arXiv:2301.03439v1 [eess.SY] 9 Jan 2023

用于交通状态估计的广义自适应平滑神经网络架构

Chuhan Yang*[1]、Ambadipudi Sai Venkata Ramana[2]，和Saif Eddin Jabari[1,2]

[1]纽约大学坦登工程学院，美国纽约州布鲁克林[2]纽约大学阿布扎比分校，阿联酋阿布扎比萨迪亚特岛，邮政信箱129188。

摘要。 自适应平滑方法（ASM）是一种用于交通状态估计的标准数据驱动技术。ASM 包含一些自由参数，实际应用中通常凭直觉将其设定为一些普遍接受的取值。然而，我们注意到，凭启发式方法选取的数值往往会导致 ASM 得出不符合物理规律的预测。在本研究中，我们提出了一种基于 ASM 的神经网络，通过从道路传感器的稀疏数据中学习，自动调整这些参数。我们将其称为自适应平滑神经网络（ASNN）。我们还提出了一种改进型 ASNN（MASNN），通过集成平均使其成为一种强学习器。我们在两个真实世界数据集上对 ASNN 和 MASNN 进行了训练和测试。实验结果表明，ASNN 和 MASNN 的表现优于传统 ASM。

1 引言

流量和车辆平均速度等宏观交通状态变量，是衡量交通网络中道路路段交通状况的关键指标，在交通运输规划与管理中发挥着重要作用。由于技术和经济条件有限，交通状态变量无法在所有地点直接测量，因此必须根据含噪且不完整的交通数据进行估计，准确估计交通状态变量也因此受到广泛关注。从部分观测到的交通数据中推断交通状态变量的过程称为交通状态估计（TSE），一直是系统研究的重要课题。通常，交通数据来自多种异构数据源，包括由固定在基础设施中的传感器采集的固定式检测器数据（SDD），以及由GPS设备和手机采集的浮动车数据（FCD）。

所关注的方法通常分为模型驱动方法和数据驱动方法 [15]。Lighthill-Whitham-Richards（LWR）模型等模型驱动方法 [11], [13], Aw-Rascle-Zhang（ARZ）模型 [1] 采用双曲守恒律与动态测量模型相结合的方式来估计交通状态。数据驱动方法则使用监督学习算法来预测交通状态。一个广泛用于估计交通状态的数据驱动方法是自适应平滑方法（ASM） [19]。TSE 中使用的其他数据驱动方法包括深度神经网络 [8], [2], [18], 支持向量回归 [22]和矩阵分解 [10]。

ASM因实现简单、计算成本低而广泛用于交通状态估计。它本质上是一种插值方法，通过对离散交通数据应用非线性低通滤波器，重建时空交通状态，并将缺失的交通状态变量表示为空间和时间上的平滑函数。具体而言，ASM考虑了交通流扰动的传播特性：在自由流状态下扰动向下游传播，在拥堵状态下则向上游传播，且具有特征恒定速度；然后利用一个自适应权重因子，将交通状态估计为两个线性各向异性低通滤波器的叠加。

ASM 的一个主要缺点是该方法包含自由参数。理想情况下，应通过校准使自由参数与真实数据相匹配。然而，在大多数情况下，可用的真实数据过于稀疏且分散，传统拟合方法的效率并不高。这导致该方法得出的交通状态预测不符合物理规律。

为解决这一不足，我们开发了一种基于 ASM 的神经网络架构，称为 ASNN。我们

认为，所提出的 ASNN 能够更好地从稀疏数据中估计参数。我们首先开发了 ASNN 的基础版本，然后通过添加多个采用不同初始化的平滑节点并纳入多个先验估计，构建了更复杂的版本 MASNN。在无法轻易获取参数先验信息的情况下，MASNN 能够为 ASM 找到合适的参数。我们在不同输入设置下，使用来自下一代仿真计划（NGSIM）和德国高速公路无人机（HighD）数据集的数据，对比了 ASM 与我们所提方法的性能。

本文其余部分安排如下：第2节回顾相关文献。第3节介绍 ASM 和我们提出的方法 ASNN，并讨论 ASNN 的工作流程以及 ASNN 的泛化形式 MASNN。第4节说明实验细节，随后在第5节简要讨论结果。最后，我们在第6节总结全文并讨论未来研究方向。

2 相关工作

自适应平滑方法（ASM）属于数据驱动方法中的结构化学习方法，这类方法遵循守恒定律等物理约束，以提升性能或可解释性，参见 [18], [17], [16], [4], [14], [3]。物理约束可纳入模型拟合阶段，例如 [16], [4] ；也可融入模型架构，例如 [6], [5], [7], [18]。结构化学习方法表现出稳健的估计性能，并且在函数拟合过程中只需有限的数据。ASM 是一种结构化学习方法，因为其插值过程考虑了自由流和拥堵交通波传播的特性。

文献中已有多种尝试，旨在改进和修改传统 ASM。例如，[14] 对 ASM 进行离散化，并采用快速傅里叶变换技术，进一步缩短其实时应用中的计算时间。在 [3]的研究中，ASM 的平滑宽度参数在滚动时域框架下动态变化，以捕捉复杂的交通状态。但这项研究忽略了 ASM 的其他参数（自由流速度、激波速度、过渡宽度、临界速度），这些参数的取值均为固定值。本文提出的方法通过系统地搜索 ASM 中考虑的最优参数，克服了这一局限。此外，[18]还将 ASM 的各向异性核应用于设计高效的卷积神经网络，以进行交通速度估计。 [23] 近期的一项研究从矩阵补全的角度考察了 ASM 并提出了一套系统化流程，用于计算最优权重因子，而非采用传统的启发式权重因子。

3 方法论

3.1 符号说明

我们使用大写粗体罗马字母表示矩阵（$\mathbf{W}$、$\mathbf{Z}$、$\mathbf{V}$等）。我们将 $\mathbf{J}$ 定义为全 1 矩阵，其中每个元素均等于 1。符号 $\odot$ 表示阿达玛积。$\|\cdot\|_{\mathrm{F}}$ 表示矩阵的弗罗贝尼乌斯范数。符号 $*$ 表示卷积运算。其他符号见表 1。

3.2 传统自适应平滑方法（ASM）

自适应平滑方法以任意宏观交通量 $\mathbf{Z}$ 作为输入。$\mathbf{Z}$ 的元素 $\mathbf{Z}(x,\ t)$ 可表示时空索引 $(x,\ t)$ 处的交通流量，记作 $q(x,\ t)$、速度 $(v(x,\ t))$ 或交通密度 $(\rho(x,\ t))$。ASM 基于如下假设计算估计场：交通处于两种状态之一。在自由流交通中，扰动基本沿交通流向下游传播；而在拥堵交通中，扰动则向上游传播。根据运动波理论，在这两种状态下，扰动均以恒定波速沿特征曲线在时空中传播。ASM 首先计算两个先验场，如下所示：

$$\begin{aligned}\mathbf{Z}^{\mathrm{free}}(x,t) &= \frac{1}{N(x,t)}\sum_n \phi\left(x-x_n, t-t_n-\frac{x-x_n}{c_{\mathrm{free}}}\right) z_n,\\ \mathbf{Z}^{\mathrm{cong}}(x,t) &= \frac{1}{N(x,t)}\sum_n \phi\left(x-x_n, t-t_n-\frac{x-x_n}{c_{\mathrm{cong}}}\right) z_n,\end{aligned} \tag{1}$$

其中，c_{free} 是自由流状态下的特征波速，c_{cong} 是拥堵状态下的特征波速，$N(x,\ t)$是归一化常数，$\phi(\cdot,\ \cdot)$ 是平滑核函数：

$$\phi(x,t) = \exp\Big(-\frac{|x|}{\sigma}-\frac{|t|}{\tau}\Big). \tag{2}$$

(x_n, t_n) 是测量数据 (z_n) 时所对应的离散位置和时间对。σ 和 τ 分别表示 x 中空间平滑的范围以及 t 中时间平滑的范围。我们也可以应用其他局部函数，例如二维高斯核函数。输出将是这两个先验估计与自适应权重场的叠加，$\mathbf{W}^{\mathrm{cong}}$ 可简洁地写为

$$\mathbf{Z} = \mathbf{W}^{\mathrm{cong}} \odot \mathbf{Z}^{\mathrm{cong}} + (\mathbf{J}-\mathbf{W}^{\mathrm{cong}}) \odot \mathbf{Z}^{\mathrm{free}}. \tag{3}$$

$\mathbf{W}^{\text{cong}} \in [0,1]$ 也以非线性方式依赖于这两个先验估计，定义如下：

$$\mathbf{W}^{\text{cong}} = \frac{1}{2}\left[1 + \tanh\left(\frac{Z_{\text{thr}} - \min\{\mathbf{Z}^{\text{free}}, \mathbf{Z}^{\text{cong}}\}}{\Delta Z}\right)\right]. \quad (4)$$

注意，方程（$\{\cdot,\cdot\}$ 中的最小值和双曲正切（$\cdot$）运算符均按元素应用。Z_{thr} 为临界阈值，ΔZ 为拥堵交通与畅通交通之间的过渡范围。

ASM估计涉及六个参数。表1总结了ASM参数的典型取值及其解释。 [20] 建议，σ 和 τ 的适当取值分别为检测器间距的一半和采样时间的一半。此外，他们通过目视检查进行了敏感性分析，并指出ASM对其余参数不太敏感。然而，我们在实验中发现，并且从 [20]中的图3也可以看出，ASM对参数值敏感；我们认为这种敏感性源于 Z_{thr} 和 ΔZ。因此，需要一种鲁棒算法来优化ASM参数。此外，在某些情况下，我们没有参数值的先验知识可供初始化，因此必须采用一种方法来调整ASM参数。例如，对于由异构数据源记录的混合信号输入，我们不知道平滑宽度的取值。为此，我们将ASM建模为神经网络（ASNN），以高效地处理场参数的调整。我们的架构还可以容纳多个波速，从而在表1 所示的典型取值不适用时，确定最优参数设置。

表1：参数设置

参数	值	描述
c_{cong}	-15 km/h	拥堵波速
c_{free}	80 km/h	自由流波速
v_{thr}	60 km/h	临界交通速度
Δv	20 km/h	过渡宽度
σ	$\Delta x/2$	空间坐标平滑宽度
τ	$\Delta t/2$	时间坐标平滑宽度

3.3 自适应平滑神经网络 (ASNN)

我们构建的自适应平滑神经网络 (ASNN) 使用了 ASM。因此，如下文所述，该网络旨在使隐藏层从内在上遵循运动波理论。

ASNN 的结构示意如图1所示。ASNN 由以下几层组成：(i) 输入层，固定检测器数据或异构源数据被输入神经网络。(ii) 输出层，在此重构估计场并将其作为输出。(iii) 隐藏层，在遵循运动波理论的同时，于输入层和输出层之间处理信息。从左至右看图1中的隐藏层，第一层隐藏层是平滑层。在平滑层中，输入被送入平滑时空函数式（2），以生成 $\mathbf{Z}^{\text{free}}$ 和 $\mathbf{Z}^{\text{cong}}$ 的估计值，如式（1）所示。第二层隐藏层是权重层。平滑层输出的 $\mathbf{Z}^{\text{free}}$ 和 $\mathbf{Z}^{\text{cong}}$ 用于根据式（$\mathbf{W}^{\text{cong}}$）计算权重矩阵 4）。随后，$\mathbf{W}^{\text{cong}}$ 用于对 3）中的 $\mathbf{Z}^{\text{free}}$ 和 $\mathbf{Z}^{\text{cong}}$ 进行凸组合，从而在输出层预测输出。该架构严格保留了 ASM 的工作流程，因此，若将表 1 中的相同参数值用作初始化，ASNN 的一次前向传播即可复现传统 ASM 的结果。

成本函数用于衡量神经网络的平均估计精度。在每次训练迭代中，都会调整神经元中的权重，以使成本最小化。在本研究中，我们为 ASNN 提出了两种成本函数：

1. 卷积代价函数：我们采用 ℓ_1 正则化均方根误差，其依据的启发式原则是，估计矩阵中每个单元的状态都应接近其相邻单元的状态。该成本函数为

$$\frac{\|\mathsf{P}_\Omega(\mathbf{Z}^{\text{est}} - \mathbf{Z}^{\text{true}})\|_F}{\|\mathsf{P}_\Omega(\mathbf{J})\|_F} + \lambda \frac{\sum_{(x,t)} |\omega * \mathbf{Z}^{\text{est}}(x,t)|}{\|\mathbf{J}\|_F} \quad (5)$$

二值掩码算子 P_Ω 仅在观测索引 Ω 处计算目标函数。λ 是正则化参数（或惩罚参数）。惩罚项是对估计矩阵 $\mathbf{Z}^{\text{est}}$进行的核卷积运算。ω 是一个滤波核，它接收两个表示距离的输入 $-a \le dx \le a$ 和 $-b \le dy \le b$，并生成一个权重。对于 $|dx| > a$ 或 $|dy| > b$，$\omega(dx, dy) = 0$。卷积表达式为：

$$\omega * \mathbf{Z}^{\text{est}}(x,t) = \sum_{dx=-a}^{a} \sum_{dy=-b}^{b} \omega(dx,dy)\mathbf{Z}^{\text{est}}(x-dx, y-dy) \quad (6)$$

它衡量每个单元格的估计值与其邻近单元格的估计值之间的差异幅度。

2. 物理信息代价函数：我们可以将交通流模型编码为成本函数中的正则化项，从而促使估计结果遵循某些基于物理的约束。在本研究中，我们考虑一种简

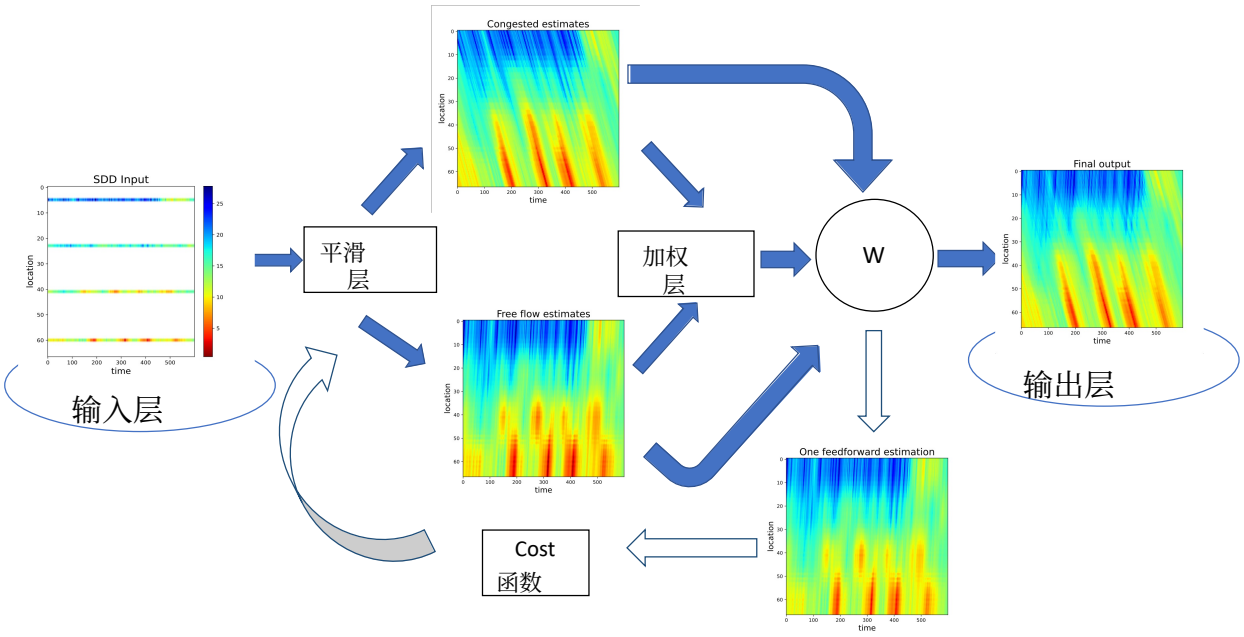

图 1：用于交通状态估计的自适应平滑神经网络

基于Lighthill-Witham-Richards（LWR）交通流模型的守恒原理 [11], [13]:

$$\partial_t \rho(x,t) = -\partial_x Q\big(\rho(x,t)\big), \tag{7}$$

其中 $Q(\cdot)$ 是一个凹通量函数，用于描述局部流量（$q(x,t)$）随交通密度（$\rho(x,t)$）变化的关系。图 2a 对此作了说明。

LWR 型模型是非线性双曲偏微分方程（PDE），其守恒形式为[9]。为数值求解双曲偏微分方程而开发的 Godunov 格式可得到如下离散动力系统:

$$\rho(x+\Delta x,t) = \rho(x,t) + \frac{\Delta x}{\Delta t}[q_{j-1\to j} - q_{j\to j+1}], \tag{8}$$

其中， $q_{j-1\to j}$ 和 $q_{j\to j+1}$ 分别表示数值交通流量（从单元 $j-1$ 流向单元 j 以及从单元 j 流向单元 $j+1$的车辆数）数值交通流量根据最小供需原则[21]计算:

$$q_{j-1\to j} = \min\left\{Q_{\text{dem}}(x,t-\Delta t), Q_{\text{sup}}(x,t)\right\} \tag{9}$$

$$q_{j\to j+1} = \min\left\{Q_{\text{dem}}(x,t), Q_{\text{sup}}(x,t+\Delta t)\right\} \tag{10}$$

单元格（x， t）中的需求函数和供给函数定义为

$$Q_{\text{dem}}(x,t) = \begin{cases} Q(\rho(x,t)) & \text{if } \rho(x,t) \le \rho_{\text{cr}} \\ q_{\max} & \text{otherwise} \end{cases} \tag{11}$$

and

$$Q_{\text{sup}}(x,t) = \begin{cases} Q(\rho(x,t)) & \text{if } \rho(x,t) > \rho_{\text{cr}} \\ q_{\max} & \text{otherwise} \end{cases}, \tag{12}$$

分别。 ρ_{cr} 是临界交通密度，而 $q_{\max} = Q(\rho_{\text{cr}})$ 是最大局部流量。这些局部需求与供给关系分别如图 2b 和图 2c所示。

我们将公式(8)用作正则化项

$$l_{\text{P}} = \sum_{(x,t)} \|\rho(x+\Delta x,t) - \rho(x,t) - \frac{\Delta x}{\Delta t}[q_{j-1\to j} - q_{j\to j+1}]\|_2 \tag{13}$$

并得到如下物理信息代价函数:

$$\frac{\|\mathsf{P}_\Omega(\mathbf{Z}^{\text{est}} - \mathbf{Z}^{\text{true}})\|_F}{\|\mathsf{P}_\Omega(\mathbf{J})\|_F} + \lambda \frac{l_{\text{P}}}{\|\mathbf{J}\|_F}. \tag{14}$$

它促进满足离散守恒方程（8）的解。

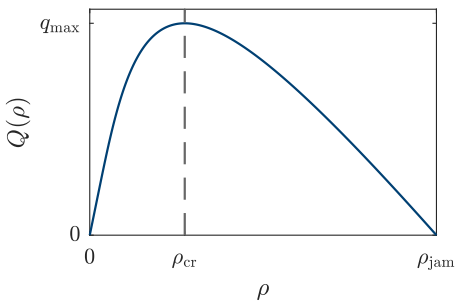

(a) $Q(\rho)$

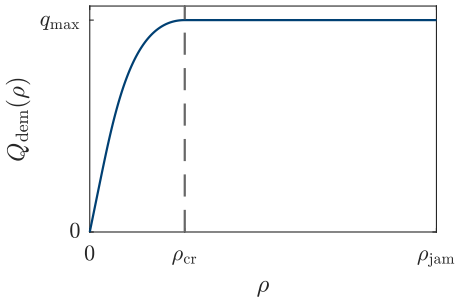

(b) $Q_{\text{dem}}(\rho)$

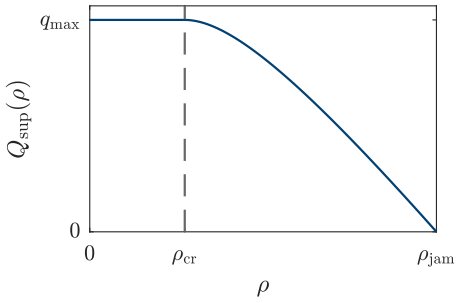

(c) $Q_{\text{sup}}(\rho)$

图 2：通量、需求和供给关系。 ρ_{jam} 是“拥堵密度”，即车辆停止移动时的最大交通密度，此时车辆速度为零，因此通量也为零。

3.4 ASNN 工作流程和 MASNN

为评估模型，我们将真实交通状态数据集划分为训练集和测试集，其中训练集由部分观测交通数据（SDD 或 FCD）组成。训练集作为输入被馈送至神经网络。成本函数计算整个训练集上的平均损失，并使用反向传播计算损失相对于参数的梯度。利用这些梯度更新每个参数。训练过程需要经过多个轮次才能收敛。如果总成本没有变化，则达到最大迭代次数后结束学习过程。

ASNN继承了ASM的架构；它由与权重相同的六个参数组成。需要指出的是，与其他基于梯度的学习方法类似，ASNN架构也面临梯度消失效应的挑战，且平滑层中的权重（c，σ，τ）在训练期间的每次更新中仅发生微小变化。这一现象表明，为了提高整体效率，平滑层的参数需要进行合理的初始化。幸运的是，ASNN和ASN共享这些参数，且参数含义相同，因此我们可以使用其典型值进行初始化，并冻结平滑层以实现快速收敛。

我们从实验中发现，ASNN是一个弱学习器。例如，当数据为混合数据，即来自包括固定式检测器和浮动车在内的异构数据源时，ASNN的估计结果对初始化很敏感。为缓解这一问题并使ASNN成为稳健的学习器，我们开发了多重先验自适应平滑神经网络（MASNN）。MASNN的图示见图 3。

MASNN 基本上采用集成平均技术，使预测不受初始猜测的影响。为此，我们考虑由具有不同可能初始化的 ASNN 组成的集成，并添加一个凸组合层，以合并由不同初始化生成的所有 ASNN 估计值。ASNN 和凸组合层的权重通过优化成本函数共同确定。

4 实验设置

我们使用 NGSIM US 101高速公路数据和德国高速公路数据测试所提方法的性能。NGSIM US 101 数据由一段长 670 米的道路区段中的车辆轨迹组成，德国高速公路数据则由一段长 400 米的道路区段中的车辆轨迹组成。随后将这些数据转换为真实值宏观速度场 $\mathbf{V}(\mathbf{x},\ \mathbf{t})$。因此，本文研究的是速度场估计。速度热力图

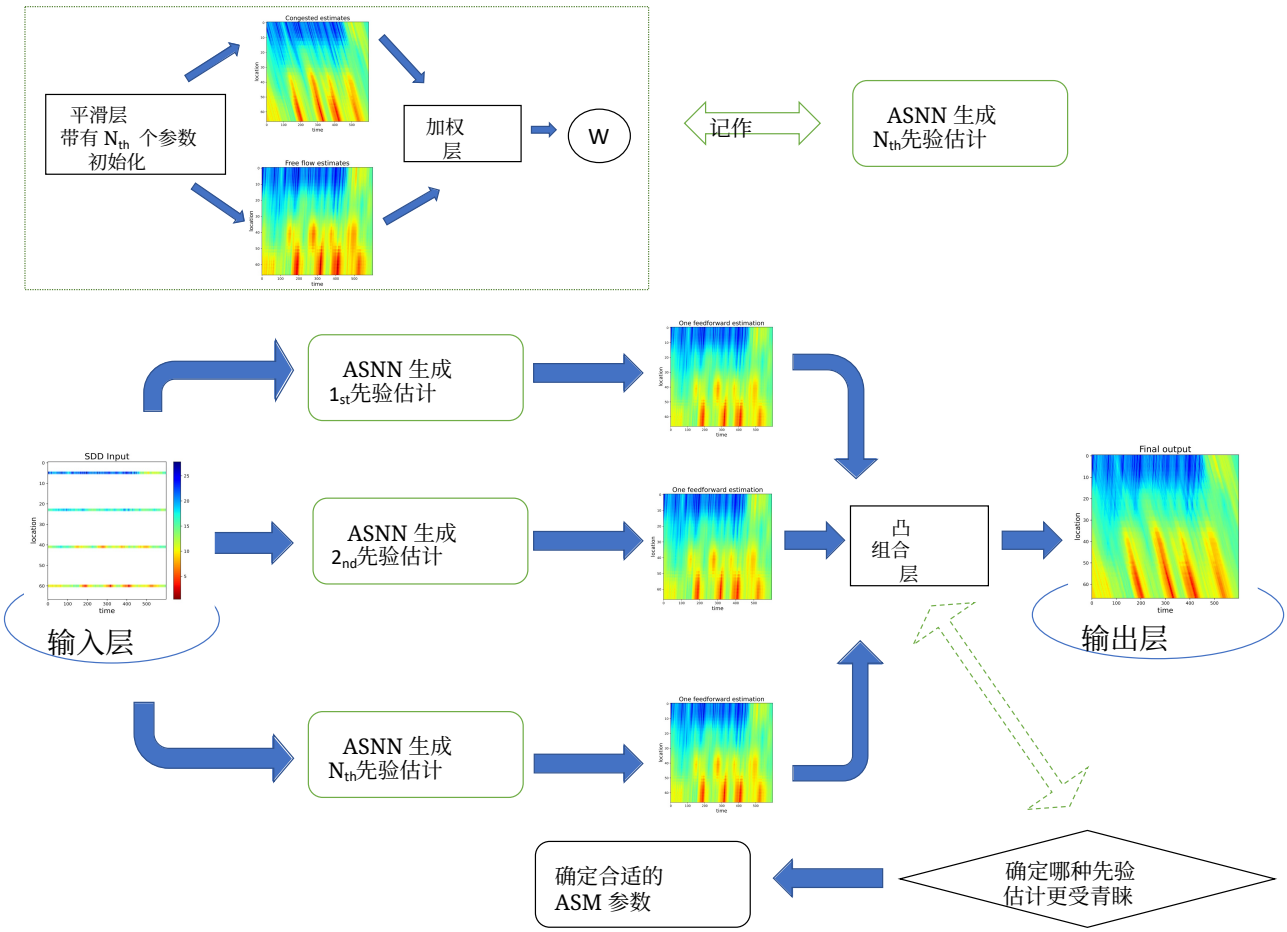

图3：用于交通状态估计的多先验自适应平滑神经网络

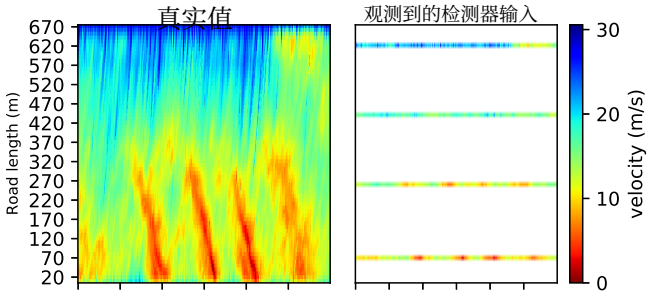

图 4：包含固定检测器输入的 US101 数据

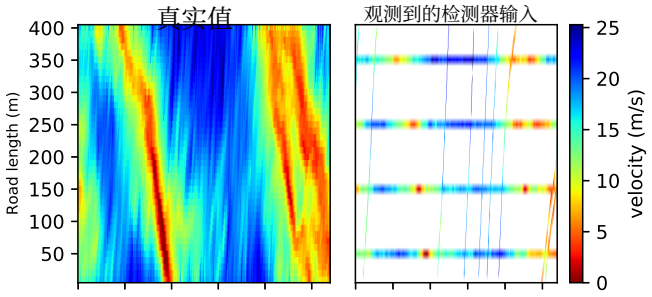

图 5：包含异构输入的德国高速公路数据

字段如图 4 和图 5 所示，分别对应 NGSIM US 101 和德国高速公路数据，二者的时间跨度均为 600 秒。US101 数据来自 4 个间隔均匀的固定式交通传感器（感应线圈检测器）。德国高速公路数据的输入来自 5% 的浮动车轨迹与 2 个固定检测器的组合。这两种情况都涉及拥堵的复杂形成与消散，其中混合出现自由流、拥堵交通以及逆着交通方向传播的激波（图中的红色带状区域）。

本研究开展了两类实验。第一项实验中，我们比较了所提出的 ASNN算法与传统 ASM 的估计误差。我们采用表 1 中的典型值作为 ASM 的最优设置，并作为 ASNN 的初始化参数。ASNN 使用卷积代价函数和物理信息代价函数进行训练。第二项实验中，当数据来自异构数据源且 ASNN 参数的良好初始化值未知时，我们评估所提出的 MASNN估计算法的优势。

我们通过在候选值范围内进行网格搜索来优化 λ $[10, 5, 1, 0.5, 0.1, 0.05, 0.01]$，并在两项实验中均将 λ 设为 0.01。卷积代价函数中的核函数 ω 选取为

$$\omega = \begin{bmatrix} -1 & 0 & 0 \\ -1 & 3 & 0 \\ -1 & 0 & 0 \end{bmatrix} \tag{15}$$

该核函数背后的启发式假设是，当前交通状态会受到过去交通状态的影响。

物理信息代价函数中引入的交通密度 ρ 通过求逆 Newell-Franklin 关系 [12]，$v = V(\rho) = \frac{1}{\rho} Q(\rho)$，将每个单元格中的速度值转换为密度，计算方式如下：

$$\rho(x,t) = V^{-1}\big(\rho(x,t)\big) = \frac{\rho_{\text{jam}}}{1 - \frac{v_{\text{f}}}{|c_{\text{cong}}|} \ln\left(1 - \frac{v(x,t)}{v_{\text{f}}}\right)}, \tag{16}$$

其中，ρ_{jam} 为拥堵密度（约为 120 辆/公里/车道），v_{f} 为期望的（自由流）速度，与道路限速相当。我们设定 $v_{\text{f}} = 100$ km/h，该值高于观测到的速度数据最大值，c_{cong} 为拥堵波速。采用这组参数时，ρ_{cr} 为 30 辆/公里/车道。

我们通过数值计算以及直观重建生成的热力图，来考察算法的准确度。所有实验中，速度场 $\mathbf{V}$ 的估计质量均通过相对误差衡量：

$$m_{\text{r}} = \frac{\|\widehat{\mathbf{Z}} - \mathbf{Z}\|_{\text{F}}}{\|\mathbf{Z}\|_{\text{F}}} \tag{17}$$

5 结果分析与讨论

实验1：*ASM* 与 *ASNN* 的比较：
传统 ASM 和 ASNN 的估计误差 m_{r}（分别采用卷积损失和物理损失）汇总于表2，其中最佳性能以粗体标出。

表2：估计误差结果

US101	m_{r}	德国	m_{r}
ASM	0.12417	ASM	0.08179
ASNN（卷积）	0.11868	ASNN（卷积）	**0.08123**
ASNN（物理）	**0.11866**	ASNN（物理）	**0.08123**

我们发现，在这两种情况下，ASNN 的估计结果都比 ASM 表现更好。虽然 ASM 和 ASNN 的误差估计值没有显著差异，但我们注意到，当表中采用典型参数值时，传统 ASM 对美国101号公路数据的预测不符合物理规律

1 。具体而言，在自由流状态下，ASM 估计值中出现了交叉阴影，这违背了交通的因果性（自由流交通沿车辆行驶方向传播）。ASNN 修正了 ASM 产生的不符合物理规律的预测（见图6）。

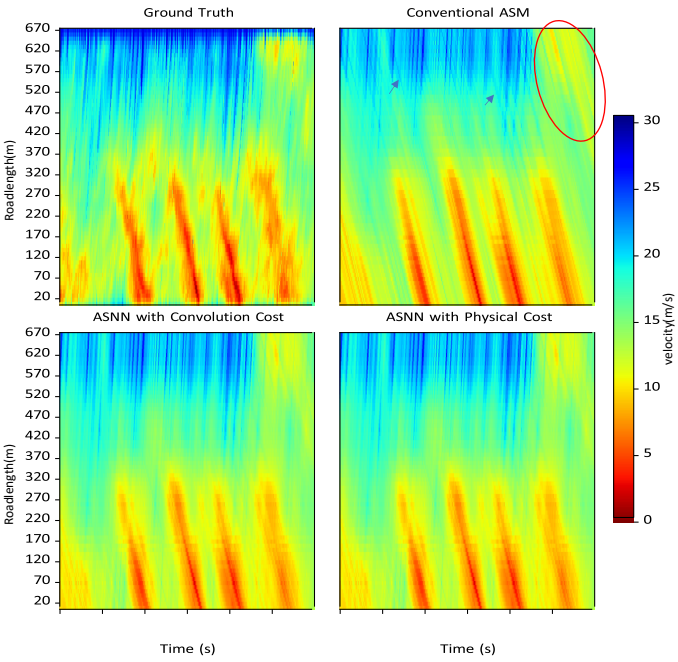

图 6：使用固定检测器输入的 US101 数据估计结果：在显示传统 ASM 情形的面板中，深色箭头和红圈标出了非物理模式。

我们注意到，随着可用于插值的数据增加，ASM 给出的预测会更加准确，其准确度也会逐渐接近 ASNN。例如，我们使用轨迹数据以及检测器数据来估计德国高速公路的交通状态，并注意到 ASM 的结果更接近 ASNN 的结果。见图7。

在此情形下，使用卷积代价和物理代价训练的 ASNN 表现同样出色。这表明，卷积代价函数中考虑的时间因果性有助于重建交通模式。这也说明，如果我们对待重建的交通模式有先验信息，将交通流模型用作正则化项是合理的。我们在实验中注意到，如果初始化参数值选在 0 与其在表 1。所列典型值之间，ASNN 就能很好地收敛。

实验 *2*：具有多个先验估计的 *MASNN*

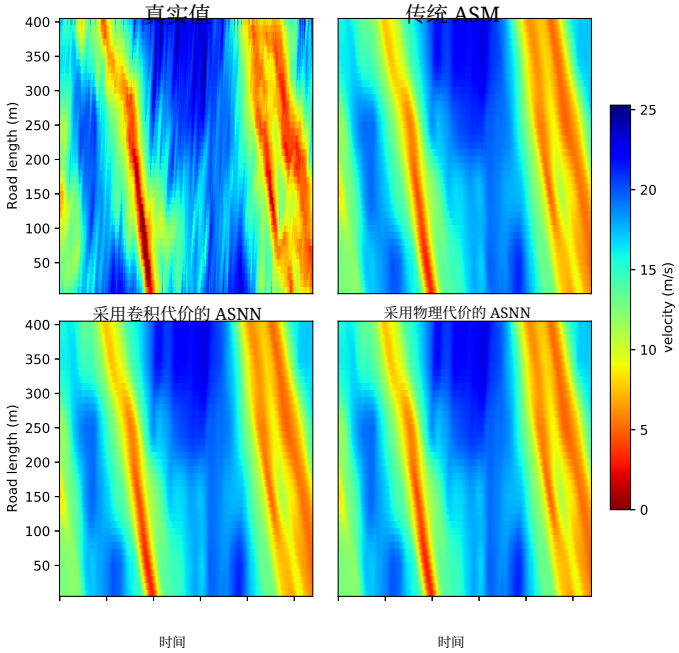

图 7：采用异构输入的德国高速公路数据估计结果

这里，我们讨论使用 5 组可能的初始化值对具有异构输入的德国高速公路数据进行处理所获得的结果。对于 $\{\tau$，我们使用 5 个不同的初始化值：2.5,5, 7.5,10, 12.5$\}$。对于每一组初始化值，拥堵波速和自由流波速分别固定为 -15 km/hr 和 80 km/hr。 V_{thr} 和 Δv 在所有组中均初始化为 1 km/hr。 σ 仍被视为 $\Delta x/2$ ，即检测器之间距离的一半。之所以为 τ 选择这五种不同的初始化值，是因为浮动车数据中的时间间隔不均匀。我们注意到，增加更多初始化值不会显著改变结果。

MASNN 的估计准确度 m_{r} 为 0.08021。从表2 以及图7和图8中也可以直观看出，MASNN 能够结合多个先验估计，从而提升其性能并超越 ASNN。

凸组合层中训练得到的权重列于表 3。随后，使用传统 ASM 估计对每组权重设置进行测试，并记录相应的估计误差。训练权重最高的初始化组以粗体标出。比较相应的 ASM 误差可见，MASNN 倾向于选择能为 ASM 带来更好估计结果的权重，这表明 MASNN 也能够为传统 ASM 选择合适的参数。图 8

表3：MASNN 在凸组合层中训练得到的权重

德国： σ, τ	权重	ASM m_{T}
50,2.5	**1**	**0.08240**
50,5	**1**	**0.08674**
50,7.5	0	0.09367
50,10	0	0.10154
50,12.5	0	0.10963

展示了 MASNN 和 ASM 在不同参数设置下生成的速度场热力图。我们观察到

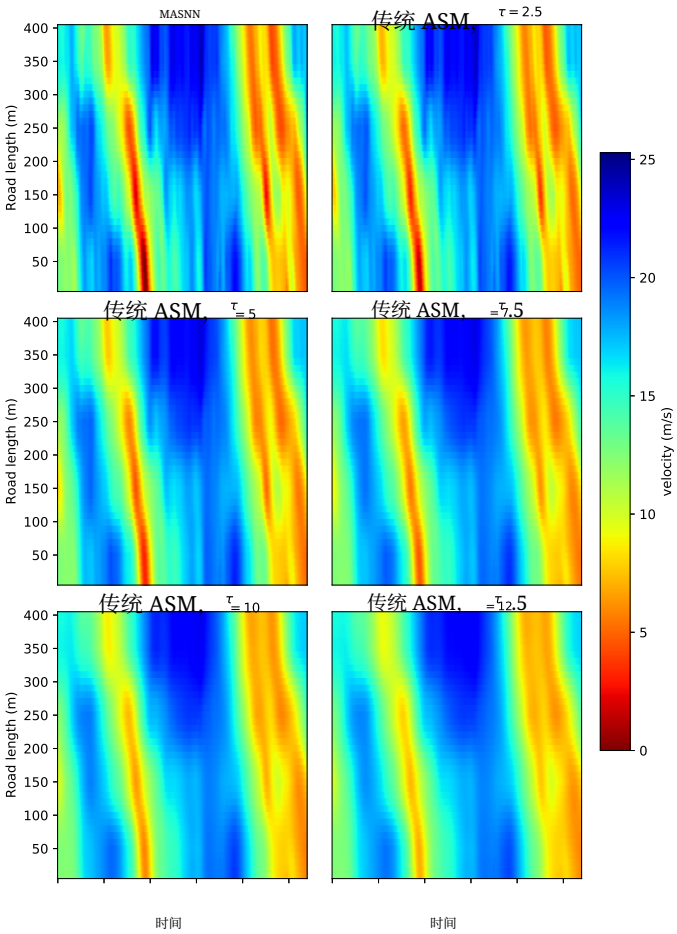

图 8：MASNN 估计结果及其在 ASM 中应用的最优时间平滑宽度

与 ASM 和 ASNN 估计的结果相比，MASNN 生成的冲击波模式更接近真实值可视化中的模式。即使使用 MASNN 确定的参数集，ASM 对剧烈变化的平滑程度也高于 MASNN。ASM 中的平滑效应会随着τ的增加而增强。

6 总结与结论

本研究开发了一种基于自适应平滑方法（ASM）的神经网络（ASNN）。ASNN 利用检测器的稀疏数据调整 ASM 的参数，并重建沿整条道路的交通状态。我们使用两种成本函数对 ASNN 进行了测试。一种通过正则项惩罚相邻单元间速度的剧烈差异，从而使数据损失最小化。另一种成本函数则通过基于交通密度守恒原理的物理信息正则项使数据损失最小化。我们还提出了一种通过集成平均技术增强 ASNN 学习稳健性的方法，并将其称为 MASNN。我们将 ASNN 和 MASNN 应用于两个真实世界数据集；其中一个是来自固定式检测器的 NGSIM US 101 高速公路数据集，另一个使用来自异构数据源的德国高速公路数据，包括固定式检测器和浮动车。实验表明，在所有情况下，采用 ASM 典型参数值初始化的 ASNN 在交通状态估计方面均优于 ASM。在检测器具有异构性的情况下，由于未知合适的参数初始化集合，MASNN 在交通估计方面表现出色。我们还注意到，MASNN 预测的权重最高的初始化参数，可作为传统 ASM 的良好参数值。总的来说，我们发现 MASNN 和 ASNN 是用于交通状态估计的有前景的工具。

我们发现仍有改进空间：ASNN 架构受到梯度消失效应的影响，进而影响初始层中的参数。此外，ASM 作为一种平滑方法，会抹平模式中的剧烈变化。用前馈网络替代平滑层，或许能够改善上述两个方面的性能。基于 Frobenius 范数的代价函数侧重于较大的数值，因此在速度较低时估计不准确。可以通过使用密度作为待估计变量，或添加其他惩罚项以强调低速交通，来避免这一问题。

致谢

本研究得到了纽约大学阿布扎比分校城市网络交互中心（CITIES）的支持，该中心由 Tamkeen 通过纽约大学阿布扎比分校研究所奖 CG001 资助。本文所表达的观点仅代表作者个人意见，并不代表 CITIES 的观点。

参考文献

[1] AATM Aw 和 Michel Rascle。交通流“二阶”模型的复兴。 *SIAM journal on applied mathematics* 60 3 916 938, 2000 , ( ): – 。

[2] Ouafa Benkraouda、Bilal Thonnam Thodi、Hwasoo Yeo、Monica Menendez 和 Saif Eddin Jabari。使用深度卷积神经网络进行交通数据插补。 *IEEE Access* 8 104740 104752, 2020 , : – 。[3] Xiqun Chen、Shuaichao Zhang、Li Li 和 Liang Li。利用异构数据进行自适应滚动平滑，以实现交通状态估计和预测。 *IEEE transactions on intelligent transportation systems* 20 4 1247 1258, 2018 , ( ): – 。

[4] Jiheng Huang 和 Shaurya Agarwal。用于交通状态估计的物理信息深度学习。载于 *2020 IEEE 23rd International Conference on Intelligent Transportation Systems (ITSC)* 1 6 2020 ，第 – 页。IEEE，。

[5] Saif Eddin Jabari、Deepthi Mary Dilip、DianChao Lin 和 Bilal Thonnam Thodi。利用随机场学习交通流动力学。 *arXiv preprint arXiv:1806.08764*，2018年。

[6] Saif Eddin Jabari、Fangfang Zheng、H Liu 和 Monika Filipovska。交通动力学的随机拉格朗日建模。载于 *Proc. 97th Annu. Meeting Transp. Res. Board*，第 1–14 页，2018年。

[7] Saif Eddin Jabari、Nikolaos M Freris 和 Deepthi Mary Dilip。基于流数据的稀疏行程时间估计。*Transportation Science*，54(1)：1–20，2020年。

[8] Yuhan Jia、Jianping Wu 和 Yiman Du。使用深度学习方法预测交通速度。载于 *2016 IEEE 19th international conference on intelligent transportation systems (ITSC)* 1217 1222 2016 ，第 – 页。IEEE，。

[9] Randall J LeVeque 和 Randall J Leveque。 *Numerical methods for conservation laws* 214 1992 ，第 卷。施普林格，。

[10] Wenqing Li、Chuhan Yang 和 Saif Eddin Jabari。将非线性交通预测作为矩阵补全问题，并采用集成学习。 *Transportation science* 56 1 52 78, , ( ): – 。2022

[11] Michael James Lighthill 和 Gerald Beresford Whitham。《运动学波 II：长而拥挤道路上的交通流理论》。 *Proceedings of the Royal Society of London. Series A. Mathematical and Physical Sciences*，229(1178)：317–345，1955。[12] Gordon Frank Newell。《跟驰动力学中的非线性效应》。 *Operations research*，9(2)：209–229，1961。[13] Paul I Richards。《高速公路上的激波》。 *Operations research* 4 1 42 , ( ): – 51，1956。[14] Thomas Schreiter、Hans van Lint、Martin Treiber 和 Serge Hoogendoorn。《用于高速公路交通状态估计的自适应平滑方法的两种快速实现》。载于 *13th International IEEE Conference on Intelligent Transportation Systems* 1202 1208 ，第– 页。IEEE，2010。

[15] Toru Seo、Alexandre M Bayen、Takahiko Kusakabe 和 Yasuo Asakura。高速公路交通状态估计：全面综述。 *Annual reviews in control*, 43:128– 151, 2017。

[16] Rongye Shi、Zhaobin Mo、Kuang Huang、Xuan Di 和 Qiang Du。用于交通状态和基本图估计的物理信息引导的深度学习范式。*Transactions on Intelligent Transportation Systems* 2021 , 。

[17] Bilal Thonnam Thodi、Zaid Saeed Khan、Saif Eddin Jabari 和 M´onica Men´endez。从可视化中学习交通速度动态。载于 *2021 IEEE International Intelligent Transportation Systems Conference (ITSC)*，第 1239–1244 页。IEEE，2021。

[18] Bilal Thonnam Thodi、Zaid Saeed Khan、Saif Eddin Jabari 和 Monica Men´endez。将运动波理论融入深度学习方法，以实现高分辨率交通速度估计。 *IEEE Transactions on Intelligent Transportation Systems* 23 10 17849 17862, , ( ): –。2022

[19] Martin Treiber 和 Dirk Helbing。利用固定式检测器数据重建时空交通动态。 *Cooper@ tive Tr@ nsport@ tion Dyn@ mics*，1(3)：3–1，2002。

[20] Martin Treiber、Arne Kesting 和 R Eddie Wilson。通过异构数据融合重建交通状态。 *Computer-Aided Civil and Infrastructure Engineering* 26 6 408 419, 2011 , ( ): –。

[21] Femke van Wageningen-Kessels。交通流建模：通过模型增系介绍交通流理论。2019。

[22] Jianli Xiao、Chao Wei 和 Yuncai Liu。使用多核空转向量回归进行交通流速度估计。 *Physica A: Statistical Mechanics and its Applications* 509 989 997, 2018 , : – 。

[23] Chuhan Yang、Bilal Thonnam Thodi 和 Saif Eddin Jabari。使用矩阵补全进行交通状态估计的广义自适应平滑。 *arXiv preprint arXiv:2206.01461* 2022 , 。