

Research on Generalization Method of Automotive Active and Passive Simulation Models Based on Physics-Informed Neural Networks

Hailiang CHEN^{1,2}, Zhenfei ZHAN^{1,2}, Weijian HAN^{1,2}, Houchao WANG¹, Minchi, LI¹, Kun WANG¹

¹College of Electromechanical and Vehicle Engineering, Chongqing Jiaotong University, Chongqing, 400074, China

² Materials Academy, JITRI, Suzhou, 215131, China

Email: zhenfei_zhan@163.com

Abstract: In modern automotive industries, accurate simulation of vehicle dynamic behavior is crucial for product design and performance optimization. However, with the increasing complexity of vehicles, ensuring the accuracy and reliability of simulation models has become an urgent issue to address. Currently, the verification of automotive simulation models primarily focuses on establishing reasonable verification metrics and validating model effectiveness through data consistency checks. Despite these efforts, existing verification methods still face limitations when dealing with high-dimensional complex systems, especially in handling uncertain and variable data sources. This paper proposes a method for the generalization of automotive active and passive simulation models based on Physics-Informed Neural Networks (PINNs). By constructing a secondary network to learn the implicit physical relationships between inputs and outputs under independent collision scenarios, this network is embedded into the primary network used for predicting experimental data under AEB+crash (Automatic Emergency Braking and crash) scenarios. The secondary network is utilized to refine the predictions of the primary network, thereby achieving accurate predictions of AEB+crash experimental data. Experimental results demonstrate that this method exhibits superior predictive accuracy and effectiveness, significantly enhancing the accuracy and reliability of the models. The approach utilizing PINNs not only addresses situations with scarce data but also leverages known physical laws to enhance the generalization capabilities of models, providing a new perspective for addressing the verification and generalization challenges of automotive simulation models.

Keywords: Active and passive safety; Model validation; Model generalization; Physics-informed neural networks

基于物理信息神经网络的汽车主被动仿真模型泛化方法研究

陈海量^{1,2}, 詹振飞^{1,2}, 韩维建^{2,1}, 王后超¹, 李珉驰¹, 王堃¹

¹重庆交通大学机电与车辆工程学院, 重庆, 中国, 400074

²长三角先进材料研究院, 苏州, 中国, 215131

Email: zhenfei_zhan@163.com

摘要: 在现代汽车工业中, 车辆动态行为的准确模拟对于产品设计和性能优化至关重要。然而, 随着车辆复杂度的增加, 如何确保仿真模型的准确性和可靠性成为了一个亟待解决的问题。目前, 汽车仿真模型验证主要集中在建立合理的验证指标体系和通过数据一致性检验等方法验证模型的有效性。尽管有这些努力, 现有的验证方法在面对高维复杂系统时仍存在局限性, 尤其是在处理不确定性和多变性数据源方面。本文提出了一种基于物理信息神经网络(Physics-Informed Neural Networks, PINNs)的汽车主被动仿真模型泛化方法。通过构建一个副网络来学习独立碰撞工况下输入与输出之间的隐式物理关系, 并将其嵌入到用于预测AEB+crash(自动紧急制动与碰撞)工况下的实验数据的主网络中, 用副网络对主网络进行修正从而实现对AEB+crash试验数据的准确预测。实验结果表明, 该方法在预测精度和有效性方面具有优越性, 能够显著提高模型的准确性和可靠性。基于物理信息神经网络的方

法不仅能够处理数据稀缺的情况，还能利用已知的物理规律来增强模型的泛化能力，为解决汽车仿真模型验证和泛化问题提供了一种新的思路。

关键词：主被动安全；模型验证；模型泛化；物理信息神经网络

1 引言

在现代汽车工业中，车辆动态行为的准确模拟对于产品设计和性能优化至关重要。然而，随着车辆复杂度的增加，如何确保仿真模型的准确性和可靠性成为了一个亟待解决的问题。目前，汽车仿真模型验证主要集中在以下几个方面：首先，需要有一套完善的验证指标体系，方可等人^[1]对此进行了探讨，他们指出合理的指标体系是保证模型质量的基础；其次，由于实际测试数据有限，因此需要通过数据一致性检验等方法来验证模型的有效性^[2]。然而，尽管有这些努力，现有的验证方法在面对高维复杂系统时仍存在局限性，尤其是在处理不确定性和多变性数据源方面^[3]。陈小勇^[4]在其博士论文中研究了动态系统仿真模型验证方法及工具，提出了多种验证手段，并开发了相应的工具，以提升模型的可靠性和有效性。李伟等人^[5]对现有的仿真模型验证方法进行了全面的综述，总结了当前技术的优点和局限性，并指出了未来的研究方向。Fachada 等人^[6]提出了一种模型无关的仿真输出比较方法，这种方法能够在不依赖具体模型的情况下进行有效的输出对比。此外，廖卓等人^[7]总结了汽车动态系统仿真模型验证的方法，指出在汽车行业，仿真模型的准确性和可靠性至关重要。张雪钊^[8]研究了新能源汽车整车及动力系统的精确建模方法，为电动汽车的设计提供了重要参考。

然而，由于某些仿真模型所对应的试验较为复杂或实验成本过高而无法轻易获得试验数据，缺失的试验数据只能通过给定条件下的模型验证实验来弥补，迫使研究人员从具有大量实验数据的验证域出发，对新设计域的输出进行推测，进而实现复杂仿真模型的可信度评估，该过程即为模型泛化。模型泛化能力决定了其在真实世界应用中的有效性。值得注意的是，随着人工智能技术的进步，特别是深度学习和大数据分析技术的应用，预计将有更多的创新方法涌现出来，助力于解决模型验证和泛化的问题。例如，基于卷积神经网络的模型验证方法^[9]，利用深度学习技术提高了验证的精度和速度。此外，集成学习方法也被用于提高复杂仿真模型的验证效果，通过组合不同的学习器来增强模型的泛化能力^[10]。在处理复杂系统中的不确定性和多变性数据源方面，Hu 等人^[11]建立了一个基于参数校准的模型验证框架，该框架考虑了随机不确定性和认知不确定性的影响，从而提高了模型验证的鲁棒性。郑凯等人^[12]提出了结合定性知识的定量贝叶斯模型外推方法，为处理复杂系统的不确定性提供了一种新的途径。

可见，机器学习在仿真模型验证中的应用越来越多，但是目前还没有针对机器学习在仿真模型可信度泛化中的应用。在这样的背景下，物理信息神经网络（Physics-Informed Neural Networks, PINNs）作为一种新兴的技术，因其将物理定律嵌入到神经网络中而受到关注。PINNs 不仅可以从有限的数据中学习，还能通过遵守物理定律来增强模型的泛化能力。这种方法特别适用于数据稀缺的情况，并且可以用来估计模型中的未知参数。PINNs 目前在其他科学领域已得到了广泛的应用，例如，Raissi 等人^[13]的工作展示了一种将物理定律编码进神经网络训练过程的方法，使得神经网络不仅能从数据中学习，还能利用已知的物理规律来约束解空间，从而得到既符合数据又满足物理定律的解。此外，Wang H 等人^[14]的研究进一步证明了 PINNs 在材料动态力学性能预测中的潜力，这表明 PINNs 同样可以在汽车材料科学中发挥重要作用。其他相关研究还包括 Liu 等人^[15]的工作，他们利用机制信息人工神经网络模型发现了金属各向异性路径相关塑性特性，这进一步证明了将物理知识嵌入神经网络在处理复杂材料特性时的优势。Diao 等人^[16]利用基于域分解技术的物理信息神经网络解决了固体力学中的多材料问题。Cranmer 等人^[17]提出了拉格朗日神经网络（Lagrangian Neural Networks），这是一种能够保持物理守恒定律的神经网络架构。这些工作共同推动了物理信息神经网络在解决复杂物理问题中的应用。基于以上分析，将 PINN 用于汽车仿真领域可以显著提高模型的准确性和可靠性，由此本文提出了一种基于物理信息神经网络的汽车主被动仿真模型泛化方法，以解决某些无法进行试验情况下的模型验证问题。本文用一个副网络用于训练得到单独碰撞工况下输入与输出之间的隐式物理关系，而后将副网络嵌入到用于预测 AEB+crash 工况下的实验数据的主网络中，用副网络对主网络进行修正从而实现对 AEB+crash 试验数据的准确预测，达到模型泛化的目的。

2 试验设计与仿真模型搭建

2.1 试验参数设计

考虑到碰撞测试的复杂性和高成本，本文仅专注于自动紧急制动系统（AEB）在主动安全系统中的作用，并重点研究了作为被动安全装置的座椅和安全带。在主被动安全联合碰撞试验中，滑车在牵引系统的帮助下加速至 50 公里/小时，然后在 AEB 的作用下减速至 30 公里/小时，并最终发生碰撞。AEB 的预制动过程持续 1000 毫秒，而实际碰撞过程则持续 120 毫秒。试验所需的设备包括预制动牵引系统、预制动减速台车、Hybrid III 50% 假人模型、安全带力传感器、加速度传感器以及 TEMA 视频分析系统。调整后的实验示意图如图 1 所示。

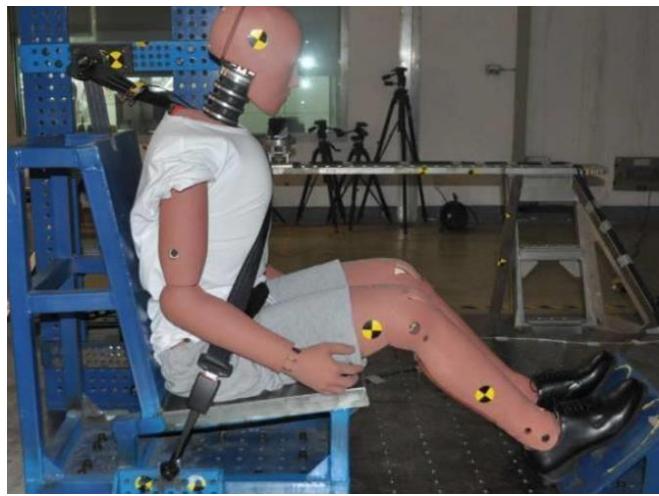


Figure 1. Schematic Diagram of Test Setup

图 1. 试验状态示意图

2.2 仿真模型搭建

本节使用 MADYMO 作为建模工具，基于车身模型、安全带系统模型以及代表 50 百分位标准体型成年男性的假人模型，构建了一个汽车正面碰撞的仿真模型。建模过程分为以下几个步骤：首先，依据滑车尺寸数据创建了包含座椅和脚踏板的车体模型，座椅和脚踏板均采用有限元方法进行建模。由于脚踏板与车身之间没有相对运动，因此将其与座椅固定在一起。接下来，导入 Hybrid_III_50th 有限元假人模型，并使用 MADYMO 中的运动铰调节假人各部位的位置，确保假人与车体模型匹配。安全带在防止乘员直接撞击车辆内部硬质部件方面至关重要，统计显示正确佩戴安全带可减少高达 42% 的乘客致命伤害风险。在 MADYMO 中，安全带模型通常有标准模型、有限元模型和混合模型三种类型，其中混合模型结合了简洁性和高精度的优势，缩短计算时间同时保证了精度。安全带从卷收器延展，穿过 B 柱导向孔，通过 D 环调节高度，肩带约束上身并通过锁扣固定，腰带则通过滑动环稳固脊柱和大腿，最终连接到固定的锚点。混合式安全带模型包含了有限元和多刚体元素，使用 Belt 单元来建模多体部分，如 D 环、卷收器、卡扣和锚点，而有限元部分则由与乘员身体接触的肩带和腰带构成。建立完成的仿真模型如下图所示。

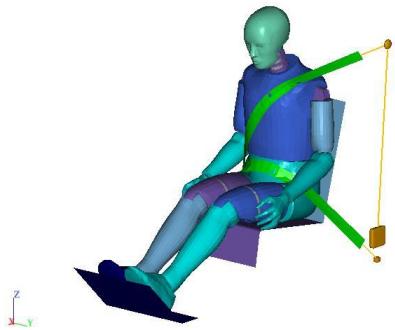


Figure 2. Frontal Impact Simulation Model of Occupant

图 2.乘员正面碰撞仿真模型

3 基于物理神经网络的碰撞模型精度预测

物理神经网络是一种融合了物理定律与机器学习技术的先进计算模型。不同于传统纯数据驱动的方法，物理神经网络在设计之初就嵌入了已知的物理规律，如牛顿第二定律、能量守恒等，以确保模型预测的物理一致性。这种方法不仅提升了模型的解释性，使其预测结果更加易于理解和验证，而且增强了模型在面对未见过的数据时的泛化能力。通过将物理定律作为先验知识纳入模型结构之中，物理神经网络在诸如工程学、材料科学以及能源管理等多个领域展现出了巨大潜力，特别是在那些需要高度准确性和可靠性的应用场景中，物理神经网络能够提供更为稳健的解决方案。

3.1 数据情况

在本研究中，针对乘员的左右摇摆度、腰部倾斜度和颈部倾斜度这三个自由度的取值范围进行了随机选取（如图 3 所示），生成了 60 组不同的乘员坐姿组合。每组坐姿组合都是在相应自由度范围内随机选择的，以确保多样性和代表性。对于每一种坐姿，调整仿真模型的参数，确保其能够准确反映乘员的实际姿态。接着，对调整后的每一种坐姿模型，在两种不同的工况下进行了 MADYMO 仿真：首先是标准碰撞工况，其次是自动紧急制动（AEB）作用下的碰撞工况。每种工况都得到了相应的仿真数据输出结果，总共产生了 60 组不同的仿真数据文件，每组文件中包含了两种工况的数据结果。

为了训练模型，将前 50 组数据作为训练集（按照 4: 1 进行交叉验证），用于优化模型参数。剩下的 10 组数据则作为测试集，用于评估模型的泛化能力和预测精度。通过这种方式，可以确保模型不仅在训练数据上有良好的表现，也能在未见过的数据上保持较高的预测准确性。此外，将三个自由度的角度（左右摇摆度、腰部倾斜度和颈部倾斜度）作为输出，并将乘员的损伤曲线作为输出的一部分，具体包括肩带力、腰带力、头部合成加速度、颈部力矩和胸部压缩量。这些输出数据为我们提供了详细的乘员受伤情况，有助于进一步优化模型的预测性能。

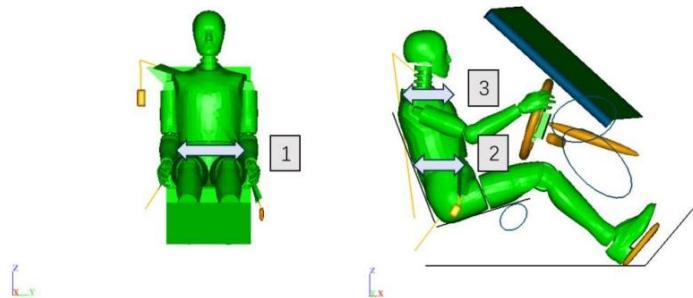


Figure 3. Three Degrees of Freedom of the Occupant

图 3.乘员的三个自由度

3.2 物理神经网络建立

当前，嵌入物理机制的方式主要有三种：第一种是设计特殊的神经网络架构，例如当需要满足某些物理条件（如周期性、连续性等）时，可以通过精心设计网络结构，使其在学习过程中自动遵守这些条件，从而提高模型的泛化能力。第二种方法是将物理先验知识直接嵌入到损失函数中，形成物理学指导的神经网络（Physics-Informed Neural Networks, PINNs），这样可以在训练过程中引导模型更好地拟合物理规律。第三种则是从数据中挖掘物理知识，即使在缺乏显式物理规律的情况下，也可以通过大量的模拟数据隐式地捕捉物理规律，并用于模型的约束。

本文的方法是通过仿真获得的 AEB（自动紧急制动）与碰撞（crash）数据（这些数据未经模型验证，因此被视为低保真数据）输入到一个复杂的多层神经网络中，该网络主要用于预测头部合成加速度、胸部压缩量、颈部力矩、腰带力和肩带力等关键参数。此外，利用一个副网络来学习独立碰撞工况下输入与五个输出之间的隐式物理关系，并将此副网络嵌入到主网络的损失函数中，用于修正主网络的输出数据，其中单独碰撞工况和 AEB+crash 工况的发生碰撞的速度相同，以保证副网络学习到的相关物理规律符合 AEB+crash 工况。由于本文只关注了 AEB+crash 工况中后 0.12s 的碰撞阶段对乘员的损伤情况，故忽略了前 1s 的 AEB 前预制动阶段，故在副网络只嵌入了碰撞工况下相关隐式物理信息，以实现对碰撞规律的修正。通过这种方法，可以实现对 AEB+crash 试验数据的准确预测。独立碰撞工况下的仿真模型通过相应的试验数据验证被认为具有较高的保真度，因此，利用这些高保真数据对低保真数据进行修正，能够实现对 AEB+crash 试验数据的精确预测，具体流程如下图所示。

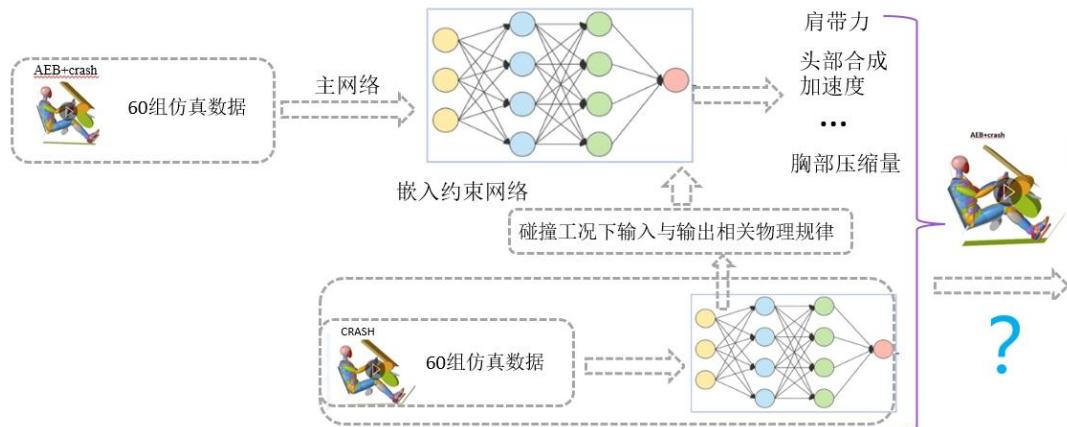


Figure 4. Model generalization process based on physical neural network

图 4. 基于物理神经网络的模型泛化流程

该神经网络系统主副网络均采用两层隐藏层，每层隐藏层包含 130 个节点，使用 ReLU 作为激活函数。隐藏层数和节点数的选择是为了平衡模型复杂度和泛化性能，使得模型有足够的表达能力同时避免过拟合。学习率设置为 0.001，这是因为较低的学习率可以帮助模型更好地收敛，减少震荡，提高稳定性。这样的参数设置旨在实现良好的预测性能和稳定的学习过程。

3.3 模型评估

决定系数：在机器学习中， R^2 （决定系数，也称为 R-squared 或 R^2 分数）是一种用于评估回归模型性能的统计度量。 R^2 提供了模型拟合程度的量化信息，即模型解释了因变量变化的多少比例。其值越接近于 1 表示模型的预测越准确，其计算公式为：

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

均方根误差：均方根误差是衡量预测值与实际观测值之间差异的一个常用指标，用 RMSE 表示。它是先计算预测误差的平方，然后计算这些平方误差的平均值，最后对这个平均值开平方得到的结果。RMSE 对大的预测误差非常敏感，因为它使用了平方误差。计算公式如下：

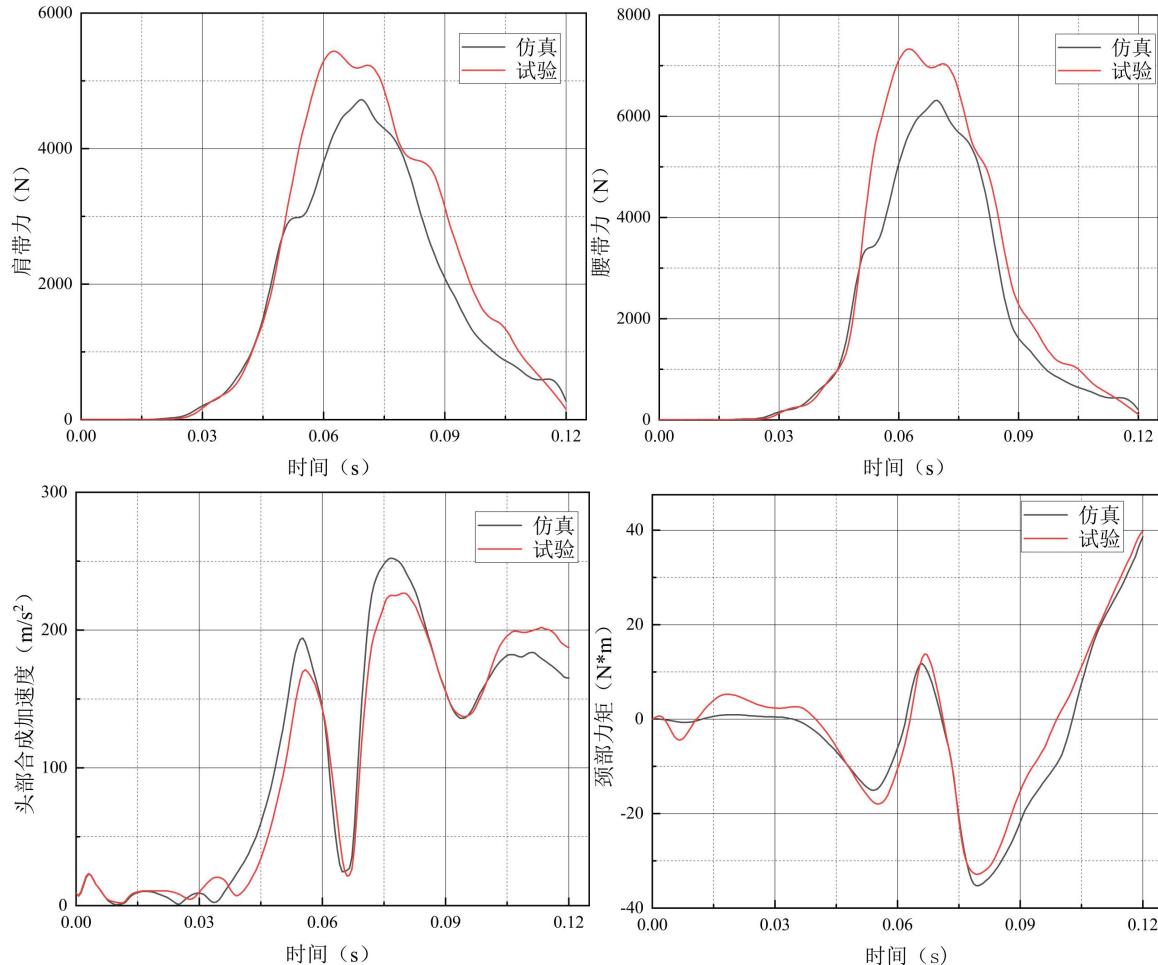
$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (2)$$

在式（1）和（2）式中， \hat{y}_i 为模型的预测值， y_i 为真实值， \bar{y}_i 为真实值的平均值，n 为样本数。

4 结果分析

4.1 碰撞工况模型验证

碰撞工况下，车辆在牵引设备的作用下加速至 30 公里/小时，并按照特定轨迹撞击障碍物，整个碰撞过程耗时 120 毫秒。图 5 显示了碰撞期间试验仿真在安全带肩部力、腰部力、头部合成加速度、上颈椎力矩和胸部压缩量等多种响应参数的时间变化对比曲线。这些图表清楚地表明，模拟曲线与实测曲线在形态、强度及演变趋势方面高度一致，两条曲线的重叠度高，证实建立的模拟模型具备一定有效性和精确性。



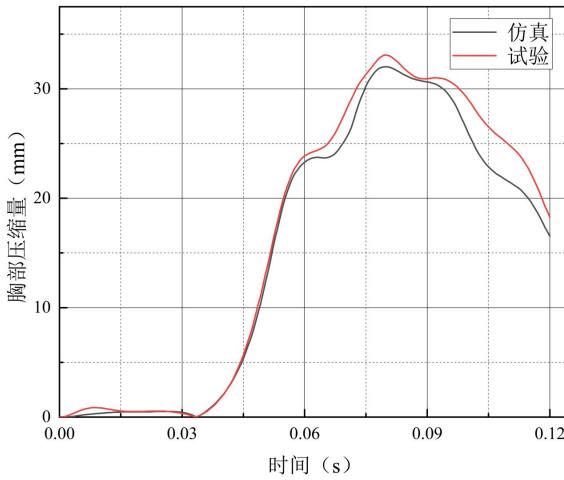


Figure 5. Comparison curve between test and simulation under collision conditions

图 5.碰撞工况下试验与仿真对比曲线

采用詹振飞等人^[18]提出的EEARTH 仿真模型精度评估方法,对碰撞工况下各个响应参数的试验结果与仿真结果进行了量化评分。表 1 展示了各响应量的特性误差(EE)得分及其对应的EEARTH 综合评价得分。根据所列出的数据,可以观察到胸部压缩量这一关键安全指标在EEARTH 评分体系中获得了最高的得分,达到了92.32%,这表明了该响应量在仿真过程中的模拟精度非常高,能够较好地反映实际情况。相比之下,腰带力这一响应量的得分最低,为83.24%,尽管如此,这个得分依然维持在一个相对较高的水平上。值得注意的是,所有其它响应量的EEARTH 得分均超过了80%,这说明了整个仿真过程中,实验获得的数据曲线与计算机模拟产生的曲线之间有着良好的一致性,仿真数据与实际测试数据之间的差异较小。

这一结果不仅验证了仿真模型的有效性和可靠性,同时也强调了所收集的仿真数据具有较高的保真度,能够在一定程度上准确地反映出碰撞过程中乘员的真实受力情况。鉴于此,我们可以合理地推断,这些高保真度的数据可以用来进一步校准和优化自动紧急制动系统(AEB)在实际碰撞情况下的性能表现,从而提高车辆安全性能。此外,通过对比仿真数据与实测数据之间的差异,我们还可以进一步优化仿真模型,使其更加贴近现实世界中的碰撞情景,为未来的汽车安全设计提供更加精准的数据支持。

Table 1. EEARTH score under collision conditions

表 1.碰撞工况下 EEARTH 评分

响应量	相位误差评分	幅值误差评分	形状误差评分	EEARTH 评分
肩带力	95.02%	92.19%	65.21%	84.14%
腰带力	95.02%	90.68%	64.01%	83.24%
头部合成加速度	94.03%	91.09%	82.69%	89.60%
颈部力矩	97.51%	82.49%	80.76%	86.92%
胸部压缩量	95.02%	98.39%	83.56%	92.32%

4.2 物理神经网络预测结果

本文提出的物理设计网络的预测精度如图 6 所示,在验证集上,模型的 RMSE 为 0.0608, R² 为 0.9165;在测试集上,模型的 RMSE 为 0.0785, R² 为 0.8951,显示出良好的预测能力和泛化能力。AEB+crash 的试验数据预测结果如下图 7 所示,通过对安全带肩部受力、腰部受力、头部合成加速度、上颈部伸展力矩以及胸部压缩量的实验数据、仿真数据与预测数据进行对比分析,可以看出三者的曲线在形状特征、幅度大小及变化趋势上表现出显著的一致性。这一结果强有力地验证了本文提出的预测模型在预测精度和有效性方面的优越性。

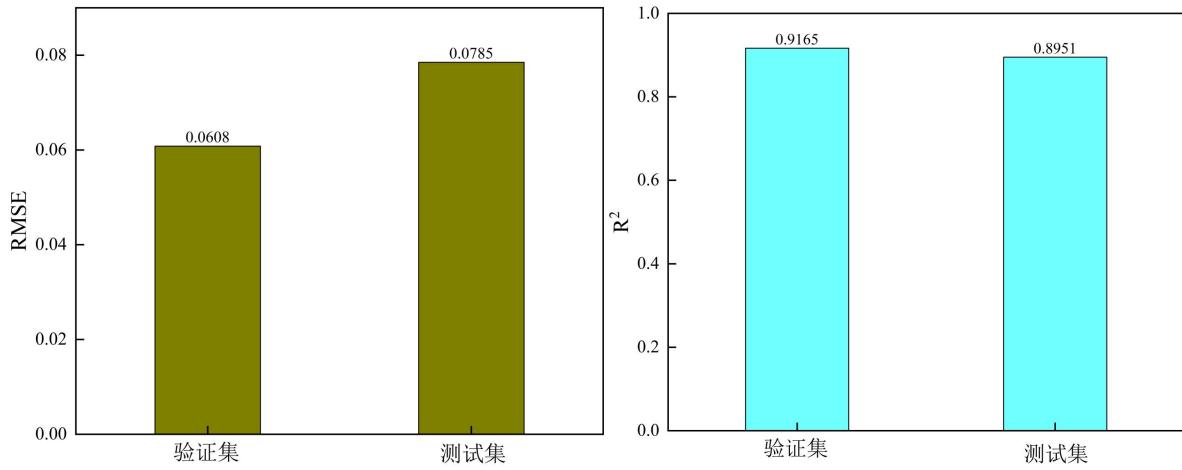
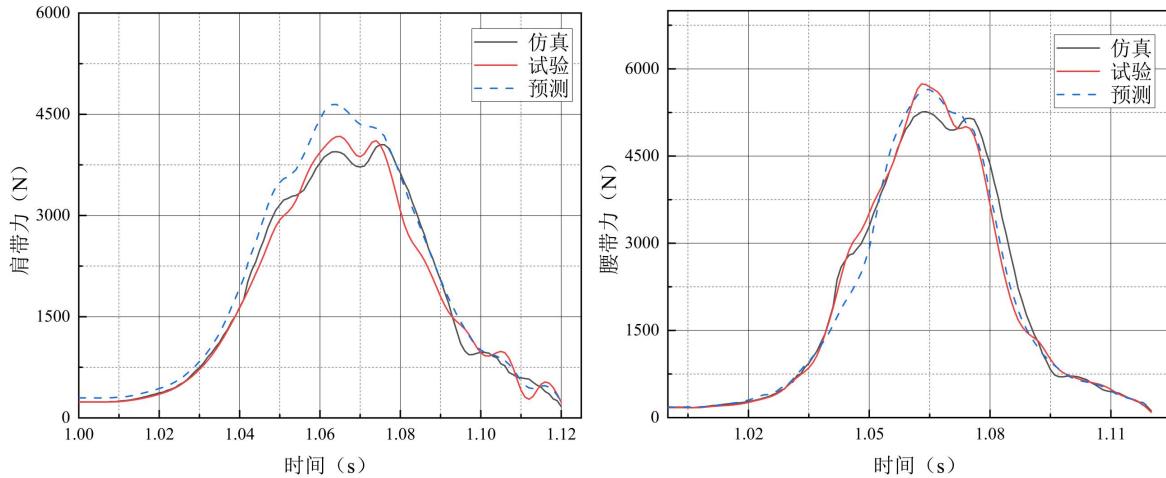


Figure 6. Prediction accuracy of the model

图 6.模型的预测精度

根据 EARTH 方法, 对 AEB+crash 工况下的各组响应量进行了试验数据与仿真数据、预测数据之间的拟合度评估。表 2 展示了实验数据与仿真数据在各响应量上的特征误差评分及其 EARTH 综合评分, 这些评分反映了在 AEB+crash 工况中, 仿真模型的有效性验证结果。评估结果显示, 腰带力的 EARTH 评分为最高, 达到了 87.88%, 显示出非常好的拟合效果; 相比之下, 颈部力矩的评分最低, 为 76.51%, 但仍维持在一个相对较高的水平。除此之外, 其他各项响应参数的 EARTH 评分均超过了 80%, 表明实验数据与仿真数据之间的匹配度较高, 进一步验证了仿真模型的有效性和可靠性, 能够较好地再现实际碰撞过程中乘员的受力情况。

表 3 列出了在 AEB+crash 工况下, 预测数据与仿真数据在各响应量上的特征误差评分及其 EARTH 综合评分。这些评分数据反映了仿真模型在预测精度方面的表现。从表中可以看出, 预测评分最高的是腰带力, 达到了 88.73%, 显示出极高的拟合效果; 最低的是胸部压缩量, 评分为 76.72%, 尽管这一评分相对较低, 但仍保持在一个较高的水平。具体而言, 肩带力的 EARTH 综合评分为 87.22%, 头部合成加速度的评分为 87.27%, 颈部力矩的评分为 87.35%。除了胸部压缩量外, 其他各项响应量的 EARTH 综合评分均超过了 87%, 这表明预测数据与仿真数据之间具有较高的拟合度。



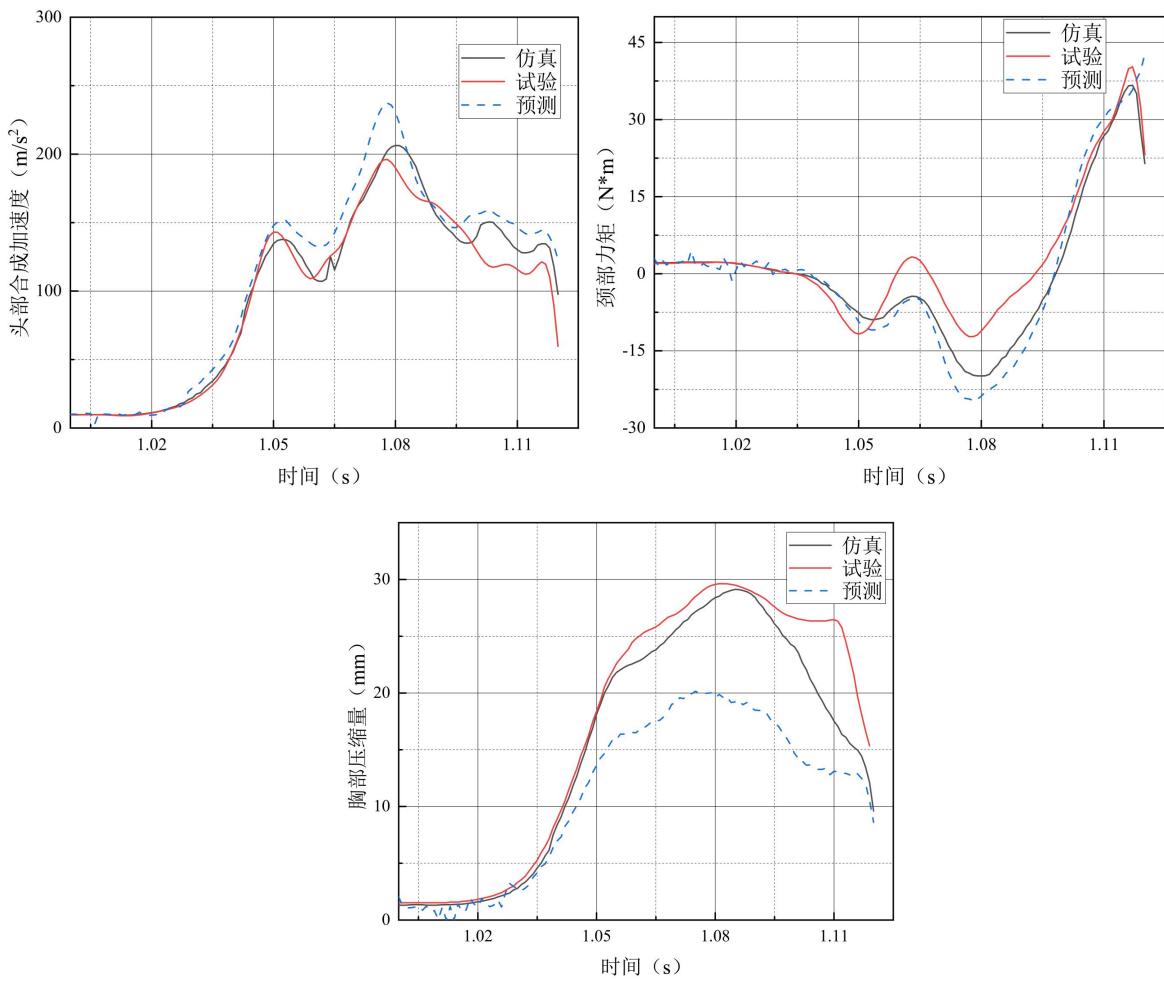


Figure 7. Prediction results of physical neural network

图 7.物理神经网络预测结果

Table 2. Comprehensive EEARTH score for testing and simulation under AEB+crash conditions
表 2. AEB+crash 工况下试验与仿真 EEARTH 综合评分

响应量	相位误差评分	幅值误差评分	形状误差评分	EEARTH 评分
肩带力	89.58%	95.15%	71.92%	85.55%
腰带力	89.58%	95.12%	78.94%	87.88%
头部合成加速度	89.58%	94.32%	65.99%	83.30%
颈部力矩	89.58%	68.49%	75.57%	76.51%
胸部压缩量	82.59%	98.09%	71.86%	85.70%

这些评分结果不仅验证了仿真模型的有效性和可靠性，还进一步证明了模型在预测各种响应量时的准确性。尤其是对于肩带力、头部合成加速度和颈部力矩等关键指标，其评分均维持在较高的水平，这说明模型在模拟这些响应量时能够很好地再现实际碰撞过程中的受力情况。尽管胸部压缩量的评分稍低，但这并不影响整体模型的预测性能。总体而言，这些评分结果表明所使用的仿真模型在 AEB+crash 工况下具有很高的预测精度，能

够为后续的车辆安全设计提供可靠的参考数据。因此，可以认为这些仿真数据具有较高的保真度，能够有效地用于修正和优化 AEB+crash 试验数据的预测，从而提升整体车辆安全性能。

Table 3. EEARTH comprehensive score for prediction and simulation under AEB+crash conditions

表 3. AEB+crash 工况下预测与仿真 EEARTH 综合评分

响应量	相位误差评分	幅值误差评分	形状误差评分	EEARTH 评分
肩带力	89.58%	91.25%	80.83%	87.22%
腰带力	89.58%	95.20%	81.40%	88.73%
头部合成加速度	94.79%	91.24%	75.79%	87.27%
颈部力矩	94.79%	87.56%	79.68%	87.35%
胸部压缩量	89.58%	63.39%	77.19%	76.72%

图 8 所示为各响应试验评分与预测评分的对比图，从图中可以看出腰带力试验评分与预测评分的误差最小，误差为 0.85%，显示出了良好的预测性能；颈部力矩的试验评分和预测评分最大为 10.84%，具体分析颈部力矩的各误差评分主要是颈部力矩的幅度误差偏差较大导致总评分误差较大，其余 3 个响应量的误差都在 10% 以内都在可接受的范围内，基于此可看出本文提出的物理神经网络能较好的预测出 AEB+crash 的试验数据，能够对缺少实验数据的碰撞仿真模型精度进行预测。

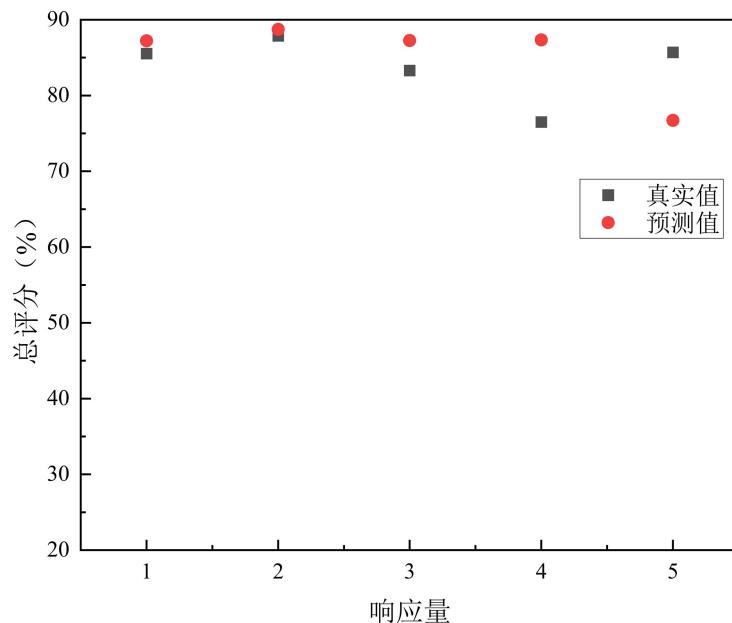


Figure 8. Comparison of predicted and actual scores of collision response under AEB action

图 8. AEB+crash 工况响应量预测与实际评分对比

5 结论

本文针对现代汽车工业中车辆动态行为的准确模拟问题，探讨了如何确保仿真模型的准确性和可靠性。目前，汽车仿真模型验证主要集中在建立合理的验证指标体系和通过数据一致性检验验证模型的有效性。然而，现有方法在处理高维复杂系统和不确定数据源时仍存在局限性。为解决这些问题，本文提出了一种基于物理信息神经网络（PINNs）的汽车主被动仿真模型泛化方法。通过构建一个副网络来学习独立碰撞工况下输入与输出之间的隐式物理关系，并将其嵌入到用于预测 AEB+crash 工况下的实验数据的主网络中，用副网络对主网络进行修正从而实现对 AEB+crash 试验数据的准确预测。实验结果表明，该方法在预测精度和有效性方面具有优越性，能够显著提高模型的准确性和可靠性，后续可以用在高速损伤研究中。

参考文献 (References)

- [1] 方可, 周玉臣, 赵恩娇. 关于仿真模型验证指标体系的探讨 [J]. 系统工程与电子技术, 2017, 39(11):11. DOI:10.3969/j.issn.1001-506X.2017.11.29.
- [2] 罗檬. 基于数据一致性检验的仿真模型验证方法研究[D]. 哈尔滨工业大学, 2017.
- [3] Hu J, Zhou Q, McKeand A, et al. A model validation framework based on parameter calibration under aleatory and epistemic uncertainty[J]. Structural and Multidisciplinary Optimization, 2021, 63(2):645-660. DOI:10.1007/s00158-020-02715-z.
- [4] 陈小勇. 动态系统仿真模型验证方法及工具研究[D]. 长沙理工大学, 2019. DOI:10.26985/d.cnki.gcsjc.2019.000077.
- [5] 李伟, 周玉臣, 林圣琳, 等. 仿真模型验证方法综述 [J]. 系统仿真学报, 2019, 31 (07): 1249-1256. DOI:10.16182/j.issn1004731x.joss.19-0250.
- [6] Fachada N, Lopes V V, Martins R C, et al. Model-independent comparison of simulation output[J]. Simulation Modelling Practice and Theory, 2017, 72: 131-149.
- [7] 廖卓, 赵敬培, 罗龙健. 汽车动态系统仿真模型验证方法综述 [J]. 时代汽车, 2023, (10): 22-24.
- [8] 张雪钊. 新能源汽车整车及动力系统精确建模方法研究 [J]. 时代汽车, 2023, (09): 93-95.
- [9] 朱耿焘. 基于卷积神经网络的模型验证方法[D]. 哈尔滨工业大学, 2022. DOI:10.27061/d.cnki.ghgdu.2022.002357.
- [10] 周玉臣, 方可, 马萍, 等. 基于集成学习的复杂仿真模型验证方法 [J]. 系统工程与电子技术, 2018, 40 (09): 2124-2130.
- [11] Hu J, Zhou Q, McKeand A, et al. A model validation framework based on parameter calibration under aleatory and epistemic uncertainty[J]. Structural and Multidisciplinary Optimization, 2021, 63: 645-660.
- [12] 郑凯, 胡洁, 彭颖红, 等. 结合定性知识的定量贝叶斯模型外推方法 [J]. 上海交通大学学报, 2012, 46 (06): 994-998. DOI:10.16183/j.cnki.jsjtu.2012.06.029.
- [13] Raissi M, Perdikaris P, Karniadakis G E. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations[J]. Journal of Computational physics, 2019, 378: 686-707.
- [14] Wang H, Zhao H, Zhan Z, et al. Prediction Model of Material Dynamic Mechanical Properties Embedded with Physical Mechanism Neural Network[J]. JOM, 2024: 1-11.
- [15] Liu X, He J, Huang S. Mechanistically informed artificial neural network model for discovering anisotropic path-dependent plasticity of metals[J]. Materials & Design, 2023, 226: 111697.
- [16] Diao Y, Yang J, Zhang Y, et al. Solving multi-material problems in solid mechanics using physics-informed neural networks based on domain decomposition technology[J]. Computer Methods in Applied Mechanics and Engineering, 2023, 413: 116120.
- [17] Cranmer M, Greydanus S, Hoyer S, et al. Lagrangian neural networks[J]. arXiv preprint arXiv:2003.04630, 2020.
- [18] 詹振飞. 面向汽车安全的不确定性多元动态系统模型验证理论和应用研究[D]. 上海交通大学, 2011.