

doi:10.3969/j.issn.1003-3114.2025.05.022

引用格式: 畅鑫, 李艳斌, 刘东辉. 基于卷积神经网络的指挥控制网络关键节点识别方法[J]. 无线电通信技术, 2025, 51(5): 1087-1101. [CHANG Xin, LI Yanbin, LIU Donghui. Recognition Method of Key Nodes in Command and Control Network Based on Convolutional Neural Network[J]. Radio Communications Technology, 2025, 51(5): 1087-1101.]

## 基于卷积神经网络的指挥控制网络关键节点识别方法

畅鑫<sup>1</sup>, 李艳斌<sup>1</sup>, 刘东辉<sup>2,3</sup>

(1. 中国电子科技集团公司第五十四研究所, 河北 石家庄 050081;

2. 石家庄铁道大学 管理学院, 河北 石家庄 050043;

3. 石家庄铁道大学 工程建设管理研究中心, 河北 石家庄 050043)

**摘要:** 针对当前指挥控制网络关键节点识别方法依赖专家经验知识等问题, 基于通信侦察视角, 提出基于卷积神经网络的指挥控制节点识别方法。依靠卷积神经网络在特征提取上的强大能力, 构建关键节点识别智能范式。利用特征工程, 将各节点之间的通联关系信息转化为多维信息矩阵, 受有限长单位冲击响应 (Finite Impulse Response, FIR) 滤波器结构的启发, 提出 FIRSE (Finite Impulse Response Squeeze and Excitation) 神经网络。提出动态峰值检测法改进训练策略, 获取最优神经网络参数。实验结果表明, 相比基于典型机器学习和深度学习的识别方法, 提出的方法具有更高的识别准确性。

**关键词:** 指挥控制网络; 关键节点; 识别; 特征工程; 卷积神经网络

中图分类号: E211

文献标志码: A

开放科学(资源服务)标识码(OSID):

文章编号: 1003-3114(2025)05-1087-15



## Recognition Method of Key Nodes in Command and Control Network Based on Convolutional Neural Network

CHANG Xin<sup>1</sup>, LI Yanbin<sup>1</sup>, LIU Donghui<sup>2,3</sup>

(1. The 54th Research Institute of CETC, Shijiazhuang 050081, China;

2. School of Management, Shijiazhuang Tiedao University, Shijiazhuang 050043, China;

3. Research Institute of Engineering Management, Shijiazhuang Tiedao University, Shijiazhuang 050043, China)

**Abstract:** To address the issue of current command and control network key node recognition methods relying on expert knowledge, a method based on convolutional neural networks from the perspective of communication reconnaissance is proposed. Powerful feature extraction capabilities of convolutional neural networks are leveraged to develop an intelligent paradigm for key node recognition. First, the communication relationship information between nodes is transformed into a multi-dimensional information matrix using feature engineering. Then, inspired by the Finite Impulse Response (FIR) filter structure, a Finite Impulse Response Squeeze and Excitation (FIRSE) neural network is proposed. Finally, a dynamic peak detection method is introduced to improve the training strategies and obtain optimal neural network parameters. Experimental results show that compared with typical machine learning and deep learning-based recognition methods, the proposed method offers higher identification accuracy.

**Keywords:** command and control network; key nodes; recognition; feature engineering; convolutional neural network

收稿日期: 2024-05-28

基金项目: 中国博士后科学基金(2021M693002); 国家自然科学基金(71991485, 71991481, 71991480)

Foundation Item: China Postdoctoral Science Foundation(2021M693002); National Natural Science Foundation of China(71991485, 71991481, 71991480)

## 0 引言

指挥控制网络关键节点识别是支撑指挥控制体系博弈的重要组成部分和决定作战结果的关键因素<sup>[1-3]</sup>。通过干扰或者打击指挥控制网络关键节点,能够有效抑制敌方对于战场态势的获取,从而压制决策空间,在体系对抗博弈中获得信息优势<sup>[4-7]</sup>。因此,指挥控制网络关键节点识别是实现智能化指挥控制的关键技术。

当前研究集中在节点重要性度量参数和关键节点的提取映射上。从数学原理出发,利用复杂网络理论<sup>[8]</sup>,基于 Tsallis 熵<sup>[9]</sup>、引力方法<sup>[10]</sup>和信度函数<sup>[11]</sup>等提出节点重要性评估方法。该类方法立足于拓扑学等数学理论,构建评估体系和识别映射,适用性强<sup>[12]</sup>。但是,该类方法以抽象数学拓扑模型进行研究,缺少实际应用场景的领域知识。特别是在指挥控制网络中,结合领域知识的方法通常可以更好地理解和解释数据,因其可以利用领域专家的经验和理解来指导模型的构建和优化,克服节点选取方法的片面性。

本文基于通信侦察视角,提出了基于卷积神经网络的指挥控制网络关键节点识别方法。依靠卷积神经网络在特征提取上的强大能力,构建指挥控制网络关键节点的智能识别范式。为了适应卷积神经网络对于数据结构的需求,基于特征工程,将通信侦察获得的指挥控制网络节点互通次数和通信类型转换为多维数据矩阵。然后,结合残差网络(Residual Network, ResNet)结构<sup>[13]</sup>、Squeeze-and-Excitation Network (SENet)神经网络结构<sup>[14]</sup>和密集卷积网络(Densely Connected Convolutional Network, DenseNet)结构<sup>[15-16]</sup>这些典型卷积神经网络架构的优点,受数字信号处理中 FIR 滤波器结构的启发<sup>[17]</sup>,提出适用于指挥控制节点识别问题的 FIRSE 神经网络,进一步提高了卷积神经网络在指挥控制网络关键节点识别上的适应性。实验验证表明,本文方法能够有效识别关键节点,并且相比应用在该问题上的机器学习和深度学习方法具有更高的准确性和相对较低的计算复杂度,为指挥控制网络关键节点的识别方法提供了新思路和新方法,为指挥控制回路的保护和摧毁提供了帮助,为博弈策略的制定提供了可靠的技术支撑。

## 1 指挥控制网络关键节点识别方法分类

指挥控制网络关键节点识别方法包括经典指挥

控制网络关键节点识别方法和智能指挥控制网络关键节点识别方法。

### 1.1 经典指挥控制网络关键节点识别方法

基于应用场景,融合领域知识,提出了一系列关键节点识别方法。从信息对抗复杂网络攻击的角度,节点被攻击后,指挥控制体系毁伤程度越高,表明该节点越具有价值、越关键。基于此,王劲松等<sup>[7]</sup>基于攻击方收益、攻击方损耗、攻击方遇到的风险建立了节点攻击效果指标体系用以衡量网络中各节点的价值,并利用 TOPSIS (Technique for Order Preference by Similarity to Ideal Solution)方法对节点价值排序,从而实现关键节点识别。针对天基信息网络的结构和特点,李国栋等<sup>[18]</sup>基于图论梳理了节点重要性度量主要参数,包括度中心性、介数中心性、接近度中心性、特征向量中心性和子图中心性,并以复杂网络理论为基础,总结了局部特性和全局特性的节点重要性评估方法。借鉴北约网络赋能指控成熟度模型,张笑楠等<sup>[19]</sup>基于信息分布指标、决策权分配指标和交互模式指标,评估指挥控制体系成熟度,间接可用于衡量各执行节点的价值。从通信网络群中节点引起通信中断的程度考虑,陈周牛<sup>[20]</sup>在孪生节点分布模型的基础上,利用蒙特卡罗法对各节点逐个测试其对整体通信网络群性能的影响,间接实现对于关键节点的识别。针对利用局部信息识别关键节点精度低、利用全局信息识别关键节点复杂度高的问题,基于结构洞理论,王运明等<sup>[21]</sup>在识别关键节点的过程中,综合考虑了指挥控制网络结构特征和全局拓扑信息,引入了层级流介数作为约束系数。闫志英<sup>[22]</sup>提出节点易损性容忍概念,计算各网络节点的最大易损性容忍率,并通过判断通信节点易损类型,实现对通信网络节点安全态势的评估。基于超网络,引入多层网络之间的交互机制,许怡岚等<sup>[23]</sup>构建超网络模型,提出综合效能评价算法,并运用节点删除法,获得超网络中节点的体系价值排序,从而获得关键节点。针对空战特性引入超网络理论,王瑛等<sup>[24]</sup>抽取作战网络节点交互关系,构建信息流转超网络模型,基于中心性、介数、聚类系数和接近中心性构建评估指标,利用多属性决策的节点重要性综合评价方法得出网络关键节点。

### 1.2 智能指挥控制网络关键节点识别方法

但是,基于领域知识和专家经验的方法在评估体系的构建和映射选择方面面临着挑战。随着在不同领域的研究不断深入,特征和评估方法的

复杂度和种类也在不断增加,导致评估体系的结构相差较大,给指标体系和映射的选择带来了较大困难。此外,这类方法受到主观性的影响,结构的简单性可能无法充分表达复杂指挥控制网络中节点的识别需求。因此,方法的适用性和可靠性受到专家认知限制,技术发展路径存在较强的主观性。与此相比,机器学习技术的发展使得不依赖于专家经验和领域知识构建指标特征和映射方法成为可能。通过机器学习技术,可以直接从数据中学习关键节点的特征表示,从而避免了人为因素的影响<sup>[25]</sup>。此外,机器学习技术还可以将关键节点识别问题转化为一个数据驱动的过程,使得模型能够根据实际数据不断优化和演进,从而持续提高模型的效果和性能。因此,基于机器学习的方法在指挥控制网络等实际应用场景中可能具有更大的潜力和优势。通过机器学习技术,可以有效地避免专家经验和领域知识的局限性,从而提高模型的适用性和可靠性。这为指挥控制网络中节点的识别提供了一种新的思路和方法,有助于解决评估体系构建和映射选择方面的困难。

与传统基于领域知识的节点重要性度量参数和关键节点的提取映射相对应,基于机器学习的节点识别的关键在于特征工程和网络模型。陈诗等<sup>[26]</sup>研究了典型机器学习技术在节点识别方面的可行性。特别是,决策树已在节点识别领域应用,且相关研究分析了其效果<sup>[27]</sup>。虽然实现了基于特征的映射关系的自动化提取,但是传统机器学习方法通常需要手动设计和选择特征,这需要领域专家的知识 and 经验。特征工程的过程可能会很繁琐,且需要花费大量时间和精力。相比于需要人工提炼特征的机器学习方法,张锴等<sup>[28]</sup>结合图神经网络和循环神经网络,对动态网络特征自动化提取,实现了对于关键节点的提取。但是,在处理长序列数据时,循环神经网络会出现梯度消失或梯度爆炸的问题,导致训练失败,无法准确识别关键节点<sup>[25,29]</sup>。除此之外,图神经网络复杂度较高,面临计算和内存消耗过大的问题<sup>[30]</sup>。李懿凡等<sup>[31]</sup>采用广义连续时间贝叶斯网络,能够基于数据和领域知识建立概率模型,有效地捕捉节点之间的依赖关系和不确定性,间接实现了指挥控制网络关键节点的识别。但是,贝叶斯网络通常需要假设数据服从特定的概率分布,如果数据的真实分布与假设的分布不一致,可能会影响模型的性能。相比于机器学习、图神经网络、循环神经网络和贝叶斯网络,卷积神经网络在微波通信网结构

等具有空间结构的数据上表现出色<sup>[32-33]</sup>,能够有效地捕捉局部特征和全局结构<sup>[34,14]</sup>。受限于利用通信侦察获得数据的表现形式<sup>[35]</sup>,并没有将卷积神经网络的优势在该领域发挥出来。对于指挥控制网络的关键节点识别,需要通过特征工程将互联关系结构转化为适合于卷积神经网络处理的矩阵形式<sup>[34,36]</sup>。

## 2 指挥控制网络关键节点识别场景与问题构建

详细阐述基于通信侦察的指挥控制网络关键节点识别场景,通过对指挥控制网络关键节点识别问题的构建,设计识别流程。

### 2.1 指挥控制网络关键节点识别场景

在通信侦察参与的情况下,指挥控制网络关键节点识别场景如图1所示。指挥控制网络中各传感器将探测得到的信息通过多种传输方式向指挥节点进行汇总,生成态势和策略后,向各实体发送指挥控制命令。




图1 指挥控制网络关键节点识别场景

Fig. 1 Command and control network key node identification scenario

在场景中,侦察设备对各节点的通信过程进行侦察,记录节点之间的信息传输关系和采用的通信类型,形成指挥控制网络节点关系数据。通过对数据的分析和映射,提取指挥控制网络中的关键节点。针对这些关键节点进行精准打击,实现对敌指挥控制体系的破坏,造成体系能力的显著下降,从而支撑决策中心战的实施。

### 2.2 指挥控制网络关键节点识别问题构建

通过对指挥控制网络关键节点识别场景分析可知,指挥控制网络关键节点识别问题可以映射

为监督学习中的分类问题,将关系数据作为输入,关键节点作为输出。网络模型中各实体之间的通联关系和通信类型是关系数据的关键参数。但是,上述2个参数的收集表达方式常以表格方式进行记录,这种信息结构形式不利于使用深度神经网络的优势进行分类识别,如何构建能够有利于应用深度神经网络优势的数据结构是本文的关键问题之一。综上所述,指挥控制网络关键节点识别流程如图2所示。

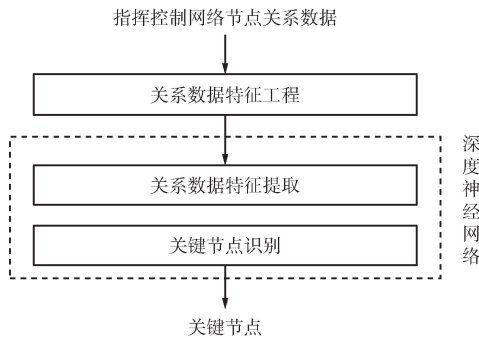


图2 指挥控制网络关键节点识别流程

Fig. 2 Command and control network key node identification process

指挥控制网络关键节点识别流程可分为2步:  
① 将指挥控制网络节点关系数据通过关系数据特征工程映射为便于卷积神经网络可以处理的数据格式<sup>[6,36]</sup>;② 基于卷积神经网络,从数据中智能化、客观地提取关键节点的特征后,再进行关键节点的识别。

### 3 基于特征工程的多维信息矩阵构建

下面详细阐述将包含网络结构信息的关系数据映射为多维信息矩阵的方法,并给出用于深度神经网络模型训练和验证的数据集构造方法。

#### 3.1 指挥控制网络场景

从通信侦察的角度,在指挥控制网络结构确定的情况下,可获得的是关键节点的互联关系和通信方式。统计在  $T$  次通信侦察下,各节点之间、不同通信方式下的互通次数  $t_{nm}^l$ 。其中  $n$  和  $m$  分别为通信节点标号,表示信息从第  $n$  个节点向第  $m$  个节点发送,  $n, m \in N$ , 节点数为  $N$ ;  $l$  表示通信方式种类索引,共  $L$  种通信方式。基于总侦察次数  $T$ ,对数据样本  $x$  进行归一化处理,将  $t_{nm}^l$  转化为互通率。

将互通率数据转换成多维矩阵形式,组成数据样本  $x$ :

$$x = \begin{bmatrix} [t_{11}^1 \cdots t_{1N}^1] & \cdots & [t_{11}^L \cdots t_{1N}^L] \\ \vdots & & \vdots \\ [t_{N1}^1 \cdots t_{NN}^1] & \cdots & [t_{N1}^L \cdots t_{NN}^L] \end{bmatrix}_{L \times N \times N} \quad (1)$$

将该网络结构下对应的关键通信节点设置为  $y$ ,作为对应的标签。

#### 3.2 训练与验证数据集构建

基于多维信息矩阵构建训练与验证数据集。针对不同指挥控制网络结构,共经过  $K$  次通信侦察组成数据集,包括样本数据集和标签数据集。

样本数据集  $X$  为:

$$X = \begin{bmatrix} [ [t_{11}^1 \cdots t_{1N}^1] & \cdots & [t_{11}^L \cdots t_{1N}^L] ]_1 \\ \vdots \\ [ [t_{11}^1 \cdots t_{1N}^1] & \cdots & [t_{11}^L \cdots t_{1N}^L] ]_K \end{bmatrix}_{K \times L \times N \times N} \quad (2)$$

标签数据集  $Y$  为:

$$Y = [y_1 \ y_2 \ \cdots \ y_K]_K \quad (3)$$

按照比例  $\mu$  将数据集切分为训练数据集和验证数据集,二者数量分别为  $\lfloor \mu K \rfloor$  和  $K - \lfloor \mu K \rfloor$ ,其中  $\lfloor \cdot \rfloor$  表示向下取整。

训练数据集的样本数据集为  $X'$ , 维度为  $\lfloor \mu K \rfloor \times L \times N \times N$ ; 训练数据集的标签数据集为  $Y'$ , 维度为  $\lfloor \mu K \rfloor$ ; 测试数据集的样本数据集为  $X''$ , 维度为  $(K - \lfloor \mu K \rfloor) \times L \times N \times N$ ; 测试数据集的标签数据集为  $Y''$ , 维度为  $K - \lfloor \mu K \rfloor$ 。

### 4 指挥控制网络关键节点识别模型

本节采用总分的方式详细阐述指挥控制网络关键节点识别模型。从整体角度解释用于指挥控制网络关键节点识别的 FIRSE 深度神经网络结构,针对组成模块分别进行阐述。

#### 4.1 FIRSE 深度神经网络

针对指挥控制网络关键节点识别的 FIRSE 深度神经网络不是简单地将 DenseNet、ResNet、SENet 和 FIR 滤波器的结构进行组合,而是基于这些模型的思想 and 优点,设计了一种全新的网络结构。FIRSE 模型不仅继承了 DenseNet 的密集连接、ResNet 的残差学习和 SENet 的注意力机制,还融入了 FIR 滤波器的滤波思想,实现了跨领域的融合和功能拓展。FIRSE 深度神经网络结构如图3所示。其创新部分可以归纳为4个方面。

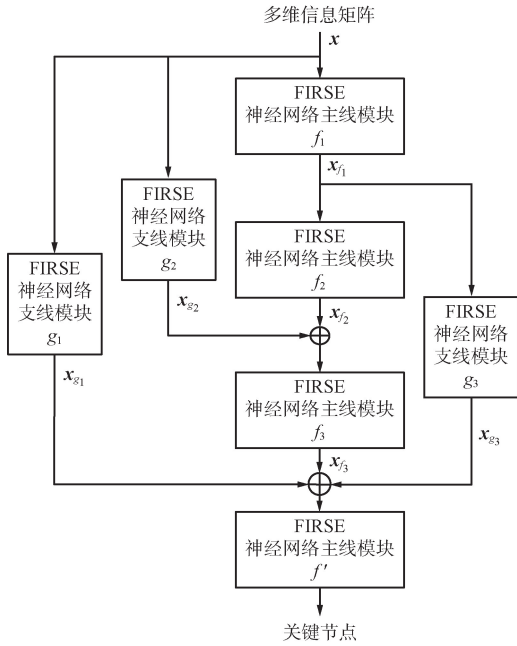


图3 FIRSE 深度神经网络结构

Fig. 3 FIRSE deep neural network structure

① FIRSE 模型中的特征输出采用密集连接的方式,确保输出特征融合到所有神经网络主线模块的特征信息,增强特征复用和信息传递。在 FIRSE 深度神经网络结构图中,密集连接通过箭头和线条密集交汇的方式表示,展示分类模块与所有主线模块的连接关系。

② 引入残差学习的思想,通过跳跃连接帮助模型学习,缓解深层网络中梯度消失的问题。在 FIRSE 深度神经网络结构中,残差连接以线条汇总于加号处表示。

③ 利用 SENet 的 SE 模块为模型引入注意力机制,使模型能够自动学习不同特征的重要性,并对其进行加权处理。SE 模块在模型图中作为一个独立的子模块出现,经过 Squeeze 和 Excitation 操作后输出加权后的特征。在 FIRSE 深度神经网络结构图中的主线模块中使用,并在主线模块详述中详细展示和说明。

④ 将 FIR 滤波器的线性相位和稳定性特点融入网络设计中。FIR 滤波器在结构上的突出特点为信号传输路径上的单位时延元素和滤波器的系数,在 FIRSE 深度神经网络结构图中以支线模块代替,线条中以穿插该支线模块的方式表示。

综上所述,将数字信号处理中的 FIR 滤波器结构引入计算机视觉领域,借鉴 FIR 滤波器的线性相位和稳定性特点,增强模型对具有图像特征的通信侦察数据提取关键节点的能力。这种跨领域的融合

是本文的主要创新点之一。

FIRSE 深度神经网络由主线模块 ( $f_1$ 、 $f_2$  和  $f_3$ )、支线模块 ( $g_1$ 、 $g_2$  和  $g_3$ ) 和分类模块  $f'$  三部分组成。从多维信息矩阵到关键节点的映射过程  $F$  可以表示为:

$$y = F(x) = f' \{ g_1(x) + f_3 \{ g_2(x) + f_2 [ f_1(x) ] \} + g_3 [ f_1(x) ] \} \quad (4)$$

#### 4.2 FIRSE 深度神经网络主线模块

主线模块由二维卷积层、归一化层、非线性激活层、自适应池化层和全连层组成,如图4所示。相比于经典卷积神经网络模型,其特点在于引入了由全连层和非线性激活层构成的 SE 层。该层通过显式地构建卷积特征通道之间的相互依赖关系来提高网络对信息的敏感度。

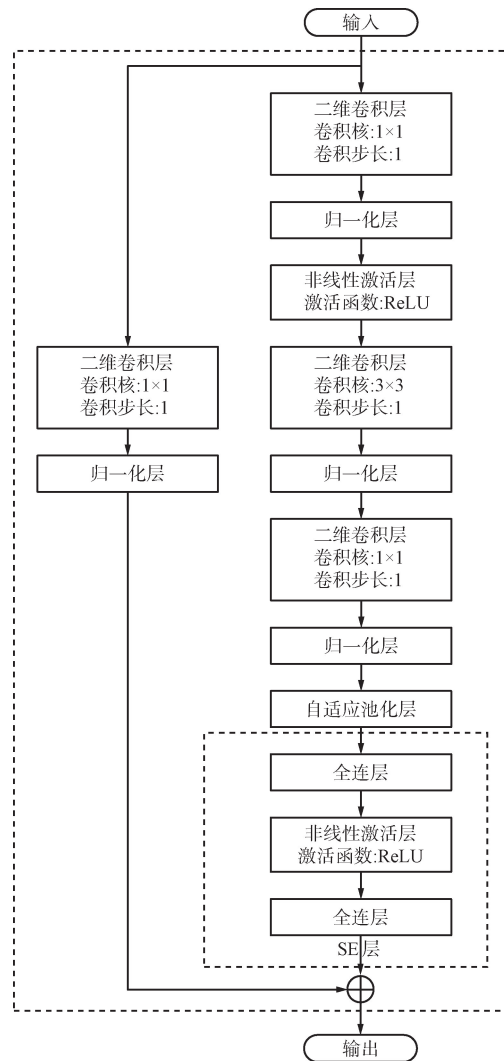


图4 FIRSE 深度神经网络主线模块结构

Fig. 4 FIRSE deep neural network main module structure

对全局信息进行压缩,以产生每个特征通道的描述符。结合主线模块具体处理过程来看,全连层通过对卷积后得到的特征图沿通道进行压缩,使得每个通道都被压缩成一个单一数值,用以表示该通道的全局响应随后捕捉通道之间的依赖关系,为每个通道生成一个权重。通过非线性的交互,使得模型能够识别重要通道并抑制不重要通道,即进一步赋予网络对于通信手段与关键节点间关系的敏感性。

### 4.3 FIRSE 深度神经网络支线模块

支线模块由二维卷积层和归一化层组成,如图 5 所示。




图 5 FIRSE 深度神经网络支线模块结构

Fig. 5 FIRSE deep neural network branch module structure

卷积核尺度设置为  $1 \times 1$ , 主要基于 2 点考虑: 跨通道的信息交互整合与特征图的通道数调整。

跨通道的信息交互整合具有深度学习理论和专业领域优势。从深度学习理论出发,  $1 \times 1$  卷积核可以看作是一种特殊的线性变换,能够在多个输入通道之间进行信息整合。具体来说,  $1 \times 1$  卷积核可以将多个通道的特征图进行线性组合,通过乘以一个系数并相加,从而输出一个新的特征图。这个新的特征图包含了多个通道的整合信息,可以使网络提取的特征更加丰富。对关键节点识别而言,跨通道的信息交互整合是为了神经网络能够综合权衡节点的互联关系和通信方式,使得其识别过程更加全面客观。

除此之外,通过改变  $1 \times 1$  卷积核的数量,可以控制输出特征图的通道数,从而实现对网络层之间通道数的调整。在 ResNet 残差网络的 Bottleneck 残差模块和 GoogleNet 的 Inception 模块中,都使用了  $1 \times 1$  卷积核来提取特征。这些模块中的  $1 \times 1$  卷积核主要用于提升或降低特征(个数)的维度,而不改变图像的宽高。

总的来说,支线模块在 FIRSE 深度神经网络中扮演着重要的角色,对于提取特征、调整网络结构以及提高网络的表达能力都具有重要作用。

### 4.4 FIRSE 深度神经网络分类模块

深度神经网络分类模块基于浅层全连接神经网络,包含 Dropout 层、全连层、非线性激活层和 softmax 层,如图 6 所示。得益于 FIRSE 深度神经网络结构,对于关键节点的特征已经通过主线和支线模块提取,选择浅层全连接神经网络的优势在于结构相对简单,并且在完成特征提取的基础上能够高效和简洁地识别出关键节点。

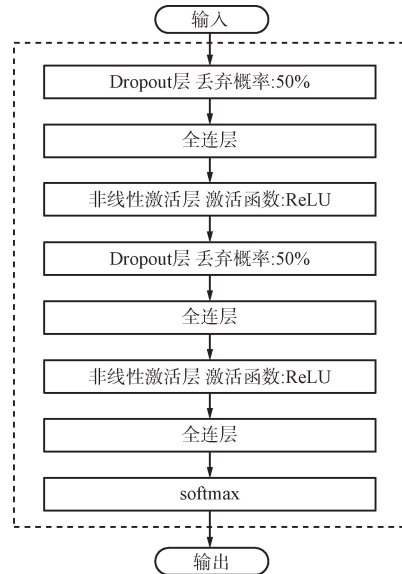


图 6 FIRSE 深度神经网络分类模块结构

Fig. 6 FIRSE deep neural network classification module structure

## 5 FIRSE 神经网络训练策略

本节详细阐述训练过程,提出基于动态峰值检测法的最优模型参数获取方法,并给出训练策略的伪代码以便于工程实践。

### 5.1 训练过程

首先,前向传播。将训练数据集的样本切分为维度相同的批样本数据  $X^m$  和对应的标签数据  $Y^m$ , 维度分别为  $B \times L \times N \times N$  和  $B$ , 其中  $B$  为批数量。将批样本数据  $X^m$  依次通过指挥控制网络关键节点识别神经网络得到预测的标签数据  $Z^m$ , 其过程可以描述为:

$$Z^m = F(X^m) \tag{5}$$

选择交叉熵函数为损失函数<sup>[25]</sup>。依据交叉熵函数计算误差,批训练的误差为:

$$l = -\frac{1}{B} \sum_{i=1}^B \sum_{j=1}^N y_{ij}^m \lg(z_{ij}^m) \tag{6}$$

式中:  $y_{ij}^m$  为第  $i$  个批样本的第  $j$  个类别的真实标签,  $z_{ij}^m$  为第  $i$  个批样本的第  $j$  个类别的预测标签。

然后,根据误差进行反向传播,并根据 Adam 自适用学习率方法对 FIRSE 深度神经网络参数进行优化。

最后,将测试数据集的样本数据  $X''$  依次通过指挥控制网络关键节点识别神经网络得到预测的标签数据  $Z''$ ,其过程可以描述为:

$$Z'' = F(X'') \quad (7)$$

统计标签数据  $Y''$  与预测的标签数据  $Z''$  相同的个数,并除以批数量  $B$ ,获得本次训练的准确率:

$$\varphi = \sum_{b=1}^B h(z''_b, y''_b) / B \quad (8)$$

式中:  $h = \begin{cases} 1, z''_b = y''_b \\ 0, z''_b \neq y''_b \end{cases}, z''_b \in Z'', y''_b \in Y''$ 。

### 5.2 最优模型参数获取

通过不断地重复前文训练过程中前向传播、计算损失、反向传播和参数更新等步骤,对神经网络参数进行优化,从而提高网络识别能力。如何设定停止条件是训练策略的关键,典型的停止条件有最大迭代次数、损失函数收敛或者直到模型在验证集上达到满意的性能。但是,上述3种方法均有缺陷。对于设置最大迭代次数,可能导致过早停止训练,使得模型没有达到最优性能。对于非凸优化问题,损失函数可能存在多个局部最优解,设置损失函数收敛作为终止条件可能无法保证找到全局最优解。而设置模型在测试集上达到满意性能的阈值需要人工选择,可能因为主观因素而影响模型的最终性能。针对上述不足,受信号处理领域恒虚警(Constant False Alarm Rate, CFAR)检测方法启发<sup>[13]</sup>,提出动态峰值检测法作为停止条件。

动态峰值检测法记录训练次数  $s$  和对应得到的相似度  $\varphi_s$ 。如果本次迭代相似度  $\varphi_s$  大于之前训练过程中所有相似度的最大值  $\varphi_m$ ,则将本次相似度  $\varphi_s$  赋值于  $\varphi_m$ ,并且保存对应的网络参数。如果本次训练相似度  $\varphi_s$  小于等于之前迭代过程中所有相似度的最大值  $\varphi_m$ ,则进入下一次训练。直到最大相似度  $\varphi_m$  所对应的重复次数  $m$  小于总训练次数  $s$  一半时停止,如不满足该条件,则继续重复训练。

### 5.3 训练策略伪代码

训练策略的伪代码如算法1所示。

算法1 训练策略伪代码

初始化:  $s=1, \varphi_s=0$

While True:

for 每一批次 in 训练数据:

    获取下一个批次的数据 ( $X''$ ,  $Y''$ )

    进行前向传播,得到预测标签数据  $Z''$

    计算损失  $l$ ,使用交叉熵函数作为损失函数  
    反向传播并更新参数  
    获取测试数据 ( $X''$ ,  $Y''$ )  
    进行前向传播,得到预测标签数据  $Z''$   
    计算准确率  $\varphi$   
    使用动态峰值检测法进行判断是否停止训练  
 $s=s+1$

## 6 实验结果与分析

### 6.1 数据准备与预处理

由于本文方法基于通信侦察结果识别指挥控制网络的关键节点,目前尚无公开的数据集可供使用。此外,本文从通信侦察的角度对指挥控制网络的关键节点识别开展研究,研究视角独特,相比于已有成果具有一定的差异性和创新性,因此需要构建特异性数据集。本文采用自建数据集<sup>[37]</sup>,对所提方法的有效性进行验证。下面基于自建数据集,详细介绍了数据准备与预处理阶段工作。

根据前文指挥控制网络场景描述可知,构建指挥控制网络数据集应该考虑3个方面内容:网络结构(即节点之间互联关系)、通信类型和对应的关键节点。进一步来看,基于本文特征工程的多维信息矩阵构建,需要对上述数据进行特征工程,形成与 FIRSE 神经网络相匹配的多维信息矩阵数据形式。

综上所述,本实验的指挥控制网络节点数为5,节点之间采用3种通信手段,共构建10种指挥控制网络交互关系,并分别给出对应的关键节点。10种指挥控制网络交互关系如图7~图16所示。

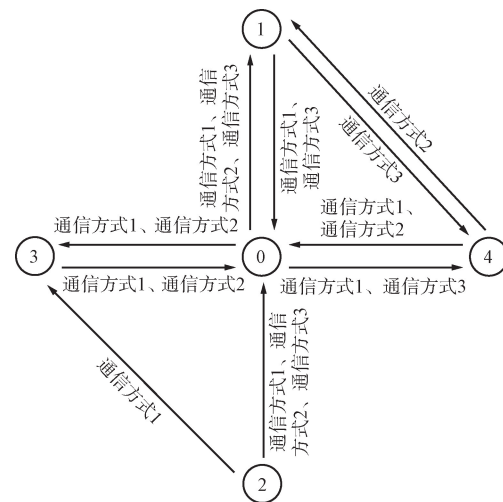


图7 节点交互关系例1

Fig. 7 Node interaction example 1

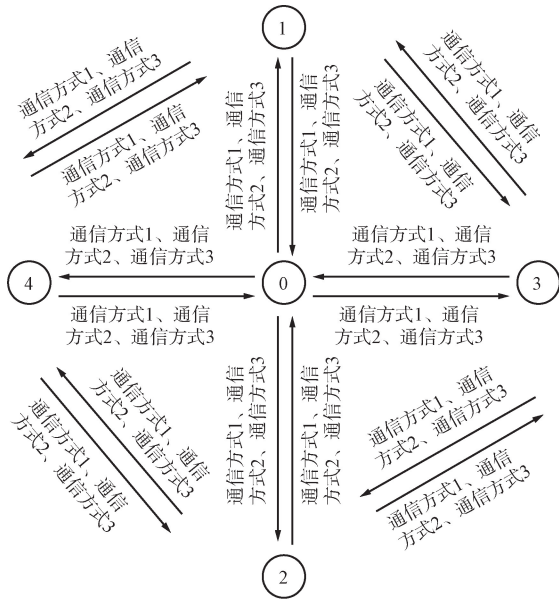


图 8 节点交互关系例 2

Fig. 8 Node interaction example 2

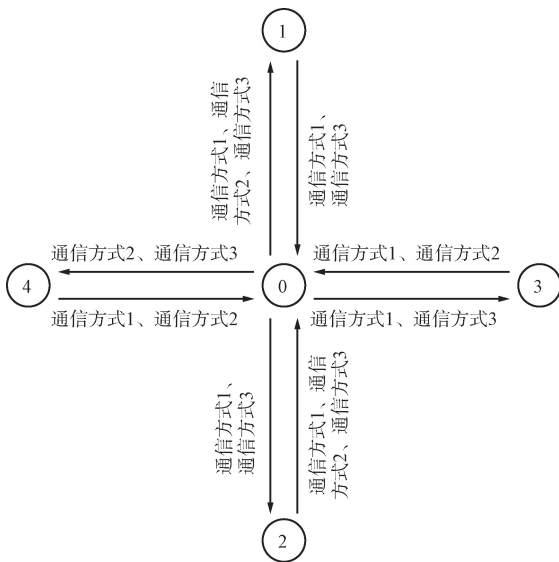


图 9 节点交互关系例 3

Fig. 9 Node interaction example 3

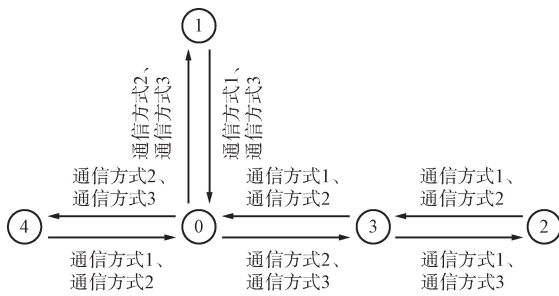


图 10 节点交互关系例 4

Fig. 10 Node interaction example 4

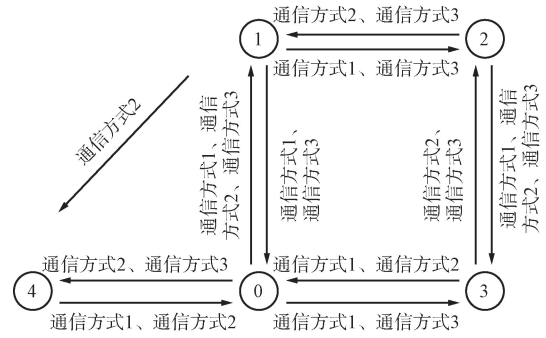


图 11 节点交互关系例 5

Fig. 11 Node interaction example 5

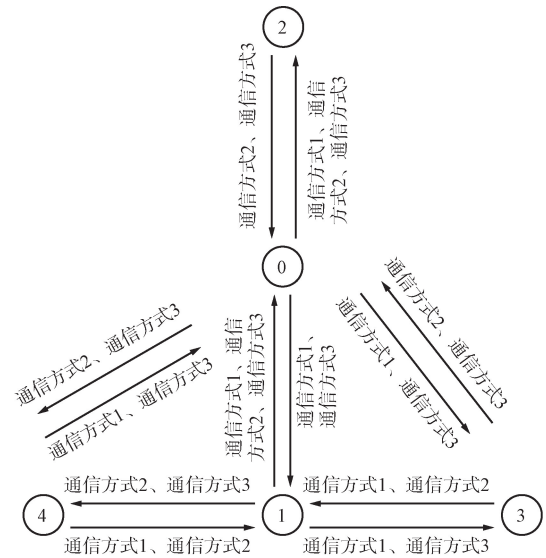


图 12 节点交互关系例 6

Fig. 12 Node interaction example 6




图 13 节点交互关系例 7

Fig. 13 Node interaction example 7

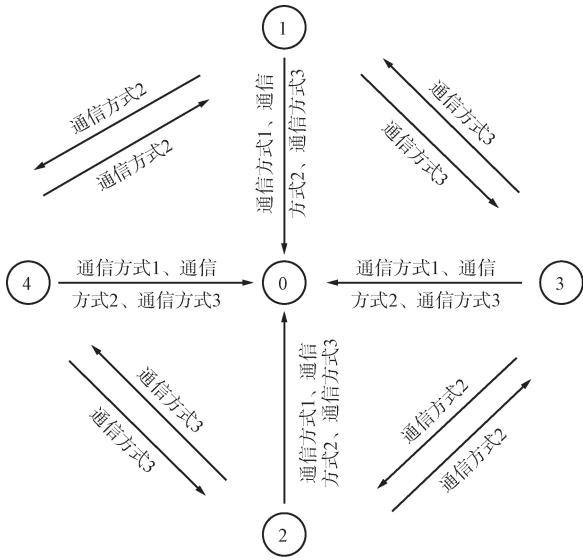


图 14 节点交互关系例 8  
Fig. 14 Node interaction example 8




图 15 节点交互关系例 9  
Fig. 15 Node interaction example 9






图 16 节点交互关系例 10  
Fig. 16 Node interaction example 10


基于蒙特卡罗实验理念,统计在 1 000 次通信侦察中,基于指挥控制节点交互关系,使各节点之间采用不同通信方式进行随机通信,并统计互通次数,以通信方式作为第一个维度、节点间互通次数作为第二个和第三个维度,体现节点之间通信的相互性。图 7 中指挥控制节点交互关系例 1 对应的多维信息矩阵如图 17 所示。



(a) 多维信息矩阵的第一层



(b) 多维信息矩阵的第二层



(c) 多维信息矩阵的第三层

图 17 多维信息矩阵例

Fig. 17 Multi-dimensional information matrix example

对每种指挥控制网络交互关系侦察 100 次,形成样本数据集和对应的标签数据集,用于关键节点识别能力的训练。

6.2 实验环境设置与参数配置

本实验在 Windows 10 操作系统上开展,为英伟达 GeForce RTX 2070 SUPER,采用的主要设备为 Intel(R) Core(TM) i7-10700K 处理器、机带内存容量为 80 GB 和图像处理。采用 Python 3.8 编译环境进行实验,机器学习采用 scikit-learn 库,神经网络采用 PyTorch 开源深度学习框架搭建。

参数配置分为 2 个部分:训练策略参数和神经网络参数。训练策略参数包括数据集比例、批数量和学习率。设置数据集比例  $\mu$  为 0.9,批数量为 64 和学习率为 0.000 3。然后,详尽给出 FIRSE 神经网络的组成参数。FIRSE 神经网络的 3 种主线模块参数如表 1 所示。

表 1 3 种主线模块参数  
Tab.1 Three main module parameters

层类型	主线模块 1	主线模块 2	主线模块 3
Conv2d	$in\_channels=3, out\_channels=6, kernel\_size=(1, 1), stride=(1, 1)$	$in\_channels=12, out\_channels=24, kernel\_size=(1, 1), stride=(1, 1)$	$in\_channels=48, out\_channels=8, kernel\_size=(1, 1), stride=(1, 1)$
BatchNorm2d 层	$num\_features=6$	$num\_features=24$	$num\_features=8$
ReLU 层	$inplace=True$	$inplace=True$	$inplace=True$
Conv2d	$in\_channels=6, out\_channels=6, kernel\_size=(1, 1), stride=(1, 1)$	$in\_channels=24, out\_channels=24, kernel\_size=(3, 3), stride=(1, 1)$	$in\_channels=8, out\_channels=8, kernel\_size=(3, 3), stride=(1, 1)$
BatchNorm2d 层	$num\_features=6$	$num\_features=24$	$num\_features=8$
Conv2d	$in\_channels=6, out\_channels=12, kernel\_size=(1, 1), stride=(1, 1)$	$in\_channels=24, out\_channels=48, kernel\_size=(1, 1), stride=(1, 1)$	$in\_channels=8, out\_channels=16, kernel\_size=(1, 1), stride=(1, 1)$
BatchNorm2d 层	$num\_features=12$	$num\_features=48$	$num\_features=16$
全连层	$in\_features=12, out\_features=4$	$in\_features=48, out\_features=16$	$in\_features=16, out\_features=5$
ReLU 层	$inplace=True$	$inplace=True$	$inplace=True$
全连层	$in\_features=4, out\_features=12$	$in\_features=16, out\_features=48$	$in\_features=5, out\_features=16$
Sigmoid	-	-	-
Conv2d	$in\_channels=3, out\_channels=12, kernel\_size=(1, 1), stride=(1, 1)$	$in\_channels=12, out\_channels=48, kernel\_size=(1, 1), stride=(1, 1)$	$in\_channels=48, out\_channels=16, kernel\_size=(1, 1), stride=(1, 1)$
BatchNorm2d 层	$num\_features=12$	$num\_features=48$	$num\_features=16$

FIRSE 神经网络的支线模块参数如表 2 所示。

表 2 支线模块参数  
Tab.2 Feeder model parameters

层类型	支线模块 1	支线模块 2	支线模块 3
Conv2d	$in\_channels=3, out\_channels=48, kernel\_size=(1, 1), stride=(1, 1)$	$in\_channels=3, out\_channels=16, kernel\_size=(1, 1), stride=(1, 1)$	$in\_channels=3, out\_channels=16, kernel\_size=(1, 1), stride=(1, 1)$
BatchNorm2d 层	$num\_features=48$	$num\_features=16$	$num\_features=16$

FIRSE 神经网络的分类模块参数如表 3 所示。

表 3 分类模块参数  
Tab.3 Classification model parameters

层类型	分类模块 1	分类模块 2	分类模块 3
ReLU 层	$inplace=False$	$inplace=True$	$inplace=True$
全连层	$in\_features=400, out\_features=120$	$in\_features=120, out\_features=84$	$in\_features=84, out\_features=5$

6.3 实验过程

数据集维度为  $120\ 000 \times 3 \times 5 \times 5$ ,将数据集打乱

后,分为训练样本集和测试样本集,维度分别为  $108\ 000 \times 3 \times 5 \times 5$  和  $12\ 000 \times 3 \times 5 \times 5$ 。通过训练样本

集和测试样本集对 FIRSE 深度神经网络模型进行训练,然后对所有数据集中的样本进行分类,通过关键节点识别正确率验证本方法有效性。

由于本文针对问题的特殊性,当前尚未有从通信对抗领域角度进行关键节点识别的方法,所以尚无可以直接进行对比的实验结果。针对此情况,以关键节点提取方法的主干方法进行了对比验证,包括决策树分类器<sup>[27]</sup>、贝叶斯分类器<sup>[26]</sup>、循环神经网络<sup>[6,28]</sup>和 ResNet34 神经网络<sup>[33,13]</sup>,作为对照组分别计算其关键节点识别正确率。其中,决策树分类器、贝叶斯分类器和循环神经网络在关键指控节点识别领域有所应用,通过对比可以表明本文方法在采用通信侦察手段识别关键节点领域内的先进性。而通过与经典的 ResNet34 神经网络进行对比,表明本文方法针对专业领域的改进后,相比于直接使用典型模型效果更优,进一步说明本文的改进具有应用价值。

### 6.4 结果分析

本文方法的损失和正确率随训练次数变化的曲线分别如图 18 和图 19 所示。




图 18 损失随训练次数变化曲线

Fig. 18 Loss change curve with training times




图 19 正确率随训练次数变化曲线

Fig. 19 Correct change curve with training times

采用混淆矩阵展示模型对每个样本的关键节点识别结果,包括哪些样本的关键节点被错误识别(即对角线上元素),哪些样本的关键节点被错误识别成其他节点(即非对角线上元素)。本文方法的关键节点识别混淆矩阵是  $N \times N$  矩阵( $N$  代表节点数量),其每一行代表一个通联数据对应的实际关键节点,用  $i$  表示,每一列代表一个模型对样本识别后得到的关键节点,用  $j$  表示,  $i, j \in N$ 。矩阵中的每个元素  $A_{ij}$  表示通联数据样本的关键节点实际为节点  $i$  但被模型识别为节点  $j$  的样本数量。基于混淆矩阵,提出结合关键节点识别问题的评估指标,分别为识别准确率  $\varphi$ 、识别假正例率  $\phi_j$  和识别假负例率  $\eta_i$ 。

识别准确率  $\varphi$  用于表示所有被正确识别出关键节点的测试集样本数与总测试集样本数的比值。

$$\varphi = \frac{\sum_i \sum_{i=j} A_{ij}}{\sum_i \sum_j A_{ij}} \quad (9)$$

识别假正例率  $\phi_j$  为通联信息样本的关键节点不为某节点,但是被模型错误识别为该节点的平均概率。

$$\phi_j = \frac{\sum_{i \neq j} A_{ij}}{\sum_i A_{ij}} \quad (10)$$

识别假负例率  $\eta_i$  为通联样本的关键节点为某节点,但是被模型错误地识别为其他节点的平均概率。

$$\eta_i = \frac{\sum_{i \neq j} A_{ij}}{\sum_j A_{ij}} \quad (11)$$

本文方法、决策树分类器、贝叶斯分类器、循环神经网络和 ResNet34 神经网络经过训练和测试后,得到关键节点识别混淆矩阵和对应的评估指标。

本文方法的关键节点识别混淆矩阵如图 20 所示。




图 20 本文方法的关键节点识别混淆矩阵

Fig. 20 Confusion matrix for key node identification in this method

基于本文方法的关键节点识别混淆矩阵的评估指标如表 4 所示。

**表 4 本文方法的评估指标**  
**Tab. 4 Evaluation indices of this method**

节点标号	准确率/%	假正例率/%	假负例率/%	均值/%
0		0.025	0.054	
1		0.050	0.067	
2	99.953	0.038	0.046	0.047
3		0.088	0.030	
4		0.033	0.038	

决策树分类器的关键节点识别混淆矩阵如图 21 所示。

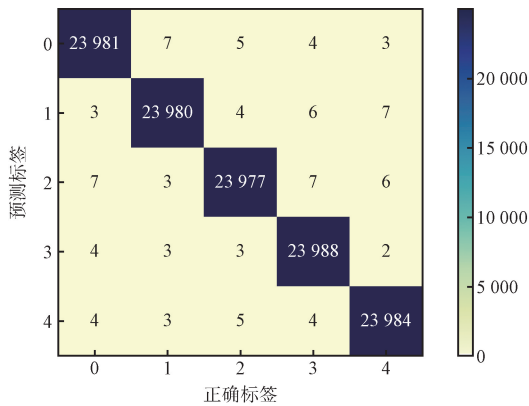


图 21 决策树分类器的关键节点识别混淆矩阵  
Fig. 21 Confusion matrix for key node identification of decision tree classifier

基于决策树分类器的关键节点识别混淆矩阵的评估指标如表 5 所示。

**表 5 决策树分类器的评估指标**  
**Tab. 5 Evaluation indices of decision tree classifier**

节点标号	准确率/%	假正例率/%	假负例率/%	均值/%
0		0.075	0.079	
1		0.067	0.083	
2	99.925	0.071	0.096	0.075
3		0.075	0.050	
4		0.075	0.067	

贝叶斯分类器的关键节点识别混淆矩阵如图 22 所示。

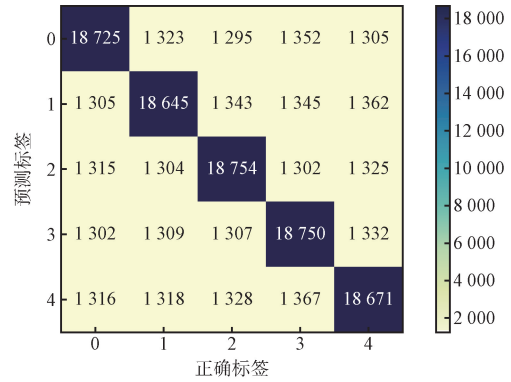


图 22 贝叶斯分类器的关键节点识别混淆矩阵  
Fig. 22 Confusion matrix for key node identification of Bayesian classifier

基于贝叶斯分类器的关键节点识别混淆矩阵的评估指标如表 6 所示。

**表 6 贝叶斯分类器的评估指标**  
**Tab. 6 Evaluation indices of Bayesian classifier**

节点标号	准确率/%	假正例率/%	假负例率/%	均值/%
0		21.859	21.979	
1		21.974	22.313	
2	77.954	21.936	21.849	22.042
3		22.251	21.865	
4		22.188	22.204	

循环神经网络的关键节点识别混淆矩阵如图 23 所示。




图 23 循环神经网络的关键节点识别混淆矩阵  
Fig. 23 Confusion matrix for key node identification of recurrent neural networks

基于循环神经网络的关键节点识别混淆矩阵的评估指标如表 7 所示。

表 7 循环神经网络的评估指标

Tab. 7 Evaluation indices of recurrent neural networks

节点 标号	准确率/%	假正 例率/%	假负 例率/%	均值/%
0		24. 821	26. 526	
1		28. 092	23. 977	
2	75. 073	23. 788	25. 583	24. 907
3		24. 183	24. 259	
4		23. 750	24. 189	

ResNet34 神经网络的关键节点识别混淆矩阵如图 24 所示。




图 24 ResNet34 神经网络的关键节点识别混淆矩阵  
Fig. 24 Confusion matrix for key node identification of ResNet34

基于 ResNet34 神经网络的关键节点识别混淆矩阵的评估指标如表 8 所示。

表 8 ResNet34 神经网络的评估指标  
Tab. 8 Evaluation indices of ResNet34

节点 标号	准确率/%	假正 例率/%	假负 例率/%	均值/%
0		0. 092	0. 145	
1		0. 358	0. 087	
2	99. 840	0. 100	0. 150	0. 160
3		0. 133	0. 096	
4		0. 117	0. 329	

对上述指标进行汇总,各方法的对比结果如表 9 所示。除此之外,增加运算时间和资源用量指标,用于尝试从计算复杂度的角度对方法进行参考和对比。其中运算时间指对全部数据集中样本完成关键节点识别所需要的时间。资源使用量是指占用图形处理器(Graphics Processing Unit, GPU)的内存

资源量。其中,决策树分类器和贝叶斯分类器进行识别时,不需要使用 GPU,故不在表中进行统计。

表 9 结果对比

Tab. 9 Results comparison

方法	准确率/%	假正 例率 均值/%	假负 例率 均值/%	运算 时间/s	资源使 用量/GB
本文方法	99. 953	0. 047	0. 047	5. 312	7. 7
决策树分类器	99. 925	0. 075	0. 075	0. 026	—
贝叶斯分类器	77. 954	22. 042	22. 042	0. 312	—
循环神经网络	75. 073	24. 927	24. 907	0. 242	1. 9
ResNet34 神经网络	99. 840	0. 160	0. 160	22. 061	3. 7

本文方法以 99. 953% 的准确率显著领先于其他方法,显示出其在识别关键节点方面极高的准确性。决策树分类器的准确率为 99. 925%, ResNet34 神经网络的准确率为 99. 840%, 尽管二者相对较高,但仍低于本文方法。贝叶斯分类器和循环神经网络的准确率分别为 77. 954% 和 75. 073%, 显著低于前三者,表明其在该任务中的表现不够理想。

在假正例率和假负例率方面,本文方法均为 0. 047%, 显示出其在减少错误识别方面的优势。决策树分类器的假正例率和假负例率均为 0. 075%, 略高于本文方法,但仍在可接受范围内。ResNet34 神经网络的假正例率和假负例率为 0. 160%, 高于本文方法,表明其误识别率较高。贝叶斯分类器和循环神经网络的假正例率和假负例率同样较高。

在运算时间和资源使用量方面,本文方法的运算时间为 5. 312 s, 资源使用量为 7. 7 GB。尽管成本相对较高,但考虑到其显著的准确率和低误识别率,这些成本是可以接受的。决策树分类器的运算时间为 0. 026 s, 是所有方法中最快的,但其误识别率略高。ResNet34 神经网络的运算时间为 22. 061 s, 资源使用量为 3. 7 GB, 尽管运算时间较长,但其准确率接近本文方法。贝叶斯分类器和循环神经网络的运算时间较短,分别为 0. 312、0. 242 s, 但由于其准确率较低,这些方法在该关键节点识别任务中的实用性有限。

综上所述,本文方法在识别准确率、假正例率和假负例率方面均表现优异,尽管其运算时间和资源使用量较高,但在实际应用中,考虑到其在关键节点识别任务中的卓越表现,这些成本可以接受。因此,本文方法在精度和可靠性方面明显优

于其他方法,特别适用于对识别精度要求较高的应用场景。

## 7 结束语

传统指挥控制网络关键节点识别方法高度依赖复杂网络理论,而各领域改进方法过度依赖专家经验知识,主观性强且差异性大。除此之外,应用机器学习的改进方法对于节点关系数据特征捕捉能力差。针对上述问题,基于通信侦察视角,本文提出基于卷积神经网络的指挥控制节点识别方法。依靠卷积神经网络在特征提取上的强大能力,构建指挥控制网络关键节点的智能识别范式。首先,为了适应卷积神经网络对于输入数据结构的需求,基于特征工程,将通信侦察获得的指挥控制网络节点互通次数和通信类型转换为多维数据矩阵。然后,结合 ResNet、SENet 和 DenseNet 等典型卷积神经网络架构的优点,受数字信号处理中 FIR 滤波器结构的启发,提出适用于指挥控制节点识别问题的 FIRSE 神经网络,进一步提高了卷积神经网络在指挥控制网络关键节点识别上的适应性。最后,针对典型神经网络训练策略的不足,提出通过动态峰值检测法获取最优神经网络参数,增强了本文方法的工程实现能力。实验结果表明,本文方法能够有效识别关键节点。以识别正确率和单次训练耗时作为评价指标,与应用在节点识别任务的机器学习和深度学习方法进行对比,本文方法对于细微差别提取和具有图结构特点数据的特征提取具有明显优势,能够获得更精确的识别结果,具有更高的准确性和相对较低的计算复杂度。在后续的研究中,将着重解决网络节点数变化导致多维数据矩阵维度变化和给出网络中所有节点的关键概率。除此之外,将针对该领域问题的计算复杂度评估方法论和评估体系构建开展研究,支撑工程实现。

### 参考文献

- [1] 黄谦,李坎,李美兰,等.面向信息时代网络赋能指挥控制的层次模式连通结构[J].指挥与控制学报,2023,9(5):589-595.
- [2] 王文浩,朱承,王云飞.威胁体智能孪生技术及其在网络防御指挥控制上的应用[J].指挥与控制学报,2022,8(1):64-71.
- [3] 汪跃,唐志军,车德朝,等.战场态势一张图技术综述[J].指挥信息系统与技术,2020,11(1):12-17.
- [4] 黄美根,王维平,王涛,等.基于 EC2 的无人化作战体系云流化指控架构设计方法[J].系统工程与电子技术,2022,44(11):3413-3422.
- [5] 畅鑫,李艳斌,赵研,等.基于 MA2IDDPG 算法的异构多无人机协同突防方法[J].河北工业科技,2022,39(4):328-334.
- [6] CHANG X, LI Y B, ZHAO Y, et al. An Improved Anti-Jamming Method Based on Deep Reinforcement Learning and Feature Engineering [J]. IEEE Access, 2022, 10: 69992-70000.
- [7] 王劲松,李宗育,徐晏琦.基于多属性决策的复杂网络节点攻击研究[J].电光与控制,2016,23(4):42-47.
- [8] LATORA V, NICOSIA V, RUSSO G. Complex Networks: Principles, Methods and Applications [M]. Cambridge: MIT Press, 2017.
- [9] 杨松青,蒋沅,童天驰,等.基于 Tsallis 熵的复杂网络节点重要性评估方法[J].物理学报,2021,70(21):273-284.
- [10] 阮逸润,老松杨,汤俊,等.基于引力方法的复杂网络节点重要度评估方法[J].物理学报,2022,71(17):298-309.
- [11] 莫泓铭.一种基于信度函数的复杂网络重要节点识别方法[J].长春师范大学学报,2018,37(6):19-26.
- [12] 王力梅.基于多指标决策的复杂网络节点识别[J].兰州文理学院学报(自然科学版),2023,37(5):58-62.
- [13] 邱明劼,张鹏,汪圣利.一种基于 ResNet 的雷达弱小目标检测方法[J].无线电工程,2024,54(7):1652-1659.
- [14] HU J P, SHEN L, ALBANIE S, et al. Squeeze-and-Excitation Networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2011-2023.
- [15] 刘杰,朱宇轩,马钰.基于深度残差网络的  $(n, l, m)$  卷积码盲识别[J].无线电通信技术,2023,49(6):1052-1058.
- [16] 孟丽楠,谢红薇,宁晨,等.基于深度卷积神经网络的心音分类算法[J].计算机测量与控制,2021,29(8):211-217.
- [17] ALAN O, RONALD W, JOHN R. Discrete-time Signal Processing [M]. Upper Saddle River: Prentice Hall, 2017.
- [18] 李国栋,赵忠文,石成豪.基于复杂网络的天基信息网络节点重要性评价综述[J].兵工自动化,2023,42(2):70-74.
- [19] 张笑楠,罗鹏程,胡鑫武,等.基于复杂网络的指挥控制体系成熟度评估方法[J].火力与指挥控制,2020,45(1):94-99.
- [20] 陈周牛.舰船电子通信网络群体节点位置自动预测方法[J].舰船科学技术,2019,41(22):169-171.
- [21] 王运明,王青野,潘成胜,等.面向结构洞的指挥控制网络关键节点识别方法[J].火力与指挥控制,2017,42(3):59-63.
- [22] 闫志英.多数据源舰船通信网络节点安全态势评估研究[J].舰船科学技术,2019,41(2):154-156.
- [23] 许怡岚,郭唐仪,唐坤,等.基于超网络的军事交通运输网络节点价值评估方法[J].兵工学报,2024,45(2):552-563.

- [24] 王瑛,张泽,张滢,等. 基于多属性决策的 PCAS-SNIF 关键节点分析[J]. 空军工程大学学报(自然科学版), 2021,22(6):90-96.
- [25] GÉRON A. Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems [M]. Sebastopol: O'Reilly Media, 2019.
- [26] 陈诗,任卓明,刘闯,等. 时序网络中关键节点的识别方法研究进展[J]. 电子科技大学学报, 2020, 49(2): 291-314.
- [27] DAI J H, CHEN Y Q, CHEN Y C, et al. An Analysis of Network Traffic Identification Based on Decision Tree [C]//2021 International Conference on Artificial Intelligence and Electromechanical Automation (AIEA). Guangzhou: IEEE, 2021: 308-311.
- [28] 张镔,潘志松,胡谷雨,等. 基于时空图卷积的动态网络节点重要性研究[J]. 大学数学, 2023, 39(4): 65-71.
- [29] 靳越,吴晓富,张剑书. 融合注意力机制和 LSTM 的跳频抗干扰智能决策[J]. 无线电通信技术, 2023, 49(6): 1059-1066.
- [30] GILSIC G, LORENZO D B. Artificial Intelligence and Quantum Computing of Advanced Wireless Networks [M]. New York: John Wiley & Sons, 2022.
- [31] 李懿凡,钱华明,黄洪钟,等. 基于广义连续时间贝叶斯网络的指挥控制网络系统可靠性分析[J]. 系统工程与电子技术, 2022, 44(12): 3880-3886.
- [32] HU K B, YU L F, XU L B, et al. Dynamic Identification of Key Nodes in Digital Microwave Communication Link Based on Network Topology [C]//2021 2nd International Seminar on Artificial Intelligence, Networking and Information Technology (AINIT). Shanghai: IEEE, 2021: 454-457.
- [33] WANG L Y, LI Y, REN Y, et al. Key Node Identification of Satellite Time-varying Network with Deep Reinforcement Learning [C]//2022 International Conference on Image Processing, Computer Vision and Machine Learning (ICICML). Xi'an: IEEE, 2022: 572-579.
- [34] 吴玲玲,李广峰,韩邦杰,等. 基于卷积神经网络学习的盲突发通信信号检测方法[J]. 无线电通信技术, 2023, 49(2): 318-324.
- [35] 王满喜,史佳明,陆科宇,等. 电磁信号调制识别中的对抗性攻击技术研究[J]. 无线电通信技术, 2022, 48(6): 1098-1104.
- [36] CHANG X, LI Y B, ZHANG G J, et al. An Improved Reinforcement Learning Method Based on Unsupervised Learning [J]. IEEE Access, 2024, 12: 12295-12307.
- [37] 畅鑫,李艳斌,赵研,等. 一种基于深度学习的指挥控制网络关键节点识别方法: ZL202111332644.7 [P]. 2024-05-03.

---

**作者简介:**

畅鑫 男, (1990—), 博士, 高级工程师。

刘东辉 女, (1990—), 博士, 讲师。