

ПРИМЕНЕНИЕ СВЕРТОЧНОЙ НЕЙРОННОЙ СЕТИ ДЛЯ СЕГМЕНТАЦИИ СИГНАЛОВ ЭЛЕКТРОПРИВОДНОЙ АРМАТУРЫ

К.И. Коцоев*, *, Е.Л. Трыков**, И.В. Трыкова*****

* МГТУ им. Н.Э. Баумана

105005, Москва, 2-я Бауманская ул., д. 5, стр. 1

** АО «НТЦ Диапром»

249031, Калужская обл., г. Обнинск, ул. Королева, д. 6, пом. 22-23

*** ООО «КВАНТ ПРОГРАММ»

111558, г. Москва, Зеленый проспект, д. 5/12, стр. 3, пом. Б1



Одним из самых многочисленных классов оборудования на АЭС является электроприводная арматура (ЭПА). Важной проблемой диагностирования ЭПА является оперативный (он-лайн) автоматизированный контроль её технического состояния при работе энергоблока на мощности.

В связи с этим актуальной является задача диагностирования ЭПА по сигналам тока и напряжения, потребляемых в процессе выполнения операций «открытие» и «закрытие» ЭПА. Сигналы тока и напряжения представляют собой временные ряды, измеренные через равные промежутки времени. Сигналы тока (и напряжения) могут быть получены в режиме он-лайн и содержат всю необходимую информацию для оперативной диагностики состояния ЭПА.

Суть подхода состоит в том, чтобы по сигналам тока и напряжения рассчитать сигналы активной мощности, далее из определенных участков (сегментов) сигналов активной мощности извлечь характеристики («диагностические признаки»), по значениям которых диагностировать ЭПА.

Статья посвящена проблеме автоматизации сегментирования сигналов активной мощности. Для этого был разработан алгоритм, основанный на использовании свёрточной нейронной сети.

Ключевые слова: свёрточная нейронная сеть, сегментация временных рядов, электроприводная арматура, автоматизированная система.

ВВЕДЕНИЕ

В задачах анализа временных рядов часто случается, что ряд порожден различными механизмами генерации. Поэтому разбиение временного ряда на внутренне однородные сегменты - важная проблема интеллектуального анализа данных, так как позволяет выделять из больших объемов информации ключевые характеристики временного ряда в более компактной форме [1].

Примером таких временных рядов являются сигналы активной мощности ЭПА при выполнении операций «открытие» и «закрытие», диагностика заключается в разбиении

© К.И. Коцоев, Е.Л. Трыков, И.В. Трыкова, 2021

сигналов на сегменты и дальнейшем выделении из каждого сегмента «диагностических признаков» (численных величин, по которым делаются выводы об исправности или неисправности ЭПА) [2]. Каждый сегмент отвечает за срабатывание определенных узлов и элементов ЭПА и имеет характерные особенности.

В большинстве систем диагностики ЭПА подобное разбиение производится вручную, что занимает большое время и не позволяет перевести диагностику в автоматический режим. Для решения этой проблемы предложена глубокая нейронная сеть, автоматически сегментирующая сигнал активной мощности.

ПОСТАНОВКА ЗАДАЧИ

В соответствии с методологией [3] диагностика ЭПА производится по набору численных значений в характерных точках и на определенных временных интервалах сигнала активной мощности в цикле срабатывания ЭПА. На рисунке 1 характерные точки выбраны с учетом факторов, влияющих на техническое состояние ЭПА и на изменения сигнала активной мощности, на основании периодов движения запорного элемента арматуры.

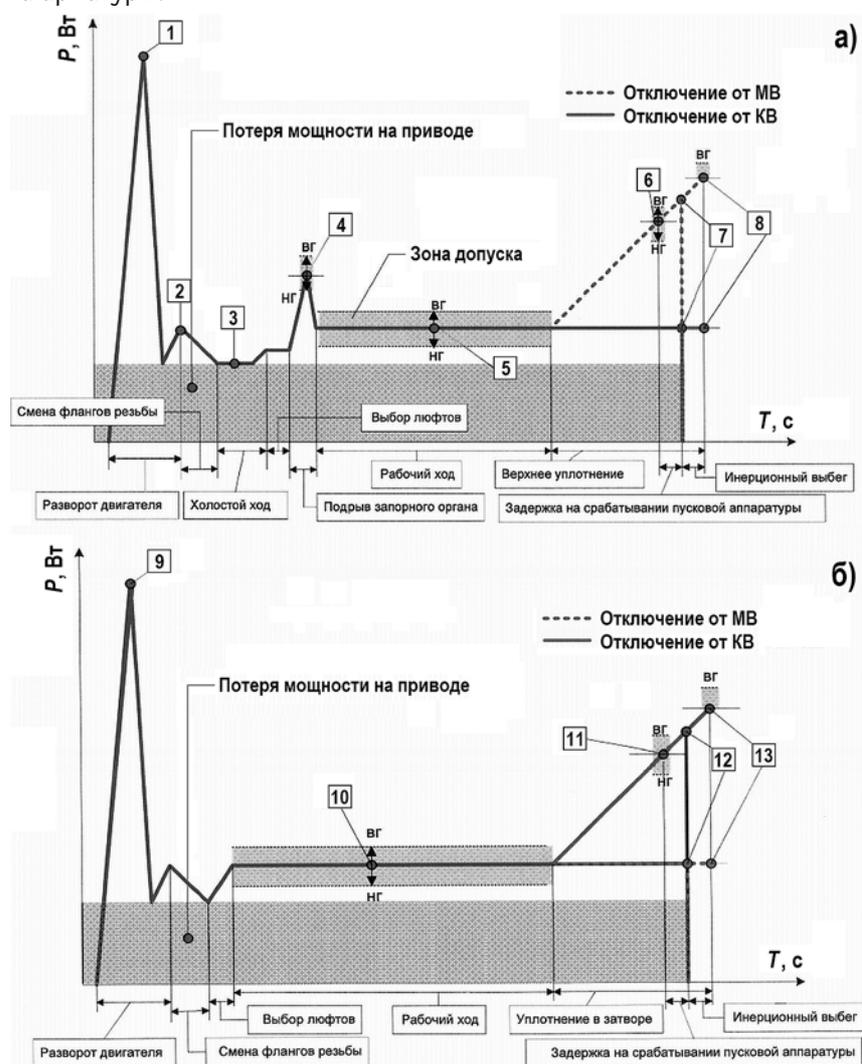


Рис. 1. Характерные точки сигнала активной мощности: а) открытие задвижки, б) закрытие задвижки

Недостатком данного подхода является человеко-зависимый алгоритм выделения временных участков. Поэтому для автоматизации процесса диагностирования ЭПА была поставлена задача автоматического разбиения сигнала активной мощности на сегменты с целью дальнейшего извлечения из этих сегментов численных величин, характеризующих техническое состояние ЭПА.

В [4] было показано, что искусственные нейронные сети хорошо справляются с задачей сегментации временных рядов.

ИСХОДНЫЕ ДАННЫЕ

Для расчета сигнала активной мощности использовались электрические параметры тока и напряжения со статорных обмоток электродвигателя ЭПА (по трем фазам). Активная мощность рассчитывалась по формуле

$$P(t) = \frac{1}{T} \cdot \int_t^{t+T} u(\tau) \cdot i(\tau) dt, \quad (1)$$

где T – период несущей частоты (50 Гц); $u(\tau)$, $i(\tau)$ – значения напряжения и тока в момент времени τ соответственно.

ОПРЕДЕЛЕНИЕ СЕГМЕНТОВ ДЛЯ ОБУЧЕНИЯ НЕЙРОННОЙ СЕТИ

Для обучения нейронной сети были выбраны следующие временные интервалы:

- разворот двигателя;
- подрыв запорного органа (для сигнала «открытия»);
- рабочий ход;
- уплотнение в затворе (для сигнала «закрытия»).

Таким образом, результатом сегментации является разбиение сигнала активной мощности на четыре сегмента (рис. 2).

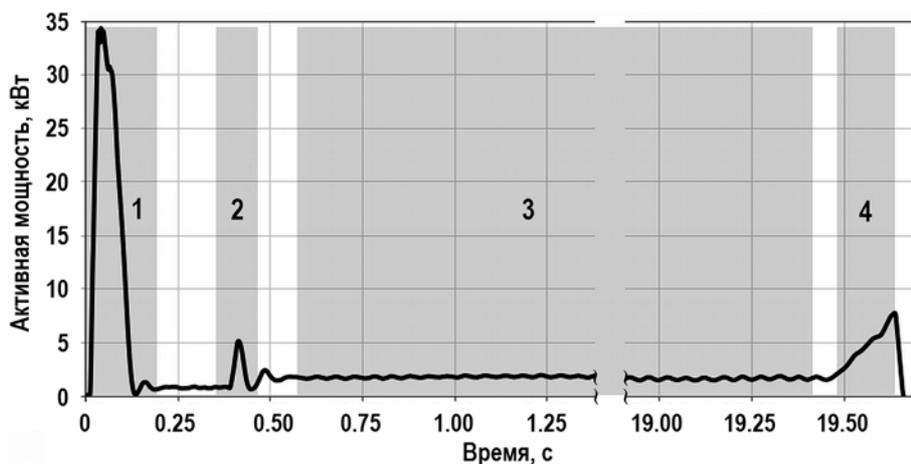


Рис. 2. Сегментация сигнала активной мощности: 1 – старт (разворот) двигателя; 2 – подрыв запорного органа (для «открытия»); 3 – рабочий ход; 4 – уплотнение (для «закрытия»)

Для обучения сети имеющиеся сигналы активной мощности были объединены в одномерный массив и «нарезаны» на отрезки длиной 100000. Данные отрезки размечались в интерактивном режиме с помощью кода, написанного на языке Python, где каждой точке в сигнале выставлялся соответствующий класс. Далее с помощью кодировщика One hot создавался целевой вектор. Этот кодировщик берёт столбец с категориальными данными и создаёт для него несколько новых столбцов. Числа заменяются на единицы и нули в зависимости от того, какому столбцу какое значение присуще. В нашем случае получились пять столбцов, которые обозначают

– четыре класса (см. рис. 2) с метками от 1 до 4, соответствующими номеру сегмента и окрашенными в серый цвет;

– один класс с меткой «No_label» – оставшиеся участки сигнала, не представляющие интерес для анализа и не имеющие окраски на рис. 2.

В итоге исходные данные представлены набором, состоящим из 571 отрезков равной длины и соответствующих им масок с обозначением каждого пикселя в сигнале, принадлежащего классу (сегменту) на рис. 2.

Для лучшего понимания в табл. 1 приведены сведения по размеченным сегментам, их количеству и соотношению.

Таблица 1

Информация по сегментам

Класс	Revers	Podriv	Flat	Stop	No_label
Соответствующий временной интервал (сегмент)	Пуск (разворот) двигателя	Подрыв запорного органа	Рабочий ход	Уплотнения запорного органа	Участки сигнала, не рассматриваемые в анализе
Соотношение пикселей, %	0.69	0.68	95.93	0.38	2.32
Количество сегментов во всей выборке	333	121	330	137	838
Объем выборки	571				

АРХИТЕКТУРА СЕТИ

За основу была принята сеть U-Net, предложенная в [4], созданная в 2015 г. для сегментации биомедицинских изображений. Её архитектура представляет собой свёрточную сеть, модифицированную так, чтобы она могла работать с меньшим количеством примеров (обучающих образов) и делала более точную сегментацию.

Сеть состоит из последовательно соединённых энкодера и декодера. Энкодер отвечает за захват различных признаков в разных масштабах, а декодер использует эти признаки для построения окончательной карты сегментации. Отличительной особенностью данной модели являются элементы «skip-connections», соединяющие части декодера и энкодера в каждом масштабе, т.е. для передачи на вход декодера тензора выполняется соединение симметричного выхода с энкодера и выхода предыдущего слоя декодера. Эти слои позволяют повторно использовать карты признаков из любого масштаба в декодере, что приводит к улучшению детализации сегментации.

После всех свёрточных слоев добавлена также batch-нормализация, что улучшило процесс сходимости и скорости обучения. Кроме того, она помогает контролировать веса сети, поскольку их значения всегда сохраняются в пределах нормированных значений.

ФУНКЦИИ ПОТЕРЬ

Как видно из табл. 1, в данных явно прослеживается несбалансированность классов. Дисбаланс данных является распространенной проблемой в задачах машинного обучения, таких как сегментация и классификация. В такой ситуации, если все данные используются как есть, высока вероятность того, что классификатор будет демонстрировать искаженную производительность в пользу наиболее представленных классов.

Для решения этой проблемы и достижения наилучшего качества сегментации было

проведено исследование различных функций потерь.

Кросс-энтропия

Наиболее часто используемая функция потерь для задачи сегментации изображений – это кросс-энтропийная потеря, исследующая каждый пиксель индивидуально и сравнивающая предсказания класса с заданным целевым вектором.

Поскольку кросс-энтропийная потеря оценивает предсказания класса для каждого пиксельного вектора индивидуально, а затем выполняет усреднение по всем пикселям, то, по сути, утверждается, что обучение каждого пикселя в изображении одинаково. Это является проблемой, так как рассматриваемые классы имеют несбалансированное представление по выборке.

В статье [5] предлагается взвешивание этой потери для каждого выходного канала, чтобы противодействовать дисбалансу классов, присутствующему в наборе данных. Формула для взвешенной по классам категориальной кросс-энтропии записывается следующим образом:

$$WCE = -\frac{1}{N} \cdot \sum_i \omega_i \sum_j y_{ij} \lg p_{ij}, \quad (2)$$

где N – число классов; y – истинное значение класса, которому принадлежит пиксель; p – предсказанное значение класса для пикселя.

В статье [4] обсуждается схема взвешивания потерь для каждого пикселя, чтобы у границ сегментированных объектов был больший вес. Эта схема взвешивания потерь помогла модели U-Net сегментировать клетки в биомедицинских изображениях прерывистым образом, так что отдельные клетки могут быть легко идентифицированы в бинарной карте сегментации.

Таким образом итоговая формула для попиксельно взвешенной категориальной кросс-энтропии принимает вид

$$PWCE = -\frac{1}{N} \cdot \sum_i \sum_j (\omega_i + \omega_{ij}) y_{ij} \lg p_{ij}, \quad (3)$$

$$\omega_i = \lg \frac{n - n_i}{n_i}, \quad \omega_{ij} = \omega_0 \exp[-d_{ij}^2 / (2\sigma^2)],$$

где ω_i – вес класса, который был рассчитан по формуле, предложенной в [6]; n_i – количество элементов в i -ом классе; n – общее количество элементов; d – расстояние до ближайшей границы; ω_{ij} – вес пикселя.

С помощью этой стратегии возможен контроль результатов сегментации как на уровне класса, так и на уровне пикселей с настройкой функции потерь по желанию.

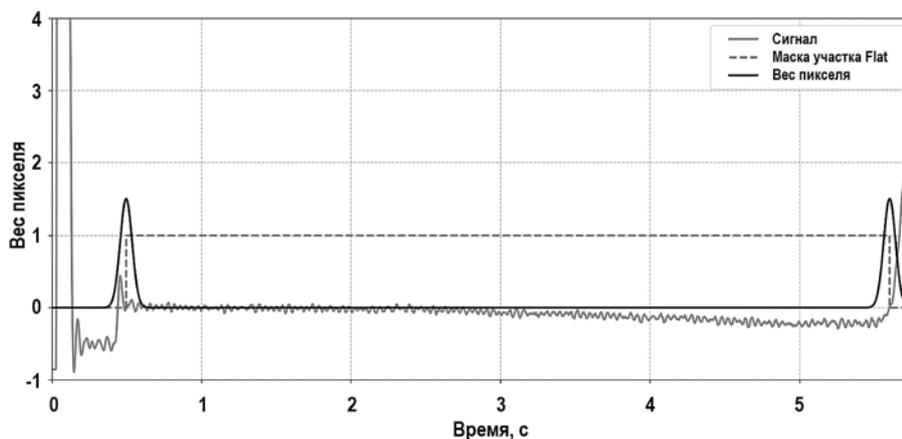


Рис. 3. График весов пикселей

На рисунке 3 показано, как выглядят веса пикселей, рассчитанные по формуле (3).

Dice-коэффициент

В статье [4] в качестве функции потерь рассматривался также Dice-коэффициент, описанный в [8] и впервые представленный в статье [7]. Эта функция хорошо показала себя при решении задач семантической сегментации с чрезвычайно несбалансированными классами. Этот показатель находится в диапазоне $[0, 1]$, где Dice-коэффициент, равный единице, означает идеальное и полное перекрытие. Dice-коэффициент был первоначально разработан для двоичных данных, и может быть рассчитан по формуле

$$Dice = 2|A \cap B| / (|A| + |B|). \quad (4)$$

Здесь в числителе записан удвоенный набор общих элементов между наборами A и B , а в знаменателе – сумма количеств элементов в этих наборах.

В случае оценки Dice-коэффициента на предсказанных масках сегментации можно аппроксимировать $|A \cap B|$ как поэлементное умножение между прогнозом и целевой маской, а затем суммировать полученную матрицу.

Поскольку целевая маска для каждого класса является двоичной, то эффективно обнуляются все пиксели из прогноза, которые не «активированы» в целевой маске. Для остальных пикселей, по существу, штрафуются прогнозы с низкой достоверностью; более высокое значение этого выражения приводит к лучшему Dice-коэффициенту.

Для количественной оценки $|A|$ и $|B|$ некоторые исследователи [9] используют простую сумму, тогда как другие [6] предпочитают использовать для этого вычисления сумму квадратов. В данной работе предпочтение было отдано сумме квадратов, так как эта функция потерь имеет лучшую сходимость. В связи с этим формула для расчёта Dice-коэффициента принимает вид

$$Dice = \frac{2 \sum_i y_i \cdot p_i}{\sum_i y_i^2 + \sum_i p_i^2}, \quad (5)$$

где y_i и p_i – истинная и предсказанная вероятности принадлежности классу.

Тогда функция потерь определяется как

$$Dice_loss = 1 - Dice. \quad (6)$$

Что касается выходных данных нейронной сети, то числитель в (5) представляет общие активации между прогнозом и целевой маской, тогда как знаменатель учитывает количество активаций в каждой маске отдельно. Это приводит к нормализации потерь в соответствии с размером целевой маски, так что потеря $Dice_loss$ не препятствует обучению классов с меньшим пространственным представлением во входных данных.

Аналогично формулам (3), (4) введем понятие попиксельно взвешенного $Dice_loss$:

$$PWDice_loss = Dice_loss + \frac{1}{N} \sum_i \sum_j \omega_{ij} \cdot (y_{ij} - p_{ij})^2. \quad (7)$$

ОЦЕНКА КАЧЕСТВА НЕЙРОННОЙ СЕТИ

В качестве метрики для оценки качества нейронной сети была использована функция «пересечение над объединением» (Intersection over Union – IoU), известная как индекс Жаккарда, являющаяся одним из наиболее часто используемых показателей в семантической сегментации. IoU – это область перекрытия между прогнозируемой сегментацией и истинной, разделенная на область объединения между

прогнозируемой сегментацией и истинной. Этот показатель находится в диапазоне $[0, 1]$ (0 – 100%), где ноль означает отсутствие перекрытия, а единица – полное перекрытие сегментации. Для мультиклассовой сегментации среднее значение IoU ($Mean_IoU$) вычисляется путем взятия IoU каждого класса и их усреднения.

Формула для определения коэффициента IoU схожа с Dice-коэффициентом, но отличается знаменателем и выглядит следующим образом:

$$IoU = |A \cap B| / |A \cup B|, \quad (8)$$

где $|A \cap B|$ – пересечение объектов A и B ; $|A \cup B|$ – их объединение.

ОБУЧЕНИЕ

Обучение нейронной сети производилось с фиксированным набором гиперпараметров для всех тестов. В качестве оптимизатора был выбран алгоритм Adam [10] с размером партии 20, скоростью обучения 0.001. Каждый раз скорость обучения снижалась на 20% после 10-ти эпох без улучшения.

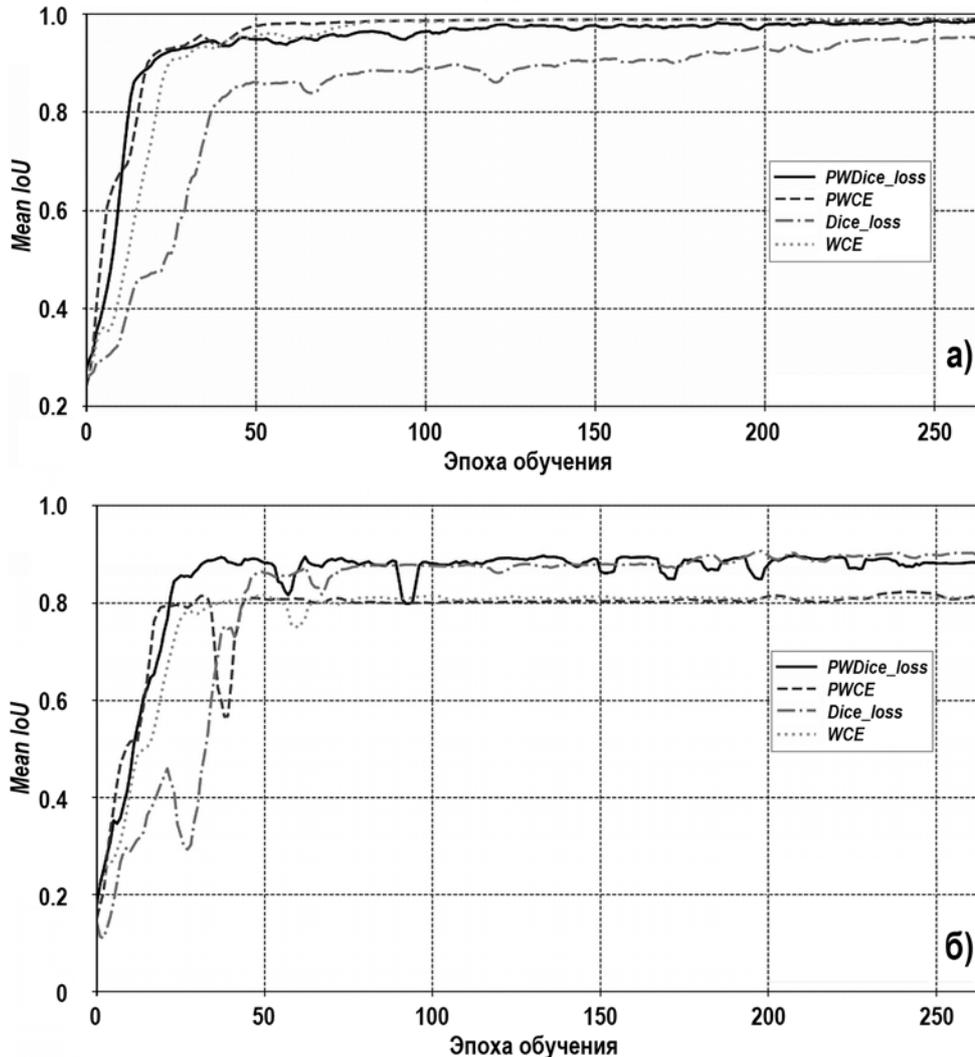


Рис. 4. Метрика $Mean IoU$ во время обучения сети с разными функциями потерь (см. формулы 8, 3, 7, 2): а) – тренировочная выборка; б) – валидационная выборка

На рисунке 4 приведены результаты обучения сети на тренировочной и валида-

ционной выборках с использованием различных функций потерь.

Категориальная кросс-энтропия приводит к лучшим результатам на обучающей выборке, но к худшим при валидации, что указывает на лучшую обобщающую способность функции *Dice*.

Как видно из графиков, добавление в функцию потерь пиксельного взвешивания приводит к лучшей сходимости сети, и в случае «взвешенного» *PWDice-loss* значения на тренировочной выборке метрики *Mean_IoU* на 5 – 10% больше, чем у *Dice_loss* без взвешивания. Однако на тестовой выборке у этих функций потерь значения метрики *Mean IoU* примерно одинаковы.

Для более детальной оценки результатов сегментации в табл. 2 представлены значения метрики *IoU* для каждого класса (см. табл. 1), посчитанные сетью с различными функциями потерь.

Таблица 2

IoU по классам (в процентах) на тестовой выборке

Название класса	Функция потерь			
	<i>PWDice_loss</i>	<i>PWCCE_loss</i>	<i>Dice_loss</i>	<i>CCE_loss</i>
Revers	98.12	97.98	97.68	98.28
Podriv	81.32	71.44	92.60	73.21
Flat	99.65	99.64	99.73	99.14
Stop	69.38	62.61	71.65	63.01
No_label	88.49	87.99	90.06	87.32

Для каждой временной точки сигнала активной мощности нейронная сеть предсказывает вероятность того или иного класса. Таким образом, выбрав множество точек сигнала активной мощности, для которых вероятность близка к единице по классу «Flat», можно утверждать, что эти точки относятся к сегменту «Рабочий ход».

Пример сегментации сигнала активной мощности приведен на рис. 5. Линиями показаны вероятности классов (Flat, Podriv, Revers, Stop). Отсекая эти вероятности по порогу, например, больше 0.95, получаем границы сегментов.

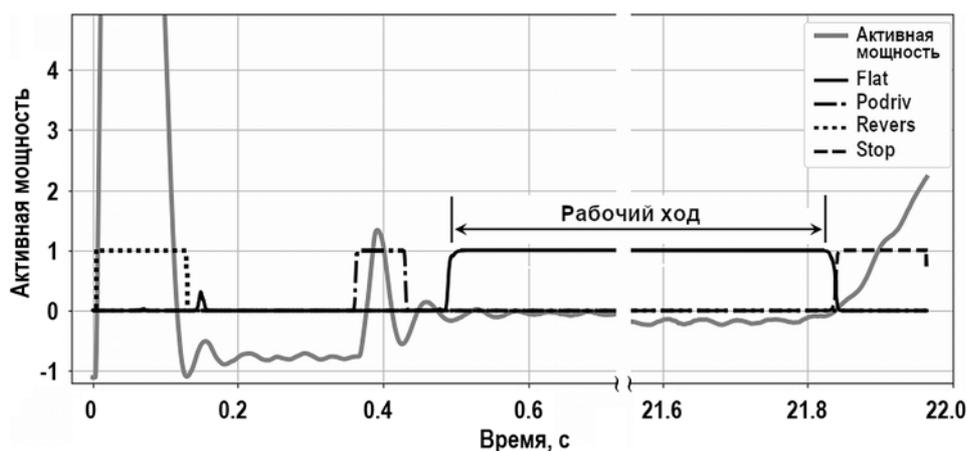


Рис. 5. Результат сегментации сигнала активной мощности нейронной сетью

ВЫВОДЫ

Разработан и исследован новый подход к сегментации сигналов активной мощности ЭПА с использованием свёрточной нейронной сети. Установлено, что функция потерь *Dice_loss* позволяет достичь наилучших результатов.

Нейронная сеть показала результаты высокого качества и позволяет автоматизировать процесс диагностирования ЭПА, исключить влияние человеческого фактора, значительно увеличить скорость диагностирования и выявления неисправностей ЭПА, исключить возможные ошибки, связанные с влиянием человеческого фактора.

За счет автоматизации процесса разбиения сигналов активной мощности на сегменты диагностирование технического состояния ЭПА стало возможно проводить как в формате офф-лайн, так и в формате он-лайн.

Литература

1. *Abonyi J., Szeifert F., Babuska R.* Modified Gath-Geva Fuzzy Clustering for Identification of Takagi-Sugeno Fuzzy Models. // IEEE Systems, Man and Cybernetics, Part B. – 2002. – PP. 612-621.
2. *Матвеев А.В., Жидков С.В., Адаменков А.К., Галивец Е.Ю., Усанов Д.А.* Комплексный подход к диагностированию электроприводной арматуры применительно к задачам управления ресурсом. // Арматуростроение – 2009. – №2 (59). – С. 53-59.
3. МТ 1.2.3.02.999.0085-2010. Методика «Диагностирование трубопроводной электроприводной арматуры». – М.: Росэнергоатом, 2010. – 239 с.
4. *Ronneberger O., Fischer P., Brox T.* U-Net: Convolutional Networks for Biomedical Image Segmentation. // arXiv:1505.04597v1 [cs.CV]. – 18 May 2015. – 8 p.
5. *Long J., Shelhamer E., Darrell T.* Fully Convolutional Networks for Semantic Segmentation. // arXiv:1411.4038v2 [cs.CV]. – 8 Mar 2015. – 10 p.
6. *Xiaoya Li.* Dice Loss for Data-imbalanced NLP Tasks. // arXiv:1911.02855v3 [cs.CL]. – 29 Aug 2020. – 12 p.
7. *Sorensen Th.* A Method of Establishing Groups of Equal Amplitude in Plant Sociology Based on Similarity of Species Content and its Application to Analyses of the Vegetation on Danish Cc of the Vegetation on Danish Commons. // Biologiske Skrifter. – 1948. – Bind 5. – PP. 1-34.
8. *Milletari F.* V-Net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation. // arXiv:1606.04797v1 [cs.CV]. – 15 Jun 2016. – 11 p.
9. *Drozdal M., Vorontsov E., Chartrand G., Kadoury S., Pal Ch.* The Importance of Skip Connections in Biomedical Image Segmentation. // arXiv:1608.04117v2 [cs.CV]. – 22 Sep 2016. – 9 p.
10. *Kingma D.P., Ba J.* Adam: A Method for Stochastic Optimization. // arXiv:1412.6980v9 [cs.LG]. 30 Jan 2017. – 15 p.

Поступила в редакцию 24.02.2021 г.

Авторы

Коцоев Константин Игоревич, инженер
E-mail: kotsoev@kvantprogramm.ru

Трыков Евгений Львович, специалист по ИТ, канд. физ.-мат. наук
E-mail: trykov@diaprom.ru

Трыкова Ирина Владимировна, программист
E-mail: trykova@kvantprogramm.ru

UDC 621.646

THE USE OF CONVOLUTIONAL NEURAL NETWORK FOR SEGMENTING SIGNALS OF ELECTRICALLY-ACTUATED VALVES

Kotsoev K.I.*,**, Trykov E.L.**, Trykova I.V.***

* Bauman Moscow State Technical University

5, Bld. 1, 2-ya Baumanskaya Str., 105005 Moscow, Russia

** JSC «STC Diaprom»

6, Rooms 22-23 Koroleva Str., 249031 Obninsk, Kaluga Reg., Russia

*** «KVANT PROGRAMM» LTD

5/12, Bld. 3, Room B1, Zeleny Ave., 111558 Moscow, Russia

ABSTRACT

Electrically-actuated valves (EAV) represent one of the most numerous classes of equipment at nuclear power plants. The main problem of diagnosing EAV failures is the lack of operational (online) automated control of the technical condition of the EAV when the power unit is operating at full capacity.

In this regard, an important task is diagnosing the EAV according to the current and voltage signals consumed during the 'opening' and 'closing' operations of the EAV. The current and voltage signals are time series measured at regular intervals. The current (and voltage) signals can be received online and contain all the necessary information for the online diagnostics of the EAV condition.

The essence of the approach is to be able to calculate active power signals from the current and voltage signals, and then extract characteristics ('diagnostic signs') from certain sections (segments) of the active power signals, according to the values of which the state of the EAV can be diagnosed.

The paper is focused on the problem of automating the division of active power signals into segments (segmentation). In order to transfer the segmentation process to automatic mode, the authors have developed an algorithm based on the use of a convolutional neural network.

The developed convolutional neural network makes it possible to perform online segmentation of active power signals of the EAV. The network has shown good results, which will allow automated monitoring of the technical condition of the EAV when the reactor is operating at full capacity. As a result, the quality of the EAV operation is improved while the failure rate is reduced.

Key words: convolutional neural network, time series segmentation, electrically-actuated valves, automated system.

REFERENCES

1. Abonyi J., Szeifert F., Babuska R. Modified Gath-Geva Fuzzy Clustering for Identification of Takagi-Sugeno Fuzzy Models. *IEEE Systems, Man and Cybernetics, Part B*. 2002, pp. 612-621.
2. Matveev A.V., Zhidkov S.V., Adamenkov A. K., Galivets E.Yu., Usanov D.A. An Integrated Approach to Diagnosing Electrodriven Valves to applied to the Tasks of Resource Management. *Armaturostroenie*. 2009, no. 2 (59), pp. 53-59 (in Russian).
3. MT 1.2.3.02.999.0085-2010. *Methodology «Diagnosing of Pipeline Electrodriven Valves»*. Moscow. Rosenergoatom Publ., 2010, 239 p. (in Russian).
4. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. *arXiv:1505.04597v1 [cs.CV]*. 18 May 2015, 8 p.
5. Long J., Shelhamer E., Darrell T. Fully Convolutional Networks for Semantic Segmentation. *arXiv:1411.4038v2 [cs.CV]*. 8 Mar 2015, 10 p.

6. Xiaoya Li. Dice Loss for Data-imbalanced NLP Tasks. *arXiv:1911.02855v3 [cs.CL]*. 29 Aug 2020, 12 p.
7. Sorensen Th. A Method of Establishing Groups of Equal Amplitude in Plant Sociology Based on Similarity of Species Content and its Application to Analyses of the Vegetation on Danish Cc of the Vegetation on Danish Commons. *Biologiske Skrifter*. 1948, v. 5, pp. 1-34.
8. Milletari F. V-Net: Fully Convolutional Neural Networks for Volumetric Medical Image Segmentation. *arXiv:1606.04797v1 [cs.CV]*. 15 Jun 2016, 11 p.
9. Drozdal M., Vorontsov E., Chartrand G., Kadoury S., Pal Ch. The Importance of Skip Connections in Biomedical Image Segmentation. *arXiv:1608.04117v2 [cs.CV]*. 22 Sep 2016, 9 p.
10. Kingma D. P., Ba J. Adam: A Method for Stochastic Optimization. *arXiv:1412.6980v9 [cs.LG]*. 30 Jan 2017, 15 p.

Authors

Kotsoev Konstantin Igorevich, Engineer
E-mail: kotsoev@kvantprogramm.ru

Trykov Evgeny L'vovich, Information Technology Specialist, Cand. Sci. (Phys.-Math.)
E-mail: trykov@diaprom.ru

Trykova Irina Vladimirovna, Programmer
E-mail: trykova@kvantprogramm.ru