

一种基于混合预测模型的海上多目标群行为意图预测方法

刘青 张江明

中国电波传播研究所 山东 青岛 266107

【摘要】：在现代海上复杂的电磁环境下，目标通信网络节点呈现出了动态化、分布式和智能化特征，其通信行为模式蕴含着深层的决策逻辑，构成了反映目标体系的“数字指纹”。针对传统方法难以有效结合目标通信网络空间拓扑特征与动态时序特征的问题，本研究提出一种融合图神经网络（Graph Convolutional Network, GCN）和门控循环单元网络（Gated Recurrent Unit, GRU）的时空联合建模方法。该方法首先对多源目标通信侦察数据进行特征提取与数据标注，构建了包含节点属性、拓扑结构和时间属性的时序数据集；然后利用 GCN 层捕获目标通信网络的空间拓扑特征，并利用 GRU 层建模目标节点通信行为的时序演变规律，协同构建时空特征向量集合；最后通过全连接分类层来实现行为意图的语义映射。本研究实验基于虚拟化仿真平台生成的 40,520 组通信轮次样本数据开展验证实验，结果表明本研究所提出的混合预测模型的准确率达到 90.27%，能够有效捕捉目标通信行为中的隐含语义，为态势感知与决策提供了可靠的智能支撑。

【关键词】：意图预测；图神经网络；门控循环单元网络；通信行为模式分析

DOI:10.12417/2705-0998.26.03.040

目前，针对目标行为意图识别的研究主要围绕规则匹配、专家系统、机器学习及深度学习等技术路径展开。早期研究以规则与模板匹配技术为核心方法^[1]，该方法通过构建基于专家经验的决策框架，实现目标模型与预设模板的匹配推理。例如，和钰等人提出的基于贝叶斯规则推理（Belief Rule-Based, BRB）的防空目标意图识别系统，其核心机制在于依托专家知识库，通过特征参数与规则模板的匹配过程完成目标意图识别^[1]。机器学习模型可以接收实时采集到的环境信息，并通过映射函数，模型能够将原始数据转化为有意义的信息，从而分析出目标的行为模式^[2]。循环神经网络（Recurrent Neural Network, RNN）及其变体为序列数据处理开辟了新路径，其独特的时序建模能力可有效捕捉目标行为特征中的时间依赖性和非线性关联特征。为了根据海上场景中的目标通信网络态势，分析目标节点通信行为，本研究提出了一种融合 GCN 和 GRU 的海上目标行为意图预测方法。

1 传统的预测方法

1.1 支持向量机（SVM）算法预测模型

SVM 算法主要在构建的特征空间寻找最优的超平面实现对不同目标进行分类。对于给定数据集 $D = \{x_j, y_j\}$ ，SVM 分类转化为如下表示：

$$\begin{cases} y_i(\sigma^T x_i + \alpha) \geq 1 \\ \min_{\sigma, \alpha} \frac{1}{2} \|\sigma\|^2 \end{cases} \quad (1)$$

也就是求解在 $y_i(\sigma^T x_i + \alpha) \geq 1$ 的条件下， $\min_{\sigma, \alpha} \frac{1}{2} \|\sigma\|^2$ 的最优值。通过引入拉格朗日变换，并且满足 KKT 的条件时，可以得到 σ 和 α 的更新迭代模型如下，其中 ω 是在拉格朗日变换下得到的最优解。

$$\sigma = \sum_{i=1}^N \omega_i y_i x_i \quad (2)$$

$$\alpha = y_i - \sum_{i=1}^N \omega_i y_i x_i^T x_i \quad (3)$$

1.2 长短记忆网络(Long Short-Term Memory, LSTM)算法预测模型

LSTM 算法主要针对现有 RNN 中存在的问题而改进的一种网络模型。该网络由门控制单元和记忆细胞所组成，通过长时间记忆细胞记录关键重要的信息，与门控制系统协调作用实现其时序状态的预测可以摆脱对单一状态的依靠。

假设上一时刻的输出为 y_{t-1} 和 t 时刻的输入 x_t ，通过遗忘门可以得到 φ_t 。

$$\varphi_t = \lambda(\omega_\varphi \cdot [y_{t-1}, x_t] + b_\varphi) \quad (4)$$

其中 λ 是激活函数， ω_φ 是权重系数。

作者简介：刘青（1989-），女，陕西省西安市人，硕士，主要研究方向为电磁频谱管理、电磁资源筹划与调度研究等。

张江明（1991-），男，山东省潍坊市人，硕士，主要研究方向为电磁频谱管理、电磁干扰计算等。

t时刻的输入门 I_t 为:

$$I_t = \lambda(\omega_l[y_{t-1}, x_t] + b_l) \quad (5)$$

此时记忆单元状态更新如下:

$$R_t = \varphi_l * R_{t-1} + I_t * \tanh(\omega_r[y_{t-1}, x_t] + b_r) \quad (6)$$

综上可得模型的最终预测输出 y_t 为:

$$y_t = \omega_y \lambda(\omega_o[y_{t-1}, x_t] + b_o) * \tanh(R_t) + b_y \quad (7)$$

2 混合模型构建

在海上对抗场景中,本研究将目标意图定义为:海空目标为完成特定战役任务而制定并准备实施的行动方案集合。首先,对侦察节点捕获的多元异构通信数据进行数据清洗与数据标注,从中提取出与意图预测任务高度相关的属性特征,形成结构化的目标通信行为时序数据集;其次,基于专家战术知识库与历史数据,构建涵盖侦察渗透、火力打击、协同突防等典型行为的意图语义空间;最后,设计基于GCN的空间特征提取模块,通过图嵌入技术捕捉通信网络的拓扑关联特性,构建GRU时序建模模块,建立通信行为在时间维度的动态演化模型,最终通过全连接分类层,将融合空间拓扑特征与时间动态特征的时空特征向量映射至预设的意图语义空间,实现对目标行为意图的精准预测。

2.1 行为意图空间构建

在本研究所构建的行为意图预测框架中,目标的行为意图被形式化定义为在具有语义标注的离散状态,该意图空间通过分析一段时间内的本研究所使用的原始时序数据集,并结合领域专家经验。

2.2 数据预处理

在构建了详尽的目标意图空间之后,需要对意图空间的目标进行标注,为后续的模型训练和测试提供样板。本研究采用了一种人工标注与计算机脚本自动化标注相结合的方法,可以实现对本研究所用的原始时序数据集进行高效标注,从而形成了模型训练、测试所使用的标注时序数据集。该数据集涵盖了通信节点的空间位置、占空比、传输路径、目标意图标签、当前通信轮次等关键信息。

2.3 算法设计

本方法采用时序图神经网络模型,在输入层到输出层之间精心设计了四个核心信息处理层,包括空间特征提取层、时间序列建模层、分类决策层以及辅助层。各个核心模块协同处理,可以有效的实现对目标行为意图进行预测,每个模块的具体功能如下:

(a)空间特征提取层

空间特征提取层由2层图卷积网络(Graph Convolutional

Network, GCN)组成,用来学习如何表示某一通信轮次中目标通信网络节点的空间特征(如节点类型、地理位置)以及网络拓扑关系。在GCN中,每个图中的节点都关联一个特征向量,而边则表示节点之间的连接关系,其基本思想是将传统的卷积操作扩展到图数据上,聚合邻居节点的信息,从而更新每个节点的特征表示。类似于CNN的卷积操作,图卷积操作的输入为图数据的邻接矩阵A和特征矩阵H,如公式(8)所示。

$$H^{(l+1)} = \sigma \left(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^{(l)} W^{(l)} \right) \quad (8)$$

其中, \tilde{A} 为调整后的邻接矩阵,通常邻接矩阵A不包含自身特征,故需要做出调整 $\tilde{A} = A + I$, I为单位矩阵; $\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}}$ 是对邻接矩阵进行对称归一化,防止度高的节点在聚合时占据主导地位,保证信息传播的平衡性, W为权重矩阵; σ 为激活函数。

(b)时间序列建模层

时间序列建模层采用了GRU,用于捕捉多个时间步长上空间特征提取层输出的目标通信网络空间特征向量间的时序依赖关系。不仅可以结合目标通信网络在某一通信轮次的空间特征,还考虑了连续几个通信轮次中的空间变换趋势,从而能够构建出一个关于目标通信网络动态演化的全面视图。

在GRU中,更新门决定使用多少历史信息 and 当前信息来更新当前隐含状态,具体而言,更新门采用sigmoid激活函数,其输出值介于0到1之间,用于调节前一通信轮次隐藏状态向当前状态的转移比例:当接近1时保留更多历史信息,当接近0时则主要依赖新输入。重置门同样基于sigmoid激活函数,决定旧状态信息在计算候选隐藏状态时的参与程度,通过控制历史信息的遗忘比例实现对记忆的动态管理。第n个通信轮次的更新门用公式(9)表示。重置门决定保留多少历史信息,第n个通信轮次的重置门如公式(10)所示。

$$Z_n = \sigma(W_z \times x_n + u_z \times h_{n-1} + b_z) \quad (9)$$

$$R_n = \sigma(W_r \times x_n + u_r \times h_{n-1} + b_r) \quad (10)$$

其中, x_n 为输入向量; h_n 为输出向量; Z_n 、 R_n 分别表示更新门和重置门的激活值; σ 为激活函数; W 、 u 为权重矩阵; b 为偏执矩阵。在更新门和重置门的作用下,当前隐含输出状态 h_n 可以更新为:

$$h_n = Z_n \times h_{n-1} + (1 - Z_n) \times \tanh(W \times x_n + R_n \times h_{n-1} + b) \quad (11)$$

(c)分类决策层

经过特征提取层后,可以从上述时序数据集中提取出一系

列关键属性时空特征, 构成时空特征集合 V_n 。这个特征集是一个动态的数据结构, 包含了在连续通信轮次上目标通信活动的时序特征, 可以形式化地表示为:

$$V_n = \{V^{(1)}, V^{(2)}, \dots, V^{(n)}\} \quad (12)$$

其中, 每个 $V^{(i)}$ 表示在通信轮次 i 抽取的目标通信网络特征向量, 该向量既包含了当前轮次的通信网络特征, 也包含了目标通信网络历史变化特征。作为全连接层, 分类决策层的任务是将 GRU 层输出的高维时空特征向量集合 V_n 映射到意图空间中具体的意图编码上。

3 实验评估

本次实验主要与 SVM 预测模型和 LSTM 预测模型进行对比。通过开展多轮次推演模拟实验, 共采集到 40,520 个具有时间序列特性的通信行为样本, 每个样本的单位为“通信轮次”, 具体定义为目标通信网络主节点向其他从节点发送控制指令或者从节点向主节点回传状态信息的基本操作单元。在数据特征维度上, 每个数据样本中包含了节点身份标识、三维坐标位置、通信时延、占空比、中心频率、带宽、码率等 13 个关键参数指标, 每个样本不仅记录了单个节点的通信行为, 更反映了整个目标通信网络在特定时间窗口内的协同通信活动模式。针对上述提取的原始数据样本, 运用本方法的数据预处理方法进行数据清洗与数据标注, 生成意图类型标签, 最终形成了模型训练、验证、测试所使用的标准化标注数据集。该数据集包含 5 类典型行为意图, 分布比例如下: 正常通信 (8.5%)、驱逐舰投放 M 型无人机集群和小型无人艇集群 (16.5%)、M 型无人机集群和小型隐身无人艇集群侦察信息 (20.5%)、驱逐舰投放 E 型无人机集群抵近压制, 并发射 A 型导弹进行远程打击 (29.45%)、突击舰发射 B 型战斧巡航导弹, 小型隐身无人艇集群发射 N 型导弹, 实施中远程联合打击 (25.05%)。其中, 攻击性意图样本占比达 54.50%, 充分反映了目标通信网络在不同阶段的行为特征差异。

实验环境配置方面, 采用 Python 3.8 编程环境搭建数据处理平台, 依托 Pandas 和 NumPy 进行数据预处理, 使用 Scikit-learn 实现特征工程, 所有实验均在配备 NVIDIA GeForce RTX 3090 GPU 的服务器上运行, 确保大规模时序数据的高效处理能力。

在进行模型训练、测试时, 将标注数据集的 70% 用于模型训练, 30% 用于模型测试。为了避免偶然性, 确保实验结果可

参考文献:

- [1] 和钰,常雷雷,姜江,谭跃进.基于置信规则库的防空目标意图识别方法[J].火力与指挥控制,2017,42(9):7-12.
- [2] 李泽鹏,吉琳娜,杨风暴.动态贝叶斯网络与独热编码 DTW 结合的空中目标意图识别方法[J].探测与控制学报,2025,47(02):82-90.

靠, 本次实验循环 15 次, 并且取 15 次的预测结果平均值作为实验的最终结果。模型训练完成后, 输入测试样本进行测试, 并采用公式 (13) 进行准确度计算。

$$Accuracy = \frac{|\{v \in V | b_{pred}(v) = b_{true}(v)\}|}{|V|} \quad (13)$$

其中, V 表示目标通信网络拓扑中的节点集合; $b_{pred}(v)$ 表示节点 v 的行为预测标签; $b_{true}(v)$ 表示节点 v 的真实行为标签; $|\bullet|$ 表示集合的基数。

采用公式(14)计算混合模型相比 SVM 模型和 LSTM 模型准确度提升百分比。

$$Accuracy_{ip} = \frac{Accuracy_{GCN+GRU} - Accuracy_{model}}{Accuracy_{model}} \quad (14)$$

其中, $Accuracy_{ip}$ 表示准确度提升百分比; $Accuracy_{GCN+GRU}$ 表示 GCN+GRU 模型的准确度; $Accuracy_{model}$ 表示 SVM 模型或 LSTM 模型的准确度。

表 1 展示了不同模型预测准确度结果以及混合模型相比 SVM 模型和 LSTM 模型准确度提升的百分比。

表 1 不同模型预测准确率以及性能提升百分比

模型	准确度 (%)	准确度提升 (%)
SVM 模型	60.37	49.53
LSTM 模型	61.11	47.72
GCN+GRU 模型	90.27	-

实验结果表明, 本研究所提出的 GCN+GRU 模型预测准确度最高, 性能最好。与 SVM 模型和 LSTM 模型相比, 预测准确度分别提升了 49.53% 和 47.72%。

4 结论

本文提出的一种基于图神经网络 (GCN) 与门控循环单元 (GRU) 融合的行为意图预测方法, 通过时空特征建模实现对目标通信行为的深度解析。实验结果表明, 该方法在 40,520 个通信轮次样本上实现了 90.27% 的高准确率, 性能超过了 SVM 预测模型和 LSTM 预测模型。同时证明了所提出的模型在复杂环境中提取目标通信网络拓扑特征与时序依赖关系的能力, 为态势感知提供了可解释性强、泛化能力高的智能决策支持。