

## **Разработка автоматизированных средств фиксации моментов воспламенения топлива и срыва пламени методами визуального анализа**

© А.В. Янук, А.Н. Тарасенко, Е.Н. Панов

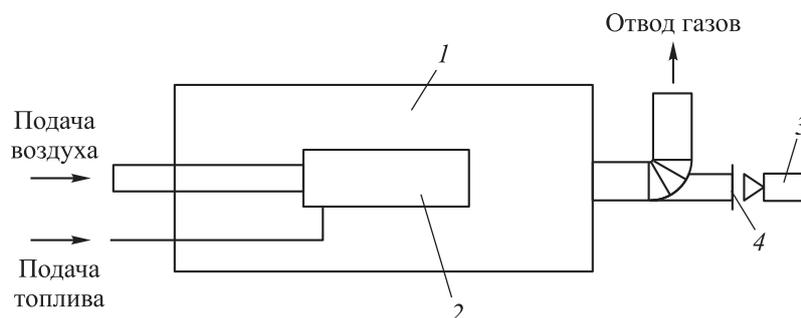
Центральный институт авиационного моторостроения имени П.И. Баранова,  
Москва, 111116, Российская Федерация

*Апробированы архитектуры нейронных сетей ResNet18, ResNet50, DenseNet121, MobileNetV1, MobileNetV2, MobileNetV3 и их вариации применительно к задаче классификации изображений, получаемых в ходе эксперимента на этапе ввода двигателя в эксплуатацию. Описаны изменения, которым подвергались стандартные реализации рассматриваемых архитектур нейронных сетей, и использованная методика обучения. Применено несколько способов аугментации данных для расширения и балансировки выборки: изменение пространственной ориентации изображений поворотом на 90, 180, 270 град, зеркальное отражение изображения относительно вертикальной оси, изменение цветового тона изображения. Вычислены метрики accuracy, precision и recall для каждого класса изображений; замерено время выполнения одного прохода и количество параметров каждой модели. Составлен набор моделей, удовлетворяющих требованиям по точности классификации, вычислительным и временным затратам на классификацию.*

**Ключевые слова:** глубокое обучение, классификация изображений, воспламенение топлива

**Введение.** Одним из этапов введения авиационного двигателя в эксплуатацию является его сертификация, содержащая экспериментальное установление соответствия двигателя критериям НЛГ-33 [1]. Данные правила регламентируют ряд испытаний, которые должны быть проведены для подтверждения летной годности двигателя. К таковым испытаниям относится и запуск двигателя в условиях различных высот.

Характеристики запуска представляют в виде области условий, в пределах которой может быть осуществлен повторный запуск после произошедшего по тем или иным причинам срыва пламени. Наибольшее влияние на возможность такого запуска оказывают давление и температура воздуха. Для определения осуществимости высотного запуска проводится серия испытаний с попыткой воспламенения при различных полетных условиях с постоянными расходом, температурой и давлением воздуха на входе в камеру сгорания (КС) газотурбинного двигателя (ГТД). Граница бедного срыва определяется путем увеличения расхода топлива и повторения эксперимента. Схема испытательного стенда изображена на рис. 1.



**Рис. 1.** Схема испытательного стенда:

1 — термобарокамера; 2 — объект; 3 — видеокамера; 4 — смотровое окно

Для проведения эксперимента в термобарокамеру подаются топливо и воздух при требуемых температуре и давлении. После установления режима течения воздуха через КС начинается подача топлива и включается свеча зажигания. Результат опыта фиксируется видеокамерой через смотровое окно и с помощью датчиков.

При неудачном проведении эксперимента требуются дополнительные затраты времени и расходных материалов для выполнения нового испытания. В статье [2] описана методика оценки возможности высотного запуска при низких температурах без воссоздания условий с низкими температурами в эксперименте, что позволяет сократить число испытаний, в которых не удалось достичь воспламенения топлива, и избежать дорогостоящих затрат на понижение температуры воздуха. В ряде случаев проблему выявления неудачных испытаний может решить поточная обработка информации, полученной экспериментально, с целью корректировки хода испытания. Регистрирование момента воспламенения по таким измеряемым величинам, как температура и давление на выходе, обладает определенной инерционностью, что влечет неточность определения момента воспламенения.

В работе [3] регистрация момента розжига топливовоздушной смеси осуществлялась оптико-электронным методом. Оптическое излучение, испускаемое объектом, попадает в фотоприемное устройство, преобразуется в электрический сигнал, который, пройдя усиление и фильтрацию, оцифровывается. К анализу предлагается цифровой сигнал с его частотой и амплитудой.

В статье [4] представлена методика определения режима работы ГТД по показаниям датчиков с некоторой временной задержкой. Для данной задачи классификации применялась *полносвязная нейронная сеть* с одним скрытым слоем. Были экспериментально определены оптимальные ширина временного окна и размер скрытого слоя.

В случае обработки визуальной информации в условиях ограниченных вычислительных ресурсов могут быть применены *сверточные нейронные сети*, удовлетворяющие техническим требованиям

стендового оборудования. Такие архитектуры нейронных сетей получают путем архитектурного поиска подобно тому, как это было проведено в работах [5–7]. Иным подходом является масштабирование стандартных моделей.

Задачей данной работы является реализация второго подхода: изменение архитектур моделей ResNet18 (R18), ResNet50 (R50) [8], DenseNet121 (DN) [9], MobileNetV1 (MV1) [10], MobileNetV2 (MV2) [11], MobileNetV3 (MV3) [5] путем уменьшения количества фильтров в слое и количества самих слоев в модели и использование масштабированных архитектур в составе системы определения моментов воспламенения топлива и затухания пламени.

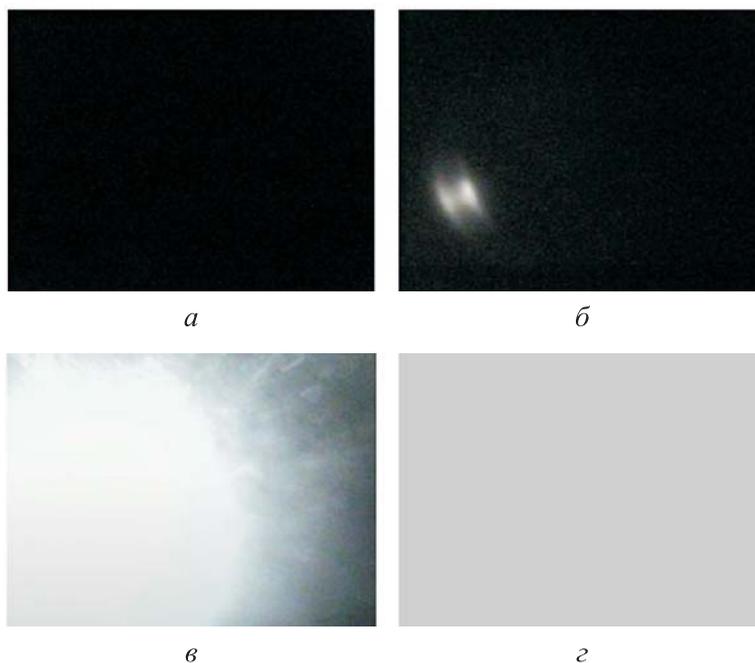
Цель данного исследования — проанализировать средства определения наличия или отсутствия воспламенения топлива в камерах сгорания в условиях высотного запуска с помощью методов визуального анализа.

**Набор данных для обучения и валидации.** В рассматриваемой работе для обучения классификатора изображений использовался набор полученных экспериментально данных, состоящий из изображений и соответствующих этим данным меток класса. Изображения представляют собой снимки экрана компьютера, на которых отображаются показания датчиков, используемых для измерений в проводимом эксперименте, и фотография выхода испытываемой модели КС. Изображения подразделяются на четыре класса: «Пламени нет», «Пламя есть», «Вспышка», «Брак». К классу «Вспышка» отнесены изображения, на которых имеется фотография выхода КС и на ней наблюдается детонация топлива; к классу «Брак» — изображения, на которых по техническим причинам отсутствует фотография выхода КС.

Изображения классов «Пламя есть» и «Вспышка» различаются размерами пламени и стабильностью наблюдаемого явления: детонация топлива, как правило, не протекает достаточно долго для попадания в несколько подряд сделанных кадров. Опираясь на указанные критерии, инженер-испытатель и принимает решение об отнесении изображения к тому или иному классу. На рис. 2 представлены урезанные до области, содержащей фотографию выхода КС, образцы изображений выделенных классов, образующих систему полных событий.

Количество изображений каждого класса в исходных обучающей и тестовой выборках приведено в табл. 1.

Исходный набор данных мал и несбалансирован, для чего потребовалось расширить выборку. Были применены такие методы аугментации, как изменение пространственной ориентации и смещение цветового тона изображения. Так, изменение пространственной ориентации заключалось в повороте изображения на 90°, 180°, 270° и зеркальном отражении относительно вертикальной оси.



**Рис. 2.** Образцы изображений классов «Пламени нет» (а), «Пламя есть» (б), «Вспышка» (в), «Брак» (г)

Таблица 1

**Размер исходного набора данных по классам изображений**

Класс изображения	Обучающая выборка	Тестовая выборка
Пламени нет	515	221
Пламя есть	46	20
Вспышка	13	6
Брак	16	7

Таблица 2

**Размер расширенного набора данных по классам изображений**

Класс изображения	Обучающая выборка	Тестовая выборка
Пламени нет	1030	221
Пламя есть	4784	260
Вспышка	1352	78
Брак	1664	91

Для балансировки классов к изображениям разных классов применялось разное количество преобразований: в обучающей выборке к классам «Пламя есть», «Вспышка» и «Брак» использовались все виды преобразований, а к классу «Пламени нет» — изменение тона только в одном, случайно выбранном варианте; в тестовой выборке

к классам «Пламя есть», «Вспышка» и «Брак» — только сдвиг тона, а к классу «Пламени нет» каких-либо преобразований не применялось. В табл. 2 приведено количество изображений каждого класса в расширенных обучающей и тестовой выборках.

#### **Используемые архитектуры нейронных сетей и их обучение.**

Несколько вариаций стандартных архитектур было рассмотрено, причем в каждой из них изменялись гиперпараметры, определяющие количество слоев в блоках нейронной сети и/или количество фильтров в слое сети.

Обучение моделей осуществлялось на протяжении 20 эпох с размером пакета обучения из 50 образцов. Для корректировки весов использовался алгоритм Adam [12]. В качестве функции ошибок была выбрана категориальная кроссэнтропия [13]. В процессе обучения моделей на обучающей и тестовой выборках отслеживались метрики Асс (ассигасу), которая вычисляется как доля правильно классифицированных экземпляров ко всем классифицированным экземплярам; Пре (precision) — вычисляется для каждого класса отдельно как отношение количества экземпляров, относящихся к данному классу и отнесенных к этому классу, к общему количеству экземпляров, отнесенных к данному классу; Рс (recall) — вычисляется как количество экземпляров, относящихся к данному классу и отнесенных к этому классу, к общему количеству экземпляров, относящихся к данному классу.

В одном из вариантов архитектуры ResNet ResNet18 остаточный блок состоит из двух сверточных слоев (Conv), за каждым из них следует операция пакетной нормализации (BatchNormalization) [14] и функция активации ReLU [15]. К выходу второго сверточного блока Conv-BatchNorm-ReLU прибавляются данные, подаваемые на вход остаточному блоку, после чего еще раз применяется функция активации ReLU.

Остаточный блок архитектуры ResNet50 состоит из трех сверточных слоев, размеры сверточных ядер которых равны, соответственно,  $(1 \times 1)$ ,  $(3 \times 3)$  и  $(1 \times 1)$ . В последнем слое увеличение количества фильтров определяется гиперпараметром расширения (*expansion*). За каждым сверточным слоем следует операция пакетной нормализации и функция активации ReLU, и тогда выход третьего подблока увеличивается на значение входных данных остаточного блока, после чего применяется функция активации ReLU.

Вариации архитектур ResNet18 и ResNet50 были получены путем изменения гиперпараметра масштабирования (SF — scale factor), определяющего, во сколько раз уменьшается число фильтров в каждом слое относительно исходной модели. Исходное количество фильтров взято согласно оригинальной статье [8]. Схемы блоков сетей ResNet18, ResNet50, DenseNet121 представлены на рис. 3.

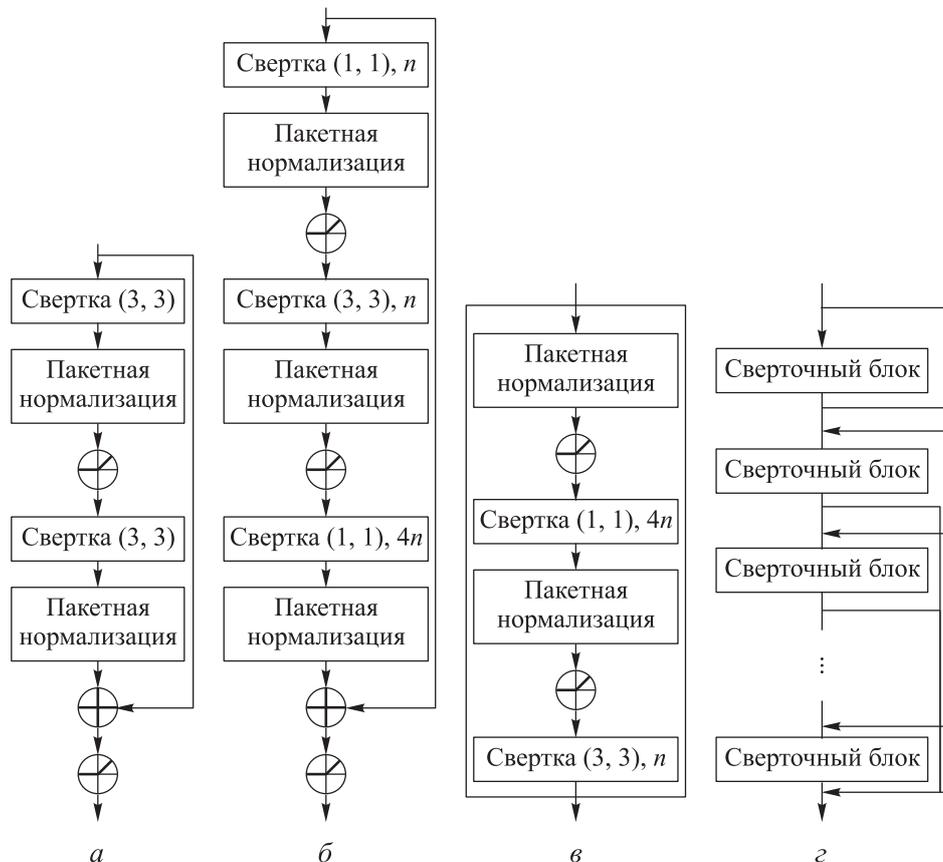
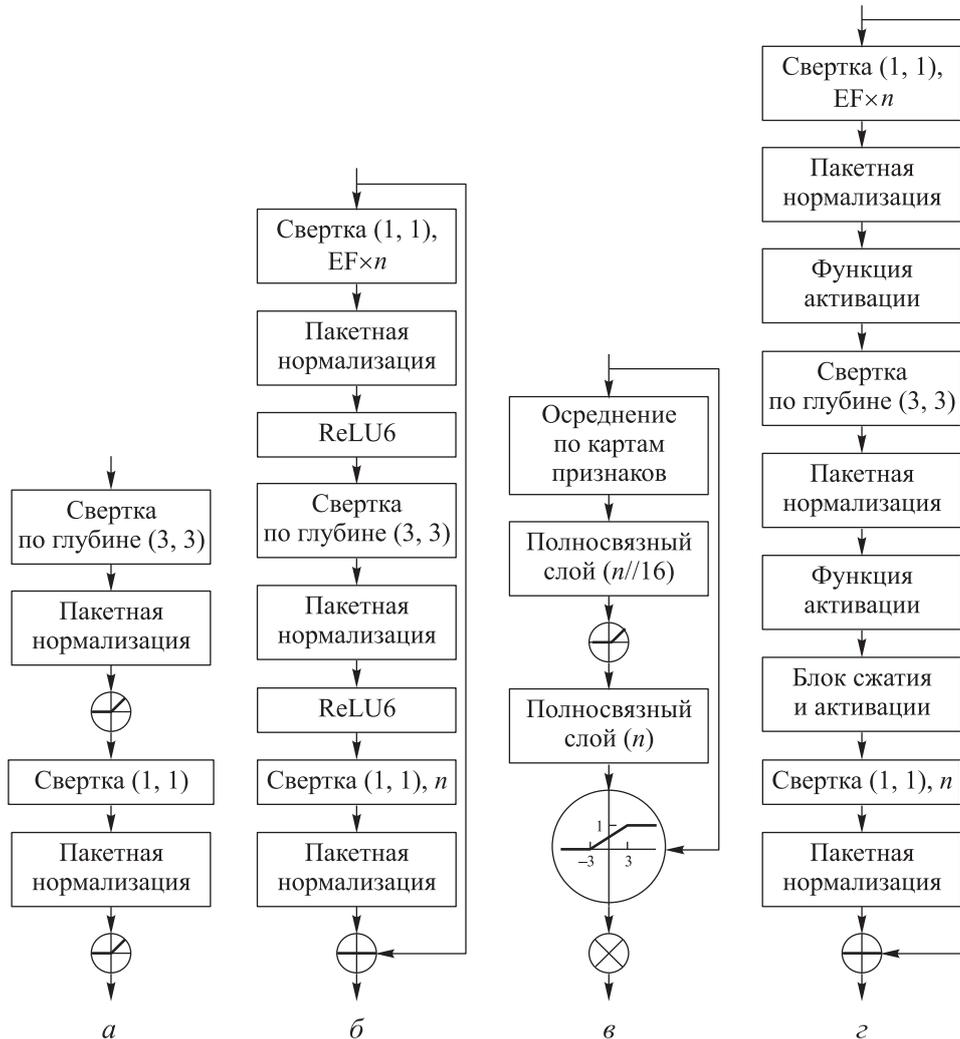


Рис. 3. Схемы блоков сетей:

*a* — остаточный блок сети ResNet18; *б* — остаточный блок сети ResNet50; *в* — сверточный блок сети DenseNet121; *г* — плотный блок сети DenseNet121

Для эксперимента с DenseNet была использована в качестве исходной архитектуры модель DenseNet121 с ее количеством блоков и их расположением. Относительно исходной модели изменялось количество сверточных блоков в плотных блоках и количество фильтров в каждом сверточном слое путем изменения значения гиперпараметра скорости роста ( $n$  — growth rate). Гиперпараметр сжатия (CF — compression factor), определяющий уменьшение размера карт признаков в переходном слое, был взят равным 0,5 и оставался неизменным во всех моделях. Блоки нейронных сетей MobileNetV1, MobileNetV2, MobileNetV3 изображены на рис. 4.

В архитектуре MobileNetV1 количество фильтров в полном сверточном слое определяется изначально заданным числом и гиперпараметром ширины (WM — width multiplier), который определяет, на сколько исходное число фильтров будет сокращено. Через гиперпараметр разрешения (RM — resolution multiplier) изменяется размер карт признаков. Количество разделяемых сверток по глубине и их взаимное расположение описано в оригинальной статье [10].



**Рис. 4.** Блоки нейронных сетей: блок MobileNetV1 (а), инвертированный остаточный блок сети MobileNetV2 (б), механизм сжатия и активации (в) и инвертированный остаточный блок сети MobileNetV3 (г)

Рассмотрим вариации модели MobileNetV1 со стандартными значениями WM (1; 0,75; 0,5; 0,25) и RM (1; 0,75; 0,5).

Сеть MobileNetV2 содержит гиперпараметр расширения (EF — expansion factor), определяющий увеличение количества фильтров в соответствующем слое относительно поступившего на вход числа карт признаков.

Кроме гиперпараметра расширения изменялся гиперпараметр масштабирования (SF — scale factor), определяющий, во сколько раз будет уменьшено число фильтров в каждом слое относительно исходной реализации MobileNetV2.

Инвертированный остаточный блок сети MobileNetV3 основан на блоке сети MobileNetV2. По сравнению с инвертированным остаточным блоком сети MobileNetV2 в блок сети MobileNetV3 внесен механизм сжатия и активации (Squeeze and Excitation) [6], действующий как механизм внимания для карт признаков. В MobileNetV3 в некоторых блоках также используется функция активации *h-swish* вместо ReLU и *h-sigmoid* вместо сигмоидальной функции.

**Анализ результатов исследования.** Было рассмотрено 55 моделей, различающихся как количеством параметров, так и количеством необходимых вычислительных операций. Наиболее важной характеристикой обученной модели, определяющей возможность использования нейронной сети для решения поставленной задачи, является точность ее предсказаний. Поэтому выбор модели, подходящей для данной задачи, начинается с анализа ее точности.

На обучающем наборе все модели достигли абсолютной точности по всем измеряемым метрикам. На рис. 5 и 6 приведены тепловые карты со значениями метрик  $P_{re}$  и  $R_{c}$  для каждого класса в конце обучения на тестовой выборке.

В результате анализа точности предсказания обученных моделей из пространства выбора оптимальных архитектур исключаются модели со значениями метрики Acc, меньшей или равной 0,98, и значениями метрик  $P_{re}$  и  $R_{c}$  для класса «Пламя есть», меньшими или равными 0,98.

Причинами низкой обобщающей способности могут быть как слишком большое, так и недостаточное количество параметров модели нейронной сети. Так, модели с большим количеством параметров могут выражать более сложные зависимости, что позволяет применять их для решения более сложных задач, чем модели меньшего размера. Однако увеличение количества параметров несет риск переобучения модели, усложняет процесс оптимизации параметров, может сделать проблематичным или даже невозможным обучение и применение модели на оборудовании с ограниченными вычислительными ресурсами.

При выборе подходящих для поставленной задачи моделей отслеживалось определенное число параметров. На рис. 7 представлено количество параметров в каждой из рассмотренных архитектур.

Из рассмотренных моделей наименьший размер имеет вариация архитектуры MobileNetV3 с количеством фильтров в каждом сверточном слое, уменьшенном в 8 раз относительно исходной модели. Количество параметров архитектуры MobileNetV1 со значением гиперпараметра ширины 0,0625 незначительно превышает количество параметров сети MobileNetV3.

	val Acc	val Pte Брак	val Pte Вспышка	val Pte Пламени нет	val Pte Пламя есть	val Rc Брак	val Rc Вспышка	val Rc Пламени нет	val Rc Пламя есть
MV1_WM=0.5_RM=0.5	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
MV1_WM=0.5_RM=0.75	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
MV1_WM=0.75_RM=0.5	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
MV1_WM=0.75_RM=0.75	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
MV1_WM=1_RM=0.5	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
MV1_WM=1_RM=1	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
MV2_EF=2_SF=1	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
MV2_EF=4_SF=2	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
MV2_EF=4_SF=2	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
MV2_EF=6_SF=1	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
MV2_EF=6_SF=4	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
MV2_EF=6_SF=8	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
MV3_VR=small_SF=1	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
ResNet18_SF=4	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
ResNet18_SF=4	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
ResNet18_SF=2	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
ResNet18_SF=3	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
ResNet50_SF=4	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
ResNet50_SF=16	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
ResNet50_SF=3	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
MV1_WM=1_RM=0.75	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
MV3_VR=large_SF=1	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
ResNet18_SF=16	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
MV1_WM=0.5_RM=1	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00	1.00
MV2_EF=4_SF=4	1.00	1.00	1.00	1.00	1.00	1.00	0.99	1.00	1.00
MV1_WM=0.25_RM=0.75	1.00	1.00	1.00	1.00	0.99	1.00	1.00	0.99	1.00
MV2_EF=2_SF=4	1.00	1.00	1.00	1.00	0.99	1.00	1.00	0.99	1.00
MV1_WM=0.25_RM=0.5	1.00	1.00	1.00	0.99	1.00	1.00	1.00	1.00	0.99
MV1_WM=0.75_RM=1	1.00	1.00	1.00	0.99	1.00	1.00	1.00	1.00	0.99
MV1_WM=0.125_RM=0.75	0.99	1.00	1.00	0.99	1.00	1.00	1.00	1.00	0.99

**Рис. 5.** Тепловая карта со значениями метрик Pte и Rc для каждого класса изображений (модели, предложенные к дальнейшему рассмотрению)

	val Acc	val Pre Брак	val Pre Вспышка	val Pre Пламени нет	val Pre Пламя есть	val Rc Брак	val Rc Вспышка	val Rc Пламени нет	val Rc Пламя есть
MV3_VR=small_SF=8	0.99	1.00	1.00	1.00	1.00	1.00	1.00	1.00	0.98
DenseNet121_GR=16	0.99	1.00	1.00	1.00	0.98	1.00	1.00	0.98	1.00
MV3_VR=large_SF=2	0.99	1.00	1.00	1.00	0.98	1.00	0.96	0.99	1.00
MV3_VR=large_SF=8	0.99	1.00	1.00	1.00	0.98	1.00	0.97	0.99	1.00
MV1_WM=0.25_RM=1	0.99	1.00	1.00	1.00	0.97	1.00	1.00	0.96	1.00
MV3_VR=small_SF=4	0.99	1.00	1.00	0.96	1.00	1.00	1.00	1.00	0.97
MV1_WM=0.125_RM=0.5	0.98	1.00	1.00	0.99	0.97	1.00	0.88	1.00	0.99
MV3_VR=large_SF=4	0.98	1.00	1.00	0.96	1.00	1.00	1.00	1.00	0.96
MV2_EF=6_SF=2	0.98	1.00	1.00	1.00	0.95	1.00	0.83	1.00	1.00
MV1_WM=0.0625_RM=0.5	0.97	1.00	1.00	0.97	0.94	1.00	0.88	0.97	0.98
DenseNet63_GR=8	0.96	1.00	1.00	0.93	0.97	1.00	1.00	0.96	0.94
MV3_VR=small_SF=2	0.96	1.00	1.00	0.91	1.00	1.00	1.00	1.00	0.91
MV2_EF=4_SF=8	0.96	1.00	1.00	0.90	0.99	1.00	1.00	1.00	0.90
VM1_WM=0.125_RM=1	0.95	1.00	1.00	0.88	0.99	1.00	0.96	1.00	0.89
ResNet50_SF=2	0.94	1.00	1.00	0.87	0.97	1.00	1.00	0.97	0.88
DenseNet63_GR=16	0.94	1.00	1.00	0.88	0.95	1.00	1.00	0.94	0.89
ResNet18_SF=1	0.93	1.00	1.00	0.83	1.00	1.00	1.00	1.00	0.72
VM1_WM=0.0625_RM=0.75	0.90	1.00	1.00	0.79	0.97	1.00	1.00	0.97	0.77
DenseNet121_GR=8	0.90	1.00	1.00	0.80	0.94	1.00	0.96	0.96	0.79
DenseNet43_GR=8	1.00	1.00	1.00	0.76	1.00	1.00	1.00	1.00	0.76
MV1_WM=0.0625_RM=1	1.00	1.00	1.00	0.91	0.69	1.00	0.99	0.48	0.96
DenseNet63_GR=32	1.00	1.00	1.00	1.00	0.58	1.00	0.83	0.22	1.00
DenseNet121_GR=32	0.66	1.00	1.00	1.00	0.54	1.00	1.00	1.00	1.00
ResNet50_SF=1	0.43	1.00	0.18	0.44	1.00	1.00	1.00	0.03	0.40

Рис. 6. Тепловая карта со значениями метрик Pre и Rc для каждого класса изображений (модели, исключенные из дальнейшего рассмотрения)

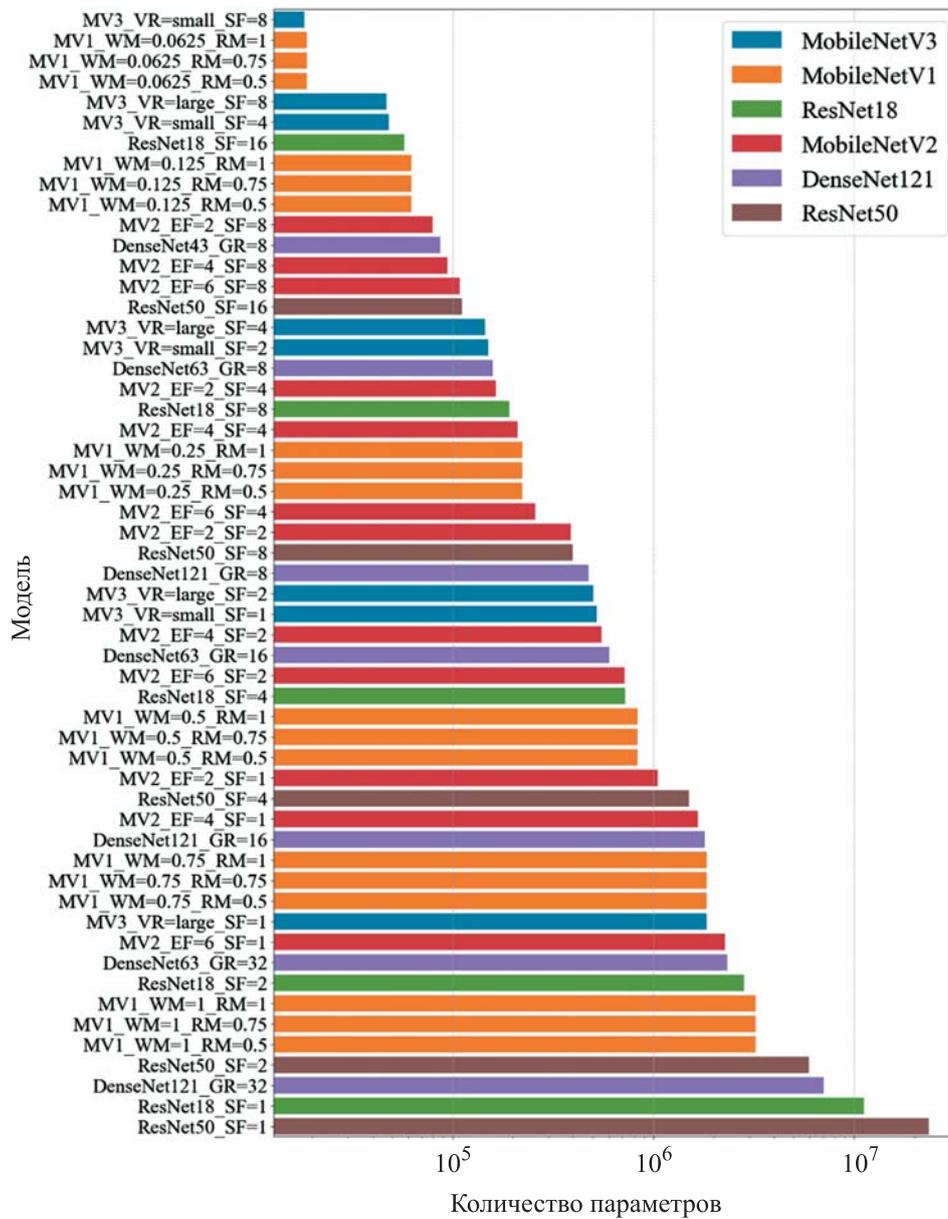


Рис. 7. Количество параметров моделей сетей

Среди архитектурных решений, кроме размера модели, на скорость ее работы влияют тип слоев и выполняемые специализированные операции. При оценке влияния этих факторов на величину задержки для каждой модели было измерено время одного ее прохода. Полученные значения представлены на рис. 8.

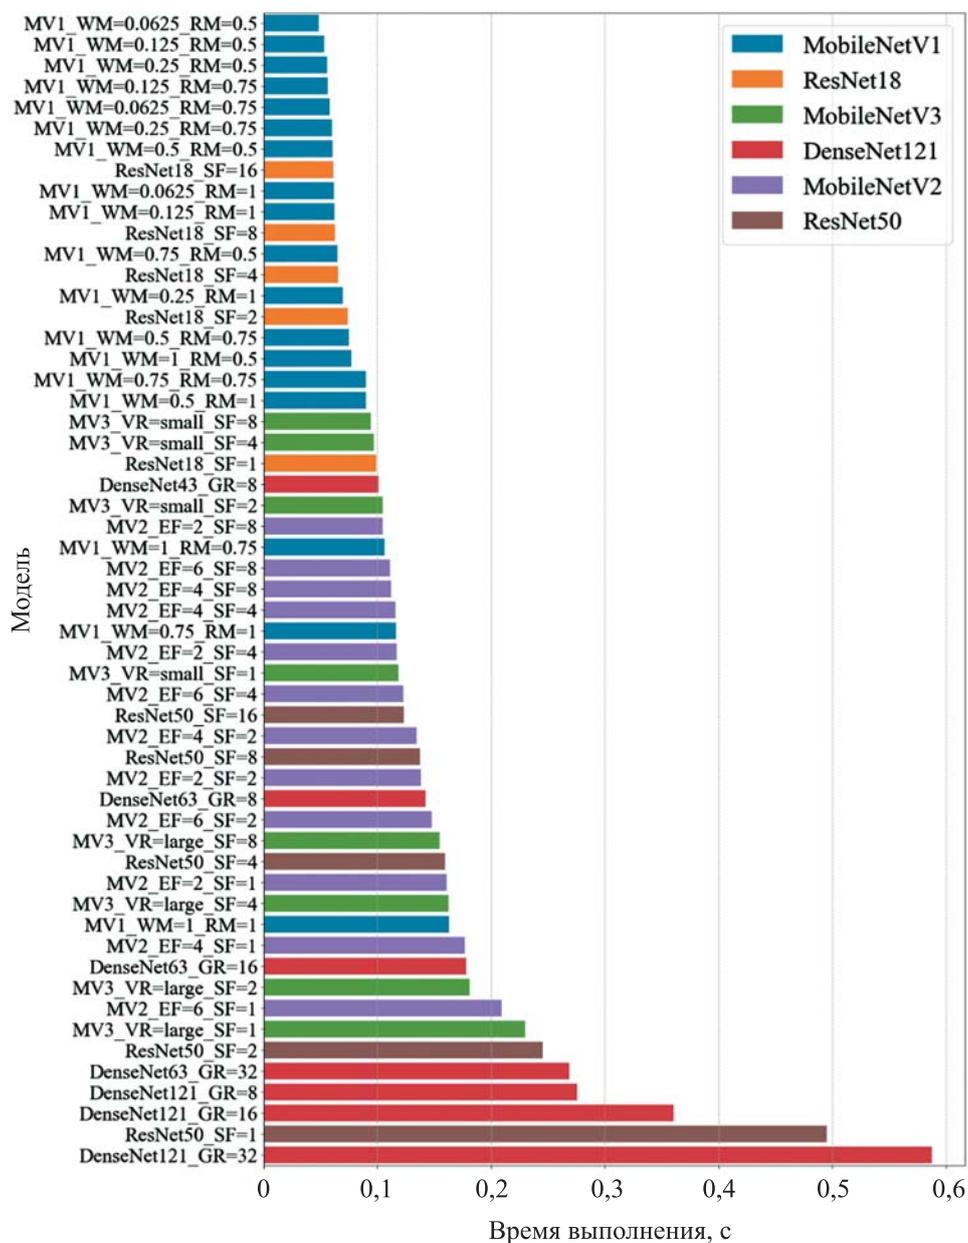


Рис. 8. Время выполнения одного прохода моделей

Согласно рис. 6, наилучшую скорость работы показывают модели, использующие разделяемую свертку по глубине и выполняющие операции над картами с признаком уменьшенного размера. Из диаграмм, представленных на рис. 7 и 8, видно, что модели, подобные DenseNet121 и ResNet50, значительно уступают в скорости работы моделям с соизмеримым количеством параметров.

В результате совокупного анализа данных, представленных на рис. 5–8, к применению для постобработки результатов эксперимента с потенциалом к их обработке в поточном формате рекомендованы обученные модели MobileNetV1\_WM=0.25\_RM=0.5, MobileNetV1\_WM=0.125\_RM=0.75, MobileNetV1\_WM=0.25\_RM=0.75, MobileNetV1\_WM=0.5\_RM=0.5, ResNet18\_SF=16, ResNet18\_SF=8, MobileNetV1\_WM=0.75\_RM=0.5, ResNet18\_SF=4, ResNet18\_SF=2.

**Заключение.** Проведена апробация моделей сверточных нейронных сетей с различной структурой остаточных блоков применительно к задаче классификации изображений, получаемых в ходе эксперимента. В результате масштабирования стандартных архитектур были получены модели, обеспечивающие точность классификации, размер модели и скорость ее работы, позволяющие как ускорить постобработку результатов эксперимента, так и корректировать ход испытания. Однако в данной работе не проводились исследования характера воспламенения: не выявлялось количество устройств, в которых наблюдается устойчивый процесс горения, и время переброса пламени от устройства к устройству, а зафиксирован лишь первый момент воспламенения топлива за какой-либо форсункой. Это ограничивает анализ зависимости характеристик воспламенения от обеспечиваемых физических условий. Таким образом, дальнейшие работы должны быть направлены на детектирование пламени за форсунками при постобработке.

#### ЛИТЕРАТУРА

- [1] *Нормы летной годности воздушных судов. Часть 33.* Утв. Приказом № 820-17 от 17 ноября 2022 г. Министерства транспорта Российской Федерации, Федерального агентства воздушного транспорта.
- [2] Богданов В.И., Голубев П.А., Чельшев В.Б. О возможности оценки некоторых высотных характеристик камеры сгорания ГТД в наземных условиях. *Вестник Рыбинской государственной авиационной технологической академии им. П.А. Соловьёва*, 2012, № 2, с. 91–94.
- [3] Гумеров А.Р., Ясовеев В.Х. Оптико-электронная система контроля и оценки эффективности процессов воспламенения топлива в камере сгорания газотурбинного двигателя. *Современные проблемы науки и образования в техническом вузе: сб. статей.* Уфа, Уфимский государственный авиационный технический университет, 2015, с. 128–132.
- [4] Коршак С.А. Нейросетевая модель классификации режимов работы газотурбинного двигателя по материалам объективного контроля. *Авиационный вестник*, 2023, № 8, с. 54–60.
- [5] Howard A., Sandler M., Chu G., Chen L.C., Chen B., Tan M., et al. Searching for MobileNetv3. *2019 IEEE/CVF International Conference on Computer Vision (ICCV)*. Seoul, Korea (South), 2019, pp. 1314–1324. DOI: 10.1109/ICCV.2019.00140
- [6] Tan M., Chen B., Pang R., Vasudevan V., Sandler M., Howard A., Le Q.V. MnasNet: Platform-aware neural architecture search for mobile. *2019 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Long Beach, CA, USA, 2019, pp. 2820–2828. DOI: 10.1109/CVPR.2019.00293

- [7] Zhang X., Zhou X., Lin M., Sun J. ShuffleNet: An extremely efficient convolutional neural network for mobile devices. *2018 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Salt Lake City, UT, USA, 2018, pp. 6848–6856. DOI: 10.1109/CVPR.2018.00716
- [8] He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Las Vegas, NV, USA, 2016, pp. 770–778. DOI: 10.1109/CVPR.2016.90.
- [9] Huang G., Liu Z., Van Der Maaten L., Weinberger K.Q. Densely connected convolutional networks. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Honolulu, HI, USA, 2017, pp. 4700–4708. DOI: 10.1109/CVPR.2017.243
- [10] Howard A.G. *MobileNets: Efficient convolutional neural networks for mobile vision applications*. 2017. DOI: 10.48550/arXiv.1704.04861
- [11] Sandler M., Howard A., Zhu M., Zhmoginov A., Chen LC. MobileNetV2: Inverted residuals and linear bottlenecks. *2018 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Salt Lake City, UT, USA, 2018, pp. 4510–4520. DOI: 10.1109/CVPR.2018.00474
- [12] Kingma D.P., Ba J. Adam: A method for stochastic optimization. *3rd International Conference for Learning Representations, San Diego, 2015*. DOI: 10.48550/arXiv.1412.6980
- [13] Goodfellow I., Bengio Y., Courville A. *Deep learning*. Cambridge, MIT Press, 2016, 775 p.
- [14] Ioffe S., Szegedy Ch. *Batch normalization: Accelerating deep network training by reducing internal covariate shift*. 2015. <https://doi.org/10.48550/arXiv.1502.03167>
- [15] He K., Zhang X., Ren S., Sun J. Delving deep into rectifiers: Surpassing human-level performance on ImageNet classification. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Santiago, Chile, 2015, pp. 1026–1034. DOI: 10.1109/ICCV.2015.123

Статья поступила в редакцию 30.07.2025

Ссылку на эту статью просим оформлять следующим образом:

Янук А.В., Тарасенко А.Н., Панов Е.Н. Разработка автоматизированных средств фиксации моментов воспламенения топлива и срыва пламени методами визуального анализа. *Инженерный журнал: наука и инновации*, 2025, вып. 10. EDN LLAIKF

**Янук Андрей Владимирович** — инженер ФАУ «ЦИАМ им. П.И. Баранова».  
e-mail: avyanuk@ciam.ru

**Тарасенко Антон Николаевич** — начальник сектора ФАУ «ЦИАМ им. П.И. Баранова». e-mail: antarasenko@ciam.ru

**Панов Егор Николаевич** — инженер ФАУ «ЦИАМ им. П.И. Баранова».  
e-mail: enpanov@ciam.ru

## **Development of the automated tools for registering the fuel ignition and flameout moments using the visual analysis methods**

© A.V. Yanuk, A.N. Tarasenko, E.N. Panov

Central Institute of Aviation Motors, Moscow, 111116, Russian Federation

*The paper presents results of testing the ResNet18, ResNet50, DenseNet121, MobileNetV1, MobileNetV2 and MobileNetV3 neural networks and their variations applied to the task of classifying images obtained during the experiment at the stage of putting the engine into operation. It describes modifications made to the standard implementations of the considered neural network architectures and the learning methodology used. Certain data augmentation methods are used to expand and balance the sampling. They include alteration in the image spatial orientation by rotations of 90, 180, and 270 degrees, mirroring the image relative to the vertical axis, and alteration in the image color tone. The accuracy, precision, and recall metrics are computed for each image class; the runtime and the number of parameters for each model are measured. A set of models satisfying the requirements for classification accuracy, computational costs, and time consumption are compiled.*

**Keywords:** deep learning, image classification, fuel ignition

### REFERENCES

- [1] *Normy letnoy godnosti vozdukhnykh sudov. Chast 33* [Airworthiness Standards for Aircraft. Part 33]. Utv. Prikazom No. 820-17 ot 17 noyabrya 2022 g. Ministerstva transporta Rossiyskoy Federatsii, Federalnogo agentstva vozdušnogo transporta [Approved by Order No. 820-17 of November 17, 2022, of the Ministry of Transport of the Russian Federation and the Federal Air Transport Agency].
- [2] Bogdanov V.I., Golubev P.A., Chelyshev V.B. O vozmozhnosti otsenki nekotorykh vysotnykh kharakteristik kamery sgoraniya GTD v nazemnykh usloviyakh [On a possibility of assessing certain altitude characteristics of the gas turbine combustion chamber in the ground conditions]. *Vestnik Rybinskoy gosudarstvennoy aviatsionnoy tekhnologicheskoy akademii im. P.A. Solovyeva*, 2012, no. 2, pp. 91–94.
- [3] Gumerov A.R., Yasoveev V.Kh. Optiko-elektronnaya sistema kontrolya i otsenki effektivnosti protsessov vosplamneniya topliva v kamere sgoraniya gazoturbinnogo dvigatelya [Optoelectronic system for monitoring and evaluating efficiency of fuel ignition processes in the combustion chamber of a gas-turbine engine]. In: *Sovremennyye problemy nauki i obrazovaniya v tekhnicheskoy vuzze: sb. statey* [Modern problems of science and education in a technical university: collection of articles]. Ufa, Ufimskiy Gosudarstvennyi Aviatsionnyi Tekhnicheskii Universitet Publ., 2015, pp. 128–132.
- [4] Korshak S.A. Neyrosetevaya model klassifikatsii rezhimov raboty gazoturbinnogo dvigatelya po materialam obyektivnogo kontrolya [Neural network model of classification of operating models of a gas turbine engine based on the materials of objective control]. *Aviatsionnyi vestnik — The Aviation Herald*, 2023, no. 8, pp. 54–60.
- [5] Howard A., Sandler M., Chu G., Chen L.C., Chen B., Tan M., et al. Searching for MobileNetv3. *2019 IEEE/CVF International Conference on Computer Vision (ICCV)*. Seoul, Korea (South), 2019, pp. 1314–1324. <https://doi.org/10.1109/ICCV.2019.00140>

- [6] Tan M., Chen B., Pang R., Vasudevan V., Sandler M., Howard A., Le Q.V. MnasNet: Platform-aware neural architecture search for mobile. *2019 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Long Beach, CA, USA, 2019, pp. 2820–2828. <https://doi.org/10.1109/CVPR.2019.00293>
- [7] Zhang X., Zhou X., Lin M., Sun J. ShuffleNet: An extremely efficient convolutional neural network for mobile devices. *2018 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Salt Lake City, UT, USA, 2018, pp. 6848–6856. <https://doi.org/10.1109/CVPR.2018.00716>
- [8] He K., Zhang X., Ren S., Sun J. Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Las Vegas, NV, USA, 2016, pp. 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- [9] Huang G., Liu Z., Van Der Maaten L., Weinberger K.Q. Densely connected convolutional networks. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Honolulu, HI, USA, 2017, pp. 4700–4708. <https://doi.org/10.1109/CVPR.2017.243>
- [10] Howard A.G. *MobileNets: Efficient convolutional neural networks for mobile vision applications*. 2017. <https://doi.org/10.48550/arXiv.1704.04861>
- [11] Sandler M., Howard A., Zhu M., Zhmoginov A., Chen L.C. MobileNetV2: Inverted residuals and linear bottlenecks. *2018 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Salt Lake City, UT, USA, 2018, pp. 4510–4520. <https://doi.org/10.1109/CVPR.2018.00474>
- [12] Kingma D.P., Ba J. Adam: A method for stochastic optimization. *3rd International Conference on Learning Representations*, San Diego, 2015. <https://doi.org/10.48550/arXiv.1412.6980>
- [13] Goodfellow I., Bengio Y., Courville A. *Deep learning*. Cambridge, MIT Press, 2016, 775 p.
- [14] Ioffe S., Szegedy Ch. *Batch normalization: Accelerating deep network training by reducing internal covariate shift*. 2015. <https://doi.org/10.48550/arXiv.1502.03167>
- [15] He K., Zhang X., Ren S., Sun J. Delving deep into rectifiers: Surpassing human-level performance on ImageNet classification. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Santiago, Chile, 2015, pp. 1026–1034. <https://doi.org/10.1109/ICCV.2015.123>

**Yanuk A.V.**, Engineer, Central Institute of Aviation Motors.  
e-mail: [avyanuk@ciam.ru](mailto:avyanuk@ciam.ru)

**Tarasenko A.N.**, Head of Sector, Central Institute of Aviation Motors.  
e-mail: [antarasenko@ciam.ru](mailto:antarasenko@ciam.ru)

**Panov E.N.**, Engineer, Central Institute of Aviation Motors.  
e-mail: [enpanov@ciam.ru](mailto:enpanov@ciam.ru)