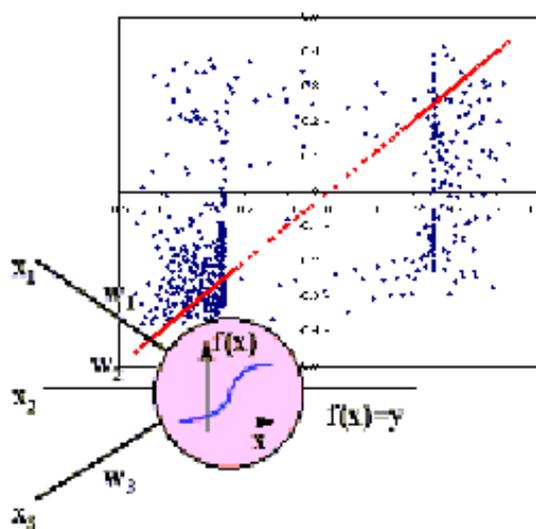


Міністерство освіти і науки України
Національна академія наук вищої освіти України
Інститут проблем штучного інтелекту (Україна)
Донбаська державна машинобудівна академія (Україна)
Academy of Professional Studies Šumadija - Kragujevac (Serbia)
Apeiron University in Banja Luka, (Bosnia and Herzegovina)
DAAAM International Vienna
Mechanical Engineering Faculty in Slavonski Brod, JJ Strossmayer University of Osijek (Croatia)
University of Montenegro Faculty of Mechanical Engineering
University of Zielona Góra (Poland)
"American Jurnal Neural Network and Aplication" (USA)
Тернопільський національний технічний університет імені Івана Пулюя
Вінницький національний аграрний університет (Україна)
Вінницький національний технічний університет (Україна)
Проблемна лабораторія мобільних інтелектуальних технологічних машин (Україна)



ЗБІРНИК НАУКОВИХ ПРАЦЬ

XXI Міжнародної наукової конференції

«НЕЙРОМЕРЕЖНІ ТЕХНОЛОГІЇ ТА ЇХ ЗАСТОСУВАННЯ НМТЗ-2022»

м.м. Краматорськ-Вінниця-Тернопіль - 2022

УДК 004.032.26+621(061.3)

Н46

Рецензенти:

Рамазанов С.К., докт.техн.наук, докт.екон.наук, професор, Київський національний університет імені Тараса Шевченка;

Суботін С. О., докт. техн. наук, професор, Запорізький національний технічний університет

Рекомендовано

вченою радою Донбаської державної машинобудівної академії
(протокол № 4 від 24.11.2022)

Н46 Нейромережні технології та їх застосування НМТЗ-2022: збірник наукових праць XXI Міжнародної наукової конференції «Нейромережні технології та їх застосування НМТЗ-2022» / [за заг. ред. д-ра техн. наук., проф. С. В. Ковалевського і Hon.D.Sc., prof. Dasic Predrag]. - Краматорськ: ДДМА, 2022. – 122 с.

ISBN 978-617-7889-32-7

У збірнику праць представлені перспективні теоретичні та практичні розробки в області нейромережних технологій, виконані в 2021 р. науковими школами України і світу. Розглядається можливість застосування нейронних мереж для управління об'єктами в режимі реального часу і особливості нейронного керування динамічними об'єктами. Наводиться ряд розробок по застосуванню нейронних мереж в різних областях практичної і науково-дослідної діяльності та створенню інтелектуальної системи для підвищення швидкості та зниження трудомісткості технологічної підготовки виготовлення нових виробів.

Для здобувачів освіти, наукових працівників широкого профілю та фахівців.

ISBN 978-617-7889-32-7

©ДДМА, 2022

1. **Ковалевський С.В.** (*Донбаська державна машинобудівна академія, м. Краматорськ-Тернопіль, Україна*) **XXI МІЖНАРОДНА НАУКОВА КОНФЕРЕНЦІЯ «НЕЙРОМЕРЕЖНІ ТЕХНОЛОГІЇ ТА ЇХ ЗАСТОСУВАННЯ - НМТІЗ-2022».** 9
2. **Shevchenko A. I., Vakulenko M. O., Klymenko M. S.** (*Institute of Problems of Artificial Intelligence, Kyjiv, Ukraine*) **THE PROJECT STRATEGY FOR ARTIFICIAL INTELLIGENCE DEVELOPMENT IN UKRAINE: WHYS AND HOWS.** 10
3. **Predrag Dasic** (*Academy of Professional Studies Šumadija - Department in Trstenik, Serbia*) **DEVELOPMENT OF SOFTWARE SYSTEMS FOR RELIABILITY ANALYSIS OF THE COMPONENTS TECHNICAL SYSTEM** 17
4. **Domenico Guida** (*Department of Industrial Engineering, University of Salerno, Italy*) **DEVELOPMENT OF SIMULATION OF UNMANNED TRANSPORT SYSTEMS** 20
5. **Ryszard Tadeusiewicz** (*AGH University of Science and Technology, Krakow Poland*) **SIĘCI NEURONOWE JAKO NOWE NARZĘDZIE AUTOMATYKI I INFORMATYKI.** 22
6. **Jeanette Hellgren Koteleski** (*Science for Life Laboratory, School of Electrical Engineering and Computer, Science, KTH Royal Institute of Technology, Stockholm, Sweden*) **HYPOTHESES OF NEURAL NETWORK MODELING.** 25
7. **Рамазанов С.К., Макаренко М.Б., Вовчак А.В.** (*Київський національний економічний університет імені Вадима Гетьмана, Україна*) **ВИКОРИСТАННЯ МОДЕЛЕЙ МАШИННОГО НАВЧАННЯ ДЛЯ ПОШУКУ МЕДИЧНИХ ДАНИХ.** 27
8. **Бодянський Є.В., Костюк С.О.** (*Харківський національний університет радіоелектроніки, Харків, Україна*) **ПРОЦЕДУРА ДВОКРОКОВОГО ОНОВЛЕННЯ ПАРАМЕТРІВ ШТУЧНИХ НЕЙРОНІВ З АДАПТИВНИМИ АКТИВАЦІЙНИМИ ФУНКЦІЯМИ.** 30
9. **Слюсар В.И.** (*Центральний науково-дослідний інститут озброєння та військової техніки ЗС України*), **Слюсарь И.И.** (*Полтавський державний аграрний університет*) **АНАЛИЗ ЭФФЕКТИВНОСТИ МЕХАНИЗМОВ ВНИМАНИЯ В ЗАДАЧЕ СЕГМЕНТАЦИИ ИЗОБРАЖЕНИЙ ЦИФЕРБЛАТОВ АНАЛОГОВЫХ СЧЕТЧИКОВ.** 37
10. **Малий Р.І., Хаджиков А.С., Клименко М.С., Сімченко С.В.** (*Інститут проблем штучного інтелекту МОН і НАН України*) **РОЗРОБКА СИСТЕМИ КЕРУВАННЯ ГРУПОЮ БЕЗПІЛОТНИХ АПАРАТІВ.** 44
11. **Dilip Kumar, Neha lakhwan, Anita Rawat** (*Department of Civil Engineering, Govind Ballabh Pant Engineering College, Pauri, India*) **STUDY AND PREDICTION OF LANDSLIDE IN UTTARKASHI, UTTARAKHAND, INDIA USING GIS AND ANN.** 46
12. **Гітіс В.Б., Следнєв Л.С.** (*Донбаська державна машинобудівна академія, м. Краматорськ-Тернопіль, Україна*) **ДОСЛІДЖЕННЯ ЕФЕКТИВНОСТІ МЕТОДІВ ІНТЕЛЕКТУАЛЬНОГО АНАЛІЗУ** 48

Слюсар В.И. (Центральний науково-дослідний інститут озброєння та військової техніки ЗС України)

Слюсарь И.И. (Полтавський державний аграрний університет)

АНАЛИЗ ЭФФЕКТИВНОСТИ МЕХАНИЗМОВ ВНИМАНИЯ В ЗАДАЧЕ СЕГМЕНТАЦИИ ИЗОБРАЖЕНИЙ ЦИФЕРБЛАТОВ АНАЛОГОВЫХ СЧЕТЧИКОВ

Рассмотрены результаты исследования точности различных архитектур нейросетей U-Net с механизмом внимания при решении задачи сегментации изображений циферблатов аналоговых счетчиков. Сделан вывод об отсутствии эффекта увеличения точности за счет интеграции одно- и двухканальных схем внимания, при этом достигнутая точность сегментации составила 86.3 %.

The results of studying the accuracy of various architectures of U-Net neural networks with an attention mechanism in solving the problem of image segmentation of analogue counter dials are considered. It is concluded that there is no effect of increasing accuracy due to the integration of one- and two-channel attention schemes, while the achieved segmentation accuracy was 86.3%.

Важной задачей при реализации концепций Smart City, Smart Home, Industry 5.0 и т.д. является удаленный сбор данных с множества аналоговых средств контроля расхода ресурсов, например, счетчиков потребления электроэнергии, воды, газа, тепла и др. Во многих случаях их замена на современные цифровые приборы является нерентабельной. Немаловажную роль при этом играют большое разнообразие и количество аналоговых средств учета в той или иной инфраструктуре, запреты на внесение изменений в коммуникации, высокая стоимость разработок проектно-технической документации по модернизации оборудования. По этой причине некоторые разработчики идут по пути использования оптических каналов снятия показаний аналоговых счетчиков с последующей передачей изображений их циферблатов на визуальные средства наблюдения. Эффективность такого подхода может быть увеличена путем комбинации технологий Интернета вещей и оптического распознавания данных на основе искусственного интеллекта (IoT + AI).

В качестве возможных примеров подобной интеграции следует указать решения [1]. Однако их массовому внедрению препятствует ряд недостатков, связанных с отсутствием унификации по типам счётчиков, влиянием вибраций при определенной специфике технологических процессов, высокими требованиями к пространственной стабильности изображений и параметрам экспозиции. Кроме того, использование ограниченных возможностей аппаратных средств edge computing вынуждает подстраиваться под минимальные вычислительные ресурсы. При этом возникает необходимость ручной сегментации, точной первоначальной настройки, ручной коррекции считанных данных, и все это – в условиях низкой разрешающей способности изображений (обычно, порядка 28x28 пикселей).

Одним из вариантов решения указанных проблем является использование процедуры предварительной сегментации изображений циферблатов, до того момента, как они поступят на оптическое распознавание. Это позволит снизить объём передаваемой оптической информации, удалить с полученных изображений мешающий фон и сузить поле для распознавания. Варианты такой обработки рассмотрены, например, в [2, 3]. Помимо анализа эффективности различных архитектур нейросетей в [3] было проведено также исследование влияния настроек параметров их типовых слоев (Conv2D MaxPool и др.) в различных комбинациях. Вместе с тем за пределами рассмотрения в [3] остались структуры нейросетей с механизмом внимания, применение которого в задаче сегментации изображений циферблатов счетчиков ранее никем не было изучено.

Целью работы является анализ результатов тестирования новых архитектур нейросетей для сегментации изображений счетчиков с применением механизма внимания.

Для обучения всех предложенных вариантов нейронных структур применительно к рассматриваемой сфере сегментации изображений циферблатов счетчиков использовался общедоступный датасет Water Meters, размещенный на web-портале Kaggle (www.kaggle.com/datasets/tapakah68/yandextoloka-water-meters-dataset).

В качестве базовой архитектуры нейросети была выбрана средняя по размерам U-Net [4] (рис. 1) с количеством параметров 1721730, из которых не подлежали тренировке только 2688 параметров. Особенностью данной структуры U-Net является 4-кратное уменьшение формата матрицы пикселей в процессе обучения. Поэтому размер изображений, поступающих на вход такой нейросети, должен нацело делиться на 4. Вместе с тем, спецификой датасета Water Meters является размер исходных изображений 1000x1778 пикселей, что лишь частично удовлетворяет указанному требованию. Чтобы адаптировать датасет, все его изображения были предварительно пережаты в размеры, кратные 4. В частности, для нового формата изображений была выбрана матрица 224x128 пикселей, как наиболее близкая по своим пропорциям к исходным фотоснимкам. Строго говоря, для изображений со стороной кадра 128 пикселей пересчет с коэффициентом 1778/1000 дает результат 227,584. В этом случае округление до 224 пикселей должно быть практически незаметным. Следует отметить, что при выборе конкретного формата пережатого изображения помимо максимальной возможности сохранения пропорций исходных фотоснимков датасета также необходимо было учитывать ограничения доступных вычислительных ресурсов, на которых выполняется обучение нейросети. Для максимизации этих ресурсов в рамках исследования использовались возможности графических карт, предоставляемых платным сервисом Google ColabPro+.

Тренировочный датасет содержал 870 снимков, тогда как проверочный сегмент датасета включал 374 изображения. Маски для сегментации циферблатов были заданы черно-белыми. Соответственно процент пространства, занятого черным фоном, составил 98 %, а на белый вырез под цифровое табло счетчика приходилось 2 %. Процесс обучения нейросети U-Net (рис. 1) выполнялся с шагом обучения 0.001 и батчем 32. Время выполнения 80 эпох обучения составило 7 мин в стандартном режиме подключения к Google ColabPro+ с видеокартой A100-SXM4, оснащенной 40 ГБ ОЗУ. В процессе обучения ее ресурсы на некоторых этапах были задействованы более, чем на 87 %. При этом также сервисом Google Colab было предоставлено ОЗУ процессорного модуля объемом 83,48 ГБ и дисковое пространство 166,77 ГБ, хотя их возможности использовались на уровне 6 и 15 процентов соответственно.

Максимальная достигнутая точность обучения U-Net в пределах 400 эпох составила 86.3 %. Комментируя сравнительно невысокий полученный результат следует указать, что датасет Water Meters от Kaggle содержит достаточно много ошибочных масок. Например, некоторым вертикально расположенным циферблатам соответствует горизонтально ориентированная маска. В других случаях при реальном наклоне циферблата влево на маске соответствующий сегмент изображения наклонен вправо. Вполне понятно, что на таких изображениях нейронная сеть дает значительную ошибку, и общая точность сегментации снижается. В подобных случаях исходный датасет следует предварительно отфильтровать от артефактов. Однако, применительно к решаемой задаче, наличие указанного недостатка, напротив, явилось полезным фактором, создавшим стрессовые условия для функционирования анализируемых нейросетей.

На следующем этапе исследования проводились с применением различных по структуре и месту включения в нейронную сеть типа U-Net механизмов внимания. Основная идея применения структур внимания состояла в том, чтобы взвесить матрицу пикселей изображений с помощью особой маски, селективирующей их наиболее значимую область. При

этом соответствующие веса подбираются в процессе обучения, максимизируя точность сегментации.

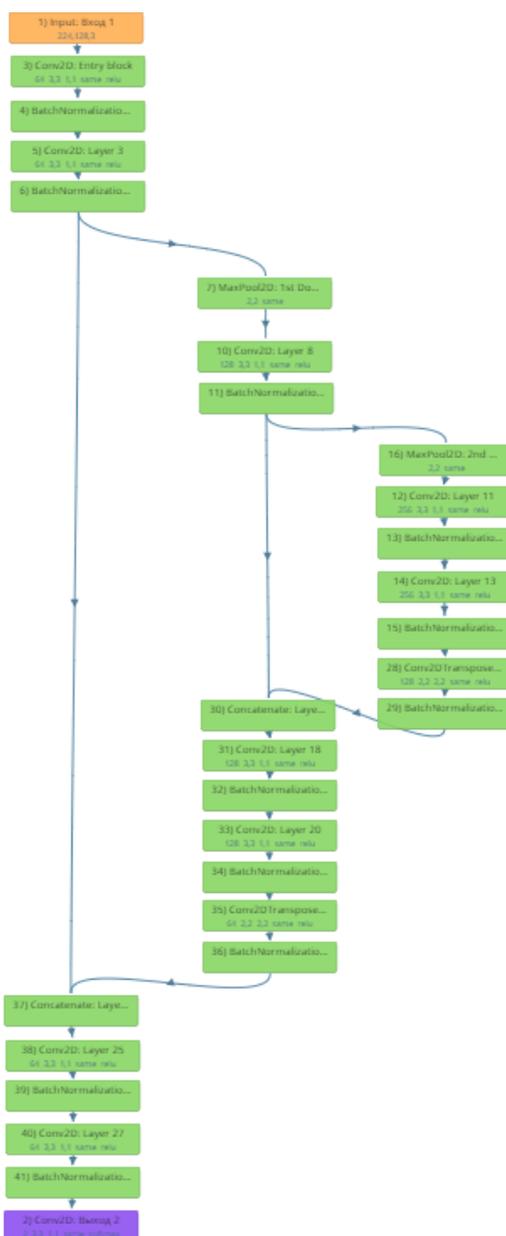


Рис. 1. Базовая архитектура нейросети U-Net в фреймворке “Terra AI”.

Процесс анализа проводился в отношении одно- и двухканальных структур внимания. На рис. 2 представлен один из использовавшихся вариантов одноканального механизма внимания, охватывающий несколько слоев нейросети с пробросом выхода канала внимания вперед по ее структуре. Детализированная на рис. 3 схема механизма внимания содержит на входе сверточный слой Conv2D с одним фильтром, формируемым с помощью единичного весового ядра и такого же шага скольжения. На вход Conv2D поступает изображение формата 112×64 пикселей. Далее следует выравнивающий слой Flatten, выходы которого подключены к полносвязному нейронному слою Dense с функцией активации ReLU. Он имеет количество нейронов, равное количеству пикселей в одном кадре на выходе механизма внимания (1792). Столько же нейронов содержит и последующий слой Dense с функцией активации Softmax. Векторный выход второго слоя Dense далее трансформируется слоем Reshape в изображение формата 52×32 пикселей. Для согласования структуры массивов, поступающих в качестве сомножителей на вход слоя умножения Multiply, на выходе канала

внимания в слое Conv2D формируется 256 фильтров, выходы которых подвергаются нормализации в соответствии с процедурой BatchNormalization.

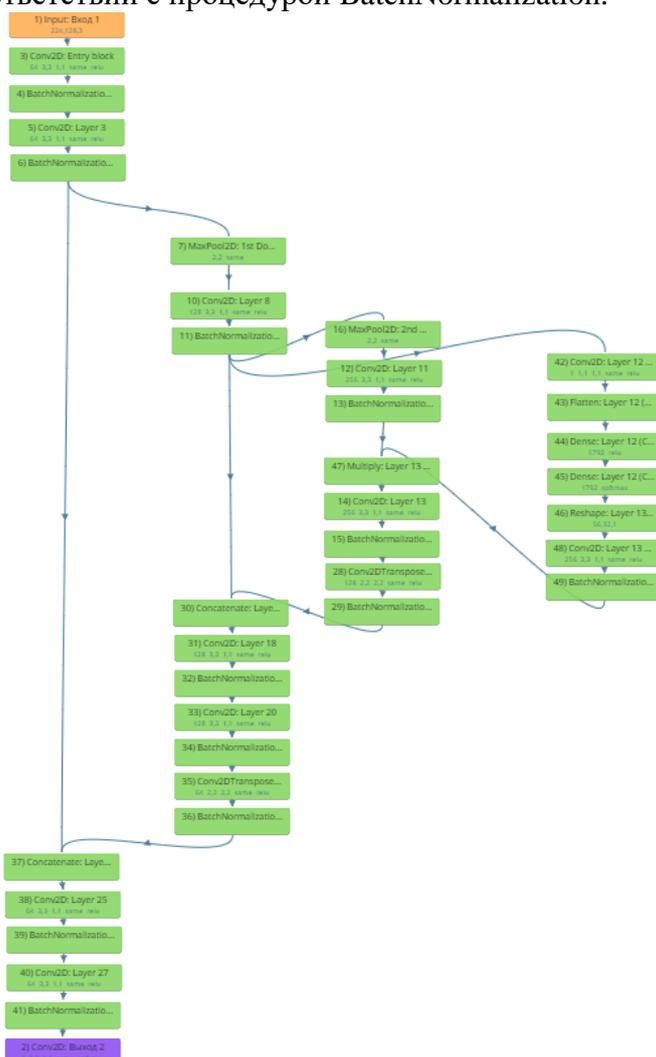


Рис. 2. U-Net с механизмом внимания, охватывающим 3 слоя нейросети.



Рис. 3. Структура одноканального механизма внимания на рис. 2.

Обучение нейросети рассмотренной структуры позволило получить точность 85.1 % в пределах 200 эпох. При этом наблюдалось затягивание начала процесса обучения на проверочной выборке до 18 эпох, что было обусловлено увеличением количества тренируемых параметров.

Более высокую точность, 85,3 %, позволило получить включение описанной выше схемы внимания в сегменте сети, соответствующем минимальному размеру изображения. При этом вход и выход канала внимания подключались параллельно стыку двух соседних слоев (рис. 4).

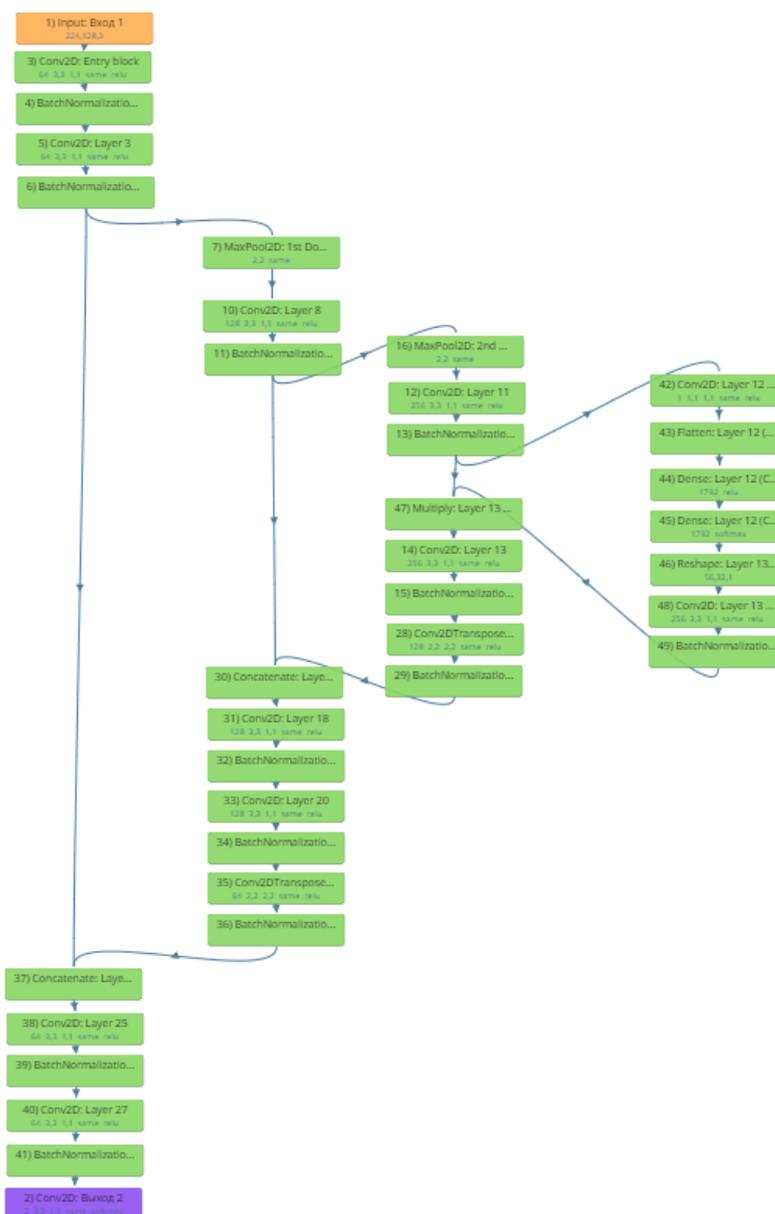


Рис. 4. Структура U-Net с одноканальным механизмом внимания, интегрированным между двумя слоями.

Альтернативный вариант подключения механизма внимания состоит в его интеграции параллельно линии связи между двумя слоями непосредственно перед слоем увеличения изображения Conv2DTranspose, как показано на рис. 5. Общее количество параметров нейросети в данном случае равно 8151683, из них тренировке подлежат 8148483. Такой

вариант нейросети позволил достичь точности 86.3 % на 418-й эпохе, что совпадает с точностью базовой версии U-Net без механизма внимания.

Руководствуясь концепцией множественного внимания, далее была синтезирована схема U-Net с двумя последовательными канала внимания, представленная на рис. 6. Против ожидания, такое усложнение нейросети привело к ухудшению точности сегментации, которая снизилась до величины 75.3 %. При этом также заметно ухудшилась и скорость обучения.

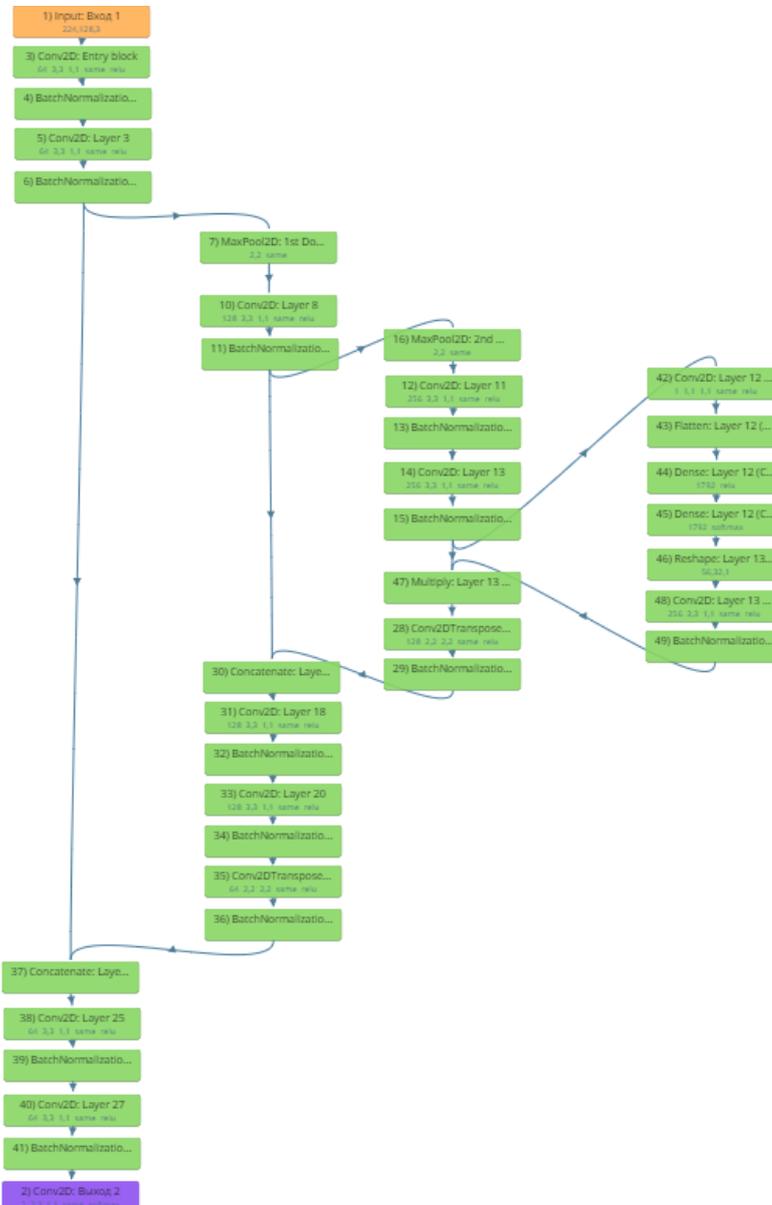


Рис. 5. Альтернативная архитектура U-Net с одноканальным механизмом внимания, подключенным в межслойный интервал.

Данный результат позволил сделать однозначный вывод, что применительно к рассматриваемому датасету одноканальный (однокаскадный) механизм внимания является предпочтительным решением. Также более выигрышным вариантом является использование в схеме внимания последовательно двух слоев Dense вместо одного. Такой принцип реализации механизма внимания на спарке слоев Dense дает преимущества в точности сегментации и по сравнению с сугубо сверточной схемой, содержащей несколько последовательно включенных сверточных слоев и слоев нормализации.

Естественно, в рамках проведенных исследований невозможно было охватить все варианты реализации механизма внимания. Вполне вероятно, что некоторые из них могут оказаться более эффективными. Проверка данного предположения является целью дальнейших исследований.

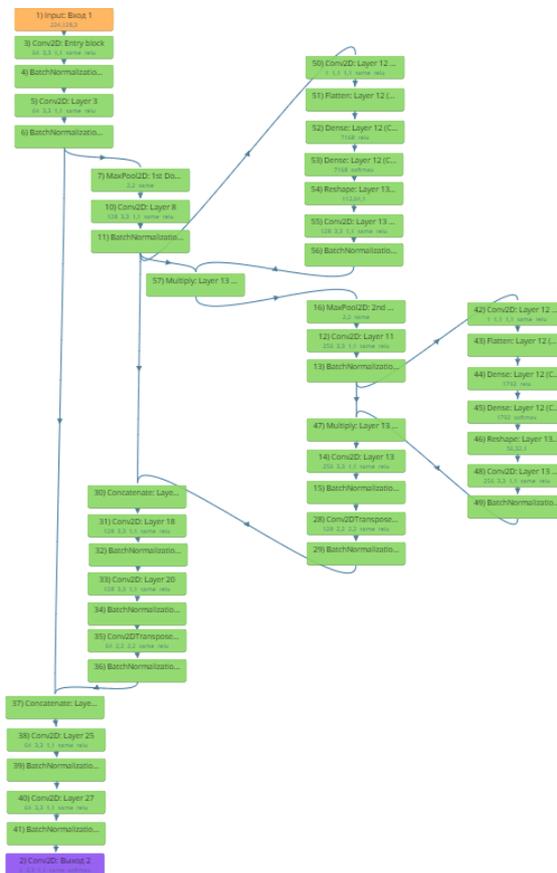


Рис. 6. U-Net с двухканальным механизмом внимания.

ВЫВОДЫ

Полученные результаты позволили сделать вывод, что применительно к датасету Water Meters механизм внимания, интегрированный в U-Net средней сложности, не позволил улучшить точность сегментации по сравнению с базовой архитектурой. В проведенных экспериментах удалось получить точность сегментации 86,3 %, как в случае использования механизма внимания, так и без него. Однако, не исключено, что использование более сложных схем внимания в сочетании со структурным разнообразием архитектур U-Net позволит преодолеть указанный паритет в пользу нейросетей с интегрированным механизмом внимания.

Литература

1. Analog meters in the digital enterprise: change or integrate? URL: <https://habr.com/ru/company/lanit/blog/676240/>.
2. Vadym Slyusar, Mykhailo Protsenko, Anton Chernukha, Vasyl Melkin, Olena Petrova, Mikhail Kravtsov, Svitlana Velma, Nataliia Kosenko, Olga Sydorenko, Maksym Sobol. Improving a neural network model for semantic segmentation of images of monitored objects in aerial photographs.// Eastern-European Journal of Enterprise Technologies.- № 6/2 (114). – 2021. - Pp. 86 – 95.DOI: 10.15587/1729-4061.2021.248390.
3. Vadym Slyusar, Ihor Sliusar, Nataliia Bihun, and Volodymyr Piliuhin. Segmentation of analogue meter readings using neural networks. // 4th International Workshop on Modern Machine Learning Technologies and Data Science MOMLET&DS2022, Lviv, Ukraine, 23 -25 Nov. 2022. – 11 p.
4. Ronneberger, O., Fischer, P., Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015, 234–241.

Наукове видання

**НЕЙРОМЕРЕЖНІ ТЕХНОЛОГІЇ
ТА ЇХ ЗАСТОСУВАННЯ
НМТІЗ-2022**

Збірник наукових праць

Загальною редакцією
д-ра техн. наук, проф. С. В. Ковалевського і
Hon.D.Sc., prof. Predrag Dašić

32/2016 Формат 60 x 84/16. Ум. друк. арк. 16,1
Обл.-вид. арк. 17,2. Тираж 100 прим. Зам. № 13

Видавець і виготівник
Донбаська державна машинобудівна академія
84313, м. Краматорськ, вул. Академічна, 72.
Свідоцтво суб'єкта видавничої справи
ДК № 1633 від 24.12.2003