



基于机器学习的无线网络流量预测与增长潜力评估

Traffic Prediction and Growth Potential Evaluation in Wireless Network Based on Machine Learning

摘要: 提出一个基于机器学习的无线网络流量预测及流量增长潜力评估方案。该方案分析蜂窝网络中的实际业务流量数据在时间维度上的变化规律,并借助高斯过程的机器学习方法来预测业务变化趋势,从短期角度为运营商的网络优化部署提供指导。基于极限梯度提升(XG-Boost)机器学习框架,建立网络中其他运营数据与业务流量的多维映射关系,应用改进的量子粒子群算法进一步寻找蜂窝小区所能承载的流量上限,从长期角度为网络优化部署提供指导,提升网络流量水平、释放流量增长潜力。

关键词: 机器学习;移动网络数据分析;流量预测;流量增长潜力评估

Abstract: A wireless network traffic prediction and traffic growth potential evaluation scheme based on machine learning is proposed. Based on the actual traffic data in the cellular network, this scheme analyzes the change rule in the time dimension and uses the machine learning method of Gaussian process to predict the trend of traffic, which provides guidance for the network optimization deployment of operators in the short term. Based on the eXtreme Gradient Boosting (XGBoost) machine learning framework, the multi-dimensional mapping relationship between other operation data and traffic in the network is established, and the revised quantum particle swarm optimization algorithm is applied to further find the upper limit of traffic that the cellular cell can carry, so as to provide guidance for network optimization deployment from a long-term perspective, improve the network traffic level, and release the traffic growth potential.

Keywords: machine learning; mobile network data analysis; traffic prediction; traffic growth potential evaluation

邢旭东/XING Xudong¹

高晖/GAO Hui¹

顾军/GU Jun²

(1. 北京邮电大学可信分布式计算与服务教育部重点实验室,中国 北京 100876;
2. 中兴通讯股份有限公司,中国 深圳 518057)
(1. Key Laboratory of Trustworthy Distributed Computing and Service, Beijing University of Posts and Telecommunications, Ministry of Education, Beijing 100876, China;
2. ZTE Corporation, Shenzhen 518057, China)

DOI: 10.12142/ZTETJ.202102013

网络出版地址: <https://kns.cnki.net/kcms/detail/34.1228.TN.20210402.1133.006.html>

网络出版日期: 2021-04-02

收稿日期: 2021-02-08

随着无线设备数量的飞速增长,移动用户对更高性能无线服务的需求正在逐年上升。在这样的背景下,5G 应运而生。更密集的组网、更快的速率、更低的时延和更可靠的移动性保障是 5G 的特点^[1]。随着 5G 商业化进程的逐步推进,物联网、云计算、大数据等领域将呈现裂变式发展态势,逐步形成 5G 产业生态,为行

业升级提供强劲动力。

近年来,在无线网络流量预测和流量增长潜力挖掘等领域中,基于人工智能和机器学习等方法的研究引起了学术界和产业界的极大关注^[2]。无线网络流量预测方法是指,将网络流量随时间的变化视作一个时间序列,根据过往的流量变化规律来预测未来的变化趋势,并将预测流量与当前流量之间的差异作为流量增长潜力的量化结果^[3-4]。典型的时间序列预测方法包括差分整合移动平均自

回归模型(ARIMA)^[5]、季节性 ARIMA^[6]等。在对规律不明显、构成成分复杂的时间序列进行预测时,传统方法的预测性能已经明显下降。因此,人们需要寻找新的方法来应对复杂的流量模式。得益于硬件计算能力的极大提升,当前业界也在尝试使用深度学习模型来预测网络流量。例如,文献^[7]首先对流量数据做栅格化预处理,然后以栅格为单元,利用堆叠自编码器(SAE)提取栅格流量在不同历史时刻的特征,并利用这些特

基金项目:中兴通讯产学研合作基金(2018ZTE 01-01-06)

征训练长短期记忆(LSTM)网络,最终实现对栅格单元的网络流量预测。然而,自定义栅格忽视了单个蜂窝小区的流量浮动,这导致深度学习模型容易出现过拟合现象。鉴于此,本文提出一种基于机器学习的可解释性强、泛化性能好的流量预测方法,从短期角度指导网络优化部署。

长期来看,对网络流量增长潜力的评估能够有效解决网络的优化部署问题。蜂窝网络流量的波动意味着小区的负载也会随之波动。如果小区的历史指标经常处于高负载状态,就说明其覆盖范围内的数据传输需求高于网络本身的负载水平。这意味着该小区具有较大的运营收益潜力。为此,运营商通常会实施网络扩容,在满足用户需求的同时扩大收益。反之,如果网络的业务量没有达到相对较高的收益水平,增长受到抑制,则需要收集多种指标数据,分析具体原因,并制定相应的优化策略,以提升网络流量,释放流量增长潜力^[8]。因此,在充分挖掘大量蜂窝网络业务数据的基础上,本文设计一种基于机器学习的获取无线网络高价值状态的通用方法,从长期角度释放网络流量增长潜力。同时,本文以现网中的实际业务数据为基础,从小区流量的短期变化趋势与长期增长潜力两个方面考虑,围绕蜂窝网络流量指标来设计解决方案。在小区流量短期预测方面,本文提出基于高斯过程(GP)的流量预测方案。基于高斯过程对物理资源块(PRB)利用率预测的研究^[9],本文进一步综合考虑分组数据汇聚协议(PDCP)服务数据单元(SDU)下行流量、PRB利用率等指标,将各指标的历史时刻流量作为输入,采用高斯过程核函数分别对其短期、长期变化趋势等因素进行拟合建模,并将模型预测的流量变化趋势作

为输出。在小区流量长期增长潜力评估方面,本文首先分析其他网络指标对流量指标的影响情况,即建立其他指标与流量指标之间的映射关系;其次,调整其他指标的取值使流量指标最大化,即基于该映射关系挖掘蜂窝网络的高价值状态。

1 流量预测及增长潜力评估的问题描述

本节分别对流量预测和流量增长潜力评估两部分内容进行数学描述,首先将其抽象为数学问题,然后分析相应的难点并提出解决思路。

1.1 基于高斯过程的业务流量预测

根据无线网络历史时刻的流量数据来预测未来时刻的流量,可以为网络优化提供相应的指导。基于高斯过程的流量预测的数学表达式如公式(1)所示:

$$\begin{aligned} \min L(y_{t+1}, f(Y)) \\ \text{s.t. } Y = (y_1, y_2, \dots, y_t)^T, \end{aligned} \quad (1)$$

其中, $y_{t+1} \in \mathbf{R}$ 代表未来时刻流量值, $Y = (y_1, y_2, \dots, y_t)^T \in \mathbf{R}^{t \times 1}$ 代表历史时刻流量。我们定义 $\hat{y}_{t+1} = f(Y)$ 代表基于历史时刻预测的 $t+1$ 时刻的流量。 $L(\bullet)$ 代表损失函数,用以衡量真实值与预测值之间的差距,并反映预测精度。均方误差等函数可以作为损失函数使用。流量预测的难点在于如何寻找合适的 $f(\bullet)$ 。因此,本文提出基于高斯过程的流量预测方案,用以捕捉日、周、月流量周期模式,进而准确预测业务流量。

1.2 基于XGBoost方法的多元流量增长潜力评估

实现流量增长潜力评估需要应对两个主要挑战:(1)建立网络流量

指标与其他业务指标之间的多元映射关系,以量化不同指标对网络流量的影响;(2)基于多元映射关系来挖掘高价值状态信息,即当多元映射关系返回的流量达到最大时,需要明确其他指标的取值状态。

假设存在一个总数据条目为 N 的数据集 $S = \{(\mathbf{x}^{(1)}, y^{(1)}), \dots, (\mathbf{x}^{(i)}, y^{(i)}), \dots, (\mathbf{x}^{(N)}, y^{(N)})\}$, 其中, $\mathbf{x}^{(i)} = (x_1^{(i)}, \dots, x_j^{(i)}, \dots, x_D^{(i)})$ 代表其他 D 个网络指标组成的特征向量, $y^{(i)}$ 代表下行蜂窝网络流量的标量值。有监督学习实际上可以解决优化问题 $\min \sum_{i=1}^N J(y^{(i)}, F(\mathbf{x}^{(i)}))$ 。其中, $F(\cdot)$ 是网络业务指标与下行流量指标之间的映射关系,即机器学习模型; $J(\cdot)$ 是优化目标函数,它由衡量真实流量值 $y^{(i)}$ 和模型输出 $F(\mathbf{x}^{(i)})$ 之间的误差与模型 $F(\cdot)$ 的复杂度叠加组成。模型复杂度越高,越容易出现过拟合现象,因此,优化的目标是同时最小化模型的推测误差和模型的复杂度。

在给定机器学习模型 $F(\cdot)$ 的前提下,挖掘网络高价值状态相当于解决优化问题 $\max F(\mathbf{x})$ 。其中, $\mathbf{x}$ 表示一组包含各个网络指标取值的特征向量。

2 流量预测及增长潜力评估方案

2.1 基于高斯过程的流量预测

高斯回归过程作为后深度学习时代的统计建模工具,天然地拥有数据驱动和清晰的模型解释性等特点。因此,本文基于高斯回归过程设计一种无线流量预测方法。

针对流量预测,我们将已有的历史时刻 PDCP SDU 流量数据和 PRB 利用率数据划分为训练数据集和测试数据集。在训练数据集中,输入为前

t 时刻的流量(或PRB利用率),即 $Y = (Y(1), Y(2), \dots, Y(k)) \in \mathbf{R}^{t \times k}$ 。其中, $Y(k) = (y_1^k, y_2^k, \dots, y_t^k)^T \in \mathbf{R}^{t \times 1}$, t 代表时间, k 代表训练样本数。相应的标签则为下一时刻的流量 $Y_{t+1} = (y_{t+1}^1, y_{t+1}^2, \dots, y_{t+1}^k) \in \mathbf{R}^{1 \times k}$ 。我们的目标是,当给定新的测试数据集的前 t 时刻流量 $Y^* = (y_1^*, y_2^*, \dots, y_t^*) \in \mathbf{R}^{t \times 1}$ 时,能够求解出其下一时刻的流量值 $y_{t+1}^* \in \mathbf{R}$,其中 $*$ 代表测试数据集。高斯过程存在随机变量的集合,这个集合中任意两个随机变量都服从联合高斯分布。高斯随机过程有两个核心参数:均值与协方差函数。针对高斯过程的机器学习方法,文献[9]假设训练集与测试集均服从联合高斯分布,那么有:

$$\begin{pmatrix} Y_{t+1} \\ Y_{t+1}^* \end{pmatrix} \sim N \left(\begin{pmatrix} m(Y) \\ m(Y^*) \end{pmatrix}, \begin{pmatrix} \Sigma(Y, Y) & \Sigma(Y, Y^*) \\ \Sigma(Y^*, Y) & \Sigma(Y^*, Y^*) \end{pmatrix} \right) \quad (2)$$

公式(2)中, $m(Y) = E[Y] = (E(y_1^1), E(y_1^2), \dots, E(y_1^k)) \in \mathbf{R}^{1 \times k}$, $\Sigma(Y, Y) \in \mathbf{R}^{k \times k}$ 为协方差矩阵, $\Sigma_{i,j} = \text{cov}(y_i^i, y_i^j)$ 为 $\Sigma(Y, Y)$ 的第 i 行、第 j 列元素值。

$$\begin{aligned} m(t) &= \begin{pmatrix} m(Y) \\ m(Y^*) \end{pmatrix}, \Sigma(t) = \\ &= \begin{pmatrix} \Sigma(Y, Y) & \Sigma(Y, Y^*) \\ \Sigma(Y^*, Y) & \Sigma(Y^*, Y^*) \end{pmatrix} \end{aligned} \quad (3)$$

公式(3)中, $t = (1, 2, \dots, t)$ 表示序列的时间索引, $m(t) \in \mathbf{R}^{1 \times (k+1)}$ 表示训练集与测试集的联合高斯分布的数学期望, $\Sigma(t) \in \mathbf{R}^{(k+1) \times (k+1)}$ 表示协方差。高斯过程由数学期望及协方差函数决定。一些具有特定形式的协方差函数称为核函数,如径向基核函数、

指数核函数、二次有理核函数等[9]。因此,求解流量集合高斯联合分布就是求解其数学期望及核函数。

在高斯过程中,我们需要选取合适的核函数,以捕获相应的流量周期模式。基于对流量数据的研究,我们将专家经验内嵌于高斯过程中,以有效提升算法精度。综合考虑无线通信中的日、周、月周期模式,以及动态偏差和残留噪声,我们提出一种新的核函数。该核函数是以下4个常用核函数之和,即 $\Sigma = \Sigma_1 + \Sigma_2 + \Sigma_3 + \Sigma_4$ 。

(1)长周期核。应用周期核函数来拟合PRB利用率以及PDCP SDU流量中的长周期模式,以表征长期趋势,例如月周期模式。该核函数的表达形式如公式(4)所示,其中 y_i, y_j 分别代表第 i, j 时刻的数据。 l_1 的值可以人为设定,以控制函数随时间变化的快慢。 λ_1 为周期长度,表示一个月中采集到的数据点数。

$$\Sigma_1 = \exp \left(-\frac{1}{l_1^2} \sin^2 \frac{\pi(y_i - y_j)}{\lambda_1} \right) \quad (4)$$

(2)短周期核。该核函数的表达形式与长周期核函数相同,如公式(5)所示。通过改变一些参数,该核函数可以拟合PRB利用率以及PDCP SDU流量中的短周期模式,即可以用于表征数据中的周周期和日周期趋势。

$$\Sigma_2 = \exp \left(-\frac{1}{l_2^2} \sin^2 \frac{\pi(y_i - y_j)}{\lambda_2} \right) \quad (5)$$

(3)有理式核。有理式核变化平滑,它不仅可以拟合数据中不规则变化的成分,还可以拟合PRB利用率以及PDCP SDU流量中的动态变化成分。该核函数的表达形式如公式(6)所示。其中, α, l_3 共同控制核函数随时间变化的快慢。

$$\Sigma_3 = \exp \left(1 + \frac{(y_i - y_j)^2}{2l_3^2} \right)^{-\alpha} \quad (6)$$

(4)噪声核函数。该核函数主要用于建模残留的噪声,其表达形式如公式(7)所示:

$$\Sigma_4 = \exp \left(-\frac{(y_i - y_j)^2}{2l_4^2} \right) \quad (7)$$

在配置完核函数之后,基于贝叶斯理论,我们可以通过最大化超参数的对数似然函数来求解高斯联合分布的数学期望及核函数[9],如公式(8)所示:

$$\begin{aligned} \log P(y_{t+1}^* | Y^*, m(t), \Sigma(t)) &= \\ &= -\frac{1}{2} \log |\Sigma(t)| - \frac{1}{2} (y_{t+1}^* - \\ &= m(t))^T \Sigma(t)^{-1} (y_{t+1}^* - m(t)) \end{aligned} \quad (8)$$

公式(8)的常用求解方法包括拟牛顿法、随机梯度下降法、共轭梯度法等。在获得高斯联合分布模型后,便可以实现对无线流量的预测。

2.2 基于XGBoost的多元流量潜力评估建模

为了量化网络中不同指标对流量增长潜力的长期联合影响,我们采用XGBoost框架来建立潜力评估模型。XGBoost的基本模型是决策树,它通过不断建立新的二叉树来拟合原有集成模型的输出与真实数据之间的残差,以逐步提升模型的拟合性能。建立多维流量潜力评估模型的目标是使一个目标分数最小化,具体描述过程如下:

假设需要建立 K 个基本模型,那么在建立第 t 个基本模型时,优化目标如公式(9)所示:

$$\min Obf^{(t)} = \sum_{i=1}^N \left[l(y^{(i)}, \hat{y}_{t-1}^{(i)} + f_t(x^{(i)})) + \sum_{k=1}^{t-1} \Omega(f_k) \right] \quad (9)$$

其中, $f(\cdot)$ 代表基本的决策树模型, $\mathbf{x}^{(i)}$ 表示训练集 $\mathbf{S}$ 中的样本特征(用户数、资源利用率等网络指标数据), $y^{(i)}$ 是特征 $\mathbf{x}^{(i)}$ 对应的网络流量数据。 $\hat{y}_{t-1}^{(i)} = \sum_{k=1}^{t-1} f_k(\mathbf{x}^{(i)})$ 表示由前 $t-1$ 个基本模型组成的集成模型的推断值。 $\Omega(f)$ 是模型的复杂程度, 它的定义如公式(10)所示^[10]:

$$\Omega(f) = \gamma T + \frac{\lambda}{2} \sum_{j=1}^T w_j, \quad (10)$$

其中, T 表示二叉树的叶子节点总数。叶子节点数越多, 叶子权重越大, 模型复杂程度越高。 γ, λ 为惩罚因子, 用于控制模型复杂度对目标函数的影响程度。 $\sum_{k=1}^{t-1} f_k(\cdot)$ 表示已经建好的前 $t-1$ 棵二叉树模型, $f_t(\cdot)$ 则是第 t 轮迭代中建立的新模型。根据文献[10]中对目标函数(9)的推导过程, 我们可以获得每一轮迭代所得到的二叉树模型的最优目标函数值 $Obj^{(i)}$ 和每个叶子节点最优叶子权重 w_j^* , 如公式(11)和(12)所示:

$$Obj^{(i)} = -\frac{1}{2} \sum_{j=1}^T \frac{G_j^2}{H_j + \lambda} + \gamma T, \quad (11)$$

$$w_j^* = -\frac{G_j}{H_j + \lambda}, \quad (12)$$

其中, G_j 和 H_j 分别表示第 $t-1$ 轮迭代的目标函数 $Obj^{(t-1)}$ 在第 j 个叶子节点上对 $\hat{y}_{t-1}^{(i)}$ 所求的一阶梯度和二阶梯度。公式(11)和(12)给出了新建二叉树模型对应的最佳目标分数与叶子权重值。事实上, 在生成新的二叉树的过程中, XGBoost 采用的是基于贪婪策略的建模方式, 它仅仅关注一个叶子节点是否会分裂成两个新的叶子节点。在选择合适的网络指标作为节点分裂判决条件的情况下, 原

有叶子节点中的输入特征 $\mathbf{x}^{(i)}$ 将会被分拆至两个新生成的叶子节点中。这意味着叶子权重和目标函数值将根据公式(12)与(11)进行更新。当旧叶子节点分裂为两个新叶子节点时, 我们定义 $Gain$ 为目标函数的变化量, 如公式(13)所示:

$$Gain = \frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{G^2}{H + \lambda} - \gamma, \quad (13)$$

其中, $G = G_L + G_R, H = H_L + H_R$, G 和 H 分别表示新的左右分支的一阶梯度和二阶梯度。选择不同的网络指标和不同的判决阈值会得到不同的 $Gain$ 值。为了获得最小化目标函数值 $Obj^{(i)}$, 当存在大于 0 的 $Gain$ 值时, XGBoost 会从中选择最大 $Gain$ 值所对应的网络指标的阈值作为判决条件, 以完成节点分裂过程和更新叶子权重, 直至获得树模型的最大深度。此时的决策树模型包含能够使目标分数最小化的树结构和相应的叶子权重。

XGBoost 在每一轮迭代中都会建立一个基本二叉树模型。当达到最大迭代次数 K 后, XGBoost 将得到一个完整的模型 $F(\cdot) = \sum_{k=1}^K f_k(\cdot)$ 。在使用模型时, 我们给定一组蜂窝网络的指标向量 $\mathbf{x}$ 。将并行地输入整体模型中的每一个基本模型, 从而获取每个基本模型的叶子权重 $f_k(\mathbf{x})$ 。所有叶子权重的累加值 $F(\mathbf{x})$ 即为整个模型的输出结果。

2.3 基于群体智能优化的网络最优运营状态挖掘

建立网络流量潜力评估模型不仅需要构建诸多下行业务指标与下行流量指标之间的映射关系, 还需要明确不同网络指标的取值对流量产生的影响。调整各个指标的取值使

潜力评估模型给出流量最大化的推断结果, 目的是获取小区的高价值运营状态 $\mathbf{x}^*$ 和流量上限 y^* , 即 $\mathbf{x}^* = \arg \max F(\mathbf{x}), y^* = F(\mathbf{x}^*)$ 。本文中, 我们提出一种基于量子行为粒子群优化^[11]的改进量子粒子群优化(RQPSO)算法, 以获得对多元回归模型的最优化搜索求解。该算法的思想是在特征空间中初始化 M 个随机的粒子 $\mathbf{x}_m$, 其中 $1 \leq m \leq M$ 。在第 s 轮迭代中, $\mathbf{x}_m(s) = (x_{m,1}(s), \dots, x_{m,d}(s), \dots, x_{m,D}(s))$ 。评价粒子当前“携带”的网络指标组合优劣的方式是: 将 $\mathbf{x}_m(s)$ 输入 2.2 节中使用网络业务数据训练的 XGBoost 模型中, 得到的输出值 $F(\mathbf{x}_m(s))$ 将作为评价粒子 $\mathbf{x}_m(s)$ 的指标。由于目标是解决最大化问题, 因此, 粒子所对应的 $F(\mathbf{x}_m(s))$ 值越大, 其所处的位置越优于其他粒子。在迭代过程中, 算法始终维护所有粒子的个体历史最优指标组合 $P_m(s) = (P_{m,1}(s), \dots, P_{m,d}(s), \dots, P_{m,D}(s))$ (粒子在前 s 轮迭代中的最优组合)、对 XGBoost 模型输出的值 $F(P_m(s))$ 、所有粒子中 $F(P_m(s))$ 最大的全局最优粒子 $G(s) = (G_1(s), \dots, G_d(s), \dots, G_D(s))$ 和与之对应的前向推断流量 $F(G(s))$ 。

在每轮迭代中, RQPSO 算法会根据当前每个粒子的个体历史最优 $P_m(s)$ 和全局最优 $G(s)$, 计算对应的吸引子 $p_m(s) = (p_{m,1}(s), \dots, p_{m,d}(s), \dots, p_{m,D}(s))$ 。对于 $p_m(s)$ 中的每一个网络业务指标, 我们有:

$$p_{m,d}(s) = \varphi_{m,d}(s) \cdot P_{m,d}(s) + (1 - \varphi_{m,d}(s)) \cdot G_d(s). \quad (14)$$

在公式(14)中, $\varphi_{m,d} \sim U(0, 1)$ 。

$U(0,1)$ 表示服从0~1的均匀分布。不同粒子在达到历史最优和全局最优时具有各自的倾向权重。粒子 $x_m(s)$ 携带的每个网络指标值 $x_{m,d}(s)$ 是基于基本量子粒子群优化(QPSO)算法迭代过程的。它表示粒子在运动过程中受到 $p_{m,d}(s)$ 的吸引,如公式(15)所示:

$$X_{i,j}(s+1)=p_{i,j}(s)\pm\alpha\cdot[p_{i,j}(s)-X_{i,j}(s)]\cdot\ln\left[1/u_{i,j}(s)\right], \quad (15) \\ +\beta\cdot[C_j(s)-X_{i,j}(s)]\cdot Rn(s)$$

其中, $X_{i,j}(s+1)$ 代表在新一轮迭代中候选关键指标的更新结果。 $p_{i,j}(s)$ 是算法迭代过程中的吸引子,它由整个粒子群中最优个体的关键指标组合与个体在过去搜索到的最优关键指标组合共同决定。 $X_{i,j}(s)$ 是上一轮迭代候选关键指标组合, $u_{i,j}(s)$ 是一个服从0~1均匀分布的随机变量, $C_j(s)$ 表示所有粒子个体历史最优的平均值, $Rn(s)$ 是一个服从标准正态分布的随机变量, α,β 是算法的两个收缩系数。最优的候选解将作为算法输出的最优运营状态。由于候选解是流量潜力的上限,因此,所有候选解将向着目标函数最大的方向进行搜索。当达到最大迭代次数 T 时,算法将跳出循环,并把输出的全局最优网络业务指标组合 $G(T)=(G_1(T),\dots,G_d(T),\dots,G_D(T))$ 作为优化结果。将 $G(T)$ 输入2.2节中的XGBoost模型后,得到的输出 $F(G(T))$ 将作为对应的最优下行流量值。

3 基于网管数据的实验

本节采用的数据集由某运营商在中国的真实数据组成。采样时间跨度为2018年10月15日—2019年1月15日,采样粒度为24 h/d。每个小

区共有2 232条记录,每条记录均包含平均激活用户设备(UE)数、PDCP层平均速率、平均信道质量指示(CQI)、下行PDCP SDU数据量等指标。我们从中随机抽取80%的数据作为训练数据,并将剩余20%的数据作为测试数据。结合相关网络运营方面的专家经验,本研究从现有数据集包含的指标中遴选网络下行流量指标和其他6种不同业务行为的指标,即 $D=6$ 。这些指标分别是平均激活UE数、物理下行共享信道(PDSCH)利用率、下行PDCP层平均速率、平均CQI、下行64正交振幅调制(QAM)占比、下行PRB满负荷时间和下行PDCP SDU数据量。

3.1 基于高斯过程的流量预测仿真

实验中,我们采用MATLAB中的基于高斯过程的机器学习包(GPML)进行建模,利用高斯过程对PRB利用率和下行PDCP SDU流量进行预测。本实验分别利用单小区的300 h历史时刻的PRB利用率和下行PDCP SDU流量数据,来预测下一个小时的数据。预测结果基本符合真实数据的变化趋势。该模型对突变比较明显的缺乏一定的适应性,但对变化平稳的数据具有很高的预测精度。从平均绝对百分比误差(MAPE)来看,基于高斯过程建立的模型对PDCP SDU流量数据和PRB利用率的预测性能分别为0.3551和0.2068,而基于ARIMA建立的模型在这两个指标上的表现分别是0.4015和0.3081。由此可见,高斯过程预测模型的表现要优于ARIMA模型。

3.2 多元流量增长潜力建模

我们利用开源XGBoost框架^[11]建立多元流量潜力评估模型,使用拟合优度(R^2)指标来评价模型性能。 R^2 的定义如公式(16)所示:

$$R^2 = \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2}, \quad (16)$$

其中, $y_i,\hat{y}_i$ 分别表示真实标签与模型输出, $\bar{y}$ 是数据集中真实流量值的平均值。拟合优度能够反映数据集自身的波动对模型预测结果的影响,其取值范围为0~1。拟合优度越接近1,模型的拟合能力越强,数据的波动对模型预测的影响就越小。在图1中,灰色虚线表示最优的拟合优度。随着集成模型中基本模型数量的不断增加,训练集曲线和测试集曲线均逐步逼近最优值。当基本模型的数量超过80时,两条曲线已基本收敛。这说明XGBoost框架在此蜂窝网络数据集上已达到拟合极限。

3.3 最优运营状态挖掘

充分拟合数据的机器学习模型能够量化不同网络业务指标对网络下行流量的影响。本文中,我们测试多种群体智能算法在多元回归模型上的搜索性能,使用RQPSO算法从基于XGBoost量化的模型中挖掘最优网络运营状态,并将基本粒子群算法(PSO)和QPSO算法作为对照。3种算法各迭代60次,它们的收敛过程如图2所示。

由图2可知,PSO算法在早期的收敛速度较快,但在10次迭代之后,该算法的搜索基本陷入停滞状态。QPSO算法的收敛速度慢于RQPSO算法,在同样的迭代次数内没有获得相对较优的优化结果。RQPSO算法在前30次的迭代中搜索速度较快,在迭代末期逐步收敛在28 GB左右。因此,RQPSO算法的优化结果在3种算法中是最优的。与QPSO算法相比,带有混合量子搜索行为的RQPSO算法能够充分发掘流量评估模型潜力,

得到最高的网络流量潜力值和与之对应的高价值运营状态。在高价值运营状态下的各个网络指标的取值如图3所示。

3.4 网络优化指导

以基于机器学习方法得到的蜂窝网络运营高流量价值(流量潜力上限状态)为参考,我们列举一些评估流量增长潜力的实例。图4中的两张子图分别展示不同蜂窝小区在某单位时段内的各网络指标的真实统计值与机器学习方法得到的高价值状态的对比。其中,蓝色雷达图表示由机器学习方法得到的蜂窝网络运营高流量价值状态,红色雷达图表示实际的运营数据值。高价值状态的各项指标依次是:流量潜力上限为27.94 GB,平均激活用户数为42, PDSCH资源利用率为96%,下行PD-CP层平均速率为72 Mbit/s,平均CQI为14,下行64QAM调制占比为81%,下行PRB满负荷时间为2 391 s。


在图4(a)中,网络实际流量为16.15 GB,比上限流量少了约12 GB。用户数、PDSCH利用率和PRB满负荷时间基本相同。平均CQI为11,比最优状态低3个等级。下行64QAM调制占比仅为28%,与最优状态相比,差距较大。下行速率为38 Mbit/s,差距也较大。总的来说,流量增长潜力受到抑制的原因在于当前蜂窝网络的整体覆盖能力偏弱。因此,我们应当分析造成弱覆盖的具体原因,并进行相应优化,以释放流量增长潜力。

在图4(b)中,网络实际流量约15.02 GB(比最优状态的流量少了约13 GB),平均CQI为14,下行64QAM调制占比为85%,这说明覆盖质量良好。用户数、PDSCH利用率和下行PRB满负荷时间等其他指标,与最优状态相比,差距较大。总的来说,流


量差距较大的主要原因在于该小区覆盖范围内的激活用户数量较少。如果网络长时间处于这种状态,就需要运营商加大业务推送力度,增加新用户来提升流量,从而释放流量增长潜力。

4 结束语


本文提出一个基于机器学习的无线网络流量预测和流量潜力评估方案。与传统方法相比,高斯过程回归的无线流量预测




▲图1 拟合优度随基本模型数量的变化



▲图2 群体智能算法的优化结果



▲图3 由改进量子粒子群优化算法得到的潜力上限状态



▲图4 真实数据与流量潜力上限状态的对比

方法能够显著提高预测精度,从短期角度指导网络优化部署。同时,流量增长潜力评估方案可以量化其他指标与流量的关系,构建多维映射模型。本文提出的RQPSO算法能够对多维映射模型进行最大化求解,从长期角度指导网络优化部署,更好地为运营商提供网络优化量化指导,从而提高运营商的经济效益。

致谢

本研究得到中兴通讯产学研合作基金的资助。感谢项目负责人北京邮电大学许文俊教授。北京邮电

大学项目组团队中的童伟强、林元杰、蒲俊林、郑远、黄春雷、胡卓尔等对本文的研究工作做出大量贡献,在此谨致谢意。

参考文献


- [1] IMT-2020 (5G)推进组. 5G愿景与需求白皮书 [EB/OL]. (2014-05-28) [2021-01-20]. <http://www.imt2020.org.cn/zh/documents/1>
- [2] 吕惠. 中国电信发布人工智能发展白皮书 [J]. 计算机与网络, 2019, (13): 15
- [3] LI R, ZHAO Z, ZHOU X, et al. The prediction analysis of cellular radio access network traffic: from entropy theory to networking practice [J]. IEEE communications magazine, 2014, 52(6): 234-240. DOI: 10.1109/MCOM.2014.6829969
- [4] YANG S, KUIPERS F A. Traffic uncertainty models in network planning [J]. IEEE communications magazine, 2014, 52(2): 172-177. DOI: 10.1109/MCOM.2014.6736759
- [5] ZHANG M, FU H, LI Y, et al. Understanding urban dynamics from massive mobile traffic data

- [J]. IEEE transactions on big data, 2017, 5(2): 266-278. DOI: 10.1109/TBDATA.2017.2778721
- [6] SHU Y, YU M, YANG O, et al. Wireless traffic modeling and prediction using seasonal ARIMA models [J]. IEICE transactions on communications, 2005, 88(10): 3992-3999
- [7] WANG J, TANG J, XU Z, et al. Spatiotemporal modeling and prediction in cellular networks: a big data enabled deep learning approach [C]//IEEE INFOCOM 2017-IEEE Conference on Computer Communications. Atlanta, GA, USA: IEEE, 2017: 1-9. DOI: 10.1093/ietcom/e88-b.10.3992
- [8] 李一, 杨雨苍, 李菲, 等. 基于用户感知的FDD LTE网络扩容方法研究 [J]. 邮电设计技术, 2018, (3): 54-58. DOI: 10.12045/j.issn.1007-3043.2018.03.012
- [9] RASMUSSEN C E. Gaussian processes in machine learning [C]//Summer School on Machine Learning. Berlin, Heidelberg, Germany: Springer, 2003: 63-71
- [10] CHEN T, GUESTRIN C. Xgboost: a scalable tree boosting system [C]//The 22nd ACM Sigkdd International Conference on Knowledge Discovery and Data Mining. San Francisco, CA, USA: ACM, 2016: 785-794
- [11] SUN J, FENG B, XU W. Particle swarm optimization with particles having quantum behavior [C]//IEEE 2004 Congress on Evolutionary Computation. Portland, OR, USA: IEEE, 2004, 1: 325-331

作者简介



邢旭东, 北京邮电大学可信分布式计算与服务教育部重点实验室在读硕士研究生; 研究方向为机器学习、深度学习算法在无线网络大数据分析中的应用。



20余项。

高晖, 北京邮电大学信息与通信工程学院副教授; 主要从事5G/B5G物理层新理论及关键技术、无线大数据及人工智能等方面的研究; 主持并参与多个国家自然科学基金、国家重点研发计划等项目; 发表论文160余篇, 申请专利



顾军, 中兴通讯股份有限公司高级方案架构师; 主要从事4G/5G无线组网方案及性能方面的研究工作; 发表论文5篇, 申请专利20余项。