

## МОДЕЛЬ КОМБИНИРОВАННОЙ КАСКАДНОЙ РАДИАЛЬНО БАЗИСНОЙ НЕЙРОННОЙ СЕТИ И АЛГОРИТМ ЕЕ ОБУЧЕНИЯ

Елена Зайченко, Екатерина Малышевская

**Аннотация:** В статье предложена модель комбинированной каскадной радиально-базисной нейронной сети и представлен гибридный метод ее обучения, который заключается в том что процесс нахождения оптимальных значений параметров сети разбивается на 2 этапа, на первом из которых, оптимизируются нелинейные параметры радиально базисных функций, а на втором веса связей нейронной сети.

**Ключевые слова:** нейронные сети, каскадные структуры нейронных сетей, радиально-базисные функции, методы оптимизации.

**ACM Classification Keywords:** I.2.6 Connectionism and neural nets.

---

### Введение

---

Каскадные нейронные сети являются перспективным направлением в развитии нейронных сетей, потому разработка их математических моделей и алгоритмов является актуальной задачей в сфере искусственного интеллекта. В статье предложен гибридный метод обучения каскадных нейронных сетей, который заключается в том что процесс нахождения оптимальных значений параметров каскадной радиально - базисной нейронной сети разбивается на 2 этапа, на первом из которых, оптимизируются нелинейные параметры радиально базисных функций, а на втором веса связей нейронной сети, благодаря чему снижается общая размерность задачи оптимизации и ускоряется работа алгоритма обучения.

---

### Модель и алгоритм обучения комбинированной каскадной радиально базисной нейронной сети

---

Модель комбинированной каскадной радиально базисной нейронной сети (КРБНС) можно представить в таком виде:

1-й каскад.

$$\varphi_{1j}^{(1)}(x_j) = e^{-\frac{(x_j - c_{1j})^2}{2r_1^2}}$$

$$\varphi_{kj}^{(1)}(x_j) = e^{-\frac{(x_j - c_{kj})^2}{2r_k^2}}$$

Выходы РБФ нейрона первого каскада:

$$z_1^1 = \prod_{j=1}^n \varphi_{1j}(x_j) = e^{-\sum_{j=1}^n \frac{(x_j - c_{1j})^2}{2r_1^2}} \quad (1)$$

$$z_2 = \prod_{j=1}^n \varphi_{2j}(x_j) = e^{-\sum_{j=1}^n \frac{(x_j - c_{2j})^2}{2r_2^2}}$$

$$z_k = \prod_{j=1}^n \varphi_{kj}(x_j) = e^{-\sum_{j=1}^n \frac{(x_j - c_{kj})^2}{2r_k^2}}$$

Выходы нейронной сети первого каскада

$$y_1^{(1)} = \sum_{k=1}^N z_k^{(1)} w_{k1}^{(1)} = Z^T W_1$$

$$y_i^{(1)} = \sum_{k=1}^N z_k^{(1)} w_{ki}^{(1)} = Z^T W_i, \quad i = \overline{1, N}$$

Вектор выходов  $y^{(1)} = [y_i^{(1)}] = W^{(1)}Z$

$$W^{(1)} = \left\| w_{ik}^{(1)} \right\|_{\substack{k=1, \overline{N} \\ i=1, \overline{N}}}$$

**2-й каскад.**

$$z_1^{(2)} = \exp \left( - \left\{ \sum_{j=1}^n \frac{(x_j - c_{1i}^{(2)})^2}{2} + \sum_{i=1}^N \frac{(z_i^{(1)} - c_{i1}^{(1)})^2}{2r_{21}^{(2)}} \right\} \right)$$

$$z_k^{(2)} = \exp \left( - \left\{ \sum_{j=1}^n \frac{(x_j - c_{kj}^{(2)})^2}{2r_j^2} + \sum_{i=1}^N \frac{(z_i^{(1)} - c_{ik}^{(1)})^2}{2r_{2k}^2} \right\} \right)$$

$$y_k^{(2)} = y_k^{(1)} + \sum_{i=1}^N z_{ik}^{(2)} w_{ik}^{(2)}$$

**k-й каскад.**

Непосредственные выходы k-го каскада:

$$\varphi_j^{(k)}(x_j) = e^{-\frac{(x_j - c_j^{(k)})^2}{2r_{jk}^2}}, \quad j = \overline{1, n}$$

Входы с выходов предыдущих каскадов

$$\varphi^{(k)}(z_i^{(k)}) = \exp \left\{ - \frac{(z_i^{(k)} - c_i^{(k)})^2}{2r_k^2} \right\}, \quad i = \overline{1, N}, \quad k = \overline{1, K-1}$$

i-й выход K-го каскада (промежуточный)

$$z_i^{(K)} = \prod_{j=1}^n \varphi_j^{(k)}(x_j) \prod_{k=1}^{K-1} \varphi(z_k) = \exp \left\{ - \sum_{j=1}^n \frac{(x_j - c_j^{(k)})^2}{2r_j^2} - \sum_{k=1}^{K-1} \frac{(z_i^{(k)} - c_i^{(k)})^2}{2r_{ik}^2} \right\}$$

Общий выход после  $K$  каскадов

$$y_1^{(K)} = \sum_{k=1}^K \sum_{l=1}^N z_l^{(k)} w_{l1}^{(k)} = y_1^{(K-1)} + \sum_{l=1}^N z_l^{(K)} w_{l1}^{(K)}$$

$$y_i^{(K)} = \sum_{k=1}^K \sum_{l=1}^N z_l^{(k)} w_{li}^{(k)} = y_i^{(K-1)} + \sum_{l=1}^N z_l^{(K)} w_{li}^{(K)}, \quad i - \text{общий выход}$$

Или в матричной записи

$$Y_1^{(k)} = W_1^{(k)} Z^{(k)}, \quad Y_i^{(k)} = W_i^{(k)} Z^{(k)}, \quad i = \overline{1, N}$$

**Модель описания работы каскадной РБФН сети.**

1. Модель 1-го каскада.

Используются РБ-функции для всех входов (входы  $j = \overline{1, n}$ ; выходы  $i = \overline{1, N}$ ):

$$\varphi_{1j}^{(1)}(x_j) = e^{-\frac{(x_j - c_{1j})^2}{2r_1^2}}, \quad i = \overline{1, N} \quad \text{где } N = 6 - \text{число выходов сети.}$$

Первый  $z$ :

$$\varphi_{kj}^{(1)}(x_j) = e^{-\frac{(x_j - c_{kj})^2}{2r_k^2}} \quad (2)$$

Первый выход РБФ нейрона 1-го каскада:

$$z_1^{(1)} = \prod_{j=1}^n \varphi_{1j}^{(1)}(x_j) = \exp \left\{ \sum_{j=1}^n -\frac{(x_j - c_{1j})^2}{2r_1^2} \right\},$$

$i$ -й выход

$$z_k^{(1)} = \prod_{j=1}^n \varphi_{kj}^{(1)}(x_j) = \exp \left\{ \sum_{j=1}^n -\frac{(x_j - c_{kj})^2}{2r_k^2} \right\}$$

Выходы сети:

$$y_1^{(1)} = \sum_{k=1}^N z_k^{(1)} w_{k1}^{(1)}, \quad y_i^{(1)} = \sum_{k=1}^N z_k^{(1)} w_{ki}^{(1)}, \quad y_N^{(1)} = \sum_{k=1}^N z_k^{(1)} w_{kN}^{(1)}$$

$$y^{(1)} = [y_i^{(1)}] = W^{(1)} Z$$

$$W^{(1)} = \left\| w_{ik} \right\|_{\substack{k=1, \overline{N} \\ i=1, \overline{N}}}$$

2. Модель 2-го каскада.

Непосредственные входы:

$$\varphi_{1j}^{(2)}(x_j) = e^{-\frac{(x_j - c_{1j})^2}{2r_{1j}^2}}, \quad j = \overline{1, n}.$$

$$\varphi_{ij}^{(2)}(x_j) = e^{-\frac{(x_j - c_{ij}^{(2)})^2}{2r_{ij}^2}}, \quad j = \overline{1, n}, \quad i = \overline{1, N}.$$

Входы с выходов 1-го каскада:

$$\varphi(z_i^{(1)}) = e^{-\frac{(z_i^{(1)} - c_{n+i}^{(1)})^2}{2r_{n+i}^2}}$$

$$z_1^{(2)} = \prod_{j=1}^n \varphi_{1j}^{(2)}(x_j) \varphi(z_1^{(1)}) = \exp \left\{ -\sum_{j=1}^n \frac{(x_j - c_{1j})^2}{2r_{1j}^2} - \frac{(z_1^{(1)} - c_{1n+1}^{(1)})^2}{2r_{1n+1}^2} \right\}$$

$$z_i^{(2)} = \prod_{j=1}^n \varphi_{ij}^{(2)}(x_j) \varphi(z_i^{(1)}) = \exp \left\{ -\sum_{j=1}^n \frac{(x_j - c_{ij}^{(2)})^2}{2r_{ij}^2} - \frac{(z_i^{(1)} - c_{n+i}^{(1)})^2}{2r_{n+i}^2} \right\}$$

Выходы 2-го каскада:

$$y_1^{(2)} = \sum_{i=1}^N z_i^{(1)} w_{1i}^{(1)} + \sum_{i=1}^N z_i^{(2)} w_{1i}^{(2)}; \quad y_k^{(2)} = \sum_{i=1}^N z_i^{(1)} w_{ki}^{(1)} + \sum_{i=1}^N z_i^{(2)} w_{ki}^{(2)}$$

### Алгоритм обучения КРБНС.

Общий критерий обучения выглядит так:

Найти такие матрицы весов  $W_k = \|W_{ij}^{(k)}\|$ ,  $i = \overline{1, N}$ ,  $l = \overline{1, N}$ ,  $k = \overline{1, K}$ ; а также параметры РБ-функций  $\{c_{ij}^{(k)}\}$  и  $\{r_{ij}^{(k)}\}$  для которых  $E = \sum_{t=1}^T \sum_{i=1}^N (y_{it}^{\text{target}} - \hat{y}_{it}^{(k)}(W, C, R))^2 \rightarrow \min_{W, C, R}$ , где  $y_{it}^{\text{target}}$  – требуемый желаемый выход  $i$ -го класса,  $\hat{y}_{it}^{(k)}(W, C, R)$  – выход модели  $i$ -го класса для образца  $t$ ,  $T$  – общий объем обучающей выборки.

### Описание алгоритма.

Общий алгоритм состоит из последовательности итераций. Обучение проходит последовательно, начиная с первого каскада [Fahlman & Lebiere, 1989].

### Алгоритм обучения каскада 1.

Используем гибридный алгоритм состоящий из последовательности двух этапов.

- 1 этап. Обучение весов связей  $W_{ij}^{(1)}$ ;
- 2 этап. Настройка параметров РБ-функций  $\{r_{ij}, c_{ij}^{(k)}\}$ .

### Этап 1.

1. Первоначально выберем начальные значения параметров РБФ [Kovacevic & Loncaric, 1997]

$c_{ij}^{(1)}(0)$  и  $r_{ij}^2(0)$  их можно инициализировать случайно или рассчитать так  $c_{ij}^{(1)}(0) = \frac{1}{n_i} \sum_{t \in V_i} x_{jt}$ , где  $t$

– номер образца;  $V_i$  – подмножество образцов класса  $i$  ( $i = \overline{1, N}$ );  $n_i$  – число образцов класса  $V_i$  обучающей выборке,  $x_{jt}$  – значение входа  $j$  образца  $t$ :

$$r_{ij}^2(0) = \frac{1}{n_i - 1} \sum_{t \in V_i} (x_{jt} - c_{ij}^{(1)}(0))^2.$$

2. Далее определяем  $\{\varphi_{ij}^{(1)}(x_{jt})\}, t \in T$  и находим  $z_{it}^{(1)}$ . Обозначим для удобства  $[z_{it}^{(1)}]_{t \in V_i} = z_i^{(1)}$ .

$$y_{it}^{(1)} = \sum_{l=1}^N z_{it}^{(1)} w_{li}^{(1)}, y_{Nt}^{(1)} = \sum_{l=1}^N z_{it}^{(1)} w_{lN}^{(1)} - \text{выходы 1-го каскада.}$$

Поскольку классификация происходит по критерию max выхода, то решающее правило классификации  $X_t = [x'_{jt}]$ ,  $j = \overline{1, N}$  относится к классу  $V_i$ , если

$$y_{it}^{(1)} = \sum_{l=1}^N z_{it}^{(1)} w_{li}^{(1)} = \max_k y_{kt}^{(1)} = \max_k \sum_{l=1}^N z_{it}^{(1)} w_{lk}^{(1)}.$$

Обозначим желаемое значение  $i$ -го выхода (класса)  $y_{\text{target } i}^t = y_{\text{max}}$  образцов из класса  $V_i$ , а для всех образцов из других классов  $\overline{V_i}$  через  $y_{\text{target } i}^t = y_{\text{min}}$ . Запишем соответствующие неравенства для  $i$ -го выхода первого каскада

$$y_{it} = z^{(1)} w^{(1)} = \sum_{l=1}^N z_{it}^{(1)} w_{li}^{(1)}, \geq y_{\text{target}}^t = y_{\text{max}}, t \in V_i \tag{3}$$

$$\leq y_{\text{target}}^t = y_{\text{min}}, t \notin V_i \tag{4}$$

Тогда можно записать следующую задачу ЛП

$$\min \sum_{t \in V_i} \varepsilon_t \tag{5}$$

при таких условиях:

$$\sum_{l=1}^N z_{it}^{(1)} w_{li}^{(1)} - \varepsilon_t = y_{\text{max}}, t \in V_i, i = \overline{1, N} \tag{6}$$

$$\sum_{l=1}^N z_{it}^{(1)} w_{li}^{(1)} + \varepsilon_t = y_{\text{min}}, t \notin V_i, i = \overline{1, N} \tag{7}$$

$$\varepsilon_t \geq 0$$

Решаем ЗЛП (5) – (7) симплекс методом и если она разрешима, то конец обучения 1 каскада, иначе если она оказалась неразрешимой по соответствующему признаку симплекс-метода, то переходим к следующей вспомогательной задаче:

$$\min \sum_{t=1}^T \varepsilon_t^2 \quad (8)$$

при условиях (6), (7). Эта задача квадратичного программирования, которая решается стандартным методом [Зайченко, 2004].

Повторяем ее решение для всех начальных значений весов  $[W_{il}^{(1)}]_{l=1, \overline{N}}^{i=1, \overline{N}}$ .

*Конец этапа 1.*

Переходим ко второму этапу, на котором оптимизируем значения параметров РБ-функций  $c_{ij}^{(1)}$  и  $r_{ij}^{(1)}$ .

## Этап 2

Оптимизируемый критерий имеет следующий вид:

$$E = \frac{1}{T} \sum_{i=1}^N \sum_{t \in V_i} (y_{it}^{\text{target}} - \hat{y}_{it}(c, r))^2 \rightarrow \min \quad (9)$$

где  $y_{it}^{\text{target}} = \begin{cases} y_{\max}, & \text{if } t \in V_i \\ y_{\min}, & \text{if } t \notin V_i \end{cases}$  - заданное значение для образца  $t$ -го выхода,  $V_i$ — множество

образцов  $i$ -го класса обучающей выборки,  $\hat{y}_{it}$  –  $i$ -й выход для  $t$ -го образца КРБН-сети.

Для оптимизации параметров используется градиентный метод или метод обучения Вироу-Хоффа Найдем значение  $\frac{\partial E}{\partial c_{ij}^{(1)}}$  для градиента:

$$\frac{\partial E}{\partial c_{ij}^{(1)}} = -\frac{1}{T} \sum_{t=1}^T (y_{it}^{\text{target}} - \hat{y}_{it}(c, r)) \frac{\partial \hat{y}_{it}}{\partial c_{ij}^{(1)}} = -\frac{1}{T} \sum_{t=1}^T (y_{it}^{\text{target}} - \hat{y}_{it}(c, r)) \frac{\partial \hat{y}_{it}}{\partial c_{ij}^{(1)}} \quad (10)$$

С учетом того, что:



$$\hat{y}_{it} = \sum_{l=1}^N z_{li}^{(1)} w_{li}^{(1)} = \sum_{l=1}^N \prod_{j=1}^n \varphi(x_{jt}^{(l)}) w_{li}^{(1)} = \sum_{l=1}^N \exp\left(-\sum_{j=1}^n \frac{(x_{jt}^{(l)} - c_{lj}^{(1)})^2}{2r_j^2}\right) w_{li}^{(1)}, \quad j = \overline{1, n}, \quad l = \overline{1, N} \quad (11)$$

$$\frac{\partial E}{\partial c_{lj}^{(1)}} = w_{ji} \exp\left(-\sum_{j=1}^n \frac{(x_{jt}^{(l)} - c_{lj}^{(1)})^2}{2r_j^2}\right) \frac{(x_{jt}^{(l)} - c_{lj}^{(1)})}{2r_j^2} \quad (12)$$

$$\frac{\partial E}{\partial r_j^{(1)}} = w_{ji} \exp\left(-\sum_{j=1}^n \frac{(x_{jt}^{(l)} - c_{lj}^{(1)})^2}{2r_j^2}\right) \frac{(x_{jt}^{(l)} - c_{lj}^{(1)})^2}{2r_j^3} \quad (13)$$

Далее реализуем градиентный алгоритм спуска и находим рекуррентно:

$$c_{lj}^{(1)}(m+1) = c_{lj}^{(1)}(m) - \gamma_m \frac{\partial E(m)}{\partial c_{lj}^{(1)}}, \quad m = 1, 2, \dots \quad (14)$$

$$r_{lj}^{(1)}(m+1) = r_{lj}^{(1)}(m) - \gamma'_m \frac{\partial E(m)}{\partial r_{lj}^{(1)}}, \quad m = 1, 2, \dots \quad (15)$$

Условия сходимости

а.  $\gamma_m \rightarrow 0; m \rightarrow \infty$

б.  $\sum_{m=0}^{\infty} \gamma_m = \infty$

в.  $\sum_{m=0}^{\infty} \gamma_m^2 < \infty$

Итерации градиентного спуска повторяем до тех пор, пока значения  $c_{lj}^{(1)}$  и  $r_{lj}^{(1)}$  не будут стабилизированы.

В результате находим  $c_{lj}^{(1)_{\text{new}}} = c_{lj}^{(1)}(1)$  и  $r_{lj}^{(1)_{\text{new}}} = r_{lj}^{(1)}(1)$ .

Далее переходим снова к этапу 2 и решаем (7) при условиях (5) и (6) с новыми значениями параметров РБ-функции  $c_{lj}^{(1)}$  и  $r_{lj}^{(1)}$ .

Последовательность этапов 1 и 2 повторяем до тех пор, пока значения параметров  $c_{ij}^{(1)}$  и  $r_{ij}^{(1)}$  и веса  $\left[ w_{li}^{(1)} \right]_{i=1, N}^{l=1, N}$  не стабилизируются. На этом обучение параметров первого каскада заканчивается.

Поскольку число итераций градиентного метода зависит нелинейно от размерности (числа варьируемых параметров), то разбиение предлагаемого алгоритма оптимизации на 2 отдельных этапа существенно сокращает размерность задачи. Благодаря этому, общее число итераций предл. алгоритма значительно меньше, чем у классического градиентного метода, а его скорость сходимости выше.

## Алгоритм обучения каскада 2

Далее переходим к оптимизации параметров обучения второго каскада ( $k=2$ ) зафиксировав параметры РБФ и выходы каскада 1 ( $y_1^{(1)}, \dots, y_N^{(1)}$ ).

Для него используется тот же гибридный алгоритм что и ранее (для каскада 1).

При этом на этапе 1 для  $i$ -го выхода каскада 2 имеем:

$$y_{it}^{(2)} = \sum_{l=1}^N z_{lt}^{(2)} w_{li}^{(2)} + \sum_{l=1}^N z_{lt}^{(1)} w_{li}^{(1)} = \sum_{l=1}^N z_{lt}^{(2)} w_{li}^{(2)} + y_{it}^{(1)} \quad (16)$$

Решаем задачу квадратичного программирования для  $i$ -го выхода:

$$\min \sum_{t \in V_i} \varepsilon_t^2 \quad (17)$$

при условиях

$$\sum_{l=1}^N z_{lt}^{(2)} w_{li}^{(2)} + y_{it}^{(1)} - \varepsilon_t = y_{\max}, \quad t \in V_i \quad (18)$$

$$\sum_{l=1}^N z_{lt}^{(2)} w_{li}^{(2)} + y_{it}^{(1)} + \varepsilon_t = y_{\min}, \quad t \notin V_i \quad (19)$$

В результате находим начальные веса  $\left[ w_{li}^{(2)} \right]_{i=1, N}^{l=1, N}$ , затем переходим ко второму этапу.

---

---

На втором этапе градиентным методом или методом сопряженного градиента вычисляем значения параметров РБ-функций второго каскада по формулам, аналогичным (14), (15).

Повторив многократно 2 этапа, определяем установившиеся параметры РБ-функций и веса  $[w_{li}^{(2)}]$  второго каскада.

Обозначим через  $E_2$  значение общего критерия после 2-го каскада.

Проверка условия останова.

Если а)  $|E_2 - E_1| < \varepsilon$  или б)  $E_2 > E_1$ , то stop; синтез структуры заканчивается.

В противном случае, переходим к синтезу 3-го каскада.

Последовательность итераций останавливается на каскаде  $k$ , когда  $E_{k+1} > E_k$  или  $|E_{k+1} - E_k| < \varepsilon$ , где  $\varepsilon$ - заданная точность.

---

### Результаты экспериментов

---

Проводилось 2 эксперимента классификации типа и процентного содержания эпителия на шейке матки. Всего было 100 наблюдений. Каждое наблюдение это известный результат биопсии. Другими словами входы сети это часть изображения, где была взята биопсия и известны ее результаты, а выходы сети это тип эпителия, то есть результат биопсии. Выборка делилась на обучающую (80) и тренировочную (20) подвыборки. Для анализа результатов использовался cross validation.

В первом эксперименте мы классифицировали эпителий на 6 типов. Использовалось 4 вида нейронных сетей. Сравнивались результаты классификации типов эпителия известных нейронных сетей с новым алгоритмом комбинированной каскадной радиально базисной нейронной сети.

Во втором эксперименте мы проверяли область на наличие опасного типа эпителия. Так как опасными считаются определенные три типа ткани - мы определяли их суммарный процент на исследуемой области органа. Для того чтоб этого сделать мы фактически провели первый эксперимент с пост процессингом: мы использовали наблюдения с полными результатами биопсии (включая процентное содержание каждого типа эпителия) и проверили результаты для суммарного процента трех опасных видов эпителия.

Результаты приведены в следующей Таблице 1. Из таблицы видно, что комбинированный алгоритм каскадной нейронной сети дает лучший результат.

**Таблица 1.** Результаты классификации типов тканей (СКО)

	Каскадная нейронная сеть	Нейронная сеть Back propagation	Радиально базисная нейронная сеть	Каскадная радиально базисная нейронная сеть
6 типов тканей	0.0479	0.0584	0.0610	0.0361
CIN1+CIN2+CIN3 (до обучения)	0.0832	0.1089	0.0569	0.0498
CIN1+CIN2+CIN3 (после обучения)	0.0479	0.0584	0.0610	0.0361

### **Заключение**

Разработан новый метод синтеза нейронных сетей на основе которого получена новая структура комбинированной каскадной радиально-базисной нейронной сети для обработки оптических изображений.

Разработан метод обучения каскадной радиально-базисной нейронной сети, который заключается в том, что процесс нахождения оптимальных значений параметров КРБНМ разбивается на 2 этапа, на первом из которых, оптимизируются нелинейные параметры РБ функций, а на втором веса связей НМ, благодаря чему снижается общая размерность задачи оптимизации и ускоряется работа алгоритма обучения.

Из проведенных экспериментальных исследований видно, что комбинированная нейронная сеть дает лучший результат классификации.

---

## Библиография

---

- [Fahlman & Lebiere, 1989] Scott E. Fahlman, Christian Lebiere, "The Cascade-Correlation Learning Architecture", NIPS 1989, pp. 524-532
- [Kovacevic & Loncaric, 1997] Domagoj Kovacevic, Sven Loncaric, "Radial Basis Function-based Image Segmentation using a Receptive Field", Computer-Based Medical Systems, Proceedings, Tenth IEEE Symposium, 1997, pp. 126-130
- [Зайченко, 2004] Зайченко Ю.П., "Основы проектирования интеллектуальных систем", Учебное пособие – К.: Издательский дом "Слово", 2004.

---

## Сведения об авторах

---



**Елена Юрьевна Зайченко** – НТУУ „КПИ”, д.т.н., профессор, Киев-03056, Украина;  
e-mail: syncmaster@bigmir.net

Основные области научных исследований: методы оптимизации, нейронные сети, компьютерные сети



**Екатерина Николаевна Малышевская** - НТУУ „КПИ”, аспирант, Киев-03056, Украина; e-mail: kate.inv@gmail.com

Основные области научных исследований: нейронные сети, обработка изображений.

## The Model for the Combined Cascade Radial Basis Neural Network and Its Learning Algorithm

Olena Zaychenko, Kateryna Malyshevskaya

**Abstract:** In this article, the combined cascade radial basis network is proposed and a hybrid learning method is presented, in which the optimal values for network's parameters are calculated in two stages. In the first stage, the nonlinear parameters of radial basis functions are optimized and, in the second stage, the connection weights are optimized.

**Keywords:** radial basis function network, neural network, cascade neural network, learning algorithm, neural network model.