

теплового стану ДКГ схема КТКЧ формує корегуючий код  $D(T)$  у відповідності до наступного співвідношення:

$$D(f_{\text{aux}}, T) = \frac{f_{\text{aux}} \cdot 2^N}{f_{\text{REF}}(F, T)}, \quad (20)$$

де  $N$  – розрядність керуючого слова  $D(T)$  [3, 4].

### Висновки

Використання в квадратурному демодуляторі в якості генератора опорних сигналів цифрового квадратурного синтезатора частоти з компенсацією температурної нестабільності на основі поточної ідентифікації теплового стану кварцового резонатора в двочастотному режимі збудження дозволяє суттєво підвищити точність та завадостійкість демодуляції квадратурних сигналів за рахунок усунення температурно-залежної похиби втрати ортогональності опорних коливань та суттєвого зменшення (мінімум на порядок) частотної неузгодженості сигналів.

### Література

1. Склар Б. Цифровая связь. Теоретические основы и практическое применение / Склар Б.; [пер. с англ.]. – 2-е изд., испр. – М. : Издательский дом «Вильямс», 2003. – 1104 с. : ил.
2. Синхронизация в радиосвязи и радионавигации / [Б. И. Шахтарин, В. В. Сизых, Ю. А. Сидоркина и др.]. – М. : Горячая линия – Телеком, 2011 – 278 с. : ил.
3. Колпаков Ф. Ф. Теорія і реалізаційні основи інваріантних п'єзорезонансних коливальних систем / Ф. Ф. Колпаков, С. К. Підченко. – Харків : Нац. аерокосм. ун-т «Харк. авіац. ін-т», 2011. – 327 с.
4. Підченко С.К. Моделювання термокомпенсованого DDS в середовищі MATLAB / С. К. Підченко, С. В. Марков. – Вимірювальна та обчислювальна техніка в технологічних процесах. – 2010. – № 1. – С. 77–80.

Надійшла 23.11.2012 р.  
Рецензент: д.т.н. Шинкарук О.М.

УДК 004.032.26::004.93

В.В. РОМАНЮК  
Хмельницький національний університет

## ПОСТАНОВКА ЗАДАЧИ ОПТИМИЗАЦИИ ПАРАМЕТРОВ НЕЙРОСЕТИ С ПРЯМОЙ СВЯЗЬЮ ДЛЯ РАСПОЗНАВАНИЯ ОБРАЗОВ ПО КРИТЕРИЯМ МАКСИМИЗАЦИИ ЕЁ ПРОИЗВОДИТЕЛЬНОСТИ И УСЛОВИЯ ИХ СВЁРТКИ

*Обсуждается проблема улучшения производительности нейросетевого исследования на примере нейросети с прямой связью для распознавания образов. Формализуется отображение входных параметров такой нейросети в пять показателей её производительности. Представляются пять критериев максимизации производительности нейросети, и предлагаются условия их свёртки для получения однозначного решения в форме множества оптимизированных входных параметров нейросети.*

*Ключевые слова:* нейросеть, производительность нейросети, оптимизация параметров нейросети, распознавание образов.

*There is discussed a problem of improving the productivity of neuronet investigation on the pattern of the feedforward neuronet for image recognition. There is formalized the mapping of input parameters of that neuronet into five factors of its productivity. Five criterions of maximizing the neuronet productivity are represented, and there are suggested conditions of their convolution for obtaining the unambiguous solution in the form of the set of optimized neuronet input parameters.*

*Keywords:* neural networks, Productivity neural network, neural network optimization parameters, of recognition images.

### Проблема улучшения производительности нейросети

Улучшение производительности искусственных нейросетей является естественным стремлением к усовершенствованию качества их функционирования. Сюда же относится и процесс обучения нейросети, чья длительность и сопутствующие характеристики должны удовлетворять определённым требованиям [1]. В частности, этот процесс не может протекать достаточно долго для нейросетей, решающих задачи распознавания в условиях зашумленности входных образов, когда часто возникает необходимость процедуры переобучения [1, 2]. Но на производительность нейросети влияет даже не одна, а несколько групп входных параметров. И при этом общая численность этих параметров для некоторых нейросетевых задач с многослойным персептроном иногда исчисляется десятками [1, 2]. К тому же производительность нейросети также определяется сразу по нескольким критериям, где фигурируют длительность обучения, вероятность паралича, функции качества обучения и уровень ошибок функционирования. Поэтому главная

особливість проблеми улучшення продуктивності нейросетів полягає в тому, що отображення груп входних нейросетевих параметрів в показатель продуктивності являється многозначним [1].

### Современі методи підстройки параметрів нейросетів для улучшення її продуктивності

Процедура улучшення продуктивності нейросетів потребує численних оценок упомянутого вище отображення. Разуміється, ці оценки можуть використовуватися для інтерполяції відповідних функцій продуктивності з можливістю їх аналітическої апроксимації, після чого легко перейти до задачі непосредственного пошуку екстремума. Однак різні завдання навіть в межах одного класу нейросетевих задач породжують, скоріше всього, різну розміщення [1, 2] функції продуктивності. Поэтому переход до їх нормування очевидний, хоча і необязателен, оскільки вовсе не гарантує збіження точок екстремумів.

Підстройка параметра штучної нейросеті на множестві їх значень (свойств або атрибутів) виконується через програмоване циклическе тестування функціональності [1, 2] та фіксацію цього значення, при якому середня продуктивність нейросетів досягає максимального рівня. Коли досліджуваних параметрів кілька, то використовують вложені цикли. Но слід зазначити, що численна оцінка продуктивності залежить від статистичного обсягу тестових дослідження. Наприклад, для ідентифікації вероятності параліча (занурення при навчанні) нейросетів та інших її вероятностних характеристик необхідно більше число тестів, ніж для функції якості навчання [1, 2].

Таким чином, підстройка параметрів нейросетів основана на її серйозному статистическому тестуванні, враховуючи природу кожного параметра. Но при цьому не враховують ступінь впливу окремого параметра на функціональність, де можна було б виділяти та оптимизувати продуктивність нейросетів по тому параметру, к якому вона найменше чутливіша. І на цей момент єдиного підходу до розв'язання завдання оптимальної підстройки параметрів нейросетів не описано.

### Цель статті

Існує відсутність єдиного підходу до постановки завдання підстройки параметрів нейросетів для улучшення її продуктивності, предложим обобщающую модель оптимизации нейросетевой производительности в задачах распознавания образов, используя в качестве основы нейросеть с прямой связью. Для этого выполним формализацию многозначного отображения групп входных параметров нейросети в показатель її продуктивності та построим критерии повышения качества распознавания образов с условиями свёртки этих критериев.

### Формalизация отображений входных параметров нейросети в показатели її продуктивності

Нейросеть з прямою зв'язкою навіть дуже простий архітектури обладає великим кількості регульованих параметрів (рис. 1), серед яких для задачи распознавания образов можна виділити 10 основних [1]:

1) кількість шарів  $q_{lyr}$  з множеством їх значень  $Q_{lyr} \subset \mathbb{Y}$ ,  $q_{lyr} \in Q_{lyr} \subset \mathbb{Y}$ ;

2) загальна кількість нейронів  $q_{nm}$  в  $q_{lyr}$  шарах з множеством їх значень  $Q_{nm} \subset \mathbb{Y}$ ,  $q_{nm} \in Q_{nm} \subset \mathbb{Y}$ ;

3) вектор  $D_{lyr-nrn}$  розподілення  $q_{nm}$  нейронів по  $q_{lyr}$  шарах як точка  $D_{lyr-nrn} = [q_{nm}^{(k)}]_{1 \times q_{lyr}}$  в просторі  $\mathbb{Y}^{q_{lyr}}$  при

$$\sum_{k=1}^{q_{lyr}} q_{nm}^{(k)} = q_{nm} \text{ з множеством варіантів таких}$$

розподілів  $D_{lyr-nrn} \in \prod_{k=1}^{q_{lyr}} \mathbb{Y}$ ,

$$D_{lyr-nrn} \in D_{lyr-nrn} \subset \prod_{k=1}^{q_{lyr}} \mathbb{Y};$$

4) матриця  $W_k = [w_{ij}^{(k)}]_{q_{nm}^{(k)} \times d_k}$  початкових ваг в  $k$ -му шарі з множеством вещественних  $q_{nm}^{(k)} \times d_k$ -матриць  $W(q_{nm}^{(k)}, d_k)$ ,

$$W_k \in W(q_{nm}^{(k)}, d_k) \text{ при } d_k = q_{nm}^{(k-1)}, k = \overline{2, q_{lyr}} \text{ та}$$

кількість входів (кількість елементів

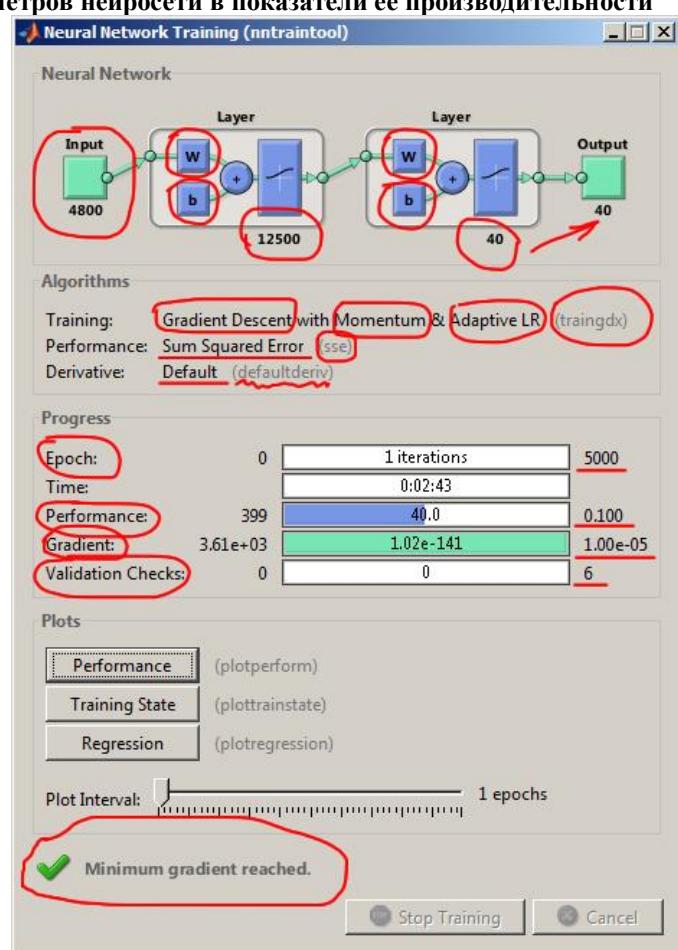


Рис. 1. Персепtron з одним скрітим шаром як нейросеть з прямою зв'язкою, параметри, властивості та атрибути якої візуалізуються з допомогою інструментів Neural Network Toolbox середи MATLAB 7.14

анализируемого образа) нейросети  $d_1$ ;

5) вектор  $\mathbf{B}_k = \left[ b_i^{(k)} \right]_{1 \times q_{\text{nrm}}^{(k)}}$  смещений в  $k$ -м слое с множеством вещественных  $q_{\text{nrm}}^{(k)}$ -мерных точек  $\mathbf{B}(q_{\text{nrm}}^{(k)})$ ,  $\mathbf{B}_k \in \mathbf{B}(q_{\text{nrm}}^{(k)})$ ;

6) функция активации  $k$ -го слоя  $\Phi_k$  с множеством функций активации  $\Phi$ ,  $\Phi_k \in \Phi$ ;

7) алгоритм обучения нейросети  $a_{\text{train}}$  с множеством  $\{a_u\}_{u=1}^{q_{a_{\text{train}}}} = A$  таких алгоритмов для данной задачи распознавания образов,  $a_{\text{train}} \in \{a_u\}_{u=1}^{q_{a_{\text{train}}}} = A$ ,  $q_{a_{\text{train}}} \in \mathbb{Y}$ ;

8) метод реализации  $m_{\text{train}}(a_{\text{train}})$  выбранного алгоритма обучения с множеством

$$\{m_v(a_{\text{train}})\}_{v=1}^{q_{m_{\text{train}}}(a_{\text{train}})} = M(a_{\text{train}})$$

таких методов для данной задачи распознавания образов,

$$m_{\text{train}}(a_{\text{train}}) \in \{m_v(a_{\text{train}})\}_{v=1}^{q_{m_{\text{train}}}(a_{\text{train}})} = M(a_{\text{train}}), q_{m_{\text{train}}}(a_{\text{train}}) \in \mathbb{Y};$$

9) параметры  $\{h_l(m_{\text{train}}(a_{\text{train}}))\}_{l=1}^{q_h[m_{\text{train}}(a_{\text{train}})]}$  выбранного метода реализации алгоритма обучения с множеством значений  $l$ -го параметра  $H_l(m_{\text{train}}(a_{\text{train}}))$ ,

$$h_l(m_{\text{train}}(a_{\text{train}})) \in H_l(m_{\text{train}}(a_{\text{train}})), q_h[m_{\text{train}}(a_{\text{train}})] \in \mathbb{Y};$$

10) количество этапов  $q_{\text{pass}}$  обучения на зашумленных выборках эталонных образов с множеством их значений  $Q_{\text{pass}} \subset \mathbb{Y}$ ,  $q_{\text{pass}} \in Q_{\text{pass}} \subset \mathbb{Y}$ .

Как видим, каждая функция критерия производительности нейросети с прямой связью для задачи распознавания образов задаётся на множестве

$$\begin{aligned} \mathbf{P} = & Q_{\text{lyr}} \times Q_{\text{nrm}} \times \mathbf{D}_{\text{lyr-nrm}} \times \left\{ \prod_{k=1}^{q_{\text{lyr}}} \mathbf{W}(q_{\text{nrm}}^{(k)}, d_k) \right\} \times \\ & \times \left\{ \prod_{k=1}^{q_{\text{lyr}}} \mathbf{B}(q_{\text{nrm}}^{(k)}) \right\} \times \left\{ \prod_{k=1}^{q_{\text{lyr}}} \Phi \right\} \times A \times M(a_{\text{train}}) \times \left\{ \prod_{l=1}^{q_h[m_{\text{train}}(a_{\text{train}})]} H_l(m_{\text{train}}(a_{\text{train}})) \right\} \times Q_{\text{pass}}. \end{aligned} \quad (1)$$

При этом подчеркнём, что множество возможных методов обучения  $M(a_{\text{train}})$  зависит от выбранного алгоритма  $a_{\text{train}} \in A$ , порождая множество  $q_h[m_{\text{train}}(a_{\text{train}})]$  параметров

$$\prod_{l=1}^{q_h[m_{\text{train}}(a_{\text{train}})]} H_l(m_{\text{train}}(a_{\text{train}}))$$

выбранного метода  $m_{\text{train}}(a_{\text{train}})$ . Множество (1) с элементами

$$\mathbf{P} = \left\{ q_{\text{lyr}}, q_{\text{nrm}}, \mathbf{D}_{\text{lyr-nrm}}, \{\mathbf{W}_k\}_{k=1}^{q_{\text{lyr}}}, \{\mathbf{B}_k\}_{k=1}^{q_{\text{lyr}}}, \{\Phi_k\}_{k=1}^{q_{\text{lyr}}}, a_{\text{train}}, m_{\text{train}}(a_{\text{train}}), \{h_l(m_{\text{train}}(a_{\text{train}}))\}_{l=1}^{q_h[m_{\text{train}}(a_{\text{train}})]}, q_{\text{pass}} \right\} \quad (2)$$

отображается в длительность обучения  $t_{\text{train}}(\mathbf{P})$ , вероятность паралича  $p_{\text{off-train}}(\mathbf{P})$ , функции качества обучения  $f_{\text{SSE}}(\mathbf{P})$  и  $f_{\text{MAE}}(\mathbf{P})$ , а также уровень ошибок функционирования  $r_{\text{ER}}(\mathbf{P})$ , которые необходимо минимизировать на (1). Эта операция не представляется сложной для каждой зависимости в отдельности, где применимы численные методы поиска экстремумов функции многих переменных.

#### Критерии максимизации производительности нейросети с условиями их свёртки

Для удобства работы с функциями  $t_{\text{train}}(\mathbf{P})$ ,  $p_{\text{off-train}}(\mathbf{P})$ ,  $f_{\text{SSE}}(\mathbf{P})$ ,  $f_{\text{MAE}}(\mathbf{P})$  и  $r_{\text{ER}}(\mathbf{P})$  в совокупности можно рассматривать их в нормированном виде, представляя оценки их значений в виде многомерных матриц (рис. 2). Естественно, максимальная производительность нейросети достигается на таком  $\mathbf{P}^* \in \mathbf{P}$ , что

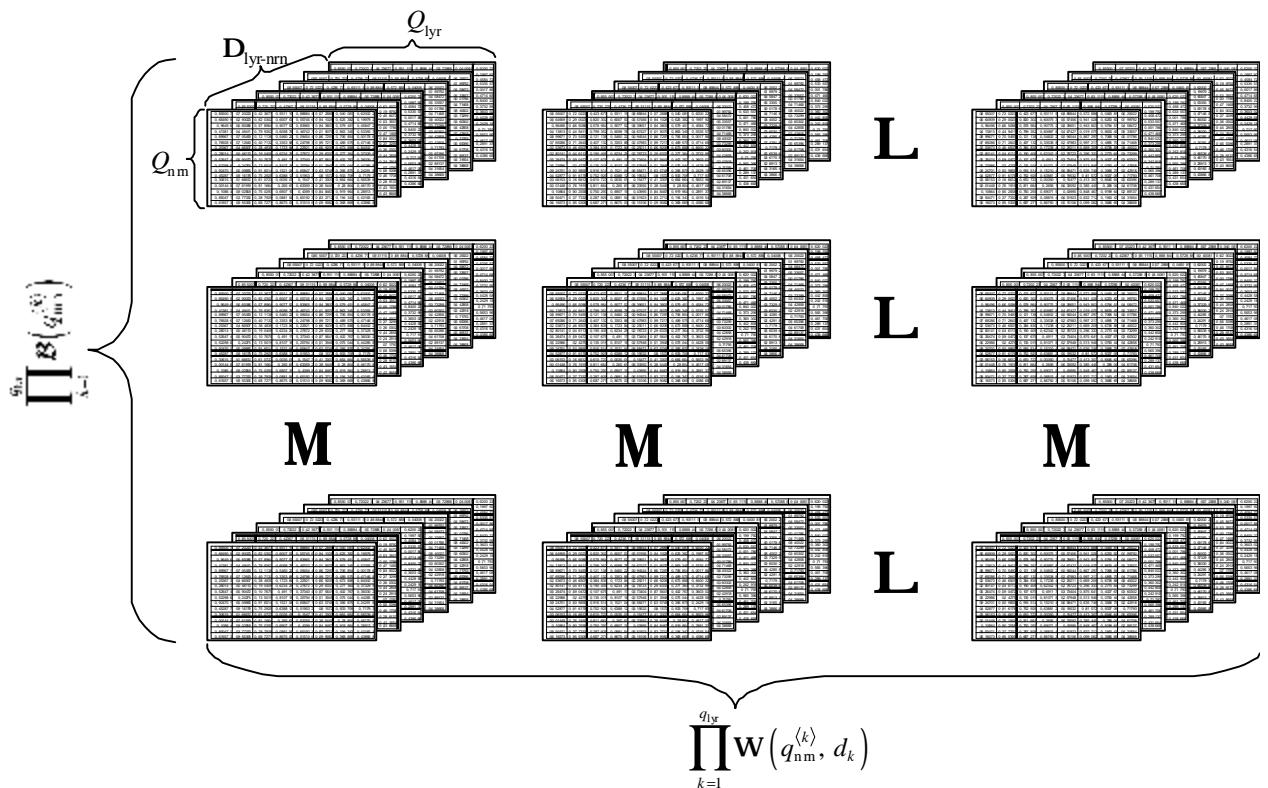
$$\mathbf{P}^* \in \arg \min_{\mathbf{P} \in \mathbf{P}} \frac{t_{\text{train}}(\mathbf{P})}{\max_{\mathbf{P} \in \mathbf{P}} t_{\text{train}}(\mathbf{P})}, \quad \mathbf{P}^* \in \arg \min_{\mathbf{P} \in \mathbf{P}} \frac{p_{\text{off-train}}(\mathbf{P})}{\max_{\mathbf{P} \in \mathbf{P}} p_{\text{off-train}}(\mathbf{P})}, \quad \mathbf{P}^* \in \arg \min_{\mathbf{P} \in \mathbf{P}} \frac{f_{\text{SSE}}(\mathbf{P})}{\max_{\mathbf{P} \in \mathbf{P}} f_{\text{SSE}}(\mathbf{P})},$$

$$\mathbf{P}^* \in \arg \min_{\mathbf{P} \in \mathcal{P}} \frac{f_{\text{MAE}}(\mathbf{P})}{\max_{\mathbf{P} \in \mathcal{P}} f_{\text{MAE}}(\mathbf{P})}, \quad \mathbf{P}^* \in \arg \min_{\mathbf{P} \in \mathcal{P}} \frac{r_{\text{ER}}(\mathbf{P})}{\max_{\mathbf{P} \in \mathcal{P}} r_{\text{ER}}(\mathbf{P})}. \quad (3)$$

Поэтому, агрегируя критерии в пяти задачах (3), получаем пятикритериальную задачу минимизации на множестве (1) с элементами (2). Такая задача, как известно, не имеет решения в общем случае. Следовательно, необходимо решать задачу минимизации

$$\mathbf{P}^{**} \in \arg \min_{\mathbf{P} \in \mathcal{P}} \left( \lambda_1 \cdot \frac{t_{\text{train}}(\mathbf{P})}{\max_{\mathbf{P} \in \mathcal{P}} t_{\text{train}}(\mathbf{P})} + \lambda_2 \cdot \frac{p_{\text{off-train}}(\mathbf{P})}{\max_{\mathbf{P} \in \mathcal{P}} p_{\text{off-train}}(\mathbf{P})} + \right. \\ \left. + \lambda_3 \cdot \frac{f_{\text{SSE}}(\mathbf{P})}{\max_{\mathbf{P} \in \mathcal{P}} f_{\text{SSE}}(\mathbf{P})} + \lambda_4 \cdot \frac{f_{\text{MAE}}(\mathbf{P})}{\max_{\mathbf{P} \in \mathcal{P}} f_{\text{MAE}}(\mathbf{P})} + \lambda_5 \cdot \frac{r_{\text{ER}}(\mathbf{P})}{\max_{\mathbf{P} \in \mathcal{P}} r_{\text{ER}}(\mathbf{P})} \right) \quad (4)$$

по выпуклой свёртке критериев в (3) с положительными коэффициентами  $\{\lambda_s\}_{s=1}^5$  при  $\sum_{s=1}^5 \lambda_s = 1$ .



**Рис. 2. Представление оценок значений функции производительности нейросети, задаваемой на множестве**

$$Q_{\text{lyr}} \times Q_{\text{nm}} \times D_{\text{lyr-nm}} \times \left\{ \prod_{k=1}^{q_{\text{lyr}}} \mathbf{W}\left(q_{\text{nm}}^{(k)}, d_k\right) \right\} \times \left\{ \prod_{k=1}^{q_{\text{lyr}}} \mathbf{B}\left(q_{\text{nm}}^{(k)}\right) \right\}, \text{ в виде пятимерной матрицы (функция пяти переменных)}$$

Вопрос об оценивании коэффициентов  $\{\lambda_s\}_{s=1}^5$  для задачи (4) нетривиален [3], поскольку её решение весьма чувствительно к ним. Если нейросеть уже была задействована в реальном процессе распознавания образов определённого класса, то наверняка существует возможность экспериментального оценивания важности (весомости) или уровней приоритета каждого из пяти критериев в (4) через эти коэффициенты. Когда же функционирование нейросети (в рабочем режиме, не тестовом) находится на начальном этапе, то можно прибегнуть к критерию Бернулли [3], положив  $\lambda_s = 0.2 \quad \forall s = 1, 5$ . А самым, пожалуй, нечувствительным здесь видится минимаксный критерий Вальда [3], согласно которому коэффициенты  $\{\lambda_s\}_{s=1}^5$  являются компонентами оптимальной стратегии первого игрока в матричной  $5 \times |\mathcal{P}|$ -игре с матрицей, строки которой составлены из всех возможных значений каждой из функций в задачах (3).

#### Заключение и перспектива продолжения исследования оптимизации параметров нейросети

Следует помнить, что перечисленные пять критериев оптимизации параметров нейросети относятся лишь к задаче распознавания образов, а в других технических задачах [1] множество этих критериев может пополняться. Кроме того, ряд свойств процесса обучения (граничные значения количества эпох, градиента функции ошибок, попыток повысить качество обучения) в элементах (2) множества (1) были преднамеренно

опущены, поскольку их влияние на продуктивность при разумном выборе значений по умолчанию мало [1]. И, как уже упоминалось, задача (4) сводится к численному поиску минимума функции 10 переменных (или  $6 + 3q_{ly} + q_h [m_{train}(a_{train})]$ ) переменных, если не группировать по слоям и параметрам выбранного метода обучения), где в перспективе стоит рассмотреть учёт влияния длительности обучения на функции качества обучения и уровень ошибок функционирования, а также проанализировать взаимосвязь между ними.

### Література

- Хайкин С. Нейронные сети: полный курс / Хайкин С. — [2-е изд.]. — М. : Издательский дом “Вильямс”, 2006. — 1104 с.
- Hagan M. T. Training feedforward networks with the Marquardt algorithm / M. T. Hagan, M. Menhaj // IEEE Transactions on Neural Networks. — 1994. — Vol. 5, N. 6. — P. 989 — 993.
- Трухаев Р. И. Модели принятия решений в условиях неопределённости / Трухаев Р. И. — М. : Наука, 1981. — 258 с.

Надійшла 23.11.2012  
Рецензент: д.т.н. Сорокатий Р.В.

УДК 621.3

О.І. ПОЛІКАРОВСЬКИХ  
Хмельницький національний університет

## АНАЛІЗ МЕТОДІВ ПЕРЕТВОРЕННЯ ФАЗА-АМПЛІТУДА У ЦИФРОВИХ ОБЧИСЛЮВАЛЬНИХ СИНТЕЗАТОРАХ

Проаналізовано методи перетворення відліків фази у відліки амплітуди в цифрових обчислювальних синтезаторах – DDS. Проаналізовано різноманітні алгоритми такого перетворення. Розглянуті методи проаналізовані з точки зору зменшення апаратних затрат на реалізацію перетворення з необхідною якістю.

**Ключові слова:** АЦП, ЦАП, цифровий обчислювальний синтезатор, ADC, DAC, direct frequency synthesizer (DDS).

*The methods of converting counts in samples of the amplitude phase in digital computer synthesizers (DDS) was proposed. Analysis of various algorithms for this conversion. Considered methods are analyzed in terms of reducing hardware costs to implement transformation of the required quality.*

**Keywords:** ADC, DAC, digital computer synthesizer, ADC, DAC, direct frequency synthesizer (DDS).

### Постановка задачі

Цифровий обчислювальний синтезатор у спрощеному виді представлено на рис. 1.

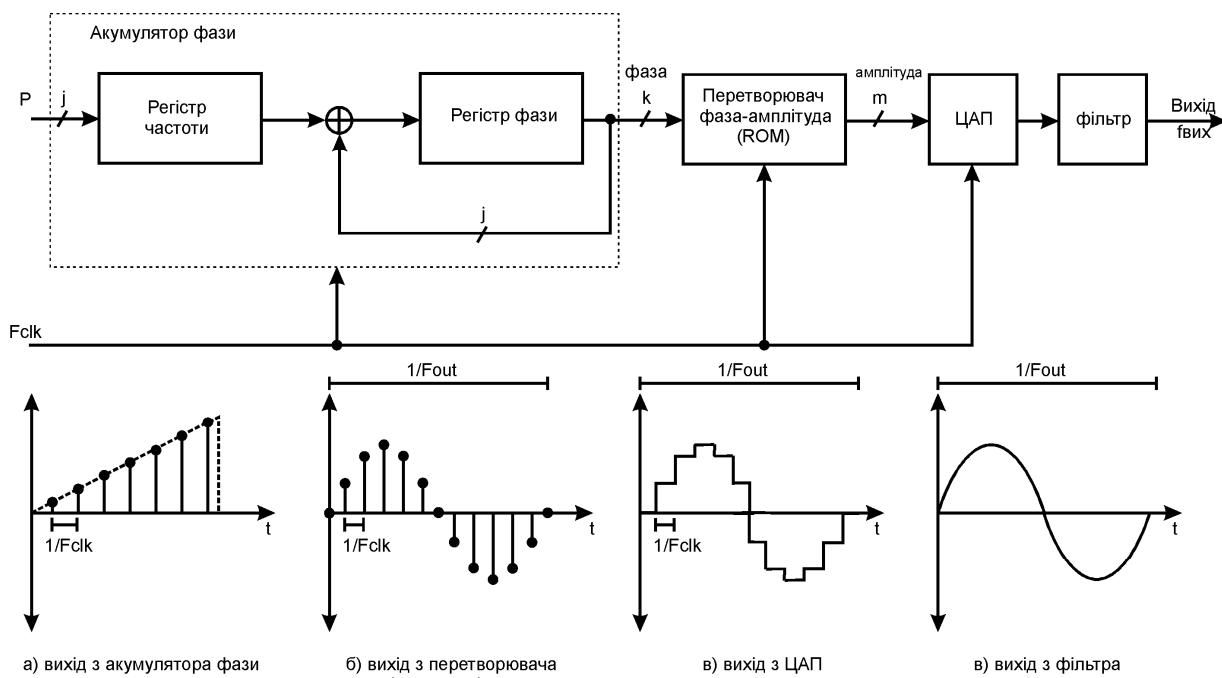


Рис. 1. Структурна схема DDS, та перетворення сигналів у ньому [2]

Проаналізуємо методи перетворення відліків фази у відліки амплітуди, які надходять до ЦАП, а далі