

一种基于ANFIS的自动驾驶汽车交通风险 预判模型

赵楚铃, 罗振宇, 曾爱桢

桂林电子科技大学建筑与交通工程学院, 广西 桂林

收稿日期: 2025年6月16日; 录用日期: 2025年7月16日; 发布日期: 2025年7月25日

摘 要

为降低交通事故风险并提升自动驾驶车辆的通行安全性和效率, 研究了一种基于自适应神经模糊推理系统(ANFIS)的自动驾驶交通风险预判方法。首先, 以车辆速度和加速度作为量化指标, 构建交通风险预判模型的输入参数。其次, 利用MATLAB工具箱对数据进行模糊化处理, 通过模糊规则确定输入隶属度, 计算隶属度的可信度及规则的综合适应度, 并结合人工神经网络的训练能力, 优化模型的决策质量和风险管理能力。最后, 通过仿真验证, 结果表明该模型的交通风险预测误差约为13.77%, 误差较小, 能够有效实现自动驾驶汽车的交通风险预判, 为后续优化自动驾驶汽车性能、确保其行驶安全性和可靠性提供了有力支持。

关键词

5G通信, ANFIS, 风险预判, 危险驾驶

A Self-Driving Car Traffic Risk Prediction Model Based on ANFIS

Chuling Zhao, Zhenyu Luo, Aizhen Zeng

School of Architecture and Transportation, Guilin University of Electronic Technology, Guilin Guangxi

Received: Jun. 16th, 2025; accepted: Jul. 16th, 2025; published: Jul. 25th, 2025

Abstract

To reduce the risk of traffic accidents and enhance the safety and efficiency of autonomous vehicles, a method for traffic risk prediction in autonomous driving based on the Adaptive Neuro-Fuzzy Inference System (ANFIS) has been studied. Firstly, vehicle speed and acceleration are used as quantitative indicators to construct the input parameters of the traffic risk prediction model. Secondly,

文章引用: 赵楚铃, 罗振宇, 曾爱桢. 一种基于 ANFIS 的自动驾驶汽车交通风险预判模型[J]. 交通技术, 2025, 14(4): 513-521. DOI: 10.12677/ojtt.2025.144051

the data is fuzzified using the MATLAB toolbox. The membership degrees of the inputs are determined through fuzzy rules, and the credibility of the membership degrees and the comprehensive adaptability of the rules are calculated. Combining this with the training capability of artificial neural networks, the decision quality and risk management capability of the model are optimized. Finally, the model is verified through simulation, and the results show that the traffic risk prediction error of the model is approximately 13.77%, which is relatively low. This demonstrates the model's effectiveness in predicting traffic risks for autonomous vehicles and provides strong support for further optimizing the performance of autonomous vehicles and ensuring their driving safety and reliability.

Keywords

5G Communication, ANFIS, Risk Prediction, Dangerous Driving

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

根据全球道路安全报告的交通事故统计, 全球每年约有 130 万人因道路事故丧生, 近 5000 万人受伤。自动驾驶技术通过减少人为错误、提高道路通行能力和适应不同驾驶环境, 有助于降低交通事故发生率并提升交通效率。然而, 现有技术应对复杂路况、极端条件和突发状况时仍有不足, 可能导致严重的安全问题。

为降低交通事故风险, 国内外学者为此投入了大量的研究, 孙启鹏等[1]利用模糊逻辑方法构建驾驶员的风险感知模型, 构建自动驾驶汽车的综合效用函数, 并采用离散动作空间进行策略博弈, 现实中车辆的动作连续。严利鑫等[2]根据驾驶员对于车辆行驶环境风险实施做出反应的特征, 提出一种智能汽车人机共驾模式的决策方法, 但是考虑因素不够全面且未能进行模拟实验对研究结果进行论证。Samyeul 等[3]提出了一个能够预测、评估在城市自动驾驶风险的评估框架, 但在风险评估过程中对于影响因素考虑不够充足, 导致评估结果具有不确定性。JinWei 等[4]提出了一种基于自动驾驶的交互式插入车辆预测及风险评估设计框架, 但没有考虑复杂的多车交互场景下的自动驾驶插入车辆的情况。SHENG 等[5]提出了一种检测驾驶员疲劳程度的自动驾驶和远程驾驶模式切换框架, 但未考虑用汽车的运动传感器数据来检测异常驾驶行为。贾安琪等[6]提出一种基于 BP 神经网络的驾驶疲劳预测模型, 但缺乏考虑驾驶过程中的数据主观性。李海青等[7]提出一种基于人类风险感知机理的智能汽车拟人驾驶风险量化方法, 但涉及多个复杂的模型和计算过程, 导致模型的复杂性较高, 难以在实时性要求较高的自动驾驶系统中高效运行。

已有的大部分研究中, 大多采用模糊算法来解决自动驾驶情况下的主观不确定因素, 或利用神经网络、机器学习等算法来探究交通风险规律, 但很少考虑到将二者优势结合赋予模型自主学习能力且适应于现实环境下驾驶员主观判断的模型。因此, 本文提出了一种在 5G 环境下基于自适应神经模糊推理系统(ANFIS)的自动驾驶汽车交通风险预判方法, 该方法结合了模糊算法和人工神经网络的优势, 考虑到不同驾驶员的习惯差异带来的不确定性, 同时具备神经网络的自主学习优势。车辆特征行为可以客观反映潜在的危险驾驶情况, 这些异常行为通常能被内部传感器或监控系统监测和记录。本文采用传感器所收集到的车辆速度以及加速度作为模型的输入, 通过分析这类数据特征, 得到的预测结果可以提前预警驾

驶员。该方法旨在对当前交通风险进行量化评估，并分析主车与其他车辆间的相互作用强度，形成有效的风险预判机制，以提高对外部风险的感知灵敏度，增强交通风险预判的效率与安全性。

2. 自动驾驶汽车交通风险预警指标选取

由于车辆驾驶行为对事故产生息息相关，但不同个体之间的差异不尽相同。对于目前人工驾驶车辆和自动驾驶车辆混合的道路情况而言，应当考虑驾驶人产生的主观因素，但不同驾驶人之间驾驶的影响因素受到其年龄、驾驶经验、性别等主观因素影响，此类主观因素难以量化。通过梳理文献发现，张晖等[8]试验结果表明车辆的速度标准差、速度极差、加速度均值以及加速度最大值等影响因素对车辆驾驶产生的风险影响度更大。黄江涛等[9]认为驾驶速度是驾驶过程中最重要的因素，并将驾驶速度独立划分为一级指标。因此本文参考学者研究成果，设置风险驾驶因素体系指标如图 1 所示，考虑到速度是影响自动驾驶的重要因素之一，同样加速度是衡量车辆动态行为的重要指标，并且速度与加速度的变化可以一定程度上体现驾驶人行为以及习惯，能够有效反映车辆的动态行为和潜在风险。本文为提高计算效率，故后续实验采用速度和加速度作为自动驾驶风险的核心评估指标。




Figure 1. Factors affecting risky driving
图 1. 风险驾驶影响因素

3. 基于 ANFIS 的交通风险预判模型分析

3.1. ANFIS 的实现原理与训练

在自动驾驶过程中，车辆特征行为能够客观反映驾驶者的危险驾驶行为。这些异常行为通常由内部传感器或监控系统实时监测和记录。通过分析这些数据特征，系统可以识别潜在的危险驾驶情况，并提前预警驾驶员。然而，不同驾驶员的驾驶行为和习惯存在显著差异，导致他们对驾驶环境的适应能力和应对突发状况的能力有所不同，增加了驾驶风险评估的模糊性。

考虑到交通风险的模糊特性，本文结合了模糊算法以解决主观不确定性问题，并利用人工神经网络的自主学习优势，构建了一种基于自适应神经模糊推理系统(ANFIS)的自动驾驶汽车交通风险预判及车辆故障诊断系统。

该模型具有自主学习和推理过程明确的优点，使模型能够更好地反应实际系统的特征，其计算过程如 ANFIS 流程图(见图 2)。




Figure 2. ANFIS flow chart
图 2. ANFIS 流程图

3.2. ANFIS 模型的原理

ANFIS 模型是一种包含五层一阶 Sugeno 模型，包含两个输入量，如图所示。节点之间的连接具有信息可流动性，矩形节点表示可自适应调整参数的节点，圆形节点表示固定节点。ANFIS 的层次结构图(见图 3)。




Figure 3. The hierarchy of ANFIS
图 3. ANFIS 的层次结构

假设该模型有 x, y 两个输入量和 f 一个输出量, 形成两个 if-then 模糊规则, 模糊规则如下式:

规则 1:

$$\text{if } x = A_1 \quad y = B_1, \text{ then } f_1 = p_1 x + q_1 y + r_1 \quad (1)$$

规则 2:

$$\text{if } x = A_2 \quad y = B_2, \text{ then } f_2 = p_2 x + q_2 y + r_2 \quad (2)$$

式中: f_i 为规则 i 所对应的输出量; A_i, B_i 为规则 i 的非线性参数; p_i, q_i, r_i 为规则 i 的结论参数。

第一层: 输入层, 本层节点将输入信号模糊化。

首先, 选择多源传感器融合后的数据作为输入, 通过模糊规则对输入数据进行模糊化, 得到各个输入的隶属度。

如下式:

$$O_i^1 = \mu_{A_i}(x), i = 1, 2 \quad (3)$$

$$O_j^1 = \mu_{B_j}(y), j = 1, 2 \quad (4)$$

式中: i, j 作为节点; x, y 作为节点 i, j 的输入; A_i, B_j 表示模糊集; $\mu_{A_i}(x)$ 、 $\mu_{B_j}(y)$ 表示各个输入的隶属度函数; O_i^1 、 O_j^1 分别表示第一层中 A_i 、 B_j 的隶属度函数值。

第二层: 规则层。计算每条准则的综合适应度。

进一步的, 本层节点通过计算不同模糊集合隶属度函数的乘积, 得出各条模糊规则的可信度, 并将该乘积作为每条规则的综合适应度, 用于评估规则的整体有效性。

如下式:

$$O_i^2 = \omega_i = \mu_{A_i}(x) \times \mu_{B_j}(y), i = 1, 2 \quad (5)$$

式中, O_i^2 为每条准则的综合适应度; ω_i 为第 i 条规则的可信度。

第三层: 归一化层。计算归一化结果。

进一步的, 本层节点将第二层所得的各条规则的可信度进行归一化处理, 这一过程涉及到将每条规则的激活强度除以所有规则激活强度的总和, 从而得到每条规则的归一化权重。即: 计算第 i 条规则的 ω_i 和全部规则可信度之和 $\sum \omega_i$ 的比值, 该层负责监督处理各条规则的激励过程, 表示各条不同规则在所有规则中的触发比重。

如下式:

$$O_i^3 = \bar{\omega}_i = \frac{\omega_i}{(\omega_1 + \omega_2)}, i = 1, 2 \quad (6)$$

$\bar{\omega}_i$ 表示每条规则对最终输出的相对贡献。

第四层: 结论层。本层节点负责计算各条规则的输出结果。

如下式:

$$O_i^4 = \bar{\omega}_i f_i = \bar{\omega}_i (p_i x + q_i y + r_i), i = 1, 2 \quad (7)$$

第五层: 去模糊化层。

进一步的, 本层节点负责计算每条规则的输出, 并将所有规则的输出进行加权求和得到最终输出结果。基于输出结果对各条规则的结果进行加权平均。该步骤负责将模糊规则的输出转换为一个精确的数值。

本层节点为固定节点, 用于计算所有输入信号的总输出。对各条规则的结果进行加权平均。

如下式:

$$O_i^s = \sum \overline{\omega_i} f_i = \frac{\sum \omega_i f_i}{\sum \omega_i}, i = 1, 2 \tag{8}$$

上述过程确定了自适应神经模糊推理系统网络结构。

3.3. ANFIS 模型的训练

本文首先通过公开数据集设计模型。

本文采用公开数据集中 2021 年美国州际公路的自动驾驶车辆轨迹数据(来源: Kaggle), 包含车辆速度、加速度及事故标签(由车载传感器与交通管理部门事故报告交叉验证生成)。共筛选 200 组有效样本, 按 7:2:1 比例分层随机划分训练集(140 组)、验证集(40 组)和测试集(20 组), 确保事故样本在各类别中均匀分布。本文需确定模型的基本设置。以聚类法生成速度与加速度模糊集合, 详见表 1。

Table 1. Fuzzy collection of speed and acceleration
表 1. 速度与加速度模糊集合

类型	低范围	中范围	高范围
速度	[0.98, 27.54]	[27.54, 90.2]	[90.2, 149.92]
加速度	[0, 1.23]	[1.23, 3.72]	[3.72, 5]

以网格分割法生成模糊规则, 并选用线性输出层隶属度函数, 钟型输入隶属度函数。




Figure 4. ANFIS model structure diagram
图 4. ANFIS 模型结构图

在本研究中, 利用 MATLAB 的 Neuro Fuzzy Designer 工具箱通过自适应神经模糊推理系统(ANFIS)训练样本, 构建了一个用于预测危险驾驶行为风险的模型。在模型开发过程中, 对隶属度函数的数量和训练次数进行了多次调整。最终, 确定使用 15 个隶属度函数, 并将训练次数设定为 50 次。根据 MATLAB 生

成的 ANFIS 模型结构图(参见图 4)，该模型包括以下层次：输入变量层(input)、输入变量的隶属函数层(inputmf)、规则层(rule，包含 225 条规则，即 15×15)、输出隶属函数层(outputmf)以及输出结果层(output)。实验结果显示，训练集的最终误差为 0.088735，表明模型在训练数据上的表现良好，从而完成了参数调试与优化步骤。



Figure 5. Data training results
图 5. 数据训练结果

为了进一步验证训练后的 ANFIS 模型的性能，对 40 个测试样本进行了仿真分析。将测试集数据输入到已训练好的 ANFIS 模型中，通过对比模型输出的预测值与实际值发现，仿真效果较为理想，偏差较小，并且在可接受范围内(参见图 5)。这表明模型对于未知数据具有良好的预测能力。

此外，为了更客观地评估模型的拟合情况，采用了平均测试误差和均方根误差作为评价指标。计算结果显示，平均测试误差为 0.13772，均方根误差为 0.15031。这两个指标的数值相对较低，说明该 ANFIS 模型在学习样本数据的信息方面表现出色，能够实现对样本数据的精准仿真。因此，可以认为经过参数调试优化后的 ANFIS 模型具有较高的可靠性和泛化能力，适用于危险驾驶行为的风险预判工作。

这些结果共同证明了所提出的基于 ANFIS 的模型在处理危险驾驶行为风险预判问题上的有效性及其潜在的应用价值。

基于训练好的 ANFIS 模型，本文以 2021 年美国某地区的车辆速度与加速度作为输入变量，以 2021 年美国某地区车辆是否发生交通事故作为输出变量，对该区域 2021 年自动驾驶汽车的交通风险进行预测，并对照交通风险等级对其进行划分风险状态，从而实现预警，结果参见表 2。

从预测结果来看，由 ANFIS 得到的 2021 年该区域自动驾驶汽车的交通风险预判结果较好，但考虑实际情况，ANFIS 不可能产生很完美的预测结果，因为除了风险驾驶的所有指标外，道路情况和天气状态也在一定程度上影响驾驶情况，面对极端路面情况或异常天气情况驾驶情况会发生较大改变，模型预测的准确率随之降低，且训练集和测试集中的部分数据存在部分矛盾的情况，此类矛盾数据对模型的预测结果有影响。总体而言，本文构建的 ANFIS 模型在预测性能方面表现良好，能够有效满足预测需求，

并达到了较高的精度水平。

Table 2. Traffic risk forecast value in a certain region of the United States in 2021
表 2. 2021 年美国某区域交通风险预测值

速度	加速度	风险值	是否发生风险
33.14	4.17	0.6813	否
19.46	-0.2	0.1210	否
27.54	3.66	0.3642	否
73.97	-4.39	0.6762	否
69.3	4.81	0.6423	否
111.03	4.56	0.9145	是
120.55	4.29	0.8174	是
...	...	...	...

4. 总结

由于交通风险的影响因素复杂繁多，这些因素存在较大不确定性，同时还存在较强的主观性。尽管采用模糊算法和神经网络可以量化交通风险，但模糊算法不具备自主学习能力，神经网络不能体现主观性。因此，ANFIS 模型结合二者优点，相较于模糊算法具备更强的可解释性和自适应性，同时相较于人工神经网络具备处理主观复杂场景的能力，从而实现对实际系统的精确建模。

本文基于 ANFIS 的自动驾驶汽车交通风险预判模型，考虑车辆速度与加速度作为模型的两个输入，将是否发生交通事故作为模型输出，经过仿真实验得到以下结论：

- (1) 模型数据的训练和检验结果表明，本文所建立的 ANFIS 模型复合实际要求，且具备较高的可靠性，误差较小。
- (2) 在驾驶过程中，车辆的驾驶状态受到多种因素的综合影响，导致交通风险预判模型的构建往往面临复杂性和计算成本的双重挑战。然而，本文通过对驾驶过程的文献查阅和深入分析，识别出车辆速度与加速度这两个对驾驶状态影响最为明显的因素，并将其作为模型的核心输入变量。这种简化策略不仅能够有效聚焦于驾驶过程的关键动态特征，避免因过多因素引入而导致的模型冗余和复杂性增加，同时显著提高模型的计算效率，从而在保证预判精度的前提下，实现对交通风险的快速、高效预判。

尽管本文所建立的交通风险预判模型具备上述优点，但用于模型训练与检验的数据量较少，且并未考虑自动驾驶汽车在极端环境(天气、地势)作为影响因子的情况，模型的精度和适用范围仍有不足。故在后续的研究中，应当考虑继续收集不同环境下的自动驾驶汽车驾驶数据，增加样本数量，同时将极端环境因素考虑在内。

基金项目

国家级大学生创新训练项目(20231059006)资助。

参考文献

[1] 孙启鹏, 武智刚, 曹宁博, 马飞, 杜婷竺. 基于风险预测的自动驾驶车辆行为决策模型[J]. 浙江大学学报(工学版), 2022, 56(9): 1761-1771.

[2] 严利鑫, 吴超仲, 贺宜, 等. 人机共驾智能车驾驶模式决策属性析取研究[J]. 中国公路学报, 2018, 31(1): 120-127.

-
- [3] Noh, S. and An, K. (2022) Reliable, Robust, and Comprehensive Risk Assessment Framework for Urban Autonomous Driving. *Journal of Computational Design and Engineering*, **9**, 1680-1698. <https://doi.org/10.1093/jcde/qwac079>
 - [4] Sheng, W.H., Ou, Y.S., Tran, D., Tadesse, E., Liu, M.Q. and Yan, G.F. (2013) An Integrated Manual and Autonomous Driving Framework Based on Driver Drowsiness Detection. 2013 *IEEE/RSJ International Conference on Intelligent Robots and Systems*, Tokyo, 3-7 November 2013, 4376-4381. <https://doi.org/10.1109/iros.2013.6696984>
 - [5] Xia, S., Wen, X., Yao, Z., Li, Y. and Wang, G. (2020) Dynamic Task Offloading and Resource Allocation for Heterogeneous MEC-Enable IoT. 2020 *IEEE/CIC International Conference on Communications in China (ICCC)*, Chongqing, 9-11 August 2020, 847-852. <https://doi.org/10.1109/iccc49849.2020.9238863>
 - [6] 贾安琪, 邓超. 基于 BP 神经网络的驾驶疲劳预测模型及其有效性分析[J]. 农业装备与车辆工程, 2024, 62(2): 40-43.
 - [7] 李海青, 李永福, 郑太雄, 等. 智能汽车拟人驾驶风险量化方法研究[J]. 电子测量与仪器学报, 2023, 37(8): 120-127.
 - [8] 张晖, 刘永杰, 吴超仲, 等. 考虑行车安全事件严重程度和个体差异的驾驶行为风险评估[J]. 中国安全, 2023, 33(7): 24-31.
 - [9] 黄江涛, 王鑫, 乔少杰. 面向车联网的自适应危险驾驶行为分析与预测框架[J]. 无线电工程, 2023, 53(6): 1311-1320.