



Е.В. БОДЯНСКИЙ, Н.Е. КУЛИШОВА

УДК 519.7: 004.8

НЕЙРО-ФАЗЗИ СИСТЕМА, ОСНОВАННАЯ НА ПАМЯТИ, ДЛЯ ИНТЕРПОЛЯЦИИ КОЭФФИЦИЕНТОВ ОТРАЖЕНИЯ ПОЛИГРАФИЧЕСКИХ КРАСОК

Ключевые слова: *вычислительный интеллект, нейро-фаззи система, интерполяция.*

ВВЕДЕНИЕ

Современные устройства воспроизведения цветных изображений используют системы управления цветом, реализующие многоэтапные процессы обработки цветowych данных посредством применения профилей. Однако в полиграфической практике такой подход не всегда эффективен, поскольку требует наличия большого количества профилей для каждой печатной машины с учетом конкретных сортов бумаги и красок. Кроме того, в одной печатной машине разные красочные секции могут иметь различные характеристики и нестабильно формировать один и тот же цвет в пределах печатного листа. Для точного воспроизведения сюжетно важных цветов часто пользуются методом дубликатов, когда фиксируются такие соотношения основных красок полиграфического синтеза, которые дадут цвета, близкие заданным.

Такой подход требует наличия подробной информации о цветовоспроизводящих свойствах системы «машина – краска – бумага», выраженной в аналитической форме. Именно в этом случае решение задачи воспроизведения цвета будет наилучшим. Однако подобные сведения доступны лишь в виде множества экспериментальных данных о спектральных характеристиках красочного слоя на бумаге. Обычно их получают в процессе спектрофотометрических измерений контрольных шкал, отпечатанных на конкретных печатных машинах. Для оптимального выбора сочетаний базовых красок синтеза необходимо аналитическое представление зависимости коэффициента отражения красочного слоя от концентрации краски и длины волны, что является достаточно сложной задачей.

С математической точки зрения эта задача сводится к интерполяции двумерной нелинейной функции достаточно сложного вида, заданной на множестве узлов, число которых может быть очень велико. В общем случае для решения подобных задач могут быть использованы искусственные нейронные сети, обладающие универсальными аппроксимирующими возможностями, в частности радиально-базисные нейронные сети [1–3], хорошо приспособленные также для решения задач интерполяции многомерных нелинейных функций [4, 5]. Важным свойством этих сетей является линейная зависимость выходного сигнала от настраиваемых параметров, что позволяет для их обучения использовать либо обычный метод наименьших квадратов (в задаче аппроксимации), либо стандартные методы решения систем линейных уравнений (в задаче интерполяции).

© Е.В. Бодянский, Н.Е. Кулишова, 2008

Опыт, однако, показал [6], что обычная радиально-базисная нейронная сеть, обеспечивающая высокую точность интерполяции, может порождать существенные колебания между узлами, что делает ее практически неприемлемой. Это объясняется неопределенностью параметров рецепторных полей радиально-базисных функций, которые выбираются исходя из сугубо эмпирических соображений. Кроме того, практическое использование радиально-базисных нейронных сетей ограничивается так называемым «проклятием» размерности, которое особенно ярко проявляется в задаче интерполяции, когда количество радиально-базисных функций совпадает с количеством узлов интерполяции. В этом случае в процессе обучения сети могут возникнуть непреодолимые вычислительные трудности.

Альтернативой нейронным сетям, обучение которых сводится к задаче оптимизации либо к решению систем уравнений, объединенным общим названием «сети, основанные на оптимизации» (optimization-based networks), являются так называемые сети, основанные на памяти (memory-based networks), наиболее ярким представителем которых является обобщенная регрессионная нейронная сеть, предложенная Д. Шпехтом [7]. В основе этой сети лежат идеи окон Парзена [8], ядерных оценок Надарая–Ватсона [9, 10] и непараметрических моделей [11], а ее обучение сводится к однократной установке многомерных радиально-базисных функций в точках гиперкуба, однозначно определяемых обучающей выборкой. Эта сеть может быть отнесена к так называемым мгновенно обучаемым моделям (just-in-time models) [12], настраиваемым с помощью одного прохода алгоритма обучения (one-pass learning algorithm). Обобщенная регрессионная сеть, практически совпадая с радиально-базисными архитектурами, обучается намного быстрее, устанавливая центры радиально-базисных функций в точках с координатами, определяемыми входными сигналами, по принципу «нейроны в точках данных» (neurons at data points) [13] и с высотой активационных функций, совпадающей с соответствующими значениями обучающего сигнала. При этом вопрос выбора параметров рецепторных полей остается открытым.

Естественным развитием искусственных нейронных сетей являются нейро-фаззи системы [14, 15], сочетающие возможности обучаемости нейронных сетей с прозрачностью и интерпретируемостью систем нечеткого вывода. В общем случае нейро-фаззи системы представляют собой нечеткие модели, обучаемые с помощью алгоритмов, принятых в теории нейронных сетей, и использующие вместо многомерных радиально-базисных функций одномерные фаззи-базисные функции, которые являются по сути колоколообразными функциями принадлежности, принятыми в нечеткой логике. Использование колоколообразных фаззи-базисных функций позволяет сочетать локальные особенности ядерных функций со свойствами традиционных сигмоидальных активационных функций нейронных сетей, обеспечивающих глобальные аппроксимирующие свойства [16]. Обладая аппроксимирующими-интерполирующими возможностями радиально-базисных сетей, нейро-фаззи системы в меньшей мере подвержены «проклятию» размерности, что обеспечивает им преимущество по сравнению с обычными нейросетями.

Среди нейро-фаззи систем наибольшее распространение получила адаптивная нейро-система нечеткого вывода (ANFIS) [17], представляющая собой пятислойную архитектуру, синаптические веса которой обучаются аналогично весам радиально-базисной нейронной сети. В системе предусмотрена также возможность настройки фаззи-базисных функций с помощью алгоритма обратного распространения ошибок. ANFIS и другие подобные ей нейро-фаззи системы [12, 15, 16] являются типичными представителями сетей, основанных на оптимизации, характеризующихся недостаточной скоростью обучения.

Представителями сетей, основанных на памяти, могут считаться решетчатые ассоциативные нейросетевые памяти (Lattice-Based Associative Memory Networks) [18, 19], выходной сигнал которых формируется с помощью одномерных колоколообразных функций, равномерно распределенных по осям многомерного пространства входов. Однако расположение этих функций никак не связано с характеристиками обучающей выборки.

Цель настоящей статьи — синтез архитектуры и алгоритма обучения нейро-фаззи системы, основанной на памяти и предназначенной для решения задачи интерполяции коэффициентов отражения красок полиграфического синтеза по информации, заданной в узлах прямоугольной неравномерной решетки.

ПОСТАНОВКА ЗАДАЧИ. АРХИТЕКТУРА ИНТЕРПОЛИРУЮЩЕЙ НЕЙРО-ФАЗЗИ СИСТЕМЫ

Пусть в узлах прямоугольной неравномерной решетки (рис. 1) заданы значения функции $f(x_i, y_j)$, $i=1, 2, \dots, n$; $j=1, 2, \dots, m$, либо в виде $(m \times n)$ -матрицы $\{f(x_i, y_j)\}$, либо в виде $(mn \times 1)$ -вектора $\{f_k(x, y)\}$, $k=(j-1)n+i$. Необходимо построить кусочно-полиномиальное приближение $F(x, y)$ исходной функции, строго совпадающее в узлах x_i, y_j со значениями интерполируемой функции $F(x_i, y_j) = f(x_i, y_j)$ и не меняющее знаков производной между соседними узлами.

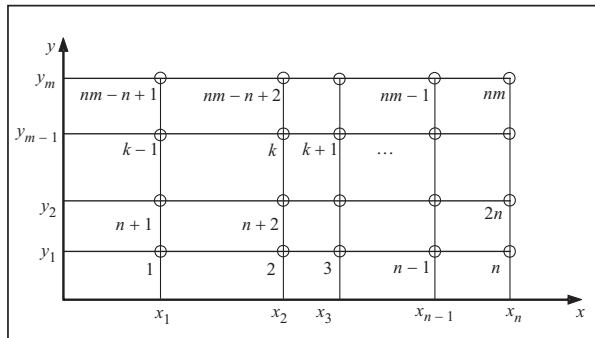


Рис. 1. Решетка исходных данных

Архитектура интерполирующей нейро-фаззи системы приведена на рис. 2. Она состоит из пяти последовательно соединенных слоев. Нулевой слой системы является рецепторным, и на него подаются преобразованные согласно соотношениям

$$\tilde{x} = \frac{x-x_1}{x_n-x_1}, \quad \tilde{y} = \frac{y-y_1}{y_m-y_1} \quad (1)$$

входные сигналы. Обратное преобразование при этом имеет вид

$$x = x_n \tilde{x} - x_1 (\tilde{x} - 1), \quad y = y_m \tilde{y} - y_1 (\tilde{y} - 1).$$

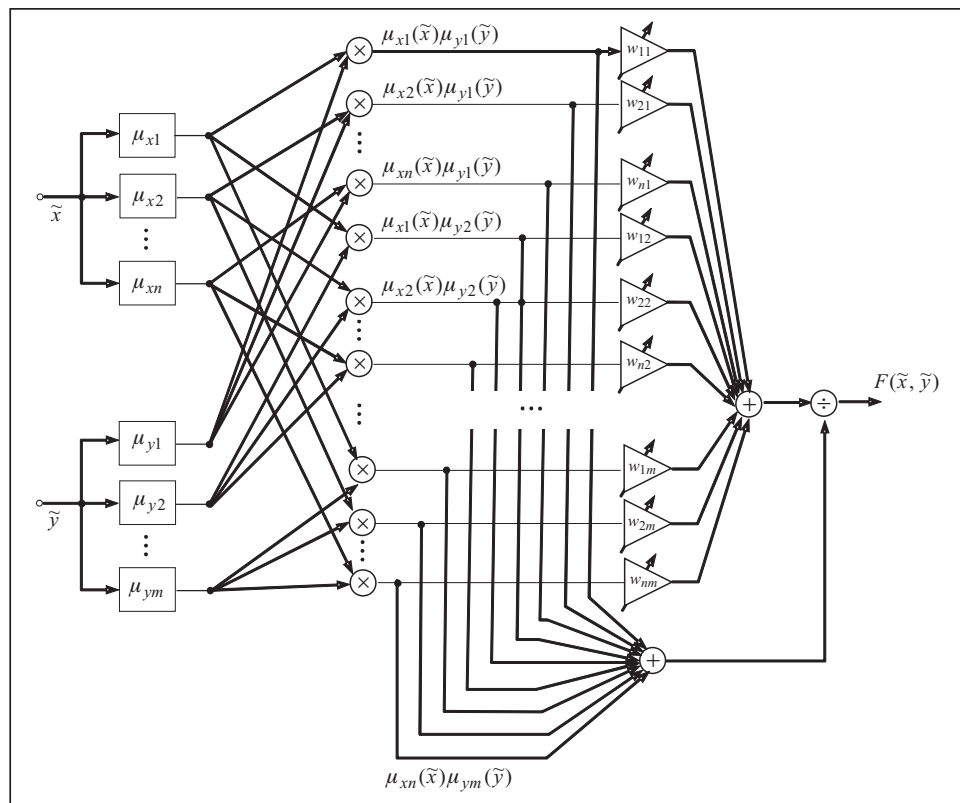


Рис. 2. Архитектура интерполирующей нейро-фаззи системы

Первый скрытый слой состоит из $n + m$ блоков, реализующих фаззи-базисные функции, и выполняет фаззификацию входных сигналов. Второй скрытый слой осуществляет агрегирование уровней принадлежности, вычисленных в первом слое, и состоит из nm блоков умножения. Третий скрытый слой — это слой синаптических весов, определяемых в процессе обучения системы. Четвертый слой образован двумя сумматорами и вычисляет суммы выходных сигналов второго и третьего слоев. И, наконец, в пятом (выходном) слое производится нормализация, в результате которой вычисляется выходной сигнал нейро-фаззи системы $F(\tilde{x}, \tilde{y})$.

Как видно, данная архитектура совпадает с архитектурой нейро-фаззи системы Ванга–Менделя [20] с решетчатым разбиением пространства входов, являющейся, в свою очередь, модификацией системы нечеткого вывода Такаги–Сугено [21] нулевого порядка. Однако если указанные системы обучаются с помощью тех или иных процедур оптимизации, рассматриваемая интерполирующая нейро-фаззи система настраивается по принципу «нейроны в точках данных».

ОБУЧЕНИЕ ИНТЕРПОЛИРУЮЩЕЙ НЕЙРО-ФАЗЗИ СИСТЕМЫ

Поскольку рассматриваемая система относится к сетям, основанным на памяти, ее настройка производится с помощью одного прохода процедуры обучения, что делает ее достаточно простой и быстрой.




Рис. 3. Фаззи-базисные функции принадлежности

Предварительно преобразованные на единичный квадрат с помощью соотношений (1) данные обучающей выборки $\{\tilde{x}_i, \tilde{y}_j\}$ формируют в первом скрытом слое

набор фаззи-базисных функций принадлежности μ_{xi}, μ_{yj} так, что их центры совпадают с точками \tilde{x}_i, \tilde{y}_j . Процесс формирования фаззи-базисных функций иллюстрируется рис. 3. Кроме треугольных фаззи-базисных функций, которые здесь приведены и имеют вид

$$\begin{aligned} \mu_{x1} &= \frac{\tilde{x}_2 - \tilde{x}}{\tilde{x}_2}, \quad \tilde{x} \in [0, \tilde{x}_2], \\ \mu_{xi} &= \begin{cases} \frac{\tilde{x} - \tilde{x}_{i-1}}{\tilde{x}_i - \tilde{x}_{i-1}}, & \tilde{x} \in [\tilde{x}_{i-1}, \tilde{x}_i], \\ \frac{\tilde{x}_{i+1} - \tilde{x}}{\tilde{x}_{i+1} - \tilde{x}_i}, & \tilde{x} \in [\tilde{x}_i, \tilde{x}_{i+1}], \quad i = 2, \dots, n-1, \end{cases} \\ \mu_{xn} &= \frac{\tilde{x} - \tilde{x}_{n-1}}{1 - \tilde{x}_{n-1}}, \quad \tilde{x} \in [\tilde{x}_{n-1}, 1], \\ \mu_{y1} &= \frac{\tilde{y}_2 - \tilde{y}}{\tilde{y}_2}, \quad \tilde{y} \in [0, \tilde{y}_2], \\ \mu_{yj} &= \begin{cases} \frac{\tilde{y} - \tilde{y}_{j-1}}{\tilde{y}_j - \tilde{y}_{j-1}}, & \tilde{y} \in [\tilde{y}_{j-1}, \tilde{y}_j], \\ \frac{\tilde{y}_{j+1} - \tilde{y}}{\tilde{y}_{j+1} - \tilde{y}_j}, & \tilde{y} \in [\tilde{y}_j, \tilde{y}_{j+1}], \quad j = 2, \dots, m-1, \end{cases} \\ \mu_{ym} &= \frac{\tilde{y} - \tilde{y}_{m-1}}{1 - \tilde{y}_{m-1}}, \quad \tilde{y} \in [\tilde{y}_{m-1}, 1], \end{aligned}$$

для придания большей гладкости интерполирующей поверхности могут быть использованы кубические сплайны вида

$$\begin{aligned} \mu_{x1} &= 0,25 \left(2 - 3 \frac{2\tilde{x} - \tilde{x}_2}{\tilde{x}_2} + \left(\frac{2\tilde{x} - \tilde{x}_2}{\tilde{x}_2} \right)^3 \right), \quad \tilde{x} \in [0, \tilde{x}_2], \\ \mu_{xi} &= \begin{cases} 0,25 \left(2 + 3 \frac{2\tilde{x} - \tilde{x}_i - \tilde{x}_{i-1}}{\tilde{x}_i - \tilde{x}_{i-1}} - \left(\frac{2\tilde{x} - \tilde{x}_i - \tilde{x}_{i-1}}{\tilde{x}_i - \tilde{x}_{i-1}} \right)^3 \right), & \tilde{x} \in [\tilde{x}_{i-1}, \tilde{x}_i], \\ 0,25 \left(2 - 3 \frac{2\tilde{x} - \tilde{x}_{i+1} - \tilde{x}_i}{\tilde{x}_{i+1} - \tilde{x}_i} + \left(\frac{2\tilde{x} - \tilde{x}_{i+1} - \tilde{x}_i}{\tilde{x}_{i+1} - \tilde{x}_i} \right)^3 \right), & \tilde{x} \in [\tilde{x}_i, \tilde{x}_{i+1}], \quad i = 2, \dots, n-1, \end{cases} \\ \mu_{xn} &= 0,25 \left(2 + 3 \frac{2\tilde{x} - 1 - \tilde{x}_{n-1}}{1 - \tilde{x}_{n-1}} - \left(\frac{2\tilde{x} - 1 - \tilde{x}_{n-1}}{1 - \tilde{x}_{n-1}} \right)^3 \right), \quad \tilde{x} \in [\tilde{x}_{n-1}, 1], \\ \mu_{y1} &= 0,25 \left(2 - 3 \frac{2\tilde{y} - \tilde{y}_2}{\tilde{y}_2} + \left(\frac{2\tilde{y} - \tilde{y}_2}{\tilde{y}_2} \right)^3 \right), \quad \tilde{y} \in [0, \tilde{y}_2], \end{aligned}$$

$$\mu_{yj} = \begin{cases} 0,25 \left(2 + 3 \frac{2\tilde{y} - \tilde{y}_j - \tilde{y}_{j-1}}{\tilde{y}_j - \tilde{y}_{j-1}} - \left(\frac{2\tilde{y} - \tilde{y}_j - \tilde{y}_{j-1}}{\tilde{y}_j - \tilde{y}_{j-1}} \right)^3 \right), & \tilde{y} \in [\tilde{y}_{j-1}, \tilde{y}_j], \\ 0,25 \left(2 - 3 \frac{2\tilde{y} - \tilde{y}_{j+1} - \tilde{y}_j}{\tilde{y}_{j+1} - \tilde{y}_j} + \left(\frac{2\tilde{y} - \tilde{y}_{j+1} - \tilde{y}_j}{\tilde{y}_{j+1} - \tilde{y}_j} \right)^3 \right), & \tilde{y} \in [\tilde{y}_j, \tilde{y}_{j+1}], i=2, \dots, m-1, \end{cases}$$

$$\mu_{ym} = 0,25 \left(2 + 3 \frac{2\tilde{y} - 1 - \tilde{y}_{m-1}}{1 - \tilde{y}_{m-1}} - \left(\frac{2\tilde{y} - 1 - \tilde{y}_{m-1}}{1 - \tilde{y}_{m-1}} \right)^3 \right), \tilde{y} \in [\tilde{y}_{m-1}, 1].$$

Заметим, что такие функции принадлежности обеспечивают единичное разбиение Руспини, т.е. выполнение условия

$$\sum_{i=1}^n \mu_{xi}(\tilde{x}) = 1; \sum_{j=1}^m \mu_{yj}(\tilde{y}) = 1, \quad (2)$$

что, как будет показано ниже, существенно упрощает процесс обучения.

Одновременно с формированием фаззи-базисных функций первого скрытого слоя в третьем слое происходит установка синаптических весов w_{ij} , которые полагаются равными значениям интерполируемой функции $f(x_i, y_j)$.

Таким образом, при подаче на вход системы произвольного сигнала \tilde{x}, \tilde{y} в первом скрытом слое вычисляются уровни принадлежности $\mu_{xi}(\tilde{x}), \mu_{yj}(\tilde{y})$, $i=1, 2, \dots, n; j=1, 2, \dots, m$, во втором слое производится их агрегирование путем формирования двумерных фаззи-базисных функций

$$\mu_{ij}(\tilde{x}, \tilde{y}) = \mu_{xi}(\tilde{x}) \mu_{yj}(\tilde{y}).$$

В третьем слое вычисляются произведения $f(x_i, y_j) \mu_{ij}(\tilde{x}, \tilde{y})$, четвертый слой определяет значения сигналов

$$\sum_{i=1}^n \sum_{j=1}^m f(x_i, y_j) \mu_{xi}(\tilde{x}) \mu_{yj}(\tilde{y}) = \sum_{i=1}^n \sum_{j=1}^m w_{ij} \mu_{ij}(\tilde{x}, \tilde{y}),$$

$$\sum_{i=1}^n \sum_{j=1}^m \mu_{xi}(\tilde{x}) \mu_{yj}(\tilde{y}) = \sum_{i=1}^n \sum_{j=1}^m \mu_{ij}(\tilde{x}, \tilde{y}),$$

и, наконец, в выходном слое формируется интерполирующий сигнал

$$F(\tilde{x}, \tilde{y}) = \frac{\sum_{i=1}^n \sum_{j=1}^m f(x_i, y_j) \mu_{xi}(\tilde{x}) \mu_{yj}(\tilde{y})}{\sum_{i=1}^n \sum_{j=1}^m \mu_{xi}(\tilde{x}) \mu_{yj}(\tilde{y})} = \frac{\sum_{i=1}^n \sum_{j=1}^m w_{ij} \mu_{ij}(\tilde{x}, \tilde{y})}{\sum_{i=1}^n \sum_{j=1}^m \mu_{ij}(\tilde{x}, \tilde{y})}.$$

Покажем, что введенная архитектура и процедура обучения действительно решают задачу интерполяции двумерной функции $f(x, y)$. Для этого перейдем от матричного двухиндексного представления к одноиндексному векторному описанию, заменяя пару i, j индексом $k=1, 2, \dots, (j-1)n+i, \dots, nm$, а пару \tilde{x}_i, \tilde{y}_j — скаляром \tilde{z}_k . Тогда можно записать

$$\mu_{ij}(\tilde{x}, \tilde{y}) \equiv \mu_k(\tilde{x}, \tilde{y}), \quad w_{ij} \equiv w_k, \quad f(\tilde{x}_i, \tilde{y}_j) \equiv f_k(\tilde{x}, \tilde{y}),$$

$$F(\tilde{x}, \tilde{y}) = \frac{\sum_{k=1}^{nm} w_k \mu_k(\tilde{x}, \tilde{y})}{\sum_{k=1}^{nm} \mu_k(\tilde{x}, \tilde{y})},$$

при этом будем полагать, что синаптические веса w_k неизвестны. При подаче на вход системы сигнала \tilde{z}_k из обучающей выборки сигналы на выходе второго скрытого слоя могут быть представлены в векторной форме $\boldsymbol{\mu}(k) = (\mu_1(\tilde{z}_k), \mu_2(\tilde{z}_k), \dots, \mu_k(\tilde{z}_k), \dots, \mu_{nm}(\tilde{z}_k))^T$, а выходной сигнал системы — в виде

$$F(\tilde{z}_k) = \frac{\mathbf{w}^T \boldsymbol{\mu}(k)}{\mathbf{I}^T \boldsymbol{\mu}(k)},$$

где \mathbf{w} — $(nm \times 1)$ -вектор синаптических весов, \mathbf{I} — $(nm \times 1)$ -вектор-столбец, составленный из единиц.

Условия интерполяции задаются системой nm уравнений вида

$$\begin{cases} f_1(\tilde{z}_1) = \frac{w^T \boldsymbol{\mu}(1)}{I^T \boldsymbol{\mu}(1)}, \\ f_2(\tilde{z}_2) = \frac{w^T \boldsymbol{\mu}(2)}{I^T \boldsymbol{\mu}(2)}, \\ \vdots \\ f_{nm}(\tilde{z}_{nm}) = \frac{w^T \boldsymbol{\mu}(nm)}{I^T \boldsymbol{\mu}(nm)} \end{cases}$$

или в матричной форме

$$\mathbf{f}(\tilde{\mathbf{z}}) = \boldsymbol{\mu} \mathbf{w}, \quad (3)$$

где $\mathbf{f}(\tilde{\mathbf{z}}) = (f_1(\tilde{z}_1), f_2(\tilde{z}_2), \dots, f_k(\tilde{z}_k), \dots, f_{nm}(\tilde{z}_{nm}))^T$, $\boldsymbol{\mu} = \left(\frac{\mu(1)}{I^T \boldsymbol{\mu}(1)}, \frac{\mu(2)}{I^T \boldsymbol{\mu}(2)}, \dots, \frac{\mu(k)}{I^T \boldsymbol{\mu}(k)}, \dots, \frac{\mu(nm)}{I^T \boldsymbol{\mu}(nm)} \right)^T$ является $(nm \times nm)$ -матрицей.

Поскольку решение системы (3) имеет вид

$$\mathbf{w} = \boldsymbol{\mu}^{-1} \mathbf{f}(\tilde{\mathbf{z}}),$$

а матрица $\boldsymbol{\mu}$ в силу (2) является единичной, то очевидно, что

$$\mathbf{w} = \mathbf{f}(\tilde{\mathbf{z}}),$$

т.е. рассмотренная нейро-фаззи система действительно является интерполирующей.

РЕЗУЛЬТАТЫ ЭКСПЕРИМЕНТАЛЬНОГО ИССЛЕДОВАНИЯ

Для исследования интерполирующих свойств нейро-фаззи системы были использованы результаты спектрофотометрических измерений коэффициента отражения полиграфической контрольной шкалы. Эта шкала содержит четыре ряда полей, отпечатанных четырьмя красками синтеза, каждое поле запечатано рас-

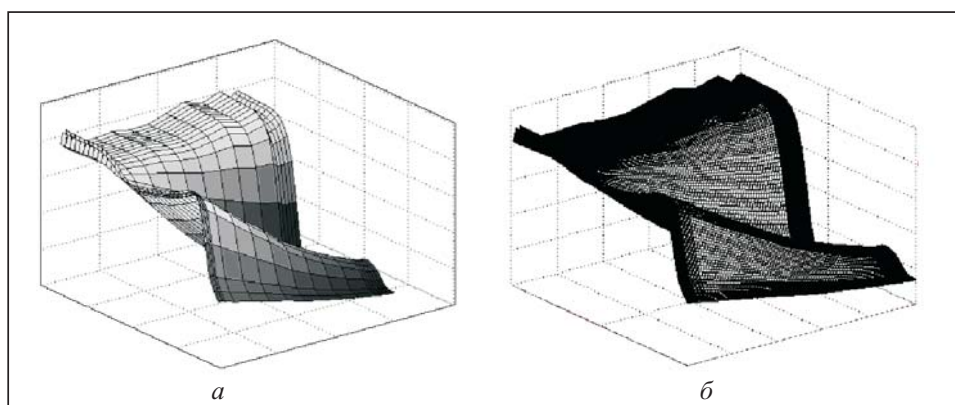


Рис. 4. Спектральная характеристика пурпурной краски: *а* — исходные данные; *б* — поверхность, интерполированная с помощью нейро-фаззи системы

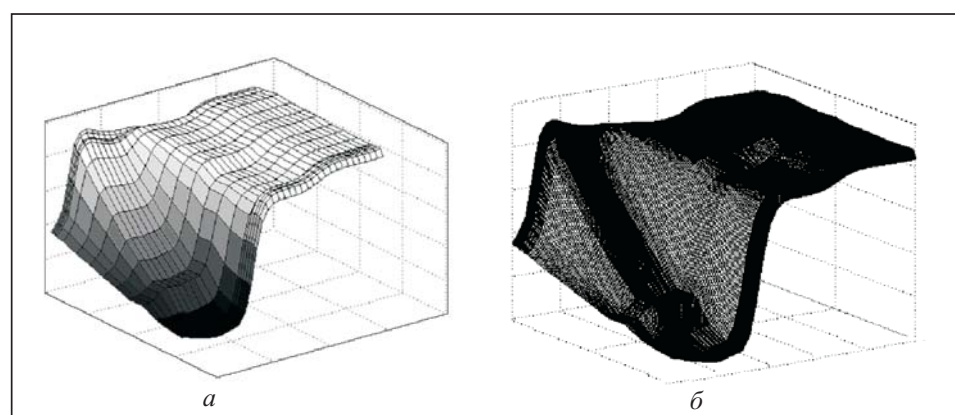


Рис. 5. Спектральная характеристика желтой краски: *а* — исходные данные; *б* — поверхность, интерполированная с помощью нейро-фаззи системы

тровыми точками разных размеров — от 1 до 100 % заполнения относительной площади ячейки. Полям соответствуют следующие значения (в процентах) относительной запечатанной площади: 1, 2, 3, 4, 5, 10, 20, 30, 40, 50, 60, 70, 80, 90, 92, 94, 96, 98, 100. Измерения проводятся спектрофотометром Eye-One автоматически в видимом диапазоне излучений, что соответствует длинам волн от 380 до 730 нм. Этот диапазон разбит на интервалы по 10 нм. Таким образом, решетка интерполяции является прямоугольной, но неравномерной относительно одной оси.

На рис. 4, 5 приведены исходные спектральные коэффициенты отражения двух красок полиграфического синтеза и восстановленные с помощью нейро-фаззи системы. Точность интерполяции при этом определяется на уровне $3 \cdot 10^{-12} - 8 \cdot 10^{-12}$, что является удовлетворительным для решения практических задач. При интерполировании была выбрана более густая решетка узловых точек для оценивания характера восстановленной поверхности в промежутках между исходными узловыми точками.

Таким образом, предложенные архитектура и алгоритм обучения нейро-фаззи системы решают задачу интерполяции коэффициентов отражения красок полиграфического синтеза для наилучшей передачи цвета при печати. Система обеспечивает высокое качество интерполяции, крайне проста в реализации, характеризуется вычислительной простотой, а ее обучение сводится к одноразовой установке синаптических весов.

СПИСОК ЛИТЕРАТУРЫ

1. Moody J., Darken C.J. Fast learning in networks of locally-tuned processing units // *Neural Computation*. — 1989. — **1**. — P. 281–294.
2. Park J., Sandberg I.W. Universal approximation using radial-basis-function networks // *Ibid.* — 1991. — **3**. — P. 246–257.
3. Schilling R.J., Carrol J.J., Al-Ajlouni A.F. Approximation of non-linear systems with radial basis function neural networks // *IEEE Trans. on Neural Networks*. — 2001. — **12**. — P. 1–15.
4. Bishop C.M. *Neural networks for pattern recognition*. — Oxford: Clarendon Press, 1995. — 482 p.
5. Бодянский Е.В., Руденко О.Г. *Искусственные нейронные сети: архитектуры, обучение, применение*. — Харьков: ТЕЛЕТЕХ, 2004. — 372 с.
6. Кулишова Н.Е. Интерполяция коэффициентов отражения красок с помощью радиально-базисной искусственной нейронной сети // *Бионика интеллекта*. — 2006. — № 1 (64). — С. 105–109.
7. Specht D. A general regression neural network // *IEEE Trans. on Neural Networks*. — 1991. — **2**. — P. 568–576.
8. Parzen E. On the estimation of a probability density function and the mode // *Ann. Math. Statist.* — 1962. — **38**. — P. 1065–1076.
9. Надарая Э.А. О непараметрических оценках плотности вероятности и регрессии // *Теория вероятностей и ее применение*. — 1965. — **10**, № 1. — С. 199–203.
10. Friedman J., Hastie J., Tibshirani R. *The elements of statistical learning. Data mining, inference, and prediction*. — Berlin: Springer, 2003. — 552 p.
11. Живоглядов В.П., Медведев А.В. *Непараметрические алгоритмы адаптации*. — Фрунзе: Илим, 1974. — 135 с.
12. Nelles O. *Nonlinear system identification*. — Berlin: Springer, 2001. — 785 p.
13. Pattern recognition using radial basis function network / D.R. Zahirniak, R. Chapman, S.K. Rogers, B.W. Suter, M. Kabrisky, V. Pyati // *Proc. 6-th Ann. Aerospace Application of AI Conf.* — Dayton, OH, 1990. — P. 249–260.
14. Jang J.-S.R., Sun C.-T., Mizutani E. Neuro-fuzzy modeling and control // *Proc. IEEE*. — 1995. — **83**. — P. 378–406.
15. Jang J.-S.R., Sun C.-T., Mizutani E. *Neuro-fuzzy and soft computing*. — Upper Saddle River, NJ: Prentice Hall, 1997. — 614 p.
16. Cios K.J., Pedrycz W. Neuro-fuzzy algorithms / *Handbook on Neural Computation*. — Oxford: IOP Publishing and Oxford University Press, 1997. — D1.3:1–D1.3:7.
17. Jang J.-S.R. ANFIS: Adaptive-network-based fuzzy inference system // *IEEE Trans. on Systems, Man and Cybernetics*. — 1993. — **23**. — P. 665–685.
18. Brown M., Harris C.J. *Neural networks for modeling and control* / Ed. by C.J. Harris «Advances in Intellectual Control». — London: Taylor and Francis, 1994. — P. 17–55.
19. Wang H., Liu G.P., Harris C.J., Brown M. *Advanced adaptive control*. — Oxford: Pergamon, 1995. — 262 p.
20. Wang L., Mendel J.M. Fuzzy basis functions, universal approximation and orthogonal least squares learning // *IEEE Trans. on Neural Networks*. — 1992. — **3**. — P. 807–814.
21. Takagi T., Sugeno M. Fuzzy identification of systems and its application to modeling and control // *IEEE Trans. on Systems, Man and Cybernetics*. — 1985. — **15**. — P. 116–132.

Поступила 18.06.2007