

УДК 004.056.55

**ДИСТАНЦИОННЫЙ КОНТРОЛЬ КАЧЕСТВА
СВАРНЫХ СОЕДИНЕНИЙ ПЛЁНОК
МЕТОДОМ ИЗМЕРЕНИЙ ДЕФЕКТОВ
СИСТЕМОЙ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА**

**А.С. Степашкина, К.В. Епифанцев,
В.О. Смирнова, О.В. Чупринова, К.В. Золотухин**

*Санкт-Петербургский государственный университет аэрокосмического приборостроения,
Санкт-Петербург, Россия,
stepashkina.anna@yandex.ru, epifancew@gmail.com*

Аннотация. Вопросы бесконтактных измерений важны на этапе контроля качества с целью ускорения процесса обнаружения дефекта и определения его точностных параметров. Бесконтактный (дистанционный) метод контроля качества также применим для стерильных типов изделий, прямой контакт инструмента с которыми крайне нежелателен. Современные системы оптических измерительных механизмов, такие как видеоизмерительные машины, безусловно, способны с высокой точностью определить дефект по нескольким представленным образцам. Однако низкая скорость и невозможность интеллектуальной сортировки бракованных элементов от соответствующих качественным признакам ограничивают их быстроедействие.

В работе описаны основные методы работы с машинным зрением и предложен подход к контролю качества материалов сварных соединений. Машинное зрение позволяет осуществить непрерывный автоматизированный контроль на производстве. В основе машинного зрения лежит обработка и анализ фотоматериалов, которые служат базой для сравнения продукции на наличие дефектов. Внедрение такой технологии на производстве на порядок снижает возможный выпуск брака. Для реализации рассмотрен подход капиллярного метода контроля и его внедрение с помощью алгоритма в аналитической платформе KNIME. Капиллярный метод основан на использовании контрастного вещества, которое, проникая в различные дефекты, образует под воздействием капиллярного давления визуализируемые индикаторные рисунки. Контроль осуществляется с помощью машинного зрения: в постоянном режиме сканируются все материалы и сравниваются с созданной базой дефектов.

Описанный метод обеспечит повышение качества конечной продукции и позволит перейти от ручной проверки дефектов на автоматизированную.

Ключевые слова: автоматизация, машинное зрение, бесконтактные измерения, «умные» производства, контроль качества изделий, капиллярный метод, роботизированные системы, сварные соединения.

**REMOTE QUALITY CONTROL OF WELDED JOINTS
OF FILMS BY MEASURING DEFECTS
BY ARTIFICIAL INTELLIGENCE SYSTEM**

**A.S. Stepashkina, K.V. Epifantsev,
V.O. Smirnova, O.V. Chuprinova, K.V. Zolotukhin**

*St. Petersburg State University of Aerospace Instrumentation, St. Petersburg, Russia,
stepashkina.anna@yandex.ru, epifancew@gmail.com*

Abstract. The issues of non-contact measurements are important at the stage of quality control in order to speed up the process of detecting a defect and determining its accuracy parameters. The contactless (remote) method of quality control is also applicable for sterile types of products, direct contact of the instrument with which is extremely undesirable. Modern systems of optical measuring mechanisms, such as video measuring machines, are certainly capable of detecting a defect with high accuracy from several samples presented. However, the low speed and the impossibility of intellectual sorting of defective elements from the corresponding qualitative characteristics limits their performance.

The paper describes the main methods of working with machine vision and suggests an approach to quality control of welded joint materials. Machine vision allows for continuous automated control in production. Machine vision is based on the processing and analysis of photographic materials, which serve as a basis for comparing products for defects. The introduction of such technology in production reduces the possible release of marriage by an order of magnitude. For implementation, the approach of the capillary control method and its implementation using an algorithm in the KNIME analytical platform are considered. The capillary method is based on the use of a contrast agent, which, penetrating into various defects, forms visualized indicator patterns under the influence of capillary pressure. The control is carried out using machine vision: all materials are scanned in a continuous mode and compared with the created database of defects.

The described method will provide an improvement in the quality of the final product and will allow moving from manual defect checking to automated.

Keywords: automation, machine vision, smart manufacturing, product quality control, capillary method, robotic systems, welded joints.

Введение

В настоящее время активно развивается область разработки и прикладного применения измерительных систем, интегрированных в системы искусственного интеллекта. Одним из важнейших элементов подобных систем являются программно-аппаратные средства, обеспечивающие преобразование, обработку и отображение измерительной информации, последующее отделение годных элементов от дефектных.

При создании прототипов средств измерений часто используют программные среды разработки виртуальных измерительных приборов [1, 2]. Их применение наступает на предварительном этапе, перед разработкой принципиальной схемы прибора.

Системы машинного зрения способны значительно повысить операционную эффективность и пропускную способность производственных линий без ущерба для качества выпускаемой продукции. Эффективно работают они и там, где особое внимание уделяется контролю качества упаковки.

Оценить качество изделия порой бывает сложно. При выборе номенклатуры показателей качества продукции устанавливается перечень наименований количественных характеристик свойств продукции, входящих в состав качества продукции и обеспечивающих возможность оценки ее уровня качества. Обоснование выбора номенклатуры показателей качества проводится с учётом:

- назначения и условий использования продукции;
- анализа требований потребителя;
- задач управления качеством продукции;
- состава и структуры характеризующих свойств;
- основных требований к показателям качества продукции.

Порядок выбора номенклатуры показателей качества продукции предусматривает определение:

- вида (группы) продукции;
- цели применения номенклатуры показателей качества продукции;
- исходной номенклатуры групп показателей качества продукции;
- исходной номенклатуры показателей качества продукции по каждой группе;
- метода выбора номенклатуры показателей качества продукции.

Применение машинного (компьютерного) зрения для оценки характеристик материалов

Машинное зрение — это одна из основополагающих технологий промышленной автоматизации. Оно помогает повышать качество продукции, оптимизировать логистику и ускорять производство уже не одно десятилетие. Сейчас эта испытанная технология объединяется с искусственным интеллектом и становится двигателем четвертой промышленной революции.

Можно выделить следующие основные этапы работы с технологией компьютерного зрения: в самом простом случае — это подготовка обучающих данных и обучение моделей компьютерного зрения.

1) Подготовка фотоматериала, в нашем случае это фотографии дефектов материалов и изделий: труб, сварных соединений, предварительно обработанных пенетратом. Необходимо подготовить хотя бы 500 фотографий с дефектами и 500 фото — без, поместить в разные каталоги. Конечно, чем больше фотоматериала, тем лучше. Можно брать открытые данные, если такие имеются. Популярным открытым ресурсом данных, который можно использовать в качестве упражнения, является Kaggle.

2) После подготовки фотоданных переходим к обучению компьютерной модели машинного зрения. Это можно сделать двумя способами: с помощью библиотек языка программирования, например Python, или на аналитической платформе. Решаем задачу классификации на наличие или отсутствие дефекта. В реальности задача может быть сложнее: алгоритмы компьютерного зрения позволяют определять даже тип дефекта при корректно подготовленной обучающей выборке.

Раньше для обработки фотоматериалов и большого объёма данных требовалось хорошее умение программировать. Сегодня эффективные инструменты позволяют нам проводить анализ, не будучи специалистом в обработке изображений. Некоторые пакеты также доступны для языков программирования высокого уровня, таких как Python (например, библиотека `scikit-learn`). Поскольку библиотеки Python очень объёмные, из опыта рекомендуем работать в блокноте Google Colab, поскольку данный ресурс, во-первых, бесплатный, а, во-вторых, многие библиотеки уже предустановлены, нет необходимости устанавливать дополнительное программное обеспечение. Использование машинного зрения позволяет снижать вероятность выпуска брака до 0,01 %, в то время как вероятность этого после контроля глазом — до 20 %.

Капиллярный метод контроля

Для повышения скорости и точности исследований и измерений, уменьшения времени, затрачиваемого на обработку и оценку результатов, а также для устранения ошибок, допускаемых самими исследователями при проведении контроля качества, часто проводят его полную автоматизацию [1, 2].

Приведём пример автоматической линии контроля качества для капиллярного метода контроля, который широко используется для выявления поверхностных и сквозных дефектов материала, сварных соединений. В его основе лежит использование контрастного вещества (пенетранта), которое, проникая в различные дефекты, образует под воздействием капиллярного давления визуализируемые индикаторные рисунки.

Основными инструментами автоматизации капиллярного метода могут выступать алгоритмы компьютерного зрения. Суть работы алгоритмов, реализованных на языке программирования и аналитической платформе, идентичны. Целью интеллектуального анализа изображений является извлечение ценных знаний из массива изображений для обучения алгоритма компьютерного зрения. В контексте классификации изображений мы хотим автоматически присвоить изображению метку из их визуального содержимого. Весь процесс идентичен стандартному процессу интеллектуального анализа данных. Затем мы можем применить предобученную модель классификации к новому изображению, чтобы предсказать его принадлежность к классу. Особенность заключается в том, что мы должны извлечь вектор числовых характеристик из изображения перед запуском алгоритма машинного обучения и перед применением классификатора на этапе развёртывания.

Основные результаты исследования

Пример реализации алгоритма в аналитической платформе KNIME можно представить в виде блочного решения, представленного на рис. 1.

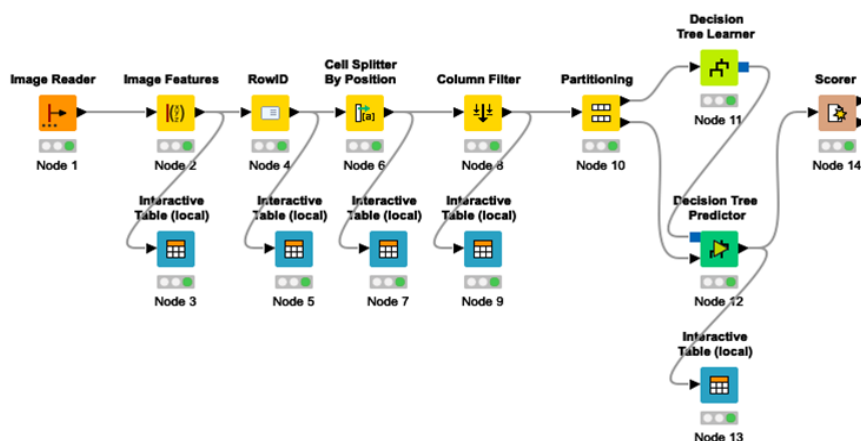


Рис. 1. Пример реализации алгоритма

Заранее подготовленные изображения материалов без дефектов и с дефектами (рис. 2) сначала подгружаются на платформу с помощью функциональных узлов.




Рис. 2. Категории дефектов:

а — значительный; б — малозаметный; в — отсутствие дефектов

Затем происходит декодирование, перевод рисунка на язык машины. После этого применяется алгоритм классификации, например, дерево решений. Результат работы алгоритма оценивается с помощью метрики Scorer, ошибка не превышает 10 %.

Применение в промышленном производстве (при лабораторных испытаниях и научных работах) систем машинного зрения, программно-реализующих автоматическое выполнение операций для контроля качества продукции, вызвано всё более ужесточающимися требованиями к соответствию выпускаемых товаров стандартам качества и неудобством контроля, проводимого «вручную». Внедряемые компьютерные технологии за счёт автоматизации обеспечивают рост производительности труда и, соответственно, увеличение скорости и качества производства. Использование специального программного обеспечения, входящего в системы машинного зрения, гарантирует отсутствие в результатах работы ошибок, обусловленных «человеческим фактором».

Рассмотрим результат решения задачи классификации изображения в зависимости от метрологических характеристик и дефектологических признаков на пленке.

Каждое выходное значение на карте объектов не обязательно должно быть связано с каждым значением пикселя во входном изображении. Ему нужно только подключиться к рецептивному полю, где применяется фильтр. Поскольку выходной массив не обязательно должен напрямую сопоставляться с каждым входным значением, свёрточные (и объединяющие) слои обычно называют «частично связанными» слоями. Однако эту характеристику также можно описать как локальную связность.

На вход подаются два каталога с изображениями: “pos” (изображения материалов без дефектов), “neg” (изображения материалов с дефектами). Фотографии изображения без дефекта и с дефектами приведены на рис. 3.



Рис. 3. Элементы без дефектов (слева) и с дефектами (справа)

Выведенный на экран результат реализации алгоритма на Python с использованием свёрточной нейронной сети из библиотеки Keras в GoogleColab приведён на рис. 4.




Рис. 4. Результат вывода анализа на экран

Построим нейронную сеть. Подключаем необходимые библиотеки.

Разбиваем данные на тестовую и обучающую выборки. В качестве обучающей выборки берем 20 %.

Строим многослойную свёрточную нейронную сеть.

Обучаем сеть, в качестве валидационной выборки берём тестовую.

Оценка точности модели говорит о том, что метрика Accuracy соответствует значению 0,8750, процент ошибок step - loss: 0,3357. Такой результат говорит о высокой точности модели. Выведем информацию о нейронной сети.

Выполним предсказание и визуализируем результат в виде таблицы (рис. 5).




Рис. 5. Визуализация результата

Реализация в KNIME

Для работы с изображениями необходимо установить плагин “Supervised-ImageSegmentation”. Для это в платформе KNIME в верхнем меню “File” выбрать “InstallKNIMEExtension”, в появившемся окне выбрать “KNIMECommunityExtensions–ImageProcessingandAnalysis”, далее следовать инструкциям.

Перейдём к следующему этапу — «Выделение признаков», который состоит в том, чтобы извлечь из каждого изображения числовой вектор, который характеризует изображение и который будет использоваться на этапе моделирования. Этот этап имеет решающее значение для точности работы классификатора (рис. 6).

Добавляем узел “ImageFeature (CommunityNodes / KNIMEImageProcessing / Features)”. Соединяем стрелкой “ImageReaderImageFeature”. Устанавливаем параметры путём двойного клика мыши по иконке “ImageFeature”.

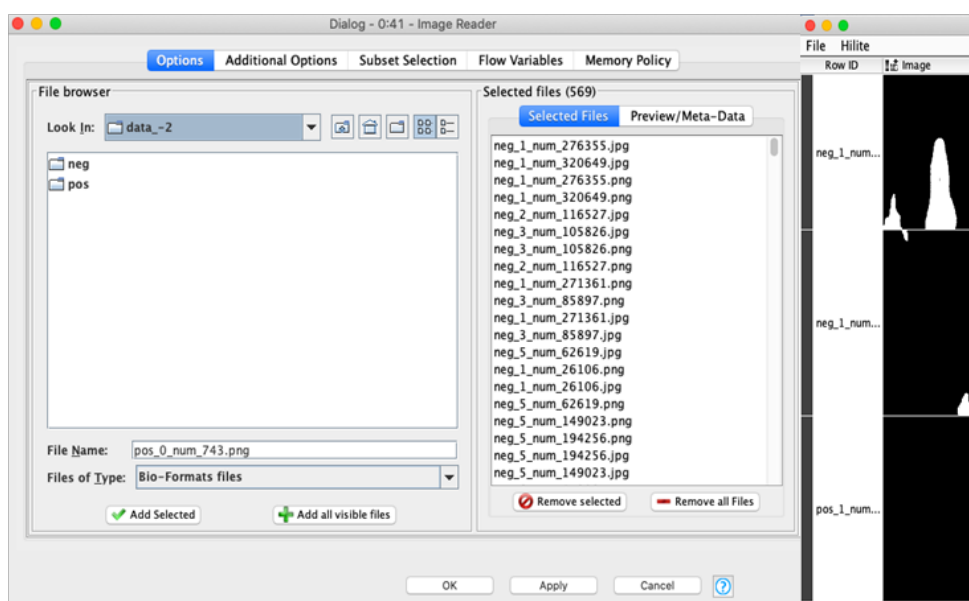


Рис. 6. Этап выделения признаков

На вкладке “Column Selection” выберите столбец “Image”. На вкладке “Features” выбираем элементы, которые нужно извлечь. Мы устанавливаем только статистику первого порядка “FirstOrderStatistics”. Нажимаем кнопку “OK”. Значения функций можно визуализировать с помощью узла “InteractiveTable” (находится в разделе “View / Local (Swing)”). Соединяем узлы “Image-Feature” и “InteractiveTable” с помощью мыши и запускаем кнопкой “Execute-andOpenViews” последний добавленный узел. Сработали сразу оба узла, на экране появилась таблица признаков (рис. 7).

Table View - 0:43 - Interactive Table (local)													
File Edit Hilite Navigation View													
Row ID	D Max	D Mean	D Geom...	D Sum	D Square...	D Std Dev	D Varian...	D Skewn...	D Kurtosis	D Quanti...	D Qua		
neg_1_num...	226	76.909	72.722	7,060,572	592,156,2...	23.134	535.203	0.01	1.07	66	78		
neg_1_num...	255	71.14	69.761	3,559,983	263,067,5...	14.002	196.052	0.756	6.166	62	72		
neg_1_num...	255	0.413	0	37,945	9,096,561	9.946	98.917	24.724	614.385	0	0		
neg_1_num...	255	0.679	0	33,997	7,810,543	12.475	155.621	19.256	375.847	0	0		
neg_2_num...	255	74.348	69.308	7,637,284	631,001,9...	24.801	615.084	-0.139	0.044	58	78		
neg_3_num...	255	106.805	101.677	16,579,595	1,929,952...	32.021	1,025.338	0.391	0.528	83	105		
neg_3_num...	255	1.082	0	167,983	36,292,309	15.252	232.624	15.139	234.642	0	0		
neg_2_num...	255	0.69	0	70,829	16,675,779	12.723	161.863	19.11	367.402	0	0		
neg_1_num...	255	0.623	0	37,990	8,893,640	12.061	145.467	20.106	408.24	0	0		
neg_3_num...	255	0.601	0	89,200	20,822,380	11.827	139.886	20.358	416.374	0	0		
neg_1_num...	208	65.449	61.958	3,990,885	280,858,8...	17.956	322.411	-0.589	1.919	58	67		
neg_3_num...	238	85.827	81.769	12,742,665	1,183,955...	24.661	608.186	0.111	0.718	70	88		
neg_5_num...	255	120.10	125.538	4,526,721	628,648,7...	23.626	1,120.603	0.068	-0.473	103	121		

Рис. 7. Таблица признаков

Сейчас в таблице нет указания на разделение между фотографиями с дефектами материала и без них, нет целевой переменной. Однако имена файлов имеют подсказку — первые 3 буквы, которые можно извлечь и превратить в категориальную переменную.

На первом этапе используем узел “RowID(Manipulation / Row / Other)”. Подключаем узел “ImageFeature” к этому новому узлу. Устанавливаем настройки узла. В разделе “AppendRowIDcolumn” создадим новый столбец в строке “Newcolumnname” с именем “n/p”. Нажимаем кнопку “ОК” (рис. 8).

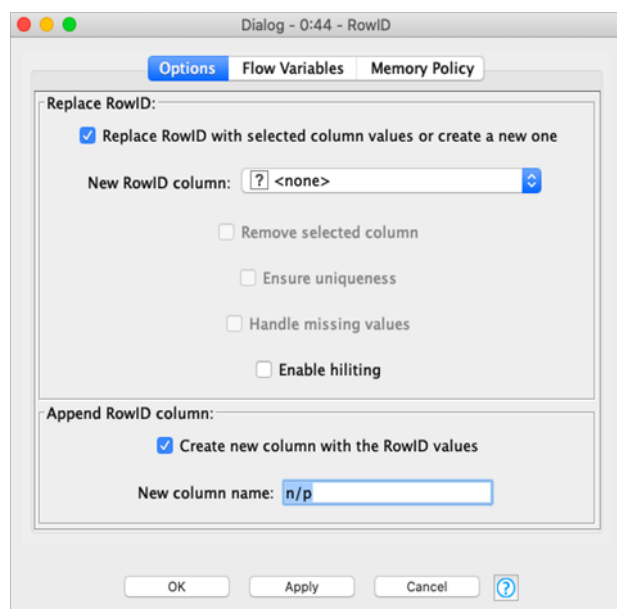


Рис. 8. Настройки узла

Добавим элемент “InteractiveTable”, далее делаем известную нам операцию: соединяем узлы, нажимаем “ExecuteandOpenViews” на последнем добавленном. Появится окно в таблице, в которой появится новый столбец “n/p”.

На втором этапе извлекаем первые 3 символа, чтобы создать новый столбец, который будет представлять целевую переменную. Мы используем узел “Cell Splitter By Position (Manipulation / Column / Split & Combine)”. Соединяем с узлом “RowID”, двойным кликом мыши вызываем меню с настройками. Задаем следующие настройки: вырезаем 3 первых символа из колонки “n/p”. Создаются два новых столбца “target” (в нем будет либо “neg”, либо “pos”) и “etc” (окончание названия файла). Нажимаем кнопку “ОК” (рис. 9). Проверку срабатывания сделаем с помощью узла “InteractiveTable”. Столбец “target” теперь можно использовать для контролируемого процесса обучения.

Тянуть за собой лишние данные не целесообразно (столбцы “n/p” и “etc”), в этом нам поможет добавление узла “Column Filter (Manipulation / Column / Filter)”. Двойным кликом мыши вызываем настройки: из правого столбца переносим в левый те наименования, которые не являются важными для нас данными при анализе изображений — колонки “n/p”, “etc” (рис. 10). Проверку срабатывания сделаем с помощью узла “InteractiveTable”.

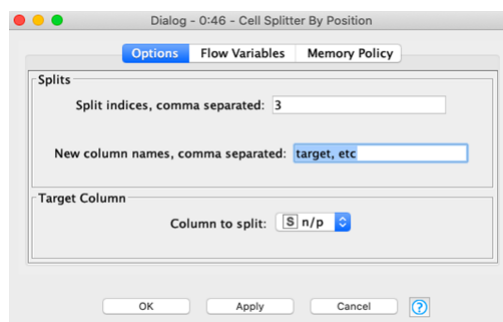


Рис. 9. Использование узла “Cell Splitter By Position”

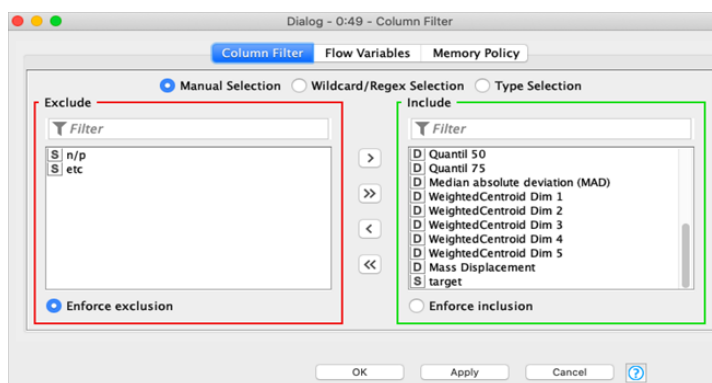


Рис. 10. Добавление узла “Column Filter”

Разделяем данные на обучающую и тестовую выборки для проверки корректности алгоритма, аналогично делалось и при реализации алгоритма на Python. Вставляем узел “Partitioning (Manipulation / Row / Transform)” в рабочий процесс. В качестве обучающей выборки выбираем 80 % фотографий с учётом пропорциональности положительных и отрицательных результатов по атрибуту “target” (рис. 11). Затем запускаем узел в работу.

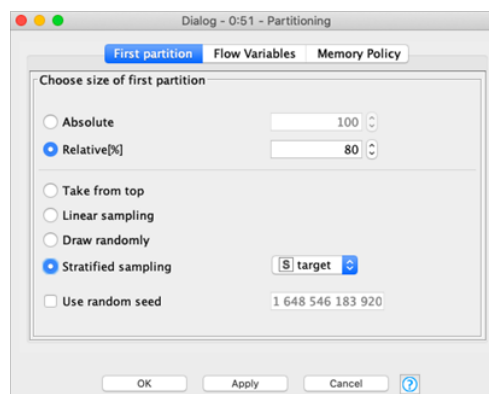


Рис. 11. Вставка узла “Partitioning”

Для обучения аналитической модели используем алгоритм дерева решений (могут быть использованы и другие методы). Добавляем в рабочий процесс узел “Decision Tree Learning (Analytics / Mining / Decision Tree)”.

Проверяем, чтобы в настройках столбец “ClassColumn” имел значение “target”. Остальные настройки не меняем. Визуализируем дерево функцией “ExecuteandOpenViews” (рис. 12).

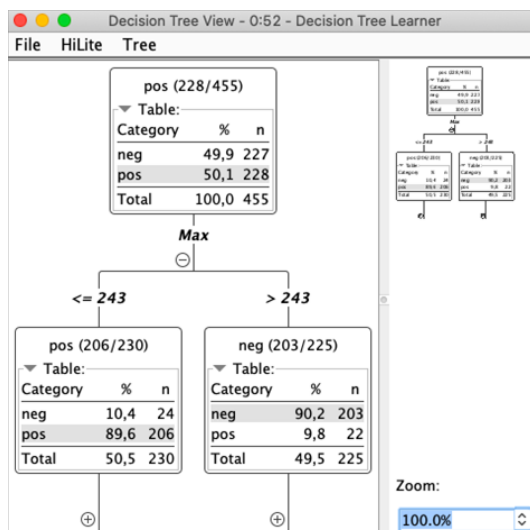


Рис. 12. Дерево функций

Для оценки работы модели применим классификатор к набору тестовой выборки, которая была сгенерирована в узле “Partitioning”. Мы вставляем узел “DecisionTreePredictor (Analytics / Mining / DecisionTree)”, чтобы получить прогноз модели на тестовой выборке. Инструмент принимает в качестве входных данных обученную модель и сгенерированные тестовые данные в “Partitioning”. В настройках узла “DecisionTreePredictor” задаём название столбцу, которое будет заполнено предсказанием модели в разделе “Change-predictioncolumnname” (рис. 13).

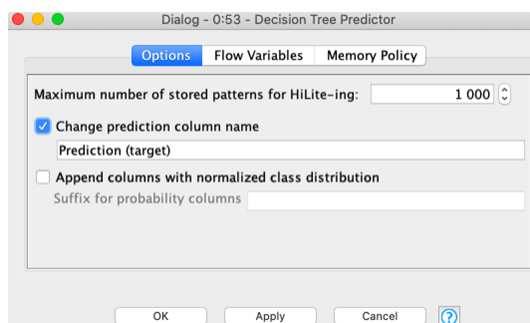
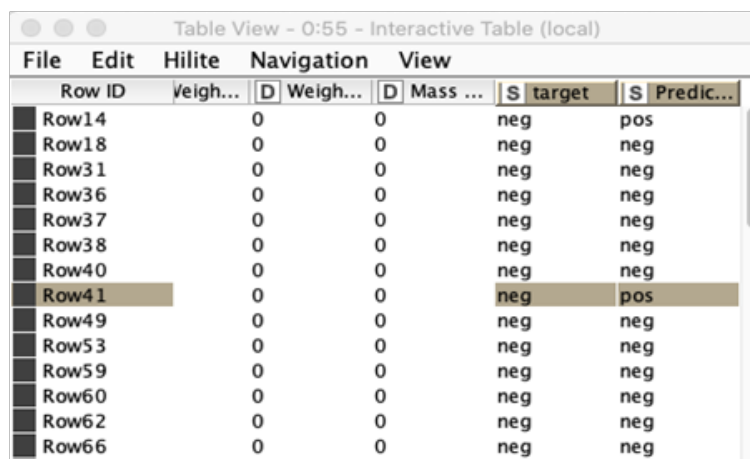


Рис. 13. Заполнение окон предсказаний

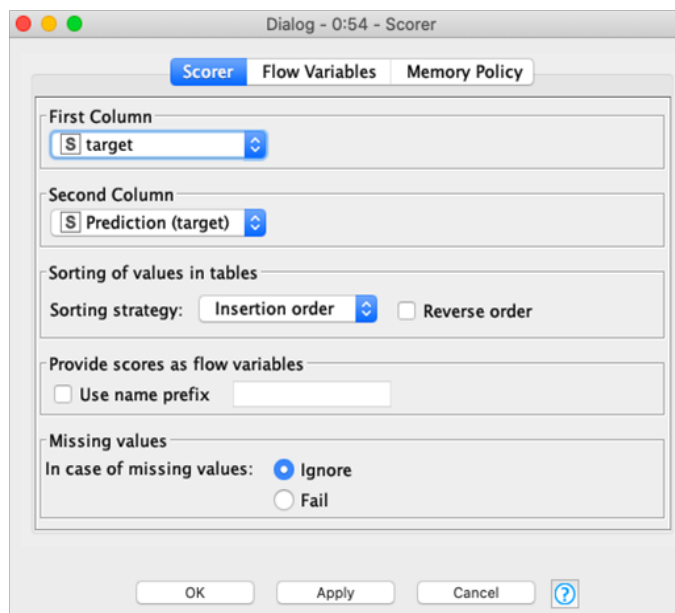
Мы используем узел “InteractiveTable” для визуализации этих прогнозов. Видим, что в большинстве случаев значения в строках для столбцов “target” и “Prediction (target)” совпадают (рис. 14).



Row ID	Veigh...	D Weigh...	D Mass ...	S target	S Predic...
Row14	0	0		neg	pos
Row18	0	0		neg	neg
Row31	0	0		neg	neg
Row36	0	0		neg	neg
Row37	0	0		neg	neg
Row38	0	0		neg	neg
Row40	0	0		neg	neg
Row41	0	0		neg	pos
Row49	0	0		neg	neg
Row53	0	0		neg	neg
Row59	0	0		neg	neg
Row60	0	0		neg	neg
Row62	0	0		neg	neg
Row66	0	0		neg	neg

Рис. 14. Сличение значений

Оценим точность работы модели с помощью узла “Scorer (Analytics / Mining / Scoring)”. Соединим узел “Scorer” узлом “DecisionTreeLearning”. В настройках узла “Scorer” выставить значения (рис. 15), которые будем сопоставлять: в нашей задаче это “target” и “Prediction (target)”.



Dialog - 0:54 - Scorer

Scorer Flow Variables Memory Policy

First Column
S target

Second Column
S Prediction (target)

Sorting of values in tables
Sorting strategy: Insertion order Reverse order

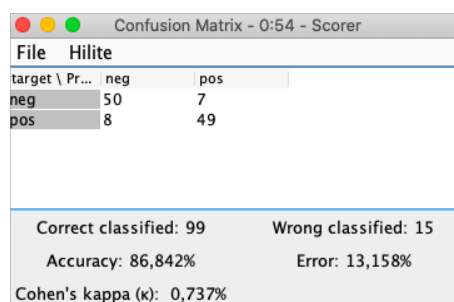
Provide scores as flow variables
Use name prefix

Missing values
In case of missing values: Ignore Fail

OK Apply Cancel ?

Рис. 15. Выставляем значения в настройках узла “Scorer”

Запускаем расчёты. Получаем матрицу корреляций (рис. 16).



File	Hilite	neg	pos
target \ Pr...			
neg		50	7
pos		8	49

Correct classified: 99	Wrong classified: 15
Accuracy: 86,842%	Error: 13,158%
Cohen's kappa (κ): 0,737%	

Рис. 16. Матрица корреляций

Выводы

В нашем быстро развивающемся мире резко вырос спрос на полимерные материалы. Трудно себе представить полноценную работу заводов, учебных заведений, электрической бытовой техники, которая нас окружает дома и на работе, без использования полимерных материалов.

Одним из самых распространённых изделий из полимерных материалов является пленка, применяемая, в основном, как упаковочный материал. В последние годы во многих странах помимо обычных методов упаковывания получили большое развитие следующие: быстрое замораживание, хранение в модифицированной газовой среде, стерилизация, асептические способы консервирования, микроволновый нагрев и др. Каждая из этих технологий непосредственно связана с выбором материала упаковки и предъявляет к нему специфические требования. Современные требования к гибким упаковочным материалам заставляют производителей искать пути и способы удовлетворения высокого спроса. Для повышения конкурентных методов производства плёночных материалов важно полностью исключить наличие дефектной продукции. Важно, чтобы на раннем этапе дефектная продукция не была допущена до заказчика. Однако, применения на линии только лишь наблюдательности специалиста по качеству недостаточно. Именно для этого необходимо развивать методы машинного зрения с минимальной реакцией на брак.

Оценка точности построенной модели говорит о том, что метрика Accuracy соответствует значению 0,8750, процент ошибок step - loss: 0,3357. Такой результат говорит о высокой точности модели. Выведем информацию о нейронной сети. Частота ошибок весьма мала: всего 13,158 %. Можно сделать вывод о том, что созданная модель может быть использована для дальнейшей классификации изображений и поиска дефектов.

Дальнейшие исследования будут направлены на повышение метрологических характеристик рассмотренного программного продукта, более быстрого и безошибочного метода определения дефектов плёночных образцов.

Список литературы

1. Основы метрологии: учеб. пособие / В.В. Окрепилов, Ю.А. Антохина, А.А. Оводенко, Е.Г. Семенова, В.Ш. Сулаберидзе, А.Г. Чуновкина. — СПб.: ГУАП, 2019. — 485 с.
2. Хюммель Кристи, Ширман Сэм. Виртуальные приборы и проектирование DSP-систем // Компоненты и технологии. — 2008. — № 80. — С. 38–42.
3. Ketelaete B., Wouters N., Kalfas I., Belleghem R.V. A fresh look at computer vision for industrial control. Quality Quandaries. — DOI: <https://doi.org/10.1080/08982112.2021.2001828>.
4. Blaga M., Dobrea D.M. Computer Vision Systems for Textiles Quality Control // Proceedings of the 6th International Conference on Management of Technological Changes. — 2009. — URL: https://www.researchgate.net/publication/236645983_Computer_Vision_Systems_for_Textiles_Quality_Control.

Статья поступила в редакцию: 09.09.2022 г.

Статья прошла рецензирование: 10.11.2022 г.

Статья принята в работу: 14.11.2022 г.