

МОНИТОРИНГ ЭНЕРГОСБЕРЕЖЕНИЯ В СТРОИТЕЛЬНЫХ СООРУЖЕНИЯХ И КОММУНИКАЦИЯХ НА ОСНОВЕ ИНТЕЛЛЕКТУАЛЬНЫХ ТЕХНОЛОГИЙ

Робота присвячена проблемі ухвалення рішень про стан будівельних об'єктів і теплових комунікацій методами неруйнівного контролю із застосуванням інтелектуальних технологій. Запропонований підхід растрового розкладання теплографічного зображення досліджуваного об'єкта, побудови нейромережної моделі ухвалення рішення про його стан на основі теорії розпізнавання образів і визначення достовірності ухваленого рішення.

Ключові слова: термографічний портрет, бінарний масив ознак, вчення нейронної мережі, розпізнавання класів.

Работа посвящена проблеме принятия решений о состоянии строительных объектов и тепловых коммуникаций методами неразрушающего контроля с применением интеллектуальных технологий. Предложен подход растрового разложения теплографического изображения исследуемого объекта, построения нейросетевой модели принятия решения о его состоянии на основе теории распознавания образов и определения достоверности принятого решения.

Ключевые слова: термографический портрет, бинарный массив признаков, обучение нейронной сети, распознавание классов.

Work is devoted a decision-making problem about the state of build objects and thermal communications by the methods of nerazrushayuschego control with the use of intellectual technologies. Approach of raster decomposition of teplograficheskogo image of explored ob'ek-ta is offered, constructions of neyrosetevoy model of decision-making about his state on the basis of theory of raspo-znavaniya appearances and determination of authenticity of the accepted decision.

Key words: thermografhic portrait, binary array of signs, teaching of neuron network, recognition of classes.

Постановка проблемы. В современных условиях актуальна проблема энергосберегающих технологий и процедур контроля энергетических параметров. В строительстве используются различные средства неразрушающего контроля, в том числе и строительные тепловизионные камеры, необходимые для проведения тепловизионного обследования строительных сооружений [1, 2]. Инфракрасная термография является эффективным бесконтактным методом контроля и диагностирования состояния строительных объектов и применяется для определения тепловой изоляции поверхностей, стыков, областей, чувствительных к возникновению трещин, детектирования плохо заизолированных участков, обследования сооружений, поиска утечек в заглублённых трубопроводах, анализ состояния скрытой электропроводки, обнаружения участков, восприимчивых к образованию плесени, и т.п. Результатами использования инфракрасной термографии часто являются существенное энергосбережение, минимизация работ по исправлению повреждений и другая экономия расходов вследствие быстрой окупаемости затрат на приобретение инфракрасной камеры.

Анализ последних исследований и публикаций. Публикации, связанные с исследованиями в этой области, отражают значительные успехи в разработке и применении технологий и устройств термографического анализа для различных предметных областей. Теплолокация позволяет обнаруживать движущиеся объекты; термографический анализ тела человека даёт возможность ставить диагноз; тепловой портрет здания показывает

места потери тепла; термографическое сканирование электропроводки позволяет оценить состояние изоляции и др. Достигнута высокая чувствительность устройств, разрешающая способность по диапазону температур и селективность по направлению при относительно приемлемых ценах. Это позволяет достаточно оперативно и точно установить сам факт отклонения от нормы теплового фона объекта или его участка и **выделить не решенную ранее часть общей проблемы, которой и посвящена данная статья**, – интеллектуальная обработка данных для автоматического распознавания состояния проблемного объекта на основе его термографического портрета. Очень часто на практике не удается создать точный термографический портрет исследуемого участка (подземные тепловые коммуникации, скрытая электропроводка и т.д.) и с достаточной степенью достоверности классифицировать состояние проблемного участка. Для принятия решения этого зачастую бывает недостаточно, а прямой доступ к участку связан со значительными материальными и временными затратами. Поэтому получение надежных данных об объекте по результатам термографического исследования в условиях затрудненного доступа к объекту, частичного поглощения и рассеивания инфракрасного излучения возможно путем применения технологии распознавания ситуаций на основе обучаемых искусственных нейронных сетей [3, 4].

Цель статьи (постановка задачи). 1. Формализовать образ исследуемого участка на языке информативных признаков. 2. Построить нейросетевую модель процесса принятия решения о принадлежности объекта к одному из возможных классов. 3. Сформировать массив обучающих данных и привести его к двоичному формату. 4. Обучить модель на выборке прецедентов и оценить степень доверия к результату.

Изложение основного материала. Определим пространство признаков, описывающих термографический образ исследуемого объекта. Допустим, что это городская теплотрасса, залегающая на некоторой глубине в земле и не имеющая прямого доступа без вскрышных работ. Современные принципы термографии состоят в использовании неохлаждаемого микроболометра для получения изображений с достаточно высоким разрешением (320 x 240 пикселей), например у FLIR B20. При чувствительности (0,080°C), частоте изображений 50 кадров в секунду, сохранении до 1000 изображений в памяти имеются все условия для нейросетевого анализа ситуации. Предварительно необходимо сформировать несколько десятков теплоизображений наличия протечек с различными ракурсами и расстояниями до приемной камеры. Так же необходимо зафиксировать несколько десятков изображений часто встречающихся дефектов с различными ракурсами и расстояниями до приемной камеры. Необходимы и изображения типичных нарушений покрытий укрывных и изолирующих материалов.

Анализ таких изображений сводится к количественному оцениванию тепловых потерь объектов и классификации отклонений от нормы. Визуальное оценивание теплограммы экспертом носит субъективный характер и позволяет получать лишь качественные оценки. Методы цифрового компьютерного анализа изображений являются объективными и дают возможность автоматизировать количественный анализ состояния проблемных объектов и детализировать характер возникших нарушений или повреждений. Нашей целью является разработка и исследование подхода к оцениванию состояний объектов по термографическим изображениям с помощью искусственных нейронных сетей.

Основой разработанного алгоритма является использование нейронной сети как инструмента оценки состояний объектов по термографическим изображениям.

При термографической съемке исследуемых участков создаются термоизображения, на основании которых необходимо сформировать данные для автоматического принятия решения о принадлежности исследуемого участка к одному из классов, например: полностью исправный участок; в предаварийном состоянии, с протечкой малой степени; аварийное состояние и иные возможные или желательные варианты классификации. В качестве входных данных используется цифровая растровая последовательность изображения кадра, например 320 x 240 пикселей. То есть размерность входного вектора определяется общим числом пикселей, а активность каждого пикселя – записанным числом в двоичном коде установленной разрядности. Другими словами, входом нейронной сети является вектор фиксированной размерности, равный числу пикселей растровой развертки одного кадра. А компонентами вектора являются интенсивности инфракрасного излучения пикселей, выраженные двоичными числами соответствующей разрядности, определяемой техническими возможностями тепловизионной камеры. Это зафиксированный образ текущего состояния исследуемого участка на языке признаков растровой развертки. Необходимо отнести полученный образ к одному из классов и оценить степень риска принятого решения.

Процесс обучения нейронной сети. Очевидно, что задача оценки состояния объекта в данных условиях сводится к задаче распознавания образов в пространстве признаков, описывающих интенсивности термоизображений массивом чисел. Стандартное графическое изображение, например, компьютеров IBM AT 286 обеспечивает размер 320 x 240 точек и может быть представлено массивом из 76800 чисел. Кодировка каждой точки может быть как монохромной, когда каждая точка отображена значениями 0 (белая) или 1 (черная), так и полутоновой с некоторым числом градаций. Во втором случае каждая точка должна выражаться числом, разрядность которого достаточна для представления любого цвета или полутона. Каждый кадр изображения является единичным примером обучающей выборки. Вся совокупность примеров (кадров) представляется выборкой соответствующей размерности, которая размещается в базе данных.

В качестве обучающего алгоритма для нейронной сети был выбран алгоритм back propagation [3].

Данный алгоритм подразумевает такой тип обучения, как обучение с учителем, то есть для каждого входа нейронной сети необходимо иметь требуемый выход. Цель обучения заключается в том, чтобы за конечное число тактов обучения каждому входному образцу из обучающей выборки нейронная сеть ставила в соответствие выход, представленный ей на этапе обучения. В нашем случае входом нейронной сети является вектор растровой развертки размерности N с элементами интенсивностей разрядности N двоичного кода. В качестве выходных данных используются номера классов, обозначающие соответствующие состояния исследуемого проблемного объекта. Для каждого входного вектора из текущей обучающей выборки в процессе обучения ставится в соответствие истинный номер класса и соответствующий ему эталонный вектор.

Выбор целевой функции. Обучение сети, состоящее в оптимальном подборе весов, подразумевает минимизацию целевой функции в виде интегральной ошибки по всему массиву входных данных для каждого класса. Удобно пользоваться широко распространенной квадратичной формой вида

$$E(W) = \sum_{k=1}^K \sum_{j=1}^N (x_j^k - d_j)^2, \quad (1)$$

где x_j^k – текущее значение яркости j -го пикселя в k -м кадре;

d_j – значение яркости j -го пикселя эталонного изображения;

$k = 1, 2, \dots, K$; $j = 1, 2, \dots, N$; N – размерность вектора входных параметров (число пикселей в развертке одного кадра); K – максимальное число кадров (количество термографических изображений на каждый класс состояний объекта).

Воспользуемся математическим аппаратом градиентного метода наискорейшего спуска [3, 4], при котором уточнение весовых коэффициентов производится по алгоритму

$$w_j(t+1) = w_j(t) - \alpha \cdot \frac{\partial E(w)}{\partial w_j(t)}, \quad (2)$$

где $\frac{\partial E(w)}{\partial w_j(t)}$ – производная функции ошибки по пространству синаптических весовых коэффициентов;

$w_j(t)$ и $w_j(t+1)$ – соответствующие весовые коэффициенты предыдущего и последующего циклов обучения нейронной сети;

α – параметр, определяющий скорость итерационного процесса обучения сети ($0 < \alpha < 1$).

Минимизация $E(w)$ проводится для каждого эталона по всему массиву весовых коэффициентов, размерность которого определяется общим числом нейронов выбранной сети. Процесс обучения нейросети производится модифицированием синаптических весов методом градиентного спуска [3, 4]; мультимодальность поверхности ошибки, переобучение, замирание сети, неадекватность ошибок обучения и обобщения здесь пока не рассматриваются.

При выборе аналитического вида x^k и d целесообразно воспользоваться подходом, предложенным в работах [5, 6], где обоснован выбор ошибки обучения с учетом допустимых рисков в предметной области через статистические критерии согласия. Суть подхода в алгоритмической связи величины ошибки через статистику Смирнова и квантиль распределения Колмогорова заданного уровня значимости с ошибками первого и второго рода при проверке статистической близости текущего и целевого состояний исследуемого объекта. Подобный подход обеспечивает адаптацию адекватности модели при модификации синаптического пространства сети на основе классических критериев с учетом особенностей предметной области и автоматизирует поиск условия окончания итерационного процесса обучения нейронной сети. Итерационная процедура (2) реализована в программных пакетах NeuroShell Day Trader 3.8, NeuroShell Predator 2, NeuroShell Classifier 2, имеющих законченную среду для синтеза нужных архитектур сетей и разнообразные сервисные программные дополнения. Их использование упрощает обучение сети и моделирование сводится к простым и понятным действиям:

1. Из обучающей выборки берется первый текущий пример, и его входные параметры (представляющие в совокупности вектор входных сигналов) подаются на входные синапсы обучаемой нейросети. Обычно каждый входной параметр примера подается на один соответствующий входной синапс.

2. Нейросеть производит заданное количество тактов функционирования, при этом вектор входных сигналов распространяется по связям между нейронами.

3. Измеряются сигналы, выданные теми нейронами, которые считаются выходными.

4. Производится интерпретация выданных сигналов, и вычисляется оценка, характеризующая различие между выданным сетью ответом и требуемым ответом, имеющимся в примере. Оценка вычисляется с помощью соответствующей функции оценки (1). Чем меньше оценка, тем лучше распознан пример, тем ближе выданный сетью ответ к требуемому.

5. Если оценка примера равна нулю, ничего не предпринимается. В противном случае на основании оценки вычисляются поправочные коэффициенты для каждого синаптического веса матрицы связей, после чего производится подстройка синаптических весов (обратное функционирование). В коррекции весов синапсов и заключается обучение.

6. Осуществляется переход к следующему примеру задачника, и вышеперечисленные операции повторяются. Проход по всем примерам обучающей выборки с первого по последний считается одним циклом обучения.

Пример. Воспользуемся пакетом Matlab (The MathWorks) и рассмотрим пример конструирования *нейронной сети* для задачи распознавания классов.

Пусть имеется вектор независимых переменных, входных параметров – показателей интенсивности инфракрасного изображения отдельного кадра и номера классов, которым он может принадлежать. Формируем обучающую выборку, как было показано выше. Для решения задачи выберем трехслойную сеть с алгоритмом обратного распространения ошибки. Сигнальные функции в слоях установим соответственно: первый *слой* – `logsig`, второй – `logsig`, третий – `purelin`.

В выбранной среде описание такой *сети* выглядит так:

`Net=netff(PR, [S1,S2, : , Sn], {TF1,TF2, : , TFn},btf, blf, pf),`

где PR – массив значений для R векторов входа;

S_i – количество нейронов в i-м *слое*;

TF_i – функция активации *слоя* i;

btf – обучающая функция, реализующая *метод обратного распространения*;

blf – функция настройки, реализующая *метод обратного распространения*;

pf – критерий качества обучения.

Синтаксис выбранных активационных функций имеет вид

`Net=netff(minmax (P), [n,m, l], { logsig, logsig, purelin }),`

где P – множество входных векторов;

n – количество входов НС;

m – количество нейронов в скрытом *слое*;

l – количество выходов НС.

Методом расчета значения ошибки выбран метод наименьших квадратов. Тогда функция будет выглядеть так: `Net.performFcn = 'SSE'`.

Для упрощения критерием окончания обучения выберем фиксированное число циклов, например 1000, и воспользуемся функцией

`net.trainParam.epochs=1000.`

Инициализация (запуск) процесса обучения осуществляется следующим образом:

`[net, tr]=train(net, P, T).`

Последний шаг – выполнение команды `save nn1 net` для сохранения параметров обучения в файле, например, с именем `nn1.mat`.

Выводы и перспективы дальнейших исследований в данном направлении.

1. В задачах анализа состояния теплоизоляции сооружений, тепловых коммунальных магистралей, изоляции электрических коммуникаций целесообразно использовать аналитический инструментальный искусственных нейронных сетей на основе стандартных нейропакетов.

2. Достоверность результатов обеспечивается корректным выбором исходных данных, строгим математическим описанием обучающих процедур и их реализацией путем применения стандартных программ – конструкторов нейросреды, реализующих на практике этот математический аппарат, а также результатами моделирования.

3. Расширить применение полученных результатов на предметные области, где признаковые пространства формируются в бинарном формате (аэрофотосъемка, видеосистемы охранной сигнализации, системы идентификации документов и денежных купюр и т.п.).

Литература

1. СНиП 23-02-2003. Тепловая защита зданий. – М: Госстрой России, 2004. – 214 с.
2. ГОСТ 26629-85. Здания и сооружения. Метод тепловизионного контроля качества теплоизоляции ограждающих конструкций.
3. Хайкин С. Нейронные сети: полный курс. 2-е издание / С. Хайкин. – М.: «Вильямс», 2006. – 1104 с.
4. Галушкин А.И. Нейрокомпьютеры и их применение на рубеже тысячелетий в Китае. Т.1 и 2 / А.И. Галушкин. – М., 2004. – 367+464 с.
5. Ляхов А.Л. Проблема моделирования сложных социотехнических систем / А.Л. Ляхов, С.П. Алёшин // V дистанционная научно-практическая конференция с международным участием « Системы поддержки принятия решений. Теория и практика». СППР, 2009 <http://conference.imtsp.kiev>. Сборник докладов ИПММС НАН Украины. – К., 2009. – С. 31–34.
6. Ляхов А.Л. Искусственная нейронная сеть как измерительный инструмент адекватности модели с адаптивным классом точности / А.Л. Ляхов, С.П. Алёшин // IV научно-практическая конференция с международным участием «Математическое и имитационное моделирование систем. МОДС `2009»: сборник докладов ИПММС НАН Украины. – К., 2009. – С. 116–119.

Надійшла до редакції 10.02. 2010

© А.Л. Ляхов, С.П. Алёшин