

基于空间深度置信网络的风速预测优化方法*

许皓宇¹, 薛巍¹, 张涛¹, 谢洪亮²

(1.清华大学 计算机科学与技术系, 北京 100084; 2.远景能源(南京)软件技术有限公司, 上海 200050)

摘要: 风能是目前应用最为广泛、技术最为成熟的可再生能源。为了保证风电场的稳定和安全运行, 风速的准确预测至关重要。除传统的数值天气预报以外, 机器学习技术已经广泛应用于不同时间尺度的风速预测。然而这些工作大多局限于单一地点的风速序列分析, 没有考虑和利用风速的空间相关性。对此, 使用深度置信网络(Deep Belief Network, DBN)对同一区域内多个地点的风速序列进行空间相关性特征识别。在训练过程中, 深度置信网络充分挖掘了该区域内历史风速的联合分布, 借此改善未来的风速预测。多组风速预测实验表明, 空间深度置信网络能够有效降低风速的预测误差, 经过空间深度置信网络重构后的风速预测误差平均降低了 0.4 m/s。

关键词: 深度置信网络; 风速预测; 高斯过程回归

中图分类号: TP181

文献标识码: A

DOI: 10.16157/j.issn.0258-7998.212141

中文引用格式: 许皓宇, 薛巍, 张涛, 等. 基于空间深度置信网络的风速预测优化方法[J]. 电子技术应用, 2022, 48(8): 111-116, 122.

英文引用格式: Xu Haoyu, Xue Wei, Zhang Tao, et al. The improvement of wind speed prediction using spatial deep belief network[J]. Application of Electronic Technique, 2022, 48(8): 111-116, 122.

The improvement of wind speed prediction using spatial deep belief network

Xu Haoyu¹, Xue Wei¹, Zhang Tao¹, Xie Hongliang²

(1.Department of Computer Science and Technology, Tsinghua University, Beijing 100084, China;

2.Envision Energy Software Technology Limited, Shanghai 200050, China)

Abstract: Wind energy is the most widely used renewable energy. Accurate wind speed prediction is critical for the safety and stability of wind power system. Besides traditional numerical weather prediction, the machine learning technique has been used in wind speed prediction of different time scales. However, most previous studies focused on the wind speed sequence of single station and ignored the spatial dependency and correlation of wind. To improve the prediction with spatial information, this paper tries to extract the wind spatial correlation features in one region area and reconstruct the wind speed using deep belief network(DBN). The experiment results of different regions prove that the spatial deep belief network can reduce the prediction error significantly and increase the accuracy of wind speed prediction by 0.4 m/s on average.

Key words: deep belief network; wind speed prediction; Gaussian process regression

0 引言

随着环境污染以及能源紧缺问题的加剧, 风能作为一种可再生的清洁能源在各国得到了迅速的发展。目前, 风力发电在我国的电源结构占比已超过了核能, 仅次于火力和水力发电。而在欧美各国, 风力发电的总电量占比已经超过 10%。风速变化非常剧烈, 具有很强的波动性和随机性, 导致风力发电无法保证稳定的输电功率, 为保证供电网络的稳定, 大量的风电能源被浪费。同时, 由于风力资源的不稳定, 一旦风电功率达到穿透功率, 将严重威胁电网的安全运行。风速和风功率的准确预测对于风能的进一步的开发和利用至关重要。

目前, 针对风速的长短期预测已经进行了大量的研究。传统的数值天气预报以大气动力学方程为基础, 从当前天气状态逐步向前迭代积分来预报未来的风速。数值天气预报模式包含了大规模偏微分方程求解, 需要消耗大量的计算资源。随着人工智能和机器学习技术的快速发展, 将基于数据的机器学习技术应用于风速预测得到了逐步深入的研究。

机器学习算法利用历史数据来训练模型, 在模型训练好后就可以基于过去的特征预测未来风速, 相比数值天气预报, 模型推理需要的计算资源大大减少。一些经典的机器学习模型包括线性回归(Linear Regression)、可支持向量机回归(Support Vector Machine)和不同结构的人工神经网络(Artificial Neural Network)等都被用于短期

* 基金项目: 国家重点研发计划项目(2016YFA0602103)

(0~12 h)的风速预报^[1-6]。这些工作首先将历史数据转化为特征和预测目标,进行简单的数据预处理后使用模型训练和学习,在短期的风速预测上能够取得不亚于数值天气预报的精度^[7]。

上述机器学习预测方法在选取特征时均局限于单一地点风速和相关气象因子(这种预测技术称之为单点预测),没有考虑到风速的空间特性。风速的物理特性决定了风速在区域内的分布存在一定的规律并满足一定的约束^[8]。受到不同地形及风速的不稳定性的影响,这些规律或约束很难用确切的数学函数表示。因此,本文提出使用深度置信网络(Deep Belief Network, DBN)从数据中学习和挖掘复杂混沌的风速的空间规律和约束,并利用学习到的规律和约束重构和改善单一地点的风速预测结果。

深度置信网络是一个概率生成模型,能够建立输入变量之间的联合分布,通过学习到的联合分布 DBN 可以完成特征提取、数据压缩与重构、图像降噪等任务。经过 DBN 提取的特征(即隐藏层节点)可以将音乐分类的准确率提高 14%^[9]。将 DBN 应用于“瑞士卷”数据压缩,可以无损地将三维数据压缩至二维再恢复^[10]。经过训练的 DBN 网络也可以重构有噪声的原始数据达到降噪的目标。DBN 也被用于提取不同气象因子(风速、温度、气压、湿度)之间的规律用于重构天气状态^[11]。

本文比较了多种机器学习算法的 12~72 h 单点风速预测性能,随后使用 DBN 改善了其中误差最低的单点预测结果,经过 DBN 重构的预测误差下降达到平均 0.4 m/s。

1 风速预测问题

按照预测目标、时间范围,风速预测可以分为短期、中期和长期预测,不同时间尺度的预测及其主要应用见表 1。

表 1 不同时间尺度风速预测和应用场景	
预测种类	应用场景
短期预测(0~6 h)	市场清算、短期调度、负载均衡
中期预测(6~24 h)	风机上线/离线计划、运行安全风险控制
长期预测(1 天以上)	减少风机维修损失,风电场建设规划

表 1 中对于不同时间尺度的风速预测的划分并不是严格的。我国能源局发布的《风电功率预测功能规范》中规定了超短期和短期预测两种预测任务^[12]。其中超短期预测要求预测未来 0~4 h 的风速和风功率,短期预测要求预测 0~72 h 的风速和风功率,时间分辨率均为 15 min。

目前用于风速预测的主要方法包括数值天气预报和统计回归(机器学习)模型。统计回归模型也是后续本文单点试验所选用的模型。

尽管在短期风速预测上机器学习方法取得了成功,但在中长期(12~72 h)预测上机器学习却无法达到数值天气预报的精度。这是因为中长期预测中预测目标和特

征的相关性相比短期预测大大降低,且在几十个小时的时间里,很多天气现象都会对风速产生明显的影响,再加上风速具有很强的波动性,导致中长期风速预测难度显著增加。而中长期的风速预测对于风电场的任务调度、成本和收益估算等具有重要的意义,因此本文致力于提高中长期风速预测的精度。

2 深度置信网络

2.1 DBN 模型结构和训练

深度置信网络(DBN)是一个包括多层隐藏层的神经网络模型^[13]。DBN 既可以解决有监督学习中的分类问题,也可以训练一个无监督学习的生成模型。本文主要采用用于重构的无监督生成型 DBN,其结构如图 1 所示。




图 1 DBN 网络基础结构^[13]

图 1 中每一层都是一个受限玻尔兹曼机(Restricted Boltzmann Machines, RBM),每一层的输出作为下一层的输入。每一层的 RBM 包含可见层 v 和隐藏层 h , b 为可见层偏移量, c 为隐藏层偏移量, W 为可见层和隐藏层之间的权值矩阵。模型的能量函数形式如式(1):

$$E(v, h) = -b^T v - c^T h - h^T W v$$
 (1)

自可见层开始向上依次训练每一层 RBM 完成无监督 DBN 的训练^[14]。

2.2 针对风速预测空间深度置信网络

风速的空间特性来源复杂,同时受到地形的影响,很难用统一固定的数学函数表示。文献[8]研究了在同一方向上相距 10~30 km 的多个地点的风速情况,发现风速呈现很强的时延相似性。此外,在一些特殊地形,例如盆地、山谷,风速也将受到一定的约束。由于地形的影响,一个地区的规律和物理约束很难推广到其他区域。因而,本文采用深度置信网络来通过历史数据自动学习和挖掘具体某一地区内空间风速分布的规律。

DBN 可以从数据训练和学习到变量的联合概率分布。如果将某一地区内多个观测点的历史风速数据输入到 DBN 中,DBN 就可以学习到风速的空间分布规律(即联合分布),而这些内在的规律和特征在 DBN 内部通过权值矩阵、偏移量和隐藏层节点来存储和表示。在完成

DBN 的训练后, DBN 可以对输入的一组空间风速预测进行重构。重构过程中, DBN 将判断输入的预测风速是否满足之前学习到的风速分布规律并根据规律对预测风速进行修正, 生成新的一组风速预测。新的风速预测是 DBN 在原预测基础上根据历史空间风速分布规律修改得出的。

基于 DBN 的风速预测改进算法的具体流程如下:

(1) 构建训练数据集 $x_1, x_2, x_3, \dots, x_n$, 其中 x_i 代表时刻 i 风场风速向量, 包含了 d 个地点的风速值。

(2) 确定 DBN 的结构和参数(层数、每层节点数、训练代数、学习率), 使用训练数据集无监督训练 DBN。

(3) 完成训练后, 输入时刻 n 之后的风速预测序列 $x_{n+1}, x_{n+2}, x_{n+3}, \dots$ 进行重构, DBN 返回每一时刻重构后的修正预测值。

3 面向风速预测的 DBN 参数选择与训练

同其他深度学习模型一样, DBN 的参数对于 DBN 的性能影响非常大。DBN 的参数包括通过训练更新的模型参数(权值矩阵和偏移量 $\langle b, c, W \rangle$), 以及需要在训练前决定的学习率 η 、训练迭代次数和网络结构参数等, 这些参数称为超参数(hyper parameter)。通过训练更新的权值矩阵和偏移量取决于训练数据和超参数, 选择合理的超参数对于 DBN 性能具有重要的意义。

在监督学习中会定义预测和标签的损失函数, 最终选择损失函数最低的超参, 而无监督 DBN 的目标是减少重构后的风速预测误差, 定义重构后的预测风速与观测风速之间的均方根误差(Root Mean Squared Error, RMSE)为评价指标, 即选取一组超参使得 DBN 重构后的风速预测结果 RMSE 最低。

传统的自动超参调优和选择算法包括网格搜索(Grid Search)、随机搜索(Random Search)。网格搜索在超参数空间建立网格, 需要进行的采样(模型训练)次数随超参数指数级增长。网格搜索会在不重要的超参上浪费大量的采样, 导致耗费大量的计算资源, 因此网格搜索并不适合训练成本昂贵的 DBN 超参调优。文献[15]则通过实验和理论分析证明随机搜索相比网格搜索更加高效, 能够以更少的采样次数和计算成本寻找到更优超参(更优模型)。为了能够以尽可能低的成本完成超参调优和选择, 本文采用代理模式优化(Surrogate-Based Optimization)。代理模式优化通过对目标优化问题建立一个代理模式来预测每一组超参数的模型训练结果。代理模式基于统计回归方法构建, 与真实模式有很强的相似性, 计算成本低廉, 可以进行大量采样。通过在代理模式进行充分的采样和搜索, 多数无意义的搜索和采样将被过滤, 每一组优质的候选超参数根据代理模式生成, 进行真实模型训练后更新和改进代理模式。随着代理模式的精确度不断提高, 最终能够寻找到最优超参数, 即最优 DBN 模型。通过代理模式优化来进行 DBN 超参调优和选择的

流程如图 2 所示。文献[16]、[17]使用代理模式优化对大量的深度学习和传统的机器学习模型进行超参调优, 结果表明, 代理模式优化的性能明显优于随机搜索、网格搜索等传统算法。

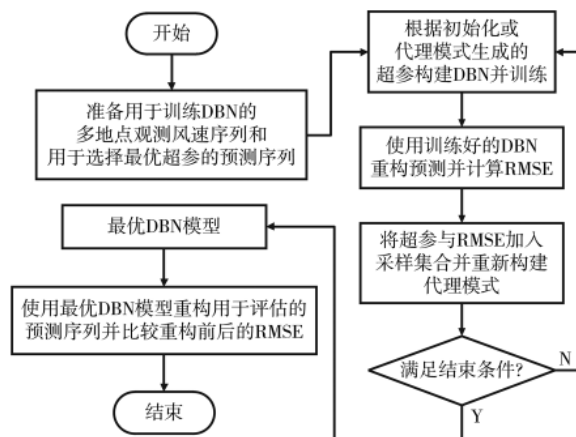


图 2 DBN 模型超参选择、训练和重构流程

4 单点风速预测

单点风速预测指的是利用单一站点的历史风速来预测该站点未来风速的技术。本文选择了 4 种具有代表性的机器学习模型进行单点预测, 包括: 线性回归(Linear Regression)^[18]、梯度提升回归树(Gradient Boosting Regression Tree, GBRT)、支持向量机回归(Support Vector Regression, SVR)和高斯过程回归(Gaussian Process, GP)。

线性回归是应用最广泛也是最简单的回归模型, 其训练成本非常低, 适合处理高维稀疏特征空间的分类和回归问题^[18]。相比线性回归, 其他 3 种模型都是非线性模型。梯度提升回归树是决策树类模型的一种, 相比于单决策树模型, 它通过大量简单的决策树组合克服了单决策树模型容易过拟合的缺陷, 同时通过 boosting 思想保证了收敛速率, 具有训练速度快、对异常数据鲁棒性强等优点^[19]。支持向量机回归利用核函数将特征空间映射到新的特征空间从而实现非线性回归。高斯过程回归则通过建立训练数据的联合分布来解决回归问题, 能够根据特征预测概率分布。

本文选取了国内某区域内 9 个测风塔一年的历史数据来进行单点风速预测实验, 每个测风塔每隔 10 min 记录一次观测数据, 包括风速、温度和气压。预测时选取过去 7 天的历史数据作为输入特征, 分别以未来 12 h 和未来 72 h 的观测作为预测目标, 每个模型都进行了五折交叉验证。表 2 和表 3 展示了使用 4 种模型对每个测风塔进行 12 h 和 72 h 预报的 RMSE。

从两组预测实验可以发现, 除了测风塔 4 和 8 之外, 高斯过程回归的预测误差是最低的。同时, 高斯过程的性能非常稳定, 即使在不是最优模型的观测站 4 和 8, 与 RMSE 最优模型的差距也不超过 0.2 m/s。

表 2 12 h 风速预测实验

测风塔	线性回归	GBRT	SVR	GP
1	2.180	2.229	2.182	2.128
2	2.318	2.453	2.382	2.199
3	2.392	2.477	2.484	2.264
4	2.414	3.399	2.350	2.352
5	2.433	2.549	2.492	2.282
6	2.839	3.122	3.113	2.408
7	3.206	3.679	3.361	2.717
8	2.235	3.167	2.207	2.286
9	3.427	3.304	4.244	2.667
平均	2.502	2.884	2.571	2.329

表 3 72 h 风速预测实验

测风塔	线性回归	GBRT	SVR	GP
1	2.369	2.414	2.457	2.335
2	2.497	2.536	2.555	2.465
3	2.751	2.808	2.792	2.375
4	3.128	3.757	3.160	3.303
5	3.002	3.052	3.040	2.315
6	2.883	2.752	2.914	2.509
7	3.723	2.892	4.117	2.669
8	3.091	3.663	3.178	3.090
9	3.169	3.127	2.952	2.688
平均	2.957	3.000	3.018	2.639

5 风速预测重构实验

5.1 长间距风速重构实验

长间距代表区域内不同观测点的距离为几十千米，第 4 节用于单点预测实验的 9 个测风塔相互间的距离在 10~60 km。本文使用 DBN 来重构误差最低的高斯过程回归预测结果，并比较重构前后风速预测情况的变化，如表 4 所示。

表 4 长间距风速重构结果

测风塔	12 h 预测 RMSE		72 h 预测 RMSE	
	GP	GP+DBN	GP	GP+DBN
1	2.128	2.078	2.335	2.286
2	2.199	2.193	2.465	2.453
3	2.264	2.225	2.375	2.238
4	2.352	2.343	3.303	2.665
5	2.282	2.268	2.315	2.308
6	2.408	2.333	2.509	2.436
7	2.717	2.417	2.669	2.639
8	2.286	2.228	3.090	2.540
9	2.667	2.458	2.688	2.524
平均	2.329	2.261	2.639	2.454

从表 4 中可以看到，尽管 9 个观测站平均改善不大，12 h 预测误差降低 0.068 m/s，72 h 预测误差降低 0.185 m/s，但 DBN 重构后所有测风塔的预测都优于 GP

的预测结果，说明 DBN 重构非常稳定且没有损失。此外，在测风塔 7 的 12 h 预测、测风塔 4 和 8 的 72 h 预测上，DBN 重构后的结果都有相当明显的改善，最大改善达到了 0.55 m/s。这些测风塔的预测误差明显高于其他测风塔，但经过 DBN 重构修正，预测误差降到了平均水平，说明 DBN 对较差的预测结果有更为明显的改善。

图 3 展示了测风塔 8 的 72 h 预测结果在 DBN 重构前后的变化情况。图 3 的两条曲线分别是 GP 的预测误差和 DBN 重构预测误差的天平均，可以看到在大多数误差较大的时段，DBN 重构后的预测误差显著低于 GP 预测误差。DBN 重构 GP 测风塔风速预测结果的实验结果表明，DBN 能够从数据中学习几十公里间距的风速相关性特征，并利用学习到的信息和特征来改善整个区域的风速预测结果，对原预测比较差的情况改善尤为明显。




图 3 DBN 重构前后风速误差曲线
(横坐标代表不同日，纵坐标风速预测的 RMSE)

5.2 短间距风速重构实验

相比于长距离的空间相关性，短距离(小于 10 km)的空间特性主要出现在相同风电场的不同风机之间。风机的间隔一般小于 5 km，由于风机的运转也会对风速产生影响，即众所周知的尾流影响，因而短间距的风速空间特性更为复杂。本文选取国内某个风场进行风速预测重构实验，该风场包括 49 个风机，风机间隔 1~5 km，每台风机每隔 6 min 记录一次风速和风电功率，时间长度为 1 年。选取前 80% 时间的记录作为训练数据，使用其余 20% 来验证 DBN 对风速预测的改善能力。

从图 4 可以看到，49 个风机的风速预测经过 DBN 重构后均得到了改善，改善幅度为 0.1~0.7 m/s，大多数风机的风速预测结果改善了 0.4 m/s。这一结果从空间角度验证了 DBN 的改善效果。

图 5 展示了经过 DBN 重构后，每天风场所有风机平均风速的预测误差的变化情况，图 5 中标记点为预测误差的日平均变化，即 $error_{AfterDBN} - error_{BeforeDBN}$ 。从图 5 中可以看出，风场总平均风速改善的天数超过了总天数的一半以上，同时在某些时期改善幅度非常大，例如第 2、6、19 和 29 天，风场平均风速误差下降了约 2 m/s。整体来看，




图4 风场内不同风机风速预测改善情况统计




图5 DBN 重构后风场平均风速预测误差改善情况

长期上 DBN 对于风速预测的改善也很明显。

图6中的两条曲线分别代表风场总平均风速 GP 预测和 DBN 重构后的天平误差。从图6中可以看出,第18和23天的单点预测误差是很低的,经过 DBN 后上升到 3 m/s,处于平均水平。而单点预测误差很差的第3、9、29天和误差高于 4 m/s 的天中,DBN 重构后误差都有了明显下降,第29天的预测误差从 8 m/s 下降到 6 m/s。因此,虽然在预测误差很低的情况下 DBN 可能导致预测误差上升,但可以极大改善风速预测误差很大的情况,有利于提高风速预测的稳定性。整体来看,DBN 对风速




图6 风场总平均风速预测误差变化

预测误差呈现明显的改善效果。

本实验中,风机的运转使得风的空间特性更加复杂,但 DBN 通过数据依然能够捕捉到相关规律,进而优化单点预测的结果,平均改善幅度达到 0.4 m/s。相比5.1节长间距情况下平均改善0.185 m/s的结果,说明距离越近,风速的空间内在规律和约束程度越强,DBN 的优化潜力也越大。

6 结论

本文比较了目前主流的单点风速预测算法,分析了它们的不足之处,进一步提出了利用深度置信网络学习风速的空间特性规律和约束来改善风速预测结果的方法。通过实验和分析,主要结论如下:

(1)基于单点的风速预测模型中,高斯过程(GP)的预测误差最低,并且预测性能稳定,在所有单点预测试验中均表现优异;

(2)DBN 能够充分学习和挖掘风速的空间分布规律和相关性特征,并且适用于不同间距(1~60 km)的情况;

(3)DBN 能够利用学习到的规律重构和改善风速预测,重构后的每个地点的预测误差最大降低 0.7 m/s,平均降低 0.4 m/s;

(4)DBN 对于预测比较差的情况改善尤为明显,改善幅度甚至可以达到 2 m/s,这对于提高风速预测的稳定性有着重要的意义;

(5)DBN 在改善一些地点的预测的时候并不会增加其他地点的预测误差;

(6)DBN 存在降低高质量单点预测精度的现象,这可能源于多点风速预测误差的不一致,改进方案值得进一步深入研究。

参考文献

- [1] KANI S A P, MOUSAVI S M, KAVIANI A K, et al. A new integrated approach for very short-term wind speed prediction using linear regression among ann and markov chain[Z]. 2008.
- [2] SALCEDO-SANZ S, ORTIZ-GARC A E G, PEREZ-BEL-LIDO A M, et al. Short term wind speed prediction based on evolutionary support vector regression algorithms[J]. Expert Systems with Applications An International Journal, 2011, 38(4): 4052-4057.
- [3] TRONCOSO A, SALCEDO-SANZ S, CASANOVA-MATEO C, et al. Local models-based regression trees for very short-term wind speed prediction[J]. Renewable Energy, 2015, 81: 589-598.
- [4] VOYANT C, MUSELLI M, PAOLI C, et al. Numerical weather prediction(NWP) and hybrid ARMA/ANN model to predict global radiation[J]. Energy, 2012, 39(1): 341-355.
- [5] BARBOUNIS T G, THEOCHARIS J B, ALEXIADIS M C, et al. Long-term wind speed and power forecasting using local recurrent neural network models[J]. IEEE Transactions on

Energy Conversion, 2006, 21(1): 273-284.

- [6] KULIGOWSKI R J, BARROS A P. Localized precipitation forecasts from a numerical weather prediction model using artificial neural networks[J]. Weather & Forecasting, 2010, 13(4): 1194-1204.
- [7] SOMAN S S, ZAREIPOUR H, MALIK O, et al. A review of wind power and wind speed forecasting methods with different time horizons[C]//North American Power Symposium. IEEE Xplore, 2010: 1-8.
- [8] ALEXIADIS M C, DOKOPOULOS P S, SAHSAMANOGLU H S. Wind speed and power forecasting based on spatial correlation models[J]. IEEE Transactions on Energy Conversion, 1999, 14(3): 836-842.
- [9] HAMEL P, ECK D. Learning features from music audio with deep belief networks[C]//International Society for Music Information Retrieval Conference, Ismir 2010, Utrecht, Netherlands,

August. DBLP, 2010: 339-344.

- [10] 胡昭华, 宋耀良. 基于 Autoencoder 网络的数据降维和重构[J]. 电子与信息学报, 2009, 31(5): 1189-1192.
- [11] GROVER A, KAPOOR A, HORVITZ E. A deep hybrid model for weather forecasting[C]//ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2015: 379-386.
- [12] 国家电网公司. Q/GDW 588—2011 风电功率预测功能规范[M]. 北京: 中国电力出版社, 2011.
- [13] HINTON G E. Deep belief networks[J]. Scholarpedia, 2009, 4(6): 5947.
- [14] HINTON G E, OSINDERO S, TEH Y, et al. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
- [15] BERGSTRA J, BENGIO Y. Random search for hyper-para-

(下转第 122 页)

(上接第 110 页)

配置信息等数据格式简单、数据量小及需要缩短应用程序响应时间的场景。而对于数据量比较大、数据格式比较复杂的应用场景, 适合选择 File 文件和 SQLite 数据库存储与访问机制。如果经常需要大批量处理数据, 则选择 SQLite 数据库更合适。在需要实时更新移动端设备应用程序数据的场景, 或者需要将移动端设备的数据发送给远端服务器进行处理的场景, 则需要选择网络存储与访问机制, 随着网络性能和移动终端设备处理能力的提升, 现在越来越多的应用程序选择这种机制。

4 结论

随着 5G 技术的不断发展和成熟, 5G 在各领域的应用速度也不断加快, 应用程度也日益深化, 同时也为移动应用的开发者们提供了更大的发挥空间。但是移动应用程序的开发效率和性能已经成为当前移动应用开发最为关注的问题, 而数据的存储与访问是开发应用程序时需要解决的最基本的问题^[15]。本文对 Flutter 开发框架下 4 种存储与访问机制的实现原理、实现方法进行研究与分析, 并展示出具体实现代码, 为 Flutter 项目开发提供了有效范例。最后, 通过对 key-value 键值对、File 文件、SQLite 数据库和网络 4 种数据存储访问机制优缺点的分析, 给出了应用场景建议, 为 Flutter 项目开发者选择合适的数据存储与访问机制提供了重要依据。

参考文献

- [1] Frank Zammetti. Flutter 实战[M]. 贡国栋, 任强, 译. 北京: 清华大学出版社, 2020.
- [2] CHRIS S. Dart 语言程序设计[M]. 韩国恺, 译. 北京: 人民邮电出版社, 2012.
- [3] Alessandro Biessek. Flutter 入门与实践[M]. 李强, 译. 北京: 清华大学出版社, 2020.

- [4] 亢少军. Dart 语言实战: 基于 Flutter 框架的程序开发[M]. 北京: 清华大学出版社, 2020.
- [5] TRAN T. Flutter native performance and expressive UI/UX[D]. Helsinki: Metropolia University of Applied Sciences, 2020.
- [6] Flutter Favorite. Shared_preference[EB/OL]. (2021-04-16) [2021-08-05]. https://pub.flutter-io.cn/packages/shared_preferences.
- [7] Flutter Favorite. Path_provide[EB/OL]. (2021-04-17) [2021-08-05]. https://pub.flutter-io.cn/packages/path_provider.
- [8] Flutter Favorite. Sqflite[EB/OL]. (2021-04-16) [2021-08-05]. <https://pub.flutter-io.cn/packages/sqflite>.
- [9] 倪红军. Flutter 开发零基础入门[M]. 北京: 清华大学出版社, 2021.
- [10] 何瑞群. Flutter 从 0 到 1 构建大前端应用[M]. 北京: 电子工业出版社, 2019.
- [11] 张益琿. 用 Flutter 极速构建原生应用[M]. 北京: 清华大学出版社, 2019.
- [12] 汪若彪, 史国芳, 施尹志, 等. 基于 Flutter 的跨平台的工业移动应用软件设计[J]. 仪表技术, 2021(2): 1-3, 70.
- [13] 杜文. Flutter 实战[M]. 北京: 机械工业出版社, 2020.
- [14] 萧文翰. Flutter 从 0 基础到 App 上线[M]. 北京: 电子工业出版社, 2020.
- [15] 黄阳. 一个跨平台的移动应用开发和运行支撑平台的研究与实现[D]. 南京: 南京大学, 2013.

(收稿日期: 2021-08-05)

作者简介:

倪红军(1975-), 男, 硕士, 副教授, 主要研究方向: 移动应用开发技术、教学改革研究、实验室建设与管理。

周巧扣(1982-), 男, 硕士, 副教授, 主要研究方向: 管理信息系统、机器学习。



扫码下载电子文档

- [3] ZHANG X, XIONG H, ZHOU W, et al. Picking deep filter responses for fine-grained image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1134–1142.
- [4] ZHAO B, WU X, FENG J, et al. Diversified visual attention networks for fine-grained object classification[J]. IEEE Transactions on Multimedia, 2017, 19(6): 1245–1256.
- [5] YANG Q, L. Z. Y. B. SA-Net: shuffle attention for deep convolutional neural networks[J]. arXiv Preprint arXiv: 2102.00240, 2021.
- [6] LIU W, ANGUELOV D, ERHAN D, et al. Ssd: single shot multibox detector[C]//European Conference on Computer Vision. Springer, Cham, 2016: 21–37.
- [7] HU T, QI H, HUANG Q, et al. See better before looking closer: weakly supervised data augmentation network for fine-grained visual classification[J]. arXiv Preprint arXiv: 1901.09891, 2019.
- [8] YANG Z, LUO T, WANG D, et al. Learning to navigate for fine-grained classification[C]//Proceedings of the European Conference on Computer Vision (ECCV), 2018: 420–435.
- [9] FU J, LIU J, TIAN H, et al. Dual attention network for scene segmentation[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 3146–3154.
- [10] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132–7141.
- [11] WANG X, GIRSHICK R, GUPTA A, et al. Non-local neural networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7794–7803.
- [12] MA N, ZHANG X, ZHENG H T, et al. Shufflenet v2: practical guidelines for efficient cnn architecture design[C]//Proceedings of the European Conference on Computer Vision (ECCV), 2018: 116–131.
- [13] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770–778.
- [14] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv preprint arXiv: 1409.1556, 2014.
- [15] LIN T Y, ROYCHOWDHURY A, MAJI S. Bilinear CNN models for fine-grained visual recognition[C]//ICCV, 2015: 1449–1457.
- [16] FU J, ZHENG H, MEI T. Look closer to see better: recurrent attention convolutional neural network for fine-grained image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 4438–4446.
- [17] MOGHIMI M, BELONGIE S J, SABERIAN M J, et al. Boosted convolutional neural networks[C]//BMVC, 2016, 5: 6.
- [18] ZHENG H, FU J, MEI T, et al. Learning multi-attention convolutional neural network for fine-grained image recognition[C]//Proceedings of the IEEE International Conference on Computer Vision, 2017: 5209–5217.
- [19] ZHENG H, FU J, ZHA Z J, et al. Looking for the devil in the details: learning trilinear attention sampling network for fine-grained image recognition[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 5012–5021.
- (收稿日期: 2021-07-25)
- 作者简介:**
潘新辰(1996-), 通信作者, 男, 硕士研究生, 主要研究方向: 工业信息化, E-mail: 1573749331@qq.com。
杨小健(1963-), 男, 教授, 主要研究方向: 工业信息化、计算机控制。
秦岭(1980-), 男, 讲师, 主要研究方向: 工业信息化。
- +++++
- (上接第 116 页)
- meter optimization[J]. Journal of Machine Learning Research, 2012, 13(1): 281–305.
- [16] THORNTON C, HUTTER F, HOOS H H, et al. Auto-WEKA: automated selection and hyper-parameter optimization of classification algorithms[C]//Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. ACM, 2013: 847–855.
- [17] BERGSTRA J, BARDENET R, BENGIO Y, et al. Algorithms for hyper-parameter optimization[C]//Advances in Neural Information Processing Systems, 2011: 2546–2554.
- [18] EXPLAINED P M D. Introduction to linear regression analysis[J]. Technometrics, 2007, 170(2): 856–857.
- [19] FRIEDMAN J H. Greedy function approximation: a gradient boosting machine[J]. Annals of Statistics, 2001, 29(5): 1189–1232.
- (收稿日期: 2021-09-10)
- 作者简介:**
许皓宇(1992-), 男, 硕士, 主要研究方向: 机器学习、参数估计。
薛巍(1974-), 通信作者, 男, 博士, 副教授, 主要研究方向: 量化不确定性分析、高性能计算, E-mail: xuewei@tsinghua.edu.cn。
张涛(1988-), 男, 博士, 主要研究方向: 地球系统模式不确定性量化分析、机器学习。



扫码下载电子文档



扫码下载电子文档

版权声明

经作者授权，本论文版权和信息网络传播权归属于《电子技术应用》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、DOAJ、美国《乌利希期刊指南》、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《电子技术应用》编辑部

中国电子信息产业集团有限公司第六研究所