

УДК 004.932.2

ИССЛЕДОВАНИЕ ВЛИЯНИЯ ВХОДНЫХ ПАРАМЕТРОВ НА КЛАССИФИКАЦИЮ ИЗОБРАЖЕНИЙ ПРОДУКТОВ



А.В. Деркач

Магистрант кафедры
электронных вычислительных
машин БГУИР
i.angelika897@gmail.com



И.И. Фролов

Доцент кафедры электронных
вычислительных машин БГУИР,
кандидат технических наук,
доцент
frolov@bsuir.by

А.В. Деркач

Окончила Белорусский государственный университет информатики и радиоэлектроники по специальности «Вычислительные машины, системы и сети». Обучается в магистратуре БГУИР по специальности «Компьютерная инженерия», выполняет исследования в рамках магистерской диссертации на тему «Автоматизированная система анализа продуктов по изображениям для рецептурного подбора».

И.И. Фролов

Окончил Белорусский государственный университет информатики и радиоэлектроники. Доцент кафедры электронных вычислительных машин БГУИР. Проводит научные исследования в области машинного обучения и компьютерного зрения, участвует в проектировании и разработке систем технического зрения.

Аннотация. Проведен комплексный анализ влияния параметров входных изображений на качество классификации изображений продуктов питания с использованием разных моделей нейронных сетей. Описаны основные этапы подготовки изображений, включая изменение разрешения, добавление гауссовского шума и изменение средней яркости. Проведены эксперименты с различными параметрами входных изображений для оценки их влияния на точность классификации.

Ключевые слова: обработка изображений, машинное обучение, нейронные сети, классификация продуктов, качество классификации, параметры входных данных.

Введение. Автоматизированная классификация продуктов питания на основе изображений играет важную роль в ряде приложений, включая системы самообслуживания, контроль качества продукции, управление запасами и персонализированные рекомендации. Однако качество классификации во многом зависит от характеристик входных данных [1]. В реальных условиях съёмки изображения могут содержать шумы, варьироваться по разрешению и освещённости, что потенциально снижает эффективность работы нейросетевых моделей, а влияние таких искажений на классификацию часто остаётся недостаточно изученным.

В данном исследовании анализируется, как изменение разрешения, добавление гауссовского шума и коррекция средней яркости изображений влияют на точность работы модели. Эти параметры выбраны, поскольку они моделируют распространённые искажения, возникающие в процессе сбора данных. Полученные результаты позволяют количественно оценить степень деградации классификации и определить, насколько устойчивы современные модели к данным изменениям.

Практическая значимость исследования заключается в возможности учитывать влияние подобных факторов при подготовке обучающих выборок, разработке методов предобработки изображений и создании моделей, менее чувствительных к изменению входных данных. Это особенно важно для автоматизированных систем, где невозможно контролировать условия съёмки, но требуется высокая точность классификации.

Цель исследования. Целью проведения исследования является оценка влияния различных характеристик входных изображений на эффективность и точность классификации продуктов в автоматизированной системе анализа изображений продуктов. Эксперимент направлен на выявление ключевых факторов, оказывающих наибольшее влияние на производительность моделей классификации, с последующей настройкой системы для оптимальных условий работы.

Проведено 8 отдельных экспериментов, каждый из которых сосредоточен на одном типе продукта. Это позволяет изолировать влияние исключительно параметров изображений, исключая дополнительные переменные, связанные с различиями между продуктами. Такой подход обеспечивает точные и репрезентативные результаты, поскольку в каждом эксперименте будут варьироваться только параметры входных изображений при неизменном объекте классификации.

Для анализа будут использованы три различных архитектуры нейронных сетей для обнаружения объектов (object detection), что позволит оценить, как изменения параметров изображений влияют на результаты классификации на разных моделях. Каждая модель получает одинаковые изображения с одинаковыми параметрами, что позволит более полно исследовать воздействие характеристик изображений на точность классификации, а также поможет определить оптимальные условия для работы системы в реальных сценариях. Однако сравнение самих алгоритмов не является целью исследования – основное внимание сосредоточено на анализе параметров изображений, оказывающих влияние на результаты классификации.

Кроме того, исследование позволит оценить устойчивость моделей к различным условиям съёмки изображений, таким как шумы, изменения яркости и качество. Результаты помогут в дальнейшей оптимизации автоматизированных систем анализа изображений, а также могут быть полезными для практического применения в области распознавания и классификации изображений продуктов питания в реальных условиях.

Описание исследования. В рамках эксперимента будут исследоваться три ключевых фактора, влияющих на качество классификации изображений:

1 *Разрешение изображений.* Позволяет оценить, насколько детализация изображения влияет на точность классификации. В рамках эксперимента будут рассмотрены три уровня разрешения: 128×128, 256×256, 512×512 пикселей.

2 *Гауссовский шум (стандартное отклонение шума).* Исследуется влияние добавления случайных вариаций пикселей на способность модели классифицировать объекты. Гауссовский шум был выбран для моделирования реальных искажений изображений, так как он имитирует случайные вариации пикселей, характерные для условий съёмки, например, из-за недостаточной освещенности или качества сенсоров камеры. Для этого используются три уровня шума, заданные стандартным отклонением (σ): 0 (без шума), 30 (умеренный шум), 60 (высокий шум).

3 *Освещенность изображения (средний уровень яркости).* Влияет на способность модели распознавать объекты при разной интенсивности освещения. В качестве исследуемых значений примем три уровня яркости, измеряемые в среднем значении интенсивности пикселей (от 0 до 255 в 8-битном представлении): 30 (тёмное изображение), 130 (естественное освещение), 210 (очень яркое изображение).

Для исследования влияния параметров изображений на качество классификации будут использованы три нейросетевых модели. Использование нескольких алгоритмов

позволит нивелировать зависимость результатов от специфики одной конкретной модели и выявить универсальные закономерности, влияющие на качество классификации. Модели, применяемые в эксперименте:

1 YOLOv8 (You Only Look Once) – модель для детекции объектов в реальном времени, использующая подход одноэтапной обработки [2]. YOLO делит изображение на сетку и прогнозирует координаты объектов и классы объектов для каждого сегмента. Особенностью модели является высокая скорость работы при относительно хорошем качестве детекции, что делает ее популярной для задач, требующих быстрой обработки.

2 DETR (DEtection TRansformer) – трансформер-архитектура, разработанная Facebook [3]. DETR применяет трансформеры для обработки изображений и выявления объектов без необходимости в традиционных этапах постобработки, таких как non-maximum suppression (NMS). Это позволяет модели быть более гибкой и эффективной в сложных сценах с множеством объектов и разнообразными контекстами, но может иметь большую вычислительную нагрузку по сравнению с более традиционными методами.

3 RetinaNet – модель, основанная на архитектуре ResNet-50 с использованием Feature Pyramid Networks (FPN) для улучшенной обработки признаков на разных уровнях масштаба [4]. RetinaNet использует механизм потерь focal loss, который помогает бороться с дисбалансом между большим количеством фонов и меньшим количеством объектов на изображении. Эта модель подходит для детекции объектов в условиях, когда важно правильно классифицировать малые или трудные для распознавания объекты.

Эксперимент будет проводиться с использованием 8 различных изображений (рис. 1) для каждой комбинации факторов.



Рисунок 1. Изображения для исследования

Это позволит учесть естественную вариативность данных и рассчитать усреднённые показатели качества классификации, минимизируя влияние случайных факторов. Для большего разнообразия в эксперимент были выбраны 5 изображений обычных продуктов и 3 изображения готовых блюд. Такой выбор обеспечит более определённую картину, отражающую как распознавание простых объектов, так и сложных составных объектов.

Изображения были выбраны высокого качества, с равными размерами по высоте и ширине (1000×1000 пикселей), чтобы исключить влияние исходного разрешения на результат. Эти изображения были выбраны, поскольку на них все модели в первоначальной обработке продемонстрировали отличные результаты, с вероятностью предсказания объектов более 75%.

На изображениях, где присутствуют несколько одинаковых объектов, будет учитываться только наиболее уверенное предсказание модели, класс которого совпадает с ожидаемым. В случае нескольких объектов одного типа выбирается тот, у которого вероятность предсказания наиболее высока.

Ниже приводится диаграмма предсказания моделей без предварительной обработки исходных изображений:




Рисунок 2. Результаты экспериментов для исходных изображений разрешением 1000×1000

Для каждой из моделей (YOLOv8, DETR и RetinaNet) использовались предобученные веса, что позволило сразу приступить к оценке их работы без необходимости в проведении нескольких итераций на одном изображении. Это значительно ускоряет процесс тестирования и исключает дополнительную тренировку моделей для конкретного эксперимента.

Изменение разрешения изображения. Для изменения разрешения изображений использовалась библиотека PIL (Python Imaging Library). Каждое изображение было масштабировано до трёх заранее заданных разрешений: 128×128, 256×256 и 512×512 пикселей. Масштабирование выполнялось с помощью метода *resize()* из PIL, который изменяет размер изображения до целевого, сохраняя пропорции. Все изображения имели одинаковые размеры в пикселях, что обеспечивало их единообразную обработку в ходе эксперимента.

Изменение средней яркости изображения. Для изменения яркости изображений в эксперименте использовался метод коррекции с помощью библиотеки PIL (Python Imaging Library). Яркость изображения оценивалась как среднее значение интенсивности пикселей, вычисляемое по всем цветовым каналам (RGB). Для этого изображение сначала преобразовывалось в массив данных с помощью библиотеки NumPy, и затем рассчитывалась средняя яркость всех пикселей. После этого применялась коррекция яркости с целью достижения заданного значения.

Для каждого изображения был выбран целевой уровень яркости (30, 130 или 210), который представлял собой соответствующие уровни: тёмное изображение, естественное освещение и яркое изображение. Чтобы привести изображение к заданной яркости, рассчитывался коэффициент коррекции, который представлял собой отношение целевой яркости к текущей средней яркости изображения. Этот коэффициент использовался для масштабирования исходного изображения с помощью метода *ImageEnhance.Brightness()*, что позволяло изменить яркость изображения на нужный уровень. Таким образом, изображения были приведены к заданной яркости, при этом сохранялась естественная цветовая насыщенность.

Наложение гауссовского шума. Для наложения гауссовского шума на изображения использовалась библиотека NumPy для работы с массивами данных и PIL для работы с изображениями. Сначала изображение было загружено с помощью библиотеки PIL, и оно преобразовывалось в массив с помощью *np.array()* с типом данных *np.float32* для точности операций. Затем для каждого пикселя изображения генерировался гауссовский шум с помощью функции *np.random.normal()*, где в качестве параметров задавались: среднее значение шума (0) и стандартное отклонение (σ), которое определяет интенсивность шума. Этот шум добавлялся к исходному массиву изображения для всех трех цветовых каналов (красного, зеленого и синего), что приводило к изменению цветовых значений пикселей.

После добавления шума, чтобы избежать выхода значений за пределы допустимого диапазона [0, 255] для изображений в формате RGB, использовалась функция *np.clip()*,

которая ограничивает значения в пределах этого диапазона. Далее массив преобразовывался обратно в изображение с помощью функции *Image.fromarray()*, и результат сохранялся как новое изображение.

Пример измененных изображений представлен на рисунке 2. На картинке слева – изображение размером 512×512 с средней яркостью пикселей 30 и отклонением гауссовского шума равным 30, по центру – изображение размером 512×512 с средней яркостью пикселей 130 и отклонением гауссовского шума равным 60, справа – изображение размером 512×512 с средней яркостью пикселей 210 и отклонением гауссовского шума равным 0.




Рисунок 3. Пример обработанных входных изображений

Применение моделей для детекции объектов. Для детекции объектов использовались три модели с предобученными весами:

1 YOLOv8. Модель была загружена через библиотеку Ultralytics YOLO с использованием предобученных весов *yolov8n.pt*. Для обработки изображений использовалась функция *show()*, которая отображала детектированные объекты с рамками и текстовыми метками.

2 DETR. Модель загружена через библиотеку Transformers с использованием предобученных весов *facebook/detr-resnet-50*. Для предсказания использовались тензоры PyTorch [5], а выходные данные модели использовались для дальнейшей обработки и получения ограничивающих рамок объектов на изображениях.

3 RetinaNet. Модель была загружена с предобученными весами *RetinaNet_ResNet50_FPN_Weights.DEFAULT* через библиотеку TorchVision. Эти веса были обучены на наборе данных COCO и содержат информацию о категориях объектов, что позволяет модели классифицировать и локализовать объекты на изображениях.

Результаты проведения исследования. В таблице приведены результаты тестирования трех моделей детекции объектов на изображениях с различными параметрами. В столбце 6 указаны значения предсказаний моделей для 8 изображений, расположенных в том же порядке, как на рисунке 1. Процентные значения в этом столбце отражают степень успешности детекции объектов для каждого изображения. В случае, если модель не распознала объект, указано значение 0%.

Разрешение	h	w	h>256	Модель	Яблоко	Банан	Бутылка	Корзина	Печенье	Полка	Тарелка
128*128	0	30	DETR	1	0.99	0.98	0	0	0.94	0	0
128*128	0	130	DETR	0.99	0.99	0.96	0.98	0.99	0.99	1	0
128*128	0	210	DETR	0.94	0.91	0.97	0.98	1	0.99	1	0.84
128*128	30	30	DETR	0	0	0.9	0	0	0	0	0
128*128	30	130	DETR	0	0.72	0.98	0.81	0	0.95	0	0
128*128	30	210	DETR	0	0.9	0.98	0	0	0.83	0	0
128*128	60	30	DETR	0	0	0	0	0	0	0	0
128*128	60	130	DETR	0	0	0	0	0	0	0	0
128*128	60	210	DETR	0	0	0	0	0	0	0	0
128*128	0	30	RetinaNet	0.7	0.47	0.78	0.06	0.13	0.82	0.31	0.05
128*128	0	130	RetinaNet	0.87	0.7	0.98	0.76	0.56	0.81	0.71	0.13
128*128	0	210	RetinaNet	0.96	0.72	0.79	0.34	0.79	0.76	0.73	0.26
128*128	30	30	RetinaNet	0.09	0.21	0.13	0	0.07	0.17	0.12	0
128*128	30	130	RetinaNet	0.12	0.61	0.44	0.25	0.61	0.74	0.37	0
128*128	30	210	RetinaNet	0.2	0.59	0.58	0.07	0.66	0.66	0.4	0
128*128	60	30	RetinaNet	0.09	0	0	0	0	0	0	0
128*128	60	130	RetinaNet	0.06	0.28	0	0	0	0	0	0
128*128	60	210	RetinaNet	0	0.4	0.15	0	0	0	0	0
128*128	0	30	YOLOv8	0	0	0.93	0	0	0.61	0	0
128*128	0	130	YOLOv8	0.63	0.81	0.66	0.36	0	0.7	0.39	0
128*128	0	210	YOLOv8	0	0.75	0.64	0	0	0.42	0.76	0
128*128	30	30	YOLOv8	0	0	0	0	0	0	0	0
128*128	30	130	YOLOv8	0	0	0	0	0	0	0	0
128*128	30	210	YOLOv8	0	0	0	0	0	0	0	0
128*128	60	30	YOLOv8	0	0	0	0	0	0	0	0
128*128	60	130	YOLOv8	0	0	0	0	0	0	0	0
128*128	60	210	YOLOv8	0	0	0	0	0	0	0	0

Рисунок 4. Результаты экспериментов для изображений с разрешением 128×128

		Средняя яркость											
Разрешение	σ	Модель	Яблоко	Апельсин	Банан	Морковь	Брокколи	Пилецца	Помидор	Торт			
256×256	0	30 YOLOv8	0.9	0.53	0.72	0.61	0	0.9	0	0			
256×256	0	30 DETR	1	1	0.98	0.94	0	0.98	0	0			
256×256	0	30 RetinaNet	0.84	0.68	0.82	0.18	0.2	0.85	0.33	0.25			
256×256	0	130 YOLOv8	0.94	0.83	0.87	0.89	0.72	0.85	0.54	0.61			
256×256	0	130 DETR	0.98	0.97	0.97	0.99	1	1	0.99	0.98			
256×256	0	130 RetinaNet	0.88	0.82	0.89	0.89	0.87	0.85	0.9	0.71			
256×256	0	210 YOLOv8	0.93	0.86	0.71	0.41	0.74	0.8	0.85	0.32			
256×256	0	210 DETR	1	0.99	0.98	0.98	1	1	0.98	0.68			
256×256	0	210 RetinaNet	0.89	0.78	0.83	0.74	0.87	0.75	0.92	0.33			
256×256	30	30 YOLOv8	0	0	0	0	0	0	0	0			
256×256	30	30 DETR	1	0.99	1	0	0	0	0	0			
256×256	30	30 RetinaNet	0.56	0.59	0.6	0.08	0.07	0.49	0.33	0.1			
256×256	30	130 YOLOv8	0	0	0.6	0	0	0.5	0.31	0			
256×256	30	130 DETR	1	0.99	0.99	0.87	0.99	1	1	0			
256×256	30	130 RetinaNet	0.56	0.69	0.83	0.46	0.73	0.8	0.75	0.15			
256×256	30	210 YOLOv8	0	0	0.83	0	0	0.39	0	0			
256×256	30	210 DETR	0.98	0.94	0.96	0	0.6	0	0	0.83			
256×256	30	210 RetinaNet	0.29	0.71	0.82	0.07	0.61	0.48	0.67	0.17			
256×256	60	30 YOLOv8	0	0	0	0	0	0	0	0			
256×256	60	30 DETR	0	0	0.98	0	0	0	0	0			
256×256	60	30 RetinaNet	0.16	0.47	0.23	0	0	0.34	0.25	0			
256×256	60	130 YOLOv8	0	0	0	0	0	0	0	0			
256×256	60	130 DETR	0	0.98	0.98	0	0	0	0	0			
256×256	60	130 RetinaNet	0.12	0.42	0.26	0.09	0.13	0.14	0.16	0.1			
256×256	60	210 YOLOv8	0	0	0	0	0	0	0	0			
256×256	60	210 DETR	0	0.99	0.91	0	0	0	0	0			
256×256	60	210 RetinaNet	0.14	0.52	0.42	0	0.06	0.25	0.06	0.08			

Рисунок 5. Результаты экспериментов для изображений с разрешением 256×256

		Средняя яркость											
Разрешение	σ	Модель	Яблоко	Апельсин	Банан	Морковь	Брокколи	Пилецца	Помидор	Торт			
512×512	0	30 YOLOv8	0.92	0.69	0.65	0.89	0.64	0.85	0	0.64			
512×512	0	30 DETR	1	0.99	0.96	0.96	1	1	0	0			
512×512	0	30 RetinaNet	0.82	0.69	0.89	0.55	0.68	0.89	0.5	0.38			
512×512	0	130 YOLOv8	0.93	0.89	0.72	0.88	0.66	0.87	0.87	0.7			
512×512	0	130 DETR	1	0.93	0.96	0.99	1	1	1	1			
512×512	0	130 RetinaNet	0.84	0.82	0.88	0.88	0.84	0.87	0.92	0.68			
512×512	0	210 YOLOv8	0.93	0.87	0.75	0.78	0.74	0.8	0.94	0.52			
512×512	0	210 DETR	1	0.98	0.98	1	1	1	1	0.96			
512×512	0	210 RetinaNet	0.86	0.77	0.87	0.68	0.88	0.84	0.92	0.44			
512×512	30	30 YOLOv8	0.73	0.49	0.61	0.26	0.4	0.85	0	0			
512×512	30	30 DETR	1	1	0.98	0.54	0.99	1	0	0			
512×512	30	30 RetinaNet	0.67	0.62	0.86	0.14	0.45	0.87	0.31	0.1			
512×512	30	130 YOLOv8	0.54	0.62	0.79	0.7	0.74	0.75	0.45	0			
512×512	30	130 DETR	1	0.94	0.98	0	0.94	1	1	0.86			
512×512	30	130 RetinaNet	0.84	0.71	0.86	0.6	0.81	0.89	0.88	0.22			
512×512	30	210 YOLOv8	0.31	0.72	0.83	0	0.26	0.78	0.8	0			
512×512	30	210 DETR	1	0.94	0.98	0	0.9	0.96	1	0.89			
512×512	30	210 RetinaNet	0.76	0.73	0.84	0.09	0.63	0.76	0.8	0.2			
512×512	60	30 YOLOv8	0	0	0	0	0	0.33	0	0			
512×512	60	30 DETR	0.93	0.97	1	0	0	0.97	0	0			
512×512	60	30 RetinaNet	0.51	0.54	0.73	0.07	0.07	0.42	0.27	0.08			
512×512	60	130 YOLOv8	0	0	0	0.26	0	0	0	0			
512×512	60	130 DETR	0	0.93	1	0	0.66	0	0.92	0			
512×512	60	130 RetinaNet	0.43	0.58	0.8	0.13	0.65	0.35	0.57	0.12			
512×512	60	210 YOLOv8	0	0	0	0	0.31	0	0	0			
512×512	60	210 DETR	0	0.96	1	0	0	0	0.99	0.97			
512×512	60	210 RetinaNet	0.29	0.58	0.61	0.08	0.52	0.31	0.55	0.07			

Рисунок 6. Результаты экспериментов для изображений с разрешением 512×512

Выводы. На основе полученных данных из таблицы 1 можно сделать выводы о влиянии различных параметров изображений на эффективность классификации продуктов. Эксперимент проводился с учетом нескольких факторов, включая разрешение изображения, уровень шума и освещенность, которые имели заметное влияние на результаты работы моделей.

1 *Влияние разрешения изображения.* Модели показали улучшение результатов с повышением разрешения, что указывает на важность высококачественных изображений для точной классификации продуктов. Однако стоит отметить, что подача сверхвысококачественных изображений не всегда оправдана с точки зрения вычислительных ресурсов.

2 *Влияние шума.* Все модели показали снижение точности классификации при увеличении уровня шума в изображениях. Особенно это было заметно для модели YOLOv8, которая показала значительное падение точности при сильном уровне шума ($\sigma = 60$). Модели DETR и RetinaNet оказались более устойчивыми к шуму, сохраняя более высокие значения точности даже при сильных искажениях изображения. Это указывает на то, что некоторые модели могут быть более подвержены шуму, в то время как другие лучше справляются с его присутствием в данных.

3 *Влияние освещенности.* Освещенность изображений также оказала влияние на точность классификации, причем эффект был различен для каждой модели. Модели продемонстрировали разные уровни точности в зависимости от изменений освещенности, где в некоторых случаях повышение яркости способствовало улучшению точности (например, для модели DETR), в то время как другие модели (например, RetinaNet) показали стабильность даже при изменении яркости. Это может свидетельствовать о том,

что оптимизация под изменения освещенности также важна для достижения высоких показателей классификации, но должна быть адаптирована под конкретную модель.

Хотя основная цель эксперимента не заключалась в сравнении моделей, можно отметить, что модель DETR показала наибольшую устойчивость к изменениям освещенности и шума, достигая лучших результатов на части изображений с низким качеством. Модель YOLOv8, в свою очередь, продемонстрировала высокую точность на изображениях с высоким разрешением, но была более чувствительна к шуму.

Список литературы

- [1] Dodge S., Karam L. Understanding how image quality affects deep neural networks. 2016 Eighth International Conference on Quality of Multimedia Experience (QoMEX). 2016; 1-6. DOI: 10.1109/QoMEX.2016.7498955.
- [2] Mupparaju S., Thotakura S. R., Ch. V. R. Reddy. A Review on YOLOv8 and Its Advancements. Cryptology and Network Security with Machine Learning. 2024; 529-545. DOI: 10.1007/978-981-99-7962-2_39.
- [3] Carion N., Massa F., Synnaeve G., Usunier N. End-to-End Object Detection with Transformers. In: Computer Vision – ECCV 2020, 16th European Conference, Glasgow, UK, August 23–28, 2020, Proceedings, Part I. Lecture Notes in Computer Science. 2020; 213-229. DOI: 10.1007/978-3-030-58452-8_13.
- [4] Al-Hasanat M., Alsafasfeh M., Alhasanat A., Althunibat S. RetinaNet-Based Approach for Object Detection and Distance Estimation in an Image. International Journal on Communications Antenna and Propagation (IRECAP). 2021; 11(1):19. DOI: 10.15866/irecap.v11i1.19341.
- [5] Фролов, И. И. Эффективные библиотеки машинного обучения / И. И. Фролов // Технические средства защиты информации : тезисы докладов XVI Белорусско-российской научно – технической конференции, Минск, 5 июня 2018 г. – Минск: БГУИР, 2017. – С. 94.

Авторский вклад

Деркач Анжелика Валерьевна – проведение исследования, анализ результатов исследования, формирование структуры статьи.

Фролов Игорь Иванович – руководство исследованием, рецензирование статьи.

INVESTIGATION OF THE INFLUENCE OF INPUT IMAGE PARAMETERS ON PRODUCT CLASSIFICATION

A.V. Dziarkach

*Master's student of the Department
of Electronic Computing Machines
of BSUIR*

I.I. Frolov

*Associate Professor of the
Department of Electronic
Computing Machines of BSUIR,
PhD of Technical Sciences,
Associate Professor*

Abstract. A comprehensive analysis of the influence of input image parameters on the quality of food classification using different neural network models has been carried out. The main stages of image preparation are highlighted, including changing the resolution, adding Gaussian noise, and changing the average brightness. Experiments have been conducted with various parameters of the input images to assess their effect on classification accuracy.

Keywords: image processing, machine learning, neural networks, product classification, classification quality, input data parameters.