



ПРОТОТИПНЫЙ ПОДХОД К ПОСТРОЕНИЮ АВТОМАТИЗИРОВАННЫХ ЭКСПЕРТНЫХ СИСТЕМ С МНОГОСТРУКТУРНЫМ РАСПОЗНАВАНИЕМ СЛОЖНЫХ ОБРАЗОВ

В.Б. Трофимов (Сибирский государственный индустриальный университет)

Рассмотрены особенности функциональной структуры автоматизированной экспертной системы распознавания сложных образов, предложен подход к ее построению. Сформирована схема многоструктурного распознавателя, состоящего из элементарных нейросетевых классификаторов.

Ключевые слова: распознавание образов, экспертная система, искусственные нейронные сети.

Автоматизированная экспертная система распознавания образов представляет собой организационно-техническую систему с элементами искусственного интеллекта, аккумулирующую знания, обеспечивающую выработку решений о принадлежности образа к тому или иному классу на основе анализа значений информативных признаков, а также рекомендаций. Под образом можно понимать состояние промышленного объекта или процесса, сигнал, ситуацию, явление в некоторой прикладной области. Особенностью экспертной системы является наличие в ней подсистемы объяснений, предназначенной для интерпретации и обоснования результатов распознавания, а также для обучения и оказания консультационной помощи пользователям (операторам-технологам, операторам-контролерам и т. п.).

Структура экспертной системы распознавания образов представлена на рис. 1, построена на основе анализа и обобщения результатов работ [1–4]. Она функционирует следующим образом: пользователь,

желающий получить необходимые данные и знания, через свой интерфейс отправляет запрос к экспертной системе, а решатель, используя базу знаний, ищет и выдает пользователю подходящую рекомендацию, комментируя ход своих рассуждений при помощи подсистемы объяснений.

Основной задачей инженера по знаниям является извлечение и интерпретация знаний из различных источников (например, из баз данных, официальных документов, технологических инструкций, монографий, изобретений, книг, справочников), структурирование их в виде базы знаний и наполнение ее знаниями, относящимися к конкретной прикладной области. Для формализации знаний инженер выбирает модель их представления. Инженер по знаниям также извлекает знания из результата общения с экспертами в интерактивном режиме, используя методы системного анализа.

Эксперт владеет разнообразными знаниями в прикладной области, имеет доступ к действующему промышленному объекту автоматизации и к большому количеству источников знаний, которые освоил за годы обучения, теоретической и экспериментальной работы, а также приобрел навыки и опыт поиска эффективных решений конкретного класса задач распознавания сложных образов.

Редактор базы знаний, содержащий шаблоны языка представления знаний, меню, подсказки и другие сервисные средства, позволяет инженеру по знаниям создавать и наполнять базу знаний через интерфейс инженера в диалоговом режиме путем ввода в нее новых знаний о прикладной области. Систему управления базой знаний следует рассматривать как совокупность программных и аппаратных средств для организации в базе знаний процедур, связанных с поиском знаний, пополнением базы знаний, ее корректировкой.

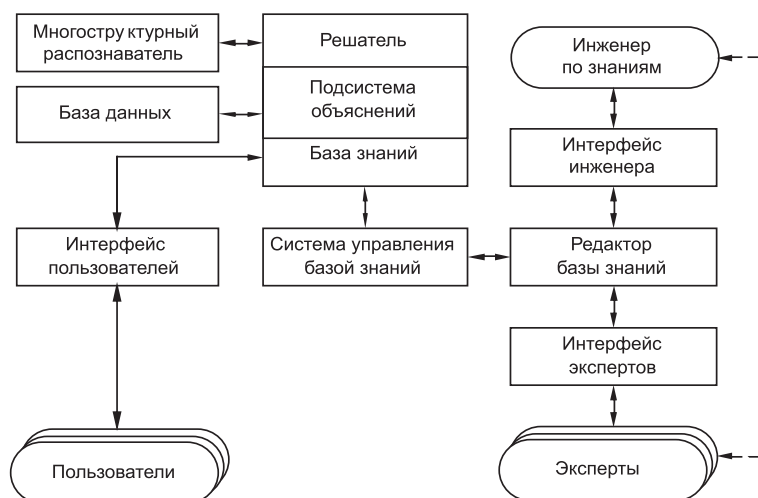


Рис. 1. Схема автоматизированной экспертной системы распознавания образов

Решатель осуществляет обработку данных и знаний циклически путем логического вывода. В каждом цикле он считывает и сопоставляет существующие данные из базы данных, результаты классификации из многоструктурного распознавателя и продукционные правила из базы знаний. Если в конкретной ситуации активизировалось сразу несколько конфликтующих правил, то решатель рассчитывает критерий, по которому выбирается единственное правило, заключение которого содержит рекомендуемые действия.

База знаний предназначена для хранения сложно структурированных информационных единиц — формализованных знаний прикладной области в явном виде (например, с помощью продукционных правил, семантических сетей и фреймообразных структур), то есть на некотором языке, понятном пользователям и экспертам.

Подсистема объяснений разъясняет пользователям путь решения задачи распознавания, поясняет, почему получено именно это решение (результат распознавания), а не какое-либо другое, а также выдает информацию о промышленном объекте, например, значения информативных признаков. В этой подсистеме имеется набор специальных процедур и рабочая память, предусмотрена возможность трассировки всего процесса получения решения с указанием использованных фрагментов базы знаний.

В теории совместной классификации (коллективного принятия решений множеством классификаторов) утверждается, что не существует классификатора, который был бы пригоден для всех приложений, актуальным является поиск наилучшего множества классификаторов и затем поиск наилучшего метода объединения. Использование множества разнообразных классификаторов приводит к более высокой точности распознавания и лучшим показателям вычислительной эффективности, что достигается за счет того, что на множестве ошибочных решений некоторого классификатора другие классификаторы не ошибаются.

Основные предпосылки предлагаемого многоструктурного распознавателя (рис. 2):

- данные, используемые для распознавания, искусственно собираются множеством распределенных измерительных блоков;
- имеется естественная декомпозиция источников данных и знаний;
- пространство признаков содержит весьма разнообразные типы признаков (булевы, целочисленные, непрерывные, изображения и т. п.);
- решаемая задача обладает большой размерностью пространства признаков;
- признаковые пространства, используемые клас-

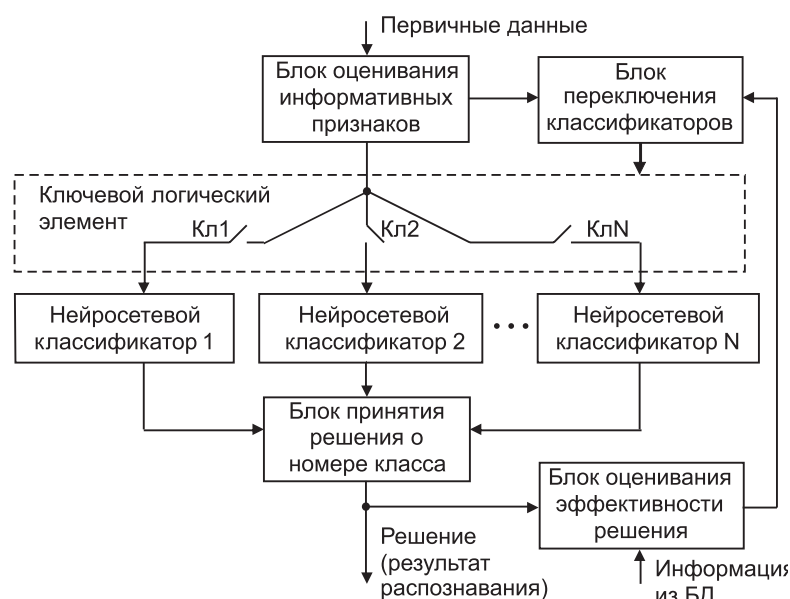


Рис. 2. Схема многоструктурного распознавателя

сификаторами, различны.

Решению проблемы распознавания образов в автоматизированных системах, построения решающих правил с повышенной структурной сложностью, комбинирования классификаторов посвящено достаточно много теоретических и практических работ, к числу которых относятся труды [5, 6] и многих других ученых. Это показывает, что теория совместной классификации — фундаментальное, развивающееся направление в распознавании образов, которое находит широкое применение в решении сложных прикладных задач, является предметом активных научных исследований. С точки зрения улучшения качества совместной классификации путем коррекции параметров многоструктурных распознавателей, их практической реализации в интеллектуальных системах автоматизированного управления, известные методы распознавания образов требуют переосмысления и дальнейшего развития. Это вызвано несколькими причинами.

1) Известные теоретические вычислительные процедуры распознавания, как правило, базируются на строгих ограничениях и жестких исходных предпосылках (например, требование нормальности априорных распределений в статистических методах, гипотеза компактности в методе потенциальных функций, условие неразличимости признаков, предположение, что апостериорные вероятности, вычисленные соответствующими классификаторами, не слишком отличаются от априорных, а также линейность и стационарность динамических систем «в большом»), выполнение которых на реально действующих объектах весьма затруднительно.

2) Выбор классификатора для решения конкретной задачи распознавания чрезвычайно затруднен из-за огромного многообразия алгоритмов распознавания, разработанных к настоящему времени. Процесс

выбора и применения классификаторов до сих пор зависит от интуитивных соображений исследователей, от предметной области, а также от предпочтений разработчиков. Проверка предпосылок классификаторов не всегда возможна (например, необходимые распределения вероятностей обычно либо неизвестны, либо приводят к сложным вычислениям, либо распределение сложно оценивается), поэтому объединение различных классификаторов в многоструктурный распознаватель и многокритериальный их выбор в реальном режиме времени позволяет наилучшим образом использовать особенности различных классификаторов.

3) Более совершенным подходом для распознавания образов является классификация, базирующаяся на интеллектуальном анализе информативных признаков и структурной адаптации, чем подход, основанный на сравнении входного образа с эталонами. Только тесное объединение интеллектуальных методов обработки полученных данных с многоструктурным подходом к автоматизации может привести к желаемому результату.

4) Элементарные (базовые, индивидуальные) классификаторы могут быть «не так хороши», но, работая в команде как единое целое, они обладают высокой точностью и низкими требованиями к вычислительным ресурсам, даже наихудший классификатор может внести свой вклад в улучшение свойств системы управления в целом. Необходимо выбирать такие элементарные классификаторы, которые обеспечивают некоррелированность ошибок классификации, то есть которые «ошибаются» на различных входных данных или в разных подобластях пространства признаков.

5) Для эффективного решения задачи распознавания необходимо первоначально заняться обучением множества элементарных классификаторов, построенных на базе различных алгоритмов. Обучение должно осуществляться с помощью неодинаковых алгоритмов на разных подмножествах обучающих данных посредством показа образов, принадлежность которых к тому или иному классу известна.

Предлагаемый многоструктурный распознаватель с переключением элементарных нейросетевых классификаторов (рис. 2) представляет собой такое их соединение, при котором блок переключения на основе анализа информативных признаков и многокритериального выбора дает команду ключевому элементу, который замыкает один или несколько из каналов передачи информации, после чего на вход классификаторов поступают оценки информативных признаков, далее осуществляется процесс классификации и принимается решение о номере класса.

Блок переключения классификаторов создан на основе многокритериального подхода и работает по следующей процедуре.

Шаг 1. Расчет исходных критериев эффективности Q работы классификаторов: отношения правильно

распознанных ситуаций к их общему числу, ошибки регистрации, ошибки захвата данных, ошибки ложного несоответствия, ошибки ложного соответствия, ошибки ложного отказа, ошибки ложного пропуска.

Шаг 2. Нормализация критериев эффективности работы классификаторов по следующей формуле:

$$M(N, j) = \begin{cases} \frac{Q(N, j) - Q_{\min}}{Q_{\max} - Q_{\min}}, & \text{если } Q(N, j) \rightarrow \max; \\ \frac{Q_{\max} - Q(N, j)}{Q_{\max} - Q_{\min}}, & \text{если } Q(N, j) \rightarrow \min, \end{cases}$$

где $M(N, j)$ — значение нормализованного безразмерного критерия; $Q(N, j)$ — значение размерного исходного критерия; Q_{\max} — максимальное значение обрабатываемого критерия; Q_{\min} — минимальное значение обрабатываемого критерия; N — номер элементарного нейросетевого классификатора; $j = 1, 2, \dots, J$ — номер критерия.

Шаг 3. Расчет критерия переключения по формуле:

$$C(N) = \sum_{j=1}^J \alpha(j) M(N, j) \rightarrow \max,$$

где $\alpha(j)$ — весовые коэффициенты важности нормированных критериев эффективности, задаваемые экспертами, при условии что $\sum_{j=1}^J \alpha(j) = 1$.

Шаг 4. Выбор элементарных классификаторов по критерию $C(N)$, после чего ключевой элемент замыкает соответствующие каналы передачи информации.

В качестве элементарных классификаторов были выбраны нейросетевые, поскольку искусственные нейронные сети обладают следующими достоинствами [7]: а) быстрое «доучивание» за счет использования предыдущей карты синапсов (весовых коэффициентов); б) большое число входных элементов, что позволяет учитывать внешние воздействия, которые обуславливают нестационарность процесса; в) отсутствие некоторых жестких статистических предпосылок о свойствах данных, подаваемых на вход сети (например, нормальное распределение, стационарность, или что искомая зависимость является линейной); г) возможность в полной мере учитывать экспертную информацию; д) способность к самообучению; е) нейронные сети можно сочетать с нечеткими множествами; ж) способность воспроизводить сложные нелинейные зависимости; з) высокая надежность; и) уникальная способность обучаться на примерах и «узнавать» в потоке зашумленной и противоречивой информации черты ранее встреченных ситуаций; к) обработка большого объема данных за короткое время; л) эффективная работа с временными последовательностями, в которых мал интервал наблюдений; м) ориентация на решение задач, имеющих следующие особенности: отсутствие «простого» алгоритма, позволяющего находить эффективные реше-

ния в разнообразных «сложных» ситуациях; наличие достаточно большого числа примеров оптимальных решений, найденных экспертом для различных типопредставительных ситуаций; наличие большого объема данных о внешних влияющих факторах; зашумленность, частичная противоречивость, неполнота или избыточность исходных данных.

Однако нейронные сети обладают и недостатками, такими как: а) представление знаний осуществляется в неявном виде в архитектуре сети, параметрах нейронов и связей, в отличие от экспертных систем, в которых знания представлены в явном виде, например, с помощью процедурных правил; б) аппаратная реализация нейронной сети затруднена при росте числа промежуточных слоев или нейронов в отдельном слое; в) отсутствует возможность оперативной замены отказавших элементов сети; г) при использовании алгоритмов самообучения нейронной сети в условиях возникновения неисправностей увеличивается вероятность потери устойчивости в петле обучения; д) при обучении искусственной нейронной сети становится актуальной задача переобучения; е) использование немасштабированных значений входных переменных сети может привести к эффекту насыщения; ж) избыточность переменных на входе сети может привести к «проклятию размерности».

При формировании стадий и этапов процедуры построения автоматизированных экспертных систем (ЭС) за основу был взят ГОСТ 34.601-90 «Автоматизированные системы. Стадии создания», а также использовали подход, предложенный в работе [2].

В автоматизированных экспертных системах база знаний, являющаяся ее ядром, представляет собой совокупность формализованных знаний, введенных в систему инженером по знаниям через интеллектуальный интерфейс. Для заполнения базы знаний, то есть для обучения экспертной системы распознавания, знания извлекаются из трудов по распознаванию, технологических инструкций и опыта работы экспертов, а также из предыстории работы самого объекта. Извлечение знаний выполняется с помощью рационального сочетания активных и пассивных методов на основе системного подхода. Активное извлечение знаний осуществляется с нанесением специально организованных явных и неявных испытательных (тестовых) воздействий, способствующих построению адекватных моделей изучаемых промышленных объектов.

После извлечения знаний необходимо их структурировать, то есть выполнить их неформальное описание в виде графа, таблицы, диаграммы или текста, которое отражает поле знаний, включающее терминологию, список основных понятий и атрибутов, отношения между входной и выходной информацией, стратегии принятия решений, а также ограничения стратегий.

После извлечения и структурирования знаний выполняется этап их формализации. Наибольшее распространение в промышленных системах автоматизации для формализации знаний получила продук-

ционная модель или модель, основанная на правилах. Правила позволяют представлять знания в виде предложений типа «Если (условие), то (решение)». Под условием понимается некоторое предложение-образец, по которому осуществляется поиск в базе знаний, а под решением — событие, выполняемое при успешном исходе поиска (оно может быть промежуточным, выступающим далее как условия, и терминальным, завершающим работу системы, то есть результатом распознавания).

Современные промышленные машины, агрегаты, технологические линии, участки, цехи горнодобывающей, металлургической, химической, машиностроительной и других отраслей промышленности в большинстве своем относятся к классу сложных объектов автоматизации. Существенного повышения эффективности управления ими можно достигнуть путем применения адекватно сложных систем, какими и являются автоматизированные экспертные системы распознавания. Эти системы целесообразно использовать, например, для распознавания:

- дефектов различного металлопроката (рельсового, листового, трубного и т. п.) путем автоматического сканирования поверхности с помощью промышленных видеокамер;
- дефектов рельс на железнодорожных путях с целью снижения вероятности аварий;
- маркировки металлопроката в потоке производства;
- состояний агломерационной машины, доменной печи, воздухонагревателей и для обучения операторов-технологов;
- дефектов отливок;
- номеров железнодорожных вагонов.

Этот подход открывает новые возможности для повышения эффективности производств, может быть использован на предприятиях черной металлургии и других отраслей промышленности для развития традиционных автоматизированных систем сложных технологических объектов, а также для извлечения и использования знаний опытных специалистов — экспертов. Его апробация была реализована в промышленных условиях комплекса неразрушающего контроля качества продукции рельсобалочного цеха ОАО «ЕВРАЗ Объединенный Западно-Сибирский металлургический комбинат» (ранее ОАО «Новокузнецкий металлургический комбинат»), а именно: разработана автоматизированная экспертная система распознавания поверхностных дефектов рельс [7], использующая их морфологические и генетические признаки, позволяющая с помощью искусственных нейронных сетей автоматически обнаружить типовые поверхностные дефекты, оценить их параметры и пространственные координаты, а в нестандартных случаях (например, для редко встречающихся дефектов) оказывать помощь оператору-технологу посредством специализированной подсистемы объяснений. Внедрение этой системы обеспечивает достижение

максимума правильно опознанных дефектов в автоматическом режиме (90...97%), снижение брака на 20...30%, уменьшение числа рекламаций, а также увеличение числа рельс, пригодных для высокоскоростных магистралей.

Сравнение предлагаемого подхода к распознаванию с известными подходами [6].

1. Недостаток вероятностного подхода на основе правила Байеса и его упрощений в том, что для объединения решений необходимо, чтобы все классификаторы имели однородные выходные данные, а именно: их выходы должны быть или бинарными, или категориальными, или векторами с мерами неопределенности одного типа. Также, если классификаторы нижнего уровня обладают высокой точностью, то использование ковариационных матриц классов, как правило, приведет к неустойчивости вычислений, поскольку матрицы станут сингулярными или плохо-обусловленными.

2. В подходе «многоярусного обобщения» такие методы, как багинг, бустинг и ряд других используют классификаторы, построенные на базе одного и того же алгоритма, которые различаются выборками, на которых они обучены и тестированы, что не является наилучшим вариантом выбора элементарных классификаторов. Отрицательной стороной методов этой группы является необходимость их переобучения в том случае, когда на базовом уровне в систему добавляется новый классификатор.

3. Недостаток подхода, основанного на оценке компетентности классификаторов, состоит в том, что чем детальнее описаны области компетентности каждого из классификаторов, тем большей точностью обладает алгоритм в целом, при этом характеристики компетентности классификатора могут оказаться достаточно грубыми, также этот подход снижает требование некоррелированности ошибок используемых классификаторов. При этом в каждой области компетентности (области пространства признаков) принимается во внимание решение одного и только одного классификатора, а свойства классификаторов, работающих как единое целое, могут меняться.

Заключение

В результате исследования создана структура автоматизированной экспертной системы распознавания

Трофимов Владимир Борисович — канд. техн. наук, доцент Сибирского государственного индустриального университета.
Контактный телефон (3843) 74-88-06.
E-mail: trofimov_vbt@mail.ru

На МУП «Горсвет» внедряется специальное решение

В продолжение внедрения системы «Галактика ЕАМ» на Архангельском МУП «Горсвет» специалисты предприятия приступили к опытной эксплуатации специализированного информационного комплекса CityLight v2.1. Основная задача данного комплекса — управление основным видом деятельности предприятия в едином информационном пространстве.

Данное решение было создано на базе информационной системы «Галактика ЕАМ», разработанной одноименной корпорацией. Значительная

сложных образов, включающая многоструктурный распознаватель, состоящий из элементарных нейросетевых классификаторов. Предложен подход к построению экспертных систем, отличающийся сочетанием активных и пассивных методов извлечения знаний на основе системного подхода. Многоструктурный распознаватель с переключением элементарных нейросетевых классификаторов, отличающийся тем, что операция переключения на основе анализа информативных признаков и многокритериального выбора позволяет ключевому элементу замыкать один или несколько каналов передачи информации, после чего на вход классификаторов поступают оценки информативных признаков, далее осуществляется процесс классификации и принимается решение о номере класса. Сочетание разнообразных классификаторов с разными условиями их эффективного применения позволяет с наибольшей эффективностью решать задачи распознавания сложных образов, поскольку обучающая выборка данных для элементарных классификаторов по своим характеристикам может существенно отличаться от свойств данных, поступающих в рабочем режиме от объекта автоматизации.

Список литературы

1. Васильев С. Н., Жерлов А. К., Федосов Е. А., Федун Б. Е. Интеллектуальное управление динамическими системами. М.: Физико-математическая литература. 2000.
2. Гаврилова Т. А., Хорошевский В. Ф. Базы знаний интеллектуальных системы. СПб.: Питер, 2001.
3. Геловани В. А., Башлыков А. А., Бритков В. Б., Вязилов Е. Д. Интеллектуальные системы поддержки принятия решений в нештатных ситуациях с использованием информации о состоянии природной среды. М.: Эдиториал УРСС, 2001.
4. Охтилев М. Ю., Соколов Б. В., Юсупов Р. М. Интеллектуальные технологии мониторинга и управления структурной динамикой сложных технических объектов. М.: Наука. 2006.
5. Методы компьютерной обработки изображений/Под ред. В. А. Сойфера. М.: ФИЗМАТЛИТ, 2003.
6. Городецкий В. И., Серебряков С. В. Методы и алгоритмы коллективного распознавания//Автоматика и телемеханика, 2008. № 11.
7. Кулаков С. М., Трофимов В. Б. Интеллектуальные системы управления технологическими объектами: теория и практика. Новокузнецк: СибГИУ, 2009.

часть созданного для МУП «ГОРСВЕТ» решения была взята из базовой версии «Галактика ЕАМ», при этом была учтена специфика свойственная МУПам, ориентированным на основного заказчика в лице города.

Основное направление деятельности МУП «Горсвет» — техническое обслуживание городской инфраструктуры: обеспечение работоспособности электрических сетей наружного освещения, обеспечение надлежащей работоспособности городских световых объектов, а также обслуживание знаков регулирующих дорожное движение.

[Http://www.galaktika.ru](http://www.galaktika.ru)