arXiv:2304.02249v1 [physics.optics] 5 Apr 2023

面向时间拉伸仪器的低延迟计算

Tingyi Zhou[1],Bahram Jalali[1, *], **1 电气与计算机工程系**

加利福尼亚大学洛杉矶分校

***jalali@ucla.edu**

摘要

时间拉伸仪器在发现光学怪波等单次采集超快现象方面取得了极大成功，并推动了创纪录速度的显微成像、光谱学、激光雷达等技术的发展。这些仪器将超快事件编码到飞秒脉冲的光谱中，然后利用群速度色散扩展数据的时间尺度。它们能够产生高达每秒太比特的数据，是深度学习网络的理想合作伙伴；深度学习网络由于自身的复杂性，需要大型数据集进行训练。然而，神经网络处于毫秒级的推理时间尺度，比时间拉伸仪器的数据采集速率长数个数量级。这凸显出探索相关方法的必要性，即在数据仍处于光学域时，完成部分较低层级的计算任务。非线性薛定谔核计算解决了这一困境。它利用光学非线性将数据映射到一个新的域中，在不增加数据维度的情况下提高分类准确率。该技术的一个局限是光学传递函数固定不变，从而限制了训练能力和泛化能力。在此，我们展示了通过利用飞秒激光脉冲的数字相位编码，可以有效调谐和训练光学核，从而降低数据分类中的错误率。

引言

最先进的深度神经网络拥有数十亿个参数，已应用于计算机视觉、语音处理、工程设计和科学发现等多个领域。网络复杂度不断提升，得益于半导体技术的进步，而摩尔定律描述了这一进步。摩尔定律预计将走到尽头，这令人担忧神经网络未来的发展 [9]。此外，神经网络必须经过训练，而训练需要海量标注数据，其数量会随着网络复杂度的增加而增加。许多领域缺乏经过整理的数据，这使得深度神经网络无法应用。当前神经网络的推理速度通常处于毫秒级。这与超快光学传感器的工作速度相悖：这类传感器能够以飞秒为时间间隔采集数据，并以皮秒为帧间隔成像。

这需要重新审视能够在超快时间尺度下处理有限数据量的方法。模拟计算 [14] 是一种很有前景的方法，它能在复杂的非线性系统中执行专用计算，从而减轻数字计算机的负担。光子硬件加速器便是其中一种方法，专注于在光学系统中实现复杂的数学模型。例如，可以用一组空间光调制器 [11] 来模拟卷积神经网络（CNN）。前馈神经网络可以通过互连光子电路 [13] 在光子芯片上实现。光子储备池计算机可以通过光放大器和反馈回路 [7] 组装而成。然而，所有

已展示的作品要么结构复杂，要么需要大幅增加数据维度，这限制了它们在实际应用中的推广。

近期，研究人员提出了一种可在超快时间尺度上进行数据分类的技术，称为非线性施罗丁格核¨ [16]。这种技术与数值核计算类似，无需显式增加数据维度，即可对数据进行非线性变换。它利用光学非线性将数据映射到一个新域，从而提高分类准确率。具体而言，该技术将数据调制到飞秒脉冲的光谱上，并通过非线性光学介质进行复杂的非线性变换。因此，它最初是为时间拉伸仪器等应用而开发的；在这类仪器的测量过程中，数据会被编码到超短激光脉冲的光谱上。此前的研究表明，与传统数值核相比，该技术在小型数据集上能取得相近的结果，同时延迟低几个数量级。此外，它不会增加数据维度，因此不会牺牲计算资源。该技术的局限之一是光学传递函数固定，无法进行训练，也缺乏泛化能力，这意味着其性能高度依赖于数据集。

为解决这一问题，我们提出了一种方法，用于调节和优化内核的非线性光学传递函数。虽然无法调节非线性光学系统的参数，但可以通过改变输入数据 [4] 的相位，有效地设计非线性过程。这一方法基于这样一个认识：大多数非线性相互作用，例如自相位调制、四波混频等，都是依赖于输入相位的相干过程。因此，调节输入数据的谱相位必然会改变光谱分量之间的非线性相互作用。由于数据被编码到光谱上，这一过程会改变数据维度之间的非线性相互作用。

本文首先研究光学核内部的关键效应，然后提出一种利用复数数据编码的调谐方案。为评估调谐效果，系统中加入了数字反馈回路，以获得能够实现最佳分类准确率的最优相位编码。本文在三个数据集上展示了相位编码与优化的效果：时间拉伸细胞图像 [3], 指骨轮廓 [2], 和脑电图（EEG） [6]。

实验系统

图 1 展示了系统框图，其中包含对光学核的闭环优化。该系统由一个高度可调谐的非线性薛定谔核和一个数字反馈回路组成。在可调谐核中，输入 $data(n)$ 被映射到光谱域（$data(\omega)$），并通过振幅调制加载到超连续谱飞秒激光脉冲上。随后，数据经过一个非线性光学元件，在其中进行非线性变换。变换后的数据最终由光谱仪采集，并发送至后端数字分类器，该分类器采用轻量级机器学习模型。为避免增加数据维度，对核的输出光谱进行采样，使其维度与输入数据相匹配。通过在光谱调制过程中将谱相位 $\varphi(\omega)$ 调制到激光脉冲上来实现调谐，这相当于对输入数据的相位进行编码。这种“相位编码”会改变非线性元件中的非线性相互作用，从而对光学核进行设计。在数字反馈回路中，算法将预测结果与真实标签进行比较，并计算整个数据集的平均分类误差。随后，优化器生成新的相位编码，以尽可能降低该误差。系统通过迭代运行获得最优相位编码，从而训练光学核，使其达到最佳性能。实验系统的详细信息将在后文中介绍。

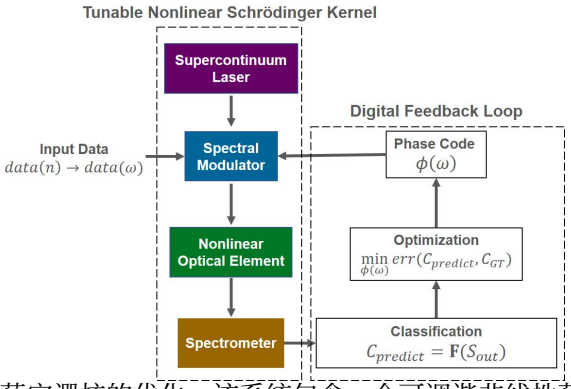


图 1. 可调谐非线性薛定谔核的优化。该系统包含一个可调谐非线性薛定谔核和一个数字反馈回路。在可调谐非线性薛定谔核中，经过相位编码的输入 $data(n)$通过光谱调制映射到超连续谱激光器的光谱上。调制后的激光在非线性光学元件中传播，其非线性过程由相位编码 $\varphi(\omega)$ 进行调控。随后，使用光谱仪采集非线性光学元件的输出光谱 S_{out}，并将其发送至分类器 F。通过比较预测类别 $C_{predict}$ 与真实标签 C_{GT}，计算分类误差。该误差作为优化算法的输入，用于更新相位编码，以实现更低的分类误差。详情请参见材料与方法。

见“材料与方法”部分。

结果

本文的主要主题是非线性光学核的优化与训练。我们首先阐述非线性在这一方法中的关键重要性。

光学非线性的关键作用

图 2 通过模拟展示了飞秒脉冲在非线性光学元件中的演变过程，该脉冲经过数据的光谱调制。输出光谱使用简单的机器学习算法进行分类。图 2 还展示了使用线性支持向量机（SVM）分类器作为数字后端时产生的错误。这里的非线性核是固定的，即未经调优。如“方法”一节所述，数据是流经微流控通道的生物细胞的一维线扫描图像。这些图像由时间拉伸显微镜 [3] [10] 捕获。该数据集包含三类图像：（1）没有细胞，（2）正常细胞，以及（3）癌细胞。分类任务是区分这三种不同类型。

在图 2a 中，通过将非线性系数设为零来模拟线性核。正如预期，光谱保持不变。如图 2c 所示，与将数据直接输入后端数字分类器得到的 14.7% 基线误差相比，分类误差几乎没有变化，为 14.9%。图 2b 显示了同一经过光谱调制的脉冲在非线性元件中的传播情况。为避免数据维度增加，我们在光谱收窄区间内运行。当经历自相位调制的脉冲具有负啁啾时，就会出现这种情况 [1]。如方法部分所述，对输出光谱进行采样，使其维度与输入数据（128）相同。非线性变换

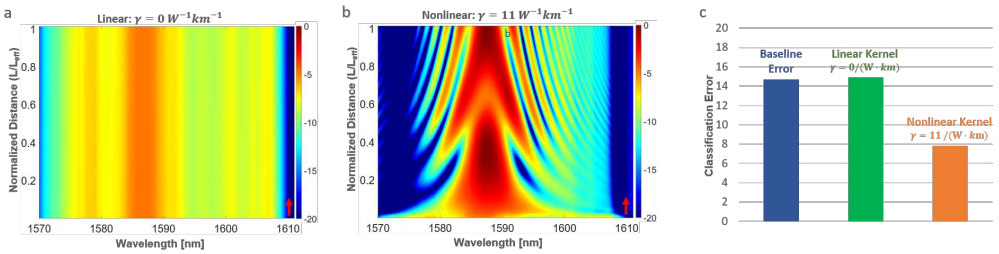


图 2. (a) 非线性系数为 $\gamma = 0/(W \cdot km)$ 时，线性光学核中光谱的演变；(b) $\gamma = 11/(W \cdot km)$ 时，非线性光学核中光谱的演变。(c) 比较三种情况下分类误差的柱状图：不使用核计算出的基线误差（蓝色，14.7%）、线性光学核（绿色，14.9%）和非线性光学核（橙色，7.8%）。基线误差通过将输入数据直接输入数字后端计算得出；此处的数字后端是线性支持向量机（SVM）分类器。对于 (a) 和 (b)，横轴为波长，纵轴为传播距离（以光学元件的有效长度为基准归一化）。颜色表示对数尺度下的光强，侧边的色条显示其对应关系。红色箭头指示传播方向。

将分类误差降至 7.8%，证实光学核能够在不牺牲（即增加）数据维度的情况下提升机器学习效果。

比较线性核和非线性核的效果可以发现，若没有光学非线性，就无法提高分类准确率。然而，作为一种恰当的机器学习技术，非线性必须可调，才能对其进行优化。先前的研究已证明，可以通过对输入光进行光谱相位调制来成功控制光学非线性 [4]。在此，我们将同样的技术应用于非线性光学核的调谐和优化，并以分类误差作为优化依据。

机器学习的光学非线性训练

在本节中，我们将展示如何通过对输入数据进行相位编码来调节非线性光学核。正如引言中所述，这种方法背后的直观原理如下：自相位调制、四波混频（FWM）等非线性光学相互作用本质上具有相干性，即它们对输入脉冲的相位十分敏感。因此，调节输入相位会影响光学非线性所产生的输出。

实验实现如图 1 所示。数字反馈回路中的光谱相位调制控制非线性光学相互作用，从而调谐光学核。遗传算法求得使数字分类器误差最小化的最优相位编码。三个数据集的结果均通过实验展示。材料与方法中所述的数据集包括细胞图像（图 3a） [3] [10]，指骨轮廓（图 3b） [2]，和脑电图（图 3c） [6]。

图 3 显示，在全部三个数据集中，训练后的核（橙色）和固定（未经训练的）核（蓝色）与未使用光学核的基线情况（灰色）相比，均能降低错误率。不过，训练后的光学核比固定核产生的误差更低。基线误差是将输入数据直接馈入数字后端得到的。结果证明，相位编码能够有效调节非线性薛定谔核的性能，并且与数字反馈回路结合后，可使光学核具备可训练性。

在这些实验中，相位编码是使用一个包含两个.....的多项式生成的。

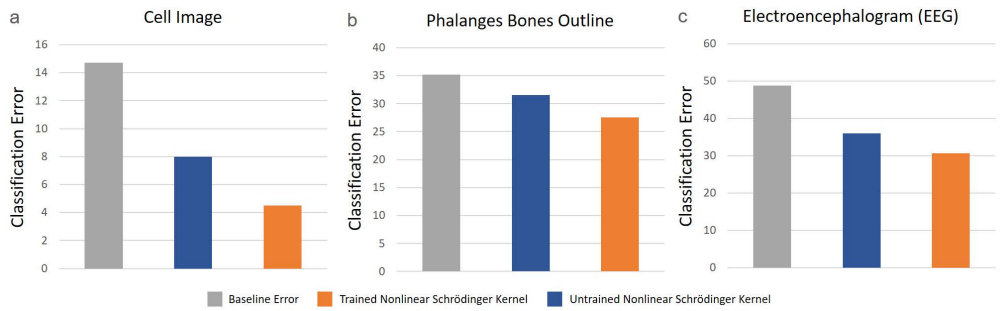


图 3. 在三个数据集上对非线性薛定谔核进行优化：(a) 时间拉伸生物细胞图像 (b) 指骨轮廓 (c) 脑电图（EEG）。在每个柱状图中，对比了三种情况下的分类误差：基线误差（灰色）、未经训练的非线性薛定谔核（蓝色）和经过训练的非线性薛定谔核（橙色）。基线误差通过将输入数据直接馈送至数字后端（即线性支持向量机（SVM）分类器）计算得出。所有结果均通过三折交叉验证计算。

二阶系数和三阶系数的可调参数。该方案可轻松扩展至更多参数，以提供额外的自由度。实验详情也见材料与方法。

局限性

这项技术的一些局限性及未来可能的研究方向如下。首先，输入数据允许的最大维度取决于光谱调制。在我们的实验中，我们使用了一台商用波形整形器（详见“方法”部分），其具有 500 个像素。因此，输入数据的最大维度受限于 500。其次，尽管可以训练该核，但分类误差方面的性能仍取决于数据，如 3 中所示。所有机器学习技术都存在这种情况，因为它们本质上是统计性的（而非确定性的）。未来研究的一个可能方向是，将分类性能与输入数据的属性相关联，以确定哪类数据最适合采用光学核计算。

结论

近期提出的光学核计算利用光学非线性对数据进行变换，使得能够借助计算开销较低的线性数字分类器实现非线性分类。所谓的非线性薛定谔核计算（Nonlinear Schr¨odinger Kernel computing）非常适合对调制到飞秒激光器光谱上的数据进行低延迟分类。时间拉伸成像和光谱仪器就是这类应用的典型例子 [12] [17]。在该技术的先前实现中，核的特性完全由光学介质的非线性系数决定。因此，无法按照机器学习任务的需求对核进行训练或优化。本章通过在数字反馈回路中引入输入脉冲的光谱相位调制，提出了一种解决这一问题的方法。相位调制会影响数据经非线性光学相互作用变换的方式，并使光学核能够接受训练。研究表明，通过训练，可以降低三个不同数据集上的分类误差。

材料与方法

在本节中，我们将详细介绍：(1) 核优化的实验实现；(2) 展示光学非线性关键作用的仿真研究；(3) 光学核的数学表述；以及 (4) 数据集和机器学习模型。

实验

闭环光学核计算系统的物理实现如图 1 所示。超连续谱激光器由一台锁模掺铒光纤激光器（ELMO）和其后的掺铒光纤放大器（ELMA）组成，两者均来自 Menlo Systems。它产生以 $1560nm$ 为中心、具有 $90nm$ 带宽的 $<90fs$ 激光脉冲。经过放大器后，脉冲峰值功率约为 30 W。数据通过 Finisar（现为 II-VI / Coherent）的 Waveshaper 1000 S/L 型号对光谱进行调制。该设备在 L 波段（$1567nm \quad 1609nm$）工作，分辨率为 500 像素。Waveshaper 同时执行振幅和相位调制。振幅即输入数据（缩放至 0 到 1 之间），相位则为用于调节非线性效应的（相位）编码。非线性光学元件是一段来自康宁的 $500m$ 高非线性光纤（HNLF）。其非线性系数为 $\gamma = 11/（W \cdot km）$，低色散为 $D = 1.43ps/（nm \cdot km）$，在 $1588nm$ 处的色散斜率为 $S = 0.04ps/（nm^2 \cdot km）$。使用带有 $0.1nm$ 分辨率的安藤 AQ6317B 光谱分析仪测量输出光谱。光谱分析仪的采样范围根据各数据集输出的实际带宽分别设置。对于细胞图像和指骨轮廓数据集，采样范围为 $1545nm \quad 1635nm$；对于脑电图数据集，则为 $1550nm \quad 1630nm$。对测得的光谱进行重采样，使其维度与输入相同。随后进行最小-最大标准化，并送入线性支持向量机（支持向量机）分类器。

数字反馈回路在一台配备 16 GB 随机存取存储器的计算机上通过 MATLAB 实现。它以迭代方式运行，以优化非线性薛定谔核的性能。每次迭代中，分类错误率取整个数据集上的平均值，并通过三折交叉验证计算得出。该值被发送至优化器；此优化器是一种来自 MATLAB 全局优化工具箱的遗传算法 [8] 。为了降低分类错误，优化器会将当前迭代的结果与此前各次迭代的结果进行比较，并生成下一次迭代所用的相位编码。本文中，相位编码由一个系数可调的三阶多项式计算得出，

$$\varphi(\omega) = a\omega^2 + b\omega^3 \tag{1}$$

其中，a 和 b 是由优化器生成的可调系数。未考虑一阶系数，因为它只会造成恒定延迟，不会影响非线性光学过程。优化结果如图 3 所示。细胞图像数据集的最优系数（图 3a）列于表 1。优化后的分类错误，$Err_{trained}$ 也一并列出，并与未优化的分类错误 $Err_{untrained}$ 和基线误差 $Err_{baseline}$进行比较。

深入理解光学非线性的关键作用

为了评估光学非线性对非线性薛定谔核运行的作用，我们在 MATLAB 中建立了计算机模型。超连续谱激光源被建模为一个变换极限脉冲，其超高斯光谱以$1588nm$为中心。该脉冲具有 $40nm$ 带宽，与光谱调制器（波形整形器）的通带一致。光谱调制通过将输入

	细胞图像	指骨	EEG
$a(\times 10^{-24})$	1.353	0.854	1.022
$b(\times 10^{-37})$	-3.628	0.925	-4.742
$Err_{trained}$	4.5%	27.5%	30.7%
$Err_{untrained}$	8.0%	31.5%	36.04%
$Err_{baseline}$	15.0%	35.2%	30.7%

表 1. 最优相位编码

数据（时间拉伸细胞图像数据，缩放至 0 到 1）与激光光谱相乘来建模。在这些仿真中，相位编码设为 0，以模拟未优化（开环）系统。随后，将调制激光脉冲送入非线性光学元件，本例中为高非线性光纤。光纤中的复杂传播通过求解时域非线性薛定谔方程（NLSE）来建模，求解采用在 MATLAB 中实现的分步傅里叶法（SSFM）。该算法将光纤划分为多个短段（步），以分离不同效应，并通过迭代计算获得近似解 [1]。每一步都会记录光脉冲的光谱，以跟踪输入信号的演变，如图 2 所示。使用光谱仪测量高非线性光纤的输出，并通过快速傅里叶变换（FFT）和取绝对值平方进行建模。最后，对采集到的光谱进行重采样，使其维度与输入数据相同，然后进行均值-标准差标准化，并输入线性支持向量机分类器。

对于图 2 所示的仿真，光纤长度设为 $500m$。光学损耗为 $0.02dB/km$，在 $1588nm$ 处，色散系数 (D) 为 $1.43ps/(nm \cdot km)$，色散斜率 (S) 为 $0.04ps/(nm^2 \cdot km)$，光功率 P为 $20W$。对于线性核，非线性系数 (γ) 为 $0rad/(W \cdot km)$。而对于非线性核，则为 $\gamma = 11rad/(W \cdot km)$。光谱的采样范围为 $1570nm$ 至$1610nm$ ，共设 128 个采样点，以匹配输入数据的维度。

MATLAB 模型运行于一台配备 64 GB 内存和 24 GB NVIDIA RTX TITAN GPU 的服务器上。SSFM 算法由开源函数 ssprop 修改而来，并通过使用 CUDA 在 GPU 上实现加速。

数学模型

本节将介绍非线性薛定谔核计算的数学描述。如 1 所示，首先将数据的每个条目映射到一个频率，从而将数据映射到光谱中。在当前实验中，数据存储在文件中，并使用波形整形器调制到飞秒脉冲光谱上。波形整形器执行以下映射 M:

$$M : data(n) \rightarrow data(\omega) \tag{2}$$

$data(n)$ 是输入，其中 n 是其第 n 个条目， ω 是相应的光频率。随后将此滤波器应用于一个超连续谱激光脉冲:

$$E_{in}(\omega) = \sqrt{data(\omega)} \cdot E_{laser} e^{\varphi(\omega)} \tag{3}$$

这里， E_{laser} 是超连续谱激光源， $\varphi(\omega)$ 是相位编码，训练时也由波形整形器施加。 E_{in} 是调制后的脉冲，随后将进入非线性阶段。数据被调制到功率光谱上，这相当于将其平方根与电场相乘。调制后的激光被送入非线性光学元件，其复杂的非线性变换由非线性薛定谔方程支配:

$$\frac{\partial E(t)}{\partial z} = (\hat{D} + \hat{N})E(t) \tag{4}$$

其中， E 是光脉冲的电场，z 是传播距离， D 是色散算子， N 是非线性算子，可根据非线性光学元件 [11] 的参数计算得出。通过使用以下初始条件求解非线性薛定谔方程：

$$E_inT = \frac{1}{2\pi}\int_{-\infty}^{+\infty} e^{i\omega t}E_{in}(\omega)d\omega \tag{5}$$

由此得到输出 $E_{out}(t)$。随后获取经过非线性变换的输入数据以及激光光谱 $S_{out}(\omega)$。根据傅里叶变换，光谱为：

$$E_{out}(\omega) = \int_{-\infty}^{+\infty} e^{-i\omega t}E_out(t)dt \tag{6}$$

$$S_{out}(\omega) = |E_{out}(\omega)|^2 \tag{7}$$

然后对测量得到的输出光谱进行分类：

$$C_{predict} = F(S_{out}) \tag{8}$$

这里， C_{redict} 是预测类别， F 是一个线性支持向量机分类器。我们选择线性支持向量机是因为它应用广泛且简单易用。也可以使用其他分类器。

在反馈回路中，通过比较预测结果和真实标签，计算分类误差 $err(C_{predict}, C_{GT})$。由于 C_{predic} 是相位编码 $\varphi(\omega)$ 的函数，因此我们可以通过最小化误差获得最优的 $\varphi(\omega)$：

$$\min_{\varphi(\omega)} err(C_{predict}, C_{GT}) \tag{9}$$

本文中提到，正如实验部分所述，优化器采用的是遗传算法。

数据集与机器学习模型

训练后的非线性薛定谔核的性能通过三个数据集进行评估：时间拉伸细胞图像 [3] [10]，指骨轮廓 [2]，和脑电图 [6]。详情如下。

时间拉伸细胞图像数据集是通过时间拉伸显微流式细胞术 [3] [12]采集的细胞图像。在此装置中，一束飞秒激光脉冲经一对衍射光栅进行空间色散，形成准直的一维彩虹光。彩虹光照射微流控通道，样本血细胞从中流过。由此，受照细胞的空间特征被调制到飞秒激光脉冲的光谱上。随后，使用时间拉伸光谱仪实时读取这些特征，低损耗色散光纤将光谱映射到时间域。模拟光谱的时间波形由实时模数转换器进行数字化。每帧都是细胞随微流控液流移动时的一次线扫描。该装置的详情见我们早期发表的文献 [12]。该数据集包含三类线扫描：背景、结肠癌血细胞（SW-480上皮细胞）和白细胞（OT-II杂交瘤497 T细胞）。每类包含200个观测样本（波形），每个波形有128个维度（空间特征）。详情也可见

指骨轮廓是一个来自UCR时间序列分类档案 [2]的开源数据集。它旨在研究指骨轮廓自动提取算法的正确性。该算法应用于X射线图像，以提取中指三块骨骼（指骨）的轮廓。随后，对提取结果进行评估。

由三位人工评估员进行评估。本文使用了 400 个观测样本，均匀分布在两类中：正确轮廓和错误轮廓。数据集的详细信息见 [5]。

该脑电图数据集是来自 UCI 机器学习资料库 [6] 的开源数据集。它源自一项测量脑电活动的测试。研究人员使用 Emotiv EEG Neuroheadset 收集数据，以研究脑电信号与人类眼动之间的对应关系。本文从该数据集中抽取了 400 个观测样本，涵盖两种眼动状态（每种 200 个）：睁眼和闭眼。每个观测样本包含 14 个维度。

本研究中的后端数字分类器采用线性支持向量机模型 [15]。分类误差通过三折交叉验证计算。

致谢

本项目由 DARPA-MTO PEACH 项目资助，合同编号为 HR00111990050。BJ 提出了构想和技术方案。TZ 开展了实验和数据分析。BJ 和 TZ 撰写了论文。

参考文献

1. G. Agrawal。《非线性光纤光学》。光学与光子学。爱思唯尔科学出版社，2012年。2. A. Bagnall、J. Lines、A. Bostrom、J. Large 和 E. Keogh。《大型时间序列分类评测》：近期算法进展的综述与实验评估。《数据挖掘与知识发现》，31:606–660，2017年。3. C. L. Chen、A. Mahjoubfar、L.-C. Tai、I. K. Blaby、A. Huang、K. R. Niazi 和 B. Jalali。《无标记细胞分类中的深度学习》。《科学报告》，6(1):1–16，2016年。4. J. Chou、O. Boyraz 和 B. Jalali。《自适应光学后失真线性化》。《光学快报》，13(15):5711–5718，2005年。5. L. M. Davis。《骨骼老化的预测建模》。未发表，2013年7月。6. D. Dua 和 C. Graff。UCI 机器学习资料库，2017年。7. F. Duport、B. Schneider、A. Smerieri、M. Haelterman 和 S. Massar。《全光学储备池计算》。《光学快报》，20(20):22783–22795，2012年。8. J. H. Holland。《自然与人工系统中的适应》。密歇根大学出版社，安娜堡，密歇根州，1975年。第二版，1992年。9. B. Jalali、Y. Zhou、A. Kadambi 和 V. Roychowdhury。《物理学与人工智能共生》。《机器学习：科学与技术》，3(4):041001，2022年。10. Y. Li、A. Mahjoubfar、C. L. Chen、K. R. Niazi、L. Pei 和 B. Jalali。《深度细胞术》：细胞分选和流式细胞术中的实时推理深度学习。《科学报告》，9(1):1–12，2019年。11. X. Lin、Y. Rivenson、N. T. Yardimci、M. Veli、Y. Luo、M. Jarrahi 和 A. Ozcan。《利用衍射深度神经网络实现全光学机器学习》。《科学》，361(6406):1004–1008，2018年。

12. A. Mahjoubfar、D. V. Churkin、S. Barland、N. Broderick、S. K. Turitsyn 和 B. Jalali。时间拉伸及其应用。*Nature Photonics*，11(6):341–351，2017年。13. M. Miscuglio、A. Mehrabian、Z. Hu、S. I. Azzam、J. George、A. V. Kildishev、M. Pelton 和 V. J. Sorger。用于光子神经网络的全光非线性激活函数。*Optical Materials Express*，8(12):3851–3863，2018年。14. D. R. Solli 和 B. Jalali。模拟光计算。*Nature Photonics*，9(11):704–706，2015年。15. V. Vapnik。使用广义肖像法进行模式识别。*Automationand remote control*，24:774–780，1963年。16. T. Zhou、F. Scalzo 和 B. Jalali。用于机器学习硬件加速的非线性 schr¨odinger 核。*Journal of Lightwave Technology*，40(5):1308–1319，2022年。17. Y. Zhou、J. C. Chan 和 B. Jalali。光子时间拉伸系统的统一框架。*Laser & Photonics Reviews*，16(8):2100524，2022年。