

Использование агрегированных классификаторов при технической диагностике на базе машинного обучения

В.Н. Клячкин^а, Ю.Е. Кувайскова^а, Д.А. Жуков^а

^а Ульяновский государственный технический университет, 432027, ул. Северный Венец, 32, Ульяновск, Россия

Аннотация

При решении задач технической диагностики объекта с применением машинного обучения проводится бинарная классификация состояния объекта: объекты подразделяются на исправные и неисправные с помощью моделей, полученным по обучающим выборкам. Качество классификации, которое определяет эффективность машинного обучения, зависит от ряда факторов: объема исходной выборки, метода машинного обучения, способа разделения выборки на обучающую и контрольную части, отбора значимых показателей и других. Иногда целесообразно воспользоваться агрегированными методами классификации, которые представляют собой объединенные результаты базовых методов классификации. Для нахождения наилучшего агрегированного метода используется перебор всевозможных базовых наборов.

Ключевые слова: бинарная классификация; исправное и неисправное состояние; агрегированные методы

1. Введение

Техническая диагностика объекта проводится с целью повышения надежности системы и часто сводится к оценке его исправности [1,2]. Основной задачей является распознавание состояния объекта. Под распознаванием понимают отнесение состояния объекта к одному из классов – диагнозов. Как правило, решение задачи сводится к отнесению объекта к исправным, то есть способным выполнять заданные функции, или неисправным, – это задача бинарной классификации. Важным является выбор параметров, характеризующих состояние системы. Оценка состояния системы проводится в условиях эксплуатации, получение информации обычно затруднено, для принятия решения используются различные методы распознавания. Решение задач технической диагностики также связано с прогнозированием состояния технического объекта [3,4].

Распознавание состояния технического объекта обычно проводится по результатам измерений косвенных показателей функционирования объекта в условиях ограниченной информации. В качестве исходных данных рассматриваются известные результаты оценки состояния системы: при заданных значениях контролируемых показателей техническая система исправна или неисправна. Таким образом, имеется множество объектов (ситуаций) с заданными показателями и множество возможных состояний системы. Существует некоторая неизвестная зависимость между показателями функционирования объекта и его состояниями. Известна конечная совокупность пар «набор показателей, состояние» – исходная выборка данных. На основе этих данных требуется восстановить зависимость, то есть построить алгоритм, способный для любого объекта выдать достаточно точный ответ. При этом всегда имеется риск ложной тревоги или пропуска цели. Это задача машинного обучения, или обучения по прецедентам (с учителем) [5,6].

Для измерения точности классификации вводится функционал качества, в частности, может использоваться средняя ошибка: исходная выборка разбивается на обучающую, по которой строится алгоритм поиска искомой зависимости, и контрольную (тестовую), по которой и оценивается средняя ошибка [7,8].

2. Методы машинного обучения, используемые для бинарной классификации

Методы машинного обучения активно используются в самых разных областях деятельности: распознавании речи, медицинской диагностике, кредитном скоринге и других. С точки зрения технической диагностики машинное обучение сводится к задаче бинарной классификации: по заданному вектору параметров объекта требуется определить, к какому состоянию (исправному или неисправному) относится объект.

Для решения задач технической диагностики используются методы обучения с учителем. К ним относятся байесовский классификатор, метод ближайших соседей, нейронная сеть, логистическая регрессия, дискриминантный анализ, метод опорных векторов, деревья принятия решений и другие.

Задача классификации технического объекта решается по следующему принципу: объект считается исправным $Y = 1$, если модель спрогнозировала вероятность $P\{Y = 1 | X\} > 0,5$, и неисправным $Y = 0$ – в противном случае. При этом в качестве граничного значения может быть использовано число, отличное от 0,5.

Например, при использовании логистической регрессии делается предположение о том, что вероятность исправного состояния объекта $Y = 1$ равна:

$$P\{Y = 1 | X\} = f(z),$$

$$z = q_0 + q_1 x_1 + \dots + q_n x_n, \quad (1)$$

где q_0, \dots, q_n – параметры модели (1), $f(z)$ – логистическая функция:

$$f(z) = \frac{1}{1 + e^{-z}}. \quad (2)$$

Поскольку переменная Y принимает одно из пары значений (0,1), то вероятность неисправного состояния $Y = 0$ равна:

$$P\{Y = 0 | X\} = 1 - f(z). \quad (3)$$

Таким образом, логистическая регрессия находится на основе следующего выражения:

$$\log \frac{P\{Y = 1 | X\}}{P\{Y = 0 | X\}} = \frac{f(z)}{1 - f(z)} = q_0 + q_1 x_1 + \dots + q_n x_n. \quad (4)$$

Для нахождения параметров q_0, \dots, q_n , как правило, применим метод максимального правдоподобия, который сводится к максимизации функции правдоподобия с помощью метода градиентного спуска, метода Ньютона-Рафсона или других методов.

С течением времени, при получении новых данных, найденные параметры могут устаревать. Для их обновления могут быть использованы различные процедуры, например, основанные на использовании псевдоградиента [9].

Недостатком логистической модели является чувствительность к корреляции между факторами, поэтому в модели недопустимо наличие сильно коррелированных входных переменных. К преимуществам модели можно отнести учет ограничения на значения вероятности, которые не могут выходить за рамки 0 и 1, возможность проведения исследования и взвешивания факторов, влияющих на результат.

При использовании другой широко распространенной модели – дискриминантного анализа – для определения принадлежности объекта к одному из m классов используют линейные дискриминантные функции:

$$\begin{aligned} o_1(x) &= q_0^1 + q_1^1 x_1 + \dots + q_n^1 x_n, \\ o_2(x) &= q_0^2 + q_1^2 x_1 + \dots + q_n^2 x_n, \\ &\dots \\ o_m(x) &= q_0^m + q_1^m x_1 + \dots + q_n^m x_n, \end{aligned} \quad (5)$$

где $o(x)$ – «счет», согласно которому определяется тот или иной класс. В итоге выбирается тот класс, которому соответствует больший счет. Параметры модели оцениваются с использованием обучающей выборки. В случае двух классов результат совпадает с результатом линейной регрессии.

Проблема состоит в том, что нельзя заранее сказать, какой из этих методов обеспечит корректное решение задачи, поэтому часто используется множество различных методов или их комбинации, а решение о применении принимается по результатам исследования функционала качества для контрольной выборки.

3. Агрегированные методы

Представляет интерес совместное использование нескольких методов (их агрегирование) с целью компенсировать недостатки одних моделей при помощи других, что способствует повышению точности прогнозирования. Рассмотрим следующий набор, например, из семи базовых моделей [10,11]: нейронная сеть, логистическая регрессия, дискриминантный анализ, байесовский классификатор, метод опорных векторов, деревья решений и бэггинг деревьев.

Составим всевозможные комбинации базовых моделей, состоящих их двух, трех и т.д. моделей. В случае семи моделей общее количество различных комбинаций, начиная с двух и заканчивая всеми семью моделями, составит: $C_7^2 + C_7^3 + C_7^4 + C_7^5 + C_7^6 + C_7^7 = 120$ моделей. Пусть Y_j^m – результат оценки исправности j -го объекта, найденный с помощью m -ой базовой модели, причем $j = 1, \dots, l$ и $m = 1, \dots, M$, где M – количество базовых моделей в комбинации. Тогда рассмотрим следующие способы агрегирования (объединения) результатов базовых моделей.

3.1. Агрегирование по среднему значению

В этом случае

$$Y_j^{AK_mean} = \frac{\sum_{m=1}^M Y_j^m}{M}, \quad (6)$$

где $Y_j^{AK_mean}$ – результат агрегированного классификатора по среднему значению.

3.2. Агрегирование по медиане

Для начала следует ранжировать ряд, содержащий результаты базовых моделей в комбинации Y_j^m . В случае нечетного числа базовых моделей:

$$Y_j^{AK_median} = Y_j^{\frac{M+1}{2}}, \quad (7)$$

где $Y_j^{AK_median}$ – результат агрегированного классификатора по медиане.

3.3. Агрегирование по голосованию

Работает по следующему принципу: если большинство моделей определило объект как исправный, то результат агрегированного классификатора представляет собой среднее значение результатов моделей, проголосовавших за исправный класс. В противном случае – объект неисправен ($Y = 0$).

4. Оценка качества диагностики

Точность классификации оценивается с помощью функционала качества, в частности, может использоваться средняя ошибка классификации по контрольной выборке.

Когда результаты классификации представляются в виде вероятности принадлежности объекта к классу исправных или неисправных, для оценки качества методов можно найти дисперсию ошибки σ^2 , которая показывает отклонение прогнозируемых значений от реальных:

$$\sigma^2 = \frac{1}{l} \sum_{r=1}^l (P(Y_r) - \hat{P}(X_r))^2, \quad (8)$$

где $P(Y_r)$ – фактическая вероятность принадлежности к классу исправности r -го объекта ($P(Y_r) = 0$, если объект неисправен или $P(Y_r) = 1$ при исправности объекта), $\hat{P}(X_r)$ – прогнозируемая вероятность принадлежности к классу исправности r -го объекта, l – количество объектов.

Функционал качества в значительной мере зависит от того, каким образом была сформирована контрольная выборка. При необходимости возможна проверка влияния способа формирования этой выборки на дисперсию ошибок.

В целях оптимизации диагностики функционирования технического объекта предлагается алгоритм прогнозирования исправности его состояния, который заключается в использовании комбинаций моделей машинного обучения и формировании оптимального решения на их основе. Основные этапы алгоритма:

1. Формирование и предварительная обработка исходных данных с разбивкой данных на обучающую и контрольную выборки.
2. Построение на обучающей выборке базовых моделей классификации.
3. Построение на этой же обучающей выборке дополнительно к базовым моделям всех возможных комбинаций моделей с агрегированием тремя рассмотренными методами.
4. На контрольной выборке с помощью всех построенных моделей прогнозируется исправность новых (контрольных) объектов.
5. Для каждой модели или комбинации моделей рассчитывается среднеквадратичная ошибка прогнозирования и выбирается наилучшая модель, обеспечивающую минимум этой ошибки.

5. Результаты и обсуждение

Численное исследование проводилось на примере функционирования станции водоочистки Санкт-Петербургского водоканала [12]. Контролировались параметры водоисточника и дозы реагентов, используемых при очистке. Как неисправность системы рассматривался выход за допустимые пределы хотя бы одного из показателей качества питьевой воды. Исходная выборка данных разбивалась на обучающую и контрольную (объемом 10% от исходной) случайным образом. Из семи базовых методов бинарной классификации, указанных выше, наилучшие результаты

показал метод опорных векторов; средняя ошибка классификации оказалась равной 0,238. При этом агрегирование по среднему значению дало ошибку 0,196 (сочетание метода опорных векторов с дискриминантным анализом и нейронными сетями). При использовании отбора значимых параметров методом пошаговой регрессии результаты несколько ухудшились, но и при этом минимальным оказалось значение средней ошибки при агрегировании и составило 0,207. Изменился и набор базовых классификаторов: к трем перечисленным выше добавилась логистическая регрессия.

Качество классификации определяется объемом исходной выборки, выбранным методом машинного обучения (одним из базовых или агрегированных), способом разделения исходной выборки на обучающую и контрольную (используется случайный отбор, или в качестве контрольной выборки принимается определенная часть исходной; иногда целесообразна процедура скользящего экзамена, очевидно, играет роль и объем контрольной выборки), методом отбора значимых показателей (например, с использованием пошаговой регрессии) и рядом других факторов.

Для обеспечения эффективности машинного обучения при диагностике технического объекта необходима разработка системы для исследования влияния этих факторов на качество классификации при исходных данных для конкретного объекта, которая обеспечила бы применение оптимальных подходов.

6. Заключение

Проведенное исследование показало, что методы машинного обучения могут быть использованы при решении основной задачи технической диагностики – распознавании исправности состояния рассматриваемого объекта. При этом возможен ряд проблем, связанных с формированием исходной выборки достаточно большого объема, с разбивкой этой выборки на обучающую и контрольную части, с оценкой эффективности применения того или иного метода, с возможностью использования агрегированных классификаторов.

Благодарности

Исследование выполнено при финансовой поддержке РФФИ, проекты №16-48-732002 и №16-38-00211мол_а.

Литература

- [1] Биргер, И. А. Техническая диагностика / И. А. Биргер – М.: Машиностроение, 1978. – 240 с.
- [2] Жуков, Д.А. Задачи обеспечения эффективности машинного обучения при диагностике технических объектов / Д.А.Жуков, В.Н.Клячкин // Современные проблемы проектирования, производства и эксплуатации радиотехнических систем. – 2016. – № 1 (10). – С. 172-174.
- [3] Клячкин, В.Н. Прогнозирование состояния технического объекта на основе кусочно-линейных регрессий / В.Н. Клячкин, Д.С. Бубырь // Радиотехника, 2014. №7. – С. 137-140.
- [4] Клячкин, В.Н. Прогнозирование состояния объекта с использованием систем временных рядов / В.Н. Клячкин, Ю.Е. Кувайскова, Д.С. Бубырь // Радиотехника, 2015. №6. – С. 45-47.
- [5] Witten, I. H. Data mining : practical machine learning tools and techniques / Ian H.Witten, Eibe Frank. – 2nd ed. – San Francisco: Morgan Kaufmann Publishers, 2005. – 525p.
- [6] Мерков, А. Б. Распознавание образов. Введение в методы статистического обучения / А.Б. Мерков – М.: Едиториал УРСС, 2011. – 256 с.
- [7] Клячкин, В.Н. Статистические методы анализа данных / В.Н. Клячкин, Ю.Е. Кувайскова, В.А. Алексеева. – М. : Финансы и статистика, 2016. – 240 с.
- [8] Клячкин, В.Н. Применение методов машинного обучения при решении задач технической диагностики / В.Н.Клячкин, И.Н. Карпунина, Ю.Е.Кувайскова, А.С.Хорева // Научный вестник УВАУ ГА(И). – 2016. – Т. 8. – С. 158-161.
- [9] Крашенинников, В.Р. Обновление агрегированных классификаторов на основе псевдоградиентной процедуры / В.Р. Крашенинников, В.Н. Клячкин, Ю.С. Шунина// Вестник компьютерных и информационных технологий. – 2016. – № 10 (148). – С. 36-40.
- [10] 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.
- [11] Шунина, Ю.С. Прогнозирование кредитоспособности клиентов банка на основе методов машинного обучения / Ю.С. Шунина, В.А. Алексеева, В.Н. Клячкин // Финансы и кредит. –2015.–№ 27 (651). – С. 2-12.
- [12] Кувайскова, Ю.Е. Прогнозирование состояния источника водоснабжения в целях обеспечения качества воды / Ю.Е. Кувайскова, Е.М. Бульжев, В.Н. Клячкин, Д.С. Бубырь // Справочник. Инженерный журнал с приложением. – 2016. – №5. – С.37-42.