

## СОЧЕТАНИЕ ВРУЧНУЮ ПОСТРОЕННЫХ ПРИЗНАКОВ И ПРИЗНАКОВ ГЛУБОКИХ СЕТЕЙ ДЛЯ АВТОМАТИЧЕСКОГО ОБНАРУЖЕНИЯ ДЕФЕКТОВ В ПРОЦЕССЕ ВИЗУАЛИЗАЦИИ КВАДРАТИЧНОЙ ЧАСТОТНО-МОДУЛИРОВАННОЙ ТЕПЛОВОЙ ВОЛНЫ

© 2021 г. Г.Т. Весала<sup>1,\*</sup>, В.С. Гали<sup>1</sup>, А. Виджая Лакшми<sup>1</sup>, Р.Б. Найк<sup>2</sup>

<sup>1</sup>Центр инфракрасной визуализации, Образовательный фонд Конеру Лакшмайя, Ваддесварам, Андхра-Прадеш, Индия.

<sup>2</sup>Военно-морская исследовательская лаборатория материаловедения, Амбернат, округ Тхане, Махараштра, Индия

\*E-mail: gopitilak7@gmail.com

Поступила в редакцию 27.02.2021; после доработки 26.03.2021

Принята к публикации 02.04.2021

Последние достижения в области неразрушающего контроля и оценки надежности в совокупности с машинным обучением, искусственным интеллектом и интернетом вещей как ключевых инструментов идеи об индустрией 4.0 достигли четвертой промышленной революции. Тем не менее активная термография (АТ) — это бесконтактный, безопасный, экономичный и широко используемый метод неразрушающего контроля для поиска подземных аномалий. При АТ автоматическое обнаружение дефектов подразумевает локализацию объекта и семантическую сегментацию термограммах. В этой статье представлена сеть объединения признаков, которая соединяет глобальные признаки, полученные с помощью глубокой нейронной сети (ГНС), с глубокими признаками, полученными с помощью сверточной нейронной сети (СНС). Набор вручную построенных статистических и частотных характеристик тепловых профилей во временной области передается подсети ГНС, тогда как подсеть СНС получает тепловые профили в сети объединения признаков. Эксперименты проводились на образце армированного углеродным волокном полимера (углеполимера) с просверленными отверстиями с плоским дном, возбуждаемым квадратично-частотно-модулированным оптическим импульсом. Экспериментальные результаты показали, что объединение признаков улучшило возможность обнаружения дефектов по сравнению с локальными сетями за счет значительного увеличения отношения сигнал / шум, точности и F-меры.

*Ключевые слова:* NDT 4.0, визуализация квадратичной частотно-модулированной тепловой волны, объединение признаков, 1D-СНС, ГНС, признаки во временной и частотной областях, полимер, армированный углеродным волокном.

**DOI:** 10.31857/S0130308221060051

### ВВЕДЕНИЕ

Компьютерная автоматизация в недавнем прошлом позволила отрасли производить продукцию по индивидуальному заказу с высоким качеством и надежностью. Цифровизация, искусственный интеллект и интернет вещей стали ключевыми движущими силами нынешней промышленной революции, индустрии 4.0. Однако для специализированных изделий требуется оценка качества и анализ целостности с помощью неразрушающего контроля (НК) без нарушения их будущей функциональности. Тем не менее неразрушающий контроль, как область знаний и набор методик, эволюционировал вместе с индустриализацией — от использования только органов чувств к цифровизации и созданию сетей. NDT 4.0 — это настоящая революция в области неразрушающего контроля, основанная на искусственном интеллекте, машинном обучении, 5G и квантовых технологиях [1].

Но возможности бесконтактного, безопасного и экономичного контроля позволяет рекомендовать активную инфракрасную термографию (АТ) как хорошо известный и широко распространенный метод неразрушающего контроля, при котором анализируется тепловая карта исследуемого образца в условиях внешнего воздействия. Возбуждение с высокой пиковой мощностью в течение короткого времени при импульсной термографии (ИТ) [2] и периодическое возбуждение с низкой пиковой мощностью в течение длительного времени при синхронной термографии (СТ) [3] являются традиционными и широко используемыми механизмами стимуляции при ИКТ. Благодаря комбинации импульсного воздействия при ИТ и фазовой обработки при СТ, к традиционным подходам АТ позже была причислена импульсная фазовая термография (ИФТ) [4]. В последние два десятилетия при визуализации частотно-модулированной тепловой волны (ВЧМТВ) оптический импульс с низкой пиковой мощностью модулируется полосой низких частот [5], чтобы преодолеть ограничения традиционных методов стимуляции (высокая пиковая мощность и увеличенное время экспериментов) и улучшить детектирование дефектов и разрешение по глубине. С другой стороны,

квадратичная версия ВЧМТВ (КВЧМТВ) обеспечивает улучшенное разрешение по глубине и обнаружение более глубоких дефектов, чем ее линейный аналог [6]. Однако в АТ были разработаны различные методы для обработки захваченного теплового отклика [2—8].

Абсолютный тепловой контраст, восстановление теплового сигнала (ВТС), термография главных компонент (ТГК) и фаза преобразования Фурье — это обычно используемые методы обработки в традиционной термографии [2]. С другой стороны, сжатие импульсов (СИ) и Z-преобразование с линейной частотной модуляцией (ЛЧМ-ЗП) стали удобны при обработке в процессе ВЧМТВ и КВЧМТВ, с улучшенным разрешением по глубине и количественной оценкой глубины, поддерживаемыми аналитическими моделями, представленными в [7, 8]. Однако для эффективного обнаружения и определения характеристик дефектов требуется опытный специалист в области АТ, что приводит к значительно меньшему количеству человеческих ошибок при наблюдении за массивами данных обработки результатов термографии. Следовательно, недавние достижения в NDT 4.0 служат подтверждением успешного применения различных алгоритмов машинного обучения в АТ с целью избежать вмешательства человека и обеспечить автоматическое обнаружение дефектов [9—22].

Машинное обучение стало использоваться в АТ в начале 2000-х годов за счет использования искусственных нейронных сетей (ИНС), многослойного персептрона (МСП) и метода опорных векторов (МОВ) для автоматического контроля и описания дефектов. Авторы извлекали из тепловых профилей характеристики, такие как максимальный тепловой контраст и время его появления [9], кривые теплового контраста [10], коэффициенты ВТС [11], главные компоненты [12] и фазовые кривые [13], чтобы обучать свои модели. Совсем недавно автоматический контроль дефектов состоял из локализации объекта, классификации и семантической сегментации термограмм, которые могут быть получены с помощью таких архитектур глубоких нейронных сетей с ядрами двухмерной сверточной нейронной сети (СНС), известных в ИТ, как Yolo-Net и U-Net [14—17]. Однако это непростой подход с точки зрения использования термограмм по двум причинам: первая — это термограммы, на которые влияет неоднородное излучение и эффекты неоднородной излучательной способности, а вторая — выбор тестовых термограмм для обнаружения дефектов [18].

В отличие от моделей 2D-СНС, в СТ вводится двухпоточная модель СНС со структурой 1D-СНС для контроля дефектов путем сравнения сходства между тепловыми профилями бездефектных и дефектных областей [18]. В недавнем прошлом в КВЧМТВ предлагались ИНС, дерево решений и одноклассовые модели автоматического обнаружения и описания дефектов на основе использования тепловых профилей [19, 20, 27]. Помимо автоматического контроля дефектов, в АТ недавно были введены автокодировщики и генеративно-сопоставительные сети как модели сжатия и увеличения термографических данных соответственно [21, 22]. Однако модели глубоких нейронных сетей в ВЧМТВ с использованием одномерных СНС или моделей на основе долгой краткосрочной памяти (ДКСП) еще не обсуждались.

В данной статье представлена глобальная сеть объединения признаков в КВЧМТВ для автоматической составной проверки, которая объединяет локальные характеристики, извлеченные из модели СНС, и глобальные характеристики, извлеченные из моделей ГНС. Локальные характеристики, извлеченные из обработанных тепловых профилей с использованием модели СНС, и глобальные характеристики, извлеченные с помощью ГНС, где ГНС содержит несколько статистических характеристик во временной области и частотных характеристик тепловых профилей. Углеполимер с искусственно просверленными отверстиями с плоским дном различных размеров на разной глубине. Температурные профили из дефектной и бездефектной области вместе с их характеристиками (статистическая во временной области и частотная область) выбираются случайным образом для подготовки обучающего набора. Обученные модели тестируются на тепловом отклике всего образца для классификации и визуализации дефектов. Значительное улучшение было отмечено при автоматическом контроле дефектов с использованием модели объединения признаков по сравнению с локальными моделями.

## СЕТЬ ОБЪЕДИНЕНИЯ ПРИЗНАКОВ

**Глубокая нейронная сеть (ГНС).** Искусственные нейронные сети (ИНС) с мелкой архитектурой использовались для автоматического обнаружения дефектов в инфракрасной термографии [9—13]. Простая модель ИНС состоит из трех уровней: входного слоя, скрытого слоя и выходного слоя с несколькими нейронами в каждом слое для обучения целевой функции. ИНС с более чем тремя скрытыми слоями считается глубокой нейронной сетью (ГНС). Параметры выборки входных данных определяют количество нейронов во входном слое. Несколько скрытых слоев позво-

ляют сети изучать сложные отношения, используя количество нейронов в каждом скрытом слое, и каждый вывод скрытого слоя нелинейно преобразуется с использованием функций нелинейной активации, таких как сигмоид, гиперболический тангенс, ReLU и т.д. Все нейроны в каждом скрытом слое полностью связаны с нейронами в предыдущем и следующем скрытых слоях. Количество меток выборки определяет нейроны в выходном слое. Для заданных входных данных  $x$  выход произвольного скрытого слоя задается как

$$f(x) = \varphi(w'_{ij}x + b^l), \quad (1)$$

где  $w_{ij}$  — весовая коэффициент между  $i$ -м нейроном в скрытом слое и  $j$ -й нейронной ячейкой в скрытом слое  $l$ ,  $b$  определяет смещение нейронов в скрытом слое  $l$ ,  $f(x)$  — выход скрытого слоя  $l$ ,  $\varphi$  представляет собой функцию активации. Слой исключений широко используется между скрытыми слоями, чтобы пропустить несколько нейронов в скрытых слоях для управления переобученной сетью [25]. Последний выходной слой и последние скрытые слои связаны с софтмакс-слоем. Для вычисления ошибки проводится сравнение между окончательным выводом слоя классификации и желаемым выводом. Вычисленная ошибка обратно распространяется на предыдущие уровни для обновления параметров до первого уровня в текущей итерации с заданным пакетом данных. Процесс повторяется с новыми данными на следующей итерации, пока ошибка на выходе не станет ниже порогового значения.

**Сверточная нейронная сеть.** Последние успехи в области глубокого обучения со сверточными нейронными сетями привлек внимание исследователей АТ, и различные предварительно обученные модели доступных сверточных нейронных сетей (СНС) были введены посредством трансферного обучения для автоматического обнаружения дефектов [14—17]. Однако типичная СНС состоит из двух элементов: сети извлечения признаков и полносвязной нейронной сети (ПНС). Сеть извлечения признаков представляет собой комбинацию сверточных слоев и слоев подвыборки с нелинейными функциями активации. Сверточный слой содержит несколько ядер свертки с разными весами, которые скользят по функциям предыдущего слоя и используют операцию свертки. Операции свертки с разными ядрами приводят к локальным связям и распределению веса между предыдущим и текущим слоями. Кроме того, количество выходных функций в сверточном слое уменьшается путем сканирования прямоугольной оконной матрицей со статистическим параметром. Как правило, максимальные и средние значения в окне выбираются в качестве операций объединения, т.е. более конкретно, широко используются максимальные значения. Полносвязная сеть подключается в конце к сети извлечения признаков. Он состоит из скрытых слоев с нейронами, подобными ГНС, но на входе — карта признаков, извлеченная из сети извлечения признаков. Последний слой и последний скрытый уровень ПНС подключаются к софтмакс-слою для классификации.

В АТ контроль дефектов осуществляется с помощью 2D-моделей СНС. Yanpeng [20] представил двухпоточковую архитектуру СНС с одномерными ядрами СНС для прогнозирования сходства между парой характеристик теплового профиля, извлеченных с помощью операции 1D СНС. Точно так же извлечение признаков из временного теплового профиля  $x$  с использованием одномерной свертки с последующей нелинейной активацией дается выражением:

$$f_k^l = \varphi\left(\sum_{i=1}^{N_{l-1}} (w_{ik}^{l-1} \cdot x_i^{l-1} + b_k^l)\right), \quad (2)$$

где  $x_i^{l-1}$  — это выход  $i$ -го нейрона на уровне  $l-1$ ,  $w_{ik}^{l-1}$  — это ядро от  $i$ -го нейрона в слое  $l-1$  до  $k$ -го нейрона на слое  $l$ ,  $b_k^l$  определяет смещение  $k$ -го нейрона на слое  $l$ ,  $\varphi$  представляет функцию активации,  $f(x)$  — выходной сигнал сверточного слоя  $l$ . Размер объектов, извлеченных из  $l$ -го сверточного слоя, уменьшается с помощью объединяющего слоя и передается в ПНС. Последний скрытый слой и выходной слой ПНС подключены к софтмакс-слою, и градиенты, сгенерированные путем сравнения с желаемым выходом, передаются обратно на последний слой свертки в текущей итерации с заданным пакетом данных. Процесс повторяется с новым пакетом данных на следующей итерации до тех пор, пока ошибка вывода не станет ниже порогового значения.

**Сеть объединения признаков.** В вышеотмеченной литературе были проанализированы глобальные характеристики, извлекаемые нейронной сетью из вручную построенных признаков, и локальные характеристики, извлекаемые из модели СНС автоматического контроля дефектов [9—22]. Влияние на возможность обнаружения дефектов в обоих случаях еще не проанализировано. Однако недавние исследования доказали значительное улучшение процесса классификации сигналов при мониторинге состояний конструкций и классификации биомедицинских сигналов за счет объединения построенных вручную и глубоких признаков [23, 24]. Следовательно, в

Таблица 1

Параметры сети слияния функций

Слой	СНС		ГНС	
1	Входной слой	$1 \times 625$	Входной слой	10
2	Сверточный слой	$n = 20, k = 1 \times 11$	Скрытый слой 1 + Дропаут	20, 0,2
3	Пулинговый слой	$P = 5$	Скрытый слой 2 + Дропаут	40, 0,2
4	Сверточный слой	$n = 40, k = 1 \times 7$	Скрытый слой 3 + Дропаут	80, 0,2
5	Объединение	$P = 5$	Скрытый слой 4	160
6	Сверточный слой	$n = 60, k = 1 \times 3$	Дропаут	0,5
7	Получение глобального среднего			
8	Слой объединения			
9	Дропаут		0,5	
10	Софтмакс		1 (2 класса)	

настоящем исследовании представлена сеть объединения признаков в КВЧМТВ для автоматического контроля дефектов подповерхностных несплошностей в композитном образце. Подробная информация о сети объединения признаков представлена в табл. 1.

Предлагаемая глобальная архитектура состоит из локальных моделей СНС и ГНС, как показано на рис. 1. Модель СНС построена с входным слоем, тремя уровнями свертки с одномерной структурой, двумя уровнями максимального объединения, за которыми следует один глобальный средний слой объединения с временным тепловым профилем в качестве входного сигнала. Модель ГНС состоит из входного слоя, нескольких скрытых слоев и слоев регуляризации со статистическими характеристиками временной области и характеристиками частотной области теплового профиля в качестве входных данных. Выходные характеристики СНС и ГНС объединяются с помощью слоя слияния. Объединенные элементы проходят через слой регуляризации и, наконец, передаются на выходной софтмакс-слой. Сеть объединения параметров обучается так же, как и две локальные сети, которые итеративно реализуют прямое и обратное распространение. Для набора обучающих данных  $D = \{T, T', y\}$  из  $N$  тепловых профилей  $X \in R^{N \times 1 \times M}$  и вручную созданных статистических и частотных характеристик во временной области  $X \in R^{N \times 1 \times k}$  с соответствующими метками  $y \in R^{N \times 1}$ , прямое распространение на итерации  $i$  определяется выражением:

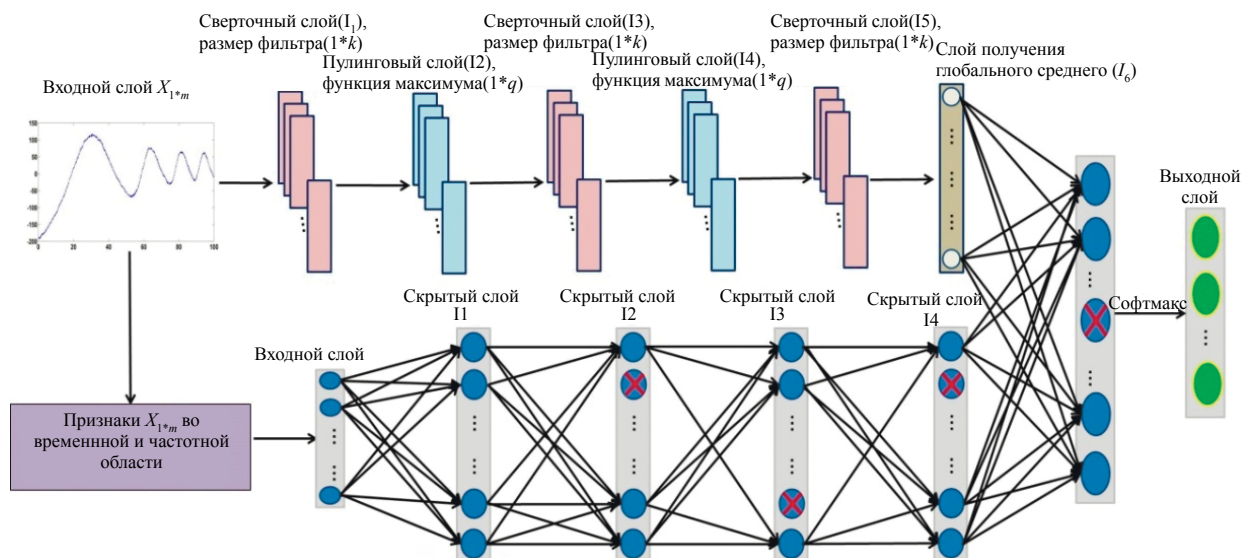


Рис. 1. Схема предложенной сети объединения признаков.

$$f(t, t') = \varphi_{l-1} \left( \varphi_{c, l-2} \left( \dots \varphi_{c, 1} \left( t, \theta_{c, 1}^i \right), \theta_{c, l-2}^i \right), \varphi_{d, l-2} \left( \dots \varphi_{d, 1} \left( t', \theta_{d, 1}^i \right), \theta_{d, l-2}^i \right), \theta_{l-1}^i \right), \quad (3)$$

где  $\theta_{c, n}$ ,  $\theta_{d, n}$  и  $\varphi_{c, n}$ ,  $\varphi_{d, n}$  для  $n = 1, 2, \dots, l-1$  представляют собой параметры обучения операции на каждом слое локальных моделей СНС и ГНС на тепловом профиле  $t$  и его параметрах  $t'$  соответственно. Результат классификации  $y'$  на софтмакс-слое определяется по:

$$y' = \frac{e^{f_i(t, t', \theta_i^j, p)}}{\sum_{j=1}^p e^{f_i(t, t', \theta_i^j, j)}}. \quad (4)$$

Параметры обучения сети объединения признаков обобщаются как  $\theta'$ , и функция потерь, рассчитываемая путем сравнения полученного результата с метками, определяется как

$$L(y', y) = -\frac{1}{2} \sum_{i=1}^N y_i \ln(y'_i). \quad (5)$$

Задача обнаружения дефектов моделируется как задача двоичной классификации. Следовательно, учитывается функция потерь бинарной кросс-энтропии. Исходя из слоя объединения, потери распределяются обратно на каждый уровень локальных сетей, а обучаемые параметры локальных сетей оптимизируются для каждого пакета в обучающем наборе данных  $D$ . На рис. 2 представлена пошаговая методика предложенной сети объединения признаков.




Рис. 2. Схема работы предложенной сети объединения признаков.

## ЭКСПЕРИМЕНТ И ПОДГОТОВКА ДАННЫХ

**Матриалы и экспериментальная работа.** Временная тепловая оценка профилей пикселей в области дефекта в композитных структурах представляет различные параметры, такие как затухание и временные задержки в зависимости от глубины и геометрических размеров дефектов. Однако тепловые профили подвергаются процессу обработки, анализируется соответствующий параметр контраста, при этом на обнаружение более глубоких и мелких дефектов влияет низкий контраст и другие неоднородные эффекты, включая шум в тепловых данных. В данном случае возможность обнаружения дефектов сетью объединения признаков для еще более глубоких дефектов анализируется с использованием образца из углеполимера с искусственно просверленными отверстиями с плоским дном различных размеров на разной глубине в виде дефектов расслоения. Принципиальная схема, фото (в оптическом диапазоне) переднего и заднего вида тестового образца представлены на рис. 3а—в. Передняя поверхность тестового образца покрыта черной эмалевой краской с коэффициентом излучения 0,96 для получения однородного коэффициента излучения во время экспериментов [2].

Испытуемый образец помещают перед комплектом галогенных ламп мощностью 1 кВт каждая на расстоянии 80 см. Две галогенные лампы испускают квадратичный частотно-модулированный оптический импульс, имеющий развертку по частоте от 0,01 до 0,1 Гц в течение 100 с, как показано на рис. 3г, смещение постоянного тока добавляется к возбуждению, чтобы избежать фазы охлаждения [6]. Соответствующие тепловые карты поверхности объекта записываются со скоростью 25 кадров в секунду в течение 100 с с помощью тепловизора FLIR A655SC, работаю-




Рис. 3. Принципиальная схема (а) (размеры в см); вид спереди (б); вид сзади образца из углеполимера (в) и общая схема экспериментальной установки для визуализации квадратично частотно модулированной тепловой волны (КВЧМТВ)(z).

шего в спектральном диапазоне от 7,5 до 14 мкм с чувствительностью 30 мк. Тепловые данные включали 2500 термограмм с пространственным разрешением 640×480 пикселей.

**Предобработка данных и их подготовка.** Интересующая область выбирается из наблюдаемой, чтобы исключить ненужный фон и выделить тепловой отклик тестового образца. Урезанные данные охватывают тепловой отклик тестового образца с пространственным разрешением 315×317 пикселей на всех термограммах. Наблюдается средний рост каждого пиксельного профиля в поле зрения из-за смещения постоянного тока, добавляемого к импульсу, и соответствующая методика полиномиальной аппроксимации удаляет его. Кроме того, динамический компонент каждого временного теплового профиля извлекается путем вычитания из него среднего. Необработанные и динамические тепловые профили до и после выравнивания представлены на рис. 4. Далее у каждого динамического теплового профиля уменьшается дискретизация с прореживанием, равным 4, для уменьшения входной длины признака для сети объединения признаков [18]. Тепловой отклик с пониженной дискретизацией включает 625 точек выборки. Следовательно, каждый временной тепловой профиль связан с бинарным слоем, указывающим, принадлежит ли профиль области дефекта или бездефектной области. Температурные профили бездефектной области и области дефекта обозначаются метками «0» и «1». Помеченные данные означают, что из 99855 тепловых профилей 6045 относятся к дефектным областям, а 93810 профилей относятся к бездефектной.




Рис. 4. Необработанные и динамические временные тепловые профили в бездефектной и дефектной областях образца.

Трехмерный тепловой отклик преобразуется в двумерный вектор путем размещения каждой пиксельной тепловой карты в строку и соответствующей ему эволюции во времени в столбцах вместе с соответствующими метками. Параллельно с этим из каждого теплового профиля выделяется несколько характеристик для обучения предлагаемой сети объединения признаков. Совсем недавно объединение статистических признаков во временной области и комбинация характеристик сигналов во временной и частотной областях повысило эффективность классификации сигналов в различных приложениях [23, 24]. В данном случае из тепловых профилей выделяется несколько статистических и частотных характеристик во временной области. Характеристики временной области включают минимум, максимум, размах, стандартное отклонение, асимметрию и эксцесс тепловых профилей, тогда как характеристики частотной области включают четырехфазные компоненты, полученные из фазы преобразования Фурье. В табл. 2 представлен список выбранных вручную признаков для объединения с локальными характеристиками тепловых профилей, полученных из модели СНС. Далее был подготовлен набор обучающих данных с тепловыми профилями и характеристиками, включающий 10000 образцов с соотношением 1: 4 тепловых профилей дефектной и бездефектной областей. Каждый пиксельный профиль всего тестового образца и их соответствующие характеристики остаются в качестве данных тестирования.

Таблица 2

Выбранные параметры во временной и частотной областях

№ п/п	Параметр	Формула	№ п/п	Параметр	Формула
1	Минимум	$T_{\min} = \min T_i $	4	Стандартное отклонение	$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (T_i - \bar{T})^2}$
2	Максимум	$T_{\max} = \max T_i $	5	Ассиметрия	$S = \frac{1}{N} \sum_{i=1}^N (T_i - \bar{T})^3$
3	Размах	$T_{p-p} = T_{\max} - T_{\min}$	6	Эксцесс	$S = \frac{1}{N} \sum_{i=1}^N (T_i - \bar{T})^4$
7—10	Признаки в частотной области (Фаза)			$\varphi_n = \tan^{-1} \left( \frac{\text{Im}(T(x, \omega))}{\text{Re}(T(x, \omega))} \right)$	

## РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

**Обучение и валидация.** Эффективность обучения сети объединения признаков анализируется путем одновременной передачи тепловых профилей и построенных вручную признаков в локальные сети. Моделирование проводилось с использованием четырехъядерного процессора AMD A10 с тактовой частотой 3,5 ГГц, поддерживаемом графикой AMD Radeon R7 3 ГБ, внутренней памятью 6 ГБ и твердотельным накопителем на 256 ГБ. Перед инициализацией сетей данные обучения и тестирования нормализуются как предварительный этап машинного обучения. Сети, инициализированные с помощью инициализации веса Ксавье с нулевым смещением [26], обучены на 500 итерациях обратного распространения с размером пакета 64. Adam со скоростью обучения 0,00015 используется в качестве оптимизатора для обучения сетей.

Обучающие данные 10 тысяч тепловых профилей, соответствующих вручную построенным признакам, и соответствующие метки сначала перетасовываются, нормализуются и передаются в СНС, ГНС и сети объединения признаков. 20% данных обучения разделяются для оценки модели сразу после обучения каждой эпохи. Потеря при валидации, показанная на рис. 5, представляет эффективность обучения каждой сети. Замечено, что модель ГНС достигает глобальных минимумов за меньшее количество итераций, тогда как потеря при валидации СНС и сетей объединения признаков медленно уменьшается. Кроме того, объединение признаков приводит к быстрой сходимости глобальной модели по сравнению с ее локальными сетями. Время обучения, указанное для глобальной модели, аналогично СНС, которое составляет 6,5 с, тогда как ГНС занимает 0,3 с для обучения эпохи (включая прямое и обратное распространение).

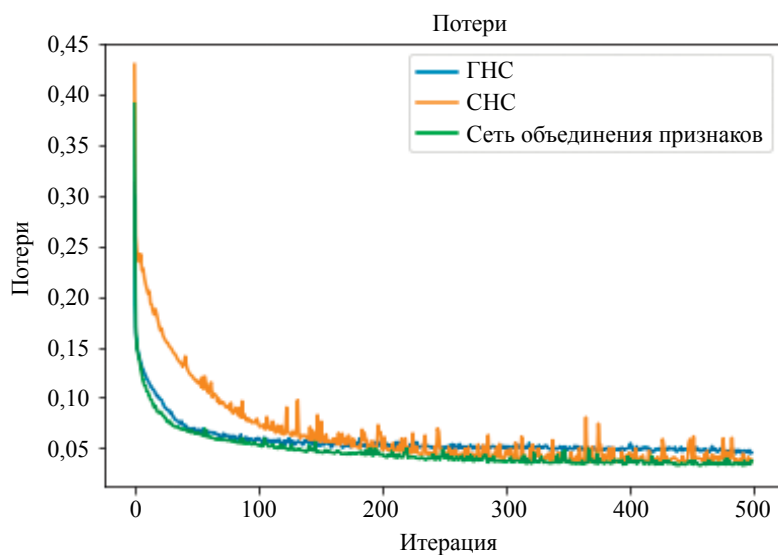


Рис. 5. Сравнение кривых потерь между ГНС, СНС и сетью объединения признаков.

**Автоматическое обнаружение дефектов.** Обученная модель тестируется на полном тепловом отклике образца и его построенными вручную признаками. Окончательный результат классификации —  $y' \in R^{N \times 1}$ , который преобразуется в 2D, чтобы предоставить результаты автоматического контроля дефектов. На рис. 6а—в показан результат обнаружения дефектов с использованием ГНС, СНС и сетями объединения признаков. Можно отметить, что в случае использования моделей ГНС и СНС имеет место большее количество ложных дефектов, а именно, профили бездефектных областей расцениваются как дефектные и, при этом, меньшее количество пропущенных дефектов. Это связано с неоднородными эффектами, связанными с особенностями временной области, влияющими на производительность ГНС, и хорошо известен факт, что фаза преодолевает эти неоднородные эффекты.

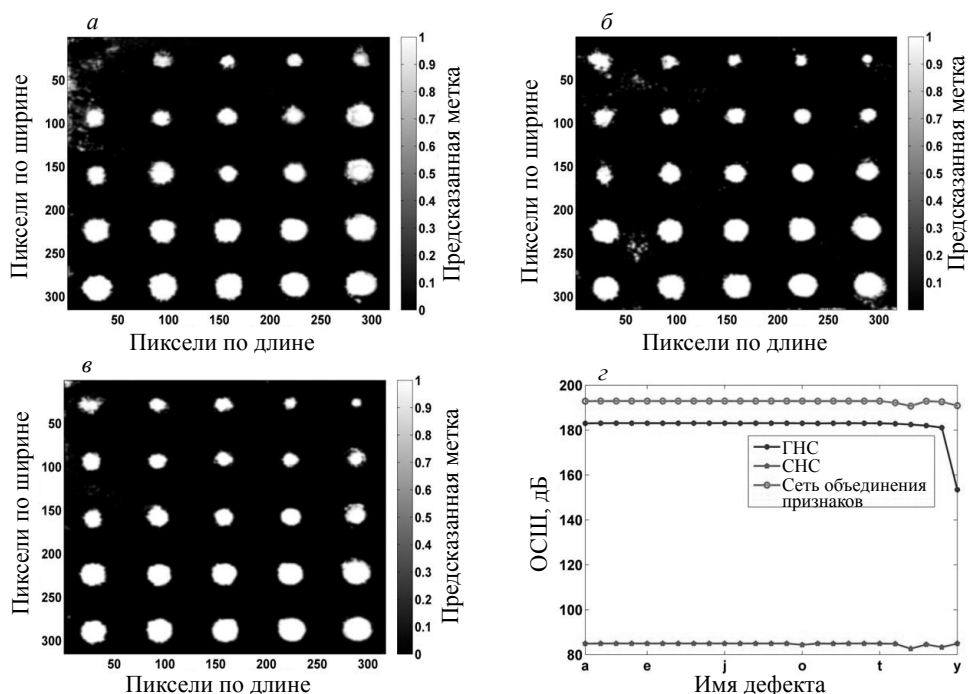


Рис. 6. Сравнение способности обнаружения дефектов используя: а — ГНС; б — СНС; в — сеть объединения признаков (цветная полоса обозначает предсказанные метки).



Кроме того, сеть объединения признаков обеспечивает эффективное обнаружение более глубоких и мелких дефектов. Однако наблюдается превышение в количестве более глубоких дефектов, что связано с неоднородными тепловыми эффектами, имеющими место во временной эволюции теплового профиля отдельных областей. С другой стороны, время тестирования для сети объединения признаков составляет 26,73 с, что меньше, чем у СНС, где ГНС занимает 2,15 с для классификации признаков. Эффективность автоматического контроля дефектов посредством предлагаемой методики подтверждается с использованием показателей термографии и машинного обучения. Отношение сигнал/шум (ОСШ) — широко используемая мера оценки качества в АТ. ОСШ определяется балансом между средней ( $\mu$ ) разницей в дефектной области и бездефектной области и стандартным отклонением ( $\sigma$ ) бездефектной области, приведенным в уравнениях (6), а наблюдаемые отношения сигнал / шум представлены на рис. 6г.

$$SNR(db) = 20 \cdot \log \left( \frac{\mu_{\text{дефект}} - \mu_{\text{бездефект}}}{\sigma_{\text{бездефект}}} \right). \quad (6)$$

По рисунку можно предположить, что модель ГНС и сеть объединения признаков обладают высоким ОСШ по сравнению с архитектурой СНС из-за заметно низкого стандартного отклонения в бездефектной области. Стандартное отклонение, зарегистрированное в бездефектной области для ГНС, СНС и сети объединения признаков, составляет  $1,0584 \times 10^{-4}$ , 0,0143 и  $6,4660 \times 10^{-5}$  соответственно. Небольшое стандартное отклонение дает право полагать, что сеть предсказала вероятность того, что тепловые профили бездефектной области очень близки к целевой метке 0. А также очень малы отклонения в предсказанных вероятностях. Это, в свою очередь, приводит к тому, что сеть объединения признаков классифицирует тепловые профили бездефектных и дефектных областей, несмотря на наличие других важных параметров.

Кроме того, предлагаемая методика проверяется с использованием нескольких показателей машинного обучения, таких как точность тестирования, F-мера и площадь под кривой рабочих характеристик приемника (ППК). Высокое значение полноты и низкая точность приводят к слишком большому количеству ложных срабатываний в задачах классификации, и баланс этих двух параметров увеличивает эксплуатационные затраты. Следовательно, рассматривается F-мера, которая задается как баланс между этими двумя показателями [24]. Помимо точности и F-меры, кривые ППК демонстрируют способность классификатора анализировать термические профили, соответствующие дефектным и бездефектным областям. ППК рассматривается между показателем ложноположительных результатов и истинно положительными результатами. Точность, полнота и F-мера математически выражаются в уравнениях (7)—(9), а в табл. 3 представлены рассматриваемые параметры классификации. Сравнение показателей эффективности показывает, что предлагаемая сеть объединения признаков обеспечивает более высокую точность тестирования, полноту и F-меру, чем локальные модели.

Таблица 3

## Сравнение показателей эффективности предлагаемой сети объединения признаков с архитектурами ГНС и СНС

Показатель		ГНС	ГНС	Сеть объединения признаков
Точность испытания, %		94,82	96,03	<b>96,87</b>
F-мера	Отсутствие дефекта	0,97	0,98	0,98
	Дефект	0,70	0,75	<b>0,79</b>
ППК, %		96,64	97,65	<b>98,14</b>

$$\text{Точность} = \frac{\text{Истинно положительная оценка (ИП)}}{\text{Истинно положительная оценка} + \text{Ложно положительная оценка (ЛП)}}; \quad (7)$$

$$\text{Полнота} = \frac{\text{Истинно положительная оценка (ИП)}}{\text{Истинно положительная оценка} + \text{Ложно отрицательная оценка (ЛО)}}; \quad (8)$$

$$F1\text{-мера} = \frac{(2 \times \text{точность} \times \text{полнота})}{(\text{точность} + \text{полнота})} \quad (9)$$

## ЗАКЛЮЧЕНИЕ

Данная работа представляет КВЧМТВ-сеть объединения признаков для автоматического контроля дефектов в составном образце. Построенные вручную признаки, извлеченные из тепловых профилей, передаются в ГНС, который извлекает глобальные характеристики тепловых профилей, объединенные с глубокими характеристиками тепловых профилей, извлеченных из СНС. Экспериментальная проверка композитного образца из углепластика с искусственными плоскодонными отверстиями подтвердила значительное улучшение способности обнаруживать дефекты в сети объединения признаков по сравнению с локальными моделями ГНС и СНС. Следует отметить, что особенности временной области, обусловленные изменениями временного теплового профиля (амплитуда), снижают точность классификации ГНС, где не рекомендуется анализ на основе амплитуды в инфракрасной термографии из-за его чувствительности к неоднородностям и другим шумам в тепловом отклике. Кроме того, хорошие результаты классификация достигаются за счет объединения построенных вручную признаков с признаками глубокой сети в сеть объединения признаков. Показатели производительности также подтверждают, что сеть Fusion Fusion можно реализовать даже на экономичном оборудовании.

Работа частично поддержана грантом совета по военно-морским исследования (Индия), № гранта NRB-423/MAT/18-19.

## СПИСОК ЛИТЕРАТУРЫ

1. *Vrana Johannes*. NDE 4.0: The Fourth Revolution in Non-Destructive Evaluation: Digital Twin, Semantics, Interfaces, Networking, Feedback, New Markets and Integration into the Industrial Internet of Things. 2019.
2. *Chung Yoonjae, Ranjit Shrestha, Seungju Lee, Wontae Kim*. Thermographic Inspection of Internal Defects in Steel Structures: Analysis of Signal Processing Techniques in Pulsed Thermography // *Sensors* 20. 2020. No. 21. P. 6015.
3. *Razani Marjan, Parkhimchyk Artur, Tabatabaei Nima*. Lock-in thermography using a cellphone attachment infrared camera // *Aip Advances*. 2018. V. 8. No. 3. P. 035305.
4. *D'Accardi E., Palano F., Tamborrino R., Palumbo D., Tati A., Terzi R., Galietti U.* Pulsed phase thermography approach for the characterization of delaminations in cfrp and comparison to phased array ultrasonic testing // *Journal of Nondestructive Evaluation*. 2019. V. 38. No. 1. P. 20.
5. *Ghali V.S., Mulaveesala R.* Frequency modulated thermal wave imaging techniques for non-destructive testing // *Insight-Non-Destructive Testing and Condition Monitoring*. 2010. V. 52. No. 9. P. 475—480.
6. *Subbarao Ghali Venkata, Mulaveesala Ravibabu*. Quadratic frequency modulated thermal wave imaging for non-destructive testing // *Progress In Electromagnetics Research*. 2012. V. 26. P. 11—22.
7. *Subhani Shaik, Gampa V.P., Chandra Sekhar Yadav, Ghali Venkata Subbarao*. Defect characterization using pulse compression-based quadratic frequency modulated thermal wave imaging // *IET Science, Measurement & Technology*. 2020. V. 14. Is. 2. P. 165—172.
8. *Subhani Sk., Suresh B., Ghali V.S.* Quantitative subsurface analysis using non stationary thermal wave imaging // *Infra. Phy. & Tech*. 2018. V. 88. P. 41—47.
9. *Bison P.G., Bressan C., Di Sarno R., Grinzato E., Marinetti S., Manduchi G.* Thermal NDE of delaminations in plastic materials by neural network processing // *In QIRT*. 1995. V. 94. P. 214—219.
10. *Darabi Akbar, Maldague Xavier*. Neural network based defect detection and depth estimation in TNDE // *Ndt & E International*. 2002. V. 35. No. 3. P. 165—175.
11. *Benitez Hernan, Ibarra-Castanedo Clemente, Loaiza Humberto, Caicedo Eduardo, Bendada Abdelhakim, Maldague Xavier*. Defect quantification with thermographic signal reconstruction and artificial neural networks // *In Proceedings of 8th Conference on Quantitative Infrared Thermography*. Padova, Italy. 2006. V. 2. P. 6.
12. *Benítez Hernán D., Loaiza Humberto, Caicedo Eduardo, Ibarra-Castanedo Clemente, Bendada Abdelhakim, Maldague Xavier*. Defect characterization in infrared non-destructive testing with learning machines // *NDT & E International*. 2009. V. 42. No. 7. P. 630—643.
13. *Maldague Xavier, Largouët Yves, Couturier Jean-Pierre*. A study of defect depth using neural networks in pulsed phase thermography: modelling, noise, experiments // *Revue générale de thermique*. 1998. 37.8. P. 704—717.
14. *Numan Saeed, King Nelson, Said Zafar, Omar Mohammed A.* Automatic defects detection in CFRP thermograms, using convolutional neural networks and transfer learning // *Infrared Physics and Technology*. 2019. V. 102. P. 103048.

15. *Fang Q., Nguyen B.D., Ibarra Castanedo C., Duan Y., Maldague, X.* Automatic defect detection in infrared thermography by deep learning algorithm / In *Thermosense: Thermal Infrared Applications XLII*, 2020. V. 11409.
16. *Luo Q., Gao B., Woo W.L., Yang Y.* Temporal and spatial deep learning network for infrared thermal defect detection // *NDT & E International*. 2019. V. 108. P. 102164.
17. *Oliveira B.C.F., Seibert A.A., Borges V.K., Albertazzi A., Schmitt R.H.* Employing a U-net convolutional neural network for segmenting impact damages in optical lock-in thermography images of CFRP plates // *Non-destructive Testing and Evaluation*. 2020. P. 1—19.
18. *Cao Yanpeng, Dong Yafei, Cao Yanlong, Yang Jiangxin, Yang Michael Ying.* Two-stream convolutional neural network for non-destructive subsurface defect detection via similarity comparison of lock-in thermography signals // *NDT&E International*. 2020. June. V. 112. P. 102246.
19. *Lakshmi A. Vijaya, Tilak V. Gopi, Parvez Muzammil M., Subhani S.K., Ghali V.S.* Artificial neural networks based quantitative evaluation of subsurface anomalies in quadratic frequency modulated thermal wave imaging // *Infrared Physics and Technology*. 2019. V. 97. P. 108—115.
20. *Lakshmi A. Vijaya, Ghali V.S., Subhani Sk., Balaji Naik R.* Automated quantitative subsurface evaluation of fiber reinforced polymers // *Infrared Physics & Technology*. 2020. V. 110. P. 103456.
21. *Kaur K., Mulaveesala R., Mishra P.* Constrained Autoencoder based Pulse Compressed Thermal Wave Imaging for Sub-surface Defect Detection // *IEEE Sensors Journal*. Doi: 10.1109/JSEN.2021.3056394
22. *Kaixin Liu, Li Yingjie, Yang Jianguo, Liu Yi, Yao Yuan.* Generative Principal Component Thermography for Enhanced Defect Detection and Analysis // *IEEE Transactions on Instrumentation and Measurement*. 2020.
23. *Li Hongmei, Huang Jinying, Ji Shuwei.* Bearing fault diagnosis with a feature fusion method based on an ensemble convolutional neural network and deep neural network // *Sensors*. 2019. V. 19. No. 9. P. 2034.
24. *Fajardo Jose Manuel, Gomez Orlando, Prieto Flavio.* EMG hand gesture classification using handcrafted and deep features // *Biomedical Signal Processing and Control*. 2021. V. 63. P. 102210.
25. *Srivastava Nitish, Hinton Geoffrey, Krizhevsky Alex, Sutskever Ilya, Salakhutdinov Ruslan.* Dropout: a simple way to prevent neural networks from overfitting // *The journal of machine learning research*. 2014. V. 15. No. 1. P. 1929—1958.
26. *Glorot Xavier, Bengio Yoshua.* Understanding the difficulty of training deep feedforward neural networks // *Proceedings of the thirteenth international conference on artificial intelligence and statistics*. P. 249—256. *JMLR Workshop and Conference Proceedings*, 2010.
27. *Tilak V. Gopi, Ghali V.S., Lakshmi A. Vijaya, Suresh B., Naik R.B.* Proximity based automatic defect detection in quadratic frequency modulated thermal wave imaging // *Infrared Physics & Technology*. 2021. V. 114. P. 103674.