



Онтологическая декомпозиция задачи технического зрения в дискретном производстве

© 2026, В.А. Печенин ✉, А.И. Хаймович

Самарский национальный исследовательский университет имени академика С.П. Королева, Самара, Россия

Аннотация

Предлагается онтологически ориентированный подход к автоматизации учёта состояния производственного передела в дискретном производстве. Разработан программно-аппаратный комплекс, обеспечивающий идентификацию деталей в производственных тарах с использованием технологий технического зрения и каскадного алгоритма на основе свёрточных нейронных сетей. Выполнена онтологическая декомпозиция задачи: вместо обучения одной универсальной модели нейронной сети применяется иерархия специализированных моделей, активируемых на основе онтологических маркеров (*ArUco*, *QR*-коды). Такой подход позволяет на 50-70% снизить требуемый объём обучающих данных при сохранении точности детектирования в условиях «информационного шума» (освещённость, ориентация тары, посторонние объекты). В разработанном комплексе формализованы знания о структуре производственной тары, её состояниях, отношениях и неопределённостях в дискретном производстве. Сравнительный анализ решения экспериментальных задач подтверждает эффективность предложенного метода для прослеживаемости материальных потоков в гибких производственных системах.

Ключевые слова: онтологическая декомпозиция, техническое зрение, производственная тара, дискретное производство, прослеживаемость, неопределённость, машинное обучение.

Цитирование: Печенин В.А., Хаймович А.И. Онтологическая декомпозиция задачи технического зрения в дискретном производстве. *Онтология проектирования*. 2026. Т.16, №3(61). С.465-476. DOI: 10.18287/2223-9537-2026-16-3-465-476.

Финансирование: подготовка статьи поддержана Министерством науки и высшего образования Российской Федерации (проект FSSS-2024-0019).

Вклад авторов: Печенин В.А. – постановка задачи, разработка онтологической модели и каскадного алгоритма, проведение экспериментов, обработка и анализ результатов; Хаймович А.И. – формулировка онтологического подхода к задаче, интерпретация результатов.

Конфликт интересов: авторы заявляют об отсутствии конфликта интересов.

Введение

Современное машиностроительное производство характеризуется высокой степенью гибкости и широкой номенклатурой выпускаемой продукции. Гибкие производственные системы обеспечивают автоматизацию процессов планирования и контроля, однако остаются уязвимыми к ошибкам, связанным с человеческим фактором при учёте материальных потоков и состояния производственных переделов. Это особенно важно в дискретном производстве, где партии деталей перемещаются в тарах, а автоматическая прослеживаемость каждой детали внутри тары затруднена из-за изменения размеров деталей в процессе обработки и необходимости маркировать каждую единицу.

Системы управления производством оперируют неявными, распределёнными по людям знаниями, что приводит к высокой проектной неопределённости и ошибкам. Отсутствует явная формализация знаний субъектов проектирования (технологов, операторов, конструкторов) о структуре и возможных состояниях производственных объектов и процессов [1, 2]. В онтологии проектирования рассматриваются методы формализации знаний о проектируемых

объектах, процессах и среде их функционирования [3]. Формирование онтологических моделей предметной области (ПрО) позволяет систематизировать знания экспертов [4] и использовать их при создании интеллектуальных систем поддержки принятия решений и автоматизации проектной и производственной деятельности [5].

Активно развиваются исследования, связанные с применением онтологических моделей в задачах технического зрения (ТЗр) и интеллектуального производства. В [6] предложен подход к применению систем ТЗр на производстве, в котором результаты ТЗр семантически связываются с онтологической моделью производственных событий. Показано, что использование семантического уровня позволяет повысить интерпретируемость результатов распознавания и упростить интеграцию систем ТЗр с информационными системами.

В [7] разработана онтология производственных процессов, предназначенная для формального представления структуры производственного потока, оборудования и операций; показана возможность использования онтологий для динамического управления производственными сценариями и повышения согласованности данных между различными уровнями цифрового производства.

В [8] предложен онтологически ориентированный конвейер построения цифровых двойников производственных систем. Онтология используется как средство формализации структуры оборудования, параметров процессов и взаимосвязей между компонентами системы.

В [9] онтологии используются для интеграции данных сенсорных систем и ТЗр в промышленной среде. Онтологическое описание объектов и процессов позволило унифицировать данные от различных источников и повысить устойчивость системы к неопределённости и шуму.

В [10] проведён анализ производственных онтологий в Индустрии 4.0, включая семантическое описание оборудования, маршрутов обработки, логистики и интеллектуальных систем контроля качества.

В [11] предложен подход к объединению методов ТЗр и семантических связей для анализа производственных сцен. Семантическая интерпретация позволяет распознавать объекты, выполнять логическую проверку корректности наблюдаемых состояний и выявлять нештатные ситуации.

Целью настоящей статьи является описание разработки и экспериментального обоснования онтологически ориентированного подхода к автоматизации учёта состояния производственного передела в дискретном производстве на основе каскадного алгоритма (КА) машинного обучения (МО), обеспечивающего высокую точность идентификации при ограниченных объёмах данных. В данной статье онтологическая модель используется как средство формального описания производственного объекта и как основа для онтологически ориентированной декомпозиции задачи ТЗр на иерархию специализированных моделей МО.

1 Онтологическая декомпозиция задачи технического зрения

На рисунке 1 приведена схема онтологии задачи автоматизированной идентификации содержимого производственных тар (ПТ). Онтология ПТ включает:

- модель объекта (классы «тара», «ячейка», «деталь», «маркер», атрибуты типоразмера, материала, допустимого содержимого);
- модель состояний (пустая/занятая ячейка, наличие/отсутствие маркера, ориентация);
- модель отношений (однозначное соответствие: «ID детали – ID тары – номер ячейки», «тара - технологический маршрут», «ячейка - допустимый класс детали»);
- модель неопределённости и «информационного шума» (классы отклонений: освещённость, угол поворота, частичное перекрытие, посторонние объекты).




Рисунок 1 – Схема онтологии задачи автоматизированной идентификации содержимого производственных тар

Для формализации ПрО разработана прикладная онтология ПТ, описывающая классы объектов, их свойства и ограничения. Основные элементы онтологии приведены в таблице 1.

Онтология позволяет выполнять семантические запросы к состоянию производственного передела. Примеры запросов: определить все занятые ячейки тары заданного типа; проверить соответствие типа детали типу тары; выявить случаи отсутствия маркеров; определить изображения с высоким уровнем неопределённости.

Таблица 1 – Основные классы и свойства онтологии производственной тары

Класс	Описание	Обозначения свойств на формальном языке	Ограничения
Тара	Производственная тара с фиксированной геометрией	<i>hasCell, hasMarker, containerType</i>	Тара должна содержать не менее одной ячейки
Ячейка	Локальная область хранения детали	<i>containsPart, cellID, cellState</i>	Ячейка может содержать не более одной детали
Деталь	Деталь определённого типа	<i>partType, partID</i>	Тип детали должен соответствовать типу тары
Маркер	Визуальный идентификатор	<i>markerType, markerID</i>	Каждый маркер принадлежит только одной таре
	Маркер пространственной ориентации <i>ArUco</i>	<i>activatesCascade</i>	Используется для активации каскада
	Маркер типа тары <i>QR</i> -код	<i>containerTypeID</i>	Определяет допустимый набор деталей

На схеме (см. рисунок 1) используется иерархическая онтология, где каждый уровень соответствует онтологии объекта, процесса и неопределённости. Маркеры используются как онтологические якоря, обеспечивающие активацию онтологий и моделей.

Под онтологической декомпозицией понимается функциональное разделение задачи ТЗр на последовательность подзадач (детектирование маркеров - выбор специализированных моделей - детектирование ячеек - классификация содержимого) и формализацию взаимосвязей между уровнями обработки данных, объектами ПрО и соответствующими моделями.

Использованы следующие принципы построения онтологии задачи ТЗр:

- *Разделение по уровням абстракции.* На верхнем уровне рассматривается ПТ как целостный объект производственного процесса. На нижних уровнях выделяются маркеры, ячейки и отдельные детали. Каждому уровню соответствует модель МО.
- *Инкапсуляция знаний о классе объектов.* Для каждого типа тары формируется фрагмент онтологии, включающий типы ячеек, деталей и состояний.
- *Наследование свойств и ограничений.* Тип тары, определяемый по *QR*-маркеру, задаёт ограничения для последующих этапов обработки: допустимые типы ячеек, наборы деталей и сценарии эксплуатации.
- *Композиция результатов распознавания.* Итоговое состояние ПТ формируется путём объединения результатов отдельных моделей в единую семантическую структуру: *Тара → Ячейка → Деталь → Состояние ячейки → Состояние тары*.

2 Онтологически управляемый каскадный алгоритм

В разработанном КА МО вместо использования одной универсальной модели на всём множестве классов ПрО используется многоуровневая онтология задачи (см. рисунок 2).

Предложенный каскад представляет собой формализацию знаний эксперта-технолога о процессе идентификации в виде иерархии решающих правил и специализированных моделей. *QR*-код и *ArUco*-маркеры позволяют в реальном времени подгружать нужный фрагмент онтологии ПрО и активировать соответствующие процедуры детектирования. Онтология используется для динамической валидации распознанных состояний ПТ и проверки согласованности результатов работы КА. После завершения этапов детектирования и классификации формируется семантическое описание текущего состояния тары в виде набора фактов:

$$\{Тара_i, Ячейка_i, Деталь_i, Состояние_i\}.$$

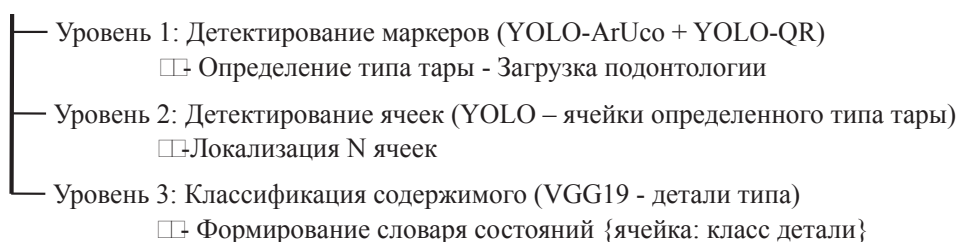


Рисунок 2 – Многоуровневая онтология задачи

Полученные факты проверяются на соответствие ограничениям ПрО, заданным в онтологии. В частности, выполняется контроль:

- соответствия типа детали типу тары;
- допустимости размещения детали в конкретной ячейке;
- отсутствия одновременно нескольких деталей в одной ячейке;
- технологического маршрута партии;
- наличия обязательных маркеров идентификации.

Например, если после распознавания система получает состояние: $Ячейка_{12} \rightarrow Деталь_B$, а онтология определяет, что для тары типа $Ячейка_{12}$ допустимы только детали типа $Деталь_A$, формируется сообщение о логическом противоречии и событие классифицируется как нештатная ситуация.

Онтология может использоваться для поддержки оператора производственного участка. При обнаружении противоречивых состояний система способна автоматически формировать рекомендации: проверить корректность загрузки тары; выполнить повторное сканирование; удалить посторонний объект из зоны видимости; направить тару на дополнительную проверку и др. В разработанном комплексе онтология определяет декомпозицию задачи и выполняет функцию семантической верификации состояний производственного передела.

Пусть для одного изображения X нужно принять четыре решения (метку):

- Y_1 – есть ли $ArUco$ на таре (число возможных состояний $K_1=2$).
- Y_2 – есть ли QR -код на таре ($K_2=2$).
- Y_3 – детектировать ячейки тары ($K_3=2$).
- Y_4 – заполненность ячейки типом детали по QR -коду или пустая ячейка ($K_4=2$).

Декомпозиция задачи ТЗр приводит к снижению требуемого объема обучающих данных за счёт факторизации исходной многомерной задачи распознавания на иерархию более простых и онтологически однородных подзадач. В традиционной постановке одна нейронная сеть обучается аппроксимации совместного апостериорного распределения:

$$P(Y_1, \dots, Y_4 | X) = \frac{P(X | Y_1, \dots, Y_4) P(Y_1, \dots, Y_4)}{P(X)}. \quad (1)$$

Число возможных состояний такой совместной метки растёт мультипликативно, что приводит к экспоненциальному увеличению требуемого объема обучающих данных.

В предложенном подходе структура задачи определяется онтологией объекта и процесса, что позволяет аппроксимировать факторизованное распределение вида:

$$P(Y_1, \dots, Y_4 | X) \approx \prod_{i=1}^4 P(Y_i | X, \theta_i), \quad (2)$$

где θ_i – соответствующий фрагмент онтологии (тип тары, класс деталей, структура ячеек).

Такая факторизация отражает физический и технологический смысл процесса и реализуется в виде каскада специализированных моделей.

Использование $ArUco$ - и QR -кодов дополнительно снижает энтропию подзадач, поскольку тип тары и допустимые классы деталей определяются маркером. В результате каждая специализированная модель обучается в узком, семантически однородном подпространстве без смешения геометрий, масштабов и типов объектов.

3 Решение экспериментальных задач

В МО автоматическому распознаванию используются нескольких видов деталей, находящихся в ячейках ПТ. Детали перемещались в ПТ с обрешёткой, в каждой ячейке могла находиться одна деталь. Необходимо выделить и классифицировать ячейки ПТ как пустые или содержащие детали, а также определить *ArUco*- и *QR*-коды.

Исходные данные представляли собой набор видеозаписей с двумя типами ПТ с ячейками, в каждой из которых могла находиться одна из множества деталей или же ячейка могла быть пустой. Каждый видеокادر использовался для обучения модели, где важно было распознать присутствие деталей, учесть их тип, а также тип *QR*-кодов (обычный или *ArUco*-). Обучение нейронных сетей проводилось с использованием видеокарты *NVIDIA GeForce GTX 1080 Ti* с 12Гб видеопамати.

В разработанном программно-аппаратном комплексе для съёмки использовались *Web*-камера *Logitech* и *IP*-камера *DH-IPC-HFW5442EP-ZE*. Аппаратная часть комплекса включала также: системный блок *Hiper M9 Cel G5905 (3.5) 4Gb SSD128Gb UHDG 610*; штатив *Hama Action 165 3D* для закрепления камер; коммуникационный модуль для включения автоматической подсветки и сигнала оператору; сигнальную лампу и светодиодную лампу подсветки. В качестве устройства ввода-вывода использован персональный компьютер, а коммуникационный модуль представлял собой аппаратное устройство, подключаемое к компьютеру по *USB*-порту и выполняющее включение/выключение светодиодной и сигнальной ламп.

3.1 Набор данных

В экспериментах использовались изображения ПТ двух типов, оснащённых *QR*- и *ArUco*-кодами, с размещёнными внутри ПТ тремя типами деталей. В таблице 2 приведены данные для обучения моделей *YOLO* [12], используемых для детектирования ПТ.

Таблица 2 – Используемые данные

Параметр	Одна модель			Каскад моделей			
Объём выборки/ тип объекта	100%	60%	30%	<i>ArUco</i>	<i>QR</i>	Ячейка тары 1	Ячейка тары 2
Обучение	287	146	86	20	20	27	19
Тест	34			8	9	10	7
Проверка	145			28	36	53	28

Исходный набор данных включал 466 уникальных изображений, содержащих различные комбинации положения ПТ, освещённости, и заполненности ячеек. Изображения были поделены в пропорции 69 % и 31 %. Первая группа изображений разделена на обучающую и тестовую выборки в соотношении 90 % и 10 % для универсальной модели детектирования всех классов объектов. Для анализа влияния объёма данных дополнительно формировались обучающие подвыборки, содержащие 30 % и 60 % исходной обучающей выборки. Формирование подвыборок осуществлялось случайным образом с сохранением пропорций классов объектов и типов тар. Вторая группа изображений использовалась как проверочная (не участвующая в обучении) выборка.

Для каскадной модели использовались те же исходные изображения, однако обучающие подвыборки формировались отдельно для каждой специализированной модели. Поскольку каждая модель решала узкую задачу (детектирование только *ArUco*-маркеров, только *QR*-кодов либо ячеек определённого типа тары), из общего набора выбирались только изображения, содержащие соответствующий объект. Таким образом, обучающие выборки каскадной модели являлись специализированными подмножествами единого исходного набора данных. Обучающая выборка составила 30% от данных, используемых в универсальной модели. Те-

стовая и проверочная выборка оставались в прежнем объёме. Для классификации содержимого ячеек выбрана архитектура *VGG19* [13], и для её обучения использовано 1100 взятых фрагмента из изображений, участвующих в обучении и тестировании *YOLO*. На фрагментах изображена ячейка тары с содержимым. 90% составили обучающую выборку, 10% – тестовую. Кроме того, использованы 375 фрагментов фотографий для проверочной выборки, не участвующей в обучении. При формировании подвыборок обеспечивалась сбалансированность по типам тар, типам деталей, состояниям ячеек (пустая/заполненная) и условиям съёмки (освещённость, угол поворота).

3.2 Подход с универсальной моделью нейронной сети

В рамках первого эксперимента обучались универсальные модели *YOLOv5* [14], позволяющие одновременно детектировать маркеры, ячейки тары и детали. Рассматривались три варианта архитектуры, различающиеся числом параметров и вычислительной сложностью: *YOLOv5s (small)* – компактная и быстрая модель; *YOLOv5m (medium)* – модель средней ёмкости; *YOLOv5l (large)* – наибольшая по числу параметров и потенциальной способности. Указанные варианты далее обозначаются соответственно как *Y5-S*, *Y5-M* и *Y5-L*. Обучение проводилось отдельно для каждого объёма обучающей выборки.

Для оценки точности результатов детектирования использовалась метрика $mAP_{\{50\}}$ (*Mean Average Precision*) являющаяся средним значением всех детектируемых классов C (количество N_C) на изображении для метрик AP (*Average Precision*) для каждого класса. Рассчитывалась AP для порога уверенности IoU (*Intersection over Union*) [15] равного 0,5.

$$mAP = \frac{1}{N_C} \sum_{c \in C} AP_c . \quad (3)$$

Результаты расчёта приведены в таблице 3.

Таблица 3 – Результаты по точности и производительности подхода с универсальной моделью

Модель	Доля обучающей выборки	mAP , %			Время на кадр, с
		Обучение	Тест	Проверочная	
<i>Y5-S</i>	30%	0,840	0,791	0,785	0,073
	50%	0,912	0,870	0,866	
	100%	0,945	0,907	0,895	
<i>Y5-M</i>	30%	0,826	0,786	0,767	0,143
	50%	0,949	0,856	0,874	
	100%	0,922	0,902	0,886	
<i>Y5-L</i>	30%	0,937	0,828	0,842	0,266
	50%	0,921	0,855	0,860	
	100%	0,954	0,897	0,879	

Увеличение времени детектирования между версиями *YOLOv5* коррелирует с ростом количества параметров и вычислительной сложности каждой модели. Между *Y5-S* и *Y5-M* время детектирования увеличивается примерно в 2 раза. Это связано с тем, что модель *Y5-M* имеет почти в 3 раза больше параметров, чем *Y5-S*. Между *Y5-M* и *Y5-L* время детектирования возрастает ещё в 1,9 раза. В среднем время выросло между *Y5-S* и *Y5-L* в 3,6 раза. С ростом модели растёт точность, а при разном объёме выборки точность снижается: для модели *Y5-M* на 11,9%, для модели *Y5-L* – на 3,7%. Полученные результаты показывают, что для используемого объёма данных применение более сложных архитектур не обеспечивает статистически значимого прироста качества по сравнению с компактной моделью *Y5-S*, тогда как время обработки кадра возрастает более чем в 3,5 раза.

3.3 Подход с использованием онтологически ориентированного каскада моделей

Во втором эксперименте применялся каскад специализированных моделей, структура которого определялась онтологией объекта и процесса: *Y5-S* для детектирования *QR*-кодов, *ArUco*-кодов и ячеек тары (отдельная модель для каждого типа тары); *VGG19* для классификации содержимого ячеек (отдельная модель для каждого типа деталей).

Каждая модель обучалась на наборе данных (п. 3.1), соответствующем своей онтологически однородной подзадаче. Для моделей детектирования использовалась метрика mAP (3), для классификационных моделей – точность работы ac , как отношение количества правильно классифицированных изображений N_i к их общему количеству N_{all} :

$$ac = N_i / N_{all} . \quad (4)$$

В таблице 4 приведены результаты расчётов точности и затрат времени отдельно обученных моделей, входящих в онтологически ориентированный каскад.

Таблица 4 – Результаты по точности и производительности моделей каскадного подхода

Подзадача	Модель	mAP			Время на кадр, с
		Обучение	Тест	Проверочная	
Детектирование <i>ArUco</i>	<i>Y5-S</i>	0,996	0,991	0,949	0,071
Детектирование <i>QR</i>		0,977	0,869	0,878	
Ячейки тары 1		0,965	0,925	0,871	
Ячейки тары 2		0,977	0,937	0,844	
Подзадача	Модель	ac			Время на кадр, с
		Обучение	Тест	Проверочная	
Деталь А	<i>VGG19</i>	0,993	0,933	0,928	0,043
Деталь В		1,000	1,000	0,985	
Деталь С		1,000	0,946	0,931	

Затраты времени на обработку одного кадра в каскаде складываются из затрат времени трёх сетей *YOLO*. После детектирования *QR* используется определённая сеть для конкретного типа тары. Кроме того, производится классификация содержимого каждой ячейки использованием определённой (в соответствии с типом тары и партией в ней) сети *VGG* каждой ячейки (в рассматриваемых объектах максимум 12 ячеек). Максимальное время для рассматриваемых объектов как сумма затрат времени отдельно обученных моделей, входящих в каскад, составило 0,729 с.

3.4 Сравнительный анализ подходов

Для оценки качества каскада моделей в целом введена метрика корректной идентификации ячейки (сквозная точность) – mAP_r . Ячейка считалась корректно распознанной, если выполнялись следующие условия:

- проведена корректная активация системы для детектирования по *ArUco*-коду;
- корректно определён тип тары по *QR*-коду;
- ячейка была правильно локализована;
- правильно определено состояние ячейки (пустая или содержащая деталь).

Сквозная точность определялась как отношение числа корректно идентифицированных ячеек N_{c_c} к общему числу ячеек на тестовой выборке N_{c_all} :

$$mAP_r = N_{c_c} / N_{c_all} . \quad (5)$$

Использована метрика mAP_r^* , отражающая накопление ошибок между этапами алгоритма и позволяющая оценить влияние качества отдельных подсистем на итоговый результат:

$$mAP_r^* = mAP_{ArUco} \cdot mAP_{QR} \cdot mAP_{cell_obj} , \quad (6)$$

где mAP_{ArUco} – точность детектирования $ArUco$ -кодов; mAP_{QR} – точность детектирования QR -кодов; mAP_{cell_obj} – точность локализации и определения состояния ячейки.

$$mAP_{cell_obj} = \frac{1}{N_{cell} \cdot N_{obj}} \sum_{j \in C_{cell}} \sum_{i \in C_{obj}} mAP_{cell}^j \cdot ac_i, \quad (7)$$

где N_{cell} – количество типов ячеек из множества C_{cell} ; N_{obj} – количество типов классов объектов в ячейках из множества C_{obj} ; mAP_{cell} – точность детектирования ячеек.

Итоговая сквозная точность дополнительно рассчитывалась непосредственно на тестовой выборке как доля полностью корректно обработанных ячеек mAP_r . В таблице 5 приведено сопоставление подхода с универсальной моделью и онтологически ориентированного подхода по критерию (5) и вычислительной эффективности на проверочной выборке.

Таблица 5 – Сравнение двух подходов по точности и производительности

Подход		Объём обучающих данных	mAP_{ArUco}	mAP_{QR}	mAP_{cell_obj}	mAP_r^*	mAP_r	Время на кадр, с
Универсальная модель	Y5-S	30%	0,823	0,700	0,792	0,457	0,701	0,073
		50%	0,836	0,722	0,880	0,531	0,736	
		100%	0,935	0,744	0,912	0,634	0,768	
	Y5-M	30%	0,858	0,675	0,783	0,454	0,695	0,143
		50%	0,874	0,734	0,892	0,572	0,742	
		100%	0,951	0,758	0,899	0,648	0,781	
	Y5-L	30%	0,804	0,710	0,864	0,493	0,714	0,266
		50%	0,890	0,699	0,881	0,548	0,751	
		100%	0,929	0,750	0,894	0,623	0,772	
Каскад моделей		30%	0,949	0,878	0,815	0,679	0,823	0,729

Каскадный подход обеспечивает более высокую точность на уровне конечной задачи (идентификация состояния ячейки), несмотря на сопоставимые или более низкие значения mAP_r на отдельных этапах. Значения экспериментальной сквозной точности mAP_r оказались выше оценки mAP_r^* , вычисляемой как произведение метрик отдельных этапов каскада. Метрика mAP характеризует качество точности и полноты и зависит от распределения порогов уверенности IoU , поэтому её прямое перемножение приводит к консервативной оценке. Этапы КА являются условно зависимыми: успешное обнаружение $ArUco$ - и QR -кодов уменьшает пространство поиска и снижает вариативность задач локализации и классификации.

Полученные результаты (рост точности с 65 % до 68 % по mAP_r^* и с 77% до 82% по mAP_r при снижении объёма обучающих данных более чем в три раза) показывают эффективность онтологически ориентированного подхода к построению систем МО в задачах ТЗр.

Максимальное время обработки одного кадра с использованием разработанного КА детектирования составило 0,729 с. Максимальное время обработки одного кадра при подходе с универсальной моделью составило 0,143-0,266 с. С учётом специфики рассматриваемой производственной системы (движение деталей малыми партиями) подобный рост времени обработки не критичен для автоматизации процесса.

Заключение

В статье рассмотрен онтологически ориентированный подход на основе технологий ТЗр для идентификации содержимого ПТ. Предложен КА, основанный на принципе онтологической декомпозиции задачи, при котором вместо одной универсальной модели используется иерархия специализированных нейронных сетей: модели *YOLO* применяются для детектирования онтологических якорей ($ArUco$ - и QR -кодов) и ячеек ПТ, а модель *VGG19* – для классификации их содержимого.

Показано, что использование онтологических якорей и декомпозиция задачи позволяют сократить объем требуемой обучающей выборки (на 50-70%) при сохранении точности распознавания и устойчивости к вариациям условий наблюдения.


Разработанный программно-аппаратный комплекс автоматизированной идентификации содержимого ПТ показал возможность практического применения в задачах промышленного ТЗр, обеспечивая повышение эффективности МО в условиях ограниченности данных и высокой вариативности номенклатуры, характерных для дискретного производства.

Список источников

- [1] **Боргест Н.М.** Границы онтологии проектирования. *Онтология проектирования*. 2017. Т.7, №1(23). С.7–33. DOI: 10.18287/2223-9537-2017-7-1-7-33.
- [2] **Боргест Н.М.** Научный базис онтологии проектирования. *Онтология проектирования*. 2013. Т.3, №1(7). С.7–25.
- [3] **Боргест Н.М.** Онтологии проектирования от Витрувия до Виттиха. *Онтология проектирования*. 2018. Т.8, №4(30). С.487–522. DOI: 10.18287/2223-9537-2018-8-4-487-522.
- [4] **Насонов М.А., Манцеров С.А.** Онтологическая модель профилактического обслуживания оборудования промышленного предприятия. *Онтология проектирования*. 2026. Т.16, №1(59), С.25-39. DOI: 10.18287/2223-9537-2026-16-1-25-39.
- [5] **Дородных Н.О., Николайчук О.А., Юрин А.Ю.** Использование онтологических шаблонов содержания при построении баз знаний для технического обслуживания и ремонта авиационной техники. *Онтология проектирования*. 2022. Т.12, №2(44). С.158-171. DOI: 10.18287/2223-9537-2022-12-2-158-171.
- [6] **Xia K., Saidy C., Kirkpatrick M., Anumbe N., Sheth A., Harik R.** Towards semantic integration of machine vision systems to aid manufacturing event understanding. *Sensors*. 2021. Vol.21, No.13. Art.4276. DOI: 10.3390/s21134276.
- [7] **Yang C., Zheng Y., Tu X., Ala-Laurinaho R., Autiosalo J., Seppänen O., Tammi K.** Ontology-based knowledge representation of industrial production workflow. *Advanced Engineering Informatics*. 2023. Vol.58. Art.102185. DOI: 10.1016/j.aei.2023.102185.
- [8] **Göppert A., Grahn L., Rachner J. et al.** Pipeline for ontology-based modeling and automated deployment of digital twins for planning and control of manufacturing systems. *Journal of Intelligent Manufacturing*. 2023. Vol.34. P.2133–2152. DOI: 10.1007/s10845-021-01860-6.
- [9] **Gonçalves E.M.N., Freitas A., Botelho S.** An AutomationML based ontology for sensor fusion in industrial plants. *Sensors*. 2019. Vol.19, No.6. Art.1311. DOI: 10.3390/s19061311.
- [10] **Sapel P., Molinas Comet L., Dimitriadis I., Hopmann C.** A review and classification of manufacturing ontologies. *Journal of Intelligent Manufacturing*. 2025. Vol.36. P.3669–3693. DOI: 10.1007/s10845-024-02425-z.
- [11] **Liu Z., Zhang A., Wang W.** Combining computer vision with semantic reasoning for on-site safety management in construction. *Journal of Building Engineering*. 2021. Vol.42. Art.103036. DOI: 10.1016/j.jobe.2021.103036.
- [12] **Redmon J., Divvala S., Girshick R., Farhadi A.** You only look once: Unified, real-time object detection. *Proc. IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Las Vegas, USA, 2016. P.779–788. DOI: 10.1109/CVPR.2016.91.
- [13] **Simonyan K., Zisserman A.** Very deep convolutional networks for large-scale image recognition. *Proc. 3rd International Conference on Learning Representations (ICLR)*. San Diego, USA, 2015. Vol.1409. P.1556. DOI: 10.48550/arXiv.1409.1556.
- [14] **Dulal R., Zheng L., Kabir M.A. et al.** Automatic cattle identification using YOLOv5 and mosaic augmentation: A comparative analysis. *arXiv preprint*. 2022. P.1–8. DOI: 10.48550/arXiv.2210.11939.
- [15] **Rezatofighi H., Tsoi N., Gwak J., et al.** Generalized intersection over union: a metric and a loss for bounding box regression. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 2019. P.658–666. DOI: 10.1109/CVPR.2019.00075.

Сведения об авторах

Печенин Вадим Андреевич, 1990 г. рождения. Окончил Самарский государственный аэрокосмический университет имени академика С.П. Королева в 2012 г., к.т.н. (2017). Заведующий научно-исследовательской лабораторией "Искусственный интеллект в производственных стемах", доцент кафедры технологий производства двигателей Самарского национального





исследовательского университета имени академика С.П. Королева (Самарский университет). В списке научных трудов около 150 работ. Author ID (РИНЦ): 793203; Author ID (Scopus): 56401223700; Researcher ID (WoS): F-1835-2017. ORCID: 0000-0003-4961-7338. pechenin.va@ssau.ru. ✉.

Хаймович Александр Исаакович, 1965 г. рождения. Окончил Куйбышевский авиационный институт имени академика С.П. Королёва (1989), д.т.н. (2014). Заведующий кафедрой технологий производства двигателей Самарского университета, г.н.с. Инжинирингового центра Самарского университета. В списке научных трудов более 200 работ. Author ID (РИНЦ): 463931; Author ID (Scopus): 56400927200. ORCID: 0000-0002-9935-5703. khaimovich.ai@ssau.ru.

Поступила в редакцию 30.03.2026, после рецензирования 18.05.2026. Принята к публикации 27.07.2026.



Scientific article

DOI: 10.18287/2223-9537-2026-16-3-465-476

Ontological decomposition of a machine vision task in discrete manufacturing

© 2026, V.A. Pechenin ✉, A.I. Khaimovich

Samara University (Samara National Research University named after academician S.P. Korolev), Samara, Russia

Abstract

An ontology-oriented approach to automating the monitoring of production process status in discrete manufacturing is proposed. A hardware and software system has been developed for identifying parts in manufacturing containers using machine vision technologies and a cascade algorithm based on convolutional neural networks. An ontological decomposition of the task is implemented: instead of training a single universal neural network model, a hierarchy of specialized models is employed, with individual models activated on the basis of ontological markers (ArUco markers and QR codes). This approach reduces the required amount of training data by 50–70% while maintaining detection accuracy under conditions of “information noise,” including variations in illumination, container orientation, and the presence of extraneous objects. The developed system formalizes knowledge concerning the structure of manufacturing containers, their states, relationships, and uncertainties in discrete manufacturing. A comparative analysis of experimental results confirms the effectiveness of the proposed method for ensuring material-flow traceability in flexible manufacturing systems.

Keywords: *ontological decomposition, machine vision, manufacturing container, discrete manufacturing, traceability, uncertainty, machine learning.*

For citation: *Pechenin VA, Khaimovich AI. Ontological decomposition of a machine vision task in discrete manufacturing [In Russian]. Ontology of designing. 2026; 16(3): 465-476. DOI: 10.18287/2223-9537-2026-16-3-465-476.*

Financial Support: The preparation of the paper was sponsored by the Ministry of Science and Higher Education of the Russian Federation (project FSSS-2024-0019).

Authors' contributions: *Pechenin V.A.* – problem formulation, development of the ontological model and cascade algorithm, experimental investigation, data processing, and analysis of the results; *Khaimovich A.I.* – formulation of the ontological approach to the problem and interpretation of the results.

Conflict of interest: The authors declare no conflict of interest.

List of figures and tables

Figure 1 – Ontology scheme for the automated identification of manufacturing container contents

Figure 2 – Multi-level task ontology

Table 1 – Main classes and properties of the manufacturing container ontology

Table 2 – Data used

Table 3 – Accuracy and performance results of the universal-model approach

Table 4 – Accuracy and performance results for the cascade-approach models

Table 5 – Comparison of the two approaches in terms of accuracy and performance

References

- [1] **Borgest NM.** Boundaries of the ontology of designing [In Russian]. *Ontology of Designing*. 2017; 7(1): 7–33. DOI: 10.18287/2223-9537-2017-7-1-7-33.
- [2] **Borgest NM.** Scientific basis for the ontology of designing [In Russian]. *Ontology of Designing*. 2013; 3(1): 7–25.
- [3] **Borgest NM.** The ontologies of designing from Vitruvia to Vittikh [In Russian]. *Ontology of Designing*. 2018; 8(4): 487–522. DOI: 10.18287/2223-9537-2018-8-4-487-522.
- [4] **Nasonov MA, Mantserov SA.** Ontological model of preventive maintenance of industrial enterprise equipment [In Russian]. *Ontology of Designing*. 2026; 16(1): 25–39. DOI: 10.18287/2223-9537-2026-16-1-25-39.
- [5] **Dorodnykh NO, Nikolaychuk OA, Yurin AY.** Using ontological content patterns in knowledge base engineering for maintenance and repair of aviation equipment [In Russian]. *Ontology of Designing*. 2022; 12(2): 158–171. DOI: 10.18287/2223-9537-2022-12-2-158-171.
- [6] **Xia K, Saidy C, Kirkpatrick M, Anumbe N, Sheth A, Harik R.** Towards semantic integration of machine vision systems to aid manufacturing event understanding. *Sensors*. 2021; 21(13): 4276. DOI: 10.3390/s21134276.
- [7] **Yang C, Zheng Y, Tu X, Ala-Laurinaho R, Autiosalo J, Seppänen O, Tammi K.** Ontology-based knowledge representation of industrial production workflow. *Advanced Engineering Informatics*. 2023; 58: 102185. DOI: 10.1016/j.aei.2023.102185.
- [8] **Göppert A, Grahn L, Rachner J et al.** Pipeline for ontology-based modeling and automated deployment of digital twins for planning and control of manufacturing systems. *Journal of Intelligent Manufacturing*. 2023; 34: 2133–2152. DOI: 10.1007/s10845-021-01860-6.
- [9] **Gonçalves EMN, Freitas A, Botelho S.** An AutomationML based ontology for sensor fusion in industrial plants. *Sensors*. 2019; 19(6): 1311. DOI: 10.3390/s19061311.
- [10] **Sapel P, Molinas Comet L, Dimitriadis I, Hopmann C.** A review and classification of manufacturing ontologies. *Journal of Intelligent Manufacturing*. 2025; 36: 3669–3693. DOI: 10.1007/s10845-024-02425-z.
- [11] **Liu Z, Zhang A, Wang W.** Combining computer vision with semantic reasoning for on-site safety management in construction. *Journal of Building Engineering*. 2021; 42: 103036. DOI: 10.1016/j.jobe.2021.103036.
- [12] **Redmon J, Divvala S, Girshick R, Farhadi F.** You only look once: Unified, real-time object detection. In: *Proc. 2016 IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*. Las Vegas, USA, 2016: 779–788. DOI: 10.1109/CVPR.2016.91.
- [13] **Simonyan K, Zisserman A.** Very deep convolutional networks for large-scale image recognition. In: *Proc. 3rd International Conference on Learning Representations (ICLR)*. San Diego, USA, 2015. Vol. 1409, p. 1556. DOI: 10.48550/arXiv.1409.1556.
- [14] **Dulal R, Zheng L, Ashad Kabir M. et al.** Automatic cattle identification using YOLOv5 and mosaic augmentation: A comparative analysis. *arXiv preprint* 2022: 1–8. DOI: 10.48550/arXiv.2210.11939.
- [15] **Rezatofighi H, Tsoi N, Gwak J. et al.** Generalized intersection over union: a metric and a loss for bounding box regression. In: *Proc. IEEE/CVF Conf. on Computer Vision and Pattern Recognition (CVPR)*. Long Beach, USA, 2019: 658–666. DOI: 10.1109/CVPR.2019.00075.

About the authors

Vadim Andreevich Pechenin (b. 1990) graduated from Samara State Aerospace University named after Academician S. P. Korolev in 2012; Candidate of Technical Sciences (2017). Head of the Research Laboratory “Artificial Intelligence in Manufacturing Systems” and Associate Professor at the Department of Engine Manufacturing Technologies, Samara National Research University named after Academician S. P. Korolev (Samara University). He is the author and a co-author of about 150 scientific publications. Author ID (RSCI): 793203; Author ID (Scopus): 56401223700; Researcher ID (WoS): F-1835-2017. ORCID: 0000-0003-4961-7338. pechenin.va@ssau.ru. ✉.

Alexander Isaakovich Khaimovich (b. 1965) graduated from Kuibyshev Aviation Institute named after Academician S. P. Korolev in 1989; Doctor of Technical Sciences (2014). Head of the Department of Engine Manufacturing Technologies at Samara University and Chief Researcher at the Engineering Center of Samara University. He is the author and co-author of more than 200 scientific publications. Author ID (RSCI): 463931; Author ID (Scopus): 56400927200. ORCID: 0000-0002-9935-5703. khaymovich.ai@ssau.ru.

Received March 30, 2026. Revised May 18, 2026. Accepted July 27, 2026.