

ПРИМЕНЕНИЕ ГИБРИДНЫХ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ДИАГНОСТИКИ ДИАБЕТА

д.т.н., проф. Мухамедиева Дилноз Тулкуновна

Национальный исследовательский университет «Ташкентский институт
инженеров ирригации и механизации сельского хозяйства», Узбекистан
dilnoz134@rambler.ru

Васиева Дильфуза Дилишод кизи

Национальный исследовательский университет «Ташкентский институт
инженеров ирригации и механизации сельского хозяйства», Узбекистан

Собиров Рузимбой Атабекович

Национальный исследовательский университет «Ташкентский институт
инженеров ирригации и механизации сельского хозяйства», Узбекистан

Нажмиддинов Ахлиддин Сирожиддин угли

Национальный исследовательский университет «Ташкентский
институт инженеров ирригации и механизации сельского хозяйства»,
Узбекистан

<https://doi.org/10.5281/zenodo.12749857>

Аннотация. В работе исследуется применение ансамблевых методов, таких как случайный лес, градиентный бустинг и бэггинг для диагностики сахарного диабета и анализирует их преимущества и вызовы. Гибридные методы способствуют увеличению точности диагностики и снижению ложных срабатываний и ложноотрицательных результатов. В целом, гибридные методы машинного обучения представляют собой перспективный инструмент для улучшения диагностики сахарного диабета и могут способствовать более эффективному выявлению и управлению этим хроническим заболеванием.

Ключевые слова: машинное обучение, случайный лес, градиентный бустинг, модель стекинга, метрика.

Аннотация. Мақолада қандли диабетга таъхис қўйиш учун тасодифий ўрмон, градиентли бустинг ва беггинг каби ансамбл усулларидан фойдаланиш қўриб чиқилган ва уларнинг афзалликлари ва мураккабликлари таҳлил қилинган. Гибрид усуллар диагностика аниқлигини оширишга ва нотўғри ижобий ва нотўғри салбийларни камайтиришга ёрдам беради. Умуман олганда, гибрид машинали ўқитиш усуллари диабет таъхисини яхшилаш учун истиқболли воситадир ва ушбу сурункали касалликни янада самарали аниқлаш ва

бошқаришига ёрдам беради.

Калим сўзлар: машинали ўқитиш, тасодифий ўрмон, градиентли бустинг, стекинг модели, метрика.

Annotation: *The paper explores the use of ensemble methods such as random forest, gradient boosting, and bagging for diagnosing diabetes mellitus and analyzes their advantages and challenges. Hybrid methods help to increase diagnostic accuracy and reduce false positives and false negatives. Overall, hybrid machine learning techniques represent a promising tool for improving diabetes diagnosis and may contribute to more effective detection and management of this chronic disease.*

Keywords: *machine learning, random forest, gradient boosting, stacking model, metric.*

1. Введение. Актуальность применения машинного обучения в области диагностики и управления диабетом трудно переоценить. Машинное обучение позволяет создавать модели, которые могут анализировать множество медицинских данных пациентов и предсказывать риск развития диабета. Это позволяет врачам и пациентам принимать меры по ранней диагностике и профилактике заболевания, позволяет анализировать характеристики и реакцию каждого пациента на лечение. Машинное обучение способствует интеграции данных из различных источников, таких как медицинские карты, данные лабораторных исследований, информация о лекарствах и мониторинге, что позволяет врачам и исследователям получить более полное представление о состоянии пациентов. Автоматизированные системы и инструменты машинного обучения помогают врачам принимать более обоснованные решения и предоставлять более точный и персонализированный уход для пациентов с диабетом [1-3].

Цель применения ансамблевых методов машинного обучения для диагностики диабета заключается в улучшении процесса диагностики сахарного диабета путем повышения точности, надежности и эффективности выявления этого хронического заболевания [4].

2. Методы. Применение ансамблевых методов машинного обучения для диагностики сахарного диабета может улучшить точность и надежность моделей. Ансамблевые методы объединяют несколько базовых моделей в одну, чтобы уменьшить переобучение, повысить обобщающую способность и улучшить качество прогнозов [5].

1. Случайный лес (Random Forest) - это мощный ансамблевый метод машинного обучения, который используется для задач классификации и

регрессии. Он основан на идее создания нескольких деревьев решений и объединения их результатов для улучшения точности и устойчивости модели [5].

2. Градиентный бустинг - это ансамбль, в котором каждое дерево настраивается на ошибки предыдущего дерева. Это улучшает качество предсказаний и позволяет работать с данными разного типа [6].

3. Смешивание моделей (Model Stacking).

Модель стекинга - это метод, при котором несколько моделей объединяются, и их прогнозы становятся входными данными для финальной модели. Это может быть полезным для объединения различных типов моделей.

В начале создаются несколько различных базовых моделей (или классификаторов), использующих разные алгоритмы или параметры. Каждая базовая модель обучается на одном и том же обучающем наборе данных. Они могут использовать разные признаки или параметры, что увеличивает разнообразие моделей. Создается дополнительная модель (называемая "моделью стекинга" или "метамоделью"), которая принимает предсказания базовых моделей в качестве входных признаков.

3. Результат.

Чтобы применить ансамблевые методы к диагностике сахарного диабета, нужно следовать следующим шагам:

Собрать и подготовить данные: Получите надежные и чистые данные о пациентах, включая признаки, такие как возраст, пол, ИМТ (индекс массы тела), уровень глюкозы в крови, артериальное давление и другие. Разделите данные на обучающий и тестовый наборы.

Выбрать ансамблевый метод: Решите, какой из ансамблевых методов наилучшим образом подходит для вашей задачи классификации диабета.

Обучить ансамбль: Обучите выбранный ансамбль на обучающем наборе данных. Оценить производительность: Используйте метрики, такие как accuracy, precision, recall, F1-score и AUC-ROC, для оценки производительности модели на тестовом наборе данных.

Валидация и настройка: Проведите кросс-валидацию и тюнинг параметров, чтобы убедиться, что модель работает хорошо и не переобучается.

Применение модели: Используйте обученную модель для диагностики сахарного диабета на новых пациентах.

1. По разработанной программе по алгоритму Случайный лес (Random Forest) получены следующие результаты:

Confusion Matrix:

[[37 12]


[13 27]]

Classification Report:

	precision	recall	f1-score	support
Class 0	0.74	0.76	0.75	49
Class 1	0.69	0.68	0.68	40
accuracy		0.72		89
macro avg	0.72	0.72	0.72	89
weighted avg	0.72	0.72	0.72	89

Accuracy: 0.7191, Precision: 0.6923, Recall: 0.6750, F1-Score: 0.6835, AUC-ROC: 0.8125.

AUC-ROC - это показатель качества модели, который оценивает способность модели разделять классы и зависит от порогового значения вероятности. Значение 0.8125 означает, что модель хорошо разделяет классы, и AUC-ROC близка к 1, что свидетельствует о хорошей производительности модели.



2. По разработанной программе по алгоритму Градиентный бустинг (Gradient Boosting) получены следующие результаты:

Confusion Matrix:

[[37 13]

[14 25]]

Classification Report:

	precision	recall	f1-score	support
0	0.73	0.74	0.73	50
1	0.66	0.64	0.65	39

accuracy		0.70		89
macro avg	0.69	0.69	0.69	89
weighted avg	0.70	0.70	0.70	89

Accuracy: 0.6966292134831461

Precision: 0.6578947368421053

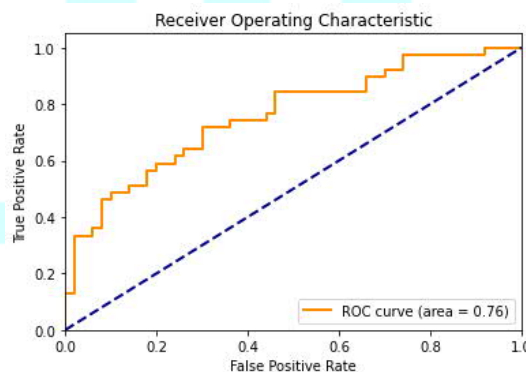
Recall: 0.6410256410256411

F1-Score: 0.6493506493506495

AUC-ROC: 0.7605128205128205

Метрики, представленные в отчете о классификации и матрице путаницы, оценивают производительность модели машинного обучения в задаче бинарной классификации. В данном случае, у вас есть два класса: "0" и "1". Давайте разберемся, что означают эти метрики:

AUC-ROC (Площадь под кривой ROC):



5.Результат Смешивание моделей (Model Stacking):

Этот метод показывает, как можно создать стекинг моделей для задачи диагностики диабета, используя логистическую регрессию и случайный лес в качестве базовых моделей и градиентный бустинг в качестве метамодели. Вы можете изменить базовые модели и параметры в соответствии с вашими потребностями и данными.

Accuracy оценивает долю правильно классифицированных объектов по отношению ко всем объектам. В данном случае, точность равна 0.764, что означает, что модель правильно классифицировала 76.4% объектов.


Precision (точность) измеряет долю истинных положительных предсказаний относительно всех положительных предсказаний. В данном случае, точность для класса "0" равна 0.71, а для класса "1" - 0.95.

Recall (полнота) измеряет долю истинных положительных предсказаний относительно всех истинных положительных объектов. В данном случае, полнота для класса "0" равна 0.98, а для класса "1" - 0.49.

F1-мера является средним гармоническим между точностью и полнотой. Это числовая оценка баланса между точностью и полнотой. В данном случае, F1-

мера для класса "0" составляет 0.82, а для класса "1" - 0.64.

AUC-ROC (Площадь под кривой ROC):



AUC-ROC - это показатель качества модели, который оценивает способность модели разделять классы и зависит от порогового значения вероятности. Значение 0.7756 означает, что модель разделяет классы с неплохой производительностью, и AUC-ROC близка к 0.5, что свидетельствует о средней производительности модели классификации. Наилучший результат показал случайный лес.

5. Заключение. Применение ансамблевых методов машинного обучения для диагностики сахарного диабета представляет собой многообещающую и важную область исследований и практического применения в медицине. В ходе нашей дискуссии мы рассмотрели ряд ключевых моментов, связанных с использованием ансамблевых методов для этой цели.

Важно подчеркнуть, что ансамблевые методы машинного обучения, такие как случайный лес, градиентный бустинг, бэггинг и адаптивный бустинг, предоставляют значительные преимущества при диагностике сахарного диабета. Некоторые ансамблевые методы, такие как случайный лес, могут предоставить информацию о важности признаков, что помогает врачам и исследователям лучше понимать факторы, влияющие на диагностику диабета. В итоге, применение ансамблевых методов машинного обучения для диагностики сахарного диабета имеет огромный потенциал для улучшения здравоохранения и качества жизни пациентов. Дальнейшие исследования и разработки в этой области будут способствовать развитию эффективных инструментов для диагностики и лечения сахарного диабета.

Литература

1. Ahmad H, Asghar MU, Asghar MZ, Khan A, Mosavi AH. A hybrid deep learning technique for personality trait classification from text. *IEEE Access*. (2021) 9:146214–32. doi: 10.1109/ACCESS.2021.3121791
2. Alghazzawi D, Bamasaq O, Ullah H, Asghar MZ. Efficient detection of DDoS attacks using a hybrid deep learning model with improved feature selection. *ApplSci*. (2021) 11:11634. doi: 10.3390/app112411634
3. Рашка, С. Python и машинное обучение [Текст] / С. Рашка. – М. : ДМК Пресс, 2017. – 418 с.

4. Khattak A, Habib A, Asghar MZ, Subhan F, Razzak I, Habib A. Applying deep neural networks for user intention identification. *Soft Comput.* (2021) 25:2191–220. doi: 10.1007/s00500-020-05290-z
5. Char, D. S., Shah, N. H., & Magnus, D. (2018). Implementing Machine Learning in Health Care—Addressing Ethical Challenges // *New England Journal of Medicine*, 378(11), 981-983.
6. Butt UM, Letchmunan S, Ali M, Hassan FH, Baqir A, Sherazi HHR. Machine learning based diabetes classification and prediction for healthcare applications. *JHealthcareEng.* (2021)

