



УДК 621.3.01

Е. Б. Соловьева

## Нейронные предкомпенсаторы для борьбы с нелинейными искажениями в высокочастотном усилителе мощности

Предложена каскадная структура нелинейного предкомпенсатора, синтезируемого прямым алгоритмом обучения. Рассмотрены функционально связанная и полиномиальная перцептронная нейронные сети. Показано, что для усилителя мощности с моделью Винера–Гаммерштейна наибольшую точность подавления нелинейных искажений сигналов обеспечивает каскадный предкомпенсатор, включающий полиномиальную перцептронную сеть и радиально ограниченную модель Вольтерры.

### Нелинейная компенсация, нелинейная модель, усилитель мощности, нелинейное искажение

С развитием интегральной технологии для усилителей мощности (УМ), применяемых в разнообразных отраслях науки и техники, характерно снижение массы и размеров, а также повышение надежности их работы. УМ обеспечивает заданную мощность в нагрузке, сопротивление которой, как правило, мало. Обычно в УМ амплитуды выходного тока и напряжения близки к предельно допустимым значениям, а выходная мощность соизмерима с предельно допустимой мощностью, рассеиваемой прибором, и сравнима с мощностью, потребляемой от источника питания. Важными показателями, характеризующими УМ, являются: КПД, мощность, отдаваемая в нагрузку, коэффициент нелинейных искажений выходного сигнала. Поскольку транзисторы в УМ работают при значительных амплитудах сигнала, усилителям мощности присущи значительные нелинейные искажения [1].

Одним из способов борьбы с нелинейными искажениями в УМ является синтез предкомпенсатора (предысказителя, digital predistorter, DPD). Задача DPD – внести нелинейные предыскажения, которые позволят компенсировать нелинейные искажения усилителя (линеаризовать УМ). Совершенствование методов синтеза адаптивных предкомпенсаторов для линеаризации УМ является актуальной задачей. Наряду с модификацией полиномиальных моделей DPD развиваются ме-

тоды синтеза DPD в виде нейронных сетей [2]. 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) [2]–[4] и полиномиальную перцептронную сеть (polynomial perceptron network, PPN) [4] 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.

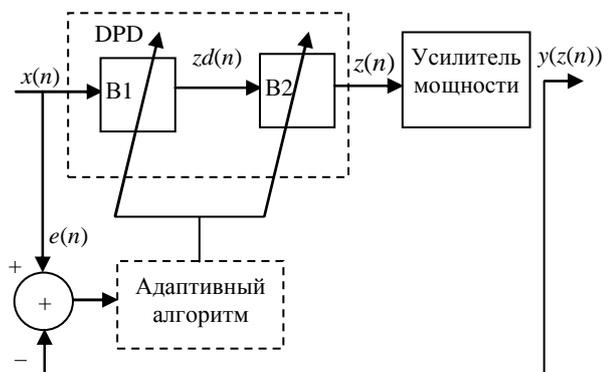


Рис. 1

**Адаптивный DPD с каскадной структурой.**

Синтез DPD выполним на основе операторного подхода с применением входных и выходных сигналов УМ.

Блок-схема включения адаптивного DPD с применением прямого алгоритма его обучения [1] изображена на рис. 1. Здесь DPD содержит два каскадно соединенных блока В1 и В2.

Блоки В1 и В2 описываются соответствующими операторными уравнениями:

$$z(n) = S_1[x(n)], \quad z(n) = S_2[zd(n)],$$

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 [5]) 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  $x(n)$ .

Согласно принципу сжатых отображений [5] последовательные итерации опишем выражениями

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

$$zd_{k+1}(n) = zd_k(n) + e_k(n),$$

где  $k$  – номер итерации;  $e_k(n)$  – ошибка приближения на  $k$ -й итерации расчета;  $e_k(n) = x(n) - y(z_k(n))$ . При  $k = 1$  полагаем  $z_1(n) = zd_1(n) = x(n)$ .

В рассмотренном подходе параметры моделей блоков В1 и В2 DPD находятся в два этапа. В результате

– точность синтеза DPD повышается, так как решение, полученное на первом этапе аппроксимации (блок В1), уточняется на втором этапе (блок В2);

– 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 [2]–[4] и PPN [4].

**Функционально связанная искусственная нейронная сеть (FLANN).** FLANN является однослойной сетью (в ней отсутствует внутренний слой) [2]–[4]. 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

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

где  $f$  – нелинейная функция активации;  $\vec{X}(n) = [x_1(n), x_2(n), \dots, x_Q(n)]^T$  – вектор воздействий, « $T$ » – знак транспонирования;  $\vec{W} = [w_1, w_2, \dots, w_G]^T$  – вектор весов сети;  $\vec{\Phi}(\vec{X}(n)) = [\phi_1(\vec{X}(n)), \phi_2(\vec{X}(n)), \dots, \phi_G(\vec{X}(n))]^T$  – вектор функций  $\phi_i$ ,  $i = 1, 2, \dots, G$ ;  $y(n)$  – выходной сигнал модели.

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

Структурная схема FLANN показана на рис. 2.

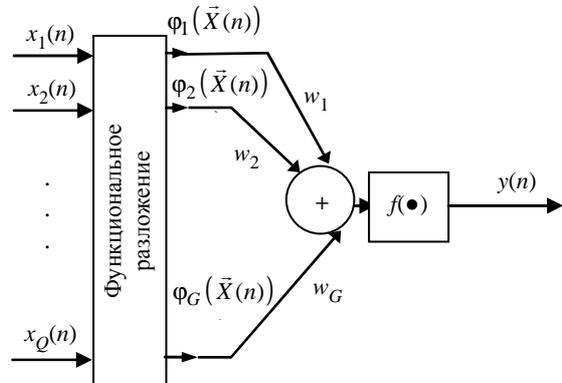


Рис. 2

Для синтеза DPD используем модель (1) с линейной функцией активации  $f$  и базисными функциями – полиномами Чебышева  $T_i(\bar{X}(n))$  степени  $i$  ( $i=1, 2, \dots, P$ ) [2]–[6]. В этом случае модель (1) преобразуется в выражение

$$y(n) = \bar{W}^T \bar{\Phi}(\bar{X}(n)), \quad (2)$$

где

$$\begin{aligned} \bar{\Phi}(\bar{X}(n)) = & \left[ 1, T_1(x_1(n)), \dots, T_Q(x_Q(n)), \dots, \right. \\ & T_2(x_1(n)), \dots, T_2(x_Q(n)), \dots, \\ & T_1(x_1(n))T_1(x_2(n)), \dots, T_1(x_{Q-1}(n))T_1(x_Q(n)), \dots, \\ & \left. T_P(x_1(n)), \dots, T_P(x_Q(n)) \right]^T. \end{aligned}$$

В блоке «Функциональное разложение» (рис. 2) формируются и подвергаются многомерному преобразованию полиномы Чебышева.

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 [6].

CFLANN в DPD формирует выходной сигнал со спектром, расположенным в полосе пропускания усилителя на частотах входного сигнала и комбинационных частотах интермодуляционных составляющих, порождаемых нелинейностью УМ [7].

#### 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 [4]

$$y(n) = f(\bar{W}^T \bar{F}(\bar{X}(n))), \quad (3)$$

где  $f$  – нелинейная функция активации;  $\bar{W} = [w_1, w_2, \dots, w_G]^T$  – вектор весов нейронной сети;  $\bar{F}(\bar{X}(n))$  – вектор функций, содержащий элементы с многомерным преобразованием:

$$\begin{aligned} \bar{F}(\bar{X}(n)) = & \left[ 1, x_1(n), \dots, x_Q(n), \dots, x_1^2(n), \dots, x_Q^2(n), \dots, \right. \\ & x_1(n)x_2(n), \dots, x_{Q-1}(n)x_Q(n), \dots, x_1^P(n), \dots, x_Q^P(n) \left. \right]^T; \\ & P \text{ – степень элемента вектор-функции, } y(n) \text{ –} \end{aligned}$$

выходной сигнал модели;  $\bar{X}(n) = [x_1(n), x_2(n), \dots, x_Q(n)]^T$  – вектор воздействий.

Анализ PPN и FLANN показывает, что PPN может быть преобразована во FLANN (рис. 2) путем перехода к базисным функциям, полученным из входных сигналов модели на основе полиномов Лежандра, Чебышева и т. д.

При синтезе DPD введем в модель (3) линейную функцию активации. В итоге запишем:

$$y(n) = \bar{W}^T \bar{F}(\bar{X}(n)). \quad (4)$$

Вектор воздействий  $\bar{X}(n)$  сформируем с помощью линии задержки и выполним многомерное преобразование в  $\bar{F}$  модели (4) с учетом правил конструирования интермодуляционных спектральных составляющих в выходном сигнале DPD [7]. В результате получим используемую для синтеза DPD модель PPN вида

$$y(n) = y_1(n) + y_2(n), \quad (5)$$

где

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

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

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

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

Отметим, что выражение (6) 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 [8], [9].

**Компенсация нелинейных искажений в модели Винера–Гаммерштейна УМ.** Низкочастотная модель Винера–Гаммерштейна УМ класса АВ описывает каскадное соединение следующих блоков [9]:

– линейной динамической цепи с передаточной функцией

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

NMSE, $Q$	Модель (2) 9-й степени CFLANN	RPVM (6) при $P = 7$	Модель (5) PPN при $P = 7$	Каскадное соединение		
				Модель (2) 9-й степени CFLANN и модель (2) 7-й степени CFLANN	RPVM (6) при $P = 7$ и RPVM (6) при $P = 7$	Модель (5) PPN при $P = 7$ и RPVM (6) при $P = 7$
NMSE	-65,04	-72,87	-75,50	-69,42	-78,14	-79,14
$Q$	226	145	221	375	290	366

– 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, RPVM (6) при  $P = 7$ , модели (5) PPN при  $P = 7$ , а также каскадных соединений указанных моделей. Отметим, что в выражениях (6), (7) верхние пределы операторов суммирования равнялись  $(P - 1) / 2$ . Длина памяти исследуемых моделей равнялась четырем ( $M = 4$  в (6), (7)).

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

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

где  $x(n)$  – входной сигнал длиной  $N_x$  отсчетов ( $N_x = 106\,339$ ) каскадного соединения DPD и РА, 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 таблице.

Из анализа таблицы вытекает следующее:

– модель PPN обеспечивает более высокую точность линеаризации УМ, чем модели RPVM и CFLANN,

– применение каскадной структуры DPD повышает точность линеаризации УМ. Большая точность линеаризации достигается при каскадной структуре DPD с моделью PPN.

Научная новизна работы состоит в декомпозиции общей задачи аппроксимации нелинейного оператора DPD на подзадачи меньшей размерности, решаемые при синтезе DPD последователь-

но. Такой подход позволяет снять проблему плохой обусловленности, характерную для задач моделирования устройств с высокой степенью нелинейности по соотношению вход-выход, а также повысить точность линеаризации УМ за счет лучшего (поэтапного) приближения к оптимальным параметрам DPD.

Декомпозиция задачи аппроксимации оператора DPD реализована путем синтеза адаптивного DPD каскадной структуры на основе прямого алгоритма обучения. В качестве моделей блоков

DPD использованы: функционально связанная нейронная сеть, полиномиальный перцептрон, радикально ограниченная модель Вольтерры.

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.

## СПИСОК ЛИТЕРАТУРЫ

1. RF power amplifier behavioral modeling / D. Schreurs, M. O'Droma, A. A. Goacher, M. Gadringer. N. Y.: Cambridge University Press, 2009.

2. Feng Complex-Chebyshev functional link neural network behavioral model for broadband wireless power amplifiers / M. Li, J. Liu, Y. Jiang, W. Feng // IEEE Trans. MTT. 2012. Vol. 60, № 6. Part 2. P. 1979–1989.

3. 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.

4. 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.

5. Бахвалов Н. С., Жидков Н. П., Кобельков Г. М. Численные методы. М.: БИНОМ. Лаборатория знаний, 2003.

6. 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.

7. 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.

8. 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.

9. Соловьева Е. Б. Предкомпенсатор Вольтерры с девиацией динамики для линеаризации усилителя мощности // Изв. вузов. Радиоэлектроника. 2011. Т. 54, № 10. С. 29–36.

E. B. Solovyeva

## NEURAL PRECOMPENSATORS AGAINST NONLINEAR DISTORTIONS IN HIGHFREQUENCY POWER AMPLIFIER

*The cascade structure of nonlinear digital precompensator synthesized by the direct learning algorithm is proposed. Functional link and polynomial perceptron neural networks are represented. It is shown that for the power amplifier described by Wiener-Hammerstein model the most accuracy of nonlinear distortion cancelling is provided with the cascade precompensator including the polynomial perceptron network and radially pruned Volterra model.*

**Nonlinear compensation, nonlinear model, power amplifier, nonlinear distortion**