

СИСТЕМА РАСПОЗНАВАНИЯ ОБРАЗОВ НА БАЗЕ НЕЧЕТКОГО НЕЙРОННОГО КЛАССИФИКАТОРА

Полторак В.П., Дорогой Я.Ю.

Введение в проблему

Теория нечетких множеств оперирует качественными понятиями, что характерно для человека, вместе с тем она дает им количественную оценку, что характерно для ЭВМ. Таким образом, в ней объединяются достоинства человеческого оперирования знаниями и вычислительная мощность ЭВМ. Нечеткая логика, которая служит основой для реализации методов нечеткого управления, более естественно описывает характер человеческого мышления и ход его рассуждений, чем традиционные формальнологические системы. Именно поэтому использование математических средств для представления нечеткой исходной информации позволяет строить модели, которые наиболее адекватно отражают различные аспекты неопределенности, постоянно присутствующей в окружающей нас реальности. Однако при всем своем потенциале теория нечетких множеств не была способна решать практические задачи, а существовала действительно всего лишь как теория. Ситуация изменилась в последние 5-10 лет и это связано с появлением прикладных реализаций для решения интеллектуальных задач с использованием теории нечетких множеств [1].

В статье [2] основоположник теории нечетких множеств Лотфи Заде отмечает тот факт, что появились системы, способные решать такие задачи, как распознавание образов, распознавание речи, распознавание рукописных символов, распознавание голоса, т.е. те задачи, решение которых с помощью компьютерной техники до недавнего времени считалось научной фикцией. На сегодняшний день интеллектуальные компьютерные системы способны идентифицировать отпечатки пальцев, лицевые характеристики, геометрию руки и т.п.

Следует также отметить, что при решении задач с использованием аппарата нечеткой логики аксиомы вводятся по ходу решения задачи и формируются, главным образом, из эмпирических знаний человека.

1. Анализ проблемы и существующих решений

Задача классификации данных (основная задача теории распознавания) в настоящее время является одной из наиболее актуальных сфер приложения систем искусственного интеллекта. Для ее решения было предложено различных подходов и направлений, среди которых наибольшую популярность приобрели решения, сочетающие нейронные сети и нечеткие системы логического вывода. Одним из таких решений является система NEFCLASS (NEuro-Fuzzy CLASSifier) [3, 4, 5], основанная на обобщенной архитектуре нечеткого персептрона. Данная система обладает рядом несомненных достоинств, выделяющих ее среди остальных. Среди наиболее важных следует упомянуть простоту реализации, высокую скорость работы алгоритмов обучения, а также, что является наиболее важным, высокую точность классификации данных - на уровне лучших систем в данной области. Вместе с тем базовая система NEFCLASS имеет ряд недостатков - используемые формулы для обучения параметров носят эмпирический характер, кроме того, неясно, как выбирать в алгоритме обучения параметр скорости обучения a . Цель данной работы – создать альтернативную модель нечеткой нейронной системы.

2. Предлагаемый подход

2.1 Нечеткая фильтрация изображения

Система, выполняющая нечеткую обработку, обладает двумя основными особенностями: во-первых, нечеткий фильтр вычисляет нечеткое приращение таким образом, чтобы оно было менее чувствительно к локальным изменениям структур изображения, таким

как границы объектов; во-вторых, функция принадлежности формируется так, чтобы адаптироваться к шумовым составляющим для выполнения нечеткого сглаживания (предполагается, что шум равномерно распределен по всему изображению). Основная идея нечеткого фильтра состоит в следующем: значение пикселя определяется в зависимости от значений окружающих соседних пикселей. Фильтр должен обеспечивать высокую степень различения между шумом и структурными объектами изображения. Чтобы решить данную задачу для каждого пикселя вычисляется оценочная степень, которая характеризует то, насколько велико или мало приращение в определенном направлении. Конструирование нечеткого фильтра базируется на следующем наблюдении: *малое нечеткое приращение соответствует шуму, большое нечеткое приращение - границам объектов*. На рис.1 изображен пиксель (x,y), а также его соседние пиксели NW, N, NE, E, SE, S, SW, W, что соответствует участку изображения размерностью 3x3 пикселя.

137	94	30	NW	N	NE
72	15	47	W	(x,y)	E
254	8	92	SW	S	SE

Рис. 1 Часть участка изображения

Простое приращение центрального пикселя (x,y) в направлении D(D ∈ {NW,N,NE,E,SE,S,SW,W}) определяется как разность между пикселем с координатами (x,y) и одним из соседних пикселей в направлении D. Значение приращения обозначается ∇_D(x,y), например:

$$\nabla_N(x,y) = I(x,y-1) - I(x,y) \quad (1)$$

$$\nabla_{SW}(x,y) = I(x-1,y+1) - I(x,y) \quad (2)$$

В основу нечеткого приращения положено следующее наблюдение: если мысленно расположить границу объекта вдоль направления SW-NE через пиксель (x,y), то значение приращения ∇_{NW}(x,y) будет велико, но также будет велико и значение приращений соседних пикселей, которые перпендикулярны направлению расположения границы объекта, т.е. ∇_{NW}(x-1,y+1) и ∇_{NW}(x+1,y-1). Идея состоит в том, что *если два значения приращений из трех малые, то можно предположить, что в рассматриваемом направлении отсутствуют границы объектов*. Таким образом, чтобы определить нечеткое приращение, нужно рассмотреть его качественное понятие *малое*. Этому понятию в рамках теории нечетких множеств соответствует нечеткое множество *малое*. Функция принадлежности $m_k(u)$ понятия *малое* может определяться:

$$m_k(u) = \begin{cases} 1 - \frac{|u|}{k}, & 0 \leq |u| \leq k \\ 0, & |u| > k \end{cases} \quad (3)$$

где k - адаптивный параметр. График выражения построен на рис.2.а.

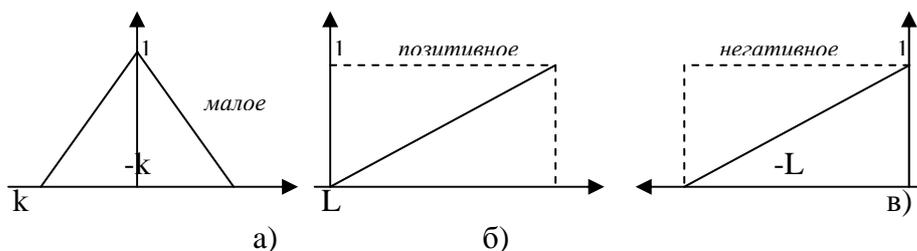


Рис. 2 Функции принадлежности качественных понятий:

а) малое;

б) позитивное;

в) негативное.

Значение нечеткого приращения для пикселя в направлении NW вычисляется при помощи следующих правил:

$$\begin{aligned} & \text{if } (\nabla_{NW}(x,y) \text{ малое}) \text{ and } (\nabla_{NW}(x-1,y+1)) \text{ малое} \\ & \text{or } (\nabla_{NW}(x,y) \text{ малое}) \text{ and } (\nabla_{NW}(x+1,y-1) \text{ малое}) \\ & \text{or } (\nabla_{NW}(x-1,y+1) \text{ малое}) \text{ and } (\nabla_{NW}(x+1,y-1) \text{ малое}) \\ & \text{then } \nabla^F NW (x,y) \text{ малое} \end{aligned} \quad (4)$$

Восемь таких нечетких правил применяются для каждого из направлений. Как уже упоминалось ранее, для того, чтобы выполнить нечеткую фильтрацию изображения необходимо устранить шумовые составляющие пикселей путем модификации значений пикселей, поэтому обозначим модификационный параметр $difX$. Для вычисления значения $difX$ используется пара нечетких правил для каждого направления. Сущность этих правил заключается в следующем: если предполагается отсутствие границ объекта в определенном направлении, то четкое значение приращения в этом направлении может быть использовано для вычисления модификационного значения $difX$. Следовательно, первая часть функционирования алгоритма фильтрации изображений - выявление границ структурных объектов, может быть реализована в виде нечеткого приращения, вторая часть алгоритма должна быть реализована в виде схемы, которая способна различать *позитивное* и *негативное* значение для нечеткого приращения:

$$\begin{aligned} \lambda_{NW}^+ : & \text{if } (\nabla^F NW (x,y) \text{ малое}) \text{ and } (\nabla_{NW}(x,y) \text{ позитивное}) \\ & \text{then } c - \text{позитивное} \\ \lambda_{NW}^- : & \text{if } (\nabla^F NW (x,y) \text{ малое}) \text{ and } (\nabla_{NW}(x,y) \text{ негативное}) \\ & \text{then } c - \text{негативное} \end{aligned} \quad (5)$$

Для описания понятий *негативное* и *позитивное* также используются нечеткие множества с функциями принадлежности (рис.2в и 2б).

Последний шаг - дефаззификация результата: необходимо определить модификационное значение $difX$, которое будет добавлено к текущему значению пикселя:

$$\Delta = \frac{L}{8} \sum_{D \in dir} (\lambda_D^+ - \lambda_D^-) \quad (6)$$

где D - обозначает направления, L - количество градаций серого.

Итак, рассмотрен первый этап, который должна выполнять система распознавания образов. Стоит заметить, что этот этап является очень важным, потому как во многом именно от качества преобразованного изображения зависит стабильная работы системы в целом. Следующий этап связан с сегментацией и выделением контуров объектов. Цель этапа - нахождение объекта на изображении.

2.2 Сегментация и выделение контуров объектов

Рассматриваемая нечеткая нейросистема сегментации изображения в работе [6] является самообучаемой. Системы, выполняющие нечеткую сегментацию (кластеризацию) обладают одним существенным недостатком: количество кластеров, как правило, задается человеком.

Описываемая система состоит из многослойного персептрона, который выполняет сегментацию изображения путем выделения адаптивных порогов, используя нечеткие метки [6]. Выход сети описывается как нечеткое множество, а нечеткая энтропия - как функция ошибки процесса сегментации.

Процесс сегментации - это процесс, при котором происходит разбиение изображения на составляющие объекты. При этом обычно используется следующее *формальное определение*: Пусть F - это обозначение сетки всех пикселей изображения, т.е. набор всех пар: $F_{M \times N} = \{(i,j) : i = 1,2, \dots, N; j = 1,2, \dots, M\}$. При этом $\bigcup_{i=1}^n F_i = F, F_i \cap F_j = 0, i \neq j$.

Фаззификация входного изображения выполняется с использованием значений пикселей. Так изображение в шкале серого может рассматриваться как нечеткое разделение на определенные наборы или классы качественных понятий, как показано на рис.3.

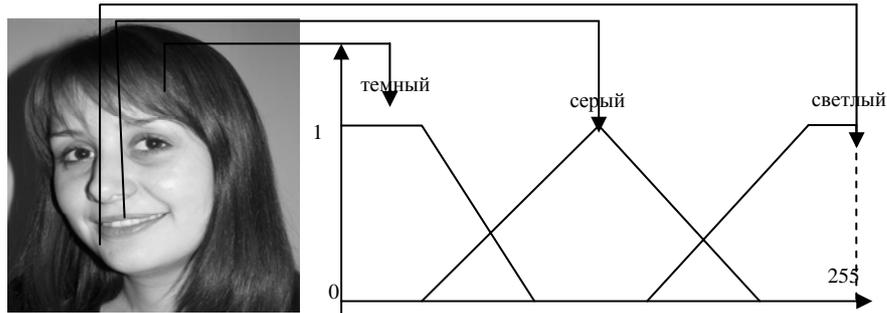


Рис. 3 Функции принадлежности, базируемые на пиксельных значениях

Как уже отмечалось, система сегментации состоит из многослойного персептрона, который выполняет адаптивную многоуровневую сегментацию, используя метки, полученные с помощью метода нечеткой кластеризации. Используется обучение без учителя, т.е. сеть учится находить признаки классового обобщения во входной информации. Выход нейронной сети описывается нечетким распределением, в то время как нечеткая энтропия выступает в качестве меры ошибки. Описание рационально рассматривать с позиции этапов функционирования системы:

- *формирование гистограммы входного изображения.* Данный этап выполняет подсчет количества пикселей с определенными интенсивностями.

- *применение FCM алгоритма.* Используется для нахождения нечетких меток [7].

- *кластерная валидация.* Здесь основным элементом выступает самоорганизующая нейронная сеть. На вход нейронной сети поступает нормализованная информация в диапазоне [0,1], которая пропорциональна величине интенсивности пикселя. Выходы каждого нейрона имеют значение в диапазоне [0,1]. При обучении на каждой итерации вычисляется ошибка, которая используется для обновления весов. Обучение продолжается до тех пор, пока не будет достигнута минимальная ошибка, или не будет достигнута максимальная итерация обучения. Выходом системы на данном этапе будет набор сегментированных изображений, т.е. сегменты изображения лица (для нас важным сегментом является только сегмент глаз).

- *определение функции ошибки.* Цель этого этапа - обеспечить определение целевой функции ошибки. В начале происходит фаззификация входного изображения, а затем функция ошибки вычисляется путем определения распределения уровня каждого серого оттенка по отношению к нечеткой энтропии.

- *адаптивное выделение порогов.* Этот этап состоит из самой системы выделения порогов, блока вычисления нечеткой энтропии, а также алгоритма обучения/корректировки. Адаптивное выделение порогов основано на самоорганизующейся нейронной сети. Сеть состоит из входного слоя, скрытого и выходного слоев. Каждый слой состоит из $M \times N$ нейронов, каждый нейрон соответствует пикселю изображения, причем каждый нейрон слоя соединен только с соответствующим нейроном предыдущего слоя, а также с нейронами со степенью соседства d . Между нейронами одного и того же слоя связь отсутствует. Веса нейронной сети не могут быть инициализированы случайным числом, все они устанавливаются в 1. Для того, чтобы обеспечить более двух стабильных состояний на выходе нейрона разработана специальная функция активации. Эта функция состоит из набора сигмоподобных функций с множественными уровнями. Мульти-сигмоида образуется путем суперпозиций сдвинутых сигмоидальных функций. Она выражается следующим образом:

$$f(x) = \sum_k \left(\frac{y_k - y_{k-1}}{1 + e^{-(x - \theta_k) / \theta_0}} + y_{k-1} \right) \cdot [u(x - y_{k-1} \cdot d^a) - u(x - y_k \cdot d^a)], \quad (7)$$

где u – шаговая функция, θ_k – пороги, y_k – целевой уровень каждой сигмоиды, θ_0 – параметр крутизны, d – степень соседства, a – параметр активности соседства. Пороги и целевые величины выводятся из функции ошибки. Так как диапазон значений состояния нейронов входного слоя зависит от количества нейронов последующего слоя, то значения порогов адаптированы таким образом, чтобы отображать эту зависимость. Функция ошибки, обозначенная на первом этапе, вычисляется для определения значения выхода на каждой эпохе обучения.

- *дефаззификация.* Нейронная сеть работает с интенсивностями пикселей, а не с нечеткими значениями функции принадлежности, как это следовало бы понимать из описания нейронной сети. Другими словами сеть не изменяет значения нечеткой принадлежности пикселей для того, чтобы уменьшить ошибку, а вместо этого она отображает первоначальные значения пикселей на такие значения, которые уменьшают среднее количество нечеткости в соответствии с первоначальным распределением. Таким образом, выход нейронной сети первоначально рассматривается в терминах серого цвета, который далее преобразуется в нечеткость для определения ошибки. Информация о значениях принадлежности пикселей может быть полезна в дальнейшем в зависимости от назначения приложения.

2.3 Нечеткая классификация

В работе [8] представлен новый метод нечеткого распознавания 2-D объектов. Предполагается, что распознаваемый объект корректно позиционирован по отношению к координатным осям, т.е. прошел нормализацию.

Задача распознавания может быть рассмотрена так: предположим, что существует проблема распознавания C - классов объектов в 2-D пространстве. Каждый класс состоит из экземпляров, которые представляют этот класс. В начале необходимо описать экземпляры класса в виде нечеткого представления. Затем для каждого класса c , $c = 1 \dots C$ строится нечеткая модель класса c . Когда неизвестный объект (человек) u должен быть распознан, то сравнивается нечеткое представление u с каждой нечеткой моделью c путем определения меры схожести. Неизвестный объект считается распознанным в том случае, когда он принадлежит классу c наивысшей мерой схожести. Для каждого экземпляра объекта i определяется ограничивающая маска (например, минимальный прямоугольник или овал), которая параллельна координатным осям и содержит экземпляр i , что обеспечивает нормализацию. Пусть горизонтальное и вертикальное пространства обозначаются горизонтальным и вертикальным измерениями ограничивающей маски, содержащей экземпляр i соответственно. Экземпляры объекта класса моделируются путем выполнения следующих шагов:

- 1) нечеткое разделение горизонтального и вертикального пространств. Деление горизонтального и вертикального пространства на T и K интервалов ($T \neq K$) выполняется с помощью генетических алгоритмов. Значения T и K , а также размер интервалов оптимизируются таким образом, чтобы выделить те регионы объекта, которые наиболее важны для нечеткого моделирования этого же объекта. Для обоих пространств строится функция принадлежности треугольной формы для каждого интервального экстремума, который является модальным значением нечеткого множества (т.е. значение функции принадлежности в данной точке равняется единице). Каждая функция принадлежности охватывает два соседних интервала, исключением лишь являются первый и последний интервал каждого пространства, для которых функция принадлежности сугубо своя. Метка назначается для каждого нечеткого множества. Распределение точки объекта $p = (h_p, v_p)$, используемое для конструктивной модели объекта, обладает тем большим значением, чем ближе координата h_p к модальному значению нечеткого множества. Следовательно, модальные значения должны выбираться таким образом, чтобы подчеркивать важные величины точек объекта, которые определяются на основании близости координат этих точек к модальным значениям.

Поэтому количество и расположение модальных значений должно быть оптимизировано так, чтобы они действительно отображали ключевые характеристики объекта.

В офтольмогеометрическом методе [9] используется 8 характеристических точек.

Для нечеткой модели значение функции принадлежности в этих точках равна 1 (см. рис. 4).

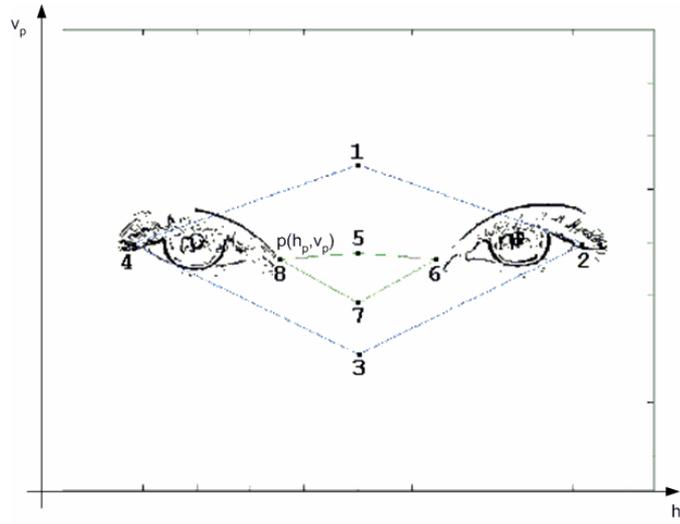


Рис. 4 Определение нечетких меток для офтольмогеометрического подхода

2) нечеткое представление. Для каждого нечеткого множества $V_k, k = 1...K+1$ ассоциируется *горизонтальное значение важности* $hv_{i,t,k}$ с каждым регионом $R_{t,k}, t = 1...T+1$:

$$hv_{i,t,k} = \frac{\sum_{p \in P_{i,t,k}} \mu_{H_t}(h_p) \mu_{V_k}(v_p)}{\sum_{p \in P_{i,t,k}} \mu_{V_k}(v_p)}, \quad (8)$$

где $P_{i,t,k}$ - это набор точек экземпляра i объекта, который содержится в $R_{t,k}$, h_p и v_p - горизонтальная и вертикальная координаты p -ой точки, μ_{H_t} и μ_{V_k} - треугольные функции принадлежности. Рациональное зерно для этого вычисления состоит в том, что распределение $hv_{i,t,k}$ точки, близкой к модальному значению горизонтального и вертикального пространств должно быть больше, чем распределение точки с меньшей степенью принадлежности. Горизонтальное значение важности $hv_{i,t,k}$ лежит в интервале $[0,1]$. Точно также для каждого нечеткого множества $H_t, t = 1...T+1$, мы ассоциируем *вертикальное значение важности* $vv_{i,t,k}$ с каждым регионом $R_{t,k}, k = 1... K+1$:

$$vv_{i,t,k} = \frac{\sum_{p \in P_{i,t,k}} \mu_{H_t}(h_p) \mu_{V_k}(v_p)}{\sum_{p \in P_{i,t,k}} \mu_{H_t}(h_p)}, \quad (9)$$

Вертикальное значение важности $vv_{i,t,k}$ лежит в интервале $[0,1]$.

Для каждого нечеткого множества V_k определяется нечеткое множество $X_{i,k} = \{hv_{i,1,k}/H_1 + \dots + hv_{i,T+1,k}/H_{T+1}\}$ в пространстве меток H_t . Горизонтальное значение важности $hv_{i,t,k}$ является степенью принадлежности к этому пространству. Аналогично для каждого нечеткого множества H_t определяется нечеткое множество $Y_{i,k} = \{vv_{i,1,k}/H_1 + \dots + vv_{i,T+1,k}/H_{T+1}\}$ в пространстве меток V_k . Вертикальное значение важности $vv_{i,t,k}$ является степенью принадлежности к этому пространству. Нечеткое представление экземпляра объекта выражается четким множеством $I_i = \{HI_i, VI_i\}$, где четкие множества $HI_i = \{X_{i,1}, \dots, X_{i,K+1}\}$ и $VI_i = \{Y_{i,1}, \dots, Y_{i,T+1}\}$ являются горизонтальным и вертикальным нечетким представлением экземпляра. Для каждого класса $c, c = 1...C$ строится нечеткая модель, называемая нечетким представлением класса. Нечеткое представление класса формируется из набора экземпляров класса (обучающего набора). Размер пространства объекта выбирается так, чтобы он соответствовал минимальной ограничивающей маске, как это следует из вышеизложенной информации. Горизонтальное и вертикальное пространства всех экземпляров делятся на T и K интервалов. Внутри каждого пространства интервалы могут иметь различный размер. Оптимальное количество и расположение интервальных экстре-

мумов в горизонтальном и вертикальном пространствах являются параметрами, зависящими от приложения.

Предположим, что для каждого класса c , обучающий набор состоит из N экземпляров. Для каждого класса c и для каждого нечеткого множества $V_k, k = 1...K+1$ горизонтальная нечеткая полоса $\bar{X}_{c,k}$ класса c определяется следующим образом:

$$\bar{X}_{c,k} = \left\{ \frac{\bar{h}v_{c,1,k}}{H_1} + \dots + \frac{\bar{h}v_{c,T+1,k}}{H_{T+1}} \right\}, \quad (10)$$

где $\bar{h}v_{c,l,k}, t = 1...T+1$ - это средняя величина горизонтального значения важности, ассоциированного с регионом $R_{t,k}$. Аналогично для каждого класса c и нечеткого множества $H_t, t = 1...K+1$ вертикальная нечеткая полоса $\bar{Y}_{c,t}$ класса c определяется следующим образом:

$$\bar{Y}_{c,t} = \left\{ \frac{\bar{v}v_{c,t,1}}{V_1} + \dots + \frac{\bar{v}v_{c,t,K+1}}{V_{K+1}} \right\}, \quad (11)$$

где $\bar{v}v_{c,t,k}, k = 1...K+1$ - средняя величина вертикального значения важности, ассоциированного с регионом $R_{t,k}$. Следовательно, нечеткое представление класса c есть четкое множество $C_c = \{HC_c, VC_c\}$, где $HC_c = \{\bar{X}_{c,1}, \dots, \bar{X}_{c,K+1}\}$ - горизонтальное нечеткое представление класса c , $VC_c = \{\bar{Y}_{c,1}, \dots, \bar{Y}_{c,T+1}\}$ - вертикальное нечеткое представление класса c .

3) Распознавание. Нечеткие представления классов C_c , построенные в фазе обучения, используются для классификации неизвестных объектов. Когда поступает неидентифицированный объект u для выполнения классификации, то вычисляется его нечеткое представление I_u . Затем I_u сравнивается с каждым нечетким представлением класса C_c для определения коэффициента схожести S_c . Для каждого класса c вычисляется коэффициент схожести $S_c(I_u, C_c)$ между нечетким представлением экземпляра I_u и нечетким представлением каждого из классов C_c :

$$S_c(I_u, C_c) = w_1 S(HI_u, HC_c) + w_2 S(VI_u, VC_c) \quad (12)$$

где $S(HI_u, HC_c)$ - коэффициент схожести между горизонтальным нечетким представлением HI_u и HC_c , $S(VI_u, VC_c)$ - коэффициент схожести между вертикальным нечетким представлением VI_u и VC_c . Веса w_1 и w_2 - числа с плавающей точкой в интервале $[0,1]$, так что $w_1 + w_2 = 1$. Коэффициенты схожести $S(HI_u, HC_c)$ и $S(VI_u, VC_c)$ являются суммой коэффициентов схожести между парами соответствующих нечетких полос в горизонтальном и вертикальном представлениях:

$$S(HI_u, HC_c) = \sum_{k=1}^{K+1} \text{weight}H_{c,k} S(X_{u,k}, \bar{X}_{c,k}) \quad (13)$$

$$S(VI_u, VC_c) = \sum_{t=1}^{T+1} \text{weight}V_{c,t} S(Y_{u,t}, \bar{Y}_{c,t}) \quad (14)$$

где веса $\text{weight}H_{c,k}$ и $\text{weight}V_{c,t} \in [0,1]$. $\sum_{k=1}^{K+1} \text{weight}H_{c,k} = 1$. $\sum_{t=1}^{T+1} \text{weight}V_{c,t} = 1$. $S(X_{u,k}, \bar{X}_{c,k})$ - коэффициент схожести горизонтальных нечетких полос $X_{u,k}, \bar{X}_{c,k}$, $S(Y_{u,t}, \bar{Y}_{c,t})$ - коэффициент схожести вертикальных нечетких полос $Y_{u,t}, \bar{Y}_{c,t}$.

Коэффициент схожести двух нечетких полос вычисляется с помощью взвешенного расстояния Евклида:

$$S(X_{u,k}, \bar{X}_{c,k}) = \sum_{t=1}^{T+1} \sqrt{(q_t (1 - |hv_{u,t,k} - \bar{h}v_{c,t,k}|))^2} \quad (15)$$

$$S(Y_{u,t}, \bar{Y}_{c,t}) = \sum_{k=1}^{K+1} \sqrt{(r_k (1 - |vv_{u,t,k} - \bar{v}v_{c,t,k}|))^2} \quad (16)$$

На каждом шаге вычисления коэффициента схожести $S_c(I_u, C_c)$ необходимо использовать определенные веса. Выбор значений для весов зависит от приложения, благодаря тому факту, что различные регионы пространства объекта могут иметь различные степени

важности, которые характеризуют этот объект. Обычно рассматривается случай, когда распределение горизонтального и вертикального представлений для коэффициента схожести имеют одинаковую важность.

Следовательно, $w_1 = w_2 = 1/2$. А. В (12) веса $weightH_{c,k}$ выбираются таким образом, чтобы придать большую степень важности горизонтальной нечеткой полосе $X_{c,k}$. Они являются мерой релевантности горизонтальной нечеткой полосы $X_{c,k}$ по отношению к другим горизонтальным нечетким полосам. Подобные рассуждения могут быть использованы для вертикальных нечетких полос. В эксперименте используется следующее выражение:

$$s_{c,k} = \frac{\sum_{n=1}^N S(X_{n,k}^c, \bar{X}_{c,k})}{\sum_{j=1}^K \sum_{n=1}^N S(X_{n,j}^c, \bar{X}_{c,j})} \quad (17)$$

где $S(X_{n,k}^c, \bar{X}_{c,k})$ - коэффициент схожести между k -тым горизонтальным нечетким представлением $X_{n,k}^c$, n -того экземпляра класса c и $X_{c,k}$. Коэффициент схожести $S(X_{n,k}^c, \bar{X}_{c,k})$ вычисляется, используя выражение (15), в котором веса q_t выбираются с учетом предыдущих коэффициентов схожести, чтобы придать большую степень важности прямоугольнику $R_{t,k}$, а именно:

$$q_t = \frac{\sum_{n=1}^N \sqrt{(1 - |hv_{n,t,k}^c - \bar{h}v_{c,t,k}|)^2}}{\sum_{j=1}^K \sum_{n=1}^N \sqrt{(1 - |hv_{n,j,k}^c - \bar{h}v_{c,j,k}|)^2}} \quad (18)$$

Классификация неизвестного объекта выполняется путем определения того класса c , который дает наибольший коэффициент схожести.

Выводы

В данной работе рассматривается процесс распознавания образов (на примере идентификации человека) с использованием математического аппарата нечеткой логики. Для построения системы распознавания объектов необходимо обеспечить как минимум три основных этапа, а именно: улучшение качества изображения путем фильтрации шумовых составляющих, сегментации или кластеризации объектов, присутствующих на изображении, и, наконец, классификации образов. Следует отметить, что результат распознавания в одинаковой степени зависит от качества каждого из этапов, причем если на предыдущем этапе был получен негативный результат, то последующие этапы только усилят эту ошибку, что в целом даст негативный результат для системы распознавания в целом.

Еще одним важным моментом, который необходимо отметить, является то, что на этапе классификации образов огромную роль играет набор входных данных для процесса классификации. Если этот набор избыточный или, наоборот, недостаточный, то это также отразится на качестве распознавания. Как правило, непосредственно перед процессом классификации выполняется процедура выделения характерных признаков во входной информации, т.е. выделение наиболее значимой информации и игнорирование малозначимой. Для выделения наиболее значимой информации можно использовать метод, описанный в [10]. Таким образом, можно сделать вывод, что теория нечетких множеств становится мощным инструментом для построения интеллектуальных аппаратно-программных систем распознавания образов.

In work application of the theory of fuzzy sets for realization of process of recognition of graphic images for human identification is considered. The basic attention is given to algorithmic features of realization of functions of recognition with use of fuzzy operations.

1. Леоненков А.В. Нечеткое моделирование в среде MATLAB и fuzzyTECH – СПб.:БХВ-Петербург, 2003. – 736 с.: ил.
2. Lotfi A. Zadeh. Foreword – Recognition Technology and Fuzzy Logic // IEEE TRANSACTION ON FUZZY SYSTEM, VOL.9, NO.1, FEBRUARY 2001.
3. Detlef Nauck and Rudolf Kruse. New learning strategies for NEFCLASS. In Proc. Seventh International Fuzzy Systems Association World Congress IFSA'97, Vol. IV, pp. 50-55, Academia Prague, 1997.
4. Detlef Nauck and Rudolf Kruse. What are neuro-fuzzy classifiers? In Proc. Seventh International Fuzzy Systems Association World Congress IFSA'97, Vol. IV, pp. 228-233, Academia Prague, 1997.
5. Detlef Nauck. Building neural fuzzy controllers with NEFCON-I. In Rudolf Kruse, Jorg Gebhardt, and Rainer Palm, editors, Fuzzy Systems in Computer Science, Artificial Intelligence, pages 141-151. Vieweg, Wiesbaden, 1994.
6. V. Boskovitz, H. Guterman. An Adaptive Neuro-Fuzzy System for Automatic Image Segmentation and Edge Detection // IEEE TRANSACTION ON FUZZY SYSTEM, VOL.10, NO.2, APRIL 2002.
7. L.O. Hall, A. Bensaid, L. Clark, R. Velthuizen, M.Silbiger, and J. Bezdek. A comparison of neural network an fuzzy clustering techniques in segmenting magnetic resonance images of the brain // IEEE TRANSACTION ON NEURAL NETWORK, VOL.3, SEPTEMBER 1992.
8. B. Lazerini, F. Marcelloni. A Fuzzy Approach to 2-D Shape Recognition // IEEE TRANSACTION ON FUZZY SYSTEM, VOL.9, NO.1, FEBRUARY 2001.
9. Я.Ю.Дорогой. Реализация офтольмогеометрического подхода к идентификации человека. //Вісник НТУУ «КПІ», «Інформатика, управління та обчислювальна техніка», №44. – 2006. – С. 240-253.
10. Я.Ю.Дорогой. Оценка значимости признаков на основе многослойных нейронных сетей в системах диагностики автотранспорта //Автомобильный транспорт, №13, 2003. – с. 52-55.