

Выбор агрегированных классификаторов при прогнозировании состояния технического объекта

Д.А. Жуков¹, В.Н. Клячкин¹, В.Р. Крашенинников¹, Ю.Е. Кувайскова¹

¹Ульяновский государственный технический университет, Северный Венец 32, Ульяновск, Россия, 432027

Аннотация. В задаче прогнозирования исправности технического объекта по заданным показателям его функционирования исходными данными являются известные результаты оценки состояния объекта по информации о предшествующей эксплуатации. Задача может быть решена методами машинного обучения, она сводится к бинарной классификации состояний объекта. Исследование проводилось в пакете Matlab, использовано десять различных базовых методов машинного обучения: наивный байесовский классификатор, нейронные сети, бэггинг деревьев решений и другие. Для повышения качества распознавания исправного состояния предложено использовать агрегированные методы, объединяющие несколько базовых классификаторов. В работе рассматривается вопрос о выборе наилучшего агрегированного классификатора. Эффективность такого подхода подтверждена численными испытаниями на временных рядах реальных объектов.

1. Введение

Прогнозирование состояния технического объекта возможно с применением различных методов. Наиболее распространен подход, связанный с моделированием реального процесса с помощью систем временных рядов [1-3]. Однако часто задача прогнозирования сводится к разделению состояний объекта на заданном горизонте на исправные, то есть способные выполнять заданные функции, или неисправные. При всех подходах диагностика проводится по результатам эксплуатации объекта по измерениям косвенных показателей его функционирования. Например, исправность двигателя диагностируется по расходу топлива, температуре газов, уровню шума и вибрации, составу выпускных газов, зазору между цилиндром и поршнем, зазору между шейками коленчатого вала и подшипниками и другим показателям [4]. При этом имеется риск ложной тревоги (когда исправный объект будет признан неисправным) или наоборот – пропуска цели, при котором неисправный объект считается исправным.

Исходными данными является известная информация о состоянии объекта по результатам предшествующей эксплуатации: при заданных значениях контролируемых показателей техническая система исправна или неисправна. Предполагается, что существует некоторая неизвестная зависимость между показателями функционирования объекта и его состояниями. На основе исходных данных требуется восстановить эту зависимость, то есть построить алгоритм, способный для заданного набора показателей функционирования объекта выдать достаточно точный ответ о его состоянии. Это задача машинного обучения, или обучения по

прецедентам (с учителем); частным случаем этой задачи является бинарная классификация, т. е. разделение состояний объекта на два класса [5-7].

Для оценки качества построенного алгоритма с точки зрения возможности прогнозирования исходную выборку разбивают на два непересекающихся подмножества. Первое подмножество – это собственно обучающая выборка, с помощью которой и решается задача обучения (которая, как правило, сводится к оценке параметров модели соответствующего алгоритма). Второе подмножество является контрольной (или тестовой) выборкой, не используемой для обучения. По этой части выборки оценивается ошибка прогнозирования, которая и характеризует качество обучения. При использовании кросс-валидации выборка разбивается на N частей (на практике обычно принимают $N = 5$ или $N = 10$). Часть $(N - 1)$ используется для обучения, а оставшаяся – для контроля. Последовательно перебираются все варианты.

Методы машинного обучения активно применяют в самых разных областях деятельности. Используется множество различных подходов к классификации. Это и классические статистические методы (байесовские классификаторы, дискриминантный анализ, логистическая регрессия), и методы, специально ориентированные на машинное обучение (метод опорных векторов, нейронные сети), композиционные методы (бэггинг, бустинг) и др. Проблема состоит в том, что нельзя заранее определить, какой из выбранных методов обеспечит лучшее решение задачи, поэтому часто используется множество различных методов или их комбинации, а решение о применении принимается по результатам исследования функционала качества для контрольной выборки. В работах [8-9] для повышения качества прогнозирования предложен агрегированный подход - использование комбинации нескольких методов классификации. Эти результаты были подтверждены экспериментально и для задач технической диагностики [10-12].

Цель исследования – разработка алгоритмов выбора наилучшего агрегированного классификатора.

2. Использование базовых классификаторов

Наиболее распространенным показателем, который может быть использован для оценки качества бинарной классификации, – доля правильных ответов на контрольной выборке

$$Accuracy = P/N,$$

где P – количество правильно классифицированных объектов контрольной выборки, а N – общий размер контрольной выборки. Чаще используется противоположная характеристика - доля (или процент) ошибок на контрольной выборке.

При несбалансированных классах (когда исправных состояний объекта значительно больше, чем неисправных) доля ошибок не может объективно оценивать качество классификации [14]. Гораздо более информативны точность

$$P = tp/(tp + fp)$$

и полнота

$$R = tp/(tp + fn),$$

где tp – количество правильно классифицированных исправных состояний, fp – количество неправильно классифицированных исправных состояний, fn – количество неправильно классифицированных неисправных состояний. На основе этих двух показателей может быть сформирован единый критерий

$$F = 2PR/(P + R)$$

– это гармоническое среднее точности и полноты (F -мера): чем ближе значение F к единице, тем качество классификации выше.

Функционалом качества также может быть выбрана площадь под ROC-кривой (receiver operating characteristics): AUC (area under the curve) [15]. ROC-кривая образуется, если по оси абсцисс брать значения $fp(c)$, а по оси ординат $tp(c)$, где c - порог. Площадь под ROC-кривой позволяет оценить модель в целом, не привязываясь к конкретному порогу. Критерий AUC-ROC устойчив к несбалансированным классам и может быть интерпретирован как вероятность того, что случайно выбранный объект из класса 1 будет иметь значение вероятности ближе к 1, чем случайно выбранный объект из класса 0.

В качестве примера для численного исследования рассмотрена система управления водоочисткой, по которой известны результаты 348 наблюдений по восьми показателям качества очистки питьевой воды, из которых система находилась в неисправном состоянии в 47 случаях (хотя бы один из показателей качества воды выходил за допустимые пределы). Поскольку разбивка исходных данных на обучающую и контрольную выборки производится случайным образом, испытания повторялись по 50 раз.

Исследование проводилось в пакете Matlab. В таблице 1 приведены усредненные значения F-критерия и площадь под ROC-кривой AUC для тех пяти методов машинного обучения, где эти величины оказались максимальными. Видно, что наилучшие результаты показал бэггинг деревьев решений. Расхождение по F-критерию между наилучшим и наихудшим (0,801 для метода RUSBoost) результатами составило 8,7%, по AUC – 21,5%.

Таблица 1. Меры качества при различных методах классификации.

	F-критерий	AUC
Нейронная сеть	0,836	0,822
Бэггинг деревьев решений	0,871	0,893
Градиентный бустинг	0,860	0,862
AdaBoost	0,852	0,854
Логистическая регрессия	0,844	0,870

3. Агрегированные классификаторы

Агрегированный подход был предложен для решения задач кредитного скоринга [8-9] и позднее применен для диагностики технического состояния систем. В композиционных подходах (бэггинг, бустинг) для построения ансамбля используется один и тот же метод классификации, построенный или на разных подмножествах выборки или ориентированный на компенсацию ошибки предыдущей итерации. Представляет интерес совместное использование *различных* методов классификации, построенных на обучающей выборке. При этом для достижения наилучшего результата надо решить вопросы о том, какие методы обучения использовать, как их объединить, и как принять единое решение об исправности объекта на основе решений отдельных методов?

Воспользуемся полным перебором наборов из H базовых методов. Тогда, например, при $H = 2$ получим три набора: два базовых и один агрегированный; при $H = 3$ наборов уже 7: три базовых, три агрегированных по два базовых и один агрегированный из всех трех базовых методов. Нетрудно видеть, что в общем случае число наборов равно $2^H - 1$. Для формирования единого решения об исправности объекта на основе решений отдельных методов классификации, рассмотрим агрегирование результатов по среднему значению, по медиане, и с помощью процедуры голосования.

Пусть $\hat{P}_K(X_r)$ – вероятность того, что r -й объект исправен, найденная с помощью K -го базового метода, $K = 1, \dots, H$. Тогда при агрегировании по среднему значению:

$$\hat{P}_{AKcp}(X_r) = \frac{\sum_{K=1}^H \hat{P}_K(X_r)}{H},$$

где $\hat{P}_{AKcp}(X_r)$ - вероятность того, что r -й объект исправен.

При агрегировании по медиане вначале следует ранжировать ряд, содержащий результаты базовых методов в наборе. При нечетном числе базовых методов вероятность того, что r -й объект исправен:

$$\hat{P}_{AKmed}(X_r) = \hat{P}_{\frac{H+1}{2}}(X_r).$$

В случае четного числа базовых методов, соответствующая вероятность находится как полусумма результатов срединных значений.

Результат агрегированного метода классификации по голосованию представляет собой среднее значение результатов базовых методов, которые определили исправность объекта с вероятностью, например, не ниже, чем $0,1 (\hat{P}_K(X_r) \geq 0,1)$. В противном случае вероятность того, что r -й объект исправен, считается нулевой.

При этом, поскольку, как уже отмечалось, разбивка исходных данных на обучающую и контрольную выборки производится случайным образом, структуры агрегированных классификаторов оказываются различными, и возникает вопрос, какую структуру предпочесть для принятия окончательного решения об исправности объекта.

Испытания, как и ранее, повторялись по 50 раз. В таблице 2 представлены соответствующие результаты по F-критерию для пяти вариантов каждого типа агрегирования.

Таблица 2. F-критерий при агрегировании.

Структура агрегата	F-критерий
Агрегирование по среднему значению	
GrV+БДР+AB	0,891
GrV+ БДР	0,889
БДР+AB	0,889
МОВ+БДР+AB+LB	0,889
МОВ+БДР	0,879
Агрегирование по медиане	
ДА+МОВ+GrV+БДР+AB+GB+RB	0,892
МОВ+БДР	0,881
МОВ+БДР+AB+RB	0,891
МОВ+БДР+LB	0,888
GrV+БДР	0,887
Агрегирование по голосованию	
НС+МОВ+БДР+AB+RB	0,887
GrV+БДР+AB	0,889
БДР+AB	0,889
GrV+БДР	0,885
МОВ+GrV+БДР+LB+GB+RB	0,887
Обозначения:	
GrV – градиентный бустинг, БДР – бэггинг деревьев решений,	
AB – AdaBoost, МОВ – метод опорных векторов, LB –	
LogitBoost, ДА – дискриминантный анализ, RB – RUSBoost,	
НС – нейронная сеть, GB – GentleBoost	

Заметим, во-первых, что любой из агрегированных методов по F-критерию оказался лучше любого из базовых. Во-вторых, значения F-критерия для агрегированных методов не слишком сильно отличаются друг от друга. Наконец, имеет смысл обратить внимание на то, что лучший из базовых методов – бэггинг деревьев решений – входит в структуру любого из агрегированных классификаторов.

4. Заключение

Для оценки исправности объекта имеет смысл выбрать наиболее простой из агрегированных классификаторов с достаточно большим значением F-критерия: в рассматриваемом примере это агрегирование по среднему значению для бэггинга деревьев решений и AdaBoost, или

бэггинг деревьев решений в сочетании с градиентным бустингом (кроме достаточно высоких значений F-критерия, эти сочетания встречаются в таблице 2 чаще всего).

Рассмотренный подход был использован также (кроме системы управления водоочисткой) при оценке исправности гидроагрегата по уровню вибраций и технологического процесса механической обработки.

5. Литература

- [1] Гаскаров, Д.В. Прогнозирование технического состояния и надежности радиоэлектронной аппаратуры / Д.В. Гаскаров, Т.А. Голинкевич, А.В. Мозгалевский. – М.: Советское радио, 1974. – 224 с.
- [2] Клячкин, В.Н. Прогнозирование состояния технического объекта на основе кусочно-линейных регрессий / В.Н. Клячкин, Д.С. Бубырь // Радиотехника. – 2014. – № 7. – С. 137-140.
- [3] Крашенинников, В.Р. Обновление моделей прогнозирования состояния объектов в виде систем временных рядов и многомерных классификаторов / В.Р. Крашенинников, Ю.Е. Кувайскова, В.Н. Клячкин, Ю.С. Шунина // Вестник компьютерных и информационных технологий. – 2017. – № 6. – С. 11-16. DOI: 10.14489/vkit.2017.06.pp.011-016.
- [4] Биргер, И.А. Техническая диагностика. – М.: Машиностроение, 1978. – 240 с.
- [5] Witten, I.H. Data mining: practical machine learning tools and techniques / I.H. Witten, E. Frank. – San Francisco: Morgan Kaufmann Publishers, 2005. – 525 p.
- [6] Мерков, А.Б. Распознавание образов. Введение в методы статистического обучения. – М.: Едиториал УРСС, 2011. – 256 с.
- [7] Воронина, В.В. Теория и практика машинного обучения: учеб. пособие / В.В. Воронина, А.В. Михеев, Н.Г. Ярушкина, К.В. Святков. – Ульяновск: УлГТУ, 2017. – 290 с.
- [8] Клячкин, В.Н. Система оценки кредитоспособности заемщиков и прогнозирования возврата кредитов / В.Н. Клячкин, Ю.С. Шунина // Вестник компьютерных и информационных технологий. – 2015. – № 11. – С. 45-51. DOI: 10.14489/vkit.2015.11.pp.045-051.
- [9] Шунина, Ю.С. Прогнозирование платежеспособности клиентов банка на основе методов машинного обучения и марковских цепей / Ю.С. Шунина, В.Н. Клячкин // Программные продукты и системы. – 2016. – № 2. – С. 105-112.
- [10] Klyachkin, V.N. The use of aggregate classifiers in technical diagnostics, based on machine learning / V.N. Klyachkin, Yu.E. Kuvayskova, D.A. Zhukov // CEUR Workshop Proceeding. – 2017. – Vol. 1903. – P. 32-35.
- [11] Клячкин, В.Н. Диагностика технического состояния аппаратуры с использованием агрегированных классификаторов / В.Н. Клячкин, Ю.Е. Кувайскова, Д.А. Жуков // Радиотехника. – 2018. – № 6. – С. 46-49.
- [12] Kuvayskova, Y.E. The prediction algorithm of the technical state of an object by means of fuzzy logic inference models // Procedia Engineering. – 2017. – Vol. 201. – P. 767-772.
- [13] Воронцов, К.В. Машинное обучение. Композиция классификаторов [Electronic resource]. – Access mode: <https://yadi.sk/i/FItIu6V0beVmF> (01.11.2018).
- [14] Соколов, Е.А. ФКН ВШЭ. Лекция 4. Линейная классификация [Electronic resource]. – Access mode: <https://github.com/esokolov/ml-course-hse/blob/master/2018-fall/lecture-notes/lecture04-linclass.pdf> (01.11.2018).
- [15] Дьяконов, А.М. AUC ROC (площадь под кривой ошибок) [Electronic resource]. – Access mode: <https://dyakonov.org/2017/07/28/auc-roc-площадь-под-кривой-ошибок/#more-5362> (01.11.2018).

Благодарности

Исследование выполнено при финансовой поддержке РФФИ и Правительства Ульяновской области, проект 18-48-730001.

Selection of aggregated classifiers for the prediction of the state of technical objects

D.A. Zhukov¹, V.N. Klyachkin¹, V.R. Krasheninnikov¹, Yu.E. Kuvayskova¹

¹Ulyanovsk State Technical University, Severny Venets street 32, Ulyanovsk, Russia, 432027

Abstract. The basic data in the problem of the prediction of technical object's state of health based on the known indicators of its operation are the known results of the object state estimation by information about previous service. The problem may be solved using the machine learning methods, it reduces to binary classification of states of the object. The research was conducted in the Matlab environment, ten various basic methods of machine learning were used: naive Bayes classifier, neural networks, bagging of decision trees and others. In order to improve quality of healthy state identification, it has been suggested that aggregated methods combining several basic classifiers should be used. This paper addresses the issue of selection of the best aggregated classifier. The effectiveness of such approach has been confirmed by numerous tests of real-world objects.