

基于人工神经网络的超冷原子实验多参数 自主优化系统

刘乾^{1,2}, 谢昱^{1,2}, 李琳^{1,2}, 梁昂昂^{1,2}, 李文文^{1,2}, 程鹤楠^{1,2}, 方苏¹, 屈求智¹,
刘亮^{1***}, 汪斌^{1**}, 吕德胜^{1*}

¹ 中国科学院上海光学精密机械研究所量子光学重点实验室, 上海 201800;

² 中国科学院大学材料科学与光电技术学院, 北京 100049

摘要 实验参数的优化调整在冷原子实验中是最基础且最重要的工作, 优良实验结果的获得离不开实验参数的不断优化。提出了一种基于人工神经网络的超冷原子实验多参数自主优化方案。首先, 详细介绍了神经网络结构的设置、自优化的学习策略。然后, 将神经网络与全局最优化模拟退火算法相结合搭建了相应的多参数自主优化系统。最后, 进行了利用直接蒙特卡罗模拟方法模拟磁光阱中冷原子动力学行为的实验, 对所提系统的性能进行了验证。实验结果表明, 经过约 30 h 的优化迭代, 所提方案有效完成了对冷原子动力学行为实验系统输入参数的优化, 并得到了一个稳定、有效且最优的实验结果。

关键词 量子光学; 激光冷却; 磁光阱; 人工神经网络; 直接蒙特卡罗模拟

中图分类号 O562

文献标志码 A

doi: 10.3788/CJL202148.2412001

1 引言

光与原子相互作用的实验研究一直是探究量子力学的基础。原子-光耦合技术使原子的冷却成为可能。基于激光冷却^[1-2]的冷原子实验是许多重要科学探究发展的基础, 如玻色-爱因斯坦凝聚物的产生^[3-4], 基于冷原子的精密计量学^[5], 新一代光学原子钟^[6-7]和量子信息处理^[8-9]。

众所周知, 冷原子实验涉及激光失谐量、激光功率变化率、激光偏振、环境磁场等多个变量, 因此开展冷原子实验是一个反复、多步骤、多参数的过程。以传统玻色-爱因斯坦凝聚超冷原子实验为例, 一个完整的实验周期^[4]: 1) 磁光阱(MOT)中原子的装载与冷却; 2) 冷原子的光抽运与选态; 3) 保守力阱的装载压缩; 4) 蒸发冷却; 5) 超冷原子制备完成后进行各项科学实验所需的实验步骤。各个实验步骤不仅有时序上的要求, 还需要相应地调节光场、磁场、微波、射频等物理场参数。因此, 整个实验周期

内所需调整的参数将构成高维度的参数集。

在传统情况下, 实验参数是通过人的直觉与不断尝试进行分阶段优化的。基于人的直觉优化得到的实验参数受实验系统、环境等一系列外界因素的限制, 相同的实验在不同的系统配置、不同的实验环境条件下会得到不同的测量结果。除此之外, 通过直觉调整实验参数的方式需要付出大量时间成本, 优化一次实验参数可能需要几个月或者更长的时间。因此, 在某些情况下需要寻找人类直觉以外的解决方案, 即利用算法的优化, 设计最小化成本函数, 进而确定最终的解决方案。虽然这类方案是高度非直观的, 但是优于传统的解决方案。与传统方案相比, 机器学习技术特别是基于深度神经网络(深度学习)的技术在解决复杂的问题等方面已经显示出巨大优势^[10-12], 这些技术已经被广泛用于优化量子实验参数过程的控制中^[13-15]。使用机器学习对冷原子系统进行在线优化的方法包括高斯过程模型^[16]和进化算法^[17-20], 但这些技术并没有表现出深

收稿日期: 2021-04-23; 修回日期: 2021-05-08; 录用日期: 2021-05-17

基金项目: 国家自然科学基金(12004401)、中国科学院青年创新促进会(2013YQ09094304)

通信作者: *dslv@siom.ac.cn; **wangbin@siom.ac.cn; ***liang.liu@siom.ac.cn

度学习在处理大型数据集时的计算速度。文献[10-20]中的实验虽然展示了深度学习的功效,但是它们是离线执行的,这意味着它们是在先前采集的数据上采取行动的,进而不具备实时性。

本文提出了利用人工神经网络进行多参数自优化的方案。首先,介绍了神经网络结构的设置和自优化的学习策略。然后,将神经网络与全局最优化模拟退火算法(SAA)^[21-22]相结合搭建了相应的多参数自主优化系统。最后,将所提方案与直接蒙特卡罗模拟(DSMC)^[23-24]方法相结合对模拟原子冷却实验进行了验证。结果表明,所提方案具有较高的计算效率,可以实时优化一个具有大量控制参数的冷原子实验系统,为工程化超冷原子平台的操控提供了一种便利的方法。

2 多参数优化系统的搭建

2.1 深度学习模型的建立

从数学模型角度分析基于深度神经网络的深度学习技术时,可以认为其是复杂的函数拟合,即利用大量的输入和目标数据并结合一系列数据变换,来得到输入与目标的映射关系。然而,这些数据变换都是通过观察大量的示例学习得到的。因此,设置数据变换中的超参数是重中之重。

神经网络预测参数示意图如图 1 所示。其中,用于参数预测的网络结构是由多层次感知器拓扑构成的。从宏观上来说,该神经网络是由输入层、隐藏层、输出层构成的。此外,最终训练完成的神经网络在数学上可以看作是一个复杂的函数,在此基础上采用 SAA 算法可得到最优目标解情况下的预测参数。考虑到整套冷原子实验的复杂程度,最终还是选用了分实验阶段进行参数优化的方案。图 1 中

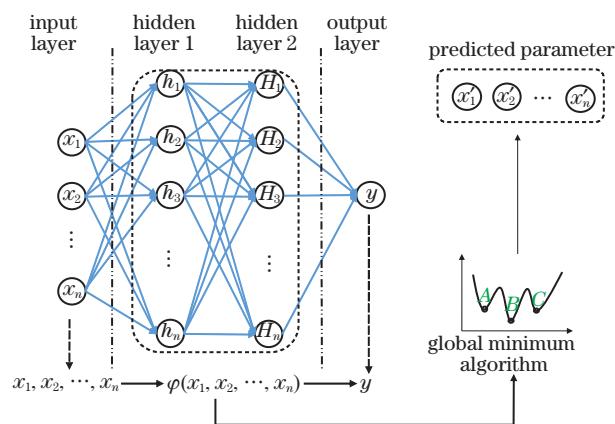


图 1 神经网络预测参数示意图

Fig. 1 Schematic diagram of parameter prediction by neural network

$x_n, h_n, H_n, y, \varphi(x_1, x_2, \dots, x_n), x'_n$ 分别表示第 n 个输入参数、隐藏层 1 的第 n 个神经元、隐藏层 2 的第 n 个神经元、计算实验值、训练好的神经网络模型、经过优化后的第 n 个输入参数, A, B, C 分别表示复杂函数的最优解。

网络结构的建立首先要考虑的就是模型中的学习参数^[25],即神经网络的层数以及神经元的数目。在深度学习中,学习参数的个数通常被称为模型的容量,即学习参数较多的模型拥有较大的记忆容量。因此,对于神经网络来说,学习参数是影响网络性能的重要指标。如果记忆容量较小,那么最终拟合出的网络将不能完全描述所有输入和目标数据的对应关系,也就是所谓的欠拟合。若是网络记忆容量过大,最终简单的对应关系将被拟合得过分复杂,会表现出许多错误与无关紧要的模式,也就是所谓的过拟合。此外,过拟合情况下的计算成本较大,效率较低。为防止过拟合与欠拟合现象的出现,需要在容量过大与容量不足之间找到一个折中值。

由于初始用于优化调整网络性能的数据量较小,故在划分完训练集与测试集后,测试集将不能参与模型的训练,这就降低了数据的利用率。因此,采用 K 折交叉验证^[26]来提高数据的利用率。具体做法是利用不重复抽样将原始数据随机分为 K 份,每次挑选其中 1 份作为测试集,剩余 $K-1$ 份作为训练集用于模型训练,这样每个子集都有一次机会作为测试集。在每个训练集上训练后可得到一个模型,用这个模型在相应的测试集上进行测试后,计算并保存模型的评估指标。最终,计算 K 组测试结果的平均值,在将其作为模型精度估计的同时,作为当前 K 折交叉验证下模型的性能指标。

实验中利用 Keras(利用 Python 编写的开源人工神经网络库)^[26]搭建神经网络,研究了 2 层和 3 层隐藏层的情况。神经元数量通常选择 2 的 n_1 次方 ($n_1 \in \mathbf{N}^+$),实验中依次选择了 8,16,32,64,128,256,并选取 K 为 10,梯度下降算法为 Adam^[26],每一层的激活函数为 ReLU^[26],学习率为 0.0001,损失函数为均方误差(MSE),最终实验结果如图 2 所示。

图 2 中(a)~(c)展示了平均绝对误差(MAE)、MSE 和预测精度随神经元数目的变化。MAE 是网络完成训练后预测值与目标值之差的绝对值,MSE 是预测值与目标值之差的平方。预测精度是重新打乱训练数据后,随机选取一组训练数据,将其输入值放入网络重新得到的预测值与随机选取训练数据的原目标值之比的平均值。

从图2中可以看出,无论是2层还是3层神经网络的情况,随着神经元的增加,MAE和MSE均会先减小,然后趋于一个相对稳定的值。同时,相应的预测精度也会逐渐上升至一个相对稳定的值。然而,随着网络复杂度的上升,所消耗的计算时间将大大增加,另外最终神经网络拟合的对应关系将出现

过拟合。根据以上结果,综合考虑计算时间成本,最终实验选择了具有2层神经网络,128个神经元的网络结构。基于该结构,最终的预测精度大于90%,MSE小于 4.0×10^{-5} ,MAE小于 4.7×10^{-3} 。虽然所选网络结构的预测精度不算太高,但是可以满足用于参数预测的实验系统。

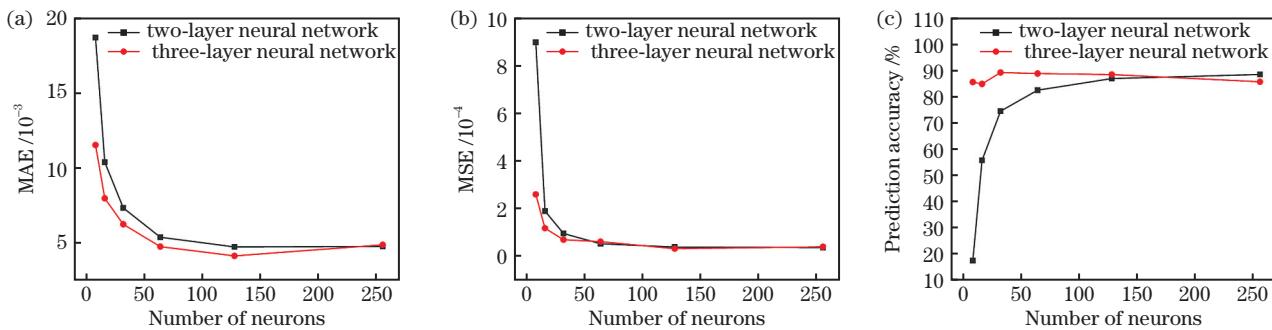


图2 不同性能指标随神经元数目的变化。(a) MAE;(b) MSE;(c)预测精度

Fig. 2 Different performance indexes varying with number of neuorns. (a) MAE; (b) MSE; (c) prediction accuracy

2.2 在线自主调参结构的搭建

利用2.1节中已有的网络结构,进行对应参数的实验结果预测。要想实现实时的参数自主调节系统,需要利用全局最优化算法,本文所用的全局最优化算法是SAA。参数自主优化实验流程如图3所示。首先是确定参数区间,随机选择64组初始参数并借助实验系统完成初步的64次实验,将得到的数据归一化后作为神经网络的预训练数据。预训练完成后,神经网络利用SAA求解得到此时的全局最优解,并给出相应的预测参数集与预测值。将此参

数集反馈回实验系统进行实验,进而得到最终的实验值。接下来,根据计算实验值与预测值(y')的绝对差值和实验值的比值是否小于0.0005,以及实验值是不小于训练数据中最优值(Y_{\max})的95%这两个条件进行分析。如果两个条件都不满足,那么证明整个参数自优化过程没有完成,本轮得到的最优参数和相应的实验值将会被填充进训练集,进而对网络进行进一步的训练。如此反复迭代,直至满足上述条件的任一条件,即可结束本次自优化实验过程,并给出相应预测值和预测参数。

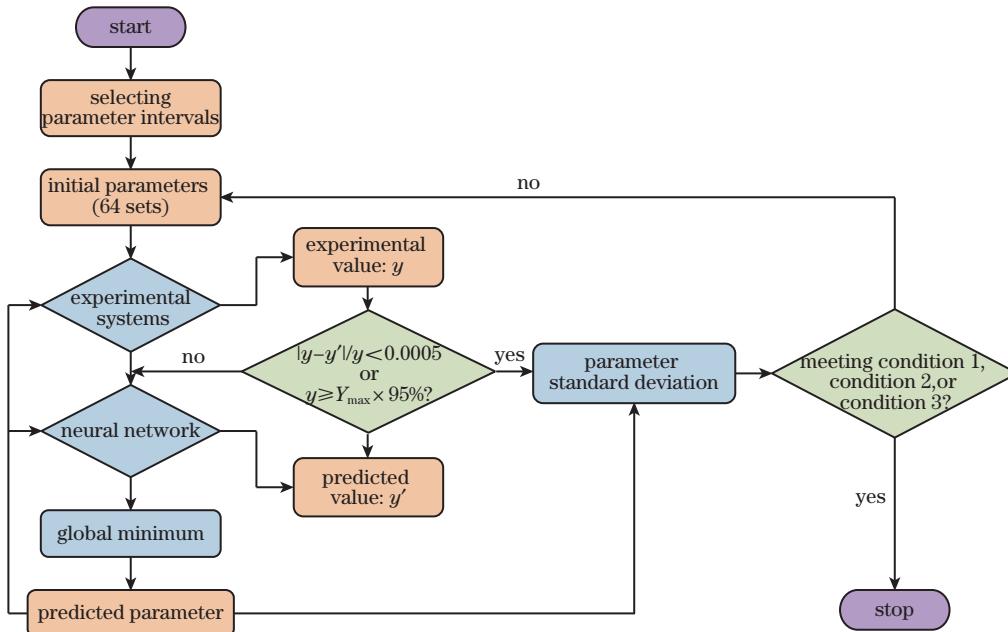


图3 参数自主优化实验流程

Fig. 3 Flow chart of parameter autonomous optimization experiment

为了提高整个系统的置信度,避免由于初始参数区间选择不合适导致最终最优化的失败。对每一组预测值增加一个很小的随机偏置量^[27],并将求得的标准差代入神经网络继续进行 50 次训练。若连续 5 次预测得到的标准差均大于之前得到的最优值的标准差,则相当于当前优化结果陷入局部最优,故将重新选择下一组初始参数区间。若训练满足以下三种情况之一则结束整个优化过程,并得到最优的实验结果。三种情况分别为得到一个优于预期最低标准差的值(condition1)、到达最大循环次数(condition2)和连续 20 次预测值均没有优于之前的最优值(condition3)。

由于实验中的网络结构选择了 2 层神经网络,128 个神经元,故单轮次训练所需时间很短,预测最优参数也很快。因此,最终可以在 3 min 内完成单轮次训练、参数预测和每组参数求标准差的完整过程。可以发现,整个优化过程所消耗的时间完全取决于实验系统的单轮次实验所需要的时间。

3 实验系统介绍

在实验系统中,利用 DSMC 方法模拟 MOT 中原子的动力学行为。初始原子由二维 MOT(2D MOT)制备,原子的初始位置与速度分布依赖于入射进科学腔内的 2D MOT 的原子束流。其中,科学腔的真空度设置为 1×10^{-9} Pa。

原子在 MOT 中会受到冷却和陷俘的作用。原子的受力模型通常由对射激光和四极磁场构成。从宏观角度来说,MOT 中原子所受冷却陷俘力主要来源于激光与磁场。其中激光提供辐射压力,磁场提供一个辐射压力随位置变化的环境。因此,MOT 内的原子受到一个指向中心的光散射力^[28]

$$\mathbf{F}_i = \pm \frac{\hbar k \Gamma}{2} \frac{S_0}{1 + S_0 + (2\delta_{\pm}/\Gamma)^2}, \quad (1)$$

式中: Γ 为⁸⁷Rb 原子循环跃迁的自然线宽; k 为光波矢; $S_0 = I/I_{\text{sat}}$, 其中 I 为激光光强, I_{sat} 为原子饱和光强(对于 D2 线圆偏光来说, I_{sat} 为 1.6 mW/cm^2); \hbar 为普朗克常数; i 为不同的受力方向; $\delta_{\pm} = \delta \mp \mathbf{k} \cdot \mathbf{V} \pm \mu' B / \hbar$, 其中 $\delta = |\omega - \omega_0|$ 为激光本身频率(ω_0)与对应原子能级(ω)的失谐量, $\mathbf{k} \cdot \mathbf{V}$ 为多普勒频移, \mathbf{V} 为原子相对光传播方向的运动速度, $\mu' B / \hbar$ 为磁场引起的塞曼频移, B 为磁场强度, μ' 是玻尔磁子;±表示对向传输的两支方向相反的激光束,其对应的多普勒频移和塞曼频移的符号都相反。

利用一对反亥姆霍兹线圈提供科学腔中的四极

磁场。中心处磁场可近似表示为

$$\mathbf{B} = \alpha (x_1 \mathbf{e}_x + y_1 \mathbf{e}_y - 2z_1 \mathbf{e}_z), \quad (2)$$

式中: α 是磁场梯度; x_1, y_1, z_1 分别表示在 x, y, z 方向上的磁场大小; $\mathbf{e}_x, \mathbf{e}_y, \mathbf{e}_z$ 分别表示 x, y, z 方向上的矢量;磁场强度 $B = \alpha \sqrt{x_1^2 + y_1^2 + 4z_1^2}$ 。

依据以上受力分析,最终采用 DSMC 方法来模拟粒子的运动过程。具体过程:1) 将空间按照粒子分布划分为一系列单元胞;2) 对各个单元胞内的粒子进行受力情况分析,并进行动力学计算。由于模拟实验关注的重点是最终原子的俘获结果,故为了节省计算时间,实验中没有考虑粒子间碰撞问题。利用龙格-库塔方法计算原子在自由运动一段时间(计算步长)后的速度与位置;3) 判断粒子是否满足 MOT 的束缚条件。如果不满足束缚条件,则说明该粒子逃逸出 MOT。如果满足束缚条件,则根据粒子演化后的位置统计阱中原子数目。简化后的模拟实验最终选择初始计算原子数为 1000,时间步长为 $8 \mu\text{s}$ 。

根据以上模拟实验,将冷却光功率、冷却光失谐、四极阱磁场梯度以及 2D MOT 中传输过来的原子束流的轴向速度作为优化参数,并将最终的原子数作为对应的优化目标。

4 结果与讨论

结合模拟实验与深度神经网络调参实验,将冷却光功率设置为 $10 \sim 80 \text{ mW}$,冷却光失谐设置为 $-5\Gamma \sim 0 \text{ MHz}$,磁场梯度设置为 $0.10 \sim 0.25 \text{ T/m}$,冷原子束流轴向速度设置为 $4 \sim 40 \text{ m/s}$ 。在以上参数区间随机选取 64 组输入参数,代入基于 DSMC 方法的模拟实验中可计算得出 64 个实验结果目标值。将 64 组输入参数组合后,作为神经网络调参系统的初始训练数据。经过约 30 h 的优化过程,迭代 348 次后的实验结果如图 4 所示。

图 4(a)反映了冷却光功率在参数区间内的优化过程,图 4(b)反映了冷却光失谐在参数区间内的优化过程,图 4(c)反映了磁场梯度在参数区间内的优化过程,图 4(d)反映了冷原子束流的轴向速度在参数区间内的优化过程。4 张图的横坐标均是总实验次数,包括 64 次初始化实验与 348 次优化实验。从图 4 中可以发现,4 个参数起初起伏比较大,起伏较大处为在参数区间内初始随机选择 64 组参数的结果。随着后续 348 次的迭代,各个参数在区间内起伏程度逐渐降低,并趋于稳定。

由于 4 个输入参数是相互影响的,因此 4 张图

中优化的后段,参数在区间内还是会起伏变化的。然而,随着迭代次数的增加,起伏变化的幅度逐渐降低并趋于稳定,这样的结果是符合实验逻辑的。最

终得到的优化实验参数为冷却光功率为 19.86 mW,冷却光失谐为 -2.76Γ ,磁场梯度为 0.18 T/m,冷原子束流轴向速度为 10.09 m/s。

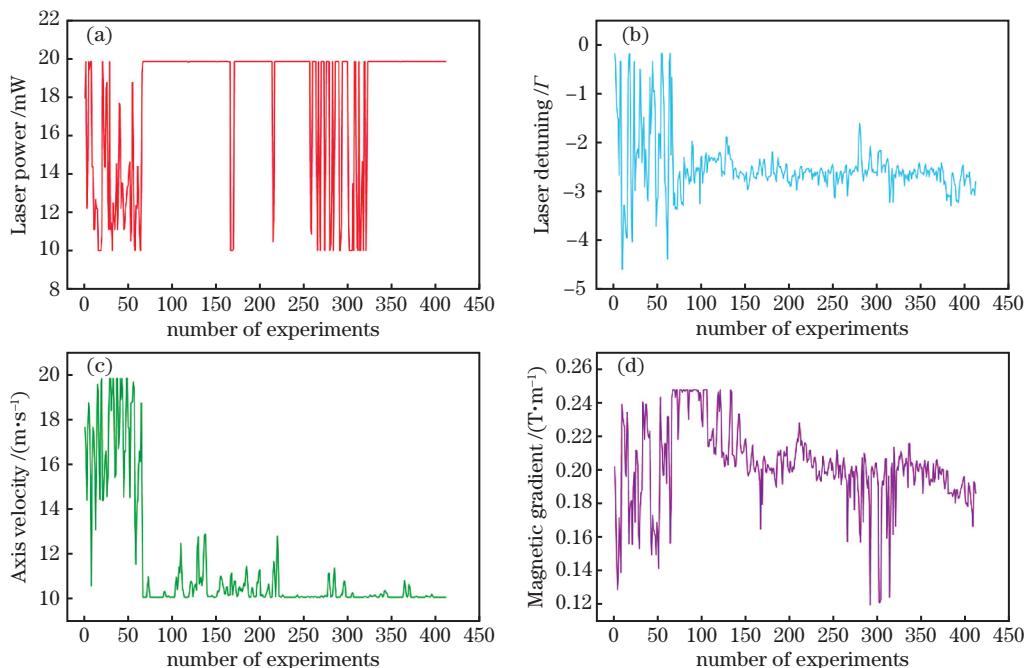


图 4 基于参数自主优化系统的参数调整实验结果。(a)冷却光功率;(b)冷却光失谐;(c)冷原子束流轴向速度;(d)磁场梯度

Fig. 4 Experimental results of parameter adjustment based on parameter autonomous optimization system. (a) Cooling laser power; (b) cooling laser detuning; (c) axial velocity of cold atomic beam; (d) magnetic gradient

图 5(a)是模拟实验目标值(MOT 中俘获原子数)随着实验次数变化的关系图。可以发现,初始 64 组随机选取的参数所对应的实验值分布较为离散,随着后续迭代次数的增多,原子数逐渐趋于稳定。优化后得到的最优原子数为 7.23×10^8 ,该结果符合实验预期。图 5(b)是预测精度随迭代次数

的变化。可以发现,在整个 348 次迭代优化的实验过程中绝大多数预测精度都在 0.5% 以内。个别偏差较大点可能是陷入局部最优值造成的。最终的优化结果趋于稳定,也从侧面证明了基于神经网络的在线自主调参系统在正常工作,且所提系统确实可以实现系统参数的自主优化调整。

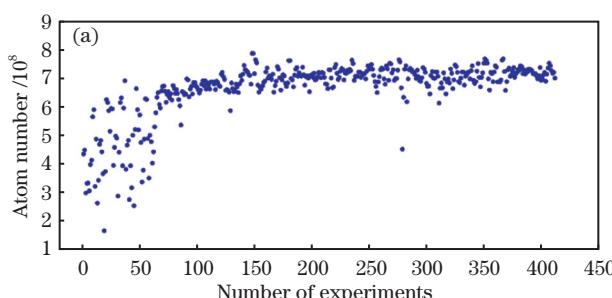


图 5 基于参数自主优化系统的实验结果。(a)原子数随实验次数的变化;(b)预测精度随迭代次数的变化

Fig. 5 Experimental results based on parameter autonomous optimization system. (a) Atom number varying with number of experiments; (b) prediction accuracy varying with number of iterations

5 结 论

详细介绍介绍了基于人工神经网络与全局最优化算法搭建的多参数自主优化系统。利用 DSMC 方法模拟了 MOT 中原子冷却与囚禁的实验,验证了自

主优化参数系统的有效性。实验结果表明,所提系统可以实现多参数实验系统的参数优化,并得到一个可靠、稳定的最优实验结果。只需对评估判断依据进行修改,就可将所提方案用于其余实验过程的优化。同时,所提方案还可以推广到其余的多参数

调整实验系统中,如原子钟,干涉仪等。本研究为工程化、远程操控的冷原子实验系统提供了一种自动、智能的运行控制方案。此外,所提方案可以大大减少人工工作量,提高实验系统的利用率和最终实验结果的质量。

参 考 文 献

- [1] Migdall A L, Prodan J V, Phillips W D, et al. First observation of magnetically trapped neutral atoms [J]. Physical Review Letters, 1985, 54(24): 2596-2599.
- [2] Adams C S, Riis E. Laser cooling and trapping of neutral atoms[J]. Progress in Quantum Electronics, 1997, 21(1): 1-79.
- [3] Cornell E A, Wieman C E. Bose-Einstein condensation in a dilute gas: the first 70 years and some recent experiments[J]. International Journal of Modern Physics B, 2002, 16(30): 4503-4536.
- [4] Ketterle W, Durfee D S, Stamper-Kurn D M. Making, probing and understanding Bose-Einstein condensates[EB/OL]. (1999-04-02) [2021-04-20]. <https://arxiv.org/abs/cond-mat/9904034>.
- [5] Kitching J, Knappe S, Donley E A. Atomic sensors: a review[J]. IEEE Sensors Journal, 2011, 11(9): 1749-1758.
- [6] Briegel H J, Dür W, Cirac J I, et al. Quantum repeaters: the role of imperfect local operations in quantum communication [J]. Physical Review Letters, 1998, 81(26): 5932-5935.
- [7] Göbel E O, Siegner U. Quantum metrology: foundation of units and measurements[M]. Weinheim: Wiley-VCH Verlag GmbH & Co. KGaA, 2015.
- [8] Dowling J P, Milburn G J. Quantum technology: the second quantum revolution [J]. Philosophical Transactions of the Royal Society of London Series A, 2003, 361(1809): 1655-1674.
- [9] Campbell G T, Pinel O, Hosseini M, et al. Configurable unitary transformations and linear logic gates using quantum memories[J]. Physical Review Letters, 2014, 113(6): 063601.
- [10] Silver D, Huang A, Maddison C J, et al. Mastering the game of Go with deep neural networks and tree search[J]. Nature, 2016, 529(7587): 484-489.
- [11] Mnih V, Kavukcuoglu K, Silver D, et al. Human-level control through deep reinforcement learning[J]. Nature, 2015, 518(7540): 529-533.
- [12] 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): 120405.
- [13] August M, Ni X T. Using recurrent neural networks to optimize dynamical decoupling for quantum memory[J]. Physical Review A, 2017, 95: 012335.
- [14] Ju S H, Shiga T, Feng L, et al. Designing nanostructures for phonon transport via Bayesian optimization[J]. Physical Review X, 2017, 7(2): 021024.
- [15] Mavadia S, Frey V, Sastrawan J, et al. Prediction and real-time compensation of qubit decoherence via machine learning[J]. Nature Communications, 2017, 8: 14106.
- [16] Wigley P B, Everitt P J, van den Hengel A, et al. Fast machine-learning online optimization of ultracold-atom experiments[J]. Scientific Reports, 2016, 6: 25890.
- [17] Amstrup B, Toth G J, Szabo G, et al. Genetic algorithm with migration on topology conserving maps for optimal control of quantum systems [J]. The Journal of Physical Chemistry, 1995, 99(14): 5206-5213.
- [18] Geisel I, Cordes K, Mahnke J, et al. Evolutionary optimization of an experimental apparatus [J]. Applied Physics Letters, 2013, 102(21): 214105.
- [19] Beil F, Buschbeck M, Heinze G, et al. Light storage in a doped solid enhanced by feedback-controlled pulse shaping[J]. Physical Review A, 2010, 81(5): 053801.
- [20] Tsubouchi M, Momose T. Rovibrational wave-packet manipulation using shaped midinfrared femtosecond pulses toward quantum computation: optimization of pulse shape by a genetic algorithm [J]. Physical Review A, 2008, 77(5): 052326.
- [21] Knoll D A, Keyes D E. Jacobian-free Newton-Krylov methods: a survey of approaches and applications[J]. Journal of Computational Physics, 2004, 193(2): 357-397.
- [22] Liu H L, Zhu P X, Chen Y, et al. Optimization of indoor VLC coverage uniformity by improved genetic simulated annealing algorithm[J]. Chinese Journal of Lasers, 2019, 46(1): 0106001.
刘焕淋, 朱平鑫, 陈勇, 等. 改进遗传模拟退火算法优化室内 VLC 覆盖均匀性[J]. 中国激光, 2019, 46(1): 0106001
- [23] Bird G A. Molecular gas dynamics and the direct simulation of gas flow [M]. Oxford: Clarendon Press, 1994.
- [24] Zhao Z H, Wang X C, Li B, et al. Atom transport

- with exponentially growing population on an atom chip[J]. Acta Optica Sinica, 2018, 38(9): 0902001.
赵子豪, 王晓晨, 李博, 等. 原子芯片上指数型布居增长的原子输运[J]. 光学学报, 2018, 38(9): 0902001.
- [25] Goodfellow I, Bengio Y, Courville A. Deep learning [M]. Cambridge: MIT press, 2016.
- [26] Chollet F. Deep learning with Python[M]. Zhang L, Transl. Beijing: Posts & Telecom Press, 2018: 68-72.
弗朗索瓦·肖莱. Python 深度学习[M]. 张亮, 译. 北京: 人民邮电出版社, 2018: 68-72.
- [27] Peng X K, Ji J W, Li L, et al. Online learning method based on artificial neural network to optimize magnetic shielding characteristic parameters[J]. Acta Physica Sinica, 2019, 68(13): 0903002.
彭向凯, 吉经纬, 李琳, 等. 基于人工神经网络在线学习方法优化磁屏蔽特性参数[J]. 物理学报, 2019, 68(13): 0903002.
- [28] Wang Y Q. Laser cooling and trapping of atoms[M]. Beijing: Peking University Press, 2007.
王义遒. 原子的激光冷却与陷阱[M]. 北京: 北京大学出版社, 2007.

Multiparameter Autonomous Optimization System for Ultracold Atomic Experiments Based on Artificial Neural Network

Liu Qian^{1,2}, Xie Yu^{1,2}, Li Lin^{1,2}, Liang Ang'ang^{1,2}, Li Wenwen^{1,2}, Chen Henan^{1,2}, Fang Su¹, Qu Qiuzhi¹, Liu Liang^{1***}, Wang Bin^{1**}, Lü Desheng^{1*}

¹ Key Laboratory of Quantum Optics, Shanghai Institute of Optics and Fine Mechanics, Chinese Academy of Sciences, Shanghai 201800, China;

² College of Materials Science and Opto-Electronic Technology, University of Chinese Academy of Sciences, Beijing 100049, China

Abstract

Objective The optimal adjustment of experimental parameters is the most basic and important work in cold atomic experiments. Excellent experimental results cannot be achieved without the continuous optimization of parameters. In this paper, a multiparameter autonomous optimization system for ultracold atomic experiment based on artificial neural network is proposed. The setup of neural network structure, the autonomous optimization learning approach, and the construction of a multiparameter autonomous optimization system using the global optimization simulated annealing algorithm (SAA) are described in detail. The parameter autonomous optimization system is validated by using direct simulation Monte Carlo (DSMC) method to simulate the kinetic behavior of cold atoms in magneto-optical trap (MOT). The final results reveal that after about 30 h of optimization iteration, the input parameters of validation experimental system are effectively optimized, yielding a stable, efficient, and optimal experimental result. Therefore, the multiparameter autonomous optimization system based on artificial neural network can greatly reduce manual workload, enhance experimental system utilization, and improve the quality of the final experimental results. The proposed scheme provides a solution for engineering and remote control of cold atomic experimental systems.

Methods This paper presents a detailed scheme for a multiparameter autonomous optimization system using artificial neural networks. The setup of the neural network structure, the autonomous optimization learning strategy, and the construction of a multiparameter autonomous optimization system using SAA are described. The experimental validation of the proposed scheme combined with the DSMC method for simulating atomic cooling experiment is shown. Finally, four parameters are employed to optimize the number of cold atoms trapped in MOT: cooling laser power, cooling laser detuning, magnetic gradient, and axial velocity of cold atomic beam.

Results and Discussions For the combined simulation and deep neural network tuning experiments, the cooling laser power is set from 10 to 80 mW, the cooling laser detuning is set from -5Γ to 0 MHz, the magnetic gradient is set from 0.10 to 0.25 T/m, and the axial velocity of cold atomic beam is set from 4 to 40 m/s. From these parameter ranges, 64 sets of input parameters are randomly selected and brought into the simulation experiment based on DSMC method. For each of the 64 experimental results, target values are calculated. These parameters are pooled and utilized as initial training data for the neural network tuning system. A total of 348 iterations are

conducted after approximately 30 h of optimization, and the final experimental results are shown in Fig. 4 and Fig. 5. The optimization of the cooling laser power in the parameter interval, the optimization of the cooling laser detuning in the parameter interval, the optimization of the magnetic field gradient in the parameter interval, and the optimization of the axial velocity of cold atomic beam in the parameter interval are shown in Figs. 4(a)–(d). Moreover, the total number of experiments, including 64 initialization and 348 optimization experiments, is shown in the horizontal coordinates. As a result of the initial random selection of 64 sets of parameters within the parameter interval, it can be seen that the four parameters change significantly at the beginning of the procedure. However, the degree of variation of each parameter in the interval progressively reduces and stabilizes during the next 348 iterations. Finally, the cooling laser power, cooling laser detuning, magnetic gradient and axial velocity of cold atomic beam are optimized to 19.86 mW, -2.76Γ , 0.18 T/m and 10.09 m/s, respectively. Figure 5 shows that the experimental values corresponding to the initial 64 sets of randomly selected parameters are rather uniformly distributed and that the atomic number gradually stabilizes with the later iterations. The optimal number of atoms obtained after the final optimization is 7.23×10^8 . The prediction accuracies are within 0.5% for the entire 348 iterations. Those results show that the proposed scheme is computationally efficient enough to optimize a cold atomic experimental system with a high number of control parameters in real-time.

Conclusions This paper presents a multiparameter autonomous optimization system built on artificial neural networks and global optimization algorithm. By using the DSMC method to simulate experiments on atomic cooling in MOT, the effect of the autonomous parameter optimization system is verified. The final results show that the proposed scheme can optimize the parameters of multiparameter experimental system and produce a consistent and stable optimal experimental result. Subsequent applications only require equivalent changes to the evaluation judgment basis, which can be used to optimize the remaining experimental processes. Moreover, the experimental solution can be extended to other multiparameter tuned experimental systems such as atomic clocks, interferometers, etc. The proposed scheme provides an automatic and intelligent operational control solution for the engineering and remote control of cold atomic experimental systems. In addition, the manual workload can be significantly reduced, the utilization of the experimental system can be increased, and the quality of the final experimental results can be effectively improved using the proposed scheme.

Key words quantum optics; laser cooling; magneto-optical trap; artificial neural network; direct simulation Monte Carlo

OCIS codes 270.5585; 020.7010; 020.3320; 100.4996