

Мультиклассовая классификация для диагностики функционирования сложных технических систем

Ю.Е. Кувайскова
Ульяновский государственный
технический университет
Ульяновск, Россия
u.kuvaiskova@mail.ru

Н.А. Ломовцева
Ульяновский государственный
технический университет
Ульяновск, Россия
natalya.lomovtseva@gmail.com

В.Н. Клячкин
Ульяновский государственный
технический университет
Ульяновск, Россия
v_kl@mail.ru

Abstract—Диагностика функционирования сложных технических систем часто сводится к разделению состояния объекта на несколько классов: исправное состояние и различные типы неисправностей. С помощью разработанной программы проводится мультиклассовая классификация методами машинного обучения. В качестве примера рассмотрены особенности диагностики компьютерной системы.

Keywords—*диагностика, классификация, кросс-валидация, тестовая выборка, F-мера.*

1. ВВЕДЕНИЕ

Диагностика функционирования сложных технических систем проводится в целях обеспечения их безопасности и надежности [1]. При этом часто задача сводится к разделению состояния объекта на несколько классов: исправное состояние и различные типы неисправностей. В качестве исходных данных используются результаты наблюдений за функционированием объекта в период предшествующей эксплуатации: набор показателей работы объекта и его состояние.

Задача сводится к мультиклассовой классификации методами машинного обучения [2-3]. По имеющемуся набору исходных данных строится классификатор, с помощью которого можно спрогнозировать состояние объекта при новом наборе показателей.

Частный случай такой задачи при классификации режимов работы авиационного газотурбинного двигателя решалась с применением нейронных сетей [4]. Еще один частный случай – бинарная классификация, когда состояние объекта разделяется на два класса – исправное и неисправное, был использован для вибродиагностики гидроагрегата [5].

Необходимо выбрать метод классификации, обеспечивающий нужную точность, провести отбор значимых показателей, задать объем контрольной выборки. Для исключения переобучения может быть использована кросс-валидация. Это вопросы, решаемые в любой задаче машинного обучения.

Особенностью диагностики сложных технических систем является сравнительно небольшой объем наблюдений и несбалансированность классов: как правило наблюдений при неисправных состояниях объекта гораздо меньше, чем при исправных. В этом случае основной критерий качества обучения – доля

правильных ответов на тестовой выборке – может привести к ложным выводам.

2. ПРОГРАММА МУЛЬТИКЛАССОВОЙ КЛАССИФИКАЦИИ

Программа разработана на языке программирования Python. Обеспечивается ввод файла исходных данных, разбиение его в заданном соотношении на обучающую и тестовую части случайным образом с применением стратификации, проведение кросс-валидации с заданным пользователем количеством блоков. Программа обеспечивает также отбор значимых показателей функционирования объекта двумя методами: по коррелированности показателей и по значимости регрессоров в линейной регрессионной модели зависимости номера класса объекта от показателей.

Используется библиотека Sklearn, из которой импортируются готовые конструкторы для базовых классификаторов LogisticRegression, LinearDiscriminantAnalysis, KNeighborsClassifier, DecisionTreeClassifier, GaussianNB, SVC (метод опорных векторов), а также композиционных классификаторов RandomForestClassifier (случайный лес) и AdaBoostClassifier (адаптивный бустинг).

Для реализации агрегирования по среднему значению использованы функции Python для нахождения вероятностей принадлежности каждого объекта к соответствующему классу: `predict_proba`.

Из этой же библиотеки Sklearn импортируются модули для вычисления метрик мультиклассовой классификации: `accuracy_score` – функционал ошибок; `f1_score` – F-мера (основная характеристика качества классификации для несбалансированных классов) и `confusion_matrix` – матрица неточностей, а также модуль для кросс-валидации: `cross_val_score` и модуль для разбиения исходных данных на обучающую и тестовую выборки: `train_test_split`.

Результат работы программы – расчет трех мер качества классификации по тестовой выборке для каждого из базовых, композиционных и агрегированных классификаторов.

Пользователь в зависимости от характера исходных данных выбирает наилучший классификатор по тому или иному критерию. Этот классификатор в дальнейшем используется для прогнозирования состояния объекта. По вновь найденным показателям функционирования объекта прогнозируется, к какому классу относится его состояние.

3. ЧИСЛЕННОЕ ИССЛЕДОВАНИЕ

Исследовалось влияние различных показателей работы компьютера (загрузки процессора, температуры нагрева компонентов динамической памяти, напряжения, мощности и других – всего 9 показателей $x_1 \dots x_9$) на его состояние: 1 – исправен, 2 – зависание, 3 – искажение изображения, 4 – заторможенность курсора, 5 – заедание звука. Всего получено 715 наблюдений, из которых нарушения имели место в 143 случаях (20%).

Исследовалось влияние отбора показателей, доли тестовой выборки и метода обучения на качество классификации по F-мере на тестовой части выборки. В рассматриваемом примере отбор значимых показателей несущественно влияет на результат, максимальное значение рассматриваемого критерия получено при объеме тестовой выборки 25% и методе классификации – дерево решений – таблица 1).

Увеличение объема тестовой выборки до 30% не улучшило результат: в этом случае высшее значение F-меры на тестовой выборке составило 0,973 при агрегировании случайного леса с адаптивным бустингом.

Заметим, что в отличие от бинарной классификации, где агрегированные методы практически всегда улучшали результаты, в мультиклассовой задаче это обстоятельство не подтвердилось.

Варьирование объема тестовой выборки не увеличило заметно качество прогнозирования состояния компьютера (расхождение составляет 2-3%). Такого порядка расхождение имеет место при повторении испытаний (за счет случайного отбора данных в обучающую и тестовую выборки).

Таблица 1. F-МЕРА ПРИ РАЗЛИЧНЫХ БАЗОВЫХ И КОМПОЗИЦИОННЫХ КЛАССИФИКАТОРАХ С ОБЪЕМОМ ТЕСТОВОЙ ВЫБОРКИ 25%

Метод классификации	F-мера
Дерево решений	0,978
Случайный лес	0,960
Метод опорных векторов	0,906
Метод K-ближайших соседей	0,909
AdaBoost	0,823
Логистическая регрессия	0,923
Линейный дискриминантный анализ	0,899

Следует отметить, что при разных объемах тестовой выборки наилучший результат показывают разные методы обучения. При этом в двух из пяти испытаний применение агрегированных классификаторов [6-8] повысило качество диагностики.

4. ЗАКЛЮЧЕНИЕ

Разработанная программа мультиклассовой классификации для диагностики функционирования сложных технических систем методами машинного

обучения обеспечивает достаточно высокую точность классификации по предварительно сформированной выборке исходных данных по результатам предшествующей работы объекта.

Наилучший классификатор может быть использован для прогноза состояния системы по заданным показателям ее функционирования.

В рассмотренном примере диагностики функционирования компьютерной системы выявлено, что отбор значимых факторов и изменение доли тестовой выборки не приводят к значимому повышению качества классификации, однако в других сложных технических системах это влияние может быть существенным, поэтому разработанная программа предусматривает возможность учета и варьирования этих факторов.

В общем случае алгоритм диагностики функционирования сложных технических систем путем мультиклассовой классификации должен включать:

- исследование влияния отбора значимых показателей,
- оценка наилучшей доли тестовой выборки,
- оценка количества блоков кросс-валидации,
- влияние метода машинного обучения на значение выбранного критерия качества диагностики.

При этом основным критерием качества диагностики служит доля правильных ответов на тестовой выборке (при достаточно большом количестве данных о неисправном состоянии объекта) или F-мера при несбалансированных данных.

ЛИТЕРАТУРА

- [1] Биргер, И.А. Техническая диагностика / И.А. Биргер. – М.: Машиностроение, 1978. – 240 с.
- [2] Wang, B. A Multicategory Kernel Distance Weighted Discrimination Method for Multiclass Classification / B. Wang, H. Zou // *Technometrics*. – 2019. – Vol. 61(3). – P. 396-408.
- [3] Paynabar, K. A Change-Point Approach for Phase-I Analysis in Multivariate Profile Monitoring and Diagnosis / K. Paynabar, Ch. Zou, P. Qiu // *Technometrics*. – 2016. – Vol. 58(2). – P. 191-204.
- [4] Васильев, В.И. Классификация режимов работы ГТД с использованием технологии нейронных сетей / В.И. Васильев, С.В. Жернаков // *Вестник Уфимского государственного авиационного технического университета*. – 2009. – Т. 12, № 1. – С. 53-56.
- [5] Клячкин, В.Н. Прогнозирование и диагностика стабильности функционирования технических объектов: монография / В.Н. Клячкин, В.Р. Крашенинников, Ю.Е. Кувайскова. – М.: Русайнс, 2020. – 200 с.
- [6] Klyachkin, V.N. Aggregated classifiers for state diagnostics of the technical object / V.N. Klyachkin, J.E. Kuvaysova, D.A. Zhukov // *International Multi-Conference on Industrial Engineering and Modern Technologies*. – 2019. – P. 8934362.
- [7] Klyachkin, V.N. Aggregated Classifiers for State Diagnostics of the Technical Objects International Multi-Conference on Industrial Engineering and Modern Technologies / V.N. Klyachkin, J.E. Kuvaysova, D.A. Zhukov // *FarEastCon*. – 2019. – Vol. 2019. – P. 8934362.
- [8] Zhukov, D.A. Selection of Aggregated Classifiers for the Prediction of the State of Technical Objects / D.A. Zhukov, V.N. Klyachkin, V.R. Krashennnikov, Yu.E. Kuvaysova // *CEUR Workshop Proceedings*. – 2019. – P. 361-365.