

РАСПОЗНАВАНИЕ ДИНАМИЧЕСКИХ ОБРАЗОВ РАСПРЕДЕЛЕННОЙ ИНФОРМАЦИОННО- ИЗМЕРИТЕЛЬНОЙ СИСТЕМОЙ СЕГМЕНТАРНОГО ТИПА

Ю. Н. Кульчин, А. Ю. Ким

Институт автоматики и процессов управления ДВО РАН, г. Владивосток

Предложена архитектура распределенной информационно-измерительной системы сегментарного типа, использующая нейронную сеть для распознавания динамических образов. Разработан алгоритм получения модели динамического образа с помощью преобразований матриц Ганкеля. Предложен алгоритм классификации образов в нейронной сети на основе теории нечетких множеств.

ВВЕДЕНИЕ

Расширение диапазона потенциальных применений современных информационно-измерительных систем сталкивается с необходимостью поиска новых физических, технических и технологических решений, поскольку эти системы должны быть способны обеспечить надежное и достоверное представление о контролируемом, в большинстве случаев протяженном, объекте и его состоянии в условиях неполнозаданной или априорно неизвестной среде, при наличии помех, воздействии случайных возмущений, нечеткости поступающей информации и других факторов на основе комплексного привлечения методов и технологий искусственного интеллекта.

Сфера потенциальных применений таких интеллектуальных распределенных информационно-измерительных систем (ИРИИС) охватывает широкий спектр различных прикладных задач, связанных с контролем состояния и управлением эксплуатируемых в экстремальных условиях разнообразных крупномасштабных объектов, например таких как: мосты, тоннели, высотные здания, крупные социокультурные и спортивные сооружения, нефтяные платформы, нефте- и газопроводы, самолеты, корабли, космические аппараты и др., направленных на предотвращение техногенных аварий, катастроф и борьбу с терроризмом.

Внедрение в практику ИРИИС требует создания и использования разнообразных измерительных устройств и систем, позволяющих получать в реальном времени достоверную картину о состоянии контролируемых объектов и о протекающих в них процессах и оснащения их

мощными вычислительными и программными средствами, что позволяет выполнять сложные процедуры измерений. В результате возникает необходимость создания новых подходов к самому измерительному процессу, а также к выбору измерительного оборудования. Как следствие, возникает необходимость развития новой идеологии и поиска новых системных решений при разработке и эксплуатации измерительных устройств, отвечающих современным требованиям. Поэтому, если ранее многие физические величины измерялись независимо друг от друга отдельными измерительными приборами в отдельных точках, то теперь четко обозначились тенденции их одновременного и интегрированного сравнения, установления их распределения и закономерностей взаимодействия [1, 2].

Значительный прогресс техники волоконно-оптических линий связи у нас в стране и за рубежом привел к возникновению нового направления метрологии — волоконно-оптические датчики физических величин. Сочетание развитой технологии волоконно-оптических линий связи с современными достижениями в областях опто- и микроэлектроники открывают широкие перспективы для создания разнообразных датчиков физических величин. Как показано в работах [1, 3], значительный фундаментальный и практический интерес для решения проблемы создания высокочувствительных распределенных измерительных систем (РИС) представляют волоконные измерительные интерферометры, которые способны эффективно интегрироваться с оптоэлектронными и компьютерными нейронными вычислительными сетями для обработки получаемой информации. Важной составной частью данных РИС являются распределенные волоконно-оптические измерительные



сети (РВОИС), основанные на применении волоконных интерферометров в качестве протяженных измерительных линий, позволяющие измерять определенные физические параметры контролируемых объектов. Принцип действия таких РВОИС базируется на применении томографического подхода в их структурной организации и реконструкции пространственной функции распределения измеряемых физических параметров, а также на применении нейронных сетей для обработки полученных данных [2, 4, 5]. Характеристики распространяющегося вдоль оптического волокна интерферометра излучения изменяются в зависимости от характеристик воздействующих физических полей, а сигнал на выходе измерительной линии представляет собой линейный интеграл от функции распределения исследуемого параметра физического поля [6]. Математически — это классическая томографическая задача, так как для исследуемых полей число информационных каналов меньше, чем число требуемых решений. В связи с этим для обработки поступающей от РВОИС информации и решения томографической задачи видится целесообразным применение нейронных сетей, поскольку их отличительная особенность состоит в возможности обучения и адаптации к конкретным условиям, а также высокой скорости обработки данных.

Применение ИРИИС для мониторинга состояний объектов и систем сопряжено с решением проблемы классификации поступающих данных об объектах и физических полях и автоматического принятия на их основе в режиме реального времени решения о дальнейших действиях. Для решения данной проблемы также весьма перспективны технологии, основанные на применении нейронных сетей и нечеткой логики.

Проблема восстановления и классификации образов в нейросетевом базисе описана в ряде работ [7–10]. Результаты исследований находят применение в различных отраслях науки и техники (медицине, робототехнике, географии и астрофизике), но у разработанных методов есть существенный недостаток, они основываются на статичности или квазистатичности как самих образов, так и параметров окружающей среды, что существенно ограничивает возможности их применения.

Как показали результаты исследований [1, 5–7, 9], применение РИС, в том числе и РВОИС, и нейронных сетей для обработки их сигналов при мониторинге динамических образов выдвигает ряд первоочередных проблем:

— необходимость решения чрезвычайно трудоемкой задачи обучения нейронной сети, требующей применения оптимизационных алгоритмов. В результате, в процессе обучения нейронной сети возникает задача минимизации функции ошибки рассогласования относительно большого числа (около нескольких тысяч) весовых коэффициентов матриц связи. Кроме этого, профиль многомерной поверхности минимизируемой функции в пространстве ее переменных имеет очень сложный характер и, как следствие, решение данной задачи требует длительного времени и больших вычислительных мощностей;

— поступающая от РИС информация определяется не только воздействием физического поля контролируемого объекта, но и наличием разброса параметров из-

мерительных линий, дефектов в топологии реальных протяженных РИС, накапливающихся при отклонении профиля распределения от идеального, шумами, возникающими из-за неконтролируемых воздействий со стороны окружающей среды, что приводит к ошибкам в распознавании и чрезвычайно трудно учитывается при обучении нейронной сети;

— при мониторинге динамических объектов (например, при движении объекта) неустойчивость картины данных, полученной с помощью РИС, затрудняет, а в ряде случаев делает невозможным оперативное выделение признаков, по которым его можно классифицировать.

Для решения обозначенных проблем представляется целесообразным разбить РВОИС на части и представить ее в виде большого числа одинаковых и самостоятельных измерительных сегментов (ИС) столь малой величины, чтобы разброс параметров измерительных линий и дефекты топологии всей РИС не вызывали существенного отклонения характеристик ИС друг от друга и тем самым позволяли унифицировать обучение связанных с каждым ИС нейронных сетей, значительно уменьшив само время обучения. Такой подход, при организации конвейерного принципа опроса ИС, позволяет вообще обойтись только одной вычислительной нейронной сетью, обученной на одном конкретном ИС. В этом случае процесс распознавания образа ИРИИС на основе РВОИС будет состоять из несколько стадий. Сначала по информации, полученной от ИС, осуществляют быстрый поиск представляющих интерес образов безотносительно к конкретному его местоположению (т. е. ИРИИС работает в ждущем режиме). Если интересующие нас образы будут найдены, то на следующем шаге выделяются ИС, содержащие эти образы, определяется их расположение, а также другие характеристики, позволяющие отнести их к известному классу образов.

Поэтому целью настоящей работы явилась разработка принципов построения ИРИИС сегментарного типа большой размерности, обеспечивающей при достаточно хорошем качестве распознавания образов высокую скорость обработки данных для принятия управленческих решений в реальном времени.

1. ОСНОВНЫЕ ПРИНЦИПЫ ПОСТРОЕНИЯ И ОРГАНИЗАЦИИ ИРИИС СЕГМЕНТАРНОГО ТИПА

Структура ИРИИС представляется блоками и модулями, организованными таким образом, что между ними распределены все функции, выполняемые системой в целом (рис. 1).

В процессе работы ИРИИС осуществляются следующие действия:

- через систему волоконно-оптических разветвителей модули лазерных излучателей возбуждают соответствующие измерительные линии сегментов РВОИС;
- световое излучение, выходящее из измерительных линий сети, принимают фотоприемники, а затем сигналы поступают в формирователь массива выходных сигналов и аналого-цифровой преобразователь АЦП;
- из полученных на выходе данных РВОИС, представленных в виде блочной матрицы Ганкеля, путем преобразования последней формируют блочную матри-

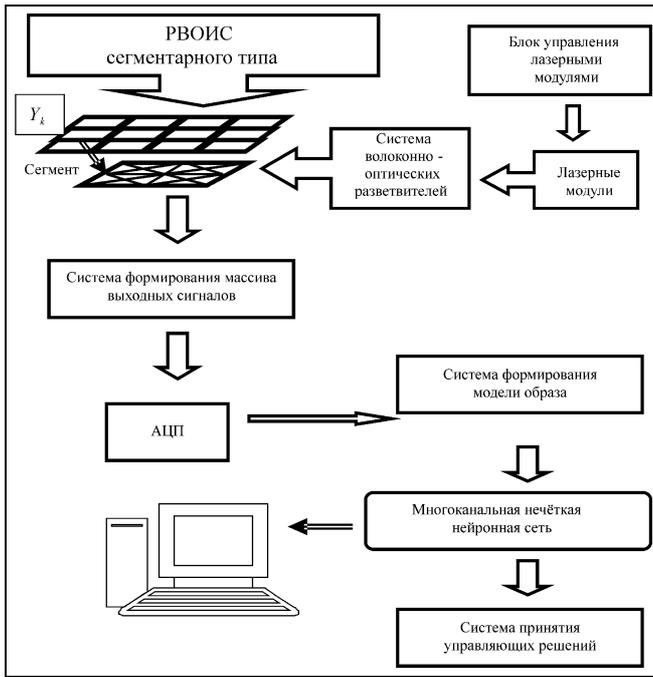


Рис. 1. Обобщенная схема ИРИИС сегментарного типа

цу коэффициентов (в дальнейшем мы ее и будем называть моделью образа — МО);

- массив данных МО подается на вход многоканальной нечеткой нейронной сети (МННС);
- с помощью МННС определяются степени принадлежности МО к заданным классам образов, что позволяет перейти к принятию управляющих решений системой.

Каждый отдельный ИС состоит из набора линий с датчиками и имеет определенную заданную конфигурацию. Сегменты РВОИС одинаковы, и каждому из них присваивается цифровой код. Как уже отмечалось, искажениями, которые создает ИС, можно пренебречь из-за их малости. Сбор информации в РВОИС происходит последовательно от сегмента к сегменту в заданной очередности и циклично. По данным опроса РВОИС формируется блочная матрица Ганкеля. Формирование матрицы Ганкеля завершается после нескольких циклов опроса РИС. Число циклов опроса зависит от порядка динамического образа, а размеры блока матрицы соответствуют числу сегментов в РВОИС. Алгоритм обработки данных ИС аналогичен для всех сегментов, поэтому после преобразования блочной матрицы Ганкеля в МО дальнейшая обработка в НС при классификации образа может быть распараллелена, а обучение МННС можно проводить на выборке данных для одного из ИС.

Таким образом, функционирование ИРИИС сегментарного типа складывается из следующих этапов.

I этап. Регистрация данных РВОИС и получение модели реального образа (МРО).

II этап. Сравнение МРО с имеющимися образами в памяти ИРИИС, определение ИС, в котором интересный образ найден, и определение степеней принадлежности данного образа к каждому из известных классов образов.

III этап. Принятие решения и, при необходимости, выработка рекомендаций для проведения дальнейшего распознавания с поиском дополнительных признаков, характеризующих образ и его поведение в сегменте.

2. АЛГОРИТМ ПОСТРОЕНИЯ МОДЕЛИ ДИНАМИЧЕСКОГО ОБРАЗА

Построение численных моделей образов — важная задача общей проблемы моделирования динамических систем. Как показывает анализ, одно из перспективных направлений решения данной проблемы заключается в развитии методов моделирования на основе матриц Ганкеля [11]. Ранее с помощью подобных матриц моделировались неизвестные структуры элементов интеллектуального робота. Построение и преобразования матрицы Ганкеля позволяют построить модели динамических образов регистрируемых и распознаваемых ИРИИС. Если РВОИС составлена из K самостоятельных эквивалентных ИС, каждый из которых содержит N измерительных линий отдельного ИС составляет T_s , то полное время опроса всей РВОИС составит $T_K = KT_s$. Таким образом, за каждый j -й цикл опроса РВОИС ($j = 1, 2, 3, \dots$) к моменту времени $t = jT_N$ от каждого k -го ИС на выходе соответствующего ему массива измерительных линий получается набор интегральных данных: y_{ij}^{kl} , где $i = 1, 2, \dots, N$, а l — номер исследуемого объекта ($l = 1, 2, \dots, L$).

Для построения матрицы Ганкеля конкретного динамического образа следует получить набор дискретных значений выходных сигналов ИС соответственно для моментов времени $j = 1, 2, \dots, 2r$. В результате образуем матрицу Ганкеля размером $r \times r$, которая для каждой i -й измерительной линии k -го ИС и исследуемого объекта с номером l имеет следующий вид:

$$H_{ij}^{kl}(y) = \begin{pmatrix} y_{i1}^{kl} & y_{i2}^{kl} & \dots & y_{ir}^{kl} \\ y_{i2}^{kl} & y_{i3}^{kl} & \dots & y_{i(r+1)}^{kl} \\ \vdots & \vdots & \dots & \vdots \\ y_{ir}^{kl} & y_{i(r+1)}^{kl} & \dots & y_{i2r}^{kl} \end{pmatrix}.$$

В случае, если порядок уравнения динамики, описывающего исследуемый динамический образ, равен n , то ранг матрицы $H_{ij}^{kl}(y)$ равен r при $r \leq n$ и равен n при всех $r \geq n + 1$ [11]. Поэтому в нашем случае число независимых строк или столбцов матрицы Ганкеля равно рангу матрицы $r = n$, что и задает необходимое число циклов измерений.

Для всей РВОИС формируется блочная матрица Ганкеля вида:

$$H_{r,r}^l = \begin{pmatrix} Y_1^l & Y_2^l & \dots & Y_r^l \\ Y_2^l & Y_3^l & \dots & Y_{r+1}^l \\ \vdots & \vdots & \dots & \vdots \\ Y_r^l & Y_{r+1}^l & \dots & Y_{2r}^l \end{pmatrix}, \quad (1)$$



$$\text{где } Y_j^l = \begin{pmatrix} y_{1j}^{1l} & y_{1j}^{2l} & \dots & y_{1j}^{Kl} \\ y_{2j}^{1l} & y_{2j}^{2l} & \dots & y_{2j}^{Kl} \\ \vdots & \vdots & \dots & \vdots \\ y_{Nj}^{1l} & y_{Nj}^{2l} & \dots & y_{Nj}^{Kl} \end{pmatrix}.$$

Наличие полученной блочной матрицы Ганкеля (1) позволяет построить обратную блочную матрицу $(H_{r,r}^l)^{-1}$.

Дальнейшая задача состоит в получении численного образа или МО для исследуемого объекта в виде матрицы коэффициентов, которая не зависит от местоположения этого объекта в пространстве. Для этого необходимо выполнить дополнительное $(2r + 1)$ измерение, получив следующий $(r + 1)$ столбец блочной матрицы Ганкеля и представив его как блочную матрицу:

$$h_r^l = \begin{pmatrix} Y_{r+1}^l \\ Y_{r+2}^l \\ \vdots \\ Y_{2r+1}^l \end{pmatrix}.$$

Далее обратная блочная матрица $(H_{r,r}^l)^{-1}$ перемножается с матрицей h_r^l . В итоге получаем МО в виде матрицы коэффициентов: $A^l = (H_{r,r}^l)^{-1} h_r^l$, которая может быть представлена следующим образом:

$$A^l = \begin{pmatrix} A_1^l \\ A_2^l \\ \vdots \\ A_r^l \end{pmatrix},$$

$$\text{где } A_q^l = \begin{pmatrix} a_{1q}^{1l} & a_{1q}^{2l} & \dots & a_{1q}^{Kl} \\ a_{2q}^{1l} & a_{2q}^{2l} & \dots & a_{2q}^{Kl} \\ \vdots & \vdots & \dots & \vdots \\ a_{Nq}^{1l} & a_{Nq}^{2l} & \dots & a_{Nq}^{Kl} \end{pmatrix} \text{ при } q = 1, 2, \dots, r.$$

Следуя описанному алгоритму, для всех интересующих нас динамических образов определяются матрицы коэффициентов, которые заносят в память ИРИИС. В процессе работы ИРИИС сравнивает МРО с теми МО, которые уже находятся в ее базе данных благодаря МННС.

3. КЛАССИФИКАЦИЯ ОБРАЗОВ МНОГОКАНАЛЬНОЙ НЕЧЕТКОЙ НЕЙРОННОЙ СЕТЬЮ

Нечеткие нейронные сети (ННС) могут быть разнобразной архитектуры и по сравнению с классическими НС они обладают большими возможностями обработки и представления информации [12, 13]. Наибольшее рас-



Рис. 2. Структурная схема классификации образов нечеткой нейронной сетью

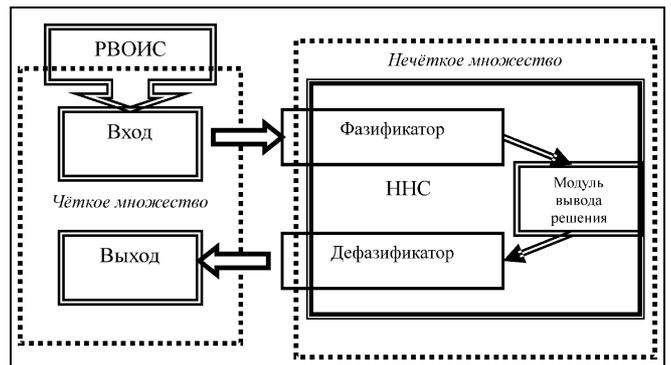


Рис. 3. Схема функционирования нечеткой нейронной сети

пространение получили ННС персептронного типа. Для системного представления многослойных ННС, как и для всей системы в целом, удобна модульная структура. Основная особенность таких сетей состоит в возможности применения нечетких правил вывода для расчета выходных данных. Структурная схема классификации образов ННС представлена на рис. 2, где ϵ_i является указанием о принадлежности текущего образа на входе ННС к тому или иному классу, а каждый класс охватывает определенное множество образов, объединенных по некоторым свойствам. Множество A_i формируется из данных ННС о принадлежности текущего образа к той или иной области пространства решений. В связи с этим рассматриваются следующие множества A_i' , A_i и E — соответственно, реальных образов, моделей образов и указаний.

Процесс получения с помощью ННС четкого значения при классификации МРО на основе известных входных значений по правилам, заложенным в базе знаний, состоит в выполнении следующих операций (рис. 3).

Фазификация известных четких переменных. Эта операция заключается в преобразовании множества входных данных в нечеткое множество. Вычисляются степени принадлежности известных переменных на основе их функции принадлежности. Благодаря этой операции происходит переход в новое пространство, в котором обрабатываются нечеткие переменные с помощью логических операций.

Нечеткий вывод на основе выбранного алгоритма. Цель этой операции — вычисление итоговой функции принадлежности.

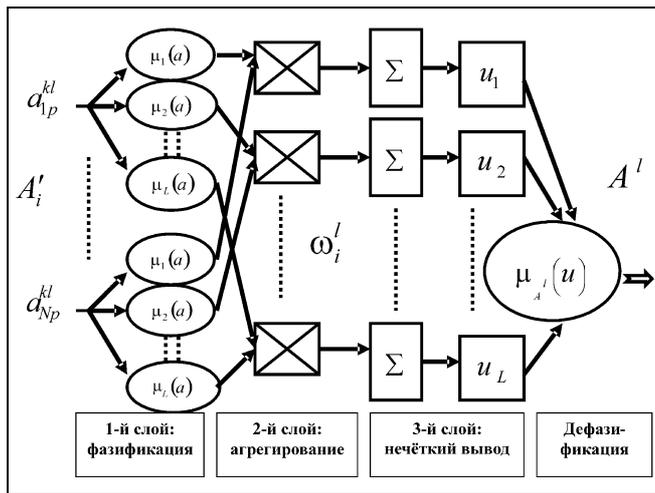


Рис. 4. Структура многослойной многоканальной нечеткой нейронной сети:

i — номер канала; ω_i^l — весовые коэффициенты; $\mu_{A^l}(u)$ — итоговая функция принадлежности элемента u к нечеткому подмножеству A^l

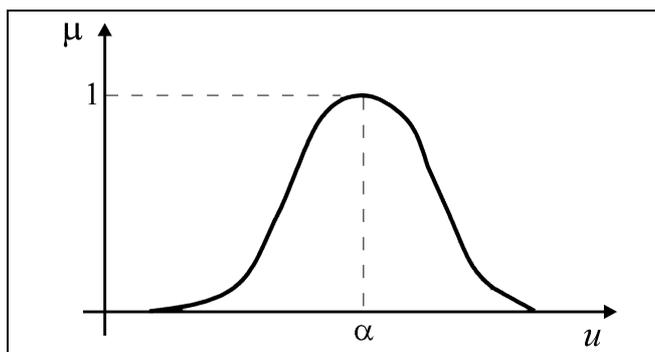


Рис. 5. Колоколообразная функция принадлежности

Известные алгоритмы нечеткого вывода различаются по видам используемых правил нечеткой импликации. Наиболее часто применяется принцип минимакса в виде алгоритмов Мамдами—Заде, Ларсена, Цукamoto и др. [14].

Дефазификация нечетких величин. Данная операция заключается в преобразовании полученной нечеткой величины в четкую. Используются обратные преобразования, переводящие ранее вычисленные нечеткие величины в исходное пространство четких переменных [14, 15].

Для выполнения анализа МО предлагаемая МННС организована по принципу квазиперсептрона: все нейроны предыдущего слоя связаны со всеми нейронами последующего слоя; нейроны одного слоя не взаимодействуют друг с другом; структура самого слоя нейронов выбирается многоканальной из-за блочного вида матрицы входных данных; вся обработка осуществляется за один проход информации от входа к выходу сети (рис. 4).

Для распознавания динамических образов в нашем случае вполне достаточно, чтобы МННС состояла из трех слоев, если не задано ограничение на число нейронов во втором слое. При этом можно реализовать разделяющую кусочно-линейную поверхность произвольной конфигурации, что важно при настройке весовых коэффициентов, так как повышает правильность распознавания образов.

В первом слое происходит раздельная фазификация каждой переменной с определением коэффициентов функции принадлежности для каждого правила. Далее выполняется агрегирование отдельных переменных a_i^{kl} , при котором получают веса правил вывода. Затем генерируется функция для расчета значения u_i для каждого правила вывода, и принимается решение по максимальному значению функции принадлежности $\mu_{A^l}(u)$. Задача синтеза МННС при заданном числе нейронов в первом и третьем слоях сводится к минимизации числа нейронов второго слоя, настройке весовых коэффициентов и коэффициентов функции принадлежности МННС.

Для классификации образов в МННС применяется теория нечетких множеств [16]. Элементы u_i , связанные с МО, принадлежат множеству U , а M является множеством принадлежностей элементов u_i к нечеткому подмножеству образов A^l (классу образов), $\mu_{A^l}(u) : U \rightarrow M$.

Нечетким подмножеством A^l множества U называют график отображения $\mu_{A^l}(u)$, т. е. множество вида $\{(u, \mu_{A^l}(u)) : u \in U\}$. Таким образом, нечеткое подмножество A^l задается тройкой $\langle U, M, \mu_{A^l} \rangle$.

Вид функции принадлежности задает правило, по которому относят элементы u_i и связанные с ними образы к множеству A^l (некоторому классу образов). В качестве функции принадлежности в МННС используют обобщенную гауссовскую функцию (модель Мамдами—Заде), общий вид которой показан на рис. 5. Для каждого правила вывода МННС регулируют параметры этой функции:

$$\mu(u) = \exp\left[-\left(\frac{u-\alpha}{\sigma}\right)^{2\beta}\right],$$

где α — центр нечеткого множества, σ — коэффициент широты (чем меньше его значение, тем больше крутизна функции), а параметр β влияет на форму кривой.

При уменьшении коэффициента σ кривая равномерно «стягивается» к вертикальной оси симметрии при сохранении общей формы самой кривой, а при уменьшении параметра β форма кривой меняется от трапециевидальной через треугольную к пикообразной.

Цель МННС, как и классической НС, состоит в достижении путем обучения соответствия ожидаемого значения получаемому на ее выходе. Обучение в нашем случае целесообразно осуществлять с учителем. При обучении с учителем минимизируется целевая функция рассогласования между требуемым значением и получаемым [17].



ЗАКЛЮЧЕНИЕ

Представлена архитектура интеллектуальной распределенной информационно-измерительной системы сегментарного типа и многоканальная нечеткая нейронная сеть для распознавания динамических образов.

Алгоритм преобразования матриц Ганкеля позволяет получить модель образа для распознавания в таком виде, что уравнение динамики образа отображается с помощью таких преобразований в коэффициенты матрицы, которые не меняются до тех пор, пока поведение и характеристики самого регистрируемого объекта остаются неизменными.

Интеллектуальные распределенные информационно-измерительные системы могут найти широкое применение в качестве экспертных систем и систем управления в чрезвычайных ситуациях.

ЛИТЕРАТУРА

1. Кульчин Ю. Н., Витрик О. Б., Урываев К. П. Распределенные адаптивные оптоэлектронные информационно-измерительные системы // Вестник ДВО РАН. — 2005. — № 6 — С. 66—76.
2. Восстановление векторных физических полей с использованием двухмерной волоконно-оптической сети / Ю. Н. Кульчин, О. Б. Витрик, О. Т. Каменев, Р. В. Ромашко // Измерительная техника. — 1999. — № 6 — С. 21—28.
3. Метод обработки сигналов двухмодового волоконного интерферометра / Ю. Н. Кульчин, О. Б. Витрик, О. В. Кириченко и др. // Автометрия. — 1995. — № 5 — С. 32—35.
4. Томографические методы для исследования векторных полей при помощи волоконно-измерительных систем / Ю. Н. Кульчин, О. Б. Витрик, Р. В. Ромашко и др. // Квантовая электроника. — 1997. — Т. 24, № 5. — С. 467—470.
5. Кульчин Ю. Н., Денисов И. В., Каменев О. Т. Оптоэлектронная нейроподобная система обработки выходных данных волоконно-оптической измерительной сети // Письма в ЖТФ. — 1999. — Т. 25, вып. 6. — С. 65—69.
6. Многомерная обработка сигналов с использованием волоконно-оптической измерительной сети / Ю. Н. Кульчин, О. Б. Витрик, О. В. Кириченко, Ю. С. Петров // Квантовая электроника. — 1993. — Т. 20, № 5. — С. 711—714.
7. Principal of Reconstruction of the Single Influences on Fiber-Optical Measuring Network / Yu. N. Kulchin, E. V. Denisova, I. V. Denisov and N. A. Rybalchenko // Pacific Science Review. — 2003. — Т. 1, № 5. — С. 32—37.
8. Neural networks for linear inverse problems with incomplete data especially in applications to signal and image reconstruction / A. Cichocki, R. Unbehauen, M. Lendl, K. Weinzierl // Neurocomputing. — 1995. — № 8. — С. 7—41.
9. Neural data processing method for fiber-optic distributed measuring systems / I. V. Denisov, O. T. Kamenev, A. Yu. Kim, et al. // Optical Memory and Neural Networks (Information Optics). — 2003. — Vol. 12, № 3. — P. 165—172.
10. Галушкин А. И. Теория нейронных сетей. — М.: Радиотехника, 2000. — 485 с.
11. Каляев И. А., Гайдук А. П. Однородные нейроподобные структуры в системах выбора действий интеллектуальных роботов. — М.: Янус-К, 2000. — 346 с.
12. Бураков М. В., Коновалов А. С. Нейронечеткие системы управления // Информационно-управляющие системы. — 2002. — № 1. — С. 2—7.
13. Комарцова Л. Г., Максимов А. В. Нейрокомпьютеры. — М.: МГТУ им. Н. Э. Баумана, 2002. — 320 с.
14. Оссовский С. Нейронные сети для обработки информации. — М.: Финансы и статистика, 2002. — 344 с.
15. Takagi T., Sugeno M. Fuzzy identification of systems and its application to modeling and control // IEEE Trans. — SMS. — 1985. — P. 116—132.
16. Рыжов А. П. Элементы теории нечетких множеств и ее приложений. — М., 2003.
17. Калан Р. Основные концепции нейронных сетей. — М.: Изд. дом «Вильямс», 2001. — 288 с.

☎ (4232) 26-88-90

☎ (4232) 31-04-39

E-mail: kulchin@hq.febras.ru

ayukim@mail.ru



Новая книга

Шутьков А.А. Система управления агропромышленным комплексом: теория, политика и практика. — М.: Нац. ин-т бизнеса, 2005. — 808 с.

В монографии академика РАСХН А.А. Шутькова обобщен исторический опыт формирования системы управления АПК, раскрывается ее связь с аграрной политикой. Рассмотрены проблемы совершенствования управления агропромышленным комплексом в контексте трансформации российского общества и мировых тенденций. Автор, возглавляя прагматическую школу управления, анализирует взгляды крупных ученых в области управления, особенности отдельных школ в теории и практике.

Большое внимание уделено обобщению отечественного опыта накопления и использования интеллектуального потенциала в различных эпохах социально-экономического развития села. Дана оценка современного состояния аграрной политики и управления, предложены пути их корректировки и совершенствования в условиях кризиса АПК.

Определяя значение науки управления для агропромышленного производства, автор на основе обобщения результатов исследований и собственного опыта обосновывает практические рекомендации в области формирования новых организационных структур и функций государственного и хозяйственного управления, методов управления, техники и технологии управления, организации управленческого труда.