中国农村老年人家庭照护方式选择的影响因素

——基于机器学习方法的实证分析

肖 雪 胡冰川

摘要：本文基于2022年中国乡村振兴综合调查数据，综合运用多种线性和非线性机器学习模型，系统识别中国农村老年人家庭照护方式选择的重要影响因素。研究结果表明：非线性机器学习模型的预测效果显著优于线性机器学习模型，其中集成学习模型表现最佳。个体、家庭和村庄三个层面的特征变量中，家庭层面特征变量的重要性最高，其中家庭老年人比重与农村老年人选择子女照护的概率呈负相关，家庭人口数、与子女合住和家庭收入均与农村老年人选择子女照护的概率呈正相关。个体层面特征变量也是影响农村老年人家庭照护方式选择的重要特征变量。上述结论经过一系列的稳健性检验后仍然成立。进一步利用ALE图分析发现，家庭老年人比重、家庭人口数、受教育水平、年龄和家庭收入均与农村老年人家庭照护方式选择存在显著的非线性关系。此外，本文延伸讨论了农村老年人对社会养老服务的购买意愿，分析发现家庭收入和承包地面积是最重要的影响因素，均与购买意愿的概率呈正相关。本文的研究结论对优化农村养老政策、完善家庭照护体系具有重要的价值。

关键词：农村老年人 家庭照护方式 养老服务购买 机器学习

中图分类号：F328 **文献标识码：**A

一、引言

当前，中国人口老龄化程度持续加深，已进入中度老龄化社会。根据国家统计局

[资助项目] 中国社会科学院重大经济社会调查项目“乡村振兴综合调查及中国农村调查数据库项目”（编号：GQDC2022020）；上海市哲学社会科学规划课题“上海农村社会保障体系的家庭化路径研究”（编号：2022BSH012）。

[作者信息] 肖雪，上海市乡村振兴研究中心，电子邮箱：xuexiao1999@outlook.com；胡冰川，中国社会科学院农村发展研究所，电子邮箱：hubch@cass.org.cn。

最新数据，2024年末，中国60岁及以上人口首次突破3亿，并在2025年末占比达到23.0%[①]。在人口结构发生巨大转变的过程中，中国老年人口呈现“城乡倒置”的显著特征，农村老龄化水平始终高于城镇（杨菊华等，2019）。快速的人口老龄化和城市化，以及长期以来城乡经济社会领域的不平衡发展，使得中国农村养老服务与城市相比面临更加严峻的挑战（陈欣欣等，2021）。在滞后的社会养老保障体系建设和传统的家庭文化观念影响下，农村老年人普遍将家庭养老视作最理想且最主要的养老模式。均衡互惠的“反馈模式”，即“父母抚养子女长大成人，子女为父母养老送终”，一直以来都是中国社会的文化传统，具有深厚的历史基础（费孝通，1983）。

然而在工业化和城镇化的时代洪流下，农村家庭的结构、功能及分工发生了新的变化，在现代化进程中农村家庭呈现小型化、核心化与居住模式变化的特征（彭希哲和胡湛，2015）。这些新变化正在瓦解传统农村家庭养老的基础，当前农村子女给予的经济支持、生活照料和精神慰藉均已全面弱化（于长永等，2017）。同时，农村家庭代际间的资源与权力关系日益失衡，也推动了农村家庭养老模式和照护方式加速分化（狄金华和郑丹丹，2016）。按照老年照护责任的归属区分，自我照护和子女照护是两种最主要的家庭照护类型，子女被认为是家庭养老中最主要的老年照护承担者（杜鹏等，2016）。如今家庭照护仍是农村占主导地位的老年照护方式（朱玲等，2020）。农村老年人的家庭照护方式选择本质上是家庭内部代际间决策过程的具象化表达，不仅反映出微观农村家庭资源的分配逻辑，也映照着宏观社会转型对传统家庭秩序的冲击。家庭照护方式的变化深刻影响着农村老年人的晚年福祉，并成为理解当代农村家庭代际关系嬗变的微观切口。在此背景下，系统分析农村老年人家庭照护方式选择的影响因素，对探究当前家庭代际关系新变化，挖掘其背后转变的内在驱动力以及完善未来农村养老政策体系具有紧迫的现实意义。

当前，学者对农村老年人照护方式选择的影响因素及其机制等做了大量的相关前期研究，取得了丰富的研究成果，但仍存在几个方面的不足。首先，部分实证研究（廖小利，2019）仅采用特定区域的样本，研究数据相对陈旧且缺乏代表性，难以及时准确地反映整体社会经济状况变迁下农村老年人家庭养老意愿出现的新变化。其次，现有研究（孙兰英等，2019；曹丽丽和陈鸣声，2024）在方法层面普遍从传统计量统计框架出发，根据被解释变量特点构建Logit或多元Logit回归模型，通过解释变量的系数显著性进行分析。这种通用做法虽然操作简便且结果易解释，但从更广义的方法论角度来看，具有明显的局限性。具体而言，传统的Logit模型由于预设了简化的

① 资料来源：《国家统计局：2024年我国60岁以上人口首次突破3亿人》，https://laoling.cctv.com/2025/01/17/ARTI1YQU2WRMlO75bKSmmyLY250117.shtml；《中华人民共和国2025年国民经济和社会发展统计公报》，https://www.stats.gov.cn/sj/zxfbhjd/202602/t20260228_1962662.html。

模型形式且对纳入变量进行预先人为筛选，不仅难以准确刻画复杂现象的非线性特征和捕捉变量间的交互效应，也无法有效处理遗漏变量等内生性问题，因而降低了估计结果的可靠性。随着农村老年人家庭养老照护相关研究的深化，亟须引入新数据和新方法来进一步拓展对该问题的认识和理解。近年来，机器学习方法的迅速发展为未来研究提供了新的分析视角和技术手段，能够有效解决已有研究中存在的不足。鉴于此，本文采用机器学习方法重新探讨这一问题，以求更加准确刻画农村老年人家庭照护方式选择的影响因素以及变量间的真实复杂关系，拓展已有研究边界并深化研究结论，据此提出更有效的农村家庭养老保障方案，提升农村老年人的晚年福祉。

机器学习方法的兴起，深刻改变了传统经济学、管理学、社会学等社会科学领域的传统研究范式，推动了新兴交叉学科的发展，实现了从模型驱动到数据驱动、从参数不确定性到模型不确定性、从低维建模到高维建模等研究方法上的变革（洪永淼和汪寿阳，2021；刘景江等，2023）。与计量分析等解释性建模方法相比，机器学习在数据处理和模型建构等方面具有独特优势，因而具有更好的预测能力（齐秀琳和汪心如，2024）。特别是集成学习方法的发展，通过在建模过程中着重控制过拟合问题，进一步提升了模型的泛化能力（Kleinberg et al.，2015）。但任何预测方法都是在偏差与方差之间进行权衡取舍，机器学习基于数据驱动构建复杂模型（王芳等，2020），由此导致的结果是部分机器学习方法因缺乏可解释性而饱受诟病，其计算过程类似于“黑箱”，而“黑箱”内部如何运算则不得而知（郭峰和陶旭辉，2023）。近年来，机器学习可解释性方法的发展极大地推动了机器学习在社会科学研究中的运用。例如，SHAP（SHapley Additive exPlanation，SHAP）值可解释性方法（Lundberg and Lee，2017）和ALE（accumulated local effects，ALE）图（Apley and Zhu，2020），能够衡量不同特征变量对响应变量影响的贡献大小和方向，直观描述重要特征变量如何影响模型预测，并揭示特征变量与响应变量之间的非线性关系。

本文基于2022年中国乡村振兴综合调查（Chinese Rural Revitalization Survey，CRRS）数据，采用多种具有代表性的线性和非线性机器学习模型，系统探讨个体、家庭及村庄三个层面的特征变量对农村老年人家庭照护方式选择的影响。对不同机器学习方法的性能进行综合评估后，本研究利用模型评价效果最佳的随机森林（Random Forest）和梯度提升（Gradient Boosting）两种集成学习模型，在对特征变量进行预处理的基础上，基于SHAP值可解释性方法对农村老年人家庭照护方式选择的特征变量进行重要性排序，并分析各特征变量对模型预测结果的影响方向及贡献大小，结合ALE图探讨重要特征变量对农村老年人家庭照护方式选择的非线性影响。进一步地，本文对农村老年人社会养老服务购买意愿的重要特征变量进行了拓展讨论，以全面深入理解家庭养老弱化背景下农村老年人养老模式的发展和演变。

本文研究尝试将前沿机器学习方法运用到重要社会科学议题，对现有研究的边际贡献主要有以下两个方面。一是采用兼具代表性和时效性的全国性调查数据，创新性地将前沿的机器学习方法应用于农村养老领域研究，系统分析农村老年人家庭照护方式选择和社会养老服务购买意愿的多维度影响因素，突破以往研究在视角和方法上的局限性，深化了研究结论，并丰富了机器学习方法在社会科学研究领域的应用场景。二是通过引入不同的机器学习可解释性方法对特征变量进行重要性排序并分析变量间的非线性关系，清晰地呈现了关键特征变量对农村老年人家庭照护方式选择的影响程度、方向与模式。这使研究结论更具现实意义和政策价值，为未来制定更有针对性的农村养老政策、提升家庭养老保障水平和增进农村老年人福祉提供了重要的实践指导。

二、机器学习模型与可解释性方法介绍

（一）从因果推断到机器学习

机器学习方法与传统的因果推断属于两种不同的建模范式，前者更侧重于预测性能，后者则强调因果识别，两者各有优劣且互为补充。基于机器学习方法得到的新发现能够为未来进一步开展因果推断提供坚实基础，而因果推断的结论则为机器学习方法的结果解释提供重要支撑。与因果推断相比，机器学习在处理高维数据、分析变量之间的非线性关系、控制混淆因素和预测等方面具有显著的优势。

其一，机器学习方法具有更强的高维数据处理能力。随着数据维度和样本量的增大，传统计量统计方法会面临“维数灾难”，导致估计结果失效。在传统的计量分析框架下，研究者通常手动限制控制变量的数量，而不是依赖于数据进行选择（Athey and Imbens，2019）。与之相比，机器学习方法具有处理更高维度数据的天然优势，能够通过正则化技术等手段进行有效处理，并能通过算法对变量进行自动降维，提高估计效率（洪永淼和汪寿阳，2021）。

其二，机器学习方法具有更灵活的模型形式。传统的计量分析通常预先假设模型形式（通常为线性形式），并基于一系列严苛的假设。然而，变量间复杂的非线性关系不仅提高了模型误设的可能性，同时有关假设在现实中往往难以成立。而机器学习方法不假设具体的函数形式且能够较好地拟合更高维度的数据，因而具有较大的灵活性（Athey，2018），对处理社会科学领域广泛存在的模型不确定性问题具有普遍的适用性（刘岩和谢天，2019）。

其三，在进行因果推断研究时，遗漏变量、反向因果等内生性问题会导致模型估计结果产生偏差，而机器学习方法的主要目标在于提升预测性能，并不依赖于变量的外生性假设。本文研究本质上属于预测性研究，旨在通过机器学习方法识别与农村老

年人家庭照护方式选择高度相关的重要特征变量并提高预测准确性，主要关注特征变量与响应变量之间的相关关系。事实上，在采用机器学习方法的预测性研究中，深入探究变量之间的相关关系同样能够为研究者和政策实施者提供重要启示（郭峰和陶旭辉，2023）。因此，即使变量间存在不可避免的潜在内生性问题，也不会对本文农村老年人家庭照护方式选择的预测效果产生实质性影响，反而凸显了机器学习方法在高维复杂数据分析中的适用性和独特优势。同时，近年来随着SHAP值、ALE图等可解释性方法的兴起与发展，机器学习的可解释性也在逐渐提升。

（二）机器学习模型选择

根据是否利用已知的被解释变量进行训练，当前机器学习方法主要可以分为有监督学习和无监督学习（Athey and Imbens，2019）。社会科学问题的特性决定了研究者所关注的被解释变量往往是已知的，因此社会科学研究中主要使用有监督机器学习模型，其核心思想在于，构建一个损失函数，通过代入数据来选择最优的预测模型，模型形式更加灵活（黄乃静和于明哲，2018）。根据研究问题，本文所采用的机器学习模型主要针对被解释变量为分类变量的情形，即分类型机器学习模型。

模型选择上，本文选取多种经典机器学习模型，涵盖线性与非线性、单一与集成等不同特征。具体而言，Logit回归是最经典且应用最广的解释型线性模型之一，常作为基准模型开展分类预测和因果推断。本文使用的是横截面微观农户调查数据，数据类型多样且变量之间可能存在复杂的非线性关系，而Logit回归的建模能力有限，难以捕捉复杂的非线性关系与交互效应；lasso回归在Logit回归基础上引入正则化项，有助于进行特征选择和处理多重共线性问题，但在本质上仍属于线性模型，无法完全挖掘变量间的非线性关系。为进一步挖掘变量间潜在的非线性特征，本文引入三类经典非线性机器学习模型。其中，支持向量机（support vector machine，SVM）适用于中小样本的非线性分类任务，能够较好地处理复杂边界问题；前馈神经网络（feedforward neural network，FNN）作为基础的深度学习结构，能够较好地拟合高维特征间的非线性映射关系；随机森林和梯度提升分别是Bagging和Boosting两类集成学习模型的典型代表，均通过构建多个弱学习器提升整体预测性能，在处理高维和复杂变量关系方面表现突出。

不同模型在建模性能、解释能力和计算效率等方面各具特点，机器学习中的没有免费午餐（no free lunch，NFL）定理表明，在一定理论假设下，没有一个模型在所有问题上绝对优于其他模型（Wolpert，1996）。模型的预测效果取决于模型与具体问题特征之间的匹配程度，模型本身并不存在普遍意义上的优劣。接下来，本文将结合多项评价指标对上述模型进行比较[①]，以选择最适用于本研究的机器学习模型。

① 关于各模型的介绍详见《中国农村观察》网站或中国知网本文附录中的“一、不同模型的比较”。

1.Logit回归。本文研究的响应变量为二分类变量，故选取传统的Logit回归模型考察农村老年人家庭照护方式选择的影响因素，同时作为其他机器学习方法的预测结果的基准参照。Logit回归通过输入特征的线性组合计算某个类别的概率，并选择概率最高的类别作为预测结果。

2.lasso回归。lasso回归由Tibshirani（1996）提出，属于惩罚回归的一种，在Logit回归的基础上引入基于L_1范数的正则化项对回归系数施加惩罚约束，以实现变量选择和参数估计的目的。lasso回归的目标函数结合了Logit回归的交叉熵损失和L_1正则化项，由负对数似然损失函数和正则化项两部分组成。

3.支持向量机。支持向量机由Cortes and Vapnik（1995）提出，其目标是找到一个最佳分类超平面，最大化分类边界的间隔。由于在实际问题中数据可能无法完全线性可分，因此引入松弛变量，允许部分样本违反约束条件。

4.前馈神经网络。前馈神经网络是目前最基础且广泛使用的神经网络结构之一。其基本结构由输入层（input layer）、隐藏层（hidden layers）和输出层（output layer）组成（Bishop，1995）。其中，输入层负责接收输入样本的特征变量，每个节点（神经元）代表一个输入特征；隐藏层由多个神经元组成，负责提取输入数据的特征，每个神经元通过权重、偏置和激活函数对输入特征进行线性和非线性变换；输出层则负责将隐藏层的结果转化为最终输出。

5.随机森林。随机森林是Breiman（2001）提出的一种集成学习算法，基于Bagging框架设计，通过构建多棵决策树（dicision tree，DT）并将预测结果集成，以提高分类精度并增强模型的泛化能力。每棵树通过Bootstrap抽样从训练集中随机抽取样本进行训练，独立预测样本属于某个类别的概率，进而通过多数投票法集成每棵树的预测结果从而得到最终预测结果。

6.梯度提升。梯度提升属于集成学习算法，由Friedman（2001）提出，基于Boosting框架，通过结合多个弱学习器来逐步改进模型预测性能。它的核心思想是利用前一轮的预测误差来指导后续弱学习器的构建，从而使整个模型的预测误差最小化。梯度提升的损失函数与神经网络的交叉熵损失类似，同样使用对数损失函数。

（三）机器学习模型的参数调整与评价

1.参数调整。本文采用K折交叉验证法进行参数调整，为了平衡计算成本和模型性能稳定性，最终使用5折交叉验证，并将数据集按照8∶2的比例随机划分，然后重复进行验证。具体操作上，将80%的数据随机划分为训练集，用于模型训练和交叉验证；将20%的数据划分为测试集，用于最终评估模型性能。然后，再将训练集均分为5个子集（5折），依次使用其中1折作为验证集，其余4折作为训练集，重复5次后取平均结果。

模型的最优参数通过网格搜索法确定[①]。另外，针对本文的数据特征，即农村老年人家庭照护方式二分类变量的类别分布不均衡问题，Logit回归、lasso回归、支持向量机、前馈神经网络和随机森林模型中均将“类权重（class_weight）”设置为“平衡（balanced）”来自动调整类别权重，以适应数据集的类别分布不平衡问题。这一设置会根据样本的类别分布自动调整权重，使得模型在训练过程中对少数类样本赋予较高的权重，而对于多数类样本的误分类惩罚相对较小，从而有效避免类别分布不平衡所导致的模型偏向多数类的情况，提高整体模型的泛化能力。而梯度提升在逐步优化过程中已经通过残差和损失函数自动考虑了类别分布不平衡问题。具体而言，梯度提升通过在每轮迭代中拟合前一轮的残差，自动关注误分类较多的样本，从而在训练过程中强化对少数类的学习。其损失函数对分类错误高度敏感，具备天然的类别自适应优化机制，因此不需要特别设置类权重。在此基础上，本文进一步采用合成少数类过采样技术（synthetic minority oversampling technique，SMOTE）平衡样本数据[②]。该方法在样本分层抽样的基础上，通过“插值”的方式合成新的、虚拟的少数类样本，能够有效缓解类别分布不平衡问题，提升模型对少数类样本的识别能力。

2.*模型评价*[③]。在具体实证问题的分析中，需要先对不同机器学习模型的性能进行评估和比较，从而找出综合性能较好的模型。对于分类型机器学习模型，参考相关研究的做法（高雅和邬红梅，2025），本研究将综合使用准确率（accuracy）、AUC-ROC值、AUC-PR值和F1值4种指标对不同的机器学习模型进行全面评价，以筛选出综合性能表现最好的机器学习模型。准确率是分类型机器学习模型中最基础和最常用的评价指标，用于衡量预测正确的样本占总样本数的比例。在此基础上，AUC-ROC值和AUC-PR值也是评估分类型机器学习模型的重要工具（Leist et al.，2022）。AUC-ROC值和AUC-PR值分别指ROC曲线和PR曲线下方的面积，取值范围均为0-1，越接近于1表明模型的总体性能越好。具体而言，ROC曲线的纵轴为真阳性率（true positive rate，TPR），代表所有实际为正类的样本中被正确预测为正类的比例；横轴为假阳性率（false positive rate，FPR），表示所有实际为负类的样本中被误识别为正类的比例。ROC曲线越接近于左上角，模型效果越好。PR曲线的纵轴为精确率（precision），衡量被模型预测为正类

① 在综合考虑稳定性、准确性和计算资源消耗等指标的基础上，本文最终选择使用网格搜索法在指定的参数集合中筛选最优参数。各模型的网格搜索超参数范围详见《中国农村观察》网站或中国知网本文附录中的附表1。

② 使用SMOTE处理样本不平衡时，本文的关键参数设置包括：sampling_strategy=‘auto’，自动将少数类过采样至与多数类相同的数量；k_neighbors=5，每个少数类样本与其最近的5个相邻样本合成新的样本；random_state=2025，将其设为固定整数以确保采样过程的可重复性。

③ accuracy、TPR、FPR、precision和F1值的计算公式详见《中国农村观察》网站或中国知网本文附录中的（9）~（13）式。模型预测结果与实际分类之间的对应关系详见附表2。

的样本中实际为正类的比例；横轴为召回率（recall），又称真阳性率。PR曲线越靠近右上角，模型性能越佳。相比于ROC曲线，PR曲线在处理类别分布不平衡的响应变量时更具参考价值。另外，F1值是评价分类型机器学习模型的综合指标，能够权衡模型的精确率和真阳性率，综合考虑模型对正类的预测准确性和覆盖率。

（四）基于SHAP值的机器学习可解释性方法

由于集成学习模型本质上仍属于黑箱模型，在结果的直接解释性方面有所欠缺。借鉴相关研究的做法（齐秀琳和汪心如，2024；刘媛等，2025），本文采用SHAP值可解释性方法[①]对影响农村老年人家庭照护方式选择的特征变量进行重要性排序。SHAP值可解释性方法是基于博弈论中的Shapley值理论，由Lundberg and Lee（2017）提出，专用于解释机器学习模型特别是黑箱模型（如随机森林等）中每个特征变量对目标预测值的贡献大小，能够为每个特征变量分配一个明确的贡献值，以量化其对模型预测结果的影响。具体而言，SHAP值衡量的是某一特征变量在样本中对模型预测结果的贡献方向和贡献程度。若SHAP值为正，表示该特征变量的当前取值提高了模型对目标类别的预测概率；若SHAP值为负，则表示该特征变量的当前取值降低了模型对目标类别的预测概率。SHAP值的绝对值大小反映该特征变量对模型预测结果影响的重要程度，绝对值越大，说明贡献越大。

（五）基于ALE图的特征效应分析方法

在采用SHAP值可解释性方法对特征变量进行重要性排序后，本文进一步采用ALE图[②]探究关键特征变量对农村老年人家庭照护方式选择的影响效应以及二者之间的非线性关系。相比于过去文献中广泛使用的部分依赖图（partial dependence plot，PDP）（高雅和邬红梅，2025），ALE图通过计算局部效应放松了需要各特征变量相互独立的假设，因而当各特征变量存在相关性时，ALE图仍然有效。此外，ALE图还具有可解释性更强和计算速度更快的优点（Molnar，2025）。农村老年人家庭照护方式的各特征变量之间可能存在更复杂的相关关系，因此ALE图能够提供更无偏可靠的分析结果。ALE图的核心思想在于计算每个特征变量对模型预测结果的局部效应，并逐步累积这些局部效应，从而生成反映特征变量与模型预测结果之间非线性关系和交互效应的全局可视化结果。由于不同取值区间的局部效应可能存在差异，当这些局部效应逐步累积时，ALE曲线的变化趋势便能够反映特征变量对模型预测结果的边际影响是否随取值变化而发生改变。因此，ALE图不仅能够直观揭示特征变量与模型预测结果之间的非线性关系，同时还能在一定程度上反映特征变量间的交互作用。

① SHAP值的计算公式详见《中国农村观察》网站或中国知网本文附录中的（14）式。

② ALE值的计算公式详见《中国农村观察》网站或中国知网本文附录中的（15）式。

三、数据来源与变量说明

（一）数据来源

本文研究使用来自中国社会科学院农村发展研究所于2022年开展的中国乡村振兴综合调查第二期数据，即CRRS（2022）。该数据遵循多阶段分层随机抽样的原则，数据质量较高，且具有较好的代表性和时效性。调查抽样过程具体为：一是根据经济发展水平、区域位置等从东部、中部、西部和东北部地区中抽取各地区所有省份数量的1/3，共计抽取10个调查省份，包括浙江、山东、广东、安徽、河南、贵州、四川、陕西、宁夏和黑龙江；二是在每个省份中对所有县（市、区）按照GDP高低分为5组，并结合地理位置分布从每组中抽取1个县，每个省份共抽取5个县；三是按照同样的抽样原则，在每个县按经济发展水平高、中、低抽取3个乡镇；四是在每个乡镇中按经济发展水平高、低抽取2个行政村；五是基于村委会提供的花名册，采用等距抽样法在每个行政村抽取12～14个农户开展问卷调查。CRRS（2022）为CRRS（2020）的追踪调查，涵盖全国10个省份、50个县（市、区）、304个行政村，共计3700余户、1.5万余人。相较于CRRS（2020），CRRS（2022）增加了对农民养老方式、养老意愿等相关问题的提问，更符合本文的研究需要。因此，本文主要采用CRRS（2022）的数据进行实证分析。

在样本数据清理方面，本文先选择年龄在60岁及以上的农村老年人个体，然后删除缺失值和异常值，最终获得2701个农村老年人样本。

（二）变量说明

1.响应变量。本文研究的响应变量是受访农村老年人的家庭照护方式。根据受访者对CRRS（2022）问卷中“您家里老人目前怎么照护?”这一提问的回答进行赋值，将回答“子女照顾”看作“子女照护”，赋值为1；将回答“自己照顾自己”看作“自我照护”，赋值为0[①]。本文样本中，子女照护占比为26.0%，自我照护占比为74.0%，属于分布不均衡样本，需要在模型设置中进行特别处理。

2.特征变量。已有研究表明，影响农村老年人家庭照护方式的因素不仅包括微观层面的个体因素和家庭因素，还包括村庄因素（田北海等，2012；孙鹃娟和沈定，2017）。以往研究由于采取传统的计量经济学研究框架，为避免线性模型中的内生性问题，往往预先挑选控制变量因而可能遗漏了重要变量，从而影响估计结果的准确

① 需要说明的是，对于该提问还有“亲戚邻居帮忙照顾”“聘请保姆照顾”“村里的志愿者照顾”等几个回答，但在实际的调研中发现，选择上述几种照护方式的农村老年人样本占比极少，不到1%，“自己照顾自己”和“子女照顾”是当前农村老年人最主要的家庭照护方式。为了不因样本占比太少而影响结果的有效性，本文最终将家庭照护方式限定在“自我照护”和“子女照护”两种选择上。

性。与之相比，机器学习算法具备更灵活的分析框架，可以将与响应变量相关的各维度特征变量均纳入分析，在挖掘较高维度数据时更具广泛性和适应性。本文在已有研究和数据可得性的基础上，选取三个层面共计42个特征变量。具体的变量说明与描述性统计如表1所示。

表1　　主要变量定义及描述性统计结果

变量名称	变量定义及赋值	平均值	标准差	最小值	最大值
家庭照护方式	受访农村老年人目前的家庭照护方式：子女照护=1，自我照护=0	0.260	0.439	0	1
个体层面					
年龄	接受调查时的年龄（岁）	69.897	7.060	60	98
性别	性别：男=1，女=0	0.509	0.500	0	1
婚姻状况	是否有配偶：是=1，否=0	0.822	0.383	0	1
受教育水平	受教育年限（年）	5.830	3.554	0	16
政治面貌	是否共产党党员：是=1，否=0	0.150	0.357	0	1
民族	是否汉族：是=1，否=0	0.897	0.304	0	1
养老保险	是否参加养老保险：是=1，否=0	0.920	0.271	0	1
医疗保险	是否参加医疗保险：是=1，否=0	1.000	0.000	0	1
自评健康	与同龄人相比的健康状态如何：很好=5，好=4，差不多=3，差=2，很差=1	2.677	1.152	1	5
残疾	是否有残疾：是=1，否=0	0.129	0.335	0	1
慢性病	是否有慢性病：是=1，否=0	0.606	0.489	0	1
担任职务	在本村是否担任职务：是=1，否=0	0.059	0.235	0	1
就业状况	目前就业状况：全职务农、非农就业和兼业=1，无业（包括因病因残无法就业、无业、待业和离退休）=0	0.595	0.491	0	1
家庭层面					
家庭人口数	家庭户籍人口数（人）	4.332	2.095	1	16
家庭收入	2021年家庭总收入（元）	65855.970	89514.980	900	1401355
承包地面积	家庭承包地面积（亩）	20.853	391.923	0	301
宅基地数量	家庭宅基地数量（块）	1.174	0.552	0	6
外出从业	家庭成员是否有外出从业史：有=1，无=0	0.564	0.496	0	1
低保户	是否低保户：是=1，否=0	0.053	0.225	0	1
脱贫户	是否脱贫户：是=1，否=0	0.044	0.206	0	1
防返贫监测户	是否防返贫监测户：是=1，否=0	0.014	0.118	0	1
上网设备	家中是否有上网设备：是=1，否=0	0.858	0.349	0	1
网络条件	家中网络条件如何：条件好=1，条件差=0	0.774	0.418	0	1
与子女合住	是否与子女合住：是=1，否=0	0.604	0.489	0	1
与孙辈合住	是否与孙辈合住：是=1，否=0	0.382	0.486	0	1
上幼儿园	家中是否有孩子上幼儿园：有=1，无=0	0.122	0.327	0	1
上小学或初中	家中是否有孩子上小学或初中：有=1，无=0	0.349	0.477	0	1
家庭老年人比重	家庭中60岁及以上老年人占家庭总人数比重	0.660	0.324	0	1
家庭女性比重	家庭中女性成员占家庭总人数比重	0.481	0.171	0	1
家庭高文化比重	家庭中文化程度为高中及以上的成员占家庭总人数比重	0.135	0.223	0	1

（续表）

变量名称	变量定义及赋值	平均值	标准差	最小值	最大值
家庭健康比重	家庭中自评健康为较好的成员占家庭总人数比重	0.790	0.317	0	1
村庄层面					
地势	村庄地势：平原=1，其他=0	0.403	0.491	0	1
距乡镇政府距离	村委会与所在乡镇政府距离（千米）	5.922	6.480	0	57
村集体资产总额	截至2021年底本村村集体资产总额（万元）	972.850	1879.210	0	14830
村卫生室	本村是否有村卫生室：是=1，否=0	0.903	0.297	0	1
居家养老服务中心	本村是否有居家养老服务中心：是=1，否=0	0.271	0.445	0	1
定期探望独居老人	本村是否组织定期探望独居老人：是=1，否=0	0.348	0.476	0	1
农村电商	本村是否有农户经营电商：是=1，否=0	0.455	0.498	0	1
合作社数量	本村合作社数量（个）	3.621	5.631	0	45
乡村旅游	本村是否有乡村旅游：是=1，否=0	0.348	0.476	0	1
种植经济作物	本村是否种植经济作物：是=1，否=0	0.767	0.423	0	1
外出务工人口比例	2021年外出务工人口占本村户籍人口比例	0.261	0.814	0	0.126

注：①为了使描述性统计有意义，表1中对家庭收入和村集体资产总额的描述性统计结果为其原值的统计值，在后文分析中则对其进行取对数处理。②“网络条件”变量中，回答为“可以”“偶尔断网”“非常好”的视为网络条件好；回答为“没有网络”“较差”“经常断网”的视为网络条件差。③“家庭健康比重”变量中，回答为“很好”“好”“一般”的视为自评健康较好，回答为“差”“较差”的视为自评健康较差。

一是个体层面。已有研究表明，影响农村老年人家庭照护方式选择的个体因素主要包括人口特征和社会特征。其中，人口特征涵盖年龄、性别、婚姻状况、受教育水平、健康状况等（孙兰英等，2019），社会特征则包括就业状况、是否有养老保险和医疗保险等。基于数据可得性，本文从个体层面选取13个特征变量纳入分析，涵盖了农村老年人的人口特征和社会特征。

二是家庭层面。当前家庭养老仍是中国农村老年人最主要的养老方式，家庭因素对老年人的养老意愿具有重要影响（孙鹃娟和沈定，2017）。农村家庭通常以整体进行决策，以家庭整体利益最大化为目标实现家庭资源在代际之间的分配（狄金华和郑丹丹，2016）。因此，探讨家庭养老中农村老年人的照护方式时需全面考虑多维度的家庭特征。本文在家庭层面共选取18个特征变量，包括家庭结构特征（家庭人口数、家庭老年人比重、家庭女性比重、是否有孩子上学、是否与子女合住等），家庭经济特征（家庭收入、承包地面积、宅基地数量、网络条件等），以及家庭是否享受相关政策（低保户、脱贫户、防返贫监测户）。

三是村庄层面。在中国传统乡土社会中，村庄作为农村老年人生活场景和日常体验的核心载体，农村老年人的家庭照护决策深刻嵌入村庄环境与社会网络（Granovetter，1985），村庄内部的结构性差异对农村老年人的养老模式选择具有显著影响（吴海盛和邓明，2010）。本研究从村庄地理特征（地势、距乡镇政府距离）、社会经济条件（村集体资产总额、农村电商等）、公共服务供给（村卫生室、居家养老

服务中心等）等多个维度出发，选取11个村庄层面的特征变量以系统刻画村庄层面的异质性。

为了避免因引入强相关特征变量或引入噪声变量而增加模型拟合风险，进而影响后续分析结果，本文在建模前对特征变量进行筛选处理。具体方法为：计算任意两两特征变量之间的Pearson相关系数，若两个变量之间的相关系数大于阈值0.4，则视为存在较强相关性并剔除其中相关系数较大的变量，仅保留相关系数较小的特征变量用于后续模型训练和分析[①]。后文还将重设变量筛选标准进行稳健性检验。经过上述处理后，最终保留34个特征变量进行后续分析。

四、实证结果分析

（一）模型预测效果评价

表2展示了不同机器学习方法对农村老年人家庭照护方式选择预测效果的评价结果。整体来看，无论采用何种评价指标或者是否使用SMOTE处理类别分布不平衡问题[②]，随机森林和梯度提升这两种集成学习模型均表现最优。具体而言，就模型预测的准确率指标来看，非线性机器学习模型预测的准确率显著高于Logit回归和lasso回归这两种线性模型。当放松对模型线性形式的假设后，非线性机器学习模型对分类变量预测的准确率显著提高，其中集成学习算法的预测准确率更是超过85%，远高于线性模型约73%的准确率水平。这表明，农村老年人家庭照护方式选择影响因素之间的关系是复杂的，仅用传统的线性模型难以充分捕捉特征变量之间以及特征变量与响应变量之间复杂的非线性关系。

此外，就AUC-ROC值、AUC-PR值和F1值这三个评价模型预测总体性能的综合指标来看，集成学习模型仍表现最佳。随机森林和梯度提升的AUC-ROC值和AUC-PR值均更接近1，综合评价指标F1值也显著高于其他模型，进一步验证了集成学习模型优越的预测能力。相较于单一模型，集成学习模型直接从数据集出发，通过构建并结合多个弱学习器，预测性能、稳定性和样本外泛化能力更强（陈运森等，2024）。基于上述分析，本文后续将主要聚焦于随机森林和梯度提升这两类集成学习模型开展分析。

---

① Pearson相关系数只能衡量变量之间的线性相关程度，无法有效捕捉非线性关系。但在本文研究中，仅使用Pearson相关系数作为变量的预筛选手段，随后采用的机器学习模型可以自行捕捉变量间的非线性关系。另外，稳健性检验部分还将变量预筛选标准调整为0.3和0.5，以验证特征变量重要性排序结果不受变量预筛选标准的影响。

② 表2展示了采用SMOTE平衡样本数据后的结果。处理样本类别不平衡之前的模型预测效果详见《中国农村观察》网站或中国知网本文附录中的附表3。

表2　　不同机器学习模型的预测效果评价

模型	准确率	AUC-ROC值	AUC-PR值	F1值
Logit回归	0.7338	0.7977	0.5770	0.5886
lasso回归	0.7357	0.7994	0.5814	0.5903
支持向量机	0.8115	0.8491	0.6455	0.5992
前馈神经网络	0.7689	0.8010	0.5693	0.5247
随机森林	0.8688	0.9232	0.8022	0.7527
梯度提升	0.8743	0.9271	0.8098	0.7481

（二）不同特征变量的重要性排序

表3展示了基于SHAP值可解释性方法的特征变量重要性前十名排序及其影响方向[①]。对于模型评价表现最好的随机森林和梯度提升两种集成学习模型而言，特征变量的重要性排序基本一致。总体上，在筛选后纳入分析的34个特征变量中，个体层面的就业状况、受教育水平和年龄，以及家庭层面的家庭老年人比重、与子女合住、家庭人口数、家庭女性比重、家庭收入、承包地面积和家庭高文化比重，均属于解释农村老年人家庭照护方式选择排名前十的重要特征变量。

表3　　特征变量重要性排序：基于SHAP值可解释性方法

排序	随机森林		梯度提升	
	特征变量	SHAP值	特征变量	SHAP值
1	家庭老年人比重	（-）0.0896	家庭老年人比重	（-）0.3551
2	与子女合住	（+）0.0522	与子女合住	（+）0.2251
3	家庭人口数	（+）0.0495	家庭人口数	（+）0.2218
4	就业状况	（-）0.0440	就业状况	（-）0.1680
5	受教育水平	（-）0.0315	年龄	（+）0.1194
6	家庭收入	（+）0.0277	受教育水平	（-）0.1146
7	年龄	（+）0.0260	家庭收入	（+）0.1067
8	家庭女性比重	（+）0.0224	家庭女性比重	（+）0.1046
9	承包地面积	（+）0.0193	承包地面积	（+）0.0823
10	家庭高文化比重	（+）0.0178	家庭高文化比重	（+）0.0766

注：括号内的“+”代表正相关，“-”代表负相关。后文均与此相同。

可以发现，相比于其他层面的特征变量，家庭层面的特征变量更重要且占比明显更大。在仍以家庭养老为主的中国农村地区，家庭特征禀赋（如家庭照护资源、人口结构和经济条件等）是决定农村老年人家庭照护方式选择的重要考量维度。已有研究也表明，对农村老年人养老意愿有显著影响的因素基本集中在家庭层面（孙鹃娟和沈定，2017）。具体而言，家庭层面的特征变量中，与子女合住、家庭人口数、家庭收

① 不同特征变量对预测概率的影响方向由特征SHAP值蜂群图得出。随机森林和梯度提升的蜂群图详见《中国农村观察》网站或中国知网本文附录中的附图1和附图2。

入、家庭女性比重、承包地面积和家庭高文化比重与农村老年人选择子女照护的概率呈正相关。这表明，家庭内部照护和经济资源越丰富，农村老年人越倾向于选择子女照护。然而，重要性排名第一的特征变量是家庭老年人比重，该变量与农村老年人选择子女照护的概率呈负相关。这意味着在老年照护负担较重且照护资源相对紧张的家庭中，农村老年人可能更倾向于选择自我照护。另外，个体层面的特征变量中，年龄与农村老年人选择子女照护的概率呈正相关，就业状况、受教育水平与农村老年人选择子女照护的概率则呈负相关。

（三）重要特征变量对农村老年人家庭照护方式选择的非线性影响分析

本文基于特征变量重要性排序结果，选取重要性排名前列的家庭老年人比重、家庭人口数、受教育水平、年龄和家庭收入，进一步利用随机森林和梯度提升模型，借助ALE图分析这5个连续型特征变量[①]对农村老年人家庭照护方式选择的非线性影响。ALE图的纵轴是累积局部效应，反映不同特征取值相对于模型平均预测结果的变化方向及影响程度。ALE值为正，表示模型预测样本属于“子女照护”类别的概率随着特征变量值的增加而增加；反之则相反。整体上看，这些核心特征变量对农村老年人家庭照护方式选择的影响均呈现显著的非线性特征。相比传统线性机器学习模型，机器学习模型特别是集成学习模型能够更好地捕捉到这种非线性关系，因而其预测效果更优。

家庭老年人比重和家庭人口数的ALE图[②]相互印证，共同揭示了家庭结构特征与农村老年人家庭照护方式选择之间的非线性关系。一般而言，对于有照护需求的老年人，当前家庭成员仍然是最主要的照护资源（杜鹏等，2016）。家庭人口数较多，意味着家庭老年人比重较低，家庭内部也有更多可以用于老年照护的人力资源。因此在家庭人口数的ALE图中可以观察到，随着家庭人口增加，有更多的家庭成员能够提供照护，农村老年人选择子女照护的概率也相应增加。而在家庭老年人比重的ALE图中，则呈现出“先上升后下降”的非线性趋势。具体来说，在家庭老年人比重较低时，农村老年人选择子女照护的概率随老年人比重增加而上升；但到了比重较高的阶段，即家庭老年人比重大致达到0.7之后，ALE值由正转负，此时农村老年人更倾向于自我照护；随着家庭老年人比重的提升，农村老年人选择自我照护的概率进一步提高。家庭老年人比重过高时，家庭照护压力显著增大，子女难以负担全部照护责任。有研究指出，在有限资源的硬约束下，家庭照顾资源存在代际竞争，家庭普遍采取儿童优先原则，而对老人仅采取危机响应（钟晓慧和彭铭刚，2022）。这一现象与家庭

① 由于与子女合住和就业状况为分类特征变量，未纳入分析。

② ALE图详见《中国农村观察》网站或中国知网本文附录中的附图3。

老年人比重所呈现的负向影响相符，即在家庭老年人比重较大的家庭中，农村老年人选择自我照护的概率更大。

另外，为进一步探讨家庭老年人比重和家庭人口数之间的交互作用对农村老年人家庭照护方式选择的影响，本文计算二者在随机森林和梯度提升模型中的SHAP交互值均值。SHAP交互值用于衡量两个特征变量的共同作用对于模型预测结果的边际贡献，能够进一步捕捉特征之间的非线性协同关系。计算结果显示，基于随机森林模型的SHAP交互值均值为0.0099，基于梯度提升模型的SHAP交互值均值为0.0484。上述结果表明，家庭老年人比重与家庭人口数之间存在一定程度的正向交互效应，即两者协同变化时，对农村老年人的家庭照护方式选择影响的贡献有所增强。在家庭人口规模较大且老年人比重较高的情况下，农村老年人更倾向于选择子女照护；而在规模较小或老年人比重偏低的家庭中，农村老年人选择自我照护的可能性更大。当家庭人口规模较大时，家庭内部能够进行照护的成员数量增加，能够在一定程度上缓解老年人口增加带来的照护压力；而当家庭规模较小或家庭照护资源有限时，即使家庭老年人比重较低，老年人也可能由于缺乏稳定的照护支持而更倾向于选择自我照护。

受教育水平、年龄和家庭收入与农村老年人家庭照护方式选择同样存在非线性关系[①]。其一，在受教育水平的ALE图中，可以观察到受教育水平越高，农村老年人越倾向于选择自我照护。其中，ALE值由正转负的拐点出现在农村老年人受教育年限为5年左右时。这表明，受教育水平较低的农村老年人更倾向于选择子女照护；之后随着受教育水平的提升，农村老年人更可能具备丰富的健康知识和较强的独立意识，从而选择自我照护的概率逐渐上升。其二，处于不同年龄阶段的农村老年人行为逻辑具有显著差异，低龄农村老年人将长期处于自主养老状态（梁琦，2023）。事实上，较年轻的农村老年人通常健康状况相对良好且具备一定的劳动能力，而子女则处于婚育成本高企的生命周期阶段，部分农村老年人会选择自我照料甚至主动承担隔代照料等家庭责任，出现“代际支持倒挂”的现象，对子女照护的依赖程度相对较弱。相较之下，随着年龄增长，中高龄农村老年人的身体机能和劳动能力逐渐下降，对家庭照护支持的需求不断上升，因而更加倾向于选择子女照护，呈现出显著的照护需求转向。这一趋势在年龄与农村老年人家庭照护方式选择的ALE图中也可以观察到：整体来看，农村老年人的年龄与其选择子女照护的概率呈正相关。其中，大致以72岁为分界，此时ALE值由负转正，低年龄阶段的农村老年人更可能选择自我照护；而进入中高龄阶段后，农村老年人选择子女照护的可能性逐渐增强。其三，在家庭收入与农村老年人家庭照护方式选择的ALE图中，ALE值呈现先上升后趋于平稳的变化趋势，反

① ALE图详见《中国农村观察》网站或中国知网本文附录中的附图3。

映了随着家庭收入增加，农村老年人选择子女照护的概率也相应提升。在家庭经济条件有限的约束下，家庭收入相对较低的农村老年人为减轻家庭经济负担而压缩自身照护需求，选择自我照护的概率更高，但此阶段收入的提升能够显著增强其选择子女照护的倾向，表现为ALE曲线迅速上升；对于中等收入及以上的农村家庭，子女不仅具备更强的经济转移支付能力，还有更多的时间为老年父母提供更充分的生活照护，因而农村老年人从自我照护转向子女照护，选择子女照护的概率显著提升，此时ALE值由负转正。根据计算，这一转变大致出现在家庭收入达到每年16000元左右时。随着收入水平继续提升并达到更高收入阶段，家庭收入对农村老年人家庭照护方式选择的边际影响逐渐减弱，ALE曲线趋于平稳。

（四）稳健性检验

1.更换选择模型。前文对多种机器学习模型预测效果的评价表明，随机森林和梯度提升模型具备最佳的综合性能。除上述两种主流集成学习模型外，极端梯度提升（eXtreme Gradient Boosting，XGBoost）也是一种广泛应用的集成算法，特别适用于中等规模的结构化数据，能够高效捕捉变量间的复杂非线性关系与交互效应。但在本文的数据结构下，其预测性能略弱于梯度提升[①]，因此本文将随机森林和梯度提升作为主要分析模型，以XGBoost作为稳健性检验工具。检验结果显示[②]，家庭老年人比重、与子女合住和家庭人口数均被识别为最重要的特征变量，且对农村老年人家庭照护方式选择概率的影响方向均与随机森林和梯度提升的预测结果一致。

2.调整随机种子。本文进一步通过重新设置随机种子的方式，对不同模型的预测性能和基于SHAP值的特征变量重要性排序结果进行稳健性检验。机器学习模型在训练过程中包含大量随机操作，如数据集划分和参数初始化等，这些随机性因素可能导致模型输出的不稳定性，进而对模型的预测性能和特征变量重要性排序产生影响。通过调整随机种子，可以生成多组不同的数据划分比例和模型初始化状态，进而观察模型预测性能评价指标和基于SHAP值的特征变量重要性排序的变化情况。若在不同的随机种子设定下，模型的预测性能和特征变量重要性排序保持相对稳定，则表明模型对随机性的敏感性较低，特征变量重要性排序结果具有较强的稳健性。具体操作中，本文通过重新设置随机种子并重复10次[③]，对不同机器学习模型的预测效果和基于

① XGBoost模型预测效果评价详见《中国农村观察》网站或中国知网本文附录中的附表4。

② XGBoost模型下基于SHAP值可解释性方法的特征变量重要性排序结果详见《中国农村观察》网站或中国知网本文附录的附表5，蜂群图详见本文附录中的附图4。

③ 经验研究表明，随机种子10次重复已经能够捕捉到机器学习模型性能的主要波动范围，此时模型评估的各项指标趋于稳定。鉴于计算的效率与成本的平衡，10次随机重复通常已能满足大多数社会科学研究和机器学习模型评估的需求。

SHAP值可解释性方法的特征变量重要性排序结果进行稳健性检验。

模型预测效果评价的稳健性检验结果[①]表明，在考虑了随机性的影响后，非线性模型在所有机器学习模型中的综合表现仍是最佳，并且显著优于线性模型。其中，随机森林和梯度提升模型在各项评价指标上均表现最优，进一步体现了集成学习模型在预测性能和模型稳健性方面的优势。即使在不同的随机初始化条件下，集成学习模型仍能保持较高的预测准确性，从而增强了研究结论的可靠性。

重新设置随机种子并重复10次后，计算SHAP值均值的特征变量重要性排序的稳健性检验结果[②]表明，特征变量重要性排序前五位分别是家庭老年人比重、与子女合住、家庭人口数、就业状况和婚姻状况，与表4的排序结果基本一致。这表明，本文的特征变量重要性排序结果对随机性的敏感性较低且具有较高的稳定性，验证了SHAP值可解释性方法在特征变量重要性排序上的稳健性。

3. 重设变量筛选标准。在特征变量筛选环节，本文通过重设变量筛选标准进行稳健性检验。前文将特征变量预筛选的Pearson相关系数阈值设定为0.4，为检验特征变量重要性排序结果对预筛选标准的敏感性，本文进一步将相关系数阈值分别调整为0.3和0.5，重新进行特征变量预筛选和模型训练。具体而言，将相关系数阈值设为0.3时，筛选出25个特征变量；设为0.5时，筛选出39个特征变量。稳健性检验结果表明[③]，在家庭层面的特征变量中，家庭老年人比重、与子女合住和家庭人口数是重要性排序前三的特征变量，对农村老年人家庭照护方式选择的概率具有关键影响。调整相关系数阈值后，特征变量重要性排序结果基本与表4相同，增强了排序结果的可靠性。这也进一步证实，在特征变量预筛选环节相关系数的阈值设定并不会对最终结果产生较大影响，研究结论具有较强的稳健性。

4. 更换可解释性方法。由于SHAP值可解释性方法具备诸多优势，如有较强的通用性而广泛适用于任何类型的机器学习模型，因此前文主要使用SHAP值进行特征变量的重要性排序。而随机森林和梯度提升这两种集成学习算法具备能够在模型训练过程中自动评估特征变量的重要性的特点。具体而言，随机森林是通过计算每个特征在决策树节点分裂时的基尼不纯度（Gini impurity）减少的平均值对特征变量进行重要性排序，梯度提升是通过累加每个特征分裂时带来的损失函数减少量对特征变量重要性进行排序。

① 调整随机种子的稳健性检验结果详见《中国农村观察》网站或中国知网本文附录中的附表6。

② 调整随机种子后的特征变量重要性排序结果详见《中国农村观察》网站或中国知网本文附录中的附表7。

③ 重设变量筛选标准的稳健性检验结果详见《中国农村观察》网站或中国知网本文附录中的附表8和附表9。

根据更换可解释性方法后重新计算特征变量重要性排序的稳健性检验结果[①]可以发现，老年人比重和家庭人口数在两种集成学习方法中均被识别为最重要的特征变量，核心特征变量的重要性排序结果对可解释性方法具有较强的稳健性。尽管个别特征变量的重要性排序略有变化，但总体上家庭层面的特征变量在不同的排序方法下均占据主导地位，与表4基本保持一致，进一步增强了模型预测结果的可信度。

（五）进一步讨论

前文主要集中于对农村家庭养老中农村老年人照护方式选择的讨论。但从长期来看，从以家庭养老为主向以社会养老为主转变是未来养老模式演变的基本趋势（刘晓梅，2012），未来农村老年人的养老照护模式将逐渐朝社会化养老方式转型，由专业人员提供部分照料（郭瑜和张寅凯，2021）。不同于家庭养老，社会养老服务在农村地区的全面推广需要兼顾农村老年人社会养老服务购买意愿和购买能力的双重约束，其中购买意愿是形成需求的前提条件。然而当前农村老年人普遍对社会养老服务的购买意愿较弱且支付能力较低（朱玲等，2020）。作为对前文农村老年人家庭照护方式选择影响因素研究的扩展和延伸，这部分主要探究农村老年人社会养老服务购买意愿的影响因素，为未来构建和优化农村养老公共服务供给体系提供实证依据，也对制定更有针对性的农村老年人社会养老服务需求激励政策具有重要启示。

对于农村老年人社会养老服务购买意愿这一响应变量，根据受访者对CRRS（2022）中“若您或家里老人无人照料看护，您是否愿意付费购买服务？”这一提问的回答进行赋值：是=1，否=0。受访样本中，有35.06%的农村老年人愿意购买社会养老服务。前文42个特征变量基本涵盖了农村老年人社会养老服务购买意愿的关键因素，本文将通过机器学习算法从这42个特征变量中识别出对农村老年人社会养老服务购买意愿具有重要影响的特征变量，对特征变量的预先筛选和处理方式与前文相同[②]。另外，通过对不同模型预测效果的评价，发现随机森林和梯度提升这两种集成学习模型的综合性能仍是最佳[③]。为了便于与农村老年人家庭照护方式选择的特征变量重要性排序结果进行直观对比，本文在分析农村老年人社会养老服务购买意愿时，沿用随机森林和梯度提升模型。特征变量的重要性排序结果如表4所示[④]。

① 更换可解释性方法的稳健性检验结果详见《中国农村观察》网站或中国知网本文附录中的附表10。

② 特征变量预筛选标准的协方差阈值同样设置为0.4，共筛选出34个特征变量纳入后续分析。

③ 以社会养老服务购买意愿为响应变量的不同模型预测效果评价详见《中国农村观察》网站或中国知网本文附录中的附表11。

④ 不同特征变量对预测结果的影响方向由特征SHAP值蜂群图得出。随机森林和梯度提升的蜂群图详见《中国农村观察》网站或中国知网本文附录中的附图5和附图6。

表4表明，影响农村老年人社会养老服务购买意愿的因素均集中于家庭特征层面，老年人社会养老服务需求高度嵌入家庭结构情境，受资源约束机制的影响。其中家庭收入、承包地面积、家庭人口数、与子女合住和家庭老年人比重是最重要的五个特征变量。其一，家庭收入水平的高低直接决定了农村老年人对社会养老服务的支付能力，进而影响其对社会养老服务的需求和购买意愿。家庭收入水平越高，农村老年人越有可能表现出强烈的社会养老服务购买意愿。其二，当前部分农村地区较为盛行以地养老，农村老年人普遍通过参与农业生产来获取养老的经济收入（李俏和朱琳，2016）。因此，承包地作为重要的生产性资产，不仅是农村家庭重要的收入来源，也能够在一定程度上提升农村老年人的经济保障能力，因而与其社会养老服务购买意愿呈正相关。其三，家庭人口数、与子女合住这两个特征变量与农村老年人社会养老服务购买意愿呈正相关。即家庭规模越大以及与子女合住的农村老年人，往往更愿意购买社会养老服务。这一现象可能反映了家庭人口增加和代际同住的农村家庭其整体照护需求也在增加，尽管具备一定的家庭支持，但这类家庭的农村老年人养老需求并未得到满足。因此，在条件允许的情况下，农村老年人更倾向于寻求外部养老照护。其四，家庭老年人比重与农村老年人社会养老服务购买意愿呈负相关。这说明，虽然家庭老年照料需求增加，但整体能够提供的经济资源被稀释，反而限制了其对社会养老服务的实际购买能力和意愿。这也与前文ALE图的分析结论一致，即家庭老年人比重较大时，农村老年人选择自我照护的概率提高。总体来看，当前农村老年人对社会养老服务的购买意愿在很大程度上受家庭经济禀赋及家庭内部资源配置状况的制约，特别是家庭照护负担较重且经济能力有限的农村老年家庭，更应该是未来社会养老服务相关政策需要重点关注的对象。

表4　　农村老年人社会养老服务购买意愿的特征变量重要性排序

排序	随机森林		梯度提升	
	特征变量	SHAP值	特征变量	SHAP值
1	家庭收入	（+）0.0528	家庭收入	（+）0.2101
2	承包地面积	（+）0.0325	承包地面积	（+）0.1469
3	家庭人口数	（+）0.0318	家庭人口数	（+）0.1378
4	家庭老年人比重	（−）0.0302	与子女合住	（+）0.1246
5	与子女合住	（+）0.0295	家庭老年人比重	（−）0.1237

五、结论与政策启示

本文基于2022年CRRS数据，综合应用多种线性机器学习模型和非线性机器学习

模型，从个体、家庭和村庄三个层面系统探讨了农村老年人家庭照护方式选择的影响因素。研究结果表明：第一，非线性机器学习模型的预测效果显著优于线性机器学习模型，其中集成学习模型随机森林和梯度提升的综合表现最佳。第二，基于SHAP值可解释性方法分析发现，家庭层面的特征变量在模型中的重要性占比最大。其中家庭老年人比重与农村老年人选择子女照护的概率呈负相关，家庭人口数、与子女合住和家庭收入则提升了其选择子女照护的概率。个人层面特征变量如就业状况、受教育水平和年龄也具有较高的重要性。上述结论经过更换选择模型、调整参数设置、重设变量筛选标准和更换可解释性方法等一系列稳健性检验后结果仍然稳健。第三，利用ALE图分析重要特征变量对农村老年人家庭照护方式选择概率的非线性影响，发现家庭老年人比重、家庭人口数、受教育水平、年龄和家庭收入均与农村老年人家庭照护方式选择之间存在显著的非线性关系。第四，对农村老年人社会养老服务购买意愿的扩展讨论发现，家庭经济禀赋中的家庭收入和承包地面积是最重要的特征变量，与购买意愿的概率呈正相关。

基于上述研究结论，本文的政策启示主要有以下几个方面。一是建立差异化农村家庭支持政策，分类施策增强家庭养老保障能力。农村老年群体的异质性特征应成为未来相关政策制定的重要考量因素，需建立科学的分层识别机制，构建差异化养老支持体系。具体而言，对于家庭照护负担较重、收入水平较低和有高龄老人的农村家庭，在政策设计上应有所倾斜，通过财政专项补贴、税收减免优惠、政府购买服务、护理技能培训等综合配套措施，有针对性地对困难农村家庭予以兜底保障，提升农村家庭的老年照护能力和抗风险能力。二是加快社会养老保障体系建设，提供普惠、高质量的多元化农村养老服务。未来随着家庭养老逐渐弱化乃至“缺位”，部分更可能选择自我照护的农村家庭对社会公共养老服务的需求会更加强烈，亟须以政府为主导并充分激发农村内生养老服务力量，加快构建农村社会化养老服务体系。各地应因地制宜推进模式创新，积极总结推广互助养老、时间银行、医养结合等新型农村养老实践的有益经验，鼓励整合村庄资源运营“农村幸福院”“老年食堂”等全托或半托普惠型养老服务设施，增强社会养老服务供给能力。另外，还需充分考虑和尊重农村老年群体对社会养老服务的合理诉求与潜在顾虑，真正做到以人为本，切实保障和提升农村老年人的晚年生活质量与福祉。三是持续推进乡村振兴战略，以提高收入为重点提升农村老年人对社会养老服务的购买意愿和能力。由于养老保障水平较低，长期以来劳动收入一直是中国农村老年人最主要的收入来源，收入的低水平和不稳定性严重制约了农村老年人对社会养老服务的购买意愿和能力。在全面推进乡村振兴的背景下，应以提升农村老年人收入为核心目标，通过盘活土地等资源要素，深化农村集体产权制度改革，发挥新型农业经营主体的带动作用等

多种途径，拓宽农村老年人增收渠道，进而增强其对社会养老服务的支付能力和需求意愿。

不同于传统计量分析方法，本文利用多种机器学习模型深入挖掘了变量之间的相互影响和复杂关系，揭示了以往研究中未涉及的变量重要性排序和非线性特征，为未来深入开展相关研究提供了新的视角。机器学习方法在处理较高维度数据、分析变量之间的非线性关系、控制混淆因素和进行预测等方面展现出显著优势，有助于深化对社会科学重要问题的认识，更好地理解现实社会的规律。然而，机器学习方法由于自身存在缺乏解释性等缺陷而饱受争议，若要成为社会科学研究的主流方法还为时尚早。虽然本文采用的SHAP值和ALE图等机器学习可解释性方法对各种复杂机器学习模型的结果具有较强的解释性，但不可否认的是，在实际应用中这两种方法仍存在一定的局限性。例如，SHAP值在变量共线性的情况下可能对变量的真实贡献估计不够准确，且在处理高维模型（如神经网络）时计算成本较高；ALE图主要基于单变量扰动，难以捕捉变量之间的复杂交互关系。针对这些问题，本文对特征变量进行预处理和预筛选以降低样本分布不平衡和变量共线性的影响，并通过多种方式的稳健性检验以保证结果的可靠性。同时，计算SHAP交互值以探究潜在交互效应，进一步提升解释的深度。总体而言，对待机器学习结果仍需保持审慎的态度，避免盲目依赖算法输出而忽视其局限性，经验知识与社会科学理论永远是解读机器学习方法结果的基础。

最后，受限于篇幅和研究重点，本文主要聚焦农村家庭养老中的老年人照护方式选择，未对机构养老等其他养老模式进行深入探讨。另外，尽管本文分析了农村老年人社会养老服务购买意愿的影响因素，但未对具体的社会养老服务形式展开研究，也未涉及农村老年人对社会养老服务价格的接受程度。这些不足为开展进一步研究提供了新的方向，有待未来通过更全面细致的分析，拓展相关领域研究的深度和广度。

参考文献

曹丽丽、陈鸣声，2024：《社会经济因素对老年长期照护方式选择的影响：基于安德森健康行为模型的实证研究》，《健康发展与政策研究》第2期，第104–111页。

陈欣欣、陈燕凤、龚金泉、贾媛、孟琴琴、王格玮、王亚峰、颜力、杨鹏、赵耀辉，2021：《我国农村养老面临的挑战和养老服务存在的突出问题》，《中国农业大学学报（社会科学版）》第4期，第64–77页。

陈运森、周金泳、彭嘉续，2024：《中国上市公司分红的动因研究——基于机器学习的证据》，《中国工业经济》第5期，第155–173页。

狄金华、郑丹丹，2016：《伦理沦丧抑或是伦理转向——现代化视域下中国农村家庭资源的代际分配研究》，《社会》第1期，第186–212页。

杜鹏、孙鹃娟、张文娟、王雪辉，2016：《中国老年人的养老需求及家庭和社会养老资源现状——基于2014年中国老年社会追踪调查的分析》，《人口研究》第6期，第49–61页。

费孝通，1983：《家庭结构变动中的老年赡养问题——再论中国家庭结构的变动》，《北京大学学报（哲学社会科学版）》第3期，第7–16页。

高雅、邬红梅，2025：《基于机器学习方法的农民非农创业影响因素研究》，《华南农业大学学报（社会科学版）》第1期，第42–57页。

郭峰、陶旭辉，2023：《机器学习与社会科学中的因果关系：一个文献综述》，《经济学（季刊）》第1期，第1–17页。

郭瑜、张寅凯，2021：《代际关系、养老保险与中国城镇养老新图景》，《社会学研究》第2期，第160–180页。

洪永淼、汪寿阳，2021：《大数据如何改变经济学研究范式?》，《管理世界》第10期，第40–55页。

黄乃静、于明哲，2018：《机器学习对经济学研究的影响研究进展》，《经济学动态》第7期，第115–129页。

李俏、朱琳，2016：《农村养老方式的区域差异与观念嬗变》，《西北农林科技大学学报（社会科学版）》第2期，第93–102页。

梁琦，2023：《从物质生产到价值生产：中西部农村老年人以地养老的转化逻辑》，《经济社会体制比较》第6期，第88–98页。

廖小利，2019：《农村失能老年人长期照护服务需求及影响因素分析——基于湖南的实证》，《人口与发展》第1期，第119–128页。

刘景江、郑畅然、洪永淼，2023：《机器学习如何赋能管理学研究？——国内外前沿综述和未来展望》，《管理世界》第9期，第191–216页。

刘晓梅，2012：《我国社会养老服务面临的形势及路径选择》，《人口研究》第5期，第104–112页。

刘岩、谢天，2019：《跨国增长实证研究的模型不确定性问题：机器学习的视角》，《中国工业经济》第12期，第5–22页。

刘媛、熊柴、蔡继明，2025：《农民工进城落户的意愿为什么不高？——基于可解释机器学习方法的分析》，《中国农村经济》第4期，第20–41页。

彭希哲、胡湛，2015：《当代中国家庭变迁与家庭政策重构》，《中国社会科学》第12期，第113–132页。

齐秀琳、汪心如，2024：《基于机器学习方法的农业转移人口市民化水平影响因素研究》，《中国农村经济》第5期，第128–150页。

孙鹃娟、沈定，2017：《中国老年人口的养老意愿及其城乡差异——基于中国老年社会追踪调查数据的分析》，《人口与经济》第2期，第11–20页。

孙兰英、苏长好、杜青英，2019：《农村老年人养老决策行为影响因素研究》，《人口与发展》第6期，第107–116页。

田北海、雷华、钟涨宝，2012：《生活境遇与养老意愿——农村老年人家庭养老偏好影响因素的实证分析》，《中国农村观察》第2期，第74–85页。

王芳、王宣艺、陈硕，2020：《经济学研究中的机器学习：回顾与展望》，《数量经济技术经济研究》第4期，第146–164页。

吴海盛、邓明，2010：《基于村庄内部差异视角的农村居民养老模式选择意愿及其影响因素分析》，《中

国农村经济》第11期，第75-83页。

杨菊华、王苏苏、刘轶锋，2019：《新中国70年：人口老龄化发展趋势分析》，《中国人口科学》第4期，第30-42页。

于长永、代志明、马瑞丽，2017：《现实与预期：农村家庭养老弱化的实证分析》，《中国农村观察》第2期，第54-67页。

钟晓慧、彭铭刚，2022：《养老还是养小：中国家庭照顾赤字下的代际分配》，《社会学研究》第4期，第93-116页。

朱玲、何伟、金成武，2020：《农村劳动力转移与养老照护变迁》，《经济学动态》第8期，第3-19页。

Apley, D. W., and J. Zhu, 2020, "Visualizing the Effects of Predictor Variables in Black Box Supervised Learning Models", *Journal of the Royal Statistical Society Series B: Statistical Methodology*, 82(4): 1059-1086.

Athey, S., 2018, "The Impact of Machine Learning on Economics", in A. Agrawal, J. Gans, and A. Goldfarb (eds.) *The Economics of Artificial Intelligence: An agenda*, Chicago: University of Chicago Press, 507-547.

Athey, S., and G. W. Imbens, 2019, "Machine Learning Methods that Economists Should Know About", *Annual Review of Economics*, 11(1): 685-725.

Bishop, C. M., 1995, Neural Networks for Pattern Recognition, Oxford: Oxford University Press, 116-163.

Breiman, L., 2001, "Random Forests", *Machine Learning*, 45(1): 5-32.

Molnar, C., 2025, *Interpretable Machine Learning: A Guide for Making Black Box Models Explainable* (3rd ed.), https://christophm.github.io/interpretable-ml-book/.

Cortes, C., and V. Vapnik, 1995, "Support-Vector Networks", *Machine Learning*, 20(3): 273-297.

Friedman, J. H., 2001, "Greedy Function Approximation: A Gradient Boosting Machine", *The Annals of Statistics*, 29(5): 1189-1232.

Granovetter, M., 1985, "Economic Action and Social Structure: The Problem of Embeddedness", *American Journal of Sociology*, 91(3): 481-510.

Kleinberg, J., J. Ludwig, S. Mullainathan, and Z. Obermeyer, 2015, "Prediction Policy Problems", *American Economic Review*, 105(5): 491-495.

Leist, A. K., M. Klee, J. H. Kim, D. H. Rehkopf, S. P. Bordas, G. Muniz-Terrera, and S. Wade, 2022, "Mapping of Machine Learning Approaches for Description, Prediction, and Causal Inference in the Social and Health Sciences", *Science Advances*, 8(42): eabk1942.

Lundberg, S. M., and S. I. Lee, 2017, "A Unified Approach to Interpreting Model Predictions", *Advances in Neural Information Processing Systems*, 30: 4765-4774.

Tibshirani, R., 1996, "Regression Shrinkage and Selection via the Lasso", *Journal of the Royal Statistical Society: Series B (Methodological)*, 58(1): 267-288.

Wolpert, D. H., 1996, "The Lack of A Priori Distinctions Between Learning Algorithms", *Neural Computation*, 8(7): 1341-1390.

Research on the Influencing Factors of Rural Elderly Household Care in China: Based on Machine Learning Methods

XIAO Xue[1] HU Bingchuan[2]
(1. Shanghai Rural Revitalization Research Centre;
2. Rural Development Institute, Chinese Academy of Social Sciences)

Summary: Currently, China has entered a moderately aging society, with the level of aging in rural areas consistently exceeding that in urban areas. Family care remains the predominant form of elderly care for rural older adults in China. The way of family caregiving has a significant impact on the well-being of rural older adults. Based on data from the 2022 China Rural Revitalization Survey (CRRS), this paper systematically explores the factors influencing the choice of family caregiving mode among rural older adults. Drawing on 42 feature variables across individual, household, and village dimensions, and after addressing sample imbalance and conducting feature selection, this paper applies a combination of linear and nonlinear machine learning models. The results indicate that nonlinear machine learning models surpass linear models in predictive accuracy, nonlinear machine learning models significantly surpass linear models in predictive accuracy, specifically Random Forest and Gradient Boosting demonstrate the best overall performance. The interpretability analysis using the SHAP (SHapley Additive exPlanations) method reveals that household-level variables account for a significantly larger proportion of influence. The proportion of elderly family members is negatively associated with the predicted probability of choosing care by children, while a larger household size, living with children, and higher household income increase the probability of selecting cared by children. Individual-level characteristics such as employment status, education, and age also exhibit high importance. These conclusions remain robust after a series of robustness checks. Further analysis using Accumulated Local Effects (ALE) plots to explore the predictive patterns of key variables confirms significant nonlinear relationships between family caregiving ways and variables such as the proportion of elderly family members, household size, education, age and household income. Additionally, this paper further explores rural older adults' willingness to pay for social elderly care services. The results indicate that household income and contracted land area are the most important variables, both positively associated with the willingness to pay for social eldercare services.

The marginal contributions of this study are as follows: First, it utilizes the most recent and representative national survey data and innovatively applies advanced machine learning techniques to the field of rural elderly care. It overcomes the limitations of previous research in terms of research perspectives and methodologies, enriching the application of machine learning in social science research. Second, by introducing various machine learning interpretability methods, this paper ranks the importance of explanatory variables and examines nonlinear relationships. This paper clearly presents the extent, direction, and patterns of how key factors influence rural older adults' choices of family caregiving ways. Based on these conclusions, this paper proposes policy recommendations, including establishing differentiated rural family support policies, accelerating the development of a robust social elderly care system, and continuously promoting the rural revitalization strategy to improve the income levels of rural older adults.

Keywords: Rural Elderly; Household Care Methods; Elderly Care Service Purchase; Machine Learning

JEL Classification: R23; C8

（责任编辑：黄慧芬）