

Многомодельная обработка измерительной информации в интеллектуальных системах прогнозирования надежности космических средств

М. И. ЛОМАКИН*, А. Н. МИРОНОВ, О. Л. ШЕСТОПАЛОВА*****

* СТАНДАРТИНФОРМ, Москва, Россия, e-mail: lmi@gostinfo.ru

** Военно-космическая академия им. А. Ф. Можайского, С.-Петербург, Россия

*** Филиал «Восход» Московского авиационного института
(национального исследовательского университета), Байконур, Россия

Рассмотрены вопросы адаптивного синтеза структуры математического обеспечения обработки измерительной информации в интеллектуальных системах прогнозирования параметрической надежности космических средств в зависимости от характеристик прогнозных ситуаций. Сформулированные подходы могут быть использованы для оперативного получения оценок надежности космических средств на этапе наземных и летных испытаний с минимизированной на множестве моделей прогнозирования методической погрешностью.

Ключевые слова: многомодельная обработка измерительной информации, прогнозирование надежности, интеллектуальные системы прогнозирования.

The problems of adaptive synthesis of mathematical support structure of measuring information processing in intelligent space equipment reliability predicting systems depending on prognostic situation are considered. The formulated approaches may be used for rapid forecasting of parametric reliability assessment at the stage of ground and flight tests of space equipment. Methodical error of reliability prediction is minimized on the set of prediction models.

Key words: multimodel measurement information processing, reliability prediction, intelligent predicting systems.

Возрастание роли космических средств (КС) в обеспечении безопасности государства, а также высокая цена их отказа обуславливают повышение требований к качеству индивидуального прогнозирования надежности КС наземного и орбитального базирования по результатам измерений параметров их технического состояния (ТС). В настоящее время одним из возможных способов совершенствования технологий прогнозирования является применение интеллектуальных систем измерений (ИСИ), позволяющих, во-первых, совместить получение и обработку результатов измерений параметров ТС КС в рамках одной интегрированной структуры, во-вторых, реализовать адаптивный подход к идентификации типа и параметров математической модели обработки результатов измерений, минимизирующий методическую составляющую погрешности прогнозирования.

В статье рассмотрены особенности организации процедуры адаптивной многомодельной обработки измерительной информации в ИСИ для прогнозирования надежности КС.

Формулировка проблемы и противоречий. Общепринятый подход к получению количественных оценок показателей параметрической надежности КС предусматривает два последовательных этапа: измерение параметров ТС КС и формирование временных рядов (ВР); обработка результатов при помощи математических моделей. Традиционно при индивидуальном прогнозировании надежности КС указанные этапы реализуют раздельно: измерения параметров выполняют с использованием автономных систем, а обра-

ботку проводят, как правило, в специализированных вычислительных центрах. Распределенный способ получения и обработки результатов измерений снижает оперативность прогнозирования надежности КС, создает предпосылки для внесения погрешностей в результаты контроля на этапе их документирования и передачи в вычислительные центры. Кроме того, при удаленной обработке результатов измерений не учитывается информация о фактических условиях проведения измерений на конкретном объекте, что не позволяет принять во внимание дополнительную погрешность измерений при обработке ВР.

Одним из выходов в сложившейся ситуации может быть совмещение процедур измерений параметров ТС КС и прогнозирования показателей надежности КС в рамках единой системы измерений. Такая система должна содержать интеллектуальную компоненту [1], решающую задачи, которые ранее были прерогативой человека — специалиста в области прогнозистики, а именно: анализ характеристик ВР, выбор предпочтительной математической модели прогнозирования, оценка качества прогноза, принятие в случае необходимости решения об изменении параметров модели или переходе к другой модели и т. п.

При этом возникает проблема обеспечения приемлемой точности и достоверности прогнозов, напрямую связанная с методической погрешностью обработки результатов измерений, значение которой зависит от эффективности автоматизированного решения задачи идентификации типа и параметров прогнозной модели в ИСИ. В ходе решения ука-

занной проблемы необходимо преодолеть противоречия между необходимостью применения ИСИ и недостаточным научно-методическим уровнем проработки вопросов адаптивного выбора наиболее предпочтительной прогнозной модели из существующих с учетом характеристик конкретного объекта прогнозирования и фактических условий проведения измерений. При этом механизм адаптивного выбора модели должен обеспечивать минимизацию методической погрешности. Такого рода задачи относятся к классу задач метрологического сопровождения ИСИ [2].

Пути решения проблемы. При прогнозировании надежности КС в ИСИ необходимо учитывать многообразие типов параметров существующих и перспективных КС, с одной стороны, и многообразие условий, в которых осуществляется прогнозирование, с другой. Многообразие типов и условий порождает многовариантность прогнозных ситуаций (ПС). Под ПС будем понимать сложившееся к моменту прогнозирования сочетание факторов, характеризующих объект, и условия прогнозирования.

В рассматриваемом случае объекты прогнозирования — заданные в технической документации на КС параметры его ТС, выход которых за установленные пределы трактуется как параметрический отказ. Характеристики параметров, влияющих на выбор прогнозной модели: соотношение случайной и детерминированной компонент ВР; длина ВР; тип (односторонний, двухсторонний) и вид описания (детерминированный, случайный, нечеткий) границы поля допуска. Также важными факторами являются: цель получения прогноза, предъявляемые требования к точности и достоверности прогнозирования надежности КСр, условия измерений (степень «зашумленности» результатов, соотношение гауссовой и негауссовой шумовых компонент, степень присутствия грубых ошибок и т. п.).

Особенность реального процесса прогнозирования — принципиальная нестабильность ПС, изменчивость которой обусловлена как периодической сменой объекта прогнозирования (элемента КС) в процессе контроля, так и меняющимися условиями. Следовательно, в зависимости от конкретной ПС будут существенно отличаться начальные условия, определяющие требования и ограничения к применяемой модели прогнозирования. Эти отличия прежде всего относятся к характеристикам случайных процессов изменений определяющих параметров элементов КС и погрешностей измерений, объемам исходных данных (количество точек ВР, представляющего результаты контроля) и априорной информации о параметрах аналогичных элементов. При разработке подходов к прогнозированию надежности КС необходимо учитывать возможность широкого варьирования перечисленных факторов.

В настоящей работе прогнозирование надежности КС основано на предположении о невозможности ограничиться какой-либо одной моделью (алгоритмом). Выбор определенной модели зависит от конкретной ситуации. В условиях нестабильности ПС эффективное решение поставленной задачи возможно только на основе многомодельного подхода.

Пусть $\omega_i, i = \overline{1, N}$, означает определенное свойство объекта прогнозирования (ОП), $\bar{\omega}_i$ — противоположное ему свойство. Тогда элемент Ω_j множества

$$\Omega = \{\Omega_j: (\omega_1 \cup \bar{\omega}_1) \times (\omega_2 \cup \bar{\omega}_2) \times \dots \times (\omega_N \cup \bar{\omega}_N)\} \quad (1)$$

определяет логически обоснованную комбинацию наиболее общих свойств объекта — класс объекта.

Если в качестве $\omega_i, \bar{\omega}_i$ соответственно понимать такие общие свойства, как сосредоточенность или распределенность параметров, линейность или нелинейность, статичность или динамичность, стационарность или нестационарность, непрерывность или дискретность, то примерами классов будут комбинации типа «объекты с сосредоточенными параметрами: нелинейные — динамические — стационарные — дискретные» или «объекты с сосредоточенными параметрами: нелинейные — динамические — стационарные — непрерывные» и т. д. [3]. Множество (1) имеет $q = 2^N$ элементов, соответствующих различным классам ОП.

Пусть $v_k, k = \overline{1, M}$ — наиболее общее свойство модели ОП, $\bar{v}_k$ — противоположное ему свойство. Тогда V_i — класс модели ОП, являющийся элементом множества V классов,

$$V = \{V_i: (v_1 \cup \bar{v}_1) \times (v_2 \cup \bar{v}_2) \times \dots \times (v_n \cup \bar{v}_M)\}.$$

Задача оценивания класса ОП сводится к построению следующего решающего правила:

$$\Phi_k: \Omega \xrightarrow{AI, Y} V, \quad (2)$$

позволяющего на основе анализа априорной AI и апостериорной Y (экспериментальной) информации, т. е. наблюдений, некоторым способом сопоставить конкретному классу объекта соответствующий класс модели. Вследствие ряда обстоятельств, к которым относятся случайный характер изменения параметров объекта, искаженность результатов измерений параметров случайными помехами, возможная неполнота множества классов моделей (когда не все свойства объекта покрываются соответствующими свойствами модели), как правило, отсутствует возможность построения решающего правила (2) с нулевой вероятностью ошибочных решений. Следовательно, решение задачи (2) приводит, в общем случае, к некоторой оценке класса ОП. Установление класса модели на основе анализа информации об объекте составляет первый (высший) уровень идентификации типа прогнозной модели. Второй уровень связан с выбором структуры модели внутри некоторого выбранного класса V_i . Под структурой модели понимается вид математического оператора с известной точностью его параметров. Параметры могут быть как непрерывными, так и дискретными. Третий уровень связан непосредственно с оцениванием параметров модели ОП по экспериментальным данным.

Необходимо отметить различие между понятиями класса и структуры модели. Как следует из изложенного выше, понятие класса отражает только основные свойства объекта или модели. В одном и том же классе моделей могут быть применены различные математические операторы. Например, в классе «модели с сосредоточенными параметрами: нестационарные (в узком смысле) — аналитические — дискретные — индивидуальные — на основе большой выборки наблюдений» можно использовать операторы авторегрессии, скользящего среднего, Бокса—Дженкинса, экспоненциального сглаживания Брауна и др. В классе «модели с сосредоточенными параметрами: нестационарные (в узком




Рис. 1. Принцип многоуровневой идентификации модели объекта прогнозирования

смысле) — динамические — дискретные — комбинированные (ансамблево-индивидуальные) — на основе малой выборки наблюдений» есть единственный математический оператор Силина—Заковряшина [4]. Следовательно, при такой постановке вопроса число возможных операторов в общем случае больше числа классов систем и моделей. Установление класса модели сужает первоначальную совокупность возможных операторов, а в некоторых классах имеется только один — два эквивалентных математических оператора.

Задачу можно поставить и таким образом, чтобы в качестве элемента V_i принять один оператор, но тогда сильно возрастет число элементов множества V , и возникнут трудности при выделении из наблюдений характерных признаков каждой структуры модели. В этом направлении более реализуемым является многоуровневый подход: на первом уровне определить принадлежность объекта к одному из основных классов, внутри которого далее вводить новые подклассы и т. д.

Принцип многоуровневой идентификации показан на рис. 1. В формализованном виде процедура многоуровневой (трехуровневой) идентификации прогнозной модели может быть записана в виде системы отношений

$$\begin{cases} \Phi_K : \Omega \xrightarrow{AI, Y} V; \\ \Phi_C : M \xrightarrow{AI, Y} F; \\ \Phi_P : A \xrightarrow{Y} C, \end{cases}$$




Рис. 2. Взаимосвязь основных этапов идентификации прогнозной модели

где Φ_K, Φ_C, Φ_P — решающие правила, которые на основе анализа информации AI, Y позволяют последовательно оценить класс модели из множества V , структуру модели из множества F и определить параметры модели на множестве их значений C .

По ряду причин нельзя построить метод идентификации с нулевой вероятностью ошибочных решений. Кроме того, вследствие влияния объективных факторов могут изменяться условия моделирования. Это в равной степени относится как к характеристикам самого объекта, так и объему и качеству исходных данных об изменениях его параметров. В таких условиях процесс идентификации в виде цепочки наблюдений — выбор структуры модели — оценивание параметров — проверка адекватности, в общем случае, является многошаговым. Иными словами, если степень адекватности построенной модели недостаточна для достижения поставленной цели, задачу идентификации необходимо решать сначала, используя приобретенный опыт и стараясь получить дополнительную информацию из наблюдений. Взаимосвязь основных этапов идентификации показана на рис. 2.

Задача оценивания класса модели ОП (см. (2)) в ряде случаев может быть решена методом дискриминантного анализа при помощи так называемых дискриминантных функций $d_i(Z)$ от вектора признаков Z , который формируется на основе совместного анализа информации AI, Y . Дискриминантные функции выбирают таким образом, чтобы для всех значений Z , соответствующих классу V_i , выполнялись неравенства $d_i(Z) > d_j(Z)$, если $i \neq j$.

Класс модели можно определить по номеру функции $d_i(Z)$, имеющей наибольшее значение для наблюдаемого вектора Z . Тогда нерандомизированное решающее правило примет следующий вид:

$$I(z) : \arg \max_j d_j(Z) = i \Rightarrow V_i, j = \overline{1, s}, \quad (3)$$

где $s = 2^n$.

Вектор признаков Z можно составить как непосредственно из результатов наблюдений за входом и выходом исследуемого объекта, так и получить путем преобразования $Z = L(y, u)$ от векторов y, u , координаты которых — измеряемые значения выходных и входных параметров объекта. Случайный характер наблюдений и, следовательно, признаков приводит к дискриминантным функциям вида

$$d_i(Z) = - \sum_{j=1}^q P_j \pi_{ij} p(Z|V_j), i = \overline{1, s}, \quad (4)$$

где P_j — априорная вероятность класса V_j ; π_{ij} — потери, обусловленные отнесением i -го класса к j -му; $p(Z|V_j)$ — плотность условного распределения вероятностей признаков Z для класса V_j . Отметим, что технические возможности и имеющиеся ресурсы могут быть учтены при выборе вероятностей P_j , искусственно отдав априорное предпочтение некоторым из классов V_j .

При полной исходной информации (заданы $P_j, \pi_{ij}, p(Z|V_j)$) решающее правило (3) называется байесовским и дает наименьшие средние потери. Когда невозможно априори оценить потери ошибочных решений или они одинаковы ($\pi_{ij} = 0, \pi_{ji} = -1, i \neq j$), правило (3) соответствует методу максимальной апостериорной вероятности, приводящему к минимальной частоте ложной классификации. Минимаксное решение (P_j неизвестны) является оптимальным при наиболее не-

благоприятном сочетании априорных вероятностей появления класса V_j . При отсутствии информации о потерях и вероятностях появления классов ($P_j = 1/s$, $\pi_{ij} = 0$, $\pi_{ij} = -1$, $i \neq j$) соотношениями (3), (4) можно описать решающее правило метода максимального правдоподобия.

Как следует из (4), при построении любого из рассмотренных выше решающих правил всегда необходимо знать плотности $p(\mathbf{Z} | V_j)$, $j = \overline{1, s}$ условного распределения вероятностей признаков $\mathbf{Z}$. При идентификации функционирующих элементов КС эти плотности почти всегда неизвестны, поэтому появляется необходимость обучения или самообучения построенного классификатора.

Таким образом, нельзя ожидать надежной классификации, если класс действительных входных параметров объекта будет отличаться от того класса, на котором обучался классификатор. Такая ситуация характерна для большинства функционирующих элементов КС, поэтому предложенная методика построения решающих правил легко реализуется для объектов со специальными входными сигналами и в случае стационарных случайных процессов с дробно-рациональной спектральной плотностью. Успех применения методов дискриминантного анализа в случае объектов с произвольными входными возмущениями зависит от положительных результатов исследований по выделению информативных признаков, инвариантных относительно входных наблюдений y . Указанные недостатки метода дискриминантного анализа не позволяют в полной мере использовать его для решения задачи оценивания классов моделей элементов КС.

Другим методом оценивания класса модели ОП является *последовательный метод принятия решения*. Анализ структуры элементов V_j , $j = \overline{1, s}$, показывает, что процесс решения задачи оценки класса модели объекта можно разделить на отдельные этапы (шаги) таким образом, чтобы на каждом очередном i -м шаге устанавливалась только истинность свойства v_i или $\bar{v}_i$. Если принять, что v_1 — свойство сосредоточенности параметров, $\bar{v}_1$ — распределенность параметров, v_2 — непрерывность, $\bar{v}_2$ — дискретность, v_3 — линейность, $\bar{v}_3$ — нелинейность, v_4 — статичность, $\bar{v}_4$ — динамичность, v_5 — стационарность, $\bar{v}_5$ — нестационарность, то структурная схема такой последовательной процедуры будет иметь вид дерева, в конце каждой ветви которого получается определенный элемент (класс) V_j , $j = \overline{1, s}$.

Априорная информация о свойствах объекта помогает выбрать соответствующий промежуток каждой ветви. Поскольку на каждом шаге возможны только два решения, облегчается проблема выделения информативных признаков из наблюдений за входом и выходом объекта. При этом система признаков может меняться в зависимости от принятых решений на предыдущих этапах.

В [3] для проверки гипотез о наличии (отсутствии) у объекта того или иного свойства v_i , $i = \overline{1, s}$ применяют, как правило, статистические методы. Надежность таких выводов напрямую зависит от количества апостериорной информации о значениях параметров ОП. Так как в большинстве случаев такой информации недостаточно, то возможность применения последовательного метода ограничена.

Однако конструктивный выход может быть найден посредством перехода от статистических методов к нечетким, основанным на теории искусственного интеллекта [5]. До недавнего времени неформализуемую часть априорной информации об ОП, связанную с опытом специалистов по прогнозированию и идентификации по выбору моделей в условиях неопределенности, не рассматривали. Использование нечетких методов обработки и представления информации о векторе признаков $\mathbf{Z}$ в сочетании с формализованными правилами выбора класса и структуры моделей позволяет модифицировать последовательный метод принятия решений о классе модели ОП в направлении учета реальных особенностей прогнозных ситуаций.

Как отмечалось выше, в некоторых классах моделей V_j , $j = \overline{1, s}$ существует несколько различных структур — математических операторов, известных с точностью до параметров s . Поэтому актуальна задача выбора оператора, отражающего существующую связь между выходными и входными параметрами объекта. Формально эту задачу можно представить в виде

$$\tilde{F} : (\tilde{F}) = \min_{F \in V_j} R(\tilde{F}), \quad (5)$$

где $R(\tilde{F})$ — функционал средних потерь,

$$R(\tilde{F}) = M\{\Phi(\tilde{F}(\tilde{c}), y, u)\}; \quad (6)$$

$\Phi(\cdot)$ — потери, появившиеся из-за выбора оператора $\tilde{F}(\tilde{c})$; $\tilde{c} = \Theta\{y, u, p_c(c)\}$ — оценка параметров оператора по наблюдениям (y, u) с использованием априорной информации, характеризующей плотностью априорного распределения $p_c(c)$.

В условиях, когда используется нечеткий подход к оцениванию функционала (6), он может быть записан как

$$\tilde{R}(\tilde{F}) = \tilde{M}\{\tilde{\Phi}(\tilde{F}(\tilde{c})), y, u\},$$

где $\tilde{\Phi}(\cdot) = \{\langle \Phi(\cdot), \mu_{\Phi}(\Phi) \rangle\}$ — нечеткая оценка потерь из-за выбора оператора $\tilde{F}(\tilde{c})$.

Тогда оптимальный оператор можно получить как

$$\tilde{F} : \tilde{R}(\tilde{F}) = \min_{\tilde{F} \in \tilde{V}_j} \tilde{R}(\tilde{F}), \quad (7)$$

где $\min$ — операция нахождения минимального нечеткого числа на множестве чисел, генерированном подмножеством $F \in V_j$.

Может возникнуть ситуация, когда необходимо, чтобы средние потери не превышали некоторого допустимого уровня R_0 (например, дисперсия предсказания выходного параметра должна быть не больше определенного значения). Тогда оператор выбирается из условия

$$\tilde{F} : (\tilde{F}) \leq R_0, \quad \tilde{F} \in V_j. \quad (8)$$

Решение задачи (5) всегда существует, хотя может быть и неоднозначным. В то же время в классе V_j могут быть не-

сколько операторов, удовлетворяющих условию (8), или вообще решение может отсутствовать, если требуемое качество модели R_0 превышает предельные возможности данного класса, т. е.

$$R_0 = \min_{\tilde{F} \in V_j} R(\tilde{F}).$$

В такой ситуации либо допущены существенные ошибки при определении класса моделей, либо природа и интенсивность неконтролируемых возмущений, технические средства получения наблюдений за входом и выходом и используемые методы обработки, в принципе, не позволяют достичь необходимого уровня средних потерь.

В случае нечеткого оценивания функционала средних потерь решение задачи

$$\tilde{F}: R(\tilde{F}) \leq R_0, \tilde{F} \in V_j \quad (9)$$

дает некоторое нечеткое множество математических операторов

$$\tilde{F} = \{ \langle \tilde{F}, \mu_{\tilde{F}}(\tilde{F}) \rangle, \tilde{F} \in V_j \}. \quad (10)$$

Множество (10) для дальнейшего исследования может быть преобразовано к четкому виду посредством операции нахождения α -сечения нечеткого множества $\tilde{F}$:

$$\tilde{F}' = \{ \tilde{F}: \mu_{\tilde{F}}(\tilde{F}) \geq \alpha \}.$$

Алгоритм поиска операторов, удовлетворяющих условиям (5), (7) или (8), (9), можно записать в виде

$$\tilde{F}_{i+1} = \Gamma(\tilde{F}_1, \dots, \tilde{F}_i, \tilde{R}_1, \dots, \tilde{R}_i),$$




Рис. 3. Общая функциональная схема многоуровневой идентификации прогнозной модели:

AI, Y — априорная и апостериорная (экспериментальная) информация, соответственно; ИКМ — идентификатор класса модели; ИСМ 1 — идентификатор структуры модели класса 1; ИСМ K' — идентификатор структуры модели класса K'; БМО — база моделей объекта; ИПМ — идентификатор параметров модели

где Γ — правило выбора очередного оператора; $\tilde{R}_i$ — наблюдаемое (оцениваемое) значение функционала средних потерь при операторе $\tilde{F}_i$, в частности $\tilde{R}_j = \Phi(\tilde{F}(\tilde{c}), y, u)$,

$j = \overline{1, i}$. Наиболее простым и надежным алгоритмом для класса моделей с небольшим количеством операторов является полный перебор. Когда количество операторов велико, эффективными могут оказаться методы случайного поиска.

С учетом изложенного, а также результатов, описанных в [3], можно составить общую функциональную схему многоуровневой идентификации модели объекта, представленную на рис. 3. Априорная информация AI и измеренные в процессе эксплуатации значения параметров Y объекта поступают в анализатор характеристик объекта, в котором осуществляется преобразование исходной информации в значения вектора признаков Z. Далее значения вектора Z для каждого момента контроля n (в динамическом режиме) поступают в блок идентификации типа модели, в состав которого входят идентификатор класса модели ИКМ, идентификаторы структуры модели (по числу классов) ИСМ и база моделей объекта БМО. На выходе ИКМ фиксируется номер выбранного класса в соответствии с заложенным в него алгоритмом выбора. По номеру класса определяется соответствующее ему подмножество F_i математических операторов (структур модели), из которых в соответствующем ИСМ выбирается одна или несколько структур, составляющих множество наиболее предпочтительных структур F' . По индексам операторов, входящих в F' , из БМО выбираются соответствующие модели $M_{\{F'\}}$, параметры которых оцениваются по наблюдениям Y в блоке идентификации параметров модели. Их число равно числу структур, представленных в базе моделей. На выходе функциональной схемы формируется множество конкурирующих моделей, которые могут использоваться для вычисления прогнозов параметрической надежности элемента КС.

Выводы. Рассмотрен способ многоуровневой обработки результатов первичных измерений в ИСИ показателей надежности КС, позволяющий реализовать принцип адаптивного выбора модели в зависимости от характеристик прогнозной ситуации, под которой предложено понимать сочетание характеристик ОП (параметра КС) и условий прогнозирования. Показано, что наиболее адекватным подходом, учитывающим специфику прогнозирования параметрической надежности КС, является многоуровневый подход, реализованный на основе схемы многоуровневой идентификации прогнозной модели. Проведен анализ основных методов решения задачи многоуровневой идентификации. Описан способ реализации многоуровневой схемы идентификации математической модели прогнозирования параметрической надежности КС на основе применения интеллектуальных идентификаторов класса моделей объекта прогнозирования.

Л и т е р а т у р а

1. Вечеркин В. Б., Лоскутов А. И., Шестопалова О. Л. Автоматизация контроля состояния сложных технических систем на основе использования конечно-автоматной модели и нейросетевых структур // Информационно-управляющие системы. 2012. № 2(57). С. 74—81.

2. Романов В. Н., Соболев В. С., Цветков Э. И. Интеллектуальные средства измерений / Под ред. Э. И. Цветкова. М.: РИЦ «Татьянин день», 1994.

3. Каминский В. А. Идентификация динамических систем по дискретным наблюдениям. Ч. 1. Основы статистических методов, оценивание параметров линейных систем. Вильнюс: Мокслас, 1982.

4. Миронов А. Н., Кутозов В. Н., Шестопалова О. Л. Моделирование изменения технического состояния модернизируемых объектов на основе принципа многоуровневой идентификации // Неразрушающий контроль и техническая диагностика при производстве и эксплуатации авиационной и космической техники: Труды I Всерос. науч.-техн. конф. СПб.: ВКА им. А. Ф. Можайского, 2005.

5. Алиев Р. А., Церковный А. Э., Мамедова Г. А. Управление производством при нечеткой исходной информации. М.: Энергоатомиздат, 1991.

Дата принятия 30.10.2013 г.

681.2+53.08

Выбор методов проверки средств измерений в условиях ограниченных ресурсов

С. Н. ФИЛИМОНОВ

Центральный научно-исследовательский институт связи, Москва, Россия,
e-mail: snf20@yandex.ru

Рассмотрены критерии выбора детерминированных или стохастических методов решения трудоемких задач проверки (опробования) средств измерений. Процесс решения смоделирован при помощи математического аппарата теории игр. Критерий основан на сравнении имеющегося ресурса с мощностью множества стратегий решения задачи.

Ключевые слова: детерминированный и стохастический методы, теория игр, критерий выбора метода решения.

The selection criterion for deterministic or stochastic decision methods of laborious checking problems is considered. The decision-making process modelling is carried out by means of the mathematic apparatus of game theory. The criterion is based on comparison of available resource with the cardinality of problem decision strategies.

Key words: deterministic and stochastic decision methods, game theory, decision-making criterion.

Средства измерений (СИ) постоянно совершенствуются, содержат процессоры и сложное программное обеспечение (ПО) в качестве управляющего ядра, характеризуются большим числом разнообразных выполняемых функций, в том числе функций обработки информации.

Проверка работоспособности СИ перед испытаниями на соответствие техническим и метрологическим требованиям и поверкой — непростая задача, так как требуется сравнить текущее состояние объекта проверки с множествами исправных либо неисправных состояний. Для решения задачи необходимы значительные ресурсы (время, вычислительные мощности, квалификация специалистов, участвующих в решении). Наиболее ответственные изготовители сложных СИ реализуют встроенные средства проверки и программы самоконтроля, но делается это далеко не во всех СИ, поскольку их стоимость при этом значительно увеличивается, а проверяется очень ограниченное число функций. Фактическая полнота и достоверность проверок не известна не только проверяющему (испытателю, поверителю), но и производителю СИ и измерительных систем.

Рассмотрим проблему проверки ПО СИ. Процесс проверки (тестирования) ПО достаточно трудоемок, что объясняется комбинаторным характером и сложностью процесса решения подобных задач.

Методы автоматизации синтеза проверяющих последовательностей. Особенности рассматриваемой задачи: большая размерность множества последовательностей возможных действий, из которого лицу, принимающему решение (ЛПР), надо сделать выбор, и ограниченность ресурса ЛПР, затрачиваемого на поиск и реализацию последовательности действий, приводящей к решению (обнаружению неисправности (ошибки)). Задача усложняется отсутствием у ЛПР полной информации о проверяемом объекте. Эти условия охарактеризуем как условия априорной неопределенности и большой мощности множества возможных вариантов последовательностей действий ЛПР при ограниченном ресурсе.

Для решения подобных задач применяют детерминированные и стохастические методы автоматизации процесса поиска решения [1—4]. Детерминированные методы пред-