了解、增长并保护净资产：利用机器学习通过避免透支费用实现资产保护

Avishek Kumar Intuit
CreditKarma 美国加利福尼亚州奥克兰
avishek.kumar@creditkarma.com

Tyson Silver*
Lightcast 美国爱达荷州莫斯科
tyson.silver@lightcast.io

arXiv:2302.02455v2 [stat.ML] 7 Sep 2024

摘要

当客户透支其银行账户且余额为负时，银行会向其收取透支费。美国人每年支付约150亿美元的不必要透支费用，通常每次为35美元；其中，Mint个人理财应用的用户每年尤其要支付约2.5亿美元的费用。这些透支费用造成了过重的经济负担，并会导致透支费用不断累积，使客户陷入财务困境。为解决这一问题，我们创建了机器学习驱动的透支预警系统（ODEWS），利用客户在Mint应用中的银行和交易数据，评估其在未来一周内发生透支的风险。系统会向高风险客户发送提醒，使其能够采取措施避免支付费用，最终改变其行为和理财习惯。与对照组相比，部署该系统为Mint 用户节省了300万美元的透支费用。此外，本文所概述的方法也是一项更大规模工作的组成部分，旨在提供机器学习驱动的个性化财务建议，帮助我们的会员了解、增长并保护其净资产，最终实现其财务目标。

CCS 概念

• **应用计算** →**数字现金**。

关键词

透支、神经网络、预警系统、个人理财

ACM 参考格式：
Avishek Kumar 和 TysonSilver。2024年。《了解、增长并保护净资产：运用机器学习预防透支费用，实现资产保护》。载于《第*30*届*ACM SIGKDD*知识发现与数据挖掘会议论文集（*KDD '24*）》，*2024*年*8*月*25*日至*29*日，西班牙巴塞罗那。ACM，美国纽约州纽约市，11页。
https://doi.org/10.1145/3637528.3671628

*作者在 Intuit 工作期间完成了这项研究。

本文中表达的任何观点、研究结果、结论或建议均仅代表作者立场，并不一定反映其雇主的观点。

允许免费制作本作品全部或部分内容的电子版或纸质副本，供个人或课堂使用，前提是不得为营利或商业利益制作或分发副本，且副本须在首页注明本声明及完整引文。本作品中由作者以外的其他人拥有版权的部分，必须尊重其版权。注明出处后可以摘录。其他复制方式、重新出版、发布至服务器或分发至列表，均须事先获得特别许可和／或支付费用。请向 permissions@acm.org 申请许可。*KDD '24*，*2024*年*8*月*25*日至*29*日，西班牙巴塞罗那© 2024年版权归所有者／作者所有。出版权已授权给 ACM。ACM ISBN 979-8-4007-0490-1/24/08。https://doi.org/10.1145/3637528.3671628

1 引言

透支费用主要由最弱势的客户承担，他们往往是月光族；这些费用被认为过高且具有剥削性[28]。美国人每年通常要支付150亿美元的本可避免的透支费用。同样的9%客户支付了80%的透支费用，其中许多人一年要支付超过10次透支费。透支可以被视为一种从存款金额较小的账户中获利的方式[10]。此外，由于支付这些费用会让银行服务成本高昂，透支费用可能使最弱势的客户甚至不愿参与银行体系[9]。

当账户资金不足时，银行若接受一笔交易，就会收取透支费；若拒绝该笔交易，则会收取资金不足手续费。何时收取透支费或资金不足手续费，取决于银行的服务条款。本文统一使用“透支费”一词指代这两类费用，因为我们希望同时防止它们。账户可能因资金不足而通过以下五种方式出现透支：支票被拒（支票退票）、电子扣款、借记卡交易、自动取款机取款或柜台取款。最初，透支费并不常见。银行会向支票簿记录不当、未能正确核对余额的客户收取费用。随着借记交易和电子账单支付的普及，透支费用已成为银行数十亿美元的收入来源。一笔 5 美元的咖啡消费因此可能变成 40 美元，一笔 15 美元的电子账单支付也可能变成 50 美元的账单。最终，这可能导致透支费用不断累积，造成经济负担，并使客户陷入费用缠身、余额偏低的循环。

目前，应对透支费用的措施零散且临时，执行也不均衡。新冠疫情期间，许多银行向那些知道如何提出申请的客户提供了豁免，也有一些银行暂时免除了所有客户的透支费用。美国还曾提出一项立法，*2021*年《制止透支牟利法案》[6]，但该法案并未通过。人工智能工具大多聚焦于金融市场——可解释人工智能用于交易[18],交易策略[17],风险管理[30],和欺诈检测[26,29]，而非个人理财。

在 [19], 中，提出了一种贝叶斯分层模型，用于确定按透支金额百分比计算的最优透支费用结构。在 [22] 中，提出了一种机器学习框架，用于确定允许客户透支的次数以及相应的费用。还有一些回顾性经济研究探讨了透支和掠夺性贷款的影响[3, 21]，以及为透支和贷款还款发送短信通知的积极作用[7]。在行为科学领域，也有研究致力于寻找有效的助推信息，以减少透支[5]。

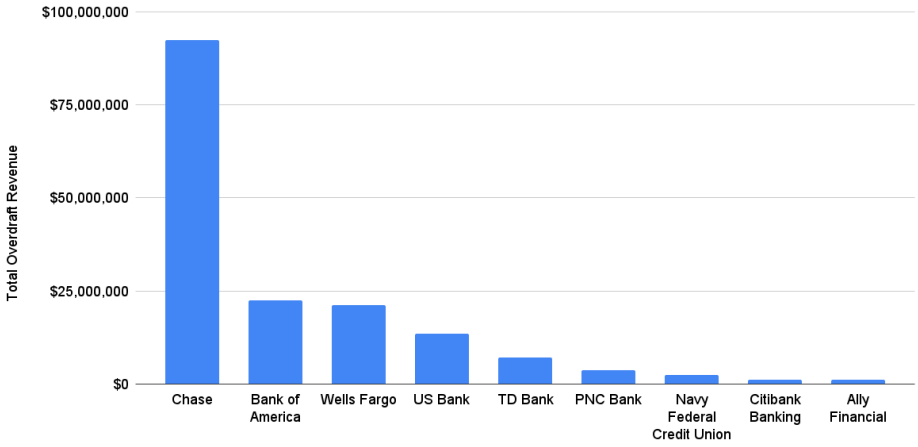

图 1：Mint 用户在 2019 年 9 月至 2020 年 9 月期间向各银行支付的透支费用。Mint 用户平均每年向银行支付 2.5 亿美元的透支费用，通常每笔为 35 美元。银行收取的透支费用与客户数量呈线性关系。ODEWS 旨在向客户提供预警，帮助其避免支付不必要的透支费用。

预防透支费用面临着诸多挑战，因此适合采用机器学习驱动的解决方案。首先，不同银行的政策各不相同，包括透支费的金额、一天内可向客户收取的透支费次数、账户可在多长的宽限期内恢复正常、收取透支费的不同门槛，以及账户发生不同类型透支时适用的不同费用[12]。基于机器学习的模型可以学习各家银行的这些政策，并随着时间推移适应政策变化。其次，银行在夜间处理交易时，会按照金额从大到小的顺序处理交易（即交易处理顺序），这会增加预测透支的难度。尽管 Mint 应用会接收余额和交易数据，但不会实时收到这些数据；根据金融机构的不同，数据延迟有时可达数小时甚至数天。交易处理顺序以及数据接收延迟，意味着无法仅仅等待待处理交易出现，再计算该交易是否会导致客户账户出现负余额，然后在交易入账前提醒客户；也无法使用时间序列模型。相反，机器学习模型可以利用金融数据，预测客户是否会发生透支。最后，我们希望量化客户透支的风险。除某一时点的余额和借记交易外，还有诸多因素会导致透支；机器学习模型可以系统、有条理地利用这些因素，提供个性化风险评估、按风险对客户进行排序，甚至为干预方式提供依据。

1.1 我们的贡献

鉴于银行采取的措施具有临时性且不均衡、立法工作停滞不前，以及预防透支费用面临的其他挑战，作者在 Mint 应用上创建了机器学习驱动的透支早期预警系统（ODEWS）。该问题被建模为

ID	总计透支	透支次数本周	距上次透支	余额	Risk 评分
01	95	True	2	-$700.00	99
02	5	否	9	$11.30	81
03	1	否	104	$700.00	74

表 1：ODEWS 输出示例。按透支风险排序的客户名单可用于确定干预优先级。本表根据交易历史和余额数据评估风险。

一个二元分类问题：系统利用平台数据和交易数据，预测客户在未来一周内支票账户发生透支的可能性。随后，系统通过电子邮件通知向高风险客户发出预警，以防止透支，最终为客户节省资金。这项工作延续了 [5] 此前的研究，重点关注机器学习如何评估透支风险并提供有效干预。除了提出百分比收费结构[19] 和其他透支定价策略 [22], 的理论模型外，ODEWS 系统还专注于预防透支，并已部署和测试，结果表明该系统成功预防了透支。此外，作者选择关注透支问题，是因为它对客户影响很大；不过，这一框架也可用于预防其他类型的垃圾费用。表 1 展示了模型输出示例，其中客户按透支风险从高到低排列。风险评分是模型的输出。随后，系统会向透支风险最高的客户发送通知，以防止透支。

1.1.1 透支问题的范围。自本研究开展以来，截至本文撰写时，已有几家银行降低了透支

费用，采取了惩罚性较低的政策，少数规模较小的银行甚至彻底取消了这些费用[4]。尽管这一变化令人鼓舞，许多大型银行仍在收取透支费用，而透支费用仍是不必要地拖累客户现金流的因素。2019年，透支收入估计为120亿美元；如今，预计其收入为90亿美元[10]。消费者金融保护局[10], 最近开展的一项调查显示，低收入家庭被收取透支费用的比例（年收入为65,000美元的家庭中有34%）远高于高收入家庭（年收入为175,000美元的家庭中有10%）；大多数产生过透支费用的家庭，如果事先得到提醒，本可以使用信用卡。因此，作者认为，防止透支费用以及总体上的垃圾费用，仍然是资产保护的重要组成部分。

1.2 Mint 用户的透支问题

Mint 应用是一款个人理财应用，在美国和加拿大拥有 2000 万用户。它通过关联客户的银行账户、信用卡和投资账户来追踪交易；此外还提供预算工具、预测和个人理财洞察[1]。减少 Mint 用户支付的不必要透支费用，可以显著节省开支并保护客户的现金流，尤其是那些靠工资过日子的人。Mint 用户每年平均支付 2.5 亿美元的不必要透支费用。客户平均透支 1.8 次后，才会意识到自己的账户已透支。在本项目开展之前，Mint 用户在产生透支费用前不会收到任何警告。图 1 展示了 2019 年 9 月至 2020 年 9 月期间，Mint 用户在九家银行产生的透支费用明细。通常，所收取的费用总额与客户数量成正比；其中，美国规模最大的三家银行——摩根大通、美国银行和富国银行——收取的费用占比最高。

ODEWS 在新冠疫情期间投入使用。当时，美国经济遭受了突然而剧烈的冲击。许多美国人突然失业，企业也纷纷停业，导致经济活动急剧下滑。如图 2 所示，疫情初期（约 2020 年 3 月），透支数量突然减少，这是因为疫情导致停摆，交易量随之骤降。其次，银行调整了透支政策，暂时停止透支服务，或采取更宽松的透支政策。在这种情况下，客户行为和透支政策都在发生变化，因此需要一种能够适应快速变化环境的机器学习解决方案。

2 数据来源

这项研究所用的数据源自客户的银行、平台及交易数据，由 Mint 应用收集（图 3）。客户可以将银行账户、信用卡、投资账户和贷款关联到应用中，从而全面了解自己的财务状况并获取财务洞察。数据安全政策请参阅 security.intuit.com。Mint 每月有 360 万活跃用户，客户的交易历史跨度可能从三个月到十多年不等，具体取决于客户使用该应用的时间长短。

2.0.1 银行业务。Mint 应用允许客户关联其金融账户，包括支票账户、储蓄账户、定期存款、货币市场账户、信用卡账户和投资账户，以及这些账户各自的余额。

2.0.2 平台。平台数据包括用户在 Mint 应用中的登录次数，以及他们在应用中访问哪些页面的点击流数据。登录次数反映了用户的使用意图，也可作为衡量客户关注自身财务状况程度的指标[11, 13]。我们的推断是，如果客户最近登录过 Mint，他们很可能已经评估过自己的财务状况，因此透支风险较低。

2.0.3 交易历史。在将金融账户关联到应用的过程中，Mint 会获取客户的交易历史。这些数据包括交易时间戳、金额、交易描述和交易类别。

2.0.4 数据局限性。数据的主要局限性在于 Mint 应用获取最新银行和交易数据的速度。从交易发生到数据传送至 Mint 应用，可能需要数小时到数天。部分银行要求客户登录 Mint 并完成双重身份验证，之后应用才能获取最新交易记录。此外，部分银行在周末进行交易处理期间不会提供数据，因此可能出现这样的情况：客户在周末消费，却直到周一早晨交易处理完成后才意识到自己已经透支。其次，Mint 的银行余额数据也存在延迟，更新速度往往慢于应用获取最新交易数据的速度。这可能导致应用显示客户有正余额，但实际上其余额为负，且账户正在发生透支。

3 方法论

本节介绍整体方法，包括提取用于训练的特征、选择和评估机器学习模型。预测单位是某一天的客户及其支票账户。大多数客户只有一个支票账户。特征分为两组：一组来自客户，另一组来自支票账户的交易历史。

客户是否发生过透支的标签，是通过搜索交易历史得出的。每家银行都有自己独特的交易描述，用于表明是否收取了费用。通过人工整理和关键词搜索交易历史，我们能够识别出表明账户发生透支的交易描述，并根据账户所属银行，将描述与相应银行匹配。在（模拟的）预测日，我们向前查看一周的客户交易历史，查找是否有透支费交易。如果发现任何透支费用，则标记为正标签（下一周内发生透支）；否则，将客户/账户标记为负标签（下一周内未发生透支）。

[1]在撰写本文时，Mint 应用正在与 Intuit Credit Karma 应用合并，相关特征将迁移至后者。

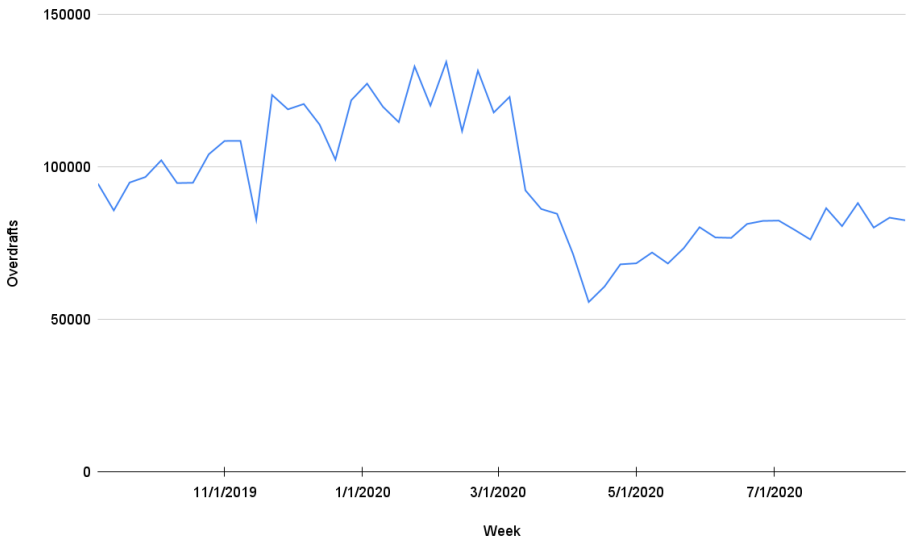

图 2：2019年9月至2020年9月的每周透支次数。新冠疫情期间的大规模停摆导致交易数量骤减，加之银行透支政策发生变化，透支次数也随之急剧下降。随着疫情持续，透支次数逐渐增加。客户行为和银行政策的变化导致透支次数迅速变化，因此，防止透支的问题非常适合采用能够灵活适应的基于机器学习的解决方案。

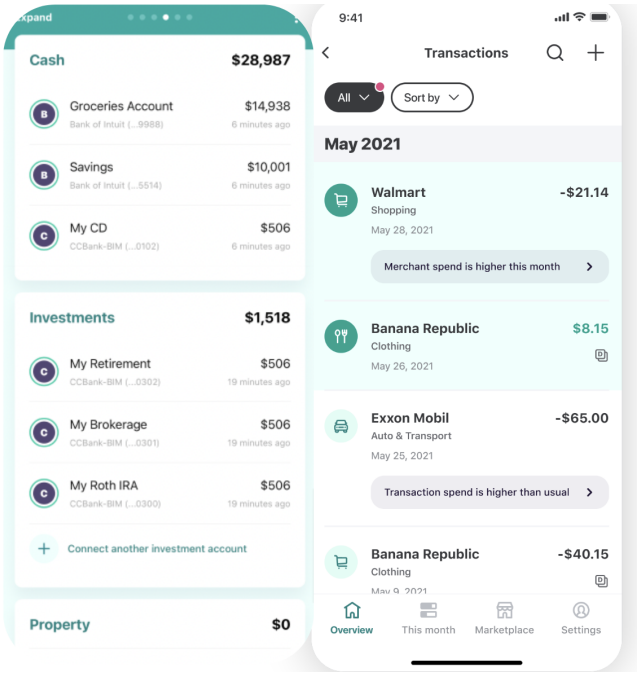

图 3：Mint 应用用于追踪客户的交易并管理其财务。客户可以关联储蓄账户、支票账户和投资账户，并查看其交易历史。

模型的特征可分为几个特征组：透支特征、交易特征、银行特征和登录特征。透支特征与客户的透支历史有关，是模型中最重要的特征。通常，如果客户以前发生过透支，那么再次透支的风险就很高，尤其是当其在同一周内已经发生过透支时。透支特征包括：该账户过去六个月的透支次数、所有账户过去六个月的透支次数、距上次透支的天数、上次透支的金额，以及过去一周内是否发生过透支。银行特征全面反映客户拥有多少个账户，体现其财务状况的复杂程度。银行级特征包括进行预测当天的支票账户、信用卡账户、储蓄账户、定期存款账户和投资账户的数量。交易特征涉及支票账户中的借记交易和贷记交易数量及金额、支票账户余额，以及银行账户余额的变动。账户活动可以预测透支风险。账户级特征包括预测日之前账户最后一次已知余额，以及预测日之前的交易活动。由于交易和余额是在不同时间获取的，客户的余额往往与实际余额不同步。为解决这一问题，我们通过获取最后一次已知余额、最后一次已知余额时间戳之后发生的交易，并据此计算新的余额。账户的交易历史会转换为特征：首先将交易分为贷记交易和借记交易，然后创建以下特征：贷记交易和借记交易的总数，

预测日之前四周和一周回溯窗口内金额的最小值、最大值和平均值；以及预测日前两个月内金额低于 50 美元的借记交易笔数和金额超过 200 美元的贷记交易笔数。针对不同特征测试了不同的回溯窗口。回溯六个月可以全面了解客户的透支历史，包括透支次数、距上次透支的天数以及距最近一次透支已过去的天数。例如，如果采用一个月的回溯窗口，模型将无法区分长期透支者和偶尔透支者，从而增加假阳性。此外，有些客户近期发生过透支，但此前六个月内可能没有透支。回溯六个月时，模型会将这类客户判定为中低风险，因此他们很可能不会被纳入风险群体。本文报告的特征回溯窗口带来了最佳模型性能。

4 建模方法与结果

接收预测的预测队列是 Mint 用户：他们在过去六个月内至少发生过一次透支，并且在以下银行拥有支票账户：摩根大通银行、美国银行、富国银行、美国合众银行、道明银行、花旗银行、PNC银行、海军联邦信用合作社和 Ally Bank。（注：在部署本系统时，花旗银行和 Ally Bank 会向客户收取透支费用。截至本文撰写时，这两家银行已取消透支费用。现在，各家银行将根据各自的透支政策，自行决定是否拒绝交易[1, 2]。）许多 Mint 用户可能拥有透支保护；发生透支时，银行不会收取费用，而是从客户的储蓄账户或信用额度中划拨资金，或者从信用卡中扣款。理想情况下，所有客户都应拥有透支保护，以避免发生透支。但由于多种原因，这并不现实。客户可能没有可与支票账户关联的储蓄账户；也可能没有可用于支付透支的信用额度或信用卡。此外，将透支金额计入信用卡并支付债务利息或相关费用，未必符合财务上的理性。我们无法了解哪些客户拥有此类透支保护，哪些客户没有。为避免向拥有透支保护的客户发送透支警告，我们将预测队列限定为过去六个月内发生过透支的客户，并假定他们没有透支保护，因为他们曾收到过透支费。这种方法存在一定的权衡：在过去六个月内首次发生透支的客户将不会进入预测队列。尽管这种保守方法会遗漏一小部分透支费用，但我们避免了发送假阳性通知，从而确保客户在确实收到通知时信任该系统。如果客户在进入预测队列后启用了透支保护，随着时间推移，其风险会降低，并会从高风险客户名单中移出。对于新客户，我们通常会在其注册时从银行获得三个月的交易历史，他们也必须满足相同的条件。

模型的目标是预测客户是否会在接下来一周内透支；为此，模型每周五下午都会生成预测。目前，由于应用接收交易数据的速度存在技术限制，我们不会在交易完成后立即进行预测，也不会每天进行预测。此外，由于从银行获取数据存在限制，Mint 应用接收各家银行交易数据的频率各不相同，导致与历史离线测试相比，各家银行的性能有所差异。而且，即使我们的系统能够预测客户当天或次日是否会透支，客户往往也无法及时改变行为来避免透支（根据客户访谈得出）。因此，系统着重预测一周时间范围内的透支风险，让客户有足够的时间改变行为；作者发现，模型使用这一标签时性能良好。若将时间范围延长至两周，可能会显得过长，客户也可能感受不到采取纠正措施的紧迫性。模型生成预测后，系统会创建一份高风险客户名单，并向他们发送电子邮件，告知他们我们认为其即将透支。这样，客户便有机会调整支出、转账，或联系银行申请豁免。由于不同银行的透支政策各不相同，尤其是在新冠疫情高峰期，因此针对每家银行分别创建了一个模型。起初，我们尝试用单一模型预测所有银行的透支情况，但发现模型会学习规模最大的银行的透支政策，从而降低了属于较小银行的客户的预测性能。作者没有尝试不同的抽样策略，而是决定为每家银行创建一个模型，尤其是为了捕捉各家银行透支政策的急剧变化。从实证结果来看，这种做法带来了更好的性能。

4.0.1 时间交叉验证：模型训练方案旨在模拟部署流程，以获得最准确的性能结果。模型使用时间交叉验证进行训练，以考虑影响客户行为（特征）和透支政策（标签）的时间效应及序列相关性[15]。如图 2 所示，且如前文所述，在新冠疫情高峰期，客户行为和透支政策受到极端外生冲击。模型每周重新训练，以考虑停摆、重新开放、政府刺激性补助[14], 以及透支政策变化等可能影响透支行为的时间效应。时间交叉验证的一个示例如下：如果模拟在 2020-06-14 进行预测，则标签根据 2020-06-07 至 2020-06-14 期间的数据计算，特征则回溯至 2020-06-07 前六个月的数据。随后，模型的测试集使用 2020-06-14 至 2020-06-21 期间的标签，以及回溯至 2020-06-14 前六个月的数据特征进行计算。这样，每周都会在六个月的时间范围内创建训练-测试对，并用于训练模型。

4.0.2 模型选择：系统具有以下高级要求。

(1) 用户必须信任该系统，系统才能发挥作用。在此背景下，如果客户是假阳性，客户需要直观地理解自己为何会收到该消息，从而信任该系统。(2) 我们的目标是尽可能覆盖最大的群体，以防止透支。

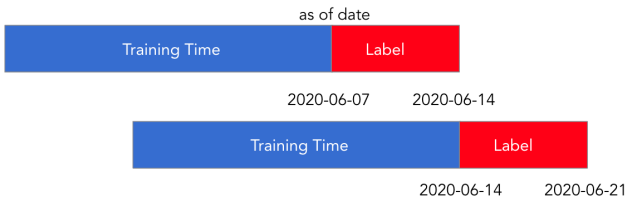

图 4：时间交叉验证：在模拟于 2020-06-14 做出预测时，标签根据 2020-06-07–2020-06-14 之间的日期计算，特征则基于从 2020-06-07 起向前追溯六个月的数据计算。随后，模型的测试集使用 2020-06-14–2020-06-21 的标签，以及从 2020-06-14 起向前追溯六个月的特征进行计算。通过这种方式，在六个月内每周创建训练-测试对，并用于训练模型，同时考虑时间效应和序列相关性。

(3) 透支电子邮件通知只是客户收到的众多不同通知之一（例如，大额支出、发薪日、信用卡优惠、滞纳金等）。一项产品需求是大致保持每周通知数量不变，以免某种通知挤占客户收件箱中的其他通知；这意味着每周收到通知的用户数量 k 大致固定。

我们比较了不同的分类方法（逻辑回归、决策树、随机森林、梯度提升决策树和神经网络）、超参数、训练数据时间范围和特征集，考察 precision@k%、recall@k%[25], 以及模型随时间变化的稳定性。完整的模型网格和超参数集见表 3。我们没有针对 AUC 等汇总指标优化模型，而是优化局部精确率-召回率空间，以尽可能提高排名前 k% 的客户中将会透支的客户数量，并准确衡量已部署模型的性能。Precision@k% 和 recall@k% 是信息检索和搜索引擎文献[15] 中常见的指标；在这些领域，列表顶部标记的项目必须准确。鉴于我们的需求，这些指标十分合适，因为我们每周只能发送大致相同数量的通知，这是电子邮件系统的一项要求。因此，系统必须最大化排名前 k% 的 precision@k% 和 recall@k%，以触达尽可能多的目标客户。使用 precision@k% 和 recall@k% 等指标时，通常也会计算 NDCG（归一化折损累积增益），以定量衡量相关客户或项目是否位于预测列表顶部。但在这个特定场景中，NDCG 并不适用，因为我们无需对排名前 k 的列表进行精确排序。无论客户在列表中的具体位置如何，只要他们位于排名前 k 的风险客户列表中，就都会收到电子邮件通知。

模型会决定哪些客户将收到电子邮件干预。电子邮件是一种成本低廉的干预方式，可以灵活决定向哪些客户发送邮件，以及每周发送多少封邮件。唯一的资源限制是，由于还有其他电子邮件营销活动以及系统要求，每周发送的透支通知数量大致需要保持恒定。这类通知只是客户收到的众多通知之一（例如，大额支出、发薪日、信贷优惠、滞纳金等）。为了确定发送多少条通知，我们必须考虑假阳性和假阴性情况所带来的成本。假阳性通知可能会让客户对今后的通知习以为常，并使他们对系统失去信任。假阴性情况的风险在于，客户未收到通知，导致账户透支。

选择模型的目标是在最高的 k% 下最大化 precision@k% 和 recall@k%。为此，选择了满足以下条件的模型：$recall@k\% \approx 0.4 - 0.5$ 和 $precision@k\% \approx 0.4 - 0.5$，以平衡精确率和召回率。这种方法隐含地平衡了假阳性和假阴性，并假设二者造成的危害相同。对于富国银行、摩根大通银行、美国合众银行、海军联邦信用合作社、道明银行和花旗银行，均找到了能够平衡 precision@k% 和 recall@k% 的模型。对于难以平衡 precision@k% 和 recall@k% 的情况——美国银行、PNC银行和 Ally Financial——则优先考虑 precision@k%，并将其设为 $precision@k\% \approx 0.4 - 0.5$，以尽量减少假阳性并维持对系统的信任。如果作者最大化 recall@k%，大量假阳性通知会导致用户对系统失去信任。每周收到通知的客户比例 k%、precision@k%、recall@k% 以及模型类型见表 2。为完整起见，表5报告了所用模型的 AUC；表6报告了摩根大通银行在不同算法下的$precision@k\%$和 $recall@k\%$。图5展示了摩根大通银行的一个具体示例。在此例中，k% 的阈值设为 10%，precision@k% 为 0.42，recall@k% 为 0.45，二者大致达到平衡。对于9家银行中的8家，梯度提升决策树（GBDT）[16] 模型表现最佳；Ally Financial 表现最佳的模型则是前馈神经网络。作者考虑过为模型采用风险评分截断值或前k截断值。最终发现二者效果相同：前k截断值与风险评分截断值相对应，且随时间推移保持稳定。模型的超参数和架构见表4。在风险评估问题中，提升法通常优于深度学习方法[23]。

为了了解部署复杂的机器学习系统是否值得，将各银行的模型与该银行的透支贝叶斯先验及基于规则的基线进行了比较。总体而言，各模型相较于先验的效果提升了 4 至 15 倍。由于目前没有预防透支的流程，因此为每家银行创建了一棵深度为 2 的决策树，用于模拟可能找到的最佳业务规则。将各模型与深度为 2 的决策树模型进行比较后发现，各模型的效果提升了 1.17 至 2 倍，表明部署这些模型是值得的。完整详情见表 2。

模型另一个需要优化的重要方面，是在性能和随时间变化的稳定性之间取得平衡。如图7所示，不同模型的方差和性能水平各不相同，这可能导致模型性能逐周出现较大波动。通过时间交叉验证，我们可以在选定模型将标记的客户数量 k% 后，衡量模型随时间变化的性能。最终模型的选择依据是：在过去四周的性能优于所有训练模型所能达到的最佳性能，同时其精确率与最佳模型的精确率相差不超过 5%。

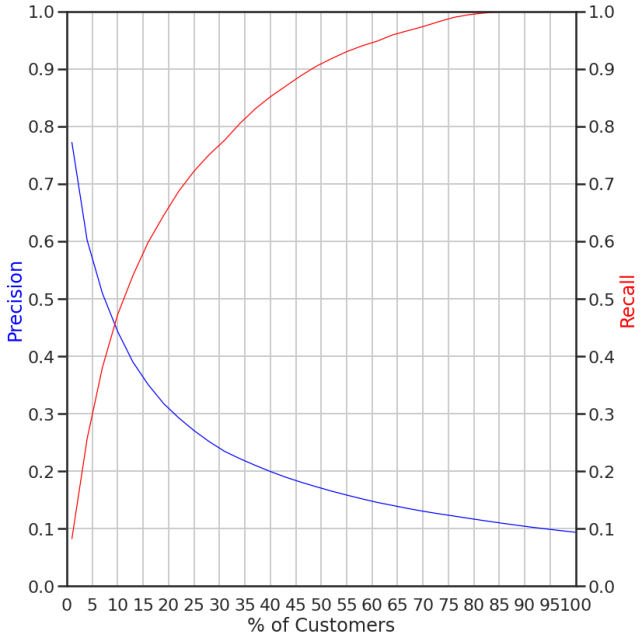

图5：摩根大通银行模型的精确率和召回率@k%：该模型会确定哪些人以及有多少人会收到电子邮件通知。由于没有资源限制，每周可发送的通知数量有很大的灵活性。选择模型时会尽量平衡精确率和召回率。在本例中，k% 的阈值设为 10%，精确率@k% 为 0.42，召回率@k% 为 0.49，两者大致相当。摩根大通银行模型相较于此前提升了 5 倍，相较于业务规则提升了 1.17 倍。

在过去四周内。此方法可确保稳定性和性能兼具。

4.0.3 特征重要性：特征重要性通过基尼重要性[20]计算得出。排名第一的特征是客户过去产生的透支费用次数。这在很大程度上符合直觉。月光族客户如果已经习惯透支，很可能会继续透支。不过，曾经有过透支记录，并不能单独预测账户是否会在下一周透支。该特征与其他透支特征（例如每周平均透支次数）存在中等程度的相关性。其次，距离上次支付透支费的天数，以及过去一周内是否发生过透支，也很重要。Mint 客户平均会透支 1.8 次，才意识到自己已经透支。距离上次透支的天数与所有其他特征的相关性都较弱。模型通常能够识别近期发生过透支的客户，并在他们再次透支之前向其发送提醒。借记交易金额较大，表明账户活动频繁，发生透支的可能性也更高。借记特征与其他借记和信用特征存在中等程度的相关性。客户通常会在存款到账后进行消费。有趣的是，借记特征的数量与透支次数并无相关性。

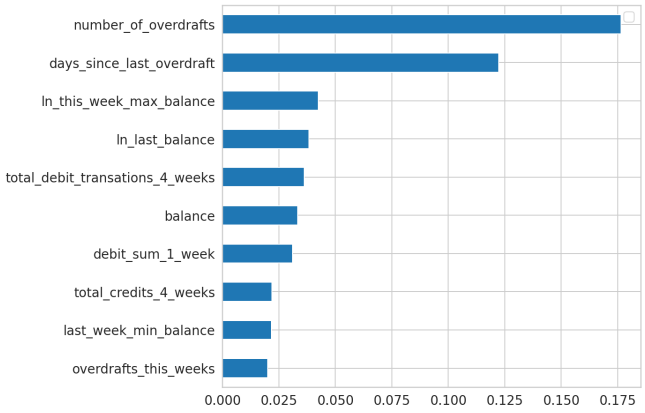

图6：摩根大通透支模型的特征重要性。特征重要性通过基尼重要性计算。摩根大通模型（梯度提升决策树）的最重要特征包括客户发生透支的次数、距上次透支的天数、本周是否发生过透支，以及过去一周借记交易的总额。这些特征大体符合直觉预期。如果客户经常透支、余额较低，或本周已经发生过透支，我们预计该客户再次透支的风险较高。

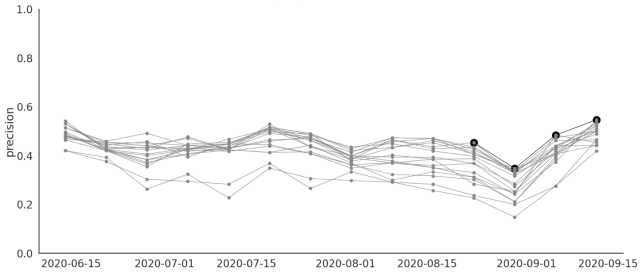

图7：余额稳定性与性能：不同模型在一段时间内的方差和性能各不相同，因此每周的性能可能出现较大波动。通过时间交叉验证，我们能够在确定模型要标记的客户比例 k% 后，衡量模型随时间变化的性能。最终模型的选择标准是：在过去四周内，其性能优于所有已训练模型所能达到的最佳性能，并且其精确率在过去四周内与最佳模型的精确率相差不超过 5%。

我们原本预计，借记交易最活跃的账户将面临最高的透支风险。较低或已经为负的余额也是即将发生透支的高风险指标，但并不能完全准确地预测透支。某些银行允许客户持有少量负余额，通常低于 50 美元，之后才会收取透支费。余额特征与其他余额相关特征高度相关，并且与信用和借记特征呈中度相关，这符合预期，因为信用和借记交易会影响余额。在低风险方面，如果客户的账户交易活动较少，

Bank	模型类型	k%	precision@k%	recall@k%	先验（基线）	相较于先验的提升	相较于业务规则的提升
富国银行	GBDT	10	0.43	0.45	0.1	4.3	1.23
摩根大通	GBDT	10	0.42	0.49	0.09	4.67	1.17
美国银行	GBDT	6	0.46	0.33	0.09	5.11	1.44
海军联邦信用合作社	GBDT	7	0.45	0.5	0.05	9	2.05
美国合众银行	GBDT	5	0.5	0.49	0.05	10	1.56
道明银行	GBDT	6	0.52	0.4	0.09	5.78	1.44
PNC银行	GBDT	2	0.45	0.26	0.03	15	1.88
Ally Financial	FFNL	2	0.48	0.17	0.06	8	1.66
花旗银行业务	GBDT	6	0.46	0.4	0.07	6.57	1.44

表 2：选择模型时，目标是在最高 k% 下最大化 precision@k% 和 recall@k%。为此，选择满足 $recall@k\% \approx 0.4 - 0.5$ **和** $precision@k\% \approx 0.4 - 0.5$ **的模型，以平衡精确率和召回率。对于富国银行、摩根大通银行、美国合众银行、海军联邦信用合作社、道明银行和花旗银行，均找到了能够平衡 precision@k% 和 recall@k% 的模型。对于难以平衡 precision@k% 和 recall@k% 的情况——美国银行、PNC银行和 Ally Financial——优先考虑 precision@k%，并将其设为** $precision@k\% \approx 0.4 - 0.5$ **，以尽量减少假阳性。将每家银行的模型与贝叶斯先验基线以及一个 a2 深度决策树进行比较，以模拟基于规则的系统。**

或者距离上次透支的天数较多，那么其账户发生透支的风险会低得多。

5种邮件变体

我们根据助推理论[8, 27] 撰写了不同版本的电子邮件，并进行了测试，以找出最有效的消息，衡量标准是邮件打开率。我们撰写了三种透支警告：“透支难免。以下是应对方法”（赋能消息）、“避免支付35美元或更高的透支费用”（损失厌恶消息）以及“透支预警”（基准消息）。如图8所示，主题行包含助推消息。电子邮件正文中包含我们认为客户可能透支的账户所属银行名称，以及客户上次支付透支费的时间。提供银行名称是为了让客户知道我们认为他们可能会透支哪个账户；出于法律原因，我们只能通过电子邮件透露账户的这一信息。通知中注明上次支付透支费的日期，有助于客户直观地了解自己为何会收到这条消息。此外，我们还列出了一些建议客户采取的措施，以避免透支。

6 模型测试设计与结果

透支早期预警系统已部署，并通过随机对照试验（RCT）进行测试，以评估该系统降低透支费用的能力。零假设是：该模型识别即将透支的客户的能力并不优于随机识别，且电子邮件干预对防止透支没有效果。测试于2020年11月至2021年1月进行，持续12周。模型每周五重新训练，随后用于生成高风险客户名单，并向这些客户发送电子邮件通知。在测试中，客户被分为四组：对照组（属于高风险客户但不接收通知），以及对应三种邮件变体的组别，即基准消息组、损失厌恶消息组和赋能型消息组。客户首次收到通知时会被随机分配到其中一组，并在测试期间收到后续通知时始终留在该组中。总体而言，共发送了20万条通知，测试参与者有6万人（其中4.8万人属于邮件变体组，1.2万人属于对照组）。如前所述，Mint 应用接收最新交易数据的速度存在延迟。在离线历史测试中，我们测得各银行模型的精确率为40%–45%（表2），该测试不受数据延迟影响。因此，我们预计在模型部署期间，测试中的客户平均每周有45%会发生透支。在对照组中，每周发生透支的客户比例约为27%。我们将这一性能差异归因于预测时所接收的交易数据存在延迟。值得注意的是，处理组中从未打开过电子邮件的用户，其透支率与对照组相近。在这些情况下，来自 Mint 应用的电子邮件可能被直接忽略，或未能送达收件人（例如被发送至垃圾邮件过滤器）。三种邮件变体的总体邮件打开率为24%。在打开电子邮件的用户中，与对照组相比，发生透支的客户减少了3.71%（呈下降趋势），这表明客户采取了某些行动，或在接下来一周内注意避免其账户透支。每封电子邮件还包含一个链接，可跳转至用户在 Mint 应用中的支票账户。在点击链接查看余额的用户中，与对照组相比，发生透支的客户减少了12.86%（具有统计显著性，$p < 0.05$），这表明这些用户查看了自己的余额，并很可能采取了措施，以防止接下来一周发生透支。

该系统的一个重要目标是促进客户改变行为，从而减少透支。从客户收到第一封电子邮件起，我们对用户进行了为期三个月的追踪。许多注册理财规划师认为，培养新的理财习惯大约需要三个月。总体而言，与对照组相比，处理组客户节省的透支费用估计达 300 万美元。此外，处理组的客户人均透支费用比对照组低 5 美元。

创建并测试邮件变体的目的是找出最有效的信息传达方式。测试结果支持这样一种观点：打开电子邮件的客户可能会减少透支。能够引起客户共鸣并促使其采取行动的信息

因此是系统中的重要组成部分。打开率达到 30% 的基准消息“透支预警”明显胜出，高于赋能型邮件（21%）“透支会在这里发生——以下是应对方法”和损失厌恶型邮件（22%）“避免支付 35 美元或更高的透支费用”。作者推测，简洁的信息“透支预警”打开率较高，是因为它传达了透支迫在眉睫、需要立即采取行动，而其他邮件变体听起来更像是在提供一般性的财务建议。

这项测试的另一个目标是了解客户对透支通知的响应能力。模型能够预测客户面临的风险，但无法预测客户在收到通知时是否有能力避免透支。通常，与高风险客户相比，风险处于中低水平的客户更常打开通知。作为测试分析的一部分，我们将客户分为三组：响应能力较强的客户，其账户有正余额且透支次数较少；响应能力中等的客户，其账户有正余额且透支次数较多；响应能力较弱的客户，其账户为负余额且透支次数较多。响应能力较强和中等的客户组中，发生透支的客户比例通常始终低于响应能力较弱的客户组，邮件打开率也更高。我们发现，响应能力较弱的客户并非不知道自己正在透支，而是没有能力避免账户透支，因此这种干预对他们无效。这引出了一个问题：即使我们认为长期透支者无法避免透支，或不会查看通知，他们是否仍应收到电子邮件通知？鉴于模型处于社会与伦理背景之中，我们认为无论客户是否有能力避免透支，都应向所有客户发出透支警告。如果某些客户收到电子邮件干预而其他客户没有，我们就有可能造成或加剧差异[15, 24]，因为并未让所有面临风险的客户都有机会避免透支。

测试期间的客户访谈深入揭示了客户对预警的反应。一个主要顾虑是，假阳性消息会导致客户失去对系统的信任，从而忽略今后的消息。在这些访谈中，我们了解到，只要客户能够根据自己的交易与余额数据直观地理解收到通知的原因，就不会因假阳性消息而感到麻木；这里的假阳性消息指的是错误地判定客户即将透支的电子邮件通知。收到消息但无法避免透支的客户仍然积极参与，并认为如果将来有机会采取行动，这些通知会有所帮助。其次，我们发现，没有客户会在收到通知的当下立即处理透支问题，有时甚至会忘记，直到被收取透支费才想起来。我们计划今后添加即时推送通知和稍后的电子邮件提醒，以提高效果。访谈中，客户普遍希望 Mint 应用能够自动处理即将发生的透支。未来可以通过自动或辅助进行资金转移，或代表客户申请豁免来实现这一点。

7 结论

本文中，作者介绍了一种机器学习方法，用于开发风险模型，预测哪些 Mint 用户会在未来一周内使其支票账户透支，并向他们发送预警邮件通知。各银行模型的效果均优于先验基准，也优于业务规则模型，同时兼顾稳定性与性能。研究人员运用助推理论测试了多种消息版本，以找出最有效的表达方式。在模型测试期间，该系统总计为客户节省了 300 万美元的透支费用。

从更高层面来看，这种方法和思路可用于提供不同类型的财务建议。本文展示了我们可以帮助客户避免不必要的透支费用。尽管大多数基于机器学习的研究都聚焦于投资和金融市场，但我们坚信，基于机器学习的工具能够帮助改善个人财务状况。具体而言，我们相信可以提供由机器学习驱动的建议，帮助客户处理个人理财的其他重要方面，例如提高信用评分、建立应急储蓄、偿还债务以及分配用于投资的资本。未来，我们希望报告更多个人理财领域中由机器学习指导的工具。

致谢

这项工作的完成离不开许多人的共同努力。我（AK）谨向以下人士致谢：Ido Mintz、Itay Granik 和 Daniel Ben David，他们完成了最初有关透支消息的工作；Victor Escoto 为本文制作图表；Joanne Locascio 设计了助推消息；Kaitlin Inghilterra 指导我如何开展客户访谈；Ivelin Angelov 帮助搭建流程管道；Kymm Kause 创建了用于 A/B测试测试和分析的仪表板；Ken Yocum 和 Kit Rodolfa 与我进行了讨论，并仔细审阅了这份稿件。

参考文献

[1] 2021. Ally Bank 透支政策。https://www.ally.com/overdraft/ [2] 2022. 花旗银行透支政策。https://online.citi.com/US/JRS/portal/template. do?ID=Citi-Overdraft-Fees-Change [3] Sule Alan、Mehmet Cemalcilar、Dean Karlan 和 Jonathan Zinman。2018。《揭开面纱：土耳其银行透支的证据：揭开面纱：土耳其银行透支的证据》。《金融学杂志》73, 2（2018年4月），481 522 10 1111 12593 – 。https://doi.org/ 。/jofi。Chris Arnold。。[4] 2022 人们讨厌透支费用。银行正在取消或降低这些费用。美国国家公共电台（2022年1月）。https://www.npr.org/2022/01/11/1071860136/people-hate-overdraft-fees-capital-one-is-ditching-them-and-other-banks-may-foll#: ~:text=所有美国银行合计每年赚取.....%20year。[5] Daniel Ben-David、Orly Sade 和 Ido Mintz。2019。《运用人工智能和行为金融学应对注意力有限并减少透支费用》。*SSRN*电子期刊（2019 10 2139 3422198 ）。https://doi.org/ 。/ssrn。[6] 2022 2021 Cory Booker。。《停止透支牟利法案》（Stop Overdraft Profiteering Act of）。https://www. congress.gov/117/bills/s2677/BILLS-117s2677is.pdf [7] Andrea Caflisch、Michael D. Grubb、Darragh Kelly、Jeroen Nieboer 和 Matthew Osborne。2018。发送短信：自动为消费者开通透支提醒的影响。*SSRN*电子期刊（2018）。https://doi. org/10 2139 3538527 。/ssrn。Cynthia Weiyi Cai。。助推金融市场？助推理论综述。[8] 2020 《会计与金融》60, 4（2020年12月），3341–3365。https://doi.org/10. 1111/acfi.12471[9] 美国消费者金融保护局。2013。《美国消费者金融保护局透支项目研究》。https://files.consumerfinance. gov/f/201306_cfpb_whitepaper_overdraft-practices.pdf [10] 美国消费者金融保护局。2023。《透支及资金不足费用：来自收支平衡调查和消费者信用调查组的见解》。https://files.consumerfinance. gov/f/documents/cfpb_overdraft-nsf-report_2023-12.pdf

[11] Betty P.I. Chang、Thomas L. Webb、Yael Benn 和 James P. Reynolds。2017。个人财务监测：目标进展和调节焦点会影响人们何时查看余额的证据。《经济心理学杂志》62（10月 2017 33 49 10 1016 2017 05 003），–。https://doi.org/[12]。/j.joep.。。Ellenn Chang。。这些银行因冠状病毒疫情而免除透支费用。《美国新闻》（2020年3月）。https://money.usnews.com/banking/articles/these-banks-are-waiving-overdraft-fees-because-of-the-coronavirus [13] Carlos L. Delgado Fuentealba、Jorge A. Muñoz Mendoza、Sandra M. Sepúlveda Yelpo、Carmen L. Veloso Ramos 和 Rodrigo A. Fuentes-Solís。2021。家庭债务、自动账单支付与注意力不集中：理论与证据。《经济心理学杂志》85（2021年8月），102385。https://doi.org/10.1016/j. joep. 2021 102385 。。Emily Flitter。2020。财务遭受重创的客户担心：没有经济刺激支票，银行会如何应对。《纽约时报》[14]（2020年12月）。https://www.nytimes.com/2020/12/31/business/stimulus-checks-overdraft.html[15] Ian Foster（编）。2021。《大数据与社会科学：研究与实践中的数据科学方法和工具》（第二版）。CRC出版社，美国佛罗里达州博卡拉顿。[16] Jerome H. Friedman。2002。随机梯度提升。《计算统计与数据分析》38, 4（2002年2月），367–378。https://doi.org/10.1016/S0167-9473(01) 00065-2[17] Danijel Jevtic、Romain Deleze 和 Joerg Osterrieder。2022。用于交易策略的人工智能。http://arxiv.org/abs/2208.07168 arXiv:2208.07168 [q-fin]。[18] Satyam Kumar、Mendhikar Vishal 和 Vadlamani Ravi。2022。运用 SHAP 对金融股票交易中的强化学习进行解释。http: //arxiv.org/abs/2208.08790 arXiv:2208.08790 [cs]。[19] Xiao Liu、Alan Montgomery 和 Kannan Srinivasan。2018。利用大数据分析银行透支费用。《营销科学》37, 6（2018年11月），855–882。https://doi.org/10 1287 2018 1106 。/mksc。。Gilles Louppe、Louis[20] Wehenkel、Antonio Sutera 和 Pierre Geurts。2013。理解随机树森林中的变量重要性。载于第26届神经信息处理系统国际会议论文集（美国内华达州太浩湖）（NIPS'13）。Curran Associates Inc.，美国，431–439。http://dl.acm.org/citation.cfm?id=2999611 2999660 。Brian T. Melzer 和 Donald P.[21] Morgan。。消费贷款市场中的竞争：发薪日贷款与透支信贷。《金融中介杂志》2015 24, 1 2015 25 44 10 1016 2014 07 001 （1月），–。https://doi.org/[22]。/j.jfi.。。Karesia Ramlal 和 Patrick Hosein。。个性化透支保护框架。载于2021年IEEE第8届数据科学与高级分析国际会议（DSAA）。IEEE，葡萄牙波尔图，1–8。https://doi.org/10.1109/ DSAA53316.2021.9564162[23] Cynthia Rudin 和 David Carlson。2019。《机器学习的秘密：你希望早些知道的十件事，助你更有效地进行数据分析》。（2019）。https://doi.org/10.48550/ARXIV.1906.01998 出版者：arXiv 版本号：1。[24] Pedro Saleiro、Benedict Kuester、Loren Hinkson、Jesse London、Abby Stevens、Ari Anisfeld、Kit T. Rodolfa 和 Rayid Ghani。2018。Aequitas：偏差与公平性审计工具包。（2018）。https://doi.org/10.48550/ARXIV.1811.05577 出版者：arXiv 版本号：2。[25] Katarzyna Stąpor。2018。《评估和比较分类器：综述、若干建议与局限》。载于第10届计算机识别系统国际会议论文集（CORES 2017），Marek Kurzynski、Michal Wozniak 和 Robert Burduk（编）。第578卷。施普林格国际出版公司，瑞士查姆，12–21。https://doi.org/10.1007/978-3-319-59162-9_2 丛书名：《智能系统与计算进展》。[26] Narendra Rao Tadapaneni。2019。金融与投资领域的人工智能。《科学、工程与技术创新研究国际期刊》9, 5（2019）。[27] Richard H. Thaler 和 Cass R. Sunstein。2021。《助推：最终版》（增订版）。企鹅图书，企鹅兰登书屋有限责任公司的一个品牌，纽约。[28] Joe Valenti。2022。透支费用可能使人们无力继续使用银行服务。消费者金融保护局（2022年3月）。https://www.consumerfinance.gov/about-us/blog/overdraft-fees-can-price-people-out-of-banking/[29] Dejan Varmedja、Mirjana Karanovic、Srdjan Sladojevic、Marko Arsenovic 和 Andras Anderla。2019。信用卡欺诈检测——机器学习方法。载于2019年第18届INFOTEH-JAHORINA国际研讨会（INFOTEH）。IEEE，波斯尼亚和黑塞哥维那东萨拉热窝，1–5。https://doi.org/10.1109/INFOTEH. 2019.8717766[30] Yu Zhao、Shaopeng Wei、Yu Guo、Qing Yang、Xingyan Chen、Qing Li、Fuzhen Zhuang、Ji Liu 和 Gang Kou。2022。结合内部风险与传染风险，利用图神经网络预测企业破产。http: //arxiv.org/abs/2202.03874 arXiv:2202.03874 [cs, q-fin]。

A 附录

模型	超参数
逻辑回归	惩罚项: [l1, l2"],C: [0.00001, 0.001, 0.1, 1, 10]
随机森林	n_估计器: [100, 1000],最大_深度: [10, 50], 最大_特征: [平方根, 对数2], 最小样本分裂: [2, 10]
梯度提升决策树-策树	估计器： [100, 1000, 10000],学习率： [0.01、0.1、0.5], 子采样： [0.1、0.5、1.0], 最大_深度： [5, 10]
决策树	标准： [基尼], 最大深度： [1, 5, 10, 20, 100]
前馈 神经网络	学习率： [0.0001、0.001、0.01], 隐-藏层大小： [128,256,512], 丢弃率: [0.25], 训练轮数: [10,30]

表 3：模型搜索的模型和超参数网格

Bank	模型	超参数
富国银行	GBDT	学习率：0.01，最大深度：10，估计-估计器：100，子采样：0.5
摩根大通	GBDT	学习率：0.01，最大深度：10，估计器—估计器：100，子采样：0.5
美国银行	GBDT	学习率：0.01，最大深度：10，估计器—计数器：100，子采样：0.5
Navy 联邦信用合作社	GBDT	学习率：0.1，最大深度：5，估计器数：100，子采样：0.5
美国合众银行	GBDT	学习率：0.01，最大深度：10，估计器：100，子采样：0.5
道明银行	GBDT	学习率：0.01，最大深度：10，估计器：100，子采样：0.5
PNC银行	GBDT	学习率：0.01，最大深度：10，估算器：100，子采样：0.5
Ally Financial	FFNL	层：3，节点：128，丢弃率：0.25，激活函数：sigmoid，训练轮数 30，学习率：0.0001
花旗银行	GBDT	学习率：0.01，最大深度：5，估计器：100，子采样：0.5

表4：各银行生产模型的超参数。

Bank	ROC曲线下面积
富国银行	0.84
摩根大通	0.85
美国银行	0.85
海军联邦信用合作社	0.94
美国合众银行	0.90
道明银行	0.86
PNC银行	0.92
Ally Financial	0.81
花旗银行	0.86

表5：各银行生产模型的ROC曲线下面积

分类器	精确率@k	召回率@k
梯度提升决策树	0.45	0.49
FFNL	0.42	0.45
决策树	0.36	0.38
随机森林	0.44	0.47
逻辑回归	0.42	0.44

表6：摩根大通银行不同分类器的性能

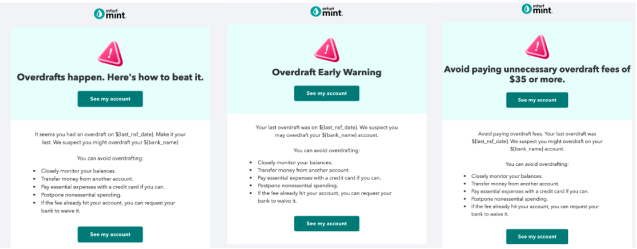

图8：透支提醒消息。向处理组的客户发送了多种消息，旨在助推他们改变行为。这些消息包括赋能型消息、基准消息和损失厌恶消息。消息还列出了我们认为客户可能会透支的账户所属银行、客户上次被收取透支费的日期，以及一系列避免支付透支费的选项。与另外两种消息相比，基准消息"透支预警"的打开率最高（30%）。我们推测，简洁的"透支预警"消息比另外两种消息更能提醒客户，他们的账户正面临立即透支的风险。