

• 第二十七届中国科协年会学术论文 •

基于证据积累的认知决策神经网络模型*

陈思羽 潘晚珂 胡传鹏

(南京师范大学心理学院; 江苏省高校哲学社会科学实验室——
南京师范大学青少年教育与智能支持实验室, 南京 210097)

摘要 证据积累模型在反应时间建模领域已取得显著进展, 但该模型缺乏刺激编码等重要过程。结合人工神经网络, 研究者能够提取刺激特征并将其嵌入证据积累过程, 实现从刺激编码、认知加工到决策反应的全过程建模。基于证据积累的认知决策神经网络模型通常包含刺激加工、证据积累和决策判断三个模块, 其在多选项决策、时序刺激和神经激活模拟中展现了初步潜力。认知决策神经网络模型为模拟人类决策全过程提供了新途径, 未来可以与数字孪生脑等进行结合, 泛化到更复杂的决策情境, 推动对人类认知的深入理解。

关键词 认知过程, 证据积累模型, 计算建模, 人工神经网络

分类号 B841

1 引言

反应时间是理解人类决策过程的重要窗口(Luce, 1986)。自 Donders 于 1869 年提出了减法法, 反应时间测量分析方法成为实验心理学的核心, 研究者能够通过测量不同任务的反应时间, 推断出认知操作可能所需时间(Donders, 1969)。随着认知科学的演进, 反应时间分析已从单纯的测量工具升级为理论建模的重要载体, 对反应时间的建模逐渐成为了理解人类决策过程的关键手段(Ratcliff & McKoon, 2008)。

证据积累模型(evidence accumulation model, EAM)是对反应时间建模的主要计算框架之一(Ratcliff et al., 2016)。该模型的基本假设: 决策者会不断地从刺激或记忆中抽取信息, 积累与决策相关的证据, 当证据积累量达到特定决策阈值时, 就会产生可观测的反应及反应时间(刘逸康, 胡传鹏, 2024)。其关键假设得到部分神经数据的支持。例如, 研究表明, 猕猴在执行视觉运动辨别任务时, 其运动皮层神经元的放电率会呈现渐进

式累积, 当活动强度达到特定阈值时触发行为决策(Shadlen & Kiani, 2013)。这一神经动态特征与证据积累模型的预测高度一致, 即决策形成依赖于感官证据的持续整合直至跨越决策阈值。EAM 有多种模型实例化的数学形式与变式, 在本文中统称为“EAMs”。其中, 最经典的是漂移扩散模型(Drift Diffusion Model, DDM), 该模型通过基于维纳过程的随机过程模型实现证据积累, 具体表现为固定漂移率参数下, 累积增量与高斯噪声的组合。该模型能够有效解释速度与准确性权衡、正确与错误反应速度的不对称性, 以及反应时间分布的正偏态现象(Evans & Servant, 2020; Ratcliff & McKoon, 2008)。

然而, 根据 Marr 的信息处理三层次框架(Three-Level Framework, Marr 1982), EAMs 本质上仍然是统计模型, 是对决策行为结果数据的描述, 仅在较抽象层面对决策过程的算法进行假定, 却未提供从刺激编码到决策反应全过程的算法描述, 也未能对硬件层面(神经环路、分子细胞层面等)如何实现决策过程进行清晰的说明(Duggins & Eliasmith, 2025; Lo et al., 2015)。EAMs 所解释的实证研究结果通常是由人类或者灵长类神经系统这一硬件完成, 从这个角度来讲, EAMs 所描述的证据积累过程与人类或灵长类动物从编

收稿日期: 2025-05-10

* 国家自然科学基金(项目编号: 32471097)资助。

通信作者: 胡传鹏, E-mail: hcp4715@hotmail.com;

潘晚珂, E-mail: panwanke@163.com

码到决策的全过程是相对独立的(见图1)(Duggins & Eliasmith, 2025; Lo et al., 2015)。因此, EAMs 通过调整模型参数描述决策过程的方式, 未能考虑刺激特征与神经特征对于行为结果的影响。鉴于此, 构建涵盖从刺激加工、证据积累到反应输出的全过程模型, 在非生物硬件上对齐人类决策过程, 是理解人类决策的重要问题。

人工神经网络(Artificial Neural Network, ANN)为实现全过程的建构提供了可能, 其与证据积累理论框架的结合可能将认知建模推向新高度(Rajalingham et al., 2022; Kheradpisheh et al., 2016; Wichmann & Geirhos, 2023)。一方面, 早期人工神经网络研究将模式识别作为主要问题, 受人类感觉皮层结构启发而设计的深度神经网络(Deep Neural Network, DNN)模型, 能够完成对视觉刺激的编码, 弥补了 EAMs 对感觉信息加工的不足。例如, 最为经典的深度卷积神经网络 AlexNet 在对高挑战性的 ImageNet 数据集执行图像分类任务时表现优异, 研究者指出未来可以优化模型以缩小与人类视觉系统的差距(Krizhevsky et al., 2017)。另一方面, 脑启发的人工智能研究正尝试模拟人脑或者动物脑的生物神经回路。例如

基于生物神经框架构建的脉冲神经网络模型, 已能够产生与视觉皮层神经元放电类似的脉冲模式(Duggins & Eliasmith, 2025)。由此可见, 人工神经网络模型可以帮助研究者在硅基硬件(*in silico*)上实现决策行为的全过程, 从而为理解人类决策过程提供强大的工具。

目前已有少量研究将证据积累模型与人工神经网络模型结合并初见成效。此类模型通过使用人工神经网络提取实验刺激特征, 并在神经网络中内嵌证据积累过程, 从而构建了从刺激编码、决策过程到反应时间与决策结果的全过程, 并尝试进一步探索认知机制的生物学假设。以下将首先从决策过程全过程模拟的视角对认知决策神经网络的特点进行阐述, 随后介绍已有研究, 分析其应用、优势和局限, 最后对未来认知决策神经网络模型进行展望。

2 基于证据积累的认知决策神经网络

认知决策神经网络的主要特点是拓展传统证据积累模型的理论框架, 结合人工神经网络的功能, 构建从刺激输入到决策输出的全过程模型, 从而实现在硅基上模拟人类的认知过程(见图1)。




图1 基于 David Marr 的三层次理论比较认知决策神经网络和 EAMs 对人类决策的理解。在计算理论层上, 认知决策神经网络和 EAMs 两者均基于证据积累理论框架下对反应时间变异性的描述以解释人类决策过程与选择结果的生成机制。在算法表征层上, 认知决策神经网络通过直接编码刺激特征, 将复杂刺激转化为动态证据值, 而 EAMs 依赖基于维纳过程的随机过程模型, 通过参数化噪声与漂移率描述证据积累的随机性(紫色箭头)。在硬件实现层上, 认知决策神经网络在硅基硬件上通过算法模拟人脑神经元通过其生物“算法”达成的计算, 而 EAMs 则以统计方法反推其可能算法, 本质上缺乏硬件层面的支持(绿色箭头)。彩图见电子版。

本小节将首先介绍证据积累模型的核心观点,在此基础上阐述人工神经网络与证据积累模型结合的可能性。

2.1 认知模型中证据积累的关键假设

证据积累模型已应用于各类研究范式,涉及知觉决策、价值决策和社会决策(Lee & Usher, 2023; Tump et al., 2020)。这类模型包含两个核心机制:证据积累过程与决策机制。证据积累机制通过决策变量(decision variable, DV)量化随时间推移不断积累有效信息的过程;决策机制通过决策边界(decision boundary)量化决策所需的证据量,以此解释决策者何时做出决策(刘逸康, 胡传鹏, 2024);证据积累的速度以及决策边界的范围共同决定了决策的反应时间(Boag et al., 2025; Pan et al., 2025)。

证据积累模型的证据积累过程和决策机制在神经生物学研究结果中得到支持(Gold & Shadlen, 2007)。例如, Roitman 和 Shadlen (2002)的研究要求经训练的猕猴判断随机点运动方向,发现当随机点开始朝着目标方向移动时,外侧内顶叶区(lateral intraparietal area, LIP)的神经元放电率以特定的速率逐渐增加,当放电率达到最高点时,猕猴会做出相应的反应,这与决策的证据积累方式相似。Lo 和 Wang (2006)则发现,上丘(superior colliculus, SC)脑区可能是实现决策阈值机制的关

键结构,其假设在决策过程中 SC 脑区专门负责终止决策,在证据量未达到决策阈值时,SC 脑区的激活程度较低,但当证据量达到固定阈值时,SC 脑区会激活以控制 LIP 脑区停止证据积累。该假设在随机动点(random dot motion, RDM)任务中得到了证实。例如, Stine 等人(2023)发现 LIP 脑区的神经元放电率随着刺激呈现不断攀升并在被试做出反应时间达到顶峰,而 SC 脑区放电率在即将反应前突然攀升至顶峰,且在不同反应时长下顶峰几乎没有任何差异,这为决策边界固定这一预设提供了证据。

2.2 从证据积累过程到决策全过程建模

传统认知建模仅对决策过程进行统计描述以更好地拟合人类决策行为的结果数据模式,但对感觉信息处理等其他过程较少涉及。对决策全过程的建模则需要从感觉信息编码开始到决策输出为止。要实现这种全过程的建模,认知决策神经网络应包括至少三个主要模块(见图 2):刺激加工与特征提取模块、证据积累以及决策判断模块、反应时间的输出模块。其中刺激加工与特征提取模块主要处理刺激编码,将感觉信息转换成决策证据;证据积累及决策判断模块则主要解决如何实现证据累积并得到决策判断,反应时间的输出模块则负责将模型决策时间与人类决策时间对齐。下面是对认知决策神经网络的实现过程的详细展开。




图 2 认知决策神经网络框架图。以随机动点任务为例,认知决策神经网络将输入实验刺激通过卷积操作、池化操作、全连接层的线性转换以及激活函数的非线性转换,实现对数据的特征提取、维度映射;为建立特征值与证据积累过程中证据值的联系,通过设定阈值 β ,定义满足决策判断的相关函数,以输出反应时间,作为认知过程的体现。最后,将模型的反应时间与真实数据反应时间对齐,采用损失函数或变分推断的方式优化。

认知决策神经网络的第一个模块是对实验刺激进行数据转换与特征提取。为兼容决策任务中刺激加工过程,模型输入多为复杂数据,如随机动点、带噪音的合成图像或真实图像等。人工神经网络通过其算法(见网络版附录 1)实现对刺激 x 时间维度映射与特征提取:

$$e_t = f_{\theta}(x)_t, t = 1, 2, \dots, T \tag{1}$$

其中 f_{θ} 是参数为 θ 的神经网络, e_t 为时间点在时间点 t 上刺激的映射结果。经处理后的数据不仅具有“时序性”,可用于理解为在单位时间点感受到的刺激量大小,而且具有“代表性”,能够体现实验刺激的核心特征。认知决策神经网络将该数据作为在 t 时刻的决策变量,即决策过程中该时刻的证据值 e_t 。在证据积累模型的理论假设中,证据即与决策相关的各种信息经过编码转换后得到的抽象表征,其在 EAMs 中,具体表现为固定漂移率参数下的累积增量(刘逸康, 胡传鹏, 2024)。类似的,本文中的“证据”指的是神经网络算法所提取出的、服务于决策且随时间积累的潜变量。

证据积累以及决策判断模块用于实现证据积累以及决策判断过程。该模块是将证据积累模型理论框架整合到人工神经网络的核心。具体来看,认知决策神经网络往往需要预先设定决策阈值 (β),类似于 DDM 中决策边界参数。同时,对不同时刻的感觉信息通过积分方式在时间维度进行累加,以实现证据累积过程,如公式 2。一旦积累的证据量达到或超过决策阈限值 β ,模型即做出决策判断,如公式 3,并输出对应的决策时间,如公式 4。

$$S_t = \sum_{k=1}^t e_k \tag{2}$$

$$Decision = \operatorname{argmin}\{t | S_t \geq \beta\} \tag{3}$$

$$RT = \min\{t | S_t \geq \beta\} \tag{4}$$

最后一个模块则负责调整模型最终的反应时间输出,对此需优化数据转换及特征提取模块的参数(如权重等),评估实验刺激与证据值的联系,以确保能够通过模型的反应时间反映出与人类相同的认知决策特征。在初步得到其决策时间输出后,往往采用损失函数拟合或变分推断逼近两种方法进行参数优化:(1)采用损失函数进行参数拟合: $\mathcal{L} = (RT - RT_{\text{human}})^2$,在反向传播中对其调整: $\theta \leftarrow \theta - \eta \nabla_{\theta} \mathcal{L}$,使其最终能够输出与人类对齐的反应时间;(2)基于变分推断,引入近似后验分布 $q(\theta; \phi)$ 来逼近真实后验分布 $p(\theta | RT_{\text{human}})$,其中 ϕ 是变分参数。其核心在于最小化两者之间的差异,通常使用 Kullback-Leibler 散度: $KL(q(\theta; \phi) || p(\theta | RT_{\text{human}}))$ 来衡量。

总的来说,认知决策神经网络将人工神经网络算法与证据积累模型理论相融合,通过对输入实验刺激加工,直接提取特征,并以输出的反应时间作为核心指标,实现对决策全过程的建模,为硬件-算法-计算三层次的全面建模提供了可能性。

3 认知决策神经网络的现状与示例

研究者已初步将认知决策神经网络应用于简单的知觉决策中,实现了从感官刺激接收到做出决策判断的全过程建模,展现出相较传统模型的独特优势。本研究将以三个不同类型的应用实例展开说明,依次为:认知决策神经网络对多选题知觉决策的模拟、对动态时序知觉决策的模拟以及基于神经放电的决策模拟(见表 1)。

表 1 认知决策神经网络模型实例

模型名称	人工神经网络算法	证据积累过程	认知决策特征反映
RTNet (Rafiei et al., 2024)	BNN	竞争模型。根据权重的概率分布进行证据积累,存在选项对应证据积累超过阈值时,判断做出决策	速度与准确性权衡、任务难度对速度及准确性的影响、正误试验对信心水平的影响
RTify (Cheng et al., 2024)	ConvLSTM	特征值积累。将隐藏层特征值映射成证据值并积累,超过阈值时做出决策,对应时间步长判定为决策时间点	任务难度对速度及准确性的影响
SN-DM (Duggins & Eliasmith, 2025)	SNN	价值评估。将感觉刺激映射为决策变量并累积积分。当决策变量超过阈值时,模型的动作群体神经元变得活跃,解码出决策行为	速度与准确性权衡

3.1 RTNet: 多选项知觉决策模拟

传统的卷积神经网络(Convolutional Neural Network, CNN)能够实现多分类任务,但其输出主要由训练后模型内部的权重决定。由于模型权重在训练完成后不再变化,模型的输出进而表现出机械决定性(deterministic),即对于相同刺激输入,模型由于固定权重而产生一致输出。此外,传统的卷积神经网络难以反映刺激与反应时间之间的关系,因其在处理不同刺激时所需的计算时间几乎恒定,表现出静态性(static),缺乏对时序动态的建模能力。以卷积神经网络在手写数字 MNIST 数据集(Deng, 2012)上做分类任务的表现为例,相同数字的不同变体(如不同开放顶部/闭合顶部书写风格的“4”)给人类决策过程带来不确定性,而这种不确定性将影响决策的表现。如果决策者为了快速反应可能会进行猜测,其决策判断快速但错误率更高;反之,如果决策者想提高准确性,则可能放慢决策速度。但卷积神经网络的“决策”则仅由刺激特征对应的静态权重决定,其反应速度仅取决于硬件的运行速度,与刺激本身无关。为反映人类决策的速度特征,Rafiei 等人(2024)提出 RTNet 模型,用于模拟人类知觉决策中不确定性与反应时间的关系。

RTNet 模型采用贝叶斯神经网络(Bayesian neural networks, BNN)作为刺激加工与特征提取的模块,基于处理图像的 AlexNet 架构,通过概率化的方式引入多个可能参数组合将视觉刺激输入转换为证据值,模拟人类决策过程受随机证据波动的影响,实现对不确定性的量化。具体而言,刺激输入后会被贝叶斯神经网络在多个时间步长下进行连续的前向传播过程处理,每次处理时,神经网络的权重和偏置均从与真实分布近似的后验分布中采样,使得在同一刺激下每个时间步长下的证据值发生随机变化。在构建证据积累以及决策判断模块时,RTNet 借鉴证据积累模型中的 Race-Model 思路实现绝对证据积累过程,即每种反应选项对应一个单独的证据累计器,当某一证据累计器超过预定义的阈值,输出决策和反应时间,并通过计算所选项与第二最佳选择的证据差值,得到类似于人类对决策的信心水平,其差值越大,表明模型的信心水平越高。

Rafiei 等人(2024)采用 MNIST 数据集作为实验刺激,包含从 0 至 9 共 10 种手写数字的 60000

个训练图像以及 10000 个测试图像,研究者随机选择 480 张图像用于实验任务中,并通过添加高斯噪声或运动模糊核得到高、低两种水平信噪比的刺激图像。在行为学实验中,给被试两种不同的指导语:要么要求快速反应,要么要求准确反应,以操纵被试的反应策略。被试反应后还需要报告其判断的信心水平。每轮刺激呈现共包括 4 种条件,每种条件包含 120 张图像,被试将接受两轮实验,对应相同刺激图像但实验条件发生随机改变,从而得到人类感知决策的数据。

研究者设定模型能根据图像复杂程度(即任务难度),合理调整决策时间,同时输出对某个数字识别判断的信心值,以模拟人类在决策时对自己判断的信心水平。在训练阶段,需调整贝叶斯神经网络权重的后验分布近似于真实分布,以确保 RTNet 具备有效识别图像数据的泛化能力。对此,模型采用变分推断方法训练贝叶斯神经网络,在 MNIST 数据集上实现高于 97% 的手写数字图像分类准确率,作为模型能够识别图像的核心指标;在测试阶段,则将 RTNet 输出的反应时间和信心水平作为评估其决策过程模拟的核心指标。

测试结果发现,RTNet 能够实现多选项任务的决策模拟,通过评估每个数字作为正确选项的可能性,体现出不同选项之间的差异,并综合考虑实验刺激引起的各选项证据积累情况。作为认知决策神经网络,其通过 AlexNet 来进行视觉刺激编码,并采用贝叶斯神经网络模拟人类决策过程中带有噪音的证据积累过程,解决了传统 EAMs 中无法进行视觉编码的问题。其结果能够表现出与人类相同的认知决策特征(如速度与准确性权衡、任务难度增加引起的准确率降低、正确试验的信心水平高于错误试验等),意味着在该任务下,该模型以某种程度模拟了人类的知觉决策。

3.2 RTify: 动态时序决策模拟

RTNet 虽然可以解释人类对模糊刺激的知觉决策结果,但刺激本身是静态的,即从刺激出现到被试做出反应,刺激本身的物理特征未发生变化。但现实生活中,刺激本身的物理特征可能也在不断变化。在经典的随机动点任务中,随机点的位置时刻发生改变。人类能够对连续变化的刺激进行知觉判断,而 RTNet 由于每次随机权重采样后参数固定,难以解释时间维度上的连续性刺

激改变对认知过程的影响(Rafiei et al., 2024)。为了弥补这一缺陷, Cheng 等人(2024)构建了 RTify 模型, 通过引入随时间步变化的证据积累过程, 来考虑证据积累的依赖性。

RTify 相比 RTNet 的主要变化在于能够根据时序刺激进行特征提取形成潜变量(即证据值)。RTify 采用卷积循环神经网络实现刺激加工与特征提取: 该网络包括能够灵活调整时间步长的长短期记忆网络层(Long Short Term Memory, LSTM)与能够体现视觉刺激整合过程的卷积层。其证据积累模块主要由定义的证据函数和证据积累器两部分组成, 用于将时序刺激特征转变为证据值。具体而言, 模型首先通过证据函数的全连接层线性变换和激活函数的非线性变换实现了从刺激特征到证据值的动态映射, 随即将映射的证据值在时间步长维度累加至证据积累器中。当积累的证据值跨过预先设定的决策边界时, 便做出决策判断。最后, 通过计算相邻时间步长的证据累积差值作为调整模型反应时间的依据, 实现与时序刺激的单位对齐, 将模型的时间步长转化为反应时间输出。

研究选用随机动点任务呈现刺激的连续变化, 并通过调节运动相干性(即同向运动点的比例)改变任务难度, 以探究速度与准确性的认知机制。参与者需整合动点信息并在充分信心时给出其方向判断, 采用其反应时间以及准确率作为核心指标。对于模型而言, 输入刺激首先在卷积层中进行特征提取并整合为长短期记忆网络层中隐藏状态的特征值, 作为证据转换的潜变量, 保证模型积累的证据与刺激的变化一致; 之后通过定义的证据函数(包括全连接和激活函数)映射隐藏状态的特征值为单位时间步的证据值(即决策变量), 基于长短期记忆层的循环连接结构, 使其融入一个非线性的证据积累过程, 当证据积累总和达到决策边界时, 模型做出判断; 最后, 在反向传播过程引入相邻时间步长的证据累积差值作为调整权重等参数的影响因素, 模拟决策变量受刺激影响的动态改变, 并在交叉熵损失中添加正则化项, 以在最大化准确性的同时最小化模型决策时间, 模拟正确试验较错误试验的反应时间更快这一决策特性, 以实现最终反应时间和决策判断的输出。

在训练阶段, 模型需拟合人类在随机动点任

务中的反应时间和准确率, 其实验数据来自于 21 名被试连续四天完成的大约 40000 次试验结果。在测试阶段, RTify 需完成视觉分类任务(object recognition task), 选用了包含多物体交互场景的 COCO 数据集(Lin et al., 2014)中 20 张自然图像以及 112 张不同背景和物体位置的人工合成图像作为实验刺激, 并采集 88 位人类被试的反应时间及决策准确率与模型的输出相比较, 以评估其对真实图像刺激及多类别图像判断的表现情况。最后, 研究者对实验进行了扩展, 将 RTify 应用于在视觉任务中表现出色的生物物理真实皮层网络 Wong-Wang 模型(Wong & Wang, 2006)中, 通过在上述随机动点任务以及视觉分类任务中测试, 探讨能否开发一个具有生物合理性且支持多类别处理的决策模型。

测试结果表明, RTify 能够表现出在时序刺激变化下的速度与准确性权衡, 能够根据任务的难度和准确性自行调整决策所需的时间步长作为输出反应时间等决策特征, 体现出人类认知的动态变化过程, 在时间维度实现与人类反应时间对齐。在最后的实验拓展中, 经整合后的模型因在复杂刺激和多分类任务下的优秀表现, 有助于推动对动态视觉背后脑机制的全面理解。作为 RTNet 的改进, RTify 基于类视觉皮层加工的网络架构, 为刺激编码的神经活动变化如何影响证据积累过程提供了更全面的模拟, 解决了传统 EAMs 中无法对视觉刺激编码以及缺乏证据积累算法的问题。

3.3 SN-DM: 基于神经放电的决策模拟

RTNet 与 RTify 使用深度神经网络虽能有效处理复杂刺激特征, 却难以直接模拟决策的神经机制。其原因在于, 深度神经网络并未直接基于或完全模拟人脑皮层的细胞构架而构建, 无法自下而上地探究认知决策的神经基础(Moustafa et al., 2015)。研究者指出, 基于生物神经框架(Neural Engineering Framework, NEF)的脉冲神经网络(Spiking Neural Network, SNN)能产生与外侧顶内沟(LIP)和上丘(superior colliculus)等视觉脑区高度一致的单神经元活动模式(Lo et al., 2015; Shen et al., 2023), 这为决策变量背后的神经编码理论提供了支持(Steinemann et al., 2024; Stine et al., 2023)。鉴于此, Duggins 和 Eliasmith (2025)构建了脉冲神经决策模型(spiking neural decision-making

model, 在本研究中简称为 SN-DM), 旨在探究神经元级别的脉冲信号以及不同功能核团在证据积累过程中的作用。

具体而言, SN-DM 由脉冲神经群体和一个非神经组件组成。非神经组件负责处理感官输入, 以模拟刺激输入时可能存在的噪音。脉冲神经群体包括感觉群体、记忆群体、价值群体、门控群体和动作群体。其中, 输入实验刺激的编码与提取模块由感觉群体构成, 记忆群体和价值群体构成证据积累模块, 而门控群体和动作群体构成决策判断模块。以随机动点任务为例, SN-DM 首先通过非神经组件根据随机动点的运动相干性生成感知估计并引入噪声, 由此作为实验刺激输入; 之后, 感觉群体对输入刺激在空间维度实现分布式编码进行选项比较, 类比神经元的方向选择性; 经特征提取后传递给记忆群体, 记忆群体因其递归连接结构, 在时间维度上将感知到的(动点)运动强度信息整合为证据积累; 接着, 价值群体根据记忆群体的证据积累总和进行价值计算, 输出各选项的当前证据强度, 并通过其参数 L 判断证据积累类型是基于绝对证据($L = 0$ 时)、相对证据($L = 1$ 时), 还是两者的混合($0 < L < 1$)。最后, 当证据强度超过决策阈值 T 时, 模型会克服来自门控群体的抑制信号, 使动作群体的神经元变得活跃, 从而解码出一个动作, 做出决策。从刺激呈现到动作群体做出决策的整个时间间隔, 即为模型的反应时间。

在训练阶段, 模型通过与恒河猴行为数据(来源于 Hanks et al., 2014)的反应时间拟合以调整参数。在测试阶段, Duggins 和 Eliasmith (2025)首先让模型在随机动点任务中, 模拟恒河猴在强调速度或准确性指令下的行为, 并评估能否应用于多选项任务中。通过调整决策阈值 T , 模型需判断随机点的主要运动方向, 任务难度由运动相干性决定。在此过程中, 记录模型的反应时间和准确率, 用于验证模型能否捕捉到速度与准确性权衡行为的核心指标, 同时判断模型神经元的活动是否与恒河猴的实际神经数据及行为数据(均来源于 Churchland et al., 2008)相符。进一步地, 为探究低层次生物变化如何影响高层次认知表现, 研究者尝试应用 SN-DM 模拟衰老对决策过程的影响。通过人为减少感觉群体与记忆群体的突触连接, 构建“老年决策模型”(elder models)模拟衰老引起

的神经功能退化特征; 同时, 基于 Forstmann 等人 (2011)实验采集的 18 岁健康被试的反应时间数据, 构建了能够拟合反应时间并预测决策准确性的“年轻模型”(young models)作为基准。在随机动点任务测试中, 通过比较两个模型输出的反应时间和准确性差异, 尝试解释生物退化对认知功能的影响。最后, 模型被应用于股票市场任务的非知觉决策模拟中, 探究由任务本身奖励驱动的决策特性(速度与准确性权衡)以及个体表现出的高阶认知策略(体现在个体频繁地采用不同的策略以完成任务)。由于与随机动点任务存在明显差异, 研究者首先选用股票市场任务的人类决策数据集(来源于 Fiedler et al., 2021)中表现不同策略(慢但准确、中等、快但不准确)参与者的反应时间作为训练数据, 在中等难度条件下设定模型对其参数拟合; 在该任务的测试阶段, 将训练好的模型应用于容易和困难难度条件下, 评估模型预测的反应时间及准确率。

测试结果表明, SN-DM 能够模拟不同任务难度以及多选项决策的随机动点任务、非知觉决策的股票市场任务以及衰老对决策过程的影响, 该模型不仅在生物层面呈现出类似的神经元激活模式, 还在认知层面表现出与任务或情景相对应的速度准确性权衡特征。研究团队根据 SN-DM 的突触权重大小, 在神经元级别解释了不同证据权衡(绝对或相对)方式、噪音水平以及复杂认知任务对速度与准确性的影响。值得一提的是, 该模型通过引入可调整的相对估值参数 L 和决策阈值 T , 能够实现绝对证据和相对证据积累过程的切换或混合, 而 RTNet 和 RTify 仅能模拟绝对证据积累过程。SN-DM 通过脉冲神经群体实现对多种任务相关的“证据”进行编码, 可以模拟更多的人类决策过程, 是未来值得深入探索的方向之一。

4 总结与展望

反应时间作为人类与动物决策时的关键结果变量之一, 是观察决策背后认知神经基础的独特窗口, 为理解决策的神经生物学机制与认知过程提供了宝贵的经验(Gold & Shadlen, 2007; Luce, 1986)。认知决策神经网络将证据积累框架进一步拓展, 实现对认知决策的全过程建模, 模拟人类对刺激的编码以及决策的关键输出: 反应时间与选择, 为研究者提供了理解人类决策过程的新方

法。当前,此类模型已经初步实现多选项决策、动态时序加工和“速度-准确率权衡”等人类知觉决策特征,为后续研究打下了坚实的基础。尽管本文中列举三个不同应用示例仍旧存在局限性,但未来研究者们能够通过替换与更新认知决策神经网络理论框架中对应内容的各个模块,实现对认知决策机制的全方位理解。

认知决策神经网络作为传统认知建模的拓展,融合了认知模型的特点:轻量化的架构设计与可解释性。首先,认知决策神经网络基于小型深度神经网络构建,训练过程不需要大量的数据和算力,使用一般消费级 CPU 和 GPU 就可胜任。其次,认知决策神经网络因结合了认知模型,其参数与认知过程有较为密切的关系,可解释性强。因此,在上述的三个认知决策神经网络模型中,均有明确的证据积累机制。

值得注意的是,当前的认知决策神经网络也具有认知模型的局限性,尤其是在模型的可泛化性上。传统证据积累的理论框架虽然有广泛的解释性,但在应用时需要根据情境更加具体地设定形成计算模型后,才能与实证数据相结合,否则可能会导致实证数据与模型预设不相匹配的情况(Boag et al., 2025; 刘逸康, 胡传鹏, 2024)。这一特点带来的问题是:几乎每个特定的实验任务均可以有其独特的计算模型。典型的例子是认知冲突相关的任务(如 Stroop/Flanker 和 Simon 任务),就存在双阶段两阶段模型(Dual-Stage Two-Phase Model, DSTP)、冲突扩散模型(Diffusion Model for Conflict Tasks, DMC)和收缩聚焦模型(Shrinking Spotlight Model, SSP)等多个证据积累模型的特殊计算模型(Evans & Servant, 2020)。当前认知决策神经网络可能也存在同样问题。RTNet 可能无法适用于随机动点任务,RTify 和 RTNet 可能均无法模拟认知冲突任务。SN-DM 无法准确预测人类在紧迫的时间压力进行决策的反应时间:人类在此情境下,决策速度及决策边界将发生改变(Duggins & Eliasmith, 2025),而 SN-DM 的决策速度与边界由预先设定的超参数决定,无法针对该情景做出灵活调整。考虑到认知心理学家们所发明的大量决策任务且人类可以毫无障碍地完成它们,当前认知决策神经网络能够模拟的认知任务仍然非常有限。传统证据积累模型已经广泛应用于基于价值的决策、社会决策等多种场景,并能

有效解释这些复杂情境下人类快速决策的反应时间与选择结果。然而,在这些情境中,认知决策神经网络如何进行证据积累,以及是否需要额外的价值计算模块(Zhang et al., 2025),将成为该领域面临的新挑战。

要提升认知决策神经网络的可泛化性问题,实现对人类决策全过程的建模,建立人类决策过程的“数字孪生”,仍然需要进行大量的工作。一种可能性是借鉴当前大语言模型(Large Language Models, LLMs)的思路。大语言模型作为当前人工智能领域的代表,具有理解人类决策背后认知过程的潜力。例如, Hafner 等人(2025)提出的大模型 Dreamer 算法,通过学习世界模型,能以固定超参数在 150 多个不同任务中实现迁移应用; Binz 等人(2025)基于语言模型(Llama 3.1 70B)微调构建的 Centaur,能够在大规模数据集 Psych101 训练下,预测和模拟 160 项自然语言可表述的心理学实验中人类行为表现。遗憾的是,这些模型无法预测人类决策时间。要使用计算模型模拟人类的决策时间,需要更多的人类在各种任务下的反应时间数据。这不仅需要更多的开放数据,也需要对认知任务本身的标准化和量化的描述,帮助未来的模型训练理解任务结构与决策时间之间关系。换句话说,认知决策神经网络领域需要自己“ImageNet”。但值得注意的是,尽管大语言模型可能能够提升认知决策神经网络的泛化能力,该方法难以满足认知科学中所强调的“轻量化建模与可解释性”要求。针对这一问题,已有研究者尝试提供解决方案。例如, Zhang 等人(2025)系统化地提出人类-AI 混合实验平台的构建原则,通过该平台对多模态数据采集持续驱动 AI 等计算模型的参数优化与架构改进,促使增强后的模型生成更精确的动态模拟与任务情境预测以反哺平台的任务范式设计及实验控制策略,从而建立一个闭环迭代系统,推动数据与算法的深度耦合。在未来的认知建模中,呼吁研究者们提出更多具有理论导向的泛化机制,以推动认知决策神经网络领域更好发展。

另一种可能的取向则是继续深入理解人类认知的过程,训练小的神经网络模型来完成人类灵活的任务。近期 tiny RNNs 提供了非常有价值的参考,其仅包含 1~4 个计算单元的极简架构能够通过参数空间优化显著提升行为预测效能,在六

类经典强化学习任务中超越经典认知模型(Ji-An et al., 2025)。而当前负责刺激加工模块的神经网络主要集中在小型的深度神经网络,未来可以考虑将其替换为此类更高级的神经网络算法,以用于认知过程的理解。就证据积累模块而言,本研究列举的认知决策神经网络实例大多基于绝对证据积累过程的理论构建(除 SN-DM 通过引入对证据的价值评估函数,提出了绝对证据积累与相对证据积累过程的动态切换),未来可尝试替换为相对证据积累或混合证据积累等作为模型对于决策过程的假设,或直接采用神经网络算法实现。而对于决策判断模块,目前认知决策神经网络多集中于对实验刺激自身特征的判断,SN-DM 已成功实现经济决策中股票市场任务的模拟,未来可引入更多抽象信息的决策判断如对于关系、意图的把握等。其训练与测试主要基于反应时间、正确率等行为数据,在神经层面多为算法与生物结构功能的类比建模,缺乏对特定神经活动或脑区的精准映射。在未来,研究者需要进一步探索认知决策神经网络与真实的神经活动之间的映射关系,加深对人类决策过程的理解以及优化对人类决策过程的模拟。现有认知决策神经网络的决策边界由预先设定的超参数所决定,无法针对任务情境自动调整。未来研究者在实现自适应性建模时,应着重于提升模型的任务泛化能力,使其更具灵活性与普适性。最后,面对认知科学中所强调的“轻量化建模与可解释性”,在未来的认知决策神经网络建模中,研究者们仍需权衡可解释性带来的参数约束与依靠数据驱动实现算法功能之间的关系。

此外,认知决策神经网络未来还可能与机器人的具身智能结合,通过机械臂按键来输出反应时间。这将进一步有助于解决传统认知建模中难以解决的问题:非决策时间。非决策时间作为证据积累模型中的一个参数,其意义至今仍模糊不清(Zeng et al., 2025)。虽然有研究者通过记录肌电等方式来厘清该参数的意义,但目前仍然知之甚少(Bompas et al., 2025)。认知决策神经网络若能与机械臂相结合,将能完整模拟人类快速决策过程,从而解决传统认知模型中模糊参数的问题。

当前神经网络模型已经突破计算机领域,在科研领域表现出巨大的应用前景,也具有应用于心理学研究的潜力。例如,大语言模型能够提高

认知科学的数据采集效率,经大量文本数据训练后,研究者能够通过与大语言模型对话,在实验任务中快速获取其行为数据以及人工神经元活动数据(Qu et al., 2024)。在认知过程研究方面,除了运用神经网络来执行任务并对人类的行为反应进行预测之外,神经网络模型也可用于解决认知建模过程中的参数估计问题,例如,结合神经网络与模拟推断,可以将传统的认知模型拓展到更加复杂的情景之中(见:潘晚珂,胡传鹏,2025)。将神经网络及其他 AI 技术与认知科学的研究进行更加深入的融合,以实现对人类多方面认知过程的全过程模拟,将有助于研究者建立更完善的人类认知模型,这些模型也可能启发新的 AI 算法开发,从而推动关于智能本质的研究。

参考文献

- 刘逸康, 胡传鹏. (2024). 证据积累模型的行为与认知神经证据. *科学通报*, 69(8), 1068–1081. <https://doi.org/10.1360/TB-2023-1080>
- 潘晚珂, 胡传鹏. (2025). 神经模拟推断: 基于神经网络和模拟推断的认知建模方法. *心理科学*, 48(4), 826–835. <https://doi.org/10.16719/j.cnki.1671-6981.20250406>
- Binz, M., Akata, E., Bethge, M., Brändle, F., Callaway, F., Coda-Forno, J., ... Schulz, E. (2025). A foundation model to predict and capture human cognition. *Nature*, 644, 1002–1009. <https://doi.org/10.1038/s41586-025-09215-4>
- Boag, R. J., Innes, R. J., Stevenson, N., Bahg, G., Bussemeyer, J. R., Cox, G. E., ... Forstmann, B. U. (2025). An expert guide to planning experimental tasks for evidence-accumulation modeling. *Advances in Methods and Practices in Psychological Science*, 8(2), 25152459251336127. <https://doi.org/10.1177/25152459251336127>
- Bompas, A., Sumner, P., & Hedge, C. (2025). Non-decision time: The Higgs Boson of decision. *Psychological Review*, 132(2), 330–363. <https://doi.org/10.1037/rev0000487>
- Cheng, Y. -A., Rodriguez, I. F., Chen, S., Kar, K., Watanabe, T., & Serre, T. (2024). RTify: Aligning deep neural networks with human behavioral decisions. *arXiv*, <https://doi.org/10.48550/ARXIV.2411.03630>
- Churchland, A. K., Kiani, R., & Shadlen, M. N. (2008). Decision-making with multiple alternatives. *Nature Neuroscience*, 11(6), 693–702. <https://doi.org/10.1038/nn.2123>
- Deng, L. (2012). The MNIST database of handwritten digit images for machine learning research. *IEEE Signal Processing Magazine*, 29(6), 141–142. <https://doi.org/10.1109/MSP.2012.2211477>
- Donders, F. C. (1969). On the speed of mental processes. *Acta Psychologica*, 30, 412–431. [https://doi.org/10.1016/0001-6918\(69\)90065-1](https://doi.org/10.1016/0001-6918(69)90065-1)
- Duggins, P., & Eliasmith, C. (2025). A spiking neural model of

- decision making and the speed-accuracy trade-off. *Psychological Review*, 132(5), 1090–1127. <https://doi.org/10.1037/rev0000520>
- Evans, N. J., & Servant, M. (2020). A comparison of conflict diffusion models in the flanker task through pseudolikelihood Bayes factors. *Psychological Review*, 127(1), 114–135. <https://doi.org/10.1037/rev0000165>
- Fiedler, K., McCaughey, L., Prager, J., Eichberger, J., & Schnell, K. (2021). Speed-accuracy trade-offs in sample-based decisions. *Journal of Experimental Psychology: General*, 150(6), 1203–1224. <https://doi.org/10.1037/xge0000986>
- Forstmann, B. U., Tittgemeyer, M., Wagenmakers, E. -J., Derrfuss, J., Imperati, D., & Brown, S. (2011). The speed-accuracy tradeoff in the elderly brain: A structural model-based approach. *Journal of Neuroscience*, 31(47), 17242–17249. <https://doi.org/10.1523/JNEUROSCI.0309-11.2011>
- Gold, J. I., & Shadlen, M. N. (2007). The Neural basis of decision making. *Annual Review of Neuroscience*, 30(1), 535–574. <https://doi.org/10.1146/annurev.neuro.29.051605.113038>
- Hafner, D., Pasukonis, J., Ba, J., & Lillicrap, T. (2025). Mastering diverse control tasks through world models. *Nature*, 640(8059), 647–653. <https://doi.org/10.1038/s41586-025-08744-2>
- Hanks, T., Kiani, R., & Shadlen, M. N. (2014). A neural mechanism of speed-accuracy tradeoff in macaque area LIP. *eLife*, 3, Article e02260. <https://doi.org/10.7554/elife.02260>
- Ji-An, L., Benna, M. K., & Mattar, M. G. (2025). Discovering cognitive strategies with tiny recurrent neural networks. *Nature*, 993–1001. <https://doi.org/10.1038/s41586-025-09142-4>
- Kheradpisheh, S. R., Ghodrati, M., Ganjtabesh, M., & Masquelier, T. (2016). Deep networks can resemble human feed-forward vision in invariant object recognition. *Scientific Reports*, 6(1), 32672. <https://doi.org/10.1038/srep32672>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84–90. <https://doi.org/10.1145/3065386>
- Lee, D. G., & Usher, M. (2023). Value certainty in drift-diffusion models of preferential choice. *Psychological Review*, 130(3), 790–806. <https://doi.org/10.1037/rev0000329>
- Lin, T. -Y., Maire, M., Belongie, S., Bourdev, L., Girshick, R., Hays, J., ... Dollár, P. (2014). Microsoft COCO: Common objects in context. *arXiv*. <https://doi.org/10.48550/ARXIV.1405.0312>
- Lo, C. -C., & Wang, X. -J. (2006). Cortico-basal ganglia circuit mechanism for a decision threshold in reaction time tasks. *Nature Neuroscience*, 9(7), 956–963. <https://doi.org/10.1038/nn1722>
- Lo, C. -C., Wang, C. -T., & Wang, X. -J. (2015). Speed-accuracy tradeoff by a control signal with balanced excitation and inhibition. *Journal of Neurophysiology*, 114(1), 650–661. <https://doi.org/10.1152/jn.00845.2013>
- Luce, R. D. (1986). *Response times: Their role in inferring elementary mental organization*. Oxford University Press, New York.
- Marr, D. (1982). *Vision: A computational investigation into the human representation and processing of visual information*. W. H. Freeman.
- Moustafa, A. A., Kéri, S., Somlai, Z., Balsdon, T., Frydecka, D., Misiak, B., & White, C. (2015). Drift diffusion model of reward and punishment learning in schizophrenia: Modeling and experimental data. *Behavioural Brain Research*, 291, 147–154. <https://doi.org/10.1016/j.bbr.2015.05.024>
- Pan, W., Geng, H., Zhang, L., Fengler, A., Frank, M. J., Zhang, R.-Y., & Chuan-Peng, H. (2025). dockerHDDM: A user-friendly environment for Bayesian hierarchical drift-diffusion modeling. *Advances in Methods and Practices in Psychological Science*, 8(1), 25152459241298700. <https://doi.org/10.1177/25152459241298700>
- Qu, Y., Du, P., Che, W., Wei, C., Zhang, C., Ouyang, W., ... Liu, Q. (2024). Promoting interactions between cognitive science and large language models. *The Innovation*, 5(2). <https://doi.org/10.1016/j.xinn.2024.100579>
- Rafiei, F., Shekhar, M., & Rahnev, D. (2024). The neural network RTNet exhibits the signatures of human perceptual decision-making. *Nature Human Behaviour*, 8(9), 1752–1770. <https://doi.org/10.1038/s41562-024-01914-8>
- Rajalingham, R., Piccato, A., & Jazayeri, M. (2022). Recurrent neural networks with explicit representation of dynamic latent variables can mimic behavioral patterns in a physical inference task. *Nature Communications*, 13(1), 5865. <https://doi.org/10.1038/s41467-022-33581-6>
- Ratcliff, R., & McKoon, G. (2008). The diffusion decision model: Theory and data for two-choice decision tasks. *Neural Computation*, 20(4), 873–922. <https://doi.org/10.1162/neco.2008.12-06-420>
- Ratcliff, R., Smith, P. L., Brown, S. D., & McKoon, G. (2016). Diffusion decision model: Current issues and history. *Trends in Cognitive Sciences*, 20(4), 260–281. <https://doi.org/10.1016/j.tics.2016.01.007>
- Roitman, J. D., & Shadlen, M. N. (2002). Response of neurons in the lateral intraparietal area during a combined visual discrimination reaction time task. *Journal of Neuroscience*, 22(21), 9475–9489. <https://doi.org/10.1523/JNEUROSCI.22-21-09475.2002>
- Shadlen, M. N., & Kiani, R. (2013). Decision making as a window on cognition. *Neuron*, 80(3), 791–806. <https://doi.org/10.1016/j.neuron.2013.10.047>
- Shen, B., Louie, K., & Glimcher, P. (2023). Flexible control of representational dynamics in a disinhibition-based model of decision-making. *eLife*, 12, Article e82426. <https://doi.org/10.7554/elife.82426>
- Steinemann, N., Stine, G. M., Trautmann, E., Zylberberg, A., Wolpert, D. M., & Shadlen, M. N. (2024). Direct observation of the neural computations underlying a single decision. *eLife*, 12, RP90859. <https://doi.org/10.7554/eLife.90859>
- Stine, G. M., Trautmann, E. M., Jeurissen, D., & Shadlen, M. N. (2023). A neural mechanism for terminating decisions. *Neuron*, 111(16), 2601–2613. <https://doi.org/10.1016/j.neuron.2023.05.028>
- Tump, A. N., Pleskac, T. J., & Kurvers, R. H. J. M. (2020). Wise

- or mad crowds? The cognitive mechanisms underlying information cascades. *Science Advances*, 6(29), eabb0266–eabb0266. <https://doi.org/10.1126/sciadv.abb0266>
- Wichmann, F. A., & Geirhos, R. (2023). Are deep neural networks adequate behavioral models of human visual perception? *Annual Review of Vision Science*, 9, 501–524. <https://doi.org/10.1146/annurev-vision-120522-031739>
- Wong, K. -F., & Wang, X. -J. (2006). A recurrent network mechanism of time integration in perceptual decisions. *The Journal of Neuroscience*, 26(4), 1314–1328. <https://doi.org/10.1523/JNEUROSCI.3733-05.2006>
- Zeng, K., Wang, Y., Tan, H., Fang, Q., Wang, Y., & Yuan, L. (2025). Prospects and technology of embodied intelligent humanoid robots driven by AI large models. *Scientia Sinica Informationis*, 55(5), 967. <https://doi.org/10.1360/ssi-2024-0350>
- Zhang, S., Seak, L., Dolan, R., & Wu, H. (2025). AI in the computation and regulation of social decision-making. *OSF*. https://doi.org/10.31234/osf.io/uf9g4_v1

Cognitive decision neural networks based on evidence accumulation framework

CHEN Siyu, PAN Wanke, HU Chuan-Peng

(School of Psychology, Nanjing Normal University, Nanjing 210097, China)

(Adolescent Education and Intelligence Support Lab of Nanjing Normal University, Laboratory of Philosophy and Social Sciences at Universities in Jiangsu Province, Nanjing 210097, China)

Abstract: Reaction time (RT) is a window into understanding human decision-making processes. The Evidence Accumulation Model (EAM) is the dominant theory of computational framework for modeling RT. However, EAMs, such as the Drift Diffusion Model (DDM), offer statistical descriptions of decision outcomes but without detailed algorithms for stimulus encoding or neural mechanisms, thereby omitting the algorithmic and hardware levels in David Marr’s three-level framework (computation, algorithm, and hardware). We suggest that these limitations can be addressed by combining Artificial Neural Networks (ANNs) and evidence accumulation model to simulate the entire decision-making process—from stimulus encoding to evidence accumulation and decision output. These new models, termed Cognitive Decision Neural Networks, enable comprehensive modeling of human decision-making on non-biological hardware (*in silico*), providing a novel approach to understanding cognitive processes. Cognitive Decision Neural Networks have demonstrated preliminary potential in multi-option decision-making, temporal stimulus processing, and neural activation simulation. Such models provide a novel approach to simulating the full spectrum of human decision-making processes. In the future, integration with digital twin brain models could extend their applicability to more complex decision-making scenarios, thereby advancing a deeper understanding of human cognition.

Keywords: cognitive process, evidence accumulation models, computational modeling, artificial neural networks

附录：当前认知决策神经网络算法主要组成及可能对应的心理过程

神经网络层	数学原理	主要操作	核心作用	心理过程
全连接层	$y = Wx + b$	维度映射，通过学习权重矩阵和偏置向量，对输入数据进行线性变换，将输入特征映射到新的特征空间。	(1)连接输入层和输出层的每个神经元； (2)实现特征值的维度变换。	决策变量分类与整合
卷积层	$O(i,j) = \sum_{u=0}^{k-1} \sum_{v=0}^{k-1} I(i+u,j+v)K(u,v)$	卷积运算，通过卷积核对输入数据进行特征提取。	在图像识别任务中，可以通过聚合局部特征，以在整个图像级别进行预测。	视觉系统的初级感知加工
池化层 (以平均池化为例)	$Y_{ij} = \frac{1}{k^2} \sum_{m,n \in [1,k]} X_{(i-1)k+m,(j-1)k+n}$	将图像划分为若干个不重叠的池化窗口，并对其数据进行相应的池化操作。	对输入数据(多为图像矩阵)采样，提取其主要特征。	认知中的注意力选择机制
激活函数 (以 Sigmoid 函数为例)	$\sigma(x) = \frac{1}{1 + e^{-x}}$	引入非线性，通过对神经元的输入进行非线性变换，将其映射到一个特定的输出范围。	(1)输出归一化，可通过判断事件发生概率对样本进行分类； (2)在反向传播中，方便梯度计算，有利于参数更新； (3)控制神经元的激活状态。	神经元激活阈值及对证据强度的非线性响应
损失函数	$L = \frac{1}{N} \sum_{i=1}^N \ell(y_i, \hat{y}_i)$	量化模型预测值 $\hat{y}$ 与真实值 y 之间的误差，通过反向传播算法，计算损失对参数的梯度，更新权重。	(1)在预测输出结果时，调整模型预测结果与真实值之间差异，优化训练； (2)在进行分类任务(如对图像辨别)时，通过衡量概率分布差异得出分类判断。	反馈学习机制与决策策略优化