



Моделирование искусственных нейронных сетей для определения параметров гармонических сигналов

В. В. Козлов

Пензенский государственный университет, Россия, 440026 г. Пенза, ул. Красная, 40

Б. Г. Раджабов

Пензенский государственный университет, Россия, 440026 г. Пенза, ул. Красная, 40

Аннотация. Рассматривается возможность реализации на нейронных сетях метода разложения автокорреляционной матрицы сигнала на собственные значения для определения параметров гармонических сигналов. Приведены результаты моделирования метода. Оценены погрешности измерения амплитуды и частоты сигнала и сформулированы некоторые рекомендации по их уменьшению.

Ключевые слова: моделирование, искусственная нейронная сеть, многослойный перцептрон, функция активации, обучающая выборка, гармонический сигнал, погрешность.

Modeling of artificial neural networks to determine the parameters of harmonic signals

V. V. Kozlov

Penza State University, 40 Krasnaya Street, 440026, Penza, Russia

B. G. Radzhabov

Penza State University, 40 Krasnaya Street, 440026, Penza, Russia

Abstract. The possibility of implementing the decomposition method of signal autocorrelation matrix on eigenvalues to determine the parameters of harmonic signals on neural networks is considered. The results of the method modeling are given. Measurement errors of the signal amplitude and frequency are estimated, and some recommendations for their reducing are formulated.

Key words: modeling, artificial neural network, multiple perceptron, activation function, training sample, harmonic signal, error.

Наиболее перспективной технологией решения измерительных задач в настоящее время является технология виртуальных приборов (ВП). Виртуальный прибор создается на базе компьютера, и ключевую роль в его функционировании наряду с аппаратурой играет программное обеспечение, которое и определяет функциональные возможности ВП. Анализ современной технической литературы показывает, что в виртуальных средствах фактически воспроизводятся те же методы, которые использовались и в аналоговых приборах, а современные методы цифровой обработки сигналов не нашли широкого распространения. Для обеспечения возможности применения наиболее перспективных методов в задачах измерения необходимо оценить метрологические характеристики каждого из них в отдельности и выявить возможные направления их совершенствования.

В большинстве известных приборов точные измерения амплитуды, частоты и фазы производятся лишь для строго гармонического сигнала. На практике часто сигнал имеет более сложную форму (например, сложение нескольких колебаний или измерения при наличии помех).

Задача решается за счет применения параметрических методов, в которых на основе перехода от аналогового процесса к дискретному, описываемому в общем случае авторегрессионным уравнением скользящего среднего (АРСС), осуществляется определение параметров колебательных составляющих сигналов [1].

Существует много способов аналитического представления колебаний [2]. Вид аналитического представления выбирается исходя из решения одной из возможных задач – сжатие информации, аппроксимация небольшим числом членов ряда (при удачном подборе типа функций), удобная форма для спектрального оценивания и т.д.

Один из параметрических методов основан на анализе собственных значений автокорреляционной матрицы или одной из матриц данных. Ключевой операцией в этом методе является разделение информации, содержащейся в автокорреляционной матрице или матрице данных, на два векторных подпространства – подпространство сигнала и подпространство шума.

Если случайный процесс состоит из смеси синусоид и аддитивного белого шума, то его можно моделировать как частный случай АРСС-процесса. В данной модели предполагается, что в общем случае синусоиды гармонически между собой не связаны. Математические свойства данного АРСС-процесса приводят к анализу собственных значений оценок его параметров. Следовательно, подход к анализу этого процесса несколько отличается от подхода к анализу обобщенного АРСС-процесса.

Если автокорреляционная функция процесса y_n известна, то АРСС-параметры можно найти из решения собственного уравнения, матричная запись которого имеет следующий вид:

$$Y^T A = W^T A, \quad (1)$$

где Y – автокорреляционная матрица сигнала; A – вектор коэффициентов регрессии; W – автокорреляционная матрица шума, $()^T$ – обозначает транспонирование матрицы.

После преобразований, описанных в работе [2], выражение (1) можно переписать в виде

$$R_{yy}A = \sigma_w^2 A, \quad (2)$$

которое представляет собой собственное уравнение процесса, в котором дисперсия шума σ_w^2 является собственным значением автокорреляционной матрицы R_{yy} . Вектор АРСС-параметров A является собственным вектором, связанным с собственным значением σ_w^2 . Уравнение (2) позволяет определить значения АРСС-параметров в том случае, когда известно значение автокорреляционной функции. Знать дисперсию шума σ_w^2 не обязательно. Можно показать, что для процесса, состоящего из p вещественных синусоид и аддитивного белого шума, дисперсия σ_w^2 соответствует *минимальному* собственному значению матрицы R_{yy} , когда размер этой матрицы равен или превышает $(2p+1) \times (2p+1)$.

Эта процедура позволяет определить точные частоты и мощности p вещественных синусоид в присутствии белого шума, если точно известны $2p+1$ значений автокорреляционной функции, включая ее значение при нулевой задержке. Так как известными полагаются только значения автокорреляционной функции, информация о фазе каждой синусоиды теряется.

После нахождения собственных векторов и соответствующих им собственных значений определяются коэффициенты полинома

$$z^{2p} + a_1 z^{2p-1} + \dots + a_{2p-1} z + a_{2p} = 0,$$

корни $z_n = \exp(j2\pi f_n \Delta t)$, формируемые из этих коэффициентов, будут определять частоты синусоид

$$f_i = \arctg \left[\frac{\text{Im } z_i}{\text{Re } z_i} \right] \cdot \frac{1}{2\pi \Delta t}.$$

Если число синусоид неизвестно, но значения автокорреляционной функции известны точно, то независимо от решения уравнения (2) для последовательно возрастающих порядков должны вы-

числяться до тех пор, пока минимальное собственное значение перестанет изменяться при переходе к следующему более высокому порядку. Это будет означать достижение правильного порядка. В этой точке минимальное собственное значение равно дисперсии шума. На практике, как правило, известны оценки значений автокорреляционной функции, поэтому число синусоид p следует выбирать в качестве значения того порядка, при котором минимальное собственное значение уравнения (2) лишь незначительно отличается от минимального собственного значения для порядка $(p - 1)$.

После определения частот по корням полинома для A можно определить мощности синусоид. Значения автокорреляционной функции от $R_{yy}(1)$ до $R_{yy}(p)$ можно записать в матричной форме

$$\mathbf{F}\mathbf{P} = \mathbf{r},$$

где

$$\mathbf{F} = \begin{bmatrix} \cos(2\pi f_1 \Delta t) & \cdots & \cos(2\pi f_p \Delta t) \\ \vdots & & \vdots \\ \cos(2\pi f_1 p \Delta t) & \cdots & \cos(2\pi f_p p \Delta t) \end{bmatrix}, \quad \mathbf{P} = \begin{bmatrix} P_1 \\ \vdots \\ P_p \end{bmatrix}, \quad \mathbf{r} = \begin{bmatrix} R_{yy}(1) \\ \vdots \\ R_{yy}(p) \end{bmatrix}. \quad (3)$$

Матрица \mathbf{F} состоит из членов, зависящих от частот синусоид, которые определяются посредством нахождения корней полинома. Мощности этих синусоид находятся посредством решения системы уравнений (3) относительно вектора мощности \mathbf{P} [3].

Рассмотрим, как можно использовать нейронную сеть (НС) для решения поставленной задачи. В нашем случае для оценивания параметров сигнала на основе анализа собственных значений необходимо определить минимальное собственное число автокорреляционной матрицы и соответствующий ему собственный вектор, элементы которого являются коэффициентами уравнения регрессии. Сразу отметим, что так как эта задача близка к задаче реализации цифрового фильтра на нейронных сетях (который также описывается АРСС-уравнением), то ее можно считать традиционной для этого класса.

Искусственный нейрон реализует на выходе y отображение в соответствии с соотношением

$$y = f\left(\sum_{i=1}^p w_i x_i + w_0 x_0\right) = f\left(\sum_{i=1}^p w_i x_i\right),$$

где x_0, x_1, \dots, x_p – входные параметры; w_0, w_1, \dots, w_p – весовые коэффициенты синаптических связей нейронов. Входной параметр x_0 и коэффициент связи w_0 вводят специально для инициализации сети, обычно $x_0 = 1$, а коэффициенты w_0 , как и остальные $w_i, i \in \overline{1, n}$, настраиваются в процессе обучения. Функция активации $f(\cdot)$ – монотонная, непрерывно дифференцируемая на интервале $(-1, +1)$ или $(0, -1)$. Для искусственных нейронов наиболее употребительны экспоненциальная функция, функция гиперболического тангенса, сигмоидная функция, бинарные функции различного определения [4].

Процесс формирования нейронной сети носит итеративный характер: в зависимости от исходных данных и решаемой задачи выбирается количество уровней и слоев, метод обучения, число нейронов в скрытом слое и т.д. Таким образом, в процессе решения поставленной задачи необходимо установить оптимальные параметры сети.

Также немаловажным параметром является обучающая выборка, на основе которой происходит обучение сети, так как по этим значениям рассчитываются коэффициенты весов и смещений. Как правило, эту последовательность задают на всем диапазоне входных данных, с которыми сеть должна впоследствии работать. Для лучшей реализации метода необходимо применять длинные последовательности входных данных для исключения влияния ложных гармоник [3].

Для решения поставленной задачи сформируем нейронные сети со следующими параметрами:

– сеть *net1*: линейная НС, имеющая 100 входов и 5 выходов; следовательно, число персептронов в единственном слое равно 100.

– сеть *net2*: двухслойная НС, имеющая 100 входов и 5 выходов; число персептронов в промежуточном слое – 20; функция активации в первом слое – сигмоидальная, во втором – линейная;

– сеть *net3*: трехслойная НС, имеющая 100 входов и 5 выходов; число персептронов в промежуточных слоях – 20 и 10; функция активации в первом слое – сигмоидальная, во втором – линейная, в третьем – линейная;

– сеть *net4*: трехслойная НС, имеющая 100 входов и 5 выходов; число персептронов в промежуточных слоях – 20 и 10; функция активации в первом слое – сигмоидальная, во втором – сигмоидальная, в третьем – линейная;

– сеть *net5*: трехслойная НС, имеющая 100 входов и 5 выходов; число персептронов в промежуточных слоях – по 20 в каждом слое; функция активации в первом слое – сигмоидальная, во втором и третьем – линейная;

– сеть *net6*: трехслойная НС, имеющая 100 входов и 5 выходов; число персептронов в промежуточных слоях – по 20 в каждом слое; функция активации в первом слое – сигмоидальная, во втором – сигмоидальная, в третьем – линейная.

Обучение проводилось на дискретных отсчетах гармонического сигнала, для каждой комбинации были взяты по 100 отсчетов для каждого сигнала. При этом входные параметры амплитуды варьировались в диапазоне от 0,16 до 1 с неоднородным шагом внутри интервала, значения частоты от 5 до 20. В связи с ограничением данного метода значение фазы сигнала определить не предоставляется возможным, несмотря на это, в обучающей выборке значение фазы изменялось от 0 до π :

$$y_1 = \cos(2\pi \cdot 9 \cdot 0,01 \cdot i + \pi / 4);$$

$$y_2 = \cos(2\pi \cdot 19 \cdot 0,01 \cdot i);$$

$$y_3 = 0,16 \cdot \cos(2\pi \cdot 7 \cdot 0,01 \cdot i + \pi / 2);$$

$$y_4 = 0,1 \cdot \cos(2\pi \cdot 19 \cdot 0,01 \cdot i).$$

Результаты определения параметров приведенных сигналов искусственными нейронными сетями приведены в табл. 1.

Таблица 1

Результаты моделирования НС

Определяемые параметры	Амплитуда $U = 1$	Частота $f = 9$	Амплитуда $U = 1$	Частота $f = 19$	Амплитуда $U = 0,16$	Частота $f = 7$	Амплитуда $U = 0,1$	Частота $f = 19$
<i>net1</i>	1,0259	8,7794	1,0017	19,0161	0,1254	4,9502	0,0253	0
<i>net2</i>	1,0093	8,9464	1,0009	19,0180	0,1623	6,9353	0,1006	18,6169
<i>net3</i>	1,0093	8,9464	1,0009	19,0180	0,1623	6,9353	0,1001	19,0027
<i>net4</i>	1,0097	8,9422	1,0009	19,0177	0,1624	6,9370	0,1000	19,0569
<i>net5</i>	1,0093	8,9464	1,0009	19,0180	0,1623	6,9353	0,0997	19,4022
<i>net6</i>	1,0093	8,9464	1,0009	19,0180	0,1623	6,9353	0,0994	19,6926

Затем на вход были поданы те же сигналы в присутствии шума, с отношением сигнал/шум равным 10. Результаты представлены в табл. 2.

Таблица 2

Результаты моделирования НС в присутствии шума

Определяемые параметры	Амплитуда $U = 1$	Частота $f = 9$	Амплитуда $U = 1$	Частота $f = 19$	Амплитуда $U = 0,16$	Частота $f = 7$	Амплитуда $U = 0,1$	Частота $f = 19$
<i>net1</i>	0,9597	9,4237	1,0018	19,0463	0,1030	4,2428	0,0222	0
<i>net2</i>	0,9160	9,9627	1,0137	18,2436	0,1549	6,9793	0,1007	18,2770
<i>net3</i>	0,9834	9,1576	0,9979	19,3918	0,1400	6,5256	0,0994	19,1880
<i>net4</i>	0,9194	9,9181	1,0023	19,0059	0,1611	7,1996	0,0998	18,8633
<i>net5</i>	1,0092	8,9040	0,9978	19,1663	0,1620	6,9372	0,0993	18,9409
<i>net6</i>	1,0104	9,0133	0,9969	19,0483	0,1644	7,1027	0,1012	18,7410

Для сравнения были взяты сети с разными структурами: линейная, двухслойные и трехслойные сети с различными функциями активации. Результаты моделирования показали, что линейная сеть *net1* в ряде случаев некорректно определяет параметры даже незашумленного сигнала. Двухслойная сеть *net2* показала удовлетворительные результаты на всех видах тестируемых сигналов, из чего

можно сделать вывод, что довольно простая структура данной сети не обеспечивает необходимой точности. Сравнивая результаты трехслойных сетей видно, что применение двух сигмоидальных функций активации привело к увеличению времени обучения сети, а также в некоторых случаях и к ухудшению результатов, следовательно, применение сетей такой структуры не всегда оправдано. Наилучшие результаты показали трехслойные сети *net3* и *net5*, отличающиеся только количеством нейронов во втором слое. Погрешности определения параметров зашумленных сигналов этими сетями в основном не превышают 1 %, что примерно соответствует данному методу.

Недостаточно точное определение параметров, в особенности сильно зашумленных сигналов, обусловлено не структурой сети, а формированием обучающей выборки. Так как обучение сети проводилось без воздействия шума, для улучшения точности необходимо формировать обучающую выборку, используя случайные данные либо смешивая случайные и детерминированные значения. Также из общей картины видно, что сети с наибольшей точностью определяют один из параметров, исходя из этого, можно построить несколько нейронных сетей, каждая из которых ориентирована на определение конкретного параметра.

Библиографический список

1. Козлов, В. В. Применение методов цифрового спектрального оценивания в задаче измерения параметров сигнала / В. В. Козлов, Б. В. Цыпин, М. Г. Мясникова, С. В. Ионов // Измерительная техника. – 2010. – № 10. – С. 260–264.
2. Марпл.-мл. С. Л. Цифровой спектральный анализ и его приложения : пер. с англ. / С. Л. Марпл.-мл. – М. : Мир, 1990. – 584 с.
3. Козлов, В. В. Оценка параметров сигналов, основанная на анализе собственных значений матриц данных / В. В. Козлов // Измерение. Мониторинг. Управление. Контроль. – 2016. – № 1 (15). – С. 61–67.
4. Уоссермен, Ф. Нейрокомпьютерная техника: Теория и практика : пер. с англ. / Ф. Уоссермен. – М. : Мир, 1992. – 184с.

Козлов, В. В.

Моделирование искусственных нейронных сетей для определения параметров гармонических сигналов / В. В. Козлов, Б. Г. Раджабов // Инжиниринг и технологии. – 2018. – Vol. 3(1). – DOI 10.21685/2587-7704-2018-3-1-4.