arXiv:2601.04019v1 [cs.LG] 7 Jan 2026

使用模糊神经网络对新闻推荐中的行为模式建模

Kevin Innerebner[0009−0001−8556−5371]、Stephan Bartl[0009−0002−6645−5617]、MarkusReiter-Haas[0000−0001−9852−8206]和Elisabeth Lex[0000−0001−5293−2967]

奥地利格拉茨工业大学人本计算研究所

摘要。 新闻推荐系统日益依赖黑箱模型，难以为编辑决策提供足够的透明度。本文提出一种透明的推荐系统，利用模糊神经网络从行为数据中学习可读规则，以预测文章点击。通过在可配置阈值下提取规则，我们可以控制规则复杂度，进而控制可解释性水平。我们在两个公开可用的新闻数据集（即 MIND 和 EB-NeRD）上评估了该方法，结果表明，与多个成熟的基线方法相比，该方法能够准确预测点击行为，同时学习可读规则。此外，我们还表明，学习到的规则揭示了新闻消费模式，使编辑能够根据目标受众行为调整内容策划目标。

关键词： 规则学习 · 新闻消费 · 模糊逻辑 · 透明的推荐系统 · 用户行为建模。

1 引言

新闻机构日益依赖推荐系统向读者推荐文章。虽然这些系统能够提升用户参与度，但它们通常基于深度学习模型构建，编辑对其透明度或控制能力有限。在编辑把关对于打击虚假信息、助力公众知情至关重要的领域，这一问题尤为突出 [18]。编辑面临的双重挑战日益严峻：既要履行传统的编辑职责，又要审查和引导算法新闻策划，而他们往往缺乏足够的信息，无法了解为何推荐某些文章 [15, 20]。

现有新闻推荐系统大多优先考虑预测性能 [21]。然而，新闻领域具有独特特征，例如新闻消费的时间动态变化迅速，以及存在极化风险 [4] ；因此，除了准确预测，还需要对读者行为提供可解释的洞察 [4]。将算法与编辑策选内容相结合的混合方法可在一定程度上缓解这一问题 [9], ，但无法解释模型决策背后的行为模式。我们认为，编辑需要的是从设计上便具备透明性的新闻推荐技术，能够将行为模式转化为

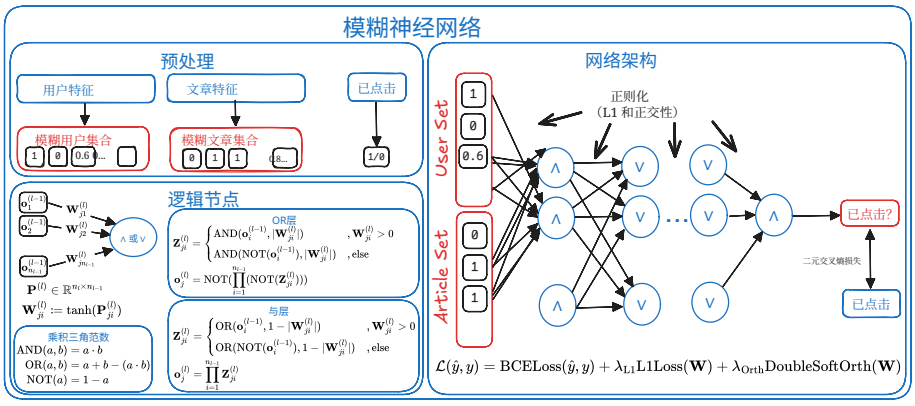

图1：我们模型设计的架构。用户和文章特征被转换为模糊集，作为输入。我们的模型包含多个逻辑节点层，对其输入执行乘积三角范数运算（∧或 ∨）。逻辑节点的每个输入都带有权重，因此较高的权重会使该输入产生较强的影响，而较低的权重则意味着该输入对计算的影响较小。当相应权重为负时，输入会被取反（¬）。

可读规则，以便分析、交流，并在必要时进行调整。例如，推荐系统可以完全基于模糊逻辑构建，如利用模糊推理预测文章相似度 [1] 或类别兴趣 [14],；但规则库通常是根据领域知识 [1] 手工构建的，或通过启发式方法挖掘得到。一种常见的神经符号替代方案是将模糊逻辑与神经网络相结合。在Wang-Mendel流程 [24], 中，首先对输入进行模糊化，再从输入输出对中挖掘IF-THEN规则；随后可以通过多种方式将这些模糊集/规则与神经网络架构结合：(i) 将用户偏好编码为模糊集并输入网络 [22], ，还可选择通过反向传播调整隶属度 [6]；(ii) 使用多层感知机将输入映射为模糊原子，并在其上应用固定的逻辑电路 [17]；(iii) 使用模糊规则缓解稀疏性，通过预测缺失的（多标准）评分或隐式反馈 [16, 28]；以及 (iv) 使用模糊规则模块的输出增强推荐系统的预测结果 [28,6]。这些混合方法仍依赖启发式规则挖掘（例如 Wang–Mendel）、固定规则集，或将数据映射至预定义模糊原子的方式。与此不同，我们的模型以端到端方式学习规则结构和参数，然后在可配置阈值下提取可读规则。

我们的方法。本文介绍一种基于模糊神经网络（FNN）架构（类似于 [19]）的透明新闻推荐系统，该系统从行为数据中学习可读规则，以预测文章点击。如图 1 所示，模型在分层架构中组合模糊与/或/非运算，从而生成丰富且富有表现力的规则。通过简单的阈值化过程，可以提取复杂度可配置的可解释规则：通过调整阈值，从业者可以在规则长度（进而影响可解释性）

与预测准确率之间进行权衡。除了提供解释，这些规则还能揭示内容消费模式，并使其与编辑目标保持一致，为人工监督提供切实可行的依据。

我们在两个公开可用的新闻数据集 MIND 和 EB-NeRD 上进行了离线实验。MIND [27] 数据集包含微软新闻（一个以英语提供内容的新闻聚合平台）的用户点击日志和文章特征。EB-NeRD [11]包含丹麦报纸$Ekstra\ Bladet$[1], 的点击数据，以及额外的用户和文章特征。我们发现，与几种成熟的基线方法相比，我们的模型能够准确预测点击行为，同时生成可解释、可读的规则。我们进一步展示了提取的规则如何捕捉新闻消费动态（例如近因效应），说明我们的方法如何帮助编辑策划新闻内容。

总而言之，我们的贡献如下[2]:
– 我们提出了一种模糊神经网络（FNN）架构，包含多个层、否定和正则化。– 我们在两个新闻数据集 MIND 和 EB-NeRD 上验证了所提方法的有效性，并将其与多种基线方法进行了比较。– 我们从模型的权重中提取规则，并展示了这些规则与模型预测结果的一致性。– 我们基于从模糊神经网络中提取的规则分析新闻读者行为，并讨论将模型用作新闻编辑辅助工具的应用。

2 使用模糊神经网络进行可解释规则学习

我们提出了一种模糊神经网络（FNN），它以分层架构组合模糊逻辑算子。与先前的工作相比， [3], 我们的方法支持多个层、否定操作，并纳入正交性正则化 [2]，以提高规则可解释性。

模糊神经网络。设 L 为层数，$\mathbf{o}^{(0)} \in [0,1]^{n_0}$为输入原子。每层由执行模糊逻辑运算的节点构成，这些运算基于乘积三角范数 [8], 定义，适用于两个模糊变量 $a,\ b \in [0,1]$ 如下:

$$\texttt{AND}(a,b) \coloneqq a \cdot b, \quad \texttt{OR}(a,b) \coloneqq a + b - a \cdot b, \quad \texttt{NOT}(a) \coloneqq 1 - a$$

层中的所有节点都执行相同的运算（与或或）。与多层感知器类似，每一层的输出$\mathbf{o}^{(l)} \in [0,1]^{n_l}$ （对于 $1 \leq l \leq L$）由前一层的输出$\mathbf{o}^{(l-1)}$和模糊权重矩阵$\mathbf{W}^{(l)} \in [-1,1]^{n_l \times n_{l-1}}$计算得出。加权输入$\mathbf{Z}^{(l)} \in [0,1]^{n_l \times n_{l-1}}$定义为：对于与层，$\mathbf{Z}_{ji}^{(l)} = $或$(\mathbf{o}_i^{(l-1)}, 1 - |\mathbf{W}_{ji}^{(l)}|)$；对于或层，则定义为$\mathbf{Z}_{ji}^{(l)} = $与$(\mathbf{o}_i^{(l-1)}, |\mathbf{W}_{ji}^{(l)}|)$ [19]。当权重$\mathbf{W}_{ji}^{(l)} < 0$ 为负时，我们会在加权之前对输入取反

[1] https://ekstrabladet.dk/ [2] 代码可在 https://anonymous.4open.science/r/FNN4NewsRecommendation/ 获取。

4 Innerebner 等人。

，即 NOT($\mathbf{o}^{(l-1)}$)。对于与层，该层的输出定义为$\mathbf{o}_j^{(l)} = \prod_{i=1}^{n_{l-1}} \mathbf{Z}_{ji}^{(l)}$；对于或层，则定义为$\mathbf{o}_j^{(l)} = \text{NOT}\big(\prod_{i=1}^{n_{l-1}} \text{NOT}(\mathbf{Z}_{ji}^{(l)})\big)$。权重定义了模糊输入对逻辑合合取（或析取）的贡献程度；权重为 0 表示完全没有贡献，权重为 1 表示完全贡献（如同清晰逻辑中一样）。

模糊权重 $\mathbf{W}^{(l)}$ 由模型参数 $\mathbf{P}^{(l)} \in \mathbb{R}^{n_l}$ 推导而来，以支持无约束的梯度下降。与以往的工作不同， [3], 我们对 $\mathbf{P}^{(l)}$应用双曲正切函数，将权重限制在区间 $[-1, 1]$内。这一修改使模型能够学习否定——如上所述——从而能够表示任意逻辑公式。

特征离散化。 由于模糊逻辑要求取值位于 $[0, 1],$ ，我们采用了若干预处理步骤。类别特征 中包含 n个类别的特征会使用独热编码转换为清晰集合 $v = \{0, 1\}^{21}$ ，其中涵盖出现频率最高的 20 个类别以及一个低频类别。多类别特征 会转换为清晰集合；多个条目可以取值为 1，并保留所有类别。数值特征 会离散化为三个基于分位数的分箱：低、中和高。缺失值 会替换为相应模糊集合的均值。

规则提取。 为了提取规则以供分析和解释，我们对权重进行阈值化处理。与 $|\mathbf{W}_{ji}^{(l)}| < t$ 相连的连接会被剪枝，其余连接则映射为清晰逻辑公式。从输入原子开始，我们根据前一层的输出构建或/与子句，以表示模糊神经网络的内部逻辑（如算法 1 所述）。

3 学习新闻行为以实现编辑监督

我们使用提供的时间训练-验证划分，在 EB-NeRD [11]和 MIND [27] 数据集的小型版本上评估我们的方法。给定有关用户和文章的模糊特征，我们训练模型来判断某条内容是否与用户相关。虽然这一任务与新闻文章排序的目标并不直接一致，但我们可以利用模糊模型的预测结果对文章进行排序。

文章年龄原子 新闻文章的相关性本质上具有时效性，因为用户参与度会随时间推移而下降 [27]。为了捕捉时间动态，我们将文章年龄 编码为以下时间区间：30 分钟、1 小时、2 小时、4 小时、8 小时、12 小时、1 天、2 天、3 天和 > 3 天。我们选择更加关注近期时间尺度，并在超过 3 天后停止划分区间。每篇文章只会被分配到文章年龄最小的区间，因此，一篇发布了 3 小时的文章只属于 4 小时区间。

EB-NeRD 原子在我们的实验中，我们利用 EB-NeRD 数据集提供的用户和文章信息。具体而言，我们使用设备类型、用户的性别、年龄（按 10 年年龄段划分）、根据邮政编码确定的地区类别，以及

用户是否为付费内容订阅者（占用户的 3.35%）。有关性别、年龄和邮政编码的数据较为稀疏，超过 95% 的条目为“未知”。对于文章，我们对文章类型、类别、子类别、主题、情感标签和付费订阅情况进行编码。此外，我们还对发布后前七天的行为数据进行建模，包括文章展示总次数（即展示次数）、点击总次数（即页面浏览量）以及总阅读时长（即阅读时长）。文章类型和类别的分布均呈偏斜：12 种文章类型中有 4 种、25 个类别中有 9 个，各自占据了 99% 的文章。

MIND 原子 与 EB-NeRD 数据集不同，MIND数据集仅提供有限的用户和文章特征。对于用户，只有 ID 和历史记录可用，这限制了我们对用户属性进行建模的能力。对于文章，我们对类别、子类别、文章标题和摘要中检测到的实体进行编码（由数据集创建者使用命名实体识别技术检测）。常见实体包括“唐纳德·特朗普”、“美国”和“国家橄榄球联盟”，

算法 1： 一种规则提取算法。移除所有权重低于阈值 t的连接，从而将模糊逻辑运算映射为清晰逻辑算子。

输入： W . . .训练好的模糊神经网络， a_i . . .表示第 i个模糊输入原子， t . . .提取阈值

$r \leftarrow [a_i | i \in [1, 2, \ldots]]$; // 用输入原子初始化子句
对 $l \in [1, 2, \ldots, L]$ **执行**
  $\mathbf{W}^{(l)} \in [0, 1]^{\text{out} \times \text{in}}$; // 当前层的权重
  $r' \leftarrow [\,]$; // 新子句
  对 $o \in [1, 2, \ldots, \text{out}]$ **执行**
    $c \leftarrow [\,]$; // 新子句
    对 $i \in [1, 2, \ldots, \text{in}]$ **执行**
      // 仅存储权重较高的子句
      如果 $|\mathbf{W}^{(l)}_{o,i}| > t$ **则**
        $c \leftarrow c + [r_i]$ 如果 $\mathbf{W}^{(l)}_{o,i} > 0$ 否则 $c + [\text{NOT}(r_i)]$
      end
    end
    $\bigoplus \in \{\bigwedge, \bigvee\}$; // l层的逻辑运算符
    $c \leftarrow \bigoplus_{k=1}^{\text{length}(c)} c_k$; // 忽略 $c_k = [\,]$
    $r' \leftarrow r' + [c]$; // 添加新子句
  end
  $r \leftarrow r'$; // 为下一次迭代存储新子句
结束
返回 r_0 ; // 最终子句是提取出的规则

这表明该数据集明显侧重于美国新闻。

超参数。我们使用**AdamW** [13]($lr = 0.01$，批量大小 $= 8196$，训练轮数 $=$20，权重衰减 $= 10^{-5}$)，并采用二元交叉熵损失（BCE）。为引导模型学习更简单的规则，我们使用 L1 正则化（$\lambda_{L1} = \frac{0.1}{\#\text{参数}}$）。此外，我们采用双重软正交正则化 [2]($\lambda_{orth} = \frac{0.1}{\#\text{参数}}$)，以鼓励同一层中的不同子句彼此区分。该架构包含三个隐藏层（48，32，16 个神经元）和一个输出层，各层之间交替使用 AND/OR运算符。我们评估两种设置：**FNN-and** （输出节点为与）和 **FNN-or** （输出节点为或）。模型权重采用 Kaiming均匀初始化 [7] ，增益为 $\frac{5}{3}$。由于用户通常点击的文章少于展示的文章，我们为每次曝光随机抽取 $K = 4$ 篇未点击文章 [25]。

评估。按照以往对数据集的研究，我们计算 AUC、MRR、

nDCG@5 和 nDCG@10 [27, 11] ，针对按曝光分组的物品排名进行评估。此外，我们引入一项自定义指标“规则复杂度”RC@t，其定义为在阈值 t 处提取的清晰规则中逻辑运算符的数量，即 $\wedge$、 $\vee$ 和 $\neg$（参见第2节）。

我们将本方法与以下基线方法进行比较：随机基线，它使用截断的 ($[0, 1]$) 正态分布（根据训练集估计）为用户-物品对预测随机分数；用户-*KNN* 和 基于物品的*K*近邻算法，二者都是基于用户间和物品间相似度的协同过滤 k 近邻模型；$SVD++$，它对用户-物品矩阵进行奇异值分解，并针对隐式反馈进行了修改 [10]; 决策树，在清晰原子上训练，通过可解释的树结构学习纯粹的清晰规则。 $NRMS$，一种成熟的双塔神经网络新闻推荐模型 [26]。

4 结果

我们报告了在 EB-NeRD 和 MIND 上的性能结果；后续分析则聚焦于 EB-NeRD，因为它提供了更多特征。对于每项实验，我们报告 5 次运行的平均结果。

4.1 定量结果

我们在两个数据集上进行了定量实验，并对五次运行的结果取平均值（见表 1）。我们通过与六种基线方法进行比较来评估预测能力（其中包括一种不具备可解释性特征的深度学习黑盒模型 NRMS）。由于冷启动问题，KNN 和 SVD 在除 AUC 以外的所有评估指标上表现不佳。这是由于采用了时间切分，且文章会随着时间推移而失去相关性。因此，许多物品未被纳入训练集，KNN 和 SVD 转而预测全局平均分。

表 1：定量结果（与基线方法对比）。最佳结果：**粗体**，次佳结果：下划线。

方法	EB-NeRD 小型 AUC	MRR	nDCG@5	nDCG@10	MIND 小型 AUC	MRR	nDCG@5	nDCG@10
随机基线	.5002	.3015	.3211	.4119	.4996	.2184	.2228	.2858
用户-KNN	.5005	.1681	.1385	.2716	.5004	.2192	.2242	.2864
基于物品的K近邻算法	.5006	.1669	.1381	.2712	.4998	.2183	.2235	.2858
SVD++	.5010	.3059	.3382	.4244	.5003	.2197	.2243	.2871
决策树	.6039	.3784	.4164	.4840	.5812	.2717	.2963	.3532
NRMS	.5548	.3488	.3878	.4648	**.6548**	**.3094**	**.3402**	**.4043**
FNN-or（我们的方法）	.6915	**.4582**	.5175	.5662	.5766	.2450	.2716	.3339
FNN-and（我们的方法）	**.6925**	.4580	**.5176**	**.5664**	.5806	.2485	.2752	.3355

在EB-NeRD上，就所有评估指标而言，我们的方法优于所有基线方法。不过，此前已有表现更好的模型被报道 [12]（在测试集上的nDCG@10最高达到79.10

表2：消融研究结果，展示了模型使用不同组件时各评估指标的均值。星号（*）表示在与 FNN-and 配置进行的配对 Dunn 检验中，经 Bonferroni 校正后存在显著差异（$\alpha = 0.05$）。

实验	AUC	MRR	nDCG@5	nDCG@10	RC@0.4	RC@0.5	RC@0.6
FNN-and（我们的模型）	**.692**	.457	**.517**	.565	175.2	91.2	27.4
FNN-or（我们的模型）	.689	.456	.514	.564	48.4	13.2	3.4
二元交叉熵 →均方误差损失	.691	**.458**	**.517**	**.566**	70.8	33.8	13.4
无 L1正则化	.691	.456	.516	.565	67.8	40.8	16.6
无正交正则化 .687		.453	.512	.562	5160.4	2475.0	627.0
无负采样 .680		.448	.504	.555	77.0	41.0	26.4
无文章年龄	.600*	.374*	.418*	.491*	184.8	80.0	28.0
双曲正切 →Sigmoid函数	.523*	.310*	.343*	.429*	1.0*	1.0*	1.0

）。尽管如此，我们发现模型能够提供准确的预测，同时规模较小，仅包含 2064（$48 \times 32 + 32 \times 16 + 16 \times 1$）个参数。在MIND数据集上，我们观察到较低的性能。原因之一是可用于模型输入的特征不足（见第3节）。这反映了我们方法的一项局限性：性能取决于所提供特征的丰富程度。尽管我们可以从文章中提取额外信号，例如文章年龄（见第2节），但这仍然取决于数据集。

虽然我们在 EB-NeRD 上优于使用与我们模型完全相同输入（即离散化特征）的决策树，但在 MIND数据集上的表现较低。这表明，尽管我们的模型能够随着特征增多而提升性能，但当模型复杂度保持不变时，在可用输入特征较少的情况下，决策树也具有竞争力（甚至表现更好）。

4.2 消融研究

为验证各组件的作用，我们通过调整模型配置进行消融研究（表2）：(i) “BCE → 均方误差损失”使用均方误差（MSE）替代二元交叉熵；(ii) “无 L1正则化”和“无正交正则化”分别移除 L1 损失项和正交损失项；(iii) “无负采样”使用所有可用交互，而非负采样；“无文章年龄”则移除文章年龄输入；(iv) “双曲正切 → Sigmoid函数”使用 Sigmoid函数计算权重，因此模型不再具备对否定进行建模的能力。我们使用 Kruskal-Wallis H检验发现，所有评估指标在不同运行之间均存在显著差异，并针对每项评估指标进行成对 Dunn检验及 Bonferroni校正。

切换到均方误差（MSE）并不会降低性能，还会略微改善两个评估指标，但会始终产生较低的权重。对于可解释性而言，这一点很重要：规则提取会将模糊模型通过阈值转换为清晰规则，而当模型的权重为 1 或 0 时，这种转换的有效性会提高，这意味着提取的清晰规则——对于除 $t = 0$ 和 $t = 1$ 之外的任何阈值——都能完美描述模型的逻辑。由于在我们的设置中，二元交叉熵（BCE）比均方误差（MSE）更能体现这一点，因此我们

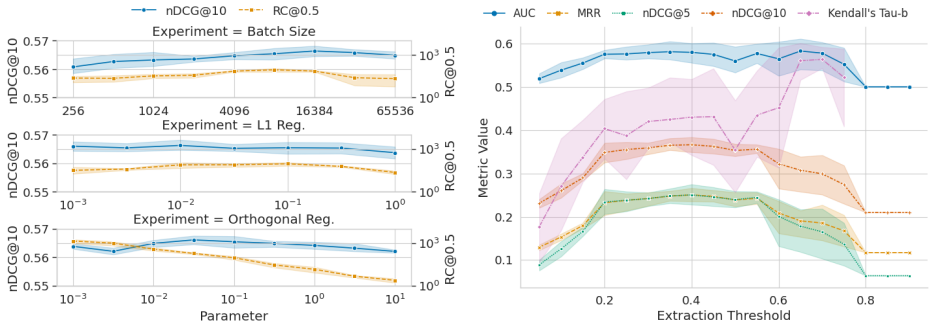

(a) 批量大小、L1 正则化和正交正则化的敏感性分析。我们展示了预测性能（以 nDCG@10 衡量）和规则复杂度（以 RC@0.5 衡量）。参数（x 轴）和 RC@0.5（右侧 y 轴）均采用对数刻度。(b) 在 EB-NeRD-small 验证集划分上提取的清晰规则的性能，并针对多个阈值进行可视化。此外，我们使用肯德尔 Tau-B 基于排名的相关性指标，衡量预测排名与模型预测排名之间的相关性。

图 2：参数敏感性（训练）和阈值（预测）分析。

将二元交叉熵作为默认选项。最后，使用 Sigmoid函数计算权重会使模型无法表示否定，从而降低模型的表达能力。

4.3 敏感性分析

我们通过对批量大小、L1 正则化和正交正则化进行参数扫描来分析敏感性，并在图 2a 中展示预测性能和规则复杂度。

对于批量大小，我们想重点关注 4096 到 16384 之间的区域。在此范围内，不同运行之间的规则复杂度变化最小，同时准确率保持较高水平。默认批量大小 8096 正好处于该范围的中间位置；尽管其预测性能略逊于 16384，但不同运行的误差条（95% 置信区间）大部分重叠。

L1 正则化对模型性能没有显著影响，但我们可以看到，在 $10^{-1} = 0.1$ 时获得的规则最具表达力。我们还可以看到，当阈值为 0.5 时，无论 L1 正则化值高低，规则的表达力都呈下降趋势。在消融研究（第 4.2 节）中，我们观察到，完全关闭 L1 正则化后，规则复杂度会降至原来的一半左右。这可能看起来有些违背直觉，因为 L1 损失会促进特征选择。特征选择会使大多数权重接近 0，而将重点放在少数输入上，并推动这些输入对应的权重趋近于 1。因此，提取出的规则会更多，因为重要特征具有较高的权重，具体来说，权重高于 0.5 的阈值。由此，选定的默认 L1 正则化参数为 0.1。

正交正则化对规则复杂度有很大影响。我们可以观察到，在阈值为 0.5 时，该参数与规则复杂度之间存在明显的双对数关系。由于我们既希望获得良好的预测性能，也希望规则具有表达力且仍然易于解释，因此将默认参数设为 0.1。请注意，该参数可用于控制提取规则的复杂度，但对预测性能的影响较小。

4.4 规则解释

图 2b 展示了在模型权重保持冻结时，提取的规则在不同阈值下的表现。由于提取的规则是明确的，因此曝光的可能输出只有**真** 和**假**，这在排序任务中会导致所有**真** 曝光之间以及所有**假** 曝光之间出现并列。

为了验证提取的规则与模型实际预测的一致性，我们计算了模型整体排序与提取规则之间的相关性。相关性统计量采用肯德尔 Tau-B，该统计量会对并列情况进行调整。我们观察到，随着阈值水平升高，相关性呈上升趋势，而准确率则在 0.2 至 0.55 之间趋于饱和。

对于阈值 > 0.8，提取的规则会预测一个恒定输出，即**真** 或**假**，原因可能是该规则为矛盾式，例如 $a \wedge \neg a$，或为重言式，例如$a \vee \neg a$。由于所有预测都相同，因此无法计算肯德尔 Tau-B。

4.5 提取规则的定性分析

我们使用 0.55 的阈值提取清晰规则，由此得到规则复杂度低、nNDG 高的规则。为进一步提高规则的可读性，我们将连续的文章年龄时间段合并，例如将 2h-4h 和 4h-8h 合并为 2h-8h。

我们将最后一层的输入视为不同的规则，并保留其权重，从而提高可解释性。由于此处研究的是 FNN-and 配置，最后一个节点为 AND，因此这些规则是相关性的必要条件。若最后一个节点为 OR，则这些规则是相关性的指标。

表3中的提取规则表明，文章相关性主要取决于文章年龄或“page9”类别（由 $C_{\texttt{side9}}$ 表示）。布尔符号 $C_{\texttt{nationen}}$ 对应“国家”类别，而 SC_{265} 表示一个未公开的子类别，ID 为 265。 AA_{interval} 表示文章年龄处于“区间”内。 $IV_{\texttt{low}}$ 表示视图内计数属于低分位数。

权重最高的规则（R1）要求文章年龄小于一天，但“第9页”类别中的文章除外。规则 R2——以及与其相同的规则 R3——始终为**真**，因为文章年龄析取项始终**为真**，即 $\neg AA_{30m-1h} \vee \neg AA_{1d<}$。规则 R4——与规则 R5 相同——要求文章发布于 30 分钟以内或 1 小时以上（AA_{2h-1d} 处于这一区间内，因此可在清晰规则中忽略）。最后，从技术上讲，R6 始终**为真** （$\neg AA_{30m-1h} \vee \neg AA_{1d<}$），但也表明我们的模型会利用“国家”类别、子类别 265 以及较低的视图内计数来预测用户点击。

表3：从 FNN-and 输出节点提取的规则。

规则	权重	提取的清晰规则
R1	0.95	$C_{\text{side9}} \vee \neg AA_{1d<}$
R2	0.94	$C_{\text{side9}} \vee \neg AA_{30m-1h} \vee \neg AA_{1d<}$
R3	0.93	R2
R4	0.83	$\neg AA_{30m-1h} \vee AA_{2h-1d}$
R5	0.66	R4
R6	0.57	$C_{\text{nationen}} \vee SC_{265} \vee IV_{\text{low}} \vee \neg AA_{30m-1h} \vee \neg AA_{1d<}$

5 变革理论：一种透明的、用于编辑监督的模糊神经新闻推荐器

我们通过设计来满足新闻推荐中对透明度的需求：黑箱新闻推荐系统限制了编辑监督，也与日益增多的算法透明度强制要求相冲突，例如欧盟人工智能法案 [23] 所提出的要求。我们的方法并非旨在取代编辑，而是作为决策支持工具（而非自动化新闻推送工具）。我们的新闻推荐系统基于曝光日志以及用户和文章元数据进行训练，并输出清晰、可读的规则，以反映从读者行为中观察到的模式。这些规则通过规则复杂度（RC@t）和 Kendall's τ_b 量化，与输出结果相对应。借此，我们使编辑能够诊断推荐背后的根本原因，并通过编辑规则或调整阈值来管理推荐，从而使算法行为适应新闻价值观和编辑政策。预期影响是提高透明度，并支持新闻策展中的编辑责任。这一变革理论的前提是能够访问日志数据、编辑参与，以及允许开展诊断的流程。风险包括过度简化、编辑室对技术的回避 [15],以及数据稀疏性；我们通过公开阈值 t、报告规则复杂度（RC@t）和 Kendall's τ_b，以及监测排序性能来降低这些风险。

6 结论与未来工作

我们的FNN模型能够准确预测点击行为，同时揭示与编辑监督相关的新闻消费模式。我们通过消融研究和敏感性分析验证了这一方法。此外，我们确认提取的规则与模型的预测逻辑一致，并结合新闻消费的背景对这些提取的规则进行了定性分析。这些信息有助于编辑实现内容策划目标，例如平衡新闻报道的时效性。未来，我们计划研究如何将这些学习得到的规则与人工定义的规则（如编辑指南）相结合。此外，我们计划使模型具备可分解、平滑和确定性等特性（定义见 [5]），以支持可处理查询（例如，哪些主题与特定人口统计群体更相关），从而具备审计能力并遵守法规。

致谢。本研究全部或部分由奥地利科学基金（FWF）资助，项目编号为10.55776/COE12。

参考文献

1. Adnan, M.N.M.、Chowdury, M.R.、Taz, I.、Ahmed, T.、Rahman, R.M.：基于模糊逻辑的基于内容的新闻推荐系统。载于：2014年国际信息学、电子与视觉会议（ICIEV）。第1–6页。电气电子工程师学会（2014） 2. Bansal, N.、Chen, X.、Wang, Z.：在训练深度卷积神经网络时，我们能从正交性正则化中获得更多收益吗? arXiv电子预印本（2018年10月） 3. Bartl, S.、Innerebner, K.、Lex, E.：用于推荐系统的可微模糊神经网络。载于：第33届ACM用户建模、适应与个性化会议附属论文集。第343–348页。UMAP Adjunct '25，美国纽约州纽约市计算机协会（2025）。https://doi.org/10.1145/3708319.3734174, https://doi.org/10 3734174 4 1145 3708319 . / . . Bentley, F.、Quehl, K.、Wirfs-Brock, J.、Bica, M.：理解在线新闻行为。载于：2019年CHI人因计算系统会议论文集。第1–11页（2019） 5. Darwiche, A.、Marquis, P.：知识编译图。《人工智能研究杂志》**17**，229–264（2002）。https://doi.org/10.1613/JAIR.989, https://doi.org/10 989 6 1613. /jair. . Deng, J.、Chen, J.、Wang, S.、Ye, J.、Wang, Y.：用于推荐系统的新型模糊神经协同过滤。《专家系统与应用》**258**，125153（2024年12月 125153 7 10 1016 2024 ）。https://doi.org/ . /j.eswa. . . He, K.、Zhang, X.、Ren, S.、Sun, J.：深入研究整流器：在ImageNet分类上超越人类水平的性能。载于：2015年IEEE国际计算机视觉会议，I CCV 2015，智利圣地亚哥，2015年12月7–13日。第1026–1034页。IEEE计算机学会（2015）。https://doi.org/10 123 8 1109 2015 123, 10 1109 2015 8 2013 . /ICCV. . https://doi.org/ . /ICCV. . . Klement, E.P.：三角范数，第 卷。施普林格科学与商业媒体（ ） 9. Klimashevskaia, A.、Elahi, M.、Jannach, D.、Trattner, C.、Buodd, S.：赋能编辑：自动化推荐如何支持编辑部文章策选。载于：与2024年ACM推荐系统会议（RecSys 2024）联合举办的国际新闻推荐与分析研讨会论文集，意大利巴里，2024年10月18日（2024） 10. Koren, Y.：因子分解遇见邻域：一种多面向的协同过滤模型。载于：Li, Y.、Liu, B.、Sarawagi, S.（编）：第14届ACM SIGKDD知识发现与数据挖掘国际会议论文集，美国内华达州拉斯维加斯，2008年8月24–27日。第426–434页。ACM（2008）。https://doi.org/10.1145/1401890.1401944, https://doi.org/10 1401944 11 1145 1401890 . / . . Kruse, J.、Lindskow, K.、Kalloori, S.、Polignano, M.、Pomo, C.、Srivastava, A.、Uppal, A.、Andersen, M.R.、Frellsen, J.：EB-NeRD：用于新闻推荐的大规模数据集。载于：2024年推荐系统挑战赛论文集。第1–11页（2024） 12. Kruse, J.、Lindskow, K.、Kalloori, S.、Polignano, M.、Pomo, C.、Srivas- tava, A.、Uppal, A.、Andersen, M.R.、Frellsen, J.：EB-NeRD：用于新闻推荐的大规模数据集。载于：推荐系统

挑战赛2024论文集，RecSysChallenge 2024，意大利巴里，2024年10月14–18日。第1–11页。ACM（2024）。https://doi.org/10.1145/3687151.3687152, https://doi.org/10.1145/3687151.3687152 13. Loshchilov, I.、Hutter, F.：解耦权重衰减正则化。载于：第7届国际学习表征会议，ICLR 2019，美国新奥尔良，2019年5月6–9日。OpenReview.net（2019），https://openreview.net/forum?id=Bkg6RiCqY7 14. Manoharan, S.、Senthilkumar, R.：使用社交媒体挖掘的智能基于模糊规则的个性化新闻推荐。《计算智能与神经科学》**2020**（1），3791541（2020） 15. Møller, L.A.：为你推荐：报纸如何使算法新闻推荐规范化，以适应其把关角色。《新闻学研究》**23**（7），800–817（2022） 16. Nilashi, M.、Ibrahim, O.B.、Ithnin, N.、Zakaria, R.：使用降维和神经模糊技术的多准则推荐系统。《软计算》**19**，3173–3207（2015） 17. Ochoa, J.G.D.、Csiszár, O.、Schimper, T.：基于连续值逻辑和多准则决策算子、使用可解释神经网络的医疗推荐系统。《BMC医学信息学与决策制定》**21**（1），186（2021年12月）。https://doi.org/10.1186/s12911-021-01553-3 18. Olsen, R.K.、Solvoll, M.K.、Futsæter, K.A.：把关人即守护者——绘制新冠肺炎危机期间受众对新闻媒体编辑监督职能的态度。《新闻与媒体》**3**（1），182–197（2022） 19. Pedrycz, W.：模糊神经网络与神经计算。《模糊集与系统》**56**（1），1–28（1993）。https://doi.org/https://doi.org/10.1016/0165-0114(93)90181-G, https://www.sciencedirect.com/science/article/pii/016501149390181G 20. Peukert, C.、Sen, A.、Claussen, J.：编辑与算法：在线新闻中的推荐技术。《管理科学》**70**（9），5816–5831（2024） 21. Raza, S.、Ding, C.：新闻推荐系统：近期进展、挑战与机遇综述。《人工智能评论》第1–52页（2022） 22. Rutkowski, T.、Romanowski, J.、Woldan, P.、Staszewski, P.、Nielek, R.、Rutkowski, L.：使用神经模糊方法的基于内容的推荐系统。载于：2018年IEEE国际模糊系统会议（FUZZ-IEEE）。第1–8页。电气电子工程师学会，里约热内卢（2018年7月）。https://doi.org/10.1109/FUZZ- IEEE.2018.8491543 23. Schedl, M.、Anelli, V.W.、Lex, E.：信息检索与推荐系统的技术和监管视角：公平性、透明度与隐私。施普林格 24. Wang, L.X.、Mendel, J.：通过从示例中学习生成模糊规则。《IEEE系统、人类与控制论汇刊》**22**（6），1414–1427（1992）。https://doi.org/10.1109/21.199466 25. Wu, C.、Wu, F.、An, M.、Huang, J.、Huang, Y.、Xie, X.：NPA：具有个性化注意力的神经新闻推荐。载于：Teredesai, A.、Kumar, V.、Li, Y.、Rosales, R.、Terzi, E.、Karypis, G.（编）：第25届ACM SIGKDD知识发现与数据挖掘国际会议论文集，KDD 2019，8，2019 4 2576 2584 2019 10 1145 3292500 3330665，美国安克雷奇，2019年8月–。第–页。ACM（）。https://doi.org/ . / . https://doi.org/10.1145/3292500.3330665

26. Wu, C., Wu, F., Ge, S., Qi, T., Huang, Y., Xie, X.：基于多头自注意力的神经新闻推荐。载于：2019年自然语言处理中的实证方法会议暨第9届国际自然语言处理联合会议（EMNLP-IJCNLP）论文集。第6389–6394页（2019） 27. Wu, F., Qiao, Y., Chen, J., Wu, C., Qi, T., Lian, J., Liu, D., Xie, X., Gao, J., Wu, W., Zhou, M.：MIND：用于新闻推荐的大规模数据集。载于：Jurafsky, D., Chai, J., Schluter, N., Tetreault, J.R.（编），第58届计算语言学协会年会论文集，ACL 2020，线上会议，2020年7月5日至10日。第3597–3606页。计算语言学协会（2020）。https://doi.org/10.18653/V1/2020.ACL-MAIN.331, https://doi.org/10 331 28 18653 1 2020 . /v / .acl-main.。Zhang, W., Zhang, X., Chen, D.：隐式推荐系统中缺失数据的因果神经模糊推理建模。Knowledge-Based Systems **222**，106678（2021年6月）。https://doi.org/10.1016/j.knosys.2020.106678