

基于模型数据双驱动的短波 MUF 短期预测网络

李俊兵¹, 曾圆钧², 曾孝平¹, 李国军³, 白晨曦⁴

1. 重庆大学微电子与通信工程学院, 重庆 400040;
2. 中国工程物理研究院电子工程研究所, 四川 绵阳 621900;
3. 重庆邮电大学超视距可信信息传输研究所, 重庆 400065;
4. 陆军工程大学通信士官学校, 重庆 400036)

摘要: 针对短波最大可用频率 (MUF) 经典模型方法预测精度低及机器学习方法训练集数据获取难度大的问题, 提出一种模型数据双驱动的双向门控递归单元 (BiGRU) 网络用于 MUF 短期预测。模型驱动方面, 利用经典 MUF 预测模型生成的大规模数据集作为模型驱动训练集, 经过 2D CNN 和 BiGRU 网络联合学习后, 获得一个初步网络。数据驱动方面, 使用小规模实测数据集对初步网络进行二次训练, 得到最终网络 CNN-BiGRU-NN。仿真结果表明, 所提网络与 GRU 网络、LSTM 网络以及 VOACAP 模型相比, 在日期尺度和时刻尺度上的平均均方根误差 (RMSE) 均有降低。

关键词: 短波通信; 最大可用频率; 短期预测; 模型数据双驱动; CNN-BiGRU-NN

中图分类号: TN92

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2023234

Short-term prediction network for short-wave MUF based on model-data dual-driven

LI Junbing¹, ZENG Youjun², ZENG Xiaoping¹, LI Guojun³, BAI Chenxi⁴

1. School of Microelectronics and Communication Engineering, Chongqing University, Chongqing 400040, China
2. Institute of Electronic Engineering, China Academy of Engineering Physics, Mianyang 621900, China
3. Lab of BLOS Reliable Information Transmission of Chongqing University of Posts and Telecommunications, Chongqing 400065, China
4. Communication NCO Academy, Army Engineering University of PLA, Chongqing 400036, China

Abstract: Predicting the maximum available frequency of short-wave communication presents the challenges of low prediction accuracy of classical prediction model methods and difficulty in obtaining training set data for machine learning prediction methods. To address this issue, a model-data dual-driven bidirectional gated recurrent unit (BiGRU) network for short-term prediction of MUF was proposed. On the model-driven, a large-scale dataset generated by the classical MUF prediction model was used as the model-driven training set, and a preliminary network was obtained after joint learning of the 2D CNN and the BiGRU network. On the data-driven, the preliminary network was trained twice using a small-scale measured dataset to obtain the final network CNN-BiGRU-NN. The simulation results show that the proposed network has reduced average root mean squared error (RMSE) at both daily and momentary scales compared with the GRU network, LSTM network and VOACAP model.

Keywords: short-wave communication, maximum usable frequency, short-term prediction, model-data dual-driven, CNN-BiGRU-NN

收稿日期: 2023-08-18; 修回日期: 2023-11-13

通信作者: 曾孝平, zxp@cqu.edu.cn

基金项目: 国家自然科学基金资助项目 (No.U21A20448, No.U20A20157, No.U22A2006); 重庆市基础研究与前沿探索基金资助项目 (No.cstc2021ycjh-bgzxm0072)

Foundation Items: The National Natural Science Foundation of China (No.U21A20448, No.U20A20157, No.U22A2006), The Chongqing Basic Research and Frontier Exploration Project (No.cstc2021ycjh-bgzxm0072)

0 引言

电离层作为一个复杂的非线性动力学系统,存在各种尺度的波动,包括大尺度的行波波动和小尺度的不规则波动。电离层的变化导致最大可用频率(MUF)存在长时间尺度下的规律变化特性(主要受太阳活动周期影响)和短期的突变特性(电离层扰动、电离层闪烁等,持续时间为几个小时或几天)^[1]。短波天波通信受益于电离层的同时也受限于电离层,准确的短波 MUF 预测是保证短波天波通信质量的前提^[2]。近年来,诸多 MUF 预测方法可以分为模型驱动和数据驱动 2 种类型。

模型驱动方法根据电离层物理机理和经验公式^[3]构建 MUF 线性预测模型,已经形成了国际电信联盟无线电通信组 (ITU-R) 的建议和标准,并正在不断改进^[4-5]。经典预测方法主要包括国际无线电咨询委员会 (CCIR) 提出的 CCIR-340 方法与亚大预测方法^[6]。CCIR-340 方法面向全球,由于未使用我国电离层观测数据,对我国的电离层参数预测误差非常大。亚大预测方法利用重庆站观测数据推导出 F_2 层临界频率 f_0F_2 和 3 000 km 传输因子 $M(3\ 000)F_2$ 的 11 年周期指数,使其替代 12 个月的太阳黑子流动平均值,用二次回归方程描述周期指数与 f_0F_2 和 $M(3\ 000)F_2$ 的关系,获得在中国地区 f_0F_2 和 $M(3\ 000)F_2$ 更高的预测精度^[7]。之后,曹红艳等^[8-9]增补了一些探测站的数据对亚大预测方法进行改进,提高了预测精度。另一方面,随着短波通信需求的发展,研究者和机构开发出了较完整的短波频率预测程序,包括电离层通信分析和预测程序 (IONCAP)^[10]、美国之音覆盖分析程序 (VOACAP)^[11]、电离层通信增强剖面分析和电路预测程序 (ICEPAC)^[12]等。此外,中国国家无线电监测中心基于求谐函数理论、ITU 建议书和最新地磁参考模型等算法,开发了短波通联参数预测模型,简称 SRMC (State Radio Monitoring Center) 模型。但是这些预测手段一般对 1~3 个月或更长时间以后的 MUF 进行预测,且只能预测 MUF 的月平均值而无法反映其逐日变化。为了提升 MUF 预测的时间分辨率与预测精度,短期 MUF 预测方法被广泛研究,包括线性拟合方法^[13]、太阳黑子数法^[14]、多元线性回归法^[15]、稳健卡尔曼滤波法^[16]等。

数据驱动的 MUF 预测方法借助机器学习强大的非线性函数近似能力进行 MUF 预测^[17], 通过从

庞大的测量数据集中提取特征信息来形成 MUF 与电离层的映射关系来进行 MUF 预测。比如较早的人工神经网络 (ANN)^[18]、小波模糊网络^[19],最近的时频残差网络 (TSRN)^[20]、统计机器学习 (SML) 网络^[21]等。这些模型都存在数据处理复杂、收敛速度慢等问题,预测精度有待提高。

通过测量和记录 MUF 及其相关参数的数值,可以得到一系列随时间变化的数据点,形成一个时间序列。循环神经网络 (RNN) 的记忆和序列建模能力,使它在处理时序数据方面具有独特的优势,尤其适用于处理具有时序依赖性的问题。Li 等^[22]提出利用长短期记忆 (LSTM) 网络进行三亚地区的 F_2 层临界频率 f_0F_2 的短期预测,然而, LSTM 网络只保留了过去数据样本的信息,而在短波通信频率预测过程中,认为在一定的时间间隔内,频率的预测可以综合考虑前后时刻的输入和状态来提高预测效果。相比之下,双向长短期记忆 (Bi-LSTM) 网络能够将输入数据向前和向后通过 LSTM 隐藏层来获得更好的底层环境^[23]。Rao 等^[24]提出利用 Bi-LSTM 网络进行印度海德拉巴站的 f_0F_2 和 h_mF_2 参数预测。但单一模型不足以表示 MUF 变化需求的内在特征,夏吉业等^[25]提出利用 CNN-BiLSTM 进行 MUF 预测,可以同时利用卷积神经网络 (CNN) 对局部特征的提取能力和 Bi-LSTM 网络对时序信息的建模能力。但以上方法所用训练数据集较小,未能完全考虑 MUF 变化特性。

综上所述,模型驱动方法的缺陷在于对 MUF 进行线性预测,未考虑电离层的动态变化特性,长期预测方法虽然形成了标准化模型,但其时间分辨率低,存在预测精度低的问题,往往仅适用于频率的初选^[26]。但是,数十年短波频率预测研究中所获得的领域知识仍然值得借鉴。基于机器学习进行 MUF 预测的数据驱动方法考虑了 MUF 随电离层非线性变化的特性,但其预测效果严格受限于训练数据集的规模和质量。在 MUF 的机器学习预测中,往往需要几年甚至几十年的测量数据作为训练数据集,而且这只能为机器学习模型提供一组样本,但获取庞大的训练数据集的成本极其高昂甚至不可行。这是机器学习在 MUF 预测的应用中受限的主要原因^[27]。此外,大多数机器学习模型泛化能力和自适应能力较弱,即使网络部分结构发生微小变化,也会导致训练模型准确性降低。

文献[28]提出利用数据增强技术实现短波通信

频率的时空预测, 可为高效实时确定可用频率集提供信息支撑。近年来, 为了克服数据驱动方法面临的数据稀缺、缺乏解释性、泛化能力弱和需满足特定约束条件等问题, 结合了经验模型和数据驱动的方法被广泛研究^[29-32]。本文根据 MUF 的变化特性, 提出由模型数据双驱动的 CNN-BiGRU-NN, 以实现小样本实测数据限制下短波 MUF 的短期预测需求。模型数据双驱动的 CNN-BiGRU-NN 以模型驱动来考虑短波 MUF 在长时间尺度下的规律变化特性, 以数据驱动来考虑 MUF 在短时间尺度下的突变特性。模型驱动利用经验模型预测结果可为数据驱动提供额外的约束和先验信息, 从而改善整体网络的准确性、可解释性和泛化能力^[33]。同时, 通过模型驱动还可以降低数据驱动对 MUF 实测数据集规模大小的依赖性, 提高网络整体的稳健性和可迁移性^[34]。

1 相关理论

1.1 MUF 变化机理

太阳辐射通过紫外线和 X 射线等高能辐射, 以及可见光和短波辐射, 对电离层中的气体分子产生光电效应和碰撞电离效应, 对电离层电子密度的变化有着直接的影响。当短波信号入射到电离层时, 一部分能量被电离层吸收, 形成传输损耗; 另一部分能量被反射回地面, 从而实现远距离的通信。当电离层的电子密度较高时, 它对较高频率的电磁波具有反射作用。这是因为较高频率的电磁波与电离层中的电子发生碰撞时, 电子会发生远程散射, 使电磁波改变方向并返回地球表面。电磁波反射效应主要发生在 F 层, 尤其是 F_2 层。 F_2 层电子密度最大, 可以反射的电磁波频率最高, 但当频率超过一定的阈值 (即 MUF) 时, 电磁波就会穿透电离层, 不能被反射, 导致通信中断^[35]。

太阳辐射的强度随着日照强度、季节和太阳活动的变化而变化, 从而影响着电离层的电子密度, 进而影响短波 MUF。一般情况下, 白天的 MUF 高于夜晚; 夏季的 MUF 高于冬季。特殊情况下, 太阳辐射强烈和频繁的变化, 如太阳耀斑和日冕物质抛射等, 会引起电离层电子密度的瞬时增加, 形成电离层扰动现象, 使 MUF 出现短期的突变。此外, 收发端的地理位置、信号入射角也会对 MUF 产生影响。电离层与 MUF 关系如图 1 所示。




图 1 电离层与 MUF 关系

1.2 模型驱动方法

ITU-R P.1240 建议给出了 MUF 的预测方法^[5]。短波信号通过 F_2 层单跳传输距离为 d 时的 MUF 表示为

$$F_2(d)\text{MUF} = \left[1 + \left(\frac{C_d}{C_{3000}} \right) (B-1) \right] f_0 F_2 + \frac{f_H}{2} \left(1 - \frac{d}{d_{\max}} \right) \quad (1)$$

$$C_d = 0.74 - 0.591Z - 0.424Z^2 - 0.090Z^3 + 0.088Z^4 + 0.181Z^5 + 0.096Z^6 \quad (2)$$

$$Z = 1 - \frac{2d}{d_{\max}} \quad (3)$$

其中, d_{\max} 为短波信号通过 F_2 层的最大单跳距离 (单位为 km), 其表达式为

$$d_{\max} = 4780 + \left(12610 + \frac{2140}{x^2} - \frac{49720}{x^4} + \frac{688900}{x^6} \right) \left(\frac{1}{B} - 0.303 \right) \quad (4)$$

$$x = \max \left(\frac{f_0 F_2}{f_0 E}, 2 \right) \quad (5)$$

$$B = M(3000)F_2 - 0.124 + \left\{ [M(3000)F_2]^2 - 4 \right\} \cdot \left[0.0215 + 0.005 \sin \left(\frac{7.854}{x} - 1.9635 \right) \right] \quad (6)$$

其中, $M(3000)F_2$ 为短波信号通过 F_2 层传输的 3000 km 距离的 MUF 的传输因子, 与接收端和发送端位置有关; $f_0 F_2$ 、 $f_0 E$ 分别为 F_2 层与 E 层的临界频率, 与时间、位置有关; C_{3000} 为 $d = 3000$ km 时的 C_d 值; f_H 为路径中点的磁旋频率 (单位为 MHz)^[36]。它们是电离层参数的映射, 由太阳辐射强度、日期和发送端与接收端的位置确定, 因此, F_2 层的 MUF 可以被看作一个与时间和位置有关的复合函数^[37]。

VOACAP 是一款广泛使用的电离层传播预测工具, 用于分析和评估短波通信的覆盖范围和传播性能^[38], 可以得到 MUF 参数。VOACAP 采用 ITU 建议书的理论计算方法、经验公式以及统计数据模型, 考虑了多种参数和因素, 包括发送端和接收端

的地理位置、频率、功率、天线高度、极化方式、接收信噪比要求等;此外,还综合考虑了太阳活动、季节变化以及大气条件对电离层的影响。VOACAP 可以生成各种输出结果,包括覆盖图、传播损耗、信号强度预测、MUF 预测等^[12]。因此,VOACAP 产生的 MUF 数据可以用来提取 MUF 的时域和频域特征^[39]。

此外,SRMC 模型用来预测短波超视距传输的必要参数,集成了国际上广泛使用的 REC533 和 VOACAP 模型,并可以从中国科学院国家空间科学中心网站上实时获得太阳黑子数。

1.3 BiGRU 网络


RNN 是一类以序列数据为输入,在序列的演进方向进行递归且所有节点(循环单元)按链式连接的神经网络。RNN 神经元可以同时接收来自自身历史时刻以及其他神经元的的信息,因此 RNN 具有记忆性、参数共享等特点,能够较好地兼顾序列性以及时序性特征的学习^[40],可以充分提取 MUF 具有的非线性以及时序性特征。但是 RNN 会出现梯度消失和梯度爆炸现象,无法掌握长时间跨度的特征。为解决此类长期依赖问题,LSTM 作为 RNN 的改进版被提出^[41]。门控递归单元(GRU)网络是 LSTM 网络的简化版本,具有更简单的结构和更低的计算复杂性。主要的简化是 GRU 通过将遗忘门和输入门集成到单个更新门中来合并单元状态和隐藏状态。如图 2 所示,LSTM 包含 3 个门(即遗忘门、输入门和输出门),而 GRU 只拥有 2 个门(即重置门和更新门)^[42]。因此,与 LSTM 相比,GRU 中需要训练的超参数数量更少。这意味着能够用更少的训练迭代次数获得相似甚至更好的训练模型^[43]。

在前向神经网络中,信息总是按顺序从前向后传播。然而,在某一时刻和确定的经纬度上的 MUF 与前一段时间和后一段时间的 MUF 均相关。如图 3 所示,BiGRU 网络能够同时学习前向及后向 MUF 影响因素与当前时刻 MUF 之间的关系,能够更充分地学习数据深层次特征。当前时刻 t 的隐藏层状态 \vec{h}_t 由沿时间前向传播的 $t-1$ 时刻的隐藏层输出 \vec{h}_{t-1} 、沿时间后向传播的 $t-1$ 时刻的隐藏层输出 \overleftarrow{h}_{t-1} 以及当前时刻的输入 x_t 这 3 个部分共同决定。BiGRU 在结构上可以看成前向与后向传播 GRU 的组合, t 时刻的隐藏层输出 \vec{h}_t 为信息前向传播隐藏

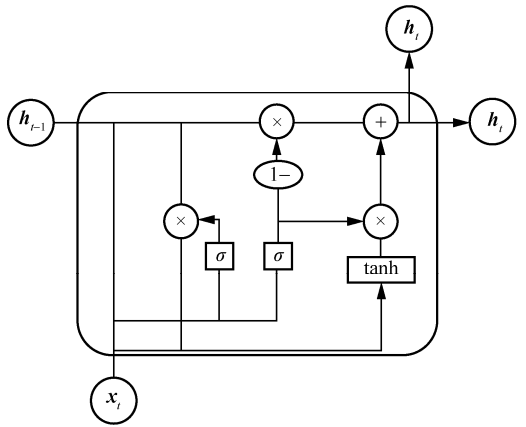
层输出 \vec{h}_t 和信息后向传播隐藏层输出 \overleftarrow{h}_t 线性叠加的结果。

$$\begin{cases} \vec{h}_t = \text{GRU}(x_t, \vec{h}_{t-1}) \\ \overleftarrow{h}_t = \text{GRU}(x_t, \overleftarrow{h}_{t-1}) \\ \vec{h}_t = \alpha_t \vec{h}_t + \beta_t \overleftarrow{h}_t + b_t \end{cases} \quad (7)$$

其中, α_t 为 t 时刻信息前向传播 GRU 单元隐藏层输出权重, β_t 为 t 时刻信息后向传播 GRU 单元隐藏层输出权重, b_t 为 \vec{h}_t 对应的偏置量。



(a) LSTM 结构



(b) GRU 结构

图 2 LSTM 和 GRU 结构

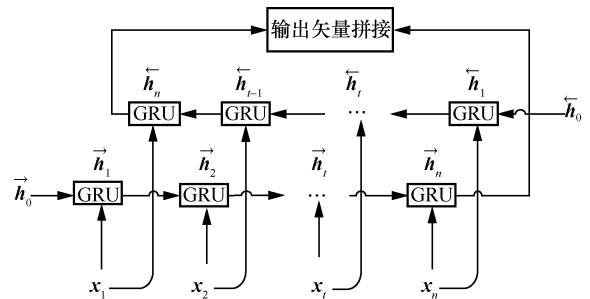


图 3 BiGRU 结构

2 模型数据双驱动 CNN-BiGRU-NN

模型数据双驱动网络并非要完全取代纯数据驱动的机器学习网络，它只是作为标准机器学习网络的强有效补充。模型数据双驱动网络主要可以分为 3 种模式^[44]。

串联模式。通过模型驱动来提取数据驱动所需的关键特征，有效减少数据驱动方法的输入特征维度。数据驱动作为模型驱动方法的后处理校正步骤，提升整体性能。

并联模式。模型驱动和数据驱动同时进行，既可以择优选择两者结果作为输出，又可以通过加权计算来获得最优结果。

嵌入模式。数据驱动方法作为内部模块嵌入模型驱动方法中，用于复杂单元替换或模型参数校准。

在进行 MUF 短期预测时，并联模式的模型数据双驱动网络由于模型驱动与数据驱动相互独立，而不能充分发挥经验模型与神经网络的联合优势。对于本文，VAOCAP 预测结果为 MUF 的月中值，不能满足 MUF 短期预测要求，如果采用并联模式，由于模型驱动的误差会导致在最后结果输出时，模型数据双驱动模式变为以实测数据为驱动的纯数据驱动模式。嵌入模式的模型数据双驱动网络虽然通过数据驱动可以优化经验模型参数，但仍需依赖实测数据训练集规模与经验模型，使其预测性能受限。因此，本文采用二级串联形式的模型数据双驱动网络，以模型驱动获得初步网络；以数据驱动对模型驱动结果校正。

图 4 为用于 MUF 短期预测的模型数据双驱动的 CNN-BiGRU-NN 流程。

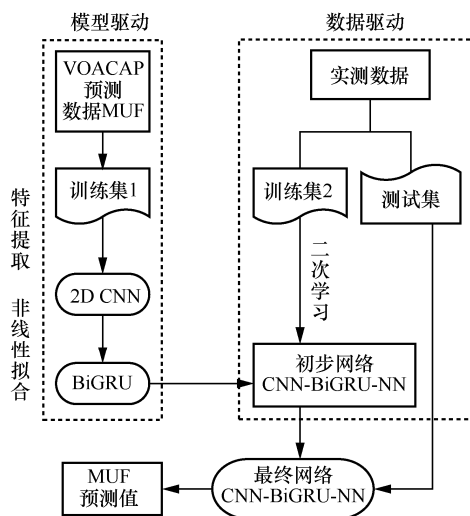


图 4 模型数据双驱动的 CNN-BiGRU-NN 流程

模型驱动——利用现有 VOACAP 模型，可以较容易地获得大量 MUF 仿真数据。将由 VOACAP 预测而来的数据集作为模型驱动的训练集 \mathcal{X}_1 ，利用 2D CNN 提取训练集 \mathcal{X}_1 在 t 时刻的深层数据特征 λ_t^1 ^[45]。以 t 时刻的输入 x_t 为例

$$\lambda_t^1 = f(x_t) = f(x_t * K + b) \quad (8)$$

其中， f 表示非线性激活函数， $*$ 表示卷积计算， K 表示卷积核， b 表示偏置向量。将特征向量 λ_t^1 作为 BiGRU 的输入进行模型训练，经过非线性拟合以获得初步 CNN-BiGRU-NN G_1^1 。

$$\begin{cases} \vec{h}_t = \text{GRU}(\lambda_t, \vec{h}_{t-1}) \\ \overleftarrow{h}_t = \text{GRU}(\lambda_t, \overleftarrow{h}_{t-1}) \\ h_t = \alpha_t \vec{h}_t + \beta_t \overleftarrow{h}_t + b_t \\ G_1^1 = \phi(\bar{\omega}\bar{x} + b) \end{cases} \quad (9)$$

其中， ϕ 为激活函数， \bar{x} 为神经元输入， $\bar{\omega}$ 为权重向量， b 为偏置向量。

用不同时刻 t 的数据进行监督学习，即可得到初步网络 G_1 ，其可行性已经在文献[46-47]中得到证明。

数据驱动——利用仿真数据可以训练出一个初步的 CNN-BiGRU-NN，但由于仿真数据与真实值之间存在较大误差，初步网络预测结果偏差巨大。因此需要利用实测数据来矫正超参数，减小误差。将实际斜向探测到的 MUF 数据分为训练集 \mathcal{X}_2 和测试集 τ 。在训练阶段，利用训练集数据 \mathcal{X}_2 对初步网络 G_1 进行再学习，即再次调整 G_1 的权重以及偏置参数，得到最终的 CNN-BiGRU-NN G_2 。最后，将测试集数据 τ 作为 G_2 的输入进行 MUF 预测。

3 实验设置

3.1 数据处理

本文将 2008 年 2 月 1 日到 2019 年 8 月 31 日重庆—海口由 SRMC 模型中 VOACAP 模型预测而得的 MUF 数据作为训练集 \mathcal{X}_1 ，数据格式为 4229×24 维矩阵；将 2019 年 9 月重庆—海口实测的 MUF 数据作为训练集 \mathcal{X}_2 ，数据格式为 30×24 维矩阵；将 2019 年 10 月 9 日到 2019 年 10 月 30 日重庆—海口的 MUF 实测数据作为测试集 τ ，数据格式为 22×24 维矩阵。

同时，考虑月份和日期对 MUF 变化的影响，

将其作为模型驱动的输入的一部分，最后得到训练集 \mathcal{X}_1 的数据格式为 $4\,229 \times 26$ 、训练集 \mathcal{X}_2 的数据格式为 30×26 、测试集 τ 数据格式为 22×26 。其中，第 25 列数据表示月份数据，第 26 列数据表示日期数据。

BiGRU 滑动窗宽设置为 8 天，步长设置为 1， $\mathbf{X}_t = (\mathbf{x}_{t,j}, \mathbf{x}_{t+1,j}, \dots, \mathbf{x}_{t+7,j})^T \in (\mathcal{X}_1, \mathcal{X}_2), j \in (1, 2, \dots, 26)$ 表示尺寸为 8×26 的单位特征图，最终输出 \mathbf{y}_{t+7} 为 1×24 的向量。对于本文所提的 CNN-BiGRU-NN，意味着用前 8 天的 24 小时 MUF 数据来对第 9 天的 24 小时 MUF 数据进行预测。

为防止训练过程中较大数据吞没较小数据进而对网络产生影响，也为了让网络有更快的收敛速度以及更高的精度，此次网络采用 min-max 归一化的方法将每一列数据放缩到 $[0,1]$ 范围内，归一化式为

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (10)$$

其中， x^* 表示 x 经过 min-max 归一化处理后的数据， x_{\min} 和 x_{\max} 分别表示样本同维度数据的最小值和最大值。

3.2 参数设置

混合神经网络模型的参数设置至关重要，直接影响到训练网络的优劣。本文 CNN 中卷积层有 2 层，卷积核数目依次为 64 和 32，平均池化层有 1 层，池大小为 2，步长为 1。BiGRU 网络中共有 2 层 BiGRU 网络层，各层的神经元个数依次为 64 和 24。同时，选用 keras 编写混合神经网络框架，以 tensorflow 作为后端进行网络的训练以及评估。

为保证网络充分拟合数据特征，防止欠拟合，网络需要对样本数据进行多次迭代学习。同时为减少网络训练时间，网络在训练过程中观测训练误差，当训练误差不再下降时，则提前停止训练。综合考虑网络拟合效果以及学习时间成本，实验设置 epoch 初始值为 70 轮次。此外，选择 Adam 算法作为优化算法，激活函数均选取 ReLU 函数。

本文选取平均均方根误差 (RMSE)、偏差值 Δf 和性能增益 η 作为模型预测性能评价指标，即

$$E_{\text{RMSE,day}} = \frac{1}{N_i} \sum_{i=1}^{N_i} \sqrt{\frac{1}{N_j} \sum_{j=1}^{24} (y_{ij} - \hat{y}_{ij})^2} \quad (11)$$

$$E_{\text{RMSE,hour}} = \frac{1}{24} \sum_{j=1}^{24} \sqrt{\frac{1}{N_i} \sum_{i=1}^{N_i} (y_{ij} - \hat{y}_{ij})^2} \quad (12)$$

$$\Delta f = y_{ij} - \hat{y}_{ij} \quad (13)$$

$$\eta = \frac{\Delta f_{\text{BiGRU}} - \Delta f'}{\Delta f'} \times 100\% \quad (14)$$

其中， y_{ij} 为第 i 天第 j 个时刻链路间的实测 MUF 值， \hat{y}_{ij} 为第 i 天第 j 个时刻链路间的预测 MUF 值， $E_{\text{RMSE,day}}$ 表示 N_i 天的平均 RMSE， $E_{\text{RMSE,hour}}$ 表示 24 个时刻的平均 RMSE， Δf_{BiGRU} 表示本文所提方法预测结果与测量值之间的偏差值， $\Delta f'$ 表示其他模型与测量值之间的偏差值。

4 实验结果

本文将所提模型数据双驱动 CNN-BiGRU-NN 在重庆—海口链路的预测结果与 SRMC 模型中 VOACAP 模型、LSTM 网络、CNN-GRU 网络的预测结果在时刻尺度和日期尺度上进行了对比。由于短波通信的 MUF 受收发端位置影响严重，利用重庆—昆明的数据对网络的泛化性进行验证。

4.1 重庆—海口链路

图 5 为 MUF 实测值与各种方法 24 个时刻的预测值比较结果。图 5(a)和图 5(b)分别为使用训练集 \mathcal{X}_1 与 \mathcal{X}_2 和仅使用训练集 \mathcal{X}_2 进行训练的预测结果。从图 5 可以看出，机器学习方法相比于经验模型方法，可以有效提升 MUF 短期预测精度。因为 VOACAP 的预测结果是月平均值，所以在具体的某一天中，与测量值出现非常大的误差是正常的。

通过图 5(a)与图 5(b)的对比可以看出，当仅使用训练集 \mathcal{X}_2 时，CNN-BiGRU-NN、CNN-GRU 网络和 LSTM 网络的预测结果非常相近，这是因为训练数据太少导致模型参数优化不够，不能充分支持本文提出的 CNN-BiGRU-NN，导致预测结果相近。结合表 1 数据可以看出，使用训练集 \mathcal{X}_1 和 \mathcal{X}_2 作为训练数据时，CNN-BiGRU-NN 的预测结果相比于 CNN-GRU 网络和 LSTM 网络的预测结果在 9:30—15:30 (北京时间 17:30—23:30) 这 7 个时刻上有明显提高，平均分别提高 0.83 MHz 和 0.70 MHz，在其他时间段虽然略微有所降低，但平均分别仅降低 0.21 MHz 和 0.005 MHz。使用训练集 \mathcal{X}_1 和 \mathcal{X}_2 作为训练数据的 CNN-BiGRU-NN 的预测结果与仅使用训练集 \mathcal{X}_2 作为训练数据的 CNN-BiGRU-NN 的预测结果相比，其预测准确度在 9:30—15:30 这 7 个时

刻上有略微降低（平均降低 0.29 MHz），其他时刻上均有所提高（平均提高 0.30 MHz）。总体而言，模型数据双驱动的 CNN-BiGRU-NN 与小样本数据驱动的 CNN-BiGRU-NN 相比，可以获得更大时间跨度的预测准确度提升；与模型数据双驱动的 CNN-GRU 网络和 LSTM 网络相比，可以在一段时间内获得更明显的预测准确度提升；也可说明，在本文情况下，串联模式优于并联模式。




图 5 重庆—海口链路的 MUF 实测值与各种方法 24 个时刻的预测值比较结果

图 6 为重庆—海口从 2019 年 10 月 9 日到 2019 年 10 月 30 日各种方法的偏差值 Δf 。其中，X 轴为时间轴，代表世界时间（UTC），Y 轴代表日期，Z 轴代表预测结果与实际测量值的偏差值 Δf 。由于太阳辐射强度的变化是有规律的，可以看出，每一天的频率偏差值都有相同的趋势。这反映了 MUF 变化的规律性特征。另外也可以看出，在不同的日期里，同一时刻的差值是不同的，这反映了 MUF 的非规则变化特征。这主要是因为每一天的同一时刻的太阳辐射强度、大气环境不同。

表 1 和表 2 分别为 2019 年 10 月 9 日到 2019 年 10 月 30 日各种方法在不同日期同一时刻和同一日期不同时刻 Δf 的时均值 Δf_{hour} 和日均值 Δf_{day} 。

$$\Delta f_{\text{hour}} = \frac{1}{22} \sum_{i=1}^{22} \Delta f_{ij} \quad (15)$$

$$\Delta f_{\text{day}} = \frac{1}{24} \sum_{j=1}^{24} \Delta f_{ij} \quad (16)$$

其中， Δf_{ij} 为第 i 天第 j 时刻的偏差值。

从表 2 可以看出，在大多数情况下，CNN-BiGRU-NN 的预测偏差小于其他 2 个网络。此外，表 3 为重庆—海口链路各个模型 RMSE。从表 3 中可以看出，本文所提网络性能明显优于其他几种方法。模型数据驱动的 CNN-BiGRU-NN 可以利用 VOACAP 模型的预测结果来提取 MUF 的物理层特征，提高预测精度。

从每天来看，使用训练集 χ_1 和 χ_2 进行网络训练的 CNN-BiGRU-NN 相比于 VOACAP 模型具有 74.21% 的平均 RMSE 增益，相比于 CNN-GRU 网络和 LSTM 网络分别具有 3.32% 和 12.68% 平均 RMSE 增益。与 CNN-GRU 网络相比，CNN-BiGRU-NN 引入了双向的 GRU 单元，更能够提取 MUF 数据的前向以及后向特征，因此具有更好的预测性能，与图 5 中显示结果相吻合。CNN-BiGRU-NN 与 LSTM 网络相比有更好的预测性能，因为加入了 CNN，它在提取数据的特征方面更有效。当只使用训练集 χ_2 进行网络训练时，CNN-BiGRU-NN 的平均 RMSE 值略高于 CNN-GRU 网络的平均 RMSE 值，而低于 LSTM 网络的平均 RMSE 值。这是因为 CNN-BiGRU-NN 比 CNN-GRU 网络更复杂，可以用更多的参数进行训练，而小规模训练集并不能更好地训练更复杂的 CNN-BiGRU-NN。使用训练集 χ_1 和 χ_2 进行网络训练的 CNN-BiGRU-NN 的平均 RMSE 值比只使用 χ_2 作为训练集的 CNN-BiGRU-NN、LSTM 网络和 CNN-GRU 网络分别具有 6.44%、5.05% 和 7.45% 的增益。从每个时刻来看，仍然是用训练集 χ_1 和 χ_2 进行网络训练的 CNN-BiGRU-NN 的性能最好。

4.2 重庆—昆明链路

由于接收端和发送端的地理位置也是影响 MUF 的重要因素之一，为了验证模型数据双驱动的 CNN-BiGRU-NN 的有效性与泛化性，本节进行了重庆—昆明链路的 MUF 预测。重庆—昆明链路各个模型 RMSE 如表 4 所示。数据处理过程与重庆—海口链路的一样，并且进行一样的网络建立与网络训练过程。

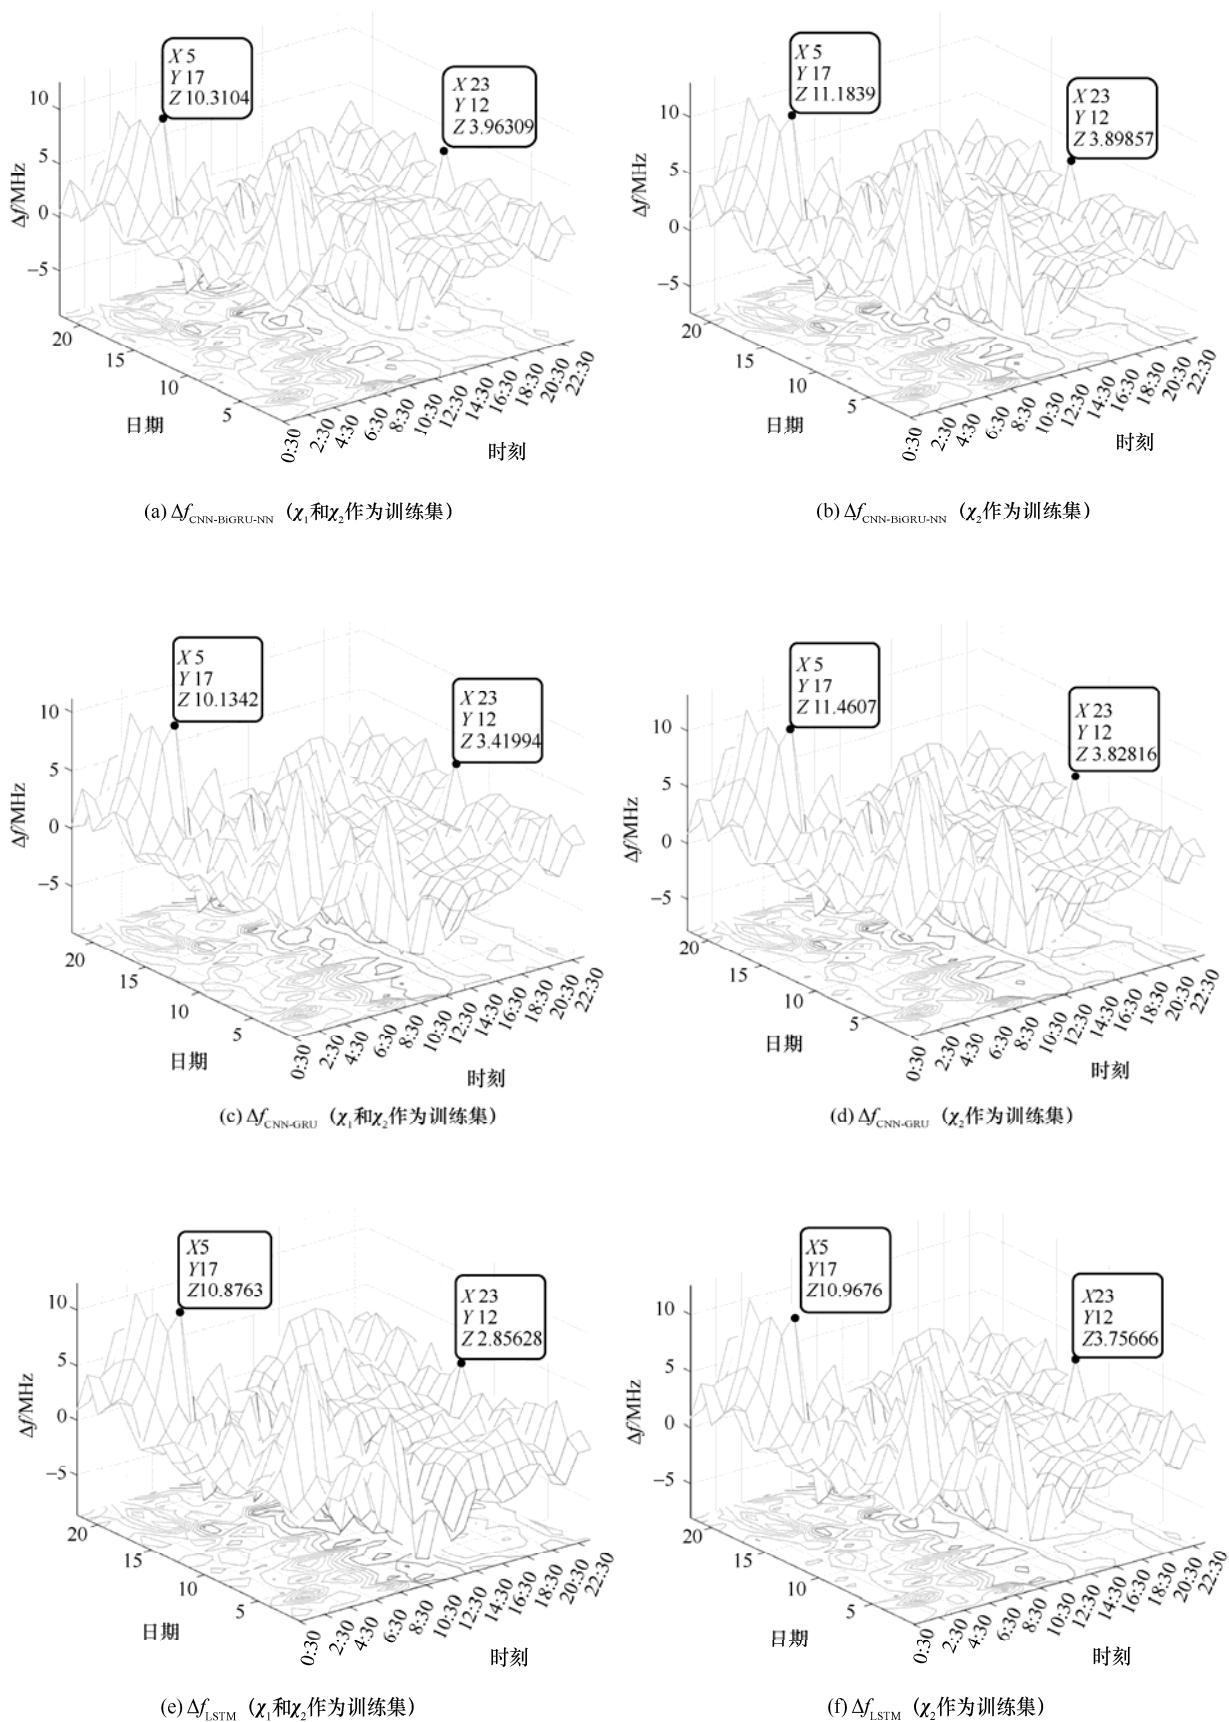


图6 重庆—海口从2019年10月9日到2019年10月30日各种方法的偏差值 Δf

表 1 各种方法在不同日期同一时刻的 Δf_{hour}

时刻	χ_1 和 χ_2 作为训练集			χ_2 作为训练集			VOACAP/MHz
	CNN-BiGRU-NN/MHz	CNN-GRU/MHz	LSTM/MHz	CNN-BiGRU-NN/MHz	CNN-GRU/MHz	LSTM/MHz	
0:30	1.487	1.082	1.213	1.621	1.539	1.517	6.630
1:30	1.344	1.029	1.222	1.470	1.447	1.380	8.032
2:30	2.159	1.633	2.114	2.629	2.644	2.315	6.983
3:30	4.687	3.902	4.776	5.692	5.752	5.233	4.564
4:30	3.932	3.475	3.924	4.563	4.819	4.380	4.382
5:30	2.774	2.578	2.681	3.053	2.939	2.773	5.011
6:30	3.270	3.057	3.209	3.952	3.635	3.368	4.409
7:30	3.205	2.964	3.046	4.497	3.772	3.602	4.427
8:30	2.240	2.131	2.117	2.724	2.490	2.259	6.553
9:30	2.919	3.229	3.329	2.658	2.793	2.825	9.487
10:30	3.497	3.963	4.519	3.071	3.328	3.476	12.256
11:30	3.886	4.706	5.191	3.322	3.523	3.907	15.284
12:30	3.164	4.613	4.333	2.758	3.009	3.270	16.475
13:30	2.377	4.301	3.824	2.353	2.727	2.949	16.534
14:30	0.939	2.523	1.150	0.929	1.015	1.057	16.756
15:30	0.985	1.424	0.918	0.645	0.552	0.486	16.940
16:30	0.952	1.343	1.419	0.746	0.684	0.685	16.599
17:30	0.831	0.931	1.192	0.772	0.730	0.703	15.306
18:30	0.806	0.766	1.191	0.919	0.880	0.834	13.300
19:30	0.989	0.714	1.140	1.040	1.013	0.958	9.967
20:30	0.646	0.946	1.140	0.561	0.469	0.571	7.765
21:30	0.980	1.321	1.149	0.711	0.784	0.907	6.757
22:30	1.332	1.161	1.556	1.545	1.481	1.416	4.537
23:30	1.502	1.464	0.952	1.605	1.606	1.433	4.385

表 2 各种方法在同一日期不同时刻的 Δf_{day}

日期	χ_1 和 χ_2 作为训练集			χ_2 作为训练集			VOACAP/MHz
	CNN-BiGRU-NN/MHz	CNN-GRU/MHz	LSTM/MHz	CNN-BiGRU-NN/MHz	CNN-GRU/MHz	LSTM/MHz	
10月9日	1.910	1.825	2.282	2.277	2.188	2.033	8.338
10月10日	2.251	2.474	2.640	2.501	2.480	2.401	9.188
10月11日	1.760	1.934	1.960	1.831	1.845	1.807	9.979
10月12日	3.044	3.155	3.263	3.224	3.211	3.128	8.815
10月13日	2.115	2.301	2.288	2.236	2.228	2.164	9.102
10月14日	1.722	2.334	1.974	1.837	1.857	1.856	10.506
10月15日	2.112	2.524	2.359	2.278	2.267	2.228	9.819
10月16日	2.434	2.539	2.437	2.693	2.617	2.514	8.832
10月17日	1.850	1.920	2.281	1.895	1.893	1.818	10.140
10月18日	1.601	1.744	1.681	1.695	1.678	1.595	9.972
10月19日	1.945	1.799	1.830	2.059	1.981	1.870	9.526
10月20日	1.636	2.161	2.595	1.649	1.676	1.680	10.580
10月21日	1.552	2.259	1.823	1.438	1.503	1.601	11.385
10月22日	1.847	2.108	2.058	2.008	2.000	1.947	10.545
10月23日	1.662	2.099	2.080	1.457	1.587	1.654	11.217
10月24日	2.073	2.267	2.294	2.038	2.086	2.081	11.022
10月25日	1.821	1.928	2.073	2.318	2.217	2.071	8.825
10月26日	2.778	2.542	2.981	3.352	3.179	2.980	7.647
10月27日	2.426	2.447	2.550	2.546	2.528	2.466	9.087
10月28日	2.736	2.785	2.976	2.727	2.722	2.659	9.827
10月29日	2.736	2.845	3.401	3.064	3.056	2.984	8.695
10月30日	2.649	2.659	2.704	2.225	2.362	2.406	10.845

表 3 重庆—海口链路各种方法的平均 RMSE

参数	χ_1 和 χ_2 作为训练集			χ_2 作为训练集			VOACAP
	CNN-BiGRU-NN	CNN-GRU	LSTM	CNN-BiGRU-NN	CNN-GRU	LSTM	
RMSE _{day} / MHz	2.287 9	2.924 9	3.238 4	3.022 6	2.978 4	3.055 6	10.964 4
η_{day}	—	3.32%	12.68%	6.44%	5.05%	7.45%	74.21%
RMSE _{hour} / MHz	2.545 2	2.583 4	2.911 6	2.668 9	2.627 6	3.332 5	9.962 1
η_{hour}	—	1.48%	12.58%	4.63%	3.14%	23.62%	74.45%

表 4 重庆—昆明链路各种方法的平均 RMSE

参数	χ_1 和 χ_2 作为训练集			χ_2 作为训练集			VOACAP
	CNN-BiGRU-NN	CNN-GRU	LSTM	CNN-BiGRU-NN	CNN-GRU	LSTM	
RMSE _{day} / MHz	1.182 4	1.194 3	1.359 6	1.215 7	1.481 8	2.105 7	7.548 2
η_{day}	—	0.99%	13.03%	2.74%	20.21%	43.85%	84.34%
RMSE _{hour} / MHz	1.060 1	1.068 1	1.176 6	1.092 6	1.298 0	1.916 7	7.355 8
η_{hour}	—	0.75%	9.90%	2.97%	18.33%	44.69%	85.89%

图 7 为重庆—昆明链路的 MUF 实测值和各种方法 24 个时刻的预测值比较结果。





图 7 重庆—昆明链路的 MUF 实测值与各种方法 24 个时刻的预测值比较结果

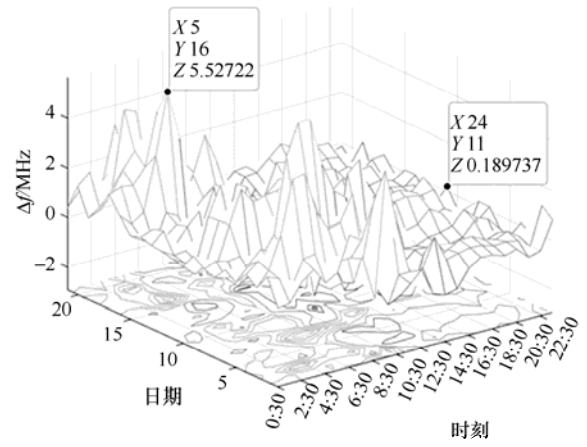
图 8 为重庆—昆明从 2019 年 10 月 10 日到 2019 年 10 月 30 日各种方法的偏差值 Δf 。从图 8 中可以看到，重庆—昆明链路的 MUF 预测结果的趋势与重庆—海口链路的 MUF 预测结果的趋势相同。从表 4 可以看出，与其他方法相比，使用训练集 χ_1 和 χ_2 进行网络训练的 CNN-BiGRU-NN，在日期和时刻 2 个尺度上都具有正向平均 RMSE 性能增益。

5 结束语


本文提出模型数据双驱动的 CNN-BiGRU-NN 用于 MUF 短期预测，模型驱动和数据驱动相结合，同时兼顾了 MUF 变化的规律性与突变性，而且可以降低数据驱动对训练集规模的需求。仿真实验表明，相比于 VOACAP 预测模型、LSTM 网络和 CNN-GRU 网络，模型数据双驱动的 CNN-BiGRU-NN 在日期尺度和时刻尺度上的 MUF 短期预测的平均 RMSE 数值均获得降低。但是，串联模式的模型数据双驱动网络对于算力、时间开销具有更高要求，后续可以对模型数据双驱动网络模型的轻量化、简单化展开研究。除此之外，MUF 预测结果对于通信频率的选择具有重要意义，后续还可以开展智能化选频研究。



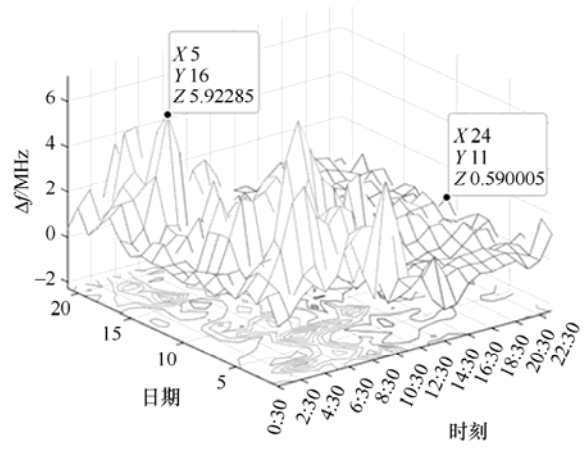
(a) $\Delta f_{\text{CNN-BiGRU-NN}}$ (χ_1 和 χ_2 作为训练集)



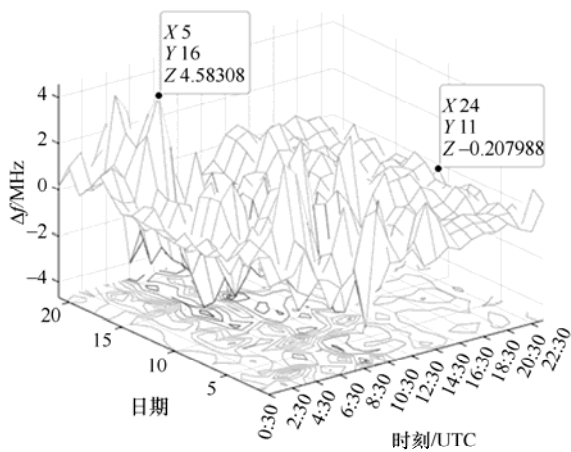
(b) $\Delta f_{\text{CNN-BiGRU-NN}}$ (χ_2 作为训练集)




(c) $\Delta f_{\text{CNN-GRU}}$ (χ_1 和 χ_2 作为训练集)



(d) $\Delta f_{\text{CNN-GRU}}$ (χ_2 作为训练集)



(e) Δf_{LSTM} (χ_1 和 χ_2 作为训练集)



(f) Δf_{LSTM} (χ_2 作为训练集)

图 8 重庆—昆明从 2019 年 10 月 10 日到 2019 年 10 月 30 日各种方法的偏差值 Δf

参考文献:

- [1] WANG J L, DING G R, WANG H C. HF communications: past, present, and future[J]. *China Communications*, 2018, 15(9): 1-9.
- [2] 王金龙. 短波数字通信研究与实践[M]. 北京: 科学出版社, 2013.
WANG J L. Short-wave digital communication research and practice[M]. Beijing: Science Press, 2013.
- [3] 张家帅, 骆志刚, 张翔, 等. 超短波通信系统的物理层仿真精确建模方法研究[J]. *电信科学*, 2012, 28(1): 86-90.
ZHANG J S, LUO Z G, ZHANG X, et al. Research on exact simulation modeling approach for physical layer of ultra-short communication system[J]. *Telecommunications Science*, 2012, 28(1): 86-90.
- [4] Recommendation ITU-RP.533-14. Method for the prediction of the performance of HF circuits[S]. 2019.
- [5] Recommendation ITU-RP.1240-7. ITU-R methods of basic MUF, operational MUF and ray-path prediction[S]. 2019.
- [6] 孙宪儒. 亚大地区 F₂ 电离层预测方法[J]. *通信学报*, 1987, 8(6): 153-156.
SUN X R. A method of predicting the ionospheric F₂ layer in the Asia Oceania region[J]. *Journal on Communications*, 1987, 8(6): 153-156.
- [7] 李忠勤, 孙宪儒. 亚大预测与 CCIR 推荐方法(340 报告)的比较[J]. *电波科学学报*, 1992(2): 17-29.
LI Z Q, SUN X R. Comparison between sub-large prediction and CCIR recommendation method (report 340)[J]. *China Industrial Economics*, 1992(2): 17-29.
- [8] 曹红艳, 孙宪儒. 新版亚大地区 F₂ 电离层频率预测方法[J]. *空间科学学报*, 2009, 29(5): 502-507.
CAO H Y, SUN X R. A new method of predicting the ionospheric F₂ layer in the Asia Oceania region[J]. *Chinese Journal of Space Science*, 2009, 29(5): 502-507.
- [9] 鲁转侠, 曹红艳, 冯静. “新版亚大地区 F₂ 电离层预测”方法数据验证[J]. *中国电子科学研究院学报*, 2011, 6(1): 59-63.
LU Z X, CAO H Y, FENG J. The new method data verification of predicting the ionospheric F₂ layer in the Asia Oceania region[J]. *Journal of China Academy of Electronics and Information Technology*, 2011, 6(1): 59-63.
- [10] FANG D, SOICHER H. The IONCAP program enhancement[C]//*Proceedings of MILCOM Conference Record*. Piscataway: IEEE Press, 2002: 288-290.
- [11] PERKIÖMÄKI J. VOACAP quick guide[R]. 2020.
- [12] TANYER S G, EROL C B. Broadcast analysis and prediction in the HF band[J]. *IEEE Transactions on Broadcasting*, 1998, 44(2): 226-232.
- [13] 高清. 短波通信中的准实时频率预报技术[J]. *通信学报*, 1987, 8(3): 79-82.
GAO Q. A quasi real-time prediction technique for HF communications[J]. *Journal on Communications*, 1987, 8(3): 79-82.
- [14] SECAN J A, WILKINSON P J. Statistical studies of an effective sunspot number[J]. *Radio Science*, 1997, 32(4): 1717-1724.
- [15] MARIN D, MIRO G, MIKHAILOV A V. A method for foF₂ short-term prediction[J]. *Physics and Chemistry of the Earth, Part C: Solar, Terrestrial & Planetary Science*, 2000, 25(4): 327-332.
- [16] 李国军, 郑广发, 叶昌荣, 等. 基于稳健卡尔曼滤波的倾斜探测电离层 MUF 短期预报方法[J]. *通信学报*, 2021, 42(1): 79-86.
LI G J, ZHENG G F, YE C R, et al. Short-term prediction method of oblique sounding ionosphere MUF based on robust Kalman filter[J]. *Journal on Communications*, 2021, 42(1): 79-86.
- [17] SEZEN U, SAHIN O, ARIKAN F, et al. Estimation of hmF₂ and foF₂ communication parameters of ionosphere F₂-layer using GPS data and IRI-plas model[J]. *IEEE Transactions on Antennas and Propagation*, 2013, 61(10): 5264-5273.
- [18] ZENG W, ZHANG X J. Predictions of HF communication MUF in the region of the South China Sea[J]. *IEEE Antennas and Propagation Magazine*, 1999, 41(4): 35-38.
- [19] 任淑婷, 郭黎利. 基于模糊小波神经网络的短波频率预测[J]. *通信技术*, 2011, 44(4): 37-39.
REN S T, GUO L L. A prediction method for HF radio communication frequency based on FWN[J]. *Communications Technology*, 2011, 44(4): 37-39.
- [20] YU L, CHEN J, ZHANG Y M, et al. Deep spectrum prediction in high frequency communication based on temporal-spectral residual network[J]. *China Communications*, 2018, 15(9): 25-34.
- [21] WANG J, YANG C, AN W X. Regional refined long-term predictions method of usable frequency for HF communication based on machine learning over Asia[J]. *IEEE Transactions on Antennas and Propagation*, 2022, 70(6): 4040-4055.
- [22] LI C, LIU Y J, WANG Y Q, et al. Short-term prediction method of HF frequency based on deep learning network[C]//*Proceedings of International Conference on Artificial Intelligence and Advanced Manufacturing (AIAM)*. Piscataway: IEEE Press, 2020: 360-363.
- [23] 兰朝凤, 王顺博, 郭小霞, 等. 基于 DCNN 和 BiLSTM 的单通道视听融合语音分离方法研究[J]. *电子学报*, 2023, 51(4): 914-921.
LAN C F, WANG S B, GUO X X, et al. A single channel audio-visual fusion speech separation method based on DCNN and BiLSTM[J]. *Acta Electronica Sinica*, 2023, 51(4): 914-921.
- [24] RAO T V, SRIDHAR M, RATNAM D V, et al. A bidirectional long short-term memory-based ionospheric foF₂ and hmF₂ models for a single station in the low latitude region[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 1-5.
- [25] 夏吉业, 张海勇, 徐池, 等. 基于 CNN-BiLSTM 的短波通信频率预测研究[J]. *通信技术*, 2020, 53(6): 1311-1318.
XIA J Y, ZHANG H Y, XU C, et al. Frequency prediction of HF communication based on CNN-BiLSTM[J]. *Communications Technology*, 2020, 53(6): 1311-1318.
- [26] 沈琪琪, 朱德生. 短波通信[M]. 西安: 西安电子科技大学出版社, 1989.
SHEN Q Q, ZHU D S. Short wave communication[M]. Xi'an: Xidian University Press, 1989.
- [27] XU Z B, SUN J. Model-driven deep-learning[J]. *National Science Review*, 2018, 5(1): 22-24.
- [28] 王金龙, 陈瑾, 徐煜华. 短波通信技术研究进展与发展需求[J]. *陆军工程大学学报*, 2022(1): 1-7.
WANG J L, CHEN J, XU Y H. On research advances and development requirements of high frequency communication technologies[J]. *Journal of Army Engineering University of PLA*, 2022(1): 1-7.
- [29] YAN Y S, LIU J M, XU S, et al. MD³Net: integrating model-driven

- and data-driven approaches for pansharpening[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-16.
- [30] ZHANG H W, LI Q, SUN Z N, et al. Combining data-driven and model-driven methods for robust facial landmark detection[J]. IEEE Transactions on Information Forensics and Security, 2018, 13(10): 2409-2422.
- [31] YIN Z Q, XU W, XIE R J, et al. Deep CSI compression for massive MIMO: a self-information model-driven neural network[J]. IEEE Transactions on Wireless Communications, 2022, 21(10): 8872-8886.
- [32] HE H T, WEN C K, JIN S, et al. Model-driven deep learning for joint MIMO channel estimation and signal detection[J]. IEEE Transactions on Signal Processing, 2020, 68: 1702-1715.
- [33] SHEN H F, JIANG M H, LI J, et al. Coupling model- and data-driven methods for remote sensing image restoration and fusion: improving physical interpretability[J]. IEEE Geoscience and Remote Sensing Magazine, 2022, 10(2): 231-249.
- [34] HE H T, JIN S, WEN C K, et al. Model-driven deep learning for physical layer communications[J]. IEEE Wireless Communications, 2019, 26(5): 77-83.
- [35] 任国春. 短波通信原理与技术[M]. 北京: 机械工业出版社, 2020.
REN G C. Shortwave communication principles and technology[M]. Beijing: Mechanical Industry Press, 2020.
- [36] Recommendation ITU-RP.1239-3. ITU-R reference ionospheric characteristics[S]. 2012.
- [37] KOPKA H, MÖLLER H G. MUF calculations including the effect of the earth's magnetic field[J]. Radio Science, 1968, 3(1): 53-56.
- [38] 廖柳添. 短波电台特征动态识别算法研究[D]. 广州: 华南理工大学, 2016.
LIAO L T. Research on dynamic identification algorithm of short-wave radio features[D]. Guangzhou: South China University of Technology, 2016.
- [39] BUCKLEY R, FURMAN W N. Application of machine learning techniques to HF propagation prediction[C]//Proceedings of IEEE Military Communications Conference (MILCOM). Piscataway: IEEE Press, 2021: 623-628.
- [40] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [41] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [42] DENG Y P, WANG L, JIA H, et al. A sequence-to-sequence deep learning architecture based on bidirectional GRU for type recognition and time location of combined power quality disturbance[J]. IEEE Transactions on Industrial Informatics, 2019, 15(8): 4481-4493.
- [43] TOLOSANA R, VERA-RODRIGUEZ R, FIERREZ J, et al. Exploring recurrent neural networks for on-line handwritten signature biometrics[J]. IEEE Access, 2018, 6: 5128-5138.
- [44] WANG Q, LI F, TANG Y, et al. Integrating model-driven and data-driven methods for power system frequency stability assessment and control[J]. IEEE Transactions on Power Systems, 2019, 34(6): 4557-4568.
- [45] 谢博, 申国伟, 郭春, 等. 基于残差空洞卷积神经网络的网络安全实体识别方法[J]. 网络与信息安全学报, 2020, 6(5): 126-138.
XIE B, SHEN G W, GUO C, et al. Cyber security entity recognition method based on residual dilation convolution neural network[J]. Chinese Journal of Network and Information Security, 2020, 6(5): 126-138.
- [46] XUAN Y, SI W G, ZHU J, et al. Multi-model fusion short-term load forecasting based on random forest feature selection and hybrid neural network[J]. IEEE Access, 2021, 9: 69002-69009.
- [47] WANG J Y, GRANT T, VELIPASALAR S, et al. Taking a deeper look at the brain: predicting visual perceptual and working memory load from high-density fNIRS data[J]. IEEE Journal of Biomedical and Health Informatics, 2022, 26(5): 2308-2319.

[作者简介]



李俊兵(1994-), 男, 四川资阳人, 重庆大学博士生, 主要研究方向为短波组网、宽带短波传输技术。



曾围钧(1993-), 男, 四川资阳人, 中国工程物理研究院电子工程研究所博士生, 主要研究方向为智能辅助短波无线通信、强化学习。



曾孝平(1965-), 男, 四川广安人, 博士, 重庆大学教授、博士生导师, 主要研究方向为下一代移动通信、无线通信、空间信息网。



李国军(1978-), 男, 四川资阳人, 博士, 重庆邮电大学教授、博士生导师, 主要研究方向为复杂恶劣环境超视距无线通信与网络。



白晨曦(1987-), 男, 内蒙古乌兰察布人, 陆军工程大学通信士官学校讲师, 主要研究方向为信息通信和物联网技术。