

小波神经网络在教育网格下行流量预测中的应用^①

邱树伟¹, 李琰琰²

¹(汕头职业技术学院 计算机系, 汕头 515078)

²(浙江工业大学 计算机科学与技术学院, 杭州 310014)

摘要: 准确预测教育资源网格的下行流量有助于网络的负载均衡和信息安全管理. 小波神经网络适合于对具有随机性和不确定性特征的网格下行流量进行建模和非线性预测. 针对一般小波神经网络预测模型存在收敛速度较慢, 误差较大, 稳定性较差等不足, 在基于梯度下降法的网络权值和参数修正方案中增加了动量项, 同时, 提出了一种对预测的中间结果引入随机样本替换机制的改进算法. 实验结果表明, 该算法能有效降低网络训练的收敛时间, 提高网络预测的准确性和稳定性.

关键词: 小波神经网络; 小波分析; 教育资源网格; 流量预测

Application of Wavelet Neural Network in Educational Grid Downlink Traffic Prediction

QIU Shu-Wei¹, LI Yan-Yan²

¹(Department of Computer Science, Shantou Polytechnic, Shantou 515071, China)

²(School of Computer Science and Technology, Zhejiang University of Technology, Hangzhou 310014, China)

Abstract: Accurate predicted the downlink traffic contributes to traffic load balancing and information security management in educational resources grid. Wavelet neural network is suitable for modeling and nonlinear prediction in grid downlink traffic which has the randomness and uncertainty characteristic. General wavelet neural network prediction model had some defects such as convergence slower, larger error and poor stability. In order to eliminate or improve the existing defects, a momentum was added in the scheme which was used to adjust the network weights and parameters based on gradient descent algorithm, meanwhile, an improved algorithm with random sample replacement mechanism in temporarily prediction results was proposed. Experimental results show that the proposed algorithm can reduce the convergence time in network training and improve the prediction accuracy and stability.

Key words: wavelet neural network; wavelet analysis; educational resources grid; traffic prediction

网络信息时代, 越来越多的教育资源以数字形态产生并通过网络进行传播. 教育资源网格(Educational Resources Grid, ERG)是将教育信息资源(如课件、文献、教学媒体等)通过网络互相连接, 为用户提供资源整合与共享的分布式计算设施. 目前, 国内各高校纷纷致力于 ERG 平台的开发、应用、管理和维护. ERG 的流量管理便是其中尤为重要的一环. 在 ERG 系统中, 因用户上传资源而产生的上行流量有严格的审核和管理, 用户上传的资源必须通过管理员审核才能最终提交到 ERG 系统, 因此, 可以认为上行流量是可控的和

安全的. 相反, 因用户下载资源而产生的下行流量则有可能对系统造成重大的影响, 例如非法用户长时间大批量下载资源, 占用了带宽;或者因某些网格节点故障而造成下行流量集中在某个节点上, 造成这个节点负载过重, 无法提供正常服务. 这些情况都会导致 ERG 系统服务质量下降, 甚至出现“宕机”. 可见, 对 ERG 系统下行流量的监控和预测, 有一定的应用价值和实际意义.

ERG 下行流量(ERG Downlink Traffic, ERGDT)是衡量网格运行状态的重要指标, 将 ERGDT 预测应用

^① 基金项目:汕头职业技术学院科研课题(SZY2013Y11)

收稿时间:2014-10-20;收到修改稿时间:2014-12-01

在数据分流和负载均衡中可以提高 ERG 的性能,也可以通过 ERGDT 对用户的行为进行建模和预测,从而及时发现网络异常行为,提升网络的安全性和可靠性。

小波神经网络(Wavelet Neural Network, WNN)是小波分析理论与人工神经网络理论相结合的产物^[1],广泛应用于数据挖掘、行为预测、优化问题求解等领域。小波神经网络充分结合了小波分析和人工神经网络两者的优点和特性,在网络流量预测领域是一种十分有效的数学建模和分析方法,由于小波变换引入了伸缩因子和平移因子,这两个因子使得小波神经网络比小波分解具有更多的自由度,从而使小波神经网络具有比一般神经网络更强的容错能力和更好的函数逼近能力,有效地克服了传统 BP 神经网络模型本身所固有的一些诸如收敛速度较慢、误差较大等缺陷。

在将 WNN 应用于网络流量预测这方面,国内外现有的研究成果很少,大多数文献主要集中在对一般网络流量(这类流量不区分上下行,也不针对特定的应用系统)的建模和预测。由于网络下行流量是一类特定的网络流量,具有与一般网络流量类似的特性(例如随机性和突发性等),因此,在网络流量预测方面可借鉴一般网络流量的预测方法。Guan 等人^[2]提出了基于小波神经网络的数据预筛选方法,其核心思想是使用峰值滤波技术来检测负载数据的峰值并对其进行修正;Senkal 等人^[3]对比了一般人工神经网络和小波神经网络在基于时间序列事件(如网络流量、风速、光照等)预测方面的性能,认为虽然两者的拓扑结构类似,但小波神经网络模型的预测结果与实际值之间的均方根误差和均方误差更小;Liu 等人^[4]提出了一种用于时间序列预测的小波神经网络控制方法,该方法通过额外的小波神经网络和向量自回归滑动平均预测,实现了更灵活的参数调节和更低的静态误差;Yilmaz 等人^[5]提出了一种基于模糊小波神经网络的非线性动力系统的预测和识别模型,该模型在模糊规则的 IF 部分中采用了高斯型激活函数,同时,采用快速梯度下降法来更新网络中的参数,具有良好的泛化能力;Zhou 等人^[6]采用相空间重构理论讨论了基于小波神经网络的混沌时间序列预测,验证了小波神经网络预测模型的可行性;Zhang 等人^[7]提出了一种基于递归小波神经网络的网络流量预测方法,给出了一种动态梯度下降法来调整小波神经网络的权值和参数;Wang 等人^[8]分析了智能电网的网络流量特性,提出了改进粒子群小波神经

网络预测模型,提高了预测的收敛速度和预测精度;Gao 等人^[9]研究了短时交通流量问题,将小波神经网络用于短时交通流量预测,该方法在预测精度方面优于 BP 神经网络。

从以上的研究工作可以看出,在 WNN 的模型结构改进、参数优化以及将 WNN 应用于时间序列预测等方面,已取得一些成果。然而,在 WNN 预测模型的收敛速度、误差以及稳定性等方面仍有进一步改善的空间。首先,WNN 预测过程最主要的部分在于网络训练,如果经过训练之后网络到达稳定状态时误差较小,那么最终的预测结果误差也会随之降低;同样,网络训练的收敛速度,也决定了网络运行时间的长短。其次,由于神经网络本身固有的特性(结构较为复杂、连接权值动态变化、参数选取灵活等),使得预测结果具有一定的“摆动性”,即对于固定的输入样本,每次预测输出都可能不同,甚至个别输出与期望输出之间的偏离程度较大(见 4.3 节图 4)。因此,使网络训练的误差和收敛速度尽可能的小、提升 WNN 预测的稳定性,是两个亟待解决的问题。

为此,本文在建立 WNN 预测模型时,在原有的基于梯度下降法的网络权值和参数修正算法中增加了动量项,减少了训练的误差,提高了收敛速度;同时,提出了一种对预测的中间结果引入随机样本替换机制的改进算法,提升了 WNN 预测的准确性和稳定性。

本文的主要贡献在于:将小波神经网络用于 ERG 下行流量预测,为 ERG 的部署、管理和维护提供借鉴;改善了现有小波神经网络预测模型的性能。

1 小波神经网络的结构

WNN 结合了小波变换和人工神经网络两者的优点,小波变换引入了伸缩系数和平移系数这两个参数,从而使 WNN 具有比一般神经网络更强的容错能力和函数逼近能力。

在函数空间 $L^2(R)$ 中,选择一个母小波函数 $\Psi(x)$,使其满足:

$$C_{\Psi} = \int_R \frac{|\hat{\Psi}(x^*)|^2}{|x^*|} dx^* < \infty \quad (1)$$

式中, $\hat{\Psi}(x^*)$ 表示 $\Psi(x)$ 的 Fourier 变换。对 $\Psi(x)$ 作伸缩和平移变换,得到小波基函数系 $\{\Psi_{a,b}(x)\}$, 其中,

$$\Psi_{a,b}(x) = \frac{1}{\sqrt{a}} \Psi\left(\frac{x-b}{a}\right) \quad (a, b \in R^2) \quad (2)$$

式中, a 是伸缩系数, b 是平移系数.

由上式可知, 改变参数 a 可以使函数产生伸缩, 形成不同 “级”的小波;改变参数 b 可以使函数移位, 形成不同 “位”的小波, 这样就衍生出一族小波函数.

对于任意信号 $f(x) \in L^2(R)$, 小波变换可表示为:

$$W_f(a,b) = \frac{1}{\sqrt{C_\Psi}} \int f(x) \Psi_{a,b} dx \quad (3)$$

由此推出其反演公式为:

$$f(x) = \frac{1}{C_\Psi} \int_0^{+\infty} W_f(a,b) \Psi_{a,b} da db \quad (4)$$

从以上式子可以看出, 小波变换与 Fourier 变换相比, 具有可改变的尺度伸缩和位置平移参数, 使其具有对信号进行适应分析的能力.

WNN 以 BP 神经网络为基础, 把小波基函数作为隐含层节点的传递函数, 在信号前向传播的同时误差反向传播. 其结构如图 1 所示.

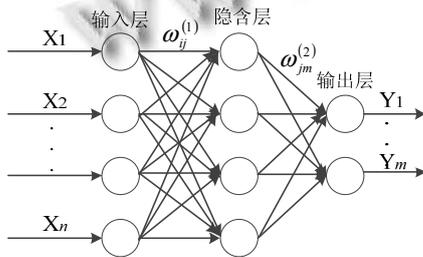


图 1 小波神经网络的结构

WNN 包含输入层、隐含层和输出层共三层, X_1, X_2, \dots, X_n 是 n 个输入数据, Y_1, Y_2, \dots, Y_m 是 m 个输出数据, $\omega_{ij}^{(1)}$ 表示输入层与隐含层的连接权值, $\omega_{jm}^{(2)}$ 表示隐含层与输出层的连接权值.

设输入信号为 $x_i (i = 1, 2, \dots, n)$, 则隐含层输出的计算公式为:

$$h(j) = \phi \left(\frac{\sum_{i=1}^n \omega_{ij}^{(1)} x_i - b_j}{a_j} \right) \quad j = 1, 2, \dots, l \quad (5)$$

式中, $h(j)$ 表示第 j 个隐含层节点的输出值, $\phi(\cdot)$ 表示小波基函数, a_j 和 b_j 分别是 $\phi(\cdot)$ 的伸缩系数和平移系数, l 是隐含层节点的个数. $\phi(\cdot)$ 有多种函数可供选择, 本文采用比较通用的 Morlet 母小波基函数, 其数学表达式为:

$$\phi(x) = \cos(1.75x) e^{-x^2/2} \quad (6)$$

输出层的计算公式为:

$$Y(k) = \sum_{j=1}^l \omega_{jk}^{(2)} h(j) \quad k = 1, 2, \dots, m \quad (7)$$

2 权值与参数修正方法的改进

WNN 在运行之前必须有一个训练过程, 训练过程需要 n 输入样本和 m 个输出样本, 训练时每个预测值要与输出样本(即期望值)进行比较, 计算出预测值与期望值之间的误差 e , 然后再根据误差对网络的连接权值 ω 、小波基函数的伸缩系数 a 和平移系数 b 等参数进行修正, 这个过程迭代进行, 从而使预测值不断逼近期望值. 参数修正过程主要有两个步骤:

步骤 1: 计算预测误差

$$e = \sum_{k=1}^m |Y_k - \bar{Y}_k| \quad (8)$$

式中, Y_k 表示预测值, \bar{Y}_k 表示期望值.

步骤 2: 修正网络参数

WNN 采用梯度下降法来修正网络的连接权值和小波基函数的参数. 不妨称采用梯度下降法的 WNN 算法为梯度 WNN(Gradient_WNN, GWNN).

计算公式为:

$$\omega^{(new)} = \omega^{(old)} + \Delta \omega^{(new)} \quad \omega = \omega_{ij}^{(1)}, \omega_{jk}^{(2)} \quad (9)$$

$$\alpha_j^{(new)} = \alpha_j^{(old)} + \Delta \alpha_j^{(new)} \quad \alpha = a, b \quad (10)$$

其中, $\Delta \omega^{(new)}$ 和 $\Delta \alpha_j^{(new)}$ 的计算公式为:

$$\Delta \omega^{(new)} = -\eta_1 \frac{\partial e}{\partial \omega^{(old)}} \quad (11)$$

$$\Delta \alpha_j^{(new)} = -\eta_2 \frac{\partial e}{\partial \alpha_j^{(old)}} \quad (12)$$

(11)、(12)两式中, η 表示学习速率. η 的选取比较关键: η 值越大, 权值的变化率就越大, 则训练的收敛速度也就越快, 但 η 值越大网络越不稳定; 相反地, η 值越小, 权值的变化率就越小, 自然, 训练的收敛速度也越慢, 但网络却较为稳定.

为了解决这个矛盾, 本文对以上方法进行改进, 主要是在式(9)和式(10)中增加一个动量项, 计算公式为:

$$\omega^{(new)} = \omega^{(old)} + \Delta \omega^{(new)} + \mu(\omega^{(old)} - \omega^{(old-1)}) \quad (13)$$

$$\alpha_j^{(new)} = \alpha_j^{(old)} + \Delta \alpha_j^{(new)} + \mu(\alpha_j^{(old)} - \alpha_j^{(old-1)}) \quad (14)$$

其中, $\mu(\omega^{(old)} - \omega^{(old-1)})$ 和 $\mu(\alpha_j^{(old)} - \alpha_j^{(old-1)})$ 分别是式(13)

和(14)的动量项, μ 是动量项系数, 取值范围一般是 $0 \leq \mu \leq 1$. 可以看到, 在式(13)中, 动量项 $\mu(\omega^{(old)} - \omega^{(old-1)})$ 可以在 η 确定的前提下, 动态调节 ω 的修正速率, 当 $\omega^{(old)} - \omega^{(old-1)} > 0$ 时, 式(13)的值大于式(9)的值, 其作用相当于提升了 ω 的修正速率, 进而加快了网络训练的收敛速度; 同理, 当 $\omega^{(old)} - \omega^{(old-1)} < 0$ 时, 则能降低 ω 的修正速率, 起到了缓解“抖动”的作用, 此时, 收敛速度会暂时变慢. μ 的不同取值决定了 ω 修正速率的提升(或降低)幅度, 当 $\mu = 0$ 时, 式(13)就退化为不加入动量项的情形. 由于一般情况下 $\omega^{(old)} \neq \omega^{(old-1)}$, 因此, $\omega^{(old)} - \omega^{(old-1)} \neq 0$. 从式(13)的表现形式可以看出, 新的连接权值 $\omega^{(new)}$ 和它前两轮迭代的权值 $\omega^{(old)}$ 和 $\omega^{(old-1)}$ 有紧密的依赖关系, 这也体现出权值修正的演化过程. 式(14)的分析类似.

从以上分析可以看出, 在修正网络连接权值和参数时加入动量项能改善网络的训练效率(见 4.3 节图 2 和图 3). 但是, 在网络预测的稳定性方面, 仍需进一步探讨.

3 随机样本替换机制

从文献[1]、[7]的实验结果可以看出, WNN 的预测值出现了一定程度的“摆动”, 作者在实验过程中也发现, WNN 存在较为明显的不稳定现象, 大部分时候预测值能很好地与期望值拟合, 但偶尔会出现较大的偏离. 经过统计, 这种偏离的概率约为 0.17, 虽然可以采取多次预测再取平均的方法来降低预测错误的风险, 但由于偏离现象(即不稳定性)的存在, 预测的准确性仍然会受影响.

为了解决 WNN 的不稳定现象, 本文引入一种随机样本替换机制, 该机制的主要思想是: 采用循环预测, 每一次循环产生一个预测的中间结果, 然后对这个中间结果进行是否发生偏离的判定(具体见本节后半部分), 若发生偏离, 则在训练样本中随机选取一个样本对其进行替换, 若不发生偏离, 则保留这个中间结果. 所有的中间结果保存在一个广义数组中, 在循环预测结束时将所有的中间结果取平均, 并将该平均值作为最后的预测值返回给用户.

为了更清晰的讨论随机样本替换机制的工作过程, 可采用数学语言描述如下:

假设网络节点每天的流量状态可用一个 m' 维向量来刻画, 它表示将每天平均等分成 m' 个时间点, 并

在每个时间点上记录节点的流量值(单位为 M). 若一共记录了 n' 天, 则这 n' 天的流量状态可以用一个 $n' \times m'$ 的样本矩阵来表示:

$$X_{n' \times m'} = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1m'} \\ x_{21} & x_{22} & \cdots & x_{2m'} \\ \vdots & \vdots & \vdots & \vdots \\ x_{n'1} & x_{n'2} & \cdots & x_{n'm'} \end{pmatrix} \quad (15)$$

事实上, n' 即为样本的数量. 现假设第 $n'+1$ 天的流量状态为: $\bar{Y} = (\bar{y}_1, \bar{y}_2, \dots, \bar{y}_m)$, 并将 \bar{Y} 设为期望输出.

随机样本替换机制的工作过程如下:

Step1: 设置循环预测的次数 p ;

Step2: 开始预测, 得到第 i 次($i \in Z^+, 1 \leq i \leq p$) 预测的中间结果为 $Y(i) = (y_{i1}, y_{i2}, \dots, y_{im})$;

Step3: 判断 $Y(i)$ 与 \bar{Y} 之间的偏离度是否大于某个给定的阈值 λ , 若是, 则在样本矩阵 $X_{n' \times m'}$ 中随机选择一行(即在 n' 个样本中随机选择一个)对 $Y(i)$ 进行替换, 保存替换后的 $Y(i)$; 若否, 无需替换, 直接保存原预测值 $Y(i)$. $i = i+1$, 返回 Step2;

Step4: 循环预测结束后得到一个广义数组 $Y(p)$, 对 $Y(p)$ 求平均值, 得到 $Y = p^{-1} \sum_{i=1}^p Y(i)$, 将 Y 作为本轮预测的输出.

以上预测方法有很大的灵活性, 当 $p = 1$ 时, 相当于仅对一次预测进行是否偏离的判定和输出; 当 p 取值较大时, 预测的时间开销比较大, 但预测的精确度会更高, 根据大数定律, 当 $p \rightarrow \infty$ 时, $\lim Y = E[Y(p)]$; 当 p 取值较小时, 时间开销较小, 但预测精度会随之降低. 由于发生偏离的中间结果被消除和替换, 因此, 网络的预测稳定性得到了保证.

随机样本替换机制的关键问题在于阈值 λ 如何选取, 阈值 λ 的直观意义是表示 $Y(i)$ 与 \bar{Y} 这两个向量之间的接近程度, λ 值越大, 则 $Y(i)$ 与 \bar{Y} 之间的差异越大; λ 值越小, 则 $Y(i)$ 与 \bar{Y} 之间越接近. 可见, λ 可以采用多种统计学指标进行定义, 较为典型的有均方根误差(Root Mean Square Error, RMSE)、平均绝对误差(Mean Absolute Error, MAE)等, 它们的定义分别为:

$$\text{RMSE}(x, y) = \left(\frac{1}{m'} \sum_{i=1}^{m'} (x_i - y_i)^2 \right)^{1/2} \quad (16)$$

$$\text{MAE}(x, y) = \frac{1}{m'} \left(\sum_{i=1}^{m'} |x_i - y_i| \right) \quad (17)$$

其中, x_i 和 y_i 分别表示向量 x 和 y 的第 i 个分量.

为简单起见, 本文用 MAE 对 λ 进行定义. 当 $Y(i)$ 和 \bar{Y} 之间的 MAE 大于 λ 时, 就认为 $Y(i)$ 发生了偏离.

虽然 λ 值并不能直接计算得到, 但可以通过近似的方法求得, 具体做法是: 先在训练样本 $X_{n' \times m'}$ 中求得 λ 的一个基准值 λ_0 , 再根据式(21)进行微调.

λ_0 的计算公式为:

$$\lambda_0 = \frac{1}{n'} \sum_{i=1}^{n'} \text{MAE}(x_i, \bar{Y}) \quad (18)$$

式中, x_i 表示 $X_{n' \times m'}$ 中第 i 个训练样本(即样本矩阵 $X_{n' \times m'}$ 中的第 i 行). 上式表示所有训练样本与期望值之间的平均绝对误差的平均值.

式(18)得到的 λ_0 仅是一个估计值, 它会随着样本的数量、样本方差的大小等的不同而出现波动, 是否具备可用性还需进一步检验. 为了说明如何从 λ_0 出发逐步得到 λ 值, 先给出几个关键概念的定义:

定义 1. 若第 i 个预测值 $Y(i)$ 与期望值 \bar{Y} 之间的 MAE 大于 λ , 即 $\text{MAE}(Y(i), \bar{Y}) > \lambda$, 则称该次输出为偏离输出.

定义 2. 在 p 次运行中, 发生偏离输出的个数, 称为偏离次数, 用 σ 表示:

$$\sigma = \text{count}(\text{MAE}(Y(i), \bar{Y}) > \lambda) \quad (19)$$

式中, $\text{count}()$ 函数表示对偏离输出的个数进行计数, 并在 p 次运行结束之后返回偏离总次数. 这个指标间接的作用是衡量系统的稳定程度. 由定义 1 和定义 2 可以看出, σ 的值跟 λ 值的选取有紧密的联系.

定义 3. 在 p 次运行中, 不发生偏离输出的次数 $p - \sigma$ 与运行总次数 p 的比值, 称为 WNN 的稳定性, 用 Θ 表示:

$$\Theta = \frac{p - \sigma}{p} \quad (20)$$

下面讨论检验及调整 λ_0 的方法.

预先设置运行次数 p , 并设置稳定性 $\Theta \in [\alpha, \beta]$ (α, β 为 $[0, 1]$ 之间的实数, 且 $\alpha \leq \beta$, 表示稳定性在 α 至 β 之间). 首先根据式(18)求出 λ_0 , 再将 λ_0 代入式(19), 求出偏离次数 σ , 然后根据式(20)求出 Θ , 最后判断 Θ 是否满足 $\Theta \in [\alpha, \beta]$, 若满足, 则返回 λ_0 的值(作为 λ); 若不满足, 则调整 λ_0 .

调整 λ_0 的方法为:

$$\lambda_0 \leftarrow \lambda_0 + \delta \quad (21)$$

其中, δ 是微调 λ_0 时的步长.

为了在实验分析时描述更加方便, 不妨称采用动

量项法和随机样本替换机制的 WNN 算法为改进型 WNN(Improve_WNN, IWNN).

4 实验分析

实验环境配置如下: Windows7 操作系统, Intel Pentium 2.2G CPU, 2.0G 内存, MATLAB R2012b.

4.1 样本选取

随机选取广东省粤东地区某高校若干网格节点的 ERGDT 数据做为实验样本, 含训练样本和检验样本. 样本的生成方式如下: 每 15 分钟一次采样, 每小时 4 次, 一天共进行 96 次采样, 每 96 个采样数据为 1 个样本, 表示这一天的流量状态. $3 \times 96 = 288$, 表示 3 天的数据. 为了更加全面地测试 WNN 的性能, 采用滚动方式对样本空间进行重构, 生成训练样本的输入和输出数据分别为 $X_{4 \times 288}$ 和 $Y_{1 \times 288}$ 实矩阵, 用于训练; 生成检验样本的输入和输出数据分别为 $X_{4 \times 96}$ 和 $Y_{1 \times 96}$ 实矩阵, 用于性能检验.

实验中 WNN 采用 4-8-1 结构, 其中, 输入层有 4 个节点, 表示在预测时间点之前的 4 个时间点的实际测量流量值(即, 由 4 个历史时间点的测量值来预测当前时间点的流量值); 隐含层有 8 个节点, 一般来说, 隐含层节点个数的确定方法有构造法、删除法和黄金分割法等, 本文采用构造法确定了隐含层节点的个数; 输出层有 1 个节点, 用于输出当前时间点的预测流量值. 首先进行训练, 迭代次数设为 150 次, 然后利用训练好的 WNN 进行预测. 初始化参数值如表 1 所示. 其中 $\text{rand}(x, y)$ 函数表示在整数区间 $[x, y]$ 中随机取一个数.

表 1 WNN 的参数值

参数	取值	参数	取值
p	20	η_1	0.01
λ	32	η_2	0.001
n	4	δ	2
l	8	$\omega_{ij}^{(1)}$	$\text{rand}(n, l)$
m	1	$\omega_{jk}^{(2)}$	$\text{rand}(m, l)$
iterator	150	a	$\text{rand}(1, l)$
μ	1	b	$\text{rand}(1, l)$

4.2 λ 的估算

按式(18)直接求得 $\lambda_0 = 26$, 并取 $\alpha = 0.9$, $\beta = 0.95$ (即稳定性介于 0.9 至 0.95 之间), 微调 λ_0 的步长 $\delta = 2$, 实验数据如表 2 所示.

表 2 λ_0 的更新过程

序号	p	λ_0	σ	Θ
1	40	26	25	0.6250
2	60	28	18	0.7000
3	60	30	14	0.7667
4	80	32	9	0.8875

上表中 p 的取值从 40 至 80 不等, 主要是因为实验过程中, 当 λ_0 分别等于 26, 28, 30 时稳定性一直较低, 不适合作为 λ , 因此实验只做了 40 和 60 次便停止. 而当 λ_0 等于 32 时, 稳定性较好, 为了使实验结果更加可信, 在已经做了 60 次的基础上又多做 20 次. 从上表可以看出, 若直接采用基准值 $\lambda_0 = 26$ 做为随机样本替换的阈值, 稳定性 Θ 仅 0.6 左右, 需进一步调整, 经过三次更新, 在 $\lambda_0 = 32$ 时, $\Theta \approx 0.9$, 此时满足 $\Theta \in [0.9, 0.95]$, 32 可作为 λ 的近似值返回.

4.3 性能评价

下面的实验主要是对比 GWNN 和 IWNN 的性能. 实验共进行 10 轮, 每轮独立运行 20 次.

首先, 比较了 GWNN 和 IWNN 在网络训练方面的性能. 图 2 和图 3 对 10 轮实验的训练数据取平均值再进行对比, 可以看出, IWNN 的训练曲线比 GWNN 下降得更快, 说明网络训练的速率比 GWNN 要快, 网络训练迭代完成之后, 误差也更小. GWNN 的误差是 20, 而 IWNN 的误差只有 8.

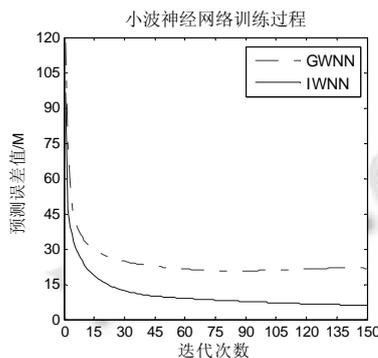


图 2 WNN 的训练过程

GWNN 和 IWNN 的平均训练时间分别为 9.6611s 和 8.7889s, 相差 0.8722s, 如图 3 所示. 可以看出 IWNN 的网络训练收敛速度比 GWNN 更快.

其次, 比较了 GWNN 与 IWNN 的预测效果. 在 10 轮实验中, 任取其中一轮实验的数据作图, 得到预测数据分布如图 4、5 所示(其它轮次的实验结果类似). 从

图 4 可以看出, GWNN 的运行过程抖动较大, 在时间点 0 至 20 抖动最大, 时间点 20 至 88 之间有 10 个左右的预测值偏离度较大, 影响了预测的准确性, 这也说明了 GWNN 的稳定程度不是很理想. 相比之下, 从图 5 可以看出, IWNN 的预测过程除了在某些时间点出现轻微偏离之外, 整体比较平滑, 更能反映真实的网络下行流量分布.

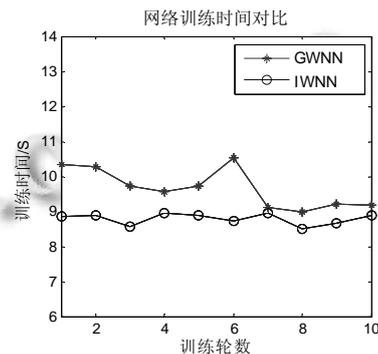


图 3 平均训练时间对比

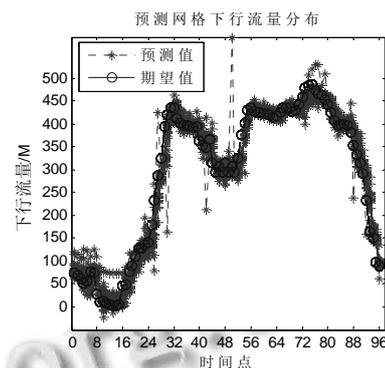


图 4 GWNN 的预测数据分布

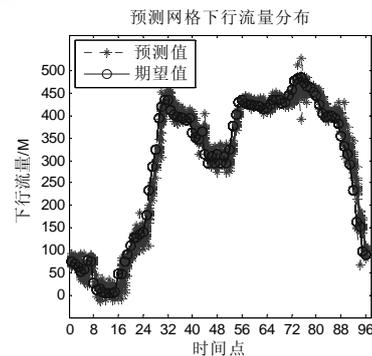


图 5 IWNN 的预测数据分布

对图 5 所示的预测中间结果取平均值, 即得到 WNN 的最终输出结果, 如图 6 所示. 可以看到, IWNN 的预测值与期望值的拟合程度较高, 效果较好.

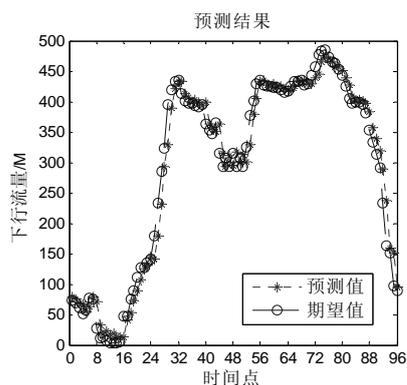


图 6 IWNN 的预测结果

最后,对 GWNN 和 IWNN 的性能指标进行对比.所采用的主要指标是 RMSE 和 MAE. RMSE 和 MAE 这两个指标用于衡量预测值与实际值之间的偏离程度, RMSE 对一组测量中的特大或特小误差非常敏感,它能够很好地反映出预测的精确程度.除了以上两个指标,还有必要考察算法的平均运行时间(Mean Run Time, MRT),以便更加全面地反映算法性能.

GWNN 和 IWNN 的性能对比如表 3 所示.表中的数据为 10 轮预测后取平均值.

表 3 性能指标对比

项目	RMSE	MAE	MRT/s
GWNN	27.70	20.10	8.20
IWNN	25.55	18.37	8.58
差值	2.15	1.73	-0.38

从上表可以看出, IWNN 前两项性能指标优于 GWNN,但在 MRT 方面略逊于 GWNN,主要原因是 IWNN 在预测时多了随机样本替换的操作,这也与直观吻合,在算法中多加了一些处理功能,优化了运行结果,同时也会付出必要的时间代价.从总体来看, IWNN 更优一些.

算法的主要开销在于网络的训练和循环预测,真正执行预测的部分复杂性低于训练阶段.训练的计算复杂性介于和之间, N 为样本数.如果训练样本是均匀分布的,则计算复杂性为;如果训练样本是非均匀分布的,则计算复杂性为.在加入随机样本替换机制之后,在预测时多了循环预测和随机样本选取等操作,这些操作的复杂性跟循环次数 p 有关,其复杂性为.因此, IWNN 算法总复杂性介于 $O(pN)$ 与 $O(pN^2)$ 之间.

4 结语

教育信息资源网格平台的开发、应用、管理和维护,对于教育系统各部门之间的资源共享、协同教学以及合作研究等方面起到关键作用.对教育信息资源网格的下行流量进行预测有助于网格系统服务质量的提升和信息安全管理.利用本文提出的方法,能够有效提高小波神经网络对网格流量预测的收敛速度,有效消除传统小波神经网络预测模型的不稳定性,提高了预测的准确性,从实验结果来看,本文提出的方法是有效的和可行的.

本文在以下方面仍存在一些不足,例如网络节点个数的确定尚未有明确的理论推导,所提出的方法也未能根据实际应用动态选取最优的小波基函数,这将值得进一步探索.

参考文献

- 1 Zhao H, Gao S, He ZY, Zeng XP, Jin WD, Li TR. Identification of nonlinear dynamic system using a novel recurrent wavelet neural network based on the pipelined architecture. IEEE Trans. on Industrial Electronics, 2014, 61(8): 4171-4182.
- 2 Guan C, Luh PB, Michel LD, Wang YT, Friedland PB. Very short-term load forecasting: Wavelet neural networks with data pre-filtering. IEEE Trans. on Power Systems, 2013, 28(1): 30-41.
- 3 Senkal S, Ozgonenel O. Performance analysis of artificial and wavelet neural networks for short term wind speed prediction. 2013 8th International Conference on Electrical and Electronics Engineering (ELECO). 2013. 196-198.
- 4 Liu JW, Wang P, Liu H, Yang L. Time series predictive wavelet neural network control method. The 26th Control and Decision Conference (2014 CCDC). 2014. 359-364.
- 5 Yilmaz S, Oysal Y. Fuzzy wavelet neural network models for prediction and identification of dynamical systems. IEEE Trans. on Neural Networks, 2010, 21(10): 1599-1609.
- 6 Zhou B, Shi AG. Application of wavelet neural network for chaos time series prediction. 2013 Fifth International Conference on Intelligent Human-Machine Systems and Cybernetics. 2013. 259-262.
- 7 Zhang R, Chai YP, Fu XA. A network traffic prediction model based on recurrent wavelet neural network. 2012 2nd International Conference on Computer Science and Network Technology (ICCSNT). 2012. 1630-1633.
- 8 Wang J, Xia YJ. Prediction of smart substations' network traffic based on improved particle swarm wavelet neural networks. 2013 IEEE International Symposium on Industrial Electronics (ISIE). 2013. 1-7.
- 9 Gao JW, Leng ZW, Qin Y et al. Short-term traffic flow forecasting model based on wavelet neural network. Proc. of 2013 25th Control and Decision Conference (CCDC). 2013. 5081-5084.