



УДК 656.7

МРНТИ 73.37.17

[https://doi.org/10.53364/24138614\\_2025\\_39\\_4\\_2](https://doi.org/10.53364/24138614_2025_39_4_2)

К.Т. Кошеков<sup>1</sup>, К. Б. Алдамжаров<sup>1</sup>, Я. М. Курбанов<sup>1</sup>, В.М. Курбанов<sup>1</sup>

<sup>1</sup>АО «Академия Гражданской Авиации», Республика Казахстан, город Алматы,

\*E-mail: [kurbanov\\_yakub@list.ru](mailto:kurbanov_yakub@list.ru)

## АНАЛИЗ ВЛИЯНИЯ КАЧЕСТВА ДАННЫХ ОБУЧЕНИЯ НЕЙРОННЫХ СЕТЕЙ И ИСКУССТВЕННОГО ИНТЕЛЛЕКТА НА БЕЗОПАСНОСТЬ ПОЛЕТОВ

***Аннотация.** Цель исследования изучить влияние качества данных, сопряженных с ним факторов и формализовать логические и математические связи между аргументами функции обучения нейронной сети или искусственного интеллекта для демонстрации взаимосвязи с безопасностью полетов.*

*Для достижения цели необходимо решить следующие задачи. Первое - оценить текущее состояние вопроса применения искусственного интеллекта в процедурах предполетного осмотра, а также ремонта и технического обслуживания воздушного судна. Это необходимо для определения уровня технологической интеграции нейронных сетей и искусственного интеллекта. Второе - на основе полученных данных необходимо определить актуальные платформы для обучения искусственного интеллекта. Это позволит определить дополнительные технические аргументы, влияющие на конечный результат обучения искусственного интеллекта. Третье - формализовать логико-математическую связь между влияющими факторами и конечным результатом. Определить дополнительные влияющие факторы и также формализовать. Формальный способ записи позволяет строить процедурно-последовательную линию связи для мониторинга рисков в отношении безопасности полетов.*

*Для решения задач применялись следующие методы. Метод наблюдения, который был применен по отношению информации, которая была собрана в ходе отслеживания хронологии применения различных автоматизированных технологий оптического обнаружения неисправностей. Декомпозиция, которая позволила отделить от комплексной технологии функциональную часть компьютерной программы, которая определяет неисправности. Сравнительный анализ, который позволил определить сильные и слабые стороны различных нейронных сетей и архитектур технических систем для этих нейронных сетей и искусственного интеллекта Математический анализ, который позволяет формализовать выражения, характеризующие влияние аргументов комплексной функции и определить аддитивность и мультипликативность комплексной функции. Диверсионный и функциональный анализы, которые позволяют определить взаимосвязи между аргументами комплексных функций и конечной комплексной функции безопасности полетов.*

*В результате были представлены выражения, которые отражают логико-математическую связь в функционально-последовательной передаточной линии связи от аргументов нейронной сети и искусственного интеллекта до комплексного показателя безопасности полетов.*

**Ключевые слова:** *искусственный интеллект, нейронные сети, предполетный осмотр, модели искусственного интеллекта, сравнительный анализ, безопасность полетов.*

### **Введение.**

*Оценка текущего состояния.* В настоящее время авиационная индустрия является самой нагруженной по отношению к затратам человеческого капитала. С целью рационализации затрат человеческого капитала авиакомпания компания KLM начала применение дронов и искусственного интеллекта в предполетном осмотре. В рамках эксперимента, начавшегося в 2015 году, были получены следующие достижения: автоматический предполетный осмотр и построение трехмерного цифрового двойника. Компания Mainblades планирует внедрение искусственного интеллекта в процесс предполетного осмотра для обнаружения неисправностей воздушного судна [1, 2].

Аналогичную технологию разработала авиакомпания Korean Air. Авиакомпания применила группу беспилотных летательных аппаратов с дистанционным управлением для выполнения предполетного осмотра. В отличие от эксперимента партнерства KLM и в партнерстве с Mainblades дроны были применены только для оптического обнаружения неисправностей. Однако результат применения сократил время процедуры предполетного осмотра на 60% [3].

*Цель исследования.* Рассматривая описанный опыт авиакомпаний необходимо отметить факт внедрения средств автоматизации, в частности искусственного интеллекта. Искусственный интеллект в настоящее время представляет из себя программное обеспечение, которое решает параметрическую задачу, где количество параметров достигает 1,8 триллионов [4]. Несмотря на то, что большинство моделей искусственного интеллекта являются открытыми и доступны для скачивания и обучения, коммерческие обученные модели являются закрытыми, что в свою очередь не позволяет обеспечить прозрачность процесса применения коммерческих моделей, а также не позволяет определить весовые коэффициенты всех этих параметров, которые оказывают влияние на конечный результат, выдаваемый этой моделью.

Исходя из описанного целью исследования становится разработка предложения по снижению уровня риска, связанного с качеством данных и возникающего при применении искусственного интеллекта в процедурах предполетного осмотра.

*Задачи исследования.* Для достижения цели необходимо решить следующие задачи с применением соответствующих методов. Провести аналитическую работу с применением следующих методов. Сравнительный анализ закрытых и открытых моделей искусственного интеллекта. Позволяет определить уровень технологического совершенства той или иной доступной для исследовательских целей моделей. Позволит определить перспективу применения каждой изученной модели в рамках объективизации и автоматизации предполетного осмотра. Структурный анализ автоматизированной техногенной системы позволяет выделить структурную взаимосвязь элементов в рамках комплексной системы предполетного осмотра. Функциональный анализ, позволяет определить функциональную взаимосвязь между структурными элементами, а также отследить движение данных между структурными элементами. При появлении сбоев в системе, позволит определить уязвимые элементы системы в ходе работы. Анализ производственных рисков применения техногенной системы с искусственным интеллектом позволяет определить наиболее критические уязвимости в применении автоматизированной системы. Что позволит в перспективе разработать меры по снижению рисков, связанных с применением техногенной системы. Синтез рекомендаций по безопасности на основе выявленных рисков, преимуществ и недостатков позволяет определить основные направления по проведению глубоких исследований и разработке рекомендаций по безопасной эксплуатации автоматизированной системы предполетного осмотра.

### Материалы и методы исследования.

Для того, чтоб провести сравнительный анализ применения между открытой и закрытой моделями искусственного интеллекта, изучим жизненный цикл искусственного интеллекта на примере YOLO, которая является доступной и применяется в различных секторах компьютерного зрения, в том числе может применяться в предполетном осмотре. В настоящее время в АО «Академия Гражданской Авиации» уже выполнено экспериментальное обучение модели YOLO версии пакета «n» для выполнения предполетного осмотра. Также обучение ведется на платформе Roboflow, которая имеет одноименную модель — Roboflow.

В отличие от YOLO модель Roboflow имеет частично закрытую архитектуру, которую можно задействовать для корректировки уже обученной модели или модели YOLO. Предварительный набор обучающих данных содержит в себе 234 изображения, распределенных на три ветви: обучающие данные, валидационные данные и подтверждающие данные. Всего было определено 14 классов объектов для обнаружения. Как видно на рисунке 1, модель Roboflow 3 оказалась более точной.

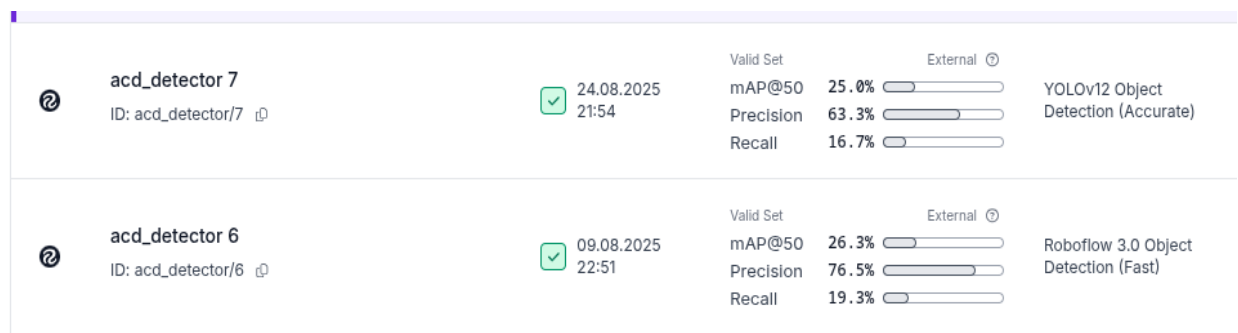


Рисунок 1 — Точность (precision) моделей компьютерного зрения

При этом даже были приняты соответствующие меры по выбору режима обучения. Как показал эксперимент, закрытая архитектура вероятно содержит дополнительную аргументацию в математических моделях, которая способствует повышению точности прогнозирования модели компьютерного зрения даже в режиме быстрого обучения по отношению к открытой архитектуре YOLO 12, в режиме повышенной точности.

Стоит отметить, что объем данных не является исчерпывающим и не содержит достаточно материалов для обучения высокоточной модели. Также одним из ключевых моментов обучения модели является качество данных. Качество данных напрямую зависит от разрешения фотографий. Кроме этого, также угол съемки влияет на качество изображения искомого объекта на снимке. Таким образом формируется перечень факторов, объективно влияющих на качество обучения модели. Запишем как функцию:

$$F = f(P_{res} \times P_{ang} \times P_{rep} \times P_{det}) \quad (1)$$

где  $F$  - комплексная параметрическая математическая функция, характеризующая влияние факторов на обучение модели;

$P_{res}$  - аргумент комплексной математической функции, определяющий влияние разрешения на обучение модели;

$P_{ang}$  - аргумент комплексной математической функции, определяющий влияние угла съемки на обучение модели;

$P_{rep}$  - аргумент комплексной математической функции, определяющий влияние повторяемости объекта в наборе данных на обучение модели;

$P_{det}$  - аргумент комплексной математической функции, определяющий влияние детализации изображения искомого объекта на обучение модели.

В рамках рассматриваемого контекста аргументов справедливо изучить метрики, предоставляемые программными средами обучения моделей и выделить ключевые характеристики.

Для начала на рисунке 2 представим графы метрик обучения модели Roboflow 3




Рисунок 2 — График метрик точности обученной модели Roboflow

График точности синим цветом указывает фактические результаты для каждой из 234 итераций по оси X и вероятности определения объекта по оси Y. Результирующий график составляет некоторое поле значений, большая часть которых находится в промежутке от 0,5 до 0,8. Пунктирной линией указано сглаженное значение параметра точности, которое находится в промежутке между 0,6 и 0,8. Однако стоит отметить, что пиковая точность значений находится до итерации изображений с номером 100. На итерации в промежутке между 100 и 200 выделяется сильный провал. Этот провал характеризует низкое качество обучения, что в первую очередь связано с низким качеством обучающих материалов. Основанием для этого утверждения является предшествующий опыт обучения этой модели, результаты которой были равны значениям, приведенным на рисунке 3. Ключевым негативным аргументом является сама классификация, так как были указаны только классы повреждений. В более новых версиях применялась более строгая классификация, которая включает в себя часть конструкции самолета и тип повреждения, что существенно позволило сократить математические погрешности в метрике точности по отношению к видам повреждения для некоторых отдельных классов искомого объектов. Прибегая к более жесткой системе классификации повреждений можно повысить результативность модели.




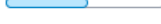
	<b>ac_damage_detector 5</b> ID: ac_damage_detector/5 	 10.02.2025 18:32	mAP@50 13.3%  Precision 31.1%  Recall 9.0% 	Roboflow 3.0 Instance Segmentation (Fast)
	<b>ac_damage_detector 4</b> ID: ac_damage_detector/4 	 08.02.2025 01:12	mAP@50 20.9%  Precision 43.4%  Recall 21.5% 	Roboflow 3.0 Instance Segmentation (Fast)
	<b>ac_damage_detector 1</b> ID: ac_damage_detector/1 	 07.02.2025 16:23	mAP@50 32.2%  Precision 51.3%  Recall 36.3% 	Roboflow 3.0 Instance Segmentation (Fast)

Рисунок 3 — Значения точности (precision) предшествующих моделей

Ниже приведем формулы для предыдущей и актуальной версий классификации объектов для обучения модели.

$$D_{type} \Rightarrow C_{co} \quad (2)$$

где  $C_{co}$  - предшествующее множества классов объектов;

$D_{type}$  - класс типа повреждений воздушного судна.

$$D_{type} \cup D_{place} \Rightarrow C_{cn} \quad (3)$$

где  $C_{cn}$  - актуальное множество классов объектов;

$D_{place}$  - расположение повреждений на воздушном судне.

Если в первом случае мы получаем линейную функцию вида  $y = x$ , то во втором случае вид функции преобразовывается в  $y = x_1 \times x_2$ . Даже в таком редуцированном виде можно понять, что классификация объектов может быть расширена за счет факторов, приведенных в первой формуле. В конечном итоге множество классов будет увеличиваться. В конечном виде мы будем иметь формулу следующего вида:

$$C_{ca} = f(\sum_1^n X_1 + \dots + \sum_1^n X_m) \quad (4)$$

где  $C_{ca}$  - множество классов;

$X$  - класс искомого объекта;

$n$  - количество значений, которые могут принять классы, для каждого класса определяется индивидуально;

$m$  - количество учитываемых классов.

Проанализируем возможность ограничения количества аргументов и их значений для сокращения значения аргументов, которые могут потребовать дополнительной вычислительной мощности и затянуть обучение модели. К текущему моменту получено шесть аргументов: разрешение, угол съемки, повторяемость, детализация, тип, расположение. Фактически приведенные аргументы математически ограничиваются только тем, что их значения принадлежат множеству позитивных рациональных и целых чисел.

Исходя из сказанного получается, что фактически множество аргументов и принимаемых значений может быть бесконечным в рамках математического выражения, однако в рамках действующей практики и приведенной аргументации нет технической потребности в увеличении сложности математической функции аргументации качества обучения от качества данных. Перечисленные шесть аргументов способствуют качественному распределению данных, что в конечном итоге позволяет повысить уровень точности конечной модели, которая будет обучена при помощи этих данных.

Теперь, после вывода общей гипотезы о влиянии качества данных на обучение, перейдем к рассмотрению модели YOLO 12 версии пакета «n».




Рисунок 4 — График метрик точности обученной модели YOLO 12 n

График итераций (OX) имеет широкий разброс данных по вероятности распознавания объекта (OY), преимущественно в диапазоне от 0,2 до 0,8. Сглаживающая характеристика оранжевым пунктиром расположена преимущественно в диапазоне от 0,5 до 0,7. Если сравнивать с моделью Roboflow то разброс показателей значительно больше, что в конечном итоге демонстрирует не достаточную точность в обучении модели, это может демонстрировать низкую аргументации в отношении математического приближения. Однако стоит упомянуть, что все настройки для модели YOLO использованы по умолчанию и не содержат дополнительной математической аргументации, в виде настройки разрешения, изменения количества циклов, преобразования изображений и иное, что может оказать влияние.

Теперь рассмотрим дополнительные факторы, которые могут оказать влияние, но в этом случае не проявились, так как не были связаны. Так как в настоящее время в области искусственного интеллекта, который задействован в графической обработке, лидирующие позиции занимает компания nvidia, то отметим, что пакет программного обеспечения cuda не был задействован, вместо этого были задействованы вычислительные мощности профессором сервиса Roboflow. Для обучения были задействованы процессоры Jetson Orin NX [5]. С учетом этого рассмотрим факт того, что значительная часть программного обеспечения, в том числе и нейросетей и искусственного интеллекта разрабатывается на процессорах с архитектурой x64 от AMD и Intel, а также ARM от nvidia. При этом каждый процессор имеет собственный набор инструкций к выполнению программ [6, 7, 8].

Одно и тоже программное обеспечение может иметь разную скорость выполнения на разных процессорах. Таким образом получается, что одна и также модель будет иметь разную скорость выполнения, однако если скорость выполнения влияет только на время обучения, то еще стоит вспомнить, что разные процессоры имеют разные наборы инструкций по выполнению кода, тем самым качество обучения может измениться в зависимости от набора инструкций, которые применяются в процессоре. Инструкции,

поддерживаемые процессором на прямую, определяют способ процессорных вычислений, там самым регламентируют вектор направленности вычислений и степень точности вычислений.

Исходя из этого предположения также стоит отметить, что, будучи лидером в вычислениях нейронных сетей и искусственного интеллекта и применяя архитектуру ARM компания NVIDIA задает темп разработки программного обеспечения с процессорами архитектуры ARM. Хотя фактически с применением языков высокого уровня абстракции, с последующей интерпретацией без компиляции позволяет переносить программное обеспечение на любую аппаратно-программную платформу, возникает вероятность влияния аппаратно-программной платформы непосредственно на результаты обучения и возникает дополнительный слой, который стоит между качественными данными и конечным результатом — обученной моделью. Схематично это можно отобразить следующим образом, смотреть на рисунок 5.




Рисунок 5 — Схема влияющих слоев на этапе обучения модели нейронной сети

В контексте рассматриваемого комплекса, состоящего из данных для обучения, написанной программы обучения на языке высокого уровня абстракции, а также аппаратно-программного комплекса, который обучает нейронную сеть, можно добавить еще одну комплексную функцию, которая оказывает влияние, но не связывает базу данных с моделью на прямую, а исходит из промежуточного этапа и фактически является дополнительной независимой самостоятельной функцией, которую необходимо учитывать. Основным аргументом в пользу того, что эту функцию необходимо учитывать, является точность компьютерных вычислений с плавающей точкой. Ключевой параметр этого аргумента заключается в том, что координаты объекта на изображении в подготовленных данных задаются в виде числе с десятичной дробной частью, что наглядно и напрямую демонстрирует потребность в высокоточных вычислениях, что зависит от архитектуры процессора и набора инструкций, по которым он выполняет вычисления. Также это можно отследить в вычислениях при обучении модели при определении метрик, где вычисляется площадь и доля перекрытия объектов на разных изображениях, а также степень совпадения тестовых данных с валидационными. Необходимо отметить, что при корректной настройке тестовые и валидационные наборы данных обязаны быть разными, что и было выполнено при проведении эксперимента.

В подтверждение гипотезы о том, что аппаратно-программная платформа влияет на конечную модель, был проведен дополнительный эксперимент, в котором сравнивается

локально обученная модель YOLO 11 n на компьютере с процессором Intel архитектуры x64 и модель и модель Roboflow на платформе с процессором Jetson Orin NX с архитектурой ARM. Результаты обучения видны на рисунке 6













MODEL NAME	UPDATED	METRICS	TYPE
 <b>local_trained_2 3</b> ID: local_trained_2/3	 21.09.2025 19:07	Valid Set External  mAP@50 13.4%  Precision 63.1%  Recall 14.3% 	YOLOv11 Instance Segmentation (Accurate)
 <b>local_trained_2 2</b> ID: local_trained_2/2	 21.09.2025 18:38	Valid Set External  mAP@50 17.2%  Precision 15.3%  Recall 22.2% 	Roboflow 3.0 Instance Segmentation (Accurate)

Рисунок 6 — Результаты обучения на локальной и онлайн платформах с разной аппаратно-программной архитектурой

Не менее важным параметром является стартовая точка обучения, а именно применение предварительно обученной модели и полностью не обученной модели. Во время начала обучения, пользователю на выбор предоставляется возможность начать обучения с начальной позиции, где в модели не содержится никакой предварительной записи и начать обучение собственной модели с точки предварительного обучения, где в зависимости от вида модели предлагается разный уровень точности модели в стартовой позиции. Для YOLO 11 n этот уровень составляет 39,5 %, а для Roboflow 44,2% [9, 10]. При этом во время проведения эксперимента локально обученная модель YOLO 11 получила точность 15%, онлайн обученная модель YOLO 11 получила точность 63%, а модель Roboflow получила точность. Рассматривая полученный результат можно прийти к выводу, что закрытая архитектура уступила место открытой. Одним из ключевых моментов является факт того, что открытую архитектуру отслеживает большое сообщество, которое используем обратную связь для совершенствования алгоритмов программного обеспечения, в то время как закрытая архитектура использует интеллектуальные ресурсы ограниченного количества людей. Также подчеркнем, что при обучении была поставлена задача сегментации, а не обнаружения объектов, тем самым подчеркивается унификация модели YOLO по отношению к модели Roboflow. Обратим внимание на рисунок 7.

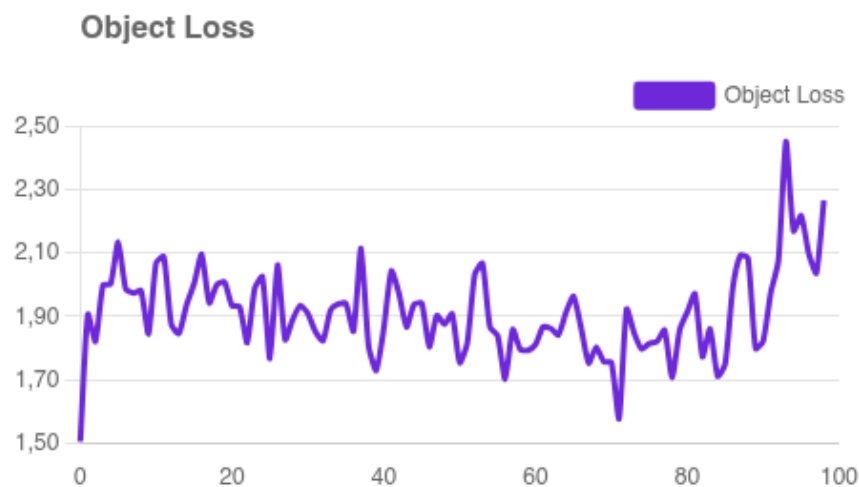


Рисунок 7 — График потери объектов во время обучения

По оси X – прогресс обучения в процентах, по оси Y – количество «потерянных» объектов. Дополнительным фактором является распределение в банке данных. Как и было отмечено ранее распределение требует наличия трех категорий данных: обучающие, достоверные и проверяющие. С учетом этого необходимо контролировать наличие соответствующих данных в каждой категории. Необходимо наличие как минимум одного объекта из каждого класса в каждой категории данных. Наличие или отсутствие класса объекта является бинарной функцией. При этом весовой коэффициент этой функции по отношению к комплексной может определяться как отношение количества объектов в классе к общему числу объектов во всех классах. Таким образом появляется некоторая функция классов объектов, которая является комплексной, и она же является аргументом в комплексной функции более высокого порядка, характеризующей влияние качества данных на результаты обучения модели. Математически эту комплексную функцию можно записать так:

$$C_{class} = \sum_1^n (k \times B) \quad (5)$$

где  $C_{class}$  - комплексная функция, которая характеризует влияние распределения данных в банке данных при помощи бинарного состояния наличия данных.  $k$  - коэффициент, отражающий отношение наличия объектов одного класса к общему числу объектов во всех классах  $B$  - бинарное состояние наличия или отсутствия объекта класса в разделе данных.

При этом стоит отметить, что бинарное состояние будет равно логической единице, если объект класса находится во всех трех категориях данных.

#### **Результаты и их обсуждение.**

С учетом всего описанного можно выделить следующие результаты: Получена формальная запись комплексной функции, характеризующей влияние качества данных, а также второстепенных сопряженных и сопутствующих факторов. Комплексная функция в выражении 4 приведена к виду многочлена с однородными одночленами. Также дополнительно определена функция сопряженного фактора, который не связан с качеством данных, но связан с их распределением, что позволяет определять фактор как значимый для обучения модели.

Математические выражения составлены на основе данных, которые были проверены в ходе эксперимента на онлайн платформе и на локальном компьютере, что в конечном итоге позволило вывести гипотезы о влияющих факторах. В конечном результате, выражениях 4 и 5, представлены только подтвердившиеся гипотезы, проверенные в ходе ряда практических экспериментов.

Полученные выражения могут лечь в основу математической модели, которая на более высоком уровне будет отражать принцип действия системы предполетного осмотра воздушного судна. Оба выражения являются аргументами более комплексной функции, характеризующей безопасность полетов. Согласно закону дистрибутивности можно записать следующую функцию по показателю безопасности полетов:

$$F_{safety} = C_{class} + C_{ca} \quad (6)$$

где  $F_{safety}$  - комплексная функция безопасности полетов.

Таким образом комплексная функция имеет математическую логическую связь с данными для обучения модели нейронной сети или искусственного интеллекта для обнаружения внешних неисправностей воздушного судна. Что в конечном итоге позволяет определять риски в процессе применения нейронной сети в предполетном осмотре. При таких наглядных демонстрациях взаимосвязей между аргументами обучаемой модели и комплексной функции можно определить последовательность, которая может нести риски

и служить предпосылкой для авиационных инцидентов или происшествий. Наглядно можно привести диаграмму, которая будет демонстрировать закон дистрибутивности для выражений 4, 5 и 6. Диаграмма приведена на рисунке 8.




Рисунок 8 — Закон дистрибутивности для аргументов и комплексных функций обучения модели и функции безопасности полетов

### Заключение.

В заключении статьи по проведенному исследованию можно сделать следующие выводы. Качество данных напрямую влияет на результаты обучения модели, что можно было увидеть на примерах датасетов с разными способами классификации распознаваемых образов.

Качество данных является комплексной функцией высокого класса комплексности. Так как во многом есть ряд переменных, которые были частично изучены в представленной статье. Также были представлены формализованные взаимосвязи переменных и конечного показателя точности распознавания.

Каждый аргумент функции качества данных также является комплексной функцией. Несмотря на то, что аргументы рассматривались в упрощенном виде, они также имеют собственную внутреннюю структуру и способны объединяться и разделяться по принципу смежности и закону дистрибутивности во влиянии на конечный результат.

Описанные выводы являются основой для разработки правил подготовки банка данных для обучения и создания проверочного листа с параметрами оценки банка данных для обучения модели.

Наиболее значимым достижением является демонстрация логически и математически прослеживаемой функциональной связи между исходными данными для обучения модели компьютерной программы и комплексной функцией безопасности полетов. При этом комплексная функция безопасности демонстрируется фрагментировано, так как фактически является многокритериальной комплексной функцией высокого порядка.

### Список литературы

1. Bruce Crumley. (2021, December 8). For KLM, Mainblades drone inspection is about to become a vital part of aircraft maintenance. DroneDJ. <https://dronedj.com/2021/12/08/for-klm-mainblades-drone-inspection-is-about-to-become-a-vital-part-of-aircraft-maintenance/>;
2. Mainblades. (2021). Aircraft drone inspections: KLM inspects aircraft with drones – Mainblades renews partnership with Engineering & Maintenance [Video]. YouTube. <https://youtu.be/qwdlXtbmT-0>;
3. Korean Air. (2021, December 16). Korean Air develops world's first aircraft inspection technology using drone swarms. <https://www.koreanair.com/contents/footer/about-us/newsroom/list/211216-korean-air-develops-world-s-first-aircraft-inspection-tec>;
4. Schreiner, M. (2023, March 17). GPT-4 architecture, datasets, costs and more leaked. The Decoder. <https://the-decoder.com/gpt-4-architecture-datasets-costs-and-more-leaked/>;

5. Banh, L., & Strobel, G. (2023). Generative artificial intelligence. Electronic Markets, 33(63). <https://doi.org/10.1007/s12525-023-00680-1>;
6. Roboflow. (2025). Vision AI at the edge. <https://roboflow.com/hardware>;
7. AMD. (2025). AMD documentation hub. <https://www.amd.com/en/search/documentation/hub.html>;
8. Intel. (2025). Intel Core Ultra processors. <https://www.intel.com/content/www/us/en/products/details/processors/core-ultra.html>;
9. NVIDIA. (2025). NVIDIA Jetson developer kits. <https://developer.nvidia.com/embedded/jetson-developer-kits>;
10. Ultralytics. (2025). Ultralytics YOLO11. <https://docs.ultralytics.com/ru/models/yolo11/>.

## НЕЙРОНДЫҚ ЖЕЛІЛЕРДІ ЖӘНЕ ЖАСАНДЫ ИНТЕЛЛЕКТ ОҚЫТУ ДЕРЕКТЕРІНІҢ САПАСЫНЫҢ ҰШУ ҚАУІПСІЗДІГІНЕ ӘСЕРІН ТАЛДАУ

*Аңдатпа.* Зерттеудің мақсаты — деректер сапасының әсерін және оған ықпал ететін факторларды зерделеу, сондай-ақ нейрондық желі немесе жасанды интеллектті оқыту функциясының аргументтері арасындағы логикалық әрі математикалық байланыстарды формализациялау арқылы олардың ұшу қауіпсіздігімен өзара тәуелділігін көрсету.

Мақсатқа жету үшін келесі міндеттер қарастырылды. Біріншіден, жасанды интеллекттің ұшуға дейінгі тексеру, әуе кемесін жөндеу және техникалық қызмет көрсету үдерістерінде қолданылуының қазіргі жағдайына талдау жасалды. Бұл нейрондық желілер мен жасанды интеллекттің технологиялық интеграция деңгейін айқындау үшін қажет. Екіншіден, жиналған деректер негізінде жасанды интеллектті оқытуға арналған өзекті платформалар анықталды. Бұл оқыту нәтижесіне әсер ететін қосымша техникалық аргументтерді белгілеуге жағдай жасайды. Үшіншіден, негізгі факторлар мен нәтиже арасындағы логика-математикалық байланыстар формализацияланды. Қосымша әсер етуші факторлар да анықталып, құрылымдық түрде сипатталды. Формалды жазу тәсілі ұшу қауіпсіздігіне ықтимал тәуекелдерді бақылауға арналған тізбекті байланыс желісін құруға негіз болады.

Зерттеуде келесі әдістер пайдаланылды. Бақылау — автоматтандырылған оптикалық ақау анықтау технологияларының қолданылу хронологиясы бойынша жиналған ақпаратқа қолданылды. Декомпозиция — кешенді технологиядан ақауларды анықтайтын компьютерлік бағдарламаның функционалдық бөлігін бөліп шығаруға мүмкіндік жасады. Салыстырмалы талдау — әртүрлі нейрондық желілер мен оларды қолдайтын техникалық жүйелердің артықшылықтары мен әлсіз тұстарын айқындады. Математикалық талдау — кешенді функция аргументтерінің әсерін сипаттайтын формулаларды құрылымдауға, сондай-ақ функцияның аддитивті және мультипликативті қасиеттерін бағалауға қолданылды. Диверсиялық және функционалдық талдаулар — факторлар арасындағы өзара байланыстар мен олардың соңғы — ұшу қауіпсіздігінің интегралдық көрсеткішіне ықпалын анықтауға бағытталды.

Нәтижесінде нейрондық желі мен жасанды интеллект аргументтерінен бастап ұшу қауіпсіздігінің кешенді көрсеткішіне дейінгі функционалды-тізбекті байланыстарды сипаттайтын логика-математикалық өрнектер ұсынылды.

**Түйін сөздер:** жасанды интеллект, нейрондық желілер, ұшу алдындағы тексеру, жасанды интеллект модельдері, салыстырмалы талдау, ұшу қауіпсіздігі.

## ANALYSIS OF THE IMPACT OF THE QUALITY OF TRAINING DATA OF NEURAL NETWORKS AND ARTIFICIAL INTELLIGENCE ON FLIGHT SAFETY

**Abstract.** *The aim of the study is to study the impact of data quality, the factors associated with it, and to formalize the logical and mathematical connections between the arguments of the neural network training function or artificial intelligence to demonstrate the relationship with flight safety.*

*To achieve the goal, it is necessary to solve the following tasks. The first is to assess the current state of the issue of the use of artificial intelligence in the procedures of pre-flight inspection, as well as repair and maintenance of the aircraft. This is necessary to determine the level of technological integration of neural networks and artificial intelligence. Secondly, based on the data obtained, it is necessary to determine relevant platforms for training artificial intelligence. This will allow you to identify additional technical arguments that affect the final result of AI training. The third is to formalize the logical and mathematical connection between the influencing factors and the final result. Identify additional influencing factors and also formalize. The formal recording method allows for the construction of a procedurally consistent communication line to monitor safety risks.*

*The following methods were used to solve the problems. An observation method that has been applied to the information that has been collected in the course of tracking the history of the application of various automated optical fault detection technologies. Decomposition, which made it possible to separate the functional part of the computer program that detects malfunctions from the complex technology. Comparative analysis, which made it possible to determine the strengths and weaknesses of various neural networks and the architectures of technical systems for these neural networks and artificial intelligence. Mathematical analysis, which allows you to formalize the expressions that characterize the influence of the arguments of a complex function and determine the additivity and multiplication of a complex function. Sabotage and functional analyses, which make it possible to determine the relationship between the arguments of complex functions and the final complex safety function.*

*As a result, expressions were presented that reflect the logical and mathematical connection in a functionally sequential transfer line from the arguments of a neural network and artificial intelligence to a complex indicator of flight safety.*

**Keywords:** *artificial intelligence, neural networks, pre-flight inspection, artificial intelligence models, comparative analysis, flight safety.*

**Финансирование:** *BR28713125 Разработка и внедрение беспилотных технологий и интеллектуальной робототехнической системы предполетного контроля для повышения безопасности на воздушном транспорте.*

### Сведение об авторах

Кошекoв Кайрат Темирбаевич	д. т. н., проректор по научной деятельности, АО «Академия гражданской авиации», г. Алматы, Қазақстан, E-mail: kkoshekov@mail.ru
Алдамжаров Казбек Бахитович	д. т. н., профессор АО «Академия гражданской авиации», г. Алматы, Қазақстан, E-mail: k.aldamzharov@agakaz.kz
Курбанов Якуб Мухсатұлы	студент первого курса докторантуры PhD, Руководитель центра научных исследований и компетенций, АО «Академия Гражданской Авиации», г. Алматы, Қазақстан, E-mail: y.kurbanov@agakaz.kz
Курбанов В.М.	научный сотрудник, АО «Академия Гражданской Авиации», magk462@gmail.com

**вторлар туралы мәлімет**

Кошекoв Кайрат Темирбаевич	т.ғ.д., «Азаматтық авиация академиясы» АҚ-ның Ғылыми қызметтер жөніндегі проректоры, Алматы қ., Қазақстан, E-mail: kkoshekov@mail.ru
Алдамжаров Казбек Бахитович	т.ғ.д., «Азаматтық авиация академиясы» АҚ-ның профессоры, Алматы қ., Қазақстан, E-mail: k.aldamzharov@agakaz.kz
Курбанов Якуб Мухсатұлы	PhD докторантураның бірінші курс студенті, Ғылыми зерттеулер және құзыреттер орталығының басшысы,, Алматы қ., Қазақстан, E-mail: y.kurbanov@agakaz.kz
Курбанов В.М.	«Азаматтық авиация академиясы» АҚ ғылыми қызметкер, magk462@gmail.com

**Information about the authors**

Kairat Koshekov	Doctor of Engineering Sciences, Vice-Rector for Research, JSC Civil Aviation Academy, Kazakhstan, E-mail: kkoshekov@mail.ru
Kazbek Aldamzharov	Doctor of Technical Sciences, Professor, Academy of Civil Aviation JSC, Almaty, Kazakhstan, E-mail: k.aldamzharov@agakaz.kz
Kurbanov Yakub	first-year PhD student, Head of the Center for Scientific Research and Competencies, Academy of Civil Aviation JSC, Almaty, Kazakhstan, E-mail: y.kurbanov@agakaz.kz
Kurbanov V.	Researcher, Academy of Civil Aviation, magk462@gmail.com