



ИПМ им.М.В.Келдыша РАН • Электронная библиотека

Препринты ИПМ • Препринт № 4 за 2025 г.

ISSN 2071-2898 (Print)
ISSN 2071-2901 (Online)

М.Х. Нгуен, В.А. Судаков

Улучшение модели
MobileNetV2 для
обнаружения и анализа
лесных пожаров по
спутниковым снимкам

Статья доступна по лицензии
[Creative Commons Attribution 4.0 International](https://creativecommons.org/licenses/by/4.0/)



Рекомендуемая форма библиографической ссылки: Нгуен М.Х., Судаков В.А. Улучшение модели MobileNetV2 для обнаружения и анализа лесных пожаров по спутниковым снимкам // Препринты ИПМ им. М.В.Келдыша. 2025. № 4. 15 с. EDN: [BWGZYZ](https://library.keldysh.ru/preprint.asp?id=2025-4)
<https://library.keldysh.ru/preprint.asp?id=2025-4>

**Ордена Ленина
ИНСТИТУТ ПРИКЛАДНОЙ МАТЕМАТИКИ
имени М.В. Келдыша
Российской академии наук**

М.Х. Нгуен, В.А. Судаков

**Улучшение модели MobileNetV2 для
обнаружения и анализа лесных пожаров
по спутниковым снимкам**

Москва — 2025

М.Х. Нгуен, В.А. Судаков

Улучшение модели MobileNetV2 для обнаружения и анализа лесных пожаров по спутниковым снимкам

В статье предложено улучшение модели искусственной нейронной сети MobileNetV2 для обнаружения и анализа лесных пожаров на спутниковых изображениях с использованием механизмов внимания. Основное внимание уделено повышению точности и эффективности модели за счёт выделения ключевых пространственных и канальных признаков. Проведён сравнительный анализ базовой и улучшенных моделей с точки зрения точности, потерь, вычислительной сложности и времени инференса. Результаты показали, что интеграция механизмов внимания улучшает качество обнаружения пожаров, минимизирует ложные срабатывания и позволяет оптимизировать ресурсы для задач с ограниченными вычислительными возможностями.

Ключевые слова: искусственные нейронные сети, механизм внимания, спутниковые снимки, метрики качества классификации.

Nguyen Minh Hieu, Sudakov Vladimir Anatolyevich

Improving the MobileNetV2 Model for Forest Fire Detection and Analysis from Satellite Images

The paper proposes an improvement of the MobileNetV2 artificial neural network model for detecting and analyzing forest fires in satellite images using attention mechanisms. The main focus is on increasing the accuracy and efficiency of the model by identifying key spatial and channel features. A comparative analysis of the base and improved models in terms of accuracy, loss, computational complexity, and inference time is conducted. The results show that the integration of attention mechanisms improves the quality of fire detection, minimizes false positives, and allows optimizing resources for tasks with limited computing capabilities.

Key words: artificial neural networks, attention mechanism, satellite images, classification quality metrics.

Введение

Лесные пожары являются одной из наиболее значимых экологических проблем современности, приводя к огромным экономическим потерям, разрушению экосистем и ухудшению качества воздуха. Своевременное обнаружение и анализ лесных пожаров имеют решающее значение для их эффективного подавления и минимизации ущерба. Благодаря достижениям в области обработки изображений и искусственного интеллекта, спутниковые данные предоставляют новые возможности для автоматизированного мониторинга пожаров.

Модель MobileNetV2, известная своей эффективностью и низкими вычислительными затратами, широко используется в задачах классификации и детекции [1]. Однако для более точного анализа сложных данных, таких как спутниковые изображения, требуется улучшение её способности выделять значимые особенности. В этом контексте особую роль играют механизмы внимания (Attention Mechanisms), такие как Squeeze-and-Excitation (SE), Convolutional Block Attention Module (CBAM) и Efficient Channel Attention (ECA). Эти механизмы позволяют модели фокусироваться на наиболее важных каналах и пространственных областях изображения, что существенно повышает её точность и устойчивость.

Целью данной работы является изучение и интеграция механизмов внимания в архитектуру MobileNetV2 для улучшения её эффективности в задаче обнаружения и анализа лесных пожаров. В рамках исследования проводятся эксперименты с различными модификациями модели, оценивается их производительность на основе метрик точности, потерь, вычислительной сложности и времени инференса. Работа направлена на создание оптимизированного решения, способного эффективно работать в условиях ограниченных вычислительных ресурсов, что делает её актуальной для реального применения в системах мониторинга лесных пожаров. Возможности модели в решении задач распознавания объектов интереса позволяют интегрировать её в системы компьютерного зрения робототехнических комплексов [2] и системы поддержки принятия оперативных решений [3].

Модель MobileNetV2 и механизмы внимания

MobileNetV2 разработана как компактная и высокоэффективная архитектура для выполнения задач, требующих применения глубокого обучения на мобильных устройствах. Её ключевые компоненты, такие как depthwise separable convolution и inverted residual blocks, позволяют значительно сократить количество вычислений, обеспечивая при этом достойную производительность. Однако при работе с комплексными данными, например спутниковыми изображениями, модель может упускать значимые признаки. Для устранения этого недостатка целесообразно использование механизмов внимания, включая

SE, СВМ и ЕСА. Эти технологии помогают модели сосредотачиваться на ключевых особенностях данных: SE усиливает важные каналы, СВМ включает пространственное внимание, а ЕСА минимизирует вычислительные затраты, сохраняя эффективность. Интеграция этих подходов позволяет адаптировать MobileNetV2 для более сложных задач анализа [4].

Свертка в MobileNetV2 состоит из двух этапов: глубокой свертки и точечной свертки, как показано на рисунках 1а, 1б. В отличие от стандартной свертки, на этапе глубокой свертки каждый сверточный фильтр обрабатывает только один канал входных данных, а объединение каналов выполняется с помощью точечной свертки. Пусть размер входного изображения составляет $H \times W$, размер сверточного ядра — $K \times K$, количество выходных каналов — C , а размер каждого выходного канала — N . Тогда вычислительная сложность стандартной свертки рассчитывается следующим образом [5]:

$$F = H \times W \times K \times K \times C \times N. \quad (1)$$

Глубинно-разделимая свертка (Depthwise separable convolution):

$$F_{DSC} = H \times W \times K \times K \times C + H \times W \times C \times N. \quad (2)$$

Рассмотрим отношение вычислительных сложностей:

$$\frac{F_{DSC}}{F} = \frac{H \times W \times K \times K \times C + H \times W \times C \times N}{H \times W \times K \times K \times C \times N} = \frac{1}{N} + \frac{1}{K^2}. \quad (3)$$

В результате такой подход значительно снижает вычислительные затраты.

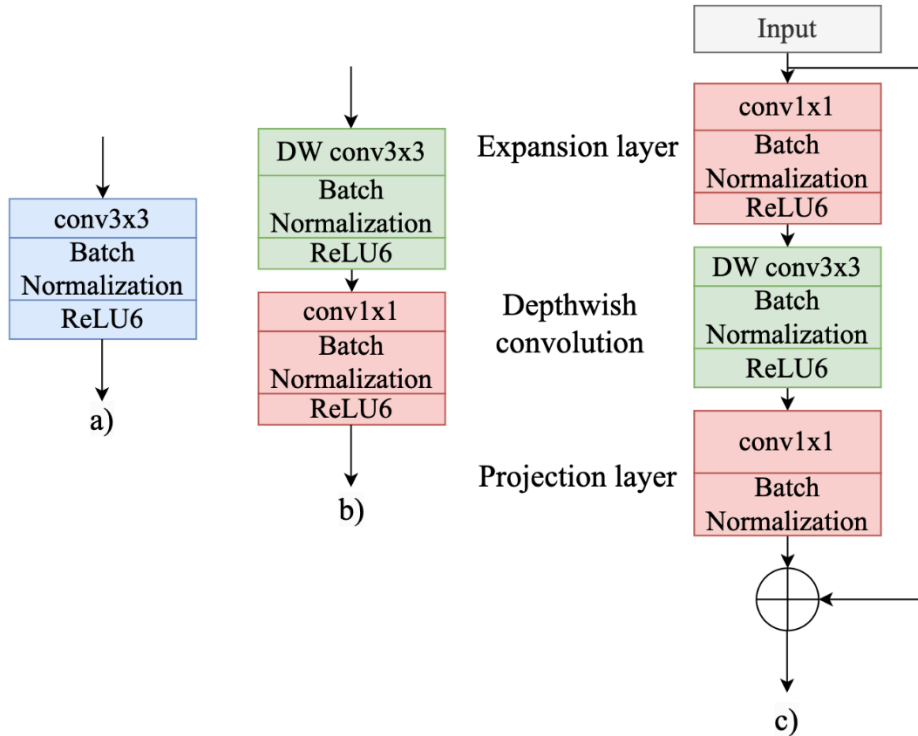


Рис. 1. Структурная схема: а) стандартная свертка, б) глубинно-разделимая свертка, в) инверсный остаточный модуль

Инверсные остаточные блоки (Inverted residual blocks). На рисунке 1с представлены инверсные остаточные блоки, которые являются ключевым элементом архитектуры MobileNetV2, обеспечивая высокую эффективность при низкой вычислительной сложности. В этих блоках сначала происходит расширение размерности каналов через 1×1 свертку, затем обработка каждого канала отдельно с помощью глубокой свертки, а после — сжатие данных обратно через слой проекции. Остаточные соединения используются для сохранения информации, если вход и выход совпадают по размеру [6].

Количество параметров стандартной свертки равно $K \times K \times C \times N$. Количество параметров глубинно-разделяемой свертки (Depthwise Separable Convolution) сокращается до $K \times K \times C + C \times N$.

Squeeze-and-Excitation (SE) — это механизм внимания, работающий в несколько этапов для усиления значимости важных каналов входного тензора. Сначала входной тензор X размером $H' \times W' \times C'$ преобразуется через слой свертки или другую обработку (F_{tr}) в тензор U размером $H \times W \times C$, где H, W — высота и ширина пространства, а C — количество выходных каналов. На этапе Squeeze (F_{sq}) выполняется глобальное усреднение по пространственным измерениям (Global Average Pooling), сжимающее информацию каждого канала в вектор размером $1 \times 1 \times C$, представляющий обобщенные данные по всем каналам. Затем, на этапе Excitation (F_{ex}), этот вектор обрабатывается двумя Dense-слоями: первый слой уменьшает размерность каналов до $\frac{C}{r}$, а второй восстанавливает исходное количество каналов C , применяя функцию активации Sigmoid для вычисления весов каналов в диапазоне $[0,1]$. На заключительном этапе Scale (F_{scale}) вычисленные веса $1 \times 1 \times C$ умножаются на исходный тензор U , создавая выходной тензор \tilde{X} размером $H \times W \times C$, где значимые каналы усиливаются. На рисунке 2 представлен процесс SE, который позволяет оптимизировать обучение ключевых признаков и повышать эффективность нейронных сетей при решении сложных задач анализа данных [7].




Рис. 2. Схема работы SE-блока

Convolutional Block Attention Module (CBAM) — это механизм внимания, который объединяет каналное внимание (Channel Attention) и пространственное

внимание (Spatial Attention) для улучшения способности нейронной сети извлекать важные признаки. На вход подается промежуточная карта признаков F , и СВАМ последовательно вычисляет карту внимания каналов в 1D (M_c) и карту пространственного внимания в 2D (M_s). Сначала входной тензор F обрабатывается в модуле канального внимания (Channel Attention Module), где Max Pooling и Average Pooling применяются к пространственным измерениям, создавая два вектора размером $1 \times 1 \times C$. Эти векторы проходят через общую полносвязную сеть (Shared MLP), которая вычисляет веса каналов M_c с использованием функции активации Sigmoid. Затем тензор F умножается на веса M_c , что приводит к формированию уточнённых признаков F' . После этого F' поступает в модуль пространственного внимания (Spatial Attention Module), где Max Pooling и Average Pooling применяются к каналному измерению, создавая два тензора размером $H \times W \times 1$. Эти тензоры объединяются и проходят через сверточный слой 7×7 с активацией Sigmoid для вычисления весов пространства M_s . В результате веса M_s умножаются на F' , создавая выходной тензор F'' , в котором усиливаются как важные каналы, так и ключевые пространственные области. На рисунке 3 представлен СВАМ, который эффективно оптимизирует анализ данных, учитывая взаимосвязь между каналами и пространством, а также является лёгким и удобным для интеграции в архитектуры CNN [8].

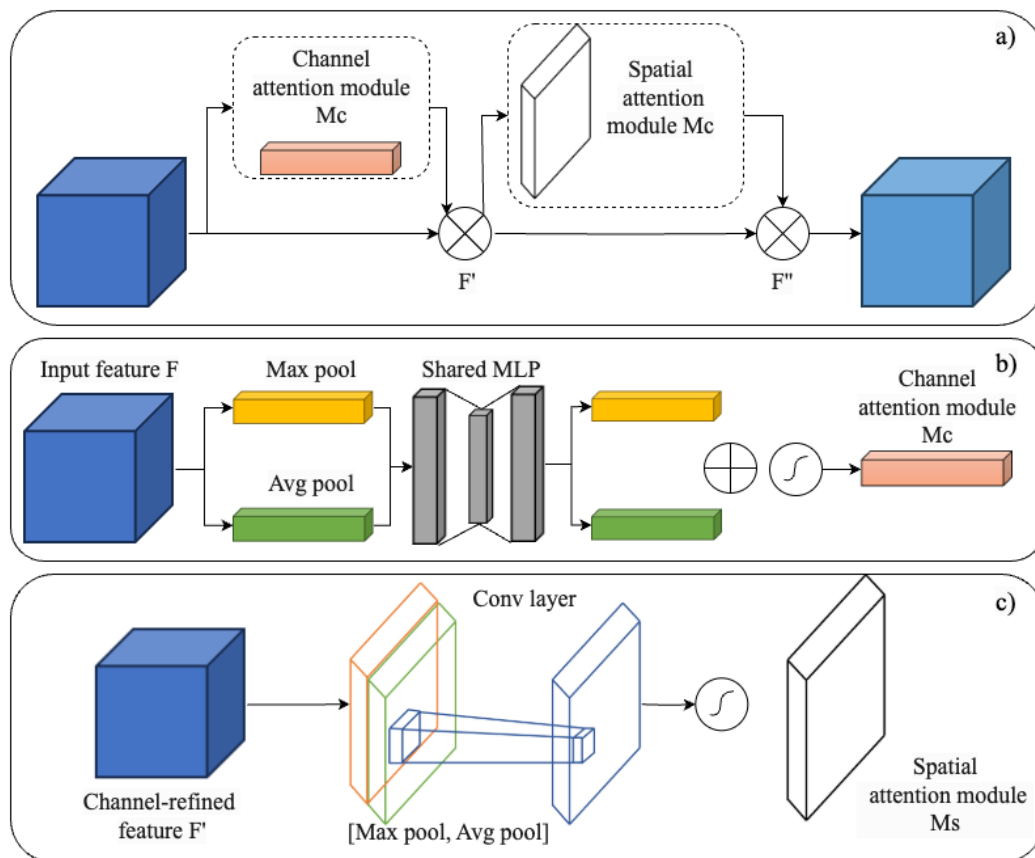


Рис. 3. Структура блоков внимания а) СВАМ, б) Channel Attention Module, в) Spatial Attention Module

Efficient Channel Attention (ECA) — это эффективный механизм внимания, разработанный для улучшения способности модели извлекать значимые признаки без значительного увеличения вычислительной сложности. Входной тензор X размером $H \times W \times C$, где H , W — высота и ширина пространства, а C — количество каналов, сначала подвергается сжатию пространственной информации с помощью Global Average Pooling (GAP). Это приводит к созданию вектора $1 \times 1 \times C$, который представляет средние значения каждого канала. Этот вектор передается в слой Conv1D, который заменяет полносвязные слои (Dense) из других механизмов, таких как SE, для вычисления взаимосвязей между каналами без увеличения числа параметров модели. Результат работы Conv1D обрабатывается функцией активации Sigmoid, что позволяет получить веса каналов K в диапазоне $[0,1]$. Эти веса умножаются на исходный тензор X , формируя выходной тензор X^* того же размера $H \times W \times C$, где усиливаются важные каналы, а менее значимые ослабляются [9].

На рисунке 4 представлен ECA, использование Conv1D позволяет эффективно изучать межканальные связи, минимизирует вычислительные затраты и улучшает способность нейронной сети выделять ключевые признаки.

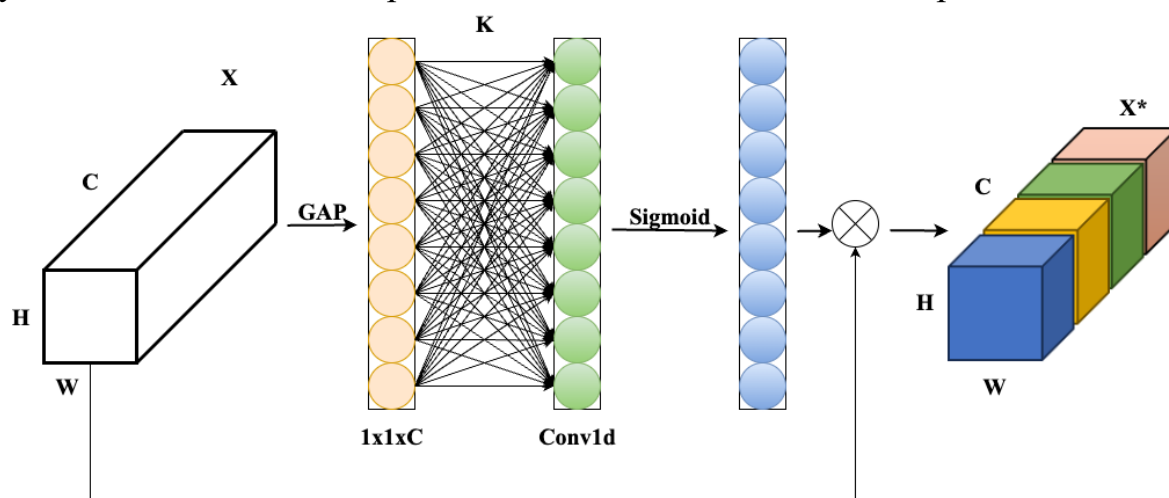


Рис. 4. Схема работы ECA-блока

Таким образом, MobileNetV2 снижает вычислительные затраты и подходит для обработки сложных изображений. Механизмы внимания, такие как SE, CBAM и ECA, улучшат обучение признаков, усиливая каналы и объединяя внимание к каналам и пространству. Эти механизмы легко интегрируются в MobileNetV2, повышая его эффективность при анализе спутниковых изображений.

Улучшение MobileNetV2

В данном исследовании механизмы внимания SE, CBAM и ECA были интегрированы в выходной слой MobileNetV2, чтобы повысить производительность модели при обнаружении и анализе лесных пожаров. На

рисунке 5 представлен процесс интеграции механизма внимания в выход MobileNetV2.




Рис. 5. Процесс интеграции механизма внимания в выход MobileNetV2

Архитектура MobileNetV2:

- MobileNetV2 выбран в качестве базовой модели благодаря использованию Depthwise Separable Convolution, что снижает количество параметров и вычислительную сложность;
- Базовая модель предварительно обучена на наборе данных imagenet, что позволяет использовать уже извлечённые общие признаки.

Интеграция механизмов внимания в выходной слой:

- SE: Этот механизм добавлен сразу после выходного слоя MobileNetV2. SE использует Global Average Pooling для сжатия пространственной информации и вычисляет веса для каждого канала, чтобы усилить наиболее важные из них;
- CBAM: CBAM также интегрирован в выходной слой. Он последовательно применяет каналное внимание (Channel Attention) для определения значимости каналов и пространственное внимание (Spatial Attention) для выделения ключевых областей на изображении;
- ECA: Механизм ECA внедрён после выходного слоя MobileNetV2. Он заменяет Dense-слои в SE на Conv1d, что позволяет эффективно вычислять межканальные зависимости без значительного увеличения числа параметров.

Настройка улучшенной модели:

- После добавления механизмов внимания к выходу MobileNetV2 в модель добавлены слои классификации, включая Global Average Pooling, Fully Connected, Dropout и функцию активации Sigmoid для выполнения бинарной классификации.
- Для каждого механизма (SE, CBAM, ECA) была создана отдельная модель для сравнения производительности. Также была протестирована их комбинация для оценки совокупного эффекта.

Обучение и оценка:

- Модели обучались на наборе спутниковых изображений с метками, относящимися к лесным пожарам.
- Для оптимизации использовался алгоритм Adam с техникой уменьшения скорости обучения на основе сходимости (ReduceLROnPlateau).

- Эффективность оценивалась по метрикам, включая Accuracy, Precision, Recall, функцию потерь, время инференса и количество Flops.

Интеграция механизмов внимания SE, CBAM и ECA в выходной слой MobileNetV2 позволяет модели лучше сосредотачиваться на значимых признаках, что способствует повышению её производительности в задачах анализа сложных данных, таких как обнаружение и анализ лесных пожаров.

Результаты сравнения производительности моделей

Набор данных, использованный в данном исследовании, включает спутниковые изображения, относящиеся к региону Квебек, которые содержат информацию о признаках лесных пожаров [10]. Этот набор данных подходит не только для научных исследований, но и для разработки систем раннего предупреждения о лесных пожарах. Изображения разделены на обучающую, проверочную и тестовую выборки, что обеспечивает баланс и репрезентативность для процесса обучения модели (см. рис. 6).

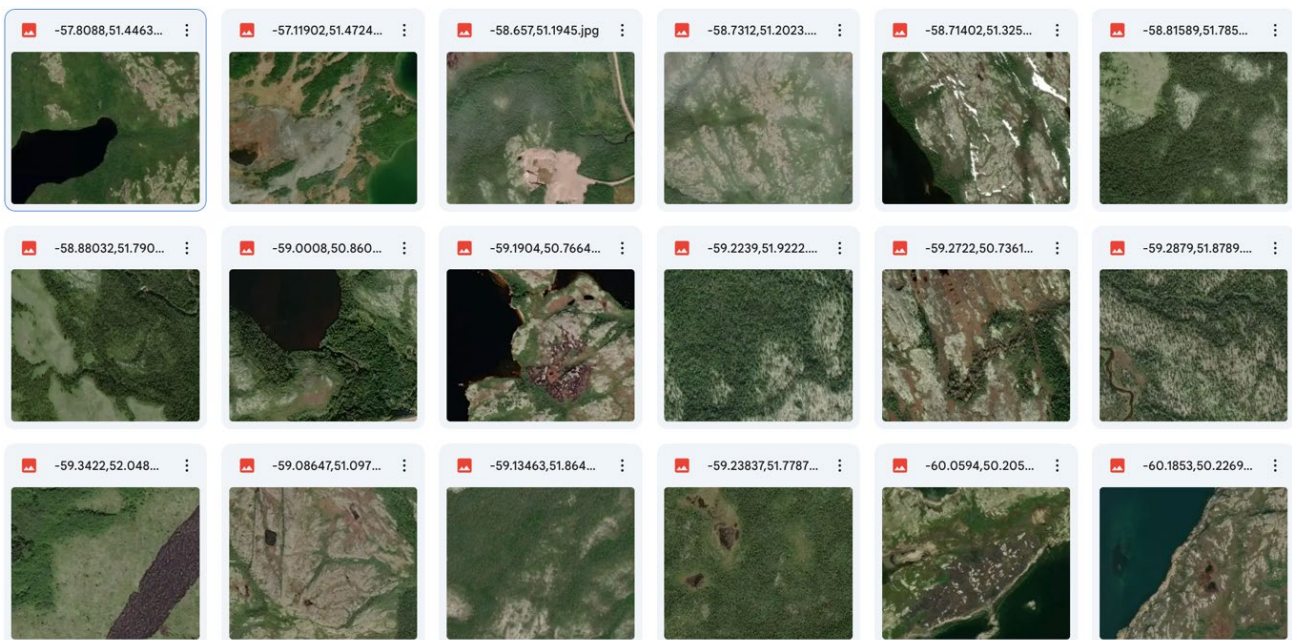


Рис. 6. Часть спутниковых изображений из набора данных

Эксперименты были проведены с использованием языка Python и библиотек Tensorflow и Keras для построения и обучения моделей. Для эксперимента использовалась среда Google Colab – облачная платформа, поддерживающая GPU/TPU, что позволяет оптимизировать процесс обучения глубоких нейронных сетей. Рабочий интерфейс — это блокнот Colab, который позволяет выполнять код и отслеживать результаты непосредственно через ячейки с кодом и графики.

На рисунке 7 представлены сравнения точности и потерь моделей MobileNetV2 с SE, CBAM и ECA.

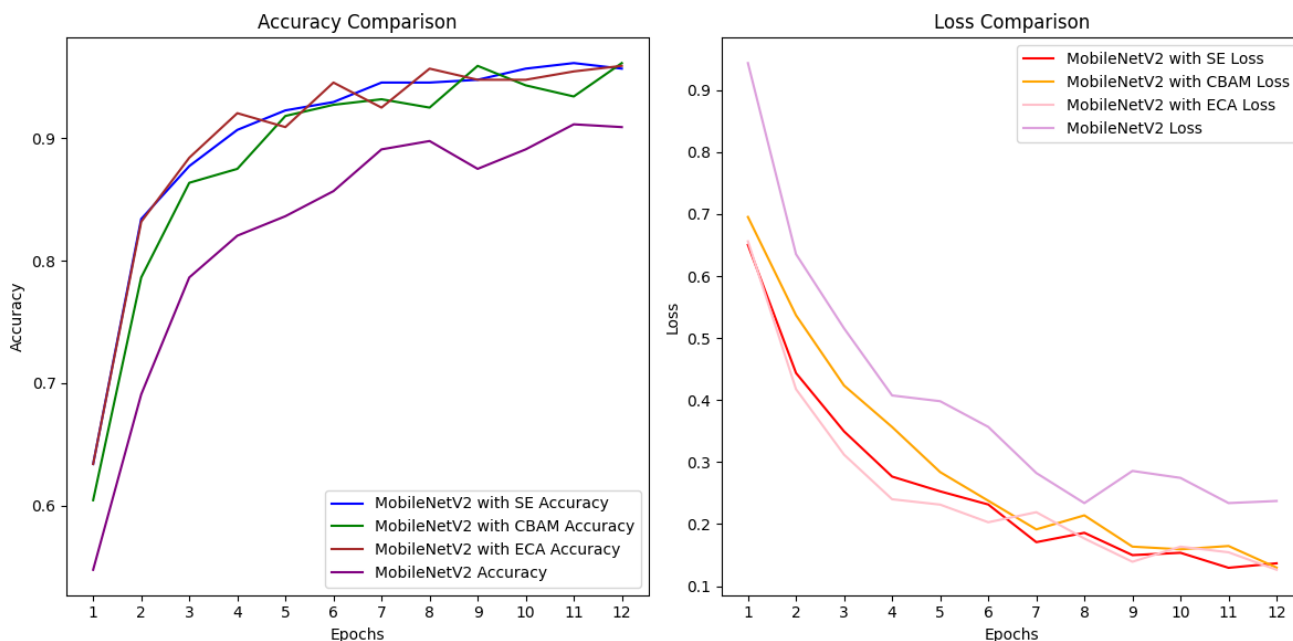


Рис. 7. Сравнение точности и потерь моделей MobileNetV2 с SE, СВМ и ЕСА

Модели, интегрированные с механизмами внимания, такими как СВМ, ЕСА и SE, демонстрируют значительное улучшение точности и снижение потерь по сравнению с базовой моделью MobileNetV2. Среди них СВМ показала наилучшие результаты, поддерживая высокую точность и быстро снижая потери на протяжении всего процесса обучения. SE и ЕСА также показали улучшения, однако их стабильность в начале обучения уступает СВМ. В целом добавление механизмов внимания в MobileNetV2 значительно повышает эффективность модели, особенно в задачах анализа спутниковых изображений, таких как обнаружение лесных пожаров.

В таблице 1 представлены результаты сравнения моделей по ключевым метрикам, оценивающим точность и вычислительную эффективность каждой модели.

Таблица 1. Результат сравнения моделей

Models	Accuracy %	Recall %	Precision %	Param MB	Flops M	Speed ms
MobileNetV2-SE	98,57	100	97,22	10,03	613,59	4,9631
MobileNetV2-CBAM	98,23	97	97,14	10,81	615,2	5,5762
MobileNetV2-ECA	97,14	97,14	97,14	10,03	613,19	3,6418
MobileNetV2	95,71	97	94,44	9,24	613,05	3,5784

Результаты сравнения моделей MobileNetV2, MobileNetV2-SE, MobileNetV2-CBAM и MobileNetV2-ECA показывают, что MobileNetV2 с SE достигла наилучших результатов по точности, при этом время инференса составляет 4,9631 мс. MobileNetV2 с СВМ показывает точность хуже, время инференса больше и количество параметров немного больше. MobileNetV2 с ЕСА показывает немного худшую точность, но время инференса быстрее, чем у

MobileNetV2 с СВAM, при этом количество параметров аналогично MobileNetV2 с SE. Несмотря на то что MobileNetV2 имеет наименьшее количество параметров (9,24 МБ) и самое быстрое время инференса (3,5784 мс), ее точность наименьшая (95,71%), а полнота составляет только 97%. Таким образом, механизмы внимания SE, СВAM и ECA значительно улучшают точность и полноту модели, при этом SE показывает наилучший общий результат, в то время как MobileNetV2 остается самым быстрым, но с меньшей эффективностью.

На рисунке 8 представлены результаты работы системы обнаружения лесных пожаров с использованием моделей для четырех различных спутниковых изображений. Для каждого изображения показана вероятность обнаружения пожара для каждой модели, что позволяет сравнить эффективность различных механизмов внимания в контексте точности и производительности моделей.

Система обнаружения и анализа лесных пожаров

Загрузите спутниковое изображение для обнаружения и анализа лесных пожаров.

Загрузите спутниковые изображения

Drag and drop files here
Limit 200MB per file • JPG, PNG, JPEG Browse files

- 75.6161,45.388345.jpg 41.6KB
×
- 73.767668,45.549022.jpg 53.5KB
×
- 72.24711,51.57194.jpg 33.0KB
×

Showing page 1 of 2 < >





 <p style="font-size: 0.8em; margin-top: 5px;">Загруженное изображение: -72.10002,50.63549.jpg</p>	<p>Результаты для -72.10002,50.63549.jpg:</p> <p>MobileNetV2: Обнаружен лесной пожар! Вероятность: 97.66%</p> <p>MobileNetV2 + SE: Обнаружен лесной пожар! Вероятность: 98.99%</p> <p>MobileNetV2 + СВAM: Обнаружен лесной пожар! Вероятность: 99.37%</p> <p>MobileNetV2 + ECA: Обнаружен лесной пожар! Вероятность: 99.30%</p>	 <p style="font-size: 0.8em; margin-top: 5px;">Загруженное изображение: -73.767668,45.549022.jpg</p>	<p>Результаты для -73.767668,45.549022.jpg:</p> <p>MobileNetV2: Лесной пожар не обнаружен! Вероятность: 99.76%</p> <p>MobileNetV2 + SE: Лесной пожар не обнаружен! Вероятность: 99.89%</p> <p>MobileNetV2 + СВAM: Лесной пожар не обнаружен! Вероятность: 100.00%</p> <p>MobileNetV2 + ECA: Лесной пожар не обнаружен! Вероятность: 99.99%</p>
 <p style="font-size: 0.8em; margin-top: 5px;">Загруженное изображение: -72.24711,51.57194.jpg</p>	<p>Результаты для -72.24711,51.57194.jpg:</p> <p>MobileNetV2: Обнаружен лесной пожар! Вероятность: 94.84%</p> <p>MobileNetV2 + SE: Обнаружен лесной пожар! Вероятность: 99.03%</p> <p>MobileNetV2 + СВAM: Обнаружен лесной пожар! Вероятность: 99.21%</p> <p>MobileNetV2 + ECA: Обнаружен лесной пожар! Вероятность: 97.50%</p>	 <p style="font-size: 0.8em; margin-top: 5px;">Загруженное изображение: -75.6161,45.388345.jpg</p>	<p>Результаты для -75.6161,45.388345.jpg:</p> <p>MobileNetV2: Лесной пожар не обнаружен! Вероятность: 99.75%</p> <p>MobileNetV2 + SE: Лесной пожар не обнаружен! Вероятность: 99.83%</p> <p>MobileNetV2 + СВAM: Лесной пожар не обнаружен! Вероятность: 99.99%</p> <p>MobileNetV2 + ECA: Лесной пожар не обнаружен! Вероятность: 99.99%</p>

Рис. 8. Результаты системы обнаружения лесных пожаров с моделями

Все модели с добавленными механизмами внимания (SE, СВAM, ECA) значительно улучшили точность обнаружения лесных пожаров по сравнению с базовой моделью MobileNetV2. Особенно модель с СВAM показала наилучшие результаты в плане точности, особенно при обнаружении отсутствия пожара. Модели с SE, СВAM и ECA продемонстрировали улучшение в обнаружении

пожаров, при этом СВМ обеспечил наиболее высокую точность, что свидетельствует о его лучшей способности выделять важные особенности на изображениях.

Анализ зоны лесного пожара на RGB-изображениях. После того как модели глубокого обучения выявляют наличие лесного пожара на RGB-изображении, система приступает к детальному анализу пораженных областей. На этом этапе применяются традиционные методы обработки изображений для оценки таких характеристик, как площадь, интенсивность пожара и распределение температуры. Анализ проводится на основе обычных RGB-изображений, без учета природных факторов, таких как направление ветра, влажность или рельеф местности, которые могут влиять на распространение пожара. Он предоставляет относительную информацию о состоянии зоны пожара.

Предобработка изображений. Для упрощения анализа спутниковых RGB-изображений с высоким разрешением они масштабируются до размера 224×224 пикселя. Также значения пикселей нормализуются в диапазон $[0,1]$ путем деления на 255, что повышает эффективность работы алгоритмов машинного обучения.

Обнаружение областей пожара. Для разделения изображения на зоны с пожаром и без него используется метод адаптивной пороговой обработки (Adaptive Thresholding), который вычисляет локальные пороги для участков с неравномерным освещением. Это позволяет создать маску зоны пожара (Burn Mask), улучшая точность выделения областей пожара на таких изображениях.

Расчет площади пожара. Масштаб пикселя зависит от разрешения изображения. Например, при разрешении 10 м/пиксель один пиксель соответствует 100 м^2 . Если в области пожара найдено 10 000 пикселей, площадь пожара рассчитывается так: $\text{Площадь} = 10\,000 \times 100 = 1\,000\,000 \text{ м}^2 = 1 \text{ км}^2$.

Анализ интенсивности пожара. Средняя яркость рассчитывается как среднее значение всех пикселей в области пожара на изображении в градациях серого, отражая тепловую интенсивность. Интенсивность красного цвета определяется как среднее значение красного канала (R) для всех пикселей в области пожара на RGB-изображениях.

Расчет площади и интенсивности пожара на основе RGB-изображений имеет ограниченную точность, так как отсутствуют данные с инфракрасных (IR) или других спектральных каналов, что делает анализ относительным.

На рисунке 9 представлены результаты анализа зоны лесного пожара.

Анализ изображения: -72.10002,50.63549.jpg





Загруженное изображение

Анализ лесного пожара**а. Измерение площади пожара**

Количество пикселей пожара: 69267.00
 Площадь области пожара (м²): 6926700.00
 Площадь области пожара (км²): 6.93
 Примечание: 1 пиксель = 100 м².

Тепловая карта интенсивности лесных пожаров

**б. Анализ интенсивности пожара**

Средняя яркость: 83.02
 Средняя интенсивность красного: 78.94

Анализ изображения: -72.24711,51.57194.jpg





Загруженное изображение

Анализ лесного пожара**а. Измерение площади пожара**

Количество пикселей пожара: 68045.00
 Площадь области пожара (м²): 6804500.00
 Площадь области пожара (км²): 6.80
 Примечание: 1 пиксель = 100 м².

Тепловая карта интенсивности лесных пожаров

**б. Анализ интенсивности пожара**

Средняя яркость: 94.73
 Средняя интенсивность красного: 91.10

Рис. 9. Результаты анализа зоны лесного пожара

Результаты анализа показывают, что оба изображения отражают лесные пожары с приблизительно одинаковой площадью, равной 6,93 км² и 6,80 км² соответственно. Однако второе изображение демонстрирует более серьезный уровень пожара с более высокой средней яркостью (94,73) и средней интенсивностью красного (91,10) по сравнению с первым изображением (83,02 и 78,94). Тепловая карта также более четко выделяет области с высокой интенсивностью пожара на втором изображении. Анализ яркости и интенсивности красного на изображениях RGB предоставляет быстрый и относительный способ оценки степени серьезности пожара, особенно в условиях ограниченных данных и ресурсов. Хотя данный метод не может полностью заменить данные, полученные с инфракрасных или мультиспектральных снимков, он остается полезным инструментом для определения приоритетных областей с серьезными пожарами.

Заключение

В данной работе проведено исследование улучшений модели MobileNetV2 для задач обнаружения и анализа лесных пожаров с использованием механизмов внимания, таких как SE, CBAM и ECA. Результаты экспериментов подтвердили, что интеграция этих механизмов значительно повышает точность, полноту и другие метрики производительности модели. Среди них механизм SE показал наилучшую эффективность, обеспечивая высокую точность и полноту, что делает его наиболее подходящим для задач обнаружения пожаров.

Дополнительно была реализована система анализа лесных пожаров на основе изображений RGB, которая предоставляет быстрый и удобный инструмент для оценки площади и интенсивности пожара. Этот подход, несмотря на свою относительность, доказал свою полезность в условиях ограниченных данных и

ресурсов. Анализ яркости и интенсивности красного цвета на изображениях RGB позволяет выявлять приоритетные области для реагирования на пожары, обеспечивая базовую оценку их серьезности.

Таким образом, предложенные улучшения модели и методика анализа демонстрируют их значимость в задачах обнаружения и оценки лесных пожаров. Эти подходы могут быть использованы для повышения эффективности систем мониторинга и реагирования, особенно в условиях ограниченных ресурсов.

Библиографический список

1. Sandler M., Howard A., Zhu M., Zhmoginov A., Chen L.C. MobileNetV2: Inverted Residuals and Linear Bottlenecks. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA, 2018, pp. 4510-4520. <https://doi.org/10.1109/CVPR.2018.00474>.
2. Sokolov S., Sudakov, V. Multicriteria Analysis of the Robotic Systems Autonomy Using Fuzzy Calculations. In Proceedings of the 16th International Conference on Agents and Artificial Intelligence (ICAART 2024) — Volume 3, pp. 916-920. <https://doi.org/10.5220/0012418200003636>.
3. Четверушкин Б.Н., Судаков В.А. Факторное моделирование для инновационно-активных предприятий // Математическое моделирование. 2020. Т. 32, № 3. С. 115-126. <https://doi.org/10.20948/mm-2020-03-07>.
4. Review: MobileNetV2 — Light Weight Model (Image Classification) [Электронный ресурс] // Medium. — Режим доступа: <https://towardsdatascience.com/review-mobilenetv2-light-weight-model-image-classification-8febb490e61c> (дата обращения: 23.12.2024).
5. MobileNet-V2: Summary and Implementation [Электронный ресурс] // HackMD. — Режим доступа: <https://hackmd.io/@machine-learning/ryaDuxe5L> (дата обращения: 23.12.2024).
6. A Summary of the “MobileNetV2: Inverted Residuals and Linear Bottlenecks” Paper [Электронный ресурс] // Medium. — Режим доступа: <https://medium.com/codex/a-summary-of-the-mobilenetv2-inverted-residuals-and-linear-bottlenecks-paper-e19b187cb78a> (дата обращения: 23.12.2024).
7. Squeeze-and-Excitation Networks [Электронный ресурс] // Medium. — Режим доступа: <https://towardsdatascience.com/squeeze-and-excitation-networks-9ef5e71eacd7> (дата обращения: 23.12.2024).
8. CBAM: Convolutional Block Attention Module [Электронный ресурс] // Reading Collections. — Режим доступа: https://owenliuyuxuan.github.io/papers_reading_sharing.github.io/Building_Blocks/CBAM%3AConvolutional_Block_Attention_Module/ (дата обращения: 23.12.2024).
9. Brief Review — ECA-Net [Электронный ресурс] // Medium. — Режим доступа: <https://sh-tsang.medium.com/brief-review-eca-net-efficient-channel-attention-for-deep-convolutional-neural-networks-8c6ca3a69770> (дата обращения: 23.12.2024).

10. Forest Fires [Электронный ресурс] // Canada.ca. — Режим доступа: <https://open.canada.ca/data/en/dataset/9d8f219c-4df0-4481-926f-8a2a532ca003> (дата обращения: 23.12.2024).

Оглавление

Введение	3
Модель MobileNetV2 и механизмы внимания	3
Улучшение MobileNetV2	7
Результаты сравнения производительности моделей.....	9
Заключение.....	13
Библиографический список.....	14