

**РОБОТОТЕХНИКА
И МЕХАТРОНИКА**

УДК 681.5.015

М. М. Кожевников

*Могилевский государственный университет продовольствия,
г. Могилев, Республика Беларусь*

НЕЙРОСЕТЕВОЙ ПОДХОД К МОНИТОРИНГУ СОСТОЯНИЯ ПРОМЫШЛЕННЫХ РОБОТОВ-МАНИПУЛЯТОРОВ

Предложен новый метод мониторинга состояния промышленных роботов-манипуляторов, основанный на анализе результатов идентификации параметров динамической модели при помощи нейронных сетей. Получены аналитические выражения, позволяющие минимизировать влияние погрешностей квантования на точность идентификации. Эффективность предложенного метода подтверждается примерами практического применения в промышленной системе мониторинга.

Ключевые слова: мониторинг состояния, роботы-манипуляторы, нейронные сети.

M. M. Kazheunikau

Mogilev State University of Food Technologies, Mogilev, Belarus

NEURAL NETWORK APPROACH TO CONDITION MONITORING OF INDUSTRIAL ROBOTIC-MANIPULATORS

The paper presents a novel technique for condition monitoring of industrial robotic manipulators, which is based on neural network analyses of the dynamic model parameters obtained by means of on-line identification. There were derived analytical expressions that allow minimising impact of the measurement errors on the identification accuracy. Efficiency of the proposed technique has been verified by real-life case studies from industrial monitoring systems.

Key words: condition monitoring, robotic-manipulators, neural network.

Возрастание сложности промышленных роботов-манипуляторов ставит задачу их мониторинга и обнаружения неисправностей в процессе эксплуатации. Несмотря на то, что эта задача рассматривалась рядом авторов [2; 3; 5; 9; 14], в настоящее время нет единого метода, позволяющего решить проблему самодиагностики в полном объеме. Поэтому в данной работе предлагается гибридный подход, объединяющий традиционные статистические модели, а также методы, основанные на принципах искусственного интеллекта.

В настоящее время наибольшее распространение получили методы мониторинга состояния роботов-манипуляторов, основанные на контрольных картах [2], в основе которых лежит предположение, что при отсутствии отказов наблюдаемая величина представляет собой некоррелированный статистический процесс [11]. Однако для большого класса промышленных роботов это предположение нарушается. Кроме того, требуется разработка специальных методов идентификации, робастных к шуму измерений и квантованию входных сигналов.

При анализе контрольных карт проводится статистическая проверка ряда гипотез,

позволяющая обнаружить необычные вариации контролируемого параметра робота, обусловленные особыми (неслучайными) причинами. Наиболее часто используются тестовые правила, основанные на выявлении маловероятных «опасных» ситуаций, таких как выход за контрольные границы, тренд, приближение к контрольным границам и т. д. [7]. Однако, как отмечается рядом авторов [6; 12], данный подход не гарантирует отсутствие ошибок. Поэтому проводятся активные исследования по разработке других методов анализа контрольных карт, использующие аппарат экспертных систем, нейронных сетей и эвристические алгоритмы [1; 4; 8; 10; 13], но предложенные в этих работах алгоритмы не учитывают специфику рассматриваемой проблемы.

В данной статье предложен новый нейросетевой метод мониторинга состояния, который позволяет распознать «опасные» ситуации в контрольных картах промышленных роботов-манипуляторов с инкрементальными датчиками перемещения в цепи обратной связи. В отличие от известных подходов, основанных на анализе данных, полученных в результате периодических измерений некоторого контролируемого параметра, предложенный метод анализирует характер изменений параметров динамической модели, которые оцениваются путем идентификации в режиме реального времени.

Динамика исполнительных приводов электромеханических роботов-манипуляторов может быть описана следующими уравнениями:

$$\dot{p}(t) = v(t);$$

$$T \cdot \dot{v}(t) + v(t) + m \cdot \text{sgn}(v(t)) = k \cdot u(t), \quad (1)$$

где $p(t)$ – угол поворота вала двигателя (выходная переменная); $v(t)$ – скорость вращения вала; $u(t)$ – управляющее воздействие; k – коэффициент передачи; T – электромеханическая постоянная времени; m – амплитуда возмущающего воздействия. Следует отметить, что в этой модели параметры T и m рассматриваются как основные характеристики состояния объекта, которые далее используются при мониторинге. Дискретизация исходной модели (1) по времени приводит к следующим выражениям:

$$v_{k+1} = \mu \cdot v_k + (1 - \mu)(ku_k - m);$$

$$v_k = (p_{k+1} - 2p_k + p_{k-1})/2T_0, \quad (2)$$

где $\mu = \exp(-T_0/T)$; T_0 – период квантования по времени. Для идентификации параметров модели первоначально предположим, что коэффициент передачи k и скорость вала v_k могут быть оценены с достаточной точностью. Тогда основное уравнение для идентификации может быть записано в виде

$$A_k + m = (B_k + m)\mu;$$

$$A_k = v_{k+1} - ku_k; B_k = v_k - ku_k. \quad (3)$$

Определим критерий качества следующим образом:

$$F(\mu, m) = \sum_{k=1}^n [(A_k + m) - (B_k + m) \cdot \mu]^2. \quad (4)$$

Приравнивая производные функции $F(\mu, m)$ к нулю и решая соответствующую систему уравнений, получаем выражения для расчета параметров (μ, m) :

$$\begin{aligned} \mu &= \frac{n \sum_{k=1}^n A_k B_k - \sum_{k=1}^n A_k \sum_{k=1}^n B_k}{n \sum_{k=1}^n (B_k)^2 - \left(\sum_{k=1}^n B_k \right)^2}; \\ m &= \frac{\mu \sum_{k=1}^n B_k - \sum_{k=1}^n A_k}{n(1 - \mu)}, \end{aligned} \quad (5)$$

где n – размер выборки. Если коэффициент передачи k неизвестен, то динамическая модель (2) может быть представлена как линейная регрессия вида $v_{k+1} = a v_k + b u_k + c$, где $a = \mu$; $b = (1 - \mu)k$; $c = -(1 - \mu)m$ и соответствующая задача идентификации может быть решена с использованием псевдоинверсии Мура-Пенроуза:

$$\begin{pmatrix} a \\ b \\ c \end{pmatrix} = \begin{pmatrix} \sum_k v_k^2 & \sum_k v_k u_k & \sum_k v_k \\ \sum_k v_k u_k & \sum_k u_k^2 & \sum_k u_k \\ \sum_k v_k & \sum_k u_k & N \end{pmatrix}^{-1} \begin{pmatrix} \sum_k v_{k+1} v_k \\ \sum_k v_{k+1} u_k \\ \sum_k v_{k+1} \end{pmatrix}. \quad (6)$$

Тогда искомые параметры модели вычисляются на основе следующих выражений:

$$\mu = a; m = -c/(1 - a); k = b/(1 - a). \quad (7)$$

Однако проведенные исследования показали, что это выражение менее робастно к шуму измерений по сравнению с выражением (5). Поэтому целесообразно разбить иден-

тификационную процедуру на два шага. На первом шаге производится оценка коэффициента передачи (в установившемся режиме), а на втором осуществляется идентификация параметров T и m , которые необходимы для мониторинга состояния и диагностики отказов робота.

Чтобы использовать выражения (5) и (7) для идентификации, требуется массив скоростей и соответствующих управляющих воздействий $\{vk, uk \mid k = 1:n\}$. Однако рассматриваемые промышленные роботы-манипуляторы оснащены инкрементальными датчиками, которые позволяют получить только код положения. Поэтому скорость должна оцениваться численно. Очевидно, что простейшая оценка скорости $\hat{v}_i^{(1)} = (p_{i+1} - p_i)/T_0$ является очень чувствительной к шуму квантования. Чтобы показать это, предположим, что ошибка измерений описывается белым шумом с нулевым математическим ожиданием и дисперсией σ^2 . Тогда среднеквадратическое отклонение оценки скорости имеет вид $\delta[\hat{v}^{(1)}] = \sigma\sqrt{2}/T_0$, причем $\sigma^2 = \sigma_1^2 + \sigma_2^2$, где $\sigma_1 = \Delta/\sqrt{12}$ обусловлено погрешностями квантования по уровню с шагом Δ , а $\sigma_2 = v_{\max} \cdot T_0/\sqrt{12}$ учитывает погрешности квантования по времени при максимальной скорости v_{\max} . Соответствующие вычисления при типичных значениях $\Delta = 2\pi/1024$ и $v_{\max} = 10 \text{ inc/tic}$ дают $\delta[\hat{v}^{(1)}]/v_{\max} \approx 40\%$ (рис. 1), поэтому для идентификации параметров динамической модели должны использоваться более точные оценки скорости.

Чтобы повысить точность вычисления скорости, применим метод скользящего окна для интервала времени $[t - LT_0; t + LT_0]$. Простейшее выражение такого типа $\hat{v}_i^{(2)} = (p_{i+L} - p_{i-L})/2LT_0$ использует граничные значения выходной координаты $p(t)$ и дает ошибку $\delta[\hat{v}^{(2)}] = \sigma\sqrt{2}/2LT_0$. Дальнейшее снижение ошибки может быть достигнуто при использовании линейного сплайна, обеспечивающего сглаживание $p(t)$:

$$v_i^{(3)} = \arg \min_{v,a} \sum_i [a + vt_i - p_i]^2. \quad (8)$$

Дифференцируя это выражение по параметрам a и v и решая соответствующие уравнения, получим

$$v^{(3)} = \bar{S}_{pt} / \bar{S}_{tt}, \quad (9)$$

где

$$\bar{S}_{pt} = \sum_k \left(p_k - n^{-1} \sum_k p_k \right) \cdot \left(t_k - n^{-1} \sum_k t_k \right);$$

$$\bar{S}_{tt} = \sum_k \left(t_k - n^{-1} \sum_k t_k \right)^2.$$

Далее предположим, что $p(t) = vt + x$, где x – белый шум с параметрами $(0, s)$, и рассмотрим скользящее окно $t \in [-LT_0; LT_0]$. Тогда эти суммы равны:

$$S_{pt} = vT_0^2 \cdot \sum_{i=-L}^L i^2 + T_0 \cdot \sum_{i=-L}^L i\xi_i,$$

$$S_{tt} = T_0^2 \cdot \sum_{i=-L}^L i^2, \quad (10)$$

и искомая оценка скорости может быть представлена как

$$v^{(3)} = v + 3 \sum_{i=-L}^L i\xi_i / T_0 (2L^3 + 3L^2 + L). \quad (11)$$

Очевидно, что среднеквадратическое отклонение $v^{(3)}$ рассчитывается следующим образом:

$$\delta[v^{(3)}] = \sigma / vT_0 \sqrt{2L^3 + 3L^2 + L}, \quad (12)$$

и существенно ниже, чем для оценок $v^{(1)}$, $v^{(2)}$. Как показали экспериментальные исследования (рис. 2), необходимая для рассматриваемых приложений точность $\delta[v^{(3)}] \leq 0,004$ достигается для скользящего окна с параметром $L \approx 20$.

Для обнаружения отклонений в динамическом поведении промышленного робота-манипулятора используем контрольные карты типа X, R, S , которые, как показал проведенный анализ, позволяют достичь наилучшей достоверности при мониторинге состояния робота. При этом разделим диапазон изменения анализируемых параметров T, m на три равные зоны (A, B, C) и применим 10 правил, нарушение которых в режиме нормальной эксплуатации маловероятно. К числу этих правил относятся: «Выход за контрольные границы», «Выход ниже/выше центральной линии» (7 из 7, 10 из 11, 12 из 14, и 14 из 16 точек), «Попадание в зону C» (15 из 15 точек), «Избежание зоны C» (4 из 5 точек), «Точки в зоне A или вне зоны A» (2 из 3 точек), «Линейный тренд» (7 точек), «Колебательный тренд». При этом для снижения вероятности




Рис. 1. Сравнение методов оценки скорости




Рис. 2. Ошибки оценок $\delta(T)$ и $\delta(m)$ для разных значений L

ошибок диагностики названные правила применяются совместно.

Для дальнейшего повышения достоверности мониторинга используем нейронную сеть обратного распространения (FFN), которая позволяет описать существенно нелинейные соотношения между входным и выходным сигналами. Предложенная модификация FFN-сети (рис. 4) представляет собой четырехслойную структуру, содержащую 21 нейрон во входном слое. Этот слой используется для ввода данных от контрольных карт (20 последовательных точек и математическое ожидание M). Выходной слой сети состоит из одного нейрона, а его выход принимает значения 1 или 0 (соответственно для нормального и аварийного состояния робота-манипулятора). Два скрытых слоя сети содержат 40 и 60 нейронов соответственно. Для активации нейронов в скрытых и выходном слоях используется функция гиперболического тангенса. Для

генерации требуемого для обучения сети множества контрольных карт использован метод Монте-Карло.

Для обучения сети применялся алгоритм обратного распространения с параметром скорости обучения 0,5. В процессе обучения весовые коэффициенты настраивались таким образом, чтобы минимизировать среднеквадратичную ошибку (MSE) между вектором состояния сети и обучающим множеством. Для обучения было сгенерировано 3800 наборов данных (1000 для нормального функционирования робота и 2800 для различных типов аварийных ситуаций). Веса нейронной сети модифицируются до тех пор, пока не выполняются условия $\varepsilon \leq \varepsilon_{\max}$ or $i \leq i_{\max}$, где ε – значение MSE , i – количество итераций.

В процессе исследования рассмотрен ряд четырехслойных сетей обратного распространения, отличающихся значениями размерности скрытых слоев h_1 и h_2 , а обучение

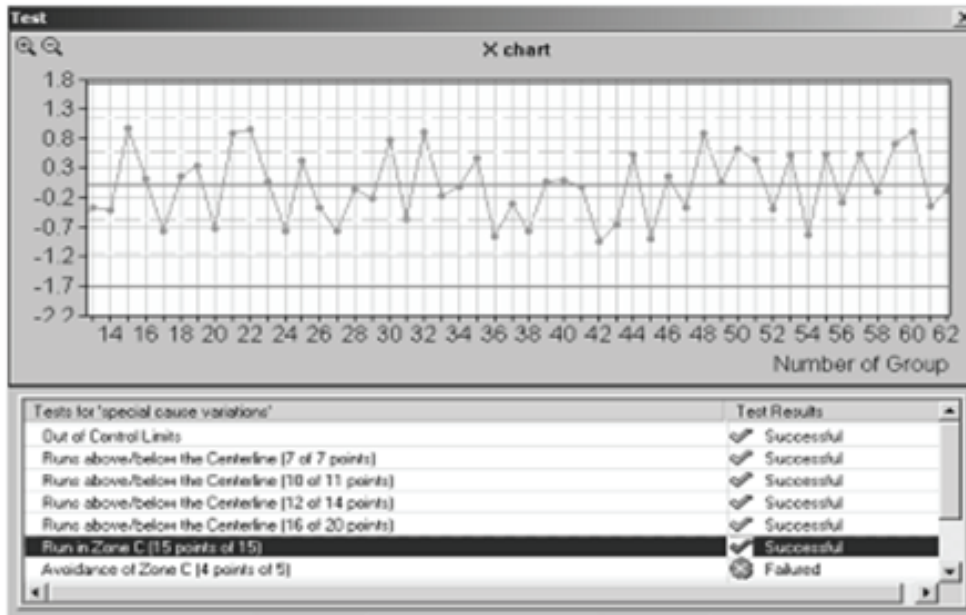


Рис. 3. Пример анализа данных идентификации




Рис. 4. Нейронная сеть для анализа контрольных карт

проводилось до достижения значений $\varepsilon_{\max} = 10^{-5}$ или $i_{\max} = 3000$. Графики изменения MSE в процессе обучения для сетей с различной размерностью скрытого слоя приведены на рис. 5 (моделирование проведено в пакете MatLab). Для тестирования этих сетей использовано 140 наборов данных для аварийных режимов и 50 наборов данных для режима нормального функционирования. Результаты обучения и тестирования сетей приведены в табл. 1 (значения достигнутых в процессе обучения ошибок (MSE) и процент корректно распознанных ситуаций на тестовом множестве P). Моделирование показало, что минимальное значение $\varepsilon = 0,00015$ достигается при размерности скрытых слоев $h_1 = 50$ и $h_2 = 40$. Однако,

как следует из табл. 1, для случая $h_1 = 60$ и $h_2 = 40$ получено большее число корректно распознанных ситуаций (94 %), поэтому сеть с такими параметрами применена для диагностики состояния манипуляционного робота в промышленной робототехнической системе, которая включает 5 подвесных манипуляторов, которые обслуживают 200 рабочих станций.

Предложенный метод мониторинга состояния электромеханических роботов-манипуляторов с инкрементальными датчиками обратной связи, основанный на анализе параметров динамической модели при помощи нейронной сети типа FFN, позволяет повысить достоверность обнаружения отказов. На основе предложенного метода разработан




Рис. 5. Визуализация обучения сети при различных параметрах h_1 и h_2

Таблица 1

Результаты обучения нейронных сетей

h_1	h_2	ϵ	Время обучения, с	$P, \%$
20	20	0.00162	300	89.5
25	25	0.000132	330	87.5
30	30	0.00035	408	91.6
35	40	0.00175	420	90.0
40	40	0.00052	480	91.1
45	40	0.00015	510	93.6
50	40	0.00015	528	93.7
60	40	0.00018	600	94.0

программный модуль, эффективность которого подтверждается примерами практического применения при мониторинге состояния промышленной робототехнической системы.

Библиографические ссылки

1. Anagun A. S. A neural network applied to pattern recognition in statistical process control // Proceedings of the 23rd International Conference on Computers and Industrial Engineering. Chicago, IL, 1998. P. 185–188.
2. Basseville M., Nikiforov I. V. Detection of abrupt changes: theory and applications. Englewood Cliffs, NJ: Prentice-Hall, 1993.
3. Chang S. I. An Integrated Scheme for Process Monitoring and Diagnosis', Proceedings. of ASQC 49th Annual Quality Congress. Cincinnati, OH, 2000. P. 725–732.
4. Cheng C.S. A neural network approach for the analysis of control chart patterns // International Journal of Production Research. 1997. № 35. P. 667–697.
5. Dash S., Venkatasubramanian V. Challenges in the industrial applications of fault diagnostic systems //

- Proceedings of the conference on Process Systems Engineering. Keystone, Colorado, 2000. P. 785–791.
6. Frank P. Fault diagnosis in dynamic systems using analytical knowledge-based redundancy- a survey and some new results // Automatica. 1990. № 26(3). P. 459–474.
 7. Grant E. L., Leavenworth R. S. Statistical quality control. New York : McGraw-Hill, 1996.
 8. Hwang H. B., Hubele N. F. X-bar control chart pattern identification through efficient off-line neural network training // IIE Transactions. 1993. № 25. P. 27–40.
 9. Kulikov G. G., Breikin, T. V., Arkov V. Y., Fleming, P. J. Real-time simulation of aviation engines for FADEC test-beds // Proceedings of the International Gas Turbine Congress. Kobe, Japan, 1999. P. 949–952.
 10. Lucy-Bouler T.L. Application to forecasting of neural network recognition of shifts and trends in quality control data // Proceedings of WCNN'93–World Congress on Neural Networks. Portland, UK, 1993. P. 631–633.
 11. Montgomery D. C. Introduction to Statistical Quality Control. New York : John Wiley and Sons, Inc. 1996.
 12. Patton R. J., Frank P. M., Clark R. N. Fault Diagnosis in dynamic systems: Theory and Applications. Prentice Hall, 1989.
 13. Pham D. T., Oztemel E. Control chart pattern recognition using learning vector quantization networks // International Journal of Production Research. 1994. № 32. P. 721–729.
 14. Tsung F. Statistical Monitoring and Diagnosis of Automatic Controlled Processes Using Dynamic PCA // International Journal of Production Research. 2000. № 38. P. 625.

*Статья поступила в редакцию
23.10.2012 г.*