车贷风险预测方法、装置、存储介质及电子设备

相关申请的交叉引用

本申请要求于2025年02月26日提交中国专利局的申请号为2025102181777,名称为“车贷风险预测方法、装置、存储介质及电子设备”的中国专利申请的优先权，其全部内容通过引用结合在本申请中。

技术领域

本申请涉及机器学习领域，具体而言，涉及一种车贷风险预测方法、装置、存储介质及电子设备。

背景技术

在现代金融风险管理中，预测风险是一项至关重要的任务。传统的风险预测模型主要基于历史数据和固定的风险特征进行建模，然后使用这些模型来预测未来的风险。然而，这种方法存在一些明显的缺点。由于这种方法通常假设风险特征是静态的，因此，忽略了风险特征可能会随时间变化。即使某些技术已经尝试通过适应风险特征的变化来改进模型，但这些改进方法仍然对突发性风险不够敏感。

申请内容

为了克服现有技术中的至少一个不足，本申请提供一种车贷风险预测方法、装置、存储介质及电子设备，具体包括：

第一方面，本申请提供一种车贷风险预测方法，所述方法包括：

获取借款人在当前还款周期的逾期风险特征；

通过神经网络架构的风险评估模型对所述逾期风险特征进行处理，得到所述借款人在所述当前还款周期的第一风险得分；

通过预先拟合出的自回归移动平均模型对所述逾期风险特征进行处理，得到所述借款人在所述当前还款周期的第二风险得分；

根据所述第一风险得分与所述第二风险得分，得到所述借款人的综合风险得分。

第二方面，本申请提供一种车贷风险预测装置，所述装置包括：

风险特征模块，用于获取借款人在当前还款周期的逾期风险特征；

风险得分模块，用于通过神经网络架构的风险评估模型对所述逾期风险特征进行处理，得到所述借款人在所述当前还款周期的第一风险得分；

所述风险得分模块，还用于通过预先拟合出的自回归移动平均模型对所述逾期风险

特征进行处理，得到所述借款人在所述当前还款周期的第二风险得分；

风险综合模块，用于根据所述第一风险得分与所述第二风险得分，得到所述借款人的综合风险得分。

第三方面，本申请提供一种存储介质，所述存储介质存储有计算机程序，所述计算机程序被处理器处理的条件下，实现所述的车贷风险预测方法。

第四方面，本申请提供一种电子设备，所述电子设备包括处理器以及存储器，所述存储器存储有计算机程序，所述计算机程序被所述处理器处理的条件下，实现所述的车贷风险预测方法。

相对于现有技术而言，本申请具有以下有益效果：

本申请提供一种车贷风险预测方法、装置、存储介质及电子设备。电子设备获取借款人在当前还款周期的逾期风险特征；通过神经网络架构的风险评估模型对逾期风险特征进行处理，得到借款人在当前还款周期的第一风险得分；通过预先拟合出的自回归移动平均模型对逾期风险特征进行处理，得到借款人在当前还款周期的第二风险得分；根据第一风险得分与第二风险得分，得到借款人的综合风险得分。如此，由于神经网络架构的风险评估模型能够更好地捕捉突发性事件的影响，从而弥补了自回归移动平均模型对突发性事件不敏感的缺陷，提高了对逾期风险的预测精度。

附图说明

为了更清楚地说明本申请实施例的技术方案，下面将对实施例中所需要使用的附图作简单地介绍，应当理解，以下附图仅示出了本申请的某些实施例，因此不应被看作是对范围的限定，对于本领域普通技术人员来讲，在不付出创造性劳动的前提下，还可以根据这些附图获得其他相关的附图。

图 1 为本申请实施例提供的车贷风险预测方法的流程示意图；

图 2 为本申请实施例提供的车贷风险预测方法的流程细示意图之一；

图 3 为本申请实施例提供的特征变化信息的示意图；

图 4 为本申请实施例提供的车贷风险预测方法的流程细示意图之二；

图 5 为本申请实施例提供的车贷风险预测方法的流程细示意图之三；

图 6 为本申请实施例提供的车贷风险预测装置的结构示意图；

图 7 为本申请实施例提供的电子设备的结构示意图。

具体实施方式

为使本申请实施例的目的、技术方案和优点更加清楚，下面将结合本申请实施例中的附图，对本申请实施例中的技术方案进行清楚、完整地描述，显然，所描述的实施例是本申请一部分实施例，而不是全部的实施例。通常在此处附图中描述和示出的本申请

实施例的组件可以以各种不同的配置来布置和设计。

因此，以下对在附图中提供的本申请的实施例的详细描述并非旨在限制要求保护的本申请的范围，而是仅仅表示本申请的选定实施例。基于本申请中的实施例，本领域普通技术人员在没有作出创造性劳动前提下所获得的所有其他实施例，都属于本申请保护的范围。

应注意到：相似的标号和字母在下面的附图中表示类似项，因此，一旦某一项在一个附图中被定义，则在随后的附图中不需要对其进行进一步定义和解释。

在本申请的描述中，术语“第一”、“第二”、“第三”等仅用于区分描述，而不能理解为指示或暗示相对重要性。此外，术语“包括”、“包含”或者其任何其他变体意在涵盖非排他性的包含，从而使得包括一系列要素的过程、方法、物品或者设备不仅包括那些要素，而且还包括没有明确列出的其他要素，或者是还包括为这种过程、方法、物品或者设备所固有的要素。在没有更多限制的情况下，由语句“包括一个……”限定的要素，并不排除在包括所述要素的过程、方法、物品或者设备中还存在另外的相同要素。

基于以上声明，正如背景技术中所介绍的，即使某些技术已经尝试通过适应风险特征的变化来改进模型，但这些改进方法仍然对突发性风险不够敏感。

示例性地，以自回归移动平均模型（Autoregressive Integrated Moving Average Model，ARIMA）为例（以下简称为 ARIMA 模型）。ARIMA 模型是一种常用的时间序列预测方法，该模型结合了自回归模型（AR）和移动平均模型（MA）。ARIMA 模型的基本思想是通过分析时间序列的历史数据，识别其中的模式和趋势，并利用这些模式对未来值进行预测。为了达到该目的，ARIMA 模型包含三个组成部分：自回归项（AR）、差分项（I）和移动平均项（MA）。自回归项表示当前值与过去若干期的值之间的线性关系，差分项用于使时间序列变得平稳，移动平均项则用来捕获误差项的自相关性。通过这三个部分的组合，ARIMA 模型能够有效地捕捉时间序列中的短期波动和长期趋势。

然而，尽管 ARIMA 模型在处理平稳时间序列数据方面表现出色，但该模型对突发性风险不够敏感。这主要是因为 ARIMA 模型主要依赖于历史数据中的模式和趋势来进行预测。当出现突发性事件（如经济危机、自然灾害等）时，这些事件往往没有先例，无法通过历史数据预测到。因此，ARIMA 模型可能无法及时调整其预测模型以应对这些突发性变化，从而导致预测的不准确。

基于上述技术问题的发现，发明人经过创造性劳动提出下述技术方案以解决或者改善上述问题。需要注意的是，以上现有技术中的方案所存在的缺陷，是发明人在经过实践并仔细研究后得出的结果，因此，上述问题的发现过程以及下文中本申请实施例针对上述问题所提出的解决方案，都应该是发明人在发明创造过程中对本申请做出的贡献，而不应当理解为本领域技术人员所公知的技术内容。

鉴于上述问题，本实施例提供一种车贷风险预测方法。如图 1 所示，该方法包括：

S1，获取借款人在当前还款周期的逾期风险特征。

S2，通过神经网络架构的风险评估模型对逾期风险特征进行处理，得到借款人在当前还款周期的第一风险得分。

S3，通过预先拟合出的自回归移动平均模型对逾期风险特征进行处理，得到借款人在当前还款周期的第二风险得分。

S4，根据第一风险得分与第二风险得分，得到借款人的综合风险得分。

如此，由于神经网络架构的风险评估模型能够更好地捕捉突发性事件的影响，从而弥补了自回归移动平均模型对突发性事件不敏感的缺陷，提高了对逾期风险的预测精度。

值得说明的是，对于本申请中涉及的方案，其涉及与用户隐私相关的数据，在本申请实施例执行过程中收集、产生之前，均以明示形式告知，且通过用户的授权。同时，对于本申请实施例涉及的个人信息，其存储设备的设置位置符合与上述数据相关行为的发生地所在国家/地区的法律法规要求，相关行为包括但不限于：授权、产生、使用、存储等。可以理解为，实施本方案所使用的逾期风险特征，其存储设备的设置位置符合与上述数据相关行为的发生地所在国家/地区的法律法规要求，相关行为包括但不限于：授权、产生、使用、存储等。

此外，还应理解的是，对于本实施例的车贷风险预测方法，实施该方法的电子设备可以是，但不限于，移动终端、平板计算机、膝上型计算机、台式计算机以及服务器等。该服务器可以是单个服务器，也可以是服务器组。服务器组可以是集中式的，也可以是分布式的（例如，服务器可以是分布式系统）。在一些实施例中，服务器相对于用户终端，可以是本地的、也可以是远程的。在一些实施例中，服务器可以在云平台上实现；仅作为示例，云平台可以包括私有云、公有云、混合云、社区云(Community Cloud)、分布式云、跨云（Inter-Cloud）、多云(Multi-Cloud)等，或者它们的任意组合。在一些实施例中，服务器可以在具有一个或多个组件的电子设备上实现。

为使本实施例提供的方案更加清楚，下面以服务器作为实施该方法的电子设备，对图 1 所示方法中的各个步骤进行详细阐述。但应该理解，流程图的操作可以不按顺序实现，没有逻辑的上下文关系的步骤可以反转顺序或者同时实施。此外，本领域技术人员在本申请内容的指引下，可以向流程图添加一个或多个其他操作，也可以从流程图中移除一个或多个操作。因此，继续参见图 1，该方法包括：

S1，获取借款人在当前还款周期的逾期风险特征。

本实施例中，上述多条逾期子特征包括了能够反映借款人是否会逾期的动态特征以及静态特征。示例性地，多条逾期子特征可以包括借款人信用历史特征、收入稳定性特征、车辆相关特征、经济环境风险特征、用户个人特征、车辆定位信息。下面对这些特征分别进行详细说明：

（1）借款人信用历史特征，包括信用卡透支记录、其他贷款的还款记录、信用分值、逾期还款记录、违约记录。

信用卡透支记录，反映了借款人使用信用卡的情况，包括是否有透支行为以及透支

的频率和额度。如果借款人经常透支且未能及时还款，这表明其财务管理能力较差，有可能在车贷还款过程中出现违约。

其他贷款的还款记录，则包括借款人以往所有贷款（如住房贷款、消费贷款等）的还款记录。如果借款人多次出现逾期还款或者拖欠贷款的情况，这说明其还款意愿较低，未来在车贷还款过程中违约的可能性较高。

信用分值，用于评估借款人信用状况的一个量化指标，通常由信用评分机构根据借款人的历史还款记录、透支情况等综合计算得出。信用分值越高，表示借款人的信用越好，违约风险越低；反之，信用分值较低则意味着较高的违约风险。

违约记录，该特征关注借款人在以往贷款中是否存在违约行为。例如，某客户在申请车贷前的两年内，信用卡还款出现逾期次数累计达[X]次，其中连续逾期最长达[X]个月，金融机构据此可初步判定该客户在车贷还款过程中违约风险极高。

因此，通过借款人的历史还款记录、透支情况、信用分值等进行全面评估，可以有效识别潜在的违约风险。

（2）收入稳定性特征，则是本实施例对车贷风险评估中的另一个重要组成部分，主要用于考察借款人的职业类型、工作年限、收入来源等因素，以判断其收入的稳定性和可靠性。

职业类型，由于不同职业的收入稳定性和可靠性存在显著差异。例如，公职人员、国有企业员工、大型企业正式员工等职业因其工作的稳定性和收入的可靠性，相较于自由职业者、个体工商户或小微企业主，违约风险相对较低。这类职业通常有固定的工资和福利待遇，减少了因收入不稳定导致的违约风险。

工作年限，工作年限较长的借款人通常拥有更高的收入稳定性和职业保障。相比之下，工作年限较短的借款人可能面临更大的收入波动和不确定性。例如，工作年限超过[X]年的借款人，其收入稳定性明显高于工作年限不足[X]年的借款人。

收入来源，除了职业类型和工作年限外，收入来源也是衡量收入稳定性的重要因素。例如，拥有多个稳定收入来源（如固定工资、租金收入、投资收益等）的借款人相比仅有单一收入来源的借款人，其收入稳定性更高。多样化的收入来源可以有效缓解单一收入来源带来的风险。

收入变化趋势，通过分析借款人在过去几年内的收入变化趋势，可以进一步了解其收入的稳定性。如果借款人的收入在过去几年内呈上升趋势或保持平稳，这表明其收入稳定性和还款能力较强；反之，如果收入呈现下降趋势，则违约风险较高。

职业前景，某些行业的职业前景较好，收入增长潜力较大。例如，高科技行业、金融行业等，这些行业通常具有较好的职业发展前景和较高的收入水平。因此，从事这些行业的借款人通常具有较高的收入稳定性和还款能力。

因此，本实施例可以通过对借款人的职业类型、工作年限、收入来源、收入变化趋势以及职业前景等方面进行综合评估，可以有效识别借款人的收入稳定性和还款能力。

（3）车辆相关特征是车贷风险评估中的重要组成部分，主要涉及车辆的价值、用途、购买渠道等信息，可以评估车辆作为抵押品的价值和可靠性。

车辆价值，车辆的市场价值是决定车贷额度和贷款比例的关键因素之一。研究发现，车辆的市场价值越高，其作为抵押品的安全性也越高。金融机构通常会参考第三方评估机构提供的车辆估值报告，以确定车辆的实际价值。此外，车辆的残值率也是一个重要的考量因素，残值率高的车辆在未来处置时更容易获得较高的回收价值。

车辆用途，车辆的用途可以分为商用和个人使用两大类。个人使用的车辆通常具有更高的稳定性和较低的贬值速度，而商用车辆由于频繁使用和较高的磨损程度，其贬值速度较快。因此，个人使用的车辆作为抵押品的风险相对较低，而商用车辆则需要更为谨慎的评估。

车辆品牌与型号，不同品牌和型号的车辆在市场上有不同的保值能力和流通性。知名品牌和高端车型通常具有较高的市场认可度和较强的保值能力，而一些小众品牌或低端车型的保值能力相对较弱。因此，在车贷评估中，车辆的品牌和型号也会被纳入考虑范围。

购买渠道，车辆的购买渠道也会影响其作为抵押品的价值和可靠性。通过正规渠道购买的车辆通常具有完整的手续和较高的透明度，而通过非正规渠道购买的车辆可能存在手续不全、权属不清等问题，增加了车辆处置的风险。因此，金融机构更倾向于接受通过正规渠道购买的车辆作为抵押品。

车辆行驶里程，车辆的行驶里程是衡量车辆使用状况的重要指标。行驶里程较低的车辆通常具有更好的车况和更高的残值，而行驶里程较高的车辆可能存在较高的维修成本和较低的残值。因此，车辆的行驶里程也是车贷评估中需要重点考虑的因素之一。

车辆保险情况，车辆的保险情况也是评估其风险的重要因素。全面的车辆保险不仅可以保护车辆在发生事故后的损失，还可以提高车辆的整体安全性。因此，保险公司提供的车辆保险情况报告也是金融机构评估车贷风险的重要依据之一。

因此，车辆相关特征通过对车辆的价值、用途、品牌与型号、购买渠道、行驶里程以及保险情况进行综合评估，可以有效识别车辆作为抵押品的风险。这些特征不仅能够反映车辆的基本状况，还能帮助金融机构更准确地预测未来的还款风险，从而采取适当的措施来管理和降低车贷风险。

（4）经济环境风险也是车贷风险评估中的一个重要组成部分，主要涉及宏观经济因素和市场条件对借款人还款能力的影响。具体而言，这些因素包括以下几个方面：

宏观经济状况，宏观经济状况直接影响借款人的就业机会、收入水平和整体财务状况。例如，经济增长放缓会导致失业率上升、收入减少，从而增加借款人违约的风险。相反，经济增长强劲则有利于提高借款人的收入水平和就业稳定性，降低违约风险。

利率变动，利率的变化对借款人的还款压力有着直接的影响。当利率上升时，借款人的还款负担增加，可能导致部分借款人无法按时偿还贷款，从而增加违约风险。反之，

利率下降则可以减轻借款人的还款压力，提高其还款能力。

通货膨胀率，通货膨胀率高会侵蚀借款人的实际收入，降低其购买力，进而影响其还款能力。高通货膨胀率还会使借款人在还款时支付更多的利息和本金，增加其财务压力。相反，低通货膨胀率有助于维持借款人的购买力和收入水平，降低违约风险。

地区经济状况，地区经济状况的差异也会影响借款人的还款能力。经济发达地区的就业机会更多，收入水平较高，借款人还款能力较强。而在经济欠发达地区，就业机会较少，收入水平较低，借款人还款能力较弱，违约风险较高。

政策法规变动，政策法规的变动也可能对借款人的还款能力产生影响。例如，政府出台的税收政策、信贷政策等都可能直接影响借款人的收入和支出。此外，监管政策的变化，如加强信贷审核、提高首付比例等，也会对借款人还款能力产生影响。

市场竞争状况，市场竞争状况也会影响借款人的还款能力。在一个竞争激烈的市场环境中，借款人可能会面临更大的经济压力，从而增加违约风险。而在一个较为稳定的市场环境中，借款人的还款能力通常更为稳定。

因此，经济环境风险通过对宏观经济状况、利率变动、通货膨胀率、地区经济状况、政策法规变动以及市场竞争状况等方面的综合评估，可以有效识别借款人在经济环境变化下的还款风险。

（5）用户个人特征是车贷风险评估中的关键组成部分，主要涉及借款人的个人信息、信用记录、还款意愿和行为等因素，以评估其作为借款人的可靠性和风险水平。

年龄和职业，研究发现借款人的年龄和职业对其还款能力和稳定性有很大影响。年轻且处于职业生涯初期的借款人可能缺乏稳定的工作经验和较高的收入水平，而年龄较大且具有稳定职业的借款人通常拥有较高的收入和良好的职业前景。此外，借款人是否具备稳定的职业，如公务员、教师、医生等，这些职业通常具有较高的收入稳定性和还款能力。

信用记录，借款人的信用记录是评估其信用状况的重要依据。良好的信用记录表明借款人有良好的还款历史和信誉，而不良的信用记录则意味着借款人可能有过逾期还款或其他信用问题。金融机构通常会参考借款人的信用报告，评估其信用得分和历史还款行为。

收入和负债情况，借款人的收入水平和负债情况是评估其还款能力的重要因素。借款人收入越高，负债越少，其还款能力越强，违约风险越低。金融机构会通过借款人提供的收入证明、银行流水等材料，评估其收入的稳定性和负债的比例。

资产状况，借款人的资产状况也是评估其还款能力的重要因素。拥有较高价值的固定资产（如房产、股票、存款等）可以作为额外的还款保障。金融机构会通过评估借款人的资产状况，了解其财务稳定性和潜在的还款来源。

还款意愿和行为，借款人的还款意愿和历史行为也是评估其信用风险的重要指标。借款人是否有良好的还款习惯，如按时还款、提前还款等，反映了其对债务的认真态度。

此外，借款人是否有过其他贷款或信用卡的使用记录，以及这些记录是否良好，也会影响其信用评分。

教育背景，借款人的教育背景也在一定程度上反映了其还款能力和信用素质。受过高等教育的借款人通常具有更高的职业素养和还款能力，而教育水平较低的借款人可能面临更大的财务压力和还款困难。

家庭状况，借款人的家庭状况，如家庭成员数量、婚姻状况等，也会影响其还款能力和稳定性。单亲家庭或家庭负担较重的借款人可能面临更大的经济压力，而家庭成员较少、婚姻稳定、经济负担较小的借款人通常具有更高的还款能力。

因此，用户个人特征通过对借款人的年龄和职业、信用记录、收入和负债情况、资产状况、还款意愿和行为、教育背景以及家庭状况等方面进行综合评估，可以有效识别借款人的信用风险和还款能力。

（6）车辆定位信息，通过该信息可以得到车辆行驶轨迹、速度、里程等信息，而这些信息有助于更准确地掌握借款人的车辆使用情况，及时发现异常行为，从而提高风险预测的准确性。

作为可选实施方式，为了告知风险评估模型哪些动态特征更加重要，哪些相对不那么重要，当前还款周期的逾期风险特征包括多条逾期子特征以及为每条逾期子特征赋予的预设权重。对此，可以理解为，在进行风险评估时，会将借款人在当前还款周期内的逾期风险特征细分为多个具体的子特征，并为每一个子特征分配一个预先设定好的权重。这样的设计是为了确保在风险评估过程中，不同特征对整体风险的影响能够得到合理的量化和体现。

示例性地，服务器可以将各种动态特征按不同的时间级别进行分组，如日级别变化、周级别变化、月级别变化和年级别变化；然后，对每组中非数值特征进行编码，以便后续进一步处理和计算。在分配权重时，服务器可以从周期变化频率、意向程度、政策敏感度、影响度、经济指标等方面为每条子特征赋予权重。

对于周期变化频率，服务器可以分析各个动态特征的周期变化频率，并根据频率高低分配不同的权重。例如，如果某个特征每天都在变化，那么会被赋予较高的权重；反之，如果特征变化较少，就会被赋予较低的权重。

对于意向程度，服务器可以根据不同时间段内特征对购车、换车、贷款等意向程度的影响，分配不同的权重。例如，在 2 月份用户对贷款的意向较大，因此该月的相关特征会被赋予更高的权重。

对于政策敏感度，服务器可以分析对政策敏感度影响较大的动态特征，如新能源更换补助政策，根据敏感度高低分配不同的权重。如果某一政策变化对风险特征影响较大，那么该政策相关的特征会被赋予较高的权重。

对于影响度，服务器可以考虑国家本年度车辆管理、生产、货币政策等因素，根据这些因素对动态特征的影响程度分配不同的权重。例如，如果某个地区的 GDP 增长较

快，会影响当地的贷款需求和还款能力，那么该地区的特征会被赋予较高的权重。

对于经济指标，服务器可以根据国家省份 GDP 与人均收入等因素，对受影响的动态特征进行加权，以反映经济环境对风险特征的影响。例如，如果某个省份的人均收入较高，那么该省的贷款风险特征会被赋予较低权重。

基于上述实施对借款人风险特征的说明，下面继续对图 1 中的步骤 S2 进行说明：

S2，通过神经网络架构的风险评估模型对逾期风险特征进行处理，得到借款人在当前还款周期的第一风险得分。

本实施例中，上述神经网络架构的风险评估模型可以是经过微调之后的大语言模型。由于该模型通过大量的训练数据，学习了如何理解和处理复杂的文本信息，并能够捕捉到不同风险特征之间的关联性和潜在模式。因此，当将上述借款人的风险特征以文本形式输入给风险评估模型后，风险模型会首先对输入的文本进行解析和理解，识别出关键的风险特征及其权重。接着，模型会运用其内部的神经网络结构，通过一系列的计算和推理过程，分析这些特征如何共同作用于整体风险。最后，模型输出一个综合的第一风险得分，这个得分反映了模型对借款人当前还款周期内逾期风险的预测。

因此，通过这种方式，经过微调的大语言模型不仅能够高效处理多样化的输入数据，还能提供更为准确和可靠的风险评估结果。并且，模型通过额外的训练数据和微调过程，学习了如何快速适应和理解新出现的信息或变化。当面对突发性事件时，该模型能够迅速解析相关的文本数据，识别其中的关键信息和异常情况。例如，在进行风险评估时，如果市场突然出现重大波动或新闻报道了影响借款人信用状况的重要事件，经过微调的大语言模型能够及时捕捉这些信息，并相应地调整风险评估结果。

示例性地，该大语言模型可以是 Qwen-14B。该模型经过了大规模训练的深度学习，具备强大的文本理解和生成能力。因此，通过对 Qwen-14B 进行微调之后，能够用于预测借款人逾期的风险。

基于上述实施例对第一风险得分获取方式说明，下面继续对图 1 中的步骤 S3 进行说明：

S3，通过预先拟合出的自回归移动平均模型对逾期风险特征进行处理，得到借款人在当前还款周期的第二风险得分。

应理解的是，ARMA 模型作为一种常用的时序分析工具，能够捕捉数据中的趋势和季节性成分，并对其进行平滑处理。在这种应用中，该模型首先会对收集到的借款人历史还款数据进行拟合，以确定模型参数。然后，利用这些参数，模型能够对借款人的逾期风险特征进行处理和预测。为了达到该目的，ARMA 模型可以识别并量化各种风险因素的时间序列特性，进而计算出借款人在当前还款周期内的第二风险得分。

相较于大语言模型，ARMA 模型则依赖于数值输入来执行计算和分析，因此无法直接处理非数值型的数据。为了使 ARMA 模型能够有效地工作，输入的风险子特征必须转换为定量形式，即通过某种方法将其转换为数值。例如，借款人的一些定性特征（如

信用记录、还款行为等）可能需要通过评分或编码的方式进行量化。这些量化后的数据能够更好地表示风险特征的变化趋势和模式，从而使 ARMA 模型能够捕捉到这些特征的时间序列特性，进行趋势分析和预测。

在一些实施例中，可以理解的是，当面对突发性事件时，由于神经网络架构的风险评估模型能够迅速解析相关的文本数据，识别其中的关键信息和异常情况，因此，上述第一风险得分可以表征特征变化信息中的突发信息对借款人在当前还款周期的还款风险的影响。

在一些实施例中，由于自回归移动平均模型能够识别并量化各种风险因素的时间序列特性，并基于此计算借款人在当前还款周期内的第二风险得分，因此，第二风险得分可以表征特征变化信息中的非突发信息对借款人在当前还款周期的还款风险的影响。

基于上述实施例对第二风险得分获取方式的说明，下面继续图 1 中的步骤 S4 进行说明：

S4，根据第一风险得分与第二风险得分，得到借款人的综合风险得分。

如此，通过结合由风险评估模型生成的第一风险得分与 ARIMA 模型生成的第二风险得分，可以综合利用两种模型的优势，提高整体预测的准确性。

本实施例中，上述第一风险得分与第二风险得分均是位于$0\sim1$之间的数值，数值越大，表示逾期的风险越高。因此，作为可选实施方式，可以利用预设的权重将第一风险得分与第二风险得分进行加权求和，从而得到综合风险得分。

可选地，上述根据第一风险得分与第二风险得分，得到借款人的综合风险得分，包括：

根据第一风险得分、第二风险得分、第一风险得分与第二风险得分各自的权重，计算借款人的综合风险得分。

可选地，第一风险得分的权重、第二风险得分的权重可以为预设权重，或者，根据权重模型实时预测得到，在此不作限定。

一些实施方式中，当第一风险得分与第二风险得分的差值较小时，可以选择使用预设权重进行计算，使得在未发生突发信息时，可以综合利用两种模型的优势，提高整体预测的准确性；而当第一风险得分与第二风险得分的差值较大时，则根据权重模型实时预测得到的预测权重进行计算，使得在发生突发信息时，可以保证整体预测的准确性。

可选地，该权重模型可以是经过预先训练的机器学习模型，如神经网络或回归模型，该模型能够根据优化后的特征变化信息自动学习和调整各个风险得分的权重。

然而，在实践过程中发现，当第一风险得分与第二风险得分差值较大时，意味着两个模型的识别结果产生了较大分歧，这往往是由 ARIMA 模型对突发信息不敏感造成的，因此，预设的权重无法适应上述情况。对此，如图 2 所示，本实施例提供步骤 S4 的以下实施方式：

S4-1，获取上个还款周期的逾期风险特征与当前还款周期的逾期风险特征之间的特

征变化信息。

可选地，逾期风险特征包括：多条风险子特征，上述获取上个还款周期的逾期风险特征与当前还款周期的逾期风险特征之间的特征变化信息，包括：

根据上个还款周期的逾期风险特征中各风险子特征和当前还款周期的逾期风险特征中各风险子特征，计算特征变化信息。

其中，特征变化信息包括多条风险子特征对应的多条变化子信息。

可选地，对于每条风险子特征，若风险子特征对应的变化子信息符合预设要求，则确定风险子特征对应的变化子信息为突发信息；若风险子特征对应的变化子信息不符合预设要求，则确定风险子特征对应的变化子信息为非突发信息。

本实施例中，服务器可以将上一个还款周期的逾期风险特征中的每条风险子特征与当前还款周期的逾期风险特征中的每条风险子特征相减，从而得到特征变化信息。如果某条风险子特征的变化数值较大，表明这种变化可能是突发信息，反映了借款人近期出现的新风险因素；相反，如果变化数值较小，则可能属于非突发信息，即借款人风险特征的正常波动。通过这种方式，可以更精确地区分突发信息和非突发信息。

示例性地，如图 3 所示，图中示了 5 条上个还款周期的风险子特征，以及 5 条当前还款周期的风险子特征。图 3 中示出了 5 条上个还款周期的风险子特征，以及 5 条当前还款周期的风险子特征，其对应的特征数值如下表所示：

风险子特征	A	B	C	D	E
上个还款周期	20	31	11.9	23.5	0.9
当前还款周期	10	20	8	25	1.3
特征变化信息	10	11	3.9	1.5	0.4

由于图 3 中的特征变化信息不难看出，风险子特征 A 与风险子特征 B 在相邻两个还款周期的变化幅度加大，而其他风险子特征的变化幅度较小。应理解的是，上述实施仅仅是为了便于解释特征变化信息说列举的示例。示例中的特征以及数值并会随实际子特征的变化而变化。

基于上述实施对特征变化信息的说明，继续参见图 2，在步骤 S4-1 之后，步骤 S4 还包括：

S4-2，将特征变化信息进行优化，得到优化后的特征变化信息。

其中，优化后的特征变化信息增强了特征变化信息中的突发信息而抑制了特征变化信息中的非突发信息。应理解的是，正如图 3 所示的，对于不同的风险子特征，其特征值的取值范围存在明显的不同，因此，不能直接用于衡量事件的变化程度。对此，本实施例提出了一种综合第一风险得分与第二风险得分之间差异以及特征变化信息的优化方式，用于对特征变化信息中的突发信息进行增强，对非突发信息进行抑制。如图 4 所示，步骤 S4-2 可以包括：

S4-2-2，根据第一风险得分以及第二风险得分，得到风险评估模型与自回归移动平均模型之间的分歧指标。

S4-2-3，利用分歧指标对特征变化信息进行优化，得到优化后的特征变化信息。

正如图 3 所示的，特征变化信息包括多条变化子信息。因此，在具体实施方式中，对于每条变化子信息，服务器可以将变化子信息与分歧指标进行幂运算，得到优化后的变化子信息，其中，变化子信息的倒数为指数，分歧指标为底数。相应的数学表达式为：

$$y = x^{n}$$

式中，y 表示优化后的变化子信息，x 表示分歧指标，n 表示变化子信息的倒数。

本实施例中，分歧指标可以是第一风险得分和第二风险得分之间的比值或者差值。换句话说，一些实施例中，可以根据第一风险得分和第二风险得分的比值或差值，确定风险评估模型与自回归移动平均模型之间的分歧指标。

当分歧指标为两者之间的差值时，分歧指标同样是取值范围在$0\sim1$之间的数值。通过上述表达式，若变化子信息为小于 1，则会被进一步的缩小，若化子信息大于 1，则会被进一步增强，并且，将优化后的变化子信息的取值范围约束在$0\sim1$之间，有利于后续权重模型的处理。

如此，能够有效解决不同风险子特征值取值范围不同的问题，确保所有特征变化信息在同一尺度下进行比较和处理。其次，利用分歧指标进行幂运算优化，可以灵活地放大或缩小变化子信息的幅度，从而更精确地区分突发信息和非突发信息。特别是对于变化子信息小于 1 的情况，优化后会进一步缩小其影响，而对于变化子信息大于 1 的情况，则会进一步增强其影响，使得模型能够更加敏感地捕捉到关键变化点。

基于上述实施方式对特征变化信息的优化方式是说明，继续参见图 2 或者图 4，在步骤 S4-2 之后，步骤 S4 还包括：

S4-3，通过预先训练的权重模型对优化后的特征变化信息进行处理，得到第一风险得分与第二风险得分各自的预测权重。

S4-4，根据第一风险得分与第二风险得分各自的预测权重，得到综合风险得分。

如此，权重模型通过对优化后的特征变化信息进行处理，确定每个风险得分在整体评估中的重要性。权重模型经过训练后，能够更加敏感地捕捉到关键变化点，自动调整各风险得分的权重，以更准确地反映其对未来风险的预测能力。此外，该权重模型可以是经过预先训练的机器学习模型，如神经网络或回归模型，该模型能够根据优化后的特征变化信息自动学习和调整各个风险得分的权重。具体来说，该模型可以采用监督学习的方法，通过大量的数据来训练，使模型能够识别哪些特征变化信息对于预测第一风险得分和第二风险得分更为重要。在训练过程中，模型会不断调整其内部参数，以最小化预测误差，最终得到能够预测每个风险得分的预测权重的模型。

正如上述实施例所介绍的，当第一风险得分与第二风险得分差值较大时，意味着两个模型的识别结果产生了较大分歧，这往往是由 ARIMA 模型对突发信息不敏感造成的。

因此，并非每次都需要使用上述权重模型以自适应的方式生成第一风险得分与第二风险得分的预测权重，而是需要依据第一风险得分与第二风险之间的分歧指标。因此，如图5所示，在图4的基础上，图4中的步骤S4-2还包括：

S4-2-1，判断分歧指标是否大于分歧阈值。若是，则执行图5中的步骤4-2-2；反之，则执行图5中步骤S4的子步骤S4-5。

S4-5，根据第一风险得分与第二风险得分各自的预设权重，得到综合风险得分。

可以理解为，服务器会计算第一风险得分与第二风险得分之间的分歧指标，并将其与一个预先设定的分歧阈值进行比较。如果分歧指标未超过该阈值，则认为两个模型的结果尚可接受，此时直接使用各自预设的权重来计算综合风险得分即可。如此，不仅能够在高分歧情形下避免不准确的权重分配，还能在低分歧情形下简化计算流程，提高整体系统的效率和鲁棒性。

对于上述风险评估模型以及自回归移动平均模型，本实施例提出了一种新的模型训练方法，能够极大提高模型的训练效率。下面以风险评估模型为例，对风险评估模型的训练方法进行详细说明。在进行说明之前，应理解的是，超参数在模型训练中至关重要，决定了模型的学习过程和最终性能。适当的超参数设置可以控制模型的复杂度，防止过拟合或欠拟合，从而确保模型有效学习；同时影响模型的收敛速度，通过合理选择可以加快训练过程；此外，超参数还影响优化算法的选择和效率，进而间接影响模型的泛化能力。

鉴于此，服务器还可以调用第三方大语言模型为待训练网络模型生成当前的超参数；利用当前的超参数对待训练网络模型进行初始化；通过训练样本对初始化后的待训练网络模型进行训练，得到由待训练网络模型训练出的候选模型以及训练效果；继续调用第三方大语言模型对当前的超参数以及训练效果进行处理，得到新的超参数；根据新的超参数，返回到利用当前的超参数对待训练网络模型进行初始化的步骤，直至满足迭代停止条件后，从多个候选模型中选取训练效果最佳的作为风险评估模型。

可以理解为，上述训练方法中，服务器借助第三方大语言模型的推理能力为待训练网络模型生成超参数，并根据反馈的训练效果对超参数进行调整，从而不断优化说设置的超参数。

示例性地，假定第三方大语言模型为Qwen72b，待训练网络模型为Qwen14b。在训练前期，预先设置了一系列超参数的限制条件，以优化模型的训练效果。首先，取{初始权重/500，初始权重*500}作为其初始权重范围，并将学习率设定为[0.001, 0.1]的区间，并以0.001为步长进行调整，以及设置了批处理大小（batch size）在[16, 128]的区间内，步长为16；最后，根据模型复杂度设置了隐藏层节点数量，范围在[32, 256]之间，步长为32。

基于上述限制条件，使得第三方大语言模型在上述限制条件的范围内生成超参数。为了实现这一过程，服务器调用第三方大语言模型Qwen72b为待训练网络模型Qwen14b

生成一组初始超参数。这些超参数用于初始化 Qwen14b 模型。接着，使用训练样本对初始化后的 Qwen14b 模型进行训练，从而得到一个候选模型以及其训练效果。随后，服务器再次调用 Qwen72b，将当前的超参数和训练效果作为输入，使得 Qwen72b 根据被调用的上下文以及当前的超参数和训练效果进行推理，得到新的超参数。根据新的超参数，服务器重新初始化 Qwen14b 模型，并重复上述训练和超参数调整的过程，直到满足迭代停止条件（例如，候选模型的损失值趋近于稳定）。在整个过程中，服务器利用 Qwen72b 的推理能力和反馈的训练效果调整超参数，逐步优化模型。最终，在多个候选模型中选择训练效果最佳的一个作为最终的风险评估模型。通过这种方式，方案有效地利用了 Qwen72b 的推理能力，实现了对 Qwen14b 模型的高效训练和优化。

对于 ARIMA 模型可以采取同样的优化方式对其进行优化，本实施例对此不再进行赘述。

基于与本实施例所提供车贷风险预测方法相同的发明构思，本实施例还提供一种车贷风险预测装置，该装置包括至少一个可以软件形式存储于存储器或固化在电子设备中的软件功能模块。电子设备中的处理器用于执行存储器中存储的可执行模块。例如，该装置所包括的软件功能模块及计算机程序等。请参照图 6，从功能上划分，该装置可以包括：

风险特征模块 11，用于获取借款人在当前还款周期的逾期风险特征；

风险得分模块 12，用于通过神经网络架构的风险评估模型对逾期风险特征进行处理，得到借款人在当前还款周期的第一风险得分；

风险得分模块 12，还用于通过预先拟合出的自回归移动平均模型对逾期风险特征进行处理，得到借款人在当前还款周期的第二风险得分；

风险综合模块 13，用于根据第一风险得分与第二风险得分，得到借款人的综合风险得分。

在本实施例中，该风险特征模块 11 用于实现图 1 中的步骤 S1，风险得分模块 12 用于实现图 1 中的步骤 S2、S3，风险综合模块 13 还用于实现图 1 中的步骤 S4。因此，对于上述各模块的详细描述可以参见对应步骤的具体实施方式，本实施例对此不再进行赘述。

由于与上述车贷风险预测方法具有相同的构思，因此，车贷风险预测装置还可以通过上述模块实现该方法的其他步骤或者子步骤。

可选地，风险综合模块 13 还具体用于：

获取上个还款周期的逾期风险特征与当前还款周期的逾期风险特征之间的特征变化信息；

将特征变化信息进行优化，得到优化后的特征变化信息，其中，优化后的特征变化信息增强了特征变化信息中的突发信息而抑制了特征变化信息中的非突发信息；

通过预先训练的权重模型对优化后的特征变化信息进行处理，得到第一风险得分与

第二风险得分各自的预测权重；

根据第一风险得分与第二风险得分各自的预测权重，得到综合风险得分。

可选地，风险综合模块 13 还具体用于：

根据第一风险得分以及第二风险得分，得到风险评估模型与自回归移动平均模型之间的分歧指标；

利用分歧指标对特征变化信息进行优化，得到优化后的特征变化信息。

可选地，特征变化信息包括多条变化子信息，优化后的特征变化信息包括多条优化后的变化子信息；风险综合模块 13 还具体用于：

对于每条变化子信息，将变化子信息与分歧指标进行幂运算，得到优化后的变化子信息，其中，变化子信息的倒数为指数，分歧指标为底数；

可选地，在根据第一风险得分以及第二风险得分，得到风险评估模型与自回归移动平均模型之间的分歧指标之后，风险综合模块 13 还具体用于：

判断分歧指标是否大于分歧阈值；

若大于分歧阈值，则执行利用分歧指标对特征变化信息进行优化，得到优化后的特征变化信息的步骤。

可选地，当前还款周期的逾期风险特征包括多条逾期子特征以及为每条逾期子特征赋予的预设权重。

可选地，车贷风险预测装置还包括模型训练模块，模型训练模块用于：

调用第三方大语言模型为待训练网络模型生成当前的超参数；

利用当前的超参数对待训练网络模型进行初始化；

通过训练样本对初始化后的待训练网络模型进行训练，得到由待训练网络模型训练出的候选模型以及训练效果；

继续调用第三方大语言模型对当前的超参数以及训练效果进行处理，得到新的超参数；

根据新的超参数，返回到利用当前的超参数对待训练网络模型进行初始化的步骤，直至满足迭代停止条件后，从多个候选模型中选取训练效果最佳的作为风险评估模型。

另外，在本申请各个实施例中的各功能模块可以集成在一起形成一个独立的部分，也可以是各个模块单独存在，也可以两个或两个以上模块集成形成一个独立的部分。

还应理解的是，以上实施方式如果以软件功能模块的形式实现并作为独立的产品销售或使用时，可以存储在一个计算机可读取存储介质中。基于这样的理解，本申请的技术方案本质上或者说对现有技术做出贡献的部分或者该技术方案的部分可以以软件产品的形式体现出来，该计算机软件产品存储在一个存储介质中，包括若干指令用以使得一台计算机设备（可以是个人计算机，服务器，或者网络设备等）执行本申请各个实施例所述方法的全部或部分步骤。

因此，本实施例还提供一种存储介质，该存储介质为计算机可读存储介质。该存储

介质存储有计算机程序，该计算机程序被处理器执行时，实现本实施例提供的车贷风险预测方法。其中，该存储介质可以是U盘、移动硬盘、只读存储器（ROM，Read-Only Memory）、随机存取存储器（RAM，Random Access Memory）、磁碟或者光盘等各种可以存储程序代码的介质。

本实施例提供的一种实施车贷风险预测方法的电子设备。如图7所示，该电子设备可包括处理器22及存储器21。并且，存储器21存储有计算机程序，处理器通过读取并执行存储器21中与以上实施方式对应的计算机程序，实现本实施例所提供的车贷风险预测方法。

继续参见图7，该电子设备还包括有通信单元23。该存储器21、处理器22以及通信单元23各元件相互之间通过系统总线24直接或间接地电性连接，以实现数据的传输或交互。

其中，该存储器21可以是基于任何电子、磁性、光学或其它物理原理的信息记录装置，用于记录执行指令、数据等。在一些实施方式中，该存储器21可以是，但不限于，易失存储器、非易失性存储器、存储驱动器等。

在一些实施方式中，该易失存储器可以是随机存取存储器（Random Access Memory，RAM）；在一些实施方式中，该非易失性存储器可以是只读存储器（Read Only Memory，ROM）、可编程只读存储器（Programmable Read-Only Memory，PROM）、可擦除只读存储器（Erasable Programmable Read-Only Memory，EPROM）、电可擦除只读存储器（Electric Erasable Programmable Read-Only Memory，EEPROM）、闪存等；在一些实施方式中，该存储驱动器可以是磁盘驱动器、固态硬盘、任何类型的存储盘（如光盘、DVD等），或者类似的存储介质，或者它们的组合等。

该通信单元23用于通过网络收发数据。在一些实施方式中，该网络可以包括有线网络、无线网络、光纤网络、远程通信网络、内联网、因特网、局域网（Local Area Network，LAN）、广域网（Wide Area Network，WAN）、无线局域网（Wireless Local Area Networks，WLAN）、城域网（Metropolitan Area Network，MAN）、广域网（Wide Area Network，WAN）、公共电话交换网（Public Switched Telephone Network，PSTN）、蓝牙网络、ZigBee网络、或近场通信（Near Field Communication，NFC）网络等，或其任意组合。在一些实施例中，网络可以包括一个或多个网络接入点。例如，网络可以包括有线或无线网络接入点，例如基站和/或网络交换节点，服务请求处理系统的一个或多个组件可以通过该接入点连接到网络以交换数据和/或信息。

该处理器22可能是一种集成电路芯片，具有信号的处理能力，并且，该处理器可以包括一个或多个处理核（例如，单核处理器或多核处理器）。仅作为举例，上述处理器可以包括中央处理单元（Central Processing Unit，CPU）、专用集成电路（Application Specific Integrated Circuit，ASIC）、专用指令集处理器（Application Specific Instruction-set Processor，ASIP）、图形处理单元（Graphics Processing Unit，GPU）、物理处理单元（Physics

Processing Unit，PPU）、数字信号处理器 (Digital Signal Processor，DSP)、现场可编程门阵列(Field Programmable Gate Array，FPGA)、可编程逻辑器件(Programmable Logic Device，PLD)、控制器、微控制器单元、简化指令集计算机(Reduced Instruction Set Computing，RISC)、或微处理器等，或其任意组合。

可以理解，图 7 所示的结构仅为示意。电子设备还可以具有比图 7 所示更多或者更少的组件，或者具有与图 7 所示不同的配置。图 7 所示的各组件可以采用硬件、软件或其组合实现。

应该理解到的是，在上述实施方式中所揭露的装置和方法，也可以通过其它的方式实现。以上所描述的装置实施例仅仅是示意性的，例如，附图中的流程图和框图显示了根据本申请的多个实施例的装置、方法和计算机程序产品的可能实现的体系架构、功能和操作。在这点上，流程图或框图中的每个方框可以代表一个模块、程序段或代码的一部分，所述模块、程序段或代码的一部分包含一个或多个用于实现规定的逻辑功能的可执行指令。也应当注意，在有些作为替换的实现方式中，方框中所标注的功能也可以以不同于附图中所标注的顺序发生。例如，两个连续的方框实际上可以基本并行地执行，它们有时也可以按相反的顺序执行，这依所涉及的功能而定。也要注意的是，框图和/或流程图中的每个方框、以及框图和/或流程图中的方框的组合，可以用执行规定的功能或动作的专用的基于硬件的系统来实现，或者可以用专用硬件与计算机指令的组合来实现。

以上所述，仅为本申请的各种实施方式，但本申请的保护范围并不局限于此，任何熟悉本技术领域的技术人员在本申请揭露的技术范围内，可轻易想到变化或替换，都应涵盖在本申请的保护范围之内。因此，本申请的保护范围应所述以权利要求的保护范围为准。

工业实用性

采用上述方案，神经网络架构的风险评估模型能够更好地捕捉突发性事件的影响，从而弥补了自回归移动平均模型对突发性事件不敏感的缺陷，提高了对逾期风险的预测精度。

权 利 要 求 书

1.一种车贷风险预测方法，其特征在于，所述方法包括：

获取借款人在当前还款周期的逾期风险特征；

通过神经网络架构的风险评估模型对所述逾期风险特征进行处理，得到所述借款人在所述当前还款周期的第一风险得分；

通过预先拟合出的自回归移动平均模型对所述逾期风险特征进行处理，得到所述借款人在所述当前还款周期的第二风险得分；

根据所述第一风险得分与所述第二风险得分，得到所述借款人的综合风险得分。

2.根据权利要求1所述的车贷风险预测方法，其特征在于，根据所述第一风险得分与所述第二风险得分，得到所述借款人的综合风险得分，包括：

根据所述第一风险得分、所述第二风险得分、所述第一风险得分与所述第二风险得分各自的权重，计算所述借款人的综合风险得分。

3.根据权利要求1或2所述的车贷风险预测方法，其特征在于，根据所述第一风险得分与所述第二风险得分，得到所述借款人的综合风险得分，包括：

获取上个还款周期的逾期风险特征与所述当前还款周期的逾期风险特征之间的特征变化信息；

将所述特征变化信息进行优化，得到优化后的特征变化信息，其中，所述优化后的特征变化信息增强了所述特征变化信息中的突发信息而抑制了所述特征变化信息中的非突发信息；

通过预先训练的权重模型对所述优化后的特征变化信息进行处理，得到所述第一风险得分与所述第二风险得分各自的预测权重；

根据所述第一风险得分与所述第二风险得分各自的预测权重，得到所述综合风险得分。

4.根据权利要求3所述的车贷风险预测方法，其特征在于，将所述特征变化信息进行优化，得到优化后的特征变化信息，包括：

根据所述第一风险得分以及所述第二风险得分，得到所述风险评估模型与所述自回归移动平均模型之间的分歧指标；

利用所述分歧指标对所述特征变化信息进行优化，得到优化后的特征变化信息。

5.根据权利要求3或4所述的车贷风险预测方法，其特征在于，所述逾期风险特征包括：多条风险子特征，所述获取上个还款周期的逾期风险特征与所述当前还款周期的逾期风险特征之间的特征变化信息，包括：

根据上个还款周期的逾期风险特征中各风险子特征和所述当前还款周期的逾期风险特征中各风险子特征，计算所述特征变化信息，所述特征变化信息包括多条风险子特征对应的多条变化子信息。

6.根据权利要求 5 所述的车贷风险预测方法，其特征在于，对于每条风险子特征，若所述风险子特征对应的变化子信息符合预设要求，则确定所述风险子特征对应的变化子信息为突发信息；

若所述风险子特征对应的变化子信息不符合预设要求，则确定所述风险子特征对应的变化子信息为非突发信息。

7.根据权利要求 4 所述的车贷风险预测方法，其特征在于，所述根据所述第一风险得分以及所述第二风险得分，得到所述风险评估模型与所述自回归移动平均模型之间的分歧指标，包括：

根据所述第一风险得分和所述第二风险得分的比值或差值，确定所述风险评估模型与所述自回归移动平均模型之间的分歧指标。

8.根据权利要求 4 所述的车贷风险预测方法，其特征在于，所述优化后的特征变化信息包括多条优化后的变化子信息；

利用所述分歧指标对所述特征变化信息进行优化，得到优化后的特征变化信息，包括：

对于每条所述变化子信息，将所述变化子信息与所述分歧指标进行幂运算，得到优化后的变化子信息，其中，所述变化子信息的倒数为指数，所述分歧指标为底数。

9.根据权利要求 4 或 7 所述的车贷风险预测方法，其特征在于，在根据所述第一风险得分以及所述第二风险得分，得到所述风险评估模型与所述自回归移动平均模型之间的分歧指标之后，所述方法还包括：

判断所述分歧指标是否大于分歧阈值；

若大于所述分歧阈值，则执行所述利用所述分歧指标对所述特征变化信息进行优化，得到优化后的特征变化信息的步骤。

10.根据权利要求 1-9 任一项所述的车贷风险预测方法，其特征在于，所述当前还款周期的逾期风险特征包括多条逾期子特征以及为每条所述逾期子特征赋予的预设权重。

11.根据权利要求 1-10 任一项所述的车贷风险预测方法，其特征在于，所述方法还包括所述风险评估模型的训练方法，所述训练方法包括：

调用第三方大语言模型为待训练网络模型生成当前的超参数；

利用所述当前的超参数对待训练网络模型进行初始化；

通过训练样本对初始化后的待训练网络模型进行训练，得到由所述待训练网络模型训练出的候选模型以及训练效果；

继续调用所述第三方大语言模型对所述当前的超参数以及所述训练效果进行处理，得到新的超参数；

根据所述新的超参数，返回到利用所述当前的超参数对待训练网络模型进行初始化的步骤，直至满足迭代停止条件后，从多个所述候选模型中选取训练效果最佳的作为所述风险评估模型。

12.一种车贷风险预测装置，其特征在于，所述装置包括：

风险特征模块，用于获取借款人在当前还款周期的逾期风险特征；

风险得分模块，用于通过神经网络架构的风险评估模型对所述逾期风险特征进行处理，得到所述借款人在所述当前还款周期的第一风险得分；

所述风险得分模块，还用于通过预先拟合出的自回归移动平均模型对所述逾期风险特征进行处理，得到所述借款人在所述当前还款周期的第二风险得分；

风险综合模块，用于根据所述第一风险得分与所述第二风险得分，得到所述借款人的综合风险得分。

13. 一种存储介质，其特征在于，所述存储介质存储有计算机程序，所述计算机程序被处理器处理的条件下，实现权利要求 1-11 任意一项所述的车贷风险预测方法。

14.一种电子设备，其特征在于，所述电子设备包括处理器以及存储器，所述存储器存储有计算机程序，所述计算机程序被所述处理器处理的条件下，实现权利要求 1-11 任意一项所述的车贷风险预测方法。