

机器学习在骨质疏松风险评估中的透明度研究：ML 与可解释性分析的比较研究

Farhana Elias

Dept. of ECE

North South University

Dhaka-1229, Bangladesh

farhana.elias@northsouth.edu

Md Shihab Reza

Dept. of ECE

North South University

Dhaka-1229, Bangladesh

shihab.reza@northsouth.edu

Muhammad Zawad Mahmud

Dept. of ECE

North South University

Dhaka-1229, Bangladesh

zawad.mahmud1@northsouth.edu

Samiha Islam

Dept. of ECE

North South University

Dhaka-1229, Bangladesh

samiha.islam2@northsouth.edu

摘要—本研究解决了通过机器学习 (ML) 方法预测骨质疏松症风险的难题，强调使用可解释的人工智能 (XAI) 来提高模型透明度。骨质疏松症是一个重要的公共卫生问题，有时由于其无症状的特点而未被治疗，早期识别对于预防骨折至关重要。该研究评估了六种机器学习分类器——随机森林、逻辑回归、XGBoost、AdaBoost、LightGBM 和梯度提升——使用基于临床、人口统计和生活方式变量的数据集。模型通过 GridSearchCV 调整超参数进行优化，目标是提高预测效果。在评估的模型中，XGBoost 准确率最高 (91%)，在精度 (0.92)、召回率 (0.91) 和 F1 分数 (0.90) 方面也超过了其他模型。研究进一步整合了 SHAP、LIME 和排列特征重要性等 XAI 方法，以阐明最优模型的决策过程。研究表明，在预测骨质疏松症风险时，年龄是主要决定因素，其次是激素变化和家族史。这些结果证实了临床知识，并证明了模型在治疗方面的意义。该研究强调了机器学习模型在医疗应用中的可解释性的重要性，确保医生可以依赖系统的预测。报告最终提出了进一步研究的方向，如跨不同人群的验证以及整合额外生物标志物以提高预测准确性。

Index Terms—机器学习，骨质疏松症，可解释的人工智能，SHAP，排列特征重要性。

I. 介绍

骨质疏松症 (OP) 是一种常见的疾病，由于全身性骨骼质量和微结构的减少而导致骨折。骨重塑是一个终身过程，涉及骨骼吸收和形成之间的连续循环。全球每三个 50 岁以上的女性中就有一个，每五个同年龄

段的男性中就有一个受到骨质疏松症的影响 [13]。全球 50 岁以上的人口共有 1.58 亿人面临较高的骨质疏松性骨折风险，并且由于人口老龄化，预计到 2045 年这种骨折的风险将翻倍 [1]。最近的研究表明，大约 37.3% 的孟加拉国成年人受到骨质疏松症的影响，另有 43.5% 的人患有骨量减少症 [2]。由于成本高昂和可用性有限，在农村和资源匮乏地区仍然缺乏双能 X 射线吸收测定法 (DXA) 的传统诊断方法。这种情况需要新的可扩展方法来进行早期检测和风险分层。机器学习 (ML) 是一个有前途的解决方案，因为它使用临床数据、人口统计信息以及生活方式模式来做出准确的骨质疏松症风险预测。机器学习模型在预测患有骨质疏松症患者的骨折风险方面显示出良好的结果。许多机器学习算法的“black-box”本质对临床应用提出了挑战，因为医疗保健专业人员需要透明度以信任并根据模型预测采取行动。这就是可解释的人工智能 (XAI) 变得至关重要的地方。通过阐明预测背后的理由，XAI 增强了可解释性，使临床医生能够理解和验证影响个体风险评估的因素。这种透明度对于有依据的决策和患者教育至关重要。本研究的动机是设计和评估多个机器学习分类器，并通过 XAI 揭示模型决策过程中具有影响力的特征。这项研究的主要贡献如下：

- 几种机器学习分类器的比较，如 RandomForest、Logistic Regression、XGBoost、AdaBoost、LightGBM 和 Gradient Boosting，并使用 GridSearchCV 来调优应用模型的最佳超参数。
- 将最具有可解释性的 AI 技术（SHAP、LIME 和排列特征重要性）应用于理解模型的工作原理以及特征在决策中的作用。

将机器学习与可解释人工智能整合到骨质疏松风险评估系统中，将在孟加拉国转变早期检测策略。这些系统可以实现针对性干预，优化资源配置，并最终减少骨质疏松性骨折的发生率。该国高患病率和低诊断率使得部署基于机器学习和可解释人工智能的工具在公共卫生领域既及时又必要。

II. 相关工作

若干研究人员对骨关节炎预测和风险评估进行了大量机器学习研究。

德弗里斯等人。[3] 开发了四个机器学习模型来预测未来主要骨质疏松性骨折 (MOF) 的概率。在研究 [4] 中，收集了个体的个人、生活方式和临床数据，并使用支持向量机 (SVM) 和树增强朴素贝叶斯 (TAN) 分类器挖掘模式并预测疾病状态。在研究 [5] 中，研究人员旨在识别绝经后妇女股骨颈骨质疏松症的风险，开发了一个机器学习模型，并将其与传统的临床决策工具——骨质疏松自我评估工具 (OST) 进行了比较。马赫穆德等人。[6] 展示了特征选择技术，如 Lasso L1，如何提高预测系统中的模型准确性和可扩展性。泽特林等人。[7] 开发了一个机器学习模型，用于通过使用临床、实验室和成像数据来预测与绝经相关的骨质疏松症的十年风险，研究结果表明，十年骨质疏松症预测模型显示了强大的区分能力 ($AUC = 0.83$, $Brier = 0.054$)，脊柱和髌部骨密度加上年龄是最重要的预测因素，风险分层阈值产生的敏感性为 81%，特异性为 82%，以及低、中、高风险的似然比分别为 0.23、3.2 和 6.8。研究 [8] 提出了一种基于生物标志物使用机器学习和仿真工具进行骨质疏松症早期检测的新方法。雷扎等人。[9] 展示了 LDA 作为特征减少技术如何有助于减轻预测系统中模型复杂性的负担。Shim 等人。[10] 通过使用来自 1,792 名绝经后韩国女性的 KNHANES V-1 和 V-2 数据，构建了七个 ML 模型，并发现 ANN 模型在骨质疏松症风险预测中达到了最高的 AUROC (0.743)。S. K. Kim

等 [10] 使用 KNHANES-V1 数据开发并验证了 ML 模型 (SVM、RF、ANN、LR)，以预测绝经后韩国女性的骨质疏松症风险。

高级 DL 和 XAI 技术也可以用于预测骨质疏松症或其风险评估。邱等人。[11] 研究了 DNN 是否能在骨质疏松症风险预测中实现更好的性能，他们的研究表明使用 16 个常规临床和人口统计数据的深度神经网络达到了最高的骨质疏松症风险预测性能。马赫穆德等人。[12] 还展示了迁移学习方法在疾病预测系统中的有效性。在研究 [13] 中，研究人员通过前向特征选择和自定义多级集成堆栈开发了一个 ML 管道，实现了 89% 的预测准确率，并使用 SHAP、LIME、ELI5 和 Qlattice 来解释模型。

III. 方法论

本节概述了研究中采用的方法论。图 1 说明了相应的流程图，总结了研究过程的关键阶段。

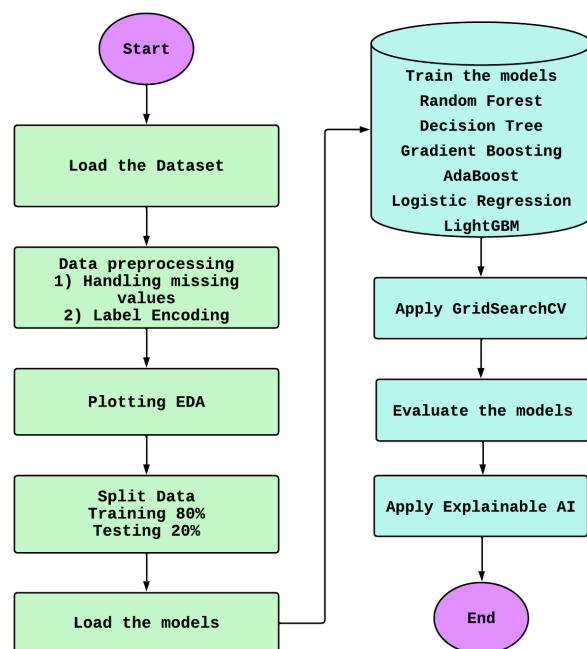


图 1. 系统的工作流程

A. 数据集

该论文名为 ‘Osteoporosis Risk Prediction’ 的数据是从 Kaggle [14] 获得的。它包含 1,958 条记录，详细描述了与骨质疏松症风险评估相关的各种健康和生活方式特征。关键特性包括人口统计细节（年龄、性别、种

族/民族)、生活习惯(体育活动、吸烟、酒精摄入量)、饮食摄入(钙、维生素D)以及医疗历史(激素变化、家族骨质疏松病史)。我们将数据集分为两部分:训练集占80%,测试集占20%,以尝试不同的机器学习模型。

B. 探索性数据分析 (EDA)

进行了若干探索性分析,以评估生活方式/医疗变量与骨质疏松症诊断之间的关系。数据揭示了大多数变量中没有明显的不平衡,表明该数据集中存在弱或非线性关联。例如,荷尔蒙变化(如:498例非骨质疏松症 vs. 483例无荷尔蒙变化的骨质疏松症)和家族史(498例 vs. 500例无家族史的情况)显示出接近均等的比例,暗示了直接预测能力较弱。同样地,种族/民族和医疗状况类别在骨质疏松症结果上显示出了均匀分布,没有一个子组超过344例。体重展示出极小的模式,即体重大于0的人群中,较低体重者(0)显示出轻微升高的骨质疏松症率(531例非骨质疏松症 vs. 496例骨质疏松症),相比高体重人群(1)。营养因素包括钙摄入量(475例 vs. 479例低摄入的骨质疏松症病例)和维生素D摄入量(482例 vs. 465例低摄入病例)显示出极小的变化,但维生素D摄入超过阈值导致了轻微升高的骨质疏松症诊断率(497例 vs. 514例)。生活习惯的分布包括体力活动(520例 vs. 501例低活动水平的骨质疏松症病例)、吸烟(480例 vs. 496例非吸烟者的骨质疏松症)和饮酒(484例 vs. 486例不饮酒者中有骨质疏松症),显示出了均衡分布。先前骨折和药物使用的分布遵循与其他变量相同的模式,因为骨质疏松症病例在各类别之间的计数少于20次。结果表明存在细微的模式(例如:药物使用显示出从509例到476例间轻微降低的骨质疏松症风险)。图2显示了数据集变量的相关矩阵,强调特征间的相互依赖性。

C. 应用的模型和评估

在这项研究中,我们应用了6种不同的机器学习分类器:随机森林、逻辑回归、XGBoost、AdaBoost、LightGBM和梯度提升,并采用了一个集成5折交叉验证的网格搜索超参数调优框架以提高性能。随机森林是一种由Breiman等人引入的集成学习方法。[15]. 逻辑回归[16]是一种监督机器学习算法,用于二分类任务,基于一个或多个预测变量建模二元结果的概率。XGBoost(极端梯度提升)是由Chen等人开发的一种可扩展的树提升机器学习系统。[17]. AdaBoost(自适




图 2. 相关矩阵

应提升)[18]通过增加先前分类错误样本的权重顺序训练弱分类器(通常是决策树桩),以便新的学习者集中处理最困难的情况。LightGBM(轻量级梯度提升机)[19]是一个开源且高效的梯度提升框架。梯度提升[20]通过拟合每个新的弱学习者到指定损失函数相对于当前模型预测的负梯度(残差)来构建集成。对于结果评估,我们使用了五种最先进的骨质疏松症风险评分指标:准确率、精确率、召回率和F1分数。用于评估模型的指标如下所示[21], [22]:

$$\text{Precision}_x = \frac{TP_x}{TP_x + FP_x} \quad (1)$$

$$\text{Recall}_x = \frac{TP_x}{TP_x + FN_x} \quad (2)$$

$$F1 - score_x = 2 \times \frac{\text{Precision}_x \times \text{Recall}_x}{\text{Precision}_x + \text{Recall}_x} \quad (3)$$

$$\text{Accuracy}_x = \frac{TP_x + TN_x}{TP_x + TN_x + FP_x + FN_x} \quad (4)$$

D. 模型的可解释性

几种可解释人工智能(XAI)技术,如SHAP、LIME、Morris敏感性分析和排列特征重要性(PFI),用于理解模型的工作原理以及特征在决策中的作用。SHAP(Shapley加法解释)是Lundberg等人[23]提出的解释模型预测的统一框架。Ribeiro等人[24]的局部

可解释的模型不可知解释 (LIME) 是一种 XAI 方法，用于生成复杂机器学习模型的人类可理解且特定实例的解释。排列特征重要性 (PFI) [25] 是一种全局可解释人工智能 (XAI) 技术，用于确定模型的重要性。将这些 XAI 技术集成不仅揭示了最具影响力的特征，还确保了模型决策过程的透明度，从而使模型更加可靠和值得信赖。

IV. 结果分析与讨论

在本节中，我们评估并比较了本研究中实现的所有机器学习模型的性能。部署了可解释的人工智能工具以了解最佳表现模型，并对特征重要性进行了全面理解。

A. 用于骨质疏松风险预测的机器学习模型

表 I 概括了六种机器学习模型在骨质疏松症风险预测上的优化性能。XGBoost 达到了最高的准确率，为 91.0%，超越了所有其他方法；它在精确度 (0.92)、召回率 (0.91) 和 F1 分数 (0.90) 上也领先，表明其整体分类能力强且敏感性/特异性平衡。LightGBM 紧随其后，准确率为 90.05%，精确度-召回率对为 0.91/0.90，展示了其基于叶子的生长和采样优化方法在此表格健康数据集上几乎达到了最先进的结果。AdaBoost 和 Gradient Boosting 的准确率相当 (89.0%)，AdaBoost 在 F1 分数 (0.88 对比 0.89) 和召回率上有轻微优势，表明在类别不平衡的情况下自适应调整困难样本的权重仍然非常有效。随机森林和逻辑回归虽然较为简单，但分别仍达到了可接受的准确率 84.0% 和 83.67%，这证实了它们作为基线方法的价值，但也突显了提升树捕捉复杂特征交互的优势。

表 I
性能指标比较

模型	准确率 (%)	精度	回忆	F1 分数
Random Forest (RF)	84.00	0.88	0.84	0.84
Logistic Regression (LR)	83.67	0.88	0.84	0.83
XGBoost(XGB)	91.0	0.92	0.91	0.90
AdaBoost (AB)	89.00	0.90	0.89	0.88
LightGBM (LGBM)	90.05	0.91	0.90	0.90
Gradient Boosting (GB)	89.0	0.89	0.89	0.89

应用的机器学习模型的最佳超参数显示在表 II 中。这些调整后的超参数表明，适度的学习率、正则化和受控树复杂度是最大化骨质疏松症风险数据预测性能的关键。提升方法的优越性能凸显了它们对建模人口统计学、临床和生活方式因素之间复杂非线性关系的能

力。图 3 显示了混淆矩阵，图 4 显示了 XGBoost 模型的 ROC 曲线。

表 II
不同模型的最佳超参数

模型	最佳超参数
RF	'criterion': 'gini', 'max_depth': 4, 'max_features': 'sqrt', 'n_estimators': 100
LR	'C': 0.01, 'penalty': 'l1', 'solver': 'liblinear'
XGB	'max_depth': 3, 'reg_lambda': 0, 'min_child_weight': 1, 'reg_alpha': 1.
AB	'algorithm': 'SAMME', 'learning_rate': 1, 'n_estimators': 50.
LGBM	'learning_rate': 0.1, 'max_depth': 10, 'colsample_bytree': 0.8, 'n_estimators': 100.
GB	'learning_rate': 0.1, 'max_depth': 8, 'n_estimators': 500, 'subsample': 1.




图 3. XGBoost 模型的混淆矩阵。




图 4. XGBoost 模型的 ROC 曲线。

B. 可解释的人工智能 (XAI) 用于解释 XGBoost 分类器的预测结果

在本节中，我们评估并比较了 XGBoost 分类器的影响特征。名为 SHAP、LIME 和置换重要性可解释 AI 工具被部署到最佳性能模型上，并全面理解特征重要性。图 5 和 6 显示了 XGBoost 模型的 SHAP 摘要图和 SHAP 水位图。




图 5. XGBoost 模型的 SHAP 总结图




图 6. SHAP 水 fall 图表用于 XGBoost 模型

SHAP 总结图通过平均绝对 SHAP 值显示特征重要性，这些值展示了每个变量对模型输出与基线预测偏差的平均影响。年龄是最具影响力的预测因子，因为其平均 SHAP 值显著高于其他所有特征。医学领域支持这一观察结果，因为骨密度会随着年龄的增长而自然下降。模型输出受到医疗状况、药物使用、激素变

化、种族/族裔和身体活动的第二大影响力。其余变量包括吸烟、钙摄入量、先前骨折史、家族病史、酒精消耗量、体重、性别和维生素 D 摄入量，对模型输出的影响较小。为了分析这些特征如何结合生成一个个体预测值 7.526 (基线 = 1.472)，我们查看了 SHAP 水落图。在这里，年龄再次占据主导地位，为最终风险评分贡献 +5.03。种族/族裔 (+0.28)、身体活动 (+0.22)、钙摄入量 (+0.16)、药物使用 (+0.13) 和吸烟 (+0.12) 产生了更微妙的正面影响。值得注意的是，激素变化减少了 -0.09 的预测风险，表明在这种情况下可能存在一种潜在的保护作用。较小的向上变动来自于医疗状况 (+0.07)、家族病史 (+0.06) 以及来自其他五个特征的 +0.08 综合提升。

第 0 个测试实例从 XGBoost 模型接收到一个 LIME 解释，该模型以 94% 的准确率预测“*No Osteoporosis*”，如图 7 所示。预测强烈指向“*No Osteoporosis*”的原因是三个主要因素：较年轻的年龄 (-0.81 影响)、男性性别和充足的钙及维生素 D 摄入量。其他因素包括医疗状况、先前的骨折、吸烟史、家族病史、饮酒情况、种族/民族背景、激素变化和体力活动均无显著影响。

图 8 中呈现的 LIME 解释显示 XGBoost 模型以 100% 的绝对信心将第 100 个测试实例预测为“*Osteoporosis*”。患者年龄（在标准化尺度上的值为 0.02）是主要的风险因素，因为它存在于较高的风险范围内，并产生了最大的正向偏移 (+0.34)，朝向“*Osteoporosis*”。患者的荷尔蒙变化（值为 1）对疾病的发展略有贡献，而其他特征包括种族/族裔、先前的骨折和钙与维生素 D 的摄入量以及药物使用和医疗条件、饮酒情况、性别、体重和吸烟习惯则影响甚微或没有影响。这些因素的组合展示了为什么该模型预测此患者患有骨质疏松症。




图 7. 使用模型 XGBoost 对随机选择的测试集样本进行 LIME 特征重要性解释。

排列重要性图（对数刻度）在图 9 中显示，年龄是影响骨质疏松风险的最重要预测因素；其重要性比任何其他特征高几个数量级。接下来最重要的因素是激素变



图 8. 使用模型 XGBoost 对不同随机选择的测试集样本进行 LIME 特征重要性解释。

化和家族史，这两个因素贡献显著但仍然远低于年龄的影响。体育活动、种族/民族以及既往骨折具有中等程度的重要性。体重和维生素 D 摄入量影响较小。药物使用、酒精消费、性别、钙摄入量、吸烟及医疗状况位于底部，表明在控制了其他变量后，它们对模型预测的影响很小。




图 9. 使用模型 XGBoost 对随机选择的测试集样本进行特征排列重要性排序。

XGBoost 模型通过所有三种可解释性方法显示年龄是骨质疏松症的主要风险因素，这些方法展示了其在其他变量中的主导作用。SHAP 方法将荷尔蒙变化和家族史分配为第二至第三高的平均贡献值，而排列重要性则将其直接排在年龄之后，LIME 显示它们在存在时影响个别预测的能力。体力活动、种族/民族以及先前骨折形成一个中等群体，其适度的重要性出现在 SHAP 和排列分析中，并且偶尔会影响 LIME 解释。最后，钙/维生素 D 摄入量、药物使用、吸烟、酒精消费、性别、体重和医疗状况等因素在所有可解释性方法中的影响一直很小。SHAP、LIME 和排列重要性的这种一致性使我们对模型依赖于年龄、荷尔蒙状态和家族史充满信心，并表明哪些其他变量只起支持或微不足道的作用。

V. 结论与未来工作

骨质疏松症是一个普遍的公共卫生挑战：起初无症状，随着骨骼强度下降最终通过致残性骨折显现出来。该研究系统评估了六种机器学习算法用于骨质疏松风险预测任务，包括随机森林、逻辑回归、XGBoost、AdaBoost、LightGBM 和梯度提升。通过对增强树方法进行五折交叉验证的 GridSearchCV 评估表明，这些方法的表现优于袋装树和线性分类器。XGBoost 在所有模型中表现最佳，准确率为 91.0%，精度为 0.92，召回率为 0.91，并且 F1 得分为 0.90。我们的超参数分析显示，平衡的集成性能需要适度的树深度设置、学习率约为 0.1 以及合适的正则化和特征与数据的控制采样。可解释的人工智能方法 SHAP、LIME 和排列重要性表明，年龄是主要的风险因素，而激素变化和家族史排名为第二重要的风险因素。

研究包含某些限制，因为数据分布可能与现实世界模式不同，并且缺乏独立队列的外部验证，也不包括生物标志物或成像或遗传数据，因此无法预测骨折发生的时间。未来的研究将探索多个方向。我们的研究将通过独立队列研究在不同的地理区域验证我们的模型以建立其适用性。我们的研究将通过添加更多生物标志物和成像衍生指标及遗传谱来扩展特征收集，以识别新的预测因素。我们的研究将通过开发生存分析框架或递归架构来超越风险分类，以预测骨折发生的时间和风险状态。在孟加拉国的数据收集将有助于创建一个基于 XAI 的决策支持系统，以符合区域临床实践的需求。

参考文献

- [1] A. Oden, E. V. McCloskey, J. A. Kanis, N. C. Harvey, and H. Johansson, "Burden of high fracture probability worldwide: secular increases 2010–2040," *Osteoporosis International*, vol. 26, pp. 2243–2248, 2015.
- [2] M. S. Kha, M. G. Kibria, F. Hossain, J. Ferdous, H. M. Shihab, and S. M. Faisal, "Unveiling the Burden of Osteoporosis: Exploring the Prevalence and Risk Factors among Postmenopausal Women in North Central Bangladesh," *Central Medical College Journal*, vol. 7, no. 1, pp. 32–40, 2023.
- [3] B. De Vries, J. Hegeman, W. Nijmeijer, J. Geerdink, C. Seifert, and C. Groothuis-Oudshoorn, "Comparing three machine learning approaches to design a risk assessment tool for future fractures: predicting a subsequent major osteoporotic fracture in fracture patients with osteopenia and osteoporosis," *Osteoporosis international*, vol. 32, pp. 437–449, 2021.
- [4] E. Jabarpour, A. Abedini, and A. Keshtkar, "Osteoporosis risk prediction using data mining algorithms," *Journal of Community Health Research*, 2020.

- [5] T. K. Yoo, S. K. Kim, E. Oh, and D. W. Kim, "Risk prediction of femoral neck osteoporosis using machine learning and conventional methods," in *Advances in Computational Intelligence: 12th International Work-Conference on Artificial Neural Networks, IWANN 2013, Puerto de la Cruz, Tenerife, Spain, June 12-14, 2013, Proceedings, Part II 12*. Springer, 2013, pp. 181–188.
- [6] M. I. Mahmud, M. S. Reza, and S. S. Khan, "Optimizing Stroke Detection: An Analysis of Different Feature Selection Approaches," in *Companion of the 2024 on ACM International Joint Conference on Pervasive and Ubiquitous Computing*, 2024, pp. 142–146.
- [7] J. Zeitlin, M. K. Parides, J. M. Lane, L. A. Russell, and K. N. Kunze, "A clinical prediction model for 10-year risk of self-reported osteoporosis diagnosis in pre-and perimenopausal women," *Archives of Osteoporosis*, vol. 18, no. 1, p. 78, 2023.
- [8] V. Budyal, H. Disha, I. H. Suresh, and S. V. Bhatt, "Early Detection of Osteoporosis using Machine Learning and Biomarkers," in *2024 5th IEEE Global Conference for Advancement in Technology (GCAT)*. IEEE, 2024, pp. 1–6.
- [9] M. S. Reza, M. I. Mahmud, I. A. Abeer, and N. Ahmed, "Linear Discriminant Analysis in Credit Scoring: A Transparent Hybrid Model Approach," *arXiv preprint arXiv:2412.04183*, 2024.
- [10] J.-G. Shim, D. W. Kim, K.-H. Ryu, E.-A. Cho, J.-H. Ahn, J.-I. Kim, and S. H. Lee, "Application of machine learning approaches for osteoporosis risk prediction in postmenopausal women," *Archives of osteoporosis*, vol. 15, pp. 1–9, 2020.
- [11] C. Qiu, K. Su, Z. Luo, Q. Tian, L. Zhao, L. Wu, H. Deng, and H. Shen, "Developing and comparing deep learning and machine learning algorithms for osteoporosis risk prediction," *Frontiers in Artificial Intelligence*, vol. 7, p. 1355287, 2024.
- [12] M. Z. Mahmud, M. S. Reza, S. R. Alve, S. Islam, and N. Fahmid, "Advance Transfer Learning Approach for Identification of Multi-class Skin Disease with LIME Explainable AI Technique," *medRxiv*, pp. 2024–12, 2024.
- [13] V. V. Khanna, K. Chadaga, N. Sampathila, R. Chadaga, S. Prabhu, S. KS, A. S. Jagdale, and D. Bhat, "A decision support system for osteoporosis risk prediction using machine learning and explainable artificial intelligence," *Heliyon*, vol. 9, no. 12, 2023.
- [14] A. V. Kulkarni, "Osteoporosis risk prediction," Kaggle dataset, 2024. [Online]. Available: <https://www.kaggle.com/datasets/amitvkulkarni/lifestyle-factors-influencing-osteoporosis>
- [15] L. Breiman, "Random forests," *Machine learning*, vol. 45, pp. 5–32, 2001.
- [16] D. R. Cox, "The regression analysis of binary sequences," *Journal of the Royal Statistical Society Series B: Statistical Methodology*, vol. 20, no. 2, pp. 215–232, 1958.
- [17] T. Chen and C. Guestrin, "Xgboost: A scalable tree boosting system," in *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, 2016, pp. 785–794.
- [18] A. Yulianto, P. Sukarno, and N. A. Suwastika, "Improving adaboost-based intrusion detection system (IDS) performance on CIC IDS 2017 dataset," in *Journal of Physics: Conference Series*, vol. 1192. IOP Publishing, 2019, p. 012018.
- [19] J. Zhang, D. Mucs, U. Norinder, and F. Svensson, "LightGBM: An effective and scalable algorithm for prediction of chemical toxicity—application to the Tox21 and mutagenicity data sets," *Journal of chemical information and modeling*, vol. 59, no. 10, pp. 4150–4158, 2019.
- [20] J. H. Friedman, "Greedy function approximation: a gradient boosting machine," *Annals of statistics*, pp. 1189–1232, 2001.
- [21] S. Islam, M. Z. Mahmud, S. R. Alve, and M. M. U. Chowdhury, "Deep Learning Approach for Enhancing Oral Squamous Cell Carcinoma with LIME Explainable AI Technique," *arXiv preprint arXiv:2411.14184*, 2024.
- [22] M. Z. Mahmud, S. Islam, S. R. Alve, and A. J. Pial, "Optimized IoT Intrusion Detection using Machine Learning Technique," in *2024 IEEE 3rd International Conference on Robotics, Automation, Artificial-Intelligence and Internet-of-Things (RAAICON)*, 2024, pp. 167–172.