

基于神经网络方法的区间删失数据回归分析：应用于 24 h 身体活动模式的死亡风险建模

何灵松¹, 范晓东², 张志方¹

(1. 吉林化工学院 理学院, 吉林 吉林 132022; 2. 深圳第三人民医院 放射科, 广东 深圳 515100)

摘要: **目的** 基于身体活动数据预测每个观测对象的生存概率。**方法** 从美国国家健康与营养调查 (NHANES) 数据库中提取 NHANES 2003—2006 年不同对象的身体活动监测数据。通过综合 Brier 评分、受试者工作特征 (ROC) 曲线及曲线下面积 (AUC) 等多种评价指标来评价模型的预测性能, 比较了条件生存森林、自适应 LASSO、深度学习生存模型等三种生存分析模型的预测性能。**结果** 本研究所建立的深度学习生存模型的预测性能优于其他两个模型。同时, 本研究还分析了各项身体活动变量在深度学习生存模型中的重要性, 其中年龄和总活动计数对人的身体影响最大, 在内部和外部验证中均观察到类似的结果。**结论** 深度神经网络生存模型可以作为预测身体活动对身体影响的有效工具。

关键词: 神经网络; 区间删失; 生存分析; 美国国家健康与营养调查 (NHANES); 身体活动预测; 身体表现
中图分类号: TP183

Regression analysis of interval-censored data based on a neural network approach: application to modelling mortality risk in 24-hour physical activity patterns

HE Lingsong¹, FAN Xiaodong², ZHANG Zhifang¹

(1. School of Science, Jilin Institute of Chemical Technology, Jilin, Jilin 132022, China; 2. Department of Radiology, Shenzhen Third People's Hospital, Shenzhen, Guangdong 515100, China)

Abstract: **[Objective]** To predict the survival probability of each observed object based on physical activity data. **[Methods]** Physical activity monitoring data from National Health and Nutrition Examination Survey (NHANES) 2003 – 2006 were extracted from the NHANES database for different study subjects. The predictive performance of the models was evaluated by combining various evaluation metrics such as Brier score, receiver operating characteristic (ROC) curve and area under the curve (AUC), and the predictive performance of three survival analysis models such as conditional survival forest, adaptive least absolute shrinkage and selection operator (LASSO), and deep learning survival model were compared. **[Results]** The prediction performance of our deep learning survival model is better than the other two models. We also analyzed the importance of each physical activity variable in the deep learning survival model, with age and total activity count having the greatest impact on a person's body. Similar results were observed in both internal and external validation. **[Conclusion]** Deep neural network survival models can be used as an effective tool for predicting the effects of physical activity on the body.

Keywords: neural networks; interval censoring; survival analysis; National Health and Nutrition Examination Survey (NHANES); physical activity prediction; physical performance

身体活动减少是人衰老的一个重要标志。可穿戴技术提供了身体活动的频率、持续时间、强

度和时间的可靠测量。在美国国家健康与营养调查 (NHANES) 数据库中, 提供了加速测量法衍生

的大量身体数据和全因死亡数据。本文使用 NHANES 2003—2006 年的身体活动数据与美国国家死亡率登记数据相结合，因此数据包含了每月的死亡率检查数据。现有的一些论文也利用这些数据进行了生存分析，但都仅从传统 Cox 模型的线性角度进行了分析^[1-2]。因此在模拟临床实践中存在非线性关系时，其预后价值有限。

目前，一些研究表明，机器学习技术（MLT）能够模拟临床特征与生存结果之间的线性和非线性关系，并通过迭代方法提高预测性能。包括条件生存森林（ICcforest）、自适应 LASSO（ALASSO）、神经网络生存模型在内的多模型技术已被成功应用于解决临床分析中复杂的预后判定问题^[3-8]，如对乳腺癌^[3]、软骨肉瘤^[4]、肺结节定性和肺癌^[5]、口腔癌^[6-7]和心上型完全性肺静脉异位引流术后^[8]的预后预测。尽管目前已经有了很多应用于删失数据的机器学习算法，但神经网络生存算法在区间删失数据的应用仍处于起步阶段。

因此，本研究建立了一种深度神经网络生存模型，并将其与两种最常用的统计回归生存分析算法，条件生存森林和自适应 LASSO 回归模型进行比较。此外，还分析了最佳预测模型中所有变量的重要性。

1 资料与方法

1.1 数据来源

研究数据来自于 NHANES 数据库，NHANES 是由美国国家卫生统计中心（NCHS）开展的一个广泛的重大项目，是一项基于人群的横断面调查，旨在收集有关美国家庭人口健康和营养的信息。项目每年调查一个全国代表性的样本。主要目标是长期监测美国人口的生活方式，例如，确定在糖尿病等常见的疾病中危险因素的流行程度。NHANES 数据可从疾病控制中心（CDC，<https://www.cdc.gov/nchs/nhanes/index.htm>）公开获得，NHANES 访谈部分包括人口统计学、社会经济学、饮食和健康相关问题。体检部分包括生理测量、实验室检查等内容。登记的变量包括每个人的表型和环境暴露信息等。一个特定的 NHANES 数据库中的加速度测量身体活动（PA）数据，可以从“Examination Data”标签下的“Physical Activity Monitor”子类别中下载。

1.2 研究对象选择与研究设计

NHANES 2003—2004 年和 2005—2006 年研究的加速度测量数据，共有 14 631 名参与者。在本次研究中，排除了缺失体重指数（BMI）、加速度测量数据少于 3 d 并且估计磨损时间至少 10 h、被 NHANES 认为数据质量不佳、死亡率信息缺失和缺失收缩压、总脂蛋白或高密度脂蛋白（HDL）胆固醇测量值的参与者。在这项工作中，使用年龄在 65~85 岁之间的 1 950 例观测对象的一个子集进行研究。分析的主要目的是通过与条件生存森林和自适应 LASSO 进行比较，评估构建的深度学习生存模型的有效性。为此，将样本按 4 : 1 的比例，随机分割为训练队列和测试队列，并与表 1 中列出的变量进行拟合。表 1 中收集了模型选择的变量。研究结果证明，构建的神经网络生存模型的预测性能明显优于另外两个生存模型，而且相信在有更多的观测数据时，本研究的算法的预测精度可以提高。

1.3 预测变量和结果

将 NHANES 加速度计数器衍生的 PA 数据，与美国国家死亡率登记处和社会人口统计学因素相结合。将年龄、性别、种族、吸烟状况、饮酒状况、BMI（ kg/m^2 ）、行动困难、糖尿病、冠心病、充血性心力衰竭、中风、癌症、收缩压、总胆固醇（ mg/dL ）和高密度脂蛋白胆固醇（ mg/dL ）等列为预测变量。如果观测对象有以下任何一个问题：行走 400 m 困难、爬 10 层楼梯困难或需要使用任何特殊设备才能行走，都将被定义为行动困难。

在 NHANES 活动监测中，使用臀部佩戴的 ActiGraph AM-7164 加速度计数器记录每分钟的活动数据。每个参与者都被要求在 NHANES 检查后连续 7 d 佩戴该设备，并在睡觉时和与水相关的活动中取下它。

由于分钟级加速度计数器衍生的 PA 数据很大，目前的做法是采取汇总措施。基于活动记录仪常用的 PA 汇总数据包括：总活动计数（TAC）、总对数活动计数（TLAC）和中高强度身体活动（MVPA），其中 MVPA 定义为每分钟超过 2 020 次的活动。为了反映日常 PA 模式的全部复杂性。笔者也考虑了每 2 小时的总对数活动汇总变量（TLAC 12 am~2 am，TLAC 2 am~4 am，...，TLAC

10 pm~12 am), 其中每个变量均为 TLAC, 但是在相应的时间间隔内计算。笔者还使用了两种活动碎片化的测量方法: 从久坐到活动的过渡概率 (SATPsl/nw) 和从活动到久坐的过渡概率 (ASTPsl/nw)。久坐定义为超过 2 h 没有活动。从 NHANES 数据相关联的每月死亡率检查中得到每个观测对象的生存结果。

1.4 统计机器学习模型

①LASSO 的特点是可以使部分特征的模型系数完全为 0, 从而达到增加模型的稀疏性和筛选重要特征变量的目的^[8]。能够较好的解决回归分析中的多重共线性问题, 并且能够很好的解释结果。②用于生存的随机森林 (RF) 是一种集合算法, 条件生存森林通过训练大量生存树, 以表决的形式, 从个体树之中加权选举出最终的预测结果^[9]。③人工神经网络 (ANN), 这是一种模拟人脑组织结构进行分布并行信息处理的算法模型^[10]。该算法模型具有高度的自适应性, 可以用来解决生存概率和协变量之间的非线性关系和协变量之间的交互作用等问题。

1.5 数据处理与模型验证

提取到符合条件的 1 950 个观测数据后, 将所有观测数据按 8 : 2 的比例随机分配到训练队列和测试队列中, 训练集包含 1 560 个观测数据, 测试集包括 390 个观测数据。此外, 从训练队列中随机抽取 10% 的患者组成验证队列, 通过与测试队列的比较来验证模型。

1.6 模型实现与参数选择

针对基于比例风险 (PH) 假设的自适 LASSO 模型 (ALASSO), 使用 R 包 “ALassoSurvIC”, “ALassoSurvIC” 为具有区间删失和左截删失数据的 Cox 比例危险模型, 提供了惩罚性变量选择工具。主函数 alacoxIC 通过带有自适应套索惩罚的惩罚性非参数极大似然估计 (PNPML) 执行变量选择。该函数还通过贝叶斯信息准则 (BIC) 最小化自动找到最佳阈值参数。对于 ICcforest 使用 R 包 “ICcforest”, “ICcforest” 为区间删失生存数据构建条件推断森林模型, 它提供了两种寻找 m_{try} (在每次分裂中随机选择的预测因子的数量) 的方法。一是基于包外误差估计, 另一种方法是设置 $m_{try}=\sqrt{p}$ 。通过对比发现, 后一种方法在模拟数据和真实数据中都具有更好的预测性能。因此, 使

用 $m_{try}=\sqrt{p}$ 。对于神经网络生存模型, 使用协变量输入的神经网络与一种由伯恩斯坦多项式构造的新型神经网络 (BNNet) 结合的多神经网络方法^[11], 对于协变量输入的神经网络, 超参数包括隐层数、每个隐层的节点数、激活函数的选择、 L_1 惩罚参数、批大小、迭代次数和学习率。对于 BNets, 超参数是伯恩斯坦多项式的度。神经网络模型涉及到超参数的选择。对于使用协变量输入的神经网络, 使用以下超参数: 2 个隐藏层, 每个隐藏层 30 个神经元, 激活函数使用缩放指数线性单位 (SELU), L_1 惩罚 $l_1=0.5$, 批大小 $N=100$, 进行 1 000 次迭代, 学习率设置为 0.002, 对于伯恩斯坦多项式构造的神经网络, 使用的超参数: 伯恩斯坦多项式度 $m_n=3$ 。

1.7 模型评估

为了评估模型的预测性能, 选择了适用于有删失数据的综合 brier 评分 (IBS)、预测中位生存时间在 (L_i, R_i) 之外的概率 (P_{out}) 和预测中值时间低于 L_i 或高于 R_i 的绝对距离 (d_{out}), 作为主要评估指标, 采用 10 折交叉验证模式, 并报告了所有 10 折中每个指标的平均值。10 折交叉验证的优点是, 所有观测数据都用于训练和验证。为了进一步评估模型, 还绘制了随时间变化的受试者工作特征 (ROC) 曲线, 并计算了曲线下面积 (AUC) 和准确率作为评估指标^[12-14]。随后, 为了解释神经网络生存模型的预测, 使用神经网络生存模型, 为 NHANES 数据中每个观测者的预测因子重要性进行度量。数据分析使用了 R 语言 (4.2.2 版) 和 Python (3.7 版)。神经网络模型通过 Tensorflow 和 Keras 构建。

2 结果

确定 1 950 例符合条件的观测数据, 随机将其中 390 例分配到测试队列, 剩下的 1 560 例作为训练队列数据。在训练队列数据中, 随机抽取 156 例观测数据作为验证队列数据, 使用剩下的 1 404 例作为训练队列数据。

2.1 基线特征

在表 1 中总结了符合条件的观测对象的人口统计、临床特征以及身体活动监测数据。对于连续变量, 采以均数 \pm 标准差 ($\bar{x} \pm s$) 进行数据表示。对于二元变量或分类变量, 使用每个类别中

的研究参与者的数量，和该类别在所有参与者中占百分比 $[n(\%)]$ 进行数据表示。截止到 2019 年，对于 NHANES 2003—2006 年的研究对象的全因死亡率为结果，通过单预测逻辑回归中的 ROC 曲线

测量，变量按预测性能递减排序。TAC 是排名最高的死亡率预测因子 (AUC=0.722)，而年龄紧随其后 (AUC=0.717)。

表 1 2003—2006 年美国国家健康和营养调查合并队列研究参与加速度测量人员的人口统计学和临床特征

变量	NHANES 编码	变量描述	变量类型	$(\bar{x} \pm s)/[n(\%)]$
X1	TAC	总活动数	连续变量	155 578.5(94 233.9)
X2	RIDAGEMN	参与监测时的年龄	连续变量	74.7(6.55)
X3	MVPA	中高度剧烈身体活动	连续变量	8.04(12.5)
X4	ASTPs/nw	从活动到久坐的转变概率	连续变量	0.081(0.052)
X5	ST	久坐时间	连续变量	894.64(133.96)
X6	TLAC 12~2 pm	总对数活动数 12 pm~2 pm	连续变量	353.56(118.81)
X7	TLAC 4~6 pm	总对数活动数 4 pm~6 pm	连续变量	326.28(115.17)
X8	TLAC 2~4 pm	总对数活动数 2 pm~4 pm	连续变量	338.73(119.06)
X9	TLAC 6~8 pm	总对数活动数 6 pm~8 pm	连续变量	268.06(112.36)
X10	TLAC 10 am~12 pm	总对数活动数 10 am~12 am	连续变量	362.97(129.89)
X11	Mobility problem		0:No 1:Yes	1 104(0.56) 856(0.44)
X12	DrinksPerWeek		连续变量	1.86(5.03)
X13	SATPs/nw	从久坐到活动的转变概率	连续变量	0.095(0.032)
X14	TLAC 8~10 am	总对数活动数 8 am~10 am	连续变量	305.04(147.99)
X15	TLAC 8~10 pm	总对数活动数 8 pm~10 pm	连续变量	171.73(108.17)
X16	DrinkStatus		0:不饮酒 1:中度 2:重度	1011(0.52) 814(0.42) 74(0.04)
X17	TLAC 6~8 am	总对数活动数 6 am~8 am	连续变量	133.28(129.85)
X18	Smoking status		0:从不 1:以前 2:现在	883(0.45) 876(0.45) 199(0.1)
X19	CHF	充血性心力衰竭	0: No 1: Yes	1 761(0.90) 179(0.09)
X20	Gender		0: 男性 1: 女性	1 017(0.52) 943(0.48)
X21	Diabetes		0: No 1: Yes	1 528(0.78) 382(0.20)
X22	Cancer		0: No 1: Yes	1 516(0.77) 441(0.23)
X23	BMI		连续变量	27.68(6.26)
X24	CHD	冠心病	0: No 1: Yes	1 706(0.87) 230(0.12)
X25	Stroke		0: No 1: Yes	1 700(0.9) 183(0.1)
X26	Race		0:MexicanAmerican 1:Other Hispanic 2:White 3:Black	327(0.1668) 37(0.0289) 1 257(0.6413) 292(0.1490)
X27	TLAC 12~2 am	总对数活动数 12 am~2 am	连续变量	17.52(41.59)
X28	TLAC 10 pm~12 am	总对数活动数 10 pm~12 am	连续变量	69.22(80.86)
X29	TLAC 4~6 am	总对数活动数 4 am~6 am	连续变量	23.98(58.08)
X30	TLAC 2~4 am	总对数活动数 2 am~4 am	连续变量	10.43(32.73)
X31	WT	磨损时间	连续变量	288.99(109.9206)

2.2 模型预测表现

模型的预测性能见表 2。总的来说，在综合考虑各种指标后，建立的神经网络生存模型的预测性能优于条件生存森林和自适应 LASSO 方法。

2.2.1 主要结果 (Brier 评分) 使用多种评价指标来评估区间删失条件下的三种模型的预测性能。对于真实的数据分析，使用集成的 Brier 评分 (IBS) [15] 为主要的评估标准，IBS 表示为：

$$IBS(\hat{S}) = \frac{1}{n} \sum_{i=1}^n \frac{1}{u} \int_0^u \{I(T_i > t|Z_i) - \hat{S}(t|Z_i)\}^2 dt$$

其中 \hat{S} 是模型预测的生存概率， u 是所有观测到的有限的 (L_i, R_i) 中的最大值，对于 $I(T_i > t|Z_i)$ ，当 $t \leq L_i$ 时， $I(T_i > t|Z_i) = 1$ 。当 $t \geq R_i$ 时， $I(T_i > t|Z_i) = 0$ 。当 $L_i < t < R_i$ 时， $I(T_i > t|Z_i) = (S(t|Z_i) - S(R_i|Z_i)) / (S(L_i|Z_i) - S(R_i|Z_i))$ ，若 $L_i = 0$ ，则 $I(T_i > t|Z_i) = (S(t|Z_i) - S(R_i|Z_i)) / (1 - S(R_i|Z_i))$ 。若 $R_i = \infty$ ，则 $I(T_i > t|Z_i) = S(t|Z_i) / S(L_i|Z_i)$ 。本研究对比了神经网络模型，条件生存森林和自适应 LASSO 三种方法在身体活动预测中的预测性能，除 Brier 评分外，还考虑另外两个评估指标：预测中位生存时间在 (L_i, R_i) 之外的概率（表示为 P_{out} ），当预测中值时间超出 (L_i, R_i) 时，预测中值时间低于 L_i 或高于 R_i 的绝对距离（表示为 d_{out} ）。这些评价指标越小，说明预测性能越好。三种方法预测表现 IBS、 P_{out} 和 d_{out} 见表 2。

表 2 三种模型预测表现

模型	IBS	P_{out}	d_{out}
NN-IC	0.152	0.895	4.5
ICcforest	0.209	0.898	4.5
ALASSO	0.243	0.896	5.3

从表 2 中，可以看出构建的神经网络模型和 ICcforest 方法，在 d_{out} 上的预测表现明显优于 ALASSO 方法。虽然神经网络方法在 P_{out} 上的预测表现和另外两种方法相似，但神经网络方法在 Brier 评分上的预测表现明显优于另外两种方法。

2.2.2 次要结果 (ROC 曲线和 AUC) 本研究分别计算了训练队列和测试队列数据中 ICcforest 和神经网络模型的 ROC 曲线和 AUC [18]，ICcforest 在训练队列下的 ROC 曲线见图 1，ICcforest 在测试队列下的 ROC 曲线见图 2，深度

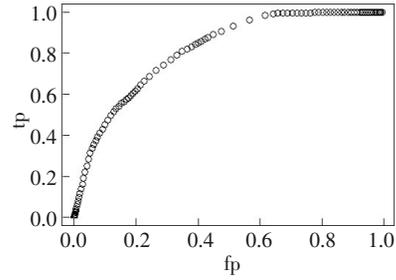


图 1 ICcforest 在训练队列下的 ROC 曲线

神经网络模型在训练队列下的 ROC 曲线见图 3，神经网络模型在测试队列下的 ROC 曲线见图 4。两个模型在训练集和测试集中的 AUC 值如下，ICcforest (0.807, 0.769) 和神经网络模型 (0.804, 0.806)。通过对比发现神经网络模型的 AUC 值一般与 ICcforest 模型相似或高于 ICcforest。此外，神经网络模型在其他评价指标方面比 ICcforest 具有优势。

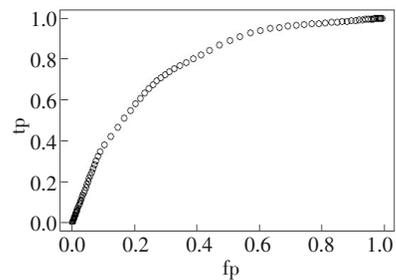


图 2 ICcforest 在测试队列下的 ROC 曲线

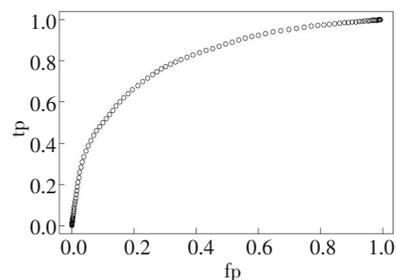


图 3 神经网络模型在训练队列下的 ROC 曲线

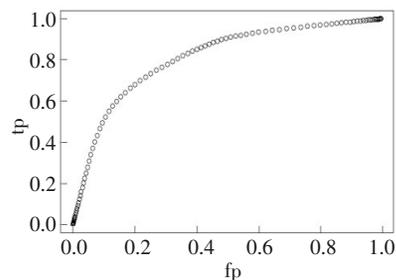


图 4 神经网络模型在测试队列下的 ROC 曲线

2.2.3 神经网络的预测解释 对神经网络的预测进行解释是至关重要的。采用 LIME (local

interpretable model-agnostic explanations) 方法^[16], 该方法计算每个受试者中每个预测因子的预测重要性水平。为了解释神经网络生存模型的预测, 使用神经网络生存模型为 NHANES 数据中每个观测者的预测因子重要性进行度量。图 5 显示了对

于每个观测对象的前 10 个重要的预测因子(通过不同的垂直色带进行可视化), 其中每一行代表一个预测因子, 每个垂直列代表一个观测对象。其中一些是有负重要性的(红色)或正重要性的(蓝色)。

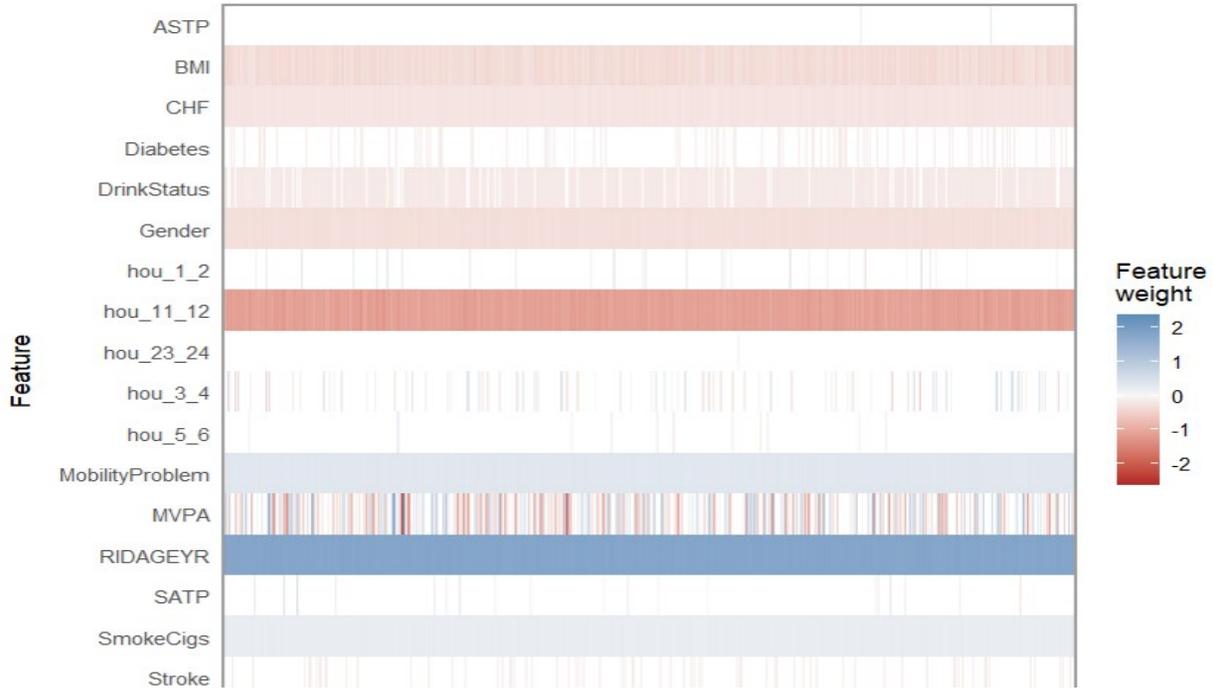


图 5 使用 LIME 方法表示在数据 2 的外部集中的顶级预测因子的个性化重要性度量

3 讨论

研究比较了自己构建的神经网络方法与 ICcForest 和 ALASSO 两种机器学习模型, 对区间删失生存数据的预测价值。通过对 NHANES 数据库中的 2003—2004 和 2005—2006 四年的 1 950 个观测对象的生存率进行预测, 对比多个不同的评价指标, 证明了神经网络生存模型在身体活动对生存率的影响的预测中性能最优, 并且在内部和外部验证中观察到了一致的结果。

本文的主要贡献是使用了一种新的神经方法, 用于区间删失数据分析, 和 Cox 模型简单的假设协变量和生存概率之间的关系是线性的不同, 笔者不假设任何函数形式的 Cox 模型参数分量, 同时选择最相关的特征。据研究者所知, 随着新的随机森林模型的发展, 研究人员克服了传统 Cox 模型和加速失效风险模型的许多局限性^[17-18], 以对抗生存时间和协变量之间的强烈非线性功能依赖关系。然而, 正如在 NHANES 数据中所看到的,

条件生存森林和自适应 LASSO 方法的性能均比构建的神经网络方法要弱。重要的是, 构造的特殊神经网络结构, 可以更好地捕捉生物标记物的表达。

研究者目前的方法已经可以很容易地根据协变量的影响和相互作用来解释了。其中一个关键的挑战是提供一种衡量新预测的不确定性的度量, 特别是在医学科学应用中, 因为患者进化的相当大的内在不确定性。在这个方向上, 由于本研究模型中存在似然方程, 因此可以使用共形推理思想的扩展来解决这些科学挑战。最后, 另一个主要的研究方向是确定每个被选择的变量的重要性。

参考文献

- [1] MCGREGOR DE, PALAREA-ALBALADEJO J, DALL PM, et al. Cox regression survival analysis with compositional covariates: application to modelling mortality risk from 24-h physical activity patterns[J]. Stat Methods Med Res, 2020, 29(5): 1447-1465.
- [2] SMIRNOVA E, LEROUX A, CAO Q, et al. The predictive performance of objective measures of physical activity derived from

- accelerometry data for 5-year all-cause mortality in older adults: national health and nutritional examination survey 2003 - 2006[J]. *J Gerontol Ser A*, 2020, 75(9): 1779-1785.
- [3] 田朝霞, 李红梅, 杨佳, 等. 基于随机森林模型的乳腺癌术后病人复发恐惧影响因素研究[J]. *护理研究*, 2023, 37(22): 3997-4002.
- [4] 林跃玮, 黄永明, 李文乐, 等. 机器学习和传统列线图预测软组织肉瘤肺转移风险的预测模型的建立与评估[J]. *中国骨与关节杂志*, 2022, 11(1): 19-26.
- [5] 吴静. 基于 18F-FDG PET/CT 的机器学习对肺结节定性和肺癌预后预测的研究[D]. 长沙: 中南大学, 2022.
- [6] RAGHAVAN A, SANDRA S, MADAN KUMAR PD. Application of artificial intelligence in the diagnosis and survival prediction of patients with oral cancer: a systematic review[J]. *J Oral Res Rev*, 2022, 14(2): 154.
- [7] ADEOYE J, HUI L, KOOHI-MOGHADAM M, et al. Comparison of time-to-event machine learning models in predicting oral cavity cancer prognosis[J]. *Int J Med Inform*, 2022, 157: 104635.
- [8] 刘晓冰, 刘付蓉, 陈泽宇, 等. Informed LASSO 机器学习方法在心上型完全性肺静脉异位引流术后生存分析中的应用[J]. *中国胸心血管外科临床杂志*, 2022, 29(7): 848-853.
- [9] ISHWARAN H, KOGALUR UB, BLACKSTONE EH, et al. Random survival forests[J]. *Ann Appl Stat*, 2008, 2(3): 841 - 860.
- [10] 张安定. 遥感原理与应用题解[M]. 北京: 科学出版社, 2016.
- [11] SUN T, DING Y. Neural network on interval-censored data with application to the prediction of Alzheimer's disease[J]. *Biometrics*, 2023, 79(3): 2677-2690.
- [12] STEYERBERG EW, VICKERS AJ, COOK NR, et al. Assessing the performance of prediction models: a framework for traditional and novel measures[J]. *Epidemiology*, 2010, 21(1): 128-138.
- [13] KAMARUDIN AN, COX T, KOLAMUNNAGE-DONA R. Time-dependent ROC curve analysis in medical research: current methods and applications[J]. *BMC Med Res Methodol*, 2017, 17(1): 53.
- [14] 柴婕, 刘香丽, 刘瑞东, 等. logistic 回归结合 ROC 曲线在乳腺癌中的诊断价值[J]. *河南医学高等专科学校学报*, 2023, 35(5): 485-489.
- [15] SOFIA T, HEIN P, MARTA F. Measures of discrimination and predictive accuracy for interval censored survival data [D]. Netherland: Leiden University, 2015.
- [16] 黄艺龙, 秦小林, 陈芋文, 等. 利用 LIME 对脓毒症预测模型进行可解释性分析[J]. *计算机应用*, 2021, 41(S1): 332-335.
- [17] CHO H, JEWELL NP, KOSOROK MR. Interval censored recursive forests[J]. *J Comput Graph Stat*, 2022, 31(2): 390-402.
- [18] 吴辰文, 梁靖涵, 王伟, 等. 基于递归特征消除方法的随机森林算法[J]. *统计与决策*, 2017(21): 60-63.

(方丽蓉 编辑)