

DOI:10.20033/j.1003-7241.(2026)02-0063-06

RMCNN 多领域知识融合的电力风险预警模型

孙伟¹, 刘辉², 邢璐¹, 许牧晨³, 赵鑫³

(1. 国网安徽省电力有限公司电力科学研究院, 安徽 合肥 230601; 2. 国网安徽省电力有限公司, 安徽 合肥 230061;
3. 安徽继远软件有限公司, 安徽 合肥 230088)

摘要:为了解决电力系统中故障和异常数据稀缺且不完整的问题,提高预测的准确性和实时性,研究提出了一种多领域知识融合模型。利用卷积神经网络的特征提取能力,并结合相关记忆机制,来提高知识图谱链接预测的准确性。通过知识图谱揭示潜在复杂关联并识别可能的风险点,使用 CombE 模型结合 1D 和 2D 卷积嵌入来进行链路预测。结果表明,相较于基线模型 TransE,所提相关记忆-卷积神经网络模型(relevant memory convolutional neural network,RMCNN)在 FB15K-237 和 WN18RR 上的平均倒数排名分别提高了 25% 和 150%。RMCNN 在 FB15K-237 上的平均倒数排名和 Hit@10 较 ConvE 分别提高了 13% 和 12%。多领域知识模型在电力系统风险预警中的应用,显著提升了预警的准确性和可靠性,为电力系统的安全运行提供了有力保障。

关键词:RMCNN; 电力系统; 多领域知识融合; 风险预警; 建模

中图分类号: TP18

文献标志码: A

文章编号: 1003-7241(2026)02-0063-06

RMCNN multi-domain knowledge fusion for power system risk warning model

SUN Wei¹, LIU Hui², XING Lu¹, XU Muchen³, ZHAO Xin³

(1. State Grid Anhui Electric Power Research Institute, Hefei 230601, Anhui, China; 2. State Grid Anhui Electric Power Co., Ltd., Hefei 230601, Anhui, China; 3. Anhui Jiyuan Software Co., Ltd., Hefei 230088, Anhui, China)

Abstract: In order to solve the problem of scarce and incomplete fault and abnormal data in power system and improve the accuracy and real-time prediction, a multi-domain knowledge fusion model is proposed in this paper. The feature extraction capability of convolutional neural network combined with related memory mechanism is used to improve the accuracy of knowledge graph linkage prediction. By revealing potential complex correlations through knowledge graphs and identifying possible risk points, the CombE model is used in combination with 1D and 2D convolutional embeddings for link prediction. The results showed that compared to the baseline model TransE, the proposed relevant memory convolutional neural network (RMCNN) model improved its average reciprocal ranking by 25% and 150% on FB15K-237 and WN18RR, respectively. The average reciprocal ranking of RMCNN on FB15K-237 Hit@10 Compared to ConvE, it has increased by 13% and 12% respectively. The application of this model in power system risk warning has significantly improved the accuracy and reliability of warning, providing strong guarantees for the safe operation of the power system.

Keywords: RMCNN; electric power system; multi-domain knowledge integration; risk early warning; modeling

电力系统网络作为现代社会的重要基础设施,负责电力的生产、传输和分配,其安全性和稳定性愈加重要。传统的电力信息安全维护主要依赖事后故障处理,这不仅效率低下,还可能引发整个电力网络的恶性循环^[1]。然而,传统的安全解决方案主要采用基于规则或特征的方法进行攻击检测和防御,但这些方法需要大量人工参与和更新,难以应对快速变化的安全威胁^[2]。随着深度学习技术的发展,利用该技术进行网络安全态势感知和风险评估已经成为热门研究领域^[3-4]。Figetakis E 等研究人员提出了一种基于深度 Q-learning 网络的防御性随机博弈模型。实验表明该方法提高了预测精度,更契合实际攻防场

景^[5]。王洪彬等学者建立了基于循环神经网络(recurrent neural network, RNN)的电网态势感知模型,并提出了相关解析及求解流程。通过某地 110 kV 变电站监控信号数据,通过语义解析及态势感知仿真验证了该模型的有效性和正确性^[6]。尽管深度学习技术的应用可有效地应对电力系统中的安全威胁,然而电力系统中的故障和异常数据稀缺且不完整,加之数据噪声和误差,影响模型训练和预测准确性。为解决这些问题,研究创新性地提出了一种新的模型,将卷积神经网络(convolutional neural network, CNN)与相关记忆(relevant memory, RM)机制相结合,应用于知识图谱(knowledge graph, RG)的链接预测,将该模型称为相关记

收稿日期:2024-08-07;录用日期:2024-08-16

基金项目:国网安徽省电力科技项目资助(52120524000B)

作者简介:孙伟(1986—),男,硕士,高级工程师,研究方向:电网数字化。

引用本文:孙伟,刘辉,邢璐,等. RMCNN 多领域知识融合的电力风险预警模型[J]. 自动化技术与应用, 2026,45(2):63-68. (SUN Wei, LIU Hui, XING Lu, et al. RMCNN multi-domain knowledge fusion for power system risk warning model[J]. Techniques of Automation and Applications, 2026,45(2):63-68.)

忆-卷积神经网络模型(relevant memory convolutional neural network, RMCNN)。研究旨在通过 RMCNN 多领域知识融合模型,高效地捕捉电力系统中元素的复杂关系,从而提升电力系统的实时风险预警能力。

1 基于 RMCNN 的电力系统预警技术

1.1 知识图谱链接预测方法

电力系统的风险预警需要综合数据支持,知识图谱能够整合电力系统中的多源异构数据,构建全面的电力系统知识库。通过实体和关系的表示,知识图谱可高效获取和处理数据,揭示潜在的复杂关联,识别可能的风险点。知识图谱链路预测是通过现有知识图谱中的信息来推测缺失的关系,可发现隐含关系和潜在故障,实现设备连锁故障风险预警^[7]。常见的链路预测模型性能评估的具体计算公式为

$$\begin{cases} \text{MRR} = \frac{1}{|N_S|} \sum_{i=1}^{|N_S|} \frac{1}{r_i} \\ \text{MR} = \frac{1}{|N_S|} \sum_{i=1}^{|N_S|} r_i \\ \text{Hit}@k = \frac{1}{|N_S|} \sum_{i=1}^{|N_S|} \text{Indi}(r_i \leq k) \end{cases} \quad (1)$$

式中, MRR 表示模型性能的平均倒数排名。MR 代表链路预测模型性能的排名平均值。MRR 表示进入前排名所占全部模型的比重。 $|N_S|$ 表示三元组数量。 r_i 代表第 i 个三元组的关联性预测排名。Indi 为指示函数(若为真则为 1, 否则为 0)。知识嵌入表示模型通过评分函数评估三元组的有效性。浅层线性模型提取潜在知识有限,深层非线性模型复杂且易丢失显性知识^[8]。为了应对知识链接预测问题,研究提出了一种名为 CombE 的模型,该模型结合了 1D 和 2D 卷积嵌入的优点。在 CNN 中,1D 卷积用于处理时间序列或一维信号数据,通过在一维方向上滑动卷积核提取特征,计算复杂度低,适合处理较长时间序列数据。它能够有效监测传感器数据中的异常变化,适用于资源有限的嵌入式系统。2D 卷积则处理二维数据,通过在二维平面上滑动卷积核提取丰富的空间特征,计算复杂度较高,但能够深入分析多维数据,捕捉复杂模式,有助于电力系统中二维数据的预警和分析。CombE 模型则充分利用了二者的优势,来提取表面和显性知识。CombE 模型框架见图 1。

图 1 中,CombE 模型由两个主要部分组成。首先,在 1D 部分,模型通过卷积运算从实体和关系嵌入中提取表面和显性的知识。在 2D 部分,模型进行矢量乘法运算,即 $h * r \approx t$, 其中, r 表示关系。 h 与 t 分别代表头实体、尾实体。用于生成一个二维特征矩阵,实现了元素级的融合。最终,1D 卷积和 2D 卷积的结果相加,形成综合特征表示。通过这种设计,CombE 模型不仅能保持三元组的表面语义,还能更深入地挖掘其潜在特征。模型开始时将三元组 (h, r, t) 投影为 k 维向量 $x_h, x_r, x_t \in \mathbf{R}^k$, 并将头实体嵌入和关系嵌入 x_h, x_r 堆叠成特征图 $M_{in} \in \mathbf{R}$ 。首先在 M_{in} 上应用 1D 卷积,得到输出特征图 M_{out} 。具体计算过程见式(2)。

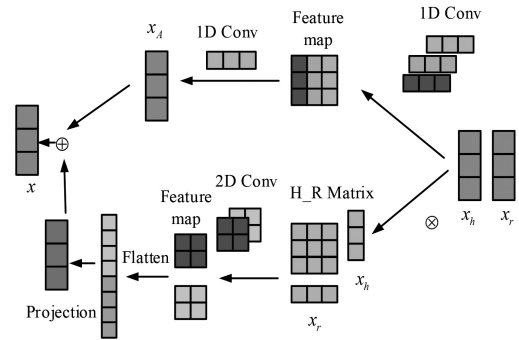


图 1 CombE 模型框架

Fig. 1 CombE model framework

$$M_{out} = M_{in} * \omega_{1D}^1 \quad (2)$$

式中, ω_{1D}^1 表示 1D 卷积核, * 为卷积操作,保留显性特征和三元组的平移特性。随后,使用另一个 1D 卷积核降低 M_{out} 维度,并捕捉全局表面特征 $x_A = M_{out} * \omega_{1D}^2$ 。在路径 B 中,生成头实体嵌入 $x_h = \{x_h^1, x_h^2, x_h^{d_h}\} \in \mathbf{R}^{n \times d_h}$ 和关系嵌入 $x_r = \{x_r^1, x_r^2, x_r^{d_r}\} \in \mathbf{R}^{n \times d_r}$, 并输入融合层进行运算。为最大化实现与尾实体的交互,对头实体嵌入和关系嵌入进行矩阵乘法运算,获得矩阵 $H_R \in \mathbf{R}^{d_h \times d_r}$ 。头实体和关系的融合过程如式(3)所示。

$$\begin{aligned} & \{x_h^1, x_h^2, \dots, x_h^{d_h}\}^T \otimes \{x_r^1, x_r^2, \dots, x_r^{d_r}\} = \\ & \begin{Bmatrix} x_h^1 x_r^1 & x_h^1 x_r^2 & \dots & x_h^1 x_r^{d_r} \\ x_h^2 x_r^1 & x_h^2 x_r^2 & \dots & x_h^2 x_r^{d_r} \\ \vdots & \vdots & \vdots & \vdots \\ x_h^{d_h} x_r^1 & x_h^{d_h} x_r^2 & \dots & x_h^{d_h} x_r^{d_r} \end{Bmatrix} \quad (3) \end{aligned}$$

CombE 模型通过将头实体和关系的嵌入表示转化为二维矩阵,并使用卷积核在矩阵上滑动,捕捉局部关联信息。这个过程能有效提取实体和关系之间的复杂相互作用特征,从而提升知识图谱中的表示学习能力和预测准确性^[9]。卷积后生成的特征图被展开为一维向量 $M \in \mathbf{R}^{c \times l \times u}$, h 与 u 均表示其两个维度。并通过投影权重矩阵映射为低维向量。具体计算过程为

$$\begin{cases} M = H_R * \omega_{2D} \\ x_B = \text{vec}(M) \cdot W \end{cases} \quad (4)$$

式中, $\omega_{2D} \in \mathbf{R}^{c \times 2 \times 2}$ 表示用于提取 H_R 矩阵特征的 2D 卷积核。 H_R 是融合后头实体关系的嵌入矩阵, vec 表示将特征图转换为特征向量的重塑操作。 $W \in \mathbf{R}^{o \times k}$ 为投影权重矩阵, $o = c \times l \times u$ 。 $x_B \in \mathbf{R}^k$ 表示路径 B 的结果输出。路径 A 和路径 B 的头实体和关系输出特征元素相加得到 $x = x_A + x_B$ 。CombE 模型的打分函数 $f(h, r, t)$ 通过对所有三元组进行评分,使得有效三元组的得分通常高于无效三元组^[10]。通过内积运算与嵌入对象 x_t 匹配,具体公式为

$$f(h, r, t) = f([x_h; x_t] * \omega_{1D}^1 * \omega_{1D}^2 + W * \text{vec}([x_h]^T \otimes x_r) * \omega_{2D}) * x_t^T \quad (5)$$

式中,特征图 $[x_h; x_t]$ 是通过堆叠生成的,展示了数据在不同层次上的表现。卷积核 ω_{1D}^1 和 ω_{1D}^2 分别用于两次 ID

卷积操作。非线性函数 f 负责对数据进行非线性变换,使模型能够处理更复杂的关系。重塑操作 vec 用于调整数据的形状或维度,以便于进一步处理。投影权重矩阵 W 则用于将数据投影到不同的空间维度,增强特征的表示能力。2D 卷积的卷积核 ω_{2D} 在处理图像等二维数据时发挥重要作用,通过卷积操作提取空间特征。三元组得分计算后会得到一个分数。采用激活函数 σ 将这个分数压缩到 0 到 1 的范围内,并将结果视为三元组的真实性概率,即 $y = \sigma(F_r(h, t))$ 。当 y 值较高时,表示三元组的可信度高。当 y 值较低时,表示三元组的可信度低。二元交叉熵损失函数的计算公式为

$$Loss = -\frac{1}{N} \sum_{i=1}^n [\hat{y}_i \log y_i + (1 - \hat{y}_i)(1 - \log y_i)] \quad (6)$$

Dettmer 指出训练 KGE 模型和优化损失函数有 3 种策略,CombE 与 ConvE 的评分方式相同,通过 $1 - N$ 打分的矩阵乘法得到评分向量 s 。具体计算公式为

$$s = x \cdot E_k^T \quad (7)$$

式中, $s \in R^k, E_k \in R^{E_l \times k}$ 。在研究中,矩阵 E_k 的每一行对应知识图谱中一个实体 e_i 的嵌入表示。其通过对实体的特征进行编码得到的,用于在向量空间中表示实体。矩

阵 y_i 用于表示三元组的存在概率,即可信度。当某个三元组 (h, r, e_i) 被认为是正确的,对应的概率值为 $\hat{y}_i = 1$ 。

否则,对应的值为 $\hat{y}_i = 0$ 。在训练过程中,采用了 Adam 优化器来调整模型参数,可加速训练收敛并提高性能。此外,还应用了标签平滑技术,其通过对标签进行平滑处理,减少模型对训练数据中噪声的敏感性,提高模型的泛化能力。为了提高训练速度,CombE 方法采用 $1 - N$ 得分策略。总结起来,研究通过使用先进的优化器和训练技术,结合高效的评分方法,提升了知识图谱嵌入的训练效率和准确性。

1.2 基于 RMCNN 的电力系统预警方法

尽管 CombE 在链路预测中表现良好,但其只关注头实体和关系特征,忽略了三元组的整体特征。为解决这一问题,研究提出了 RMCNN 模型。该模型通过持续学习新数据和动态调整参数,适应电力系统的变化,提升实时风险预警能力^[11]。知识图谱由三元组 (h, r, t) 构成, h 和 t 为实体, r 为关系。 E 和 R 分别是实体和关系的集合。研究定义了头实体、关系和尾实体的嵌入表示 $v_h, v_r, v_t \in R$ 。RMCNN 模型结构包括关系记忆模块和卷积神经网络模块,具体结果见图 2。




图 2 RMCNN 模型结构

Fig. 2 Structure of RMCNN model

图 2 中这些模块共同作用,实现对知识图谱中复杂关系的高效表示和处理。在进行三元组的语义分析时,三元组中各元素的相对位置尤为重要^[12-13]。在 Transformer 中,位置编码用于确定三元组(头实体、关系、尾实体)的相对位置,进而获取其语义相关性^[14],即

$$\begin{cases} x_h = W(v_h + p_h) + b_1 \\ x_r = W(v_r + p_r) + b_2 \\ x_t = W(v_t + p_t) + b_3 \end{cases} \quad (8)$$

式中, p_h, p_r 和 p_t 是位置编码嵌入向量, $W \in R^{N \times D}$ 为可训练的投影矩阵, N 和 D 分别表示记忆内存大小和嵌入维度。在 RMCNN 模型中,记忆矩阵 M 有 U 行 N 列,每行代表一个记忆槽。记忆矩阵 $M_i^{(e)}$ 通过输入向量 $x^{(e)}$ 更新,其中 $\widetilde{M}_i^{(e+1)}$ 和 $\widetilde{M}_i^{(e+1),c}$ 如公式(9)所示。

$$\begin{cases} \widetilde{M}_i^{(e+1)} = [M_i^{(e+1),1} \oplus M_i^{(e+1),1} \oplus \dots \oplus M_i^{(e+1),C}] \\ \widetilde{M}_i^{(e+1),c} = \alpha_{i,U+1,c}(W^{e,V} x^{(e)}) + \sum_{j=1}^U \alpha_{i,j,c}(W^{e,V} M_j^{(e)}) \end{cases} \quad (9)$$

式中, \widetilde{M} 表示记忆位置槽。 C 代表注意力机制头的数量。多头注意力机制的输出通过拼接操作组合 \oplus , 使用投影矩阵 $W^{e,V} \in R^{n \times n}$ 。权重 α 和标量 β 分别通过多头注意力机制运算及 Query 矩阵和 Key 矩阵的点乘得到。CNN 的输入是由关系记忆网络编码生成的嵌入向量矩阵 A 。使用 3×3 卷积核在原矩阵上的卷积次数为 98 次,而在整形后的矩阵上卷积次数为 224 次^[15-16]。该策略显著增加了卷积次数,进一步提升了头实体、尾实体及关系的信息表达能力。RMCNN 的评分函数计算过程为

$$f(h, r, t) = \text{vec}(g(B * \Omega)) \times W \cdot w \quad (10)$$

式中, g 表示激活函数。在 RMCNN 模型中, Ω 代表卷积核集合, w 为权重向量。模型通过三元组打分函数计算每个三元组的得分,通常有效三元组得分高于无效三元组。采用对数逻辑回归函数作为 RMCNN 的损失函数,因为非凸函数的松弛性能优于凸函数。通过最小化特定损失函数进行训练,公式为

$$L = \sum_{(h,r,t) \in |G_r \cup G_r'|} \log(1 + \exp(-\delta_{(h,r,t)} \cdot f(fh,r,t))) \quad (11)$$

式中, G_r 和 G_r' 分别表示有效(正样本)和无效三元组(负样本),其中无效三元组由伯努利分布采样生成。为了避免错误负样本,在一对多情形中更容易替换头实体;在多对一情形中更容易替换尾实体。伯努利分布参数按式(12)计算,以概率 p 替换头实体,以概率 $1-p$ 替换尾实体。

$$p = \frac{\text{tph}}{\text{tph} + \text{hph}} \quad (12)$$

式中, tph 代表了每一个头实体的平均数, hph 代表了每一个尾实体的平均数。

2 实验结果分析


在实验中,采用的数据集为 FB15K-237 和 WN18RR。FB15K-237 和 WN18RR 为两个常用于评估知识图谱嵌入方法的数据集。FB15K-237 来源于 Freebase,包含 14 541 个实体和 237 种关系,去除了容易预测的反向关系,旨在提高模型的泛化能力。WN18RR 则是从 WordNet 衍生而来,包含 40 943 个实体和 11 种关系,通过移除重复三元组以增强任务难度。参数设置见表 1。

表 1 参数设置


Tab. 1 Parameter settings

项目	参数
嵌入维度	200
注意力机制头 C	1,2,3,4
size	128,256,512,1 024
MLP 层数	2,3,4
随机失活 drop	0.2,0.3,0.4,0.5
优化器	Adam
学习率 l_r	{ $1e-6, 5e-6, 1e-5, 5e-5, 1e-4, 5e-4$ }
卷积核的数量	128,256,512,1 024

通过网格搜索最终确定研究的超参数如下,在 WN18RR 中,注意力机制头为 4,头尺寸为 4,卷积核的数量为 1 024, drop 为 0.5, l_r 为 $5e^{-5}$ 。在 FB15K-237 中,注意力机制头为 2,头尺寸为 4,卷积核的数量为 512, drop 为 0.5, l_r 为 $5e^{-5}$ 。在数据集 WN18RR 与 FB15K-237 上的 RMCNN 的链路预测结果见图 3。



(a) FB15K-237



(b) WN18RR

图 3 RMCNN 链路预测结果

Fig. 3 RMCNN link prediction results

如图 3 所示,RMCNN 模型在 FB15K-237 和 WN18RR 数据集上均取得了最佳的 MRR 和最高的 Hit@10 成绩。与 TransE 模型相比,RMCNN 在 FB15K-237 上的 MRR 提升了 25%,在 WN18RR 上则提升了 150%。TransE 作为基线模型在 FB15K-237 上的 Hit@10 超过 ComplEx,接近 ConvE。而 RMCNN 在 FB15K-237 上的 MRR 和 Hit@10 分别较 ConvE 提升了 13%和 12%,在 WN18RR 上较 ConvE 提升了 5%和 12.5%。与 InteractE 和 ConvR 等相比,RMCNN 在多个指标上也表现优异。这些结果表明,RMCNN 模型在多项指标上优于 ConvE、ConvR 和 InteractE,并在各种数据集上表现出色,证明了其鲁棒性和捕获实体与关系间联系的能力。不同关系类型的头与尾实体预测结果见图 4。

从图 4 中可以看出,RMCNN 在所有任务中的表现最为优异,MRR 和 Hit@10 值均高于其他方法。ConvKB 和 ConvE 在部分任务上表现相近,但整体上略逊于 RMCNN。特别是在 M-M(多对多)任务上,RMCNN 的性能明显优于其他方法。这表明 RMCNN 在复杂关系预测方面具有更强的泛化能力和准确性。图 5 展示了 RMCNN 在 WN18RR 数据集上各关系的 MRR 和 Hit@10 指标。

由图 5 可知,研究模型在多对多关系如 `alsosee`, `similar_to`, `verb_group` 和 `derivationally_related_form` 上超越 ConvE。RMCNN 在处理复杂关系时表现出色。其中 RMCNN(RM)仅使用关系记忆网络,RMCNN(DC)仅应用矩阵整形策略。图 6 展示了 RMCNN 模型的消融结果。

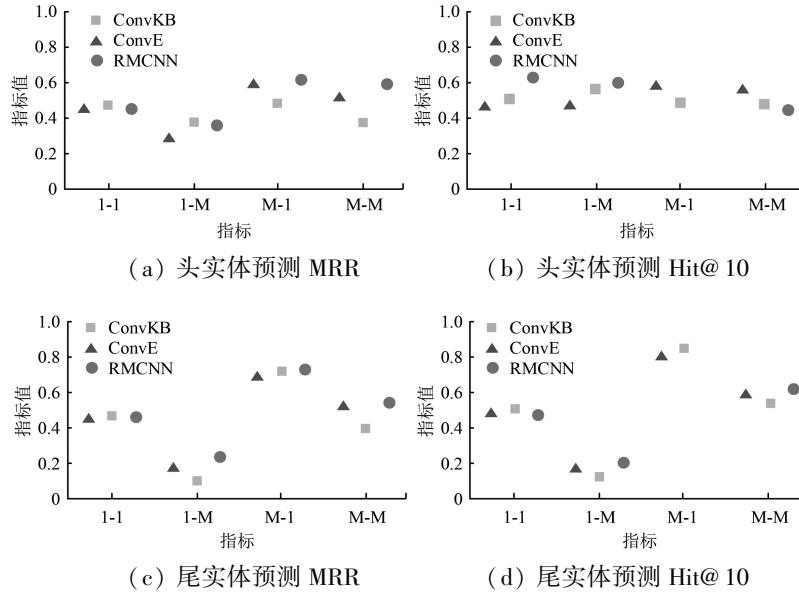


图 4 FB15K-237 数据集上的头与尾实体预测结果

Fig. 4 Head and tail entity prediction results on FB15K-237 dataset

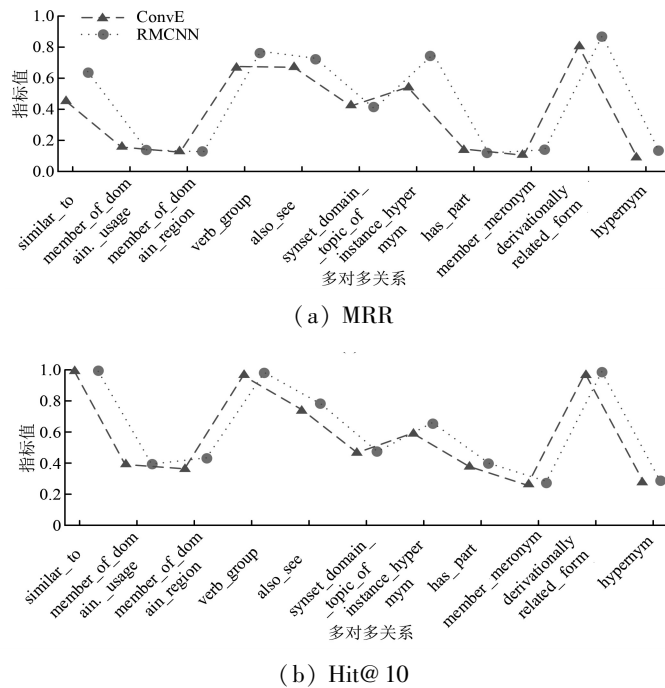


图 5 每种关系的 MRR 与 Hit@10

Fig. 5 MRR and Hit@10




图 6 RMCNN 模型的消融结果

Fig. 6 The ablation results of the RMCNN model

由图6可知,RMCNN(RM)虽然表现优异,能够很好地编码和记忆实体与关系间的依赖性,但其性能比完整模型略低,MRR在FB15k-237上从0.412降至0.328,在WN18RR上从0.486降至0.434。综上可知,关系记忆网络虽单独性能高,但链路预测效果不如完整RMCNN模型。其在链路预测中贡献显著,矩阵整形策略起辅助作用,两者结合可更好地把握实体与关系的潜在联系,增强互动,提高链路预测能力。

3 结论

为增强电力系统的实时风险预警能力,研究提出了融合CNN和关系记忆网络的多领域知识融合模型。该模型通过结合CNN与关系记忆网络的知识图谱链接预测模型,来捕捉电力系统元素间的复杂关系。实验显示,RMCNN在FB15K-237和WN18RR数据集上取得了最佳的MRR和Hit@10成绩。相较于基线模型TransE,RMCNN在FB15K-237和WN18RR上的MRR分别提高了25%和150%。RMCNN在FB15K-237上的MRR和Hit@10较ConvE分别提高了13%和12%,在WN18RR上则提升了5%和12.5%。与InteractE和ConvR相比,RMCNN在多个指标上表现优异。RMCNN(RM)模型在编码和记忆关系依赖性方面有所改进,但性能略低于完整模型,MRR在FB15K-237和WN18RR数据集上分别下降至0.328和0.434。研究模型显著提升了电力系统风险预警的准确性和实时性。

参考文献

- [1]周劫英,张晓,邵立嵩,等.新型电力系统网络安全防护挑战与展望[J].电力系统自动化,2023,47(8):15-24.
- [2]梁露,张智晟.基于多尺度特征增强DHTCN的电力系统短期负荷预测研究[J].电力系统保护与控制,2023,51(10):172-179.
- [3]任相霖,张粒子,黄弦超.计及预测误差时变相关特性的新型电力系统爬坡容量需求分析方法[J].南方电网技术,2024,18(1):49-57.
- [4]黄兴德,方陈,魏新迟,等.基于同步相量测量的电力系统网络拓扑分析方法[J].科学技术与工程,2023,23(29):12567-12576.
- [5]FIGETAKIS E, HUSSEIN A R, ULEMA M. Evolved prevention strategies for 6G networks through stochastic games and reinforcement learning[J]. IEEE Networking Letters, 2023, 5(3):164-168.
- [6]王洪彬,周念成,黄睿灵,等.基于深度学习的110 kV电网监控信号语义解析及态势感知模型[J].电力系统保护与控制,2023,51(2):160-168.
- [7]王书鸿,郑少明,刘中硕,等.面向某地区电网继电保护装置缺陷知识图谱构建的实体关系抽取[J].电网技术,2023,47(5):1874-1885.
- [8]马坤,安敬民,李冠宇.动态聚合实体和关系上下文的知识图谱补全[J].计算机工程,2023,49(8):77-84,95.
- [9]徐凡,徐健明,马勇,等.基于知识增强的开放域多轮对话模型[J].软件学报,2024,35(2):758-772.
- [10]许金伟,王庆林,李娅琳,等.多核数字信号处理卷积算法并行优化[J].国防科技大学学报,2024,46(1):103-112.
- [11]朱广宇,张萌,裔扬.基于知识图谱的城市轨道交通突发事件演化结果预测[J].电子与信息学报,2023,45(3):949-957.
- [12]王庆林,裴向东,廖林玉,等.多核数字信号处理器矩阵乘卷积算法性能评测[J].国防科技大学学报,2023,45(1):86-94.
- [13]李庆波,赵昂,田寿涛,等.结合GRN和TGTransformer的配电网分区分区电力电量平衡方法[J].自动化技术与应用,2025,44(8):156-160.
- [14]丁浩,孔令圆,刘清,等.融合多重特征词嵌入的农业实体命名识别研究[J].现代情报,2023,43(11):135-145.
- [15]张鹤译,王鑫,韩立帆,等.大语言模型融合知识图谱的问答系统研究[J].计算机科学与探索,2023,17(10):2377-2388.
- [16]李军怀,武允文,王怀军,等.融合实体描述与路径信息知识图谱表示学习模型的方法[J].智能系统学报,2023,18(1):153-161.
- [17]Zhou B W, Zhang Z B, Li G D, et al. Review of key technologies for offshore floating wind power generation[J]. Energies, 2023, 16(2):710.
- [18]LIU Y, ZHENG Y, WEI T, et al. Lightweight algorithm based on you only look once version 5 for multiple class defect detection on wind turbine blade surfaces[J]. Engineering Applications of Artificial Intelligence, 2024(138):109422.
- [19]杨茂,王达,王小海,等.基于数据物理混合驱动的超短期风电功率预测模型[J].高电压技术,2024,50(11):5132-5141.
- [20]闫浩伟.基于无人机的风机叶片表面缺陷自动检测方法[J]. Computer Measurement & Control, 2024, 32(11):72-79.
- [21]马飞越,刘佳豪,赵涛,等.电力巡检机器人运行姿态的终端滑模控制[J].西南大学学报(自然科学版),2021,43(12):172-179.
- [22]王国权,张晓鹏.基于ANSYS Workbench的高空幕墙清洁机器人主移动机构的仿真分析[J].工程机械,2025,56(8):99-105.
- [23]ZHAO Q, WANG X, WANG J, et al. Design and realization of a glass-curtain wall-cleaning robot [C] 2017 2nd Joint International Mechanical, Electronic and Information Technology Conference (JIMET 2017), Chongqing, China; IET, 2017:475-480.
- [24]丁希仑,金雪莹.旋翼无人机交互作业动力学建模研究进展[J].航空学报,2022,43(10):526-543.
- [25]聂佩哈,张雅婷,陈勇.爬壁机器人发展与关键技术综述[J].机床与液压,2022,50(4):155-161.
- [26]郭晶晶,刘允刚,满永超,等.自主多旋翼无人机系统:感知、规划与控制[J].控制理论与应用,2024,41(10):1707-1725.
- [27]樊明,梁鹏,高学山,等.反推力吸附的爬壁机器人设计及实验研究[J].北京理工大学学报,2022,42(11):1150-1158.
- [28]徐锦鑫,王保民.物业清洁机器人越障动力学分析与实验[J].机械研究与应用,2024,37(4):38-42.
- [29]田建林,陈晓波,张文昌,等.移动机器人自主导航技术研究进展[J].自动化技术与应用,2025,44(7):1-4.
- [30]汤颖,赵彬.四旋翼机器人运动控制与动力学研究与设计[J].机械设计与制造,2018(8):259-262.
- [31]古训,王鹏博.四旋翼无人机RBF-SMO容错抗扰位姿跟踪控制[J].信息与控制,2025,54(4):570-582.

(上接第16页)