

基于门控循环单元神经网络的大跨径斜拉桥 索力预测

郭新宇¹, 方圣恩^{1,2}

(1. 福州大学土木工程学院, 福建 福州 350108;

2. 福州大学土木工程防震减灾信息化国家地方联合工程研究中心, 福建 福州 350108)

摘要: 拉索索力的改变直接反映斜拉桥结构体系受力状态的变化, 因此索力监测对斜拉桥健康评估具有重要意义。然而现有关于索力的研究大多为索力识别, 难以做到根据历史索力数据实现对未来索力的预测。为此, 提出一种基于门控循环单元(GRU)神经网络的索力预测方法: 利用GRU神经网络对时序型数据的处理能力以及索力数据较强的序列化特性, 搭建基于GRU神经网络的索力预测框架, 该预测框架包含输入层、GRU隐藏层与输出层; 利用实桥连续采集的索应力时程数据作为训练及验证样本, 对样本进行数据切片和归一化; 搭建能够实现对该桥未来索力进行预测的GRU神经网络, 结合梯度下降优化算法进行网络计算。结果表明所提方法对不同长度的拉索都具有较好的预测效果。

关键词: 大跨径斜拉桥; 索力预测; 门控循环单元神经网络; 数据切片和归一化

中图分类号: U448.27 **文献标志码:** A **文章编号:** 1004-4523(2023)06-1480-05

DOI: 10.16385/j.cnki.issn.1004-4523.2023.06.002

引言

拉索作为大跨径斜拉桥的主要承重构件, 索力监测是桥梁健康监测系统的重要组成部分。据统计, 中国自1970年至1990年建造的30多座斜拉桥中, 有近50%的加固乃至拆除等措施与拉索力学性能劣化直接相关^[1]。因此, 准确掌握索力状态是保障桥梁安全运营和维养的重要先决条件。目前索力监测和测试主要分为直接测试法和间接测试法两类, 其中频率法作为一种操作简单、经济快捷的间接方法被广泛应用。近年来, 在最初张紧弦公式^[2]的基础上, 针对不同边界或应用条件下的索力公式也不断被提出^[3-4]。然而目前研究的重点仍是从一系列振动响应中识别不变的索力^[5]。大多数对于拉索索力的研究仍是事后的索力识别, 而不是事前的索力预测, 对斜拉桥性能监测来说存在不足。

机器学习的发展^[6]及健康监测系统的完善^[7]为索力预测研究提供了可能。自基于反向传播的BP神经网络被开发以来^[8], 针对不同领域的特定任务衍生出了基于深度学习算法的网络形式, 比如卷积神经网络^[9]、循环神经网络(Recurrent Neural Network,

RNN)以及它们的变种或组合模型等^[10]。其中RNN打破了传统神经网络对输入输出的诸多限制, 能够有效挖掘数据中的时序信息, 已成功应用于如桥梁性能劣化预测^[11]、损伤识别^[12]及传感数据重构^[13]等方面, 但尚未发现其在索力预测方面的研究。另一方面, 光纤光栅传感技术的发展, 也使高精度的索力监测有了新的突破^[14], 可以为研究提供高准确率的索力数据。

基于某实际大跨度斜拉桥的索力时程数据, 研究了基于门控循环单元(Gated Recurrent Unit, GRU)神经网络的索力预测模型。在分析了GRU网络的组成结构及运算特点后, 提出了基于GRU的索力预测模型。将完整的索力数据通过滑动窗口等操作进行预处理, 采用GRU层对索力序列的内在规律进行学习, 通过全连接层将学习到的信息综合输出为一个索力值, 实现对未来索力的预测。该方法可根据历史索力数据实现对未来索力的预测。

1 基于时序数列的GRU索力预测模型

1.1 循环神经网络

RNN作为经典前馈神经网络的拓展, 主要是用

收稿日期: 2022-05-29; 修订日期: 2022-08-20

基金项目: 国家自然科学基金资助项目(52178276); 福建省自然科学基金资助项目(2021J01601); 福州市科技计划项目(2021-Y-084)。

于处理和预测序列数据。如图 1 所示,RNN 主要由输入层 X 、隐藏层 U, V, W 以及输出层 Y 组成。但与前馈神经网络不同的是,RNN 能够记忆时间轴上的历史信息,并影响后续节点的输出。

根据上述特点,可以得到 t 时刻隐藏节点与输出节点的数学表达式^[15]:

$$s_t = f(Ux_t + Ws_{t-1}) \quad (1)$$

$$y_t = g(V*s_t) \quad (2)$$

式中 f 与 g 均为激活函数; x_t 为 t 时刻的输入; y_t 为 t 时刻的输出; s_t 为 t 时刻的隐藏层状态。若将式(1)循环代入式(2),则可进一步得到如下表达式:

$$\begin{aligned} y_t &= g(V*s_t) = \\ &= g(V*f(Ux_t + Ws_{t-1})) = \\ &= g(V*f(Ux_t + Wf(Ux_{t-1} + Ws_{t-2}))) = \\ &= g(V*f(Ux_t + Wf(Ux_{t-1} + Wf(Ux_{t-2} + \dots)))) \end{aligned} \quad (3)$$

由图 1 与式(3)可以看出,某个时刻的状态 s_{t-1} 将会与下个时刻的输入 x_t 一起被训练并形成回路,形成所谓的循环神经网络。要注意的是,每个时刻的 U, V, W 都是相同的,这种权值共享的机制不仅降低了模型的复杂度,更是其捕捉序列规律的关键。尽管 RNN 在理论上能够解决序列问题的训练,但随着序列长度的增加,基于梯度的优化算法将无法进行,这一点也可由式(3)看出,即序列长度的增加将导致梯度的计算复杂度呈指数型的增加,导致梯度消失或梯度爆炸。

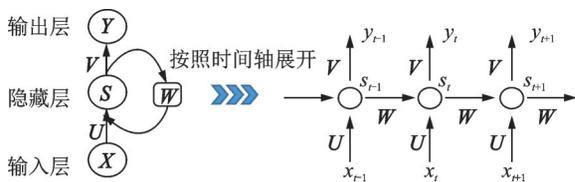


图 1 循环神经网络结构示意图
Fig. 1 Structure of a recurrent neural network

1.2 门控循环单元神经网络与索力预测

为解决上述问题,RNN 的另一种变体长短期记忆(Long Short Term Memory, LSTM)^[15]神经网络通过引入输入门、遗忘门及输出门动态调节信息流动,减少计算负担,有效解决训练过程中梯度爆炸或消失的问题。随后,又有研究将 LSTM 中的输入门与遗忘门合并,创建了结构形式更加简单的 GRU 神经网络^[16],其神经元结构如图 2 所示。图中 z_t 代表更新门,控制训练过程中要添加或舍弃的信息内容; r_t 代表重置门,控制对历史时刻信息的保留程度; h_t 为 t 时刻隐藏层单元状态, \tilde{h}_t 为更新后 t 时刻隐藏层单元状态。整个数据传递的数学表达式如下^[16]:

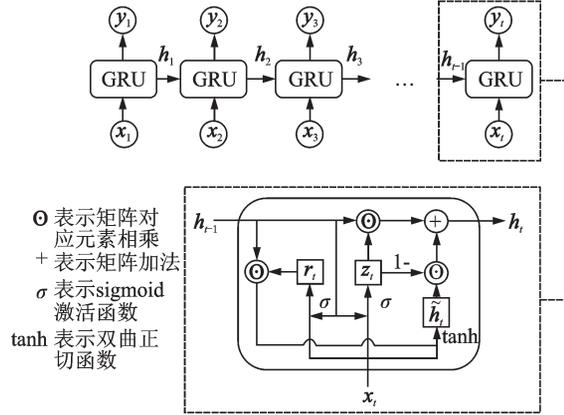


图 2 门控循环单元神经网络示意图

Fig. 2 Schematic diagram of gated recurrent unit neural networks

$$\begin{cases} h_t = (z_t \odot h_{t-1} + 1 - z_t) \odot \tilde{h}_t \\ z_t = \sigma(W_{gz}x_t + V_{gz}h_{t-1}) \\ \tilde{h}_t = \tanh(W_gx_t + V_g(r_t \odot h_{t-1})) \\ r_t = \sigma(W_{gr}x_t + V_{gr}h_{t-1}) \end{cases} \quad (4)$$

式中 $W_g, W_{gz}, W_{gr}, V_g, V_{gz}, V_{gr}$ 为各式的网络权重矩阵。

1.3 基于 GRU 神经网络的索力预测

利用 GRU 神经网络对序列数据的学习能力,提出基于 GRU 的斜拉桥索力预测框架,如图 3 所示。按照对数据处理的功能不同,可分为输入层、GRU 隐藏层与索力输出层。

输入层:由于索力的影响因素众多,想要得到较好的预测模型,需要较长一段时间的索力数据作为训练样本。为了学习序列间的前后依赖关系,需要对时序数据进行切片才能得到最终的神经网络样本。因此,在训练神经网络之前,首先需要将一段完整的索力数据进行切片、归一化处理,并根据实际

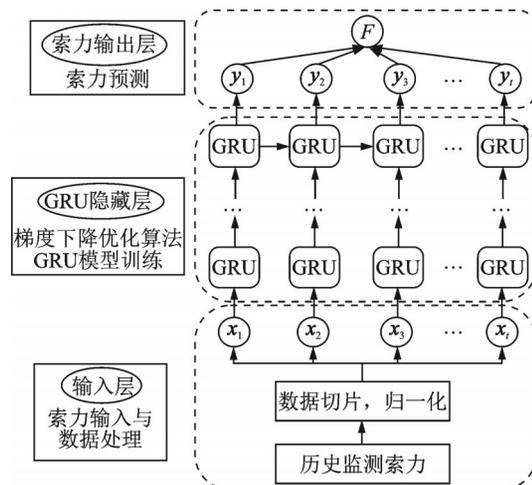


图 3 基于 GRU 网络的索力预测

Fig. 3 Cable force prediction using GRU networks

情况划分训练样本;

GRU 隐藏层: GRU 层是整个神经网络的核心,它的作用是学习索力时程数据之间的内在一般规律,从而使网络获得对未来索力预测的能力。该过程需要设定相关训练参数,如优化器、迭代次数等,同时不断调整网络拓扑,找寻比较合适的时间步长。

索力输出层: 本文研究的是索力预测问题,最终输出结果为基于已有数据的下一时间节点上的索力值,而 GRU 隐藏层输出的是对各输入时间节点上的预测结果,并非未来索力预测的期望值。因此,需要通过全连接层进一步对 GRU 层的输出结果进行综合,需要在神经网络的末端添加一层全连接隐藏层,实现对 GRU 层输出结果的综合,并将 GRU 层的输出结果作为全连接层的输入层数据,再设定与之相对应的索力标签作为整个神经网络的索力输出层,便可以实现对未来索力的预测。

2 工程实例

2.1 工程概况

如图 4 所示,本文以某实际大跨斜拉桥为研究对象,验证所提方法的可行性^[17],斜拉桥主跨长 260 m,两边跨均为 99.85 m+26.55 m。该桥于 1987 年 12 月通车,由于超载等原因,在运营 19 年后发现严重损伤,2005 年至 2007 年间进行了一系列加固维护措施。对主梁进行了重铸,并在其他梁段表面粘贴了碳纤维布进行加固,同时更换了所有拉索。在维修过程中,安装了一套完整的结构健康监测系统,其中也包括了对部分索力的监控。索力测量通过在拉索中嵌入光纤光栅传感器来记录应力时程,进而转换为拉索索力。

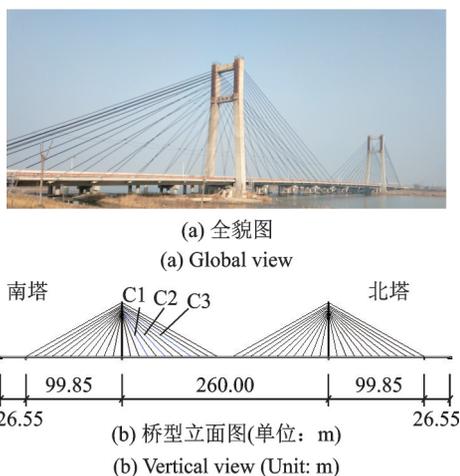


图 4 某实际斜拉桥
Fig. 4 An actual cable-stayed bridge

2.2 数据预处理与 GRU 搭建

本文选取该桥 1 周(2008 年 1 月 10 日 12:00—2008 年 1 月 17 日 12:00)内具有代表性的 3 根拉索的索应力实测数据。如图 4(b)所示,C1,C2 及 C3 分别代表了短索、中长索及长索。索力的采样频率为 2.5 Hz,考虑到一般情况下短时间内的索力变化较小,因此先对数据进行压缩,取 10 min 内索力数据的平均值为一个样本。然后选取了上述时间内连续采集的 1000 个样本来验证方法的可行性,其中前 700 个用作训练样本,后 300 个作为验证样本。

由前文和图 5 可知,待训练及预测样本实际为该桥在一周内连续不间断采集的数据。根据图 3 所示的索力预测流程,首先需要对这一段索力数据进行切片以划分数据集。在处理时间序列问题上,定长滑动窗口是一种常用的数据分割手段^[18],通过滑动窗口可将原本完整的时序数列划分为若干子序列,作为神经网络的数据集。需要注意的是,所设定的滑动窗口长度表示期望采用多长时间的历史数据实现对未来索力的预测。若滑动窗口长度过短,则不能充分学习历史索力数据的变化趋势;反之,则会增加很多冗余信息,加重网络训练负担。如图 5 所示,本算例通过 50 min 时长的 5 个索力均值数据 X 去预测未来 10 min 的索力均值 Y ,故将滑动窗口的时间步长设定为 5,即全部样本在时间轴上的连续 5 个索力数据组成一组样本的输入层,然后取窗口下个索力值作为当前窗口的标签。

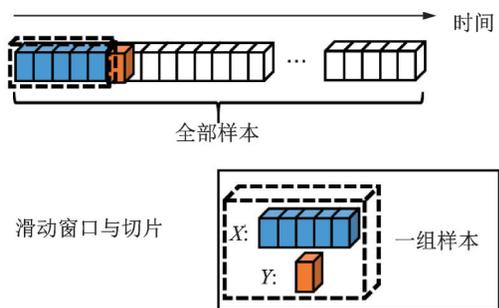


图 5 滑动窗口与数据切片

Fig. 5 Sliding window and data slices

划分好训练样本后,便可开始该桥 GRU 神经网络的搭建。采用了基于 Python 语言的 PyTorch 框架^[19]。在网络训练之前,通常还需对数据进行归一化,其目的是使各特征具有相同的度量尺度,以便于神经网络的快速收敛。本文对样本数据处理所用的归一化公式如下:

$$\tilde{x}_i = \frac{x_i - X_{\min}}{X_{\max} - X_{\min}} \quad (5)$$

式中 x_i 为样本值; X_{\min} 为样本中最小值; X_{\max} 代表样本中最大值; \tilde{x}_i 代表归一化后的值。网络训练采

用了可以自适应调节学习率的Adam优化器^[20],并通过最小化均方误差损失函数实现对GRU模型的迭代训练。经过多次调试后,确定输入层的节点数为5个,对应上述时间步长为5的5个索力值;GRU隐藏层为1层,各时间节点上的神经元个数为64个;输出层节点为1,对应了预测索力值,将GRU层的64个神经元节点与这1个输出节点通过线性的全连接层相连接,便完成了整个网络的搭建。

2.3 预测结果与分析

GRU网络模型预测准确度采用整体平均误差作为评价指标,整体平均误差是所有样本预测误差百分比的平均值,用于评价数据整体误差程度:

$$E = \frac{1}{N} \sum_{i=1}^N \left| \frac{m_i - m_i^*}{m_i^*} \right| \times 100\% \quad (6)$$

式中 N 为样本个数; m_i^* 为第 i 个样本的真实值; m_i 为第 i 个样本的预测值。

300个验证样本中第1~5个样本作为输入层数

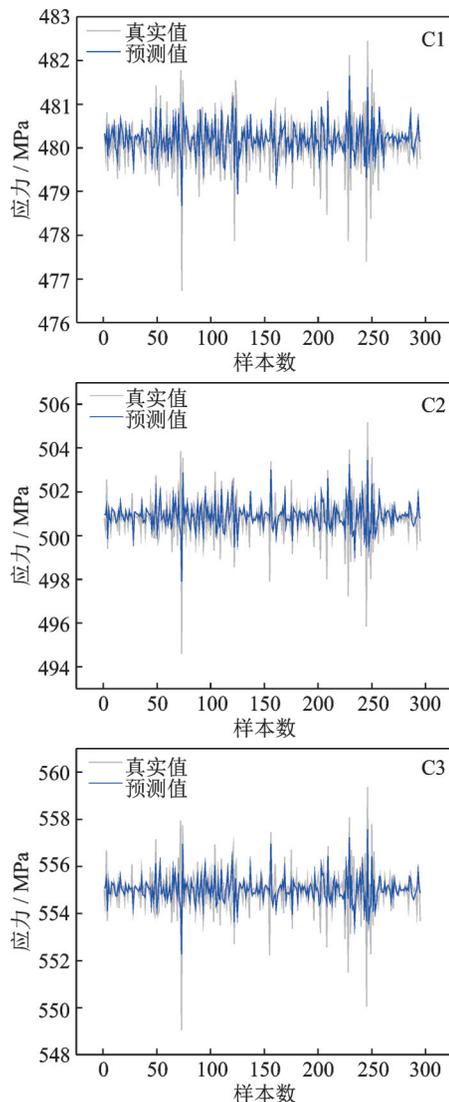


图6 拉索应力预测结果

Fig. 6 Cable stress prediction results

据时,网络输出对应第6个时刻的值,可与第6个验证样本对比,以此类推,最终得到295个预测值,如图6所示。C1~C3号拉索的预测索应力平均误差分别为0.072%,0.104%及0.090%,说明GRU神经网络能够很好地预测索力的发展趋势。另一方面,3组预测索力的最大误差分别为0.443%,0.763%及0.670%,对应于图6中C1,C2及C3号索的第228,72及72号样本值。需要指出的是,该最大误差值实际也很小,说明所提出的索力预测方法效果良好。

3 结 论

以某实际大跨斜拉桥为分析对象,提出了一种基于GRU神经网络的索力预测方法,并基于该桥3根不同长度拉索一周时间连续采集的索应力数据验证了所提方法的可行性并得到以下结论:

(1)GRU神经网络对桥梁健康监测获取的时序型数据具备良好的数据处理能力,可以利用拉索历史数据实现对未来索力的预测。对于实际斜拉桥上的不同长度拉索均可以获得较好的预测效果,平均误差及最大误差均小于1%。

(2)对实桥监测的庞大数据量进行预处理,如本文采用的压缩、数据切片和归一化,有利于提高GRU网络的训练和预测准确度。

(3)在GRU神经网络的末端添加一层全连接隐藏层,可实现对GRU层输出结果的综合,有利于获取准确的预测结果。

参考文献:

- [1] Li S L, Wei S Y, Bao Y Q, et al. Condition assessment of cables by pattern recognition of vehicle-induced cable tension ratio[J]. *Engineering Structures*, 2018, 155: 1-15.
- [2] Fang Z, Wang J Q. Practical formula for cable tension estimation by vibration method[J]. *Journal of Bridge Engineering*, 2012, 17(1): 161-164.
- [3] 唐盛华, 方志, 杨索. 考虑边界条件的频率法测索力实用公式[J]. *湖南大学学报(自然科学版)*, 2012, 39(8): 7-13. Tang Shenghua, Fang Zhi, Yang Suo. Practical formula for the estimation of cable tension in frequency method considering the effects of boundary conditions[J]. *Journal of Hunan University (Natural Sciences)*, 2012, 39(8): 7-13.
- [4] Rango B J, Serralunga F J, Piovan M T, et al. Identification of the tension force in cables with insulators[J]. *Meccanica*, 2019, 54: 33-46.
- [5] Xue S L, Shen R L. Real time cable force identification by short time sparse time domain algorithm with half wave[J]. *Measurement*, 2020, 152: 107355.

- [6] Avci O, Abdeljaber O, Kiranyaz S, et al. A review of vibration-based damage detection in civil structures: from traditional methods to machine learning and deep learning applications[J]. *Mechanical Systems and Signal Processing*, 2021, 147: 107077.
- [7] Li S L, Li H, Liu Y, et al. SMC structural health monitoring benchmark problem using monitored data from an actual cable-stayed bridge[J]. *Structural Control and Health Monitoring*, 2014, 21(2): 156-172.
- [8] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back-propagating errors[J]. *Nature*, 1986, 323: 533-536.
- [9] Kawakatsu T, Aihara K, Takasu A, et al. Deep sensing approach to single-sensor vehicle weighing system on bridges[J]. *IEEE Sensors Journal*, 2019, 19: 243-256.
- [10] Yue Z X, Ding Y L, Zhao H W, et al. Mechanics-Guided optimization of an LSTM network for Real-Time modeling of Temperature-Induced deflection of a Cable-Stayed bridge[J]. *Engineering Structures*, 2022, 252: 113619.
- [11] Zhu Jinsong, Wang Yanlei. Feature selection and deep learning for deterioration prediction of the bridges[J]. *Journal of Performance of Constructed Facilities*, 2021, 35(6): 1-13.
- [12] Moon S, Chung S, Chi S. Bridge damage recognition from inspection reports using NER based on recurrent neural network with active learning[J]. *Journal of Performance of Constructed Facilities*, 2020, 34(6): 04020119.
- [13] Jeong S, Ferguson M, Hou R, et al. Sensor data reconstruction using bidirectional recurrent neural network with application to bridge monitoring[J]. *Advanced Engineering Informatics*, 2019, 42: 100991.
- [14] Li Hui, Ou Jinping, Zhou Zhi. Applications of optical fibre Bragg gratings sensing technology-based smart stay cables[J]. *Optics and Lasers in Engineering*, 2009, 47(10): 1077-1084.
- [15] Hochreiter S, Schmidhuber J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [16] Chung J, Gulcehre C, Cho K H, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling[J]. *arXiv preprint arXiv: 1412.3555*, 2014.
- [17] Zhou W S, Li S L, Li H. Damage detection for SMC benchmark problem: a subspace-based approach[J]. *International Journal of Structural Stability and Dynamics*, 2016, 16(4): 1640025.
- [18] 赵志宏, 李晴, 李乐豪, 等. LSTM Encoder-Decoder 方法预测设备剩余使用寿命[J]. *交通运输工程学报*, 2021, 21(6): 269-277.
- Zhao Zhihong, Li Qing, Li Lehao, et al. Remaining useful life prediction for equipment based on LSTM encoder-decoder method[J]. *Journal of Traffic and Transportation Engineering*, 2021, 21(6): 269-277.
- [19] Imambi S, Prakash K B, Kanagachidambaresan G R. *PyTorch[M]// Programming with TensorFlow*. Cham: Springer, 2021: 87-104.
- [20] Kingma D, Ba J. Adam: a method for stochastic optimization[J]. *arXiv preprint arXiv: 1412.6980*, 2014.

Cable force prediction of long-span cable-stayed bridge based on gated recurrent unit neural network

GUO Xin-yu¹, FANG Sheng-en^{1,2}

(1.School of Civil Engineering, Fuzhou University, Fuzhou 350108, China; 2.National and Local Joint Engineering Center for Seismic and Disaster and Informatization of Civil Engineering, Fuzhou University, Fuzhou 350108, China)

Abstract: The variations of cable forces directly reflect the internal mechanical states of a cable-tayed bridge. Therefore, the monitoring of stayed cables is important for health evaluation of the cable-stayed bridge. However, most of the existing research on stayed cables focuses on force identification. The prediction of future forces based on the historical data is still difficult to achieve. Therefore, this study proposes a cable force prediction method using the gated recurrent unit (GRU) neural network. The application framework based on the GRU neural network is established by using the processing ability of the GRU neural network to time series data, taking into account the strong serialization characteristics of cable force data. The network construction includes the input layer, the GRU hidden layer and the output layer. The cable stress time history data of a real-world cable-stayed bridge is collected as the training and validation samples for the GRU neural network. Data slices and normalization are applied to the sampling process. The GRU neural network is successfully established to predict future cable force of this bridge. The Network calculation is performed using a gradient descent optimization algorithm. The analysis results show that the proposed method can provide satisfactory predictions for cables of different lengths.

Key words: long-span cable-stayed bridge; cable force prediction; gated recurrent unit neural network; data slices and normalization

作者简介: 郭新宇(1993—),男,博士研究生。E-mail: 200510002@fzu.edu.cn。

通讯作者: 方圣恩(1980—),男,博士,教授,博士生导师。E-mail: shengen.fang@fzu.edu.cn。