

УДК 004**ОЦЕНКА ВЛИЯНИЯ СЛУЧАЙНОСТИ ПРИ РАЗДЕЛЕНИИ ДАННЫХ
НА ТРЕНИРОВОЧНУЮ И ТЕСТОВЫЕ ВЫБОРКИ**

Смирнов А.П., студент гр. М20126, I курс

Научный руководитель: Соколова С.С., преподаватель кафедры киберфизических систем СПБГМТУ

Федеральное государственное бюджетное образовательное учреждение высшего образования

Санкт-Петербургский государственный морской технический университет
г. Санкт-Петербург

В задачах машинного обучения зачастую исследуются реально существующие данные. Грамотная их интерпретация и анализ могут существенно повлиять на результаты исследования, а также на качество и надежность построенных моделей. Одним из ключевых этапов при работе с данными является их разбиение на тренировочную и тестовую выборки, что необходимо для корректной оценки качества алгоритмов. Однако процесс этого разбиения не всегда очевиден и может оказывать значительное влияние на итоговую производительность модели.

Цель данной работы — исследовать, действительно ли случайное разделение датасета на тренировочную и тестовые выборки способно повлиять на итоги работы алгоритмов машинного обучения, а также определить, насколько велики различия между разными стратегиями разбиения данных. Данная проблема особенно актуальна при работе с небольшими выборками, где случайные флюктуации в распределении данных могут приводить к значительным колебаниям метрик качества модели.

Для достижения этой цели были поставлены следующие задачи:

1. Выбрать реально существующий, но относительно простой датасет, который позволит провести сравнение нескольких методов разбиения входных данных. В качестве рассматриваемых методов выбраны: простое разбиение, стратифицированное разбиение, кросс-валидация со стратификацией.

2. Оценить точность (accuracy) алгоритма в зависимости от метода разбиения данных, а также вычислить стандартное отклонение точности для разных случаев, чтобы выявить степень вариативности полученных результатов.

3. Проанализировать причины расхождений в результатах, объяснить, почему одни методы обеспечивают более стабильные оценки качества модели, и определить, какой метод рациональнее использовать в реальных задачах.

Результаты исследования быть использованы в образовательных целях при изучении дисциплин, связанных с машинным обучением, а также при

разработке более надежных стратегий разбиения выборок для практических задач. Наглядная демонстрация влияния метода разбиения данных на конечные результаты позволит избежать распространенных ошибок и повысить достоверность проводимых экспериментов. Выводы могут наглядно продемонстрировать, почему вопросу случайного разбиения выборок все же следует уделять внимание.

В качестве датасета для исследования был выбран один из самых известных и широко применяемых наборов данных — Ирисы Фишера (Iris Dataset). Это классический датасет, который активно используется в учебных и научных целях, а также при тестировании различных алгоритмов машинного обучения, особенно в задачах классификации. Данный набор содержит 150 наблюдений (строк), каждая из которых представляет собой параметры одного цветка ириса, включая такие характеристики, как длина и ширина лепестков и чашелистиков. На основе этих признаков можно классифицировать цветок как один из трех видов ирисов. Датасет был импортирован из библиотеки Scikit-learn (sklearn).

В качестве базового алгоритма для классификации данных использовался метод логистической регрессии. Его основная цель — предсказать, к какому классу принадлежит конкретный цветок, используя входные признаки. Перед обучением модели данные были разделены на тренировочную и тестовую выборки в стандартном соотношении 80:20. Однако важно понимать, что это разбиение не является абсолютно случайным в математическом смысле. Оно реализуется с помощью псевдослучайного генератора, где результаты разбиения зависят от фиксированного начального значения (random_state). Чтобы оценить влияние случайности, в исследовании рассматривались различные значения random_state в диапазоне от 0 до 45, что позволило проанализировать устойчивость модели к различным вариантам разделения данных.

Далее в методе простого разбиения обучение применяется со всеми вариантами random_state.

В методе стратифицированного разбиения проводится стратификация данных, то есть сохранение пропорций классов такими же в выборках, как и в изначальном датасете. Потенциально, это может уменьшить дисбаланс в данных, ведь присутствие одного класса может превалировать.

А в методе кросс-валидации со стратификацией сначала проводится стратификация данных, затем кросс-валидация на одном из популярных методов — 5-блочной кросс валидации(5-fold cross-validation). То есть данные делятся на 5 блоков, 4 из них определяются в обучающую выборку, 1 в тестовую. Модель обучается 5 раз, пока каждый из блоков не попадет и в одну, и в другую выборки. Как итоговая точность — берется среднее значение всех точностей. Схематично процесс разбиения отображен на рисунке 1.



Рисунок 1. Процесс разбиения данных при кросс-валидации.

Результаты исследования отображены в таблице 1.

random_state	Точность (Стратифицированное разбиение)	Точность (Кросс-валида- ция со страти- фикацией)	Точность (Простое разбиение)
0	1.0	0.95	1.0
5	0.966667	0.966667	0.966667
10	1.0	0.95	1.0
15	0.933333	0.958333	1.0
20	1.0	0.95	0.933333
25	0.9	0.975	0.966667
30	0.933333	0.966667	0.966667
35	0.9	0.966667	1.0
40	0.966667	0.966667	1.0
45	0.9	0.966667	0.966667

Таблица 1. Точность для методов при различном random_state

Средние и стандартные отклонения точности:

- Стратифицированное разбиение: 0.9500 ± 0.0401
- Кросс-валидация со стратификацией: 0.9617 ± 0.0085
- Простое разбиение: 0.9800 ± 0.0221

Графики с результатами точности изображены на рисунке 2.




Рисунок 2. Сравнение точности для разных разбиений.

По полученным результатам можно сделать выводы, что хотя стратификация сохраняет пропорции классов в обучающей и тестовой выборках, это не гарантирует равномерное представление всех признаков в каждом разбиении. При малом размере датасета, как в данном случае (150 наблюдений), небольшие изменения в распределении объектов по обучающей и тестовой выборкам могут значительно повлиять на результат. Также если в классе, который мало представлен, будет находиться большое количество выбросов, только стратификация может усугубить ситуацию.

Простое разбиение также продемонстрировало свою нестабильность.

А вот кросс-валидация уменьшает зависимость от случайности разбиения данных, так как модель оценивается несколько раз на разных подвыборках. Это делает метод более надежным, особенно при небольших датасетах. Стратификация в кросс-валидации помогает гарантировать равномерное распределение классов во всех разбиениях. Стандартное отклонение самое низкое среди всех методов, что говорит о стабильности результатов.

Список литературы:

1. Cross-Validation. [Электронный ресурс]. - URL: https://scikit-learn.ru/stable/modules/cross_validation.html (дата обращения: 20.02.2025).
2. LinearRegression. [Электронный ресурс]. - URL: https://scikit-learn.org/stable/modules/generated/sklearn.linear_model.LinearRegression.html (дата обращения: 20.02.2025).
3. Load_Iris. [Электронный ресурс]. - URL: https://scikit-learn.org/stable/modules/generated/sklearn.datasets.load_iris.html (дата обращения: 20.02.2025).

4. StratifiedKFold. [Электронный ресурс]. - URL: https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.StratifiedKFold.html (дата обращения: 20.02.2025).