

Н.А. ИСКРА

ПОДХОД К АНАЛИЗУ ИЗОБРАЖЕНИЙ В СИСТЕМАХ МОНИТОРИНГА

Белорусский государственный университет информатики и радиоэлектроники
П. Бровки, 6, Минск, 220013, Беларусь

Поступила в редакцию

Аннотация. В данной работе предлагается подход к анализу изображений в системах мониторинга. Основное внимание уделяется построению семантической модели изображения. Результаты экспериментов по языковой интерпретации полученной модели показывают улучшение скорости обработки и качества аннотирования изображений до 60% (метрика METEOR) по сравнению с нейросетевыми методами. Также, использование данной модели позволяет очистить и нормализовать данные для обучения, в том числе нейросетевых архитектур, применяющихся в анализе изображений. Рассматриваются перспективы использования данной методики в ситуационном мониторинге.

Ключевые слова: ситуационный мониторинг, детекция объектов, семантическая модель, нейронные сети, обработка изображений, обработка языка, R-CNN, WordNet.

Abstract. In this paper the approach to image analysis in monitoring systems is proposed. Main focus is on the construction of the semantic model of the image. Experimental results with language interpretation of the model show the increase of the processing speed and the quality of image captioning up to 60% (METEOR metric) in comparison to pure neural network based methods. The usage of the model also allows to clean and normalize data for training neural network architectures specialized on image analysis among others. The perspectives of this technique employment in situational monitoring are considered.

Keywords: situational monitoring, object detection, semantic model, neural networks, image processing, language processing, RCNN, WordNet

Doklady BGUIR. 201*, Vol. ***, No. *, pp. **-**

Approach to image analysis and interpretation for monitoring systems

N.A. Iskra

Введение

Задача анализа изображений в системах технического зрения стоит сегодня остро. Автоматическая интерпретация изображения при мониторинге – задача нетривиальная. Например, для системы видеонаблюдения, было бы актуальным не просто записывать и сохранять видео, но и анализировать происходящее, а также сигнализировать о любых подозрительных ситуациях – нарушениях, происшествиях, действиях, требующих реагирования.

Рассматриваемый в данной работе подход к анализу изображений системой технического зрения проходит по следующему сценарию:

Шаг 1. Выделение отдельных объектов на изображении. Это могут быть только значимые в контексте данной системы объекты (например, участники движения,

дорожная разметка и знаки в системах наблюдения за трафиком), области, очерчивающие объекты, или более точное выделение объекта по픽сельно.

Шаг 2. Построение семантической модели. На данном этапе формализуются связи между объектами и/или атрибуты отдельных объектов.

Шаг 3. Интерпретация модели. По построенной модели может быть получено текстовое описание происходящего (аннотация изображения, например, для ведения журнала наблюдения) или определены конкретные ситуации на изображении, представляющие интерес (например, случаи нарушения правил дорожного движения, дорожно-транспортные происшествия и т.п.) Во втором случае интерпретация модели будет состоять в выделении только тех связей и атрибутов, которые могут сигнализировать об аномальной ситуации.

Наиболее важной частью в реализации анализа ситуации является построение интерпретируемой модели изображения. В данной статье основное внимание будет уделено методике построения этой модели, а также выбору алгоритма детекции объектов на изображении, как предварительного этапа построения модели.

Теоретический анализ

А. Детекция объектов на изображении

Первым этапом анализа является обработка исходного изображения и автоматическое распознавание объектов на нём. При этом решается одна из следующих подзадач [1]:

- семантическая сегментация изображения (англ. Semantic Segmentation) – для каждого пикселя во входном изображении определить его категорию или класс;

- классификация и локализация (англ. Classification and Localization) – определить класс одиночного объекта на изображении и его точное месторасположение;

- детекция объектов (англ. Object Detection) – определить класс и прямоугольную область, ограничивающую каждый из объектов на изображении;

- сегментация образов (англ. Instance Segmentation) – на изображении с множеством объектов определить контуры (все видимые пиксели) и класс каждого из объектов.

Для построения семантической модели изображения наиболее интересны решения двух последних подзадач.

Среди современных алгоритмов детекции объектов актуальны методы, в том числе основанные на использовании глубоких нейронных сетей:

- метод скользящего окна (англ. Sliding Window) [2];

- метод предложения регионов (англ. Region Proposals) [3];

- метод детекции за один проход (англ. Single Shot Detection) [4].

Каждый из подходов имеет свои достоинства и недостатки, важные с точки зрения применения их в системах, требующих анализа изображения [5].

Для построения модели, описанной в данной статье, наиболее подходят методы, основанные на классе нейросетевых моделей с предложением регионов, так называемые R-CNN, и их развитие:

- R-CNN [3] – представляет собой модель последовательной обработки изображения: генерацию набора предложений регионов, применение предобученной свёрточной нейронной сети с завершающим слоем опорных векторов и линейную регрессию для более точного определения регионов;

– Fast R-CNN [6] – модель, в которой для ускорения работы предыдущей последовательности обработки добавляется подборка регионов и объединение всех нейросетевых моделей в одну;

– Faster R-CNN [7] – для ещё большего ускорения в модели используется селективный поиск регионов;

– Mask R-CNN [8] – в отличие от предыдущих моделей, данная использует бинарную маску для определения не просто прямоугольного региона – кандидата в объекты, а конкретных пикселей, принадлежащих объекту, что, по сути, и является решением задачи сегментации образов, описанной выше.

Б. Модель изображения

За основу модели изображения принимается так называемый сцен-граф (англ. Scene Graph) [9]. Сцен-граф – это структура данных, описывающая содержание сцены, которая, в свою очередь, может быть задана изображением или его текстовым описанием. В сцен-графе закодированы экземпляры объектов, их атрибуты и отношения между объектами.

Формально, сцен-граф определяется следующим образом: пусть C – множество классов объектов, A – множество типов их атрибутов, R – множество типов отношений. Сцен-граф задаётся как $G = (O, E)$, где $O = \{o_1, \dots, o_n\}$ – множество объектов – вершины графа, $E \subseteq O \times R \times O$ – множество ребер графа. Каждый объект представлен как $o_i = \{c_i, A_i\}$, где $c_i \in C$ – класс объекта, а $A_i \subseteq A$ – его атрибуты.

Сцен-граф может быть привязан к изображению. Пусть V – множество прямоугольных областей, каждая из которых ограничивает определённый объект на изображении (назовём их области объектов, англ. Bounding Boxes), тогда привязка сцен-графа $G = (O, E)$ к изображению, это функция $\gamma: O \rightarrow V$, или γ_o .

Для экспериментальной части используется набор данных Visual Genome [10], который представляет собой набор из размеченных 108 077 изображений, для которых путём привлечения большого количества людей, вручную были определены 5,4 миллиона описаний регионов в виде текста и сцен-графов.

Пример привязки сцен-графа к регионам на изображении из Visual Genome приведён на рис. 1.



Рис. 1. Пример изображения из Visual Genome с привязкой [11]

Fig.1. An example of an image from Visual Genome with grounding [11]

Текстовые привязки сцен-графов (каждый объект, атрибут и отношение) в Visual Genome соответствуют синсетам из WordNet [12]. WordNet – сетевое представление слов, структурированное по смысловым отношениям между ними. В WordNet каждое слово представлено множеством своих синонимичных значений, которое называется синсетом (англ. synset). Каждый синсет представлен тройкой

<word>.<pos>.<number>, где word – слово, pos – часть речи (n – существительное, v – глагол, а – прилагательное, r – наречие), number – индекс значения. Например, понятие «человек» в WordNet представлено тремя значениями person.n.01, person.n.02 и person.n.03. Текстовая привязка объекта «person» из Visual Genome соответствует синсету person.n.01. В WordNet между синсетами установлены связи синонимии, антонимии, «часть-целое» (мероним – холоним), «общее-частное» (гипероним – гипоним).

Методика построения модели изображения

Для построения модели изображения в виде сцен-графа нужно сначала определить объекты на изображении, а затем для каждой пары объектов принять решение, могут ли они иметь связи и какие именно [13]. Подбор связей может быть значительно упрощен за счёт использования внешних баз знаний (общих или узкоспециализированных для конкретной предметной области) [14]. В обоих случаях для изображения, на котором найдено n объектов, необходимо рассмотреть ($n^2 - n$) отношений. В данной работе предлагается упростить решение за счёт определения так называемых «значимых» (англ. salient) объектов [15], и в дальнейшем рассматривать ($n - 1$) отношений. Такой подход соответствует сценарию наблюдения за определёнными объектами в системах мониторинга.

Частотный анализ данных Visual Genome показывает, что самые частые отношения между объектами на изображениях – это пространственные отношения: отношение «на» («on») встречается 642 150 раз, «в» («in») – 218 166, «сзади» («behind») – 39 833. Кроме того, благодаря иерархической структуре привязок WordNet, пространственные отношения могут быть описаны более подробно: например, «car in a parking lot» («машина на стоянке») или «car is parked in a parking lot» («машина припаркована на стоянке»). Действительно, при взгляде на изображение человек прежде всего отмечает, как объекты расположены друг относительно друга в пространстве. При автоматической обработке также возможно определить смысловые пространственные отношения между объектами [16].

На рис. 2 показана методика автоматического построения модели для пространственных отношений.

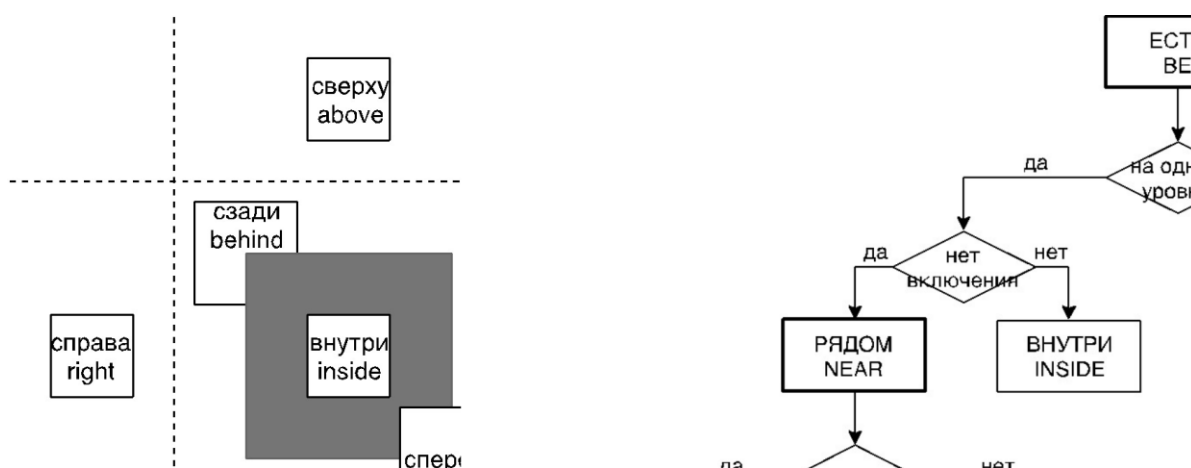


Рис. 2. Методика автоматического построения модели для пространственных отношений

Fig.2. The technique for automatic model construction for spatial relations

В левой части рис. 2 визуализирована система всех возможных пространственных отношений: область значимого объекта (субъекта) закрашена, остальные области – варианты расположения объекта интереса (объекта), для которого при помощи дерева принятия решений на правой части рис. 2 будет определяться вид пространственного отношения вида «субъект – отношение – объект».

Следует отметить, что для наименований видов отношений в данной модели используются предлоги, которые не представлены в WordNet, т.е. на данном этапе привязка к WordNet не возможна, однако на следующем шаге (для интерпретации) будут применяться синсеты, содержащие данные предлоги и их смыслы (be.v.01, along.r.01 и др.).

В дереве прямоугольниками показаны блоки, соответствующие определённому виду отношения, при этом выделены более общие отношения, требующие уточнения (как гиперонимы из WordNet). При построении дерева для ускорения процесса принятия окончательного решения правила (на рисунке показаны ромбами) формулировались в соответствии со статистическими данными анализа Visual Genome, таким образом, что более частый случай будет находиться в дереве левее. Так, в исходном наборе данных отношение «рядом» (near) встречается чаще других пространственных отношений (26 316 раз), «сверху» (above) – существенно чаще, чем «снизу» (below) – 13 767 раз и 3 349 раз соответственно и т.д.

Реализация метода, применяемая для постановки экспериментов, описанных далее, сначала производит детекцию объектов методом на основе Faster R-CNN, определяя классы объектов и их области. За значимый принимается объект с наибольшей площадью области.

На реальных естественных изображениях границы областей объектов, как правило, пересекаются. Если пересечение областей значимого объекта и объекта интереса менее 50% площади области объекта интереса, выбираются соответствующие правилу решения отношения из множества {«сверху», «снизу», «слева», «справа»} (т.е. считается, что пересечения нет). При пересечении более 50% выбор отношения осуществляется на основании сравнения пиксельных масок объектов, полученных при применении Mask R-CNN к областям объектов: если в зоне пересечения больше пикселей значимого объекта, выбирается отношение «сзади», и отношение «спереди» – в противоположном случае.

Экспериментальная часть

А. Экспериментальная оценка построения модели

Для экспериментальной оценки методики построения модели изображения из базы Visual Genome были выбраны два набора изображений.

Первый набор представляет собой выборку из изображений, в которой на каждое из рассматриваемых отношений приходится по 50 регионов с привязкой (т.е. 50 регионов с отношением «above», 50 регионов – с «below» и т.д. – всего 350 регионов). Примеры таких изображений приведены на рисунке 3.




Рис. 3. Примеры регионов из экспериментальной выборки
 Fig.3. Examples of regions from experimental set

Второй набор выбирался автоматически по результатам детекции объектов и определению отношений между объектами в соответствии с методикой. Его размер также 350 регионов (по 50 регионов на каждое отношение).

Размер экспериментальных выборок относительно небольшой, поскольку верификацию результатов определения отношений планировалось проводить вручную для того, чтобы оценить не только точность построения модели, но и «натуральность» (англ. *gameability*) полученных результатов, т.е. исключить ситуации, когда высокий показатель метрики оценки качества (правильный результат) может соответствовать выражению, которое человек считает «ненатуральным» (например, «the sky is blue in color» вместо «the sky is blue») [17].

В первом эксперименте автоматически определяются отношения в выбранных регионах и для обоих наборов результаты сравниваются с эталонными (приведенными в базе) и оцененными экспертами (см. табл. 1).

Б. Экспериментальная оценка интерпретации модели

Для экспериментальной оценки интерпретации построенной модели для первого набора регионов генерируются текстовые описания регионов путём замены отношений соответствующими наиболее часто встречающимся синонимами из WordNet (например, «car below tree» превращается в «car parked under tree») и полученные аннотации сравниваются с эталонными при помощи метрики METEOR [18].

Также результаты аннотирования сравниваются с результатами, полученными при применении комбинированного нейросетевого [19] и чисто свёрточного нейросетевого [20] подходов к аннотации регионов изображений без построения семантической модели (табл. 3).

Результаты и их обсуждение

В табл. 1 приводятся результаты оценки построения модели. Результаты детекции объектов в эксперименте принимаются за верные, если совпадает метка класса, различия в детекции областей принимаются за несущественные в данном контексте.

Таблица 1. Оценка результатов построения модели
 Table 1. The evaluation of model construction results

	Набор 1		Набор 2	
	КОЛ-ВО	%	КОЛ-ВО	%
Размер набора (отношений/объектов)	350/700	100	350/700	100
Детекция объектов (при помощи RCNN)	687	98,1	694	99,1
Отношения (совпадение с представленными в базе)	335	95,7	344	98,2
Отношения (совпадение при визуальном анализе)	340	97,1	346	98,8

Очевидно, что ошибки в детекции (в первом наборе их 13, во втором – 6) «отбраковывают» регионы, в которые входят данные объекты. Соответственно, для первого набора, если считать, что при определении отношений в эксперименте участвуют уже не 350, а 343 региона, точность определения отношений будет не 95%, а 99%.

Более высокий процент правильности определения отношений при визуальной оценке объясняется тем, что в Visual Genome некоторые исходные данные содержат неточности. В табл. 2 приведены результаты совпадения отдельных видов отношений с представленными в базе для экспериментального набора 1 и видно, что в исходном наборе присутствует 5 примеров неточностей, т.е., например, в базе записано отношение «BELOW», а эксперт видит, что объекты находятся рядом (отношение «NEAR»).

Таблица 2. Анализ точности определения отношений по видам
Table 2. The Analysis of relations estimation precision for different relations

Пространственное отношение	Визуальная оценка (из 50-ти)	Предлагаемая методика (из 50-ти)
BEHIND	49	44
IN FRONT	48	45
RIGHT	50	50
LEFT	50	50
INSIDE	50	50
ABOVE	49	48
BELOW	49	48

Таким образом, можно использовать методику автоматического определения пространственных отношений и для частичной очистки данных. Так, перезапустив процесс построения модели для набора 1 удалось «исправить» 4 из 5 неточностей, определённых путём визуального анализа.

В табл. 3 приведены результаты оценки генерации аннотаций для первого «исправленного» набора.

Таблица 3. Оценка качества аннотирования регионов
Table 3. The evaluation of region captioning quality

Модель кодера	METEOR
CNN + RNN [19]	0.305

TCN [20]	0.290
Семантическая модель	0.515

Как видно в таблице, использование семантической модели для кодирования информации из изображения существенно превосходит нейросетевые модели при построении осмысленных фраз, описывающих регионы. По метрике METEOR, учитывающей не только структуру аннотации, но и её семантические вариации, предлагаемая методика показывает результаты более чем на 60% лучше, чем нейросетевые подходы.

Заключение

Таким образом, предлагаемая в данной работе методика построения модели изображения, отличительной особенностью которой является определение значимых объектов, анализирует на порядок меньше отношений между объектами, что позволяет существенно сократить время обработки изображения на тестовых наборах из базы Visual Genome и улучшить качество аннотирования.

Необходимо отметить, что данный подход содержит упрощения – за значимый объект принимается самый большой, рассматриваются только отношения между двумя объектами (т.е. только фрагменты сцен-графа), не принимаются во внимание атрибуты объектов. В дальнейшем планируется использовать более сложные подходы к определению значимого объекта (в том числе на основе конкретной предметной области), полное построение и анализ сцен-графа.

При проведении ситуационного мониторинга для более точной интерпретации модели нужно выбирать изображения со специальными ситуациями, использовать базы изображений и экспертные знания из конкретных предметных областей (мониторинг трафика, мониторинг техногенных объектов и т.д.)

Список литературы

1. Agarwal S., Terrail J.O.D., Jurie F. Recent advances in object detection in the age of deep convolutional neural networks // arXiv preprint arXiv: 1809.03193. – 2018.
2. Müller J., Fregin A., Dietmayer K. Disparity sliding window: object proposals from disparity images / IEEE/RSJ International conference on intelligent robots and systems. – 2018. – pp. 5777 – 5784.
3. Girshick R., Donahue J., Darrell T., Malik J. Rich feature hierarchies for accurate object detection and semantic segmentation / Proceedings of the IEEE conference on computer vision and pattern recognition. – 2014. – pp. 580 – 587.
4. Liu W., Anguelov D., Erhan D., Szegedy C., Reed S., Fu C.Y., Berg A.C. Ssd: Single shot multibox detector / European conference on computer vision. – Springer, Cham, 2016. – pp. 21 – 37.
5. Хурсов П.С., Искра Н.А. Алгоритмы детекции объектов для анализа изображений / Информационные технологии и системы: материалы международной научной конференции. – Минск, 2019. – с. 128 – 129.
6. Girshick R. Fast r-cnn / Proceedings of the IEEE international conference on computer vision. – 2015. – pp. 1440 – 1448.
7. Ren S., He K., Girshick R., Sun J. Faster r-cnn: Towards real-time object detection with region proposal networks / Advances in neural information processing systems. – 2015. – pp. 91 – 99.
8. He K., Gkioxari G., Dollár P., Girshick R. Mask r-cnn / Proceedings of the IEEE international conference on computer vision. – 2017. – pp. 2961 – 2969.

9. Xu D., Zhu Y., Choy C.B., Fei-Fei L. Scene graph generation by iterative message passing / Proceedings of the IEEE conference on computer vision and pattern recognition. – 2017. – pp. 5410 – 5419.
10. VisualGenome. – URL: <https://visualgenome.org>.
11. Krishna R., Zhu Y., Groth O., Johnson J., Hata K., Kravitz J., Chen S., Kalantidis Y., Li L.J., Shamma D.A., Bernstein M.S. Visual genome: Connecting language and vision using crowdsourced dense image annotations / International journal of computer vision. – 123(1). – 2017. – pp. 32 – 73.
12. Miller G.A. WordNet: An electronic lexical database. – MIT press, 1998.
13. Yang J., Lu J., Lee S., Batra D., Parikh D. Graph r-cnn for scene graph generation / Proceedings of the european conference on computer vision. – 2018. – pp. 670 – 685.
14. Iskra N., Iskra V., Lukashevich M. Neural network based image understanding with ontological approach / Open Semantic Technologies for Intelligent Systems (OSTIS-2019): материалы международной научно-технической конференции. – Минск, 2019. – с. 113 – 122.
15. Borji A., Cheng M.M., Hou Q., Jiang H., Li J. Salient object detection: A survey / Computational visual media. – 2014. – pp. 1 – 34.
16. Искра Н.А., Межень А.Л., Шункевич Д.В. Онтология предметной области пространственных сущностей для системы семантического анализа изображений / Информационные технологии и системы: материалы международной научной конференции. – Минск, 2019. – с. 112 – 113.
17. Shunkevich D., Iskra N. Ontological approach to image captioning evaluation / Pattern Recognition and Information Processing: Proceedings of the 14 international conference. – Minsk: Bestprint, 2019. – pp. 219 – 223.
18. Banerjee S., Lavie A. METEOR: An automatic metric for MT evaluation with improved correlation with human judgments / Proceedings of the acl workshop on intrinsic and extrinsic evaluation measures for machine translation and/or summarization. – 2005. – pp. 65 – 72.
19. Johnson J., Karpathy A., Fei-Fei L. Denscap: Fully convolutional localization networks for dense captioning / Proceedings of the IEEE conference on computer vision and pattern recognition. – 2016. – pp. 4565 – 4574.
20. Iskra N., Iskra V. Temporal convolutional and recurrent networks for image captioning / Pattern Recognition and Information Processing: Proceedings of the 14 international conference. – Minsk: Bestprint, 2019. – pp. 346 – 349.

References

1. Agarwal S., Terrail J.O.D., Jurie F. Recent advances in object detection in the age of deep convolutional neural networks // arXiv preprint arXiv: 1809.03193. – 2018.
2. Müller J., Fregin A., Dietmayer K. Disparity sliding window: object proposals from disparity images / IEEE/RSJ International conference on intelligent robots and systems. – 2018. – pp. 5777 – 5784.
3. Girshick R., Donahue J., Darrell T., Malik J. Rich feature hierarchies for accurate object detection and semantic segmentation / Proceedings of the IEEE conference on computer vision and pattern recognition. – 2014. – pp. 580 – 587.
4. Liu W., Anguelov D., Erhan D., Szegedy C., Reed S., Fu C.Y., Berg A.C. Ssd: Single shot multibox detector / European conference on computer vision. – Springer, Cham, 2016. – pp. 21 – 37.

5. Hursov P.S., Iskra N.A. Algoritmy detektsii ob'ektov dlya analiza izobrazheniy / Information Technologies and Systems 2019 (ITS 2019): materialy mezhdunarodnoy nauchnoy konferentsii. – Minsk, 2019. – pp. 128 – 129.
6. Girshick R. Fast r-cnn / Proceedings of the IEEE international conference on computer vision. – 2015. – pp. 1440 – 1448.
7. Ren S., He K., Girshick R., Sun J. Faster r-cnn: Towards real-time object detection with region proposal networks / Advances in neural information processing systems. – 2015. – pp. 91 – 99.
8. He K., Gkioxari G., Dollár P., Girshick R. Mask r-cnn / Proceedings of the IEEE international conference on computer vision. – 2017. – pp. 2961 – 2969.
9. Xu D., Zhu Y., Choy C.B., Fei-Fei L. Scene graph generation by iterative message passing / Proceedings of the IEEE conference on computer vision and pattern recognition. – 2017. – pp. 5410 – 5419.
10. VisualGenome. – URL: <https://visualgenome.org>.
11. Krishna R., Zhu Y., Groth O., Johnson J., Hata K., Kravitz J., Chen S., Kalantidis Y., Li L.J., Shamma D.A., Bernstein M.S. Visual genome: Connecting language and vision using crowdsourced dense image annotations / International journal of computer vision. – 123(1). – 2017. – pp. 32 – 73.
12. Miller G.A. WordNet: An electronic lexical database. – MIT press, 1998.
13. Yang J., Lu J., Lee S., Batra D., Parikh D. Graph r-cnn for scene graph generation / Proceedings of the european conference on computer vision. – 2018. – pp. 670 – 685.
14. Iskra N., Iskra V., Lukashevich M. Neural network based image understanding with ontological approach / Open Semantic Technologies for Intelligent Systems (OSTIS-2019): materialy mezhdunarodnoy nauchno-tehnicheskoy konferentsii. – Minsk, 2019. – pp. 113 – 122.
15. Borji A., Cheng M.M., Hou Q., Jiang H., Li J. Salient object detection: A survey / Computational visual media. – 2014. – pp. 1 – 34.
16. Iskra N.A., Mezhen' A.L., Shunkevich D.V. Ontologiya predmetnoy oblasti prostranstvennykh suschnostey dlya sistemy semanticheskogo analiza izobrazheniy / Information Technologies and Systems 2019 (ITS 2019): materialy mezhdunarodnoy nauchnoy konferentsii. – Minsk, 2019. – pp. 112 – 113.
17. Shunkevich D., Iskra N. Ontological approach to image captioning evaluation / Pattern Recognition and Information Processing: Proceedings of the 14 international conference. – Minsk: Bestprint, 2019. – pp. 219 – 223.
18. Banerjee S., Lavie A.. METEOR: An automatic metric for MT evaluation with improved correlation with human judgments / Proceedings of the acl workshop on intrinsic and extrinsic evaluation measures for machine translation and/or summarization. – 2005. – pp. 65 – 72.
19. Johnson J., Karpathy A., Fei-Fei L. Densecap: Fully convolutional localization networks for dense captioning / Proceedings of the IEEE conference on computer vision and pattern recognition. – 2016. – pp. 4565 – 4574.
20. Iskra N., Iskra V. Temporal convolutional and recurrent networks for image captioning / Pattern Recognition and Information Processing: Proceedings of the 14 international conference. – Minsk: Bestprint, 2019. – pp. 346 – 349.

Сведения об авторах

Искра Н.А., магистр технических наук, старший преподаватель кафедры ЭВМ, БГУИР.

Information about the authors

Iskra N.A., M. Sci, senior lecturer at ECM department, BSUIR.

Адрес для корреспонденции

220013, Республика Беларусь,
г. Минск, ул. П. Бровки, 6,
Белорусский государственный
университет
информатики и радиоэлектроники
тел. +375-29-586-93-52;
e-mail: niskra@bsuir.by
Искра Наталья Александровна

Address for correspondence

220013, Republic of Belarus,
Minsk, P. Brovka, st., 6,
Belarusian state university of
informatics and radioelectronics
tel. +375-29-586-93-52;
e-mail: niskra@bsuir.by
Iskra Natalia Alexandrovna