

# 沥青混合料的循环神经网络本构模型构建探讨

唐由之<sup>1</sup>, 阳恩慧<sup>2</sup>, 徐加秋<sup>2</sup>, 罗浩原<sup>2</sup>, 邱延峻<sup>2</sup>

(1. 西南交通大学 唐山研究生院, 河北 唐山 063000; 2. 西南交通大学 土木工程学院)

**摘要:** 由于沥青材料高分子成分的复杂性、温度的敏感性等原因, 沥青混合料的本构关系一直是未能很好解决的工程问题。该文首先在 Python 中使用 Tensorflow 进行了循环神经网络的搭建, 并用 Boltzmann 叠加原理生成了训练循环神经网络所需要的数据。训练结果表明: 循环神经网络高度拟合了 Boltzmann 叠加原理的计算结果, 初步验证了采用循环神经网络对沥青混合料进行本构分析的可行性。运用迁移学习理论仅用一组数据再次精确拟合了 Boltzmann 叠加原理的计算结果, 表明在成功训练循环神经网络的基础上将能够用少量数据完成对其他沥青混合料的本构分析。

**关键词:** 沥青混合料; 神经网络; 本构关系; 模型构建

## 1 引言

沥青路面以平整度高、行车舒适性好、噪音低等多种优点被广泛应用于公路、城市道路及机场等交通设施的建设中。随着中国经济的发展, 公路运输量、重载交通量日益增长, 路面破坏日趋严重。进行沥青混合料本构模型的研究, 掌握其变形规律, 对改善沥青混合料的设计, 提升其路用性能具有非常重要的意义。

沥青混合料是一种典型的黏弹塑性材料, 其具有复杂的本构关系。朱浩然基于不可逆热力学理论提出一种沥青混合料黏弹塑性本构模型。分析了沥青混合料在三轴蠕变下的应力应变关系。结果表明试验最大应力值和预测最大应力值接近, 但其并未良好反映沥青混合料压缩过程中应力与应变之间的变化规律; Huang C W 等用 Schapery 非线性黏弹性模型表示沥青混合料的黏弹性形变, 用 Drucker-Prager 模型表示黏塑性形变。进行了单轴蠕变恢复试验, 结果表明: Drucker-Prager 模型在较高应力下未能良好预测塑性形变。由于该模型是由两种本构模型叠加而成的, 意味着该模型会使用更多的参数, 导致模型的复杂化; Pasetto M 基于非黏性塑性理论和硬化准则提出一种塑性流动准则, 将其运用于沥青混合料黏弹塑性本构模型上。单轴蠕变恢复试验表明, 该模型在高应力下表现较差。所以使用数值方法对沥青混合料进行本构

分析的适用范围较小, 分析过程也较复杂。

自 20 世纪 80 年代神经网络成为人工智能领域研究的热点以来, 它为当今社会的许多方面提供了动力。从图像识别到文本翻译, 再到 DNA 分析, 神经网络越来越多地出现在人们身边的各个角落。焦李成介绍了神经网络的发展过程和研究现状, 并指出了神经网络未来的研究重点; Lecun Y 对常用的 BP 神经网络 (BP)、卷积神经网络 (CNN)、循环神经网络 (RNN) 的工作原理及应用进行了逐一介绍。神经网络已在模拟金属、岩石等材料的本构模型上取得了良好的效果; Ji G L 用 BP 神经网络对 Aermet100 合金的本构模型进行模拟, 其精度高于 Arrhenius 本构模型; 李克钢用 BP 神经网络对岩石在干湿循环作用下的本构模型进行模拟, 结果表明神经网络可以很好地模拟岩石在不同干湿循环作用下的应力-应变关系, 避免了传统本构模型中对一些参数的复杂求解。

若神经网络对沥青混合料本构关系的模拟能达到较高精度, 将免去以往沥青混合料本构关系的复杂分析。只需要告诉神经网络沥青混合料每个时刻的应力与应变, 神经网络就会自动分析应力与应变之间的关系。在已完成训练的神经网络里再运用迁移学习理论分析其他沥青混合料的本构关系, 将尽可能地降低试验负担。因此, 该文探讨将循环神经网络运用于沥青混合料本构分析的可行性。

## 2 循环神经网络基本原理与方法

### 2.1 循环神经网络基本工作原理

由于沥青混合料是一种黏弹塑性材料,其蠕变和应力松弛现象非常明显,导致沥青混合料的本构关系严重受应力历史的影响。由于沥青混合料这种松弛蠕变特性,循环神经网络将比其他类型的神经网络更适合于分析沥青混合料的本构关系。

相比 BP 神经网络(BP)和卷积神经网络(CNN),循环神经网络(RNN)更擅长处理序列模型,因为 BP 和 CNN 的当前输出不会受历史输出的影响,而 RNN 会根据历史输出和当前输入决定当前输出,这让 RNN 具有记忆,使得 RNN 常应用于语言识别、机器翻译、股市分析等数据之间有前后逻辑关系的领域。RNN 的工作原理如图 1 所示,首先 RNN 的神经初始状态为  $a^{(0)}$ ,RNN 神经单元接收到输入  $x^{(1)}$  后根据  $a^{(0)}$  和  $x^{(1)}$  产生输出  $y^{(1)}$  和新的神经状态  $a^{(1)}$ ,之后 RNN 神经单元再根据  $a^{(1)}$  和  $x^{(2)}$  产生  $y^{(2)}$  和  $a^{(2)}$ ,如此循环往复。循环神经网络自始至终只有一个 RNN 神经单元在处理信息,神经单元每次接受到的输入  $x^{(n)}$  和神经状态  $a^{(n-1)}$  都不同。

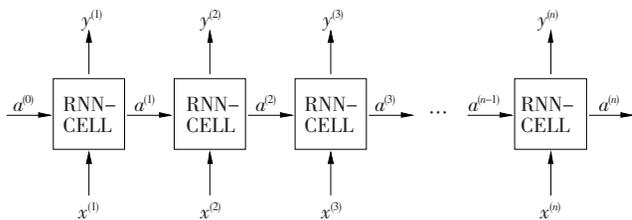


图 1 循环神经网络工作原理

### 2.2 数据输入与输出

Boltzmann 叠加原理是黏弹力学中最基本的原理之一,比较适合用于描述沥青混合料的复杂松弛及蠕变行为。所以该文将用 Boltzmann 叠加原理来探讨 RNN 模拟沥青本构关系的可行性。

Boltzmann 叠加原理有以下卷积式:

$$\varepsilon(t) = \sum_{i=1}^n \sigma_n J(t - t_n) \quad (1)$$

式中: $\varepsilon$  为应变; $\sigma_n = \sigma_t - \sigma_{t-1}$  为应力增量; $J$  为蠕变柔量; $t$  为时间; $t_n$  为应力增量  $\sigma_n$  施加的时刻。

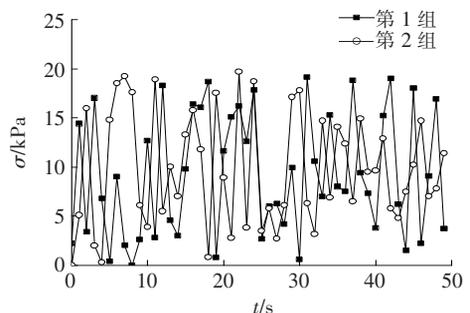
由式(1)可知:该叠加原理的应变计算结果跟每个时刻的应力大小都有关。

拟定蠕变柔量:

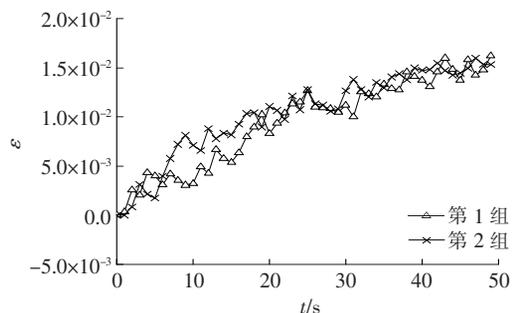
$$J(t) = \frac{1}{1586 + \frac{11375164}{\left(1 + \frac{t}{0.0003}\right)^{0.65}}} \quad (2)$$

式(2)可描述沥青混合料在单位恒力作用下应变随时间的改变量。

假定要模拟沥青混合料 0~49 s 的本构关系曲线。在 Excel 中从 0~49 s 用 Randbetween 函数每一秒随机生成幅值为 20 kPa 的正应力  $\sigma$ ,共 60 组。再进行式(1)的卷积运算产生应变  $\varepsilon$ 。应力  $\sigma$ 、应变  $\varepsilon$  随时间的变化曲线如图 2 所示(其中两组)。每秒的应力  $\sigma$  将作为循环神经网络的输入,应变  $\varepsilon$  为目标输出。通过训练,循环神经网络输出的预测应变  $\hat{\varepsilon}$  将不断逼近目标应变  $\varepsilon$ 。



(a) 随机荷载  $\sigma$



(b) 应变  $\varepsilon$

图 2 随机荷载  $\sigma$  与之产生的应变  $\varepsilon$  随时间的变化曲线

### 2.3 循环神经网络搭建

在 Python 中使用 Tensorflow 进行了神经网络的搭建,其结构如图 3 所示。这里使用 LSTM(Long Short-Term Memory)神经元。LSTM 是在 RNN 神经元的基础上进行了改进,克服了 RNN 神经元的缺陷,解决了其训练过程中梯度爆炸与梯度消失的问题,从而 LSTM 比 RNN 能记住更长的序列。

循环神经网络也可以像 BP 神经网络一样通过增加神经网络的层数来提高神经网络的表达能力。但由于循环神经网络通常需要更长的时间来训练,从而导致其最大层数一般小于或等于 3 层,这里采用了两层的 LSTM 神经网络。

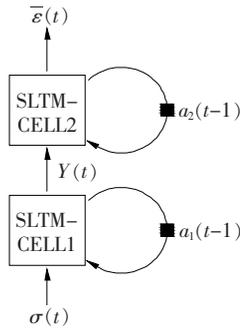


图3 循环神经网络结构

2.4 数据预处理

在正式开始训练前,需要对数据用以下公式进行归一化:

$$\sigma' = \frac{\sigma - \text{mean}(\sigma)}{\text{std}(\sigma)} \quad (3)$$

$$\epsilon' = \frac{\epsilon - \text{mean}(\epsilon)}{\text{std}(\epsilon)} \quad (4)$$

式中: $\sigma$ 、 $\epsilon$  分别为应力、目标应变; $\sigma'$ 、 $\epsilon'$  分别为归一化后的应力、目标应变; $\text{mean}(\sigma)$ 、 $\text{mean}(\epsilon)$  分别为应力、目标应变的平均值; $\text{std}(\sigma)$ 、 $\text{std}(\epsilon)$  分别为应力、目标应变的标准差。

进行归一化的目的是消除数据量纲的影响,让神经网络的输入和输出在相同的幅度内变化,对提高神

经网络学习的速度有非常重要的作用。

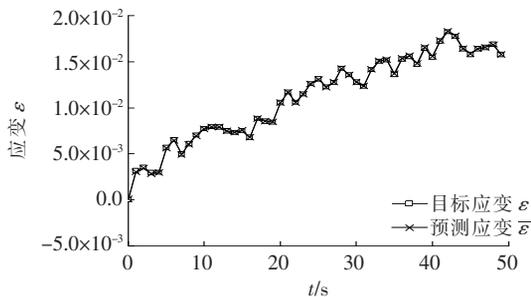
3 典型案例分析

3.1 神经网络训练

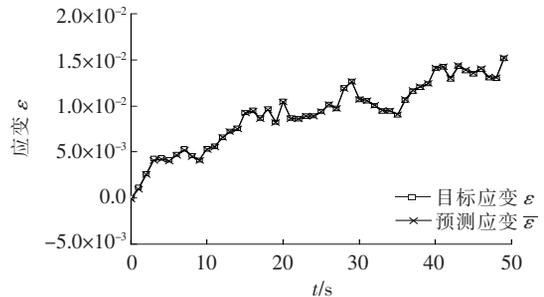
完成归一化后,随机使用 50 组数据进行训练,剩下的 10 组数据用于测试。神经网络的学习率是一个控制输出值向目标输出值逼近快慢的参数。通常在神经网络训练初期采用较大的学习率使神经网络的输出值快速向目标输出值逼近。然后采用较小的学习率来提高最终的拟合程度。参与训练的 50 组数据先后在应变  $\epsilon$  为  $1 \times 10^{-3}$  的学习率下循环 1 000 次、 $1 \times 10^{-4}$  下循环 2 000 次、 $1 \times 10^{-5}$  下循环 5 000 次、 $1 \times 10^{-6}$  下循环 10 000 次。最后使损失函数的计算值降低至 0.000 01。损失函数是描述神经网络的输出值与目标输出值拟合程度的函数,损失函数的计算值越小说明神经网络的输出值与目标输出值拟合程度越高。

完成训练后 10 组未参加训练的数据用于测试,将神经网络的输出结果进行反归一化处理得到预测应变  $\bar{\epsilon}$ , 然后与目标应变  $\epsilon$  进行对比。其中 4 组数据的拟合图见图 4。

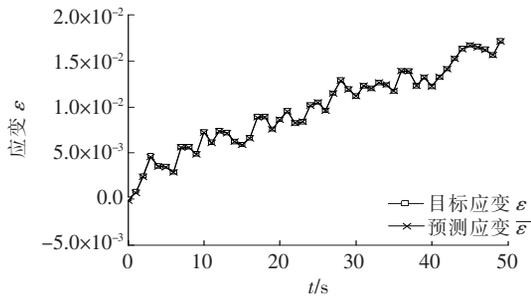
由图4可以看出:循环神经网络预测应变  $\bar{\epsilon}$  与目



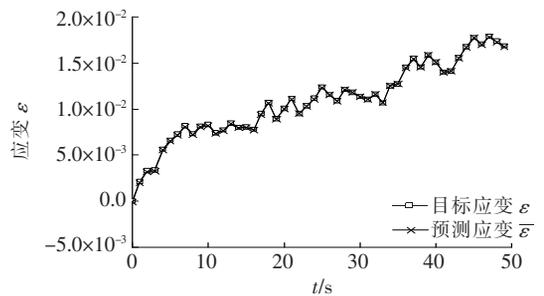
(a) 第1组



(b) 第2组



(c) 第3组



(d) 第4组

图4 4组测试数据拟合结果图

标应变  $\epsilon$  拟合度非常高,两条线几乎重合。

表 1 为 10 组数据相关系数测试结果,由表 1 可知:所有组的相关系数均大于 0.999,说明预测应变  $\bar{\epsilon}$

与目标应变  $\epsilon$  十分接近。证明循环神经网络有强大的非线性拟合能力,初步验证了循环神经网络用于沥青混合料本构分析的可行性。

表 1 数据拟合结果相关系数

组序	相关系数 $R^2$	组序	相关系数 $R^2$
1	0.999 8	6	0.999 7
2	0.999 5	7	0.999 8
3	0.999 8	8	0.999 7
4	0.999 7	9	0.999 7
5	0.999 8	10	0.999 6

### 3.2 迁移学习

训练一个神经网络,通常需要一定量的数据,花费大量资源用神经网络只为模拟一种沥青混合料的本构关系是不经济的。迁移学习的目的在已经完成训练的神经网络基础上,用少量的数据对另外的沥青混合本构关系进行模拟。Long M 对迁移学习的可行性进行了详细的论述,指出当数据之间存在相似性,则它们在

神经网络中就可以共享一些参数,从而用少量的数据完成迁移学习。

在迁移学习任务中改变了沥青的蠕变柔量:

$$J(t) = \frac{1}{700 + \frac{12\ 099\ 300}{\left(1 + \frac{t}{0.001\ 8}\right)^{0.62}}} \quad (5)$$

与上文同样的方式运用 Boltzmann 叠加原理生成了 60 组数据。对数据进行归一化后在已经训练好的循环神经网络里用 1 组数据进行迁移学习。为了验证迁移学习的效果,这 1 组数据在一个全新的循环神经网络中进行了训练,其输出的预测结果将作为对照。

用 59 组未参加训练的数据分别对这两个循环神经网络进行了测试,其中 4 组数据的最终拟合结果见图 5。

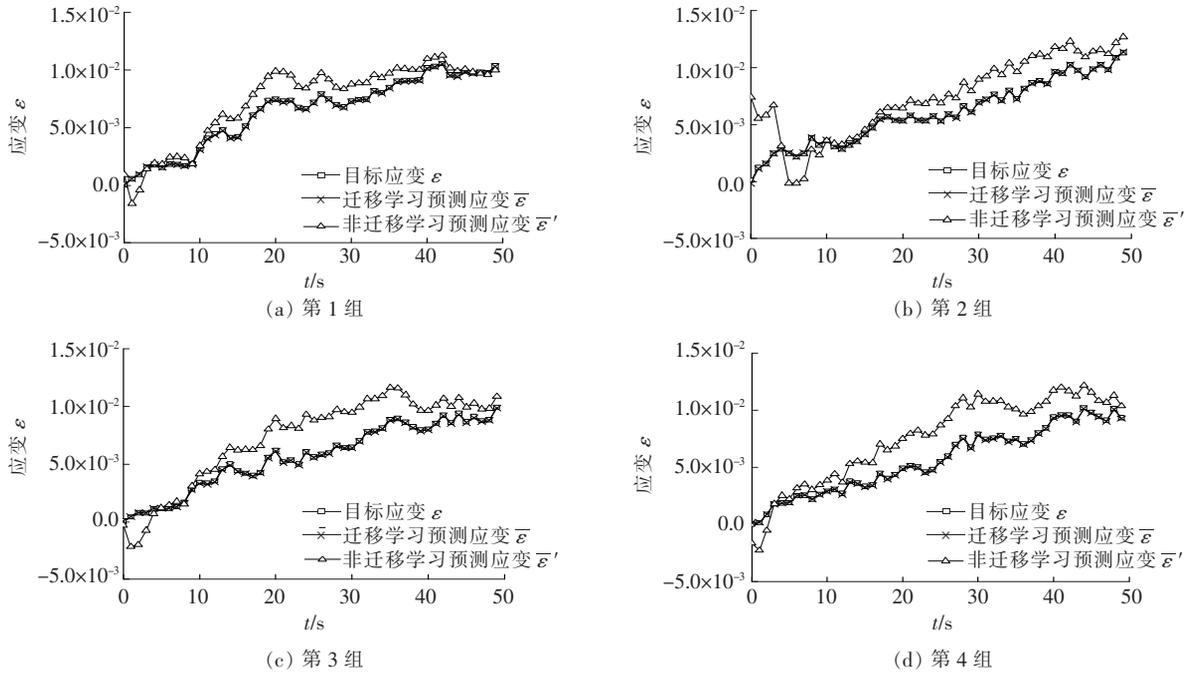


图 5 迁移学习拟合结果图

由图 5 可见:迁移学习循环神经网络的预测应变 $\bar{\varepsilon}$ 与目标应变 $\varepsilon$ 拟合程度非常高,而非迁移学习循环神经网络的预测应变 $\varepsilon'$ 与目标应变 $\varepsilon$ 拟合程度较低。

表 2 为目标应变与迁移学习预测应变和非迁移学习预测应变的相关系数。表 2 说明运用迁移学习理论对沥青混合料进行本构分析存在可行性,有利于降低试验负担。而非迁移学习循环神经网络的相关系数较低,说明重新训练一个神经网络需要足够的数

据。序列模型的特性用于模拟应力对沥青混合料的影响。用 Boltzmann 叠加原理生成了训练循环神经网络所需要的数据。简要介绍了循环神经网络搭建与训练过程。根据循环神经网络训练和迁移学习的结果,可得如下结论:

(1) 经过训练的循环神经网络模型能很好地还原 Boltzmann 叠加原理的计算结果,其相关系数大于 0.999,有非常高的精度,具有模拟沥青混合料本构关系的能力。

(2) 在循环神经网络完成训练的基础上仅用一组数据进行了迁移学习,并取得了良好的效果。运用迁移学习理论能用少量数据对其他沥青混合料的本构关

## 4 结论

分析了循环神经网络的工作原理,将其善于处理

表2 迁移学习拟合结果相关系数

组序	相关系数 $R^2$		组序	相关系数 $R^2$	
	迁移学习	非迁移学习		迁移学习	非迁移学习
1	0.999 8	0.811 8	31	0.999 8	0.712 7
2	0.999 4	0.821 9	32	0.999 4	0.254 5
3	0.999 1	0.838 6	33	0.999 6	0.714 7
4	0.999 2	0.842 3	34	0.999 8	0.846 4
5	0.999 8	0.871 3	35	0.999 4	0.356 9
6	0.999 6	0.590 6	36	0.999 5	0.759 8
7	0.999 7	0.409 5	37	0.999 6	0.595 4
8	0.999 5	0.297 4	38	0.999 4	0.554 5
9	0.999 8	0.947 3	39	0.999 8	0.205 6
10	0.999 3	0.773 4	40	0.999 6	0.091 5
11	0.999 8	0.813 2	41	0.999 4	0.861 4
12	0.999 4	0.349 7	42	0.999 6	0.839 5
13	0.999 6	0.614 9	43	0.999 5	0.725 2
14	0.999 8	0.767 1	44	0.999 6	0.839 4
15	0.999 9	0.705 9	45	0.999 7	0.771 9
16	0.999 7	0.843 1	46	0.999 6	0.653 4
17	0.999 6	0.675 3	47	0.999 4	0.339 0
18	0.999 5	0.656 6	48	0.999 7	0.709 0
19	0.999 7	0.710 9	49	0.999 9	0.737 7
20	0.999 8	0.958 2	50	0.999 7	0.507 9
21	0.999 6	0.890 0	51	0.999 8	0.915 1
22	0.999 7	0.325 6	52	0.999 8	0.886 0
23	0.999 8	0.460 5	53	0.999 6	0.923 7
24	0.999 6	0.978 0	54	0.999	0.488 4
25	0.999 7	0.733 9	55	0.999 4	0.840 4
26	0.999 8	0.484 4	56	0.999 9	0.529 2
27	0.999 9	0.317 4	57	0.999 7	0.789 7
28	0.999 5	0.635 0	58	0.999 6	0.692 9
29	0.999 7	0.440 6	59	0.999 5	0.880 2
30	0.999 7	0.375 9			

系进行模拟。

(3) 若成功构建沥青混合料的循环神经网络本构模型并运用迁移学习理论,将提升沥青混合料本构分析的精度,同时大规模降低计算与试验负担,具有一定的研究价值。

## 参考文献:

- [1] 佟禹,郭朝阳,李振,等.一种常温沥青及沥青混合料性能研究[J].中外公路,2018(1).
- [2] 黎霞,刘金凤,曾璐璐.温拌橡胶沥青混合料双面剪切疲劳试验研究[J].中外公路,2017(6).
- [3] 叶永.沥青混合料粘弹塑性本构模型的实验研究[D].华中科技大学博士学位论文,2009.
- [4] 朱浩然,孙璐,朱耀庭.基于热力学的沥青混合料粘弹-黏塑性损伤本构模型[J].中国公路学报,2013(3).
- [5] Huang C W, Abu Al-Rub R K, Masad E A, et al. Numerical Implementation and Validation of a Nonlinear Viscoelastic and Viscoplastic Model for Asphalt Mixes [J]. International Journal of Pavement Engineering, 2011, 12(4):433-447.
- [6] Pasetto M, Baldo N. Numerical Visco-Elastoplastic Constitutive Modelization of Creep Recovery Tests on Hot Mix Asphalt [J]. Journal of Traffic & Transportation Engineering, 2016, 3(5):390-397.
- [7] 焦李成,杨淑媛,刘芳,等.神经网络七十年:回顾与展望 [J].计算机学报,2016(8).
- [8] Lecun Y, Bengio Y, Hinton G. Deep Learning [J]. Nature, 2015, 521(7 553):436-444.
- [9] Ji GL, Li F G, Li Q H, et al. Comparative Study on Arrhenius-Type Constitutive Model and Artificial Neural Network Model to Predict High-Temperature Deformation Behaviour in Aermet100 Steel [J]. Materials Science & Engineering: A (Structural Materials: Properties, Microstructure and Processing), 2011, 528(13-14):4 774-4 782.
- [10] 李克钢,郑东普,黄维辉.干湿循环作用下砂岩力学特性及其本构模型的神经网络模拟 [J].岩土力学, 2013 (S2).
- [11] 张肖宁. 沥青与沥青混合料的粘弹力学原理及应用 [M]. 北京:人民交通出版社,2006.
- [12] Sak H, Senior A, Beaufays F. Long Short-Term Memory Based Recurrent Neural Network Architectures for Large Vocabulary Speech Recognition [C]. Annual Conference of the International Speech Communication Association, 2014.
- [13] Ioffe S, Szegedy C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift [C]. International Conference on International Conference on Machine Learning, 2015.
- [14] Long M, Cao Y, Wang J, et al. Learning Transferable Features with Deep Adaptation Networks [C]. International Conference on Machine Learning, 2015.