

УДК 621.317

АНАЛИЗ МЕТРОЛОГИЧЕСКИХ ХАРАКТЕРИСТИК ТЕПЛОВИЗИОННОЙ СИСТЕМЫ ТЕХНИЧЕСКОГО ДИАГНОСТИРОВАНИЯ С НЕЙРОННОЙ СЕТЬЮ

Р.В. Гирин

Самарский государственный технический университет
Россия, 443100, г. Самара, ул. Молодогвардейская, 244

E-mail: romangirin@gmail.com

***Аннотация.** Рассматривается задача определения погрешностей тепловизионной системы при техническом диагностировании электронных приборов с использованием нейронной сети. Описана структура системы, включающая измерительные каналы с тепловизором, термометром внешней среды, блок расчетных моделей тепловых состояний, базу знаний и нейросетевой программный анализатор термограмм. Предложено использовать для анализа состояний приборов двухветвенную нейронную сеть, состоящую из многослойной конволюционной нейронной сети и полносвязной сети. Построена метрологическая модель измерительных каналов. Приведена классификация составляющих инструментальной погрешности и предложены выражения для мультипликативной и аддитивной компонент инструментальной погрешности. Особое внимание уделено анализу методической погрешности, вызываемой использованием искусственной нейронной сети при классификации отказов в приборе. Выполнены экспериментальные исследования, которые подтвердили эффективность предложенных методологических и технических решений.*

***Ключевые слова:** искусственные нейронные сети, анализ погрешностей, техническое диагностирование, тепловизор, инфракрасная термография.*

Введение

Применение в информационно-измерительных системах (ИИС) искусственных нейронных сетей (ИНС) [1–5] ставит задачу оценки погрешности, вносимой в процессе контроля использованием ИНС. В работах [6–8] описана ИИС для диагностики электронных приборов методом сравнительной инфракрасной термографии [9] на основе нейронной сети. В то же время подходы к анализу погрешностей измерительных систем, содержащих нейронные сети, развиты недостаточно.

В статье проведен метрологический анализ измерительных каналов тепловизионной системы технического диагностирования (ТСТД) с нейросетевым программным анализатором на основе двухветвенной нейронной сети, выполняющей классификацию термограмм. Результатом работы нейронной сети является определение неисправностей в объекте [10].

В качестве объекта контроля рассматривается электронный прибор, находящийся в конструктиве некоторого объекта и функционирующий в штатном или испытательном режиме. Внутри прибора находится n источников тепла $Q^n(x_n, y_n, t)$, которые формируют температурное поле на поверхности прибора.

Гирин Роман Викторович, ассистент кафедры «Вычислительная техника».

Исследование факторов, определяющих погрешности ТСТД

Сделаем следующие допущения. Контролируемый прибор имеет форму параллелепипеда. Следовательно, надо рассматривать температурные поля на его гранях.

1. При креплении прибора в конструктиве системы как минимум одна грань будет соприкасаться со стенками конструкции. Максимальное число граней прибора, соприкасающихся с конструкцией, будет равно пяти. Тогда количество видимых поверхностей прибора, которые можно исследовать тепловизором, находится в диапазоне от одной до пяти граней.

2. Некоторые грани прибора, в частности имеющие интенсивный теплоотвод, могут быть изотермическими. В этом случае говорить о тепловой картине поверхности нет смысла. По существу, достаточно измерить интегральную температуру в какой-либо точке грани и сделать определенные выводы о техническом состоянии прибора. Но это не позволяет провести более тонкое исследование причин отказа и не требует использования интеллектуальной измерительной системы.

3. Таким образом, в дальнейшем будем рассматривать одну грань поверхности контролируемого прибора, температурное поле которой имеет заметный градиент.

Для анализа термограмм поверхности прибора автором предлагается использовать двухветвенную нейронную сеть, состоящую из многослойной конволюционной нейронной сети и полносвязной сети [6] и входящую в состав нейросетевого программного анализатора термограмм. Обучение ИНС проводится на модельных термограммах, соответствующих различным отказам в приборе и хранящихся в базе знаний. В процессе контроля измеренные термограммы и электрические параметры поступают на нейронную сеть, классифицирующую техническое состояние прибора.

На рис. 1 показана схема контроля приборов с интеллектуальной ТСТД, где используются следующие обозначения:

ИС – измерительная система, включающая каналы для определения термограмм и измерения электрических параметров прибора;

СПР – система принятия решений о техническом обслуживании прибора по результатам работы нейронной сети;

U – техническое обслуживание прибора по результатам тепловизионного диагностирования технических состояний;

W – электрическая мощность, поступающая на входы прибора;

V – значения параметров, дополнительно измеряемых в контролируемом приборе;

$\Theta(x, y)$ – установившееся распределение температур на плоской грани прибора;

$\Gamma = (\gamma_1, \gamma_2, \dots, \gamma_k)$ – множество теплофизических и конструктивных параметров прибора, учитываемых при построении математической модели в виде уравнения теплопроводности

$$\frac{\partial \Theta}{\partial t} = a \nabla^2 \Theta + Q(x, y, t),$$

где ∇^2 – оператор Лапласа;

Z – формальная постановка задачи определения температурного поля выбранным численным методом;

$\Theta^M(x, y)$ – модельное распределение температур на грани прибора;
 $\{\Theta_j^M(x, y)\}$ – множество модельных термограмм в базе знаний, используемых при обучении ИНС, $j = \overline{1, J}$, J – объем обучающей выборки;
 V_j^M , $j = \overline{1, J}$ – модельные значения дополнительных параметров прибора;
 $\Theta_P^{ИЗМ}(x, y)$ – измеренная термограмма установившегося распределения температур, полученная с помощью измерительного канала, включающего в себя тепловизор;
 $V_P^{ИЗМ}$ – множество реально измеренных значений дополнительных параметров;
 D_0, D_1, \dots, D_K – выходы ИНС, соответствующие техническим состояниям прибора, при этом D_0 – работоспособное состояние, а остальные выходы – состояния неисправностей.

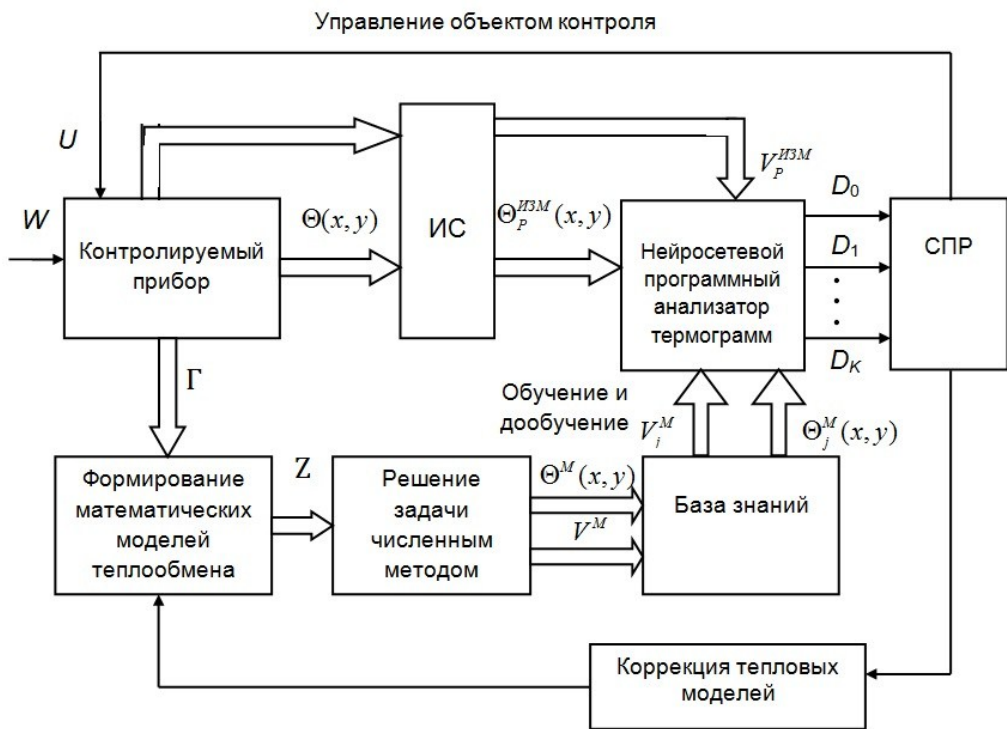


Рис. 1. Тепловизионная система с нейронной сетью для контроля приборов

Во время испытаний и текущего контроля приборов результаты работы нейронной сети фиксируются в базе знаний и в дальнейшем используются для коррекции параметров математических моделей теплообмена. Это позволяет уточнить модельные термограммы и повысить достоверность диагностики объектов.

Метрологическая модель измерительных каналов

Для иллюстрации подхода к анализу погрешностей в ИИС с нейронной сетью рассматривается интеллектуальная измерительная система диагностирования отказов в микросхеме матрицы ПЗС в оптико-электронном преобразователе [5]. Этот блок является основным в системе дистанционного зондирования Земли.

Структурная модель измерительных каналов для анализа технического состояния прибора по термограммам представлена на рис. 2.

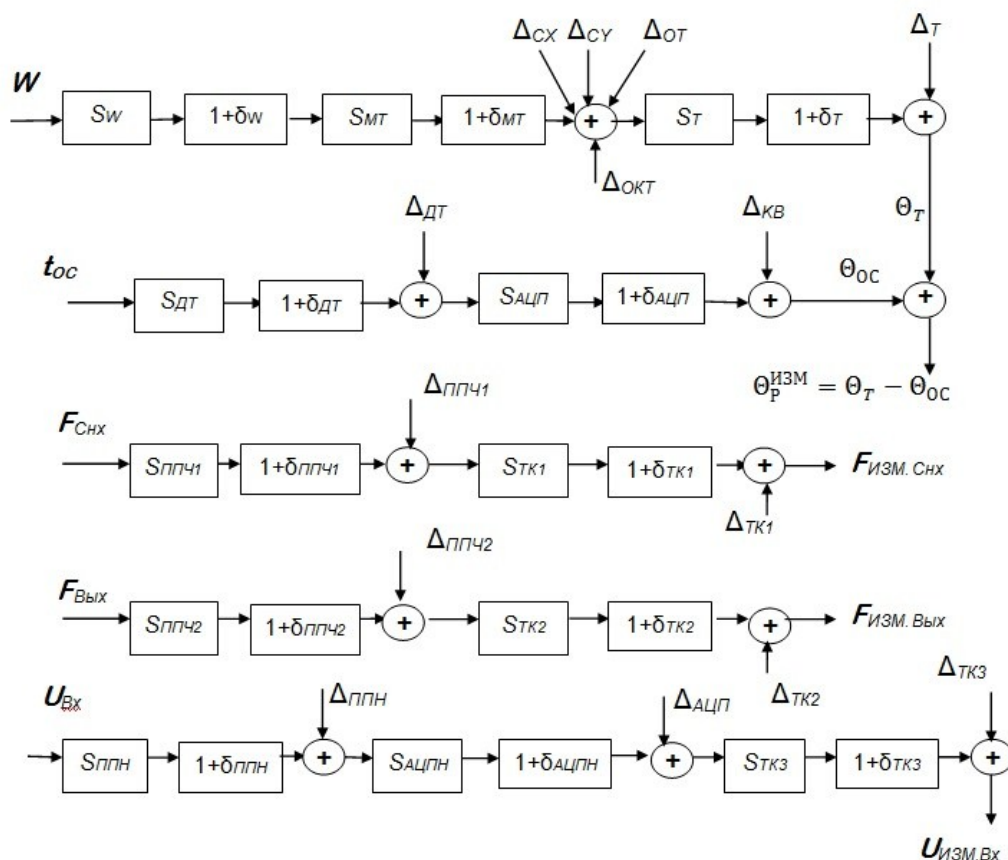


Рис. 2. Структурная модель измерительных каналов

Номинальная функция преобразования [12, 13] при измерении температурного поля равна

$$\Theta_{ИЗМ}^{НОМ}(x, y) = S_W S_{MT} S_T W - S_{DT} S_{АЦП} t_{OC}, \quad (1)$$

где S_W – функция преобразования электрической мощности W , поступающей на входы прибора, в двумерное температурное поле $\Theta(x, y)$ на контролируемой поверхности;

S_{MT} – чувствительность канала передачи температурного поля поверхности прибора на оптическую воспринимающую плоскость тепловизора;

S_T – чувствительность тепловизора;

S_{DT} – чувствительность первичного преобразователя датчика температуры t_{OC} окружающей среды;

$S_{АЦП}$ – чувствительность функции преобразования аналого-цифрового

преобразователя в канале измерения окружающей среды.

Первый измерительный канал с входным сигналом W осуществляет определение температурного поля $\Theta_T(x, y)$ поверхности прибора. Второй канал измеряет температуру окружающей среды t_{OC} для дальнейшего вычисления перегрева точек поверхности $\Theta_P^{ИЗМ}(x, y) = \Theta_T - \Theta_{OC}$.

Множество V дополнительно измеряемых параметров матрицы ПЗС содержит три компоненты: $F_{Снх}$ – частота синхронизирующих сигналов; $F_{Вых}$ – частота выходных сигналов; $U_{Вх}$ – напряжение входных управляющих сигналов.

Номинальные функции преобразования для компонент множества V :

$$F_{ИЗМ.Снх}^{НОМ} = S_{ППЧ1} S_{ТК1} F_{Снх}, \quad (2)$$

$$F_{ИЗМ.Вых}^{НОМ} = S_{ППЧ2} S_{ТК2} F_{Вых}, \quad (3)$$

$$U_{ИЗМ.Вх}^{НОМ} = S_{ППН} S_{АЦПН} S_{ТК3} U_{Вх}, \quad (4)$$

где $S_{ППЧ1}, S_{ППЧ2}, S_{ППН}$ – чувствительности первичных измерительных преобразователей ППЧ1 и ППЧ2 частот и входного напряжения управляющих сигналов ППН;

$S_{ТК1}, S_{ТК2}, S_{ТК3}$ – чувствительности телеметрических каналов передачи соответствующих измеряемых параметров;

$S_{АЦПН}$ – чувствительность функции преобразования аналого-цифрового преобразователя в канале измерения входного напряжения.

Реальные функции преобразования для модели на рис. 2 имеют вид:

а) измерение термограммы

$$\Theta_P^{ИЗМ}(x, y) = S_T (1 + \delta_T) \{ (\Delta_{СХ} + \Delta_{СУ} + \Delta_{ОТ} + \Delta_{ОКТ} + S_{MT} S_W (1 + \delta_{MT}) (1 + \delta_W) W \} + \Delta_T - S_{АЦП} (1 + \delta_{АЦП}) (S_{ДТ} (1 + \delta_{ДТ}) t_{OC} + \Delta_{ДТ}) - \Delta_{КВ}, \quad (5)$$

б) измерение частотных сигналов

$$F_{ИЗМ.Снх} = S_{ТК1} (1 + \delta_{ТК1}) (\Delta_{ППЧ1} + S_{ППЧ1} (1 + \delta_{ППЧ1}) F_{Снх}) + \Delta_{ТК1} \quad (6)$$

$$F_{ИЗМ.Вых} = S_{ТК2} (1 + \delta_{ТК2}) (\Delta_{ППЧ2} + S_{ППЧ2} (1 + \delta_{ППЧ2}) F_{Вых}) + \Delta_{ТК2}, \quad (7)$$

в) измерение амплитуды напряжения входных сигналов

$$U_{ИЗМ.Вх} = S_{ТК3} (1 + \delta_{ТК3}) (S_{АЦПН} (1 + \Delta_{АЦПН}) (S_{ППН} (1 + \delta_{ППН}) U_{Вх} + \Delta_{ППН}) + \Delta_{АЦП}) + \Delta_{ТК3}. \quad (8)$$

Анализ погрешностей ТСТД

Погрешности, входящие в выражения (5) – (8), сведены в табл. 1 и 2.

Таблица 1

Мультипликативные погрешности, учитываемые в структурной модели

Номер уравнения	Условное обозначение	Описание мультипликативной погрешности
5	δ_W	Погрешность, вызванная изменением электрических, теплофизических и конструктивных параметров при изготовлении серии микросхем

Номер уравнения	Условное обозначение	Описание мультипликативной погрешности
5	δ_{MT}	Погрешность чувствительности канала передачи термограммы на оптическую плоскость матрицы тепловизора
5	δ_T	Мультипликативная погрешность тепловизора
5	δ_{DT}	Погрешность первичного преобразователя датчика температуры окружающей среды
5	$\delta_{АЦП}$	Мультипликативная погрешность преобразования аналог – код в АЦП
6	$\delta_{ППЧ1}$	Погрешность первичного преобразователя измерения частоты синхронизирующих сигналов
6	δ_{TK1}	Погрешность канала передачи телеметрической информации о частоте синхронизирующих сигналов
7	$\delta_{ППЧ2}$	Погрешность первичного преобразователя измерения частоты выходных сигналов
7	δ_{TK2}	Погрешность канала передачи телеметрической информации о частоте выходных сигналов
8	$\delta_{ППН}$	Погрешность первичного преобразователя измерения входных управляющих сигналов
8	$\delta_{АЦПН}$	Мультипликативная погрешность преобразования напряжения в код в АЦП
8	δ_{TK3}	Погрешность канала передачи телеметрической информации об амплитуде входных управляющих сигналов

Таблица 2

Аддитивные погрешности, учитываемые в структурной модели

Номер уравнения	Условное обозначение	Описание аддитивной погрешности
5	Δ_{CX}, Δ_{CY}	Погрешности установки тепловизора, которые определяются горизонтальными смещениями относительно центральной оптической оси, перпендикулярной поверхности контролируемого прибора
5	Δ_{OT}	Погрешность, вызванная угловым отклонением оптической оси тепловизора от поверхности контролируемого прибора
5	Δ_{OKT}	Погрешность, вызванная отраженной кажущейся температурой других объектов
5	Δ_T	Аддитивная погрешность тепловизора
5	Δ_{DT}	Погрешность первичного преобразователя датчика температуры окружающей среды
5	Δ_{KB}	Погрешность квантования, определяемая разрядностью АЦП
6	$\Delta_{ППЧ1}$	Аддитивная погрешность измерения частоты $F_{Снх}$
6	Δ_{TK1}	Погрешность телеметрического канала частоты синхронизи-

Номер уравнения	Условное обозначение	Описание аддитивной погрешности
		рующих сигналов
7	$\Delta_{ППЧ2}$	Аддитивная погрешность измерения частоты $F_{Вых}$
7	$\Delta_{ТК2}$	Погрешность телеметрического канала частоты выходных сигналов
8	$\Delta_{ППН}$	Аддитивная погрешность измерения амплитуды входных управляющих сигналов
8	$\Delta_{АЦП}$	Погрешность квантования АЦП
8	$\Delta_{ТК3}$	Погрешность телеметрического канала напряжений входных управляющих сигналов

Погрешность измерения термограммы поверхности контролируемого прибора равна

$$\Delta\Theta = \Theta_P^{ИЗМ} - \Theta_{ИЗМ}^{НОМ},$$

и подставляя сюда выражения (1) и (5), получаем

$$\begin{aligned} \Delta\Theta = & (\delta_W + \delta_{MT} + \delta_T)S_W S_{MT} S_T W + (\delta_{ДТ} + \delta_{АЦП})S_{ДТ} S_{АЦП} t_{OC} + \\ & + S_T (\Delta_{CX} + \Delta_{CY} + \Delta_{OT} + \Delta_{ОКТ}) - S_{АЦП} \Delta_{ДТ} - \Delta_T - \Delta_{KB}, \end{aligned} \quad (9)$$

при этом погрешности считаются скалярными величинами, а их произведения – приближенно равными нулю.

Из выражения (9) следует, что мультипликативная погрешность измерения термограмм определяется как

$$\delta\Theta_{ИЗМ}^M = (\delta_W + \delta_{MT} + \delta_T)S_W S_{MT} S_T W + (\delta_{ДТ} + \delta_{АЦП})S_{ДТ} S_{АЦП} t_{OC}. \quad (10)$$

Соответственно аддитивная погрешность равна

$$\Delta\Theta_{ИЗМ}^A = S_T (\Delta_{CX} + \Delta_{CY} + \Delta_{OT} + \Delta_{ОКТ}) - S_{АЦП} \Delta_{ДТ} - \Delta_T - \Delta_{KB}. \quad (11)$$

Погрешности измерения частотных сигналов прибора:

$$\Delta F_{Сих} = F_{ИЗМ.Сих} - F_{ИЗМ.Сих}^{НОМ} \quad (12)$$

$$\Delta F_{Вых} = F_{ИЗМ.Вых} - F_{ИЗМ.Вых}^{НОМ}. \quad (13)$$

Выполняя аналогичные подстановки выражений (2) и (6) в (12); (3) и (7) в (13), получаем мультипликативные погрешности измерений

$$\delta F_{ИЗМ.Сих}^M = (\delta_{ППЧ1} + \delta_{ТК1})S_{ТК1} S_{ППЧ1} F_{Сих}$$

$$\delta F_{ИЗМ.Вых}^M = (\delta_{ППЧ2} + \delta_{ТК2})S_{ТК2} S_{ППЧ2} F_{Вых}$$

и аддитивные погрешности

$$\Delta F_{ИЗМ.Сих}^A = S_{ТК1} \Delta_{ППЧ1} + \Delta_{ТК1}$$

$$\Delta F_{ИЗМ.Вых}^A = S_{ТК2} \Delta_{ППЧ2} + \Delta_{ТК2}.$$

Погрешность измерения амплитуд входных управляющих сигналов U_{Bx} определяется аналогичным образом. Соответственно мультипликативная составляющая погрешности

$$\delta U_{ИЗМ.Bx}^M = (\delta_{ППН} + \delta_{АЦПН} + \delta_{ТКЗ}) S_{ТКЗ} S_{АЦПН} S_{ППН} U_{Bx}$$

и аддитивная составляющая равна

$$\Delta U_{ИЗМ.Bx}^A = S_{ТКЗ} S_{АЦПН} \Delta_{ППН} + S_{ТКЗ} \Delta_{АЦП} + \Delta_{ТКЗ} \quad .$$

Анализ методической погрешности канала с нейронной сетью

Использование расчетных термограмм при обучении ИНС вместо большого множества реальных термограмм приводит к методической погрешности Δ_M определения технического состояния объекта. Основными факторами, влияющими на величину Δ_M , являются:

- погрешность модели вычислительного метода решения нестационарного уравнения теплопроводности, а также погрешности дискретизации и округления;
- разброс теплофизических параметров прибора;
- вариативность геометрических параметров прибора;
- влияние архитектуры нейронной сети;
- влияние характера данных, обрабатываемых нейронной сетью;
- выбор способа и параметров обучения нейронной сети.

Структурная модель канала с двухветвенной нейронной сетью для формирования модельных термограмм, в которой учтены методические погрешности, представлена на рис. 3.

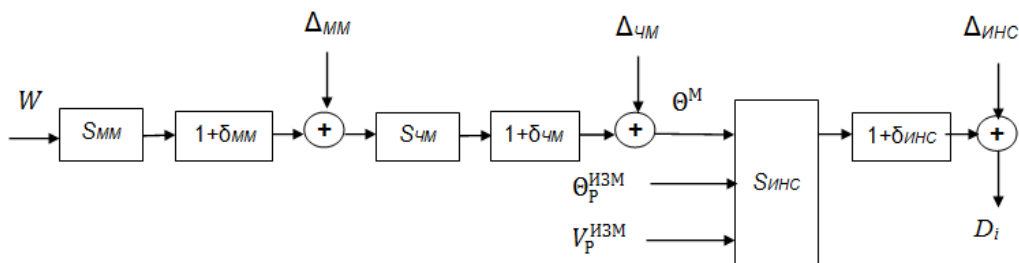


Рис. 3. Структурная модель канала с ИНС

Поскольку модельные термограммы получены путем решения нестационарного уравнения теплопроводности методом трехдиагональной прогонки, при анализе будем рассматривать составляющие методической погрешности, которые сведены в табл. 3.

В метрологической модели приняты следующие обозначения: $S_{MM} = S_\lambda S_\rho S_c S_\alpha S_\varepsilon$ – функция преобразования в математической модели параметров прибора в тепловое состояние, зависящая от значений теплофизических параметров прибора; $S_{ЧМ}$ – функция преобразования в численном методе решения уравнения теплопроводности; $S_{ИНС}$ – функция преобразования двухветвенной ИНС; δ_{MM} , $\delta_{ЧМ}$, $\delta_{ИНС}$, Δ_{MM} , $\Delta_{ЧМ}$, $\Delta_{ИНС}$ – мультипликативные и аддитивные погрешности соответственно математической модели, численного метода и искусственной нейронной сети.

Компоненты методической погрешности

Условное обозначение	Описание погрешности
<i>Аддитивные составляющие погрешности $\Delta_{чМ}$</i>	
Δ_{τ}	Погрешность от шага по времени τ
$\Delta_{дс}$	Погрешности дискретизации
$\Delta_{о}$	Погрешность округления
Δ_h	Погрешность от шага h по сетке разностной модели
<i>Мультипликативные составляющие погрешности $\delta_{ММ}$</i>	
δ_{λ}	Мультипликативная погрешность неоднородности теплопроводности материала или отличия принятого при расчете значения λ от реального
δ_{ρ}	Мультипликативная погрешность неоднородности плотности ρ материала
δ_c	Мультипликативная погрешность неоднородности удельной теплоемкости c материала
δ_{α}	Мультипликативная погрешность от различия коэффициента конвективного теплообмена α по поверхности прибора
δ_{ϵ}	Мультипликативная погрешность от различия коэффициента теплового излучения ϵ по поверхности прибора
<i>Составляющие общей аддитивной погрешности $\Delta_{ММ}$</i>	
$\Delta_{Qx}, \Delta_{Qy}, \Delta_{Qz}$	Погрешности смещения реальных координат источника с мощностью $Q(x,y,z)$ от расчетного источника с координатами $Q(x_0,y_0,z_0)$ при численном решении уравнения теплопроводности

Используя вышеописанный подход, можно найти общее выражение для методической погрешности канала определения Θ^M , включающего математическую модель и численный метод решения:

$$\Delta\Theta^M = (\delta_{\lambda} + \delta_{\rho} + \delta_c + \delta_{\alpha} + \delta_{\epsilon} + \delta_{чМ})S_{\lambda}S_{\rho}S_cS_{\alpha}S_{\epsilon}S_{чМ}W + (\Delta_{Qx} + \Delta_{Qy} + \Delta_{Qz})S_{чМ} + \Delta_h + \Delta_{\tau} + \Delta_{дс} + \Delta_{о}. \quad (14)$$

Из выражения (14) далее можно получить формулы для мультипликативной и аддитивной составляющих методической погрешности.

Проблема возникает с определением погрешностей, вызываемых использованием ИНС, поскольку в настоящий момент нет общепринятых методик для их оценки. Известные работы не дают расчетных методик и ограничиваются общими рассуждениями о природе методической погрешности ИНС [14, 15]. В работе [14] предлагается считать погрешность, вносимую аппаратным обеспечением, выполняющим программную логику ИНС, пренебрежимо малой величиной по сравнению с погрешностью, обусловленной качеством обучения и выбранной архитектурой ИНС. Аналогичное допущение сделано и в настоящей статье.

Одним из важных факторов, влияющих на точность классификации в ИНС, является соответствие ее архитектуры выполняемой задаче. На сегодняшний день известно несколько модификаций ИНС, каждая из которых в той или иной степени подходит для решения какой-либо отдельно взятой категории задач [16–

18]. Формального критерия применимости некоторой модификации ИНС для обработки тех или иных данных, к сожалению, нет. Систематизируя экспериментальные данные, накопленные в различных публикациях, можно сформулировать определенные критерии применимости некоторых типов ИНС, наиболее хорошо показавших себя при решении определенной группы задач.

Для рассматриваемой задачи анализа термограмм примером учета влияния архитектуры ИНС на получаемую точность классификации является выбор конволюционной нейронной сети вместо полносвязной. Известен ряд особенностей конволюционных нейронных сетей, которые делают их более производительными в ряде задач, связанных с обработкой изображений [16, 19]. Конволюционные нейронные сети дают более устойчивые результаты при классификации изображений, подвергнутых аффинным преобразованиям. Этого нельзя сказать про полносвязанные нейронные сети. Этот аспект подтверждается следующим экспериментом, проведенным автором.

Полносвязная ИНС была обучена на некоторой выборке термограмм. Затем эти термограммы были подвергнуты аффинным преобразованиям, в частности повороту на незначительный угол (5–10 градусов). При попытке классифицировать новые термограммы с помощью полносвязной ИНС было получено значительное уменьшение доли точных классификаций. В этом случае разница между количеством точных классификаций, выполненных конволюционной ИНС, и полносвязной сетью интерпретировалась как методическая погрешность влияния архитектуры, связанная с применением полносвязной ИНС для решения задач классификации термограмм.

Как отмечается в [4], при машинном обучении вид используемых данных так же важен, как и алгоритм, применяемый для их обобщения. Как известно, набор данных характеризуют понятием зашумленности [19]. В нашем случае под шумом понимается наличие какой-либо области в пространстве обучающей или тестовой выборки, где представлены образцы нескольких классов, неразделимых прямой (общем случае гиперплоскостью в n -мерном пространстве). Пример подобного шума изображен на рис. 4 для случая двумерного пространства. На данном рисунке каждой точке на диаграмме соответствует один элемент выборки данных. Случайные сигналы шума на термограммах могут быть исследованы с помощью методики оценки амплитудного спектра и корреляционных функций, описанной в работах [20, 21].

Расположение точки обуславливается значением атрибутов, характеризующих данный элемент выборки, а число измерений пространства соответствует числу атрибутов, которыми характеризуется каждый элемент. Двумерное пространство приведено в качестве примера, но аналогичное утверждение справедливо в общем случае для n -мерного пространства и разделяющей гиперплоскости.

Анализируя данные в выборке, можно определить долю образцов выборки, находящихся в подобных областях. Это позволяет приблизительно оценить порог точности работы ИНС, обученной на этой выборке, т. к. образцы, представляющие собой шум, скорее всего будут вносить ошибку в работу сети. Это служит основанием для приводимых далее формул, позволяющих выполнить приблизительную количественную оценку минимально возможной методической погрешности ИНС, обученной на рассматриваемой выборке.




Рис. 4. Примеры распределения классифицируемых данных в пространстве обучающей или тестовой выборки:

- а) разделение классифицируемых данных с погрешностью;
 б) точное разделение классифицируемых данных

Для оценки выборки и выделения отдельных зашумленных областей применялся метод снижения размерности исследуемого признакового пространства Dimensionality reduction [19].

Оценка относительной методической погрешности δ_d , вызываемой зашумленностью данных, равна

$$\delta_d = \frac{N_m}{N},$$

где N_m – выделенное число элементов обучающей выборки, находящихся в зашумленной области;

N – общее число элементов обучающей выборки.

Методическая погрешность, вызываемая влиянием структуры ИНС и качеством обучения, может оцениваться разными способами. Как уже отмечалось выше, можно сопоставлять точность нейронной сети путем сравнения с точностью какой-либо широко известной сети. Так часто поступают на практике в публикациях, описывающих какую-либо новую ИНС [16, 18, 19].

Альтернативно можно выполнить сравнение доли ошибочных классификаций нейронной сети со значением зашумленности данных, полученных при их статистическом анализе. Заранее предполагается, что ИНС будет ошибочно классифицировать данные, принадлежащие зашумленной этой части выборки. Таким образом, получаем меру приближенности точности ИНС к максимально возможной на рассматриваемой выборке.

Суммарная методическая погрешность, вносимая структурой ИНС и качеством обучения, оценивается по формуле:

$$\delta_{ст} + \delta_{об} \leq \delta_T - \delta_d, \quad \delta_T > \delta_d,$$

где $\delta_{об}$ – методическая погрешность, вносимая качеством обучения ИНС;
 δ_T – погрешность ИНС, оцененная на тестовой выборке.

Если будет получено $\delta_T < \delta_d$, это может быть признаком допущенных ошибок в эксперименте. Например, тестовая выборка была составлена нерепрезентативно.

Относительная погрешность ИНС, оцененная на тестовой выборке, определяется из соотношения

$$\delta_T = \frac{P_e}{P},$$

где P_e – число ошибочно выполненных классификаций ИНС;
 P – суммарное число выполненных классификаций ИНС, равное числу элементов тестовой выборки.

Описанный подход был применен для оценки погрешности классификации отказов, выполняемой конволюционной ИНС при обработке термограмм электронного прибора.

Экспериментальные результаты

При экспериментальной проверке разработанной ТСТД использовалось следующее оборудование: тепловизор FLIR E6, имеющий основную погрешность 0,06 °С, многофункциональный прибор Metrel MI 6401Poly с погрешностью измерения температуры окружающей среды ±0,2 °С и цифровой осциллограф GDS 2104. Двухветвенная ИНС построена на основе архитектуры, описанной в работе [17], а также включает в себя некоторые эвристики, предложенные в работах [18, 23]. Программная реализация ИНС выполнена на языке С# и содержит конволюционную сеть с 8573 нейронами в трех конволюционных слоях главной ветви и полносвязную сеть с 6 нейронами в одном слое во вспомогательной ветви. Нейронная сеть обучалась на выборке из 250 термограмм в течение 300 эпох с темпом обучения 0,00005.

В описываемых экспериментах сравнение проводилось на обучающей выборке, составленной из модельных термограмм. Это связано с тем, что использование каких-либо термограмм, снятых с реальных приборов, невольно закладывало бы неявным образом особенности работы тех приборов, которые использовались при формировании данной обучающей выборки. Это не совсем корректно, т. к. различность, которая была зафиксирована в ходе экспериментов при работе даже двух приборов одной модели, не должна вносить свой вклад в обучение ИНС. Это послужило мотивацией для формирования обучающей выборки из модельных термограмм, полученных на основе математической модели распределения температуры по поверхности прибора, находящемся в том или ином состоянии (режим работоспособности или один из возможных отказов). Верификация таких модельных термограмм осуществлялась путем их сопоставления с реальными термограммами, снятыми с приборов.

Примеры термограмм контролируемого прибора приведены на рис. 5.

Методическая погрешность, обусловленная наличием шума в данных, равна нулю, поскольку построенные модельные термограммы в рассматриваемой задаче делимы гиперплоскостью и не содержат зашумленных областей. Это можно видеть на примере трех классов термограмм, соответствующих трем типам дефектов в приборе. Для трех классов термограмм на рис. 6 приведена диаграмма главных компонент PCA, а на рис. 7 – диаграмма, построенная методом многомерного шкалирования [22].

Погрешность ИНС на тестовой выборке составила 2 %, так как при проверке работоспособности ИНС было получено 98 % точных классификаций. С учетом инструментальной погрешности измерительных каналов, равной 0,5 %, общая погрешность диагностирования состояний с помощью ТСТД не превысила 2,5 %.




Рис. 5. Термограммы поверхности прибора при различных технических состояниях:
а, в – термограммы работоспособных состояний;
б, г – термограммы при неисправностях в приборе

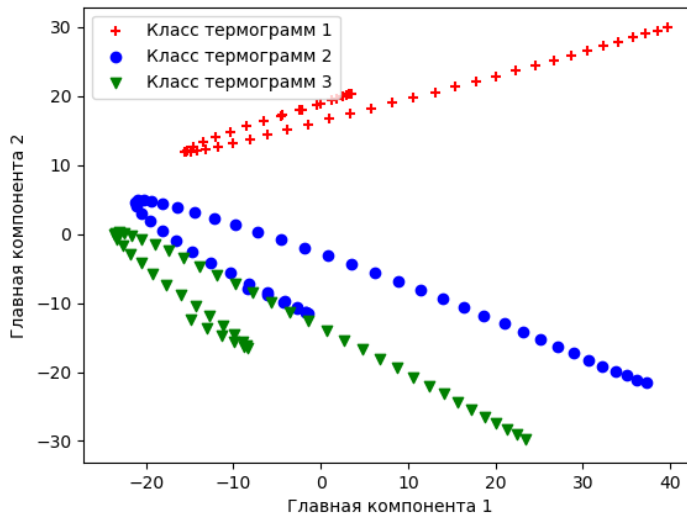


Рис. 6. Диаграмма главных компонент для трех классов термограмм

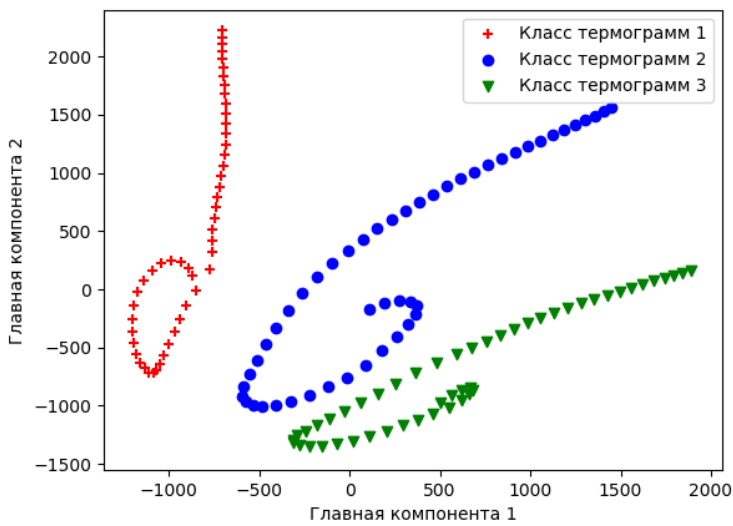


Рис. 7. Диаграмма, построенная методом многомерного шкалирования для трех классов термограмм

Заключение

Проведенный в статье метрологический анализ позволяет оценивать не только погрешности средств измерительной техники, но и методические погрешности, вносимые искусственной нейронной сетью в процесс контроля технических состояний объектов. Выполненная структуризация измерительных каналов позволила определить выражения для расчета аддитивных и мультипликативных погрешностей измерительных каналов ИИС. Предложена методика интерпретации методической погрешности ИИС и формулы для количественной оценки ее составляющих. Предложенные решения были апробированы в экспериментах по диагностированию с помощью ИИС микросхемы матрицы ПЗС в оптико-электронном преобразователе.

Данная методика контроля, основанная на термограммах объектов, может использоваться и в других приложениях, где необходимо классифицировать сложные образы технических состояний объектов при дистанционном контроле.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Селиванова З.М. Интеллектуализация информационно-измерительных систем неразрушающего контроля теплофизических свойств твердых материалов. – М.: Машиностроение-1, 2006. – 184 с.
2. Харисова З.И. Информационно-измерительная система для гранулометрического анализа жидких дисперсных сред на основе видеотехнических средств и нейросетевых технологий: автореф. дис. ... канд. техн. наук. – Уфа, 2018. – 21 с.
3. *Rassell S., Norvig P.* Artificial Intelligence: A Modern Approach, 3rd Edition. – Pearson Education, 2010. – 1095 p.
4. Яхьяева Г. Нечеткие множества и нейронные сети. – М.: Национальный открытый университет «ИНТУИТ», 2016. – 187 с.
5. Комарцова Л.Г., Максимов А.В. Нейрокомпьютеры. – М.: МГТУ им. Н.Э. Баумана, 2004. – 400 с.
6. *Orlov S.P., Vasilchenko A.N.* Intelligent measuring system for testing and failure analysis of electronic devices // 2016 XIX IEEE International Conference on Soft Computing and Measurements (SCM). – IEEE Conference Publications. – 2016. – V. 1. – P. 401–403.
7. Орлов С.П., Гурин Р.В. Интеллектуализация контроля и диагностики электронных приборов на основе нейронных сетей // XXI Международная конференция по мягким вычислениям и измерениям (SCM-2018). Сборник докладов. – СПб.: СПб ГЭТУ «ЛЭТИ». – Т. 2. – 2018. – С. 99–102.
8. Орлов С.П., Гурин Р.В., Уютова О.Ю. Интеллектуализация информационно-измерительных систем контроля и диагностирования на основе нейросетевых технологий // Мягкие измерения и вычисления. – 2018. – Вып. 4. – С. 4–12.
9. ГОСТ Р ИСО 18434-1-2013. Контроль состояния и диагностика машин. Термография. Ч. 1. Общие методы. – М.: Стандартинформ, 2014. – 28 с.
10. ГОСТ Р ИСО 13372-2013. Контроль состояния и диагностика машин. Термины и определения. – М.: Стандартинформ, 2014. – 21 с.
11. ГОСТ Р 8.596-2002. Государственная система обеспечения единства измерений (ГСИ). Метрологическое обеспечение измерительных систем. Основные положения. – М.: ИПК Издательство стандартов, 2002. – 15 с.
12. МИ 222-80. Методика расчета метрологических характеристик измерительных каналов информационно-измерительных систем по метрологическим характеристикам компонентов. – М.: Издательство стандартов, 2005. – 24 с.
13. Шлыков Г.П. Теория измерений: уравнения, модели, оценивание точности: учеб. пособие. – Пенза: Изд-во Пенз. гос. ун-та, 2008. – 100 с.
14. Дружинина Л.В., Дружинин Д.Г. Анализ и классификация погрешностей обучения информационно-измерительных систем на базе нейронных сетей // Молодой ученый. – 2016. – № 21 (125). – С. 127–129.
15. *Szegedy C., Liu W., Jia Y., Sermanet P., Reed S.E., Anguelov D., Erhan D., Vanhoucke V., Rabinovich A.* Going deeper with convolutions, IEEE Conference on Computer Vision and Pattern Recog-

16. *Nielsen M.* Neural Networks and Deep Learning, free online book. 2017 [Электронный ресурс]. – Режим доступа: <http://neuralnetworksanddeeplearning.com> (дата обращения – 27.09.2018).
17. *LeCun Y., Bottou L., Bengio Y., Haffner P.* Gradient-based learning applied to document recognition // Proceedings of the IEEE. – 1998. – Vol. 86. – Issue 11. – P. 2278–2324.
18. *Krizhevsky A., Sutskever I., Hinton G.* ImageNet classification with deep convolutional neural networks // NIPS'12 Proceedings of the 25th International Conference on Neural Information Processing Systems. 2012, Vol. 1. p. 1097–1105.
19. *Goodfellow I., Bengio Y., Courville Y.* Deep learning [Электронный ресурс]. – Режим доступа: <http://www.deeplearningbook.org> (дата обращения – 25.09.2018).
20. *Якимов В.Н., Горбачев О.В.* Программно-аппаратное обеспечение системы оценки амплитудного спектра многокомпонентных процессов // Приборы и техника эксперимента. – 2013. – № 5. – С. 49–55.
21. *Якимов В.Н., Машков А.В.* Цифровое оценивание моментов корреляционной функции на основе знакового аналого-стохастического квантования случайного процесса // Измерительная техника. – 2016. – № 1. – С. 11–13.
22. *Айвазян С.А., Мхитарян В.С.* Прикладная статистика. Основы эконометрики: 2-е изд. – М.: Юнити, 2001. – 656 с.
23. *Nair V., Hinton G.* Rectified Linear Units Improve Restricted Boltzmann Machines // Proceedings of ICML. – 2010. – V. 27. – P. 807–814.

Статья поступила в редакцию 10 сентября 2018 г.

ANALYSIS OF METROLOGICAL CHARACTERISTICS OF THE THERMOVISION TECHNICAL DIAGNOSIS SYSTEM CONTAINING A NEURAL NETWORK

R.V. Girin

Samara State Technical University
244, Molodogvardeyskaya st., Samara, 443100, Russian Federation

Abstract. *The paper deals with the problem of determining the errors of the thermovision system of the electronic devices technical diagnostics using a neural network. The structure of the system is described, including measuring channels with a thermal imager, an external thermometer, a block of computational models of thermal states, a knowledge base and a software neural network thermogram analyzer. It is proposed to use for the analysis of device states the two-branch network consisting of the multilayer convolutional neural network and the fully connected network. A metrological model of measuring channels has been built. A classification of the components of the instrumental error is given and expressions for the multiplicative and additive components of the instrumental error are obtained. Particular attention is paid to the analysis of the methodological error caused by the use of an artificial neural network in the classification of failures in the device. Experimental studies were performed that confirmed the effectiveness of the proposed methodological and technical solutions.*

Keywords: *artificial neural networks, error analysis, technical diagnostics, thermal imager, infrared thermography.*

REFERENCES

1. *Selivanova Z.M.* Intellectualization of information-measuring systems for non-destructive testing of the thermophysical properties of solid materials . – M.: Mashinostroenie Publ., 2006. – 184 p.
2. *Kharisova Z.I.* Information-measuring system for granulometric analysis of liquid dispersion substances based on video equipment and neural network technologies: avtoref. diss. kand. techn. sci. ence. Ufa, 2018. – 21 p.
3. *Russell S., Norvig P.* Artificial intelligence: A Modern Approach, 3rd Edition. – Pearson Education, 2010. – 1095 p.
4. *Iakhieiaeva G.* Fuzzy sets and neural networks. – M.: INTUIT, 2016. – 187 p.
5. *Komartsova L.G., Maksimov A.V.* Neurocomputers. – M.: MGTU im. N.E Bauman, 2004. – 400 p.
6. *Orlov S.P., Vasilchenko A.N.* Intelligent measuring system for testing and failure analysis of electronic devices // 2016 XIX IEEE International Conference on Soft Computing and Measurements (SCM). – IEEE Conference Publications. – 2016. – V. 1. – P. 401–403.
7. *Orlov S.P., Girin R.V.* Intellectualization to failure analysis and diagnostics of electronic devices using neural networks // Proc. XXI International conf. SCM'2018. – Saint-Petersburg: SPbGTU 'LETI'. – V. 2. – 2018. – P. 99–102.
8. *Orlov S.P., Girin R.V., Uyutova O.Yu.* Intellectualization of information-measuring systems for monitoring and diagnostics based on neural network technologies // Soft Measurements and Computing. – 2018. – V. 4. – P. 4–12.
9. GOST R ISO 18434-1-2013. Condition monitoring and diagnostics of machines. Thermography. Part 1. General methods. – M.: Standartinform, 2014. – 28 p.
10. GOST R ISO 13372. Condition monitoring and diagnostics of machines. Terms and Definitions. – M.: Standartinform, 2014. – 21 p.
11. GOST 8.596-2002. State system for ensuring the uniformity of measurements (GSI). Metrological assurance of measuring systems. The main provisions. – M.: Izdatelstvo standartov, 2002.
12. MI 222-80. The technique of calculating the metrological characteristics of measuring channels of information-measuring systems using the metrological characteristics of the components. – M.: Izdatelstvo standartov, 2005.
13. *Shlykov G.P.* Measurement theory: equations, models, accuracy estimation. – Penza, Izdatelstvo PGU, 2008. – 100 p.
14. *Druzhinina L.V., Druzhinin D.G.* Analysis and classification of learning errors of information-measuring systems based on neural networks // Young Scientist. – 2016. – V. 21(125). – P. 127–129.
15. *Szegedy C., Liu W., Jia Y., Sermanet P., Reed S.E., Anguelov D., Erhan D., Vanhoucke V., Rabino-vich A.* Going deeper with convolutions // IEEE Conference on Computer Vision and Pattern Recognition (CVPR). – 2015. – P. 1–9.
16. *Nielsen M.* Neural Networks and Deep Learning, free online book. 2017. – URL: <http://neuralnetworksanddeeplearning.com>
17. *LeCun Y., Bottou L., Bengio Y., Haffner P.* Gradient-based learning applied to document recognition // Proceedings of the IEEE. – 1998. – Vol. 86. – Issue 11. – P. 2278–2324.
18. *Krizhevsky A., Sutskever I., Hinton G.* ImageNet classification with deep convolutional neural networks // NIPS'12 Proceedings of the 25th International Conference on Neural Information Processing Systems. 2012, Vol. 1. p. 1097–1105.
19. *Goodfellow I., Bengio Y., Courville Y.* Deep learning. – URL: <http://www.deeplearningbook.org/>
20. *Iakimov V.N., Gorbachev O.V.* Software and hardware system for estimating the amplitude spectrum of multicomponent processes // Instruments and Experimental Technique. – 2013. – № 5. – P. 49–55.
21. *Iakimov V.N., Mashkov A.V.* Digital estimation of the moments of the correlation function based on the sign analogue-stochastic quantization of a random process // Measuring Technique. – 2016. – № 1. – P. 11–13.
22. *Ivazian S.A., Mkhitarian V.S.* Probability theory and applied statistics. Basics of econometrics. 2^d edit. – M.: Uniti, 2001. – 656 p.
23. *Nair V., Hinton G.* Rectified linear units improve restricted Boltzmann machines // Proceedings of ICML. – 2010. – V. 27. – P. 807–814.