

Dense-1D-U-Net: 用于自参考光谱干涉飞秒脉冲相位测量

况琪^{1,2}, 申雄², 徐艺林², 白丽华¹, 刘军^{2,3*}

¹上海大学物理系, 上海 200444;

²中国科学院上海光学精密机械研究所强场激光物理国家重点实验室, 上海 201800;

³中国科学院大学材料科学与光电工程中心, 北京 100049

摘要 超快激光脉冲形状宽度测量的核心是光谱相位的精确测量。本文提出了一种结合深度学习的自参考光谱干涉(SRSI)方法,并用该方法进行了飞秒脉冲相位的测量。该方法基于针对一维信号的 Dense-1D-U-Net 神经网络,采用经典的编码-解码网络结构并加入稠密连接和跳跃连接来提高网络的性能。结合 SRSI 法的特点,本文设计出结合了稠密连接块的 Dense-1D-U-Net 神经网络。基于大量接近真实光谱相位的模拟光谱相位数据可以发现,基于 Dense-1D-U-Net 的 SRSI 算法的计算结果的均方根误差相比传统 SRSI 算法至少降低一个数量级。与有无稠密连接、跳跃连接的对照组神经网络进行对比,分析了 Dense-1D-U-Net 的优势。最后用实验测量数据验证了使用模拟数据训练的 Dense-1D-U-Net 具有计算实验数据的能力。Dense-1D-U-Net 神经网络未来可以拓展应用到超快光谱等其他一维信息研究领域。

关键词 测量;深度学习;编码-解码;自参考光谱干涉;神经网络;稠密连接

中图分类号 O346; TP183

文献标识码 A

DOI: 10.3788/CJL202249.0904002

1 引言

超短脉冲激光形状宽度测量是超短脉冲激光技术中非常重要的一部分。最近,自参考光谱干涉(SRSI)方法^[1]作为一种光学外差探测方法和一种实时快速的脉冲形状宽度测量新方法获得了快速发展与广泛应用。经典的频率分辨光学快门(FROG)法^[2]处理的是二维图像数据,而 SRSI 方法与光谱相位干涉电场重建(SPIDER)法^[3]一样,处理的是一维光谱干涉数据。SRSI 方法先用待测激光自身经过三阶非线性光学效应产生参考光,再利用待测光和参考光产生的干涉条纹进行测量,具有光路简单、速度快和动态范围高等特点^[4]。

SRSI 方法要求参考光的光谱比待测光光谱更宽且更光滑,并且相位要平坦。2009 年, Oksenhendle 等^[1]发现交叉偏振波(XPW)产生的信

号光谱能较好地满足参考光的条件,从而提出了基于 XPW 的 SRSI(XPW-SRSI)方法。Liu 等^[5]先后提出了不需要偏振元件的基于自衍射(SD)效应的 SRSI(SD-SRSI)方法以及基于瞬态光栅(TG)效应的 SRSI(TG-SRSI)方法^[6]。其中瞬态光栅效应没有角色散或角色散可以忽略,具有更多优势。基于这一优势,研究人员先后提出了高灵敏度 TG-SRSI 方法^[7]、直筒式 TG-SRSI 方法^[8]、全反射式 TG-SRSI 方法^[9]、结合 TG-FROG 的 FASI 方法^[10]。

近年来,SRSI 的发展都集中在通过改进光路或光学元器件来优化参考光或适应不同场景上。SRSI 的算法依旧采用最开始提出的算法,即使用傅里叶变换光谱干涉方法(FTSI)计算干涉条纹光谱的相位初值,并使用此相位初值结合光谱信息进行少数迭代得到最终结果。此算法为使计算简便而多次使用了近似计算,从而导致大量细节信息损失,计

收稿日期: 2021-08-03; 修回日期: 2021-09-06; 录用日期: 2021-10-09

基金项目: 国家自然科学基金(61527821, 61521093)、上海市自然科学基金(18ZR1413600)

通信作者: *jliu@siom.ac.cn

算精度相对不够高。因此,提升 SRSI 测量性能和精度的新算法对于促进 SRSI 技术和超快激光技术的发展具有重要意义。

近年来,随着计算机运算能力的快速提升,深度学习在计算机视觉领域的目标检测^[11]和三维测量^[12]等方面获得了巨大成功。对于相同质量水平的数据,通过优化神经网络的结构来提高它在各个课题中的适用程度和性能,是计算机科学家不懈追求的目标。自从 U-Net 在 2015 年被 Ronneberger 等^[13]用于生物医疗成像研究后,基于 U-Net 的各种神经网络结构便被广泛应用于医学图像分割^[13]、语义分割^[14]、散射成像^[15-16]等计算机图像与视觉等的相关研究与应用中。U-Net 使用基于卷积神经网络(CNN)的编码-解码^[17]网络结构,并加入了直接连接编码器和解码器对应层的跳跃连接^[13]。一维 U-Net 在 2018 年首次被提出并命名为 WAVEUNET^[18],主要用于声波分离,在信号处理领域中的语音增强^[19]等方面取得了一定进展。

在使用 U-Net 神经网络结构的研究中,通常输入的是相对复杂的信息,输出的是相对简单的信息,即从信息熵较高的数据中提取出信息熵较低的数据。例如:在图像分割中以复杂的医学图像作为输入,以目标的轮廓为边界作为输出;在散射成像中以杂乱的散斑为输入,恢复出肉眼基本上可识别的字符图片;在一维声音识别中,以带有噪声的音频为输入,提取出所需的变化较平滑的音频。

本文将深度学习算法应用于飞秒脉冲形状宽度的 SRSI 测量中,并在传统的基于一维卷积神经网络的编码-解码神经网络结构中加入专门设计的稠密连接模块和 U-Net 标志性的跳跃链接,这里将其称为“Dense-1D-U-Net”。本文采用具有高度随机性的方式生成极具多样性且仿真度较高的光谱相位、光谱幅值和延迟时间,并基于这些变量依据 SRSI 光学过程产生与相位频谱对应的干涉光谱。干涉光谱和相位频谱是深度学习任务中有监督学习的标签和真值。基于经典模拟方法^[4]创建的多种具有不同特征的数据集,将本文所提的基于深度学习的 SRSI 算法与传统 SRSI 算法进行了对比,并对影响计算精度的原因进行了详细分析。本文将所提 SRSI 算法与传统 SRSI 算法的激光光谱相位计算精度进行了对比,结果表明,本文算法的激光光谱相位计算精度更高。此外,本文还比较了 Dense-1D-U-Net 与 U-Net 等基于传统卷积神经网络结构的编码-解码神经网络结构,分析了 Dense-1D-U-Net

的可行性、有效性和优势。最后,通过实验室所测数据验证了深度学习方法结合 SRSI 的可行性。

2 基于深度学习的 SRSI 算法

2.1 SRSI 原理

光谱干涉法利用待测光的干涉条纹重建脉冲信息,因此需要合适的参考光与待测光进行干涉产生干涉条纹。在测量过程中,参考光的光谱需要比待测光的光谱更宽,参考光相位必须是已知的或者是可以推算出的。利用待测光源本身产生参考光是一种理想的办法,称其为“自参考”。目前产生自参考光的方法有 XPW、SD 效应和 TG 效应等三种技术^[20]。SRSI 的基本光路如图 1 所示。入射光经过分束片后被一分为二,将其中一束光经过非线性过程(例如三阶非线性效应)后获得的信号光作为自参考光,将另外一束引入适量延时后作为待测光束。然后,待测光束和自参考光束空间共线重合并聚焦进入高光谱精度光谱仪,得到光谱干涉条纹。

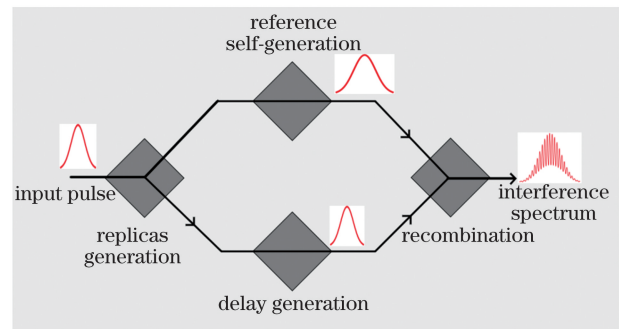


图 1 SRSI 基本光路图

Fig. 1 Basic optical path of SRSI

2.2 SRSI 算法

获得光谱干涉条纹之后,利用 FTSI 算法^[21]重建待测激光脉冲的光谱相位信息。

在频率域,如果 $E_r(\omega)$ 和 $E_u(\omega)$ 分别是参考脉冲和未知脉冲的复光谱振幅,则光谱仪测得的光谱干涉条纹可以表述成

$$D(\omega, \tau) = |E_r(\omega) + E_u(\omega) \exp(i\omega\tau)|^2 = |E_r(\omega)|^2 + |E_u(\omega)|^2 + E_r^*(\omega)E_u(\omega)\exp(i\omega\tau) + c. c. = S_0(\omega) + f(\omega)\exp(i\omega\tau) + c. c., \quad (1)$$

式中: ω 为光谱频率; τ 为延迟时间; $S_0(\omega)$ 是参考脉冲和未知脉冲的光谱强度之和; $f(\omega)$ 是参考脉冲和未知脉冲的干涉项。在传统的 FTSI 算法中,未知脉冲的光谱和光谱相位可以通过傅里叶变换并结合迭代方法求得。具体的求解步骤下:

1) 对干涉信号 $D(\omega, \tau)$ 从频率域到时域进行傅

里叶变换,得到时域信号 $S(\tau)$ 和 $f(\tau)$;

2) 利用一个合适的窗函数,比如超高斯窗函数,在时域上将步骤 1) 得到的 $S(\tau)$ 和 $f(\tau)$ 分开,所用窗函数的窗口宽度应该是 $S(\tau)$ 和 $f(\tau)$ 间隙的一半,或者可以是参考脉冲和未知脉冲之间延时的一半;

3) 对步骤 2) 获得的 $S(\tau)$ 和 $f(\tau)$ 进行傅里叶逆变换,可以分别得到频域信息 $S_0(\omega)$ 和 $f(\omega)$;

4) 利用步骤 3) 得到的 $S_0(\omega)$ 和 $f(\omega)$, 结合公式 $|E_u(\omega)| = \frac{1}{2} (\sqrt{S_0(\omega)+2|f(\omega)|} - \sqrt{S_0(\omega)-2|f(\omega)|})$ 和 $|E_r(\omega)| = \frac{1}{2} (\sqrt{S_0(\omega)+2|f(\omega)|} + \sqrt{S_0(\omega)-2|f(\omega)|})$ 解析计算出参考脉冲和未知脉冲的光谱振幅信息^[4];

5) 利用 $f(\tau)[\arg f(\omega)]$ 求得相位以后,未知脉冲的相位可以通过公式 $\varphi_u(\omega) = \varphi_r(\omega) + \arg[f(\omega)]$ 求得,其中 $\varphi_u(\omega)$ 和 $\varphi_r(\omega)$ 分别是未知脉冲和参考脉冲的光谱相位。

以上是理想情况,实际上,自参考光束的光谱相位不会完全水平,后续需要进行数次迭代运算才能获得接近真实超快激光脉冲的光谱相位。

2.3 Dense-1D-U-Net 神经网络

为了将深度学习应用到一维数据的 SRSI 方法中,本课题组设计了 Dense-1D-U-Net 神经网络,其整体结构图如图 2 所示,用它来学习 SRSI 条纹与

对应的光谱相位真值之间的关系。对于神经网络信息提取任务来说,提取过程中对信息的有效利用尤为重要。如图 2(a) 所示,在所采用的 Dense-1D-U-Net 网络模型结构中,本文将长距离跳跃连接与带稠密连接^[22]的编码-解码网络结构相结合。可见, Dense-1D-U-Net 以基于一维卷积神经网络的编码-解码结构 U-Net 为框架,将部分卷积层替换为本文特别设计的稠密连接块。神经网络的输入是一个归一化后长度为 1024 单位的光谱干涉条纹。输入的光谱干涉条纹进入神经网络后通过“编码器”路径,该路径由 4 个稠密连接块组成,这些稠密连接块通过最大池化层连接,用于降采样。编码器输出的“中间层”的长度被压缩到 64 个单位长度,但编码的信息深度非常深(有 512 个特征图)。每个稠密连接层中都包含有多个复合层,其中每一个复合层又由一个传统的批量标准化层(BN)、一个修正线性单元(ReLU)非线性激活层和一个带有 16 个滤波器的卷积层组成。因为输出的相位曲线相对于输入的干涉光谱条纹平滑很多,所以本文通过加长卷积核的长度来增大感受野,以增加稳定性。卷积核的长度为 9,卷积步长为 1。接下来,中间层的特征图通过“解码器”路径,该路径由上采样卷积层连接的 4 个稠密连接块组成。跳跃连接跨过“编码-解码”结构的跳跃连接直接连接编码层和对应的解码层部分,以更好地利用表层信息。在“解码器”之后紧接着是一层卷积层,输出激活函数使用的是双曲正切函数(tanh)。

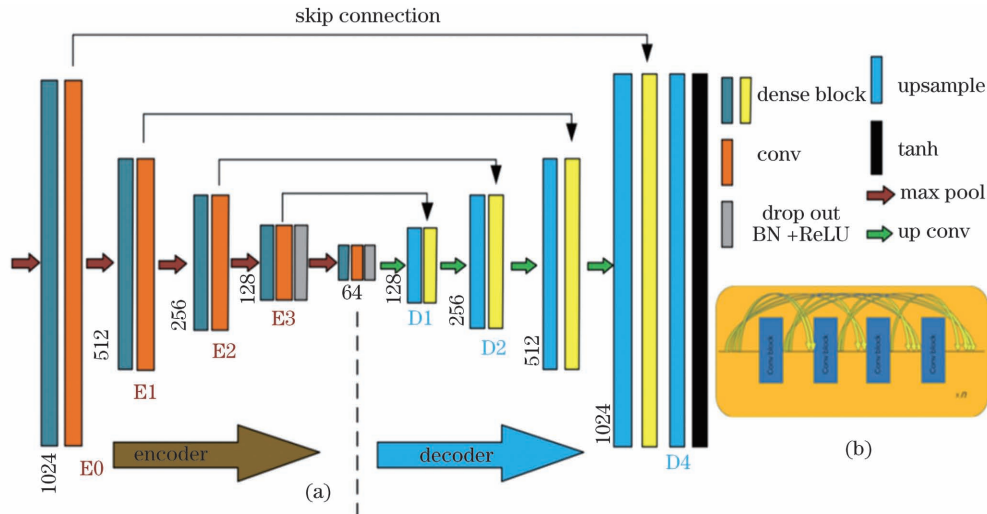


图 2 Dense-1D-U-Net 神经网络。(a)神经网络整体结构;(b)稠密连接块结构

Fig. 2 Dense-1D-U-Net neural network. (a) Overall network structure; (b) structure of dense block

如图 2(b) 所示,在本文设计的稠密连接块中,每一个特征图都是由它前面的所有特征图在通道方向融合得到的。第 l 层会接受前面所有层的特征

图, $\mathbf{X}_0, \mathbf{X}_1, \dots, \mathbf{X}_{l-1}$, 作为输入。可以用数学公式表达为

$$\mathbf{X}_l = H_l([\mathbf{X}_0, \mathbf{X}_1, \dots, \mathbf{X}_{l-1}]), \quad (2)$$

式中: $[X_0, X_1, \dots, X_{l-1}]$ 表示稠密连接块中第 l 层之前的所有特征图在通道方向融合的结果; H_l 表示第 l 层所使用的激活函数。

这里用到的长跳跃连接是一种将编码-解码结构的神经网络的编码层和解码层部分连接起来的结构。在计算机视觉领域大显身手的 U-Net, 其特征就是使用了可加强浅层信息的长跳跃连接, 其结构可用数学表达式表示成

$$\mathbf{X} = \text{Conv}(\mathbf{X}_{\text{encoder}}) + \mathbf{X}_{\text{decoder}}, \quad (3)$$

式中: \mathbf{X} 表示当前层; $\text{Conv}(\cdot)$ 表示卷积操作; $\mathbf{X}_{\text{encoder}}$ 表示编码部分的特征图; $\mathbf{X}_{\text{decoder}}$ 表示解码部分的特征图。值得一提的是, 目前尚未发现有将稠密连接

与一维 U-Net 类型的加入了跳跃连接的编码-解码神经网络相结合的公开报道。

3 模拟与训练

3.1 数据准备

根据 SRSI 产生光谱干涉条纹的原理, 本课题组对光谱干涉条纹进行仿真, 仿真流程如图 3 所示。由 SRSI 原理可知, 生成光谱干涉条纹需要三组变量: 输入激光光谱的相位 $\varphi(\omega)$ 、待测脉冲的复光谱振幅 $|E_u(\omega)|$ 和延迟时间 τ 。模拟出这些变量之后, 就可以采用 SRSI 原理仿真生成光谱干涉条纹。对这些变量进行模拟的公式为

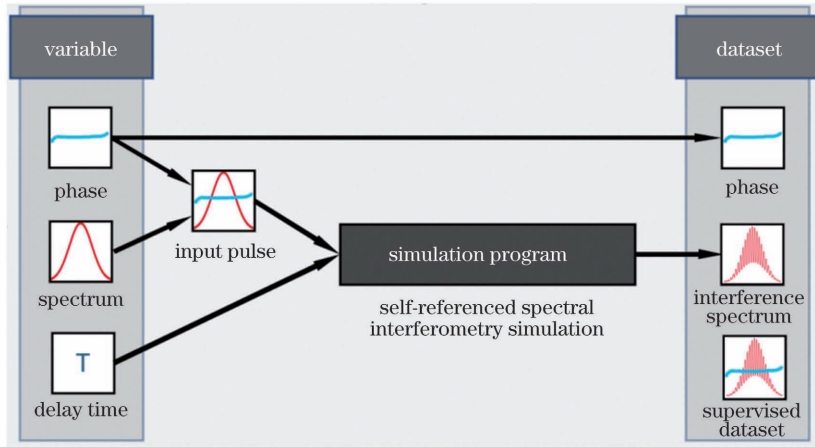


图 3 干涉条纹仿真流程图

Fig. 3 Process of interference fringe simulation

$$E_u(\omega) = |E_u(\omega)| \exp[i\varphi(\omega)], \quad (4)$$

$$E_u(t) = \text{FT}^{-1}[E_u(\omega)], \quad (5)$$

$$E_r(t) = |E_u(t)|^2 E_u(t), \quad (6)$$

$$E_r(\omega) = \text{FT}[E_r(t)], \quad (7)$$

式中: $E_r(\omega)$ 和 $E_u(\omega)$ 分别是参考脉冲和未知脉冲的复光谱振幅; $E_r(t)$ 和 $E_u(t)$ 分别是参考脉冲和未知脉冲的时域振幅。则, 干涉条纹 $D(\omega, \tau)$ 可以表示成

$$D(\omega, \tau) = |E_r(\omega) + E_u(\omega) \exp(i\omega\tau)|^2. \quad (8)$$

超短脉冲的相位曲线可以用泰勒级数展开公式表示。其中, 泰勒系数中的零阶主要与绝对相位有关, 一阶相位主要代表时间延迟, 二阶相位主要与脉冲的啁啾线性变化有关且影响脉宽, 三阶相位主要对应超快激光脉冲的前后沿小脉冲, 更高阶的光谱相位可能也会在脉宽和前后沿小脉冲上影响激光脉冲的形状, 但其影响通常太弱而不用考虑^[23]。

图 4 展示了相位的生成过程。首先, 通过拟合目标频率域中在 $0 \sim 1$ 范围内随机生成的点产生随

机曲线, 如图 4(a) 所示。将该曲线乘以在 $0 \sim 0.3$ 之间取值的比例系数 k_1 来比例缩小通过拟合随机数产生的随机曲线, 并将其作为次要形状曲线, 如图 4(b)。通过随机的泰勒展开系数来生成三阶曲线, 如图 4(c) 所示, 并将其作为脉冲光谱相位的主要形状曲线。将主要形状曲线和次要形状曲线相加的结果归一化、乘以比例系数 k_2 比例缩小后乘以 2π , 得到最后的随机光谱相位曲线, 如图 4(d) 所示。根据 Frequency-Resolved Optical Gating 中对高阶相位影响的描述^[20], 将随机曲线的最高阶次控制在五阶(含)以内。本文使用泰勒系数曲线拟合随机点来产生载波曲线, 这样产生的载波曲线不会过度复杂, 高阶系数可以使曲线的细节更加丰富。

本实验的任务是从光谱干涉条纹中提取出光谱相位信息。在实际情况中, 待测的超短激光的脉冲光谱是一个高斯光谱, 因此本文将随机产生的高斯曲线作为激光的高斯光谱, 如图 5 所示。首先采用随机数函数在 $349.4 \sim 400.6$ Hz 脉冲光谱频域范围(依据频率和波长的乘积为光在真空中的速度, 可得到 $750 \sim$

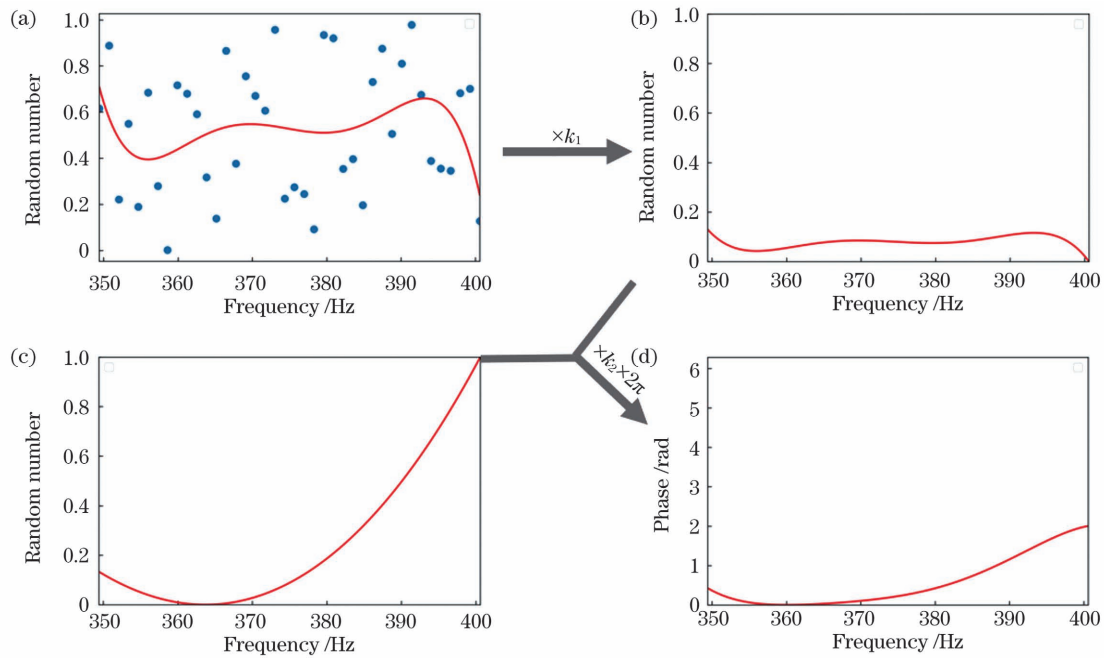


图4 相位模拟。(a)生成随机曲线的随机点;(b)曲线2;(c)曲线1;(d)最终的相位

Fig. 4 Simulation of phase. (a) Random points for random curves; (b) curve 2; (c) curve 1; (d) final phase




图5 光谱模拟

Fig. 5 Simulation of spectrum

850 nm 波长范围内与频率对应的点)内产生 5000 个高斯分布随机数。将频域范围分为 100 个区间,统计各区间内随机数的数量,如图 5 左侧所示。将统计图的顶点用曲线插值,平滑之后生成高斯光谱形状。传统 SRSI 算法和深度学习算法在计算光谱相位时都会对光谱强度进行归一化,仿真过程中光谱强度峰值在 6~60 个单位强度内随机映射,如图 5 右图所示。延迟时间在 500~1500 fs 内随机取值。

为了进行研究,本课题组通过仿真建立了 3 个数据集,并将其作为深度学习的训练数据。在第一个实验(实验 1)中,激光光谱采用完美高斯光谱,延迟时间固定为 500 fs,激光脉冲的光谱相位是变量。基于上述所提方法用随机生成的三阶以内的泰勒系数产生光谱相位。在飞秒脉冲测量过程中,相位比较平缓,通常仅需考虑三阶相位,如图 6(a)所示(SPEC 指的是归一化后的光谱干涉条纹,TRUE 指

的是干涉条纹对应的原始相位)。在第二个实验(实验 2)中,用一个更接近真实情况的光谱与光谱相位来测试 Dense-1D-U-Net 的测量能力。在数据模拟过程中,通过增加光谱和延迟时间的多样性来模拟真实情况下的脉冲。其中,利用高阶曲线对呈高斯分布的数据的柱状统计图进行拟合,并用 9 个单位长度的窗口对拟合曲线进行均值平滑处理,将平滑结果在 6~60 个单位强度范围内的随机放大作为输入光的光谱(传统算法和深度学习算法计算前都会先将光谱归一化,故此处的强度在本研究的仿真中不会对测量产生影响)。延迟时间的取值范围为 500~1500 fs。本次实验中的相位仍然采用与实验 1 一样的生成方式,如图 6(b)所示。第三个实验在实验 2 的基础加入了包含四阶和五阶等阶相位的载波。此阶数是对散点进行拟合的曲线的阶数,并非是无约束地用随机泰勒系数产生曲线的阶数。

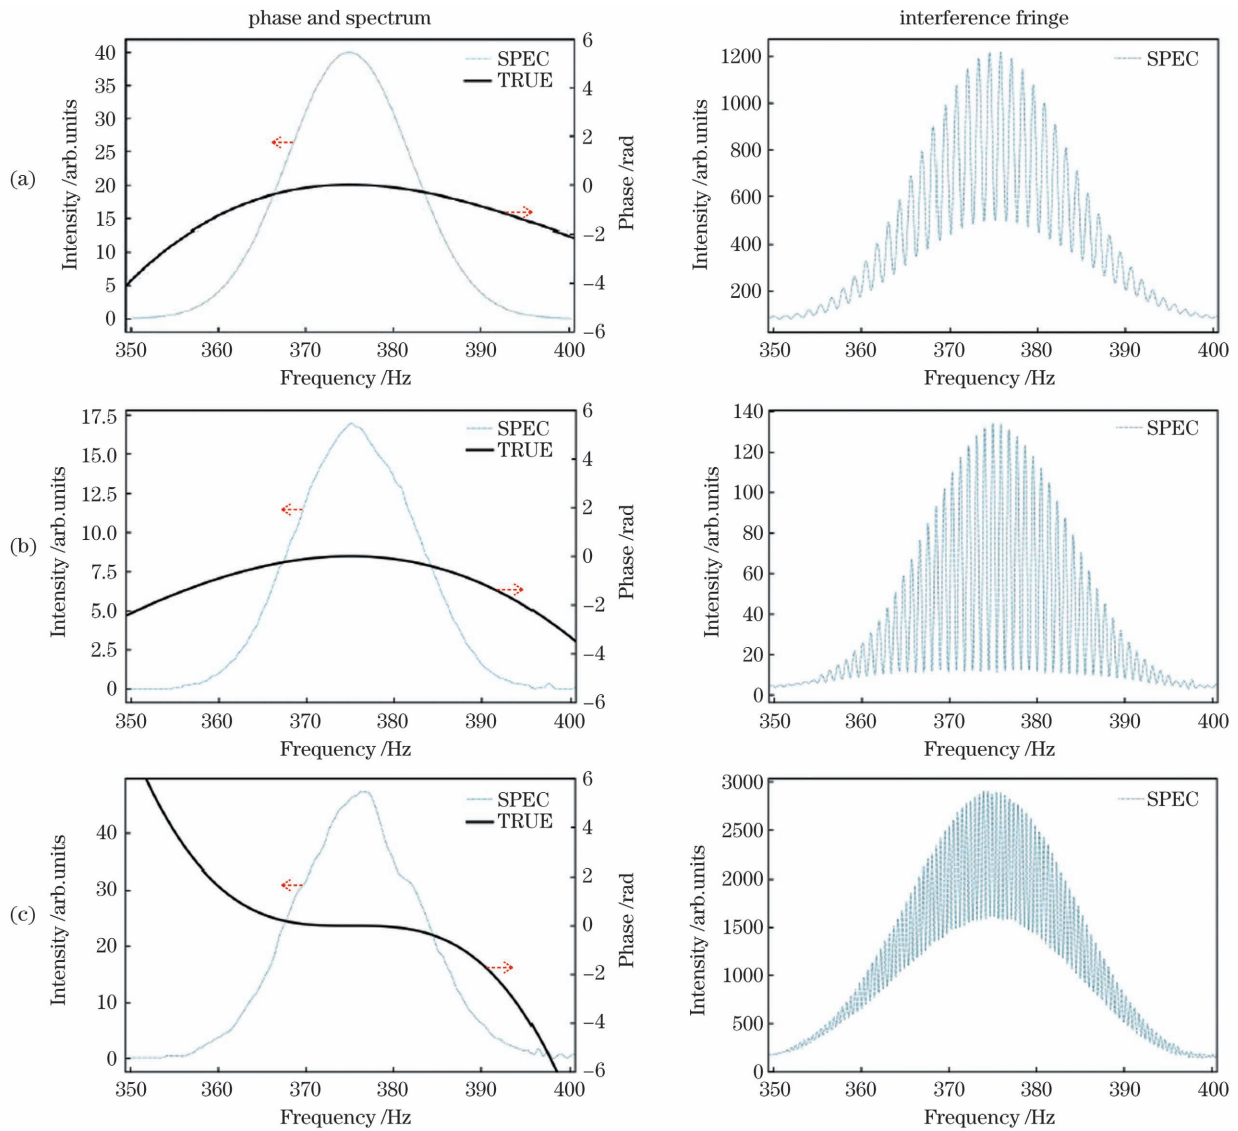


图6 各个实验所用数据集中的数据样本示例。(a)实验1;(b)实验2;(c)实验3

Fig. 6 Examples from datasets used in data experiments. (a) Experiment 1; (b) experiment 2; (c) experiment 3

本课题组将作为载波的高阶曲线乘以一个范围在0~0.3之间的比例系数,这会使原本的三阶曲线形状发生一些细微变化,从而提升相位曲线的多样性,使其更加接近真实的相位曲线。用这样的数据集去训练神经网络可以增加神经网络的鲁棒性,如图6(c)所示。

在实际的相位计算中,快速变化的载波和细微的跳变不在计算范围内。跳变会影响主要形状的获取,可以把它们作为图像处理中的噪声。以此模式拟合更高阶的相位会把可能属于噪声的部分当作真值,因此训练出来的神经网络的功能会偏离实际情况。本研究不使用过于复杂的相位。

3.2 损失函数

深度学习训练模型中的输入为光谱干涉条纹,输出为激光的光谱相位,输入输出数据均为一维向

量,采用端到端的工作方式。为了准确衡量模型输出的光谱相位与准确的光谱相位真值之间的误差,本文采用均方根误差(MSE)作为模型的损失函数,对比相位之间的误差。MSE的计算公式为

$$f_{\text{MSE}} = \frac{1}{M} \sum_{m=1}^M (y_m - \hat{y}_m)^2, \quad (9)$$

式中: M 为数据个数; y_m 为待测数据; \hat{y}_m 为真实值。值得一提的是,在相位的计算过程中,通常不考虑延时的影响,所以,本文在深度学习训练过程中使用损失函数对比的对象虽然是包含三阶相位的原始相位和深度学习恢复出来的对应的相位,但在结果分析中使用的均是去除延迟影响后的相位。具体的方法是用相位真值、SRSI计算结果和深度学习计算结果分别减去一条过频率中心且斜率为对应相位在该点的一阶导数的直线。

4 结果分析

4.1 实验的软硬件平台

模型的训练是在显卡 NVIDIA RTX2080 上完成的,操作系统为 Ubuntu16.04,CPU 型号为 AMD Ryzen 5 3600。本算法基于 Python3.8 实现,使用的编译器为 jupyter notebook,使用的框架为 TensorFlow2.4.0。使用 Adam 优化器,初始学习率为 1×10^{-4} ,以 MSE 为损失函数,训练时间为 5 h。

4.2 实验结果

在前述的三个实验中,使用不同随机程度的数据对神经网络进行训练,并用不包含在训练集中的测试数据测试传统 SRSI 算法和神经网络的拟合能力。最后,本文还比较了各种相关神经网络的性能。在每个实验中选择具有代表性的测量数据进行展

示,以说明实验效果。在每个实验中,标注为 TRUE、SRSI、DL 的曲线分别代表干涉条纹对应的原始相位、传统 SRSI 算法恢复的相位、基于 Dense1D-U-Net 的 SRSI 算法恢复的相位,标注为 SPEC 的曲线是归一化后的光谱干涉条纹。

在基于第一个数据集的深度学习研究中,用含有 1000 组与训练集 1 不重叠但具有相同特征的数据作为验证集 1 进行测试。经统计,传统 SRSI 算法计算光谱相位的 MSE 值为 0.00825,基于 Dense1D-U-Net 的 SRSI 算法的预测 MSE 值可达到 0.0000848。观察具体的相位恢复情况,如图 7(a)、(b)所示,当中心频率附近的相位斜率变化不大时,传统 SRSI 算法计算的相位和深度学习预测的相位比较接近相位真值(图 7 中黑色实线)。由图 7(c)~(f)可以看出,当中心频率附近的相位倾斜度较大

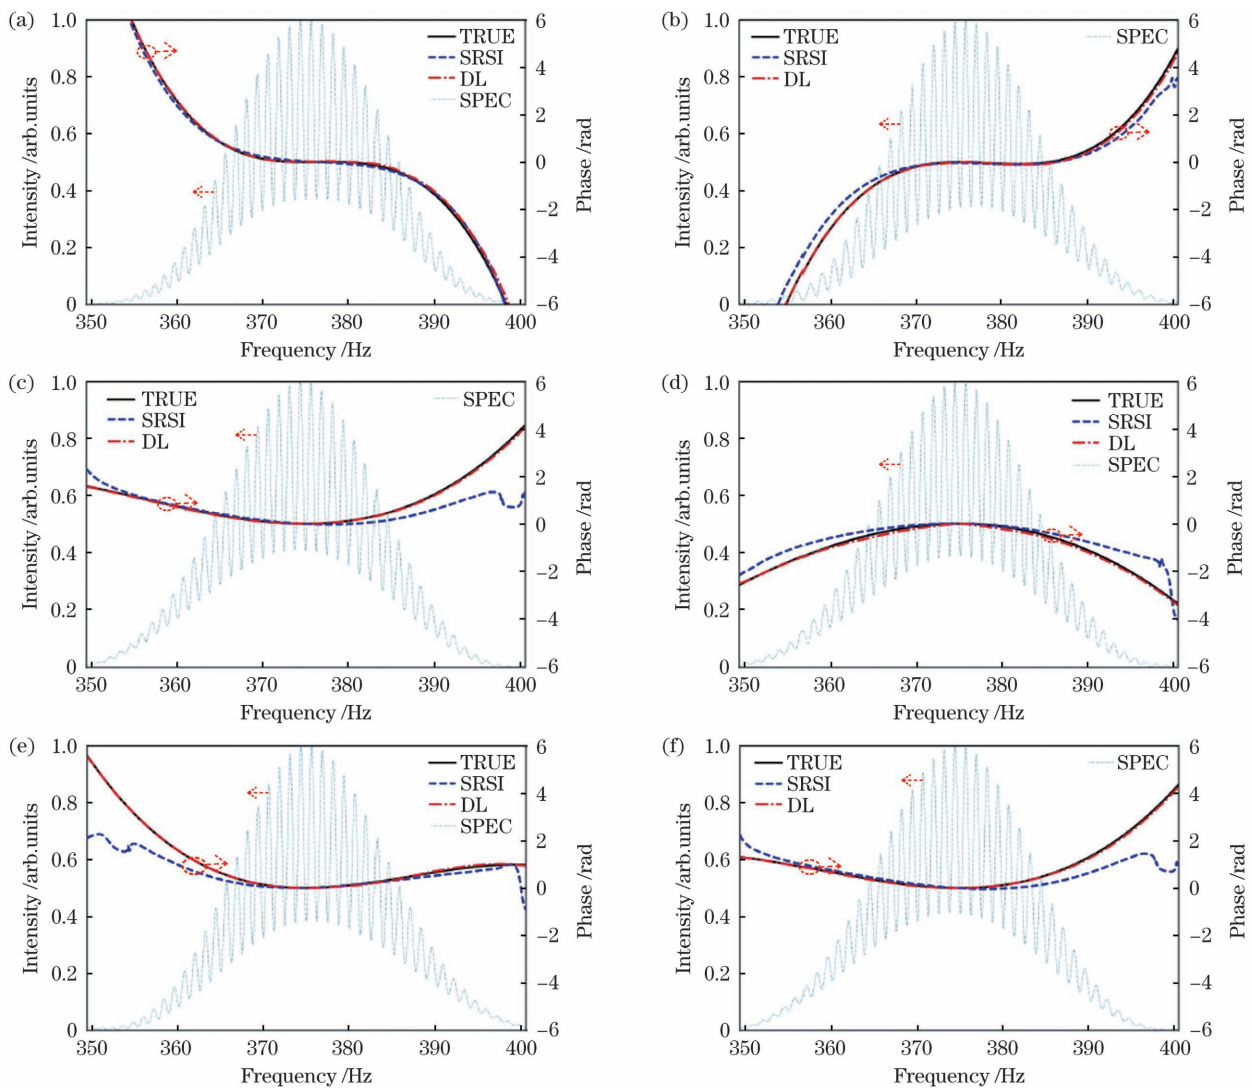


图7 实验1计算结果的若干样图

Fig. 7 Calculation results samples of experiment 1

时,传统 SRSI 的测量结果逐渐偏离真实脉冲相位, Dense-1D-U-Net 的预测结果并没有受到斜率变化速度增大的干扰,恢复的相位仍然可以贴合原始相位。在这个实验中,脉冲光谱相位在没有其他变量干扰的情况下,与光谱干涉条纹形成了很强的对应关系。端到端地对脉冲光谱相位和光谱干涉条纹的对应关系进行学习,对 Dense-1D-U-Net 来说并不困难,较大的数据集和有效的神经网络结构使基于 Dense-1D-U-Net 的 SRSI 算法相比传统 SRSI 算法在误差率上小了两个数量级。

实验 2 是基于第二个数据集(数据集 2)进行的深度学习实验,在使用数据集 2 训练神经网络之后,用含有 1000 组与训练集 2 不重叠但具有相同特征的数据作为验证集 2 进行测试。相比实验 1,实验 2 增加了变量的多样性,加入了真实情况下会改变的

变量——光谱幅值和延迟时间,但仍采用三阶相位。传统 SRSI 算法计算光谱相位的 MSE 值为 0.0101,基于 Dense-1D-U-Net 的 SRSI 算法的预测 MSE 值可达到 0.000496。选取几个有代表性的相位恢复数据进行观察,结果发现,当中心频率附近相位斜率的变化速度不大时,传统 SRSI 算法计算的相位比较接近相位真值,如图 8(a)、(b)所示。由图 8(c)~(f)可以看出,当中心频率附近的相位倾斜度较大时,传统 SRSI 算法的测量结果略微偏离真实脉冲相位。基于 Dense-1D-U-Net 的深度学习方法的预测结果相比实验 1 的误差稍有增大,但恢复的相位仍可以较好地贴合原始相位。在该实验中,本文引入了光谱幅值、延迟时间等变量,更加接近真实情况。传统 SRSI 算法的测量结果与实验 1 基本一致,比较稳定。基于 Dense-1D-U-Net 的 SRSI 算法的 MSE 值

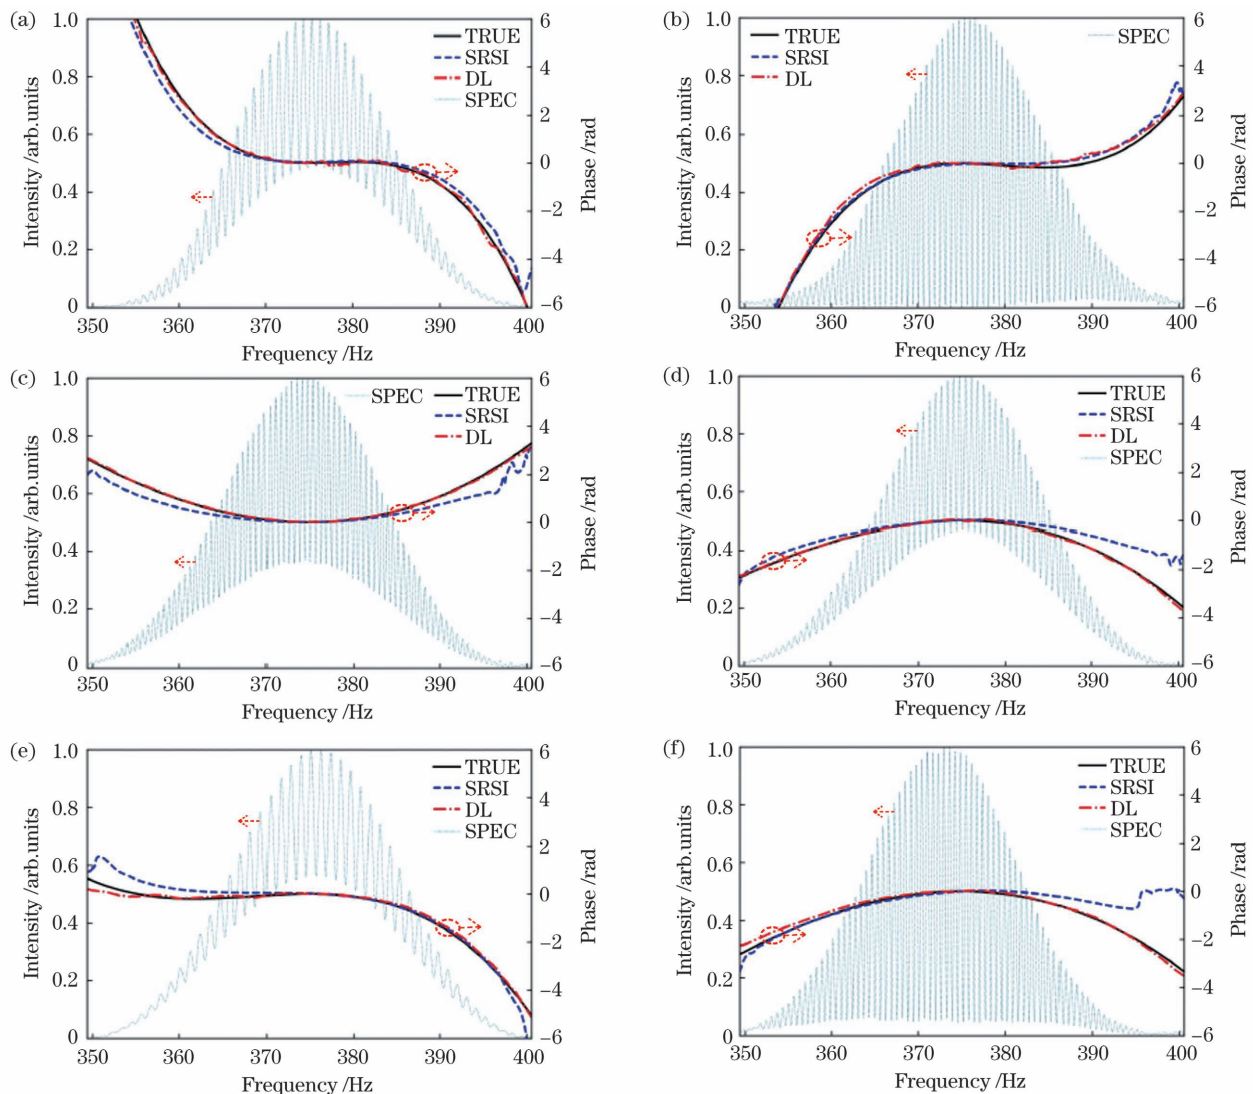


图 8 实验 2 计算结果的若干样图

Fig. 8 Calculation results samples of experiment 2

比传统 SRSI 算法的约小 2 个数量级,说明基于 Dense-1D-U-Net 的深度学习方法的测量精度更高。

在第三个基于 Dense-1D-U-Net 的训练学习中,本文在之前训练学习的基础上进一步加入了四阶和五阶高阶相位。加入四阶和五阶项之后,相位的复杂程度更接近真实情况。此时,传统 SRSI 算法的 MSE 值为 0.00984,而基于 Dense-1D-U-Net

的 SRSI 算法的 MSE 值虽然相对之前增大了一个数量级,但依然比传统 SRSI 算法的 MSE 小一个数量级以上,仅为 0.000862,如图 9 所示。这表明,对于此数据集,使用基于 Dense-1D-U-Net 的深度学习计算方法计算脉冲光谱相位形状的精度比传统 SRSI 算法更高,MSE 比传统 SRSI 算法要低一到两个数量级。

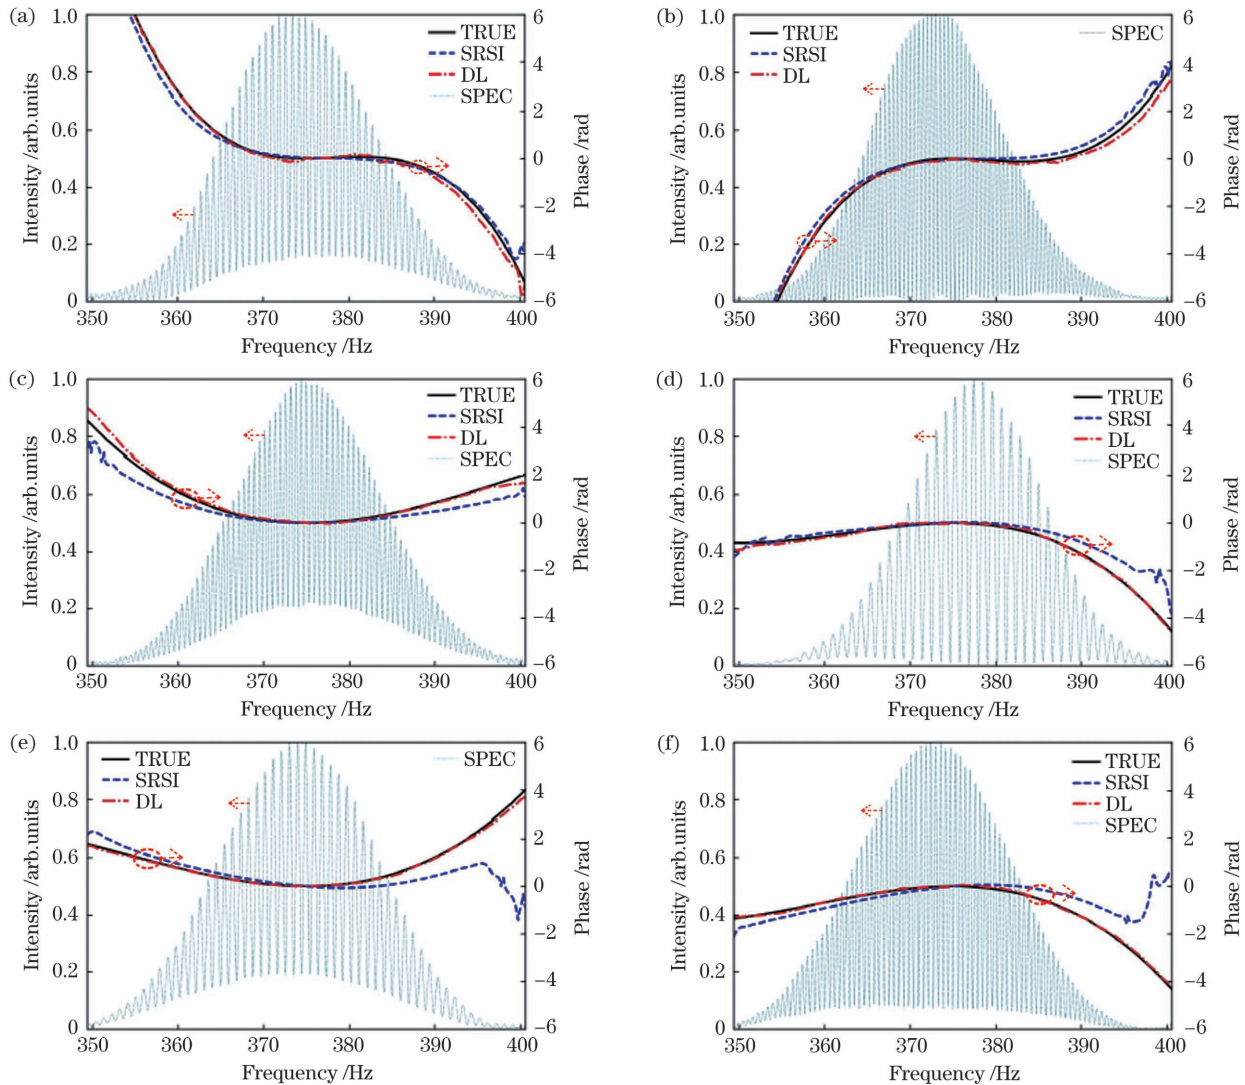


图9 实验3计算结果的若干样图

Fig. 9 Calculation results samples of experiment 3

与传统的 SRSI 算法相比,深度学习中神经网络的输入是干涉条纹的频域光谱,输出是频域相位。这种端到端的测量不包含近似计算等会直接导致信息损失的运算。从光谱仪得到的光谱干涉条纹波长域光谱中端到端地恢复出对应的波长域相位充分利用了输入信息。相比传统算法用参数数量不多的数学解析式进行计算,节点数为 2000 多万的神经网络具有更强的提取高阶特征的能力。同时通过验证集

的验证精度也可以看到,传统 SRSI 算法的表现也非常稳定可靠。

本文通过研究不同的网络结构来了解 Dense-1D-U-Net 的性能。将作为对照组的 不含稠密连接块的一维 U-Net、不含跳跃连接但含有稠密连接块的一维编码-解码神经网络和不含稠密连接块也不含跳跃连接的编码-解码神经网络被分别命名为 1D-U-Net、1D-Dense-Net 和 1D-CNN-Net。在上述

第三组数据集上训练四种网络,可以发现,不添加稠密连接块的对照组 1D-U-Net 的拟合能力与其他神经网络相比较差。该神经网络规模较小,且参数最少,因此 loss 曲线下落快,训练用时最少。不添加跳跃连接的对照组 1D-Dense-Net 的拟合能力与 Dense-1D-U-Net 接近,loss 下降速度甚至比 Dense-1D-U-Net 还快。这是因为跳跃连接将靠近输入的特征图和靠近输出的特征图连接起来,在二维图像分割、散射成像等空间域或其他神经网络输入输出信息对应点相关度较高的任务中,可以高效地利用输入信息的表层特征。在本文中,输入输出信息均为频域信息,并且在频域的对应点上,光谱干涉条纹形状和脉冲相位形状的相关性较小,输入的干涉条纹的跳动非常大,输出的相位曲线平稳。在训练不充分时,跳跃连接权重较大,会直接把表层信息传递到输出处,神经网络预测的相位曲线会出现波浪状。在本文中,Dense-1D-U-Net 的跳跃连接训练到最后的权重非常小。加入跳跃连接可使 Dense-1D-U-Net 具有更强的鲁棒性,能适应更多不同类型的任务。不含有稠密连接块也不含跳跃连接的 1D-CNN-Net 体积较小,loss 下降速度非常快,但是拟合能力相对较差。

如图 10 所示,为验证神经网络对真实相位的测量能力,使用工作中的全反射式 SRSI 装置^[9]采集了真实的激光脉冲干涉条纹数据。通过对比可以发现本组实验数据中的干涉条纹和相位与所展示的训练集相比差异明显较大,但采用本文训练的 Dense-1D-U-Net 对实测光谱数据计算后得到的相位与传统 SRSI 的测量结果仍具有较高的重合度。这说明 Dense-1D-U-Net 能在本课题组模拟的训练集中学习到干涉条纹和相位曲线的映射关系,具有在实际测量中恢复实际光谱相位的能力。

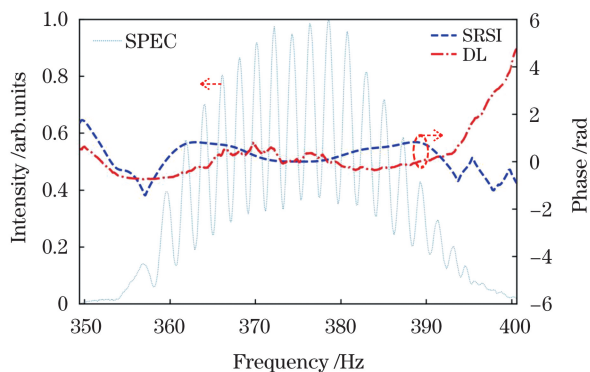


图 10 实测数据与计算结果的比较

Fig. 10 Calculation results of actual data

5 结 论

本文展示了深度学习方法在 SRSI 方法中的应用。对比传统的 SRSI 算法,Dense-1D-U-Net 神经网络显著降低了 SRSI 脉冲的测量误差。在高度接近真实情况、含有三阶光谱相位的模拟数据集中,Dense-1D-U-Net 的 MSE 值为 0.0000848,比传统 SRSI 算法的 0.00825 低了近两个数量级;在含有四阶和五阶光谱相位的数据集中,Dense-1D-U-Net 的 MSE 值为 0.000862,比传统 SRSI 算法的 MSE 值 0.00984 提升了一个数量级。通过对比、分析不同结构的神经网络,对跳跃连接、稠密连接块等在神经网络中的作用进行了分析和比较。最后,用实验室实测的干涉条纹对比了传统 SRSI 算法和深度学习方法的恢复结果,证明采用本文模拟的数据集进行训练之后,Dense-1D-U-Net 能够学习到本研究中待测脉冲的光谱干涉条纹与光谱相位的映射规律,具有测量实验数据的能力。在实际应用中,为使测量方法更加可靠,需要使用更加接近实际情况的数据集进行训练、验证。

本文提出了一种一维卷积编码-解码神经网络:Dense-1D-U-Net。该网络基于编码-解码结构采用了自行设计的稠密连接块,并加入了跳跃连接。Dense-1D-U-Net 可以通过修改神经网络参数来改变权重的初始化方式,以适应不同的研究。基于深度学习的 SRSI 方法采用了 Dense-1D-U-Net。端到端地学习光谱干涉条纹与真实光谱相位的对应方式,充分利用输入信息,无中间计算,这是深度学习的优势。本文设计的稠密连接块大大提高了神经网络的拟合能力,而加入的跳跃连接可以很好地利用表层信息。经验证,经模拟数据训练的 Dense-1D-U-Net 具有计算实测数据的能力。在实际情况中,激光脉冲具有多样性,未来需要进一步更细致地考虑激光脉冲的各种情况,通过增强数据集来适应具体情况。Dense-1D-U-Net 的优势是鲁棒性强,不仅可以用不同的方式初始化参数,还可以用不同的数据集进行训练,以适应不同的研究。未来可以将该神经网络拓展到超快光谱等的相关研究上。

参 考 文 献

- [1] Oksenhendler T, Coudreau S, Forget N, et al. Self-referenced spectral interferometry [J]. Applied Physics B, 2009, 99(12): 7-12.

- [2] Kane D J, Trebino R. Single-shot measurement of the intensity and phase of an arbitrary ultrashort pulse by using frequency-resolved optical gating [J]. *Optics Letters*, 1993, 18(10): 823-825.
- [3] Iaconis C, Walmsley I A. Spectral phase interferometry for direct electric field reconstruction of ultrashort optical pulses [J]. *Optics Letters*, 1998, 23(10): 792-794.
- [4] Oksenhendler T. Self-referenced spectral interferometry theory [EB/OL]. (2012-04-22) [2021-02-09]. <https://arxiv.org/abs/1204.4949>.
- [5] Liu J, Okamura K, Kida Y, et al. Temporal contrast enhancement of femtosecond pulses by a self-diffraction process in a bulk Kerr medium [J]. *Optics Express*, 2010, 18(21): 22245-22254.
- [6] Liu J, Okamura K, Kida Y, et al. Femtosecond pulses cleaning by transient-grating process in Kerr-optical media [J]. *Chinese Optics Letters*, 2011, 9(5): 051903.
- [7] Shen X, Wang P, Liu J, et al. Self-referenced spectral interferometry for femtosecond pulse characterization [J]. *Applied Sciences*, 2017, 7(4): 407.
- [8] Zhu J X, Shen X, Lin L, et al. A compact and alignment-free tube-type device for femtosecond pulses measurement [J]. *The Review of Scientific Instruments*, 2018, 89(8): 083109.
- [9] Si Z, Shen X, Zhu J X, et al. All-reflective self-referenced spectral interferometry for single-shot measurement of few-cycle femtosecond pulses in a broadband spectral range [J]. *Chinese Optics Letters*, 2020, 18(2): 021202.
- [10] Shen X, Si Z, Zhu J X, et al. Broad spectral range few-cycle laser pulses characterization by using a FASI device [J]. *Optics & Laser Technology*, 2021, 137: 106810.
- [11] 黄刚, 刘先林. 基于深度学习的道路标线自动提取与分类方法 [J]. *中国激光*, 2019, 46(8): 0804002. Huang G, Liu X L. Automatic extraction and classification of road markings based on deep learning [J]. *Chinese Journal of Lasers*, 2019, 46(8): 0804002.
- [12] 伍俊龙, 郭正华, 陈先锋, 等. 基于深度学习的光场成像三维测量方法研究 [J]. *中国激光*, 2020, 47(12): 1204005. Wu J L, Guo Z H, Chen X F, et al. Three-dimensional measurement method of light field imaging based on deep learning [J]. *Chinese Journal of Lasers*, 2020, 47(12): 1204005.
- [13] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation [M] // Navab N, Hornegger J, Wells W M, et al. *Medical image computing and computer-assisted intervention-MICCAI 2015. Lecture notes in computer science*. Cham: Springer, 2015, 9351: 234-241.
- [14] Siam M, Gamal M, Abdel-Razek M, et al. RTSeg: real-time semantic segmentation comparative study [C] // 2018 25th IEEE International Conference on Image Processing (ICIP), October 7-10, 2018, Athens, Greece. New York: IEEE Press, 2018: 1603-1607.
- [15] Li Y Z, Xue Y J, Tian L. Deep speckle correlation: a deep learning approach toward scalable imaging through scattering media [J]. *Optica*, 2018, 5(10): 1181-1190.
- [16] 孟球, 胡海峰, 胡金洲, 等. 基于深度学习的多模光纤散射介质成像重建 [J]. *中国激光*, 2020, 47(12): 1206005. Meng L, Hu H F, Hu J Z, et al. Image reconstruction of multimode fiber scattering media based on deep learning [J]. *Chinese Journal of Lasers*, 2020, 47(12): 1206005.
- [17] Cho K, van Merriënboer B, Gulcehre C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation [C] // Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing, EMNLP 2014, October 25-29, 2014, Doha, Qatar. Stroudsburg: Association for Computational Linguistics, 2014: 1724-1734.
- [18] Stoller D, Ewert S, Dixon S. Wave-U-net: a multi-scale neural network for end-to-end audio source separation [EB/OL]. (2018-06-08) [2021-08-01]. <https://arxiv.org/abs/1806.03185>.
- [19] Guimarães H R, Nagano H, Silva D W. Monaural speech enhancement through deep wave-U-net [J]. *Expert Systems With Applications*, 2020, 158: 113582.
- [20] 张素侠, 李方家, 刘军. 自参考光谱干涉法测量飞秒脉冲的研究进展 [J]. *激光与光电子学进展*, 2014, 51(1): 010001. Zhang S X, Li F J, Liu J. Research progress of self-referenced spectral interferometry on the characterization of femtosecond pulses [J]. *Laser & Optoelectronics Progress*, 2014, 51(1): 010001.
- [21] Lepetit L, Chériaux G, Joffre M. Linear techniques of phase measurement by femtosecond spectral interferometry for applications in spectroscopy [J]. *Journal of the Optical Society of America B*, 2004, 12(12): 2467-2474.
- [22] Huang G, Liu Z, van der Maaten L, et al. Densely connected convolutional networks [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition

(CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 2261-2269.

[23] Trebino R, Zeek E. Ultrashort laser pulses [M] //

Trebino R. Frequency-resolved optical gating: the measurement of ultrashort laser pulses. Boston: Springer, 2000: 11-35.

Dense-1D-U-Net: Encoder-Decoder Networks for Self-Referenced Spectral Interferometry

Kuang Qi^{1,2}, Shen Xiong², Xu Yilin², Bai Lihua¹, Liu Jun^{2,3,*}

¹Department of Physics, Shanghai University, Shanghai 200444, China;

²State Key Laboratory of High Field Laser Physics, Shanghai Institute of Optics and Fine Mechanics, Chinese Academy of Sciences, Shanghai 201800, China;

³Center of Materials Science and Optoelectronics Engineering, University of Chinese Academy of Sciences, Beijing 100049, China

Abstract

Objective Ultrashort laser pulses have been widely used as essential tools in many scientific research fields, such as ultrahigh intense laser physics, ultrafast spectroscopy, and nonlinear optical microscopy. The key aspect of measuring the temporal profile of an ultrafast laser pulse is the accurate characterization of its spectral phase. Self-referenced spectral interferometry (SRSI) is a relatively new characterization technique for measuring the intensity and phase of ultrashort laser pulses with attractive capacity introduced in 2010. SRSI is an analytical, sensitive, accurate, and fast method. The development of SRSI in recent years is to simplify the setup, optimize the reference pulse, or adapt to different situations. However, SRSI still uses the initially proposed algorithm, Fourier transform spectral interferometry (FTSI), based on spectral interferometry and few iterations. Thus, the approximate calculation is used in this algorithm to simplify the calculation process, leading to the loss of some details, and the calculation accuracy is not sufficiently high. Therefore, research on new algorithms that can improve the measurement performance and accuracy of SRSI is of great significance to promote the development of SRSI technology and ultrafast laser technology. With the rapid improvement of computer computing power, deep learning has recently achieved great success. This study proposes a deep learning method using a neural network called Dense-1D-U-Net used for one-dimensional signal processing to measure spectral phases of femtosecond pulses with the SRSI method. Furthermore, on our simulated datasets, the measurement of spectral phase accuracy using Dense-1D-U-Net is at least about one order of magnitude improved than that of the traditional SRSI algorithm. Additionally, measured data are used to verify that Dense-1D-U-Net, trained by simulated data, can calculate experimental data.

Methods A one-dimensional U-Net neural network structure combined with self-designed dense blocks, called Dense-1D-U-Net (Fig. 2), was designed for one-dimensional data, and its weights were initialized according to the features of SRSI. The classical encoder-decoder network structure with added dense blocks and skip connections was used in the measurement to improve the network's performance. Based on the principle of SRSI (Fig. 3), three different datasets with many analog data close to real spectral phases of ultrafast pulses were simulated (Fig. 6). The first dataset used a randomly generated phase curve of the highest order of third and a fixed perfect Gaussian curve to simulate the spectrum and a fixed delay time to generate the spectrum of interference fringes. In the second dataset, we simulated the spectra of interference fringes using curves of the highest order of third and spectra simulated by random Gaussian curves with a delay time of random values from 500 to 1500 fs. Finally, we simulated the spectra of interference fringes in the third dataset. Each set of data contains a phase curve, a spectral amplitude, and a delay time. The phase curve consists of two lines added together, a main curve simulated by three random Taylor coefficients and a carrier simulated by five Taylor coefficients multiplied by a random coefficient between 0.3 and 0.5. The spectral amplitude was simulated by a random Gaussian curve. The delay time were randomly valued between 500 and 1500 fs (Fig. 6). Dense-1D-U-Net with specially initialized weight was trained on those datasets. Then, we compared the measurement results using the traditional SRSI algorithm FTSI with trained Dense-1D-U-Net on those datasets. We also compared the result and train process of Dense-1D-U-Net with other neural networks

without dense blocks or skip connections. Consequently, we used the experimental data to verify whether Dense-1D-U-Net trained on simulated data can calculate experimental data.

Results and Discussions The measurement results using the traditional SRSI algorithm FTSI and trained Dense-1D-U-Net of the three experiments are shown in Figs. 7, 8, and 9. The accuracy of the spectral phase measurement using Dense-1D-U-Net is at least about one order of magnitude improved more than that of the traditional SRSI algorithm. Compared with other neural networks without dense blocks or skip connections, the measurement results with dense structures or skip connections show obvious superiority. Finally, the measured experimental data confirm that Dense-1D-U-Net trained on simulated data can calculate experimental data (Fig. 10).

Conclusions This study proposed a one-dimensional convolutional encoder-decoder neural network called Dense-1D-U-Net based on the encoder-decoder structure with our design of dense blocks and added skip connections. Dense-1D-U-Net can adapt to various studies by modifying neural network parameters and changing weights initialization methods. Here, it is used in the SRSI method based on deep learning. End-to-end learning of the relationships between spectral interference fringes and real spectral phases utilizes input information without intermediate calculation, which is the advantage of deep learning. The fitting ability of the neural network is significantly improved using our design of dense blocks. The added skip connections can make good use of the primary information. The accuracy of spectral phase measurement using Dense-1D-U-Net is at least about one order of magnitude improved more than that of the traditional SRSI algorithm. It is verified that Dense-1D-U-Net, trained by simulated data, can calculate measured data (Fig. 10). However, laser pulses are more diverse in practice. In future studies, we will consider various conditions of laser pulses to enhance the dataset to adapt to the specific situation. The advantage of Dense-1D-U-Net is that it is robust and can adapt to different studies by training it on different datasets and initializing its weights in different ways. This neural network can be extended to ultrafast spectroscopy and related studies based on one-dimensional information.

Key words measurement; deep learning; encoder-decoder; self-referenced spectral interferometry; neural network; dense connection