

Исследование течения, создаваемого скользящим разрядом, с помощью методов компьютерного зрения

И.А. Знаменская¹, И.А. Дорощенко², Н.Н. Сысоев³

Московский государственный университет имени М. В. Ломоносова

¹ ORCID: 0000-0001-6362-9496, znamen@phys.msu.ru

² ORCID: 0000-0002-0488-0020, doroshenko.igor@physics.msu.ru

³ ORCID: 0000-0002-1162-7680, nn.sysoev@physics.msu.ru

Аннотация

Проведено количественное исследование ударно-волнового течения, создаваемого в воздухе скользящим поверхностным разрядом длительностью менее микросекунды. Визуализация течения проводилась теневым методом, регистрация процесса велась со скоростью 124 000 кадров / с, экспозиция 1 мкс. Цель работы – исследование динамики возникающей при разряде цилиндрической взрывной волны и контактной поверхности. Каждый эксперимент позволял получить несколько сотен изображений нестационарного газодинамического процесса длительностью до 1 мс. Для определения положений разрывов обучена и применена сверточная нейронная сеть YOLOv8. Размечен набор данных, содержащий 984 разметки. Обученная модель по метрике mAP50 достигла 0.887, а mAP50-95 составила 0.557. С помощью модели автоматически измерялись вертикальные и горизонтальные размеры контактной поверхности. Она расширяется на временах до 0,4 – 0,8 мс до вертикального размера 5 – 11 мм. Измерялись x-t диаграммы и скорости цилиндрических взрывных волн. Показано, что при $t < 1$ мс основной причиной развития контактной поверхности является поток за фронтом взрывной волны. Показано, что применение компьютерного зрения позволяет значительно ускорить анализ высокоскоростной съемки течений и извлечение количественной информации.

Ключевые слова: скользящий поверхностный разряд, взрывная волна, контактная поверхность, визуализация течений, компьютерное зрение, сверточные нейронные сети.

1 Введение

1.1 Методы компьютерного зрения и глубокого обучения

Компьютерное зрение (англ. Computer Vision, CV) – область искусственного интеллекта (ИИ), изучающая методы извлечения данных из визуальных источников информации. Часто под компьютерным зрением понимаются задачи обнаружения, отслеживания и классификации объектов на цифровых изображениях. CV используется для решения широкого круга научных и бизнес задач: разработка ИИ для транспорта, анализ дорожного трафика и дорожного покрытия, автоматический анализ медицинских изображений (МРТ, рентген), обнаружение дефектов изделий на заводах, автоматическая сортировка мусора, распознавание текста, штрихкодов, различных объектов и др. Несмотря на то, что CV начало развиваться в 1960-е годы, наибольшее развитие оно получило после 2012 г., когда сверточная нейросеть AlexNet [1] с большим отрывом выиграла конкурс по распознаванию изображений ImageNet.

Методы CV часто применяются для решения научных задач при анализе экспериментальных изображений. Они позволяют улучшать качество изображений, находить определенные объекты на изображениях, выделять объекты, удалять шумы, применять

различные фильтры. CV используется для решения таких задач как: перевод в градации серого и в чёрно-белое изображение по заданному порогу, морфологические преобразования, вычисление градиентов, детектирование границ, контуров, углов, признаков, эквализация гистограммы, сопоставление шаблонов, сегментация изображений, вычитание фона и др. Методы глубокого машинного обучения позволяют значительно улучшить качество решения таких задач как: классификация изображений, распознавание объектов, сегментация, восстановление изображений, перенос стилей.

В данной работе приводятся результаты исследования газодинамического течения, возникающего при развитии импульсного разряда скользящего по поверхности диэлектрика. Возникающее течение визуализировалось теневым методом и регистрировалось с помощью высокоскоростной камеры. Анализ большого объема полученных цифровых изображений был автоматизирован и проводился с помощью модели глубокого обучения – сверточной нейронной сети. Решалась задача распознавания объектов – искомых структур течений и измерения их размеров.

1.2 Визуализация течений в газодинамическом эксперименте и объект исследования

В настоящее время наиболее распространенными методами визуализации течений являются теневая и шпирен методы [2-3], основанные на явлении преломления света. Согласно известному соотношению Гладстона-Дейла (1), показатель преломления среды n прямо пропорционален ее плотности ρ , что дает возможность визуализировать неоднородности плотности прозрачной среды (жидкости или газа):

$$n - 1 = G(\lambda)\rho, \quad (1)$$

где G – постоянная Гладстона-Дейла, λ – длина волны излучения.

На основе оптической схемы теневых или шпирен методов можно регистрировать эволюцию неоднородностей течений с помощью цифровых камер и другого оборудования. Изображения неоднородностей представляют собой участки с яркостью, отличной от фоновой. В частности, теневое изображение ударной волны состоит из чередующихся темной и светлой полос. Появление современных высокоскоростных цифровых камер позволило вести съемку течений со скоростями до 10 000 000 кадров в секунду и накапливать большие массивы визуальных данных. Соответственно, возникла потребность в автоматизации обработки полученных массивов изображений и видеозаписей. Для решения данной задачи применяются как алгоритмы классического компьютерного зрения [4], так и современные методы, основанные на сверточных нейронных сетях и глубоком обучении [5].

В настоящей работе объектом исследования являлся нестационарное ударно-волновое течение, создаваемое наносекундным поверхностным разрядом цилиндрической формы. Течение включает в себя цилиндрическую ударную (взрывную) волну и контактную поверхность (КП), распространяющиеся из области разряда. Течения такого типа возникают, например, при пробое импульсного оптического разряда, вызванного сфокусированным лазерным излучением [6] вблизи стенки. В работе [6] авторы провели экспериментальное исследование и численное моделирование оптического разряда вблизи твердой поверхности. Расстояние между фокусом (областью пробоя) и стенкой составляло 5 мм. Для моделирования течения численно решалась система уравнений Эйлера. Использовалась модель мгновенного энерговклада, который задавался в сфере радиусом 3 мм. Было показано, что динамика возникающей ударной волны сходна с динамикой взрывной волны от точечного взрыва. Также авторы показали, что контактная поверхность, разделяющая нагретый лазером газ и воздух за фронтом взрывной волны, становится нестабильной и развивается неустойчивость типа Рэлея – Тейлора. Схожие течения возникают на больших масштабах, например, при взрывах. В работе [7] проводилось численное моделирование взрыва мощностью 16 кт на высоте 580 м над землей. Энерговклад задавался в сферической области диаметром

2.4 м. Была смоделирована падающая и отраженная ударная волна, в том числе возникающий восходящий поток в виде грибовидного облака. Было показано, что за развитие грибовидного течения отвечают в основном 3 фактора: поток за фронтом ударной волны, вызванный перепадом давления, всплытие нагретой области (при $t < 10$ с его плотность примерно в 700 раз меньше плотности окружающего воздуха) и движение вихревых колец, за отраженной ударной волной.

При развитии сильноточных наносекундных поверхностных разрядов были зарегистрированы похожие конфигурации [8]. Визуализированы грибообразные вихревые образования от области повышенного энерговклада в плазменных листах, развивающиеся с нижней стенки разрядной камеры. В результате ручной обработки их изображений получено около 60 значений верхней координаты таких образований.

1.3 Применение методов компьютерного зрения и машинного обучения для решения задач газовой динамики и визуализации течений

Для обработки визуализации течений и извлечения количественной информации часто применяются такие методы классического компьютерного зрения как выделение границ с помощью различных алгоритмов [9-10], преобразование Хафа для поиска прямых линий, соответствующих, как правило, ударным волнам и другим типам газодинамических разрывов [4, 11]. Также используются алгоритмы кросс-корреляции и сопоставления шаблонов для отслеживания перемещения определенных структур течений [12]. На таких алгоритмах основан метод PIV (англ. Particle Image Velocimetry), заключающийся в засеке течения легкими частицами размером до 1 мкм и подсветке выбранных сечений течения лазерным листом. По смещению частиц между двумя последовательными кадрами вычисляется поле скоростей.

Методы машинного и глубокого обучения все чаще применяются при визуализации течений. Подробный обзор по данной теме опубликован в работе [5]. Сверточные нейронные сети Resnet, Unet и IVD-Net успешно применялись для распознавания вихрей [13]. Метод для заполнения пустых областей на PIV изображениях с помощью машинного обучения «с учителем» позволил достроить с высокой точностью поля скоростей на скрытых областях течения [14]. Для обучения модели на вход подавались синтетические PIV изображения, а на выход – соответствующие векторы скоростей. Различные методы машинного обучения использовались в работе [15] для извлечения количественной информации из шпирен-изображений плазменного канала в разреженном паре. Нейронная сеть для выявления различных типов вихревых следов за колеблющимся аэродинамическим профилем была разработана [16] и применена для классификации 3 типов следов: 2S, 2P + 2S, 2P + 4S. В работах [17-18] были предложены модели для извлечения признаков, соответствующих ударным волнам, из больших массивов данных течений, как экспериментальных, так и численных.

2 Экспериментальная установка и постановка эксперимента

Эксперименты по визуализации течений проводились в разрядной камере при давлении в диапазоне $p = 90 - 100$ Торр. Разрядная камера имеет прямоугольное сечение размером 24×48 мм². Верхняя и нижняя поверхности выполнены из диэлектрика, боковые стенки из кварцевого стекла для оптического доступа. В верхнюю и нижнюю стенки разрядной камеры встроены по паре электродов толщиной менее 0,1 мм, позволяющих создавать поверхностные разряды, расстояние между ними 30 мм. Разряд создавался одновременно как на нижней, так и на верхней стенках разрядной камеры. К электродам подавалось напряжение 25 кВ. Длительность тока разряда, скользящего по поверхности диэлектрика (плазменного листа) – до 300 нс, свечения плазмы разряда – до 1 мкс. В использовавшемся диапазоне давлений плазменный лист горит неравно-

мерно, с усилением энергоклада в 1-2 ярких каналах, как на верхней, так и на нижней поверхностях разрядной камеры.

Схема разрядной камеры, разряда и возникающего в результате импульсного энергоклада ударно-волнового течения приведена на рисунке 1. Также на рисунке 1 приведен интегральный кадр свечения разряда, полученный цифровым фотоаппаратом. Исследованные разрядные каналы представляли собой цилиндрическое образование низкотемпературной плазмы длиной 30 мм на поверхности диэлектрика [8].




Рисунок 1 – Схема эксперимента и интегральный кадр свечения наносекундного поверхностного разряда. 1 – электроды, 2 – кварцевые стекла, 3 – взрывная волна, 4 – поверхностный наносекундный разряд

Импульсный поверхностный разряд, изучаемый в данной задаче, можно рассматривать, с газодинамической точки зрения, как цилиндрически-симметричный взрыв. Взрыв можно определить как явление, вызванное выделением большого количества энергии в очень короткий промежуток времени в малом локализованном объеме [7]. Рассматриваемый разряд удовлетворяет этому определению, так как длительность нагрева газа не превышает нескольких десятков наносекунд, а объем импульсного энерговыделения ограничен цилиндром диаметром до 2 мм.

Была настроена оптическая схема для визуализации возникающего течения. Использовался теневой метод. Параллельный пучок света направлялся вдоль канала разряда. В начальный момент времени инициировался разряд. До разряда запускалась высокоскоростная камера, производящая съемку полученных теневым методом изображений со скоростью 124 000 кадров/с. Запуск разряда и включение камеры синхронизировались специально собранной электрической схемой.

Целью эксперимента было получение теневых кадров создаваемого разрядами течения – цилиндрических взрывных волн и КП, и измерение диаграмм их движения. Исследование динамики взрывных волн проводилось вручную (они присутствуют только на нескольких кадрах в связи с большой скоростью движения), тогда как для КП была разработана нейросеть для автоматического определения размера данной области на большом количестве кадров.

3 Данные

На рисунке 2 приведены примеры полученных теневых кадров при давлении в камере низкого давления $p = 93$ Торр и при скорости съемки 124 000 кадров/с. На временах до 55 мкс видны взрывные волны от двух каналов разряда - на верхней и на нижней стенках разрядной камеры. На последующих кадрах визуализировано развитие контактной поверхности, отделяющей зону нагретого разрядом газа от воздуха, движущегося за взрывной волной (КП).




Рисунок 2 – Примеры теневых кадров, полученных в экспериментах и используемых для обучения модели. 1 – взрывная волна; 2 – КП.

Для автоматического измерения размера КП был размечен набор данных для обучения сверточной нейронной сети на известной архитектуре YOLOv8 (англ. You Only Look Once) [19]. Размечались объекты одного класса “plume”, соответствующего КП. Набор данных включал в себя 492 изображения, содержащие 984 разметки. Размер изображений составлял 368×224 пикселей. Набор изображений разделялся на 3 группы: тренировочная выборка (429 изображений, 87%), валидационная выборка (40 изображений, 8%) и тестовая выборка (23 изображения, 5%).

Набор изображений включал в себя как оригинальные кадры, полученные высокоскоростной камерой, так и их аугментированные версии. Новые версии изображений создавались с помощью размытия (до 2,5 пикселей) и добавления случайного шума (до 5% пикселей). Размытие применялось, чтобы сделать модель более устойчивой к размытию изображения, связанному с протяженностью контактной поверхности вдоль направления зондирующего луча. Добавление шума применялось для того, чтобы модель была более устойчива к артефактам на изображениях.

4 Методы: сверточная нейронная сеть для детекции объектов

Для решения задачи распознавания КП использовалась сверточная нейросеть YOLOv8. Это самая современная модель на момент написания статьи, позволяющая получить оптимальный баланс между точностью распознавания объектов и скоростью. Модель показала наилучшие результаты на наборе данных COCO [20] по метрике mAP (англ. Mean Average Precision) с учетом скорости работы (мс / изображение). Схожая модель, обученная на другом наборе теневых кадров, содержащих различные структуры течений, применялась нами в работе [21]. Для улучшения качества распознавания применялось трансферное обучение. Использовались веса модели, предобученной на наборе данных COCO. Процесс обучения включал 95 эпох. Гиперпараметры модели были установлены по умолчанию и взяты из репозитория компании Ultralytics [22]. Основные гиперпараметры имели следующие значения: batch = 16, optimizer = SGD (англ. stochastic gradient descent), momentum = 0.937, weight_decay = 0.001.

Для оценки модели использовались следующие метрики: точность, полнота и F_1 – среднее гармоническое значение точности и полноты. Данные метрики определяются формулами (2-4) через значения: TP (англ. true positive – модель верно отнесла объект к рассматриваемому классу), TN (англ. true negative – модель верно определила, что

объект не относится к данному классу), FP (англ. false positive – модель неверно отнесла объект к данному классу), FN (англ. false negative – модель неверно определила, что объект не принадлежит к данному классу).

$$precision = \frac{TP}{TP + FP} \quad (2)$$

$$recall = \frac{TP}{TP + FN} \quad (3)$$

$$F_1 = 2 \cdot \frac{precision \cdot recall}{precision + recall} \quad (4)$$

Вычисление метрик модели обнаружения объектов основано на измерении перекрытия. Оно определяется метрикой «пересечение по объединению» (англ. IoU – Intersection over Union) – это отношение пересечения и объединения предсказанных участков и размеченных участков истинности на изображении. Задавалось пороговое значение IoU, определяющее насколько прогноз должен перекрываться с размеченной пользователем истинной областью, чтобы считаться верным. Если IoU оказывался больше порогового значения, то предсказание считалось верным (TP), а если меньше – то неверным (FP). Основной метрикой, которую мы использовали для оценки модели была усредненная точность mAP – это среднее значение средних значений точности всех классов в наборе данных. Средняя точность для каждого класса AP (англ. Average Precision) определяется как площадь под кривой precision-recall. Также вычислялись метрики mAP50 – это значение mAP, вычисленное при пороговом значении IoU = 0.5 и mAP50-95 – это метрика mAP, усредненная для диапазона значений IoU $\in [0,5 : 0,95]$. Кроме того, для оценки производительности модели использовалась матрица ошибок – таблица с четырьмя различными комбинациями сочетаний прогнозируемых и фактических значений.

В результате предсказания модели для каждого кадра были получены соответствующие координаты и размеры распознанных объектов. Так как в данной работе нас интересовал вертикальный размер КП, то высоты h полученных рамок сохранялись в массив вместе с соответствующими моментами времени t . Строилась зависимость $h(t)$. На те же оси накладывалась зависимость координаты взрывной волны y от времени t , измеренная вручную. В некоторых случаях проводилась аппроксимация полученных результатов с помощью полиномов различной степени, выбранной исходя из физических соображений.

5 Результаты

5.1 Метрики модели

Графики precision-confidence, recall-confidence, precision-recall и F1-confidence приведены на рисунке 3. На рисунке 4 представлены графики некоторых метрик модели, в том числе наиболее показательные графики: precision, recall, mAP50 и mAP50-95. После 95 шагов обучения метрика mAP50 достигла 0.887, а mAP50-95 составила 0.557. Для относительно небольшого набора данных, используемого для обучения, это достаточно хорошие показатели. Модель позволила распознавать интересующие нас структуры течений – КП с точностью до 1 мм. Скорость работы модели составила 13,9 кадров / с на сервере с характеристиками: Intel(R) Xeon(R) CPU @ 2.00GHz, GPU NVIDIA Tesla T4 16 Gb, 16 Gb RAM.




Рисунок 3 – Основные метрики модели

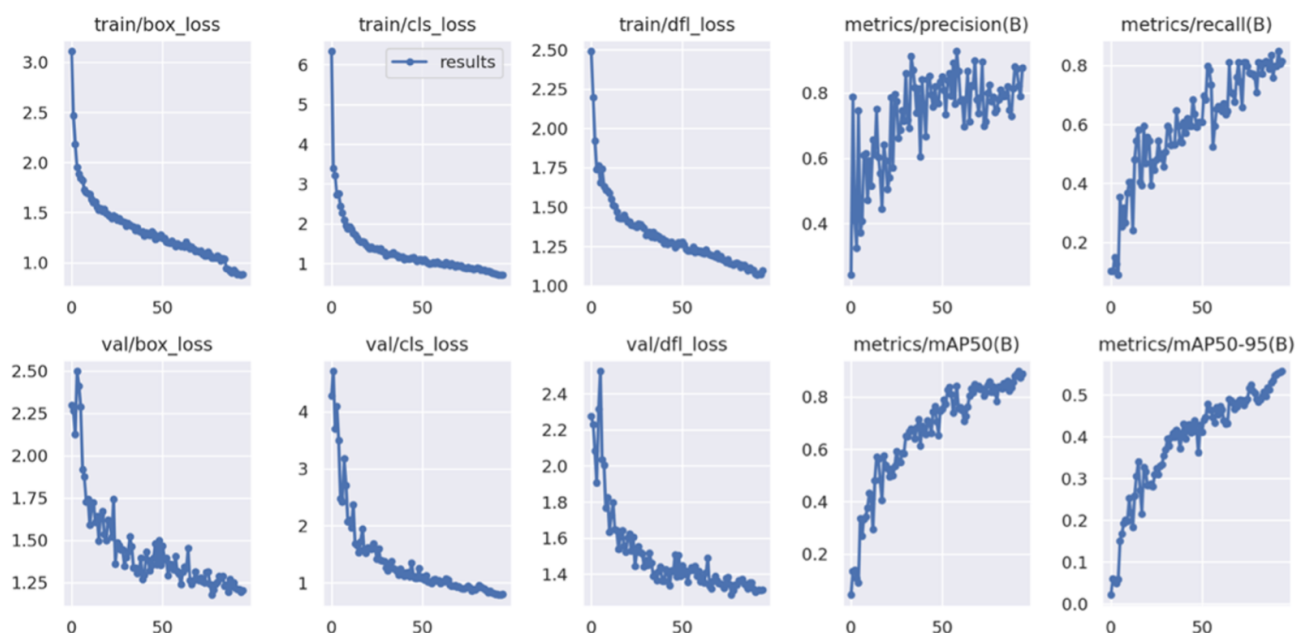


Рисунок 4 – Метрики модели

Матрица ошибок модели (рисунок 5) также показывает неплохие результаты. В 90% случаев модель верно предсказала положение КП. В 10% случаев модель ошибалась – предсказанная рамка для КП не соответствовала разметке на величину, большую пороговому значению IoU. Стоит отметить, что подавляющее большинство ошибок соответствует поздним стадиям течения при $t > 0,9$ мс, тогда как целью исследования было изучить течение на ранних стадиях на временах до 1 мс.




Рисунок 5 – Матрица ошибок модели

5.2 Распознавание структур течений с помощью сверточной нейронной сети

На рисунке 6 изображены примеры предсказаний модели для кадров на временном интервале от 93 мкс до 539 мкс. При этом вся видеозапись течения включала в себя несколько сотен кадров, на которых модель распознавала КП. Успешно были распознаны КП как на верхней, так и на нижней стенке разрядной камеры, в том числе на начальной стадии течения.




Рисунок 6 – Примеры распознавания КП обученной моделью

5.3 Анализ результатов распознавания: x-t диаграммы структур течений

Предсказанные моделью координаты и размеры областей, соответствующих КП использовались для автоматического построения зависимости размера КП от времени $h(t)$. Соответствующие зависимости для двух различных экспериментов приведены на рисунках 7-8. На каждом рисунке приведены графики как для нижней, так и верхней КП, создаваемыми импульсными разрядами на верхней и нижней стенках разрядной камеры. Также на графики нанесены x-t диаграммы возникающих цилиндрических взрывных волн. Эти точки были измерены вручную ввиду небольшого количества кадров, содержащих взрывные волны. На рисунке 7 отдельно вынесены x-t диаграммы движения взрывных волн в более крупном масштабе и нанесены соответствующие аппроксимации полиномом второй степени.

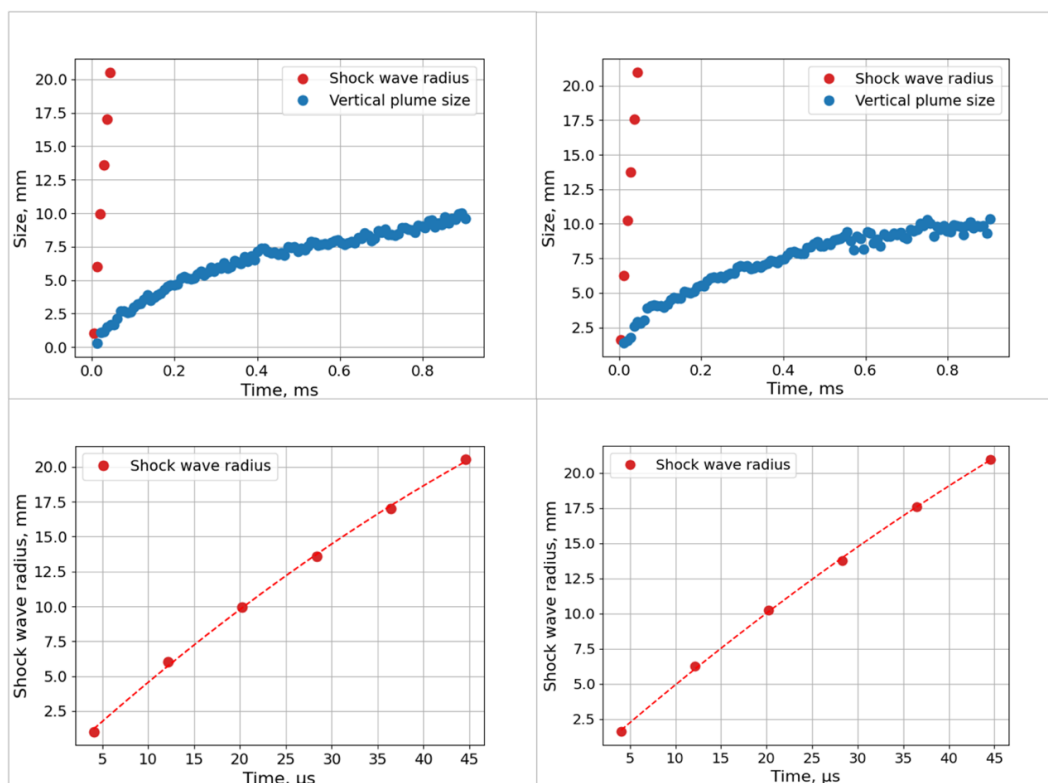


Рисунок 7 – x-t диаграммы структур течений – взрывных волн (измерены вручную) и КП (измерены с помощью модели) при давлении 92 Торр. Столбец слева соответствует верхним структурам течения, столбец справа – нижним. На графиках внизу к измеренной x-t диаграмме движения взрывной волны добавлена аппроксимация полиномом второй степени.

Эксперименты проводились при одинаковых условиях за исключением давления в разрядной камере. В эксперименте, соответствующем рисунку 7 давление составляло 92 Торр. Графики на рисунке 9 соответствуют эксперименту, проведенному при давлении 99 Торр. Анализ графиков показывает, что скорость взрывных волн, и размер, до которого расширяется КП зависит от давления. При изменении давления меняются параметры разряда и энерговклад, локализованный в зону плазменного цилиндра. Различия в скорости и величине нагрева газа приводят к формированию взрывных волн различной интенсивности. Основным фактором, влияющим на развитие КП, в данных экспериментах являются поток за фронтом взрывной волны. Оценки показали, что при анализе механизмов развития КП влиянием гравитации (всплытием) можно пренебречь. Анализ многочисленных экспериментальных данных показал, что диа-

граммы течений на верхней и на нижней стенках разрядной камеры практически не отличаются.

Различие диаграмм при схожих начальных условиях связано со случайными флуктуациями мощности разрядов, перераспределением энергии между верхним и нижним разрядами, неустойчивостью и значительной протяженностью контактной поверхности.

По полученным данным видно, что скорость взрывной волны мало меняется в области наблюдения и варьируется в различных экспериментах от 430 м/с до 480 м/с. КП расширяется до времени $t = 0,4 - 0,9$ мс до вертикального размера 5 – 11 мм. При этом финальный размер КП и скорость расширения тем больше, чем больше скорость соответствующей взрывной волны.




Рисунок 8 – x-t диаграммы структур течений – взрывных волн (измерены вручную) и контактных поверхностей (измерены с помощью модели) при давлении 99 Торр. Столбец слева соответствует верхним структурам течения, столбец справа – нижним.

По полученным x-t диаграммам можно, решив обратную задачу, численно рассчитать значения начального энерговклада – изменение внутренней энергии газа в области пробоя, а также оценить, какая доля электрической энергии была затрачена на нагрев газа и формирование возникающего течения.

На рисунке 9 приведены примеры автоматической обработки нескольких видеозаписей, полученных в диапазоне давлений от 92 до 99 Торр. С помощью разработанной модели измерялись как вертикальные, так и горизонтальные размеры контактной поверхности. Показано, что с ростом давления размер, до которого расширяется контактная поверхность по вертикали, уменьшается. При этом горизонтальные размеры слабо зависят от давления в рассматриваемом диапазоне.

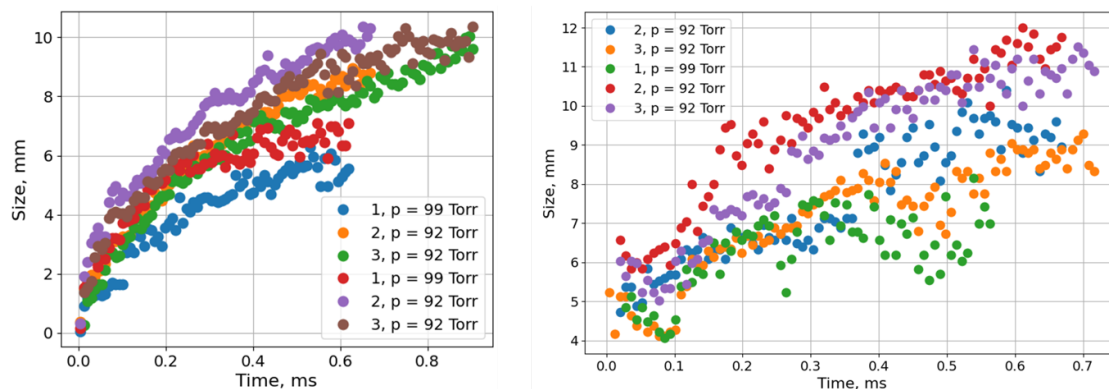


Рисунок 9. x-t диаграммы развития контактной поверхности. Слева – по вертикали. Справа – по горизонтали. Диапазон давлений 92-99 Торр.

6 Заключение

В данной работе было проведено исследование ударно-волнового течения, создаваемого в воздухе при давлениях 90-100 Торр скользящими поверхностными разрядами при напряжении, подаваемом к электродам, равным 25 кВ. Визуализация течений проводилась с помощью теневого метода при зондировании вдоль канала разряда. Изображения регистрировались высокоскоростной камерой. Скорость съемки составляла 124 000 кадров / с. Целью работы было измерение x - t диаграмм движения возникающей цилиндрической взрывной волны и КП на большом массиве полученных теневых кадров на временном интервале до 1 мс.

Для выявления возникающей после разряда области, ограниченной контактной поверхностью, была успешно обучена и применена сверточная нейронная сеть на архитектуре YOLOv8. Для обучения модели был размечен набор данных, который включал в себя 492 теневых изображения, содержащие 984 разметки. Набор изображений включал в себя как оригинальные кадры, полученные высокоскоростной камерой, так и их аугментированные версии, полученные с помощью размытия оригинальных изображений и добавления искусственного шума.

Процесс обучения включал 95 шагов, после которых метрика mAP50 достигла 0.887, а mAP50-95 составила 0.557. Матрица ошибок модели показала, что в 90% случаев модель верно предсказывала положение КП. В 10% случаев модель ошибалась – предсказанная рамка для КП не соответствовала разметке на величину, большую пороговому значению IoU. Большинство ошибок соответствовало поздним стадиям течения при $t > 0,9$ мс, при размытии и развитии неустойчивости контактной поверхности тогда как целью исследования было изучить течение до ее остановки - на временах до 1 мс.

Обученная модель компьютерного зрения позволила успешно построить зависимости вертикальных размеров КП от времени в экспериментах при различных давлениях. Измерялись также x - t диаграммы и скорости возникающих цилиндрических взрывных волн. Скорость взрывной волны практически постоянна в области наблюдения и варьируется в исследуемом диапазоне давлений от 430 м/с до 482 м/с. КП расширяется на временах до 0,4 – 0,8 мс до вертикального размера 5 – 11 мм. Показано, что для временных масштабов, рассматриваемых в данном исследовании, влиянием гравитации (всплытием нагретой разрядом области) можно, по-видимому, пренебречь, так как измеренные параметры течений внизу и вверху разрядной камеры идентичны. Таким образом, основной причиной развития КП является поток за фронтом взрывной волны.

Было показано, что применение современных методов компьютерного зрения позволяет значительно ускорить обработку визуализаций течений, полученных в газодинамическом эксперименте, и ускорить извлечение количественной информации, получение новых физических данных.

7 Благодарности

Исследование выполнено за счет гранта Российского научного фонда № 22-79-00054, <https://rscf.ru/project/22-79-00054/>.

Список литературы

1. Krizhevsky A., Sutskever I, Hinton G.E. ImageNet Classification with Deep Convolutional Neural Networks // Advances in Neural Information Processing Systems. 2012. Т. 25.
2. Settles G.S., Hargather M.J. Review of Recent Developments in Schlieren and Shadowgraph Techniques // Meas. Sci. Technol. 2017. Т. 28. № 4.
3. Rienitz J. Schlieren Experiment 300 Years Ago // Nature. 1975. Т. 254. № 5498. С. 293–295.
4. Automatic detection of oblique shocks and simple waves in schlieren images of two-dimensional supersonic steady flows / G. Cammi, A. Spinelli, F. Cozzi, A. Guardone // Measurement. 2021. Т 168.

5. Deep learning approaches in flow visualization / C. Liu, R. Jiang, D. Wei, C. Yang, Y. Li, F. Wang & Xiaoru Yuan // *Advances in Aerodynamics*. 2022. T 4. № 17.
6. Numerical and experimental study of a micro-blast wave generated by pulsed-laser beam focusing / Z. Jiang, K. Takayama, K.P.B. Moosad, O. Onodera, M. Sun // *Shock Waves*. 1998. T. 8. C. 337–349.
7. Kim J-H, Kim S. Simulation of Blast Wave Propagation and Mushroom Cloud formation by a Bomb Explosion // *AIAA SciTech Forum*, 9 - 13 January 2017, Grapevine, Texas, 55th AIAA Aerospace Sciences Meeting. 2017.
8. Shock wave interaction with a thermal layer produced by a plasma sheet actuator / E. Koroteeva, I. Znamenskaya, D. Orlov and N. Sysoev // *Journal of Physics D: Applied Physics*. 2017. T. 50.
9. Image Processing Techniques in Shockwave Detection and Modeling / S. Cui, Y. Wang, X. Qian, Z. Deng // *J. Signal Inform. Process*. 2013. T. 4. № 3B. C. 109–113.
10. Srisha Rao M.V., Jagadeesh G. Visualization and Image Processing of Compressible Flow in a Supersonic Gaseous Ejector // *J. Indian Inst. Sci*. 2013. T. 93. № 1. C. 57–66.
11. Znamenskaya I.A., Doroshchenko I.A. Edge Detection and Machine Learning for Automatic Flow Structures Detection and Tracking on Schlieren and Shadowgraph Images // *J. Flow Vis. Image Process*. 2021. T. 28 № 4. C. 1–26.
12. Gena A.W., Voelker C., Settles G.S. Qualitative and Quantitative Schlieren Optical Measurement of the Human Thermal Plume // *Indoor Air*. 2020. T. 30. № 4. C. 757–766.
13. Berenjkoub M., Chen G., Günther T. Vortex Boundary Identification Using Convolutional Neural Network // in *Proc. 2020 IEEE Visualization Conference (VIS)*, Salt Lake City, USA, October 25–30. 2020. C. 261–265.
14. Morimoto M., Fukami K., Fukagata K. Experimental Velocity Data Estimation for Imperfect Particle Images Using Machine Learning // *Phys. Fluids*. 2021. T. 33. № 8.
15. Machine learning methods for schlieren imaging of a plasma channel in tenuous atomic vapor / G. Bíró, M. Pocsai, I. F. Barna, G. G. Barnaföldi, J. T. Moody, G. Demeter // *Optics & Laser Technology*. 2023. T. 159.
16. Colvert B., Alsallman M., Kanso E. Classifying Vortex Wakes Using Neural Networks // *Bioinspir. Biomim*. 2018. T. 13. № 2.
17. A Deep Learning Approach to Identifying Shock Locations in Turbulent Combustion Tensor Fields / M. Monfort, T. Luciani, J. Komperda, B. Ziebart, F. Mashayek, G. E. Marai. M.: Springer, Cham, 2017. C. 375–392.
18. Speed detection in wind-Tunnels by processing schlieren images / M. D. Manshadi, H. Vahdat-Nejad, M. Kazemi-Esfah, M. Alavi, // *Int. J. Eng*. 2016. T. 29. № 7. C. 962–967.
19. Real-Time Flying Object Detection with YOLOv8 / D. Reis, J. Kupec, J. Hong, A. Daoudi // *arXiv:2305.09972*. 2023. C. 1–10.
20. Microsoft COCO: Common Objects in Context / T.-Y. Lin и др. // *arXiv:1405.0312*. 2014. C. 1–15.
21. Doroshchenko I.A. Analysis of the experimental flow shadowgraph images by computer vision methods // *Numerical Methods and Programming (Vychislitel'nye Metody i Programirovanie)*. 2023. T. 24. № 2. C. 231–242.
22. YOLOv8 [Электронный ресурс] / Ultralytics // GitHub. 2023. URL: <https://github.com/ultralytics/ultralytics> (дата обращения 29.06.2023).

Computer Vision Study of the Flow Generated by a Sliding Discharge

I.A. Znamenskaya¹, I.A. Doroshchenko², N.N. Sysoev³

Lomonosov Moscow State University

¹ ORCID: 0000-0001-6362-9496, znamen@phys.msu.ru

² ORCID: 0000-0002-0488-0020, doroshenko.igor@physics.msu.ru

³ ORCID: 0000-0002-1162-7680, nn.sysoev@physics.msu.ru

Abstract

A quantitative study has been made of the flow with shock waves generated in air by a sliding surface discharge lasting less than one microsecond. The high-speed flow was visualized using the shadowgraph method, the process was recorded at a rate of 124 000 frames/s, the exposure time was 1 μ s. The aim of this work is to study the dynamics of the two discontinuities: the cylindrical shock wave and the contact surface generated by the discharge. Each experiment allowed several hundred images to be taken of a short-lived gas-dynamic process lasting up to 1 ms. A YOLOv8 convolutional neural network was trained and used to determine the positions of the discontinuities. A data set of 984 markups was labeled. The model on the mAP50 metric achieved 0.887 and the mAP50-95 was 0.557. The model was used to automatically measure the vertical dimensions of the contact discontinuity. It expands at times up to 0.4 - 0.8 ms to a vertical size of 5 - 11 mm. The x-t plots and the velocities of the cylindrical shock waves were measured. It is shown that up to 1 ms after the discharge, the flow development is due to the blast wind motion behind the shock wave. It is shown that the use of computer vision can significantly speed up the analysis of high-speed flow visualizations and the extraction of quantitative information.

Keywords: sliding surface discharge, blast wave, contact discontinuity, flow visualization, computer vision, convolutional neural networks.

References

1. Krizhevsky A., Sutskever I., Hinton G.E. ImageNet Classification with Deep Convolutional Neural Networks // Advances in Neural Information Processing Systems. 2012. T. 25.
2. Settles G.S., Hargather M.J. Review of Recent Developments in Schlieren and Shadowgraph Techniques // Meas. Sci. Technol. 2017. T. 28. № 4.
3. Rienitz J. Schlieren Experiment 300 Years Ago // Nature. 1975. T. 254. № 5498. C. 293–295.
4. Automatic detection of oblique shocks and simple waves in schlieren images of two-dimensional supersonic steady flows / G. Cammi, A. Spinelli, F. Cozzi, A. Guardone // Measurement. 2021. T 168.
5. Deep learning approaches in flow visualization / C. Liu, R. Jiang, D. Wei, C. Yang, Y. Li, F. Wang & Xiaoru Yuan // Advances in Aerodynamics. 2022. T 4. № 17.
6. Numerical and experimental study of a micro-blast wave generated by pulsed-laser beam focusing / Z. Jiang, K. Takayama, K.P.B. Moosad, O. Onodera, M. Sun // Shock Waves. 1998. T. 8. C. 337–349.
7. Kim J-H, Kim S. Simulation of Blast Wave Propagation and Mushroom Cloud formation by a Bomb Explosion // AIAA SciTech Forum, 9 - 13 January 2017, Grapevine, Texas, 55th AIAA Aerospace Sciences Meeting. 2017.

8. Shock wave interaction with a thermal layer produced by a plasma sheet actuator / E. Koroteeva, I. Znamenskaya, D. Orlov and N. Sysoev // *Journal of Physics D: Applied Physics*. 2017. T. 50.
9. Image Processing Techniques in Shockwave Detection and Modeling / S. Cui, Y. Wang, X. Qian, Z. Deng // *J. Signal Inform. Process.* 2013. T. 4. № 3B. C. 109–113.
10. Srisha Rao M.V., Jagadeesh G. Visualization and Image Processing of Compressible Flow in a Supersonic Gaseous Ejector // *J. Indian Inst. Sci.* 2013. T. 93. № 1. C. 57–66.
11. Znamenskaya I.A., Doroshchenko I.A. Edge Detection and Machine Learning for Automatic Flow Structures Detection and Tracking on Schlieren and Shadowgraph Images // *J. Flow Vis. Image Process.* 2021. T. 28 № 4. C. 1–26.
12. Gena A.W., Voelker C., Settles G.S. Qualitative and Quantitative Schlieren Optical Measurement of the Human Thermal Plume // *Indoor Air*. 2020. T. 30. № 4. C. 757–766.
13. Berenjkoub M., Chen G., Günther T. Vortex Boundary Identification Using Convolutional Neural Network // in *Proc. 2020 IEEE Visualization Conference (VIS)*, Salt Lake City, USA, October 25–30. 2020. C. 261–265.
14. Morimoto M., Fukami K., Fukagata K. Experimental Velocity Data Estimation for Imperfect Particle Images Using Machine Learning // *Phys. Fluids*. 2021. T. 33. № 8.
15. Machine learning methods for schlieren imaging of a plasma channel in tenuous atomic vapor / G. Bíró, M. Pocsai, I. F. Barna, G. G. Barnaföldi, J. T. Moody, G. Demeter // *Optics & Laser Technology*. 2023. T. 159.
16. Colvert B., Alsallman M., Kanso E. Classifying Vortex Wakes Using Neural Networks // *Bioinspir. Biomim.* 2018. T. 13. № 2.
17. A Deep Learning Approach to Identifying Shock Locations in Turbulent Combustion Tensor Fields / M. Monfort, T. Luciani, J. Komperda, B. Ziebart, F. Mashayek, G. E. Marai. M.: Springer, Cham, 2017. C. 375–392.
18. Speed detection in wind-Tunnels by processing schlieren images / M. D. Manshadi, H. Vahdat-Nejad, M. Kazemi-Esfah, M. Alavi, // *Int. J. Eng.* 2016. T. 29. № 7. C. 962–967.
19. Real-Time Flying Object Detection with YOLOv8 / D. Reis, J. Kupec, J. Hong, A. Daoudi // *arXiv:2305.09972*. 2023. C. 1–10.
20. Microsoft COCO: Common Objects in Context / T.-Y. Lin и др. // *arXiv:1405.0312*. 2014. C. 1–15.
21. Doroshchenko I.A. Analysis of the experimental flow shadowgraph images by computer vision methods // *Numerical Methods and Programming (Vychislitel'nye Metody i Programirovanie)*. 2023. T. 24. № 2. C. 231–242.
22. YOLOv8 [Электронный ресурс] / Ultralytics // GitHub. 2023. URL: <https://github.com/ultralytics/ultralytics> (дата обращения 29.06.2023).