

Лабораторная работа 2

Анализ DDoS атак моделями машинного обучения

Дан датасет DDoS атак

<https://www.kaggle.com/code/chitrakhsingh/ddos-sdn>

Разработать и протестировать модели машинного обучения для классификации сетевого трафика и выявления DDoS-атак на основе датасета DDoS-SDN. Провести сравнительный анализ различных алгоритмов.

Этапы выполнения

1. Подготовка данных

1. Загрузка данных

- Скачать датасет с Kaggle и загрузить в среду разработки (например, Jupyter Notebook или PyCharm).
- Использовать библиотеки pandas и numpy для обработки данных.

2. Анализ данных

- Провести анализ структуры данных (количество строк, столбцов, наличие пропущенных значений).
- Определить целевую переменную и признаки.

3. Предобработка данных

- Обработать пропущенные значения (если есть).
- Закодировать категориальные переменные (если они присутствуют).
- Нормализовать числовые признаки (если необходимо).
- Разделить данные на обучающую и тестовую выборки (train_test_split).

2. Обучение моделей

Реализовать и обучить следующие модели:

1. Наивный Байесовский классификатор (Naïve Bayes)

- Использовать GaussianNB или MultinomialNB из sklearn.naive_bayes.

2. Логистическая регрессия (Logistic Regression)

- Использовать LogisticRegression из sklearn.linear_model.

3. Метод опорных векторов (Support Vector Machine, SVM)

- Использовать SVC из sklearn.svm с разными ядрами (linear, rbf).

4. Метод k-ближайших соседей (k-Nearest Neighbors, k-NN)

- Использовать KNeighborsClassifier из sklearn.neighbors.
- Подобрать оптимальное k с помощью кросс-валидации.

5. Дерево решений (Decision Tree)

- Использовать DecisionTreeClassifier из sklearn.tree.
- Провести настройку гиперпараметров (max_depth, criterion).

6. Случайный лес (Random Forest)

- Использовать RandomForestClassifier из sklearn.ensemble.
- Настроить параметры (n_estimators, max_depth).

7. Градиентный бустинг (XGBoost)

- Использовать XGBClassifier из xgboost.
 - Настроить параметры (learning_rate, n_estimators, max_depth).
8. **CatBoost**
 - Использовать CatBoostClassifier из catboost.
 - Подобрать параметры (iterations, depth, learning_rate).
 9. **AdaBoost**
 - Использовать AdaBoostClassifier из sklearn.ensemble.
 - Настроить параметры (n_estimators, learning_rate).

3. Оценка моделей

1. **Метрики качества**
 - Оценить модели по метрикам:
 - accuracy
 - precision
 - recall
 - F1-score
 - ROC-AUC (для вероятностных моделей)
2. **Кросс-валидация**
 - Провести кросс-валидацию (например, StratifiedKFold) для проверки устойчивости моделей.
3. **Матрица ошибок (Confusion Matrix)**
 - Построить матрицу ошибок (confusion_matrix) для анализа ошибок классификации.

4. Визуализация результатов

1. Построить графики:
 - Сравнение точности (accuracy) моделей.
 - График ROC-кривых для нескольких моделей.
 - Матрицы ошибок для лучших моделей.

5. Анализ и выводы

1. Сравнить результаты всех моделей, указав:
 - Какая модель показала наилучшую точность?
 - Какой алгоритм быстрее обучается?
 - Какие модели лучше справляются с данной задачей?
 - Какие признаки наиболее значимы?
2. Написать выводы о применимости различных алгоритмов для классификации DDoS-атак.