

基于精细神经元的类脑感知学习模型*

张祎晨¹, 何干¹, 杜凯², 黄铁军^{1,2}

¹(北京大学 计算机学院, 北京 100871)

²(北京大学 人工智能研究院, 北京 100871)

通信作者: 杜凯, E-mail: kai.du@pku.edu.cn



摘要: 大脑如何实现学习以及感知功能对于人工智能和神经科学领域均是一个重要问题. 现有人工神经网络由于结构和计算机制与真实大脑相差较大, 无法直接用于理解真实大脑学习以及处理感知任务的机理. 树突神经网络模型是一种对大脑神经元树突信息处理过程进行建模仿真的计算模型, 相比人工神经网络更接近生物真实. 使用树突神经网络模型处理学习感知任务对理解真实大脑的学习过程有重要作用. 然而, 现有基于树突神经网络的学习模型大都局限于简化树突模型, 无法完整建模树突的信号处理过程. 针对这一问题, 提出一种基于精细中型多棘神经网络的学习模型, 使得精细神经网络可以通过学习完成相应感知任务. 实验表明, 在经典的图像分类任务上, 所提模型可以达到很好的分类性能. 此外, 精细神经网络对于噪声干扰有很强的鲁棒性. 对网络特性进行进一步分析, 发现学习后网络中的神经元表现出了刺激选择性这种神经科学中的经典现象, 表明所提模型具有一定的生物可解释性, 同时也表明刺激选择特性可能是大脑通过学习完成感知任务的一种重要特性.

关键词: 大脑仿真; 类脑计算; 感知学习; 图像分类

中图法分类号: TP18

中文引用格式: 张祎晨, 何干, 杜凯, 黄铁军. 基于精细神经元的类脑感知学习模型. 软件学报, 2024, 35(3): 1403–1417. <http://www.jos.org.cn/1000-9825/6816.htm>

英文引用格式: Zhang YC, He G, Du K, Huang TJ. Biophysically Detailed Model for Brain-like Perceptual Learning. Ruan Jian Xue Bao/Journal of Software, 2024, 35(3): 1403–1417 (in Chinese). <http://www.jos.org.cn/1000-9825/6816.htm>

Biophysically Detailed Model for Brain-like Perceptual Learning

ZHANG Yi-Chen¹, HE Gan¹, DU Kai², HUANG Tie-Jun^{1,2}

¹(School of Computer Science, Peking University, Beijing 100871, China)

²(Institute for Artificial Intelligence, Peking University, Beijing 100871, China)

Abstract: How brains realize learning and perception is an essential question for both artificial intelligence and neuroscience communities. Since the existing artificial neural networks (ANNs) are different from the real brain in terms of structures and computing mechanisms, they cannot be directly used to explore the mechanisms of learning and dealing with perceptual tasks in the real brain. The dendritic neuron model is a computational model to model and simulate the information processing process of neuron dendrites in the brain and is closer to biological reality than ANNs. The use of the dendritic neural network model to deal with and learn perceptual tasks plays an important role in understanding the learning process in the real brain. However, current learning models based on dendritic neural networks mainly focus on simplified dendritic models and are unable to model the entire signal-processing mechanisms of dendrites. To solve this problem, this study proposes a learning model of the biophysically detailed neural network of medium spiny neurons (MSNs). The neural network can fulfill corresponding perceptual tasks through learning. Experimental results show that the proposed model can achieve high performance on the classical image classification task. In addition, the neural network shows strong robustness under noise interference. By further analyzing the network features, this study finds that the neurons in the network after learning show stimulus selectivity, which is a

* 基金项目: 国家自然科学基金 (61425025); 国家重点研发计划 (2020AAA0130400)

收稿时间: 2022-06-29; 修改时间: 2022-09-09; 采用时间: 2022-10-05; jos 在线出版时间: 2023-05-10

CNKI 网络首发时间: 2023-05-11

classical phenomenon in neuroscience. This indicates that the proposed model is biologically plausible and implies that stimulus selectivity is an essential property of the brain in fulfilling perceptual tasks through learning.

Key words: brain simulation; brain-like computing; perceptual learning; image classification

1 引言

具有生物可解释性的学习模型在人工智能和神经科学领域均是重要的研究课题. 近年来, 深度学习在图像、视频等人工智能领域的各项任务中均取得了突破性的进展^[1,2], 甚至在围棋、电脑游戏等复杂场景下打败了人类职业选手^[3-5]. 由于神经网络模型由大脑神经元的信号处理机制启发而来, 因此真实大脑如何实现学习这一问题正受到更加广泛的关注. 类脑计算模型是一类参考生物现象或受大脑计算机理启发的模型^[6]. 类脑计算模型有助于理解真实大脑的学习机制, 同时可作为桥梁建立起大脑学习机制和计算模型之间的联系, 对启发新型的人工智能算法有重要意义^[7].

树突是神经元接受输入的结构, 接受来自其他神经元信号输入, 对信号进行处理整合. 近年来越来越多的有关大脑学习和突触可塑性方面的研究表明树突是大脑实现学习过程不可缺少的部分^[8]. 很多研究工作将树突抽象为 1-2 个计算单元, 构建简化树突模型 (图 1(b)), 并提出基于简化树突模型的学习方法以完成相关感知学习任务. 简化树突模型相比人工神经网络中的点神经元模型更具有生物可解释性, 可用于从现象层面对大脑学习过程的探究. 模型学习过程中树突所表现出的信号反馈^[9]、信号多路复用^[10]、树突平台电压^[11]等特性可在真实生物大脑中找到对应现象, 被认为可能是大脑中学习过程实现的机制^[12].

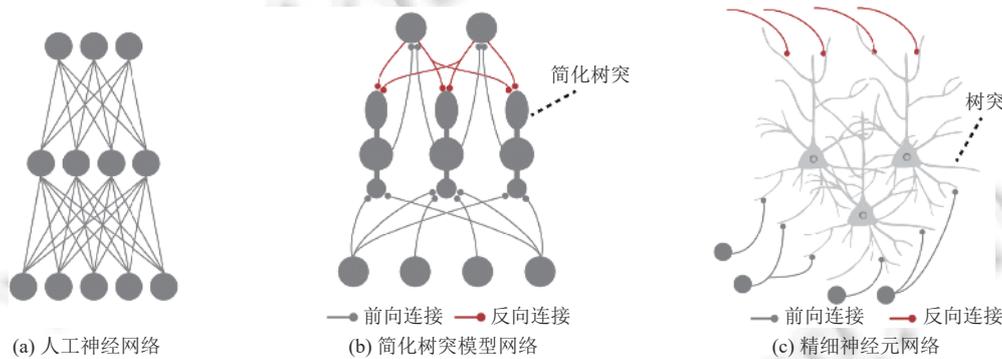


图 1 不同类型网络模型示意

精细神经元模型相比于简化树突模型更接近生物真实 (图 1(c)), 有助于从计算机理层面理解大脑学习过程^[13]. 简化树突模型由于对树突的结构和计算进行了高度抽象, 只能反应树突在信息处理中的部分特性. 相比于简化树突模型, 精细神经元模型对树突形态以及树突上的离子通道、突触等结构均进行精细建模, 可以对真实神经元完整的信息处理过程进行精细仿真, 因此基于精细神经元的模型可以帮助科学家理解大脑学习过程的实现机理, 回答例如“生物大脑中是否有和深度学习相似的学习机制”等科学问题^[8]. 此外, 对离子通道、突触以及树突形态的精细建模使得单个精细神经元模型即可实现非线性信号整合, 这种非线性特性使得单个精细神经元的信号处理与记忆能力与多层人工神经网络相当^[14-17]. 基于精细神经元的模型学习方法相关研究表明, 经过学习之后单个神经元即可处理例如异或等复杂的非线性问题^[18-20]. 精细神经元模型所具有的强大计算能力使得基于精细神经元的模型同时有助于启发全新的、更强的 AI 算法^[21].

然而, 目前基于树突神经元的模型大都以简化树突模型为基础构建, 很少有工作构建基于精细神经网络的类脑感知学习模型. 主要难点在于缺少有效的权重学习方法: 精细树突模型的信号处理过程较为复杂, 无法使用现有神经网络上的反向传播算法对其进行训练; 同样地, 由于精细模型的计算机理和简化树突模型相差较大, 现有简化树突模型上的学习方法无法直接在精细神经元模型上使用.

为解决以上问题, 本文首先构建了基于基底核 (basal ganglia) 脑区中型多棘神经元 (medium spiny neuron, MSN) 的精细神经网络模型 MSNNet, 并针对该模型设计学习方法, 使其可通过学习完成相应图像分类感知任务. 基底核脑区是人类大脑运动感知整合 (sensorimotor integration) 和决策的中枢, 在临床上和帕金森症密切相关, 其功能及计算机制对计算机领域的强化学习理论也有一定启发^[22,23]. 中型多棘神经元位于基底核脑区的入口—纹状体 (striatum), 其数量大约占纹状体中神经元的 95%–96%, 接受几乎整个大脑皮层的输入^[22–24]. 中型多棘神经元由于掌控着基底核脑区的入口, 从而被认为是基底核脑区最重要的神经元^[22,23]. 因此, 以精细中型多棘神经元模型为基础构建类脑感知学习模型, 有助于探究大脑在处理视觉信号时的学习和决策过程.

模型的整体框架如图 2 所示. 模型由输入层、隐藏层、输出层组成, 其中隐藏层使用精细 MSN 模型构建. 输入图像首先被转换为脉冲序列, 经过网络每一层的处理后, 根据输出层神经元响应得到分类结果. 当网络的输出响应和目标响应不一致时, 模型根据误差信号对连接权重进行调整. 如前文所述, 树突复杂的信息处理机制导致精细神经元上的学习较为困难. 为解决这一问题, 本文针对精细网络模型设计了学习方法. 受相关工作启发^[25,26], 本文通过对树突的信息处理过程进行分析, 使用转移电导将误差与神经元树突上的响应关联, 实现对梯度的近似, 根据近似梯度对各连接的权重进行相应更新, 从而使精细神经网络可通过误差信号反馈的方式进行学习. 实验表明, 通过以上学习方法可使模型响应逐渐逼近期望响应, 完成图像分类任务. 网络中的 MSN 神经元在学习后表现出了真实神经元的刺激选择特性, 表明模型具有一定的生物可解释性, 同时说明了刺激选择特性对感知任务有重要作用. 此外, 进一步实验表明, 精细神经网络模型对噪声有很强的鲁棒性, 在噪声干扰下依然可以取得很好的分类性能.

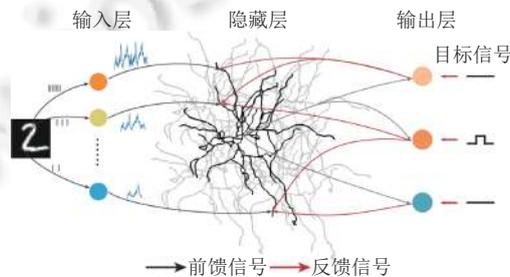


图 2 基于精细神经网络的学习感知模型示意

本文第 2 节介绍树突神经元模型上的学习方法相关工作. 第 3 节介绍本文所需的基础知识, 包括精细神经元模型与精细模型仿真. 第 4 节介绍本文提出的精细神经网络感知学习方法与精细神经网络模型. 第 5 节通过实验验证了所提出的学习方法与模型的有效性. 最后第 6 节对全文进行总结.

2 基于树突神经元的学习模型相关工作

真实大脑神经元有复杂的树突结构, 大量生物实验表明树突对于神经元信号处理有重要作用^[27]. 树突神经元模型相比人工神经元模型更接近生物真实, 有助于理解真实神经元学习过程的实现机制. 由于真实树突的计算机制过于复杂, 相关工作使用简化的树突模型构建网络, 并提出学习方法完成图像分类等感知任务, 用于探索真实神经元的学习方式, 以及深度学习中反向传播算法在大脑中可能的实现机制. Guerguiev 等人^[11]提出了一种简化树突模型, 表明利用树突所具有的树突平台电压特性可以实现学习功能, 利用此特性所构建的多层网络通过学习可完成手写数字识别任务. Sacramento 等人^[9]提出一种带有误差编码 (error-coding) 的网络, 通过网络中不同神经元之间的反馈连接表明由树突神经元组成的神经环路可以对反向传播算法进行近似, 同样在手写数字识别中取得了接近人工神经网络的性能, 验证了方法的有效性. Payeur 等人^[10]提出的学习模型表明, 网络中的高层神经元可以利用高频的脉冲发放实现对低层突触连接权重的调控, 从而完成学习. 相比上述方法, Moldwin 等人^[18]提出的 gradient clusteron 学习方法更具有生物可解释性. Gradient clusteron 方法通过调整突触连接的位置以及连接强度实现学习,

这种学习方式与真实神经元所表现出的部分现象一致. 此外, gradient clusteron 在手写数字识别中取得了与逻辑回归方法近似的性能.

相比于简化树突模型使用 1-2 个计算单元对树突进行建模, 精细神经元模型对树突的形态、计算机理进行完整建模, 是最接近生物真实的神经元模型. 相关工作提出基于精细神经元模型的学习方法, 从树突计算机理的角度探究真实神经元实现学习过程的可能方式. Schiess 等人^[28]提出一种兴奋性树突上的学习方法, 探究了误差反向传播在真实神经元上可能的实现方式, 并通过实验验证了所提出的学习方法可以完成模式分类等任务. Moldwin 等人^[20]提出了一种感知机学习算法在精细神经元上的实现方式, 相比于误差反向传播, 这种学习方式更多利用相连神经元的局部信息, 与神经科学中经典的“赫布学习规则”更接近. 实验表明, Moldwin 等人^[20]的方法可使精细神经元模型通过学习完成二分类任务, 验证了方法的有效性. 为进一步探究精细神经元的计算能力, Bicknell 等人^[19]基于精细神经元建模基础理论提出一种突触学习规则, 可利用树突的非线性实现学习, 接近真实神经元的信号处理过程. 实验表明单个精细神经元在学习之后即可完成非线性计算任务, 在验证学习方法有效性的同时进一步验证了树突的非线性使得单个神经元具有强大的计算能力.

总结而言, 现有树突模型上的学习方法可分为简化树突模型上的学习方法和精细模型上的学习方法两类. 简化树突模型上的学习方法主要从现象层面探究了真实神经元实现学习功能的方式, 由简化树突模型所构建的网络在具有生物可解释性的同时可通过学习完成相应感知任务. 基于精细神经元模型的学习方法从更底层的计算机理层面对真实神经元的学习过程进行探究, 更逼近生物真实. 通过学习, 单个精细神经元即可完成例如异或等需要点神经元网络才能完成的复杂计算任务. 然而, 很少有工作支持精细神经网络层面的学习.

3 基础知识

本文主要基于精细神经元模型展开相关研究, 下面就本文所涉及的精细神经元模型以及精细仿真相关知识进行介绍.

3.1 精细神经元模型

首先对真实神经元所包含的各类结构进行介绍 (图 3(a)). 树突是神经元上的复杂突起结构, 主要用于接受其他神经元传递而来的脉冲信号. 突触是不同神经元之间产生连接的结构, 是神经元之间脉冲信号传递的关键部位. 离子通道是神经元可以产生脉冲信号的关键, 离子通道为细胞膜上的蛋白质, 控制神经元内外的离子流动, 产生电流.

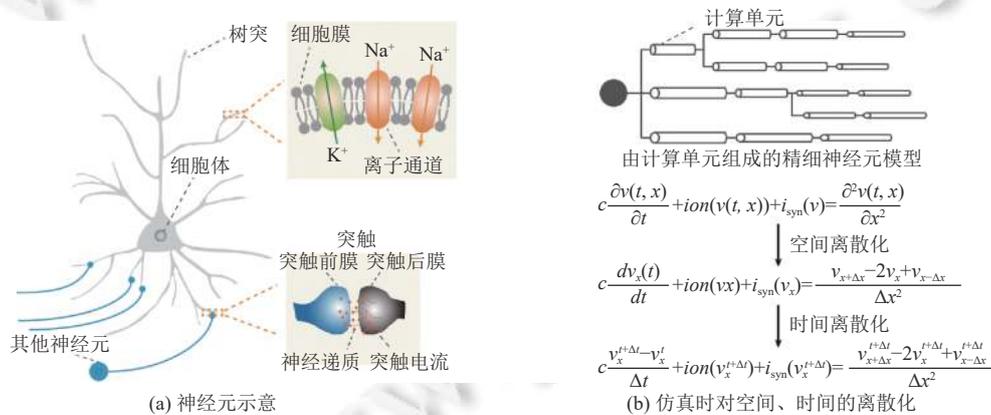


图 3 精细神经元及其仿真过程示意

精细神经元模型是一种对真实神经元树突、离子通道、突触等结构的计算机理均进行精细建模的生物物理模型, 主要用于对真实神经元的生物物理特性进行仿真. 构建精细神经元模型的理论基础主要包括由 Hodgkin 等人于 1952 年提出的 HH 模型^[29]和 Rall 于 1959 年提出的电缆理论 (cable theory)^[30]. 其中, HH 模型通过一组常微分方程描述神经元树突上离子通道所产生的电流, 电缆理论使用偏微分方程形式化描述神经元不同位置之间电流

响应的相互影响. 综合 HH 模型和电缆理论, 精细神经元模型通常使用如下偏微分方程进行描述:

$$c \frac{\partial v(t, x)}{\partial t} + ion(v(t, x)) + i_{syn}(v(t, x)) = \frac{\partial^2 v(t, x)}{\partial x^2} \quad (1)$$

其中, $v(t, x)$ 表示神经元各个位置以及各个时刻的电压值; c 为细胞膜电容值; 等号右侧的偏微分项用于描述不同位置之间电压响应的相互影响. $i_{syn}(v)$ 表示突触所产生的电流, 其具体数学模型由用户定义, 通常使用微分方程进行描述. $ion(v(t, x))$ 表示由离子通道产生的电流响应, 同样通过一组常微分方程建模. 一种经典的建模方式如公式 (2) 所示, 其中, \bar{g}_{Na} 、 \bar{g}_K 分别表示钠离子通道与钾离子通道完全打开时的电导值, g_L 表示细胞膜的漏电导; m 表示钠离子通道中基元打开的概率, 由于钠离子通道的打开由 3 个基元控制, 因此打开的总概率为 m^3 ; $\alpha_m(v)$, $\beta_m(v)$ 分别表示在电压 v 下钠离子通道在打开状态和关闭状态之间的转化率; h 表示控制钠离子通道关闭的基元发挥作用的概率, $\alpha_h(v)$, $\beta_h(v)$ 分别表示该基元打开和关闭状态之间的转化率; n 表示钾离子通道基元打开的概率, 同样地, $\alpha_n(v)$, $\beta_n(v)$ 表示打开和关闭两种状态之间的转化率. E_{Na} , E_K , E_L 分别表示钠离子通道、钾离子通道、细胞膜漏电导的平衡电位. 公式 (2) 是最经典的 HH 模型^[29], 只包含钠离子和钾离子两种离子通道, 其他离子通道模型均由该经典 HH 模型发展而来.

$$\begin{cases} ion(v) = -\bar{g}_{Na}m^3h(v - E_{Na}) - \bar{g}_Kn^4(v - E_K) - g_L(v - E_L) \\ \frac{dn}{dt} = \alpha_n(v)(1 - n) - \beta_n(v)n \\ \frac{dm}{dt} = \alpha_m(v)(1 - m) - \beta_m(v)m \\ \frac{dh}{dt} = \alpha_h(v)(1 - h) - \beta_h(v)h \end{cases} \quad (2)$$

3.2 精细神经元仿真

精细神经元模型对真实神经元的计算机理进行建模, 对模型方程公式 (1) 进行求解可得到神经元各位点在各时刻的电压响应, 从而可对神经元的生理特性进行分析与探索. 然而, 由于方程中存在非线性项, 该偏微分方程不存在解析解, 因此只能通过数值方法对其进行求解. 使用数值方法求解精细神经元方程的过程称为仿真.

隐式有限差分法, 即后向欧拉法是当前精细神经元仿真中最常用的数值方法. 有限差分法通过使用差分项替代微分项从而得到待求解变量的递推关系式, 随后通过所得到的递推式迭代计算得到每一时刻待求解变量的值. 因此在仿真前, 首先需要对公式 (1) 进行空间和时间上的离散化, 即使用差分项替代其中的微分项. 空间离散化将等式右侧偏微分项使用差分项替代, 等价于将神经元模型划分为若干计算单元 (图 3(b)). 时间离散化将等式左侧关于 t 的微分项使用差分项替代, 由此可以得到下一时刻电压值与当前时刻已知电压值的递推关系. 仿真根据所得到的递推关系式迭代进行计算, 最终可得到模型中各计算单元在各时刻的电压响应.

精细神经元仿真平台对仿真过程的实现进行封装, 使用户可以不必了解仿真过程, 专注于模型的构建. 精细神经元仿真平台是精细神经元仿真、建模的基础. 当前精细仿真平台主要有 GENESIS^[31]、NEURON^[32]、CoreNEURON^[33]等. 其中 NEURON 是国际上最主流的精细神经计算仿真平台. CoreNEURON 对 NEURON 的引擎进行了存储和计算效率上的优化, 降低仿真所需内存并提高了仿真效率. 此外, CoreNEURON 支持使用 GPU 进行精细神经仿真, 极大提高了仿真效率.

4 基于精细神经网络的类脑感知学习模型

本文使用精细中型多棘神经元模型 (MSN) 构建精细神经网络 MSNNet, 并提出一种精细神经网络上的学习方法, 使 MSNNet 可通过调整突触连接权重逐渐逼近目标响应, 完成经典的图像分类任务.

MSNNet 共包含 3 层结构, 其中输入层与输出层使用点神经元模型, 隐藏层使用精细神经元模型 (图 4). 处理图像分类任务时, 网络接受由输入图像转化而来的脉冲信号, 经过处理后, 以输出层神经元的响应计算输入图像属于各类别的概率, 得到分类结果. 随后使用所提出的学习方法, 求得模型中突触连接权重的梯度, 对连接权重进行更新, 使模型响应逐渐逼近目标响应.

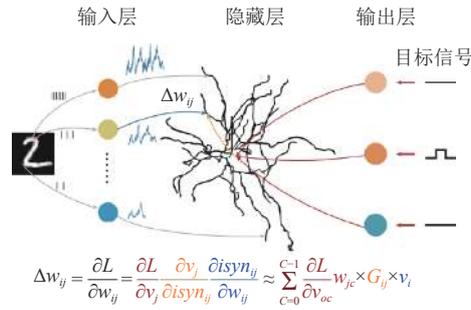


图 4 精细神经网络学习过程中的梯度计算

为使 MSNNet 可以通过学习完成相应任务, 本文提出精细神经网络上的学习方法. 误差反向传播算法^[34]是深度学习的基础. 深度神经网络可以通过反向传播算法调整自身的连接权重, 最终在特定任务上取得非常好的性能. 受相关工作启发^[25,26], 本文借鉴反向传播算法的核心思路, 使用梯度下降的方法对网络中的连接权重进行更新. 然而, 精细神经网络的计算机制以及结构与深度神经网络完全不同, 反向传播算法中的梯度求解方法无法在精细神经网络上使用. 导致该问题的主要原因是精细神经网络中后层神经元与前层神经元的响应之间不是简单的线性加权关系. 对于精细神经网络, 前层神经元的响应通过突触连接传递到下一层神经元的树突(图 4), 产生突触电流, 突触电流经过树突传递到胞体从而对胞体响应产生影响. 其中突触、树突的信息处理机制由动力学方程进行描述, 由于通常无法得到树突进行计算时的解析式, 因此无法通过直接求导的方式求得梯度.

为解决精细神经网络中梯度难以求解的问题, 本文根据树突以及突触在信号处理中的特性, 对梯度进行逼近, 使用近似得到的梯度对权重进行更新. 本文将损失函数关于权重的梯度转换为以下 3 项梯度的乘积(图 4): 1) 损失函数关于胞体响应的梯度. 2) 胞体响应关于突触电流的梯度. 3) 突触电流关于权重的梯度. 其中, 第 1 项损失函数关于胞体响应的梯度可以通过相应的模型公式求得. 突触电流由连接权重计算而来, 与连接权重直接相关, 因此第 3 项突触电流关于权重的梯度同样可以根据模型公式求得. 第 2 项胞体响应关于突触电流的梯度求解较为困难. 在精细神经元中, 突触电流在树突上产生, 在传导到胞体的过程中树突会对电流信号进行处理整合. 如前文所述, 由于树突对于电流信号的处理无法通过解析式精确描述, 因此无法直接求得胞体响应关于突触电流的梯度. 本文利用转移电导的概念将突触电流与胞体响应建立起显式关联, 由此可对第 2 项胞体响应关于突触电流的梯度进行近似. 至此, 以上 3 项梯度值均可求得, 从而可得到损失函数关于权重的梯度.

4.1 基于精细神经网络的图像分类模型 MSNNet

MSNNet 网络使用的精细神经元模型为中等棘突神经元 (MSN), 网络共包含 3 层神经元. 如图 2 所示, 输入层点神经元组成, 接受由图像转化而来的脉冲刺激; 隐藏层由精细神经元模型组成, 这里使用的精细模型为中等棘突神经元 (MSN), 隐藏层接受输入层神经元的胞体电压作为输入; 输出层同样由点神经元组成, 接受隐藏层神经元的胞体电压作为输入, 每个输出层神经元对应 1 个类别, 在图像分类时取响应最大的神经元所对应的类别作为最终分类结果. 下文将对 MSNNet 进行图像分类时的计算过程进行详细介绍.

输入图像首先被转化为脉冲信号. 对于每个输入图像, 模型首先将各像素值进行归一化, 然后根据归一化像素值生成均匀的脉冲序列作为网络输入. 对于图像中的每个像素, 其生成的脉冲序列发放频率 $f(x, y)$ 由归一化像素值 $i(x, y)$ 决定: $f(x, y) = 200 \times i(x, y)$.

输入层神经元使用点神经元进行建模, 只包含漏电导, 不包含离子通道. 每个神经元对应于一个像素点, 每个像素点产生的脉冲信号通过激活突触电流提升神经元的胞体电压, 神经元模型如下所示:

$$\begin{cases} c \frac{dv}{dt} = -g_L(v - E_L) + i_{syn} \\ i_{syn} = g_m \exp(-(t - t_{spk})/\tau) \times (v - E_{syn}) \end{cases} \quad (3)$$

其中, v 表示胞体电压; c 表示细胞膜电容; g_L 为漏电导, E_L 为漏电导的平衡电位; i_{syn} 为脉冲激活的突触电流; g_m 为突触电导的最大值, 为常数; t_{spk} 为接受到脉冲信号的时刻; τ 为电流衰减时间常数; E_{syn} 表示突触的平衡电位.

隐藏层神经元使用精细中等棘突神经元模型 (MSN), 模型形态使用已发表的相关数据构建^[35]. 模型中的树突与胞体均不包含离子通道, 只包含漏电导. 每一神经元的树突均与所有输入层神经元相连, 接受输入层神经元的胞体电压作为输入, 从而在树突上产生突触电流. 模型如下所示:

$$\begin{cases} c \frac{\partial v(t, x)}{\partial t} = \frac{\partial^2 v(t, x)}{\partial x^2} - g_L(v(t, x) - E_L) + \sum_j i_{\text{syn}}^j \\ i_{\text{syn}}^j = \begin{cases} w_h^j \times v_{\text{in}}^j, & v_{\text{in}}^j > 0 \\ 0, & v_{\text{in}}^j \leq 0 \end{cases} \end{cases} \quad (4)$$

其中, $v(t, x)$ 表示神经元各位点在不同时刻的电压, c 为细胞膜电容, g_L 表示细胞膜漏电导, E_L 表示漏电导的平衡电位, i_{syn}^j 为第 j 个输入层神经元在树突上产生的突触电流, w_h^j 为第 j 个输入层神经元与当前隐藏层神经元的连接权重, v_{in}^j 为第 j 个输入层神经元的胞体电压.

输出层同样使用点神经元模型, 模型只包含漏电导. 每个神经元接受所有隐藏层神经元的胞体电压作为输入, 具体模型如公式 (5) 所示, 其中, v 表示胞体电压; c 表示细胞膜电容; g_L 为漏电导, E_L 为漏电导的平衡电位; i_{syn}^j 为第 j 个输入层神经元产生的突触电流, 其计算方式与公式 (4) 中的突触电流相同.

$$c \frac{dv}{dt} = -g_L(v - E_L) + \sum_j i_{\text{syn}}^j \quad (5)$$

输出层神经元的电压响应用于计算最终的图像分类的结果. 具体计算方式如下: 首先取输出层神经元在一段时间内的平均电压作为最终响应, 对输出层神经元的平均电压响应进行 Softmax 函数计算得到当前图像属于各类的概率, 选取概率最大的一类作为最终分类结果. 公式 (6) 展示了各类概率的计算方式, 其中, p_i 表示当前输入图像属于 i 类的概率, \bar{v}_i 为第 i 个输出层神经元在一段时间内的平均响应, C 为总类别数目.

$$p_i = \frac{\exp(\bar{v}_i)}{\sum_{c=0}^{C-1} \exp(\bar{v}_c)} \quad (6)$$

4.2 MSNNet 学习规则

本文使用基于梯度的方法对 MSNNet 在图像分类任务上进行训练, 使 MSNNet 可以通过调整突触连接权重逼近目标响应, 完成图像分类任务.

本文所提学习方法通过损失函数关于权重的梯度对权重进行更新, 因此首先需要定义损失函数, 用于度量网络输出响应和目标响应之间的误差. 交叉熵损失函数是深度神经网络在多分类任务中常用的一种损失函数. 由于 MSNNet 同样处理多分类任务, 因此可使用交叉熵损失函数对其输出响应的误差进行度量. 具体计算方式如下所示:

$$L = - \sum_{i=0}^{C-1} y_i \log p_i \quad (7)$$

其中, p_i 表示模型判断输入样本属于类别 i 的概率, 计算方式如公式 (6) Softmax 函数所示; y_i 表示模型的期望输出, 即输入样本的真实类别, y_i 的值使用独热编码 (one-hot encoding) 的方式进行设置, 若样本属于类别 i , $y_i=1$, 否则 $y_i=0$.

根据损失函数和模型具体的计算方式, 可求得损失函数关于权重的梯度. MSNNet 对于每一输入样本均需要进行一段时间的仿真. 进行训练时, 对于每一输入样本, 在仿真中的每一时刻均对梯度 Δw_{ij}^t 进行计算, 完成当前输入样本的仿真后, 取所有时刻 Δw_{ij}^t 的均值作为最终的梯度对权重 w_{ij} 进行更新. 具体更新方式如公式 (8) 所示, 其中, w_{ij} 表示前一层神经元 i 连接到当前层神经元 j 的权重; η 表示学习率; Δw_{ij}^t 表示所求得的 t 时刻梯度; dt 表示

仿真中所使用的时间步长; t_{start} 、 t_{end} 分别为梯度计算的开始和结束时刻.

$$\begin{cases} w_{ij} = w_{ij} - \eta \Delta \bar{w}_{ij} \\ \Delta \bar{w}_{ij} = \frac{dt}{t_{\text{end}} - t_{\text{start}}} \sum_{t=t_{\text{start}}}^{t_{\text{end}}} \Delta w'_{ij} \end{cases} \quad (8)$$

每一时刻的梯度 $\Delta w'_{ij}$ 可通过所提出的学习方法求得. 如前文所述, 通过链式法则可将损失函数关于权重的梯度转换为损失函数关于胞体响应的梯度、胞体响应关于突触电流的梯度、突触电流关于权重的梯度 3 项乘积, 通过转移电导进行逼近, 最终可得到梯度的近似值. 将所提学习方法应用于 MSNNet, 可得到每一时刻的梯度 $\Delta w'_{ij}$ 的计算方式:

$$\Delta w'_{ij} = \frac{\partial L}{\partial w'_{ij}} = \frac{\partial L}{\partial v'_j} \frac{\partial v'_j}{\partial w'_{ij}} = \frac{\partial L}{\partial v'_j} \frac{\partial v'_j}{\partial i \text{syn}'_{ij}} \frac{\partial i \text{syn}'_{ij}}{\partial w'_{ij}} \approx \frac{\partial L}{\partial v'_j} \times G_{ij} \times v'_i \quad (9)$$

其中, v'_j 表示神经元 j 在 t 时刻的胞体电压值; $i \text{syn}'_{ij}$ 表示在 t 时刻, 神经元 i 在神经元 j 上引起的突触电流, 计算方式如公式 (4) 所示, 由此可知突触电流关于权重的梯度为 v'_i ; G_{ij} 为在神经元 j 上, 前层神经元 i 所连接的位置到神经元 j 胞体之间的转移电导. 转移电导定义如下: 在精细神经元 j 的树突 i 位置输入恒定突触电流 I_i , 该电流在胞体产生电压响应 v_j , 则转移电导 G_{ij} 表示 i 处突触电流对胞体电压的影响, 计算方式如公式 (10) 所示. 因此, 胞体响应关于突触电流的梯度可用转移电导 G_{ij} 逼近. 给定精细神经元模型后, 树突各位点的转移电导即随着模型的形态以及生理特性所确定. 特别地, 对于点神经元模型, 由于其不存在树突结构, 转移电导即为神经元胞体的电导值.

$$G_{ij} = \frac{v_j}{I_i} \quad (10)$$

输出层和隐藏层在计算公式 (9) 中损失函数关于电压的梯度时有所区别. 对于输出层神经元, 该项可直接由模型响应以及目标输出计算而来, 如公式 (11) 所示; 对于隐藏层神经元, 该梯度项需要借助输出层神经元中该项的值进行计算, 如公式 (12) 所示:

$$\frac{\partial L}{\partial v'_{oj}} = y_j - p'_{oj} \quad (11)$$

$$\frac{\partial L}{\partial v'_{hj}} = \sum_{c=0}^{c-1} \frac{\partial L}{\partial v'_{oc}} w_{jc} \times G_{jc} \quad (12)$$

其中, v'_{oj} 表示输出层神经元 j 在 t 时刻的胞体电压; v'_{hj} 表示隐藏层神经元 j 在 t 时刻的胞体电压; y_j 为目标输出; p'_{oj} 表示由 t 时刻响应所求得分类概率; w_{jc} 为隐藏层神经元 j 和输出层神经元 c 之间的连接权重; G_{jc} 为输出层神经元 c 的转移电导, 由于输出层使用点神经元模型, 因此 G_{jc} 取值为细胞体电导值. 将公式 (11)、公式 (12) 代入公式 (9), 即可得到各连接权重的梯度, 由此可对网络中的连接权重进行更新, 使网络响应逼近目标响应.

5 实验分析

5.1 实验数据及评价指标

为验证学习方法以及精细神经网络模型在图像分类任务上的有效性, 本文使用经典数据集 MNIST 和 Fashion-MNIST 进行实验.

MNIST 数据集由手写数字构成, 是图像分类任务中最经典的数据集, 共包含 70 000 张图像, 其中训练集由 60 000 张图像组成, 测试集由 10 000 图像组成. MNIST 中的图像均为 28×28 大小的灰度图. 图像共分为 10 类, 每一类对应于数字 0-9.

Fashion-MNIST 数据集的图像数目、训练集和测试集划分、图像大小以及类别数目均与 MNIST 相同, 在模型的训练和测试中可直接对 MNIST 数据集进行替代. 不同于 MNIST, Fashion-MNIST 图像内容为 T 恤、裤子、外套等服装, 相比于 MNIST 的手写数字更具有挑战性.

由于所使用的数据集包含多个类别,对模型性能进行评价时,本文使用常用的测试集上分类准确率作为评价指标,并与现有方法进行对比验证方法的有效性.现有精细神经元上的学习方法主要基于单神经元,无法完成图像分类这一类的感知任务,只有部分基于简化树突模型的学习方法在 MNIST 数据集上进行了相关实验.因此本文与相关简化树突模型上的学习方法进行了性能对比.此外,为进一步验证学习方法的有效性,本文同样将 MSNNet 与对应结构的人工神经网络在两种数据集上分别进行了对比.

5.2 模型设置及实验方法

实验中使用的 MSNNet 具体结构如下:输入层包含 784 个神经元,与 28×28 的图像尺寸相对应,每个神经元接受图像中 1 个像素转换而来的脉冲序列作为输入;隐藏层包含 64 个中型多棘精细神经元模型 (MSN),输入层与隐藏层使用全连接的方式,输入层神经元所连接到的树突位置为随机选取;输出层包含 10 个点神经元模型,对应于 10 个类别,隐藏层与输出层的连接方式同样使用全连接.表 1 列出了点神经元与隐藏层精细神经元相关参数的取值,输入层与输出层点神经元的相关参数相同.模型中的电容、电导等参数均有其对应的生物物理意义,因此在具体实现时参考相关生理参数进行设置.

表 1 模型参数设置

参数类型	参数	数值
点神经元模型参数	c	$1.0 \mu\text{F}/\text{cm}^2$
	g_L	$1.0\text{E}-4 \text{ S}/\text{cm}^2$
	E_L	0 mV
输入层突触参数	g_m	0.05 μS
	E_{syn}	1 mV
	τ	0.5 ms
精细神经元模型参数	c	$0.5 \mu\text{F}/\text{cm}^2$
	g_L	$1.25\text{E}-5 \text{ S}/\text{cm}^2$
	E_L	0 mV

MSNNet 的训练与测试均在扩展的 CoreNEURON 仿真平台上进行实现^[26].精细神经元模型由于其本身的复杂性在仿真时需要进行大量计算.进行训练时,模型需要对训练集中所有训练样本进行多轮仿真.因此,较低的仿真效率将极大程度上限制整个训练过程的实现.CoreNEURON^[33]仿真平台支持 GPU 上的精细神经网络仿真,是目前最高效的精细神经网络仿真平台.然而,CoreNEURON 平台针对传统生物物理仿真进行设计,只能接受固定刺激输入与模型,并进行仿真得到相应的模型响应,无法支持多样本的输入以及在仿真过程中改变模型的连接权重等状态,因此无法支持网络的学习.扩展 CoreNEURON 平台基于 GPU 实现了数据集处理以及仿真中的权重更新模块,并与原有仿真计算部分进行适配,使整体训练过程均可在 GPU 上进行,大幅提升精细神经网络在进行图像分类任务中的计算效率^[26].实验中,MSNNet 分别在 MNIST 与 Fashion-MNIST 数据集上使用扩展的 CoreNEURON 平台进行训练,并在测试集上对分类准确率进行测试.训练使用基于 mini-batch 的方式进行,以提升训练效果,训练中 batch-size 设置为 4.

本文对比了人工神经网络 (ANN) 在相同任务上的性能以验证 MSNNet 在图像分类任务中的有效性.为保证对比公平,我们构建了一个与 MSNNet 具有相同参数数目的人工神经网络.网络同样包含 3 层结构,输入层包含 784 个神经元,对应于图像中的每个像素值,各神经元的输出为归一化后的像素值;隐藏层包含 64 个神经元,与输入层全连接,各神经元的激活函数为 ReLU;输出层包含 10 个神经元,与隐藏层全连接,各神经元的输出经过 Softmax 函数进行计算后得到输入图像属于各类的概率.由于 ANN 中各层神经元数目与 MSNNet 相同,且都使用全连接的方式,因此两种网络可训练的权重数目相同.ANN 同样使用基于 mini-batch 的随机梯度下降算法进行训练,训练所用的损失函数为交叉熵损失, batch-size 设置为 4.ANN 的训练和测试均使用 GPU 版本的 TensorFlow 2.6.0 框架实现.

本文进一步探究了树突在图像分类中所发挥的作用. 相关深度学习领域研究表明, 受生物计算机机制启发的模型可以帮助神经网络提升在噪声干扰下的鲁棒性^[36,37]. 受此启发, 本文对神经网络模型在噪声干扰下的鲁棒性进行探究. 实验中, MSNNet 在原始数据集上进行训练, 完成训练后, 在带有噪声的测试集上对其分类性能进行测试. 本文所使用的噪声为图像中常见的高斯噪声、乘性噪声和椒盐噪声. 为尽可能覆盖更多情况, 我们对 MSNNet 在不同强度的 3 种噪声干扰下均进行了测试. 高斯噪声的强度由高斯分布的标准差决定, 此处对标准差为 {0.05, 0.1, 0.15, 0.2, 0.25} 的高斯噪声进行测试. 乘性噪声的强度同样由生成噪声的高斯分布中的标准差决定, 由于在 MNIST 和 Fashion-MNIST 数据集上乘性噪声的影响相对较小, 因此这里使用相比高斯噪声更大的标准差生成乘性噪声, 此处乘性噪声的标准差设置为 {0.1, 0.2, 0.3, 0.4, 0.5}. 不同于前两类噪声, 椒盐噪声的强度由噪声所覆盖的像素占比决定, 实验中将强度设置为 {0.05, 0.1, 0.15, 0.2, 0.25}, 即噪声干扰的像素占比为 5%–25%. 实验中的所有噪声图像均由 Python 上的图像处理库 scikit-image^[38]生成, 图 5 展示了不同类型的噪声图像.

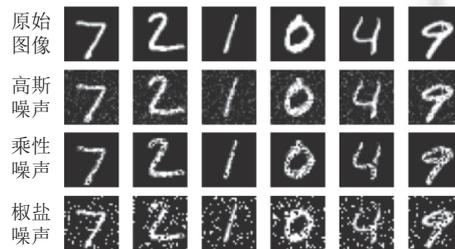


图 5 噪声图像示例

5.3 实验结果与分析

为验证所提出学习方法在图像分类上的有效性, 本文测试了 MSNNet 在图像分类任务中的性能以及在噪声干扰下的鲁棒性, 并与现有精细神经元学习方法以及人工神经网络 (ANN) 进行对比.

本文首先对 MSNNet 在图像分类中的性能进行测试, 并与简化树突神经元上的学习方法以及 ANN 进行性能对比. 图 6 展示了学习过程中测试集上分类准确率的变化, 由实验结果可见, MSNNet 在两种数据集上均有很好的收敛效果, 可以取得与神经网络可取得接近的性能. 表 2 展示了不同方法 (除了 ANN, 其余均是简化树突模型上的学习方法) 的分类性能对比, MSNNet 在两个数据集上均有很好的表现, 可达到与神经网络接近的性能. 与现有简化树突模型上的学习方法相比, MSNNet 在更加逼近生物真实、更具有生物可解释性的情况下有更好的分类性能. 相比于 Guerguiev 等人^[11]的学习方法, MSNNet 的参数量更少, 且学习效果更好. 相比 Sacramento 等人^[9]的方法, MSNNet 在参数量仅为 8% 的情况下可取得与其接近的性能. 以上性能测试验证了所提出的模型以及学习方法在图像分类感知任务上的有效性.

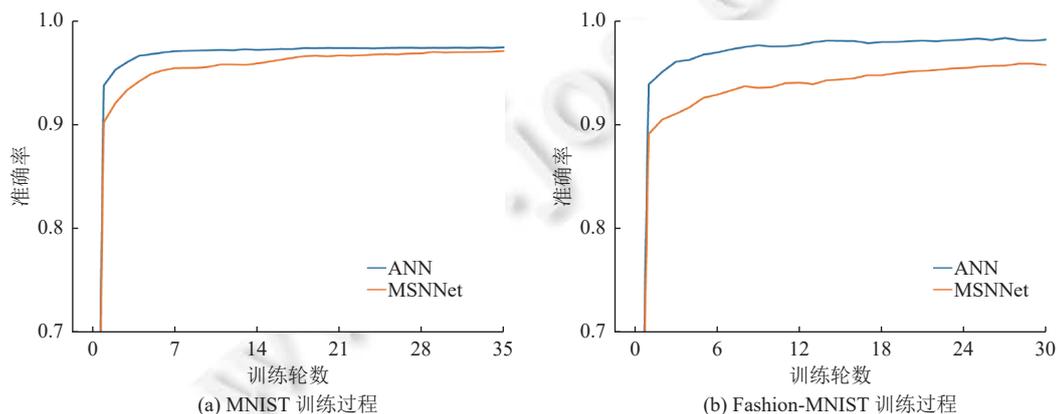


图 6 MSNNet 与 ANN 训练过程对比

表2 图像分类性能对比

方法	网络结构	MNIST	Fashion-MNIST
ANN	784-64-10	0.9741	0.8785
Guerguiev等人 ^[11]	784-500-10	0.9590	—
Guerguiev等人 ^[11]	784-500-100-10	0.9680	—
Sacramento等人 ^[9]	784-500-500-10	0.9804	—
G-clusteron ^[18]	784-10	0.891	—
MSNNet	784-64-10	0.9704	0.8574

我们对相关结果以及方法进行了分析, 推测方法之间的性能差异主要由梯度计算的不同产生. 树突模型由于计算机制较为复杂, 无法直接求得梯度. 相关模型中的学习方法可以看作在树突模型的计算机制上对梯度的逼近. 逼近时的误差导致模型最终在图像分类任务中性能有所下降. 例如, Guerguiev 等人^[11]使用了随机的反馈权重, 导致求得的梯度与误差减小方向存在一定差距. 相比于现有方法, 本文方法求得的梯度近似更接近真实值.

本文接着对 MSNNet 模型的特性进行探究, 以理解模型通过学习完成图像分类任务的机理. 本文对 MSNNet 中的隐藏层神经元在学习前后的响应进行对比, 以探究模型可以很好完成图像分类任务的原因. 图7展示了隐藏层神经元响应在学习前后的变化. 在学习前, 同一神经元对于不同输入样本的响应非常接近(图7(a1)), 隐藏层神经元近似的电压响应导致 MSNNet 无法对不同样本进行区分. 学习后, 同一神经元对不同输入的响应有明显区别, 使得网络对不同输入可以很好地进行区分(图7(a2)). 图7(b)展示了不同神经元在某一时刻对于同一输入样本的响应. 在学习前, 不同神经元对于同一输入有着非常接近的响应, 且响应均较低(图7(b1)); 学习后, 不同神经元对于同一输入的响应有明显差别, 部分神经元对于当前输入产生较强响应, 部分神经元的响应甚至在接收到输入后甚至被削弱(图7(b2)). 由于输出层神经元与隐藏层神经元为全连接, 因此不同神经元响应区分度的提升可进一步提升网络对不同输入的区分.

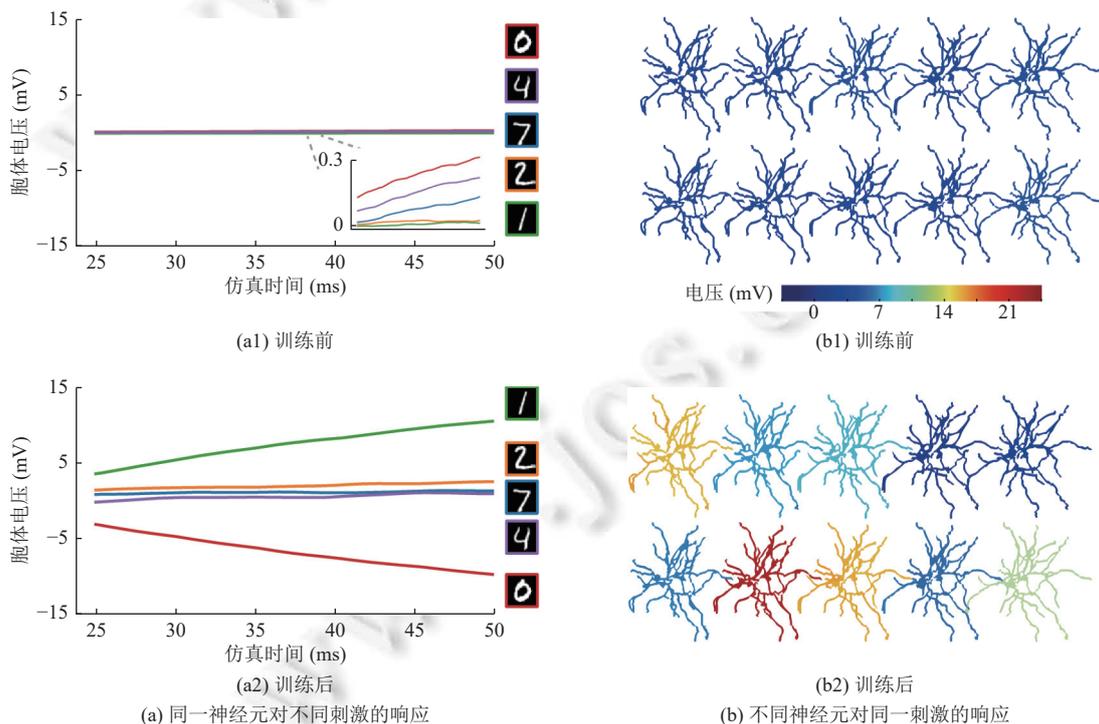


图7 隐藏层神经元学习前后响应对比

总而言之, MSNNet 在学习后可以完成图像分类任务的主要原因如下: (1) 学习后网络中的神经元对输入刺激产生选择性, 即在接收到神经元所偏好的刺激时会产生较强的响应. (2) 不同神经元所偏好的刺激各不相同. 不同神经元对不同刺激具有选择性是神经科学中的一个经典现象^[39,40]. MSNNet 中的神经元在学习后产生了刺激选择性这一现象表明所提出的模型和学习方法在一定程度上符合真实大脑的信号处理特性.

现有工作表明, 受树突突触机制启发的人工神经网络模型对于噪声有一定的鲁棒性^[37], 此外, 相关神经科学上的研究表明树突可使神经元的刺激选择性较为稳定^[41]. 由此我们猜测树突结构可使网络在噪声干扰下取得鲁棒的图像分类性能. 因此本文进一步对 MSNNet 在噪声下的鲁棒性进行测试, 以此验证树突对于噪声的防御作用. 实验中, 模型在不带噪声的原始数据集上进行训练, 在被噪声干扰的测试集上进行性能测试, 所选取的噪声为图像中常见的高斯噪声、乘性噪声以及椒盐噪声, 具体设置如第 5.2 节所示. 本文在人工神经网络上进行了同样的测试, 通过性能对比验证 MSNNet 对噪声干扰的鲁棒性. 实验所使用的人工神经网络与前文相同, 各层神经元数目为 784-64-10, 以此保证两种网络的参数量相同.

图 8、图 9 分别展示了模型在 MNIST 和 Fashion-MNIST 数据集上抵抗噪声干扰的实验结果. 由实验结果可见, MSNNet 在两个数据集上表现出的特性相似, 在不同类型噪声的干扰下均有较好的鲁棒性. 对于高斯噪声, 在强度较小时, 噪声对 ANN 和 MSNNet 的影响均较小, 这是由于高斯噪声由对应高斯分布产生, 较小的标准差导致所产生的高斯噪声的幅度也较小. 当高斯噪声强度增大时, 两种模型在噪声干扰下分类准确率均有下降, 相比于 ANN, MSNNet 在噪声较大时性能下降较少. 乘性噪声由于和原始图像为相乘的关系, 而 MNIST 和 Fashion-MNIST 中的图像大部分像素值均为 0, 因此乘性噪声对两种模型的性能影响均相对较小. 相比于前两种噪声, 椒盐噪声对于原始图像的干扰较强, 即使在强度较小的情况下模型的性能也有较明显的下降. 同样地, MSNNet 在椒盐噪声的干扰下有较强的鲁棒性, 相比于 ANN 分类准确率更高.

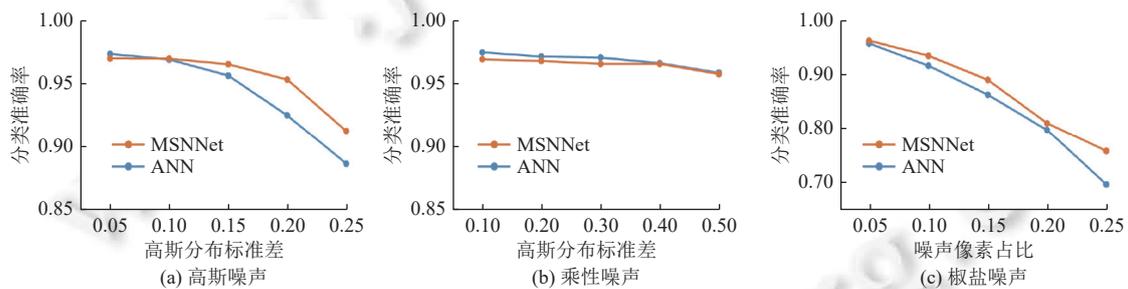


图 8 MNIST 上两种模型对于噪声图像的分类性能

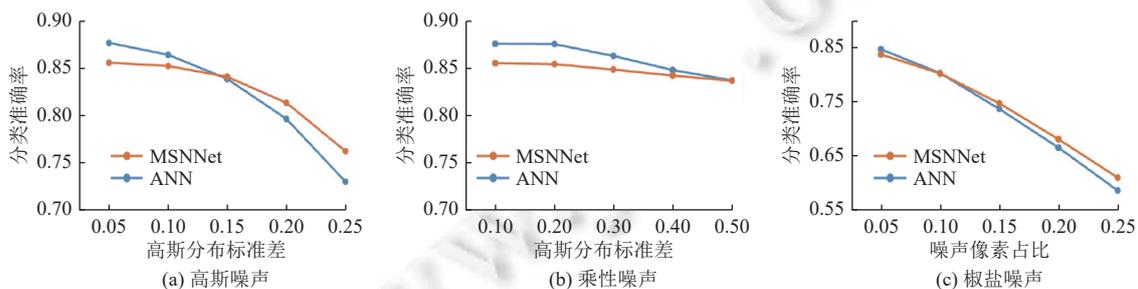


图 9 Fashion-MNIST 上两种模型对于噪声图像的分类性能

综上所述, MSNNet 在各类噪声的干扰下均比人工神经网络有更好的分类准确率, 表明其相比于人工神经网络有更强的鲁棒性. 由于模型中不存在其他处理噪声的机制, 因此 MSNNet 对于噪声的鲁棒性是由模型本身导致的, 这从一定程度上验证了树突对噪声干扰的防御作用.

6 总 结

基于精细神经元的学习模型有助于探究真实大脑的信息处理机制以及学习过程, 甚至启发新型人工智能算法. 针对当前精细神经元学习中存在的问题, 本文构建了一种基于精细神经网络模型 MSNNet, 并提出相应学习方法. 所提出的学习方法使用基于梯度的方式对模型中的突触连接权重进行更新, 通过转移电导将胞体响应和树突上的突触电流输入建立起联系, 可以对梯度值进行近似, 以此解决精细神经网络模型中梯度求解困难的问题. 通过在经典图像分类任务上的实验以及对相关方法的性能对比, 验证了本文所提学习模型的有效性. 学习后网络中的神经元所表现出了神经科学中经典的刺激偏好现象, 从一定程度上验证了所提方法的生物可解释性. 此外, 实验表明精细神经网络在噪声干扰下具有较好的鲁棒性, 验证了树突在抵抗噪声干扰中的作用.

在后续工作中, 我们将考虑在更复杂的神经元模型上实现感知学习, 以实现更接近大脑的学习模型. 例如, 使用规模更大、层数更多的网络构建学习模型, 或使用带有离子通道的神经元模型. 然而, 当模型更为复杂时, 巨大的计算量成为仿真中的一大挑战, 需要更高效的仿真平台提升计算效率. 此外, 树突计算也可能使用硬件实现, 若类脑芯片可支持树突神经网络的仿真计算, 将极大程度提升仿真效率. 精细树突网络仿真主要包含以下流程: 1) 传输脉冲信号. 2) 计算树突各计算单元的离子通道电流和突触电流. 3) 计算树突各位置的轴向电流. 4) 求解神经元对应的线性方程组. 5) 更新所有计算单元的电压. 其中, 计算过程 1)、2)、5) 与点神经元类似, 可将树突的每个计算单元均看成动力学相对复杂的点神经元. 计算过程 3) 和 4) 为树突模型特有. 树突模型的计算单元呈树状结构组织, 计算过程 3) 主要对相邻计算单元产生的电流进行计算. 计算过程 4) 对前 3 个过程构建得到的线性方程组进行求解, 线性方程组的系数矩阵为稀疏矩阵, 其形式与神经元对应的树结构的邻接矩阵相同, 方程组可用高斯消元法进行求解. 若针对计算过程 3) 和 4) 两进行硬件涉及, 则精细树突神经元的整体仿真均可使用硬件实现, 使得精细模型在真实场景中的应用成为可能.

References:

- [1] LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*, 2015, 521(7553): 436–444. [doi: [10.1038/nature14539](https://doi.org/10.1038/nature14539)]
- [2] Meng LR, Ding GY, Xu C, Qian WN, Zhou AY. Survey of novel video analysis systems based on deep learning. *Ruan Jian Xue Bao/Journal of Software*, 2022, 33(10): 3635–3655 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/6631.htm> [doi: [10.13328/j.cnki.jos.006631](https://doi.org/10.13328/j.cnki.jos.006631)]
- [3] Schrittwieser J, Antonoglou I, Hubert T, Simonyan K, Sifre L, Schmitt S, Guez A, Lockhart E, Hassabis D, Graepel T, Lillicrap T, Silver D. Mastering Atari, Go, chess and shogi by planning with a learned model. *Nature*, 2020, 588(7839): 604–609. [doi: [10.1038/s41586-020-03051-4](https://doi.org/10.1038/s41586-020-03051-4)]
- [4] Vinyals O, Babuschkin I, Czarnecki WM, *et al.* Grandmaster level in StarCraft II using multi-agent reinforcement learning. *Nature*, 2019, 575(7782): 350–354. [doi: [10.1038/s41586-019-1724-z](https://doi.org/10.1038/s41586-019-1724-z)]
- [5] Silver D, Huang A, Maddison CJ, Guez A, Sifre L, van den Driessche G, Schrittwieser J, Antonoglou I, Panneershelvam V, Lanctot M, Dieleman S, Grewe D, Nham J, Kalchbrenner N, Sutskever I, Lillicrap T, Leach M, Kavukcuoglu K, Graepel T, Hassabis D. Mastering the game of Go with deep neural networks and tree search. *Nature*, 2016, 529(7587): 484–489. [doi: [10.1038/nature16961](https://doi.org/10.1038/nature16961)]
- [6] Huang TJ, Shi LP, Tang HJ, Pan G, Chen YJ, Yu JQ. Research on multimedia technology 2015—Advances and trend of brain-like computing. *Journal of Image and Graphics*, 2016, 21(11): 1411–1424 (in Chinese with English abstract). [doi: [10.11834/jig.20161101](https://doi.org/10.11834/jig.20161101)]
- [7] Zeng Y, Liu CL, Tan TN. Retrospect and outlook of brain-inspired intelligence research. *Chinese Journal of Computers*, 2016, 39(1): 212–222 (in Chinese with English abstract). [doi: [10.11897/SP.J.1016.2016.00212](https://doi.org/10.11897/SP.J.1016.2016.00212)]
- [8] Lillicrap TP, Santoro A, Marris L, Akerman CJ, Hinton G. Backpropagation and the brain. *Nature Reviews Neuroscience*, 2020, 21(6): 335–346. [doi: [10.1038/s41583-020-0277-3](https://doi.org/10.1038/s41583-020-0277-3)]
- [9] Sacramento J, Costa RP, Bengio Y, Senn W. Dendritic cortical microcircuits approximate the backpropagation algorithm. In: *Proc. of the 32nd Conf. on Neural Information Processing Systems*. Montréal: Curran Associates Inc., 2018. 8735–8746. [doi: [10.5555/3327546.3327550](https://doi.org/10.5555/3327546.3327550)]
- [10] Payeur A, Guerguiev J, Zenke F, Richards BA, Naud R. Burst-dependent synaptic plasticity can coordinate learning in hierarchical circuits. *Nature Neuroscience*, 2021, 24(7): 1010–1019. [doi: [10.1038/s41593-021-00857-x](https://doi.org/10.1038/s41593-021-00857-x)]
- [11] Guerguiev J, Lillicrap TP, Richards BA. Towards deep learning with segregated dendrites. *eLife*, 2017, 6: e22901. [doi: [10.7554/eLife](https://doi.org/10.7554/eLife)]

- 22901]
- [12] Poirazi P, Papoutsi A. Illuminating dendritic function with computational models. *Nature Reviews Neuroscience*, 2020, 21(6): 303–321. [doi: [10.1038/s41583-020-0301-7](https://doi.org/10.1038/s41583-020-0301-7)]
- [13] Einevoll GT, Destexhe A, Diesmann M, Grün S, Jirsa V, de Kamps M, Migliore M, Ness TV, Plesser HE, Schürmann F. The scientific case for brain simulations. *Neuron*, 2019, 102(4): 735–744. [doi: [10.1016/j.neuron.2019.03.027](https://doi.org/10.1016/j.neuron.2019.03.027)]
- [14] Beniaguev D, Segev I, London M. Single cortical neurons as deep artificial neural networks. *Neuron*, 2021, 109(17): 2727–2739.e3. [doi: [10.1016/j.neuron.2021.07.002](https://doi.org/10.1016/j.neuron.2021.07.002)]
- [15] Poirazi P, Brannon T, Mel BW. Pyramidal neuron as two-layer neural network. *Neuron*, 2003, 37(6): 989–999. [doi: [10.1016/S0896-6273\(03\)00149-1](https://doi.org/10.1016/S0896-6273(03)00149-1)]
- [16] Häusser M, Mel B. Dendrites: Bug or feature? *Current Opinion in Neurobiology*, 2003, 13(3): 372–383. [doi: [10.1016/S0959-4388\(03\)00075-8](https://doi.org/10.1016/S0959-4388(03)00075-8)]
- [17] Poirazi P, Mel BW. Impact of active dendrites and structural plasticity on the memory capacity of neural tissue. *Neuron*, 2001, 29(3): 779–796. [doi: [10.1016/S0896-6273\(01\)00252-5](https://doi.org/10.1016/S0896-6273(01)00252-5)]
- [18] Moldwin T, Kalmenson M, Segev I. The gradient clusteron: A model neuron that learns to solve classification tasks via dendritic nonlinearities, structural plasticity, and gradient descent. *PLoS Computational Biology*, 2021, 17(5): e1009015. [doi: [10.1371/journal.pcbi.1009015](https://doi.org/10.1371/journal.pcbi.1009015)]
- [19] Bicknell BA, Häusser M. A synaptic learning rule for exploiting nonlinear dendritic computation. *Neuron*, 2021, 109(24): 4001–4017.e10. [doi: [10.1016/j.neuron.2021.09.044](https://doi.org/10.1016/j.neuron.2021.09.044)]
- [20] Moldwin T, Segev I. Perceptron learning and classification in a modeled cortical pyramidal cell. *Frontiers in Computational Neuroscience*, 2020, 14: 33. [doi: [10.3389/fncom.2020.00033](https://doi.org/10.3389/fncom.2020.00033)]
- [21] Chavlis S, Poirazi P. Drawing inspiration from biological dendrites to empower artificial neural networks. *Current Opinion in Neurobiology*, 2021, 70: 1–10. [doi: [10.1016/j.conb.2021.04.007](https://doi.org/10.1016/j.conb.2021.04.007)]
- [22] Gerfen CR, Surmeier DJ. Modulation of striatal projection systems by dopamine. *Annual Review of Neuroscience*, 2011, 34: 441–466. [doi: [10.1146/annurev-neuro-061010-113641](https://doi.org/10.1146/annurev-neuro-061010-113641)]
- [23] Kreitzer AC. Physiology and pharmacology of striatal neurons. *Annual Review of Neuroscience*, 2009, 32: 127–147. [doi: [10.1146/annurev-neuro.051508.135422](https://doi.org/10.1146/annurev-neuro.051508.135422)]
- [24] Hjorth JJJ, Kozlov A, Carannante I, Nysten JF, Lindroos R, Johansson Y, Tokarska A, Dorst MC, Suryanarayana SM, Silberberg G, Kotaleski JH, Grillner S. The microcircuits of striatum in silico. *Proc. of the National Academy of Sciences of the United States of America*, 2020, 117(17): 9554–9565. [doi: [10.1073/pnas.2000671117](https://doi.org/10.1073/pnas.2000671117)]
- [25] Urbanczik R, Senn W. Learning by the dendritic prediction of somatic spiking. *Neuron*, 2014, 81(3): 521–528. [doi: [10.1016/j.neuron.2013.11.030](https://doi.org/10.1016/j.neuron.2013.11.030)]
- [26] Zhang YC, He G, Liu XF, Hjorth JJJ, Kozlov A, He YT, Zhang SJ, Ma L, Kotaleski J, Tian YH, Grillner S, Du K, Huang TJ. A GPU-based computational framework that bridges neuron simulation and artificial intelligence. Technical Report, Beijing: Peking University, 2022. [doi: [10.21203/rs.3.rs-1749714/v1](https://doi.org/10.21203/rs.3.rs-1749714/v1)]
- [27] Payeur A, Béique JC, Naud R. Classes of dendritic information processing. *Current Opinion in Neurobiology*, 2019, 58: 78–85. [doi: [10.1016/j.conb.2019.07.006](https://doi.org/10.1016/j.conb.2019.07.006)]
- [28] Schiess M, Urbanczik R, Senn W. Somato-dendritic synaptic plasticity and error-backpropagation in active dendrites. *PLoS Computational Biology*, 2016, 12(2): e1004638. [doi: [10.1371/journal.pcbi.1004638](https://doi.org/10.1371/journal.pcbi.1004638)]
- [29] Hodgkin AL, Huxley AF. A quantitative description of membrane current and its application to conduction and excitation in nerve. *The Journal of Physiology*, 1952, 117(4): 500–544. [doi: [10.1113/jphysiol.1952.sp004764](https://doi.org/10.1113/jphysiol.1952.sp004764)]
- [30] Rall W. Branching dendritic trees and motoneuron membrane resistivity. *Experimental Neurology*, 1959, 1(5): 491–527. [doi: [10.1016/0014-4886\(59\)90046-9](https://doi.org/10.1016/0014-4886(59)90046-9)]
- [31] Bower JM, Beeman D. Neural modeling with GENESIS. In: Bower JM, Beeman D, eds. *The Book of GENESIS: Exploring Realistic Neural Models with the General Neural Simulation System*. New York: Springer, 1998. 17–27. [doi: [10.1007/978-1-4612-1634-6_3](https://doi.org/10.1007/978-1-4612-1634-6_3)]
- [32] Hines ML, Carnevale NT. The NEURON simulation environment. *Neural Computation*, 1997, 9(6): 1179–1209. [doi: [10.1162/neco.1997.9.6.1179](https://doi.org/10.1162/neco.1997.9.6.1179)]
- [33] Kumbhar P, Hines M, Fouriaux J, Ovcharenko A, King J, Delalondre F, Schürmann F. CoreNEURON: An optimized compute engine for the NEURON simulator. *Frontiers in Neuroinformatics*, 2019, 13: 63. [doi: [10.3389/fninf.2019.00063](https://doi.org/10.3389/fninf.2019.00063)]
- [34] Rumelhart DE, Hinton GE, Williams RJ. Learning representations by back-propagating errors. *Nature*, 1986, 323(6088): 533–536. [doi: [10.1038/323533a0](https://doi.org/10.1038/323533a0)]

- [35] Lindroos R, Dorst MC, Du K, Filipović M, Keller D, Ketzef M, Kozlov AK, Kumar A, Lindahl M, Nair AG, Pérez-Fernández J, Grillner S, Silberberg G, Kotaleski JH. Basal ganglia neuromodulation over multiple temporal and structural scales—Simulations of direct pathway MSNs investigate the fast onset of dopaminergic effects and predict the role of Kv4.2. *Frontiers in Neural Circuits*, 2018, 12: 3. [doi: [10.3389/fncir.2018.00003](https://doi.org/10.3389/fncir.2018.00003)]
- [36] Nayebi A, Ganguli S. Biologically inspired protection of deep networks from adversarial attacks. arXiv:1703.09202, 2017.
- [37] Krotov D, Hopfield J. Dense associative memory is robust to adversarial inputs. *Neural Computation*, 2018, 30(12): 3151–3167. [doi: [10.1162/neco_a_01143](https://doi.org/10.1162/neco_a_01143)]
- [38] van der Walt S, Schönberger JL, Nunez-Iglesias J, Boulogne F, Warner JD, Yager N, Gouillart E, Yu T. scikit-image: Image processing in Python. *PeerJ*, 2014, 2: e453. [doi: [10.7717/peerj.453](https://doi.org/10.7717/peerj.453)]
- [39] Hubel DH, Wiesel TN. Receptive fields and functional architecture of monkey striate cortex. *The Journal of Physiology*, 1968, 195(1): 215–243. [doi: [10.1113/jphysiol.1968.sp008455](https://doi.org/10.1113/jphysiol.1968.sp008455)]
- [40] Quiroga RQ. Concept cells: The building blocks of declarative memory functions. *Nature Reviews Neuroscience*, 2012, 13(8): 587–597. [doi: [10.1038/nrn3251](https://doi.org/10.1038/nrn3251)]
- [41] Cazé RD, Jarvis S, Foust AJ, Schultz SR. Dendrites enable a robust mechanism for neuronal stimulus selectivity. *Neural Computation*, 2017, 29(9): 2511–2527. [doi: [10.1162/neco_a_00989](https://doi.org/10.1162/neco_a_00989)]

附中文参考文献:

- [2] 孟令睿, 丁光耀, 徐辰, 钱卫宁, 周傲英. 基于深度学习的新型视频分析系统综述. *软件学报*, 2022, 33(10): 3635–3655. <http://www.jos.org.cn/1000-9825/6631.htm> [doi: [10.13328/j.cnki.jos.006631](https://doi.org/10.13328/j.cnki.jos.006631)]
- [6] 黄铁军, 施路平, 唐华锦, 潘纲, 陈云霁, 于俊清. 多媒体技术研究: 2015——类脑计算的研究进展与发展趋势. *中国图象图形学报*, 2016, 21(11): 1411–1424. [doi: [10.11834/jig.20161101](https://doi.org/10.11834/jig.20161101)]
- [7] 曾毅, 刘成林, 谭铁牛. 类脑智能研究的回顾与展望. *计算机学报*, 2016, 39(1): 212–222. [doi: [10.11897/SP.J.1016.2016.00212](https://doi.org/10.11897/SP.J.1016.2016.00212)]



张祎晨(1993—), 男, 博士生, 主要研究领域为类脑计算.



杜凯(1980—), 男, 博士, 助理研究员, 主要研究领域为计算神经科学, 类脑计算.



何千(1996—), 男, 博士生, CCF 学生会会员, 主要研究领域为人工智能, 树突计算.



黄铁军(1970—), 男, 博士, 教授, 博士生导师, CCF 会士, 主要研究领域为视觉信息处理, 神经形态计算.