



(12) 发明专利

(10) 授权公告号 CN 108280552 B

(45) 授权公告日 2021.06.01

(21) 申请号 201810157549.X

G06Q 50/06 (2012.01)

(22) 申请日 2018.02.24

G06N 20/00 (2019.01)

(65) 同一申请的已公布的文献号
申请公布号 CN 108280552 A

(56) 对比文件

CN 104792530 A, 2015.07.22

US 2016155049 A1, 2016.06.02

(43) 申请公布日 2018.07.13

何耀耀等.考虑温度因素的中期电力负荷概率密度预测方法.《电网技术》.2015,第39卷(第1期),第176-181页.

(73) 专利权人 合肥工业大学
地址 230009 安徽省合肥市包河区屯溪路193号

闻才喜.基于神经网络分位数回归及核密度估计的概率密度预测方法研究.《中国优秀硕士学位论文全文数据库 经济与管理科学辑》.2016,第28-32页.

(72) 发明人 周开乐 郭志峰 杨善林 李兰兰 陆信辉

审查员 王欣

(74) 专利代理机构 北京路浩知识产权代理有限公司 11002

代理人 王莹 余罡

(51) Int. Cl.

G06Q 10/04 (2012.01)


权利要求书3页 说明书9页 附图1页

(54) 发明名称

基于深度学习的电力负荷预测方法和系统、存储介质

(57) 摘要

本发明提供一种基于深度学习的电力负荷预测方法和系统、存储介质,涉及用电技术领域。方法包括:S101、采集在预设历史时间段内用户的电力负荷数据、气象数据以及空气质量数据,并将采集到的数据划分为训练集和测试集;S102、确定用于进行电力负荷预测的深度学习模型;S103、将所述测试集输入所述用于进行电力负荷预测的深度学习模型,得到用户在第三时间区间内的电力负荷预测数据。本发明采用深度学习的方式进行电力负荷预测,而且深度学习过程中不仅考虑电力负荷数据,还考虑气象数据和空气质量数据,能够提供电力负荷预测的准确性。



1. 一种基于深度学习的电力负荷预测方法,其特征在于,包括:

S101、采集在预设历史时间段内用户的电力负荷数据、气象数据以及空气质量数据,并将采集到的数据划分为训练集和测试集;其中,所述历史时间段包括第一时间区间和晚于所述第一时间区间的第二时间区间,所述训练集为所述第一时间区间内的数据,所述测试集为所述第二时间区间内的数据;

S102、确定用于进行电力负荷预测的深度学习模型:

S1021、对深度学习模型的网络结构和模型参数进行初始化设置;

S1022、将所述训练集输入当前的深度学习模型,通过当前的深度学习模型的深度学习,得到用户在所述第二时间区间内的电力负荷预测数据;

S1023、根据用户在所述第二时间区间内的电力负荷预测数据和所述测试集,对当前的深度学习模型的预测能力进行测定;若预测能力不满足预定要求,则对当前的深度学习模型的网络结构和/或模型参数进行调整,并返回步骤S1022;否则,将当前的深度学习模型作为所述用于进行电力负荷预测的深度学习模型,并执行步骤S103;

S103、将所述测试集输入所述用于进行电力负荷预测的深度学习模型,得到用户在第三时间区间内的电力负荷预测数据;其中,所述第三时间区间为预设的未来时间段内的时间区间;

当前的深度学习模型采用第一公式进行深度学习,所述第一公式包括:

$$v = \min \left\{ \frac{1}{n} \sum_{i=1}^n L[y_i, f(x_i; w)] + \lambda J(w) \right\}$$

式中, x_i 为所述训练集中的第 i 个训练样本, n 为所述训练集中训练样本的个数, $L()$ 为均方损失函数, λ 为正则化系数, $J(w)$ 为正则项, w 为权重参数, y_i 为所述测试集中第 i 个测试样本, v 为所述用户在所述第二时间区间内的电力负荷预测数据, $f()$ 为当前的深度学习模型。

2. 根据权利要求1所述的方法,其特征在于,所述对当前的深度学习模型的预测能力进行测定,包括:

采用第二公式确定当前的深度学习模型的第一预测误差;若所述第一预测误差低于预设的第一误差下限,则所述预测能力满足所述预定要求;否则,所述预测能力不满足所述预定要求;

其中,所述第二公式包括:

$$MAE = \frac{1}{N} \sum_{t=1}^N |\hat{X}^t - X^t| \times 100\%$$

式中, MAE 为所述第一预测误差, N 为用户在所述第二时间区间内的电力负荷预测数据的个数, \hat{X}^t 为用户在所述第二时间区间内的第 t 个电力负荷预测数据, X^t 为所述测试集中的第 t 个测试样本,所述第 t 个电力负荷预测数据和所述第 t 个测试样本分别为用户在同一时间区间内的电力负荷预测值和电力负荷真实值。

3. 根据权利要求2所述的方法,其特征在于,所述对当前的深度学习模型的预测能力进行测定,还包括:采用第三公式确定当前的深度学习模型的第二预测误差;

对应的,所述若所述第一预测误差低于预设的第一误差下限,则所述预测能力满足所

述预定要求,包括:若所述第一预测误差低于预设的第一误差下限且所述第二预测误差低于预设的第二误差下限,则所述预测能力满足所述预定要求;

其中,所述第三公式包括:

$$MAPE = \frac{1}{N} \sum_{t=1}^N \left| \frac{\hat{X}^t - X^t}{X^t} \right| \times 100\%$$

式中,MAPE为所述第二预测误差。

4. 根据权利要求3所述的方法,其特征在于,所述对当前的深度学习模型的预测能力进行测定,还包括:采用第四公式确定当前的深度学习模型的第三预测误差;

若所述第一预测误差低于预设的第一误差下限、所述第二预测误差低于预设的第二误差下限以及所述第三预测误差低于预设的第三误差下限,则所述预测能力满足所述预定要求;

若所述第一预测误差大于等于预设的第一误差下限和/或所述第二预测误差大于等于预设的第二误差下限,则所述预测能力不满足所述预定要求;

其中,所述第四公式包括:

$$MRPE = \max \left| \frac{\hat{X}^t - X^t}{X^t} \right| \times 100\%, t = 1, 2, \dots, N$$

式中,MRPE为所述第三预测误差。

5. 根据权利要求1所述的方法,其特征在于,步骤S103还包括:

提取影响所述用于进行电力负荷预测的深度学习模型的预测结果的特征以及各特征对应的影响程度值。

6. 根据权利要求1~5任一项所述的方法,其特征在于,所述将采集到的数据划分为训练集和测试集之前,所述方法还包括:对采集到的数据进行清洗处理,并对清洗处理后得到数据的格式转换为有监督学习数据格式。

7. 一种基于深度学习的电力负荷预测系统,其特征在于,包括数据采集模块、模型确定模块和负荷预测模块,其中:

所述数据采集模块用于采集在预设历史时间段内用户的电力负荷数据、气象数据以及空气质量数据,并将采集到的数据划分为训练集和测试集;其中,所述历史时间段包括第一时间区间和晚于所述第一时间区间的第二时间区间,所述训练集为所述第一时间区间内的数据,所述测试集为所述第二时间区间内的数据;

所述模型确定模块用于确定用于进行电力负荷预测的深度学习模型,且包括初始化单元、深度学习单元和能力测定单元;其中,所述初始化单元用于对深度学习模型的网络结构和模型参数进行初始化设置;所述深度学习单元用于将所述训练集输入当前的深度学习模型,通过当前的深度学习模型的深度学习,得到用户在所述第二时间区间内的电力负荷预测数据;所述能力测定单元用于根据用户在所述第二时间区间内的电力负荷预测数据和所述测试集,对当前的深度学习模型的预测能力进行测定,若预测能力不满足预定要求,则对当前的深度学习模型的网络结构和/或模型参数进行调整,并返回所述深度学习单元;否则,将当前的深度学习模型作为所述用于进行电力负荷预测的深度学习模型,并转到所述负荷预测模块;

所述负荷预测模块用于将所述测试集输入所述用于进行电力负荷预测的深度学习模型,得到用户在第三时间区间内的电力负荷预测数据;其中,所述第三时间区间为预设的未来时间段内的时间区间;

当前的深度学习模型采用第一公式进行深度学习,所述第一公式包括:

$$v = \min \left\{ \frac{1}{n} \sum_{i=1}^n L[y_i, f(x_i; w)] + \lambda J(w) \right\}$$

式中, x_i 为所述训练集中的第 i 个训练样本, n 为所述训练集中训练样本的个数, $L()$ 为均方损失函数, λ 为正则化系数, $J(w)$ 为正则项, w 为权重参数, y_i 为所述测试集中第 i 个测试样本, v 为所述用户在所述第二时间区间内的电力负荷预测数据, $f()$ 为当前的深度学习模型。

8. 根据权利要求7所述的系统,其特征在于,还包括:

特征提取模块,用于提取影响所述用于进行电力负荷预测的深度学习模型的预测结果的特征以及各特征对应的影响程度值。

9. 一种计算机可读存储介质,该介质上存储有计算机程序,其特征在于,在处理器执行所述计算机程序时可实现权利要求1~6任一所述的方法。

基于深度学习的电力负荷预测方法和系统、存储介质

技术领域

[0001] 本发明涉及用电技术领域,具体涉及一种基于深度学习的电力负荷预测方法和系统、存储介质。

背景技术

[0002] 随着电力系统不断发展,电力系统对社会的经济发展也越来越重要。随着电网技术的不断进步和经济社会对电力需求的增加,目前电力能源服务已经覆盖诸多领域。在此背景下,电网系统的正常运行十分重要,而电力需求预测对于电网系统的运行有着重要的意义,电网系统的复杂性与多变性决定了对电力负荷预测需要有较强的自适应与较高的准确性。

[0003] 目前电力系统的负荷预测的主要方法是有两大类:一大类是通过时间序列的方法对电力系统的负荷进行预测,对历史负荷数据的拟合;另一大类是利用机器学习方法对电力系统负荷进行预测,如支持向量机,随机森林等。

[0004] 随着电力系统的智能化程度不断增强,电力系统运行所产生的数据越来越多,种类日益繁杂,而且具有高维性和高度动态性。以上传统的预测方法存在一些缺陷,例如,传统的时间序列方法无法利用电力负荷以外的其他相关数据以提高预测精度,传统的时间序列方法和机器学习方法的精确性都有待提高。

发明内容

[0005] (一)解决的技术问题

[0006] 针对现有技术的不足,本发明提供了一种基于深度学习的电力负荷预测方法和系统、存储介质,能够提高电力负荷预测的准确性。

[0007] (二)技术方案

[0008] 为实现以上目的,本发明通过以下技术方案予以实现:

[0009] 第一方面,本发明实施例提供一种基于深度学习的电力负荷预测方法,包括:

[0010] S101、采集在预设历史时间段内用户的电力负荷数据、气象数据以及空气质量数据,并将采集到的数据划分为训练集和测试集;其中,所述历史时间段包括第一时间区间和晚于所述第一时间区间的第二时间区间,所述训练集为所述第一时间区间内的数据,所述测试集为所述第二时间区间内的数据;

[0011] S102、确定用于进行电力负荷预测的深度学习模型;

[0012] S1021、对深度学习模型的网络结构和模型参数进行初始化设置;

[0013] S1022、将所述训练集输入当前的深度学习模型,通过当前的深度学习模型的深度学习,得到用户在所述第二时间区间内的电力负荷预测数据;

[0014] S1023、根据用户在所述第二时间区间内的电力负荷预测数据和所述测试集,对当前的深度学习模型的预测能力进行测定;若预测能力不满足预定要求,则对当前的深度学习模型的网络结构和/或模型参数进行调整,并返回步骤S1022;否则,将当前的深度学习模

型作为所述用于进行电力负荷预测的深度学习模型,并执行步骤S103;

[0015] S103、将所述测试集输入所述用于进行电力负荷预测的深度学习模型,得到用户在第三时间区间内的电力负荷预测数据;其中,所述第三时间区间为预设的未来时间段内的时间区间。

[0016] 第二方面,本发明实施例提供一种基于深度学习的电力负荷预测系统包括数据采集模块、模型确定模块和所述负荷预测模块,其中:

[0017] 所述数据采集模块用于采集在预设历史时间段内用户的电力负荷数据、气象数据以及空气质量数据,并将采集到的数据划分为训练集和测试集;其中,所述历史时间段包括第一时间区间和晚于所述第一时间区间的第二时间区间,所述训练集为所述第一时间区间内的数据,所述测试集为所述第二时间区间内的数据;

[0018] 所述模型确定模块用于确定用于进行电力负荷预测的深度学习模型,且包括初始化单元、深度学习单元和能力测定单元;其中,所述初始化单元用于对深度学习模型的网络结构和模型参数进行初始化设置;所述深度学习单元用于将所述训练集输入当前的深度学习模型,通过当前的深度学习模型的深度学习,得到用户在所述第二时间区间内的电力负荷预测数据;所述能力测定单元用于根据用户在所述第二时间区间内的电力负荷预测数据和所述测试集,对当前的深度学习模型的预测能力进行测定,若预测能力不满足预定要求,则对当前的深度学习模型的网络结构和/或模型参数进行调整,并返回所述深度学习单元;否则,将当前的深度学习模型作为所述用于进行电力负荷预测的深度学习模型,并转到所述负荷预测模块;

[0019] 所述负荷预测模块用于将所述测试集输入所述用于进行电力负荷预测的深度学习模型,得到用户在第三时间区间内的电力负荷预测数据;其中,所述第三时间区间为预设的未来时间段内的时间区间。

[0020] 第三方面,本发明实施例提供一种计算机可读存储介质,该介质上存储有计算机程序,在处理器执行所述计算机程序时可实现上述方法。

[0021] (三)有益效果

[0022] 本发明实施例提供了一种基于深度学习的电力负荷预测方法和系统、存储介质,具备以下有益效果:

[0023] 本发明实施例提供的基于深度学习的电力负荷预测方法,对模型结构和/或模型参数进行初始化,得到初始的深度学习模型,然后初始的深度学习模型利用训练集进行深度学习,得到预测结果,并根据预测结果和测试集测定模型的预测能力,如果预测能力不满足要求,则对模型结构和/或参数进行调整,直至预测能力满足要求,得到最终的深度学习模型,最终的深度学习模型利用测试集进行测试,从而得到想要的测试结果。可见,本发明实施例采用深度学习的方式进行电力负荷预测,深度学习作为一种人工智能方法相对于传统的时间序列方法和机器学习方法,预测准确率更高,而且在深度学习过程采用的数据不仅有电力负荷数据,还有气象数据和空气质量数据,由于天气情况、空气质量都会影响人的行为,进而影响人的用电量,最终会导致负荷发生变化,因此在考虑气象数据和空气质量数据,可以进一步提高预测准确率。

附图说明

[0024] 为了更清楚地说明本发明实施例或现有技术中的技术方案,下面将对实施例或现有技术描述中所需要使用的附图作简单地介绍,显而易见地,下面描述中的附图仅仅是本发明的一些实施例,对于本领域普通技术人员来讲,在不付出创造性劳动的前提下,还可以根据这些附图获得其他的附图。

[0025] 图1示出了本发明实施例中基于深度学习的电力负荷预测方法的流程示意图;

[0026] 图2示出了本发明实施例中基于深度学习的电力负荷预测系统的结构框图。

具体实施方式

[0027] 为使本发明实施例的目的、技术方案和优点更加清楚,下面将结合本发明实施例中的附图,对本发明实施例中的技术方案进行清楚、完整地描述,显然,所描述的实施例是本发明一部分实施例,而不是全部的实施例。基于本发明中的实施例,本领域普通技术人员在没有作出创造性劳动前提下所获得的所有其他实施例,都属于本发明保护的范围。

[0028] 第一方面,本发明实施例提供一种基于深度学习的电力负荷预测方法,如图1所示,该方法包括:

[0029] S101、采集在预设历史时间段内用户的电力负荷数据、气象数据以及空气质量数据,并将采集到的数据划分为训练集和测试集;其中,所述历史时间段包括第一时间区间和晚于所述第一时间区间的第二时间区间,所述训练集为所述第一时间区间内的数据,所述测试集为所述第二时间区间内的数据;

[0030] 可理解的是,电力负荷数据为用户在历史时间段内的电力消费数据,气象数据即天气数据。

[0031] 在实际应用时,历史时间段、第一时间区间、第二时间区间可以根据需要选择,例如,在当天的24时,将前一天(即昨天)和当天作为历史时间段,采集这两天所产生的电力负荷数据以及这两天的天气数据和空气质量数据。将前一天作为第一时间区间,将当天作为第二时间区间,这样前一天的相关数据形成训练集,当天的相关数据形成测试集。

[0032] 在实际应用时,在将采集到的数据划分为训练集和测试集之前,还可以包括对采集到的数据进行清洗处理,这样可以将缺失值、异常值去除,以免其影响后续的深度学习和预测。还可以将清洗之后得到的数据进行格式转换,将其转换为有监督学习数据格式,以便执行后续的深度学习和测试过程。

[0033] S102、确定用于进行电力负荷预测的深度学习模型:

[0034] S1021、对深度学习模型的网络结构和模型参数进行初始化设置;

[0035] 可理解的是,对深度学习模型的网络结构以及模型参数进行初始化设置,实际上是对深度学习模型的初始化设置以得到初始深度学习模型的过程,具体的初始化设置可以参考如下表1:

[0036] 表1初始化设置表

	参数	初始值
	隐含层个数	3
	每个层节点数	[45,200,200,200,1]
[0037]	最大迭代次数	500
	正则化参数 L1	0.01
	正则化参数 L2	0.01
	激活函数	Rectifer 函数
[0038]	学习速率	0.1
	损失函数	均方损失函数

[0039] 从上表1中可以看出,初始深度学习模型的网络结构中,隐含层有3层,输入层、三个隐含层和输出层的节点数分别是45、200、200、200、1,在深度学习过程中最大迭代次数为500次,两个正则化参数为0.01,激活函数为Rectifer函数,学习速率为0.1,选择均方损失函数作为损失函数。

[0040] 可理解的是,此时可以仅根据表1对深度学习模型进行初始化,在后续过程中可能涉及对各个参数的调整。

[0041] S1022、将所述训练集输入当前的深度学习模型,通过当前的深度学习模型的深度学习,得到用户在所述第二时间区间内的电力负荷预测数据;

[0042] 可理解的是,如果是第一次执行步骤S1022,则当前的深度学习模型为初始深度学习模型,如果是第二次、第三次……执行步骤S1022,则当前的深度学习模型为对之前的深度学习模型的结构和/或参数进行调整后的深度学习模型。

[0043] 可理解的是,深度学习模型的输入数据为训练集,训练集为第一时间区间内采集的数据,而当前的深度学习模型的输出数据为用户在第二时间区间内的电力负荷预测数据,可见输出数据是当前的深度学习模型是基于第一时间区间的数据,对第二时间区间内的电力负荷进行预测。也就是说,通过第一时间区间内的相关数据,深度学习模型可以预测第二时间区间内的电力负荷。

[0044] 例如,将昨天的电力负荷数据、气象数据和空气质量数据形成训练集,将今天的电力负荷数据、气象数据和空气质量数据形成测试集,将训练集输入当前的深度学习模型后,得到对今天电力负荷的预测结果。

[0045] 在具体实施时,当前的深度学习模型进行深度学习的方式有多种,举例来说,可以根据第一公式进行深度学习,第一公式包括:

$$[0046] \quad v = \min \left\{ \frac{1}{n} \sum_{i=1}^n L[y_i, f(x_i; w)] + \lambda J(w) \right\}$$

[0047] 式中, x_i 为所述训练集中的第 i 个训练样本, n 为所述训练集中训练样本的个数, $L()$ 为均方损失函数, λ 为正则化系数, $J(w)$ 为正则项, w 为权重参数, y_i 为所述测试集中第 i 个

测试样本, v 为所述用户在所述第二时间区间内的电力负荷预测数据, $f(\cdot)$ 为当前的深度学习模型。

[0048] 其中, 正则项 $J(w)$ 可以用以下公式确定:

$$[0049] \quad J(w) = \frac{1}{2} \sum_{k=1}^{K-1} \sum_{j=1}^{p_k} \sum_{l=1}^{p_{k+1}} \{w_{lj}^k\}^2$$

[0050] 式中, w_{lj}^k 表示模型的第 k 层中第 i 个神经元和第 j 个神经元连接的权重, K 表示神经层数, p 表示相应层中神经元个数, 例如, p_k 为第 k 层神经元的个数。

[0051] S1023、根据用户在所述第二时间区间内的电力负荷预测数据和所述测试集, 对当前的深度学习模型的预测能力进行测定; 若预测能力不满足预定要求, 则对当前的深度学习模型的网络结构和/或模型参数进行调整, 并返回步骤 S1022; 否则, 将当前的深度学习模型作为所述用于进行电力负荷预测的深度学习模型, 并执行步骤 S103;

[0052] 可以理解的是, 由于测试集为之前采集的第二时间区间内电力负荷的真实数据, 而通过之前的步骤 S1022 得到的是对第二时间区间内电力负荷的预测数据, 根据第二时间区间内的真实数据和预测数据, 从而可以确定当前的深度学习模型的预测误差, 进而确定其预测能力是否满足要求, 如果预测能力满足要求, 则没有必要再对当前的深度学习模型的结构和/或参数进行进一步的调整, 直接将当前的深度学习模型作为最终的深度学习模型。但是如果预测能力还达不到要求, 则需要对当前的深度学习模型进行调整, 返回步骤 S1022, 继续参与循环, 直至深度学习模型的预测能力能够满足要求。

[0053] 在具体实施时, 由于计算测试误差的方式有多种, 因此对当前的深度学习模型的预测能力进行测定的方式有多种。下面介绍几种测定方式:

[0054] (1) 采用第二公式确定当前的深度学习模型的第一预测误差, 所述第二公式包括:

$$[0055] \quad MAE = \frac{1}{N} \sum_{t=1}^N |\hat{X}^t - X^t| \times 100\%$$

[0056] 式中, MAE 为所述第一预测误差, N 为用户在所述第二时间区间内的电力负荷预测数据的个数, \hat{X}^t 为用户在所述第二时间区间内的第 t 个电力负荷预测数据, X^t 为所述测试集中的第 t 个测试样本, 所述第 t 个电力负荷预测数据和所述第 t 个测试样本分别为用户在同一时间区间内的电力负荷预测值和电力负荷真实值。

[0057] 在仅根据第一测试误差对测试能力进行测定的情况下, 若所述第一预测误差低于预设的第一误差下限, 则所述预测能力满足所述预定要求; 否则, 所述预测能力不满足所述预定要求。

[0058] (2) 采用第三公式确定当前的深度学习模型的第二预测误差, 所述第三公式包括:

$$[0059] \quad MAPE = \frac{1}{N} \sum_{t=1}^N \left| \frac{\hat{X}^t - X^t}{X^t} \right| \times 100\%$$

[0060] 式中, $MAPE$ 为所述第二预测误差, 其余参数的含义案件第二公式。

[0061] 在仅根据第二测试误差对测试能力进行测定的情况下, 若所述第二预测误差低于预设的第二误差下限, 则所述预测能力满足所述预定要求; 否则, 所述预测能力不满足所述预定要求。

[0062] (3) 还可以同时根据MAE和MAPE这两个测试误差对测试能力进行测定,此时,若所述第一预测误差低于预设的第一误差下限且所述第二预测误差低于预设的第二误差下限,则所述预测能力满足所述预定要求;否则,测试能力不满足预定要求。

[0063] (4) 在以上任意一种的基础上,还可以采用第四公式确定当前的深度学习模型的第三预测误差;所述第四公式包括:

$$[0064] \quad MRPE = \max \left| \frac{\hat{X}' - X'}{X'} \right| \times 100\%, t = 1, 2, \dots, N$$

[0065] 式中,MRPE为所述第三预测误差。

[0066] 举例来说,在(3)的基础上采用MRPE确定第三预测误差,进而根据三个预测误差对预测能力进行测定,此时判断标准可以包括:

[0067] 若所述第一预测误差低于预设的第一误差下限、所述第二预测误差低于预设的第二误差下限以及所述第三预测误差低于预设的第三误差下限,则所述预测能力满足所述预定要求;

[0068] 若所述第一预测误差大于等于预设的第一误差下限和/或所述第二预测误差大于等于预设的第二误差下限,则所述预测能力不满足所述预定要求。

[0069] 由于MRPE取得是 $\left| \frac{\hat{X}' - X'}{X'} \right|$ 中的最大值,因此如果MRPE、MAE和MAPE这三者均小于相

应的误差下限,则认为预测能力肯定满足预设要求,但是如果MRPE高于或等于第三误差下限,也并不代表模型的预测能力不满足要求,此时可以继续根据MAE和MAPE进行确定,如果这两者中存在误差较大的值,则可以认为模型的预测能力不是很好,即没有满足预定要求。

[0070] S103、将所述测试集输入所述用于进行电力负荷预测的深度学习模型,得到用户在第三时间区间内的电力负荷预测数据;其中,所述第三时间区间为预设的未来时间段内的时间区间。

[0071] 可理解的是,第三时间区间为未来时间段内的时间区间,其必然晚于第二时间区间,通过第二时间区间内的相关数据,深度学习模型可以预测第三时间段内的电力负荷。

[0072] 举例来说,将今天的电力负荷数据、气象数据和空气质量数据形成测试集,将测试集输入最终的深度学习模型之后,得到对明天电力负荷的预测结果。

[0073] 当然,在利用步骤S103得到用户在第三时间区间内的电力负荷预测数据之后,还可以提取影响所述用于进行电力负荷预测的深度学习模型的预测结果的特征以及各特征对应的影响程度值。

[0074] 可理解的是,影响预测结果的特征实际上是影响预测结果的因素。

[0075] 举例来说,提取出的特征以及对应的影响程度值如下表2所示:

[0076] 表2特征以及影响程度值表

[0077]

特征	影响程度值
温度	1
月份	0.8
星期	0.7
季节	0.4

[0078] 从上表2中可以看出,提取出的影响比较大的特征有温度、月份、星期和季节,这样可以对电力负荷的影响因素有一定的了解,也便于对电力负荷进一步分析。

[0079] 在具体实施时,特征的提取和影响程度值的确定过程可以包括:在训练得到最优结果时,深度学习模型参数的最终参数 w 反映了输入变量的重要性程度。基于整个神经网络的结构以及节点对应的参数,可以根据下式计算每个变量的重要性。

$$[0080] \quad P_{rj}^l = \frac{|w_{rj}|}{\sum_{r=1}^R |w_{rj}|}$$

[0081] 式中, P_{rj}^l 表示第 l 隐含层的第 r 个神经元对其它层的第 j 个神经元的影响大小。

$$[0082] \quad Q_{io} = \sum_{l=1}^L \sum_{r=1}^{R_l} (P_{ir} \times P_{ro})$$

[0083] 式中, Q_{io} 表示第 i 个输入变量对输出节点 o 的影响大小,也就是变量重要性。 L 表示隐含层个数, R_l 表示 l 层的节点数, Q_{io} 就是自变量 i 对于因变量 y 影响的大小。 Q_{io} 越大,表明该变量(或者特征)越重要。基于此,我们可以计算出每个特征的影响程度值。本发明实施里提供的基于深度学习的电力负荷预测方法,对模型结构和/或模型参数进行初始化,得到初始的深度学习模型,然后初始的深度学习模型利用训练集进行深度学习,得到预测结果,并根据预测结果和测试集测定模型的预测能力,如果预测能力不满足要求,则对模型结构和/或参数进行调整,直至预测能力满足要求,得到最终的深度学习模型,最终的深度学习模型利用测试集进行测试,从而得到想要的测试结果。可见,本发明实施例采用深度学习的方式进行电力负荷预测,深度学习作为一种人工智能方法相对于传统的时间序列方法和机器学习方法,预测准确率更高,而且在深度学习过程采用的数据不仅有电力负荷数据,还有气象数据和空气质量数据,由于天气情况、空气质量都会影响人的行为,进而影响人的用电量,最终会导致负荷发生变化,因此在考虑气象数据和空气质量数据,可以进一步提高预测准确率。

[0084] 第二方面,本发明实施例提供一种基于深度学习的电力负荷预测系统,如图2所示,该系统包括:数据采集模块、模型确定模块和所述负荷预测模块,其中:

[0085] 所述数据采集模块用于采集在预设历史时间段内用户的电力负荷数据、气象数据以及空气质量数据,并将采集到的数据划分为训练集和测试集;其中,所述历史时间段包括第一时间区间和晚于所述第一时间区间的第二时间区间,所述训练集为所述第一时间区间内的数据,所述测试集为所述第二时间区间内的数据;

[0086] 所述模型确定模块用于确定用于进行电力负荷预测的深度学习模型,且包括初始化单元、深度学习单元和能力测定单元;其中,所述初始化单元用于对深度学习模型的网络结构和模型参数进行初始化设置;所述深度学习单元用于将所述训练集输入当前的深度学习模型,通过当前的深度学习模型的深度学习,得到用户在所述第二时间区间内的电力负荷预测数据;所述能力测定单元用于根据用户在所述第二时间区间内的电力负荷预测数据和所述测试集,对当前的深度学习模型的预测能力进行测定,若预测能力不满足预定要求,则对当前的深度学习模型的网络结构和/或模型参数进行调整,并返回所述深度学习单元;

否则,将当前的深度学习模型作为所述用于进行电力负荷预测的深度学习模型,并转到所述负荷预测模块;

[0087] 所述负荷预测模块用于将所述测试集输入所述用于进行电力负荷预测的深度学习模型,得到用户在第三时间区间内的电力负荷预测数据;其中,所述第三时间区间为预设的未来时间段内的时间区间。

[0088] 在一些实施例中,系统还包括:

[0089] 特征提取模块,用于提取影响所述用于进行电力负荷预测的深度学习模型的预测结果的特征以及各特征对应的影响程度值。

[0090] 在一些实施例中,所述深度学习单元采用第一公式进行深度学习,所述第一公式包括:

$$[0091] \quad v = \min \left\{ \frac{1}{n} \sum_{i=1}^n L[y_i, f(x_i; w)] + \lambda J(w) \right\}$$

[0092] 式中, x_i 为所述训练集中的第*i*个训练样本, n 为所述训练集中训练样本的个数, $L()$ 为均方损失函数, λ 为正则化系数, $J(w)$ 为正则项, w 为权重参数, y_i 为所述测试集中第*i*个测试样本, v 为所述用户在所述第二时间区间内的电力负荷预测数据, $f()$ 为当前的深度学习模型。

[0093] 在一些实施例中,所述能力测定单元对当前的深度学习模型的预测能力进行测定的过程包括:采用第二公式确定当前的深度学习模型的第一预测误差;若所述第一预测误差低于预设的第一误差下限,则所述预测能力满足所述预定要求;否则,所述预测能力不满足所述预定要求;其中,所述第二公式包括:

$$[0094] \quad MAE = \frac{1}{N} \sum_{t=1}^N |\hat{X}^t - X^t| \times 100\%$$

[0095] 式中,MAE为所述第一预测误差, N 为用户在所述第二时间区间内的电力负荷预测数据的个数, \hat{X}^t 为用户在所述第二时间区间内的第*t*个电力负荷预测数据, X^t 为所述测试集中的第*t*个测试样本,所述第*t*个电力负荷预测数据和所述第*t*个测试样本分别为用户在同一时间区间内的电力负荷预测值和电力负荷真实值。

[0096] 在一些实施例中,所述能力测定单元对当前的深度学习模型的预测能力进行测定的过程还包括:采用第三公式确定当前的深度学习模型的第二预测误差;

[0097] 对应的,所述若所述第一预测误差低于预设的第一误差下限,则所述预测能力满足所述预定要求,包括:若所述第一预测误差低于预设的第一误差下限且所述第二预测误差低于预设的第二误差下限,则所述预测能力满足所述预定要求;其中,所述第三公式包括:

$$[0098] \quad MAPE = \frac{1}{N} \sum_{t=1}^N \left| \frac{\hat{X}^t - X^t}{X^t} \right| \times 100\%$$

[0099] 式中,MAPE为所述第二预测误差。

[0100] 在一些实施例中,所述能力测定单元对当前的深度学习模型的预测能力进行测定的过程还包括:采用第四公式确定当前的深度学习模型的第三预测误差;

[0101] 若所述第一预测误差低于预设的第一误差下限、所述第二预测误差低于预设的第

二误差下限以及所述第三预测误差低于预设的第三误差下限,则所述预测能力满足所述预定要求;若所述第一预测误差大于等于预设的第一误差下限和/或所述第二预测误差大于等于预设的第二误差下限,则所述预测能力不满足所述预定要求;其中,所述第四公式包括:

$$[0102] \quad MRPE = \max \left| \frac{\hat{X}^t - X^t}{X^t} \right| \times 100\%, t = 1, 2, \dots, N$$

[0103] 式中,MRPE为所述第三预测误差。

[0104] 在一些实施例中,所述数据采集模块在将采集到的数据划分为训练集和测试集之前,还对采集到的数据进行清洗处理,并对清洗处理后得到数据的格式转换为有监督学习数据格式。

[0105] 可理解的是,本发明实施例提供的电力负荷预测系统与电力负荷预测方法相对应,其有关内容的解释、说明、举例和有益效果等部分可以参考方法中的相应部分,此处不再赘述。

[0106] 第三方面,本发明实施例提供一种计算机可读存储介质,该介质上存储有计算机程序,在处理器执行所述计算机程序时可实现上述方法。

[0107] 需要说明的是,在本文中,诸如第一和第二等之类的关系术语仅仅用来将一个实体或者操作与另一个实体或操作区分开来,而不一定要求或者暗示这些实体或操作之间存在任何这种实际的关系或者顺序。而且,术语“包括”、“包含”或者其任何其他变体意在涵盖非排他性的包含,从而使得包括一系列要素的过程、方法、物品或者设备不仅包括那些要素,而且还包括没有明确列出的其他要素,或者是还包括为这种过程、方法、物品或者设备所固有的要素。在没有更多限制的情况下,由语句“包括一个……”限定的要素,并不排除在包括所述要素的过程、方法、物品或者设备中还存在另外的相同要素。

[0108] 以上实施例仅用以说明本发明的技术方案,而非对其限制;尽管参照前述实施例对本发明进行了详细的说明,本领域的普通技术人员应当理解:其依然可以对前述各实施例所记载的技术方案进行修改,或者对其中部分技术特征进行等同替换;而这些修改或者替换,并不使相应技术方案的本质脱离本发明各实施例技术方案的精神和范围。

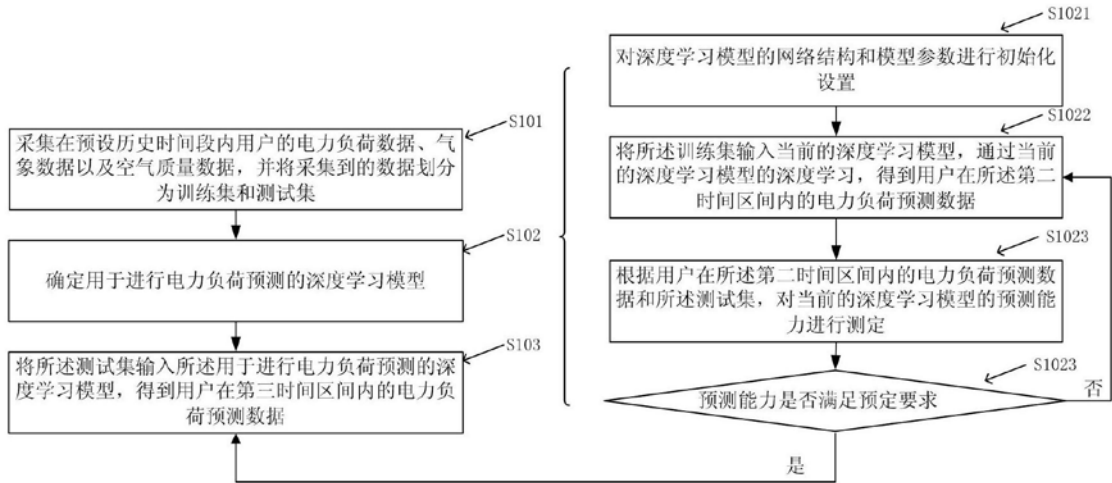


图1

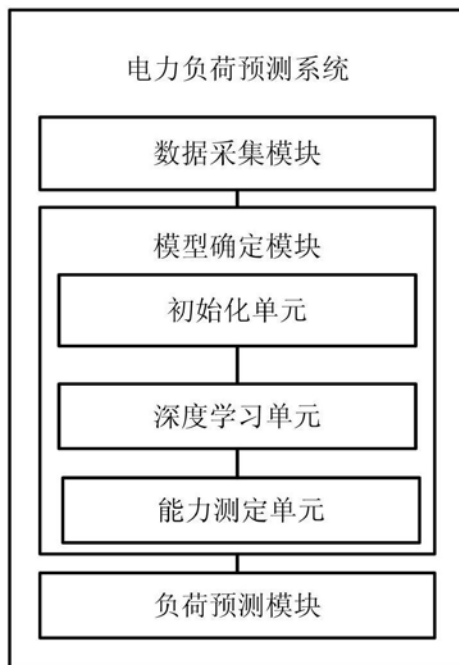


图2