

ЛИТЕРАТУРА

1. А. с. 1389138. Способ взрывной высокотемпературной обработки материалов в вакууме и установка для его осуществления / Г. В. Смирнов, В. В. Зубарь, И. В. Петров. – 1988.
2. Петров И. В., Смирнов Г. В., Коморный А. А. Ударно-волновая консолидация микропорошков сверхтвердых и алмазоподобных композиционных материалов // Слоистые композиционные материалы. – Волгоград, 2001. – С. 266–269.
3. Деформационные изменения в структуре $\text{Si}_3\text{N}_4\text{--SiC}$ / В. Н. Ковалевский, А. В. Ковалевская, Л. Ф. Керженцева, И. В. Фомихина, А. Е. Жук // Новые материалы и технологии в металлургии и машиностроении. – Запорожье, 1998. – № 2. – С. 79–86.
4. Urbanovich V. S., Shipilo V. B. Physicomechanical and thermophysical properties of high melting compounds: Based ceramics sintered at High pressures / Kee Engineering Materials. Vol. 132–136 (1977), Trans Tech Publications, Switzerland, Pt. 2. – P. 1027–1030.
5. Ковалевский В. Н., Керженцева Л. Ф., Парфененко И. А. Получение керамических материалов импульсными методами нагружения // Материалы 54-й междунауч. технич. конференции «Материалы, технология получения, обработка». – Мн., 2000. – С. 158.
6. Ковалевская А. В., Керженцева Л. Ф., Жук А. Е. Возможности получения высокоплотной керамики и порошков $\text{Si}_3\text{N}_4\text{--SiC}$, полученных СВС-методом // Порошковая металлургия. – 1992. – № 16. – С. 43–45.

УДК 681.518

ПРОЦЕДУРА САМООБУЧЕНИЯ ИНТЕЛЛЕКТУАЛЬНОЙ ДИАГНОСТИЧЕСКОЙ СИСТЕМЫ НА ОСНОВЕ СЛЕДЯЩЕГО ДИСПЕРСИОННОГО АНАЛИЗА

Канд. техн. наук, доц. ПАШКЕВИЧ В. М.

Белорусский национальный технический университет

В процессе диагностики одной из основных является задача классификации, т. е. разделения множества исходных данных на однородные подмножества (классы состояний). Критерии такого разделения далеко не всегда точно и непосредственно формализованы. Как правило, это верно для сложных объектов, выходные параметры которых могут быть подвержены недетерминированному дрейфу. Алгоритмы же классификации таких объектов в большей или меньшей степени эвристичны и могут строиться на принципах искусственного интеллекта.

Эти трудности применительно к сложным объектам возможно преодолеть, используя приводимое ниже описание адаптивной процедуры, учитывающей изменение во времени статистических взаимосвязей между входными данными.

Обучение диагностической системы заключается в построении базы входных данных в процессе нормального функционирования механизма. При этом ведется пометка входных данных моментами времени. В качестве первоначального

образца для инициализации процедуры классификации используется один механизм (пилотный образец), эксплуатируемый до момента его выхода из строя при форсированных режимах (либо при нагрузке, многократно превышающей нормальную, либо при добавлении в смазку абразива и т. п.). Полученные при этом пилотные данные будут корректироваться системой в ходе нормальной эксплуатации других механизмов. При этом на самых ранних этапах система может использоваться для диагностики. Принципиально возможны также отсутствие пилотного образца и использование системы для диагностики объектов в процессе их нормальной эксплуатации. Однако в этом случае процедура самообучения становится чрезвычайно длительной, а результаты использования системы могут быть долгое время неудовлетворительными.

На первом этапе в результате анализа пилотных данных системой определяются различающие признаки в совокупности исходных данных, а также возможное (различимое) число состояний объекта. В процессе эксплуатации объекта

пилота вектор входных (инструментальных) данных $X = \{X_1, X_2, \dots, X_N\}$ снимается через определенные (равные или неравные) промежутки времени с дублированием (в количестве m) в каждый момент времени (общим числом n). Будем называть каждый момент времени i уровнем изменения данных X .

На каждом уровне для каждого признака X_k из совокупности X должны быть определены ошибка наблюдений, связанная с наличием собственных шумов сложного объекта $S_{\text{ош } i}^2$, и общая ошибка $S_{\text{ош}}^2$ (для удобства индекс k для k -го признака X_k опущен):

$$S_{\text{ош } i}^2 = \sum_{j=1}^m (x_{ij} - \bar{x}_i)^2;$$

$$S_{\text{ош}}^2 = \sum_{i=1}^n S_{\text{ош } i}^2,$$

где x_{ij} – значение признака X_k на уровне i (дубли j); $\bar{x}_i$ – среднее значение признака X_k на уровне i :

$$\bar{x}_i = \frac{1}{m} \sum_{j=1}^m x_{ij}.$$

Далее на каждом уровне рассчитывается общая сумма квадратов отклонений наблюдений x_{ij} от общего среднего:

$$S_0^2 = \sum_{i=1}^n \sum_{j=1}^m (x_{ij} - \bar{X})^2;$$

$$\bar{X} = \frac{1}{mn} \sum_{i=1}^n \sum_{j=1}^m x_{ij}.$$

Располагая значениями S_0^2 и $S_{\text{ош}}^2$, можно определить сумму квадратов S_x^2 , характеризующую неслучайную, детерминированную долю изменчивости признака X_k , т. е.

$$S_x^2 = S_0^2 - S_{\text{ош}}^2 = m \sum_{i=1}^n (\bar{x}_i - \bar{X})^2.$$

Таким образом, с точностью до систематической погрешности наблюдений признак X_k можно считать статистически значимо влияющим на определение состояния объекта (т. е. различающим), если выполняется условие

$$\frac{S_x^2 / f_x}{S_{\text{ош}}^2 / f_{\text{ош}}} > F_{\alpha; f_x; f_{\text{ош}}},$$

где $f_x = n - 1$ – число степеней свободы суммы квадратов S_x^2 ; $f_{\text{ош}} = n(m - 1)$ – то же $S_{\text{ош}}^2$;

$F_{\alpha; f_x; f_{\text{ош}}}$ – критерий Фишера для заранее выбранного уровня значимости α и степеней свободы f_x и $f_{\text{ош}}$.

Описанная процедура позволяет сократить размерность вектора входных данных X за счет исключения из его состава неразличающих признаков, т. е. признаков, изменчивость которых в процессе эксплуатации пилотного объекта характеризуется только собственными шумами (случайными отклонениями). Для полученного в результате вектора различающих признаков

$$X^0 = \{X_1^0, X_2^0, \dots, X_{N_0}^0\}$$

можно определить возможное число различаемых состояний объекта для всех различающих признаков X_R^0 .

Очевидно, состояния X_1^0 и X_2^0 отличаются в том случае, если расстояние между ними превышает размеры поля ошибки наблюдений. Таким образом, с доверительной вероятностью $p = 1 - \alpha$ число различаемых состояний для признака X_R^0 равно

$$K_R = \text{Int} \left[\frac{(\bar{X}^{\max} - \bar{X}^{\min})(mn - 1)}{2U(p)S_0} \right],$$

где Int – оператор целой части числа; $U(p)$ – значение одностороннего квантиля распределения Гаусса для доверительной вероятности p ; $\bar{X}^{\max}$ и $\bar{X}^{\min}$ – максимальное и минимальное средние значения признака X_R^0 для всех уровней изменения.

Число состояний объекта K^0 может при этом задаваться оператором из диапазона $2 \dots X_R^{\max}$ либо выбираться как среднее из совокупности K_R . При этом исключаются из рассмотрения признаки, для которых

$$K_R < K^0.$$

На следующем этапе для сформированной на основе пилотных данных классификационной модели происходит ее уточнение в режиме нормальной эксплуатации нового механизма. Этот этап базируется на очевидном свойстве реальных механизмов, заключающемся в следующем. По окончании процесса приработки свойства реального механизма на достаточно длительное время стабилизируются, что может быть использовано для корректировки эталонов состояния объекта $X_R^0(t)$ и предсказания изменения его свойств в случае достижения значительных наработок, когда его поведение становится все менее детерминированным.

Так, если по прошествии некоторого времени t_i состояние механизма совпадает с состоянием пилотного механизма, достигнутым за время t_i^0 , то возможно введение критерия временного подобия R_i , на основе которого можно предсказывать момент достижения объектом аналогичного состояния в соответствии с формулой

$$t_i = R_i t_i^0,$$

где t_i^0 – моменты достижения установленных состояний в пилотном режиме.

Учитывая тот факт, что эталоны состояний механизма в пилотном режиме и режиме нормальной эксплуатации в общем случае не совпадают, для моментов времени t_i нормального режима можно ввести следующую корректировку эталонов, базирующуюся на модели прогнозирования с адаптивными параметрами адаптации Тригга–Лича:

$$X_R^0(t) = \alpha X_R^0(t) + (1 - \alpha) X_R^0(t - 1),$$

где $X_R^0(t)$ – прогнозируемое значение эталона R -го состояния на ближайший момент времени t ;

$X_R^0(t - 1)$ – значение эталона R -го состояния, полученного на основе исследования предыдущего (пилотного) объекта в предыдущий момент времени $t - 1$; $X_R^0(t)$ – экспериментальные данные (данные измерений) в текущий момент времени; α – постоянная сглаживания.

Величина α для первой корректировки пилотных эталонов может быть принята равной 0,5, что соответствует нахождению среднего значения для экспериментальных данных пилотного и нормального режимов. Следует выбирать α из пределов 0...1 тем больше, чем большую ценность для прогноза состояния объекта имеют последние, «свежие» наблюдения. И наоборот, значение α должно быть тем меньше, чем более консервативной должна являться модель, в наибольшей степени усредняя новые данные. В этой связи последнее соотношение может быть записано в виде

$$X_R^0(t) = X_R^0(t - 1) + \alpha (X_R^0(t) - X_R^0(t - 1)).$$

Таким образом, значения нового эталона R -го состояния объекта равно значению прежнего эталона с поправкой в виде доли α разницы текущего наблюдения $X_R^0(t)$ и прежнего эталона. Поэтому данная модель может быть интерпретирована как фильтр, на вход которого поданы экспериментальные данные, а на выходе – получено их возвышенное среднее значение. Исходя из таких представлений, становится очевидным использование пилотного объекта, которое задает достаточно «хорошее» начальное приближение эталона $X_R^0(t - 1)$. Значения эталонов без пилотного объекта равны нулю и сильно подвержены влиянию случайных погрешностей. Это сказывается на уменьшении скорости обучения системы, так как для получения первых значений эталонов необходимо провести выработку ресурса механизма в режиме его нормальной эксплуатации, что всегда занимает длительное время. Особую ценность данный подход имеет и в том случае, если ресурс объекта неизвестен (объект на стадии отладки).

Из этих же соображений необходимо обеспечить корректировку постоянной α (весов фильтра) новых экспериментальных данных или при дрейфе характеристик во времени, исходя из соотношения

$$X_R^0(t) = X_R^0(t-1) + R \operatorname{grad}(\varepsilon(t)),$$

где $\varepsilon(t)$ – ошибка прогноза; $R = 0 \dots 1$ – коэффициент скорости обучения.

Ошибка прогноза определяется зависимостью

$$\varepsilon(t) = X_R^0(t) - \sum_{i=1}^n \alpha(1-\alpha)^i X_R^0(t-i).$$

Будем рассматривать ошибку $\varepsilon(t)$ как средство для адаптации постоянной $\alpha(t)$:

$$\alpha(t) = \frac{|\varepsilon''(t)|}{\tilde{\varepsilon}(t)};$$

$$\tilde{\varepsilon}(t) = (1 - \alpha(t)) \tilde{\varepsilon}(t-1) + \alpha(t) |\varepsilon(t)|;$$

$$\varepsilon''(t) = (1 - \alpha(t)) \varepsilon''(t-1) + \alpha \varepsilon(t),$$

где $\tilde{\varepsilon}(t)$ – сглаженное абсолютное значение ошибки; $\varepsilon''(t)$ – то же прогнозируемое.

В том случае, когда обучение системы неадекватно, значение $\alpha(t) \approx 1$, если же адекватно, то $\alpha(t)$ представляет собой случайную некоррелированную величину. На этой основе может

быть также получен критерий остановки процесса обучения, когда $\alpha(t)$ стабилизируется и по величине близка к нулю (т. е. когда новые экспериментальные данные не оказывают существенного вклада в полученное ранее значение эталона состояния). На следующем этапе для новых экспериментальных данных снова уточняются по алгоритму, описанному выше, различающие признаки и число различных состояний объекта и т. д. до получения приемлемого качества работы системы.

ВЫВОД

Описанный алгоритм может быть охарактеризован как следящий дисперсионный анализ, когда по результатам дисперсионного анализа инструментальных данных выделяются существенные признаки. Следует также отметить, что этот алгоритм напоминает действия человека, отыскивающего особенности в экспериментальных данных. Другой особенностью процедуры является возможность ее использования для диагностики объектов, подверженных непрерывному или дискретному дрейфу параметров. Эталоны, полученные с использованием данной процедуры, имеют свойство видоизменяться, обеспечивая при этом подстройку под свойства исследуемого объекта и учет динамических свойств предметной области. На основе этой процедуры построена интеллектуальная диагностическая система, способная к самообучению на входных инструментальных данных.