

УДК 004.054 (004.048)
DOI: 10.17223/19988605/48/12

С.Г. Мосин

ОПТИМИЗАЦИЯ ПОСТРОЕНИЯ НЕЙРОМОРФНОГО СПРАВОЧНИКА НЕИСПРАВНОСТЕЙ ДЛЯ ТЕСТИРОВАНИЯ И ДИАГНОСТИКИ АНАЛОГОВЫХ ИНТЕГРАЛЬНЫХ СХЕМ

*Работа выполнена за счет средств субсидии, выделенной в рамках государственной поддержки
Казанского (Приволжского) федерального университета в целях повышения его конкурентоспособности
среди ведущих мировых научно-образовательных центров.*

Статья посвящена вопросам снижения сложности построения справочников неисправностей для аналоговых интегральных схем на основе искусственной нейронной сети (НС). Представлены преимущества нейроморфных справочников неисправностей (НСН) – ассоциативный режим работы и слабое влияние количества рассматриваемых неисправностей на архитектуру НС. Обсуждаются варианты построения НСН в аспекте больших данных. Предложен подход к выбору существенных характеристик контролируемых параметров для тестирования и диагностики неисправностей, обеспечивающий уменьшение размерности обучающего множества. Метод главных компонент (МГК) и критерий, основанный на объясненной дисперсии остатков, применяются для уменьшения количества коэффициентов, используемых для обучения НС. Представлен сквозной маршрут формирования НСН. Экспериментальные результаты демонстрируют эффективность предложенного подхода в виде сокращения времени и вычислительных затрат на формирование НСН, обеспечивающего высокий уровень покрываемости неисправностей до 100%.

Ключевые слова: метод главных компонент; нейросетевой справочник неисправностей; тестирование; диагностика; аналоговые интегральные схемы.

Диагностика неисправностей интегральных схем (ИС) – важный этап производственного цикла, обеспечивающий выявление места возникновения неисправностей в ходе тестирования и гарантирующий высокое качество партии ИС на выходе. Тестирование и диагностика аналоговых ИС представляют существенную функциональную сложность по сравнению с цифровыми ИС [1]. Во многом этому способствуют непрерывный характер обрабатываемых сигналов, сложные нелинейные зависимости входных и выходных сигналов, допуски на параметры внутренних компонентов, которые случайным образом влияют на отклонения параметров и передаточной функции от номинальных значений, чувствительность выходных характеристик к отклонениям внутренних и внешних параметров, возможность возникновения не только катастрофических, но и параметрических неисправностей, отсутствие эффективных моделей аналоговых неисправностей и др.

Цель предлагаемой работы – поиск и исследование метода выбора существенных характеристик выходного отклика проверяемой схемы на приложенный тестовый сигнал, которые обеспечивают снижение вычислительных и временных затрат на обучение нейроморфного справочника неисправностей без снижения покрываемости рассматриваемых неисправностей. Для достижения поставленной цели в работе определены и решены следующие задачи: представление непрерывного аналогового сигнала во временной области дискретными значениями в частотной области на основе вейвлет-преобразования; сокращение размерности матрицы коэффициентов вейвлет-преобразования, используемых для обучения нейронной сети, с применением метода главных компонент; программная реализация предложенного метода выбора существенных характеристик выходных откликов; экспериментальное исследование показателей обучения НСН с применением входных векторов различной длины; анализ полученных результатов.

1. Методы функционального тестирования и диагностики неисправностей аналоговых схем

Существует два подхода к функциональному тестированию аналоговых ИС: методы на основе соответствия спецификации и на основе моделирования неисправностей [2–3]. В ходе первого подхода контролируют соответствие выходных характеристик проверяемой схемы значениям спецификации. Контроль осуществляют как в рабочем режиме, так и в режиме тестирования, когда на вход схемы подают специальные тестовые сигналы. Второй подход получил большее распространение, поскольку обеспечивает решение задачи не только тестирования, но и диагностики неисправностей [4]. Оценка влияния возможных неисправностей на работу схемы – важный подготовительный этап, в ходе которого формируют справочник неисправностей, а затем последовательно внедряют неисправности одну за другой в исправную схему и выполняют моделирование ее поведения. Выходные отклики, измеряемые в тестовых узлах схемы, для исправного состояния и для каждой рассмотренной неисправности сохраняют в справочнике неисправностей. Для аналоговых схем различают катастрофические и параметрические неисправности. Катастрофические связывают с возникновением в схеме эффектов обрыва цепи или короткого замыкания. При параметрических неисправностях наблюдается отклонение параметров внутренних компонентов за пределы допусков. Для аналоговой схемы множество катастрофических неисправностей конечно, а множество параметрических – бесконечно. Наличие допусков на параметры внутренних компонентов схемы, в свою очередь, определяет случайность поведения как исправной, так и неисправной схемы. Таким образом, для достоверного представления поведения схемы возникает необходимость использования метода статистических испытаний при моделировании каждого состояния устройства. Как следствие, оценка поведения исправной схемы и с учетом рассматриваемых неисправностей – сложная вычислительная задача, требующая существенных временных затрат. Использование современных высокопроизводительных вычислительных систем для моделирования неисправностей в аналоговых схемах позволяет получить результат за приемлемое время за счет распараллеливания задачи на нескольких вычислительных узлах [5].

Размерность справочника неисправностей (СН) и механизм последовательного поиска соответствий в структуре СН – слабые стороны данного метода. Развитие инструментов машинного обучения открыло возможность перехода к НСН, функционирующим в ассоциативном режиме, архитектура которых нечувствительна к количеству рассматриваемых неисправностей. Методы машинного обучения и анализа данных позволяют преодолеть проблему больших данных о поведении аналоговой схемы, полученных в ходе моделирования, при построении эффективного НСН, обеспечивающего тестирование и диагностику неисправностей. При этом возникают сложности, связанные с выбором архитектуры нейронной сети, а также структуры и количества обучающих наборов [6–8]. Выбор параметров, которые будут использованы для обучения нейронной сети, – важная задача, результат которой оказывает существенное влияние на сходимость процесса обучения, его длительность и качество покрытия неисправностей при распознавании откликов тестируемой схемы.

2. Декомпозиция маршрута построения нейроморфного справочника неисправностей для аналоговых схем

Формирование условий и механизмов тестирования и диагностики разрабатываемой схемы осуществляют в рамках тестопригодного проектирования, учитывая структуру схемы и ее особенности уже на ранних этапах проектирования. Маршрут формирования справочника неисправностей на основе нейронной сети представлен на рис. 1.

Исходными данными являются список соединений (*netlist*) оригинальной схемы; список возможных неисправностей $\mathbf{FL} = [f_j]$, $j = 1..N$, который может включать как катастрофические, так и

параметрические неисправности; модели неисправностей. Для каждого i -го состояния схемы $c_i \in C$ формируется соответствующее описание схемы, которое поступает на моделирование,

$$C = C_{ff} \cup C_{cf} \cup C_{pf}; \quad (1)$$

$$C_{ff} = c_1; \quad (2)$$

$$C_{cf} = [c_k], k = 2..(N_{cf} + 1); \quad (3)$$

$$C_{pf} = [c_l], l = (N_{cf} + 2)..(N_{cf} + 1 + N_{pf}), \quad (4)$$

где C_{ff} – состояние исправной схемы; C_{cf} – множество состояний схемы с катастрофическими неисправностями; C_{pf} – множество состояний схемы с параметрическими неисправностями; N_{cf} – количество рассмотренных катастрофических неисправностей; N_{pf} – количество рассмотренных параметрических неисправностей.




Рис. 1. Маршрут формирования нейроморфного справочника неисправностей

Fig. 1. The route of formation of the neuromorphic fault dictionary

Моделирование. Для учета динамических и нелинейных свойств аналоговой схемы моделирование осуществляется во временной области с использованием анализа переходного режима. Для учета влияния допусков в ходе моделирования использован метод Монте-Карло, который обеспечивает вычисление наиболее реалистичных значений выходных откликов схемы с учетом статистической функции распределения параметров внутренних компонентов.

Значение параметра для каждого внутреннего компонента схемы p_i на каждом шаге моделирования рассчитывают по формуле

$$p_i = p_{nom_i} (1 + \Delta_i \xi_i), \quad (5)$$

где p_{nom_i} – номинальное значение параметра i -го компонента из списка соединений; Δ_i – относительный разброс параметра p_i ; ξ_i – центрированная случайная величина, принимающая значение на отрезке $(-1, +1)$ по нормальному закону с нулевым математическим ожиданием и среднеквадратическим отклонением $\sigma = 0,25$. В ходе моделирования аналоговой схемы методом Монте-Карло можно задавать закон распределения, соответствующий типовым разбросам параметров внутренних компонентов для реальной технологической линии.

Многократное повторение расчета выходной функции при случайных отклонениях параметров внутренних компонентов позволяет сформировать множество выходных откликов схемы

$$R = [R_i], R_i = [r_i^m], R \in \mathfrak{R}_{NR \times t}, \quad (6)$$

где r_i^m – вектор временных отсчетов выходного отклика схемы длины t , $i = 1..N+1$ – количество состояний схемы, m – количество итераций метода Монте-Карло, $NR = mN + m$, t – количество временных точек.

Вейвлет-преобразование. В силу влияния шумов, нелинейных искажений, фазового сдвига и тому подобного непосредственное использование выходных откликов для тестирования и диагностики нежелательно без предварительной обработки или выделения из них существенных характеристик. В маршруте предложено использовать вейвлет-преобразование (ВП) для представления непрерывного аналогового сигнала во временной области дискретными значениями в частотной области

В ходе вейвлет-преобразования одномерного сигнала реализуется его представление в виде обобщенного ряда или интеграла Фурье (7) по системе базисных функций (8), сконструированных из материнского вейвлета $\psi(t)$, за счет операций сдвига во времени (b) и изменения временного масштаба (a). Множитель $1/\sqrt{a}$ обеспечивает независимость нормы этих функций от масштабирующего числа a :

$$W(a, b) = \int_{-\infty}^{\infty} f(t) \psi_{a,b}^*(t) dt, \quad (7)$$

$$\psi_{ab} = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right). \quad (8)$$

В результате вейвлет-преобразования

$$WT : \mathbf{R} \rightarrow \mathbf{X} \quad (9)$$

непрерывный выходной отклик представляют кортежем коэффициентов масштабирования a и сдвига b : $x = [a; b]$, а множество рассматриваемых откликов – матрицей коэффициентов вейвлет-преобразования $\mathbf{X} = [x_i], i = 1..N, \mathbf{X} \in \mathfrak{R}_{N \times M}$.

Выбор существенных характеристик. Не все коэффициенты ВП одинаково полезны для определения различий откликов одних состояний схемы от откликов других состояний. Использование большого числа коэффициентов на входе НС, в том числе незначущих, приводит к росту сложности и вычислительным затратам на обучение. Кроме того, оно может спровоцировать проблемы сходимости или переобучения НС. В этой связи снижение размерности вектора коэффициентов ВП на входе НС за счет выбора из них наиболее значимых – важная задача. Для ее решения предложено использовать метод главных компонент, суть которого:

$$PCA: \mathbf{X} \rightarrow \hat{\mathbf{X}}, \quad \mathbf{X} \in \mathfrak{R}_{N \times M}, \quad \hat{\mathbf{X}} \in \mathfrak{R}_{N \times \hat{M}}, \quad M > \hat{M}. \quad (10)$$

Обучение нейронной сети. Для построения нейроморфного СН выбрана трехслойная нейронная сеть. Множество коэффициентов ВП $\hat{\mathbf{X}}$ представляем двумя подмножествами – обучающим ($\hat{\mathbf{X}}_{train}$) и тестовым ($\hat{\mathbf{X}}_{test}$). Обучение НС осуществляется с применением строк матрицы $\hat{\mathbf{X}}_{train}$ и ассоциированных с ними выходных векторов $\mathbf{y}_i$. Длина $\mathbf{y}_i$ соответствует количеству рассматриваемых состояний схемы и определяет количество нейронов в выходном слое НС. Для представления состояния использована прямая схема, когда все разряды вектора принимают значение 0 за исключением разряда, соответствующего номеру текущего рассматриваемого состояния, где назначена –1. Обучение НС завершается, если достигнут допустимый уровень ошибки обучения или превышен предел числа итераций обучения. При невыполнении первого или второго условий возможно повторное обучение НС.

Оценка покрываемости неисправностей. Качество обучения НС для решения задачи диагностики оценивают общим показателем покрываемости неисправностей в схеме

$$FC = \frac{N_{detected}}{N_{total}}, \quad (11)$$

где $N_{detected}$ – количество обнаруженных неисправностей, N_{total} – общее количество неисправностей, а также покрываемостью отдельно взятой неисправности

$$FC_i = \frac{N_{detected}^i}{N_{total}^i}, \quad (12)$$

где $N_{detected}^i$ – количество обнаруженных i -х неисправностей, N_{total}^i – общее количество i -х неисправностей.

Если покрываемость неисправностей ниже требуемого уровня, то необходимо пересмотреть множество используемых коэффициентов $\hat{\mathbf{X}}$ и повторить обучение НС.

3. Выбор существенных характеристик с использованием метода главных компонент

Метод главных компонент (МГК) обеспечивает проецирование данных одной размерности на подпространство меньшей размерности. Возникающие при этом остатки $\mathbf{E}$ принято считать шумом, не содержащим значащей информации. Пусть матрица данных $\mathbf{X}$ имеет I строк, которые называют образцами, и J столбцов, представляющих независимые переменные. Главными компонентами называют формальные переменные t_a , $a = 1..A$, которые являются линейной комбинацией исходных переменных x_j , $j = 1..J$,

$$t_a = p_{a1}x_1 + p_{a2}x_2 + \dots + p_{aJ}x_J, \quad (13)$$

A – число главных компонент, причем $A < I$, $A < J$.

Используя (13), матрицу $\mathbf{X}$ представляют произведением

$$\mathbf{X} = \mathbf{T}\mathbf{P}^t + \mathbf{E} = \sum_{a=1}^A t_a \mathbf{p}_a^t + \mathbf{E}, \quad (14)$$

где $\mathbf{T} \in \mathfrak{R}_{I \times A}$ – матрица счетов, $\mathbf{P} \in \mathfrak{R}_{J \times A}$ – матрица нагрузок и $\mathbf{E} \in \mathfrak{R}_{I \times J}$ – матрица остатков. Матрица счетов $\mathbf{T}$ представляет проекции исходных образцов – J -мерных векторов $\mathbf{x}_i$ – на A -мерное подпространство главных компонент. Строки матрицы $\mathbf{T}$ содержат координаты образцов в новой системе координат, а столбцы представляют проекции всех образцов на одну новую координатную ось и являются ортогональными. Матрица нагрузок $\mathbf{P}$ является матрицей перехода из исходного I -мерного пространства переменных $\mathbf{x}_j$ в A -мерное подпространство главных компонент. Строки матрицы $\mathbf{P}$ содержат коэффициенты, связывающие переменные t и x согласно (13).

МГК реализуется итерационной процедурой, в которой новые главные компоненты (PC – principal components) добавляются последовательно друг за другом [9]. Важно определить, когда остановить данный процесс, и выбрать достаточное число главных компонент. При малом количестве PC совокупная выборка данных будет неполной, при большом – возникает переоценка.

Для выбора достаточного количества PC предложено использовать следующий критерий:

$$\arg \min_{PC} (ERV_{PC} \geq ERV_{TH}), \quad (15)$$

где ERV_{PC} – объясненная дисперсия; ERV_{TH} – пороговое значение.

Результат моделирования методом главных компонент – матрица $\hat{\mathbf{X}}$, содержащая оценки, найденные по модели, построенной на обучающем наборе $\mathbf{X}$. Отклонение оценки от проверочного значения вычисляют как матрицу остатков

$$\mathbf{E} = \mathbf{X} - \hat{\mathbf{X}}, \quad (16)$$

элементы которой используют для расчета объясненной дисперсии остатков в (15)

$$ERV = 1 - \frac{\sum_{i=1}^I \sum_{j=1}^J e_{ij}^2}{\sum_{i=1}^I \sum_{j=1}^J x_{ij}^2}, \quad e_{ij} \in \mathbf{E}, \quad x_{ij} \in \mathbf{X}. \quad (17)$$

Применение метода главных компонент обеспечивает сокращение числа используемых коэффициентов для обучения нейронной сети ($\hat{M} < M$).

4. Экспериментальные исследования

Исследование предложенного подхода выполнено на контрольной схеме аналогового фильтра Саллена–Ки (рис. 2). В качестве тестового сигнала использован синусоидальный сигнал с амплитудой 1 В и частотой 72 Гц. Допуски на параметры внутренних компонентов схемы – для резисторов и конденсаторов – определены величиной 10%. Список рассмотренных одиночных неисправностей включает 14 катастрофических и 14 параметрических неисправностей. Катастрофические неисправности представлены эффектами обрыва цепи (ОЦ) и короткого замыкания (КЗ) для каждого компонента схемы. Параметрические неисправности задаются отклонениями $\pm 50\%$ от номинального значения для каждого компонента.




Рис. 2. Схема аналогового фильтра Саллена–Ки

Fig. 2. The circuit of analog Sallen–Key filter




Рис. 3. График зависимости объясненной дисперсии остатков от количества главных компонент

Fig. 3. A graph of the explained variance of residuals versus the number of principal components

Моделирование схемы фильтра для 29 состояний (одно исправное и 28 неисправных) выполнено во временной области с использованием метода Монте-Карло. Для моделирования схем использован пакет PSpice САПР CADENCE. Количество итераций для исправного состояния составляет 20 000, а для каждого неисправного состояния – 5 000. Выходные ответы измеряются в течение одного периода относительно тестового узла 4 с задержкой 80 мс с момента запуска теста.

Материнский вейвлет Добеши четвертого порядка (db4) использован для преобразования выходных откликов схемы из временной области в частотную область. В результате для каждого сигнала формируется вектор коэффициентов вейвлет преобразования длиной 148 элементов (по 74 для коэффициентов a и b). Обучающее множество включает 600 откликов из 20 000 для исправного состояния и по 200 откликов из 5 000 для каждого неисправного состояния. В результате была сформирована матрица коэффициентов ВП $\mathbf{X}_{train}$, включающая 6 200 строк по 148 элементов. Отклики, не включенные в это обучающее множество, образуют тестовое множество $\mathbf{X}_{test}$.

Матрицы счетов и нагрузок, а также объясненная остаточная дисперсия были рассчитаны с использованием МГК для множества $\mathbf{X}_{train}$. График для ERV представлен на рис. 3. Требуемое минимальное количество главных компонент определяется порогом $ERV_{TH} \geq 0,95$, поэтому в результирующем обучающем множестве $\hat{\mathbf{X}}_{train}$ будут использованы только 62 коэффициента для каждого отклика. При уменьшении объема значимой информации на 5% удалось уменьшить размер обучающего множества почти в 2,4 раза.

Трехслойная нейронная сеть использована для реализации НСН. Входной слой состоит из 62 нейронов в соответствии с количеством используемых коэффициентов в обучающем наборе для каждого отклика. Выходной слой состоит из 29 нейронов для представления рассматриваемых состояний схемы относительно соответствующего отдельного выходного нейрона.

Время, затраченное на обучение НСН для разных исходных данных и оцененное в ходе экспериментов, представлено в табл. 1.

Таблица 1

Характеристики обучения НСН

Номер НСН	1	2
Архитектура НС ¹	62 : 20 : 29	148 : 20 : 29
Использованные методы ²	ВП + МГК	ВП
Количество эпох обучения	109	119
Точность обучения	0,0106	0,0096
Величина ERV	0,9505	–
Время, с	24 147	271 800

¹ Показывает количество нейронов в первом : втором : третьем уровнях нейронной сети.

² ВП: вейвлет-преобразование временных откликов, ВП + МГК – преобразование матрицы с коэффициентами ВП временных откликов схемы методом главных компонент.

Построение и обучение нейронной сети осуществлялось с использованием набора инструментов Neural Network Toolbox пакета MATLAB на вычислительной системе с процессором Intel® Core™ i7-4770 @ 3,40 ГГц и оперативной памятью 8 ГБ.

Результаты покрытия отдельных неисправностей (FC), полученные для тестового множества, показаны в табл. 2. Анализ значений FC для режимов тестирования (FC_{test}) и диагностики (FC_{diag}), оцененных для отдельных неисправностей с использованием НСН, демонстрирует адекватность перехода от архитектуры 2 к архитектуре 1.

Таблица 2

Покрываемость отдельных неисправностей при тестировании и диагностике

Номер НСН	1		2		Номер НСН	1		2	
Состояние схемы	FC_{test}	FC_{diag}	FC_{test}	FC_{diag}	Состояние схемы	FC_{test}	FC_{diag}	FC_{test}	FC_{diag}
Исправное	0,9059	–	0,8974	–	–	–	–	–	–
Катастрофические неисправности	R1_K3	1	1	1	Параметрические неисправности	R1_+ 50%	0,8274	0,7328	0,8372
	R1_ОЦ	1	0,9888	0,9996		R1_– 50%	0,9552	0,9198	0,9602
	R2_K3	1	1	1		R2_+ 50%	0,9808	0,9020	0,9750
	R2_ОЦ	1	1	1		R2_– 50%	1	0,9964	1
	R3_K3	0,9978	0,8992	0,9978		R3_+ 50%	0,9324	0,9002	0,9424
	R3_ОЦ	1	0,9958	1		R3_– 50%	0,9996	0,8123	0,9980
	RA_K3	1	0,9900	1		RA_+ 50%	0,9720	0,8944	0,9716
	RA_ОЦ	1	1	1		RA_– 50%	1	0,8421	0,9996
	RB_K3	1	1	1		RB_+ 50%	0,9734	0,8198	0,9726
	RB_ОЦ	1	0,9874	1		RB_– 50%	1	0,9412	1
	C1_K3	1	1	1		C1_+ 50%	0,9982	0,8834	0,9990
	C1_ОЦ	0,9822	0,4734	0,9976		C1_– 50%	0,9998	0,9082	1
	C2_K3	1	0,9964	1		C2_+ 50%	0,9616	0,8370	0,9550
	C2_ОЦ	1	1	1		C2_– 50%	1	0,9886	1

Обнаружение исправного состояния фильтра на уровне 89,7% связано с подобием поведения исправной схемы и схемы с несколькими типами параметрических неисправностей. Увеличение количества откликов для исправной схемы в обучающем множестве позволит улучшить качество диагностики данного состояния, но в то же время приведет к увеличению ошибки второго рода, когда для соответствующих параметрических неисправностей схема будет признана исправной.

Таблица 3

Покрываемость отдельных неисправностей при тестировании и диагностике

Номер НСН	Тестирование				Диагностика		
	α	FC_{all}	FC_{cat}	FC_{par}	FC_{all}	FC_{cat}	FC_{par}
1	0,094	0,985	0,999	0,972	0,901	0,953	0,848
2	0,103	0,986	0,999	0,972	0,905	0,947	0,862

Примечание. α – значение ошибки первого рода для исправного состояния; FC_{all} – покрываемость для всех типов рассмотренных неисправностей; FC_{cat} – покрываемость для всех рассмотренных катастрофических неисправностей; FC_{par} – покрываемость для всех рассмотренных параметрических неисправностей.

Общие значения покрываемости неисправностей для режимов тестирования и диагностики, обеспеченные НСН, представлены в табл. 3. Ограничение количества главных компонент по уровню $ERV_{TH} \geq 0,95$ приводит к уменьшению размерности обучающего множества в 2,39 раза и времени обучения в 11,26 раза, обеспечивая при этом высокий уровень покрываемости неисправностей.

Заключение

Выбор существенных характеристик с использованием МГК позволил уменьшить размер обучающего множества почти в 3 раза и снизить затраты времени на обучение нейронной сети более чем в 11 раз. Полученный НСН обеспечивает решение задач как тестирования, так и диагностики неисправностей в ассоциативном режиме. Результаты экспериментальных исследований демонстрируют высокую покрываемость неисправностей: при тестировании для катастрофических неисправностей – до 99,9%, для параметрических неисправностей – до 97,2%, а при диагностике для катастрофических неисправностей – до 95,3% и параметрических – до 84,8%. Описание процесса формирования НСН в виде сквозного маршрута позволяет автоматизировать этот этап и использовать его в рамках тестопригодного проектирования аналоговых ИС.

ЛИТЕРАТУРА

1. Мосин С.Г. Анализ методов тестопригодного проектирования аналоговых и смешанных ИС // Известия высших учебных заведений. Электроника. 2007. № 1. С. 59–64.
2. Variyam P.N., Chatterjee A. Specification-driven test design for analog circuits // Proc. 1998 IEEE International Symposium on Defect and Fault Tolerance in VLSI Systems (Cat. No. 98EX223). 1998. P. 335–340. DOI: 10.1109/DFTVS.1998.732183.
3. Zhirabok A., Baranov A. Fault Diagnosis in Analog Electrical Circuits: Data-Driven Method // Proc. International Conference on Process Control. 2013. P. 1–6. DOI: 10.1109/PC.2013.6581389.
4. Мосин С.Г. Тестирование аналоговых схем с использованием нейросетевого сигнатурного анализатора // Вестник компьютерных и информационных технологий. 2012. № 10. С. 3–8.
5. Mosin S. Automated simulation of faults in analog circuits based on parallel paradigm // Proc. IEEE East-West Design & Test Symposium, Novi Sad, 2017. P. 1–6. DOI: 10.1109/EWDTS.2017.8110133.
6. Aminian M., Aminian F. Neural-network based analog circuit fault diagnosis using wavelet transform as preprocessor // IEEE Trans. CAS II. 2000. V. 47, No. 2. P. 151–156. DOI: 10.1109/82.823545.
7. Yuan L., He Y., Huang J. and Sun Y. A new neural-network-based fault diagnosis approach for analog circuits by using kurtosis and entropy as a preprocessor // IEEE Transactions on Instrumentation and Measurement. 2010. V. 59, No. 3. P. 586–595. DOI: 10.1109/TIM.2009.2025068.
8. Xiong J., Tian S. and Yang C. Fault Diagnosis for Analog Circuits by Using EEMD, Relative Entropy, and ELM // Computational Intelligence and Neuroscience. 2016. Article ID 7657054. 9 p. DOI: 10.1155/2016/7657054.
9. Jolliffe I.T. Principal Component Analysis. Springer, 2002.

Статья поступила 25 августа 2018 г.

Mosin S.G. (2019) OPTIMIZATION OF CONSTRUCTING THE NEUROMORPHIC FAULT DICTIONARY FOR TESTING AND DIAGNOSTICS OF ANALOG ICs. *Vestnik Tomskogo gosudarstvennogo universiteta. Upravlenie, vychislitel'naja tehnika i informatika* [Tomsk State University Journal of Control and Computer Science]. 48. pp. 103–111

DOI: 10.17223/19988605/48/12

Fault diagnostics of integrated circuits (IC) is an important stage of the production cycle, providing the detection of the faults location during testing and ensuring the high quality of the ICs batch at the output. Testing and diagnostics of analog ICs represent significant functional complexity compared to digital ICs. In many respects this is facilitated by the continuous nature of the signals being processed, the complex nonlinear dependences of the input and output signals, the tolerances on the parameters of internal components that randomly affect the deviations of the parameters and the transfer function from the nominal values, the sensitivity of the output characteristics to the deviations of internal and external parameters, possibility of appearance not only catastrophic, but also parametric faults, the lack of effective models for analog faults, etc.

There are two approaches to functional testing of analog ICs: specification-driven methods based on compliance with the specification and data-driven methods based on the fault simulation. The second approach is widely used because it provides the solution to the task of not only testing, but also faults diagnostics. The dimension of the fault dictionary (FD) and the mechanism for sequential matching in the FD structure are the weaknesses of this method. The development of machine learning tools has opened the possibility

of transition to neuromorphic FD, operating in an associative mode, the architecture of which is not sensitive to the number of considered faults. The choice of the parameters that will be used to train the neural network is an important task, the result of which has a significant influence on the convergence of the training process, its duration and the quality of the fault coverage. The scopes of the proposed work is to search for and study the method of selecting the essential characteristics of the output response for the circuit under test, which reduce the computational and time costs for training the neuromorphic FD (NFD) without reducing the coverage of the considered faults. To achieve this goal, the following tasks are defined and solved: representation of a continuous analog signal in the time domain by discrete values in the frequency domain based on the wavelet transform (WT); reducing the dimension of the matrix of WT-coefficients applied for training the neural network, using the principal components analysis; software implementation of the proposed method for selecting the essential characteristics of output responses; experimental study of indices of training the NFD with the use of input vectors of different lengths; analysis of the obtained results.

In the result of the wavelet transform the continuous output response is represented by a tuple of the scaling factors a and the shifts b : $x = [a; b]$, and the set of considered responses is a matrix of WT-coefficients $\mathbf{X} = [x_i]$, $i = 1..N$, $\mathbf{X} \in \mathbb{R}_{N \times M}$. The application of the principal component analysis (PCA) provides a reduction in the number of coefficients used for training the neural network

$$PCA: \mathbf{X} \rightarrow \hat{\mathbf{X}}, \mathbf{X} \in \mathbb{R}_{N \times M}, \hat{\mathbf{X}} \in \mathbb{R}_{N \times \hat{M}}, M > \hat{M}.$$

PCA is implemented by an iterative procedure in which new principal components (PC) are added sequentially one after another. It is important to determine when to stop this process, and to take a sufficient number of principal components. With a small number of PCs, the aggregate sample of data will be incomplete, at large number an overvaluation arises. The criterion for selecting a sufficient number of PCs is defined:

$$\arg \min_{PC} (ERV_{PC} \geq ERV_{TH}),$$

where ERV_{PC} is the explained residual variance, ERV_{TH} is the threshold value.

The experimental studies were carried out for the analog filter circuit on operational amplifier using the developed software. The obtained results have demonstrated the effectiveness of the proposed method of selecting the essential characteristics of output responses, which is reflected in the reduction of time and computational costs for training. The resultant NFD provides the fault coverage up to 100%.

The work is performed according to the Russian Government Program of Competitive Growth of Kazan Federal University.

Keywords: principal component analysis; neuromorphic fault dictionary; testing; diagnostics; analog integrated circuits.

MOSIN Sergey Gennadievich (Candidate of Technical Sciences, Associate Professor, Kazan (Volga region) Federal University, Kazan, Russian Federation).

E-mail: smosin@ieee.org

REFERENCES

1. Mosin, S.G. (2007) Analysis of design-for-testability methods for analog and mixed-signal IC. *Elektronika*. 1. pp. 59–64. (In Russian).
2. Variyam, P.N. & Chatterjee, A. (1998) Specification-driven test design for analog circuits. *Proceedings IEEE International Symposium on Defect and Fault Tolerance in VLSI Systems*. pp. 335–340. DOI: 10.1109/43.875320
3. Zhirabok, A. & Baranov, A. (2013) Fault Diagnosis in Analog Electrical Circuits: Data-Driven Method. *Proc. International Conference on Process Control*. pp. 1–6. DOI: 10.1109/PC.2013.6581389
4. Mosin, S.G. (2012) A testing of analog circuits using neural network signature analyzer. *Vestnik komp'yuternykh i informatsionnykh tekhnologiy – Herald of Computer and Information Technologies*. 10. pp. 3–8. (In Russian).
5. Mosin, S. (2017) Automated simulation of faults in analog circuits based on parallel paradigm. *Proc. IEEE East-West Design & Test Symposium*. pp. 1–6. DOI: 10.1109/EWDTS.2017.8110133
6. Aminian, M. & Aminian, F. (2000) Neural-network based analog circuit fault diagnosis using wavelet transform as preprocessor. *IEEE Trans. CAS II*. 47(2). pp. 151–156. DOI: 10.1109/82.823545
7. Yuan, L., He, Y., Huang, J. & Sun, Y. (2010) A new neural-network-based fault diagnosis approach for analog circuits by using kurtosis and entropy as a preprocessor. *IEEE Transactions on Instrumentation and Measurement*. 59(3). pp. 586–595. DOI: 10.1109/TIM.2009.2025068
8. Xiong, J., Tian, S. & Yang, C. (2016) Fault Diagnosis for Analog Circuits by Using EEMD, Relative Entropy, and ELM. *Computational Intelligence and Neuroscience*. Article ID 7657054. DOI: 10.1155/2016/7657054
9. Jolliffe, I.T. (2002) *Principal Component Analysis*. Springer.