

А.М. Алексеев, канд. техн. наук, М.А. Алексеев, докт. тех. наук.

(Украина, Днепр, Национальный технический университет «Днепропетровская политехника»)

ЭКСПЕРИМЕНТАЛЬНОЕ ИССЛЕДОВАНИЕ МЕТОДОВ КОНТРОЛЯ ВИБРОПАРАМЕТРОВ ОБЪЕКТОВ УПРАВЛЕНИЯ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ

Анотація. Показано, що при контролі вібропараметрів об'єктів управління нейромережеві методи допускають емпіричний підхід до завдання класифікації. Для навчання нейронних мереж потрібна менша кількість реалізацій, чим для статистичного аналізу вхідних сигналів. У загальному випадку мережа із зворотним поширенням помилки дозволяє досягти меншої кількості помилок класифікації, чим будь-який з варіантів ART. При використанні репрезентативної контрольної вибірки класифікація з використанням перестроєваних спектральних операторів по ефективності порівнянна з класифікацією за допомогою двошарової нейронної мережі, в той же час забезпечуючи значно менший час навчання.

Ключові слова: об'єкт керування, контроль, вібропараметр, нейромережа, перестроєвані спектральні оператори.

Аннотация. Показано, что при контроле вибропараметров объектов управления нейросетевые методы допускают эмпирический подход к задаче классификации. Для обучения нейронных сетей требуется меньшее количество реализаций, чем для статистического анализа входных сигналов. В общем случае сеть с обратным распространением ошибки позволяет достичь меньшего количества ошибок классификации, чем любой из вариантов ART. При использовании репрезентативной контрольной выборки классификация с использованием перестраиваемых спектральных операторов по эффективности сопоставима с классификацией при помощи двухслойной нейронной сети, в то же время обеспечивая значительно меньшее время обучения.

Ключевые слова: объект управления, контроль, вибропараметр, нейросеть, перестраиваемые спектральные операторы.

Abstract. It is shown that when controlling vibration parameters of control objects, neural network methods allow an empirical approach to the classification problem. For learning neural networks, fewer implementations are required than for statistical analysis of input signals. In the general case, a back-propagation network allows for a smaller number of classification errors than any of the ART options. When using a representative control sample, the classification using tunable spectral operators is comparable in efficiency to the classification using a two-layer neural network, while at the same time providing significantly less training time.

Keywords: control object, vibration parameters checkout, neural network, reconfigurable spectral operators.

Введение

Спектральные методы обработки информации получили широкое распространение в задачах контроля вибрационных параметров объектов управления. Анализ частотных параметров вибраций объектов управления позволяет получать информацию об их техническом состоянии. Во многих случаях решение задач виброконтроля и диагностирования объектов связано с классификацией вибрационных сигналов. Возможным решением задачи классификации может стать использование искусственных нейронных сетей. В настоящей статье рассмотрены наиболее известные парадигмы нейронных сетей [1].

Анализ существующих достижений и публикаций

Процедура использования методов контроля параметров объектов управления по спектрам в традиционных базисах хорошо известно и широко описана в литературе. В соответствии с требованиями, предъявляемыми к признакам при решении задач оперативного функционального контроля, обоснованный выбор базиса разложения необходимо проводить по комплексу критериев, вытекающих из рассмотрения информационного и вычислительного аспектов методов формирования признаков, а также требования простоты аппаратурной и программной реализации методов. Согласно подходу, который предложен академиком Петровым Б.М., целесообразно использование в качестве информационного критерия при выборе признаков понятия энтропии. Основная идея при информационно-энергетическом отборе и порядок признаков заключается в адекватности описания случайного процесса с известной матрицей ковариации спектральными составляющими, которые обеспечивают наименьшую энтропию коэффициентов разложения, наибольшее сосредоточение энергии случайного процесса в минимальном количестве

членов разложения, декореляции коэффициентов разложения и приспособленность к входным данным. Этими свойствами обладают коэффициенты разложения в базисе Карунена-Лоева. Процедура диагонализации матрицы ковариаций относительно просто реализуется для матрицы ковариаций циркулянтных типа и диадной матрицы ковариаций. В первом случае базисом Карунена-Лоева есть базис Фурье, во втором - Уолша. Однако матрицы, которые диагонализуются для традиционных базисов, не вполне учитывают особенности физических процессов. В [4] предложен метод контроля параметров объектов управления, основанный на использовании субоптимальных по Карунену-Лоэву перестраиваемых матричных спектральных операторов, каждый из которых синтезирован по эталону технологической ситуации, благодаря чему повышается вероятность правильной классификации параметров и сокращается время на принятие управляющего решения.

Цель исследования

Целью исследования является обоснование выбора метода формирования первичных информативных признаков вибрационных сигналов объектов управления с использованием перестраиваемых матричных спектральных операторов и использования нейронных сетей с целью контроля вибропараметров.

Основная часть

Контроль вибропараметров объектов управления выполнялся посредством классификации вибросигналов с использованием многослойной нейронной сети без обратных связей. Сеть состояла из нейронов с нелинейной активационной функцией во всех слоях, кроме последнего слоя. Для обучения нейронной сети использовался метод обратного распространения ошибки, модифицированный для повышения устойчивости обучения. В процессе моделирования нейронной сети коэффициент инерционности обучения устанавливался равным 0,5; коэффициент скорости обучения подбирался максимально допустимым по условию устойчивости сети (для различных сетей значение варьировалось в диапазоне 0,3-0,05). Метод классификации при помощи нейронных сетей моделировался при помощи специально созданного для этой цели нейросимулятора, разработанного в среде Microsoft Visual C++.

Сравнение методов классификации сигналов проводилось на спектрограммах вибрационных сигналов. Спектрограммы снимались в характерных точках вентиляционных установок шахт Западного Донбасса. Съём спектрограмм производился операторами Павлоградского наладочного управления с целью накопления экспериментального материала для автоматизации спектральной диагностики обслуживаемых ими вентиляционных установок и других объектов. Для классификации были использованы спектрограммы вибраций с основных вентиляторов шахт «Сташкова», «Юбилейная», «Благодатная», «Западно-Донбасская», «Терновская» и резервного вентилятора шахты «Западно-Донбасская».

Отобранные спектрограммы были приведены к длине спектра Фурье в 128 отсчетов и нормированы к единице по амплитуде спектральных компонент. Из отобранных для использования спектров были сформированы 10 различных классов. Разбиение на классы сигналов выполнялось с учетом того, на каких объектах, в каких точках и при каких условиях получены спектры вибраций.

В результате были сформированы 10 исходных классов, к которым отнесены спектры вибраций, характеризующие различные состояния объектов контроля. Спектры, отнесенные к определенному классу, в большинстве случаев коррелированы между собой в большей мере, чем спектры из различных классов. Тем не менее, некоторые спектры сравнительно слабо коррелируют с представителями «своего» класса. В частности, классы №№1, 3, 6 и 10 являются многосвязными в пространстве спектральных компонент. Каждый из сформированных исходных классов случайным образом был разделен на две приблизительно равные части, одна из которых использовалась как совокупность выборок для обучения распознающего алгоритма, а вторая – для проверки качества распознавания.

В процессе эксперимента сравнивалась эффективность классификации исходных спектров из контрольной группы (в скобках – обозначение метода классификации, использованное в табл. 3.1):

1. По евклидовым расстояниям (ED).
2. По минимуму энтропии спектральных коэффициентов перестраиваемых матричных операторов (Entr).
3. При помощи обученной нейросети следующей конфигурации:
Один слой из 10 нейронов (NN-10).
Первый слой – 128, второй – 10 нейронов (NN-128-10).
Первый слой – 128, второй – 60, третий – 10 нейронов (NN-128-60-10).
Первый слой – 128, второй – 300, третий – 10 нейронов (NN-128-300-10).
Первый слой – 200, второй – 80, третий – 10 нейронов (NN-200-80-10).

Также в процессе эксперимента была предпринята попытка использования сети со структурой 128-128-60-10 (4 слоя). Однако вследствие неудовлетворительного времени обучения сети результаты работы четырехслойной сети в таблицу не включены.

Результаты распознавания спектров контрольной группы							
Номер класса	Количество ошибок, по методу классификации						
	ED	Entr	NN-10	NN-128-10	NN-128-60-10	NN-128-300-10	NN-200-80-10
1	5	2	3	2	2	2	1
2		2	2	2	1	1	1
3	2	2	1	1	2	2	2
4		1	2	2	2	1	1
5	6	2	3	2	1	1	2
6	5	2	2	2	2	2	1
7	3	2	1	1	1	1	2
8		3	2	2	1	1	1
9	2	1	3	2	2	2	2
10	5	2	3	2	3	3	1
всего	28	19	22	18	17	16	14
всего, %	57%	19%	18%	17%	17%	16%	14%
Время обучения, эпох			453	181	132	142	82

Классификация с использованием перестраиваемых спектральных операторов по эффективности сопоставима с классификацией при помощи двухслойной нейронной сети, в то же время обеспечивая значительно меньшее время обучения. Метод классификации по евклидову расстоянию на данном наборе спектров дал неудовлетворительные результаты.

Эффективность метода классификации по минимуму энтропии спектральных коэффициентов снижается при переходе от полного к сокращенному набору спектров. Это связано с увеличением дисперсии спектральных компонент обучающих выборок в области высоких частот. В связи с этим анализ энтропии спектральных коэффициентов вторичного разложения целесообразно применять при большом (свыше сотни выборок) объеме исходных данных.

В общем случае использование нейронной сети для классификации сигналов по спектру Фурье требует большего по сравнению с другими методами времени для обучения системы. С другой стороны, вследствие способности к обобщению, для получения удовлетворительных результатов работы нейросети требуется значительно меньшее количество обучающих выборок.

Для получения приемлемого времени и качества обучения количество слоев в сети не должно быть менее трех. При увеличении количества слоев до четырех и более качество обучения несколько повышается, однако резко возрастает время обучения сети. Количество нейронов в слоях сети может быть различным. Результаты моделирования позволяют рекомендовать лишь порядок величин. В последнем слое количество нейронов определяется способом реагирования нейросети на различные классы сигналов. В данном эксперименте количество нейронов выходного слоя принималось равным количеству различаемых классов.

Во входном и скрытых слоях количество нейронов, с одной стороны, должно быть достаточным для запоминания предъявленных обучающих образов (информационная емкость сети повышается с увеличением количества связей между нейронами). С другой стороны, при избыточной информационной емкости сети снижается ее способность к обобщению и появляется склонность к прямому запоминанию отдельных обучающих образов. По-видимому, оптимальное для последнего скрытого слоя количество нейронов в 1,5-2 раза превышает общее количество обучающих образов, а для предыдущих слоев должно быть увеличено еще в несколько раз.

Ниже приведены результаты экспериментального исследования эффективности нейронных сетей с адаптивным резонансом и ограничением количества категорий (ART-C) в задачах классификации сигналов по спектру. Проведен сравнительный анализ эффективности сетей ART-C, обучающихся самостоятельно и с учителем. Также приведены результаты испытания экспериментальной сети ART-C с голосованием. В рамках эксперимента были исследованы сети ART-2 в исходном виде и с ограничением количества категорий.

Для поиска категорий и проверки критерия резонанса использовалась косинусная функция соответствия

$$T_j = M_j = \frac{A \cdot w_j}{\|A\| \|w_j\|},$$

$$\|X\| = \sqrt{\sum_i x_i^2}, \quad \text{где } \|X\| \text{ – норма } L_2 \text{ вектора } X.$$

Для обучения была использована функция $w_j^{t+1} = (1 - \eta)w_j^t + \eta A$.

В качестве критерия близости была использована функция соответствия $M_{i,j} = \frac{w_i \cdot w_j}{\|w_i\| \|w_j\|}$.

Кроме сетей ART-2 и ART-C, также испытывались вновь разработанные модели сетей ART с управляемым обучением и с голосованием. Для достижения управляемого обучения обычная сеть ART-C была дополнена слоем Гроссберга. Как и в сетях со встречным распространением ошибки, слой Гроссберга обучался преобразованию полученных выходов сети ART в требуемые выходы. В отличие от сетей со встречным распространением ошибки, нейроны в слое Гроссберга в данном случае имели переменную структуру связей. При добавлении новой категории в слой распознавания сети ART каждый из этих нейронов связывался с вновь добавленным нейроном, а затем производилось обучение слоя Гроссберга.

Для обеспечения работы в режиме голосования в состав сети ART-C с управляемым обучением была введена специальная управляющая структура, а также модифицирована работа подсистемы распознавания. В сети с голосованием на входной вектор реагируют все нейроны, вычисляя свою функцию близости. Затем вклады всех нейронов суммируются, и выходом сети считается номер класса, для которого сумма оказалась наибольшей. При суммировании учитывается, сколько раз данный нейрон оказывался победителем при подаче на вход сети образцов данного класса; поэтому в сумму функций близости не включаются «голоса» тех нейронов, которые ни разу не были победителями для входных векторов данного класса. За счет этого отсеиваются реакции нейронов, не имеющих к данному классу никакого отношения.

Сравнение методов классификации сигналов проводилось на спектрограммах вибрационных сигналов.

Ранее на этом же наборе данных производился анализ эффективности классификации спектров при помощи нейронных сетей с обратным распространением ошибки в сравнении с обычными методами классификации. Это позволяет провести корректное сравнение эффективности всех рассмотренных методов, включая ART-C.

В процессе экспериментов сравнивалась эффективность классификации исходных спектров из обучающей и контрольной группы для сетей ART-C с различными значениями параметров функционирования.

Были проведены четыре эксперимента с различными вариантами сетей ART.

1. ART-2. Обучение и классификация проводились с различными значениями параметров η и ρ . Значения η устанавливались в пределах от 0.1 до 1, а ρ – от 0.3 до 0.95.

2. ART-C. В сетях ART-C параметр ρ устанавливается автоматически в процессе работы сети в зависимости от ограничения на количество классов. В процессе проведения эксперимента параметр η устанавливался в пределах от 0.1 до 1, а ограничение на количество классов принималось равным 10, 15, 20 и 25.

3. ART-C с управляемым обучением. Условия эксперимента совпадают с таковыми для ART-C.

4. ART-C с управляемым обучением и голосованием. Условия эксперимента совпадают с таковыми для ART-C.

Эффективность классификации оценивалась по количеству допущенных сетью ошибок и приведена в таблицах 2-4.

Выводы

1. В общем случае сеть с обратным распространением ошибки позволяет достичь меньшего количества ошибок классификации, чем любой из вариантов ART. Это обусловлено большим, чем в ART, количеством межнейронных связей и слоев нейронов, а, следовательно, и большей емкостью сети.

2. Сеть ART способна выделять только односвязные классы, так как она фактически производит динамическую кластеризацию поступающих на ее вход векторов по критерию (обычно геометрической) близости. Таким образом, сеть не способна отнести к одному и тому же классу векторы, распадающиеся

Таблица 2

Результаты работы сети ART-2 на обучающей выборке

η	Количество ошибок, %, для ρ													
	0,3	0,35	0,4	0,45	0,5	0,55	0,6	0,65	0,7	0,75	0,8	0,85	0,9	0,95
0.1	65,5	61,8	61,8	50,9	45,5	45,5	41,8	41,8	29,1	29,1	18,2	10,9	10,9	9,1
0.2	65,5	61,8	61,8	52,7	47,3	45,5	43,6	41,8	29,1	29,1	21,8	10,9	10,9	5,5
0.3	65,5	61,8	61,8	52,7	49,1	45,5	41,8	41,8	27,3	29,1	21,8	16,4	10,9	5,5
0.4	61,8	61,8	52,7	52,7	49,1	45,5	41,8	41,8	27,3	29,1	21,8	16,4	10,9	5,5
0.5	61,8	52,7	49,1	52,7	49,1	49,1	43,6	41,8	27,3	23,6	21,8	16,4	10,9	5,5
0.6	52,7	52,7	47,3	52,7	50,9	49,1	41,8	30,9	27,3	29,1	21,8	10,9	10,9	5,5
0.7	52,7	52,7	45,5	52,7	50,9	49,1	32,7	25,5	29,1	25,5	21,8	10,9	10,9	5,5
0.8	56,4	52,7	47,3	52,7	41,8	40,0	30,9	29,1	29,1	25,5	16,4	12,7	10,9	5,5
0.9	54,5	54,5	49,1	43,6	45,5	32,7	30,9	29,1	25,5	25,5	12,7	12,7	10,9	5,5
1.0	54,5	54,5	49,1	43,6	43,6	34,5	34,5	30,9	29,1	25,5	16,4	12,7	10,9	5,5

Таблица 3

Результаты работы сети ART-2 на тестовой выборке

η	Количество ошибок, %, для ρ													
	0,3	0,35	0,4	0,45	0,5	0,55	0,6	0,65	0,7	0,75	0,8	0,85	0,9	0,95
0.1	69,4	67,3	67,3	57,1	59,2	59,2	51,0	51,0	40,8	42,9	36,7	32,7	36,7	61,2
0.2	69,4	69,4	67,3	59,2	55,1	57,1	55,1	51,0	38,8	40,8	38,8	28,6	36,7	59,2
0.3	69,4	67,3	67,3	59,2	55,1	55,1	53,1	53,1	38,8	40,8	38,8	34,7	36,7	59,2
0.4	67,3	67,3	59,2	59,2	55,1	53,1	51,0	49,0	36,7	38,8	40,8	36,7	38,8	57,1
0.5	67,3	59,2	59,2	59,2	55,1	55,1	49,0	46,9	34,7	34,7	40,8	38,8	38,8	55,1
0.6	59,2	59,2	57,1	59,2	59,2	55,1	49,0	34,7	34,7	38,8	40,8	36,7	38,8	55,1
0.7	59,2	59,2	57,1	59,2	59,2	55,1	36,7	32,7	34,7	40,8	40,8	36,7	38,8	55,1
0.8	61,2	59,2	57,1	59,2	53,1	46,9	34,7	32,7	36,7	40,8	36,7	34,7	38,8	55,1
0.9	57,1	57,1	55,1	51,0	53,1	40,8	36,7	36,7	38,8	46,9	34,7	34,7	38,8	55,1
1.0	55,1	55,1	53,1	51,0	46,9	40,8	36,7	40,8	49,0	46,9	40,8	36,7	40,8	55,1

Таблица 4

Результаты работы сети ART-2 на тестовой выборке

η	Количество ошибок, %, для ρ													
	0,3	0,35	0,4	0,45	0,5	0,55	0,6	0,65	0,7	0,75	0,8	0,85	0,9	0,95
0.1	69,4	67,3	67,3	57,1	59,2	59,2	51,0	51,0	40,8	42,9	36,7	32,7	36,7	61,2
0.2	69,4	69,4	67,3	59,2	55,1	57,1	55,1	51,0	38,8	40,8	38,8	28,6	36,7	59,2
0.3	69,4	67,3	67,3	59,2	55,1	55,1	53,1	53,1	38,8	40,8	38,8	34,7	36,7	59,2
0.4	67,3	67,3	59,2	59,2	55,1	53,1	51,0	49,0	36,7	38,8	40,8	36,7	38,8	57,1
0.5	67,3	59,2	59,2	59,2	55,1	55,1	49,0	46,9	34,7	34,7	40,8	38,8	38,8	55,1
0.6	59,2	59,2	57,1	59,2	59,2	55,1	49,0	34,7	34,7	38,8	40,8	36,7	38,8	55,1
0.7	59,2	59,2	57,1	59,2	59,2	55,1	36,7	32,7	34,7	40,8	40,8	36,7	38,8	55,1
0.8	61,2	59,2	57,1	59,2	53,1	46,9	34,7	32,7	36,7	40,8	36,7	34,7	38,8	55,1
0.9	57,1	57,1	55,1	51,0	53,1	40,8	36,7	36,7	38,8	46,9	34,7	34,7	38,8	55,1
1.0	55,1	55,1	53,1	51,0	46,9	40,8	36,7	40,8	49,0	46,9	40,8	36,7	40,8	55,1

на две геометрически удаленные группы. Следует отметить, однако, что этот недостаток свойственен всем нейронным сетям, обучающимся без учителя. Для его преодоления в сети ART необходимо перевести сеть в режим обучения с учителем.

3. К преимуществам сетей ART следует отнести способность к дообучению новым образам без потери ранее приобретенных знаний. За счет этого парадигма ART позволяет совмещать режим работы с обучением, чем и отличается от остальных нейросетевых парадигм. В приложении к промышленной диагностике это означает, что система функционального контроля, использующая ART, способна приступить к работе сразу, не требуя предварительной настройки или обучения.

4. В процессе функционирования изменяются не только веса межнейронных связей, но и конфигурация слоя распознавания сети ART, что затрудняет ее аппаратную реализацию. С другой стороны, ввиду невысокой вычислительной сложности сети и чрезвычайно быстрого прогресса микропроцессорных средств, программная реализация парадигмы ART не представляет никаких трудностей и легко может быть введена в состав существующих систем управления, если в них используются компьютеры или другие микропроцессорные устройства.

5. Вариант сети ART с ограничением количества категорий позволяет избавиться от необходимости настраивать параметры функционирования сети ART. Вместо этого достаточно лишь установить ожидаемое количество различных классов входных сигналов. В случае, если классы распознаваемых сигналов могут оказаться многосвязными, может потребоваться увеличение максимально допустимого количества категорий.

6. Если для перекодировки полученных выходных реакций сети ART-C в требуемые выходы используется дополнительный слой Гроссберга, увеличение количества категорий, распознаваемых сетью, в 2-3 раза по сравнению с количеством классов входных сигналов позволяет повысить точность классификации, особенно в случае сложной конфигурации классов.

7. При использовании репрезентативной контрольной выборки классификация с использованием перестраиваемых спектральных операторов по эффективности сопоставима с классификацией при помощи двухслойной нейронной сети, в то же время обеспечивая значительно меньшее время обучения.

Список литературы

1. Хайкин С. Нейронные сети. Полный курс / С. Хайкин. – М.: Изд. Вильямс, 2018. – 1104 с.
2. Alekseyev M. Dynamic objects parameters control on the basis of rebuilt spectral operators application / M. Alekseyev & T. Vysotskaya // Energy Efficiency Improvement of Geotechnical Systems : Proceedings of the international forum on energy efficiency, Dnipropetrovs'k, Ukraine, October 2013. – Leiden: CRC Press/Balkema, 2013. – С.133 – 136.