

УДК 681.518.5: 004.891.3

Т. П. Становская, к. т. н., доц.;

М. В. Закусило, асп.

ИНТЕЛЛЕКТУАЛИЗАЦИЯ МЕТОДА ФАЗОВОГО ИНТЕРВАЛА

Представлена возможность усовершенствования метода фазового интервала при выполнении технической диагностики. Отмечены и устранены недостатки метода фазового интервала путем введения неметрического диагностического пространства с настраиваемым отображением. Рассмотрен алгоритм работы соответствующей обучаемой системы диагностики. Выполнены эксперименты, подтверждающие способность системы к обучению, позволяющие определить скорость обучения системы, качество диагностики и необходимое для обучения время.

В современных условиях, когда количество и функциональность узлов технических систем резко увеличивается, становится невозможным сведение технической диагностики к предопределенному набору формальных проверок, как в случае классического тестирования цифровых устройств. Еще в то время, когда тестирование логических схем на всех возможных наборах входных сигналов было фактически единственным подходом к диагностике [1], выдвигалась идея о том, что система должна быть способна к самодиагностике. Это объясняется тем, что в условиях изменяющейся среды функционирования именно система претерпевает смену состояний и имеет возможность максимально быстро регистрировать эти изменения. Для современных сложных систем ситуация оказывается еще более сложной в силу действия случайных (непредвиденных) факторов. В результате система технической диагностики подобно медицинской диагностике [2] функционирует в условиях неполной и неточной информации при наличии большого числа разнородных параметров, влияющих на диагноз, в которых трудно построить явную аналитическую зависимость между диагнозом и определяющими его параметрами. При этом к системе предъявляются требования обучаемости и адаптации.

Учитывая, что цели технической и медицинской диагностики отличаются фактически лишь объектом диагностики, а сложность технических систем непрерывно увеличивается, неудивительным становится явление взаимного заимствования методов из медицины и кибернетики [3]. В основе предлагаемого в данной работе метода диагностики лежат идеи метода фазового интервала, который некогда пользовался популярностью в системах медицинской диагностики [2, 3]. В работе сделана попытка преодоления ограничений и недостатков названного метода и расширения его возможностей, используя некоторые идеи искусственного интеллекта [4] и обучения с подкреплением [5].

Существуют три основных подхода к задаче медицинской диагностики: вероятностный, детерминистский и логический [2, 3, 6]. Метод фазового интервала относится к группе детерминистских методов. При использовании детерминистских методов задачу удобно формулировать геометрически. Так, в случае метода фазового интервала система характеризуется n -мерным вектором X и любое состояние системы представляет собой точку в n -мерном пространстве параметров (признаков, симптомов). Области диагнозов считаются непересекающимися. В этом случае, если вероятность одного диагноза равна единице, то вероятность других равна нулю. Отнести состояние системы к тому или иному диагнозу – значит найти наименьшее расстояние от соответствующей точки пространства признаков до одного из центров областей, соответствующих различным диагнозам.

К достоинствам данного метода можно отнести простоту, наглядность, отсутствие необходимости хранения больших массивов статистических данных, а также высокую скорость обработки данных.

Однако можно отметить следующие недостатки метода фазового интервала. Для определения расстояния в фазовом пространстве чаще всего используют декартово расстояние и расстояние по Хеммингу. Встречаются также случаи использования расстояния более высоких степеней, диагностики по угловому расстоянию и др. Однако нам не удалось найти сколько-нибудь обоснованного способа выбора того или иного из перечисленных типов в зависимости от условий конкретной

задачи (например, объекта диагностики). Таким образом, один из недостатков метода заключается в недостаточной обоснованности выбора метрики, которая в общем случае может не учитывать некоторых особенностей фазового пространства.

В случае, если центр одной из областей попадает в другую область, в окрестности центра области диагностика будет выполнена неверно. Еще более опасная ситуация возникает, если центры двух или нескольких областей совпадают или располагаются слишком близко.

Существенным ограничением метода фазового интервала является отсутствие возможности обучения и повышения качества диагностики при пополнении истории болезни правильными диагнозами, полученными и проверенными в процессе эксплуатации системы диагностики. Точнее, такая возможность в принципе есть, но при этом с каждым добавляемым в систему эталоном увеличиваются необходимые для диагностики ресурсы: объем памяти и время обработки. Даже в случае добавления новых эталонов в методе не предусмотрен отбор такого множества эталонов, который бы представлял имеющиеся диагнозы наиболее адекватно.

В предлагаемом нами методе используется неметрическое пространство. Пусть M — пространство вещественных признаков (которыми можно выразить и бинарные признаки). Тогда диагностическое пространство представляет собой декартово произведение $M \times M$, на котором задается отображение $\rho : M \times M \rightarrow R$. Значение ρ для каждой точки $\langle m_1, m_2 \rangle$ диагностического пространства определяется следующими условиями:

- 1) $0 \leq |\rho| \leq 1$ и тем больше, чем больше уверенность системы в том, что точки пространства признаков m_1 и m_2 соответствуют одному или разным диагнозам в зависимости от знака ρ ;
- 2) $\rho > 0$, тогда и только тогда, когда точки m_1 и m_2 соответствуют одному диагнозу;
- 3) $\rho < 0$ тогда и только тогда, когда точки m_1 и m_2 соответствуют разным диагнозам.

Действительно, введенное диагностическое пространство не является метрическим пространством $\langle M, \rho \rangle$ поскольку из условий (1) выполняется лишь второе.

- 1) $\rho(x, y) \geq 0$ и $\rho(x, y) = 0 \Leftrightarrow x = y$;
 - 2) $\rho(x, y) = \rho(y, x)$;
 - 3) $\rho(x, y) \leq \rho(x, z) + \rho(z, y)$.
- (1)

Мощность введенного диагностического пространства соответствует метрическому пространству метода фазового интервала, однако сложность вычисления отображения $M \times M \rightarrow R$ несравнимо большая. В методе фазового интервала для вычисления метрики используется несложная функция, одна из приведенных выше. Реализация же предлагаемого метода предполагает некоторую аппроксимацию функции-отображения.

Аппроксимация функции-отображения является примером обучения с учителем и является одним из основных вопросов, рассматриваемых в таких областях как машинное обучение, искусственные нейронные сети, распознавание образов, обучение с подкреплением и др. [4, 5, 7, 8]. В принципе любой из методов, рассматриваемых этими науками, может использоваться для аппроксимации диагностического пространства. В случае большой размерности векторов состояний особое значение приобретают методы аппроксимации, сложность которых зависит не столько от размерности этих векторов, сколько от сложности самой представляемой функции. Один из подходов, используемых для такой аппроксимации, основан на принципе категоризации [9].

Введенное выше отображение позволяет для любой точки X пространства признаков определить диагноз, которому она соответствует (при условии адекватных оценок ρ и достаточной точности аппроксимации). Для каждого диагноза A_i выбираются n точек, d_j соответствующих эталонам этого диагноза (если система полностью обучена, то достаточно одной точки). Оценки $\rho(X, d_j)$ объединяются в простейшем случае как среднее

$$\bar{\rho}_i = \frac{1}{n} \sum_{j=1}^n \rho(X, d_j), \quad (2)$$

которое показывает насколько система уверена в том что состояние X относится ($\bar{\rho}_i > 0$) или не относится ($\bar{\rho}_i < 0$) к диагнозу A_i . На ранних этапах обучения, когда отображение содержит большое количество неверных оценок, целесообразным может быть вычисление объединенной оценки

как среднего лишь тех значений $\rho(X, d_j)$, только положительных или только отрицательных, которых больше среди всех оценок, относящихся к текущему диагнозу A_i . Это объясняется тем, что вероятность ошибки нескольких свидетельств уменьшается с увеличением их количества. Со временем при увеличении качества отображения можно уменьшать значение n и переходить к более простому объединению оценок по формуле (2).

В качестве результата диагностики выбирается тот диагноз A_i , для которого $\bar{\rho}_i = \max_{k=1,m} \bar{\rho}_k$. Это справедливо и в тех редких случаях, когда все средние значения отрицательны (на основании отдельных оценок состояние не может быть отнесено ни к одному из диагнозов), либо все средние значения положительны (на основании отдельных оценок состояние относится ко всем диагнозам).

Опишем работу алгоритма (здесь целиком не приводится). Целью обучения системы является построение адекватного отображения, позволяющего проводить диагностику по описанной в предыдущем разделе схеме с достаточной степенью достоверности. В начале обучения значения ρ близки к нулю во всех точках диагностического пространства за исключением $\langle m_1, m_2 \rangle$, где m_1 и m_2 – некоторые эталоны диагнозов. В точках $\langle m_1, m_2 \rangle$ значение ρ близко к 1 (если m_1 и m_2 соответствуют одному диагнозу) или -1 (если m_1 и m_2 соответствуют разным диагнозам). В процессе обучения абсолютная величина ρ стремится к единице во всех точках диагностического пространства, при этом адекватность отображения повышается.

В главном цикле периодически выполняются три основные действия:

- 1) определение принадлежности произвольно выбранной точки пространства признаков одному из диагнозов и соответствующей уверенности на основании объединения множества оценок;
- 2) подкрепление оценок для текущего множества эталонов;
- 3) обновление множества эталонов.

Первое действие направлено на расширение области адекватных оценок ρ на основании уже имеющейся информации и выполняется на каждой итерации главного цикла. Второе действие выполняется значительно реже. Оно используется для подкрепления оценок, выведенных на основании текущего множества эталонов, чтобы предотвратить искажение этих оценок в процессе обучения. Эти подкрепления служат источником верной информации, распространяющейся в диагностическом пространстве. Обновление множества эталонов необходимо для получения новой информации, которая постепенно добавляется в систему в результате выполнения предыдущих двух действий.

Источник информации для обновления множества эталонов, вообще говоря, может иметь различную природу. Это может быть, например, информация из взятой для обучения истории болезни с правильно поставленными диагнозами, т. к. занести все диагнозы в виде множества эталонов сразу может быть невозможно в силу большой вычислительной сложности $O(n^2)$, где n — количество эталонов. Однако информация, поданная частями, будет усвоена за приемлемое время. Для обновления множества эталонов могут также использоваться диагнозы, полученные во время функционирования системы диагностики и правильность которых была со временем подтверждена. Если провести нескромное сравнение предлагаемой системы диагностики с живым существом, то ядро системы — аппроксиматор многомерной функции, соответствует долговременной памяти, а множество эталонов — кратковременной. При этом удачный выбор объема множества эталонов, качества аппроксимации и скорости обработки данных приводит к наилучшему качеству обучения.

Подкрепление основано на следующей априорной информации:

1) эталоны, принадлежащие одному диагнозу, всегда образуют точку диагностического пространства, отображаемую в значение 1;

2) эталоны, принадлежащие разным диагнозам, всегда образуют точку диагностического простран-




Рис. 1. График, определяющий динамику обучения системы

тва, отображаемую в значение -1 ;

3) любая точка X пространства признаков всегда соответствует некоторому диагнозу, поэтому $\langle X, X \rangle$ отображается в значение 1 .

Обновление множества эталонов заключается в следующем. Выбирается (желательно случайно) точка X пространства признаков. На основании априорной информации устанавливаются значения ρ для всех пар, образованных этой точкой и всеми эталонами, а также для пары $\langle X, X \rangle$. Кроме того, верная информация о принадлежности точки X ее диагнозу позволяет вывести динамику обучения системы благодаря вычислению выходных параметров amount (общее количество предъявленных системе состояний для диагностики) и right (количество правильно установленных диагнозов обучаемой системой).

С целью облегчения вычислений и обеспечения наглядности в эксперименте использовалось двухмерное пространство признаков. Каждому диагнозу соответствуют точки одного цвета. График математического ожидания значения right, характеризующий процесс обучения в общем случае, был построен на основании 100 экспериментов (рис. 1).

По горизонтальной оси отложено значение amount, по вертикальной — математическое ожидание количества правильных диагнозов M . На данный момент усредненные точки соединены прямыми линиями. Очевидно, что скорость увеличения значения M , не может быть меньше 0 (значение right сохраняется неизменным) и больше 1 (наклон графика равен 45° – система работает без ошибок).

Приближенный график скорости увеличения роста значения right был построен путем последовательного отложения по вертикальной оси значений $\text{right}(i) - \text{right}(i - 1)$ для всех $i = 0 \dots 999$ (рис. 2). Действительно, эти значения образуют тангенс угла наклона соответствующего участка графика зависимости right и приближенно равны значению производной на этом участке.




Рис. 2. График скорости увеличения количества правильных ответов, построенный по экспериментальным данным




Рис. 3. Сглаженный график скорости

На рис. 3 представлен график скорости увеличения количества правильных ответов, сглаженный с помощью алгоритма «бегущих медиан» [10] для устранения высокочастотной составляющей, соответствующей случайным осцилляциям.

Было сделано предположение, что это ускорение уменьшается по экспоненциальному закону. Это предположение было подтверждено экспериментально с большой точностью. Динамика обучения системы описывается зависимостью

$$\text{right}(x) = v_0 x - \frac{A}{B^x \ln^2(B)} + \frac{Ax}{\ln(B)} - \frac{A}{\ln^2(B)}. \quad (3)$$

Регрессия исходных данных с помощью зависимости (3) дала следующие результаты. Среднее значение невязки составило $0,917$, а дисперсия — $0,402$. Значения v_0 , A и B равны соответственно $0,18 \cdot 10^{-2}$; $1,003$ и $0,31$. На основании этих данных можно построить зависимости $v(x)$ и $a(x)$ более точные, чем приведенные выше.

Выводы

Таким образом, предложенный метод технической диагностики обеспечивает возможность обучения при поступлении новой информации. Учитывая, что скорость обучения неизбежно уменьшается со временем, решающую роль в процессе обучения играет не столько количество эталонов,

існуючих на даний момент, і складність пространства признаков, определяющие начальную скорость обучения, сколько способность сохранять скорость обучения. Эта способность определяется прежде всего качеством новой поступающей информации и способностью к обобщению при построении отображения, используя уже полученные верные оценки ρ .

Експериментально были получены зависимости для скорости обучения системы диагностики и скорости увеличения количества правильных диагнозов и найдены их аналитические аналоги, которые могут использоваться для принятия решения о продолжительности обучения. Действительно, выполнение нескольких непродолжительных процессов обучения с последующей регрессией полученных данных с помощью функции (3) может быть значительно эффективнее регулярного тестирования системы после некоторого количества обучающих итераций.

Предложенный метод особенно эффективен для проведения именно технической диагностики в силу того, что по своей природе необходимые для этого параметры являются количественными и/или бинарными.

Особое значение для практического использования предложенного метода имеют дальнейшие исследования, связанные с эффективной аппроксимацией многомерной функции отображения в режиме on-line для качественного представления отображения диагностического пространства и обобщением данных, необходимым для наилучшего использования поступающей в систему информации. Исходя из того, что экспериментально проверенная аналитическая зависимость для скорости обучения отлично отражает реальный процесс для случайно выбранного объекта диагностики (пространства признаков), можно предположить, что улучшения предложенного метода с использованием результатов указанных исследований могут уменьшить кривизну графика скорости обучения, но не изменить его характер.

СПИСОК ЛІТЕРАТУРИ

1. Мэннинг Е. Г., Чжен Г. Я. и др. Диагностика отказов цифровых вычислительных систем: Пер. с англ. Под ред. Михайлова И. Б. — М.: Мир, 1972. — 232 с.
2. Степанова М. Д., Самодумкин С. А. Прикладные интеллектуальные системы в области медицины: Учебно-методическое пособие. — Мн.: БГУИР, 2000.
3. Мельников В. Г. Медицинская кибернетика. Под редакцией Мисюренко И. В. — Харьков: :Полиграфкнига, 1978, 112 с.
4. Люгер Джордж Ф. Искусственный интеллект: стратегии и методы решения сложных проблем. 4-е издание: Пер. с англ. — М.: Изд. дом «Вильямс», 2003. — 864 с.
5. Sutton R. S., Barto A. G. Reinforcement Learning: an introduction / MIT Press, Cambridge, MA, 1998
6. Гублер Е. В. Вычислительные методы распознавания патологических процессов. — Л.: Медицина, 1980, 342 с.
7. Теслер Г. С. Обобщенные адаптивные аппроксимации функций // Математические машины и системы. — 1998. — № 2. — С. 3—8
8. Колесников А. А. Синергетическая теория управления. — М.: Энергоатомиздат, 1994.
9. Josep M Porta, Enric Celaya. Reinforcement Learning for Agents with Many Sensors and Actuators Acting in Categorizable Environments // IEEE Journal of Artificial Intelligence Research. — March 2005. — N. 23. — P. 79—122.
10. Белашов В. Ю., Чернова Н. М. Эффективные алгоритмы и программы вычислительной математики. — Магадан: СВКНИИ ДВО РАН, 1997. — 160 с.

Становская Татьяна Павловна — преподаватель, **Закусило Михаил Викторович** — аспирант.

Кафедра систем автоматизированного проектирования, Одесская государственная академия холода