

能确定水面及陆地上的地形变化趋势，水面以下难以获取。获取水下地形有两种方法：一是采用对采集点水下地形实地测量；二是根据遥感影像生成的水面以上断面的发展趋势，采用 Zhao 等人提出的河道截面获取方法进行推导。

2.3. 河道流量计算

流量 (Q) 的求取采用水力学的谢才公式，公式如下：

$$Q = \omega \cdot \frac{1}{n} R^{\frac{1}{6}} \sqrt{R \cdot i} \quad (1)$$

欲求河道内任意部位流量，可对采集点中各水力参数的计算值进行插值，形成栅格数据后再利用 ArcGIS 的栅格计算器工具输入公式 (1) 进行求取。

3. 结论

本文简要介绍了无人机技术对河道流量监测的优势及方法，得出以下结论：

1 利用无人机拍摄及信息技术处理软件可以实现对不同尺度河道或沟渠的流量测量；

2 利用无人机技术进行河道流量监测具有高效率、测量成本低、分辨率高、现代化、通用性等优点；

3 用无人机拍摄高分辨率影像，在此基础上结合水力参数的特点，通过不同方式获取相应参数，最后采用谢才公式计算得到对应采集点的河道流量；亦可利用数据插值方法及 ArcGIS 软件的栅格计算器对河道各部位流量进行求取。

ПОВЫШЕНИЕ ТОЧНОСТИ НЕЙРОННОЙ СЕТИ ПУТЕМ РАСШИРЕНИЯ ТРЕНИРОВОЧНОГО НАБОРА ДАННЫХ С ПОМОЩЬЮ АУГМЕНТАЦИИ

Медведев О. С., Бирилло А. А., Дудич О. Н., Красильникова В. Л.

БГУИР, БелМАПО

o.med@bsuir.by

Аннотация. Представлены результаты исследований по улучшению точности распознавания поиска глазных яблок и костных структур глазниц. Для достижения цели было использовано глубокое обучение нейронной сети с использованием аугментации и без нее. Показано, что с расширением количества тренировочного набора увеличивается точность нейронной сети, позволяющее впоследствии оценить объемы глазниц и определить деформацию стенок глазницы.

摘要。 介绍了提高眼球和眼眶骨搜索识别精度的研究结果。为实现这一目标，使用了带有和不带有增强功能的神经网络的深度学习。已经证明，随着训练集数量的增加，神经网络的准确性也在增加，从而可以随后估计眼眶体积和检测眼眶壁的变形。

Введение. Технологии машинного обучения и глубокого обучения могут быть использованы для выявления, локализации и количественной характеристики патологических особенностей, при различных видах офтальмологических заболеваний, в том числе, и при патологии глазницы.

В то же время, анализ изображений, полученных с применением микроспирального компьютерного томографа MSCT [1–3] в формате DICOM [4] и трехмерная реконструкция костей лицевого черепа, позволяет хирургу более надежно оценить анатомические особенности отдельного пациента, локализацию, границы и распространенность патологического процесса, и планировать объем операции [5].

Для работы нейронной сети с полученными результатами работы компьютерного томографа за основной элемент программной обработки были взяты биомаркеры.

В настоящий момент тренировочный набор данных для последующего обучения сети имеет ограничение по количеству изображений, получаемых с помощью компьютерного томографа, что усложняет процесс повышения точности нейронной сети. Для того, чтобы расширить исходный набор была применена аугментация. То есть, построение дополнительных данных из исходных при решении задач машинного обучения.

Основная часть. Цель работы являлась разработка программного средства, позволяющего однозначно идентифицировать биомаркеры, ограничивающие костную глазницу, а также анализ результатов использования аугментации при обучении нейронной сети, для последующего определения объема глазницы и определение деформации стенок глазницы. Решение поставленной задачи было осуществлено средствами языка программирования Python с использованием платформы Anaconda. В качестве основных фреймворков для работы с нейронными сетями были использованы TensorFlow и Keras. Количество изображений, использованных для обучения нейронной сети, постоянно увеличивалось, начиная с одной сотни в начале и 8000 в конце исследования. Также была разработана собственная архитектура нейронной сети, которая представлена на рисунке 1.

Layer (type)	Output Shape	Param #
conv2d_1 (Conv2D)	(None, 497, 497, 16)	12304
max_pooling2d_1 (MaxPooling2D)	(None, 248, 248, 16)	0
conv2d_2 (Conv2D)	(None, 241, 241, 32)	32800
max_pooling2d_2 (MaxPooling2D)	(None, 120, 120, 32)	0
conv2d_3 (Conv2D)	(None, 116, 116, 32)	25632
max_pooling2d_3 (MaxPooling2D)	(None, 58, 58, 32)	0
conv2d_4 (Conv2D)	(None, 57, 57, 64)	8256
max_pooling2d_4 (MaxPooling2D)	(None, 28, 28, 64)	0
conv2d_5 (Conv2D)	(None, 26, 26, 128)	73856
max_pooling2d_5 (MaxPooling2D)	(None, 13, 13, 128)	0
conv2d_6 (Conv2D)	(None, 11, 11, 256)	295168
flatten_1 (Flatten)	(None, 30976)	0
dropout_1 (Dropout)	(None, 30976)	0
dense_1 (Dense)	(None, 512)	15860224
dense_2 (Dense)	(None, 256)	131328
dense_3 (Dense)	(None, 8)	2056
Total params: 16,441,624		
Trainable params: 16,441,624		
Non-trainable params: 0		

Рисунок 1 – Архитектура нейронной сети

Поскольку изначальное количество изображений не удовлетворяло минимально допустимому, было принято решения об использовании методов, увеличивающих число изображений для обучения. Ответом на данный запрос является аугментация.

Также при выборе методов было учтено, с каким их подобием может столкнуться модель в действительности. К примеру, это может быть разная яркость изображения, различные шумы, растяжение/сжатие, смещение относительно центра, повороты изображения и совокупность всех вышеуказанных методов в разных пропорциях.

Таким образом, решено создать следующие виды аугментации и их смешение:

1. Смещение (сдвиг) изображения (bias augmentation).

2. Изменение яркости изображения (вариация метода главных компонент, brightness augmentation).

3. Шумы (noise augmentation) – создание шумов различной интенсивности по всему изображению.

4. Повороты изображения (rotate augmentation).

5. Деформация изображения.

Алгоритм подготовки дата сета и подаче его в нейронную сеть для обучения был построен таким образом, что аугментация осуществляется перед подачей изображений в нейронную сеть для цикла обучения. Это гарантирует, что нейросеть каждый раз будет получать на вход псевдоновое, измененное изображение, что позволит увеличить ее точность.

Заключение. В итоге обработки изображений тестовых наборов данных с использованием обученной нейронной сети с аугментацией и без ее использования были получены зависимости ошибки нейронной сети в зависимости от конкретной эпохи.

Установлено, что погрешность расчетов координат биомаркеров на основе биомедицинских изображений (результатов компьютерной томографии) с использованием нейронной с применением аугментации сократилась вдвое по сравнению с обычным обучением.

Список использованных источников

1. Keras: Deep Learning for humans [Электронный ресурс]. – Режим доступа: <https://github.com/keras-team/keras>.

2. Deep Learning: Сравнение фреймворков для символьного глубокого обучения [Электронный ресурс]. – Режим доступа: <https://habr.com/company/microsoft/blog/313318/>. – Дата доступа: 27.05.2018.

3. Digital imaging and communications in medicine [Электронный ресурс]. – Режим доступа: <https://www.dicomstandard.org/current/>. – Дата доступа: 25.01.2020.

4. Aggregation Network for Instance Segmentation [Электронный ресурс]. – Режим доступа: <https://arxiv.org/pdf/1803.01534>. – Дата доступа: 25.01.2020.

5. Mask R-CNN for object detection and instance segmentation on Keras and TensorFlow [Электронный ресурс]. – Режим доступа: https://github.com/matterport/Mask_RCNN/. – Дата доступа: 25.01.2020.