

УДК 621.391.82

## КАСКАДНЫЙ ПРЕДКОМПЕНСАТОР ДЛЯ ЛИНЕАРИЗАЦИИ ХАРАКТЕРИСТИКИ УСИЛИТЕЛЯ МОЩНОСТИ

*Соловьева Е.Б., д.т.н., профессор, заведующая кафедрой теоретических основ электротехники Санкт-Петербургского государственного электротехнического университета "ЛЭТИ" им. В.И. Ульянова (Ленина), e-mail: selenab@hotmail.ru*

**Ключевые слова:** усилитель мощности, цифровой предкомпенсатор, линеаризация, модель Винера-Гаммерштейна, модель Вольтерры, персептронная сеть.

### Введение

С развитием мобильной связи все более жесткие требования предъявляются к передающим СВЧ-устройствам, содержащим усилители мощности (УМ). Увеличение скорости передачи данных приводит к расширению полосы частот сигналов и, как следствие, к появлению нелинейных искажений в выходных сигналах УМ [1], [2]. Совершенствование методов синтеза адаптивных предкомпенсаторов (предысказателей, digital predistorter, DPD) для линеаризации УМ является актуальной задачей. Наряду с модификацией полиномиальных моделей DPD развиваются методы синтеза DPD в виде нейронных сетей [3]. Нейронные модели DPD могут быть существенно проще полиномиальных, что важно при аппаратной реализации DPD.

В работе предлагается использовать функционально связанную искусственную нейронную сеть (functional link artificial neural network, FLANN) [3-5] и полиномиальную персептронную сеть (polynomial perceptron network, PPN) [5], [6] для синтеза каскадного DPD с целью повышения уровня подавления нелинейных искажений сигналов в УМ. Выполняется сравнительный анализ указанных моделей на примере синтеза DPD, компенсирующего нелинейные искажения в модели Винера-Гаммерштейна УМ на классе GSM-сигнала с четырьмя несущими.

### Адаптивный DPD с каскадной структурой

Задача DPD – внести нелинейные предыскажения, которые позволят компенсировать нелинейные искажения усилителя (линеаризовать УМ). Блок-схема включения адаптивного DPD с применением прямого алгоритма его обучения [7] изображена на рис. 1. Здесь DPD содержит два каскадно-соединенных блока В1 и В2.




Рис. 1

*Предложена каскадная структура нелинейного цифрового предкомпенсатора, синтезируемого прямым алгоритмом обучения. Показано, что наибольшую точность линеаризации усилителя мощности с моделью Винера-Гаммерштейна обеспечивает каскадный предкомпенсатор, включающий полиномиальную персептронную сеть и радиально ограниченную модель Вольтерры.*

Блоки В1 и В2 описываются соответствующими операторными уравнениями:

$$zd(n) = S_1[x(n)],$$

$$z(n) = S_2[zd(n)],$$

где  $n$  – нормированное дискретное время,  $x(n)$ ,  $z(n)$  – входной и выходной сигналы DPD,  $zd(n)$  – выходной сигнал блока В1 предкомпенсатора,  $S_1[\cdot]$  и  $S_2[\cdot]$  – нелинейные операторы.

Параметры моделей  $S_1[\cdot]$  и  $S_2[\cdot]$  находим в метрике  $L_2$  последовательно (вначале – параметры модели  $S_1[x(n)]$ , затем модели  $S_2[zd(n)]$ ) с помощью итерационного метода (метода простых итераций [8]) при решении задачи аппроксимации

$$\|y(z(n)) - x(n)\| \Rightarrow \min_{n \in [0, N_x]},$$

где  $y(z(n))$  – выходной сигнал усилителя мощности,  $N_x$  – длительность сигнала  $x(n)$ . В качестве моделей  $S_1[\cdot]$  и  $S_2[\cdot]$  могут выступать как полиномиальные конструкции, так и нейронные сети.

Рассмотрим преобразования, предшествующие методу простых итераций. Введем приближенное равенство

$$y(z(n)) \cong x(n), \quad (1)$$

преобразуем его следующим образом:

$$x(n) - y(z(n)) \cong 0,$$


$$z(n) \cong z(n) + (x(n) - y(z(n))) = P[z(n)],$$

где  $P$  – нелинейный оператор, отображающий множество сигналов  $Z$  в себя. Оператор  $P$  называется оператором сжатия, если выполняется условие Липшица [9]

$$\|P[z_2] - P[z_1]\| \leq \alpha \|z_2 - z_1\|,$$

где  $\forall z_1, z_2 \in Z$ ,  $\alpha$  – множитель, не зависящий от  $z_1, z_2$ ,  $0 < \alpha < 1$ .

Согласно принципу сжатых отображений, оператор  $P$  задает метод последовательных приближений (простых итераций [8], [9])



$$z_{k+1}(n) = z_k(n) + (x(n) - y(z_k(n))) = z_k(n) + e_k(n), \quad k \geq 1,$$

где  $k$  – номер итерации,  $e_k(n)$  – ошибка приближения сигналов из выражения (1) на  $k$ -й итерации расчета,  $e_k(n) = x(n) - y(z_k(n))$ .

Усилитель мощности является слабонелинейным устройством, его модель можно представить в виде сходящегося функционального ряда Вольтерры (предкомпенсатор также слабонелинейен). Следовательно, сходимость итерационной процедуры синтеза DPD определяется слабой нелинейностью усилителя, выходной сигнал  $y(z_k(n))$  которого рассчитывается на итерациях.

Сигнал  $zd(n)$  формируем итерационной процедурой. Расчет можно выполнить двумя способами:

$$zd_{k+1}(n) = z_k(n) + e_k(n) \quad (2)$$

или

$$zd_{k+1}(n) = zd_k(n) + e_k(n). \quad (3)$$

На практике применяем формулу (3), при которой параметры моделей блоков B1 и B2 находятся с использованием выходных сигналов соответствующих блоков. В результате параметры моделей B1 и B2 сходятся к истинным значениям с большей точностью, чем при равенстве (2).

При  $k = 1$  полагаем  $z_1(n) = zd_1(n) = x(n)$ .

В рассмотренном подходе параметры моделей блоков B1 и B2 DPD находятся в два этапа. В результате:

- точность синтеза DPD повышается, так как решение, полученное на первом этапе аппроксимации (блок B1), уточняется на втором этапе (блок B2);

- частично снимается проблема плохой обусловленности, поскольку размерность задач, решаемых на каждом этапе аппроксимации, может быть меньше размерности задачи аппроксимации, решаемой при типовой (одноблочной) структуре DPD.

В качестве моделей операторов  $S_1[\cdot]$  и  $S_2[\cdot]$  каскадно-соединенных блоков DPD используем FLANN [3-5] и PPN [5], [6].

### Функционально связанная искусственная нейронная сеть (FLANN)

FLANN является однослойной сетью (в ней отсутствует внутренний слой) [3-5]. Алгоритм обучения такой сети включает меньшее число преобразований и обеспечивает более быструю сходимость к решению задачи аппроксимации по сравнению с традиционными нейронными сетями.

Модель FLANN имеет вид

$$y(n) = f\left(\sum_{i=1}^G w_i \varphi_i(\vec{X}(n))\right) = f\left(\vec{W}^T \vec{\Phi}(\vec{X}(n))\right) \quad (4)$$

где  $f$  – нелинейная функция активации,

$\vec{X}(n)$  – вектор воздействий,  $\vec{X}(n) = [x_1(n), x_2(n), \dots, x_Q(n)]^T$ ,  $T$  – знак транспонирования,  $\vec{W}(n)$  – вектор весов сети,  $\vec{W} = [w_1, w_2, \dots, w_G]^T$ ,  $\vec{\Phi}(\vec{X}(n))$  – вектор функций  $\varphi_i$ ,  $i = 1, 2, \dots, G$ ,

$\vec{\Phi}(\vec{X}(n)) = [\varphi_1(\vec{X}(n)), \varphi_2(\vec{X}(n)), \dots, \varphi_G(\vec{X}(n))]^T$ ,  $y(n)$  – выходной сигнал модели.

Функции  $\varphi_i$ ,  $i = 1, 2, \dots, G$  преобразуют входные сигналы в базисные функции с помощью, например, тригонометрического полинома, полинома Лежандра, Чебышева, а также выполняют многомерное преобразование базисных функций. Формирование базисных функций в модели (4) служит для понижения числа обусловленности при решении задачи аппроксимации с высокой степенью нелинейности.

Структурная схема FLANN показана на рис. 2.




Рис. 2

Для синтеза DPD используем модель (4) с линейной функцией активации  $f$  и базисными функциями – полиномами Чебышева  $T_i(\vec{X}(n))$  степени  $i$ ,  $i = 1, 2, \dots, P$  [3], [10]. В этом случае модель (4) имеет вид

$$y(n) = \vec{W}^T \vec{\Phi}(\vec{X}(n)), \quad (5)$$

где

$$\vec{\Phi}(\vec{X}(n)) = [1, T_1(x_1(n)), \dots, T_Q(x_Q(n)), \dots, \dots, T_2(x_1(n)), \dots, T_2(x_Q(n))^T, \dots, \dots, T_1(x_1(n))T_1(x_2(n)), \dots, \dots, T_1(x_{Q-1}(n))T_1(x_Q(n)), \dots, T_P(x_1(n)), \dots, T_P(x_Q(n))]^T.$$

Блок «Функциональное разложение» (рис. 2) представляется структурой, показанной на рис. 3, включающей формирование полиномов Чебышева и их многомерное преобразование.

FLANN с чебышевскими базисными функциями будем называть чебышевской функционально связанной искусственной нейронной сетью (Chebyshev functional link artificial neural network, CFLANN). Отметим, что CFLANN соответствует двухслойной перцептронной нейронной сети [10].

CFLANN в DPD должна формировать выходной сигнал со спектром, расположенным в полосе пропускания усилителя на частотах входного сигнала и комбинационных частотах интермодуляционных составляющих, поро-

ждаемых нелинейностью УМ [11]. Составляющие модели CFLANN конструируются при перемножении каждого сомножителя из верхнего столбца табл. 1–4 на каждый сомножитель из соответствующего нижнего столбца. В таблицах знак \* – знак комплексного сопряжения, переменная  $i$  – смещение сигнала во времени. В итоге образуется вектор  $\vec{\Phi}(\vec{X}(n))$ , который умножается на вектор коэффициентов согласно формуле (5). Таким образом, конструируется модель CFLANN с нечетными членами.




Рис. 3

Таблица 1. Множители составляющих 3-й степени модели CFLANN

Первый сомножитель	$2x^2(n) - 1$
	$x(n)x(n-i),$
	$2x^2(n-i) - 1$
Второй сомножитель	$x^*(n)$
	$x^*(n-i)$

Таблица 2. Множители составляющих 5-й степени модели CFLANN

Первый сомножитель	$4x^3(n) - 3x(n)$
	$4x^3(n-i) - 3x(n-i)$
	$(2x^2(n) - 1)x(n-i)$
	$(2x^2(n-i) - 1)x(n)$
Второй сомножитель	$2(x^*(n))^2 - 1$
	$2(x^*(n-i))^2 - 1$
	$x^*(n)x^*(n-i)$

Таблица 3. Множители составляющих 7-й степени модели CFLANN

Первый сомножитель	$8x^4(n) - 8x^2(n) + 1$
	$8x^4(n-i) - 8x^2(n-i) + 1$
	$(2x^2(n) - 1)(2x^2(n-i) - 1)$
	$x(n)(4x^3(n-i) - 3x(n-i))$
	$x(n-i)(4x^3(n) - 3x(n))$

Второй сомножитель	$4(x^*(n))^3 - 3x^*(n)$
	$4(x^*(n-i))^3 - 3x^*(n-i)$
	$(2(x^*(n))^2 - 1)x^*(n-i)$
	$(2(x^*(n-i))^2 - 1)x^*(n)$

Таблица 4. Множители составляющих 9-й степени модели CFLANN

Первый сомножитель	$16x^5(n) - 20x^3(n) + 5x(n)$
	$16x^5(n-i) - 20x^3(n-i) + 5x(n-i)$
	$x(n)(8x^4(n-i) - 8x^2(n-i) + 1)$
	$x(n-i)(8x^4(n) - 8x^2(n) + 1)$
	$(4x^3(n) - 3x(n))(2x^2(n-i) - 1)$
	$(4x^3(n-i) - 3x(n-i))(2x^2(n) - 1)$
Второй сомножитель	$8(x^*(n))^4 - 8(x^*(n))^2 + 1$
	$8(x^*(n-i))^4 - 8(x^*(n-i))^2 + 1$
	$(2(x^*(n))^2 - 1)(2(x^*(n-i))^2 - 1)$
	$(4(x^*(n))^3 - 3x^*(n))x^*(n-i)$
	$(4(x^*(n-i))^3 - 3x^*(n-i))x^*(n)$

**Полиномиальная перцептронная сеть (PPN)**

PPN – однослойная сеть (без внутреннего слоя), что обеспечивает простоту алгоритма ее обучения и высокую скорость сходимости к решению задачи аппроксимации.

Модель PPN имеет вид [5], [6]

$$y(n) = f(\vec{W}^T \vec{F}(\vec{X}(n))), \tag{6}$$

где  $f$  – нелинейная функция активации,  $\vec{X}(n)$  – вектор воздействий,  $\vec{X}(n) = [x_1(n), x_2(n), \dots, x_Q(n)]^T$ ,

$T$  – знак транспонирования,  $\vec{W}(n)$  – вектор весов нейронной сети,  $\vec{W} = [w_1, w_2, \dots, w_G]^T$ ,  $\vec{F}(\vec{X}(n))$  – вектор функций, содержащий элементы с многомерным преобразованием,

$$\vec{F}(\vec{X}(n)) = [1, x_1(n), \dots, x_Q(n), \dots, x_1^2(n), \dots, x_Q^2(n), \dots, x_1(n)x_2(n), \dots, x_{Q-1}(n)x_Q(n), \dots, x_1^P(n), \dots, x_Q^P(n)]^T,$$

$P$  – степень элемента вектор-функции,  $y(n)$  – выходной сигнал модели.

Структурная схема PPN изображена на рис. 4.

Анализ PPN и FLANN показывает, что PPN (рис. 4) может быть преобразована во FLANN (рис. 2) путем дополнительного преобразования входных сигналов в базисные функции на основе полиномов Лежандра, Чебышева и т.д.




Рис. 4

При синтезе DPD введем в модель (6) линейную функцию активации. В итоге запишем

$$y(n) = \vec{W}^T \vec{F}(\vec{X}(n)). \quad (7)$$

Вектор воздействий  $\vec{X}(n)$  сформируем с помощью линии задержки и выполним многомерное преобразование в  $\vec{F}$  модели (7) с учетом правил конструирования интермодуляционных спектральных составляющих в выходном сигнале DPD [11]. В результате получим используемую для синтеза DPD модель PPN вида

$$y(n) = y_1(n) + y_2(n), \quad (8)$$

где

$$\begin{aligned}
y_1(n) = & \sum_{i=0}^M x(n-i) \sum_{k=0}^{(P-1)/2} w_{2k+1}^{(1)} |x(n-i)|^{2k} + \\
& \sum_{i=1}^M x(n-i) \sum_{k=1}^{(P-1)/2} w_{2k+1}^{(2)} |x(n)|^{2k} + \\
& + \sum_{i=0}^M x^*(n-i) x^2(n) \sum_{k=0}^{(P-3)/2} w_{2k+3}^{(3)} |x(n)|^{2k} + \\
& + \sum_{i=1}^M x^*(n) x^2(n-i) \sum_{k=0}^{(P-3)/2} w_{2k+3}^{(4)} |x(n-i)|^{2k} + \\
& + \sum_{i=1}^M x(n) \sum_{k=1}^{(P-1)/2} w_{2k+1}^{(5)} |x(n-i)|^{2k} + \\
& + x^2(n) \sum_{i=0}^M x^*(n-i) \sum_{k=0}^{(P-3)/2} w_{2k+3}^{(6)} |x(n-i)|^{2k} + \\
& + |x(n)|^2 \sum_{i=0}^M x(n-i) \sum_{k=0}^{(P-3)/2} w_{2k+3}^{(7)} |x(n-i)|^{2k} + \\
& + \sum_{i=0}^M (x^*(n))^2 x^3(n-i) \sum_{k=0}^{(P-5)/2} w_{2k+5}^{(8)} |x(n-i)|^{2k}. \quad (9)
\end{aligned}$$

\* – знак комплексного сопряжения,  $M$ ,  $P$  – длина памяти и степень модели соответственно,

$$y_2(n) = \sum_{i=1}^M (x^*(n-i))^2 x^3(n) \sum_{k=0}^{(P-5)/2} w_{2k+5}^{(9)} |x(n)|^{2k} +$$

$$\begin{aligned}
& + \sum_{i=1}^M x^*(n) x^2(n-i) \sum_{k=1}^{(P-3)/2} w_{2k+3}^{(10)} |x(n)|^{2k} + \\
& + \sum_{i=1}^M (x^*(n-i))^2 x^3(n) \sum_{k=1}^{(P-5)/2} w_{2k+5}^{(11)} |x(n-i)|^{2k} + \\
& + \sum_{i=1}^M (x^*(n))^2 x^3(n-i) \sum_{k=1}^{(P-5)/2} w_{2k+5}^{(12)} |x(n)|^{2k} + \\
& + |x(n)|^2 \sum_{i=1}^M x(n) \sum_{k=1}^{(P-3)/2} w_{2k+3}^{(13)} |x(n-i)|^{2k} + \\
& + \sum_{i=1}^M |x(n-i)|^2 x(n) \sum_{k=1}^{(P-3)/2} w_{2k+3}^{(14)} |x(n)|^{2k}. \quad (10)
\end{aligned}$$

Отметим, что выражение (9) является радиально ограниченной моделью Вольтерры (radially pruned Volterra model, RPVM). Модель RPVM – регрессионная форма усеченного ряда Вольтерры. Ядра Вольтерры в RPVM строятся на сетке  $n$ -мерного куба (гиперкуба), радиальные направления выбираются на базе ядра 3-го порядка [12], [13].

#### Компенсация нелинейных искажений в модели Винера-Гаммерштейна УМ

Низкочастотная модель Винера-Гаммерштейна УМ класса АВ описывает каскадное соединение следующих блоков [13], [14]:

– линейной динамической цепи с передаточной функцией

$$H_1(z) = \frac{1 + 0,5z^{-2}}{1 - 0,2z^{-1}};$$

– безынерционной нелинейности

$$w(n) = b_1 v(n) + b_3 v(n) |v(n)|^2 + b_5 v(n) |v(n)|^4,$$

где  $b_1 = 1,0108 + 0,0858j$ ,  $b_3 = 0,0879 - 0,1583j$ ,  $b_5 = -1,0992 - 0,8891j$ ,  $v(n)$  – выходной сигнал динамической цепи с  $H_1(z)$ ;

– линейной динамической цепи с передаточной функцией

$$H_2(z) = \frac{1 - 0,1z^{-2}}{1 - 0,4z^{-1}}.$$

Воздействие низкочастотной модели УМ – комплексная огибающая GSM-сигнала с четырьмя несущими в частотной полосе 20 МГц, расположенной относительно центральной частоты 1,845 ГГц. Частота дискретизации огибающей GSM-сигнала  $f_d = 184,32$  МГц.

Для линеаризации описанной модели УМ построены адаптивные DPD с применением модели 9-й степени CFLANN, RPVN (9) при  $P = 7$ , модели (8) PPN при  $P = 7$ , а также каскадных соединений указанных моделей. Отметим, что в выражениях (9), (10) верхние пределы операторов суммирования равнялись  $(P-1)/2$ .

Длина памяти исследуемых моделей равнялась четырем ( $M = 4$  в (9), (10)).

Точность линеаризации УМ оценивалась с помощью нормированной среднеквадратичной погрешности (normalized mean-square error, NMSE, дБ), рассчитываемой по формуле

$$NMSE = 10 \log_{10} \left( \frac{\sum_{n=0}^{N_x-1} |y(z(n)) - x(n)|^2}{\sum_{n=0}^{N_x-1} |x(n)|^2} \right),$$

где  $x(n)$  – входной сигнал длиной  $N_x$  отсчетов ( $N_x = 106\,339$ ) каскадного соединения DPD и PA, изображенного на рис. 1,  $y(z(n))$  – выходной сигнал УМ.

Значения NMSE, полученные на 45-й итерации адаптации DPD, а также число параметров  $Q$  в моделях DPD, представлены в табл. 5.

Таблица 5. NMSE и число параметров  $Q$  в моделях DPD

	NMSE, $Q$	NMSE	$Q$
	Модель 9-й степени CFLANN	-65,04	226
	RPVM (9) при $P = 7$	-72,87	145
	Модель (8) PPN при $P = 7$	-75,50	221
Каскадное соединение	Модель 9-й степени CFLANN и модель 7-й степени CFLANN	-69,42	375
	RPVM (9) при $P = 7$ и RPVM (9) при $P = 7$	-78,14	290
	Модель (8) PPN при $P = 7$ и RPVM (9) при $P = 7$	-79,14	366

Из анализа табл. 5 следует:

- модель PPN обеспечивает более высокую точность линеаризации УМ, чем RPVM и модель CFLANN,
- применение каскадной структуры DPD повышает точность линеаризации УМ. Большая точность линеаризации достигается при каскадной структуре DPD с моделью PPN.

### Заключение

В работе синтезированы адаптивные DPD с каскадной структурой на основе прямого алгоритма обучения. В качестве моделей блоков DPD использованы: функционально связанная нейронная сеть, полиномиальный перцептрон, радиально ограниченная модель Вольтерры.

В каскадном DPD задача аппроксимации нелинейного оператора решалась поэтапно. При таком подходе частично снимается проблема плохой обусловленности, характерная для задач с высокой степенью нелинейности моделей, а также повышается точность линеаризации УМ за счет лучшего приближения к оптимальным параметрам DPD.

Компенсация нелинейных искажений сигналов в УМ с моделью Винера-Гаммерштейна на классе GSM-сигнала с четырьмя несущими показала, что более точную линеаризацию характеристики УМ обеспечивает каскадный DPD, состоящий из PPN и RPVM, худший результат дает

DPD на основе моделей CFLANN.

### Литература

1. RF power amplifier behavioral modeling / D. Schreurs, M. O'Droma, A. A. Goacher, M. Gadringer.– N. Y.: Cambridge University Press, 2009.
2. Legarda J. Feedforward amplifiers for wideband communication systems.– The Netherlands, Dordrecht: Springer, 2006.
3. Li M., Liu J., Jiang Y., Feng W. Complex-Chebyshev functional link neural network behavioral model for broadband wireless power amplifiers // IEEE Trans. MTT.– 2012.– Vol. 60, № 6, Part 2.– P. 1979–1989.
4. Identification of nonlinear dynamic systems using functional link artificial neural networks / J. C. Patra, R. N. Pal, B. N. Chatterji, G. Panda // IEEE Trans. Systems, Man and Cybernetics – Part B: Cybernetics.– 1999.– Vol. 29, № 2.– P. 254–262.
5. Nonlinear channel equalization for QAM signal constellation using artificial neural networks / J. C. Patra, R. N. Pal, R. Baliarsingh, G. Panda // IEEE Trans. Systems, Man and Cybernetics – Part B: Cybernetics.– 1999.– Vol.29, № 2.– P. 262–271.
6. Xiang Z., Bi G., Le-Ngoc T. Polynomial-perceptrons and their applications to fading channel equalization and co-channel interference suppression // IEEE Trans. SP.– 1994.– V.42, № 9.– P.2470–2480.
7. Zhou D., DeBrunner V. E. Novel adaptive nonlinear predistorters based on the direct learning algorithm // IEEE Trans. SP.–2007.– Vol. 55.– № 1.– P. 120–133.
8. Бахвалов Н. С., Жидков Н. П., Кобельков Г. М. Численные методы.– М.: БИНОМ. Лаборатория знаний, 2003.
9. Лебедев В. И. Функциональный анализ и вычислительная математика.– М.: Физматлит, 2000.
10. Lee T. T., Jeng J. T. The chebyshev polynomial based unified model neural networks for function approximations // IEEE Trans. Systems, Man and Cybernetics – Part B: Cybernetics.– 1998.– Vol. 28, № 6.– P. 925–935.
11. On the baseband representation of a bandpass nonlinearity / G. T. Zhou, H. Qian, L. Ding, R. Raich // IEEE Trans. SP.– 2005.– Vol. 53, № 8, P. 2953–2957.
12. A new approach to pruning Volterra models for power amplifiers / C. Crespo-Cadenas, J. Reina-Tosina, M. J. Madero-Ayora, J. Munoz-Cruzado // IEEE Trans. SP.– 2010.– Vol. 58.– № 4.– P. 2113–2120.
13. Соловьева Е. Б. Предкомпенсатор Вольтерры с девиацией динамики для линеаризации усилителя мощности // Известия вузов. Радиоэлектроника.– 2011.– Т.54, № 10.– С. 29–36.
14. A robust digital baseband predistorter constructed using memory polynomials / L. Ding, G. T. Zhou, D. R. Morgan, Z. Ma, J. S. Kenney, J. Kim, C. R. Giardina // IEEE Trans. Com.– 2004.– Vol. 52.– № 1.– P. 159–165.

## CASCADE PREDCOMPENSATOR FOR POWER AMPLIFIER LINEARIZATION

*Solovyeva E. B.*

Cascade structure of nonlinear digital predcompensator synthesized by the direct learning algorithm is proposed. It is shown that the most accuracy of linearization of power amplifier described by Wiener-Hammerstein model is provided with the cascade predcompensator including the polynomial perceptron network and radially pruned Volterra model.