

Лекция 10. Методы снижения размерности данных

Тема: PCA, LDA, t-SNE, UMAP

1. Введение

В эпоху больших данных аналитики часто сталкиваются с проблемой высокой размерности. Когда количество признаков (атрибутов, переменных) в наборе данных слишком велико, модели машинного обучения становятся сложными, медленными и подверженными переобучению. Этот эффект известен как «**проклятие размерности**».

Для борьбы с ним применяются **методы снижения размерности (Dimensionality Reduction)** — техники, которые позволяют представить данные в более компактной форме, сохраняя при этом их основную структуру и информативность.

2. Цели снижения размерности

Основные задачи этих методов:

- уменьшить количество признаков без потери важной информации;
- улучшить визуализацию данных (особенно в 2D или 3D);
- ускорить обучение моделей;
- устранить шум и коррелированные признаки;
- повысить интерпретируемость данных.

Существует два основных подхода:

1. **Отбор признаков (Feature Selection)** — выбор подмножества наиболее информативных признаков.
 2. **Извлечение признаков (Feature Extraction)** — создание новых признаков как комбинаций исходных.
-

3. Метод главных компонент (PCA — Principal Component Analysis)

PCA — один из самых распространённых методов снижения размерности. Он преобразует исходные признаки в набор **главных компонент** — новых осей, ориентированных вдоль направлений наибольшей дисперсии данных.

Основная идея:

PCA находит такие ортогональные векторы (компоненты), при проекции на которые разброс данных максимален.

Этапы PCA:

1. Центрирование данных (вычитание среднего).
2. Вычисление ковариационной матрицы.
3. Нахождение собственных значений и векторов.

4. Сортировка компонент по величине собственных значений.
5. Выбор первых k компонент и проекция данных.

Применение:

- визуализация данных в 2D и 3D;
 - удаление шумов;
 - предварительная обработка перед классификацией или кластеризацией.
-

4. Линейный дискриминантный анализ (LDA — Linear Discriminant Analysis)

LDA — метод, ориентированный на **классификацию**.

В отличие от PCA, который не учитывает метки классов, LDA использует их, чтобы найти направления, **максимизирующие разделение между классами** при минимизации разброса внутри классов.

Основные шаги LDA:

1. Вычисление средних для каждого класса.
2. Определение внутриклассовой и межклассовой дисперсий.
3. Решение обобщённой задачи собственных значений.
4. Выбор направлений, которые дают наилучшее разделение классов.

Пример применения:

распознавание лиц, диагностика по медицинским данным, биометрия.

5. t-SNE (t-distributed Stochastic Neighbor Embedding)

t-SNE — нелинейный метод снижения размерности, разработанный для визуализации сложных данных высокой размерности в 2D или 3D.

Он не сохраняет глобальную структуру, но очень хорошо отображает **локальные группы и кластеры**.

Идея:

t-SNE моделирует вероятностное распределение сходства между точками в исходном пространстве и пытается воспроизвести это распределение в пространстве меньшей размерности.

Преимущества:

- отличная визуализация кластеров;
- работает с любыми нелинейными структурами.

Недостатки:

- высокая вычислительная сложность;
- сложно интерпретировать оси;

- чувствителен к параметрам (например, perplexity).

6. UMAP (Uniform Manifold Approximation and Projection)

UMAP — современный метод, разработанный как более быстрый и устойчивый аналог t-SNE.

Он основан на теории **многообразий** и **топологии**, строя граф соседей и затем приближая его в низкоразмерном пространстве.

Преимущества UMAP:

- высокая скорость работы;
- сохранение как локальной, так и глобальной структуры данных;
- возможность использовать для обучения моделей и кластеризации.

Применение:

геномика, обработка изображений, анализ текста и визуализация многомерных признаков.

7. Сравнение методов

Метод	Тип	Сохраняет структуру	Учитывает классы	Преимущества	Недостатки
PCA	Линейный	Глобальная	Нет	Простота, скорость	Потеря нелинейных зависимостей
LDA	Линейный	Межклассовая	Да	Хорошо разделяет классы	Только для классификации
t-SNE	Нелинейный	Локальная	Нет	Отличная визуализация	Дорогой по времени
UMAP	Нелинейный	Локальная и глобальная	Нет	Быстрый, гибкий	Зависит от параметров

8. Заключение

Методы снижения размерности являются неотъемлемой частью современного анализа данных. Они позволяют:

- упростить сложные модели;
- улучшить визуальное восприятие;
- выделить скрытые закономерности;
- ускорить вычисления и повысить качество анализа.

Выбор метода зависит от задач — если нужно сохранить глобальную структуру и интерпретируемость, подойдёт **PCA**; если важно разделить классы — **LDA**; для визуализации сложных данных — **t-SNE** или **UMAP**.

Список литературы

1. Хэн, Дж., Камбер, М., Пей, Дж. *Интеллектуальный анализ данных: концепции и методы*. — М.: Вильямс, 2019.
2. Géron, A. *Hands-On Machine Learning with Scikit-Learn, Keras & TensorFlow*. — O'Reilly Media, 2022.
3. Van der Maaten, L., Hinton, G. *Visualizing Data using t-SNE*. Journal of Machine Learning Research, 2008.
4. McInnes, L., Healy, J., Melville, J. *UMAP: Uniform Manifold Approximation and Projection for Dimension Reduction*. arXiv preprint, 2018.
5. Jolliffe, I. T. *Principal Component Analysis*. — Springer, 2016.