

DOI:10.3969/j.issn.1671-024x.2025.06.011

基于卷积-长短时记忆网络的含噪正弦信号 频率估计算法

王迪^{1,2}, 邓小涛^{1,2}, 唐隆煌³, 石嘉^{1,2}, 马鹤立³, 牛萍娟^{1,2}

(1. 天津工业大学 电子与信息工程学院, 天津 300387; 2. 天津工业大学 天津市光电检测技术与系统重点实验室, 天津 300387; 3. 中国工程物理研究院流体物理研究所 冲击波物理与爆轰物理重点实验室, 四川 绵阳 621999)

摘要: 针对低信噪比下正弦波频率难以准确估计的问题, 提出一种基于卷积-长短时记忆网络的频率估计算法。首先利用卷积神经网络层学习频率相关信息在含噪正弦信号上的局部空间表征, 然后通过长短时记忆网络处理含噪正弦信号中的时序信息, 获取全局长时依赖关系, 最终引入注意力机制聚焦的频率相关关键信息完成频率估计。仿真结果表明: 在信噪比为-10、-5、0、5、10 dB条件下, 该方法的均方误差均优于对比算法, 分别达到 1.1×10^{-3} 、 2.8×10^{-4} 、 8.9×10^{-5} 、 3.1×10^{-5} 、 6.2×10^{-6} (kHz)², 性能接近正弦波信号频率估计的克拉美罗(CRLB)界。

关键词: 含噪正弦信号; 频率估计; 卷积-长短时记忆网络; 克拉美罗(CRLB)界

中图分类号: TP183 **文献标志码:** A **文章编号:** 1671-024X(2025)05-0082-09

Frequency estimation algorithm for noisy sinusoidal signals based on convolutional long and short-term memory

WANG Di^{1,2}, DENG Xiaotao^{1,2}, TANG Longhuang³, SHI Jia^{1,2}, MA Heli³, NIU Pingjuan^{1,2}

(1. School of Electronic and Information Engineering, Tiangong University, Tianjin 300387, China; 2. Tianjin Key Laboratory of Optoelectronic Detection Technology and System, Tiangong University, Tianjin 300387, China; 3. National Key Laboratory of Shock Wave and Detonation Physics, Institute of Fluid Physics of China Academy of Engineering Physics, Mianyang 621999, Sichuan Province, China)

Abstract: For the problem that it is difficult to accurately estimate the frequency of sinusoidal waveforms at low signal-to-noise ratios, a frequency estimation algorithm based on convolutional long and short-term memory network is proposed. The method first uses the convolutional neural network layer to learn the local spatial representation of the frequency-related information on the noisy sinusoidal signal, and then processes the temporal information in the noisy sinusoidal signal through the long and short-term memory network to obtain the full long-term dependence, and finally introduces the frequency-related key information focused by the attention mechanism to complete the frequency estimation. The simulation results show that under the conditions of signal-to-noise ratios of -10, -5, 0, 5, and 10 dB, the method's mean square error (MSE) is better than one of the comparison algorithm, and the normalized MSE reaches 1.1×10^{-3} , 2.8×10^{-4} , 8.9×10^{-5} , 3.1×10^{-5} , and 6.2×10^{-6} (kHz)², respectively, and its performance approaches the Cramer-Rao lower bound (CRLB) for frequency estimation of sinusoidal signals.

Key words: noisy sinusoidal signals; frequency estimation; convolutional long short-term memory network; Cramer-Rao lower bound (CRLB)

收稿日期: 2023-10-11

基金项目: 国家自然科学基金项目(61905177, 62101518); 天津市自然科学基金项目(19JCQNJC01400); 冲击波物理与爆轰物理重点实验室基金稳定支持项目(JCKYS2022212001)

第一作者: 王迪(1991—), 男, 讲师, 博士研究生, 主要研究方向为信号处理与智能分析。E-mail: wangdi@tiangong.edu.cn

通信作者: 石嘉(1990—), 男, 副教授, 博士生导师, 主要研究方向为人工智能赋能光电子技术。E-mail: shijia@tiangong.edu.cn

对淹没在白噪声中的正弦信号进行频率估计是信号处理领域的经典课题,在雷达、声纳、通信、生物医学、电力系统、机械振动分析、电子对抗等诸多领域具有广泛的应用前景。在上述领域的典型应用系统中,接收信号模型多为正弦信号,对正弦信号频率的估计精度是相关应用开展的重要前提与基础,直接决定了整个系统的性能与可用性。

目前,现有正弦信号频率估计算法可以分为两大类:时域估计算法、频域估计算法^[1]。其中,时域估计算法主要基于信号在时间域的采样值进行分析处理,其特点是利用信号相位、频率间关系实现频率估计,如线性预测算法^[2]、最大似然算法^[3]、自相关算法^[4]、最小二乘法^[5]等。尽管时域估计算法能在一定条件下,使误差有效逼近克拉美罗下限(Cramer-Rao lower bound, CRLB),但其对信号信噪比要求较高,且存在频率估计范围有限、相位模糊等问题,不利于强噪声(低信噪比)场景下的实际应用。

频域估计算法通常采用离散傅里叶变换(discrete fourier transform, DFT)实现正弦信号频率估计,估计过程一般包含2个步骤:粗估计和细估计。粗估计主要是在对接收的正弦信号进行离散傅里叶变换后,搜索幅度最大谱线;细估计是在粗估计搜索结果基础上,通过插值方法补偿粗估计频率值与信号实际频率间的误差。现有基于离散傅里叶变换的频域估计算法一般只是在细估计阶段采用的插值策略存在差异^[6]。Rife 算法^[7-8]在快速傅里叶变换(fast fourier transform, FFT)后,基于FFT主瓣内最大谱线与次大谱线的幅度比进行插值,该方法在无噪声或高信噪比条件下均可实现频率的准确估计,在工程上应用广泛;Quinn 算法^[9]提出在插值过程中,使用FFT频谱主瓣内最大谱线与次大谱线实部比,以此消除插值方向错误导致的估计误差;Candan 算法^[10]利用FFT频率中最大谱线及左右相邻的两根谱线实现插值,通过三谱线提高在采样点较少条件下的算法性能;Fang 算法^[11]在对信号采样点进行补零填充后执行2N点FFT,利用此时搜索得到的第2大与第3大幅度谱线对信号频率进行插值估计。在上述基于离散傅里叶变换的频域估计算法中,细估计插值本质上利用的都是DFT最大谱线或对称地位于其两侧的若干谱线。尽管这种方式能够在一定程度上改善频率估计精度,但是由于谱线十分容易受到噪声干扰,因此在低信噪比时,算法依然会面临估计性能下降问题,难以满足实际应用需求。此外,无论时域估计算法还是频域估计算法,都建立在固定先验理论知识与假设条件下,尽管能够在一定程度上拟合信号与频率间关系,但是不可避免地会忽略影响估

计精度的部分潜在关键信息,从而限制频率估计性能的进一步提升。

近年来,人工智能尤其是深度学习技术快速发展,在语音识别^[12]、信号处理^[13]、频率监测^[14]等领域得到了广泛应用。相较于传统方法,深度学习方法的优势在于无需实现预设先验理论与假设条件,它不仅能够通过数据学习自动探索挖掘输入与目标间的关系,有效克服潜在关键信息的忽略问题,同时还能够基于端到端的训练过程适应不同数据分布与噪声水平,提高预测的鲁棒性。面向正弦信号频率估计,Sajedian 等^[15]提出一种基于神经网络的正弦信号频率估计方法,该方法将正弦信号直接作为输入,通过3层隐含层拟合,探索在一定信噪比下信号频率与输入数据间的关系;Gao 等^[16]构建了一种卷积神经网络结构,用于预测不同信噪比下连线干涉测量(connected element interferometry, CEI)正弦信号的频率;文献[17]在对正弦信号进行二维化处理,采用卷积残差网络提取与频率相关的高维特征,最后由输出层完成频率估计与预测。尽管上述研究为正弦信号频率估计提供了新的研究思路,但是仍存在不足。在特征提取过程中,现有基于深度学习的方法普遍只关注局部空间信息,而忽略了正弦信号数据作为典型时间序列数据所具有的全局时序依赖性,这一限制导致现有网络模型无法充分表述信号输入数据与频率预测输出间的关系,尤其在低信噪比条件下,噪声会掩盖或混淆信号中反映周期信息的细微变化,导致传统卷积神经网络无法有效提取周期特征。此时,需要进一步考虑信号全局长时依赖关系,通过记忆和融合历史信息降低噪声干扰。因此,需要探索能够兼顾局部与全局信息的深度学习方法,改善正弦信号频率估计性能。

结合上述考虑,在卷积神经网络基础上,为进一步获取并充分利用正弦信号全局信息,本文引入能够捕获信号长时依赖的长短时记忆(long short-term memory, LSTM)网络,提出了一种基于卷积-长短时记忆网络的正弦信号频率估计方法。在频率估计过程中,该方法利用卷积核通过区域卷积捕获正弦信号中的局部空间信息,在此基础上,进一步利用长短时记忆网络获取信号序列中的长时依赖关系,弥补局部空间模式的不足,实现频率相关信息的全面描述,改善低信噪比下的预测精度。在LSTM层中,采用注意力机制对所获取的信息进行权重分配,使网络更加关注输入序列中与频率估计相关的关键部分,提高网络性能。该网络采用端到端的学习方式进行特征提取,无需前期预处理与预变换,能够有效避免因主观因素干扰导致的信息损失。

1 卷积-长短时记忆网络

本文构建的基于卷积-长短时记忆网络的含噪正弦信号频率估计算法流程如图 1 所示。卷积-长短时记忆网络功能主要是实现特征学习,通过网络拟合探索输入一维信号数据中与频率相关的潜在数据分布规律。网络主要包含输入层、CNN 层、Attention LSTM 层、输出层。其中:CNN 层用于获取信号局部空间信息;Attention LSTM 层则用于捕获全局长时依赖。

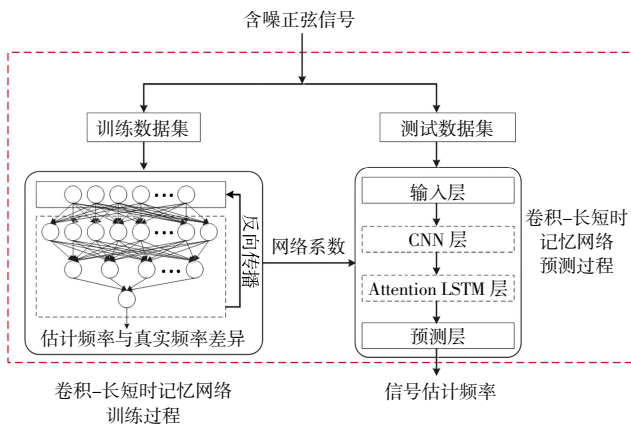


图 1 基于卷积-长短时记忆网络的含噪正弦信号估计算法流程
Fig.1 Algorithmic flow of noisy sinusoidal signal estimation based on convolutional long and short-term memory networks

1.1 数据集

为实现网络模型的构建,根据文献[15]建立数据样本集。设构建的单频含噪实正弦信号为 $x(n) = A \cos(2\pi f_0 n \Delta t + \varphi) + q(n)$ 。式中: A 为信号幅度; f_0 为正弦信号实际频率,本文频率估计范围为 $f_0[1 \text{ kHz}, 10 \text{ kHz}]$,这个频率范围内的正弦信号普遍存在于音频、通信与测量系统等,具有广泛的应用场景,数据构建过程中, f_0 随机生成; n 为采样点; Δt 为采样间隔,此时采样间隔 Δt 为 $1 \mu\text{s}$;并设置采样频率 f_s 为 1 MHz ;采样点数量为 2000 ; φ 为相位,在 $[0, 2\pi]$ 内随机选择; $q(n)$ 为白噪声,根据信噪比需求,由 MATLAB 内嵌函数 `awgn()` 生成并叠加至正弦信号上,如图 2 所示。









图 2 不同信噪比下正弦信号波形

Fig.2 Sine signal waveforms with different signal-to-noise ratios

在实验过程中,为评估算法在低信噪比条件下的性能,图 2 中取信噪比 SNR 为[-10dB : 5dB : 10dB]。根据文献[15]设置,在不同信噪比下各生成 100 000 条数据,用于面向不同信噪比的频率估计模型构建。取频率为 2 000 Hz 正弦信号为例,由图 2 直观可见,随着信噪比的降低,信号的频率逐渐被淹没在噪声中。

1.2 网络模型

本文将所获取的带噪信号的离散点作为模型的




图 3 卷积-长短时记忆网络结构

Fig.3 Structural of convolutional long and short-term memory network

1.2.1 CNN 层

在得到正弦信号数据后,将信号序列直接作为卷积-长短时记忆网络输入进行特征提取。首先,由一维卷积层进行局部空间信息提取。一维卷积层与二维卷积层相似,都是利用卷积核与输入信息执行卷积运算以获取特征映射。一维卷积过程表达式如式(1)所示:

$$Y^{CNN} = f(X * w + b) \quad (1)$$

式中: Y^{CNN} 为一维卷积输出,即提取得到的卷积特征; X 为输入信号序列数据,在本文中其维度为 2 000; w 为卷积核,卷积过程中设置卷积核通道数量为 16,卷积核尺寸为 1×8 ,多通道卷积的目的主要是为了利用多种不同卷积核对原始信号局部区域进行不同方式探索,提高模型表达能力; $*$ 为卷积运算; b 为偏置; $f(\cdot)$ 为激活函数,在此采用修正线性单元(rectified linear unit, ReLU)函数,用于实现卷积层非线性变换。

1.2.2 Attention LSTM 层

正弦信号作为一种时间序列,内部还存在与时序相关的潜在数据规律,仅凭卷积神经网络很难有效获取时序相关信息。事实上,在频率估计过程中,低信噪比情况下局部区域的数据往往难以充分反映信号周期信息,有效结合前、后信号全局数据情况进行分析,才能更准确地对频率进行估计。因此,在利用 CNN 层从原始含噪正弦信号片段中学习到局部特征后,本文进一步利用 LSTM 网络提取正弦信号中的时序相关特征。同时,考虑到 LSTM 网络不同时刻信息存在对频率

输入^[15],然后构建一个以一维卷积网络和 LSTM 网络为基础的串联模型,提取采样离散点的局部频率特征及其前后关联信息,最后对含噪正弦信号段自动提取特征并预测频率,网络结构如图 3 所示。在这里,输入层节点数量设置与输入的信号段采样点数量相同。预测层仅包含一个输出节点,该节点对应网络预测的含噪正弦信号频率值。

在特征提取过程中,执行特征提取功能的主要是 CNN 层和 Attention LSTM 层。

估计的贡献差异,将注意力机制引入 LSTM 模型中,构建 Attention LSTM 层。Attention LSTM 层在传统 LSTM 网络基础上进行构建,其结构如图 4 所示。

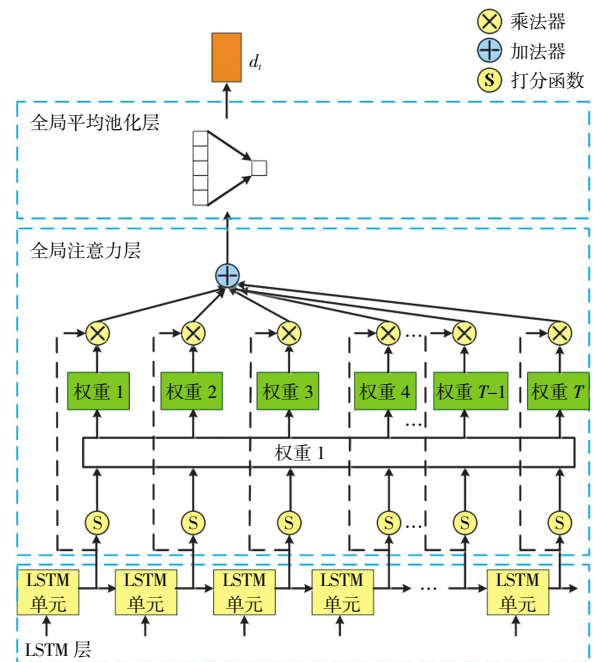


图 4 Attention LSTM 结构

Fig.4 Attention LSTM structure

图 4 中,Attention LSTM 层由 LSTM 层、全局注意力层与全局平均池化层构成。其中,LSTM 层由若干 LSTM 单元串联构成,每个单元接收上一个时间步的

输出和当前时间步的输入,产生输出和内部状态。在数据处理过程中,LSTM 单元通过一系列的门机制,如输入门、遗忘门、输出门等,来实现记忆功能。这些门允许 LSTM 单元选择性地读取、写入和遗忘信息,控制内部状态更新,实现对正弦信号频率估计过程中长时依赖相关信息的获取。通过 LSTM 层学习,可以在每个 LSTM 单元输出处(即 LSTM 网络隐藏层)获得当前时间步与以往时间步的信息整合。

全局注意力层作用是从整体角度对输入序列中与频率估计相关的关键部分进行关注和加权。在全局注意力层处理过程中,首先利用加性打分函数 $S(\cdot)$ 对各 LSTM 单元输出进行变换,分配权重分数。打分函数形式如下:

$$r_t = S(h_t) = V \tanh(W h_t + U h_k + B) \quad (2)$$

式中: r_t 为第 t 个 LSTM 单元输出对应的权重分数; h_t 为第 t 个 LSTM 单元的输出; h_k 为 LSTM 网络的最终输出,即最后 1 个 LSTM 单元的输出; W 、 V 、 U 、 B 为网络参数,可通过反向传播方法学习获取。在此基础上,利用 Softmax 函数对所有权重分数进行归一化,获取权重系数,如式(3)所示:

$$a_t = \text{Softmax}(r_t) \quad (3)$$

式中: a_t 为归一化后权重系数, a_t 值越大,表示其对频率估计任务的贡献越大,反之,则越小。进一步地,将权重系数与各 LSTM 单元输出进行加权求和:

$$C = \sum_{i=1}^k a_i \times r_i \quad (4)$$

式中: C 表示全局注意力向量。

最终,全局平均池化层会对全局注意力向量 C 所捕捉的、由注意力机制聚焦的关键信息进一步开展汇聚与提取操作,通过对每个通道全局注意力向量进行平均值计算,在保证频率估计重要信息的同时,压缩信息容量表达,减少计算复杂度。最终,采用表示根据注意力机制获取的 LSTM 网络不同时刻信息融合特征。在此基础上,通过全连接网络,即可输出正弦信号频率估计值。综上,本文构建的卷积-长短时记忆网络结构与参数设置如表 1 所示。

表 1 卷积-长短时记忆网络参数设置

Tab.1 Parameter settings of convolutional long short-term memory network

网络层	类型	网络参数
1	输入层	节点数量:2 000
2	CNN 层	卷积核尺寸:1×8;卷积核数量:16
3	池化层	池化层尺寸:1×2;池化步长:2
4	Attention-LSTM 层	LSTM 单元数量:16
5	全连接层	节点数量:32
6	输出层	节点数量:1

1.2.3 模型训练

在生成数据集后,将各个信噪比下的 100 000 条数据划分为训练集和测试集。其中,训练集用于网络模型训练,构建卷积-长短时记忆网络;测试集用于评估训练所得网络模型的频率估计性能。在实验过程中,采用 10 折交叉验证,数据划分如图 5 所示。每折交叉验证过程中训练集占总数据集的 90%,测试集占 10%。为便于模型搭建,将训练集进一步划分为训练数据与验证数据,其中训练数据占训练集总数据量的 80%,验证数据占训练集总数据量的 20%。最终取每折交叉验证实验下,在验证数据上获得最小频率误差的模型为最优模型,并用于测试集评估。




图 5 十折交叉验证实验数据分布

Fig.5 Distribution of data from ten-fold cross-validation experiments

在训练过程中,网络的目标是寻找最优参数最小化网络估计频率与真实频率间的平均均方误差(mean square error, MSE),平均均方误差如式(5)所示:

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - p_i)^2 \quad (5)$$

式中: N 为信号样本数量; y_i 表示网络预测的估计频率; p_i 为信号真实频率。网络训练过程中,使用 Adam 优化器进行反向传播,实现模型参数寻优。Epoch 设置为 300,学习率为 0.001。

进一步地,为方便比较不同量级误差,定义:

$$\text{MSE}_{\text{dB}} = 10 \log(\text{MSE}/\text{MSE}_{\text{ref}}) \quad (6)$$

式中: MSE_{ref} 取值为 1 (kHz)²; MSE_{dB} 单位为 dB。

2 实验结果与讨论

2.1 输入层点数对精度的影响

信号长度对频率估计有着重要影响,通常情况下,较长的信号能够提供更多的观测数据与有效周期,从而减小频率估计误差。为评估信号长度对含噪正弦信号频率估计精度的作用,本文对比了不同信噪比(SNR)条件下不同输入层采样点取值时的频率估计误差,实验结果如图 6 所示。

从图 6 中可以看出,随着输入层点数的增加,频




图6 不同输入层采样点的频率估计误差对比

Fig.6 Comparison of frequency estimation errors at different input layer sampling points

率估计误差首先呈现快速下降趋势。这可能是因为在采样率固定不变条件下,随着输入层采样点数的增多,信号长度随之增多。此时,相较于短信号,较长信号能够提供更多的信号周期,自身也包含更充分的信息用于误差校正,因此频率估计精度获得提升。当输入层采样点设置大于2000后,可以看出随着采样点数量进一步增加,MSE变化趋于平稳。这可能是因为在输入层采样点数为2000时,已经能够为频率估计提供足够的周期信息,长度的进一步增多不会带来更多精度增益。因此,考虑到输入点数的增加意味着需要更多的计算资源,在后续实验中,输入层点数均设置为2000。

2.2 算法性能评估

为验证本文算法的性能,通过仿真实验,对淹没在高斯白噪声下的正弦信号进行频率估计,结果如表2所示。

表2 本文算法在不同信噪比条件下的频率估计均方误差

Tab.2 Mean square error of frequency estimation for proposed algorithm under different signal-to-noise ratio conditions

信噪比/dB	-10	-5	0	5	10
均方误差/(kHz) ²	1.1×10^{-3}	2.8×10^{-4}	8.9×10^{-5}	3.1×10^{-5}	6.2×10^{-6}

由表2可以看出,随着信噪比的增加,本文方法对[1 kHz, 10 kHz]范围内含噪正弦信号的频率估计误差呈现下降趋势。当信噪比为10 dB时,均方误差为 6.2×10^{-6} (kHz)²,此时频率估计值与真实值逼近。相比之下,在-10 dB信号条件下,受较强噪声干扰,均方误差较大,为 1.04×10^{-3} (kHz)²,但实际上此时均方误差仅为1.24倍CRLB界,接近理论最佳性能。

图7以(10 dB, 1200 Hz)、(-10 dB, 5200 Hz)正弦信号为例,直观显示了根据本文算法频率估计结果重构的信号与真实信号间的波形对比。

由图7可知,对于(10 dB, 1200 Hz)情况下的正弦




图7 不同信噪比下预测正弦信号与真正弦信号的波形对比

Fig.7 Waveforms comparison of predicted sinusoidal signal and real sinusoidal signal with different signal-to-noise ratios

信号,本文算法的频率估计结果为1201.4 Hz,误差为1.4 Hz,与真实频率值的差异为1.16%;对于(-10 dB, 5200 Hz)情况下的频率估计结果为5212.2 Hz,误差为12.2 Hz,与真实频率值差异为2.34%。可以看出,根据频率估计结果重构后的正弦信号与真实频率值下的正弦信号呈现相似的波形走势,说明本文方法能够对该信号条件下的频率作出较为准确的估计。

2.3 与现有频率估计方法对比

为进一步验证本文算法性能,将本文算法与现有同类方法—Candan算法^[10]、Fang算法^[11]、DNN算法^[15,19]、CNN算法^[20]、LSTM算法^[21]和CNN-LSTM算法^[22]以及CRLB界进行比较,对比结果如图8所示。对于实正弦信号幅值、频率和初始相位未知时,克拉美罗下界可以表示为:

$$\text{CRLB} = \min \text{var}(\hat{f}) = \frac{3f_s^2}{2\pi^2 N(N^2 - 1) \times \text{SNR}} \quad (7)$$

由图8可以看出,传统频域估计方法如Fang算法、Candan算法受噪声影响较大,在低信噪比条件下,估计的均方误差较高,难以满足频率估计需求。相比之下,深度学习方法能够面向低信噪比信号,自动拟合信号输入与频率估计输出间的关系,充分利用数据潜在规律。进一步地,与CNN算法、DNN算法相比,LSTM算法、CNN-LSTM算法以及本文方法在估计精度上具有明显的提升。这可能是因为在估计精度上具有明显的提升。这可能是因为在估计精度上具有明显的提升。




图 8 各种算法在低信噪比条件下 MSE 对比

Fig.8 MSE comparison of various algorithms under low SNR conditions

算法都只考虑了输入信号数据的局部空间信息,而作为经典时序数据,含噪正弦信号的时序相关性对频率估计具有十分重要的作用,因此包含具有时序记忆功能 LSTM 网络的后 3 种方法更能够做出较为准确的频率估计。此外,对比后 3 种方法可以看出,单一考虑全局时序依赖性的 LSTM 算法性能最差;在全局时序依赖性信息基础上,进一步整合局部空间信息的 CNN-LSTM 算法性能有所改善;本文方法通过充分提取局部与全局信息,并引入注意力机制,突出信号数据中与频率估计相关的部分,取得了最优频率估计结果。与其他方法相比,在不同低信噪比条件下,本文方法均距离 CRLB 界最近。综上,本文方法能够面向低信噪比正弦信号取得良好的频率估计效果。

在上述模型性能评估过程中,不同信噪比下构建的 CNN-LSTM-Attention 模型仅对与自身信噪比相同的测试数据进行了封闭实验验证,如-10 dB 条件下训练得到的模型仅对同为-10 dB 的测试集进行频率估计。为进一步验证模型性能,对构建的本文模型进行全信噪比下开放数据测试,如-10 dB 条件下训练得到的模型对-10、-5、0、5、10 dB 下的全部测试集进行频率估计,结果如图 9 所示。




图 9 不同信噪比下的本文模型对全信噪比测试数据 MSE 对比

Fig.9 MSE comparison of proposed model at different signal-to-noise ratios for full signal-to-noise ratio test data

由图 9 可以看出,尽管随着信噪比提升,在不同信噪比构造的本文模型频率估计误差均呈现下降趋势,然而相较于其他模型,-10 dB 下本文模型对多数信号条件下的测试集,如-10 dB、-5 dB、0 dB、5 dB,均取得了逼近 CRLB 界的频率估计结果。这可能是由于相较于其他信噪比下数据,-10 dB 条件下训练数据形式更为多样,信息更为丰富。此时,本文模型能够通过整合局部空间信息与序列长时依赖信息,更好地关注含噪信号中的微弱变化与细节体现,充分挖掘较强噪声干扰下正弦序列数据中的频率估计相关规律,进而适应噪声环境,给出准确频率估计结果。此外,需要注意的是,对于 10 dB 下测试数据,尽管-10 dB 条件下训练得到的模型频率估计精度较高,MSE 为 $8.75 \times 10^{-6} \text{ (kHz)}^2$,但仍低于 0 dB 条件下构建的模型估计精度。这说明某单一低信噪比下训练的模型不能保证在所有信噪比条件下取得最优结果,在实际应用中,需要根据具体需求进行数据学习才能获得良好的模型性能与应用效果。

2.4 与序列信号估计经典网络对比

为进一步验证本文算法性能,将其与序列信号估计相关的经典网络进行对比,结果如表 3 所示。

表 3 本文方法与经典网络方法估计误差对比

Tab.3 Comparison of estimation errors between proposed method and classical network methods

方法	MSE _{err} /dB				
	-10 dB	-5 dB	0 dB	5 dB	10 dB
时序卷积网络(TCN)	-15.55	-24.77	-29.67	-33.31	-36.39
门控循环单元(GRU)	-18.84	-29.17	-30.4	-30.84	-31.12
Transformer 模型	-15.47	-21.24	-23.38	-29.95	-33.39
本文方法	-29.82	-35.47	-40.47	-45.14	-52.07

由表 3 可以看出,在全部信噪比条件下,Transformer 的估计误差最高,这可能是因为 Transformer 模型中位置信息是通过嵌入方式加入的,但是由于这种嵌入方式存在一定的不准确性,模型无法很好地捕捉和利用正弦信号中的周期性特征,因此导致频率估计结果较低。相较之下,能够直接保存和利用位置信息的 TCN、GRU 取得了较高的估计精度。具体地,在信噪比为-10、-5、0 dB 时,GRU 性能优于 TCN,当信噪比为 5、10 dB 时,TCN 估计精度高于 GRU。

在低信噪比条件下,GRU 相对于 TCN 有较高的频率估计精度,这可能是因为 GRU 具有递归性质,在时间序列数据中保留了历史信息。GRU 通过更新和重置门的机制控制信息的流动,能够更好地捕捉时间序列数据的长期依赖关系。这对于低信噪比条件下的信

号处理非常重要,因为噪声可能掩盖或混淆信号的细微变化。GRU 可以通过记忆和融合历史信息来减小噪声的影响,从而提高频率估计的准确性。

在高信噪比情况下,TCN 比 GRU 具有更高的频率估计精度。TCN 是一种直接处理时间序列的神经网络,它使用一维卷积层来捕捉信号中的局部模式和特征。相比于 GRU 的递归性质,TCN 可以更好地应对高信噪比情况下的信号处理,因为相对较低的噪声使得局部模式更加明显和清晰。通过使用卷积神经网络的并行计算能力,TCN 能够有效地提取频率信息,并且在高信噪比条件下能够更准确地估计信号的频率。

在所有信噪比条件下,本文算法均取得了最佳频率估计效果,这是因为本文算法采用了 CNN-LSTM 结构,该结构兼具 GRU 与 TCN 的特征提取优势:一方面,它可以通过一维卷积核有效捕获信号内部的局部模式与特征,能够在高信噪比下充分获取周期性信息;另一方面,它能够利用 LSTM 获取信号的时间依赖关系,在低信噪比条件下降低噪声带来的影响。

3 结 论

本文提出了一种基于卷积-长短时记忆网络的含噪正弦信号频率估计算法,利用卷积层的局部空间特征提取能力结合 Attention-LSTM 层的全局长时序列依赖性信息处理能力,实现频率相关信息的全面描述,改善低信噪比条件下的预测精度;该网络采用端到端的学习方式自动通过非线性变换拟合信号变化规律,进行特征提取,无需前期预处理与预变换,能够有效避免因主观因素干扰导致的信息损失,实现较好的频率估计效果。结果表明:

(1) 在信噪比为-10、-5、0、5、10 dB 条件下,估计频率的均方误差分别达到 1.1×10^{-3} 、 2.8×10^{-4} 、 8.9×10^{-5} 、 3.1×10^{-5} 、 6.2×10^{-6} (kHz)²,估计精度优于对比算法,面向低信噪比信号的频率估计均方误差接近 CRLB 界,具有一定的应用价值。

(2) 在信噪比为-10 dB 条件下采用本文方法构建模型,并采用该模型对全信噪比测试集进行频率估计,对多数信号条件下的测试集均取得了逼近 CRLB 界的频率估计结果,说明了该方法的鲁棒性。

(3) 尽管本文算法取得了良好的含噪正弦信号频率估计性能,但值得注意的是,现有性能评估主要建立在模拟数据集上,考虑到实际应用中信号环境的复杂性,当前模拟数据集可能无法完全涵盖并反映所有信号条件。因此,在未来研究中,将结合具体应用背景采集并构建实际场景下的信号数据集,对本文算法鲁

棒性做进一步评估。

参考文献:

- [1] HAN L, XU H T, TAO L L, et al. An iterative parameters estimator for damped exponential signal in noise[C]//2018 Prognostics and System Health Management Conference (PHM-Chongqing). Chongqing, China: IEEE, 2019: 629-635.
- [2] 田妍,王勇,杨森,等.基于线性预测分析时差估计的特高频局部放电定位方法[J].高压电器,2019,55(12):181-186.
TIAN Y, WANG Y, YANG S, et al. UHF partial discharge location method based on time delay estimation of linear prediction analysis[J]. High Voltage Apparatus, 2019, 55(12): 181-186(in Chinese).
- [3] RIFE D, BOORSTYN R. Single tone parameter estimation from discrete-time observations [J]. IEEE Transactions on Information Theory, 1974, 20(5): 591-598.
- [4] TU Y Q, SHEN Y L. Phase correction autocorrelation-based frequency estimation method for sinusoidal signal[J]. Signal Processing, 2017, 130: 183-189.
- [5] 张伟佳.高动态频率快速锁定技术研究[D].成都:电子科技大学,2021.
ZHANG W J. Research on high dynamic frequency fast locking technology[D]. Chengdu: University of Electronic Science and Technology of China, 2021(in Chinese).
- [6] DIAO R P, MENG Q F. An interpolation algorithm for discrete Fourier transforms of weighted damped sinusoidal signals[J]. IEEE Transactions on Instrumentation and Measurement, 2014, 63(6): 1505-1513.
- [7] CHIBA A, SUNAGA Y. Complex amplitude estimation of a monochromatic radio-frequency signal using frequency down-conversion via direct detection of interfered optical phase-modulation signals[J]. Optics Letters, 2021, 46(11): 2646-2649.
- [8] 路伟涛,唐歌实,任天鹏,等.一种改进的 Rife 算法及其在无线电干涉测量中的应用[J].遥测遥控,2017,38(3):28-35.
LU W T, TANG G S, REN T P, et al. An improved rife algorithm and its application in the radio interferometry[J]. Journal of Telemetry, Tracking and Command, 2017, 38(3): 28-35 (in Chinese).
- [9] QUINN B G. Estimating frequency by interpolation using Fourier coefficients[J]. IEEE Transactions on Signal Processing, 1994, 42(5): 1264-1268.
- [10] CANDAN Ç. A method for fine resolution frequency estimation from three DFT samples[J]. IEEE Signal Processing Letters, 2011, 18(6): 351-354.
- [11] FANG L Y, DUAN D L, YANG L Q. A new DFT-based frequency estimator for single-tone complex sinusoidal signals[C]

- //MILCOM 2012–2012 IEEE Military Communications Conference. Orlando, FL, USA; IEEE, 2013: 1–6.
- [12] RAJENDRAN S, RAJA K T, NAGARAJAN G, et al. Deep learning speech synthesis model for word/character-level recognition in the Tamil language[J]. International Journal of e-Collaboration, 2023, 19(4): 1–14.
- [13] 童瀛, 周宇, 姚焕章, 等. 深度神经网络的网络高敏感信息预警算法[J]. 西安工程大学学报, 2021, 35(1): 69–74, 87.
- TONG Y, ZHOU Y, YAO H Z, et al. Early warning algorithm for highly sensitive network information based on deep neural network[J]. Journal of Xi'an Polytechnic University, 2021, 35(1): 69–74, 87(in Chinese).
- [14] LIU B, DAI X L, GONG H G, et al. Deep learning versus professional healthcare equipment: A fine-grained breathing rate monitoring model[J]. Mobile Information Systems, 2018, 2018: 5214067.
- [15] SAJEDIAN I, RHO J. Accurate and instant frequency estimation from noisy sinusoidal waves by deep learning [J]. Nano Convergence, 2019, 6(1): 27.
- [16] GAO Z F, JIAO Y W, TENG F, et al. A high-precision frequency estimation method for CEI signals of high-orbit satellites[C]//GLOBECOM 2022–2022 IEEE Global Communications Conference. Rio de Janeiro, Brazil; IEEE, 2023: 3156–3161.
- [17] 贾颜滔, 朱永利, 庄崑萃. 基于 2D–1D 深度残差网络的变压器局部放电模式识别[J]. 电力科学与工程, 2022, 38(10): 20–28.
- JIA Y T, ZHU Y L, ZHUANG Y C. Partial discharge pattern recognition method for transformers based on 2D–1D deep residual network[J]. Electric Power Science and Engineering, 2022, 38(10): 20–28(in Chinese).
- [18] 肖斌, 陈嘉博, 毕秀丽, 等. 基于一维卷积神经网络与循环神经网络串联的心音分析方法[J]. 电子学报, 2022, 50(10): 2425–2432.
- XIAO B, CHEN J B, BI X L, et al. A method of heart sound analysis based on one-dimensional convolutional neural network and recurrent neural network[J]. Acta Electronica Sinica, 2022, 50(10): 2425–2432(in Chinese).
- [19] 周兴. 基于全连接神经网络的载波频率偏移估计方法[J]. 无线通信技术, 2022, 31(4): 6–11.
- ZHOU X. Carrier frequency offset estimation method based on fully connected neural network[J]. Wireless Communication Technology, 2022, 31(4): 6–11(in Chinese).
- [20] 李杰. 基于 Mask R-CNN 的电磁信号智能检测和参数估计[D]. 杭州: 杭州电子科技大学, 2022.
- LI J. Intelligent detection and parameter estimation of electromagnetic signals based on Mask R-CNN[D]. Hangzhou: Hangzhou University of Electronic Science and Technology, 2022(in Chinese).
- [21] HU Y F, WANG H Y, ZHANG Y, et al. Frequency prediction model combining ISFR model and LSTM network[J]. International Journal of Electrical Power & Energy Systems, 2022, 139: 108001.
- [22] LIU M T, YANG B H, XU M D, et al. Exploring quantitative assessment of cybersickness in virtual reality using EEG signals and a CNN-LSTM network[C]//2023 IEEE Conference on Virtual Reality and 3D User Interfaces Abstracts and Workshops (VRW). Shanghai, China; IEEE, 2023: 827–828.
- 本文引文格式:**
王迪, 邓小涛, 唐隆煌, 等. 基于卷积-长短时记忆网络的含噪正弦信号频率估计算法[J]. 天津工业大学学报, 2025, 44(6): 82–90.
- WANG D, DENG X T, TANG L H, et al. Frequency estimation algorithm for noisy sinusoidal signals based on convolutional long and short-term memory[J]. Journal of Tiangong University, 2025, 44(6): 82–90(in Chinese).
- (责任编辑: 孙广宇)

(上接第 81 页)

- [22] ZHANG X Y, SHI T N, WANG Z Q, et al. Generalized predictive contour control of the biaxial motion system[J]. IEEE Transactions on Industrial Electronics, 2018, 65(11): 8488–8497.
- [23] BARENDSSWAARD S, POOL D M, VAN PAASSEN M M, et al. Dual-axis manual control: performance degradation, axis asymmetry, crossfeed, and intermittency[J]. IEEE Transactions on Human-Machine Systems, 2019, 49(2): 113–125.
- [24] XU W, HOU J, LI J, et al. Multi-axis motion control based on time-varying norm optimal cross-coupled iterative learning[J]. IEEE Access, 2020, 8: 124802–124811.
- [25] WU Q, YU L, WANG Y W, et al. LESO-based position synchronization control for networked multi-axis servo systems with time-varying delay[J]. IEEE/CAA Journal of Automatica Sinica, 2020, 7(4): 1116–1123.
- 本文引文格式:**
金雪峰, 李示威, 高文进, 等. 基于 ESO 的多电机位置同步模型预测控制[J]. 天津工业大学学报, 2025, 44(6): 74–81, 90.
- JIN X F, LI S W, GAO W J, et al. Model predictive control for multi-motor position synchronization based on ESO[J]. Journal of Tiangong University, 2025, 44(6): 74–81, 90(in Chinese).
- (责任编辑: 孙广宇)