



计算机科学

COMPUTER SCIENCE

基于特征权重感知的VNF资源需求预测方法

王怀芹, 骆健, 王海艳

引用本文

王怀芹, 骆健, 王海艳. 基于特征权重感知的VNF资源需求预测方法[J]. 计算机科学, 2023, 50(9): 331-336.

WANG Huaiqin, LUO Jian, WANG Haiyan. [Feature Weight Perception-based Prediction of Virtual Network Function Resource Demands](#) [J]. Computer Science, 2023, 50(9): 331-336.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[一种面向最佳收益的服务功能链在线编排方法](#)

Online Service Function Chain Orchestration Method for Profit Maximization

计算机科学, 2023, 50(6): 66-73. <https://doi.org/10.11896/jsjcx.220400156>

[基于注意力机制的可解释点击率预估模型研究](#)

Study on Interpretable Click-Through Rate Prediction Based on Attention Mechanism

计算机科学, 2023, 50(5): 12-20. <https://doi.org/10.11896/jsjcx.221000032>

[多域SFC部署中基于强化学习的多目标优化方法](#)

Multi-objective Optimization Method Based on Reinforcement Learning in Multi-domain SFC

Deployment

计算机科学, 2021, 48(12): 324-330. <https://doi.org/10.11896/jsjcx.201100159>

[基于加权图的链路映射算法](#)

Link Mapping Algorithm Based on Weighted Graph

计算机科学, 2021, 48(11A): 476-480. <https://doi.org/10.11896/jsjcx.201200216>

[基于SDN-SFC的服务功能负载均衡](#)

Service Function Load Balancing Based on SDN-SFC

计算机科学, 2019, 46(9): 130-136. <https://doi.org/10.11896/j.issn.1002-137X.2019.09.018>

基于特征权重感知的 VNF 资源需求预测方法

王怀芹¹ 骆健^{1,2} 王海艳^{1,2}

1 南京邮电大学计算机学院 南京 210023

2 南京邮电大学江苏省大数据安全与智能处理重点实验室 南京 210023

(1220045225@njupt.edu.cn)

摘要 虚拟网络功能(Virtual Network Function, VNF)以服务功能链(Service Function Chain, SFC)的形式提供服务,能够满足不同服务的性能需求。由于网络具有动态性,为 VNF 实例分配固定资源会导致 VNF 实例的资源过多或者不足的问题。以往的研究对于 VNF 配置文件相关网络负载特征的重要性未做区分,因此,提出了一种基于特征权重感知的动态 VNF 资源需求预测方法。首先,使用 ECANet 学习 VNF 特征的权重值,以此来减少无用特征对模型预测结果的消极影响。其次,由于 VNF 配置文件数据集具有结构化特性,构建 VNF 资源预测模型时需要考虑以加强特征交互的方式来挖掘特征间深层的相互关系,提出使用深度特征交互网络(Deep Feature-Interactive Network, DIN)增强网络负载特征与 VNF 性能特征之间的交互能力,提高模型预测精度。最后,在基准数据集上将所提方法与同类方法进行对比实验,发现其在预测的有效性上更具优势。

关键词: 资源预测;服务功能链;虚拟网络功能;高效通道注意力网络;特征交互

中图分类号 TP391

Feature Weight Perception-based Prediction of Virtual Network Function Resource Demands

WANG Huaiqin¹, LUO Jian^{1,2} and WANG Haiyan^{1,2}

1 School of Computer Science, Nanjing University of Post and Telecommunications, Nanjing 210023, China

2 Jiangsu High Technology Research Key Laboratory for Wireless Sensor Networks, Nanjing University of Post and Telecommunications, Nanjing 210023, China

Abstract Virtual network function(VNF) provides services in the form of service function chain(SFC) to meet the performance requirements of different services. Due to the dynamic nature of the network, allocating fixed resources to VNF instances will lead to excessive or insufficient resources for VNF instances. Previous studies have not distinguished the importance of network load characteristics related to VNF profiles. Therefore, a dynamic VNF resource demand prediction method based on feature weight perception is proposed. Firstly, ECANet is used to learn the weight values of VNF features, to reduce the negative impact of useless features on the model prediction results. Secondly, because the VNF profile data set has structural characteristics, when building the VNF resource prediction model, it is necessary to consider mining the deep interrelationship between features by strengthening feature interaction. It is proposed to use the deep feature interactive network(DIN) to enhance the interaction between network load features and VNF performance features, so as to improve the prediction accuracy of the model. Finally, compared with similar methods on the benchmark dataset, it is found that the proposed method has more advantages in the effectiveness and accuracy of prediction.

Keywords Resource prediction, Service function chain, Virtual network function, Efficient channel attention network, Feature interaction

1 引言

软件定义网络(Software Defined Network, SDN)和网络功能虚拟化(Network Function Virtualization, NFV)的虚拟网络技术正受到越来越多人的关注^[1]。网络功能虚拟化使传统网络功能从专用硬件设备中抽象出软件化的虚拟网络功能(VNF),推动了网络服务部署由僵化的“网元”部署模式转向

相对灵活的切片部署模式。该方法使得网络资源分配更加灵活,能够实现网络实时业务、应用智能的快速响应,提高服务质量。传统的 VNF 资源分配方法是用固定大小的网络资源对 VNF 实例进行实例化,但是这会导致各种网络资源分配不足或过度分配,从而造成资源的浪费。研究一种有效的 VNF 资源需求分配方法,是一项巨大的挑战。

已经有研究者对 VNF 动态资源分配方法进行研究,其

到稿日期:2022-10-07 返修日期:2023-03-17

基金项目:国家自然科学基金(62272243)

This work was supported by the National Natural Science Foundation of China(62272243).

通信作者:王海艳(wanghy@njupt.edu)

中的一些方法对 SFC 数据进行分析或特征提取,通过统计学或者传统机器学习的模型来预测 VNF 资源需求。主流的方法是依据流经每个 VNF 的网络流量随时间的变化或从 VNF 网络拓扑结构中构建预测 VNF 资源需求的模型。但是,使用机器学习方法预测的准确度往往受研究者特征工程构建的影响,而且特征工程的步骤十分繁琐。为了降低特征工程构造的繁琐性和主观性带来的影响,研究者们使用深度学习技术对 VNF 资源进行预测。文献[2]根据 VNF 配置文件对 VNF 网络负载特征进行选择,但是没有考虑到输入不同特征会有不同权重,权重越大对预测结果的影响越大。由于 VNF 配置文件数据集包含执行环境信息、VNF 处理信息等具有结构化特性的数据特征,因此显式地建模 VNF 特征之间的交互关系,充分捕获不同 VNF 特征之间的非线性关系,有助于提高 VNF 资源需求预测的准确性。文献[3]依据 VNF 组件的拓扑结构,使用图神经网络构建预测 VNF 资源需求的模型。文献[4]仅利用 VNF 配置历史数据,没有考虑 VNF 特征之间的交互对预测结果的影响。然而,这类方法仍然存在一些问题:

1) 以往的研究对于 VNF 配置文件相关网络负载特征的权重未做区别,将所有 VNF 相关特征对预测结果的影响都看作相同;

2) 由于 VNF 配置文件数据集具有结构化特性,构建 VNF 资源预测方法时未考虑特征交互。

为解决以上问题,本文提出了基于特征权重感知的 VNF 资源需求预测方法 (Feature Weight Perception with ECANet, FWP-ECANet)。FWP-ECANet 方法中,使用 ECANet 模块学习 VNF 特征向量的权重。ECANet 是一种拥有轻量级通道注意力机制的卷积神经网络,进行局部跨通道交互且自适应确定卷积核大小,能够降低模型复杂度并且提高性能。将通过 ECANet 网络得到的 VNF 特征向量权重与原始的 VNF 特征向量进行乘积操作,以此来减少无用特征对模型预测结果的消极影响。另外,由于 VNF 配置文件数据集具有结构化特性,构建 VNF 资源预测的重点就是以加强特征交互的方式挖掘特征间深层的相互关系,增强网络负载特征与 VNF 性能特征之间的交互能力,提高模型预测精度,从而提高 VNF 动态预测资源分配的准确度。本文的工作如下:

1) 使用 ECANet 网络动态学习嵌入特征的权重,得到带有权重的 VNF 特征嵌入向量。

2) 提出深度特征交互网络 (DeepFeature-Interaction Network, DIN) 挖掘网络负载特征与 VNF 性能特征之间的特征交互,丰富原有特征的表达内容,并提出了一种新的 VNF 动态资源预测方法。

3) 在两个真实数据集 Nginx VNF 和 Squid VNF 上将所提方法与基线对比,并对结果进行分析,验证了所提方法的有效性 & 精确性。

2 相关工作

2.1 传统的 VNF 资源分配方法

以往的 VNF 部署算法大多使用固定的资源对每个 VNF 进行实例化^[5-7]。当网络流量变化时,传统方法利用函数对

VNF 性能和资源之间的关系进行简单建模。在文献[8-9]中,将 VNF 性能和资源之间的关系建模为简单的线性函数关系。为了描述 VNF 性能和所需资源之间的非线性关系,文献[10]中使用了分段线性函数。但是对于高度非线性的函数,使用分段线性函数来近似代替会变得非常不准确。文献[11]使用数据包长度、流量数据率和流量状态(假设周期固定流量)来建模 VNF 性能和资源需求的关系,但需要预先知道网络状态等先验知识。以上方法表明 VNF 性能和资源需求的非线性关系并不能用函数建模,因此有学者提出使用机器学习方法来预测 VNF 实例所需资源。

2.2 基于机器学习的 VNF 资源预测

文献[12]使用 LSTM 和 Attention 机制对 SFC 序列数据建模,预测 VNF 资源需求。文献[13]中使用机器学习方法构建 VNF 资源需求预测模型,预测的准确度往往受研究者的特征工程构建的影响,而且特征工程的步骤十分繁琐。为了降低特征工程构造的繁琐性和主观性带来的影响,研究者们使用深度学习技术对 VNF 资源进行预测。文献[14]通过考虑预算约束或容量约束,解决了 VNF 节点部署和容量分配问题。在机器学习或者统计学的方法中,特征工程的构建和算法模型的选取非常重要,而特征工程的构建又非常繁琐。文献[15]使用机器学习对流量特征建模,得到 VNF 的 CPU 消耗特征,以此来预测 VNF 资源需求。文献[16]使用 Sequence-to-Sequence 范例以及卷积长短期记忆,来解决网络边缘多种流量特征复杂的问题。以上方法表明,在 VNF 的特征提取和表示上,基于机器学习的方法比传统学习的方法更加简便和灵活。

2.3 ECANet 模块

受人类视觉注意力运行机制的影响,一些研究者提出了注意力机制^[17]。注意力机制在多个领域都有应用,但一般以权重的形式存在。例如在机器翻译、语音识别智能应用中,通过给不同的词赋予不同的权重,使得语言处理更富有针对性。ECANet^[18]是一种具有轻量级通道注意力机制的卷积神经网络,它在 SENet^[19]网络的基础上避免了降维并实现了跨通道交互,并利用 ECANet 模块进行局部跨通道交互且自适应确定卷积核大小,能够降低模型复杂度并提高性能。文献[20]将注意力机制 ECANet 嵌入到 U-Net 的编码阶段,以提高模型的语义特征能力,从而提高绝缘子检测的准确性。文献[21-22]使用自注意模块学习深度融合特征各时间步的权重,为不同子区域的特征赋予不同的权重。文献[23]基于高度递归注意、宽度递归注意以及通道递归注意力 3 个方面计算特征权重,最后使用权重融合注意的方法,提高了模型的预测精度。上述工作使用 ECANet,通过局部跨通道连接,在不压缩特征通道维度的前提下,降低了模型的复杂度,在相应的特征权重学习任务中达到了良好的效果。

3 FWP-ECANet 方法

本文利用机器学习建模和预测 VNF 资源需求,并提出了 FWP-ECANet 方法。FWP-ECANet 框架如图 1 所示,主要包括 VNF 特征表示模块、ECANet 特征权重感知模块、特征交互融合模块以及预测输出模块。

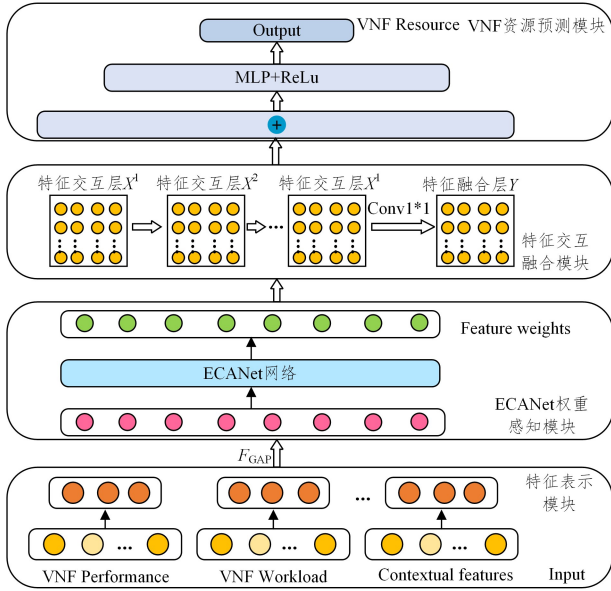


图1 FWP-ECANet资源预测模型图

Fig. 1 Overview architecture of the proposed FWP-ECANet model

3.1 特征表示模块

嵌入层:由于独热编码在数据量比较大、特征比较多的情况下得到的 VNF 特征过于稀疏,不利于神经网络学习,因此我们使用嵌入向量层,将独热编码得到的高维稀疏向量变成低维稠密向量。用一个低维稠密向量来表示 VNF 特征,公式如下:

$$e_i = W_i x_i \quad (1)$$

其中, W_i 是特征 i 的嵌入矩阵, x_i 是独热编码的特征向量, e_i 是低维稠密向量,构成了 FWP-ECANet 模型的嵌入层。最终将低维稠密向量表示成:

$$E = (e_1, e_2, e_3, \dots, e_m) \quad (2)$$

3.2 ECANet 特征权重感知模块

受到计算机视觉领域中 ECANet 网络的影响^[22], FWP-ECANet 方法中使用了 ECANet 特征权重表示模块,该模块可以使 VNF 资源预测模型对不同特征重要程度进行区分。使用 ECANet 网络层得到 VNF 特征嵌入向量的权重大小,以此来区分 VNF 不同特征的重要性,削弱对 VNF 资源预测任务影响较小的特征影响,从而对 VNF 特征重要性做出区分。FWP-ECANet 框架图中的 ECANet 网络层的结构如图 1 中间部分所示。首先,采用平均值方法将式(2)得到的 VNF 特征嵌入向量层的向量进行池化。它的嵌入向量 e_i 表示为 $[e_{i1}, e_{i2}, e_{i3}, \dots, e_{ik}]$, 则其平均值池化方法计算公式如下:

$$e_i' = T(e_i) = \frac{1}{k} \sum_{d=1}^k e_{id} \quad (3)$$

其中, $i \in [1, 2, 3, \dots, l]$, e_i 表示第 i 个特征域的 VNF 特征嵌入向量, k 表示 VNF 特征嵌入向量的维度数。由于 SENet 中采用的降维操作会对通道注意力的预测产生负面效果,因此 FWP-ECANet 方法引入了 ECANet 模块。它使用一维卷积代替原来的两层全连接层,避免了降维操作,并且实现了跨通道交互。

由此,把上面得到的特征向量记为向量 $e' = [e'_{i1}, e'_{i2}, e'_{i3}, \dots, e'_{ik}]$, 采用一维卷积来获取它们之间的关系,公式如下:

$$w_e = \sigma(W_k e') \quad (4)$$

其中, σ 表示 Sigmoid 激活函数, W_k 是 ECANet 中计算通道注意力的参数矩阵。 σ 的计算公式如下:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (5)$$

W_k 的定义如下:

$$W_k = \begin{bmatrix} w^{1,1} & \dots & w^{1,k} & \dots & 0 \\ 0 & w^{2,2} & \dots & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & \dots & 0 & \dots & w^{l,c} \end{bmatrix}$$

它可以使用卷积核为 k 的 1 维卷积实现,所以特征权重记为:

$$w_e = \sigma(W_k e') \quad (6)$$

本文的实验中,根据模型参数的数量以及运算速度,将一维卷积核 k 设置为 3。最后,将得到的权重值与原来的 VNF 特征嵌入向量相乘,计算得到带有权重的 VNF 特征嵌入向量,并将它记作向量 V , 即 $[v_1, v_2, v_3, \dots, v_l]$ 。其计算公式如下:

$$\begin{aligned} V &= T_{\text{update}}(W_e, E) \\ &= [w_{e_1} \cdot e_1, w_{e_2} \cdot e_2, \dots, w_{e_l} \cdot e_l] \\ &= [v_1, v_2, v_3, \dots, v_l] \end{aligned} \quad (7)$$

其中, E 表示原有的 VNF 特征嵌入向量, e_i 表示第 i 个 VNF 特征的嵌入向量, w_i 表示嵌入向量的权重值, v_i 表示 VNF 特征嵌入向量与对应权重值相乘的结果向量。

3.3 特征交互融合模块

该模块分为两个层:特征交互层和特征融合层。经过 ECANet 网络层, VNF 特征嵌入向量被转换为带有相应权重值的嵌入向量。由于每个 VNF 实例所分配的资源量不仅与 VNF 网络负载特征相关,而且与 VNF 性能特征之间也存在关联,因此特征交互层通过矩阵乘法来捕捉 VNF 网络负载特征和 VNF 性能特征之间的交互特征。使用矩阵乘法可以实现 VNF 网络负载特征向量之间的内部交互。该方法可以实现不同类型的特征之间的交互建模,从而增加特征的代表能力。

1) 利用矩阵乘法进行特征交互

将 ECANet 层得到的嵌入向量 X^0 记为原始特征图 $W^l \in R^{m \times D}$, 其为参数矩阵。将二阶特征交互的结果表示为原始特征和参数矩阵的乘积。VNF 特征向量二阶交互的结果向量可以表示如下:

$$X^l = X^0 W^l X^0 \quad (8)$$

其中, $X^l \in R^{m \times D}$ 是 VNF 特征向量二阶交互的结果。

$$X^0 W = \begin{bmatrix} x_{11} & x_{12} & x_{13} \\ x_{21} & x_{22} & x_{23} \end{bmatrix} = \begin{bmatrix} i_{11} & i_{12} \\ i_{21} & i_{22} \end{bmatrix} = I \quad (9)$$

上述公式得到的矩阵元素表示 VNF 原始特征向量的线性组合。为了对 VNF 网络负载特征的高阶特征建模,在二阶特征交互的基础上引入残差网络,这不会产生额外的参数,也不会增加计算复杂度。高阶特征交互的一般形式为:

$$X^{l+1} = X^0 W^{l+1} X^l + b^l + X^l \quad (10)$$

其中, b 为偏置, W^{l+1} 为参数矩阵, X^{l+1} 为 $l+1$ 层网络的输出, l 为高阶特征交互的层数。

2) 特征融合层

在 FWP-ECANet 方法中,特征融合层使用 1×1 的卷积神经网络(Convolutional Neural Network, CNN)来实现。对于特征交互层得到的特征向量,通过 1×1 的卷积核保留其高阶 VNF 特征之间的非线性关系,输出形式为:

$$Y = \delta(W_{\text{conv}} \otimes X + b) \quad (11)$$

其中, $X = \text{Concat}(X^1, X^2, X^3, \dots, X^l)$, $X \in R^{m \times D \times l}$, L 为卷积核参数矩阵, b 为偏置, $X \in R^{m \times D \times l}$, δ 为 Relu 激活函数。将 Y 变形为 $P = [p^1, p^2, p^3, \dots, p^l, p^{l+1}]$ 作为特征交互后的特征。

3.4 预测层模块

该部分主要由全连接网络以及预测层组成。经过特征交互层和特征融合层之后,已经提取到 VNF 相关网络负载特征与 VNF 性能特征之间的交互。但是 VNF 数据特征具有多样性,只考虑低级交互会影响预测结果。为了提高模型预测精度,需要考虑高阶的 VNF 特征交互,因此使用全连接层去捕捉高阶非线性特征交互,将 ECANet 权重感知模块的输出特征 $V = (v_1, v_2, v_3, \dots, v_l)$ 输入该层。全连接层表示如下:

$$z^l = \sigma(W^l + z^{l-1} + b^l) \quad (12)$$

其中, l 为神经网络的层数; σ 为激活函数 ReLu; W^l , z^l 和 b^l 分别为网络的参数矩阵、网络第 l 层的输出值,以及每一层的偏置。

预测层:该层将全连接层的输出与特征交互融合模块的输出结果进行拼接并转为最终的 VNF 资源预测值。模型的最终预测结果如下:

$$y = g^T z^l + h^T p + b \quad (13)$$

其中, h^T 和 g^T 表示权重, b 表示偏置。

3.5 损失函数

考虑到 VNF 资源预测属于连续数值预测的问题,选取均方损失 (Mean Square Error, MSE) 作为损失函数。

$$MSE = \frac{1}{x} \sum_{i=1}^x (y_i - \tilde{y}_i) \quad (14)$$

其中, x 代表训练集。为了优化目标函数,使用小批量梯度下降法将样本分成 m 个小批次,加快训练速度。

4 实验及结果分析

4.1 数据集介绍与评价指标

为了验证基于特征感知的 VNF 资源需求预测方法的有效性,利用 SDNZoo^[24] 中发布的 8 个 VNF 基准数据集进行实验,如表 1 所列。该数据集主要通过分析指定的 VNF,对其分配不同的资源并记录相应的 VNF 性能,得到 VNF 配置文件。我们主要在 Nginx VNF 和 Squid VNF 数据集上进行实验。

表 1 SDNZoo 中发布的 8 个 VNF 基准数据集概述

Table 1 Overview of eight VNF benchmark datasets published in SDNZoo

名称	类别	VNF	测试配置	实验序列特征
Sec1	IDS	Suricata	80	280
Sec2	网络安全	Snort2.9	80	280
Sec3	网络安全	Snort3.0	80	281
Web1	负载均衡器	Nginx	80	268
Web2	HAProxy	80	80	43
Web3	代理服务器	Squid	80	268
IoT1	MQTT 服务器	Mosquitto	80	275
IoT2	EMQX	80	20	275

本文选取均方根误差 (Root Mean Square Error, RMSE) 和修正 R^2 决定系数作为 FWP-ECANet 模型的评价指标。

1) 均方根误差

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \tilde{y}_i)^2} \quad (15)$$

该指标表示估计值与真实值的差异,其中 m 表示样本数量, y_i 表示真实值, \tilde{y}_i 表示预测值。

2) 修正 R^2 决定系数

普通 R^2 是利用均值作为误差基准,修正后的 R^2 能够对模型添加的非显著变量设置惩罚项,不断添加变量并不会使模型拟合度上升。本文利用修正后的 R^2 作为评价指标,计算公式如下:

$$R^2 = 1 - \frac{(1 - R^2)(n - 1)}{n - p - 1} \quad (16)$$

其中, n 为样本数量, p 为特征数量。

4.2 baseline 选取与参数设置

为了验证 FWP-ECANet 方法的有效性,将其与以下基于不同回归算法训练得到的 4 种预测模型进行比较。

Logistic Regression: 只能建模 VNF 特征和目标值之间的线性依赖关系,但其具有简单性,线性模型易于快速训练,只需调整很少的超参数。

Ridge: 线性回归的正则化版本,尤其适用于多个相关特征(如以字节/秒和数据包/秒为单位的流量负载)关系的建模,但是线性回归不能很好地逼近常见的非线性 VNF 数据。

DTree: 将数据集分成越来越小的子集来执行回归。即使在非标度数据上,决策树也能很好地工作。由于决策树可以可视化,因此预测结果很容易解释。

CAT-LSTM^[25]: 使用注意力机制获取 SFC 中 VNF 之间的连接依赖性来预测 VNF 的未来资源需求。

实验环境为: CPU Intel (R) Core (T) i9-9980XE @ 3.00 GHz, 128GB 内存和两块 Titan XP 显卡。使用科学计算库 NumPy 和 Pandas 进行数据处理,并使用 TensorFlow 和 Pytorch 实现算法。对于超参数,应用网格搜索来为每个任务找到最佳设置。其中,学习速率以 0.00001, 0.0001, 0.001, 0.005, 0.01, 0.05 搜索,批处理大小以 32, 64, 128, 256, 512 搜索,优化方法包括 Adam 和 SGD。学习率设置为 0.0001, 优化方法设置为 Adam。

4.3 实验结果及分析

1) 实验结果与比较

表 2 列出了在 Nginx VNF 和 Squid VNF 两个数据集上, FWP-ECANet 模型与基准方法预测 VNF 的 CPU 时间需求结果。可以看出, FWP-ECANet 模型在两个数据集上两个评价指标均获得了较好的结果。与传统机器学习模型相比, FWP-ECANet 模型减少了手工建立特征工程的繁琐过程和特征工程步骤对模型表现的影响。其次, CAT-LSTM^[25] 方法中使用了注意力机制对 VNF 特征之间的关系建模, 与该方法相比, ECANet 特征权重感知方法对 VNF 特征重要性进行了区分, 在 Nginx VNF 和 Squid VNF 数据集上 RESM 分别提升了 20.83% 和 18.17%, 另一个评价指标 R^2 在两个数据集上分别提升了 28.43% 和 29.4%。这是因为本文使用的 ECANet 网络是一种轻量级模块, 可以使得复杂注意力模块

获得性能提升,同时降低了模型的复杂性。此外,我们还加强了特征交互的方式,挖掘特征间深层的相互关系,从而进一步提高模型预测精度。

表 2 数据集 Nginx VNF dataset 和 Squid VNF 上的实验结果

Methods	Nginx VNF		Squid VNF	
	RMSE	R^2	RMSE	R^2
Logistic-Regression	0.2793	0.7663	0.2724	0.8143
Ridge	0.2697	0.7894	0.2614	0.8354
DTree	0.1326	0.8681	0.1317	0.8726
CAT-LSTM ^[25]	0.1296	0.8827	0.1237	0.8843
FWP-ECANet	0.1026	0.9078	0.1014	0.9103

2) 模型变体分析

为了验证 ECANet 特征权重感知模块和特征交互融合模块的有效性,设计了 4 种变体:(1)变体 DIN-NR-E 不考虑 ECANet 模块,VNF 特征重要性未进行区分;(2)变体 DIN-NR-F 不考虑特征交互融合,未挖掘特征间的交互关系;(3)DIN 同时使用 ECANet 模块对 VNF 特征重要性进行区分,考虑 VNF 特征之间的交互;(4)变体 DIN-NR-FE 既不考虑 ECANet 模块,也不考虑特征交互融合模块。图 2 和图 3 分别显示了不同变体在不同数据集上的结果。

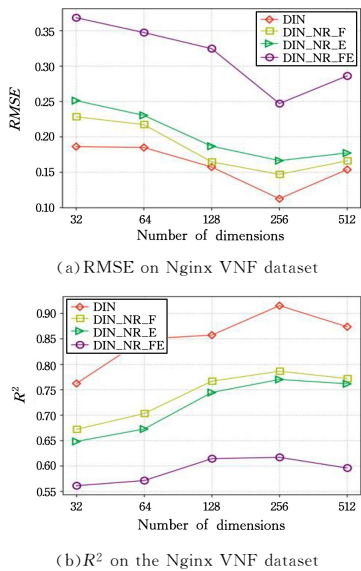



图 2 Nginx VNF 数据集上的预测结果

Fig. 2 Prediction results on Nginx VNF dataset

从图 2 和图 3 中可以看出,将 VNF 资源预测模型中的 ECANet 模块移除时,模型性能下降明显,这验证了 ECANet 权重感知模块设计的有效性,因为 ECANet 网络层能够学习 VNF 特征的不同权重,削弱无用特征的影响,增加与预测结果相关的特征权重。当不考虑特征交互融合,未挖掘特征间交互关系时,实验结果稍差,这说明对 VNF 不同特征之间的交互关系进行建模,从而丰富 VNF 特征的最终表示,是合理的。当实验中同时移除 ECANet 特征权重感知模块与特征交互融合模块时,实验预测结果最差,这说明动态学习特征权重能削弱无用特征对预测结果的影响,同时增加特征交互可以有效获取 VNF 配置文件中非结构化数据特征的交互关系,丰富 VNF 特征表示。



(a) RESM on Squid VNF dataset


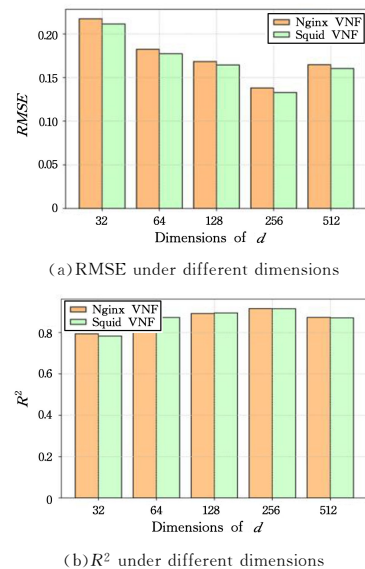
(b) R^2 on the Squid VNF dataset

图 3 Squid VNF 数据集上的预测结果

Fig. 3 Prediction results on Squid VNF dataset

3) 模型参数分析

图 4 展示了不同的嵌入维度对 VNF 资源预测效果的影响。在其他超参数保持不变的情况下,使用 32 到 512 的嵌入维度进行比较实验。从实验结果可以明显看出,模型的性能不会随着维度的增加而增加。更大的隐藏维度并不一定会带来更好的模型性能,这主要是由于过拟合导致的。从图中可以看出嵌入维度在 256 时模型的表现最好,所以最终选择的嵌入维度为 256。

图 4 特征维度 d 对 VNF 资源预测结果的影响Fig. 4 Influence of feature dimension d on VNF resource prediction results

结束语 本文提出了一种基于特征权重感知的 VNF 资源需求预测方法。该方法通过使用 ECANet 网络层获取 VNF 嵌入特征的权重,以此来减少无用特征对模型预测结果的消极影响。此外,为了丰富原有特征的表达内容,挖掘了网络负载特征与 VNF 性能特征之间的特征交互关系,使得预测结果更加准确。目前,FWP-ECANet 主要考虑使用 VNF

配置文件中的 VNF 特征进行 VNF 资源需求预测。在未来工作中,针对网络状态动态变化的挑战,我们将考虑在 VNF 实际部署过程中研究如何自适应地调整 VNF 的部署数量,从而更好地优化网络性能,提高服务质量。

参考文献

- [1] HERRERA J G, BOTERO J F. Resource allocation in NFV: A comprehensive survey[J]. *IEEE Transactions on Network and Service Management*, 2016, 13(3): 518-532.
- [2] WU J W, JIANG L Y, LIU X J. VNF resource demand prediction method based on feature selection [J]. *Computer Application Research*, 2021, 38(10): 3131-3136, 3142.
- [3] KAFAFY M, FAHMY Y. Joint coding bit-rate and activity rate optimisation in wireless visual sensor networks[J]. *IET Communications*, 2020, 14(19): 3428-3439.
- [4] LI X, TAN Y, MAREELS I, et al. Compatible formation set for uavs with visual sensing constraint[C]//2018 Annual American Control Conference(ACC). IEEE, 2018: 2497-2502.
- [5] DIEYE M, AHVAR S, SAHOO J, et al. CPVNF: Cost-efficient proactive VNF placement and chaining for value-added services in content delivery networks[J]. *IEEE Transactions on Network and Service Management*, 2018, 15(2): 774-786.
- [6] GAU R H. Optimal traffic engineering and placement of virtual machines in SDNs with service chaining[C]//2017 IEEE Conference on Network Softwarization(NetSoft). IEEE, 2017: 1-9.
- [7] DRÄXLER S, SCHNEIDER S, KARL H. Scaling and placing bi-directional services with stateful virtual and physical network functions[C]//2018 4th IEEE Conference on Network Softwarization and Workshops(NetSoft). IEEE, 2018: 123-131.
- [8] DRAXLER S, KARL H, MANN Z A. Joint optimization of scaling and placement of virtual network services[C]//2017 17th IEEE/ACM International Symposium on Cluster, Cloud and Grid Computing(CCGRID). IEEE, 2017: 365-370.
- [9] DRÄXLER S, KARL H. SPRING: scaling, placement, and routing of heterogeneous services with flexible structures[C]//2019 IEEE Conference on Network Softwarization (NetSoft). IEEE, 2019: 115-123.
- [10] ERAMO V, MIUCCI E, AMMAR M, et al. An approach for service function chain routing and virtual function network instance migration in network function virtualization architectures [J]. *IEEE/ACM Transactions on Networking*, 2017, 25(4): 2008-2025.
- [11] KIM H G, LEE D Y, JEONG S Y, et al. Machine learning-based method for prediction of virtual network function resource demands[C]//2019 IEEE Conference on Network Softwarization (NetSoft). IEEE, 2019: 405-413.
- [12] SCHNEIDER S, SATHEESCHANDRAN N P, PEUSTER M, et al. Machine learning for dynamic resource allocation in network function virtualization[C]//2020 6th IEEE Conference on Network Softwarization(NetSoft). IEEE, 2020: 122-130.
- [13] COHEN R, LEWIN-EYTAN L, NAOR J S, et al. Near optimal placement of virtual network functions[C]//2015 IEEE Conference on Computer Communications(INFOCOM). IEEE, 2015: 1346-1354.
- [14] SALLAM G, JI B. Joint placement and allocation of virtual network functions with budget and capacity constraints[C]//IEEE INFOCOM 2019-IEEE Conference on Computer Communications. IEEE, 2019: 523-531.
- [15] NTALAMPIRAS S, FIORE M. Forecasting mobile service demands for anticipatory MEC[C]//2018 IEEE 19th International Symposium on "A World of Wireless, Mobile and Multimedia Networks"(WoWMoM). IEEE, 2018: 14-19.
- [16] MESTRES A, ALARCÓN E, CABELLOS A. A machine learning-based approach for virtual network function modeling [C]//2018 IEEE Wireless Communications and Networking Conference Workshops(WCNCW). IEEE, 2018: 237-242.
- [17] CHAUDHARI S, MITHAL V, POLATKAN G, et al. An attentive survey of attention models[J]. *ACM Transactions on Intelligent Systems and Technology(TIST)*, 2021, 12(5): 1-32.
- [18] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: Efficient Channel Attention for Deep Convolutional Neural Networks [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). IEEE, 2020.
- [19] HU J, SHEN L, SUN G. squeeze-and-excitation networks [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018: 7132-7141.
- [20] HAN G, ZHANG M, WU W, et al. Improved U-Net based insulator image segmentation method based on attention mechanism [J]. *Energy Reports*, 2021, 7: 210-217.
- [21] ZHOU C, LI D, WANG P, et al. ACR-Net: Attention Integrated and Cross-Spatial Feature Fused Rotation Network for Tubular Solder Joint Detection[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 1-12.
- [22] QIN W, TANG J, LAO S. DeepFR: A trajectory prediction model based on deep feature representation [J]. *Information Sciences*, 2022, 604: 226-248.
- [23] JIANG B, LU Y, LU G, et al. Real noise image adjustment networks for saliency-aware stylistic color retouch[J]. *Knowledge-Based Systems*, 2022, 242: 108317.
- [24] VAN R S, TAVERNIER W, COLLE D, et al. Profile-based resource allocation for virtualized network functions[J]. *IEEE Transactions on Network and Service Management*, 2019, 16(4): 1374-1388.
- [25] KIM H G, JEONG S Y, LEE D Y, et al. A deep learning approach to vnf resource prediction using correlation between vnfs [C]//2019 IEEE Conference on Network Softwarization(NetSoft). IEEE, 2019: 444-449.



WANG Huiqin, born in 1996, postgraduate. Her main research interests include service computing and deep learning.



WANG Haiyan, born in 1974, Ph.D., professor, is a senior member of China Computer Federation. Her main research interests include service computing, edge computing and big data intelligent processing technology.