 0,即从量化指标上看,此时预测效果是较好的,然而从可视化的预测值与真实值对比结果上可以看出,此时偏移情况已经较为严重,应该对模型进行再次训练,已获得更加准确的预测结果。

5 结束语

提出了基于深度置信网络模型和可视化调整的用电量预测方法。解决了传统用电量预测模型需要依赖多特征数据,且预测方法存在较多缺陷的问题。提出了用电量数据清洗方法,针对采集数据中的缺失值、异常值进行处理,最大限度还原数据原有的特征,为预测模型提供了数据基础;提出了基于深度置信网络模型的用电量预测方法,方法基于受限玻尔兹曼机构建生成模型,挖掘用电量历史数据的变化特征,从而实现对未来用电量数据的预测;提出了基于量化指标的模型准确性评价方法以及可视化的模型训练策略以获得更加精确的预测结果。所提出的基于深度置信网络模型的用电量预测方法的综合准确率可达97.05%,相对于传统的支持向量机、BP神经网络以及长短时记忆网络等预测算法具有更高的准确率,对于电力协调分配和电力设备运维检修具有重要意义。

参考文献:

- [1] 乔黎伟,王静怡,郭 炜,等. 基于随机森林算法的中短期用电量预测[J]. 电力科学与技术学报,2020,35(2):150-156.
- [2] 王 诚,高 蕊. 基于特征约简的随机森林改进算法研究[J]. 计算机技术与发展,2020,30(3):40-45.
- [3] 王宏伟,黄元生,姜雨晴,等. 基于套索算法和高斯过程回归的中长期居民用电量概率预测[J]. 华北电力大学学报:自然科学版,2019,46(6):27-35.
- [4] 刘军会,白宏坤,李虎军,等. 基于温度梯度变化的月度统调用电量预测研究[J]. 河南科技,2020(1):130-133.
- [5] 王鑫琪,李 闯,焦 晗,等. 基于长短时记忆网络的电力系统负荷预测方法研究[J]. 电工电气,2019(11):17-20.
- [6] 齐 波,王一鸣,张 鹏,等. 面向变压器油色谱趋势预测的深度递归信念网络[J]. 电网技术,2019,43(6):1892-1899.
- [7] 徐尧强,方乐恒,赵冬华,等. 基于LSTM神经网络的用电量预测[J]. 电力大数据,2017,20(8):25-29.
- [8] 徐先峰,龚 美,黄刘洋. 利用温度信息及深度学习方法实现高精度电力负荷预测[J]. 物联网技术,2019,9(9):97-101.
- [9] 邓裕东,谢国荣,林永春,等. 基于四表集抄的用电信息采集系统研究[J]. 电子测量技术,2019,42(1):21-26.
- [10] 郑国和,贺 民,郑瑞云,等. 基于多表融合数据的用户短期用电量预测[J]. 电力系统及其自动化学报,2019,31(3):146-150.
- [11] 张雨薇,王庆杰,李江涛,等. 基于多维特征分析的链式电网短期用电量预测研究[J]. 电网与清洁能源,2019,35(11):37-42.
- [12] 杨泽众,严守靖,晏 斌. 基于灰色关联分析和BP神经网络的用电量预测[J]. 价值工程,2018,37(35):30-33.
- [13] 李海英,杨冰芳,孙伟卿. 基于即时学习差异化建模的用电

- 量预测方法[J]. 电力系统及其自动化学报, 2020, 32(3): 14-19.
- [14] 李 寒, 余 斌, 佟 宁, 等. 一种电力感知数据的离群点检测方案[J]. 计算机技术与发展, 2020, 30(2): 153-158.
- [15] XU M, LU Z, QIAO Y, et al. Application of change-point analysis to abnormal wind power data detection [C]//2014 IEEE PES general meeting| conference & exposition. National Harbor, Maryland: IEEE, 2014: 1-5.
- [16] ZHANG Y, YANG G, HAO X, et al. Research on identification and processing method for abnormal data of residential electric power consumption [C]//2019 IEEE 3rd international electrical and energy conference (CIEEC). Beijing, China: IEEE, 2019: 900-904.
- [17] 李建青, 张云云, 康 健. 基于 38 原则和箱线图法的更换变压器技改工程造价区间估计[J]. 中国科技纵横, 2018(23): 155-157.
- [18] 张 健, 丁世飞, 张 楠, 等. 受限玻尔兹曼机研究综述[J]. 软件学报, 2019, 30(7): 2073-2090.
- [19] 任春霞, 李金宝. 基于受限玻尔兹曼机的个体行为预测模型的研究[J]. 黑龙江大学自然科学学报, 2018, 35(6): 743-749.
- [20] ZHANG J, DING S., ZHANG N, et al. Adversarial training methods for Boltzmann machines [J]. IEEE Access, 2020, 1(8): 4594-4604.
- [21] HINTON G E. Training products of experts by minimizing contrastive divergence [J]. Neural Computation, 2002, 14(8): 1771-1800.
- [22] 高 琰, 陈白帆, 晁绪耀, 等. 基于对比散度-受限玻尔兹曼机深度学习的产品评论情感分析[J]. 计算机应用, 2016, 36(4): 1045-1049.
- [23] HUA Yuming, GUO Junhai, ZHAO Hua. Deep belief networks and deep learning [C]//Proceedings of 2015 international conference on intelligent computing and internet of things. Harbin: [s. n.], 2015: 1-4.
- [24] 刘方园, 王水花, 张煜东. 深度置信网络模型及应用研究综述[J]. 计算机工程与应用, 2018, 54(1): 11-18.
- [25] 杨 凯, 于 波, 肖艳利, 等. 基于 GA-BP 神经网络的配电网工程造价预测[J]. 自动化仪表, 2019, 1(7): 91-93.
- [26] 吴朝峰, 杨 臻, 曹文辉, 等. 基于 GA-BP 算法的外弹道落点误差预测[J]. 兵器装备工程学报, 2019, 40(12): 67-71.
- [27] CHU J, WANG H, LIU J, et al. Unsupervised feature learning architecture with multi-clustering integration RBM [J]. IEEE Transactions on Knowledge and Data Engineering, 2020, 8(2): 121-135.

(上接第 176 页)

智能电网示范工程建设存在自动化、信息化、互动化特点, 基于智能互动化用电服务系统, 统一监控管理营业厅的平台运营, 统一监管智能营业厅。基于 B/S 结构, J2EE 平台, 运用 JQuery 技术开发前端页面, 包括了数据采集、应用服务器、Web 服务器、排队机终端和缴费端等硬件组成。本次设计互动化服务系统实际运行中, 所有功能模块都能够正常运行, 经过监控维护该系统的各项功能, 确保了设备可以运行正常, 提供了客户互动服务系统使用保障。并且提高了营业厅服务能力超过 40%, 还借助该系统实现了营业厅服务分流, 减少了 30% 的人员投入, 很大程度节约了年管理成本。

5 结束语

总而言之, 通过文中设计的供电营业厅互动化服务系统, 很大程度上提升了营业厅的管理工作效率, 也有效降低了管理成本, 通过将该系统应用于实际供电营业厅工作中, 改善了客户的服务满意度, 提高了设备使用率, 也能够对突发事件进一步规范处理, 更对设施具体管理流程做到科学规范。

参考文献:

- [1] 周文琼, 王乐球, 林树华. 基于微服务架构的智慧供电营业厅服务模式创新[J]. 电力需求侧管理, 2019, 21(2): 62-65.
- [2] 聂 玮, 朱艺璇, 刘 杰, 等. 基于支持向量机的电力营业厅服务检查智能规划化研究[J]. 电子技术与软件工程, 2020(14): 172-173.
- [3] 曹 伟. 基于互动学习平台构建结构化创新课堂——以 UMU 互动学习平台为例[J]. 中国信息技术教育, 2020(10): 68-69.
- [4] 姚 露, 林培洪, 黄王晔. “三型一化”供电营业厅智能化管理系统设计思路[J]. 农村电工, 2019, 27(12): 6-7.
- [5] 陈 洵, 孙志峰, 刘海阳. 供电企业基于“三型一化”的多营业厅协同运营管理体系建设研究[J]. 中国管理信息化, 2020, 23(7): 110-116.
- [6] 陈 洵, 常 洁, 魏志丰. 面向供电营业厅的新零售业务体系建设探究[J]. 中国管理信息化, 2020, 23(9): 76-79.
- [7] 谢 玮, 余 鹤, 董重重, 等. 电力设备的 GIS 数据采集及其系统建构[J]. 自动化与仪器仪表, 2019(3): 215-218.
- [8] 盛 晏, 杨锦成, 马守达, 等. 基于需供互动的综合能源系统优化调度研究[J]. 电力需求侧管理, 2019, 21(6): 48-54.