

МЕТОД ГЛУБОКОГО ОБУЧЕНИЯ ДЛЯ ЗАДАЧИ КЛАССИФИКАЦИИ ИЗОБРАЖЕНИЙ ДРЕВЕСИНЫ, ПОЛУЧЕННЫХ С ПОМОЩЬЮ МИКРОТОМОГРАФИИ

© 2024 г. Сяоя Ян^{1,**}, Жишуай Чжэн², Хуаньци Чжэн³, Сяопин Лю^{4,*}

¹Шаньдунский политехнический институт, Цзинань, Шаньдун, 250104, Китай

²Шаньдунский университет Цзяньчжэу, Цзинань, Шаньдун, 250101, Китай

³Шаньдунский институт контроля качества продукции, Цзинань, Шаньдун, 250102, Китай

⁴Хэнаньский технологический университет, Китай 450001, Чжэньчжоу, Зона высоких технологий,
ул. Лянхуа, 100

E-mail: *liuxiaoping@haut.edu.cn; **yangxiaoxia8899@126.com

Поступила в редакцию 27.07.2024; после доработки 27.07.2024

Принята к публикации 27.08.2024

Корректная классификация ценных пород древесины имеет решающее значение для импортно-экспортной торговли и идентификации мебельных материалов. В данном исследовании используется метод неразрушающего контроля (микроскопическая компьютерная томография, микроКТ) для получения микроскопических изображений поперечных, радиальных и тангенциальных срезов 24 ценных пород древесины, что позволяет создать обширный набор данных. Разработана модель глубокого обучения SLConNet, повышающая точность распознавания за счет многомасштабной свертки и улучшенной структуры остаточных блоков. Результаты экспериментов показывают, что точность классификации поперечных, радиальных и тангенциальных срезов составляет 98,72, 96,75 и 95,36 % соответственно при значении коэффициента усиления 0,8. Модель превосходит такие традиционные модели, как Alexnet, ResNet50, Inception-V3 и Xception. Данное исследование подчеркивает эффективность неразрушающего контроля в получении большого количества микроскопических изображений древесины по сравнению с традиционными методами определения структуры анатомии. Модель SLConNet демонстрирует высокие показатели точности, запоминания и чувствительности, что указывает на ее потенциал для широкого применения в классификации древесины.

Ключевые слова: глубокое обучение, классификация и распознавание, неразрушающий контроль, древесина ценных пород.

DEEP LEARNING METHOD OF PRECIOUS WOOD IMAGE CLASSIFICATION BASED ON MICROSCOPIC COMPUTED TOMOGRAPHY

© 2024 Xiaoxia Yang^{1,**}, Zhishuai Zheng², Huanqi Zheng³, Xiaoping Liu^{4,*}

¹Shandong Polytechnic, Jinan, Shandong, 250104, China

²Shandong Jianzhu University, Jinan, Shandong 250101, China

³Shandong Institute for Product Quality Inspection, Jinan, Shandong 250102, China

⁴Henan University of Technology,

No.100 Lianhua Street, High Tech Zone, Zhengzhou, 450001 China

E-mail: *liuxiaoping@haut.edu.cn; **yangxiaoxia8899@126.com

Correctly identifying precious wood species is crucial for import and export trade and furniture material identification. This study utilizes nondestructive testing (Microscopic Computed Tomography, Micro-CT) to capture microscopic images of the transverse, radial, and tangential sections of 24 precious wood species, creating a comprehensive dataset. The SLConNet deep learning model is developed, enhancing recognition accuracy through multi-scale convolution and an improved residual block structure. The experiment results show that the classification accuracy of the transverse, radial and tangential sections is 98.72, 96.75 and 95.36 % respectively when the gain value is 0.8. The model outperforms traditional models like Alexnet, ResNet50, Inception-V3, and Xception. This research highlights the efficiency of nondestructive testing in obtaining a large number of microscopic wood images, compared to traditional anatomical methods. The SLConNet model showcases high accuracy in precision, recall, and specificity, suggesting its potential for widespread applications in wood classification.

Keywords: deep learning, classification and recognition, nondestructive testing, precious wood.

DOI: 10.31857/S0130308224100044

1. ВВЕДЕНИЕ

С быстрым развитием современной промышленности и повышением уровня жизни людей древесина, как возобновляемый ресурс биомассы, широко используется в таких развивающихся областях, как архитектура, мебель, ремесла, энергосберегающие здания и гибкая электроника [1, 2]. В связи с проблемой удовлетворения рыночного спроса на древесину внутри страны, значительное количество древесины приходится импортировать. Эффективная и точная идентифи-

кация импортируемой и экспортируемой древесины имеет решающее значение [3]. Традиционная классификация древесины в основном опирается на мнение опытных экспертов, изучающих макроскопическую и микроскопическую структуру древесины для определения ее типа. Хотя структура древесины обычно определяется с помощью срезов, которые обеспечивают высокую точность определения, они в значительной степени зависят от опыта экспертов, что приводит к увеличению производственных циклов при выполнении работ по срезам [4, 5]. Поэтому в данном исследовании используются методы неразрушающего контроля для получения многочисленных микроскопических изображений древесины с помощью микроКТ за один цикл, что экономит время и повышает эффективность. Данное исследование закладывает основу для использования компьютерного зрения в классификации древесины.

С развитием технологии компьютерного зрения для определения породы древесины перешли от таких традиционных методов, как химическая [6], ДНК [7], спектральная [8] и анатомическая идентификация [9], к автоматической идентификации древесины по компьютерным изображениям. Некоторые специалисты успешно применяют машинное обучение для классификации древесины на основе извлеченных макро- и микрохарактеристик изображений, что дает успешные результаты классификации [10]. Технология глубокого обучения, широко используемая в распознавании изображений и речи, также была применена для классификации древесины [11, 12]. В данном исследовании используются методы глубокого обучения для анализа 24 ценных пород древесины из схожих семейств и родов с целью повышения точности распознавания близкородственных видов.

Модель SLConNet, включающая многомасштабную сверточную обработку и слой усиления в остаточном блоке, эффективна для повышения точности идентификации модели путем настройки функции активации и значения усиления.

2. ОБЗОРНАЯ ЧАСТЬ

В сфере классификации древесины, наряду с традиционными химическими методами [6], методами идентификации по ДНК [7] и спектральными методами [8], большое внимание уделяется использованию макро- и микроизображений для идентификации древесины. Процесс изучения изображений древесины можно разделить на три этапа: распознавание анатомических структур древесины, применение алгоритмов машинного обучения для идентификации древесины и реализация алгоритмов глубокого обучения для классификации древесины.

2.1. Изучение анатомической структуры при классификации древесины

Анатомические методы идентификации обычно основаны на изучении макроскопических и микроскопических изображений поперечного сечения и радиальных тангенциальных изображений древесины квалифицированными специалистами для определения породы дерева. Макроскопическое распознавание выполняется с учетом цвета, запаха и особенностей древесины. Микроскопическая анатомическая идентификация включает анализ таких признаков, как поры, лучи древесины и осевая ткань паренхимы, для разделения типов материала [13—15]. Song и др. [16] использовали анатомические методы для сравнения различий между *Melia azedarach* и *Toona sinensis* с точки зрения изменений в ранних и поздних порах, осевой паренхиме, лучевой ткани и т.п. Liu и др. [17] изучили межвидовую и внутривидовую изменчивость трех выбранных видов *Swietenia*, сосредоточившись на ключевых количественных анатомических характеристиках, которые могут помочь в точной идентификации древесины на уровне вида.

2.2. Применение машинных алгоритмов для идентификации древесины

С развитием технологий искусственного интеллекта традиционные методы идентификации древесины переходят к автоматизированной идентификации с помощью генерируемых компьютером изображений. Этот подход предполагает извлечение характеристик древесины путем анализа изображений древесины для точного определения ее типа. Различные методы извлечения признаков древесины включают инвариантность Ху-момента, метод вейвлет-моментов [18], матрицу смежности уровней серого (МСУС) [19], метод извлечения признаков ЛБШ (локальные бинарные шаблоны) [20] и метод извлечения многомерных текстурных признаков [21]. Chao Xiaofei и др. [22] использовали методы ССРП («Статистические свойства распределения пор») и БМУС (Базовая матрица уровней серого) для извлечения признаков древесины в сочетании с классификаторами КБС (К-ближайших соседей) для эффективного распознавания особенностей древесины. Rosa и др. [23] применили метод

ЛБШ вместе с классификатором ближайших соседей для классификации микроскопических изображений 77 поперечных срезов древесины, достигнув точности внутривидовой идентификации 90 %. С помощью многомерных текстурных признаков было получено более 4200 изображений древесины 12 распространенных в Греции пород и классифицировано с помощью метода опорных векторов, причем точность классификации составила 91,47 % для поперечных срезов. Varmproutis и др. [24] также использовали метод многомерных текстурных признаков в сочетании с методом опорных векторов для классификации снимков 12 распространенных пород древесины в Греции, достигнув точности классификации 91,47 % для поперечных срезов, которая в целом была выше, чем для радиальных и тангенциальных срезов. Yadava и др. [25] усовершенствовали метод ЛБШ, используя ЕПЛБШТРХ (единый полный локальный бинарный шаблон текстурной размерной характеристики) для извлечения текстурных признаков из микроскопических изображений 72 видов широколиственных деревьев. Интегрировав этот метод с линейной классификацией методом опорных векторов, они достигли точности 97 %. Чжао и др. [26] предложили метод, объединяющий текстурные признаки и спектральные характеристики, в сочетании с методом опорных векторов для классификации поперечных срезов древесины. Эффективность классификации значительно повышается после объединения признаков по сравнению с использованием одного признака.

2.3. Применение глубокого обучения для идентификации древесины

С развитием технологий компьютерного зрения алгоритмы глубокого обучения все чаще используются для анализа и количественной оценки лесных ресурсов, направляя развитие лесного сектора в сторону интеллектуального анализа [27—29]. В отличие от традиционных подходов к машинному обучению, алгоритмы глубокого обучения не требуют ручной настройки признаков, что снижает общую рабочую нагрузку. Исследователи успешно применяют методы глубокого обучения для распознавания и классификации дефектов древесины. Например, Chen и др. [30] использовали метод СНС (сверточных нейронных сетей) для классификации четырех типов дефектов древесины, добившись точности классификации 99,3 %. Аналогичным образом Wang и др. [31] применили технологию цифровой обработки изображений и алгоритм быстрой идентификации и определения местоположения для выявления и маркировки дефектов поверхности древесины. Shi и др. [32] использовали метод многоканальной маски Р-СНС (Региональная-СНС) для классификации и определения местоположения дефектов в шпоне древесины, достигнув общей точности классификации 98,70 %. Помимо идентификации дефектов древесины, технология глубокого обучения также применялась для классификации и идентификации пород древесины. Yusof и др. и Wu и др. [33, 34] использовали методы трансферного обучения для классификации тропической древесины, продемонстрировав значительное повышение точности по сравнению с традиционными моделями. Ravindran и др. [35] подтвердили эти выводы, добившись высокой точности при классификации пород древесины с помощью VGG 16 для макроизображений 10 различных пород древесины. Кроме того, некоторые исследователи использовали независимые сетевые модели для классификации древесины. Briechle и др. [36] использовали модель сверточной нейронной сети Silvi net для классификации древесных пород, добившись точности классификации 96,1 %. С помощью сверточной модели нейронной сети InceptionV4_ResNetV2 макроизображения 10 видов лиственных пород в Северной Америке были распознаны с точностью 92,60 % [37]. Wu и др. [38] использовали методы ResNet-50, DenseNet-121 и облегченный MobileNet-V2 для классификации 11 распространенных лиственных пород, достигнув точности распознавания 98,2 %. Zhao и др. [39] представили модель PWoodIDNet для классификации и идентификации 16 редких древесных пород, достигнув точности 99 %. Для повышения точности идентификации схожих пород деревьев из разных семейств и родов Kita и др. [40] объединили изображения УНМФ (угол наклона микрофибрил) и СНС для идентификации древесных пород семейства кипарисовых (Cupressaceae), достигнув точности 90 %.

3. ПРЕДЛАГАЕМАЯ МЕТОДОЛОГИЯ

В данной статье представлены 24 вида ценных пород древесины, которые относятся к схожим семействам и родам. Для повышения точности идентификации схожих материалов построена модель SLConNet. Многомасштабная сверточная обработка используется для добавления слоя усиления на входе остаточного блока и после функции активации, а точность распознавания модели улучшается путем регулировки значения усиления.

3.1. Материалы эксперимента

В данной работе в качестве объектов исследования взяты 24 ценных вида деревьев, все из которых являются широколиственными и относятся к 2 семействам (Leguminosae и Ebenaceae) и 5 родам (*Pterocarpus*, *Dalbergia*, *Millettia*, *Senna* и *Diospyros*). Названия и сведения о семействах 24 видов красного дерева приведены в табл. 1.

Таблица 1

Сведения, связанные с изучаемыми высокоценными лиственными породами

Номер	Ботаническое название	Семейство	Номер	Ботаническое название	Семейство
A	<i>Pterocarpus santalinus</i>	Leguminosae	M	<i>Dalbergia cochinchinensis</i>	Leguminosae
B	<i>Pterocarpus erinaceus</i>	Leguminosae	N	<i>Dalbergia frutescens</i>	Leguminosae
C	<i>Pterocarpus indicus</i>	Leguminosae	O	<i>Dalbergia granadillo Pittier</i>	Leguminosae
D	<i>Pterocarpus macrocarpus</i>	Leguminosae	P	<i>Dalbergia oliveri</i>	Leguminosae
E	<i>Dalbergia odorifera</i>	Leguminosae	Q	<i>Dalbergia retusa</i>	Leguminosae
F	<i>Dalbergia cultrata</i>	Leguminosae	R	<i>Millettia laurentii</i>	Leguminosae
G	<i>Dalbergia latifolia</i>	Leguminosae	S	<i>Millettia leucantha</i>	Leguminosae
H	<i>Dalbergia louvellii</i>	Leguminosae	T	<i>Senna siamea</i>	Leguminosae
I	<i>Dalbergia melanoxylon</i>	Leguminosae	U	<i>Diospyros ebenum J.</i>	Ebenaceae
J	<i>Dalbergia Stevensonii</i>	Leguminosae	V	<i>Diospyros crassiflora</i>	Ebenaceae
K	<i>Dalbergia bariensis</i>	Leguminosae	W	<i>Diospyros celebica</i>	Ebenaceae
L	<i>Dalbergia cearensis</i>	Leguminosae	X	<i>Diospyros philippinensis</i>	Ebenaceae

3.2. Получение изображений с микроскопа

Как показано на рис. 1, были получены микроскопические изображения (поперечные, радиальные и тангенциальные срезы) 24 ценных пород деревьев с помощью трехмерной рентгеновской микротомографии высокого разрешения. Процедура эксперимента включала несколько этапов.




Рис. 1. МикроКТ, используемая для сканирования ценных пород древесины.

Шаг 1. Отобрать образцы сердцевины ценных пород деревьев по цвету, плотности и текстуре, обеспечив однородность и отсутствие дефектов, которые могли бы повлиять на идентификацию древесины.

Шаг 2. Подготовить образцы размером примерно 5 мм × 5 мм × 25 мм и поместить их в сканирующую камеру микротомографа (SKYSCAN1272) для сбора данных и реконструкции изображения.




Рис. 2. Изображения поперечных, радиальных и тангенциальных сечений 24 видов ценных пород древесины.

Шаг 3. Выставить параметры для сканирования на микротомографе, включая напряжение и ток 50 кВ и 200 мА, разрешение 2 мкм для восстановленных изображений, высоту сканирования 10 мм и время сканирования около 100 мин.

Шаг 4. Собрать данные, используя установленные параметры сканирования. Задействовать алгоритм восстановления изображения для получения томографических изображений, т. е. изображений поперечного среза образца древесины.

Шаг 5. Получить изображения радиальных и тангенциальных сечений с помощью алгоритма обработки микротомографа. Обработать изображения поперечных, радиальных и тангенциальных срезов алгоритмами улучшения.

После восстановления отсканированных изображений было получено 3000 изображений для каждого образца. Из них 1000 изображений — для поперечных срезов, 1000 — для радиальных и 1000 — для тангенциальных срезов. Размер изображений составлял 2042×1640 пикселей, разрешение — 2 мкм. На рис. 2 представлены изображения поперечных, радиальных и тангенциальных срезов 24 видов ценных пород древесины.

3.3. Структура модели

Новая модель под названием SLConNet разработана путем модификации модели ResNet. Модификации включают в себя добавление одного начального модуля после входного слоя и улучшение каждого остаточного блока. Начальный модуль состоит из одного сверточного ядра 5×5 , двух сверточных ядер 3×3 и пяти сверточных ядер 1×1 (рис. 4). Каждый остаточный




Рис. 3. Модель сверточной нейронной сети (SLConNet).




Рис. 4. Структура начального модуля.




Рис. 5. Структура улучшенных остаточных блоков.

блок модифицируется путем вставки одного масштабирующего слоя на остаточную функцию, остаточную связь и после выхода остаточного блока (рис. 5). Полная структура модели SLConNet показана на рис. 3. На входной слой поступают RGB-изображения размером 224×224 пикселя.

3.4. Структура остаточных блоков с усилением

Модель SLConNet позволяет улучшить структуру остаточных блоков. Существующие остаточные блоки делятся на два типа: к одному типу относятся остаточные блоки 1, 2, 4, 6 и 8, которые характеризуются скачкообразным изменением структуры без внедрения сверточных или нормализующих слоев. Другой тип включает остаточные блоки 3, 5 и 7, в которые включены сверточные и нормализующие слои. Оба типа структур остаточных блоков улучшаются путем добавления масштабирующего слоя к остаточной функции, остаточной связи и выходу (см. рис. 5). Масштабирующий слой позволяет регулировать значение коэффициента усиления для оптимизации модели SLConNet. Исследование показало, что оптимальное значение коэффициента усиления для достижения наивысшей точности в 98,72 % составляет 0,80. В результате время обучения составило 11408 с, а время тестирования — 22,00 с, что свидетельствует о превосходной производительности модели. Влияние различных значений коэффициента усиления на точность представлено в табл. 2.

Таблица 2

Влияние различных полученных значений на точность обучения

Прирост	Точность	Время обучения, с	Время тестирования, с
0,20	82,79	9900	22,32
0,40	96,92	11400	22,37
0,60	95,87	11940	21,96
0,80	98,72	11400	22,00
1,00	97,05	11580	22,36
1,20	97,37	11460	23,19
1,40	95,26	11520	23,18
1,60	95,80	12360	23,87

Поэтому модель SLConNet обучается с коэффициентом усиления 0,8 для всех масштабирующих слоев. В следующем разделе результаты обучения сравниваются с моделями AlexNet [41, 42], ResNet50 [43], Inception-V3 [44] и Xception [45].

4. ПОЛУЧЕНИЕ И АНАЛИЗ РЕЗУЛЬТАТОВ

4.1. Анализ результатов идентификации по трем сечениям

4.1.1. Результаты идентификации поперечных сечений

Для оценки эффективности обучения модель SLConNet сравнивается с 4 классическими моделями: Alexnet, ResNet50, Inception-V3 и Xception. Результаты обучения по поперечным сечениям представлены на рис. 6. Как показано на рис. 6а, точность модели SLConNet стабилизируется примерно после 2000 итераций, демонстрируя быструю скорость сходимости и значительно более высокую точность по сравнению с другими 4 моделями. Тогда как Alexnet, ResNet50, Inception-V3 и Xception требуют около 5000 итераций для постепенной сходимости, что демонстрирует более медленную скорость сходимости. Кроме того, точность Alexnet и ResNet50 сильно колеблется, что заметно влияет на точность обучения по сравнению с моделью SLConNet.

Как показано на рис. 6б, значение уровня потерь для SLConNet постепенно сходится с высокой скоростью к 2000 итераций. В то время как Alexnet, ResNet50, Inception-V3 и Xception демонстрируют плавное схождение через 4000 итераций, а кривые потерь Alexnet и ResNet50 демонстрируют значительные колебания. Таким образом, при обучении поперечных сечений модель SLConNet демонстрирует более высокую производительность, показывая более высокую точность обучения и более низкие значения потерь по сравнению с другими моделями.

4.1.2. Результаты идентификации радиальных сечений

Результаты обучения для радиальных участков показаны на рис. 7. Для проверки эффективности обучения модель SLConNet сравнивается с 4 классическими моделями. На рис. 7а видно,




Рис. 6. Сравнение результатов идентификации поперечных сечений: точность (а); уровень потерь (б).




Рис. 7. Сравнение результатов идентификации радиальных сечений: точность (а); уровень потерь (б).

что точность модели SLConNet стабилизируется примерно после 1500 итераций, демонстрируя более высокую скорость сходимости и значительно более высокую точность по сравнению с другими четырьмя моделями. С другой стороны, AlexNet, ResNet50, Inception-V3 и Xception требуют около 5000 итераций для постепенной сходимости, при этом скорость сходимости ниже. На рис. 7б значения потерь для модели SLConNet достигают сходимости с высокой скоростью после 2000 итераций. Напротив, значения потерь для ResNet50, Inception-V3 и Xception постепенно сходятся после 4000 итераций, в то время как значения потерь для AlexNet и ResNet50 демонстрируют значительные колебания.

4.1.3. Результаты идентификации тангенциальных сечений

Результаты обучения для тангенциальных сечений 24 пород ценных пород древесины представлены на рис. 8. Точность моделей показана на рис. 8а. SLConNet демонстрирует более высокую скорость сходимости и немного более высокую точность, чем Inception-V3 и Xception, и значительно превосходит Alexnet и ResNet50. Точность обучения для SLConNet остается стабильной с минимальными колебаниями. Значения потерь показаны на рис. 8б. SLConNet демонстрирует самое быстрое снижение значений потерь, стабильную кривую и эффективную сходимость, превосходя Alexnet и ResNet50. Напротив, значения потерь для Alexnet и ResNet50 медленно снижаются и сильно колеблются в процессе обучения. Модель SLConNet превосходит по скорости сходимости и величине потерь модели Inception-V3 и Xception.




Рис. 8. Сравнение результатов идентификации тангенциальных сечений: точность (а); уровень потерь (б).

Результаты идентификации поперечного, радиального и тангенциального сечений представлены в табл. 3. Для идентификации поперечных сечений точность модели SLConNet составляет 98,72 %, превосходя Alexnet, ResNet50, Inception-V3 и Xception на 3,50, 3,90, 1,41 и 1,12 % соответственно. Для радиальных сечений модель SLConNet достигает точности 96,75 %, превосходя Alexnet, ResNet50, Inception-V3 и Xception на 7,93, 6,97, 1,74 и 1,21 % соответственно. По тангенциальным сечениям модель SLConNet достигает точности 95,36 %, превосходя Alexnet, ResNet50, Inception-V3 и Xception на 9,51, 9,22, 0,4 и 0,19 % соответственно. Значения потерь модели SLConNet для поперечного, радиального и тангенциального сечений составляют 0,0756, 0,1077 и 0,0962 соответственно, что значительно ниже, чем у других классических моделей.

Таблица 3

Сравнение и анализ результатов идентификации древесины по трем сечений

Модель	Поперечные сечения			Радиальные сечения			Тангенциальные сечения		
	Точность, %	Уровень потерь	Время обучения/тестирования, с	Точность, %	Уровень потерь	Время обучения/тестирования, с	Точность, %	Уровень потерь	Время обучения/тестирования, с
SLConNet	98,72	0,0756	9075/109	96,75	0,1077	9620/117	95,36	0,0962	9980/119
Alexnet	95,22	0,1539	45120/119	88,82	0,3871	46200/118	85,85	0,4582	46680/123
ResNet50	94,82	0,1611	20520/130	89,78	0,3908	21000/125	86,14	0,4757	21240/121
Inception-V3	97,31	0,0876	38400/121	95,01	0,1239	39000/129	94,96	0,1420	39540/119
Xception	97,60	0,0840	27420/119	95,54	0,1220	28140/119	95,17	0,1469	27900/120

Таким образом, очевидно, что модель SLConNet превосходит классические модели и демонстрирует явные преимущества при идентификации ценных пород древесины. Веса оптимизируются в процессе обучения, а затем применяются для тестирования 30 % оставшихся изображений. Этот процесс дает средние значения точности и потерь для тестового набора, которые приведены в табл. 3. Модель SLConNet демонстрирует более высокую точность распознавания поперечных, радиальных и тангенциальных разрезов по сравнению с моделями AlexNet, ResNet50, Inception-V3 и Xception. Кроме того, модель SLConNet демонстрирует наименьшие значения потерь и значительно превосходит другие модели по времени тестирования. В разделе 4.2 для дальнейшей оценки эффективности модели SLConNet используются дополнительные метрики, такие как PREC (точность), REC (чувствительность) и SPEC (специфичность).

4.2. Оценка модели

При сравнении с классическими моделями, такими как Alexnet, ResNet50, Inception-V3 и Xception4, модель SLConNet демонстрирует более высокую точность идентификации — 98,72, 96,75 и 95,36 % для поперечных, радиальных и тангенциальных сечений. Это преимущество можно объяснить включением масштабирующих слоев в выходные данные, остаточную функцию и остаточную связь остаточных блоков. Для дальнейшей оценки эффективности модели на основе результатов идентификации поперечного, радиального и тангенциального сечений была построена матрица путаницы, как показано на рис. 9.

Точность классификации для каждого из 24 видов на поперечных срезах составляет более 93,3% (на рис. 9а). Некоторые виды, например, А-тип *Pterocarpus santalinus*, легко спутать с другими, такими как F-*Dalbergia cultrata*. Аналогично, H-*Dalbergia louvellii* и I-*Dalbergia melanoxylon* могут быть приняты за K-*Dalbergia bariensis* из-за сходства типа пор сосудов, размера и распределения осевой паренхимы, что приводит к ошибочной классификации.

На рис. 9б видно, что точность классификации 24 видов в радиальных разрезах превышает 86,67 %. Некоторые виды, например, класс A-*Pterocarpus santalinus*, могут быть ошибочно приняты за класс G-*Dalbergia latifolia*, класс B-*Pterocarpus erinaceus* и класс C-*Pterocarpus indicus*. Кроме того, класс H-*Dalbergia louvellii* может быть ошибочно принят за класс K-*Dalbergia bariensis*, а класс J-*Dalbergia Stevensonii* — за класс N-*Dalbergia frutescens* из-за сходства микроструктуры, в частности, лежащей лучевой клетки и древесных лучей, что приводит к неправильной классификации.

Как показано на рис. 9в, классификация тангенциальных срезов 24 ценных пород древесины показала точность более 85,33 % для каждой категории. Примечательно, что у некоторых видов древесины риск ошибки выше, например, H-*Dalbergia louvellii* часто принимают за J-*Dalbergia Stevensonii*, класс J-*Dalbergia Stevensonii* часто путают с классом N-*Dalbergia frutescens*, а класс K-*Dalbergia bariensis* легко идентифицировать с E-*Dalbergia odorifera* и H-*Dalbergia louvellii*. Кроме того, класс Q-*Dalbergia retusa* легко спутать с O-*Dalbergia granadillo Pittier*, что объясняется структурным сходством в распределении и расположении лучевых клеток у этих видов.

Результаты матрицы путаницы на рис. 8 указывают на ошибки классификации в поперечном, радиальном и тангенциальном разрезах. Для точной оценки эффективности классификации используются такие параметры, как PREC, REC и SPEC, которые определяются:

$$\text{PREC} = \frac{\text{ИП}}{\text{ИП} + \text{ЛП}}; \quad (1)$$


$$\text{REC} = \frac{\text{ИП}}{\text{ИП} + \text{ЛО}}; \quad (2)$$

$$\text{SPEC} = \frac{\text{ИО}}{\text{ИО} + \text{ЛП}}. \quad (3)$$


ИП (истинно-положительный) означает, что в реальной ситуации объект обладает искомым признаком, и прогнозируемый результат это подтверждает; ИО (истинно-отрицательный) означает, что в реальной ситуации объект не обладает искомым признаком, а прогнозируемый результат это подтверждает; ЛО (ложно-отрицательный) означает, что в реальной ситуации объект обладает искомым признаком, а прогнозируемый результат это отрицает; ЛП (ложно-положительный) означает, что в реальной ситуации объект не обладает искомым признаком, а прогнозируемый результат это отрицает.

В табл. 4 представлены значения оценок PREC, REC и SPEC для 24 ценных пород древесины. Средняя точность для поперечных сечений составляет 98,76, 98,77 и 99,94 % соответственно. Для радиальных сечений средняя точность составляет 96,71, 96,77 и 99,86 % соответственно. Средняя точность для тангенциальных сечений составляет 95,36, 95,39 и 99,80 % соответственно. Полученные результаты свидетельствуют о том, что поперечные срезы имеют самую высокую точность идентификации. Более того, несколько ценных пород древесины демонстрируют точность идентификации на уровне 100 %, включая S-*Millettia leucantha*, T-*Senna siamea*, U-*Diospyros sp.*, V-*Diospyros crassiflora*, W-*Diospyros celebica* и X-*Diospyros sp.*

а



б



в




Рис. 9. Матрицы путаницы для различных сечений: продольное (а); радиальное (б); тангенциальное (в).

Таблица 4

Эффективность классификации по трем сечениям

№	Поперечные сечения			Радиальные сечения			Тангенциальные сечения		
	PREC/%	REC/%	SPEC/%	PREC/%	REC/%	SPEC/%	PREC/%	REC/%	SPEC/%
A	97,22	97,20	99,71	91,67	96,15	99,64	95,00	91,35	99,78
B	99,67	99,67	100,00	100,00	96,77	100,00	97,33	97,99	99,88
C	99,01	99,01	100,00	98,67	97,69	99,94	98,33	100,00	99,93
D	98,35	98,34	99,97	98,33	91,33	99,93	96,00	94,74	99,83
E	99,67	99,67	99,97	96,67	98,98	99,86	98,67	94,27	99,94
F	95,83	95,81	99,99	93,33	96,89	99,71	91,67	91,06	99,64
G	99,01	99,01	99,99	99,67	92,86	99,99	95,67	94,10	99,81
H	99,64	99,64	99,71	86,67	98,11	99,42	93,33	94,92	99,71
I	97,70	97,70	99,96	96,67	98,31	99,86	98,67	99,33	99,94
J	95,35	95,47	99,81	88,33	94,64	99,49	85,33	87,97	99,36
K	96,09	96,09	99,93	93,33	92,41	99,71	85,67	97,72	99,38
L	100,00	100,00	99,96	95,00	97,27	99,78	98,33	97,36	99,93
M	97,05	97,05	99,94	96,67	96,03	99,86	95,00	100,00	99,78
N	96,10	96,10	99,94	97,00	89,26	99,87	92,67	90,26	99,68
O	100,00	100,00	99,91	100,00	97,72	100,00	98,67	92,21	99,94
P	99,67	99,67	100,00	96,67	98,64	99,86	96,67	95,71	99,86
Q	100,00	100,00	99,94	100,00	95,24	100,00	92,00	94,20	99,65
R	100,00	100,00	99,94	100,00	99,34	100,00	97,33	90,97	99,88
S	100,00	100,00	100,00	96,00	97,96	99,83	92,00	95,50	99,65
T	100,00	100,00	100,00	99,00	99,00	99,96	93,00	96,88	99,70
U	100,00	100,00	100,00	97,33	97,99	99,88	97,33	97,66	99,88
V	100,00	100,00	100,00	100,00	100,00	100,00	100,00	99,34	100,00
W	100,00	100,00	100,00	100,00	100,00	100,00	100,00	99,34	100,00
X	100,00	100,00	100,00	100,00	100,00	100,00	100,00	96,46	100,00
Среднее	98,76	98,77	99,94	96,71	96,77	99,86	95,36	95,39	99,80

5. ОБСУЖДЕНИЕ

В ходе эксперимента были проанализированы поперечные, радиальные и тангенциальные срезы 24 различных пород ценной древесины. Поперечные срезы показали заметно более высокую точность классификации по сравнению с двумя другими срезами, что, вероятно, связано с распределением микроскопических структурных особенностей, характерных только для поперечных срезов. Barmpoutis и др. [24] также получили аналогичные результаты при классификации поперечных, тангенциальных и радиальных срезов древесины с использованием набора данных WOOD-AUTH.

По сравнению с такими классическими моделями, как Alexnet, ResNet50, Inception-V3 и Xception4, модель SLConNet включает в себя остаточные структуры и модули Inception. Это не только повышает скорость сходимости и эффективность обучения сети, но и позволяет извлекать многомерную информацию из входных данных, что в конечном итоге улучшает эффективность классификации модели. Feng и др. [46] продемонстрировали повышение точности классификации гиперспектральных изображений за счет интеграции остаточных блочных структур

в сеть. Такая интеграция способствует лучшему обмену информацией между неглубокими и глубокими сетями, что приводит к извлечению глубоких характеристик из гиперспектральных изображений. Кроме того, Yao и др. [47] предложили многомасштабную SE (Squeeze and Excitation)-Residual Network с кодером преобразования (MRTNet) для повышения эффективности классификации за счет использования как глобальных, так и локальных особенностей сердцебиения.

В данном исследовании большое количество изображений было получено одновременно с помощью микротомографа, что дает значительные преимущества в поиске изображений древесины по сравнению с традиционными анатомическими методами. Однако наш эксперимент был направлен на сканирование и восстановление трех конкретных участков сердцевины из одного образца ценной древесины, что может ограничить обобщаемость наших результатов. Будущие исследования будут направлены на расширение диапазона категорий ценной древесины за счет включения образцов из различных источников одной и той же породы.

6. ЗАКЛЮЧЕНИЕ

В данной работе для получения микроскопических изображений поперечных, радиальных и тангенциальных срезов древесины используется такой метод неразрушающего контроля, как микротомография. По сравнению с традиционными методами срезов он очень эффективен, поскольку за один раз можно получить тысячи микроскопических изображений, что закладывает основу для глубокого обучения.

В данном исследовании была разработана модель SLConNet для анализа микроскопических изображений поперечных, радиальных и тангенциальных срезов ценной древесины с использованием многомасштабных операций свертки для извлечения множества признаков. Результаты показывают, что точность идентификации по поперечным срезам значительно выше, чем по радиальным и тангенциальным, что объясняется большим количеством текстурной информации, присутствующей в поперечных срезах. Из 29 признанных видов ценных пород древесины в экспериментальный набор данных включены только 24 распространенных вида, что связано с редкостью некоторых видов на рынке. Результаты эксперимента показывают, что модель SLConNet превосходит такие традиционные модели, как Alexnet, ResNet50, Inception-V3 и Xception, в точности идентификации видов ценных пород древесины на основе поперечных, радиальных и тангенциальных сечений.

Представленная работа поддержана Фондом естественных наук провинции Шаньдун Китая (№ ZR2020QC174), Национальным фондом естественных наук Китая (№ 62173127, 62472143), Ключевыми специальными проектами НИОКР в провинции Хэнань (№ 241111521000), Фондом лучших молодых талантов Центральной равнины (№ (2023)11).

Авторы заявляют, что у них нет конфликта интересов, о котором они могли бы сообщить в связи с настоящим исследованием.

СПИСОК ЛИТЕРАТУРЫ

1. Huang W., Li H.Q., Guan H. и др. Advances in functionalization and application of natural woods // *Materials Reports*. 2022. V. 36. No.18. P. 224—230.
2. Amini M.H.M., Temiz A., Hekimolu G. и др. Properties of scots pine wood impregnated with capric acid for potential energy saving building material // *Holzforschung*. 2022. V. 76. No. 8. P. 1.
3. Rojas J.A.M., Alpuente J., Postigo D., Rojas I.M., Vignote S. Wood species identification using stress-wave analysis in the audible range // *Appl Acoust*. 2011. V. 72. No.12. P. 934—942.
4. Jiao L., Lu Y., He T., Guo J., Yin Y. DNA barcoding for wood identification: global review of the last decade and future perspective // *IAWA Journal*. 2020. V. 41. No. 4. P. 620—643.
5. Wang C.K., Zhao P. Classification of wood species using spectral and texture features of transverse section // *European Journal of Wood and Wood Products*. 2021. V. 79. P. 1283—1296.
6. Creydt M., Lautner S., Fromm J. и др. Wood profiling by non-targeted liquid chromatography high-resolution mass spectrometry: Part 2, Detection of the geographical origin of spruce wood (*Picea abies*) by determination of metabolite pattern // *Journal of chromatography*. 2021. V. 1663. P. 462737.
7. Jiao L., Yu M., Wiedenhoeft A.C. и др. DNA barcode authentication and library development for the wood of six commercial *Pterocarpus* species: the critical role of xylarium specimens // *Scientific Reports*. 2018. No. 8. P. 1945.
8. Sun X.D., Cui D.D., Shen Y. и др. Non-destructive detection for foreign bodies of tea stalks in finished tea products using terahertz spectroscopy and imaging // *Infrared Physics Technology*. 2022. No. 121. P. 04018.
9. Helmling S., Olbrich A., Heinz I. и др. Atlas of vessel elements // *IAWA Journal*. 2018. V. 39. No. 3. P. 249—352.

10. Santosa S., Pramunendar R.A., Prabowo D.P. и др. Wood types classification using back-propagation neural network based on Genetic algorithm with gray level co-occurrence matrix for features extraction // *IAENG International Journal of Computer Science*. 2019. V. 46. P. 149—155.
11. Khalil R.A., Jones E., Babar M.I. и др. Speech emotion recognition using deep learning techniques: A review // *IEEE Access*. 2019. V. 99. P. 1.
12. Huang J.X., Lu X., Chen L.Y. и др. Accurate identification of pine wood nematode disease with a deep convolution neural network // *Remote Sensing*. 2022. V. 14. P. 913.
13. IAWA Committee. IAWA list of microscopic features for softwood identification // *IAWA Journal*. 2004. V. 25. No.1. P. 1—70.
14. Wheeler E.A., Baas P., Gasson P.E. и др. IAWA list of microscopic features for hardwood identification // *IAWA Journal*. 1989. V. 10. No. 3. P. 219—332.
15. Helmling S., Olbrich A., Heinz I. и др. Atlas of vessel elements // *IAWA Journal*. 2018. V. 39. No.3. P. 249—352.
16. Song L.H., Lei F.J., Huang Y.H. и др. Anatomical properties of melia azedarach and toona sinensis Woods // *Guangxi Forestry Science*. 2023. V. 52. No. 6. P. 781—786.
17. Liu S.J., He T., Lu Y. и др. Quantitative anatomy analysis on wood feature variability and wood identification of Swietenia Species // *Scientia Silvae Sinicae*. P. 1—11.
18. Guo J.X., Hu M. Features extraction and classification of wood defect based on hu invariant moment and wavelet moment and BP neural network / *The 12th International Symposium*, 2019.
19. Riana D., Rahayu S., Hasan M., Anton V.D.H. Comparison of segmentation and identification of swietenia mahagoni wood defects with augmentation images // *Heliyon*. 2021. V. 7. No. 6. P. 7417.
20. Yang X.X., Gao Y.S., Zhang S.H. Research on rosewood micro image classification method based on feature fusion and ELM // *Journal of Renewable Materials*. 2022. V. 10. No. 12. P. 3587—3598.
21. Barmpoutis P., Dimitropoulos K., Barboutis I. и др. Wood species recognition through multidimensional texture analysis // *Computers and Electronics in Agriculture*. 2018. V. 144. P. 241—248.
22. Chao X.F., Fan L.H., Cai C. и др. Wood texture classification and identification based on multi-feature extraction and selection // *Modern Agricultural Science*. 2018. No. 18. P. 118—120.
23. Rosa da Silva N., De Ridder M., Baetens J. M., Van den Bulcke J., Rousseau M. и др. Automated classification of wood transverse cross-section micro-imagery from 77 commercial Central-African timber species // *Annals of Forest Science*. 2017. V. 74. No. 2. P. 30.
24. Barmpoutis P., Dimitropoulos K., Barboutis I., Grammalidis N., Lefakis P. Wood species recognition through multidimensional texture analysis // *Computers And Electronics In Agriculture*. 2018. V. 144. P. 241—248.
25. Yusof R.A., Ahmad A.B., Khairuddin A.S.M.C. Transfer learning approach in automatic tropical wood recognition system // *Computational and Experimental Simulations in Engineering*. 2020. V. 75. P. 1225—1233.
26. Zhao P., Han J.C., Wang C.K. Classification of wood species using hyperspectral microscopic imaging based on I-BGLAM texture and spectral fusion // *Spectroscopy and Spectral Analysis*. 2021. V. 41. No. 2. P. 599—605.
27. Bruno O., Ribas L., Condori R. M., Scabini L. S., Bruno O., Ribas L. и др. Evaluating deep convolutional neural networks as texture feature extractors // *International Conference on Image Analysis and Processing*, 2019.
28. Fabijanska A., Danek M., Barniak J. Wood species automatic identification from wood core images with a residual convolutional neural network // *Computers and Electronics in Agriculture*. 2021. V. 181. P. 105941.
29. Wang Y., Zhang W., Gao R., Jin Z., Wang X.H. Recent advances in the application of deep learning methods to forestry // *Wood Science and Technology*. 2021. V. 55. No. 5. P. 1171—1202.
30. Chen L.X., Ge Z.D., Luo R. и др. Identification of CT image defects in wood based on convolution neural network // *Entia Silvae Sinicae*. 2018. V. 54. No. 11. P. 127—133.
31. Wang H., Li Z., Zou X. Wood surface defect detection based on adaboost and CNN (Article) // *Journal of System Simulation*. 2019. V. 31. No. 8. P. 1636—1645.
32. Shi J., Li Z., Zhu T., Wang D., Ni C. Defect detection of industry wood veneer based on NAS and multi-channel mask R-CNN // *Sensors*. 2020. V. 20. No.16. P. 4398.
33. Yusof R.A., Ahmad A.B., Khairuddin A.S.M.C. Transfer learning approach in automatic tropical wood recognition system // *Computational and Experimental Simulations in Engineering*. 2020. V. 75. P. 1225—1233.
34. Wu F., Gazo R., Haviarova E., Benes B. Wood identification based on longitudinal section images by using deep learning // *Wood Science and Technology*. 2021. V. 55. No. 2. P. 553—563.
35. Ravindran P., Costa A., Soares R., Wiedenhoef A.C. Classification of CITES-listed and other neotropical Meliaceae wood images using convolutional neural networks // *Plant Methods*. 2018. V. 14. No. 1. P. 25.
36. Briechle S., Krzystek P., Vosselman G. Silvi-Net-A dual-CNN approach for combined classification of tree species and standing dead trees from remote sensing data // *International Journal of Applied Earth Observation and Geoinformation*. V. 98. P. 102292.
37. Verly Lopes D.J., Burgreen G.W., Entsminger E.D. North American hardwoods identification using machine-learning // *Forests*. 2020. V. 11. No. 3. P. 298.

38. *Wu F., Gazo R., Haviarova E., Benes B.* Wood identification based on longitudinal section images by using deep learning // *Wood Science and Technology*. 2021. V. 55. No. 2. P. 553—563.
 39. *Zhao Z.Y., Yang X.X., Ge Z.D., Zhou Y.C.* Wood microscopic image identification method based on convolution neural network // *BioResources*. 2021. V. 16. No. 3. P. 4986—4999.
 40. *Kita Y., Sugiyama J.J.* Wood identification of two anatomically similar cupressaceae species based on two-dimensional microfibril angle mapping // *Holzforschung*. 2021. V. 75. No. 7. P. 591—602.
 41. *Shanthi T., Sabeenian R.S.* Modified Alexnet architecture for classification of diabetic retinopathy images // *Computers and Electrical Engineering*. 2019. V. 76. P. 56—64.
 42. *Unnikrishnan A., Sowmya V., Soman K.P.* Deep AlexNet with reduced number of trainable parameters for satellite image classification // *Procedia Computer Science*. 2018. V. 143. P. 931—938.
 43. *Paisitkriangkrai S., Shen C., Anton V.D.H.* Learning to rank in person re-identification with metric ensembles / *IEEE conference on computer vision and pattern recognition (CVPR)*. 2015.
 44. *Arredondo J.R.P., Tanscheit R., Monteiro E.C., da Silva E.C., de Sousa I.P.* Classification of mechanisms underlying cardiac arrhythmias by deep learning // *Research on Biomedical Engineering*. 2020. V. 36. No. 4. P. 475—487.
 45. *Polat Z.* Detection of Covid-19 from chest CT images using xception architecture: A deep transfer learning based approach // *Sakarya University Journal of Science*. 2021. V. 25. No. 3. P. 813—823.
 46. *Feng B., Liu Y., Chi H., Chen X.Z.* Hyperspectral remote sensing image classification based on residual generative adversarial neural networks // *Signal Processing*. 2023. V. 213. No. 9. P. 109202.
 47. *Yao Q.Y., Zhang L.M., Zheng W.G., Zhou Y.X.* Multi-scale SE-residual network with transformer encoder for myocardial infarction classification // *Applied Soft Computing*. 2023. V. 149. P. 110919.
-