arXiv:2603.06272v1 [cs.NE] 6 Mar 2026

透视玻璃盒

Alexis Kafantaris雅典经济与商业大学

2026年2月

摘要

本文探讨模糊认知图（FCM）的神经网络实现——FHM，以及相应的评估。首先，我们设计了一个神经网络，使其以与模糊认知图相同的方式运行；该网络接收多个模糊认知图作为输入，并对其进行传播，以学习因果模式。此外，该网络采用朗之万微分动力学来避免过拟合，并根据某种策略反向求解输出节点值。然而，获得反向解后，用户便可据此采用修改准则。修改准则意味着，现在可以酌情调整信息，以更好地匹配不同的服务或产品。最后，我们在多个数据集上进行了评估，以考察网络的性能。

1 引言

本文提出并分析了一种玻璃盒神经网络架构。玻璃盒架构是一种设计，可根据需求施加学习约束，以满足物理学或因果方向方面的要求。起初，该系统被设想为一个黑盒，然而，深入探究后发现，它更像一个玻璃盒。

此外，这种架构由一个简单而优雅的数学模型构成，其核心机制是融合。另一方面，该模型通过对迭代施加约束，并尝试在结果中复现已知知识，从而理解问题。这是通过模型方程强调学习的核心逻辑方面来实现的。

此外，还针对各种数据集和实际应用情境对该系统进行了评估。对此，可以得出若干观察结果，并以 MPG数据集和模糊逻辑推理为例进行说明。最后，本文对这一特定架构作了一些评述，并给出总结性意见。本文的组织结构与传统论文略有不同：首先是文献综述和一些关于方法论的评述，随后介绍数学

模型的基础，并讨论相关内容和结果。最后给出一些总结性意见，并对该特性提出建议。

2 文献综述

首先，本文旨在解决服务设计流程中信息传输模糊优化的核心问题；不过，本文所包含的信息也带来了附带益处。既然如此，为了对前述问题进行建模，就必须考察信息传输。要考察信息传输，就必须将服务作为一个整体来建模，即将服务视为一个网络；与许多其他问题一样，这可以通过多重网络来实现。

乍看之下，根据所面对的问题，研究工作会采用最先进的技术 [12] 并结合经典优化方法；有些研究似乎倾向于遗传算法，但仍有一些研究者信赖模糊认知图 [8] [7]。值得注意的是，多重网络 [14] 能够对信息数组进行建模。多重网络的另一个有趣之处在于，它为层级结构提供了替代方案。静态结构的优化与多重网络之间存在一种隐性联系。例如，蚁群优化 [2] [3] 等方法采用了一种有趣的视角，通过信息素和蚁群来处理结构的动态性。更重要的是，信息素与多重网络蚁群结合使用，由此形成了强大的进化系统 [5] [9]。

此外，图论以一种有趣的方式同时探讨多重网络和结构静态特性 [5] [6] [1] 。例如，前文提到，嵌套树结构能够以稳健的方式成功封装模糊认知图。为此，研究发现了一个研究空白：缺乏模仿模糊认知图的替代方案。尽管已有许多尝试致力于弥合信息系统逻辑或数据方面的鸿沟，但蕴含建模与神经网络方面仍有待解决的问题 [4]。本研究的核心在于，借助软计算 [15] ，或更具体地说，借助神经网络 [13]，有望弥合服务设计流程中的鸿沟。一方面，模糊认知图及其他变体和一些数学工具 [8] 有助于解决相同的问题。更具体而言，目前还没有一种多重网络能够通过软计算模仿模糊认知图，但利用神经网络则可以做到。人们已尝试采用多种方法求解逆模糊认知图问题这一相关问题，例如 q-模糊认知图 [7] 等；同样，也有人尝试使用 FHM 求解。

3 方法论

方法论主要由数学模型及其实现组成。模型与 Python代码直接对应，反之亦然；值得注意的是，这种方式更便于阐述复杂且理论性强的想法，同时保持对象的完整性。此外，解决方案的核心

是一个像玻璃盒一样运作的神经网络；也就是说，它是一种数学对象，能够学习信息的结构，并在最小化目标损失的同时理解输入其中的信息。从某种意义上说，它很像物理信息神经网络 [10]。

3.1 模型定义

输入： A, X，其中： X 是输入数据，而 A 是邻接矩阵。**编码器**:

$$H_0 = tanh(X_0 W_1 + b_1)W_2 + b_2 \tag{1}$$

其中：这是最内层，用于根据图计算并估计节点影响与权重。

度量投影:

$$Y_m = Softsign(ReLU(H_0 W_{m1} + b_{m1})W_{m2} + b_{m2}) \tag{2}$$

其中：这是实现损失函数的外层；它将内层封装为潜在维度，并且是损失目标。

参数： $W_{m1} \in \mathbb{R}^{D_{latent} \times 4}$, $b_{m1} \in \mathbb{R}^4$, $W_{m2} \in \mathbb{R}^{4 \times 1}$, $b_{m2} \in \mathbb{R}^1$
迷你模糊认知图目标:

$$min \sum w - G \tag{3}$$

其中： w 是每个节点的 i， j 权重， G 是潜在嵌入。迷你模糊认知图用作归一化融合函数。

3.2 流程

堆叠节点嵌入和:

$$H_{curr} = Encoder(X) \tag{4}$$

$$H_{prop} = MiniFCM(H_{curr}) = MiniFCM(Encoder(X)) \tag{5}$$

$$H_{t+1} = tanh(H_t + H_{prop}) + tanh(5 \cdot H_{cur}) \tag{6}$$

$$H_t^0 = H_{curr} + sign(H_{curr}) \tag{7}$$

这会对每个融合矩阵施加邻接约束，使黑盒变得透明。该算子既用于下一步操作的学习，也用于选择。区别在于，双曲正切是可微的，因此在传播过程中可以学习矩阵，而在最后会施加约束。

辅助定义：在每次迭代 t中，模型会根据某个标准和过去的嵌入 S进行选择；该标准依赖于真值数据，用于判断模型是否稳定。

节点力： $E_t = ||H_{curr}^{(t)}||_2$
传递对齐: $\Gamma_t = E_t \cdot (A \odot |S|)^\top$

因果得分: $\mathcal{S}_t = mean(E_t + \Gamma_t)$
传播算子: $\Phi(H_t) = tanh(H_t + H_{prop}) + tanh(5 \cdot H_{curr})H_{t+1} = \Phi(H_t)$

每当模型需要新的步骤时，该算子用于更新 H 。

最终迭代状态:

$$H_T = \Phi \circ \Phi \circ \cdots \circ \Phi(H_0) \tag{8}$$

H_t 由前述公式计算得出。
输出逻辑门:

$$H_{final} = H_T + sign(H_T) \tag{9}$$

这起到邻接约束的作用，因为 H_t 严格属于 [0,1]。
最佳状态选择:

$$\hat{H}_{t+1} = \begin{cases} H_{t+1}, & if\ S_t > S_{perf} \\ \hat{H}_{perf}, & otherwise \end{cases} \tag{10}$$

以下是终止准则，需要注意的是，步数是另一项准则。
总损失:

$$\mathcal{L}_{tune} = ||Y_m^{(k)} - v||^2 \tag{11}$$

$$v = \frac{1}{N}\sum_{i=1}^{N}(\frac{1}{d_m}\sum_{j=1}^{d_m} DATA_{i,j}^{(m)}) \tag{12}$$

$$\mathcal{Y}_m^{(k)} = Softsign(ReLU((H_T + sign(H_T))W_{m1} + b_{m1})W_{m2} + b_{m2}) \tag{13}$$

因此:

$$\mathcal{L}_{tune} = ||Softsign(ReLU((H_T + sign(H_T))W_{m1} + b_{m1})W_{m2} + b_{m2})_k - \frac{1}{N}\sum_{i=1}^{N}(\frac{1}{d_m}\sum_{j=1}^{d_m} X_{i,j}^{(m)})||^2 \tag{14}$$

现在来看潜在空间优化:

$$\mathcal{L}_{tune} = ||Softsign(ReLU([...ENCODER{+}FCM...])W_{m1}{+}b_{m1})W_{m2}{+}b_{m2})_k{-}v||^2 \tag{15}$$

$$\mathcal{L}_{tune} = \|Softsign(ReLU(\| \tag{16}$$

$$[tanh(\frac{H_{T-1}}{EncoderAccumulation}{+}\frac{H_{prop}^{(T-1)}}{Mini-FCM}){+}...]W_{m1}{+}b_{m1})W_{m2}{+}b_{m2})_k{-}v||^2 \tag{17}$$

$$\mathcal{L}_{tune} = ||Softsign(ReLU(([tanh(H_{T-1} + H_{prop}^{(T-1)}) + tanh(5 \cdot H_{T-1})] + sign(tanh(H_{T-1} + H_{prop}^{(T-1)}) + tanh(5 \cdot H_{T-1})))W_{m1} + b_{m1})W_{m2} + b_{m2})_k - \frac{1}{N}\sum_{i=1}^{N}(\frac{1}{d_m}\sum_{j=1}^{d_m} X_{i,j}^{(m)})||^2 \tag{18}$$

这使 H_t 达到最优。换句话说，系统在尝试优化H矩阵方程的同时，也会最小化损失。度量头充当信息投影，随后根据目标进行最小化。通过根据目标最小化外层，编码器+模糊认知图被迫学习权重和因果关系。最后，只有当H矩阵包含符号和邻接输出的信息时，系统才能通过这种方式实现最小化。

4 逆解

逆问题初始化与流程:
模糊认知图矩阵与掩码$W = FCM(H_{stored})M_{valid} = A_{mask}$,
$M_{forbidden} = 1 - M_{valid}$网络假定有效路径和无效路径的掩码；这些掩码随后用于评估损失和拓扑。

参数初始化： $\theta_0 = 0$。通过带动量的随机梯度下降（SGD）进行优化。

掩码：对于原始输入参数 $x \in [0, 1]$， $x = \sigma(x)$，模糊认知图权重依据掩码用于计算损失：

$$F_{valid} = (W \odot M_{valid})\sigma(x) \tag{19}$$

$$F_{forbidden} = (W \odot M_{forbidden})\sigma(x) \tag{20}$$

随机激活（模拟退火）反演：在总步数 T的第t步中，施加噪声 $\sim \mathcal{N}(0, 0.01_2)$以逃离局部最小值：

$$Y_t = \begin{cases} \sigma(F_{valid} + F_{forbidden} + \epsilon), & \text{if } t < \frac{T}{2} \\ (F_{valid} + F_{forbidden}), & \text{otherwise} \end{cases} \tag{21}$$

目标函数：对于每个节点， y 使用掩码作为软约束进行计算，然后施加拓扑约束以及目标数据损失约束。

$$\mathcal{L}_{target} = 100 \cdot (y_{t,i} - v)^2 \tag{22}$$

$$\lambda_t = \lambda_{soft}(1 + \frac{t}{T}) \tag{23}$$

$$\mathcal{L}_{topology} = \lambda_t ||F_{forbidden}||_2 \tag{24}$$

$$\mathcal{L}_{total} = \mathcal{L}_{target} + \mathcal{L}_{topology} \tag{25}$$

输出：最后，通过最小化总损失 $\mathcal{L}_{total}$ to y tar- get 得到逆变换，具体做法是使用以下激活函数： $Output = \sigma(Wo())$，即最小化模型的计算结果与输入数据计算结果之间的差异。最小化： $Y - \sigma(W\sigma(x))$

5 实验结果与讨论

该神经网络已在大约十个数据集上进行测试；首先，在智慧城市的合成数据集上，分别测试了 9、14、19 和 24 个节点的规模。这些数据均为随机生成，但模型的表现依然出色，甚至十分稳定。此外，还在包含蛋白质的 Sachs [11] 问题上测试了 11 和 25 个节点。经验证，该网络在此场景下能够正常工作且表现稳定。此外，还纳入了 IEEE 总线拓扑和汽车 MPG 数据集，以进一步证实该原型能够正常运行。

表 1：因果评估实验总结

实验 / 拓扑	节点	直接边准确率	传递链准确率
基础城市策略	9	99.29% ± 2.20%	99.38% ± 1.92%
扩展城市策略	14	90。89% ± 3.75%	85.91% ± 6.06%
部委城市政策*	19	87。50% ± 5.49%	74.64% ± 6.05%
扩展城市政策	24	86。49% ± 3.69%	76.13% ± 4.87%
Sachs蛋白质网络	11	76.83% ± 8.20%	75。00% ± 13.46%
Sachs蛋白质网络	25	74。60% ± 8.56%	63.50% ± 9.10%
Auto MPG（机械）	6	79.29% ± 7.11%	83。12% ± 7.93%
IEEE电网	14	73.88% ± 11.48%	81。88% ± 20.87%

*注：尽管章节标题写着“20 个节点”，但代码中定义了 19 个不同的节点。

MPG 是一组很有意思的数据集，因为该系统考察了真实数据。一个主要挑战是构建一个可运行的系统，而我们通过这种方式解决了这一问题。此外，系统运行效果很好；无论面对真实数据还是合成数据，它都能在所进行的交叉验证中给出良好且准确的预测。现在可以追踪并解决更多问题，尤其是针对真实数据的问题。数学概念很有意思，而且与代码相吻合。我们还测试了一些更复杂的变体，例如一种考虑深度为一的父子关系并将其作为判定标准的方法，但并未带来任何额外好处。另一个有意思的想法是，对节点的子节点与父节点关系使用完整动态，而不是递归深度；然而结果大致相同，甚至可能更差。

首先可以观察到，根据输入规格，租车公司可以自行决定提供不同的汽车。有人走进来，要求一辆好车，而好意味着低成本和高质量，系统中有可供搜索的节点实体；此时不再单纯依赖余弦度量，而是使用模糊逻辑来定义“好”的隶属度，然后通过逆解搜索相似性。另一点是，评估折有好有坏；为了找到最佳评估折，人们只关注好的评估折，因为该评估折更能理解解决方案。此外，系统知道解决方案的一般模式，据此可以

判断逆向策略是对还是错。选出最佳反演结果，就能得到最准确的策略。不过那是另一个话题；目前的问题主要是如何使用神经网络来模仿模糊认知图。

6 结论

总而言之，本文介绍了玻璃盒架构的实现，并给出了一些示例。本文指出了神经符号模糊计算中的一个研究空白，并采用多路复用设计来填补这一空白。通过所提出的透明架构，可以模拟模糊认知图，并验证可微性等一些有趣的性质。最后，由于所提出的架构具有透明性，人们不禁对此产生兴趣：在最小化损失的同时，还可以迫使模型按照某些期望的性质运行。这似乎是逻辑上的一个良好转变。在该模型的设计过程中，我们发现这一想法效果很好；因此，我们希望未来神经网络的发展趋势能够转向玻璃盒。

致谢

需要指出的是，本文是目前正在雅典经济与商业大学（AUEB）进行的一项博士学位论文的一部分，该论文研究服务设计流程中的信息传输模糊优化。本文的写作也与Dimitris Kardaras博士保持沟通；他是AUEB该研究课题的导师，同时也对服务优化感兴趣。

参考文献

.[1] Michael S. Bittermann 和 Ozer Ciftcioglu。基于模糊信息处理和多目标进化算法的认知系统。载于《2009年IEEE会议论文集》，2009年。[2] Marco Dorigo 和 Christian Blum。蚁群优化理论：综述。《人工智能评论》，28(1-2):33-53，2005年。[3] Marco Dorigo 和 Thomas St¨utzle。蚁群优化：概述与最新进展。载于《元启发式算法手册》。2019年。[4] Alexis Kafantaris。模糊层次多重网络。arXiv:2512.09976，2025年。提交于2025年12月10日。[5] Mikko Kivel¨a 等。多层网络。《复杂网络期刊》，2(3):203-271，2014年。[6]Giulia Menichetti、Daniel Remondini、Pietro Panzarasa、Ra´ul J. Mon- drag´on 和 Ginestra Bianconi。加权多重网络。《公共科学图书馆·综合》，9(6):e97857，2014年。[7]Gonzalo N´apoles、Agnieszka Jastrzebska 和 Yamisleydi Salgueiro。准非线性模糊认知图的基于学习的聚合。《神经计算》，626:129611，2025年。[8] Elpiniki I. Papageorgiou 和 Jose L. Salmeron。过去十年模糊认知图研究综述。《IEEE模糊系统汇刊》，21(1):66-79，2013年。[9] A. Praveen Prakash 和 N. Vanathi。利用模糊认知双向图分析交通警察的职业危害。《科学、工程与技术杂志》，1(4):846-851，2014年12月。[10]Maziar Raissi、Paris Perdikaris 和 George Em Karniadakis。用于求解涉及非线性偏微分方程的正向和逆向问题的物理信息神经网络：一种深度学习框架。《计算物理学杂志》，378:686-707，2019年。[11] Karen Sachs、Omar P´erez、Dana Pe'er、Douglas A. Lauffenburger 和 Garry P. Nolan。基于多参数单细胞数据推导的因果蛋白质信号网络。《科学》，308(5721):523-529，2005年。

[12]Abdullahi Sani Shuaibu、Ashraf Sharif Mahmoud 和 Tarek Rahil Sheltami。最后一公里配送优化综述：策略、技术、无人机集成与未来趋势。《Drones》，9(3):158，2025年。[13] Witold Stach、Lukasz Kurgan、Witold Pedrycz 和 Marek Reformat。模糊认知图的遗传学习。《Fuzzy Sets and Systems》，153(3):371-401，2005年。[14] Xiaojin Xiong、Ziyan Zeng、Minyu Feng 和 Attila Szolnoki。合作动力多层网络中关系与交互的协同演化。《Chaos》，34(2)，2024年。[15] Lotfi A. Zadeh。软计算与模糊逻辑。IEEE Press，1990年。