

Астафьев А.В., Кондрушин И.Е., Демидов А.А.
Муромский институт (филиал) федерального государственного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых»
602264, г. Муром, Владимирская обл., ул. Орловская, 23
E-mail: Alexandr.Astafiev@mail.ru

Проектирование нейронной сети для разработки генеративной модели восстановления синхронизированных фаз показаний состояния уровня сигналов точек WiFi

Распространение мобильных терминалов, таких как смартфоны, планшеты и ноутбуки, стимулировало огромный интерес к локализации внутри помещений и услугам на основе определения местоположения [1]. В качестве одной из популярных схем локализации в помещении подход на основе снятия цифровых отпечатков. Сначала создается база данных с тщательными измерениями поля, а затем делается вывод о местоположении в реальном времени путем сравнения новых измерений с данными базы данных. Перспективным направлением повышение точности является исследования радиосигнала по каналам channel state information (CSI).

CSI – это, информация которая описывает, как сигнал распространяется от передатчика к приемнику. В беспроводных сетях, использующих OFDM модуляцию, CSI представляет собой комплексное число, в котором содержится информация об амплитуде и фазе сигнала. Пакет данных CSI содержит набор комплексных чисел, соответствующей каждой поднесущей [2].

В работе [2] авторами описан подход получения данных о состоянии канала связи (CSI) и синхронизации полученных фаз. Для примера был собран набор данных, включающий в себя информацию о состоянии канала связи CSI, состоящий из 4 657 показаний. Одно показание представляет собой информацию об амплитуде и фазе каждой из 56 поднесущих. В итоге, количество измерений составляет 521 584 значения. Полученные показания были предобработаны с целью удаления выбросов и нормирования шкалы измерения. После этого, данные о фазе сигналов по поднесущим были синхронизированы для компенсации случайных фазовых сдвигов от пакета к пакету из-за ошибок синхронизации в приемнике. Визуализация полученных результатов приведена на рисунке 1.

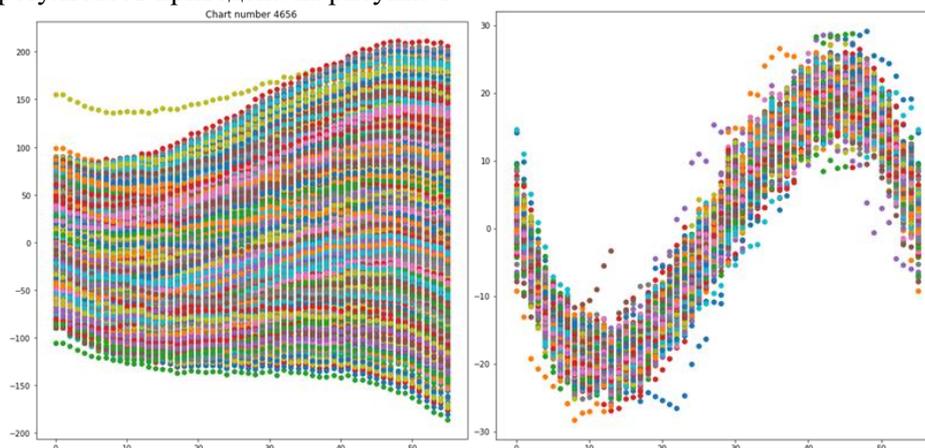


Рисунок 1 – пример синхронизированных фаз, полученных из набора данных CSI

Проведенные предварительные исследования показали, что использование обработанных показаний фаз с использованием классических математических методов и методов интеллектуального анализа не даёт высокой точности. Пробное исследование с использованием полносвязной нейронной сети на небольшом наборе данных показало точность не выше 21,8%.

Исходя из анализа отечественной и зарубежной научно-технической базы был сделан вывод, что для получения описания контролируемой территории в терминах цифровой обработки сигналов на основе синхронизированных фаз необходимо разработать генеративную модель восстановления синхронизированных фаз показаний состояния уровня сигналов точек

WiFi, скрытая информация которой будет являться использоваться для снятия цифровых отпечатков.

В работе [1] авторы предлагают использование обучения без учителя на основе ограниченной сеть Больцмана для построения генеративной модели восстановления синхронизированных фаз показаний состояния уровня сигналов точек WiFi. Схематично, предложенную схему можно представить в виде рисунка 2.

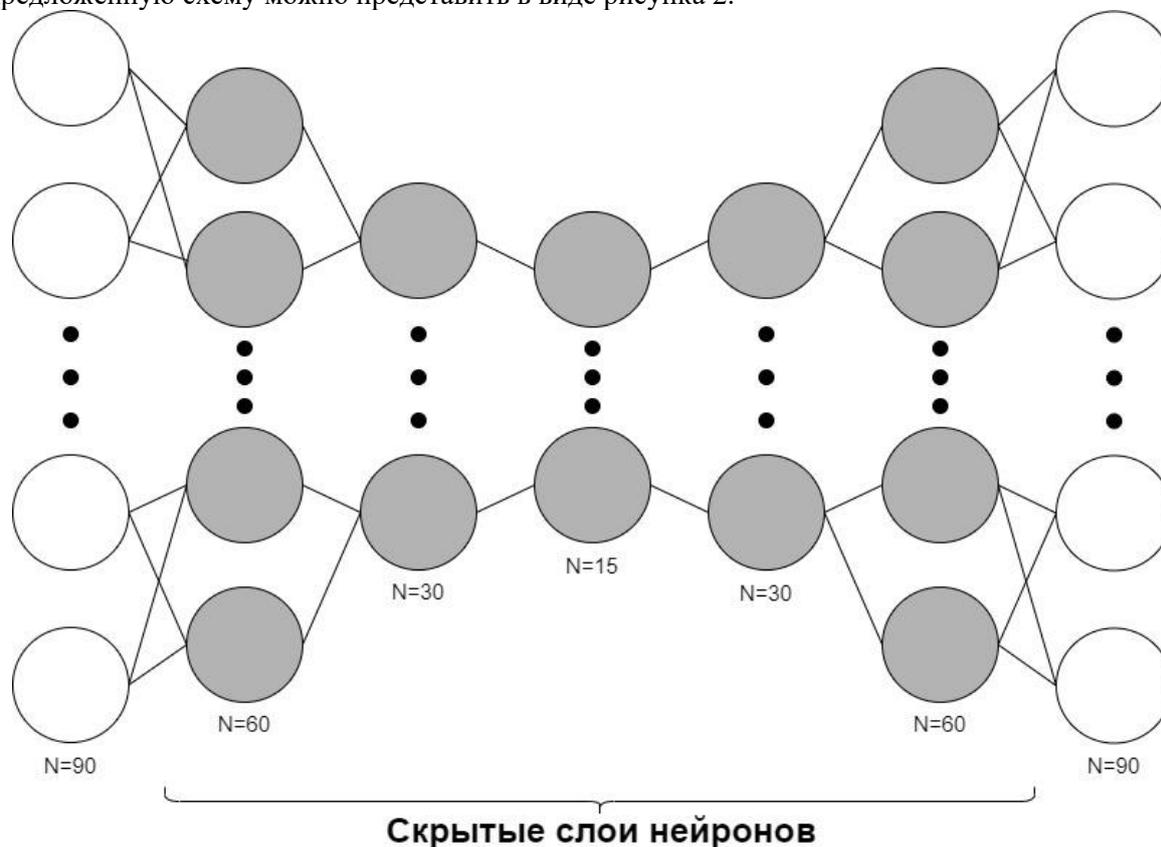


Рисунок 2 – схема нейронной сети, предложенная авторами работы [1]

В работе [1] используется оборудование на основе плат Intel 5300, которые позволяют получать информацию о состоянии канала связи по 3 антеннам и 30 поднесущим. Таким образом, на вход нейронной сети поступает 90 значений, что является количеством нейронов во входном, первом слое.

В настоящей работе базовым оборудованием являются устройства на базе плат Atheros, которые позволяют получать данные по 3 антеннам и 56 поднесущим. Исходя из этого, планируется использование схожей по структуре нейронной сети, но с большим количеством нейронов. Так, на входной слой будет поступать не 90, а 168 значений. Таким образом количество нейронов входного слоя возрастёт до 168 и все последующие слои также изменят количество нейронов.

Литература

1. X. Wang, L. Gao and S. Mao, "CSI Phase Fingerprinting for Indoor Localization With a Deep Learning Approach," in IEEE Internet of Things Journal, vol. 3, no. 6, pp. 1113-1123, Dec. 2016, doi: 10.1109/IJOT.2016.2558659.
2. Астафьев А.В. Исследование применимости использования информации о состоянии канала передачи данных для организации позиционирования внутри помещений / А.В. Астафьев, А.Л. Жизняков, А.А. Демидов, И.Е. Кондрушин // Математические методы распознавания образов: Тезисы докладов 20-й Всероссийской конференции с международным участием, г. Москва 2021 г. — М.: Российская академия наук, 2021. — 385-386 с.

Быков А.А.

*Муромский институт (филиал) федерального государственного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых»
602264, г. Муром, Владимирская обл., ул. Орловская, 23
E-mail: bykov_a_a@list.ru*

Вертикальная электротомография процесса бурения скважин

В последние десятилетия наблюдается рост добычи нефти и газа на фоне сокращения ввода новых месторождений. Многие эксперты связывают это в первую очередь с повышением эффективности бурения. Внедрение новых технологий позволило значительно увеличить добычу нефти и сократить сроки строительства скважин. Так, согласно информации департамента энергетики США (EIA) рост добычи на нетрадиционных месторождениях за последние 7 лет составил от 200% до 500% в пересчете на 1 буровую [1]. Переход от бурения вертикальных и наклонно-направленных скважин к бурению горизонтальных скважин увеличил эффективность бурения.

Бурение скважин — дорогостоящий процесс, существенно влияющий на себестоимость добычи нефти. Чтобы эффективно разрабатывать трудноизвлекаемые запасы, нужно строить сложные, высокотехнологичные и эффективные скважины.

Целью работы является разработка метода контроля процесса бурения, что позволит снизить временные затраты, а значит – повысить эффективность процесса бурения.

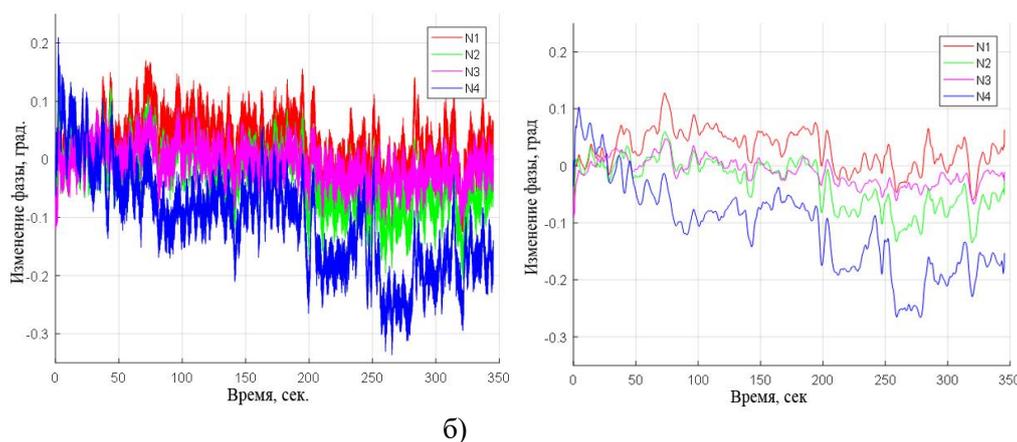
Значительно повысить эффективность бурения позволит применение методов вертикальной электротомографии в реальном времени [1].

Прогнозирование пространственного положения скважины позволит принимать более качественные решения о дальнейшем бурении, даст возможность в режиме реального времени определять продуктивность скважины и за счет этого сократит время на оценку эффективности бурения при текущем положении бурового инструмента.

Известна высокая эффективность систем векторных измерений с регистрацией фазовых характеристик электромагнитного поля. Эти системы лежат в основе фазометрического метода геоэлектрического контроля с использованием фазовых характеристик поля для последующего обнаружения и локализации геодинамических процессов [3]. Данный метод контроля обладает высокой помехоустойчивостью и чувствительностью по сравнению с фиксацией амплитудных параметров аномальных составляющих электромагнитного поля. В данном случае объектом контроля являются технологическое оборудование, скважина и окружающий ее грунт.

В работе [4] поясняется применение фазометрического метода геоэлектрического контроля, а именно использование нескольких источников зондирующих сигналов, расположенных в непосредственной близости от исследуемого объекта и необходимого количества векторных датчиков измерения электрического поля. При этом регистрация фазовых характеристик при фиксированном положении источников и измерительного базиса при возможности управления параметрами зондирующих сигналов основана на том, что первичное и вторичное электрические поля являются векторными величинами.

На рисунке 1 в качестве примера показаны результаты моделирования изменения фаз сигналов с четырех приемных линий системы фазометрического контроля во времени в процессе погружения бура в грунт.



а) б)
Рис. 1. Зависимость изменения фазы сигнала от глубины проникновения бура до (а) и после (б) использования фильтра скользящего среднего (длительность окна усреднения составляла 5 сек)

При этом установлено, что чем больше глубина погружения, тем больше изменяется фаза. Бур погружался в грунт на глубину от 0 до 1 м. Таким образом, по степени изменения фазы сигнала с различных приёмных линий можно судить о процессе погружения бура в грунт. Относительная погрешность определения глубины погружения бура составила 10-15%, но этот показатель будет снижаться при увеличении глубины погружения. В случае необходимости осуществления контроля не только глубины погружения бура, но и его местоположения относительно электродов, возможно изменить данную установку, расположив электроды крестообразно [4].

Литература

1. Annual Energy Outlook 2012. With Projections to 2035. – 2012. – June. U.S. Energy Information Administration. Available at: [http://www.eia.gov/forecasts/aeo/pdf/0383\(2012\).pdf](http://www.eia.gov/forecasts/aeo/pdf/0383(2012).pdf). (accessed 5 November 2013).
2. Baknin Maxim, Bykov Artem, Surzhik Dmitry, Kuzichkin Oleg, Geotechnical monitoring of the foundations of structures based on integrated seismoelectric measurements in conditions of karst hazard, 20th International Multidisciplinary Scientific GeoConference Proceedings SGEM 2020. Volume: 20. Pages: 559-566.
3. Baknin M, Surzhik D, Vasilyev G, Dorofeev N., The modeling of the Phase-Metric Method of the Geoelectrical Control of Oil Sludge Straits, IOP Conference Series: Earth and Environmental Science, 2020 .
4. Kuzichkin, Oleg & S., Vasilyev & Grecheneva, Anastasia & V., Mikhaleva & Baknin, Maxim & Surzhik, D.I., Application of phase-metric measuring system for geodynamic control of karst processes, Journal of Engineering and Applied Sciences, vol. 12, pp. 6858-6563, 2017.

Ватутин Э.И., Титов В.С.
Юго-Западный государственный университет
305040, г. Курск, ул. 50 лет Октября, 94

Оценка аппаратной сложности логических мультиконтроллеров в зависимости от значений технологических ограничений и методов синтеза разбиений граф-схем параллельных алгоритмов

Одним из распространенных классов цифровых управляющих систем являются логические мультиконтроллеры (ЛМК) [1]. ЛМК представляет собой коллектив однотипных контроллеров, в совокупности решающий возложенную на них задачу управления некоторым объектом путем получения от него сигналов логических условий и выдачи сигналов микроопераций в дискретные моменты времени. В основе проектирования ЛМК лежит задача поиска субоптимального разбиения заданной граф-схемы $G = \langle A, V \rangle$ параллельного алгоритма логического управления на блоки (подалгоритмы) $\Gamma = \{A_1, A_2, \dots, A_H\}$ ограниченной сложности с целью выполнения каждого из них одним из контроллеров в составе ЛМК. Данная задача относится к дискретным комбинаторным задачам многокритериальной оптимизации, а качество ее решения напрямую влияет на аппаратную сложность и быстродействие синтезируемого ЛМК.

Аппаратная сложность ЛМК складывается из аппаратной сложности логических контроллеров и связывающей их коммуникационной подсистемы и определяется как

$$R = \left(R_H + R_X X Y W_{max} R_C \left(\sum_{i=1}^H |X(A_i)| + \sum_{i=1}^H |Y(A_i)| \right) \sum_{\alpha} \sum_{i=1}^H \sum_{j=1}^H \alpha(A_i, A_j) \right)_{max}$$

где $R_H, R_X, R_Y, R_W, R_C, R_\alpha$ – соответственно аппаратные сложности логического контроллера в составе ЛМК, портов ввода/вывода в составе логических контроллеров для приема сигналов логических условий и выдачи сигналов микроопераций, памяти микропрограмм в составе контроллера, подсистемы передачи сигналов логических условий/микроопераций и коммуникационной подсистемы для реализации команд межконтроллерной передачи управления, X_{max} и Y_{max} – соответственно число выводов контроллера для приема сигналов логических условий и выдачи сигналов микроопераций, W_{max} – емкость памяти микропрограмм контроллера, $|X(A_i)|$ – число сигналов логических условий, принимаемых условными вершинами i -го блока разбиения, $|Y(A_i)|$ – число сигналов микроопераций, выдаваемых операторными вершинами i -го блока разбиения, $\alpha(A_i, A_j)$ – число связей по управлению (микрокоманд передачи управления) между i -м и j -м блоками разбиения.

В ходе анализа качества разбиений, выполненного по результатам расчетов в проекте добровольных распределенных вычислений Gerasim@Home, было установлено наличие т.н. зон нечувствительности, в каждой из которых ослабление значений технологических ограничений выше некоторого порогового значения (X'_{max}, Y'_{max} и W'_{max}) ведет лишь к увеличению аппаратной сложности ЛМК и не приводит к улучшению остальных показателей качества разбиений и соответствующих им технических характеристик ЛМК. Также было показано, что ценой незначительного 5%-го ухудшения значений частных показателей качества разбиений можно существенно (до 17,2 раз) сократить требования к числу выводов для приема/выдачи сигналов логических условий и микроопераций, однако влияние данной оптимизации на общую аппаратную сложность ЛМК ранее проанализировано не было. С целью исследования потенциала для снижения аппаратной сложности ЛМК в целом на основании полученных ранее экспериментальных данных был произведен расчет аппаратной сложности R в зависимости от числа вершин $N = |A|$ в составе граф-схем алгоритмов управления, значений технологических ограничений на примере ограничения X_{max} и анализа усредненных значений показателей качества разбиений, результаты которого приведены на рис. 1, а оценки получаемого выигрыша в аппаратной сложности – в табл. 1.

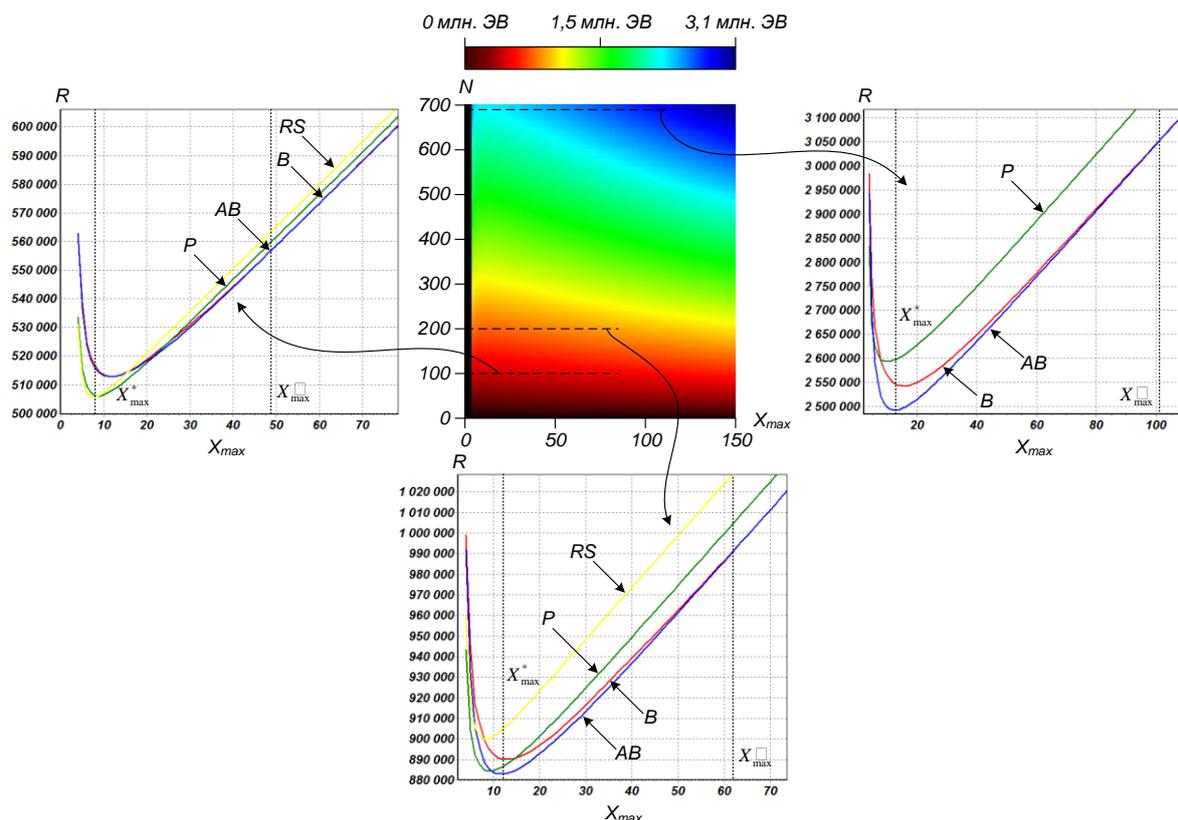


Рис. 1. Зависимость аппаратной сложности R проектируемого ЛМК от числа вершин N в граф-схемах алгоритмов управления и числа принимаемых контроллером сигналов логических условий X_{max} при Y_{max} и W_{max} (B – сокращенное обозначение метода С.И. Баранова, АВ – жадного метода с ограничением на смежность, P – метода параллельно-последовательной декомпозиции, RS – метода случайного перебора)

Таблица 1. Результаты оценки выигрыша в аппаратной сложности ЛМК

N	Граница области нечувствительности X_{max}'	Аппаратная сложность R' ЛМК на границе области нечувствительности	Оптимальное значение ограничения X_{max}^*	Аппаратная сложность R^* ЛМК при оптимальном значении ограничения	Выигрыш $\eta = \frac{R'}{R^*}$
100	49	556 – 565 тыс. ЭВ	8	508 – 516 тыс. ЭВ	8–11%
200	64	995 – 1035 тыс. ЭВ	8 – 15	885 – 900 тыс. ЭВ	12–17%
700	101	3,05 – 3,15 млн. ЭВ	9 – 16	2,49 – 2,59 млн. ЭВ	18–27%

В ходе анализа полученных результатов можно сделать вывод о том, что выбор оптимального значения X_{max}^* числа выводов для приема логических сигналов от объекта управления позволяет снизить аппаратную сложность проектируемого ЛМК от 8% до 27% в зависимости от размера граф-схем алгоритмов управления. При этом вклад в данную величину выбора оптимального метода синтеза разбиений составляет от 1,5% до 4%.

Литература

1. Ватутин Э.И. Проектирование логических мультиконтроллеров. Синтез разбиений параллельных граф-схем алгоритмов. Saarbrucken: Lambert Academic Publishing, 2011 г. 292 с.

Ватутин Э.И.¹, Титов В.С.¹, Пыхтин А.И.¹, Крипачев А.В.¹, Никитина Н.Н.²,
Манзюк М.О.³, Альбертьян А.М.⁴, Курочкин И.И.^{4,5}

¹ Юго-Западный государственный университет
305040, г. Курск, ул. 50 лет Октября, 94

² Институт прикладных математических исследований
Карельского научного центра РАН
185910, Республика Карелия, г. Петрозаводск, ул. Пушкинская, 11

³ Интернет-портал BOINC.ru
Россия, Москва

⁴ ФИЦ «Информатика и управление» РАН
117312, г. Москва, пр. 60-летия Октября, 9

⁵ Институт проблем передачи информации им. А.А. Харкевича РАН
127051, г. Москва, Большой Каретный пер., д. 19 стр. 1

Оценка мощностей спектров быстроисчисляемых числовых характеристик диагональных латинских квадратов порядков $N > 9$

Одним из известных типов комбинаторных объектов являются латинские (ЛК) и диагональные латинские квадраты (ДЛК) [1]. Для них возможно вычисление значений некоторого множества числовых характеристик, наиболее часто встречаемыми среди которых являются число трансверсалей, диагональных трансверсалей, интеркалятов и ортогональных соквадратов (ОДЛК). Для выбранного типа комбинаторных объектов, выбранной числовой характеристики и размерности задачи N различные возможные значения числовой характеристики образуют некоторое множество S , называемое спектром [2]. Для размерностей $N \leq 8$ вычисление состава спектров возможно без применения вычислительных средств с массивно-параллельной архитектурой, при росте размерности задачи $N > 9$ указанная задача не может быть решена точно на современном уровне развития средств вычислительной техники с параллельной архитектурой, ввиду чего необходимо применение ряда эвристических методов, результатом работы которых являются аппроксимации спектров и соответствующие им нижние ограничения на их мощности. Коллективом авторов разработана группа методов, алгоритмов и соответствующих им программных реализаций, в настоящее время работающих в рамках проекта добровольных распределенных вычислений Gerasim@Home на платформе BOINC. Они включают в своем составе различные генераторы исходных ДЛК различного типа, алгоритмы построения и обхода окрестностей для заданных ДЛК и алгоритмы вычисления искомым значений числовых характеристик. Мощности, супремумы и инфимумы спектров в зависимости от размерности задачи N образуют целочисленные числовые ряды, коллекционируемые в рамках Онлайн-энциклопедии целочисленных последовательностей (англ. OEIS).

По результатам расчетов на мощности спектров удалось наложить следующие нижние ограничения, являющиеся на данный момент наиболее сильными из известных (табл. 1).

Таблица 1. Нижние ограничения для мощностей спектров числовых характеристик ДЛК порядков $N \leq 9$

Числовая характеристика ДЛК	Нижние ограничения на значения членов числового ряда	Номер числового ряда в OEIS
Число трансверсалей	$a(9) \geq 359, a(10) \geq 442, a(11) \geq 5081, a(12) \geq 23112$	A344105
Число диагональных трансверсалей	$a(9) \geq 176, a(10) \geq 736, a(11) \geq 1242, a(12) \geq 17684, a(13) \geq 11919$	A345370
Число интеркалятов	$a(9) \geq 62, a(10) \geq 88, a(11) \geq 100, a(12) \geq 210, a(13) \geq 152$	A345760
Число ОДЛК	$a(10) \geq 10, a(11) \geq 38, a(12) \geq 3270$	A345761

Кроме того, в ходе работы со спектрами был усилен ряд нижних и верхних ограничений на супремумы и инфимумы соответствующих числовых характеристик (см. табл. 2 и 3).

Таблица 2. Верхние ограничения на минимальные значения (инфимумы) числовых характеристик ДЛК порядков $N \leq 9$

Числовая характеристика ДЛК	Нижние ограничения на значения членов числового ряда	Номер числового ряда в OEIS
Число трансверселей	$a(10)J 144, a(11)J 1721, a(12)J 448, a(13)J 45010,$ $a(14)J 82368, a(15)J 2269107, a(16)J 7465984$	A287645
Число диагональных трансверселей	$a(10)J 3, a(11)J 145, a(12)= 0, a(13)J 5105,$ $a(14)J 8727, a(15)J 284640, a(16)J 898988,$ $a(17)J 12058840, a(18)J 82577875, a(19)J 592174879$	A287647

Таблица 3. Нижние ограничения на максимальные значения (супремумы) числовых характеристик ДЛК порядков $N \leq 9$

Числовая характеристика ДЛК	Нижние ограничения на значения членов числового ряда	Номер числового ряда в OEIS
Число трансверселей	$a(11)i 37851, a(12)i 198144, a(13)i 1030367,$ $a(14)i 3477504, a(15)i 36362925, a(16)i 244744192,$ $a(17)i 1606008513, a(19)i 87656896891$	A287644
Число диагональных трансверселей	$a(10)i 890, a(12)i 30192, a(14)i 488792,$ $a(15)i 4620434, a(17)i 204995269,$ $a(18)i 281593874, a(19)i 11254190082$	A287648
Число интеркалятов	$a(10)i 93, a(11)i 94, a(12)i 252, a(13)i 156$	A307164
Число ОДЛК	$a(10)i 10, a(12)i 3855983322$	A287695

Подтверждающие ДЛК для приведенных в табл. 2 и 3 числовых оценок могут быть найдены в свободном доступе в составе соответствующих подтверждающих списков (например, [3–4]). Расчеты, направленные на увеличение мощностей известных в настоящее время спектров, в настоящее время активно выполняются в проекте Gerasim@Home для порядков $N \leq 13$. В качестве их результата следует ожидать дальнейшего усиления некоторых из приведенных выше оценок.

Авторы статьи выражают благодарность всем добровольцам, принимавшим участие в проекте добровольных распределенных вычислений Gerasim@Home, а также пользователю citerra [Russia Team] с интернет-портала BOINC.ru за ряд конструктивных дискуссий, предложений и замечаний.

Литература

1. Keedwell A.D., Dénes J. Latin Squares and their Applications. Elsevier, 2015. 438 p. DOI: 10.1016/C2014-0-03412-0.
2. Ватутин Э.И., Никитина Н.Н., Манзюк М.О., Альбертьян А.М., Курочкин И.И. О построении спектров быстроисчисляемых числовых характеристик диагональных латинских квадратов малого порядка // Интеллектуальные и информационные системы (Интеллект – 2021). Тула, 2021. С. 7–17.
3. http://evatutin.narod.ru/A287647_proving_list.txt
4. http://evatutin.narod.ru/A287644_proving_list.txt

Кульков Я.Ю., Бажуров С.В.

*Муромский институт (филиал) федерального государственного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых»
602264, г. Муром, Владимирская обл., ул. Орловская, 23*

Распознавание 3D объектов на основе контурных признаков проекций их моделей

На сегодняшний день автоматизация является неотъемлемой частью любого производства. Для автоматизации и полной автономности сборочных линий необходимо однозначно определять объекты в поле зрения роботизированного комплекса [1, 2].

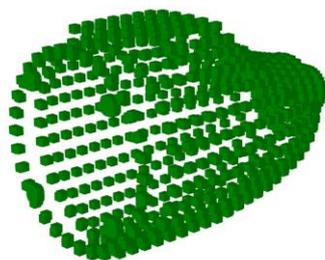
Распознавание объектов с использованием их 3D-моделей может осуществляться множеством способов, которые используют различные виды датчиков и сенсоров [3,4].

Для работы системы распознавания объемных объектов необходимо получение и хранение моделей всех объектов, подлежащих распознаванию.

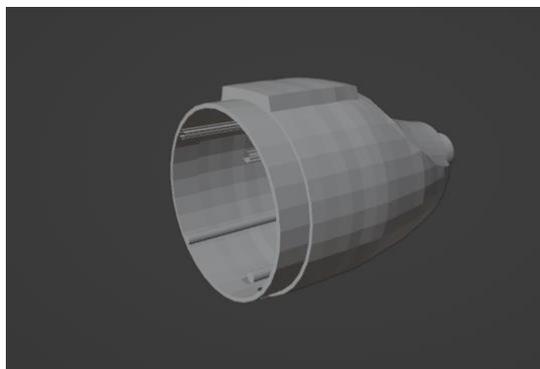
Для построения модели используется сканер серии Intel RealSense. В процессе сканирования система получает на вход значения облака точек 3D-проекции исследуемого объекта.

Для сглаживания шумов применяется фильтрация и нормализация полученных координат точек.

В процессе реконструкции объекта создается виртуальная сцена, на которой в точке начала координат размещается одна из проекций, называемая опорной. Далее берется следующая проекция, которой также смещается в начало координат. Следующим шагом происходит определение угла и поворот облака точек проекции относительно опорной точки. Действия повторяются для всех облаков точек проекций объекта. На выходе получается модель объекта в виде пространственного облака точек, которое затем трансформируется в полигональную 3D-модель (Рис.1).



а)



б)

Рис. 1. Пример модели объекта в виде облака точек (а) и полигонального представления (б)

Алгоритм распознавания на основе получения проекций. Первым шагом на вход алгоритма поступает изображение объекта, полученное с обычной камеры. Для данного объекта вычисляется угол ориентации и координаты в поле зрения СТЗ. На основе вычисленных параметров изображения создается виртуальная сцена, на которой размещается одна из полигональных моделей по заданным координатам. Далее модель поворачивается на вычисленный угол. Следующим шагом происходит получение проекции модели на плоскость сцены. Шаги повторяются для всех устойчивых положений всех моделей.

В итоге на выходе для каждой полигональной модели получают по 6 реконструированных проекций (Рис.2).

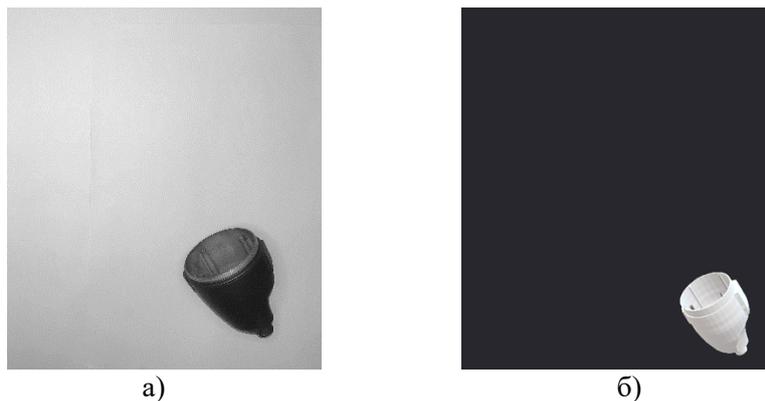


Рис. 2. Пример проекции объекта (а) и реконструированной проекции его модели (б)

После получения всех реконструкций происходит расчет контурных признаков и формирования векторов признаков. Векторы признаков вычисляются на основе первичных параметров контуров, из которых формируются вероятностные признаки объекта [5]. Далее вычисляются расстояния между вектором признаков неизвестного объекта на исходном изображении и всеми векторами полученных реконструкций. Минимальное расстояние будет указывать на принадлежность входного объекта к известному классу. Также будет установлена пространственная ориентация объекта на рабочем СТЗ.

Процесс исследования разработанных алгоритмов реконструкции и распознавания включает этапы создания 3D-моделей путем сканирования, генерации выборки для идентификации исследуемого объекта, расчёт признаки для полученного набора изображений. Было проведено исследование на наборе из 6 объектов, имеющих 19 наборов проекций, для каждой получено по 5 вариантов расположения, всего 80 изображений. Было установлено, что только в 4 случаях система ошиблась в определении класса входного объекта, что позволяет говорить о точности распознавания 0.95 при минимальных вычислительных затратах.

Полученные данные можно использовать при построении автоматизированных роботизированных сборочных и сортировочных комплексов.

Литература

1. Herekovic N. Robot Vision in Industrial Assembly and Quality Control Processes // InTech, 2010. No 26. Pp. 501-534.
2. Nerakae P., Uangpairoj P., Chamniprasart K. Using machine vision for flexible automatic assembly system // Procedia Computer Science, 2016. No 96. Pp. 428-435.
3. Bankole I. Oladapo, V.A. Balogun, A.O.M. Adeoye, C.O. Ijagbemi, Afolabi S. Oluwole, I.A. Daniyan, A. Esoso Aghor, Asanta P. Simeon. Model design and simulation of automatic sorting machine using proximity sensor // Engineering Science and Technology, an International Journal, 2016. Pp. 1452-1456.
4. Zhang W., Mei j., Ding Y. Design and Development of a High Speed Sorting System Based on Machine Vision Guiding // Physics Procedia, 2012. No 25. Pp. 1955-1965.
5. Садыков С.С. Алгоритм формирования вероятностных признаков точек контура бинарного изображения // Алгоритмы, методы и системы обработки данных. 2015. No30. С.52-59.

Кульков Я.Ю., Запатрин М.Г.

Муромский институт (филиал) федерального государственного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых»
602264, г. Муром, Владимирская обл., ул. Орловская, 23

Алгоритм распознавания маркировки железнодорожных колес в системе прослеживания производства

На сегодняшний день на больших производствах необходима система отслеживания продукции не только для наблюдения за продукцией по всему технологическому циклу производства, но также для сбора и предоставления данной информации внешним и внутренним контролирующим органам [1,2].

Так же прослеживание продукции используется для улучшения осведомленности о процессах производства; определении места и времени появления дефекта; определение местоположения всего объема продукции с дефектом, а также отзыв и изоляция партии с дефектом для дальнейших разбирательств и выявления причин дефекта в партии.

Распознавание маркировки на продукции осуществляется огромным количеством способов и выбор метода распознавания зависит так же от метода нанесения маркировки. Нами рассматривается ситуация, в которой на железнодорожное колесо методом прессовки наносится некоторый ряд символов. В нашем проекте для распознавания символов будет использоваться сверточная нейронная сеть, состоящая из нескольких слоев [3,4].

Нужно обучить сеть на множестве символов из различных маркировок для успешного распознавания различных вариантов одного и того же символа. Для этого применяется аугментация данных, искусственное увеличение набора данных путем трансформации имеющихся образцов в наборе, так же используется для предотвращения переобучения модели.

Для оценки полученных моделей и отбора наиболее точной был применен метод кросс-валидации. При оценке модели имеющиеся в наличии данные разбиваются на k частей. Затем на $k-1$ частях данных производится обучение модели, а оставшаяся часть данных используется для тестирования.

После применения кросс-валидации была получена самая удачная модель с коэффициентом распознавания 0,97.

Следующим этапом работы является получения символов пригодных для распознавания. Для удачного распознавания маркировки необходимо обработать изображения с помощью методов бинаризации для облегчения распознавания символа сетью (Рис.1.). Был выбран адаптивный метод бинаризации Брэдли-Рота, так как он показал себя более устойчивым и эффективным на исходном наборе предоставленных предприятием данных.

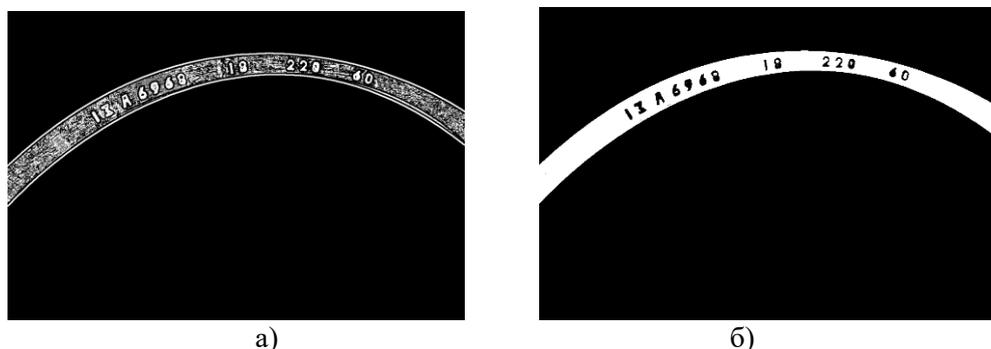


Рис. 1. Пример бинаризации маркировки по методу Берсена (а) и Брэдли-Рота (б)

Так как мы работаем с клеймом, которое может быть под различными углами поворота колеса. Найдя угол поворота и повернув изображение выделяем область с символами и вырезаем ее. После получения изображения необходимо найти контуры символов, для поиска контура используется алгоритм отслеживания контуров Suzuki85 (Рис.2.). Алгоритм предполагает

нахождение контуров с учетом вложенности, то есть способен определить, когда в контур одного объекта вложен другой.



Рис. 2. Пример выделения контуров символов

После получения контуров символов на изображении, определяется центра каждого контура. Накладывается маска по размеру чуть превышающую символ, вычисляется угол ориентации контура и нормализуется наклон символа по оси Y . Каждый символ выносится отдельно.

Далее поочередно сеть распознает символы и относит их к определенному классу на основании значения вероятности распознавания. Классы презентуют символы алфавита. Далее система составляет из символов полную маркировку пригодную для дальнейшей передачи в другие системы на производстве.

Полученный алгоритм можно использовать на производстве для облегчения системы прослеживания продукции, так как минимально полагается на человеческое присутствие и при правильном обучении и настройке будет давать безукоризненный результат.

Литература

1. Буевич, С. Прослеживание продукции как способ минимизации рисков предприятий пищевой промышленности СФЕРА: Масложировая индустрия. Масла и жиры. – 2017. – № 1(2). – С. 20-21.
2. Niemann, Jörg & Pisl, Adrian. (2021). Digital Product Tracking. 10.1007/978-3-030-56449-0_15.
3. OCR as a service: an experimental evaluation of google docs OCR, tesseract, ABBYY finereader, and transym / A. P. Tafti, P. Peissig, A. Baghaie [et al.] // Lecture Notes in Computer Science. – 2016. – Vol. 10072 LNCS. – P. 735-746. – DOI 10.1007/978-3-319-50835-1_66.
4. Кулакович, А. Ю. Программная реализация однослойной нейронной сети для распознавания цифровых символов / А. Ю. Кулакович // Инженерный вестник Дона. – 2018. – № 3(50). – С. 58.

Мортин К.В.

*Муромский институт (филиал) федерального государственного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых»
602264, г. Муром, Владимирская обл., ул. Орловская, 23*

Разработка системы определения дефектов с целью автоматизации визуального контроля поверхности листового металлопроката

На металлургических предприятиях страны остро стоит вопрос о выпуске продукции листового металлопроката без существенных дефектов или с оптимальными параметрами допуска без отбраковки. На таких предприятиях создаются отделы или лаборатории по техническому зрению [1].

Процент дефектов, видимых на поверхности листового проката, который видят в лаборатории контроля по металлу составляет 84%, а из-за деформаций 16%.

Цель таких лабораторий - исследовать цифровые изображения листового металлопроката с различными видами поверхностных дефектов, своевременно их обнаружить и принять соответствующие мероприятия по ликвидации или минимизации их возникновения.

Дефекты поверхности готового проката могут возникнуть при плавке металла и прокатке, а также вследствие нарушения технологии отделки проката. Площадь сталеплавильных дефектов при прокатке увеличивается прямо пропорционально общей вытяжке раската. Особенно велики потери на переделах производства специальных сталей и сплавов, где только при зачистке потери годного металла составляют 20% и более.

А также в заводских условиях уже применяются следующие подходы к обнаружению дефектов на листовом металлопрокате на основе фильтра Габора, вейвлет- преобразований, систем нечеткой логики, различных методов сегментации и бинаризации, алгоритмов адаптивного усиления, оптико- электронные информационно измерительные системы (ОЭИИС) оценки качества продукции, методы неразрушающего контроля, алгоритм SURF.

Рассмотренные методы обработки цифровых изображений, применяемые для обнаружения дефектов на листовом металлопрокате, показывают быструю обработку изображений. Но их применение к дефектам листового металлопроката имеет ряд недостатков:

- ограниченность функциональных возможностей и недостаточная эффективность при выделении контура дефекта из-за загрязнения исследуемой области на изображении;
- сглаживание изображения дефекта с помощью медианной фильтрации приводит к устранению границ дефекта и его зашумления;
- яркость фона изображения листового металлопроката занимает максимально допустимый диапазон, а яркость самого дефекта и его важных участков занимает узкий диапазон, что как следствие ухудшает контраст всего исследуемого изображения.

Исходя из вышеперечисленных фактов, существует необходимость в разработке методов и алгоритмов улучшения и скорости распознавания дефектов на изображениях листового металлопроката, что порождает необходимость выполнения локальных преобразований исследуемых изображений путем комплексного сегментирования, фильтрации, шумоподавления и использования комбинированного математического аппарата.

Для решения поставленных задач проектируется система предварительной обработки полутоновых дефектоскопических изображений с чередованием линейной свертки, краевой фильтрации и яркостной сегментации. Такая архитектура позволяет обнаруживать дефект и удалять его фон, делая попиксельно яркие контура обнаруженного дефекта на изображении.

Разработанная система состоит из следующей последовательности[2-3]:

1. Входное дефектоскопическое изображение;
2. Построение вертикальной проекции полутонового изображения;
3. Линейная свертка (фильтр подчеркивание краев);
4. Линейная свертка с двумя масками;
5. Линейная свертка (фильтр высокая частота);
6. Краевая фильтрация;

7. Яркостная сегментация (спектр делимости);
8. Построение вертикальной проекции изображения;
9. Попиксельно исключаящее И (краевая фильтрация, операция хог, линейная свертка);
10. Выделенный дефект с контуром без фона;
11. Запись промежуточных результатов в базу данных.

Такая система позволит повысить качество цифровой обработки дефектоскопических изображений в системах технического зрения за счет разработки новых методов, основанных на использовании комплексной свертки совместно с семантической сегментацией и теорией распознавания и детектирования полутоновых изображений [3].

Предлагаемая новая модель предварительного улучшения дефектоскопических изображений, основанная на многопоточной свертке, семантической сегментации и препарировании, позволит разработать новые алгоритмы обработки дефектоскопических изображений, отличающихся от существующих с возможностью использования на производстве листового металлопроката и накоплением базы данных исходных дефектов и их актуального анализа. Экономическая целесообразность проекта – внедрение быстродействующего алгоритма в предобработку дефектоскопических изображений перед классификатором.

Полученный метод можно применять в качестве детектора аномалий для построения датасетов, чтобы не пропустить не один дефект поверхности листового металлопроката. Эффективность от такого подхода будет заключаться в снижении затрат и времени на покупку или создание систем распознавания и детектирования.

Практическую апробацию планируется проводить на действующих производствах АО ВМЗ в рамках лаборатории компьютерного зрения.

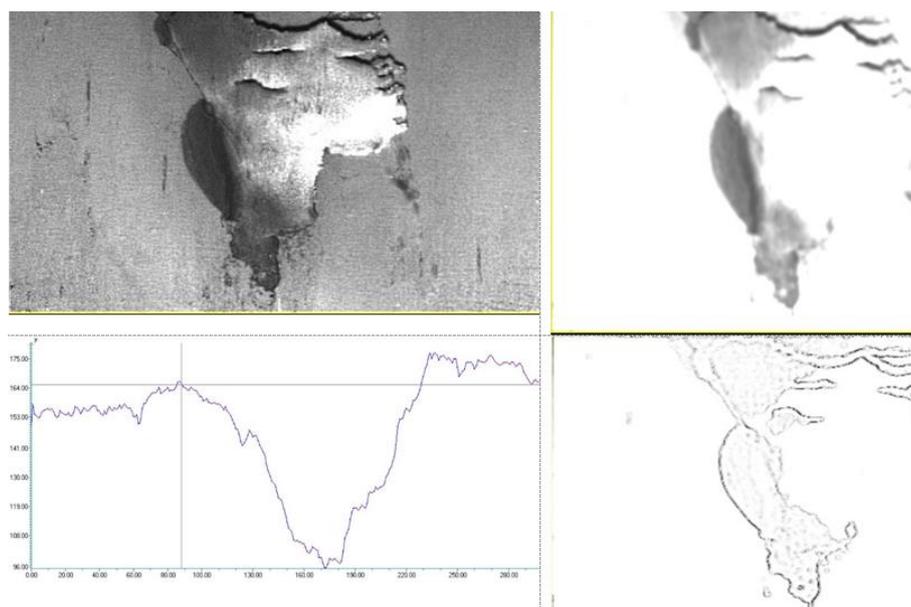


Рис. 1. Результат определения дефекта

Литература

1. Гурвич А. К. Оценка конфигурации дефектов металлопродукции с плоскопараллельными поверхностями усеченным дельта-методом // Контроль. Диагностика. 2013. № 10. С. 68-70.
2. Привезенцев Д.Г., Мортин К.В., Жизняков А.Л., Титов Д.В. Разработка сверточного слоя глубокой нейронной сети для определения дефектов металлопроката// Известия высших учебных заведений. Приборостроение. 2021. Т. 64. № 3. С. 202-207.
3. Мортин К.В., Привезенцев Д.Г. Разработка сверточного слоя нейронной сети для обнаружения дефектов листового металлопроката на дефектоскопических изображениях //Международная конференция по мягким вычислениям и измерениям. 2021. Т. 1. С. 210-212.

Муртин К.В.

*Муромский институт (филиал) федерального государственного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых»
602264, г. Муром, Владимирская обл., ул. Орловская, 23*

Система обнаружения дефектов листового металлопроката на изображениях с использованием глубокой нейронной сверточной сети

В настоящее время наблюдается бурное развитие металлургической промышленности в России, что обуславливает значительный вклад отрасли в ВВП страны (около 4%). На металлургию приходится примерно 12% промышленного производства и 10% экспорта.

Однако, несмотря на очевидные успехи, в отрасли имеется проблема своевременного обнаружения дефектов металлопроката – одна из ключевых проблем российского промышленного комплекса. Применение инновационных подходов и технологий позволит значительно снизить затраты, вызванные несвоевременным обнаружением брака в процессе производства.

В настоящее время известно большое количество видов дефектов листового металлопроката [1-3], для большей части которых разработаны методы их своевременного обнаружения. Большинство поверхностных дефектов удается обнаруживать и классифицировать оптическим методом. Однако в условиях реального производства зачастую это оказывается затруднительно из-за факторов, ухудшающих качество цифровых изображений поверхности металлопроката.

В ходе анализа установлено, что искусственные нейронные сети типовой структуры, которые получили огромное распространение, не позволяют уменьшить влияние факторов реального производства на цифровые дефектоскопические изображения, а качество обнаружения дефектов будет являться достаточно высоким. Но несмотря на это, данный подход имеет потенциал, который возможно раскрыть за счет создания нейронной сети специальной структуры и разработки специализированных алгоритмов, основанных на созданной сети.

Для решения поставленных задач проектируется глубокая сверточная нейронная сеть с чередованием слоев свертки и субдискретизации. Такая архитектура позволяет строить карты признаков из карт признаков. После каждого слоя свертки применяется функция активации GELU, а после субдискретизации – SELU [4].

Классическая структура сверточного слоя не подходит для процесса фильтрации дефектоскопического изображения, поэтому слой свертки модифицируется. А именно, применяемый фильтр должен быть 2×2 с весом 0.5 для каждого соединения карты признаков. Таким образом, для изображения размером 1600×256 , получается 28 слоев свертки. Затем применяется метод удаления фона от дефекта и функция активации GELU [5]. Для уменьшения ошибок в процессе обучения после слоя свертки добавляется модифицированная функция ошибки стохастического градиентного спуска по моментам Adam [6].

Разработанная математическая модель, применяемая в глубокой сверточной нейронной сети для определения дефекта листового металлопроката, показала хорошие результаты при апробации тестовых дефектоскопических изображений, представленных компанией «ООО Северсталь Диджтал» на открытом конкурсе по техническому зрению Kaggle.

В ходе экспериментальных исследований были успешно выделены дефекты листового металлопроката на 89% изображений тестового набора (рисунок 1). Дальнейший анализ обнаруженных объектов показал, что геометрические характеристики дефектов отличаются от значений, полученных квалифицированным оператором-дефектоскопистом не более чем на 7%. Это доказывает возможность использования разработанной сети в практических задачах дефектоскопии.

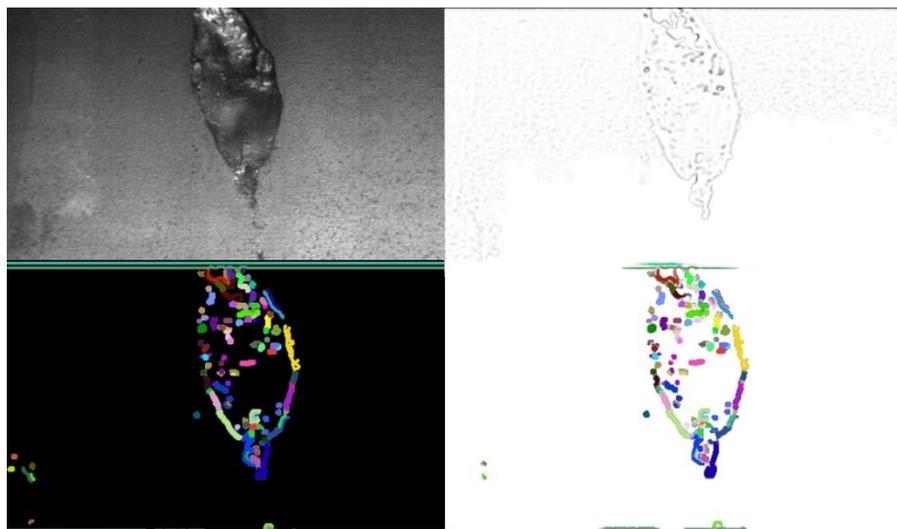


Рис. 1. Результат выделения дефекта

Литература

1. Бархатов, В.А. Распознавание дефектов с помощью искусственной нейронной сети специального типа. // Дефектоскопия – 2006. – № 2. – с. 28—39.
2. Бархатов, В.А. Обнаружение сигналов и их классификация с помощью распознавания образов. // Дефектоскопия – 2006. – № 4 – с. 14—27.
3. Бархатов, В.А. Распознавание образов класса, заданного параметрически / В.А. Васильев // Дефектоскопия – 2009. – № 2 – с. 3—17.
4. Silver, D., Huang, A., Maddison, C., et al. (2016). Mastering the game of Go with deep neural networks and tree search. *Nature*, 529(7587):484–489.
5. Wainberg, M., Alipanahi, B., and Frey, B. J. (2016). Are random forests truly the best classifiers? *Journal of Machine Learning Research*, 17(110):1–5.
6. Kingma, Diederik, and Jimmy Ba. "Adam: A method for stochastic optimization." arXiv preprint arXiv:1412.6980 (2014).

Панищева О.Н., Титов В.С., Чернецкая И.Е.
Юго-Западный государственный университет
Курск, ул. 50 лет Октября, 94
e-mail: gskunk@yandex.ru

Распознавание символов на основе гибридной нейронной сети

Аннотация

В данной работе рассматривается задача распознавания символов на основе гибридной нейросети.

В настоящее время алгоритмы обработки данных на основе машинного обучения используются для автоматического ввода данных, распознавания образов, услуг преобразования текста в речь, индексации документов для поисковых систем, когнитивных вычислений, интеллектуального анализа текста, ключевых данных и машинного перевода среди различных других приложений [1-3].

Цель работы – исследование эффективности алгоритма нейросетевого распознавания символов.

Распознавание выполнялось на основе известного нейропакета NeuroSolutions, предназначенного для моделирования широкого круга искусственных нейронных сетей.

Обучающая выборка формировалась на этапе создания нейронной сети средствами нейропакета в виде текстовых данных в формате ASCII.

Для распознавания образов использована гибридная сеть, основанная на идее сочетания свойств многоуровневого перцептрона (MLP) как классификатора и сетей с использованием, так называемого принципиального компонента анализа (PCA) как экстрактора характеристик. Главным элементом гибридной сети является синапс, который линейно проектирует входные данные на пространство с меньшим измерением. PCA сеть обычно используется для решения аналитических проблем и задач собственных параметров проблем корреляционной функции выхода.

Существует множество способов, направленных на снижение количества шумов в сигнале и последующего распознавания [4, 5, 6]. Этого можно достигнуть при помощи линейной фильтрации, если спектры шумов и сигнала не перекрываются. Чтобы отделить сигнал от шумов, используется принцип главных компонент. Если рассматривать сигнал как вектор, главные компоненты в основном будут являться направлениями сигнального вектора и сигнального пространства. Шумы широкой полосы частот полностью заполняют сигнальное пространство, так что в нём находятся компоненты, расположенные во всех направлениях. Если представляется возможным спроецировать сигнал и шум в пространстве, состоящем из главных компонент сигнала, тогда будет присутствовать меньшее количество шумов, и сигнал будет менее искажён. Таким образом, идея заключается в применении известных методов к единому слою линейных компонент для выделения главных компонент входящего сигнала. Это означает, что вектора весов сети являются главными компонентами, а выходные данные являются проекциями входных данных на протяжении этих направлений.

Структура используемой сети представлена на рисунке.

Нейросеть состоит из четырёх слоёв: входного слоя, выходного слоя и двух скрытых слоёв. На входной слой подаётся 432 элемента, которые составляют изображений в градациях серого размером 24x18. С помощью принципиального компонента анализа на слой накопления данных пошагово поступает каждый пример. В слое накопления данных 10 входов, что означает 10 различных цифр. Далее в следующем слое вычисляется мера сходства между примерами, вычисляется ошибка и корректируется результат при помощи обратных связей.

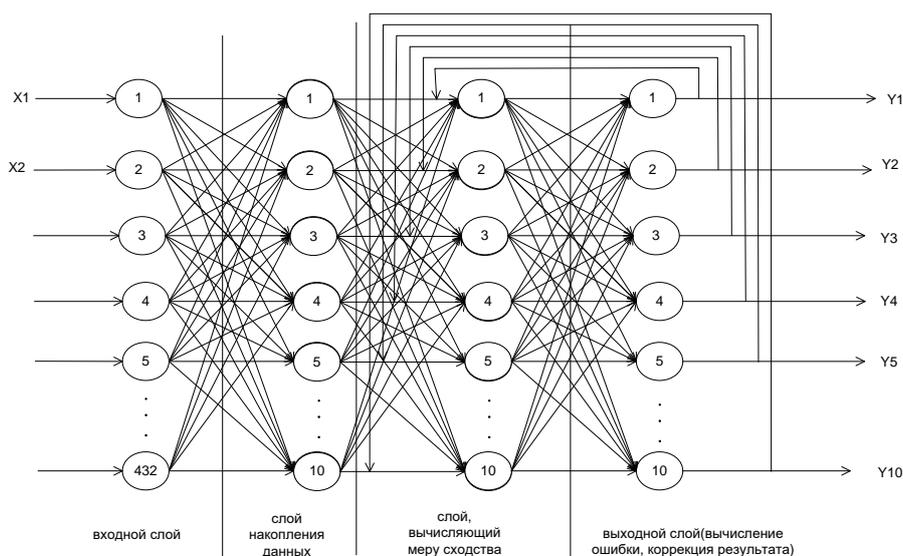


Рисунок 1 - Структура нейросети

Главным элементом гибридной сети является синапс, который линейно проектирует входные данные на пространство с меньшим измерением. РСА сеть обычно используется для решения аналитических проблем и задач собственных параметров проблем корреляционной функции выхода.

Проведено тестирование сети десятью образами на каждую цифру. Предлагаемые образы были видоизменены для распознавания путём добавления помех, непрорисованных участков и размытости форм. На выходе получим значение веса на каждую цифру, которое будет характеризовать степень похожести тестируемого примера на образец из набора обучения.

Результат были представлены в виде графика, который наглядно показывает насколько вероятен тот или иной образ, а также позволяет выявить набор близких по написанию цифр, с которыми распознанный образ и делит своё наибольшее значение меры сходства.

Наибольшую меру сходства имеет «7», т.е. образ в большинстве случаев распознаётся верно. Определённая доля вероятности распознавания, но малая существует у «1», «2», «4», «9», что обусловлено большим количеством образов с помехами в входной выборке.

Результаты распознавания составили в среднем 85%, что позволяет использовать данную сеть в системах анализа изображений.

Литература

1. Papangkorn I., Jakramate B., Sanparith M. Recognition of similar characters using gradient features of discriminative regions. *Expert Systems with Applications*, Volume 134, 2019, С. 120-137
2. Панищев В.С., Труфанов М. И., Добросердов О. Г., Хомяков О.О. распознавание символьной информации для автоматизации производственных процессов. *Известия Юго-Западного государственного университета*. 2021. С. 122-137.
3. Шиков А. Н., Самиев М. Г. Применение искусственных нейронных сетей для распознавания и идентификации маркировки кабельно-проводниковой продукции. *Экономические науки: вопросы теории и практики*. 2021. С. 169-173.
4. Панищев В.С., Панищева О.Н., Полторацкий С.Н. Алгоритм выделения периодических последовательностей в системах обработки изображений // *Опτικο-электронные приборы и устройства в системах распознавания образов и обработки изображений*. Распознавание - 2019. сборник материалов XV Международной научно-технической конференции. 2019. С. 133-135.
5. Максимова Ю.О., Мишин А.Б., Панищева О.Н. Моделирование нейросетевых фильтров изображения // *Интеллектуальные информационные системы: тенденции, проблемы, перспективы*. материалы докладов VI всероссийской очной научно-практической конференции «ИИС-2018». Юго-Западный государственный университет. 2018. С. 112-113.
6. Panishchev V.S., Titov V.S. Application of neural networks for the contour extraction in images. *Pattern Recognition and Image Analysis (Advances in Mathematical Theory and Applications)*. 2005. Т. 15. № 2. С. 277-278.

Садыков С.С., Кульков Я.Ю., Орлов А.Д.
Муромский институт (филиал) федерального государственного образовательного учреждения
высшего образования «Владимирский государственный университет имени Александра
Григорьевича и Николая Григорьевича Столетовых»
602264, г. Муром, Владимирская обл., ул. Орловская, 23

Разработка и исследование алгоритма распознавания плоских объектов на основе локальных особенностей их контуров

Большинство предприятий стремятся к автоматизации всего процесса производства. Для автоматизации сборки изделий важны такие аспекты, как скорость сборки, точность и процент выходного брака. В процессе сборки участвуют роботы, которые выполняют алгоритмы сборки, поскольку они способствуют высокой точности сборки и низкому проценту выходного брака [1,2].

Большую часть номенклатуры изделий, используемых при сборочных операциях, составляют плоские детали [3]. Под плоским в данной задаче понимается объект, у которого есть только два устойчивых положения, имеющие одинаковое изображение.

Для построения алгоритма распознавания необходим набор признаков, инвариантных к вращению и изменению масштаба объекта, и позволяющий с высокой точностью выполнять классификацию объектов. В данной работе предложен алгоритм распознавания отдельных объектов с использованием признаков, сформированных на основе локальных особенностей их контуров.

По контуру объекта вычисляется набор первичных параметров, таких как значение кривизны точки, длина контура, число точек в заданном направлении по схеме цепного кодирования Фримена [4].

Общее количество признаков контура вычисляется как $N_{\text{призн.}} = N_0 + \dots + N_{i-1}$, где $i=19$.

Значение i -го признака рассчитывается по формуле $K_i = N_i / N_{\text{призн.}}$.

Полученные значения формируют вектор признаков $K = \{K_0, K_2, \dots, K_{19}\}$.

Полученные признаки составляют вектор вероятностных признаков, который служит для распознавания объекта. Алгоритм позволяет получить характеристику точек контура, используя 20 параметров.

Точность распознавания зависит от полноты обучающей выборки. Исследование разработанного алгоритма распознавания включает этапы генерации набора изображений из 360 изображений с разным углом поворота объекта, расчётом контурных признаков для набора изображений с помощью алгоритма вычисления признаков дискретной замкнутой контурной линии, деление набора признаков на обучающую и тестовую выборку с дальнейшим распознаванием методом kNN.

В процессе исследования использовались 15 объектов, по которым сгенерированы обучающие и тестовые выборки.

Обученная модель была исследована на тестовой выборке. Точность распознавания в зависимости от класса входного объекта представлена на рисунке 1.

После определения класса объекта должен выполняться его захват манипулятором. Для заранее определенной точки захвата, объект должен находиться в заранее определённом положении. В случае невыполнения данного требования происходит захват детали в месте с неровностями, что приводит к потере детали манипулятором.

Для исключения подобных ошибок, необходимо точное указание области захвата внутри объекта. Так как объект в поле зрения СТЗ комплекса может находиться в произвольном расположении и ориентации, то необходим алгоритм определения эффективной точки захвата. Такая точка указывается на этапе обучения оператором.

Предлагаемый алгоритм позволяет находить на объекте такую точку вне зависимости от его положения и ориентации.



Рис. 2. Результат распознавания тестовых объектов

Исследуемый алгоритм расчёта точки захвата предусматривает 4 подготовительных этапа для определения локальной точки внутри объекта. На этапе настройки системы загружается изображение объекта, для которого производятся первичные расчёты, такие как расчёт моментов изображения, необходимые для определения положения объекта, построение описанного прямоугольника минимальной площади, необходимый для расчёта локальной точки и служит системой координат для объекта, и расчёт коэффициента отношения, которое хранится в системе для дальнейшего расчёта. Постановка точки захвата на объект, локальная точка которой уже определена, осуществляется путем расчёта моментов изображения, построение описанного прямоугольника минимальной площади и расчёта точки с использованием коэффициента отношения.

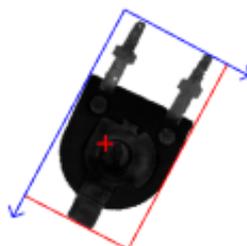


Рис. 3. Пример расчета локальной точки захвата

Разработанные алгоритмы могут использоваться как в комплексе, так и по отдельности в различных отраслях производства или как часть систем технического зрения различного назначения.

Литература

1. Shah R. Pandey A.B. Concept for Automated Sorting Robotic Arm // Procedia Manufacturing. 2018. No20. С.400-405.
2. Zhang W. Mei J. Ding Y. Design and Development of a High Speed Sorting System Based on Machine Vision Guiding // Physics Procedia. 2012. No25. С.1955-1965.
3. Les T. Kruk M. Osowski S. Automatic recognition of industrial tools using artificial intelligence approach // Expert Systems with Applications. 2013. No40. С.4777-4784.
4. Садыков С.С. Алгоритм формирования вероятностных признаков точек контура бинарного изображения // Алгоритмы, методы и системы обработки данных. 2015. No30. С.52-59.

Фролов А.О., Быков А.А.

Муромский институт (филиал) федерального государственного образовательного учреждения высшего образования «Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых» 602264, г. Муром, Владимирская обл., ул. Орловская, 23

Исследование возможных искажений данных в системе регистрации целостности систем водопровода.

Система водоснабжения в настоящее время является важнейшей частью жизнеобеспечения каждого населенного пункта. Но чаще всего из-за неудовлетворительного состояния трубопровода в воду могут попадать большое количество различных примесей вследствие чего состав воды подвергается нежелательным изменениям. Последствиями могут являться множество факторов, к ним могут относиться: качество воды, здоровье населения, состояние бытового и промышленного оборудования, а также общее состояние систем централизованного водоснабжения [1].

Поэтому контроль и поддержка исправности системы водоснабжения и трубопровода является крайне актуальной задачей, требующей особого внимания, так как материальные и временные затраты на устранение аварий требуют намного больше ресурсов, чем их предупреждение, поэтому крайне важно своевременно обнаруживать аварийные участки и устранять нарушения в ходе профилактических ремонтов.

Определение состояния таких участков будет проводиться с помощью информационной системы, которая будет работать с совокупностью различных показателей воды собираемых системой датчиков и лабораторными анализами [2]. Работа данной системы будет разбита на несколько этапов, которые будут рассмотрены ниже. Целью проведения данных этапов является заблаговременное прогнозирование времени и места предполагаемого нарушения целостности водопровода, которое впоследствии может привести к аварийной ситуации. Последовательность действий выглядит следующим образом:

Первый этап – сбор, преобразование и хранение данных. На данном этапе система на вход получает результаты собранных измерений из различных источников, как внутренних, так и внешних (система датчиков и лабораторные анализы). Далее вся информация преобразовывается в определенный вид и сохраняется в базу данных для дальнейшей работы.

Второй этап – предварительная обработка данных. На данном этапе происходит основная работа с данными: устраняются основные проблемы в виде пропусков, всплесков, производится преобразование, обработка, сравнительный анализ с нормативами, возможна применение фильтров для работы с необходимой информацией. Фильтрация поможет выполнить выборку данных по заданным критериям, что позволит избежать множества факторов, проблем, которые могут в дальнейшем повлиять на результаты анализа и неверное принятие решений.

Одной из часто встречающейся проблем при выборке – это пропуск значений. Причинами неполноты, пропусков данных могут служить множество факторов, например, таких как: помеха или ошибка при передачи данных, временной неработоспособности датчиков и потеря части полученной информации. На графике эти значения могут отображаться пустотами, что впоследствии нарушает целостность графика. Данную проблему можно решить двумя способами, первый - просто исключить из рассмотрения наблюдения с пропущенными данными, второй – восстановить значения при помощи реализованных алгоритмов, для этого в системе используется два метода - среднее значение и линейная интерполяция. При применении второго способа получится восстановить не только пропущенные значения, но и вернуть целостность графика.

Второй часто встречаемой проблемой, могут быть всплески данных. Они могут иметь, как разовый, так и постоянный характер, поэтому важно идентифицировать и правильно обрабатывать информацию, чтобы убедиться в правильности анализа. Для устранения данной проблемы изначально нужно выяснить с чем связаны изменения и какую они периодичность имеют. Вариантов решений так же несколько, это может быть, как простое удаление всплесков

из набора данных, так и применение специальных методов, которые позволят усреднить значения. В системе реализованы методы скользящей средней и экспоненциальное сглаживание. После применения разработанных алгоритмов график будет иметь более ровный вид.

Так же не стоит забывать о сезонном факторе, так как данный параметр может изменять показатели в зависимости от времени года. Но учитывать данный показатель можно только при наличии сведений о ежедневных или среднедекадных данных за период не менее полных двух, а лучше трех лет. При выделении сезонной составляющей периодичность сезонов берется за один год [3,4].

Третий этап – анализ данных. На данном этапе происходит работа с уже обработанными данными, применяются разработанные алгоритмы, которые впоследствии позволят нам перейти к дальнейшему прогнозированию.

Четвертый этап – обработка полученных данных. Данный этап является заключительным, на нем происходит работа уже с готовыми данными. Делается оценка результатов, принимаются решения и составляется прогноз. С помощью встроенных модулей прогнозирования и графического отображения данных можно построить различные графики и диаграммы для извлечения полезной информации и принятия решений, это даст возможность заранее предположить время и место возможной аварии. Прогнозирование в виде диаграмм будет строиться на основе трендов. Это может быть, как обычный линейный тренд, так и различные вариации, такие как применение полинома и экспоненциального сглаживания [5,6].

Таким образом, разрабатываемая система позволит заблаговременно выявлять появление негативных процессов в системах водоснабжения, прогнозировать время и место предполагаемого аварийного участка до его необратимого разрушения, что в итоге позволит своевременно предупреждать и устранять неполадки и тем самым минимизировать аварийные ситуации. Благодаря тому, что система разделена на несколько этапов, это позволит на основе разработанных методов, избежать часто встречаемые проблемы при работе с данными, например, такие как: пропуски значений, неполнота, всплески данных и сезонных фактор. Кроме того, система даст возможность отслеживать текущие показатели качества воды, а также тенденцию изменения этих показателей.

Литература

1. Дорофеев Н.В., Греченева А.В., Романов Р.В., Быков А.А. Мониторинг санитарно-технического состояния систем водоснабжения на базе информационных технологий. Современные проблемы надежности и техносферной безопасности: образование, наука, практика // Материалы Всероссийской научно-технической и научно-методической конференции, посвященной 20-летию каф. безопасности жизнедеятельности, экологии и химии. 2019. Издательство: Федеральное государственное бюджетное образовательное учреждение высшего образования «Ковровская государственная технологическая академия имени В.А. Дегтярева» с. 6-10.
2. Фролов А.О., Быков А.А. Проектирование автоматизированной системы обнаружения аварий в водопроводной сети [Электронный ресурс] // Sciences of Europe. 2021. Vol. 65, No. 1. с. 50–54 doi: 10.24412/3162-2364-2021-65-1-50-54
3. Методы прогнозирования изменения содержания загрязняющих веществ в водных объектах во времени по результатам систематических гидрохимических наблюдений: [Электронный ресурс] // ТЕХЭКСПЕРТ, 2011. URL: <http://docs.cntd.ru/document/1200097958>.
4. Ермолаева В.А. Изучение сезонных изменений жесткости и щелочности питьевой воды // Вода и экология: проблемы и решения. 2019. №1. с.44-53.
5. Сглаживание и прогнозирование временных рядов на основе трендовых моделей: [Электронный ресурс] // eos.ibi.spb, 2018. URL: http://eos.ibi.spb.ru/umk/15_3/5/5_R1_T3.html.
6. Светульников И.С., Светульников С.Г. Методы социально-экономического прогнозирования. Том 2. Модели и методы: Учебник и практикум для академического бакалавриата – Москва: Юрайт, 2017 – 445 с.

Хомяков¹ О.О., Панищев¹ В.С., Мухамадсадигов² Н.К., Калугин³ К.С.

¹Юго-Западный государственный университет

Курск, ул. 50 лет Октября, 94

²Московский технический университет связи и информатики

г. Москва, улица Авиамоторная, 8а

³ООО «Ценозавр»

г. Курск, ул. Л. Толстого, д. 16, оф. 21

e-mail: gskunk@yandex.ru, homyakov46rus@yandex.ru

Определение производителя продукции с помощью технологии оптического распознавания символов на примере молочной продукции.

Аннотация

В данной работе рассматривается проблема классификации объектов на изображении, на примере определения производителя молочной продукции. Классификация объектов на изображении является актуальной научной и технической задачей, наработки в данной сфере находят применение в системах инвентаризации, автоматизации учета, контроля поставки продукции. Результатом работы является система, реализующая распознавание символьной информации на изображениях видеопотока и определение производителя продукции.

В ходе данной работы был разработан прототип системы, позволяющей классифицировать объект на изображении, за счет работы с символьной информацией, понятной человеку, наносимой на этикетки продукции производителем. Результатом работы системы является текстовая информация о производителе, которая может быть использована в других информационных системах для решения прикладных технических задач, зависящих от типа продукции.

Процесс получения изображения из видеопотока с камеры выполняется в два этапа: сравнение объектов в кадре с заданным шаблоном и анализ формы объекта. В качестве шаблона может выступать обобщенное изображение, отображающее основные признаки продукции. Анализ формы объекта необходим для исключения ситуаций, когда объект находится в кадре частично, в таком случае на этапе распознавания будет невозможно полностью классифицировать символьную информацию. В ходе данного этапа находится информация о таких артефактах изображения как чрезмерно светлые или темные участки и об объектах, перекрывающих продукцию. В результате этих процессов принимается решение о начале этапа распознавания текстовой информации, либо о пропуске данного кадра [1,2,3,4].

После принятия решения о распознавании кадра изображение передается на этап предобработки, в ходе которого происходит: исправление наклона изображения, удаление шумов, артефактов и наклонов, выделение значащей информации. Целью предобработки является уменьшение погрешности распознавания символов [5,6].

Далее происходит анализ цветов изображения и взаимного положения элементов, для множества вариаций продукции созданы матрицы, описывающие возможные положения, а также интенсивности света различных диапазонов, позволяющие определить блоки изображения, содержащие текст. Таким образом, принимается решение о распознавании символов данного блока изображения [7,8].

Этап распознавания начинается с разбиения элементов изображения, содержащих текст на слова. Для разбиения текстовых блоков на слова находится базовая линия каждой строки, далее исходя из среднего расстояния между символами определяется диапазон разбиения на слова и символы [9,10]. Классификация символов осуществляется с помощью сверточной рекуррентной нейронной сети, созданной с использованием библиотеки Keras. Обучение производилось на выборке, содержащей реальные и синтетически сгенерированные изображения текста, наносимые на маркировку молочной продукции, с различной цветовой гаммой, размерами шрифта, с изменением формы символов, наклоном текста, перспективой, различным уровнем шумов и фоном [11,12,13].

Финальным этапом работы системы является классификация производителя, что и является результатом работы алгоритма. Классификация осуществляется с использованием вектора эталонных признаков, который включает в себя данные об уникальной текстовой информации на маркировке продукции определенного производителя. Для увеличения точности классификации производителя и компенсации ошибок классификации символов используется дополнительная информация, полученная на этапе выделения значимой информации.

После разработки данной системы было проведено тестирование. Точность обнаружения объекта продукции в кадре видеопотока составила 97% для изображений, не содержащих существенных искажений и перекрытий объекта; 79% для изображений, содержащих перекрытия размером менее 15 % от размера объекта продукции и уровне шума менее 25%; и 18% при размере перекрытий менее 30% и уровне шума менее 50%.

Точность классификации символов составила 97.26%. Точность классификации производителя на основе только вектора эталонных признаков 97.5%, с использованием дополнительной информации 98.7%.

Литература

1. Копылов И. В., Казаков А. В., Малыгин Л. Л. Идентификация маркировок рулонов металлопроката. Вестник череповецкого государственного университета. 2016. С. 12-15.
2. Xiang, Z., You, Z., Qian, M., Zhang, J., & Hu, X. Metal stamping character recognition algorithm based on multi-directional illumination image fusion enhancement technology. EURASIP Journal on Image and Video Processing. 2018. С 1-11.
3. Panishchev V.S., Titov V.S. Application of neural networks for the contour extraction in images. Pattern Recognition and Image Analysis (Advances in Mathematical Theory and Applications). 2005. Т. 15. № 2. С. 277-278.
4. I. Debled-Rennesson, S. Tabbone and L. Wendling. "Fast polygonal approximation of digital curves." Proceedings of the 17th International Conference. 2004.
5. Л. Шапиро, Дж. Стокман. Компьютерное зрение. БИНОМ, 2013. 752 с.
6. Р. Гонсалес, Р. Вудс. Цифровая обработка изображений. Техносфера, 2012. 1104 с.
7. I. Marosi, "Industrial OCR approaches: architecture, algorithms and adaptation techniques", Document Recognition and Retrieval XIV. SPIE, 2007
8. N. Hayashi, S. Koyanaka, T. Oki. Constructing an automatic object-recognition algorithm using labeling information for efficient recycling of WEEE. Waste Management, 2019. С. 337-346.
9. Papangkorn I., Jakramate B., Sanparith M. Recognition of similar characters using gradient features of discriminative regions. Expert Systems with Applications, Volume 134, 2019, С. 120-137
10. Панищев В.С., Труфанов М. И., Добросердов О. Г., Хомяков О.О. распознавание символьной информации для автоматизации производственных процессов. Известия Юго-Западного государственного университета. 2021. С. 122-137.
11. Шиков А. Н., Самиев М. Г. Применение искусственных нейронных сетей для распознавания и идентификации маркировки кабельно-проводниковой продукции. Экономические науки: вопросы теории и практики. 2021. С. 169-173.
12. Kazmi, W., Nabney, I., Vogiatzis, G., Rose, P., & Codd, A. An efficient industrial system for vehicle tyre (tire) detection and text recognition using deep learning. IEEE Transactions on Intelligent Transportation Systems. 2020.
13. Хомоненко А.Д., Яковлев Е.Л. Обоснование архитектуры сверточной нейронной сети для автономного распознавания объектов на изображениях бортовой вычислительной системой // Научные технологии в космических исследованиях Земли. 2018. С. 86-93