

*Воронов В.И.,
Доцент кафедры «Интеллектуальные системы
в управлении и автоматизации»,
Московский технический университет связи и информатики
Россия, г. Москва*

*Анисимова И.В.,
Студент магистратуры
Кафедра «Интеллектуальные системы
в управлении и автоматизации»,
Московский Технический Университет Связи и Информатики,
Россия, г. Москва*

АНАЛИЗ ХАРАКТЕРИСТИК СТРОЕНИЯ ГАЛАКТИЧЕСКИХ СИСТЕМ ПРИ ПОМОЩИ НЕЙРОННЫХ СЕТЕЙ

Аннотация — Созвездия — в современной астрономии участки, на которые разделена небесная сфера для удобства ориентирования на звёздном небе. В древности созвездиями назывались характерные фигуры, образуемые яркими звёздами. Звёзды, видимые на небесной сфере на небольших угловых расстояниях друг от друга, в трёхмерном пространстве могут быть расположены очень далеко друг от друга. Таким образом, в одном созвездии могут быть и очень близкие, и очень далёкие от Земли звёзды, никак друг с другом не связанные. В статье приведён пример настройки и работы в рамках программно-математических комплексов моделирующих работу нейронных сетей, обеспечивающих возможности быстрого распознавания объектов.

Ключевые слова — нейронные сети, распознавание объектов, обучение, вычисления, астрономические источники.

Annotation: - Constellations - in modern astronomy, areas into which the celestial sphere is divided for the convenience of orientation in the starry sky. In

ancient times, constellations were called characteristic figures formed by bright stars. Stars visible on the celestial sphere at small angular distances from each other, in three-dimensional space, can be located very far from each other. Thus, in one constellation there can be very close and very far from the Earth stars, which are not connected with each other in any way. The article gives an example of setting up and working within the framework of software and mathematical complexes that simulate the operation of neural networks, providing the ability to quickly recognize objects.

Key words: - *neural networks, object recognition, training, computation, astronomical sources.*

I. Введение

В настоящее время, а именно- в связи с ведением работ по разработке искусственного интеллекта проявляется повышенный спрос на развитие искусственных систем, опирающиеся на алгоритмы работы, подобные нейронным сетям.

Нейронные сети (NeuralNetworks) - это модели биологических нейронных сетей мозга, в которых нейроны имитируются относительно простыми, часто однотипными, элементами (искусственными нейронами). [1, с. 81].

Развитие современных нейронных сетей ориентировано на обработку естественного языка, т.е. компьютерный анализ естественного языка и его синтез.

Распознавание объектов на изображении с помощью алгоритмов машинного обучения решает задачи эффективнее, чем человеческое зрение. Свёрточные нейронные сети нашли широкое применение в задачах классификации, детектирования и распознавания изображений. Постепенно круг этих задач расширяется, поэтому не теряет актуальности разработка новых архитектур, слоёв сети и модификаций программных платформ.

В начале XIX века между созвездиями были проведены границы на небесной сфере, ликвидировавшие «пустоты» между созвездиями, однако их чёткого определения по-прежнему не было, и разные астрономы определяли их по-своему.

В ходе выполнения работы использованы и построены модели различных созвездий. Были задействованы компьютерные программы «Компас 3D» и «SolarSystemScope», «Octave», «MatLab». [2, с. 6].

II. ПОСТАНОВКА ЗАДАЧИ

Специфика задачи, которую решает система распознавания объектов, определяет ряд требований к аппаратной платформе. Вычислительная платформа должна представлять собой компьютер, обладающий достаточной вычислительной мощностью для быстрой обработки изображений, а также имеющий возможность подключения дополнительных устройств, таких как видеокамера, аналоговые и цифровые датчики [3, с.54]. Платформа также должна обладать достаточным объемом постоянной памяти для хранения программного обеспечения и оперативной памяти для обработки всех необходимых данных. Для решения задачи построения и анализа изучены способы решения систем дифференциальных уравнений, освоены навыки их применения в программных пакетах [4, с. 19].

III. МАТЕМАТИЧЕСКОЕ МОДЕЛИРОВАНИЕ ЗВЁЗДНЫХ СИСТЕМ

Общая форма представления обыкновенного дифференциального уравнения порядка n может быть записана в виде:

$$F(x, y, y', y'', \dots, y^{(n)}) = 0 \quad (1.1)$$

Если уравнение (1.1) удастся разрешить относительно старшей производной $y^{(n)}$, то получаем уравнение [5, с. 190]:

$$y^{(n)} = f(x, y, y', \dots, y^{(n-1)}) \quad (1.2)$$

Эта форма записи дифференциальных уравнений называется нормальной. В различных исследованиях чаще всего рассматриваются уравнения и системы уравнений, записанные в нормальной форме.

Для построения модели была использована таблица галактических координат (рис. 1)

	Альфарад	1	альфа Гидры	26°36'	26°52'	27°08'	Сатурн-Венера-Нептун
	Регул	1	альфа Льва	29°08'	29°25'	29°42'	Юпитер-Марс
	Фекда	2	гамма Большой Медведицы	29°46'	0°03'	0°20'	Марс-Уран-Нептун
♄	Алиот	2	эпсилон Большой Медведицы	8°13'	8°30'	8°47'	Марс
	Зосма	3	дельта Льва	10°37'	10°54'	11°11'	Сатурн-Венера
	Мицар	2	дзета Большой Медведицы	14°59'	15°16'	15°33'	Марс
	Денебола	2	бета Льва	20°55'	21°12'	21°29'	Уран-Марс-Венера
	Бенетнаш	2	эта Большой Медведицы	26°14'	26°31'	26°48'	Уран-Сатурн-Марс
♃	Виндемиатрикс	3	эпсилон Девы	9°16'	9°31'	9°48'	Сатурн-Меркурий
	Альгараб	2	дельта Ворона	12°45'	13°02'	13°19'	Марс-Сатурн
	Спика	1	альфа Девы	23°08'	23°25'	23°42'	Венера-Марс
	Арктур	1	альфа Волопаса	23°32'	23°49'	24°06'	Юпитер-Марс
♃	Южный крест	1	альфа и бета Южного Креста	11°01'	11°14'	11°30'	Юпитер
	Гемма/Альфекка	2	альфа Сев. Короны	11°32'	11°52'	12°09'	Венера-Меркурий
	Южные Весы	2	альфа Весов	14°23'	14°40'	14°57'	Марс-Сатурн
	Северные Весы	2	бета Весов	18°40'	18°57'	19°14'	Юпитер-Меркурий
	Унук Альхайя	2	альфа Змеи	21°23'	21°39'	21°56'	Марс-Сатурн
	Бета Центавра	1	бета Центавра	23°06'	23°23'	23°39'	Венера-Юпитер
	Бунгула (Толиман)	1	альфа Центавра	28°51'	29°06'	29°21'	Венера-Юпитер
♄	Акраб	3	дельта Скорпиона	1°51'	2°09'	2°26'	Марс-Сатурн

Знак	Название звезды	Звездная величина	Обозначение	Координаты неподвижных звезд			Качество
				1950	1970	1990	
♃	Денеб-Кейтос	2	бета Кита	1°51'	2°10'	2°27'	Сатурн
	Альгеиб	1	альфа Пегаса	8°31'	8°44'	9°01'	Марс-Меркурий
	Сиррах	2	альфа Андромеды	13°40'	13°53'	14°10'	Юпитер-Венера
	Батен-Кейтос	3	дзета Кита	21°17'	21°32'	21°49'	Сатурн
	Мирах	2	бета Андромеды	29°46'	29°59'	0°16'	♄ Нептун-Венера
♃	Мира	2-3	омикрон Кита	0°50'	1°06'	1°23'	Сатурн-Юпитер
	Эль-Шератан	3	бета Овна	3°17'	3°33'	3°50'	Марс-Сатурн
	Эль-Нат	2	альфа Овна	6°59'	7°15'	7°31'	Марс-Сатурн
	Шелар	1	альфа Кассиопеи	7°07'	7°22'	7°39'	Сатурн-Венера
	Альмах	2	альфа Андромеды	13°34'	13°48'	14°05'	Венера-Марс
	Менкар	1	альфа Кита	13°38'	13°54'	14°11'	Сатурн
	Занрак	3	гамма Эридана	22°50'	23°27'	23°44'	Сатурн
	Алголь (Альголы)	2-4	бета Персея	25°28'	25°45'	26°02'	Сатурн/Уран-Марс
	Альциона	3	эта Тельца	29°19'	29°34'	29°51'	Луна-Марс
♃	Гиалды	4	каппа Тельца	5°06'	5°23'	5°40'	Марс-Уран-Нептун-Юпитер
	Сев. глаз Тельца	4	эпсилон Тельца	7°47'	8°03'	8°19'	Венера-Луна
	Альтебаран	1	альфа Тельца	9°05'	9°22'	9°39'	Марс
	Ригель	1	бета Ориона	16°08'	16°25'	16°42'	Марс-Юпитер

Рисунок 1. Таблица исходных данных о созвездиях – галактические координаты.

Вспомнив курс дифференциальных уравнений, можно построить следующий график (рис. 2) [6, с. 149]:




Рисунок 2. Стандартное представление типовых дифференциальных уравнений.

Далее, данные были внесены в интерфейсные окна программных пакетов MatLab и Octave [7, с. 136].

```

SPS
27 reorg 27 24 / 2 26 x 26 x 64 -> 13 x 13 x 256
28 route 27 24 3 x 3 / 1 13 x 13 x1280 -> 13 x 13 x1024 3.987 BFL
SPS
29 conv 1024 3 x 3 / 1 13 x 13 x1280 -> 13 x 13 x1024 3.987 BFL
SPS
30 conv 425 1 x 1 / 1 13 x 13 x1024 -> 13 x 13 x 425 0.147 BFL
SPS
31 detection
  
```

Рисунок 3. Работа программы при построении точек на карте.

В результате получена следующая модель (рис.4):




Рисунок 4. Построенная модель.

Результаты перенесены в оболочку Компас-3D. Развернув систему в трёхмерном пространстве, заметим соответствие построенной модели базовым системам дифференциальных уравнений (рис. 5) [8, с. 58]:

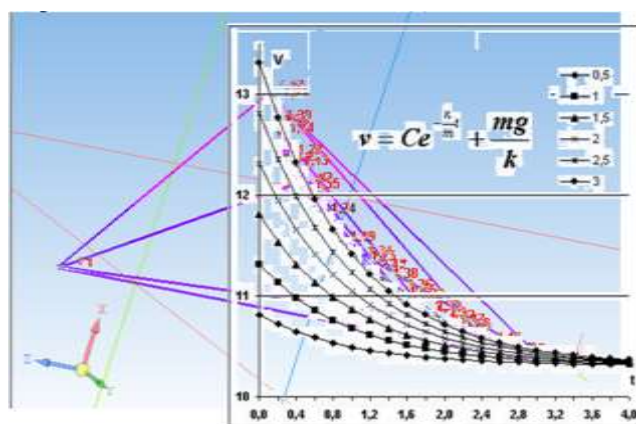


Рисунок 5. Построенная модель и дифференциальные уравнения.

Исходя из вышеперечисленного, можно подтвердить, что данная модель является адекватной и соответствует математическим правилам, выполняет заданные алгоритмы. [4, с. 49].

IV. СПОСОБЫ РАБОТЫ НЕЙРОСЕТЕВОЙ ВЫЧИСЛИТЕЛЬНОЙ АППАРАТУРЫ

Существуют различные алгоритмы, позволяющие создавать и распознавать образы. Алгоритм обучения машины распознаванию образов, основанный на методе секущих гиперплоскостей, заключается в аппроксимации разделяющей гиперповерхности частями гиперплоскостей и состоит из следующих основных этапов [9, с.184]:

- обучение (формирование разделяющей поверхности);
- проведение секущих плоскостей;
- исключение лишних плоскостей;
- исключение лишних частей плоскостей;
- распознавание новых объектов.

V. ЭТАПЫ РАСПОЗНАВАНИЯ ОБЪЕКТОВ

Задача распознавания объектов (образов) определяется следующими этапами [10, с. 332]:

определение границ — это самая низкоуровневая задача, для которой уже классически применяются свёрточные нейронные сети;

определение вектора к нормали позволяет нам реконструировать трёхмерное изображение из двухмерного;

saliency, определение объектов внимания — это то, на что обратил бы внимание человек при рассмотрении этой картинки;

семантическая сегментация позволяет разделить объекты на классы по их структуре, ничего не зная об этих объектах, то есть еще до их распознавания;

семантическое выделение границ — это выделение границ, разбитых на классы; самая высокоуровневая задача — распознавание самих объектов [11, с. 76].

VI. ХАРАКТЕРИСТИКИ ОБОРУДОВАНИЯ

Конфигурация персонального компьютера:

ЦП: Intel ® Core™ i5-8400 CPU @ 2.80 GHz

Память (ОЗУ) 8,00 ГБ

ОС Windows 10 Pro x64, Ubuntu 18.04 x64

ГП NVidia GeForce GTX 650

ЖД 1,00ТБ

Требуется установить пакеты OpenCV, CUDA, cuDNN.

VII. ЗАКЛЮЧЕНИЕ

Протестирована система на основе программного обеспечения MatCAD и Octave. Рассмотрены архитектура и процесс обработки изображений. Система создаёт объекты и идентифицирует их координаты. Нейронная сеть испытана на собственном оборудовании.

Построены и сопоставлены с математическими положениями все искомые объекты. Показаны алгоритмы работы с сетью [12, с. 87].

Литература:

1. Воронова В.И. MachineLearning / Л.И. Воронова, В.И. Воронов // Регрессионные методы интеллектуального анализа данных: учебное пособие. — М.: МТУСИ, 2017. — 81 с.
2. MachineLearning. Семинары по нейронным сетям. [Электронный ресурс]. URL: http://www.machinelearning.ru/wiki/images/1/1e/Sem07_ann.pdf (дата обращения: 27.01.21).
3. Молодяков С.А. Принципы выделения параллельных потоков команд обработки видеоизображений в smart-видеокамерах / С.А. Молодяков, А.И. Тышкевич // Міжнародний науковий журнал. — М.: Политехн. ун-та, 2016. — №. 9. — 54 с.
4. Digital Living Network Alliance, “Consumer Home,” [Online]. [Электронный ресурс]. URL: <http://www.dlna.org>. (дата обращения: 27.01.21).
5. Кузьмин В.И., Тытик Д.Л., Гадзаов А.Ф. (ред) и др. Дискретность и непрерывность в свойствах физико-химических систем. / В.И. Кузьмин, Д.Л. Тытик, А.Ф. Гадзаов. — М.: ФИЗМАТЛИТ, 2013. — 190 с.
6. Johnson M. Correlations of cycles in weather, solar activity, geomagnetic values and planetary configurations. / M. Johnson. — М.: San Francisco, Cal, 1944. — 149 с.
7. Кендалл М. Многомерный статистический анализ и временные ряды. / М. Кендалл, А. Стьюарт. — М.: Наука, 1976. — 136 с.
8. Joseph Redmon You Only Look Once. / Redmon Joseph, Divvala Santosh, Girshick Ross, Farhadi Ali. — М.: YOLO, 2016. — 58 с.
9. Круглов В.В. Искусственные нейронные сети. Теория и практика / В.В. Круглов, В.В. Борисов. — 2-е изд., стереотип. — М.: Горячая линия-Телеком, 2002. — 382 с.
10. Agrawal P. Analyzing the performance of multilayer neural networks for object recognition. / P. Agrawal, R. Girshick, J. Malik. — М.: ECCV, 2014. — С. 329–344.

11. Bengio Y. Unsupervised feature learning and deep learning: A review and new perspectives. / Y. Bengio, A.C. Courville, P. Vincent. — M.:CoRR, 2012. — 146 с.
12. Redmon J. Real-time grasp detection using convolutional neural networks. / J. Redmon, A. Angelova. — M.:CoRR, 2014. — 87 с.