

IoT подход на основе баз данных и микросервисов также предлагает улучшение поддержки конфиденциальности и политики безопасности. Так как шаблоны запросов непосредственно видны, IoT системы, основанные на микросервисах и запросах, легче обнаружить при попытке отслеживать местоположение человека.




Рисунок 1 – Перенос IoT из локальной сети в облако

Миссия IoT состоит в подключении активов, обеспечивающих поступление ценной информации и влияющих на выполнение важных задач, но поток информации от этих активов является основой в инфраструктуре интернета вещей. Принятие подхода к IoT, основанного на базах данных, может предоставить всю необходимую нам информацию без потенциальных рисков и затрат.

Список использованных источников:

1. Building Microservices: Designing Fine-Grained Systems / Sam Newman // O'Reilly Media 2015 -- 280 s
2. Интернет вещей. Исследования и область применения / Е. Зараменских, И. Артемьев // Инфра-М 2017 – 188 с.
3. Архитектура интернета вещей / Ли Перри // ДМК-Пресс, 2019 – 454 с.

ПРИМЕНЕНИЕ АЛГОРИТМА ОБРАТНОГО РАСПРОСТРАНЕНИЯ ОШИБКИ ДЛЯ КОЛОРИЗАЦИИ ИЗОБРАЖЕНИЙ

Беликова Т.О., Евсаев П.В.

*Белорусский государственный университет информатики и радиоэлектроники
г. Минск, Республика Беларусь*

Лукашевич М.М. – к.т.н., доцент

Колоризация – любой процесс, в результате которого в последовательность изображений или в монохромное изображение добавляется цвет.

Алгоритм обратного распространения ошибки представляет собой распространение сигналов ошибки от выходов сети к её входам, применяя градиентные методы оптимизации и осуществляя подбор весов для многослойной сети [1]. Ключевым фактором здесь является целевая функция, которая формируется в виде квадратичной суммы разностей между полученными и требуемыми значениями выходных сигналов.

Для обучения сети нужны обучающая выборка и расчёт соответствующих значений сигналов нейронной сети, а также необходимо минимизировать значения целевой функции. Выборка будет состоять из цветных изображений, их полутоновых копий изображений локальных признаков, построенные для каждого полутонового изображения. Одним из способов обучения для непрерывной целевой функции является градиентные методы оптимизации.

Каждый цикл обучения состоит из следующих этапов [1]:

- 1) сгенерировать входные сигналы и вычислить производные значения функции активации каждого слоя, значения выходных слоёв (включая скрытый слой);
- 2) изменить направления сигналов и заменить функции активации на производные от них, подать разность между ожидаемым и полученным значением на новый вход сети и произвести расчёт значений требуемых обратных разностей;
- 3) на основе результатов, полученных в п.1 и 2, обучить оригинальную сеть и сеть обратного распространения ошибки;

4) для каждой обучающей выборки необходимо повторить пункты 1,2 и 3. Процесс остановится, когда норма градиента упадет ниже значения точности процесса обучения.

По описанному алгоритму нейронная сеть обучится восстанавливать только одну цветовую компоненту. Посредством того, что любой цвет представляется в виде трёх компонент: красный, зеленый и синий (RGB) [2] можно сделать вывод, что для колоризации изображения понадобится три нейронных сети.

Таким образом для каждой составляющей цвета будет своя нейронная сеть (рисунок 1).




Рисунок 1 – Схема получения восстановления цвета монохромного изображения

После обучения, применяется алгоритм раскрашивания изображений:

- 1) выбирается тип сцены соответствующий содержанию исходного монохромного изображения;
- 2) происходит построение набора локальных признаков изображения;
- 3) формируется синяя составляющая выходного цветного изображения. Нейронная сеть проходит по каждой точке полутонового изображения;
- 4) пункт 3 повторяется для красной и зеленой составляющей выходного изображения;
- 5) из трёх полученных компонент собирается цветное изображение.

Список использованных источников:

1. Haykin S. Neural networks, a comprehensive foundation. – N.Y.: Macmillan College Publishing Company, 1994
2. Гонсалес Р., Вудс Р. Цифровая обработка изображений, 3-е издание, исправленное и дополненное. — М.: Техносфера, 2012. — 1104 с.

КЛАССИФИКАЦИЯ ГАЛАКТИК С ПОМОЩЬЮ КАПСУЛЬНЫХ НЕЙРОННЫХ СЕТЕЙ

Береснев Д.В.

*Белорусский государственный университет информатики и радиоэлектроники
г. Минск, Республика Беларусь*

Самаль Д.И. – к.т.н., доцент

Рассмотрена проблематика вопроса классификации галактик. Дано описание данных, а также их специфика. Представлена характеристика капсульных нейронных сетей. Рассмотрены особенности архитектуры капсульных нейронных сетей. Рассмотрено применение капсульных нейронных сетей для решения задачи классификации галактик. Приведены результаты работы капсульной нейронной сети на тренировочном и тестовом наборе данных. Сделаны выводы касательно применимости капсульных нейронных сетей для решения задачи морфологической классификации галактик, а также отмечены перспективы дальнейших исследований.

Очень быстрые темпы прироста объемов информации, улучшение характеристик собранных данных позволяют осваивать новые направления исследований в астрономии и астрофизике. Однако задачи хранения и структуризации очень больших массивов собранных данных требуют внедрения совершенно новых подходов в обработке и разработки новых методов анализа. Таким образом, возникает острая необходимость применения новых методов к последним собранным данным, и астрономические снимки галактик не являются исключением. Поэтому решение задачи классификации галактик крайне актуально сегодня в астрономии и астрофизике.

Галактика — это массивная связанная гравитацией система, которая состоит из звезд, звездных остатков, межзвездного вещества и большого количества некоторой субстанции, которая в