

数据驱动的无线信道可用吞吐量估计与预测方法

肖遥, 刘峻铄, 龙智夫, 邱才明

(华中科技大学电子信息与通信学院, 湖北 武汉 430074)

摘要: 无线局域网技术正蓬勃发展, 但随之而来的新问题严重影响了无线信道的通信质量。无线信道质量对指导路由器应对突发拥塞和选择合适信道具有重大意义。以信道可用吞吐量为指标设计了一套解决方案: 首先, 采用侵入式数据采集方法收集信道数据, 使用神经网络训练并估计当前时刻的信道可用吞吐量; 然后, 采用非侵入式数据采集方法收集信道数据, 使用改进的递归神经网络模型预测未来一段时间的信道可用吞吐量。在真实数据上的实验表明, 该方案可以有效地对信道可用吞吐量进行估计与预测, 对路由器的决策有着指导意义。

关键词: 无线信道; 数据驱动; 神经网络; 吞吐量估计与预测

中图分类号: TN925

文献标志码: A

doi: 10.11959/j.issn.2096-3750.2023.00341

A data-driven approach to wireless channel available throughput estimation and prediction

XIAO Yao, LIU Junshuo, LONG Zhifu, QIU Caiming

School of Electronic Information and Communications, Huazhong University of Science and Technology, Wuhan 430074, China

Abstract: The rapid development of wireless local area network technology has brought about new challenges that significantly affect the communication quality of wireless channels. Wireless channel quality is crucial for guiding routers in managing sudden congestion and selecting appropriate channels. A set of solutions using channel available throughput as an indicator was designed. Firstly, invasive data collection methods were used to collect channel data, and an artificial neural network was trained to estimate the available throughput of the channel at the current time. Subsequently, non-invasive data collection methods were utilized to collect channel data, and an improved recurrent neural network model was employed to predict the available throughput of the channel for a future period. Experiments on the real data show that the scheme can effectively estimate and predict the available throughput of the channel, providing guidance for router decisions.

Key words: wireless channel, data-driven, neural network, throughput estimation and prediction

0 引言

对于无线用户而言, 无线业务的服务质量至关重要。随着无线局域网 (WLAN, wireless local area network) 技术^[1-2]的迅速发展, 设备密集部署、新老协议共存、高质量无线业务需求增加等一系列问题, 使得无线信道变得混乱和拥塞, 严重影响了接

入点 (AP, access point) 的业务服务质量, 降低了用户站点 (STA, station) 的无线业务体验^[3]。因此, 对无线网络的服务质量进行定量的估计和预测, 指导 AP 选择合适的信道, 提升服务质量以提高 STA 的无线业务体验是有意义和必要的。

在 IEEE 802.11 协议中, 已经有多个物理指标被用于评估无线网络信道的质量, 如接收信号强度

收稿日期: 2022-12-14; 修回日期: 2023-04-12

通信作者: 邱才明, caiming@hust.edu.cn

基金项目: 国家自然科学基金资助项目 (No.12141107)

Foundation Item: The National Natural Science Foundation of China (No.12141107)

指示 (RSSI, received signal strength indicator)^[4]、信干噪比 (SINR, signal to interference plus noise ratio)^[5]和误码率 (BER, bit error rate)^[6]等, 然而这些指标并不能直观全面地反映无线网络的服务质量。考虑无线业务的吞吐量可以直观地反映业务质量^[7-8], 将信道的可用吞吐量作为衡量信道质量的指标具有其独特的意义。信道的可用吞吐量被定义为信道数据传输速率 (理论最大值) 与当前时刻无线业务所占用的吞吐量之差, 该物理量定量地表示了信道当前能够承受无线业务的能力。当信道可用吞吐量较低时, 信道业务繁忙或干扰严重, 进行无线业务可能导致服务质量下降; 反之, 当信道可用吞吐量较高时, 信道相对空闲或干扰较少, 进行无线业务时可以获得更好的体验。

目前, 对于信道可用吞吐量的研究主要基于模型: 通过构建数学模型对无线网络的物理原理和协议机制进行描述, 并基于所构建的数学模型对信道可用吞吐量进行估计。例如, Hu 等^[9]建立了一个单跳间隙模型捕捉单跳网络的竞争流量吞吐量和包对间隙变化之间的关系; Jain 和 Dovrolis^[10]基于端到端的思想, 构建了自加载周期流 (SLoPS, self-loading periodic streams) 方法, 在不对无线信道作出任何干扰的情况下估计信道可用吞吐量; Shah 等^[11]直接对载波侦听多路访问/冲突避免 (CSMA/CA, carrier sense multiple access with collision avoid) 机制进行细致地分析与数学建模, 提出了信道可用吞吐量的估计方案^[12]。

基于模型的方法通过所构建的数学模型直观地描述了无线网络的物理原理和协议机制, 能够定量地分析各个物理量对整个系统的影响并作出针对性的改进和优化。然而, 这类方法在构建模型的过程中往往需要进行一定程度的化简与假设, 实际场景可能无法满足这些假设, 进而导致模型性能的降低; 同时, 这类方法通常只针对某一类协议或者场景, 在新环境中的表现可能不佳, 具有一定的局限性。相比之下, 基于数据驱动的深度学习方法凭借无须建模、自动学习特征、泛化能力好等特点, 成为了解决问题的优先选择^[13-14]。

综上所述, 本文提出了一种数据驱动的无线信道可用吞吐量估计与预测方法。具体而言, 本文首先使用“打流”操作估计当前时刻信道的可用吞吐量; 在这基础上设计并实施了一套入侵式数据采集方法, 用于构建数据集, 从而训练人工神经网络 (ANN, ar-

tificial neural network) 对当前时刻信道可用吞吐量进行估计。为了获得用于预测的连续信道可用吞吐量时间序列数据, 本文提出并实现了一套非侵入式的数据采集方案, 通过训练改进的递归神经网络 (RNN, recurrent neural network) 模型对信道可用吞吐量进行预测。在真实数据集上的实验结果表明, 本文提出的方法可以更准确地估计和预测无线信道的可用吞吐量, 从而为无线网络的优化和改进提供有力的支持。

1 信道当前时刻可用吞吐量估计

为了完成对未来一段时间信道可用吞吐量的预测, 首先需要当前时刻信道可用吞吐量进行估计。因此, 本节提出了一种标定信道可用吞吐量的方法, 在此基础上设计并实现了入侵式数据采集方案。详细阐述了方案中各模块的工作原理和配合方式, 并利用该方案完成了数据集的构建。最后, 具体说明了如何确定 ANN 结构并利用该模型对当前时刻的信道可用吞吐量进行估计。

1.1 入侵式数据采集方案

为了使用 ANN 对当前时刻信道可用吞吐量进行估计, 首先需要构造能够用以训练的数据集。入侵式信道可用吞吐量探测及数据采集方案结构示意图如图 1 所示, 由打流模块、数据采集模块和实际业务模块构成。其中, 实线表示有线链路, 虚线表示无线链路。

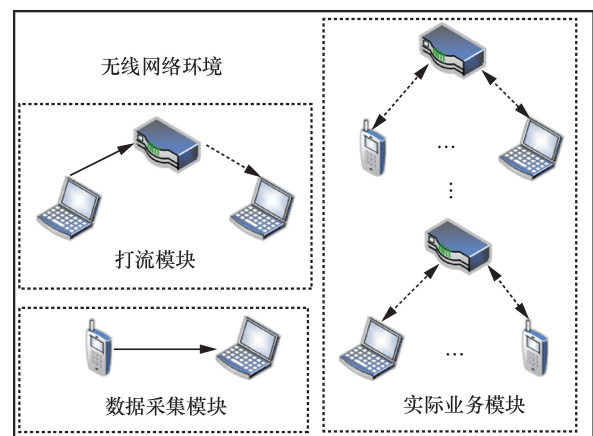


图1 入侵式信道可用吞吐量探测及数据采集方案结构示意图

1.1.1 信道可用吞吐量标定与打流模块

打流模块由两个 STA 分别设置为发送端与接收端并与 AP 进行连接。打流是一种测试无线网络性能的手段, 一次打流过程为: 发送端以固定的传输速率 S_t 发送一段时间的数据, 接收端则计算这段时间内平均的接收速率 S_r 。根据打流结果可以得

出：如果 $S_r = S_t$ ，则认为此时无线信道具有支持这次打流的能力；如果 $S_r < S_t$ ，则认为此时无线信道不具有支持这次打流的能力。

对于一个稳定的无线网络环境，应该存在一个上限速率 S_{t_0} ，当打流的传输速率 $S_t > S_{t_0}$ 时，都有 $S_r < S_t$ ；当传输速率 $S_t \leq S_{t_0}$ 时，都有 $S_r = S_t$ 。可以看出，上限速率 S_{t_0} 直观地反映了该无线信道的质量和业务承载能力，因此使用上限速率 S_{t_0} 标定当前时刻信道可用吞吐量是合理的。为了进一步验证该想法，笔者于微波暗室中构造了一个稳定的无线网络环境，使用打流模块设置不同的传输速率进行打流，稳定无线网络环境中打流结果见表 1。

表 1 稳定无线网络环境中打流结果

发送端传输速率/(Mbit·s ⁻¹)	接收端接收速率/(Mbit·s ⁻¹)
35	32.7
32	31.4
31	30.9
30	30.0
25	24.9

根据表 1 的结果可知，该稳定的无线网络具有上限速率 S_{t_0} ，其值约为 30.9 Mbit/s。这意味着，对于一个稳定的无线网络环境，可以通过设置不同的传输速率并进行打流，最终根据打流结果完成对该无线网络信道可用吞吐量的标定。

而在真实网络环境的信道可用吞吐量是时刻变化的，不存在固定不变的上限速率 S_{t_0} 。为了有效地完成对当前时刻信道可用吞吐量的标定，本文提出了使用多次打流并自适应地修改每次打流的传输速率的方法完成对信道可用吞吐量的一次逼近，传输速率自适应调整原理如图 2 所示。通过传输速率自适应调整原理，打流模块得以完成对真实网络环境中的信道可用吞吐量的标定。

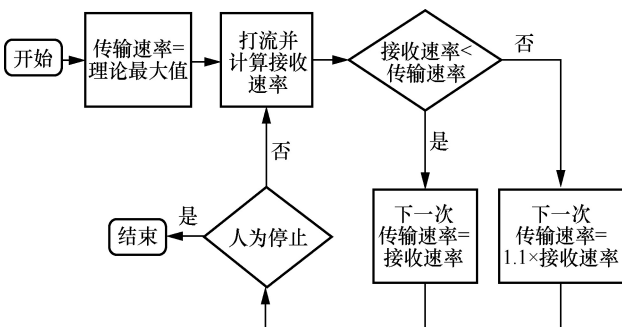


图 2 传输速率自适应调整原理

1.1.2 数据采集模块

数据采集模块由一个数据采集设备和一个数据接收与转存设备构成。前者能够分别采集无线网络中媒体接入控制 (MAC, media access control) 层和物理 (PHY, physical) 层数据，物理层则将采集的数据分别保存为.pcap 文件和.csv 文件。

.pcap 文件记录了 MAC 层的详细信息，包括帧的接收时刻、源地址、目的地址、帧控制字段类别、帧总长度和重传标志位等。其中，帧控制字段类别定义了帧的类型与功能，如 Data 帧、QoS_Data 帧、BA 帧、RTS 和 CTS 帧^[15]等。该文件以帧为单位进行记录，.pcap 文件的数据结构如图 3 所示。

源地址	目的地址	帧信息
28:d1:27:e7:49:b2	c0:3c:59:1c:71:d1	QoS Data,SN=917, FN=0,Flags=p...F.
c0:3c:59:1c:71:d1	28:d1:27:e7:49:b1	802.11 Block Ack Flags=...
...
4c:50:77:c7:eb:7f	9a:5a:18:59:70:17	QoS Data,SN=932 FN=0,Flags=p...F.

帧信息细节
Arrival Time: Jun 25, 2021 13:16:27.27406000 中国标准时间
Type/Subtype: QoS Data(0×0028)
Data rate:156.0 Mbit/s
...
QoS Control:0×0000
[Length:1504]

图 3 .pcap 文件的数据结构

.csv 文件则以秒为单位记录了 PHY 层的无线网络物理量，如.csv 文件部分 PHY 层特征及其含义见表 2。

表 2 .csv 文件部分 PHY 层特征及其含义

特征名称	含义
ant_rssi	接收信号强度指示
ant_snr	下行信噪比
chload	信道同协议占空比
duty_ratio	信道非协议 (干扰) 占空比
Free_power	底噪

1.2 模块间配合及数据集构建

1.2.1 原始数据集采集与构建

在无线通信领域中，数据采集方式可以根据对

被采集环境造成干扰的程度分为非入侵式和入侵式两类。非入侵式数据采集通常无须对环境进行物理介入,能够在不干扰无线网络正常运行的情况下获取数据。然而,这类方法往往只能采集到相对简单的无线特征,如 RSSI、SINR 等。相比之下,入侵式数据采集通常需要对无线网络环境进行物理介入,如使用额外的信号源等,可能在数据采集的过程中对通信系统或网络造成一定的干扰或影响。不过,相较于非入侵式数据采集,入侵式数据采集能够获得更为复杂的无线特征。

根据上述定义,打流模块的打流操作本质上是一种入侵式的数据采集。因此,打流模块在进行工作时,数据采集模块采集的数据不能够有效地反映无线网络环境的真实信息。为了构造能够真实反映无线网络环境和吞吐量的数据集,打流模块与数据采集模块配合工作示意图如图 4 所示。

当打流模块进行打流操作时,数据采集模块会暂时停止工作。这是因为此时采集的无线特征无法反映真实的无线网络环境状态。而打流模块在完成一次打流后,会进入一段时间的休眠,此时无线网络未被物理介入,数据采集模块可以采集到能够准确、真实地反映无线网络环境状态的数据。因此,打流模块每完成一次打流,会记录下本次的传输速率和接收速率,并将这些数据与上一轮数据采集模块所采集到的数据一起构成一个原始样本点。所有的原始样本点将组成原始数据集。

需要指出的是,打流持续时间和数据采集持续时间过长,将导致构造的数据集缺乏瞬态特征,而较短的持续时间和保护间隔可能会导致硬件设备无法正常工作。因此,如何选择合适的打流持续时间、数据采集持续时间和保护间隔是需要考虑的问题。通过大量实验研究,笔者得出结论:将打流持续时间和数据采集持续时间设置为 3 s、保护间隔设

置为 0.5 s 是较为合理的。

为了使训练好的 ANN 能够具备较好的性能和泛化能力,本文在卖场、家庭和办公室 3 个典型场景中分别部署了入侵式数据采集方案进行数据采集。此外,为了进一步丰富数据集,本文还使用多台 AP 与 STA 人工构造了模拟场景。在模拟场景中,通过控制 STA 的数量、无线业务类型以及无线业务强度,尽可能地复现了不同繁忙程度的环境,从而丰富了数据集的多样性。

1.2.2 特征提取与数据集构建

依照如图 4 所示的工作原理,本文得以使用入侵式数据采集方法构造原始数据集。该数据集包含了反映无线信道质量的特征,但并不适合直接用于训练 ANN,因此需要进行进一步的数据处理。

1) 冗余去除

为了完成对真实环境信道可用吞吐量的一次标定,打流模块需要依照如图 2 所示的自适应调整原理和如图 4 所示的模块间配合原理进行多次打流。因此在原始数据集中,存在未能对当前时刻信道可用吞吐量进行标定的冗余。因此本文规定,如果某个原始样本点满足

$$0.9 \times S_t \leq S_r \leq S_t \quad (1)$$

则认为该原始样本点完成了对当前时刻信道可用吞吐量标定,使用接收速率 S_r 标定当前时刻的信道可用吞吐量。同时,保留所有满足式(1)的原始样本点并删除其余原始样本点。

2) 特征选择与提取

PHY 层的特征以每秒平均值的方式记录于.csv 文件中,这种数据结构可以直接作为 ANN 的输入数据,因此无须额外处理。MAC 层的特征以帧的形式保存于.pcap 文件中,该数据结构不适合直接作为 ANN 的输入数据,因此本文以秒为单位,提取了 9 个特征,MAC 层无线特征提取见表 3。



图 4 打流模块与数据采集模块配合工作示意图

表 3 MAC 层无线特征提取

特征名称	特征含义
num_of_frame	该秒内帧的总数
mun_of_mac	该秒内帧发送地址的个数
num_of_QosData	该秒内服务质量数据帧的总数
num_of_Data	该秒内数据帧的总数
num_of_BA	该秒内块确认帧的总数
num_of_CTS	该秒内 CTS 帧的总数
num_of_RTS	该秒内 RTS 帧的总数
data_length	该秒内帧的总长度
retry_rate	该秒内重传帧占帧总数的比重

因此，对于每个持续时间为 3 s 的原始样本点，本文以表 2 所示的 5 个 PHY 层特征和表 3 所示的 9 个 MAC 层特征，以秒为间隔构建了一个数据集，其中每个样本点有 42 个输入特征和相应的信道可用吞吐量作为真值。本文构造了样本容量为 23 000 左右的数据集，信道可用吞吐量直方图如图 5 所示。




图 5 信道可用吞吐量直方图

1.3 基于 ANN 的信道可用吞吐量估计

考虑具有非线性激活函数的多层神经网络可以拟合任何函数^[16]，本文选择使用 ANN 模型完成对当前时刻信道可用吞吐量的估计。在构造 ANN 的过程中，ANN 的层数（包括输入层、隐藏层和输出层的总数）和每层感知机个数的选择对于 ANN 整体性能至关重要：过少的层数和感知机个数将导致欠拟合现象，使 ANN 无法有效逼近和拟合复杂的映射函数；而过多的层数和感知机个数会导致过拟合现象，严重影响 ANN 的泛化能力。文献[17-20]提出了不同的方法来确定层数和感知机个数，但是不同方法的计算结果有时存在较大差异。此外，激活函数的选择也会对最终结果产生影响。目前常用的激活函数包括 Sigmoid 函数、Tanh 函数、ReLU

函数及其变种，每种激活函数都有其独特的特点和优势，在特定问题中表现明显优于其他激活函数。

因此，本文仅基于以下共通且宽松的约束条件，在第 1.2 节构造的数据集上，测试不同层数、感知机个数和激活函数的 ANN 的性能。最终根据“在满足精度要求的前提，选择最精简紧凑的网络结构”的基本原则确定最佳的 ANN 的网络结构。

- 若使用值域为 $[0, +\infty)$ 的激活函数（如 Sigmoid 函数、ReLU 函数），需要将数据集缩放至 $[0, 1]$ ；若使用值域为 $[-1, 1]$ 的激活函数（如 Tanh 函数），需要将数据集缩放至 $[-1, 1]$ 。
- 网络层数至少为 3 层，可根据结果适当增加。
- 隐藏层感知机个数不应该超过输入层感知机个数的两倍。
- 隐藏层感知机个数减少不宜过快，为上一隐藏层感知机个数的 1/4~1/2 为宜。

最终，本文选择采用 4 层 ANN 模型，每一层的感知机个数为 42、64、16、1；选择 ReLU 作为激活函数；使用第 1.2 节提供的 42 维特征 1 维标签数据，以 80%和 20%的比例划分训练集和测试集；使用均方误差（MSE, mean square error）作为损失函数；使用随机梯度下降法（SGD, stochastic gradient descent）训练参数。为验证模型的性能，本文使用 MSE 作为评价指标将 ANN、Sigmoid 回归和多元线性回归进行比较，不同回归模型在估计信道可用吞吐量任务中的性能见表 4。可以看出，ANN 有效完成了对当前时刻信道可用吞吐量的估计。

表 4 不同回归模型在估计信道可用吞吐量任务中的性能

多元回归算法	MSE
ANN	0.009 026 81
Sigmoid 回归	0.012 897 08
多元线性回归	0.012 692 08

2 信道未来可用吞吐量预测

由于第 1 节采集的数据并非连续的时间序列，因此本节设计并实现了非入侵式数据采集方案用以采集连续的信道可用吞吐量时间序列数据，分析了非平稳性对时间序列的影响，并就如何解决时间序列的非平稳性给出了解决方案。最后，介绍所使用改进的 RNN 模型，并利用该模型对信道未来可用吞吐量进行预测。

2.1 非侵入式数据采集与构建

一般情况下, 时间序列预测算法需要一段连续的时间序列才能正常工作。然而, 在第1节采集并构建的信道可用吞吐量数据集并非连续的, 因此无法直接用于预测。为此, 本节在第1节的基础上, 设计并实现了一种非侵入式数据采集方案, 非侵入式数据采集方案结构示意图如图6所示。

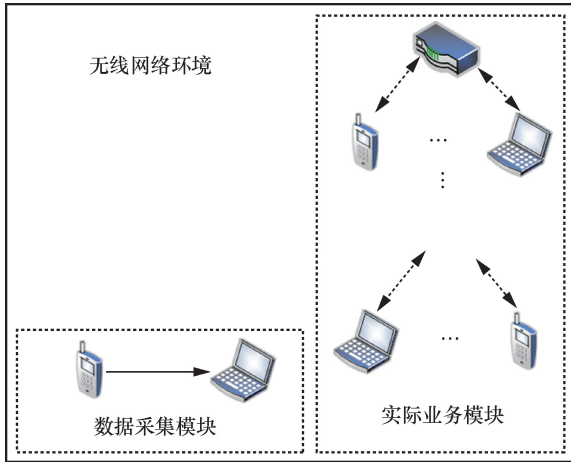


图6 非侵入式数据采集方案结构示意图

由于第1节训练得到的ANN模型可以直接使用数据采集模块提供的数据对当前时刻的信道可用吞吐量进行估计, 而无须使用打流模块进行标定, 因此可以删除打流模块。此时整个方案不会对无线网络做出任何物理介入, 数据采集模块能够连续不间断地非侵入式地对无线网络环境进行数据采集, 并依照第1.2节所述构造数据集。将构造好的数据集输入ANN模型, 即可获得连续的无线网络信道可用吞吐量时间序列。

2.2 基于经验模态分解的数据处理方法

时间序列的预测算法大致可以分为基于统计模型的方法和基于深度学习的方法, 这两类方法在进行时间序列预测时, 一般都会要求被预测的时间序列具有平稳性的特征, 因为具有非平稳性特征的时间序列如果处理不当将严重影响预测模型的性能。由于无线网络环境的网络拓扑结构、干扰强度等时刻变化, 这些因素的不断变化导致包括信道可用吞吐量在内的无线网络特征时间序列是非平稳的。

本节使用经验模态分解(EMD, empirical mode decomposition)^[21]方法将非平稳的信道可用吞吐量时间序列分解为多个平稳的时间序列以解决这个问题。EMD是一种能将非平稳时间序列数据平稳化

并分解的时间序列处理方法, 关键是将原始序列分解为若干个具有平稳性的本征模函数(IMF, intrinsic mode function)^[22]分量和一个残余分量, 其中IMF分量有两个约束条件: 任意时刻局部极小值点和极大值点分别构成的上下包络线平均值为0; 序列中极值点的个数和过零点的个数相差不超过1。EMD算法的流程如下。

步骤1 将时间序列 $x(t)$ 的所有极大值点和极小值点分别用插值法进行拟合, 获得序列的上包络线和下包络线 $x_{\max}(t)$ 和 $x_{\min}(t)$ 。

步骤2 计算上下包络线 $x_{\max}(t)$ 和 $x_{\min}(t)$ 的均值 $m_1(t) = (x_{\max}(t) + x_{\min}(t)) / 2$, 原序列减去该值得到 $h_1(t) = x(t) - m_1(t)$ 。判断新的序列 $h_1(t)$ 是否满足IMF分量的两个约束条件, 若满足, 则 $h_1(t)$ 为一个IMF分量; 否则用 $h_1(t)$ 代替 $x(t)$ 重复以上步骤, 直至满足条件。

步骤3 从原始序列中减去获得的IMF分量, 重复进行步骤1和步骤2, 直至最后的IMF分量的过零率(ZCR, zero crossing rate)为0, 过零率表示序列通过零点的次数与序列长度的比值。最终可以将原始时间序列 $x(t)$ 分解为一系列不同频率的IMF分量以及残余分量 $r(t)$ 的线性叠加:

$$x(t) = r(t) + \sum h_i(t)。$$

本节对非平稳的信道可用吞吐量时间序列进行分解, 原始时间序列通过EMD得到的4个IMF分量与1个残余分量。某一段归一化的信道可用吞吐量时间序列分解结果如图7所示。

2.3 基于EMD+CNN-LSTM模型的信道可用吞吐量预测

对信道可用吞吐量时间序列进行EMD有效地消除了时间序列数据的非平稳性, 但是将原有的1维时间序列变成了5维时间序列。如何分析不同维度之间的相互关系并同时同时对5维时间序列进行预测是本节需要解决的问题。

2.3.1 神经网络模型介绍

卷积神经网络(CNN, convolutional neural network)^[23]是一种前馈神经网络。该网络使用局部感受野、权重共享和池化3种操作, 在降低网络复杂度的同时保持了对平移、旋转、尺度缩放等变化的不变性, 因此被广泛用于图像分类、目标识别、语音识别等领域。

递归神经网络(RNN, recurrent neural network)^[24]的基本单位同为感知机。由于其特殊的网络结构,

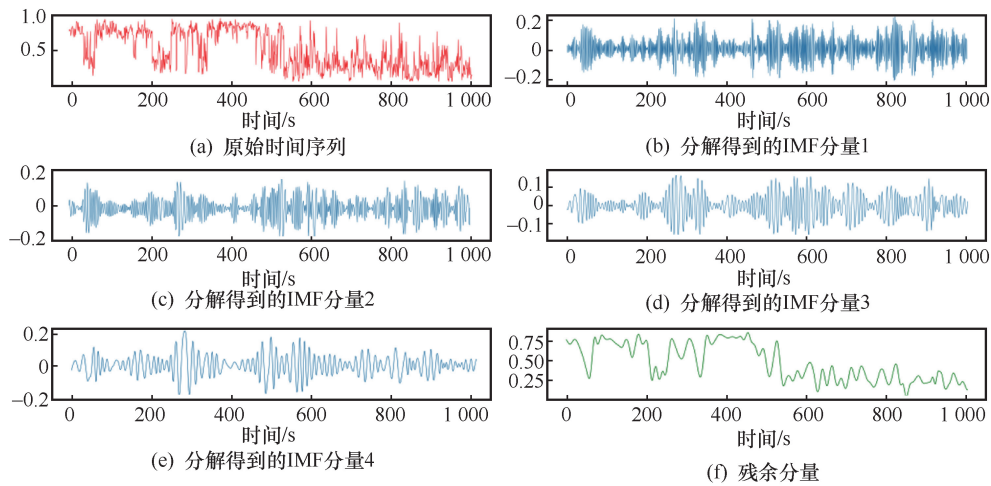


图7 某一段归一化的信道可用吞吐量时间序列分解结果

RNN 相比于前馈神经网络更适合捕捉并学习时间序列中前后样本点的时间依赖关系，被广泛用于时间序列预测任务中。但由于在梯度下降的过程中，RNN 的梯度会被近距离梯度主导，远距离梯度对整体梯度的影响微乎其微，使得 RNN 难以学习到远距离的依赖关系。针对此问题，Hochreiter 等^[25-27]提出了长短期记忆 (LSTM, long short-term memory) 网络，LSTM 模型在 RNN 的基础上引入了遗忘门、输入门和输出门 3 种门的结构以保证模型能够学习到远距离的依赖关系，在长时间序列预测问题上逐渐取代了 RNN 模型成为了主流方法。

考虑 CNN 模型具有学习空间特征的能力，LSTM 模型则具有处理长期依赖关系的能力，因此结合了两者优点的 CNN-LSTM 模型被提出并广泛应用于多维时间序列的预测。CNN-LSTM 模型结构示意图如图 8 所示，首先 CNN 模块通过卷积操作和池化操作提取输入时间序列的空间特征，然后将其传递给 LSTM 模块，LSTM 模型在时间维度上对数据进行建模，并利用其自身的优势捕捉数据集的长期依赖关系。

2.3.2 基于 EMD+CNN-LSTM 模型的信道可用吞吐量预测

在第 2.2 节中，为了解决信道可用吞吐量时间序列的非平稳性问题，使用了 EMD 方法将信道可用吞吐量时间序列分解为了 4 个 IMF 分量和 1 个残余分量。本节使用 CNN-LSTM 模型对这 5 个时间序列进行预测，并将预测结果相加，最终获得信道可用吞吐量的预测结果，EMD+CNN-LSTM 模型流程如图 9 所示。使用前 5 min 的信道可用吞吐量数据作为模型的输入，并要求模型预测后 1 min 的信道可用吞吐量时间序列。EMD+CNN-LSTM 模型预测结果如图 10 所示，可以看出，该模型很好地捕捉了信道可用吞吐量的变化趋势。

为了进一步评估 EMD+CNN-LSTM 模型的有效性，本节对该模型与多种预测模型进行了对比分析，并使用了均方根误差 (RMSE, root mean square error)、平均绝对误差 (MAE, mean absolute error)、平均绝对百分比误差 (MAPE, mean absolute percentage error) 和可决系数 (R-Square) 这 4 种评价指标评估所提算法的性能。其中，RMSE 是在 MSE




图8 CNN-LSTM 模型结构示意图

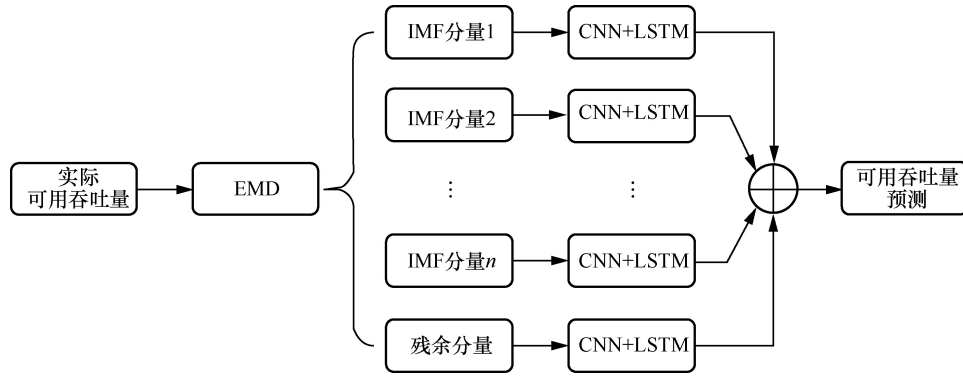


图 9 EMD+CNN-LSTM 模型流程

的基础上做平方根衡量预测值与真实值之间的偏差；MAE 是绝对误差的平均值，反映预测值误差的实际情况；MAPE 为 0%表示完美模型，该值大于 100%则表示劣质模型；R-Square 表示预测序列对原始序列的预测效果，一般可决系数越大，表示预测模型效果越好。不同模型对信道可用吞吐量预测性能对比见表 5，其中 Time_1 表示模型训练完毕所需要的时间，Time_2 表示训练完毕的模型输出预测结果所需要的时间。




图 10 EMD+CNN-LSTM 模型预测结果

由表 5 可知，EMD+CNN-LSTM 模型各项性能指标均优于其他模型，并且使用 EMD 算法的模型预测性能相较于未使用 EMD 算法的模型有显著提升。因此，所提 EMD+CNN-LSTM 预测模型可以有效解决信道可用吞吐量预测的问题。AP 可以根据

预测结果选择接下来一段时间内的最优的信道以满足 STA 的无线业务体验。

3 结束语

估计与预测无线网络信道的质量，对辅助 AP 工作、提升 STA 业务体验有重要意义。本文以信道可用吞吐量为指标，分为估计信道当前时刻信道可用吞吐量和预测信道未来可用吞吐量两个步骤以满足上述需求。具体而言：首先设计了入侵式数据采集方案，使用打流的方法获取带有信道当前时刻信道可用吞吐量的数据集；然后使用该数据集对 ANN 模型进行训练以完成多个无线网络特征对信道可用吞吐量的估计；接着设计了非入侵式数据采集方案并配合训练好的 ANN 模型获得连续的信道可用吞吐量时间序列；最后使用 EMD+CNN-LSTM 模型以完成信道未来可用吞吐量的预测。

整体方案在数据集上表现良好，较好地解决了实际问题，但依然有可以优化的空间。在未来的工作中可以针对以下几点来提升方案的整体性能。

1) 由于数据采集的时间成本与存储成本较大，本文仅选择了卖场、家庭和办公室 3 个典型场景进行数据采集。若条件允许，可以选择更多的典型场景进行数据采集。扩大方案的适用场景以提升方案

表 5 不同模型对信道可用吞吐量预测性能对比

时间序列预测模型	RMSE	MAE	MAPE	R-Square	Time_1/s	Time_2/s
EMD+CNN-LSTM	0.064	0.046	15.044%	0.905	197.99	0.075
CNN-LSTM	0.113	0.084	31.669%	0.705	81.47	0.076
EMD+LSTM	0.068	0.050	17.498%	0.892	184.07	0.080
EMD+RNN	0.069	0.050	17.783%	0.889	146.82	0.081
LSTM	0.115	0.087	33.103%	0.691	80.91	0.080
RNN	0.116	0.088	33.243%	0.686	81.73	0.081

的泛化能力。

2) 当典型场景数量增加时, 可先使用分类算法, 以典型场景名称为标签对采集的数据集进行分类, 然后对每一个典型场景数据使用整体方案, 可以减少陌生与不稳定的场景对模型性能的影响, 提升整体方案的泛化能力。

3) 同一个典型场景, 不同时间段的无线信道状态可能不同, 在场景分类的基础上进行子场景聚类, 聚类结果可作为输入特征为模型提供更多信息。这是一个时间序列子序列聚类问题^[28], 可以使用文献[29-30]中的算法解决。

4) 针对深度学习模型, 过拟合是降低泛化能力的主要问题, 通过使用正则化、添加 **Drop Out** 层、为数据集引入适量噪声、使用批量归一化等技术可以缓解模型的过拟合问题, 从而提升模型的泛化能力^[31-32]。

5) 设备不稳定造成的数据误差是客观存在的, 本文在数据处理的过程中采用了 **EMD**、数据归一化等方法尽可能地减小数据误差带来的影响。此外可以通过增加样本点的时间跨度, 用时间平均的方式削弱数据误差的影响。

参考文献:

- [1] MOZAFFARIAHRAR E, THEOLEYRE F, MENTH M. A survey of Wi-Fi 6: technologies, advances, and challenges[J]. *Future Internet*, 2022, 14(10): 293.
- [2] OUGHTON E J, LEHR W, KATSAROS K, et al. Revisiting wireless internet connectivity: 5G vs Wi-Fi 6[J]. *Telecommunications Policy*, 2021, 45(5): 102127.
- [3] SUER M T, JOSE P, TCHOUANKEM H. Experimental evaluation of IEEE 802.11ax - low latency and high reliability with Wi-Fi 6? [C]// *Proceedings of GLOBECOM 2022-2022 IEEE Global Communications Conference*. Piscataway: IEEE Press, 2023: 377-382.
- [4] HYDER Z, HE D, LI D Y, et al. Improved Wi-Fi indoor localization based on signal quality parameters and RSSI smoothing algorithm[C]// *Proceedings of 2021 10th International Conference on Information and Automation for Sustainability (ICIAFS)*. Piscataway: IEEE Press, 2021: 140-144.
- [5] GHOSH J, GUPTA A, HACI H, et al. User association, power control and channel access schemes for two-tier macro-femto networks: CDF of SINR analysis[J]. *IETE Technical Review*, 2022, 39(1): 219-230.
- [6] MOHANTY S, AGARWAL A, MALI S, et al. Design and BER performance analysis of MIMO and massive MIMO networks under perfect and imperfect CSI[C]// *Proceedings of 2020 Fourth International Conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud) (I-SMAC)*. Piscataway: IEEE Press, 2020: 307-312.
- [7] THANUJA T C, DAMAN K A, PATIL A S. Optimized spectrum sensing techniques for enhanced throughput in cognitive radio network[C]// *Proceedings of 2020 International Conference on Emerging Smart Computing and Informatics (ESCI)*. Piscataway: IEEE Press, 2020: 137-141.
- [8] AFIFI W S, EL-MOURSAY A A, SAAD M, et al. A dynamic clustering approach for increasing user throughput in 5G wireless networks[C]// *Proceedings of NOMS 2020 - 2020 IEEE/IFIP Network Operations and Management Symposium*. Piscataway: IEEE Press, 2020: 1-8.
- [9] HU N N, STEENKISTE P. Evaluation and characterization of available bandwidth probing techniques[J]. *IEEE Journal on Selected Areas in Communications*, 2003, 21(6): 879-894.
- [10] JAIN M, DOVROLIS C. End-to-end available bandwidth: measurement methodology, dynamics, and relation with TCP throughput[J]. *IEEE/ACM Transactions on Networking*, 2003, 11(4): 537-549.
- [11] BEDI H, SHARMA K K. Analyses of CSMA/CA protocol without using virtual channel sensing in DCF mode[C]// *Global Emerging Innovation Summit (GEIS-2021)*. [S.l.:s.n.], 2021: 484-491.
- [12] SHAH S H, CHEN K, NAHRSTEDT K. Available bandwidth estimation in IEEE 802.11-based[EB]. 2004.
- [13] AL-GARADI M A, MOHAMED A, AL-ALI A K, et al. A survey of machine and deep learning methods for internet of things (IoT) security[J]. *IEEE Communications Surveys & Tutorials*, 2020, 22(3): 1646-1685.
- [14] CAO Q, BANERJEE R, GUPTA S, et al. Data driven production forecasting using machine learning[EB]. 2016.
- [15] OLIVEIRA L, RODRIGUES J, KOZLOV S, et al. MAC layer protocols for internet of things: a survey[J]. *Future Internet*, 2019, 11(1): 16.
- [16] TACCHINO F, BARKOUTSOS P, MACCHIAVELLO C, et al. Quantum implementation of an artificial feed-forward neural network[J]. *Quantum Science and Technology*, 2020, 5(4): 044010.
- [17] UZAIR M, JAMIL N. Effects of hidden layers on the efficiency of neural networks[C]// *Proceedings of 2020 IEEE 23rd International Multitopic Conference (INMIC)*. Piscataway: IEEE Press, 2021: 1-6.
- [18] HANIN B, ROLNUCK D. Complexity of linear regions in deep networks[C]// *International Conference on Machine Learning*. New York: PMLR, 2019: 2596-2604.
- [19] BERRY M A, LINOFF G. Data mining techniques for marketing, sales and customer relationship[EB]. 2004.
- [20] MAO K Z, TAN K C, SER W. Probabilistic neural-network structure determination for pattern classification[J]. *IEEE Transactions on Neural Networks*, 2000, 11(4): 1009-1016.
- [21] BARBOSH M, SINGH P, SADHU A. Empirical mode decomposition and its variants: a review with applications in structural health monitoring[J]. *Smart Materials and Structures*, 2020, 29(9): 093001.
- [22] SARIKAYA Y, ATALAY I C, GURBUZ O, et al. Estimating the channel capacity of multi-hop IEEE 802.11 wireless networks[J]. *Ad Hoc Networks*, 2012, 10(6): 1058-1075.
- [23] LI Z W, LIU F, YANG W J, et al. A survey of convolutional neural

- networks: analysis, applications, and prospects[J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 33(12): 6999-7019.
- [24] YU Y, SI X S, HU C H, et al. A review of recurrent neural networks: LSTM cells and network architectures[J]. Neural Computation, 2019, 31(7): 1235-1270.
- [25] MA X L, TAO Z M, WANG Y H, et al. Long short-term memory neural network for traffic speed prediction using remote microwave sensor data[J]. Transportation Research Part C: Emerging Technologies, 2015(54): 187-197.
- [26] TIAN Y X, PAN L. Predicting short-term traffic flow by long short-term memory recurrent neural network[C]//Proceedings of 2015 IEEE International Conference on Smart City/Social Com/Sustain Com (Smart City). Piscataway: IEEE Press, 2016: 153-158.
- [27] CHENG J S, YU D Y, YU Y. Research on the intrinsic mode function (IMF) criterion in EMD method[J]. Mechanical Systems and Signal Processing, 2006, 20(4): 817-824.
- [28] AGHABOZORGI S, SHIRKHORSHIDI A S, WAH T. Time-series clustering - a decade review[J]. Information Systems, 2015, 53: 16-38.
- [29] HALLAC D, VARE S, BOYD S, et al. Toeplitz inverse covariance-based clustering of multivariate time series data[C]//KDD: Proceedings of International Conference on Knowledge Discovery & Data Mining, 2017: 215-223.
- [30] MATSUBARA Y, SAKURAI Y, FALOUTSOS C. AutoPlait: automatic mining of co-evolving time sequences[C]//Proceedings of the 2014 ACM SIGMOD International Conference on Management of Data. New York: ACM Press, 2014: 193-204.
- [31] WANG H H, WU X D, HUANG Z Y, et al. High-frequency component helps explain the generalization of convolutional neural networks[C]//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2020: 8681-8691.
- [32] ZHANG C, BENGIO S, HARDT M, et al. Understanding deep learning requires rethinking generalization[EB]. 2016.

[作者简介]



肖遥 (1997-), 男, 华中科技大学电子信息与通信学院硕士生, 主要研究方向为无线通信、智能反射面、人工智能等。



刘峻铄 (1995-), 男, 华中科技大学电子信息与通信学院博士生, 主要研究方向为无线通信、随机矩阵、智能反射面等。



龙智夫 (1998-), 男, 华中科技大学电子信息与通信学院硕士生, 主要研究方向为深度学习、智能反射面等。



邱才明 (1966-), 男, 博士, 华中科技大学电子信息与通信学院院长、教授、博士生导师, IEEE Fellow, 主要研究方向为可重构智能超表面、无线通信与网络、基于随机矩阵的深度学习理论分析及智能电网技术等。