

(12) 按照专利合作条约所公布的国际申请

(19) 世界知识产权组织
国际局

(43) 国际公布日
2020 年 7 月 16 日 (16.07.2020)



(10) 国际公布号
WO 2020/143409 A1

- (51) 国际专利分类号:
G06Q 30/02 (2012.01)
- (21) 国际申请号: PCT/CN2019/125856
- (22) 国际申请日: 2019 年 12 月 17 日 (17.12.2019)
- (25) 申请语言: 中文
- (26) 公布语言: 中文
- (30) 优先权:
201910012815.4 2019 年 1 月 7 日 (07.01.2019) CN
- (71) 申请人: 阿里巴巴集团控股有限公司 (**ALIBABA GROUP HOLDING LIMITED**) [—/CN]; 开曼群岛大开曼资本大厦一座四层 847 号邮箱, Grand Cayman (KY)。
- (72) 发明人: 张志强 (**ZHANG, Zhiqiang**); 中国浙江省杭州市余杭区文一西路 969 号 3 号楼 5 楼阿里巴巴集团法务部, Zhejiang 311121 (CN)。周俊


(ZHOU, Jun); 中国浙江省杭州市余杭区文一西路 969 号 3 号楼 5 楼阿里巴巴集团法务部, Zhejiang 311121 (CN)。李小龙 (**LI, Xiaolong**); 中国浙江省杭州市余杭区文一西路 969 号 3 号楼 5 楼阿里巴巴集团法务部, Zhejiang 311121 (CN)。

(74) 代理人: 北京博思佳知识产权代理有限公司 (**BEIJING BESTIPR INTELLECTUAL PROPERTY LAW CORPORATION**); 中国北京市海淀区上地三街 9 号嘉华大厦 B 座 409, Beijing 100085 (CN)。

(81) 指定国 (除另有指明, 要求每一种可提供的国家保护): AE, AG, AL, AM, AO, AT, AU, AZ, BA, BB, BG, BH, BN, BR, BW, BY, BZ, CA, CH, CL, CN, CO, CR, CU, CZ, DE, DJ, DK, DM, DO, DZ, EC, EE, EG, ES, FI, GB, GD, GE, GH, GM, GT, HN, HR, HU, ID, IL, IN, IR, IS, JO, JP, KE, KG, KH, KN, KP, KR, KW, KZ, LA, LC, LK, LR, LS, LU, LY, MA, MD, ME, MG, MK, MN, MW, MX,

(54) **Title:** METHOD AND DEVICE FOR PREDICTING BUSINESS INDICATORS

(54) 发明名称: 预测业务指标的方法及装置



(57) **Abstract:** A method for predicting business indicators executed by a computer, firstly, a data set sequence is acquired, wherein the data set sequence comprises m data sets corresponding to consecutive m time periods and arranged in chronological order, an ith data set in the m data sets comprises, in an ith time period, entity features of a business entity to be tested and respective indicator values of multiple business indicators to be tested of said business entity. The data set sequence is then input into a pre-trained recurrent neural network to obtain an output result; in this way, according to the output result, the respective indicator values of multiple business indicators to be tested of said business entity can be determined in the next time period of the mth time period.

MY, MZ, NA, NG, NI, NO, NZ, OM, PA, PE, PG, PH, PL,
PT, QA, RO, RS, RU, RW, SA, SC, SD, SE, SG, SK, SL,
SM, ST, SV, SY, TH, TJ, TM, TN, TR, TT, TZ, UA, UG,
US, UZ, VC, VN, ZA, ZM, ZW。

(84) 指定国 (除另有指明, 要求每一种可提供的地区
保护): ARIPO (BW, GH, GM, KE, LR, LS, MW, MZ,
NA, RW, SD, SL, ST, SZ, TZ, UG, ZM, ZW), 欧亚 (AM,
AZ, BY, KG, KZ, RU, TJ, TM), 欧洲 (AL, AT, BE, BG,
CH, CY, CZ, DE, DK, EE, ES, FI, FR, GB, GR, HR, HU,
IE, IS, IT, LT, LU, LV, MC, MK, MT, NL, NO, PL, PT,
RO, RS, SE, SI, SK, SM, TR), OAPI (BF, BJ, CF, CG, CI,
CM, GA, GN, GQ, GW, KM, ML, MR, NE, SN, TD, TG)。

本国际公布:

— 包括国际检索报告 (条约第21条(3))。

(57) 摘要: 一种计算机执行的预测业务指标的方法, 首先获取数据集序列, 该数据集序列包括对应于连续的m个时间段、且按照时间顺序排列的m个数据集, 所述m个数据集中第i个数据集包括, 第i时间段中, 待测业务实体的实体特征, 以及该待测业务实体的多个待测业务指标各自的指标值。然后将该数据集序列输入预先训练的循环神经网络, 获得输出结果; 如此, 根据输出结果, 即可确定第m时间段的下一时间段中, 待测业务实体的多个待测业务指标各自的指标值。

预测业务指标的方法及装置

技术领域

[01] 本说明书一个或多个实施例涉及机器学习领域，尤其涉及利用机器学习预测业务实体的业务指标的方法和装置。

5 背景技术

[02] 随着计算机技术的发展，机器学习已经应用到各种各样的技术领域，用于分析、预测各种业务数据。在许多应用场景中，需要对业务实体的各种业务指标进行预测，便于在预测值出现较大波动，或预测值与真实值差异较大的情况下，提前预警，或发现异常。

10 [03] 例如，在电商场景中，常常需要对商家的各种指标序列进行预测，如商家的每日营业额序列预测。有些场景会涉及到多个指标序列的联合预测，比如同时预测商家的每日交易笔单价，每日交易笔数等，如此，可以提前预警或尽快注意到一些异常现象，例如刷单现象。又例如，在互联网借贷场景中，常常需要对用户的各种业务指标进行预测，从而预知风险。

15 [04] 然而，常规技术中，面对多个业务实体，多种业务指标的情况，常常存在建模效率低，预测准确率低等问题。因此，希望能有改进的方案，更加有效地实现多业务指标的准确预测。

发明内容

20 [05] 本说明书一个或多个实施例描述了预测业务指标的方法和装置，其中采用循环神经网络针对多业务实体多业务指标进行联合建模，得到的联合模型可以适用于多实体多指标的预测，全面提高多指标预测的准确性和效率。

[06] 根据第一方面，提供了一种计算机执行的预测业务指标的方法，包括：

25 [07] 获取数据集序列，所述数据集序列包括对应于连续的 m 个时间段、且按照时间顺序排列的 m 个数据集，所述 m 个数据集中第 i 个数据集包括，第 i 时间段中，待测业务实体的实体特征，以及该待测业务实体的多个待测业务指标各自的指标值；

[08] 将所述数据集序列输入预先训练的循环神经网络，获得输出结果；

[09] 根据所述输出结果，确定第 m 时间段的下一时间段中，所述待测业务实体的所述多个待测业务指标各自的指标值。

[10] 在一个实施例中，上述待测业务实体包括商家；相应的，所述实体特征包括以下的至少一项：注册时长、商家规模、信誉等级、商品数目、商品类别、上架时长；所述多个待测业务指标包括以下指标中的多个：交易笔数、交易笔单价、交易总额、成交比例。

[11] 在另一实施例中，所述待测业务实体包括用户；相应的，所述多个待测业务指标包括，与消费行为相关的多个指标和/或与借贷行为的相关的多个指标。

[12] 在一种实施方式中，所述待测业务实体的实体特征包括，第一特征和第二特征，所述第一特征的特征值在所述 m 个时间段中保持不变，所述第二特征的特征值在所述 m 个时间段中不完全相同。

[13] 根据一个实施例，所述 m 个时间段包括，当前时刻所处的当前时间段，和从所述当前时间段向前追溯的 $m-1$ 个时间段。

[14] 在一个实施例中，所述循环神经网络包括，长短期记忆神经网络 LSTM。

[15] 根据一种实施方式，所述循环神经网络通过以下过程预先训练：

[16] 获取多个训练样本，其中包括第一训练样本，所述第一训练样本包括第一训练数据序列和第一标签，所述第一训练数据序列包括对应于连续的 m 个时间段、且按照时间顺序排列的 m 个训练数据集，所述 m 个训练数据集中第 j 个训练数据集包括，第 j 时间段中，第一业务实体的实体特征，以及该第一业务实体的所述多个待测业务指标各自的指标值；所述第一标签包括，采集到的所述第一业务实体的所述多个待测业务指标在第 m 时间段后的下一时间段中各自的指标值；

[17] 将所述第一训练数据序列输入所述循环神经网络，获得第一输出结果；

[18] 至少基于所述第一输出结果和所述第一标签，确定与第一训练样本对应的第一预测误差；

[19] 基于与所述多个训练样本中各个训练样本对应的预测误差，确定损失函数；

[20] 根据所述损失函数调整所述训练神经网络的网络参数，使得所述损失函数相比调整前减小。

[21] 根据一个实施例，所述循环神经网络包括输入层、循环单元和输出层；将所述第

一训练数据序列输入所述循环神经网络，获得第一输出结果包括：

[22] 通过所述输入层将所述 m 个训练数据集依次输入到所述循环单元，使得所述循环单元依次处理所述 m 个训练数据集，得到 m 次处理后的处理向量；

[23] 通过所述输出层对所述处理向量进行线性变换，得到所述第一输出结果。

5 [24] 在一个实施例中，通过以下方式确定损失函数：

[25] 基于所述多个样本中各个样本对应的预测误差确定总误差；

[26] 确定所述网络参数的正则化项；

[27] 将所述总误差和所述正则化项的和，确定为所述损失函数。

[28] 根据第二方面，提供一种计算机执行的预测业务指标的装置，包括：

10 [29] 数据序列获取单元，配置为获取数据集序列，所述数据集序列包括对应于连续的 m 个时间段、且按照时间顺序排列的 m 个数据集，所述 m 个数据集中第 i 个数据集包括，第 i 时间段中，待测业务实体的实体特征，以及该待测业务实体的多个待测业务指标各自的指标值；

[30] 输出结果获取单元，配置为将所述数据集序列输入预先训练的循环神经网络，获
15 得输出结果；

[31] 指标值确定单元，配置为根据所述输出结果，确定第 m 时间段的下一时间段中，所述待测业务实体的所述多个待测业务指标各自的指标值。

[32] 在一个实施例中，所述循环神经网络通过训练单元训练，所述训练单元包括：

[33] 样本获取模块，配置为获取多个训练样本，其中包括第一训练样本，所述第一训练样本包括第一训练数据序列和第一标签，所述第一训练数据序列包括对应于连续的 m
20 个时间段、且按照时间顺序排列的 m 个训练数据集，所述 m 个训练数据集中第 j 个训练数据集包括，第 j 时间段中，第一业务实体的实体特征，以及该第一业务实体的所述多个待测业务指标各自的指标值；所述第一标签包括，采集到的所述第一业务实体的所述多个待测业务指标在第 m 时间段后的下一时间段中各自的指标值；

25 [34] 结果获取模块，配置为将所述第一训练数据序列输入所述循环神经网络，获得第一输出结果；

[35] 误差确定模块，配置为至少基于所述第一输出结果和所述第一标签，确定与第一

训练样本对应的第一预测误差；

[36] 损失确定模块，配置为基于与所述多个训练样本中各个训练样本对应的预测误差，确定损失函数；

[37] 参数调整模块，配置为根据所述损失函数调整所述训练神经网络的网络参数，使得所述损失函数相比调整前减小。

[38] 根据第三方面，提供了一种计算机可读存储介质，其上存储有计算机程序，当所述计算机程序在计算机中执行时，令计算机执行第一方面的方法。

[39] 根据第四方面，提供了一种计算设备，包括存储器和处理器，其特征在于，所述存储器中存储有可执行代码，所述处理器执行所述可执行代码时，实现第一方面的方法。

[40] 根据本说明书实施例提供的方法和装置，通过利用多个业务实体的实体特征和待测业务指标的已知值的数据序列作为训练样本，训练循环神经网络，可以得到一个联合模型。该联合模型可以适用于多个待测业务实体的多个待测业务指标的预测。由于训练过程中所基于的训练数据，即包含实体的特征又包含指标数据，因此训练得到的联合模型更好地考虑和挖掘了实体间/指标间的关联关系，并且由于训练数据丰富，也使得预测的准确度更高，效果更好。

附图说明

[41] 为了更清楚地说明本申请实施例的技术方案，下面将对实施例描述中所需要使用到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申请的一些实施例，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它的附图。

[42] 图 1 为本说明书披露的一个实施例的实施场景示意图；

[43] 图 2 示出根据一个实施例的训练基于循环神经网络的联合模型的方法流程图；

[44] 图 3 示出根据一个实施例的通过 LSTM 神经网络处理训练数据序列的示意图；

[45] 图 4 示出根据一个实施例的预测业务指标的方法；

[46] 图 5 示出根据一个实施例的预测业务指标的装置的示意性框图。

具体实施方式

[47] 下面结合附图，对本说明书提供的方案进行描述。

[48] 如前所述，在多种应用场景中，都需要对业务实体的多个业务指标进行预测。在一种方案中，考虑到对于不同的实体（例如不同的商家）的同一指标预测模型应该具有个性化的差异，针对单个实体单个指标进行单独建模。然而，只对单一的指标序列进行建模预测，难以充分挖掘序列间的关联关系，并且，单个实体单个指标单独建模会面临这单个模型训练数据不足和模型太多的问题。

[49] 在另一种方案中，提出针对多个指标序列进行联合预测。然而，面对多个实体多个指标的预测问题，往往会因为实体数量太多（如支付宝交易涉及的商家上亿）而导致联合建模效率太低，最终只能针对单个实体的多个指标进行建模。

[50] 针对多实体多指标序列联合预测的问题，进一步的，在本说明书中的实施例，提出一种基于特征的联合建模方法。根据该方法，对多个业务实体多个业务指标使用统一模型进行建模，既避免了对单个实体单个指标建模遇到的训练数据不足和模型太多的问题，也充分考虑到了实体间/指标间的关联，使得建模更快，预测更准。

[51] 图 1 为本说明书披露的一个实施例的实施场景示意图。如图 1 所示，采集来自多个业务实体、关于多个业务指标的历史数据作为训练样本，训练基于循环神经网络的联合模型。更具体的，一个训练样本可以对应一个业务实体，例如一个商家，该样本用于训练的特征数据包括，该业务实体在 m 个连续时间段的实体特征，以及在该 m 个时间段中待测的多个业务指标各自的指标值。这些特征数据按照上述时间段整理成 m 个训练向量形式的数据集。该训练样本的标签数据可以是，上述业务实体在第 $m+1$ 个时间段中，上述多个业务指标的指标值。

[52] 基于这样的多个训练样本，可以训练上述基于循环神经网络的联合模型，确定模型参数。

[53] 在模型训练完成后，就可以实现多业务实体、多业务指标的预测。具体的，对于待测的业务实体 p ，获取该业务实体 p 的特征数据，该特征数据可以包括 m 个特征向量构成的序列，各个特征向量包括，业务实体 p 在 m 个时间段的对应时间段中的实体特征，以及待测的多个业务指标各自的指标值。将这样的特征数据输入上述训练好的联合模型，即可得到，该业务实体 p 在下一时间段中，待测的多个业务指标的指标值，从而实现多个指标共同预测。

[54] 下面首先描述上述联合模型的训练过程。

[55] 图 2 示出根据一个实施例的训练基于循环神经网络的联合模型的方法流程图。可以理解,该方法可以通过任何具有计算、处理能力的装置、设备、平台、设备集群来执行。如图 2 所示,训练过程至少包括以下步骤。

5 [56] 首先,在步骤 21,获取多个训练样本,所述多个训练样本涉及多个业务实体关于多个业务指标的历史数据,更具体的,其中每个训练样本包括与一个业务实体相关的训练数据序列和标签。为了描述的清楚,将其中任意的一个样本称为第一训练样本。需要理解,本文中的“第一”、“第二”的用语仅仅是为了描述和区分类似的对象,而不具有顺序或其他方面的限定。

10 [57] 具体而言,多个训练样本中任意的第一训练样本包括与第一业务实体相关的第一训练数据序列和第一标签,其中第一训练数据序列包括对应于连续的 m 个时间段、且按照时间顺序排列的 m 个训练数据集,第 j 个训练数据集包括,第 j 时间段中,第一业务实体的实体特征,以及该第一业务实体的多个待测业务指标各自的指标值;所述第一标签包括采集到的所述第一业务实体的所述多个待测业务指标在第 m 时间段后的下一时
15 间段中各自的指标值。

[58] 更清楚的,将上述第一业务实体记为 $E1$,对应的第一训练数据序列可以记为 $(D1, D2, \dots, Dm)$,其中包括了 m 个训练数据集 $D1, D2$ 到 Dm 。这 m 个训练数据集分别对应于连续的 m 个时间段,其中第 j 个训练数据集 Dj 对应于 m 个时间段中的第 j 时间段 Tj 。每个训练数据集都包含实体特征和待测指标值两部分。具体地,第 j 个训练数据集
20 Dj 包括,在第 j 时间段 Tj 中,上述第一业务实体 $E1$ 的实体特征 X ,以及该业务实体 $E1$ 在 Tj 时间段中待预测的 k 个业务指标的指标值 Y 。实体特征 X 和指标值 Y 分别可以构成向量 $x^{(j)}$,和向量 $y^{(j)}$,其中 $y^{(j)}$ 为 k 维向量。第 j 训练数据集 Dj 可以表示为,向量 $x^{(j)}$ 和 $y^{(j)}$ 的拼接 $[x^{(j)}; y^{(j)}]$ 。如此,第一训练数据序列可以表示为:

$$\{[x^{(1)}; y^{(1)}], [x^{(2)}; y^{(2)}], \dots, [x^{(j)}; y^{(j)}], \dots, [x^{(m)}; y^{(m)}]\}$$

[59] 第一训练样本还包括与该第一训练数据序列相对应的第一标签。与前述第一训练
25 数据序列的表示方式对应的,第一标签包括,采集到的第一业务实体 $E1$ 的所述 k 个待测业务指标在第 $m+1$ 时间段中各自的指标值。因此,第一标签可以记为向量 $y^{(m+1)}$ 。
下面结合具体例子进行描述。

[60] 如前所述,要训练的联合模型适用于各种业务实体,因此,上述作为训练数据的

第一业务实体可以是任意的具体的业务实体，例如是一个具体商家，或者是一个具体用户。

[61] 在上述第一业务实体为某个商家的情况下，业务实体的实体特征 X 可以包括该商家的总体属性特征，例如注册时长、商家规模、信誉等级等，也可以包括该商家所售卖的商品相关特征，例如商品数目、商品类别、上架时长，等等。

[62] 上述这些特征中，一部分特征可以是固定不变的特征，例如商家的属性特征，这些特征在所采集的 m 个时间段中是相同的；还可以有一部分特征是随时间变化的特征，例如商品数目。这样的特征在所采集的 m 个时间段中不完全相同。

[63] 在上述第一业务实体为某个商家的情况下， k 个待测业务指标可以包括以下指标中的多个：交易笔数、交易笔单价、交易总额、成交比例等等。

[64] 上述时间段的长短可以根据需要设定。例如，时间段可以是一天、1 小时、1 周、一个月等等， m 的数目也可以根据训练和预测的需要而设定，例如 m 为 7、10、30 等等。

[65] 在一个具体例子中，第一训练样本中的第一业务实体为商户标识等于 ID1 的商家，业务实体的实体特征 X 选取注册时长、商家规模、信誉等级、商品数目、商品类别等 20 项特征，待测业务指标 Y 包括交易笔数、交易笔单价、交易总额 3 项指标，即 $k=3$ 。并且，假定时间段设定为天， m 设定为 7。如此，针对该第一业务实体的第一训练数据序列即为，连续 7 天对应的 7 个训练数据集，第 j 天的训练数据集包括，第 j 天中该商家的实体特征构成的 20 维向量，和该商家在第 j 天中 3 个待测业务指标的指标值构成的 3 维向量。

[66] 对应的，第一训练样本的标签数据，即为上述商家在第 8 天中上述 3 个待测业务指标的指标值。这样的训练样本，相当于利用一周 7 天的训练数据序列，预测第 8 天的待测业务指标。

[67] 以上结合了第一业务实体为商家的例子进行了描述。在另一实施例，第一业务实体也可以是具体的用户。在第一业务实体为某个用户的情况下，提取的实体特征可以包括该用户的属性特征，例如注册时长、性别、年龄、职业类别、收入范围等等；也可以包括该用户的一些行为特征，例如，与好友的交互次数，浏览购物网站的时长，等等。用户的待测业务指标主要根据业务需求和业务场景而定，在分析和预测用户的消费行为的场景下，待测业务指标可以是与消费行为相关的多个指标，例如包括消费笔数、单笔

消费金额、消费总金额等等；在分析和预测用户的借贷行为的场景下，待测业务指标可以是与借贷行为的相关的多个指标，例如包括借贷次数、借贷总额、还款总额等等。

[68] 尽管以上给出了业务实体、实体特征和业务指标的具体例子，但是，本说明书实施例的方案并不局限于这些具体例子，而是可以扩展到更多业务场景。

5 [69] 并且，可以理解，以上所描述的第一训练样本是多个训练样本中的任意一个。每个训练样本都具有上述第一训练样本同样数据结构的训练数据序列和对应标签。

[70] 在如上所述获取到多个训练样本的基础上，在步骤 22，将上述第一训练样本中的第一训练数据序列输入循环神经网络，获得第一输出结果。

10 [71] 可以理解，循环神经网络（RNN, Recurrent Neural Networks）是一种时间递归神经网络，可用于处理序列数据。从网络结构的角度来说，循环神经网络包括输入层、循环单元和输出层；输入层用于获取序列数据，循环单元对应于神经网络的一个或多个隐含层，用于依次循环处理序列数据，输出层可以对循环单元经循环处理得到的处理向量进行进一步变换处理，得到整个神经网络的输出结果。

15 [72] 循环神经网络的时间递归性主要体现在循环单元，即隐含层的处理过程。在 RNN 中，隐含层的各个神经元节点会对之前的信息进行记忆并应用于当前输出的计算中。具体的，隐含层神经元的输入不仅包括来自输入层的输入，还包括该隐含层神经元上一时刻的状态输出，相应的，隐含层神经元的输出不仅与当前时刻输入层输入的向量相关，还与该节点之前的状态相关联。也就是说，t 时刻隐含层神经元状态可以表示为：

$$S_t = f(U * X_t + W * S_{t-1}),$$

20 其中， X_t 为 t 时刻输入层的状态， S_{t-1} 为 t-1 时刻隐含层神经元的状态，f 为计算函数，W, U 为权重。如此，循环单元将之前的状态循环回当前输入，考虑了历史输入的影响，因而适合于具有时序的数据序列。

[73] 在一个实施例中，在步骤 22，采用包含多个隐含层的 RNN 作为上述循环神经网络。

25 [74] 更进一步地，在一个实施例中，在传统 RNN 架构下，采用长短期记忆（LSTM, Long Short Term Memory）神经网络作为上述循环神经网络。

[75] 如前所述，在 RNN 中当前隐含层状态依赖于之前的状态输出，因此在处理长期记忆的情况下，需要将当前的隐含态的计算与前 n 次的计算关联，即 $S_t = f(U * X_t + W_1 * S_{t-1} + W_2 * S_{t-2} + \dots + W_n * S_{t-n})$ 。随着 n 的增大，计算量呈指数式增长，导致模型训练的时间

大幅增加。为此，提出 LSTM 模型来解决长期依赖的问题。

[76] 在 LSTM 中，通过设置让信息选择性通过的“遗忘门”来丢弃某些不再需要的信息，如此对输入的不必要的干扰信息进行判断和屏蔽，从而更好地对长期数据进行分析处理。

5 [77] 下面结合 LSTM 神经网络描述对第一训练数据序列进行处理的具体过程。

[78] 与前述常规循环神经网络类似的，LSTM 神经网络包括输入层，LSTM 单元和输出层，其中 LSTM 单元作为循环单元，可以包含若干隐含层，依次循环处理第一训练数据序列中的各个数据集。

10 [79] 图 3 示出根据一个实施例的通过 LSTM 神经网络处理训练数据序列的示意图。如图 3 所示，第一训练数据序列通过输入层被依次输入到 LSTM 单元，使得 LSTM 单元依次处理第一训练数据序列中的各个训练数据集。

[80] 具体而言，如前所述，第一训练数据序列包括按照对应的时间段顺序排列的 m 个训练数据集，其中，第 j 个训练数据集 D_j 可以表示为，向量 $x^{(j)}$ 和 $y^{(j)}$ 的拼接 $[x^{(j)}; y^{(j)}]$ ，其中 $x^{(j)}$ 为实体特征， $y^{(j)}$ 为待测业务指标的指标值。LSTM 单元按照数据集排列顺序，
15 依次读取和处理这 m 个训练数据集。

[81] 在第 1 次处理中，读取第 1 个训练数据集 $D_1 = [x^{(1)}; y^{(1)}]$ ，将该训练数据集 D_1 和初始的处理向量 h_0 共同输入到 LSTM 单元。LSTM 单元对 D_1 和 h_0 进行处理，得到处理向量 h_1 。

20 [82] 在下一时刻进行第 2 次处理，读取第 2 个训练数据集 $D_2 = [x^{(2)}; y^{(2)}]$ ，将该训练数据集 D_2 和前一时刻对第 1 个训练数据集的处理结果 h_1 ，共同作为当前输入，对 D_2 和 h_1 进行处理，从而得到处理向量 h_2 。如此继续。

[83] 在第 i 次处理中，LSTM 单元将第 i 个训练数据集，以及前一时刻对第 $i-1$ 个训练数据集的处理结果 h_{i-1} ，共同作为当前输入，得到处理向量 h_i 。直到第 m 次处理，LSTM 单元将第 m 个训练数据集，以及前一时刻对第 $m-1$ 个训练数据集的处理结果 h_{m-1} ，共同
25 作为当前输入，得到处理向量 h_m 。

[84] 然后，输出层将 LSTM 单元经过 m 次处理后得到的处理向量 h_m 进行线性变换，得到第一输出结果：

$$\hat{y}^{(m+1)} = Wh_m \quad (1)$$

其中, $\mathbf{W} \in \mathbb{R}^{k \times l}$ 是一个待优化的参数矩阵。

[85] 可以理解, 该第一输出结果是基于第一训练样本中与连续 m 个时间段对应的第一训练数据序列, 对第 $m+1$ 个时间段的待测业务指标的指标值的预测。

[86] 另一方面, 步骤 21 获取的第一训练样本还包括与第一训练数据序列对应的第一标签。因此, 接下来, 在步骤 23, 至少基于上述第一输出结果和所述第一标签, 确定与第一训练样本对应的第一预测误差。

[87] 可以通过多种具体算法确定上述第一预测误差。例如, 第一输出结果和第一标签均可表示为 k 维向量 (如前所述, k 为待测业务指标数目), 因此, 在一个例子中, 可以计算第一输出结果对应向量和第一标签对应向量之间的距离, 例如余弦距离, 欧式距离等, 将该距离作为第一预测误差。还可以将上述距离的平方作为第一预测误差。在其他实施例中, 还可以通过其他方式计算上述预测误差。

[88] 如此, 确定出与第一训练样本对应的第一预测误差。可以理解, 上述第一训练样本是多个训练样本中任意的一个样本。因此, 可以按照步骤 22 和 23 的方式, 处理每个训练样本, 从而得到多个训练样本中各个训练样本对应的预测误差。

[89] 于是在步骤 24, 至少基于与各个样本对应的预测误差, 确定损失函数。

[90] 可以理解, 对于一批训练样本, 损失函数是对这批训练样本的模型预测值与标准标签值之间误差的综合衡量。因此, 在一个实施例中, 基于各个训练样本对应的预测误差确定总误差, 基于该总误差确定损失函数。例如, 在一个例子中, 损失函数可以表示为:

$$\text{loss} = \frac{1}{2} \sum_{i=1}^n (\mathbf{y}_i^{(m+1)} - \hat{\mathbf{y}}_i^{(m+1)})^2 \quad (2)$$

[91] 在上式中, 第 i 个训练样本的预测误差表示为 $(\mathbf{y}_i^{(m+1)} - \hat{\mathbf{y}}_i^{(m+1)})^2$, 损失函数是将 n 个训练样本的预测误差求和而得到。

[92] 进一步的, 在一个实施例中, 在基于各个训练样本对应的预测误差确定总误差之外, 还确定循环神经网络的网络参数的正则化项, 将所述总误差和所述正则化项的和, 确定为损失函数。例如, 损失函数可以表示为:

$$\text{loss} = \frac{1}{2} \sum_{i=1}^n (\mathbf{y}_i^{(m+1)} - \hat{\mathbf{y}}_i^{(m+1)})^2 + \frac{\alpha}{2} \text{Reg}(\cdot) \quad (3)$$

其中, $\text{Reg}(\cdot)$ 为正则化项, 例如可以是 L2 正则化项。L2 正则化又可以表示为 $\|\mathbf{W}\|_2^2$, 可以通过对所有网络参数的平方求和 $\sum (\mathbf{w}_i)^2$ 而得到。因此, 正则化项可以刻画网络参数整

体的数值范围。

[93] 可以理解，还可以采用其他具体公式或算法来确定损失函数。

[94] 接着，在步骤 25，根据上述损失函数调整所述循环神经网络的网络参数，使得所述损失函数相比调整前减小。

5 [95] 可以理解，神经网络的训练目标是使得损失函数尽可能小，从而使得预测值与真实的标签值尽可能接近。在一个实施例中，通过误差反向传播的方式，调整各个网络参数，以最小化损失函数。

[96] 如前所述，正则化项刻画了网络参数整体的数值范围。在损失函数中添加正则化项的情况下，为了达到损失函数最小化的目标，网络参数的整体数值范围也会被优化到
10 较小的范围，从而避免出现参数取值差异过大的过拟合现象。

[97] 综合以上，通过采集多个业务实体在连续的各个时间段中的实体特征数据和待测业务指标的指标数据作为特征数据序列，采集下一时间段中待测业务指标的指标数据作为标签数据，由此形成了多个训练样本，用这样的多个训练样本训练循环神经网络，就可以得到用于多实体多业务指标的联合模型。换言之，在以上的循环神经网络训练完
15 成后，就可以作为所需的联合模型，针对待测业务实体，预测多个待测业务指标的指标值。

[98] 图 4 示出根据一个实施例的预测业务指标的方法。该方法可以通过任何具有计算、处理能力的装置、设备、平台、设备集群来执行。如图 4 所示，该预测方法包括以下步骤。

20 [99] 在步骤 41，获取用于待测业务实体的数据集序列，该数据集序列包括对应于连续的 m 个时间段、且按照时间顺序排列的 m 个数据集，所述 m 个数据集中第 i 个数据集包括，第 i 时间段中，待测业务实体的实体特征，以及该待测业务实体的多个待测业务指标各自的指标值。

[100] 需要理解，上述预测用的数据集序列，与训练过程中的训练数据序列具有对应一
25 致的数据结构。具体而言，以上数据集序列中时间段的长短， m 的数目需要与训练数据序列中的相同，待测业务实体的实体特征与训练样本中的业务实体的实体特征处于相同的特征空间，且待测业务指标也与训练样本的相同。

[101] 例如，在一个例子中，多个训练样本中的业务实体为各个商家，实体特征包括与商家有关的 20 项特征，待测业务指标包括 3 项指标，时间段为天， m 设定为 7。

[102] 在这样的情况下,待测业务实体可以是某个具体的待测商家 E_p ,步骤 41 的数据集序列可以包括对应于连续 7 天的 7 个数据集,第 i 天的数据集包括,商家 E_p 的实体特征构成的 20 维向量,例如包括注册时长、商家规模、信誉等级、商品数目、商品类别等,以及商家 E_p 的待测业务指标在第 i 天的指标值构成的 3 维向量,例如包括交易笔数、交易笔单价、交易总额。

[103] 在训练样本中的业务实体为各个用户的情况下,上述待测业务实体对应也为某个具体的待测用户,其实体特征和待测业务指标可以参照对训练样本的描述,不再赘述。

[104] 与训练样本序列类似的,待测业务实体的实体特征可以包括,在 m 个时间段中保持不变的特征,也可以包括在 m 个时间段中不完全相同的特征。

10 [105] 在一个实施例,为了对下一时间段的多个业务指标进行预测,一般地,采集从当前时间段向前追溯 $m-1$ 个时间段,共 m 个时间段的 m 个数据集,用于预测下一时间段中多个待测业务指标的指标值。例如,在时间段为天, $m=7$ 的情况下,可以采集从今天向前追溯 6 天,加上今天一共是连续 7 天各自的数据集,用于预测明天的业务指标值。

15 [106] 然而,可以理解,这并不是必须的。在一个实施例,上述 m 个时间段也可以均对应于已经过去的时间段,这可以适用于已知第 $m+1$ 个时间段中待测业务指标的真实值,想要通过联合模型得到预测值,然后通过预测值与真实值的差异,判定真实值是否出现异常的情况。

[107] 在获取到上述的数据集序列后,在步骤 42,将该数据集序列输入通过图 2 的方法训练的循环神经网络,获得输出结果。

20 [108] 如前所述,在一个实施例,上述循环神经网络包括,长短期记忆神经网络 LSTM。

[109] 更具体的,循环神经网络包括输入层、循环单元和输出层。相应的,在步骤 42,通过输入层将数据集序列中的 m 个数据集依次输入到循环单元,使得循环单元依次处理所述 m 个数据集,得到 m 次处理后的处理向量。

25 [110] 上述处理过程与结合图 4 所述的训练过程的处理相同。其中,在第 i 次处理中,循环单元将第 i 个数据集,以及前一刻对第 $i-1$ 个数据集的处理结果 h_{i-1} ,共同作为当前输入,得到处理向量 h_i 。直到第 m 次处理,循环单元将第 m 个数据集,以及前一刻对第 $m-1$ 个数据集的处理结果 h_{m-1} ,共同作为当前输入,得到 m 次处理后的处理向量 h_m 。

[111] 接着,通过输出层对处理向量 h_m 进行线性变换,就可以得到输出结果。

[112] 以上处理过程的网络参数,包括线性变换矩阵 W ,均通过训练过程而确定和优化。

[113] 于是,在步骤 43,根据上述输出结果,即可确定出,第 m 时间段后的下一时间段中,即第 $m+1$ 时间段中,待测业务实体的所述多个待测业务指标各自的指标值。

- 5 [114] 具体的,如式(4)所示,循环神经网络通过将循环单元的处理向量进行线性变换得到输出结果,经过线性变换后的输出结果通常为 k 维向量。通过该 k 维向量的各个元素值,可以确定出 k 个待测业务指标在第 $m+1$ 个时间段中分别对应的指标值。

$$\hat{y}_p^{(m+1)} = Wh_m \quad (4)$$

- 10 [115] 通过以上过程可以看到,通过利用多个业务实体的实体特征和待测业务指标的已知值的数据序列作为训练样本,训练循环神经网络,可以得到一个联合模型。该联合模型可以适用于多个待测业务实体的多个待测业务指标的预测。由于训练过程中所基于的训练数据,即包含实体的特征又包含指标数据,因此训练得到的联合模型更好地考虑和挖掘了实体间/指标间的关联关系,并且由于训练数据丰富,也使得预测的准确度更高,效果更好。

- 15 [116] 根据另一方面的实施例,提供了一种预测业务指标的装置,该装置可以部署在任何具有计算、处理能力的设备、平台或设备集群中。图 5 示出根据一个实施例的预测业务指标的装置的示意性框图。如图 5 所示,该预测装置 500 包括:

- 20 [117] 数据序列获取单元 51,配置为获取数据集序列,所述数据集序列包括对应于连续的 m 个时间段、且按照时间顺序排列的 m 个数据集,所述 m 个数据集中第 i 个数据集包括,第 i 时间段中,待测业务实体的实体特征,以及该待测业务实体的多个待测业务指标各自的指标值;

[118] 输出结果获取单元 52,配置为将所述数据集序列输入预先训练的循环神经网络,获得输出结果;

- 25 [119] 指标值确定单元 53,配置为根据所述输出结果,确定第 m 时间段的下一时间段中,所述待测业务实体的所述多个待测业务指标各自的指标值。

[120] 根据一个实施例,上述待测业务实体包括商家;在这样的情况下,实体特征包括以下中的至少一项:注册时长,商家规模,信誉等级,商品数目,商品类别,上架时长;所述多个待测业务指标包括以下指标中的多个:交易笔数,交易笔单价,交易总额,成

交比例。

[121] 根据另一实施例，上述待测业务实体包括用户；所述多个待测业务指标包括，与消费行为相关的多个指标，和/或，与借贷行为的相关的多个指标。

5 [122] 根据一种可能的实施方案，上述待测业务实体的实体特征包括，第一特征和第二特征，所述第一特征的特征值在所述 m 个时间段中保持不变，所述第二特征的特征值在所述 m 个时间段中不完全相同。

[123] 在一个实施例中，上述 m 个时间段包括，当前时刻所处的当前时间段，和从所述当前时间段向前追溯的 m-1 个时间段。

[124] 根据一个实施例，上述循环神经网络包括，长短期记忆神经网络 LSTM。

10 [125] 在一种实施方式中，所述循环神经网络通过训练单元 54 训练，该训练单元可以包含在预测装置 500 之中，也可以位于预测装置 500 之外。相应的，输出结果获取单元 52 可连接到该训练单元 54。在一个实施例中，训练单元 54 包括：

15 [126] 样本获取模块 541，配置为获取多个训练样本，其中包括第一训练样本，所述第一训练样本包括第一训练数据序列和第一标签，所述第一训练数据序列包括对应于连续的 m 个时间段、且按照时间顺序排列的 m 个训练数据集，所述 m 个训练数据集中第 j 个训练数据集包括，第 j 时间段中，第一业务实体的实体特征，以及该第一业务实体的所述多个待测业务指标各自的指标值；所述第一标签包括，采集到的所述第一业务实体的所述多个待测业务指标在第 m 时间段后的下一时间段中各自的指标值；

20 [127] 结果获取模块 542，配置为将所述第一训练数据序列输入所述循环神经网络，获得第一输出结果；

[128] 误差确定模块 543，配置为至少基于所述第一输出结果和所述第一标签，确定与第一训练样本对应的第一预测误差；

[129] 损失确定模块 544，配置为基于与所述多个训练样本中各个训练样本对应的预测误差，确定损失函数；

25 [130] 参数调整模块 545，配置为根据所述损失函数调整所述训练神经网络的网络参数，使得所述损失函数相比调整前减小。

[131] 在一个实施例中，所述循环神经网络包括，输入层，循环单元和输出层，

[132] 上述结果获取模块 542 配置为：

[133] 通过所述输入层将所述 m 个训练数据集依次输入到所述循环单元, 使得所述循环单元依次处理所述 m 个训练数据集, 得到 m 次处理后的处理向量;

[134] 通过所述输出层对所述处理向量进行线性变换, 得到所述第一输出结果。

[135] 根据一种实施方式, 所述损失确定模块 544 配置为,

5 [136] 基于所述多个样本中各个样本对应的预测误差确定总误差;

[137] 确定所述网络参数的正则化项;

[138] 将所述总误差和所述正则化项的和, 确定为所述损失函数。

[139] 如此, 通过训练单元 54 训练循环神经网络作为联合模型, 预测装置 500 通过利用训练单元 54 训练好的循环神经网络, 实现多业务实体多业务指标的预测。

10 [140] 根据另一方面的实施例, 还提供一种计算机可读存储介质, 其上存储有计算机程序, 当所述计算机程序在计算机中执行时, 令计算机执行结合图 2 和图 4 所描述的方法。

[141] 根据再一方面的实施例, 还提供一种计算设备, 包括存储器和处理器, 所述存储器中存储有可执行代码, 所述处理器执行所述可执行代码时, 实现结合图 2 和图 4 所述的方法。

15 [142] 本领域技术人员应该可以意识到, 在上述一个或多个示例中, 本发明所描述的功能可以用硬件、软件、固件或它们的任意组合来实现。当使用软件实现时, 可以将这些功能存储在计算机可读介质中或者作为计算机可读介质上的一个或多个指令或代码进行传输。

20 [143] 以上所述的具体实施方式, 对本发明的目的、技术方案和有益效果进行了进一步详细说明, 所应理解的是, 以上所述仅为本发明的具体实施方式而已, 并不用于限定本发明的保护范围, 凡在本发明的技术方案的基础之上, 所做的任何修改、等同替换、改进等, 均应包括在本发明的保护范围之内。

权利要求书

1. 一种计算机执行的预测业务指标的方法，包括：

获取数据集序列，所述数据集序列包括对应于连续的 m 个时间段、且按照时间顺序排列的 m 个数据集，所述 m 个数据集中第 i 个数据集包括，第 i 时间段中，待测业务实体的实体特征，以及该待测业务实体的多个待测业务指标各自的指标值；

将所述数据集序列输入预先训练的循环神经网络，获得输出结果；

根据所述输出结果，确定第 m 时间段的下一时间段中，所述待测业务实体的所述多个待测业务指标各自的指标值。

2. 根据权利要求 1 所述的方法，其中，所述待测业务实体包括商家，

所述实体特征包括以下中的至少一项：

注册时长、商家规模、信誉等级、商品数目、商品类别、上架时长；

所述多个待测业务指标包括以下指标中的多个：

交易笔数、交易笔单价、交易总额、成交比例。

3. 根据权利要求 1 所述的方法，其中，所述待测业务实体包括用户，

所述多个待测业务指标包括，与消费行为相关的多个指标，和/或，与借贷行为的相关的多个指标。

4. 根据权利要求 1 所述的方法，其中所述待测业务实体的实体特征包括，第一特征和第二特征，所述第一特征的特征值在所述 m 个时间段中保持不变，所述第二特征的特征值在所述 m 个时间段中不完全相同。

5. 根据权利要求 1 所述的方法，其中所述 m 个时间段包括，当前时刻所处的当前时间段，和从所述当前时间段向前追溯的 $m-1$ 个时间段。

6. 根据权利要求 1 所述的方法，其中所述循环神经网络包括，长短期记忆神经网络 LSTM。

7. 根据权利要求 1 所述的方法，其中所述循环神经网络通过以下过程预先训练：

获取多个训练样本，其中包括第一训练样本，所述第一训练样本包括第一训练数据序列和第一标签，所述第一训练数据序列包括对应于连续的 m 个时间段、且按照时间顺序排列的 m 个训练数据集，所述 m 个训练数据集中第 j 个训练数据集包括，第 j 时间段中，第一业务实体的实体特征，以及该第一业务实体的所述多个待测业务指标各自的指标值；所述第一标签包括，采集到的所述第一业务实体的所述多个待测业务指标在第 m 时间段后的下一时间段中各自的指标值；

将所述第一训练数据序列输入所述循环神经网络，获得第一输出结果；

至少基于所述第一输出结果和所述第一标签,确定与第一训练样本对应的第一预测误差;

基于与所述多个训练样本中各个训练样本对应的预测误差,确定损失函数;

根据所述损失函数调整所述训练神经网络的网络参数,使得所述损失函数相比调整

5 前减小。

8. 根据权利要求 7 所述的方法,其中,所述循环神经网络包括输入层、循环单元和输出层,

将所述第一训练数据序列输入所述循环神经网络,获得第一输出结果包括:

10 通过所述输入层将所述 m 个训练数据集依次输入到所述循环单元,使得所述循环单元依次处理所述 m 个训练数据集,得到 m 次处理后的处理向量;

通过所述输出层对所述处理向量进行线性变换,得到所述第一输出结果。

9. 根据权利要求 7 所述的方法,其中,所述确定损失函数包括,

基于所述多个样本中各个样本对应的预测误差确定总误差;

确定所述网络参数的正则化项;

15 将所述总误差和所述正则化项的和,确定为所述损失函数。

10. 一种计算机执行的预测业务指标的装置,包括:

20 数据序列获取单元,配置为获取数据集序列,所述数据集序列包括对应于连续的 m 个时间段、且按照时间顺序排列的 m 个数据集,所述 m 个数据集中第 i 个数据集包括,第 i 时间段中,待测业务实体的实体特征,以及该待测业务实体的多个待测业务指标各自的指标值;

输出结果获取单元,配置为将所述数据集序列输入预先训练的循环神经网络,获得输出结果;

指标值确定单元,配置为根据所述输出结果,确定第 m 时间段的下一时间段中,所述待测业务实体的所述多个待测业务指标各自的指标值。

25 11. 根据权利要求 10 所述的装置,其中,所述待测业务实体包括商家,所述实体特征包括以下中的至少一项:

注册时长、商家规模、信誉等级、商品数目、商品类别、上架时长;

所述多个待测业务指标包括以下指标中的多个:

交易笔数、交易笔单价、交易总额、成交比例。

30 12. 根据权利要求 10 所述的装置,其中,所述待测业务实体包括用户,所述多个待测业务指标包括与消费行为相关的多个指标,和/或

与借贷行为的相关的多个指标。

13. 根据权利要求 10 所述的装置, 其中所述待测业务实体的实体特征包括, 第一特征和第二特征, 所述第一特征的特征值在所述 m 个时间段中保持不变, 所述第二特征的特征值在所述 m 个时间段中不完全相同。

5 14. 根据权利要求 10 所述的装置, 其中所述 m 个时间段包括, 当前时刻所处的当前时间段, 和从所述当前时间段向前追溯的 $m-1$ 个时间段。

15. 根据权利要求 10 所述的装置, 其中所述循环神经网络包括, 长短期记忆神经网络 LSTM。

10 16. 根据权利要求 10 所述的装置, 其中所述循环神经网络通过训练单元训练, 所述训练单元包括:

样本获取模块, 配置为获取多个训练样本, 其中包括第一训练样本, 所述第一训练样本包括第一训练数据序列和第一标签, 所述第一训练数据序列包括对应于连续的 m 个时间段、且按照时间顺序排列的 m 个训练数据集, 所述 m 个训练数据集中第 j 个训练数据集包括, 第 j 时间段中, 第一业务实体的实体特征, 以及该第一业务实体的所述多个待测业务指标各自的指标值; 所述第一标签包括, 采集到的所述第一业务实体的所述多个待测业务指标在第 m 时间段后的下一时间段中各自的指标值;

结果获取模块, 配置为将所述第一训练数据序列输入所述循环神经网络, 获得第一输出结果;

20 误差确定模块, 配置为至少基于所述第一输出结果和所述第一标签, 确定与第一训练样本对应的第一预测误差;

损失确定模块, 配置为基于与所述多个训练样本中各个训练样本对应的预测误差, 确定损失函数;

参数调整模块, 配置为根据所述损失函数调整所述训练神经网络的网络参数, 使得所述损失函数相比调整前减小。

25 17. 根据权利要求 16 所述的装置, 其中, 所述循环神经网络包括, 输入层, 循环单元和输出层,

所述结果获取模块配置为:

通过所述输入层将所述 m 个训练数据集依次输入到所述循环单元, 使得所述循环单元依次处理所述 m 个训练数据集, 得到 m 次处理后的处理向量;

30 通过所述输出层对所述处理向量进行线性变换, 得到所述第一输出结果。

18. 根据权利要求 16 所述的装置, 其中, 所述损失确定模块配置为,

基于所述多个样本中各个样本对应的预测误差确定总误差；

确定所述网络参数的正则化项；

将所述总误差和所述正则化项的和，确定为所述损失函数。

5 19.一种计算机可读存储介质，其上存储有计算机程序，当所述计算机程序在计算机中执行时，令计算机执行权利要求 1-9 中任一项的所述的方法。

20. 一种计算设备，包括存储器和处理器，其特征在于，所述存储器中存储有可执行代码，所述处理器执行所述可执行代码时，实现权利要求 1-9 中任一项所述的方法。




图 1




图 2




图 3




图 4




图 5

INTERNATIONAL SEARCH REPORT

International application No.

PCT/CN2019/125856

A. CLASSIFICATION OF SUBJECT MATTER

G06Q 30/02(2012.01)i

According to International Patent Classification (IPC) or to both national classification and IPC

B. FIELDS SEARCHED

Minimum documentation searched (classification system followed by classification symbols)

G06Q; G06F

Documentation searched other than minimum documentation to the extent that such documents are included in the fields searched

Electronic data base consulted during the international search (name of data base and, where practicable, search terms used)

WPI, EPODOC, CNPAT, CNKI, IEEE: 预测, 指标, 特征, 序列, 时间, 时刻, 神经网络, 循环神经网络, 多个, 参数, 变量, 输出, 训练, 长短期记忆神经网络, 标签, predict, RNN, LSTM, time, sequence, character+, tag, output, train+, multi, neural network, parameter

C. DOCUMENTS CONSIDERED TO BE RELEVANT

Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
PX	CN 110009384 A (ALIBABA GROUP HOLDING LIMITED) 12 July 2019 (2019-07-12) claims 1-20	1-20
X	CN 108932567 A (YANSHAN UNIVERSITY) 04 December 2018 (2018-12-04) description, paragraphs 0060-0104	1-6, 10-15, 19, 20
A	CN 109033450 A (TAIYUAN UNIVERSITY OF TECHNOLOGY) 18 December 2018 (2018-12-18) entire document	1-20
A	WO 2017093953 A1 (TATA CONSULTANCY SERVICES LIMITED) 08 June 2017 (2017-06-08) entire document	1-20
A	CN 108764539 A (CHINA YANGTZE POWER CO., LTD.) 06 November 2018 (2018-11-06) entire document	1-20
A	CN 108038580 A (STATE GRID JIANGSU ELECTRIC POWER COMPANY, WUXI POWER SUPPLY COMPANY et al.) 15 May 2018 (2018-05-15) entire document	1-20



Further documents are listed in the continuation of Box C.



See patent family annex.

* Special categories of cited documents:

“A” document defining the general state of the art which is not considered to be of particular relevance

“E” earlier application or patent but published on or after the international filing date

“L” document which may throw doubts on priority claim(s) or which is cited to establish the publication date of another citation or other special reason (as specified)

“O” document referring to an oral disclosure, use, exhibition or other means

“P” document published prior to the international filing date but later than the priority date claimed

“T” later document published after the international filing date or priority date and not in conflict with the application but cited to understand the principle or theory underlying the invention

“X” document of particular relevance; the claimed invention cannot be considered novel or cannot be considered to involve an inventive step when the document is taken alone

“Y” document of particular relevance; the claimed invention cannot be considered to involve an inventive step when the document is combined with one or more other such documents, such combination being obvious to a person skilled in the art

“&” document member of the same patent family

Date of the actual completion of the international search

03 March 2020

Date of mailing of the international search report

20 March 2020

Name and mailing address of the ISA/CN

China National Intellectual Property Administration
No. 6, Xitucheng Road, Jimenqiao Haidian District, Beijing
100088
China

Facsimile No. (86-10)62019451

Authorized officer

Telephone No.

INTERNATIONAL SEARCH REPORT
Information on patent family members

International application No.

PCT/CN2019/125856

Patent document cited in search report			Publication date (day/month/year)	Patent family member(s)			Publication date (day/month/year)
CN	110009384	A	12 July 2019	None			
CN	108932567	A	04 December 2018	None			
CN	109033450	A	18 December 2018	None			
WO	2017093953	A1	08 June 2017	EP	3384399	A1	10 October 2018
				US	2018365715	A1	20 December 2018
				BR	112018011359	A2	04 December 2018
				AU	2016362126	A1	19 July 2018
				CA	3007338	A1	08 June 2017
CN	108764539	A	06 November 2018	None			
CN	108038580	A	15 May 2018	None			

国际检索报告

国际申请号

PCT/CN2019/125856

A. 主题的分类 G06Q 30/02 (2012.01) i 按照国际专利分类 (IPC) 或者同时按照国家分类和 IPC 两种分类																							
B. 检索领域 检索的最低限度文献 (标明分类系统和分类号) G06Q; G06F 包含在检索领域中的除最低限度文献以外的检索文献 在国际检索时查阅的电子数据库 (数据库的名称, 和使用的检索词 (如使用)) WPI, EPDOC, CNPAT, CNKI, IEEE: 预测, 指标, 特征, 序列, 时间, 时刻, 神经网络, 循环神经网络, 多个, 参数, 变量, 输出, 训练, 长短期记忆神经网络, 标签, predict, RNN, LSTM, time, sequence, character+, tag, output, train+, multi, neural network, parameter																							
C. 相关文件 <table border="1"> <thead> <tr> <th>类 型*</th> <th>引用文件, 必要时, 指明相关段落</th> <th>相关的权利要求</th> </tr> </thead> <tbody> <tr> <td>PX</td> <td>CN 110009384 A (阿里巴巴集团控股有限公司) 2019年 7月 12日 (2019 - 07 - 12) 权利要求1-20</td> <td>1-20</td> </tr> <tr> <td>X</td> <td>CN 108932567 A (燕山大学) 2018年 12月 4日 (2018 - 12 - 04) 说明书第0060-0104段</td> <td>1-6, 10-15, 19, 20</td> </tr> <tr> <td>A</td> <td>CN 109033450 A (太原理工大学) 2018年 12月 18日 (2018 - 12 - 18) 全文</td> <td>1-20</td> </tr> <tr> <td>A</td> <td>WO 2017093953 A1 (TATA CONSULTANCY SERVICES LIMITED) 2017年 6月 8日 (2017 - 06 - 08) 全文</td> <td>1-20</td> </tr> <tr> <td>A</td> <td>CN 108764539 A (中国长江电力股份有限公司) 2018年 11月 6日 (2018 - 11 - 06) 全文</td> <td>1-20</td> </tr> <tr> <td>A</td> <td>CN 108038580 A (国网江苏省电力公司无锡供电公司 等) 2018年 5月 15日 (2018 - 05 - 15) 全文</td> <td>1-20</td> </tr> </tbody> </table>			类 型*	引用文件, 必要时, 指明相关段落	相关的权利要求	PX	CN 110009384 A (阿里巴巴集团控股有限公司) 2019年 7月 12日 (2019 - 07 - 12) 权利要求1-20	1-20	X	CN 108932567 A (燕山大学) 2018年 12月 4日 (2018 - 12 - 04) 说明书第0060-0104段	1-6, 10-15, 19, 20	A	CN 109033450 A (太原理工大学) 2018年 12月 18日 (2018 - 12 - 18) 全文	1-20	A	WO 2017093953 A1 (TATA CONSULTANCY SERVICES LIMITED) 2017年 6月 8日 (2017 - 06 - 08) 全文	1-20	A	CN 108764539 A (中国长江电力股份有限公司) 2018年 11月 6日 (2018 - 11 - 06) 全文	1-20	A	CN 108038580 A (国网江苏省电力公司无锡供电公司 等) 2018年 5月 15日 (2018 - 05 - 15) 全文	1-20
类 型*	引用文件, 必要时, 指明相关段落	相关的权利要求																					
PX	CN 110009384 A (阿里巴巴集团控股有限公司) 2019年 7月 12日 (2019 - 07 - 12) 权利要求1-20	1-20																					
X	CN 108932567 A (燕山大学) 2018年 12月 4日 (2018 - 12 - 04) 说明书第0060-0104段	1-6, 10-15, 19, 20																					
A	CN 109033450 A (太原理工大学) 2018年 12月 18日 (2018 - 12 - 18) 全文	1-20																					
A	WO 2017093953 A1 (TATA CONSULTANCY SERVICES LIMITED) 2017年 6月 8日 (2017 - 06 - 08) 全文	1-20																					
A	CN 108764539 A (中国长江电力股份有限公司) 2018年 11月 6日 (2018 - 11 - 06) 全文	1-20																					
A	CN 108038580 A (国网江苏省电力公司无锡供电公司 等) 2018年 5月 15日 (2018 - 05 - 15) 全文	1-20																					
☐ 其余文件在C栏的续页中列出。 ☒ 见同族专利附件。																							
<table border="0"> <tr> <td> * 引用文件的具体类型: “A” 认为不特别相关的表示了现有技术一般状态的文件 “E” 在国际申请日的当天或之后公布的在先申请或专利 “L” 可能对优先权要求构成怀疑的文件, 或为确定另一篇引用文件的公布日而引用的或者因其他特殊理由而引用的文件 (如具体说明的) “O” 涉及口头公开、使用、展览或其他方式公开的文件 “P” 公布日先于国际申请日但迟于所要求的优先权日的文件 </td> <td> “T” 在申请日或优先权日之后公布, 与申请不相抵触, 但为了理解发明之理论或原理的在后文件 “X” 特别相关的文件, 单独考虑该文件, 认定要求保护的发明不是新颖的或不具有创造性 “Y” 特别相关的文件, 当该文件与另一篇或者多篇该类文件结合并且这种结合对于本领域技术人员为显而易见时, 要求保护的发明不具有创造性 “&” 同族专利的文件 </td> </tr> </table>			* 引用文件的具体类型: “A” 认为不特别相关的表示了现有技术一般状态的文件 “E” 在国际申请日的当天或之后公布的在先申请或专利 “L” 可能对优先权要求构成怀疑的文件, 或为确定另一篇引用文件的公布日而引用的或者因其他特殊理由而引用的文件 (如具体说明的) “O” 涉及口头公开、使用、展览或其他方式公开的文件 “P” 公布日先于国际申请日但迟于所要求的优先权日的文件	“T” 在申请日或优先权日之后公布, 与申请不相抵触, 但为了理解发明之理论或原理的在后文件 “X” 特别相关的文件, 单独考虑该文件, 认定要求保护的发明不是新颖的或不具有创造性 “Y” 特别相关的文件, 当该文件与另一篇或者多篇该类文件结合并且这种结合对于本领域技术人员为显而易见时, 要求保护的发明不具有创造性 “&” 同族专利的文件																			
* 引用文件的具体类型: “A” 认为不特别相关的表示了现有技术一般状态的文件 “E” 在国际申请日的当天或之后公布的在先申请或专利 “L” 可能对优先权要求构成怀疑的文件, 或为确定另一篇引用文件的公布日而引用的或者因其他特殊理由而引用的文件 (如具体说明的) “O” 涉及口头公开、使用、展览或其他方式公开的文件 “P” 公布日先于国际申请日但迟于所要求的优先权日的文件	“T” 在申请日或优先权日之后公布, 与申请不相抵触, 但为了理解发明之理论或原理的在后文件 “X” 特别相关的文件, 单独考虑该文件, 认定要求保护的发明不是新颖的或不具有创造性 “Y” 特别相关的文件, 当该文件与另一篇或者多篇该类文件结合并且这种结合对于本领域技术人员为显而易见时, 要求保护的发明不具有创造性 “&” 同族专利的文件																						
国际检索实际完成的日期 2020年 3月 3日		国际检索报告邮寄日期 2020年 3月 20日																					
ISA/CN的名称和邮寄地址 中国国家知识产权局 (ISA/CN) 中国北京市海淀区蓟门桥西土城路6号 100088 传真号 (86-10)62019451		受权官员 赵昕 电话号码 86-(10)-53961319																					

国际检索报告
关于同族专利的信息

国际申请号

PCT/CN2019/125856

检索报告引用的专利文件			公布日 (年/月/日)	同族专利			公布日 (年/月/日)
CN	110009384	A	2019年 7月 12日	无			
CN	108932567	A	2018年 12月 4日	无			
CN	109033450	A	2018年 12月 18日	无			
WO	2017093953	A1	2017年 6月 8日	EP	3384399	A1	2018年 10月 10日
				US	2018365715	A1	2018年 12月 20日
				BR	112018011359	A2	2018年 12月 4日
				AU	2016362126	A1	2018年 7月 19日
				CA	3007338	A1	2017年 6月 8日
CN	108764539	A	2018年 11月 6日	无			
CN	108038580	A	2018年 5月 15日	无			