

Следует предположить, что таких графов среди однородных степени 3 много. До настоящего времени все найденные графы представляли ручную работу отдельных исследователей. В настоящей работе изготавливается невод, которым будет просеяно все или почти все множество однородных графов и, надеемся, будут найдены требуемые объекты. Попробуем определить, как глубоко озеро, в которое нам необходимо будет закидывать наш невод.

Однородные графы используются в проектировании вычислительных сетей, когда каждый компьютер сети соединен с равным числом компьютеров. Также используются в исследовании однородных вычислительных сред, в теле коммуникации и т.д.

В данной работе для достижения результата использовалось 2 подхода.

Первый подход:

- Решаем диофантовы уравнения вида
- Из полученных мы выбираем те в которых выполняется теорема Гринберга

• Выбираем набор граней без ГК и начинаем соединять грани между собой пока не получим то, что все ребра граней соединены

• Проверяем граф на наличие в нём двух подграфов и тем самым проверяем граф на планарность.

Второй подход:

- Заносим описание минимального кубического графа K4

▪ Производим установку ребра в выбранной грани и получаем новый кубический граф. Продолжаем перестановку ребра до тех пор пока будут сгенерированы все возможные графы из данного.

- Проверяем граф на изоморфность с уже построенными.

- Проверяем граф на наличие гамильтонова контура по теореме

Гринберга.

Эти алгоритмы являются важной составляющей для решения широкого круга более узких задач с использованием графов, например такого вопроса как поиск кубического трехсвязного негамильтонового графа с наименьшим числом вершин.

**Список цитированных источников**

1. Грюнбаум А. – Философские проблемы пространства и времени 1969 г.
2. Н. Кристофидес. Теория графов: алгоритмический подход, Мир, 1978 г.
3. Ф.А. Новиков. Дискретная математика для программистов, Питер 2001 г
4. А. Д. Плотников. Дискретная математика, Москва, 2006.

УДК 004.89

*Суховер А.С.*

*Научный руководитель: профессор В.А. Головки*

## **ОБРАБОТКА ИЗОБРАЖЕНИЙ НА ОСНОВЕ НЕЙРОННЫХ СЕТЕЙ ГЛУБОКОГО ДОВЕРИЯ**

**Введение**

Обнаружение и распознавание объектов составляет неотъемлемую часть человеческой деятельности. Пока еще не совсем понятно, как человеку удастся так точно и так быстро выделять и узнавать нужные предметы в разнообразии окружающей среды. Попытки выяснить это делаются физиологами и психологами уже более ста лет. Распознавание трехмерных объектов по их

двумерным изображениям стало в последнее время одной из важнейших задач анализа сцен и машинного зрения.[1]

Целью настоящей работы является разработка нейросетевой системы обработки изображений для анализа сцен, позволяющей обнаруживать и идентифицировать объекты на изображении.

### 1. Архитектура сети глубокого доверия

В общем случае нейронные сети глубокого доверия (deep belief neural networks) представляют собой перцептрон с множеством слоев нейронных элементов [2–11]. До 2006 г. в научной среде была приоритетной парадигма, в рамках которой многослойный перцептрон с одним, максимум двумя скрытыми слоями является более эффективным для нелинейного преобразования входного пространства образов в выходное по сравнению с перцептроном с большим количеством скрытых слоев. Считалось, что перцептрон с более чем двумя скрытыми слоями не имеет смысла применять. Данная парадигма базировалась на теореме о том, что перцептрон с одним скрытым слоем является универсальным аппроксиматором. Другой аспект этой проблемы заключается в том, что все попытки использовать алгоритм обратного распространения ошибки (error backpropagation algorithm) для обучения перцептрона с тремя и более скрытыми слоями не приводили к улучшению решения различных задач. Это связано с тем, что алгоритм обратного распространения ошибки является неэффективным для обучения перцептронов с тремя и более слоями. В 2006 г. Дж.Хинтон (G.Hinton) предложил "жадный" алгоритм послойного обучения (greedy layer-wise algorithm) [2], который стал эффективным средством обучения нейронных сетей глубокого доверия, которые как уже отмечалось, представляют собой перцептрон с большим количеством слоев. Было показано, что нейронная сеть глубокого доверия имеет большую эффективность нелинейного преобразования и представления данных по сравнению с традиционным перцептроном. Такая сеть осуществляет глубокое иерархическое преобразование входного пространства образов[4].

Как уже отмечалось, нейронная сеть глубокого доверия содержит множество скрытых слоев (рисунок 1) и осуществляет глубокое иерархическое преобразование входного пространства образов.





Рисунок 1 - Пример сети глубокого доверия

Процесс обучения нейронных сетей глубокого доверия в общем случае состоит из двух этапов:

1) предобучение нейронной сети методом послойного обучения, начиная с первого слоя (pretraining); данный этап обучения осуществляется без учителя;

2) настройка синаптических связей всей сети (fine-tuning) при помощи алгоритма обратного распространения ошибки или алгоритма «бодрствования и сна» (wake-sleep algorithm).

Важным этапом обучения нейронных сетей глубокого доверия является предобучение слоев нейронной сети. Существует два основных подхода к предварительному обучению слоев нейронных сетей глубокого доверия (рисунок 2) [9,11].



**Рисунок 2 - Методы предварительного обучения сетей глубокого доверия**

Первый подход называется автоэнкодерным и базируется на представлении каждого слоя в виде автоассоциативной нейронной сети (рециркуляционная или PCA нейронная сеть). Вторым подходом базируется на представлении каждого слоя нейронной сети в виде ограниченной машины Больцмана (RBM)[9,11].

## 2. Алгоритмы обучения

В данной работе использовались следующие алгоритмы обучения: алгоритм обратного распространения ошибки и алгоритм предобучения основанный на использовании ограниченной машины Больцмана [9].

Выходное значение  $j$ -го нейрона  $k$ -го слоя определяется следующим образом:

$$y_j^k = F(s_j^k)$$

$$s_j^k = \sum_{i=1} w_{ij}^k y_i^{k-1} + T_j^k$$

где  $F$  – функция активации нейронного элемента;

$S$  – взвешенная сумма  $j$ -го нейрона  $k$ -слоя;

$w_{ij}$  – весовой коэффициент между  $i$ -м нейроном  $(k-1)$ -го слоя и  $j$ -м нейроном  $k$ -го слоя;

$T$  – пороговое значение  $j$ -го нейрона  $k$ -го слоя.

Выходные значения сети определяются на основе функции активации  $\text{softmax}$ [10]:

$$y_j^k = \text{softmax}(s_j) = \frac{e^{s_j}}{\sum_i e^{s_i}}$$

Ограниченная машина Больцмана состоит из двух слоев стохастических бинарных нейронных элементов, которые соединены между собой двуправленными симметричными связями (рисунок 3). Входной слой нейронных элементов называется видимым (слой  $X$ ), а второй слой – скрытым (слой  $Y$ ). Нейронную сеть глубокого доверия можно представить как совокупность ограниченных машин Больцмана. Ограниченная машина Больцмана может генерировать (представить) любое дискретное распределение, если используется достаточное количество нейронов скрытого слоя [6].




Рисунок 3 - Ограниченная машина Больцмана

Так как вычисление математического ожидания на основе RBM-сети является очень сложным, Дж.Хинтон предложил использовать аппроксимацию данных слагаемых, которую он назвал контрастным расхождением (contrastive divergence (CD)) [2]. Такая аппроксимация основывается на дискретизаторе Гиббса (Gibbs sampling). В этом случае первые слагаемые в выражениях для градиента характеризуют распределение данных в момент времени  $t=0$ , а вторые – реконструированные или генерируемые моделью состояния в момент времени  $t=k$ . Исходя из этого, CD-k процедура может быть представлена следующим образом (рисунок 4):




Рисунок 4 - Процесс CD-k

Тогда правила обучения в случае CD-k приобретают следующий вид:

$$w_{ij}(t+1) = w_{ij}(t) - \alpha (x_i(0)y_j(0) - x_i(k)y_j(k)),$$

$$T_i(t+1) = T_i(t) - \alpha (y_i(0) - y_i(k)),$$

$$T_j(t+1) = T_j(t) - \alpha (x_j(0) - x_j(k)).$$

### 3. Эксперименты

В ходе работы было разработано программное обеспечение и проведен ряд экспериментов.

В качестве обучающей и тестовой выборки использовался набор изображений CIFAR-10. CIFAR-10 состоит из 60.000 цветных изображений размером 32x32 разбитых на 10 классов. Каждый класс содержит 6.000 изображений.

Набор данных состоит из пяти тренировочных частей и одной тестовой части, каждая из которых содержит 10.000 изображений. Тестовая часть содержит ровно 1000 случайно выбранных изображений из каждого класса. Тренировочные части содержат оставшиеся изображения в случайном порядке. Все классы взаимоисключающие. То есть, например, нет перекрытия между легковыми автомобилями и грузовиками. Легковые автомобили включают в себя седаны, внедорожники и другие модели, а грузовики только большие машины.

В текущем исследовании использовалась нейронная сеть со следующими параметрами:

1) количество слоев 4. Количество нейронов 3072-6144-6144-10. Количество нейронов равно 3072 на входном слое обусловлено размером (32x32) и типом входного изображения (цветное RGB изображение). Количество нейронов на выходе равно 10, т.к. в наборе CIFAR-10 десять классов изображений.


2) шаг обучения  $a = 0.03$ .

3) количество эпох равно 100.


Для обнаружения местоположения объекта на изображении использовался метод "скользящего окна". Изображения сканируются скользящим "окном", покрывающим одновременно несколько пикселей. При этом в окне оказывается некоторый фрагмент изображения. При перемещении окна фрагмент меняется. Постепенно окно сканирует все поле изображения. После происходит увеличение размера окна и процедура сканирования продолжается с начальной позиции до тех пор, пока размер окна не будет совпадать с размером изображения.

Все пиксели, попадающие в окно, сначала сжимаются до размера изображения обучающей выборки, а после подаются на вход нейронной сети. Результатом обработки являются значения выходного слоя нейронной сети, которые показывают вероятность принадлежности к определенному классу объектов.


Пример результата работы данной системы можно наблюдать на рисунках 5,6,7:



*Рисунок 5 - Пример полученных результатов*



*Рисунок 6 - Пример полученных результатов*



*Рисунок 7 - Пример полученных результатов*

**Заключение:**

В ходе проведенных научных исследований были получены следующие результаты:

1. Разработана и исследована нейронная сеть глубокого доверия для анализа сцен, которая позволяет обнаруживать и идентифицировать объекты на изображении. Основным отличием предложенного подхода является возможность проводить анализ сцен без использования сегментации изображений.

2. Проведены эксперименты по распознаванию сцен с использованием масштабирующего скользящего окна.

3. Разработано программное обеспечение для моделирования нейронных сетей глубокого доверия для анализа изображений.

Исследования в данной работе показали, что сети глубокого доверия являются эффективным средством для обнаружения и идентификации образов и не требуют сегментации изображений.

#### Список цитированных источников

1. Гуревич И.Б. Проблема распознавания изображений. Распознавание. Классификация. Прогноз. Математические методы и их применение: Ежегодник. Вып.1. – М.: Наука, 1989.

2. Hinton G.E., Osindero S., Teh Y. A fast learning algorithm for deep belief nets // Neural Computation. – 2006. – Vol. 18. – pp. 1527-1554.

3. Hinton G. Training products of experts by minimizing contrastive divergence // Neural Computation. – 2002. – Vol. 14. – pp. 1771-1800.

4. Hinton G., Salakhutdinov R. Reducing the dimensionality of data with neural networks // Science. – 2006. – 313 (5786). – pp. 504-507.

5. Hinton G. E. A practical guide to training restricted Boltzmann machines. – Tech. Rep. 2010-000. Toronto: Machine Learning Group, University of Toronto, 2010.

6. Bengio Y. Learning deep architectures for AI // Foundations and Trends in Machine Learning. – 2009. – 2(1). – pp. 1-127.

7. Bengio Y., Lamblin P., Popovici D., Larochelle H. Greedy layer-wise training of deep networks // In B. Schölkopf, J.C. Platt, T.Hoffman (Eds.), Advances in Neural Information Processing Systems, 11. – MA: MIT Press, Cambridge, 2007. – pp. 153-160.

8. Erhan D., Bengio Y., Courville A., Manzagol P.-A., Vincent P., Bengio S. Why does unsupervised pre-training help deep learning? // Journal of Machine Learning Research. – 2010. – 11. – pp. 625-660.

9. Golovko V.A Learning technique for deep belief neural networks / V.Golovko, A.Kroshchanka, U. Rubanau, S. Jankowski // In book: Neural Networks and Artificial Intelligence. – Springer, 2014. – Vol. 440. Communication in Computer and Information Science. – pp. 136-146.

10. Головкин, В.А. Нейронные сети: обучение, организация и применение: Кн. 4: учеб. пособие для вузов / Общая ред. А.И. Галушкина. – М.: ИПРЖР, 2001. – 256 с.

11. Головкин, В.А. От многослойных перцептронов к нейронным сетям глубокого доверия: парадигмы обучения и применение/ В.А.Головкин // Лекции по Нейроинформатике. – М.: НИЯУ МИФИ, 2015. – С. 47-84.

УДК 519.2

*Липовцев А.П.*

*Научные руководители: к.т.н., доцент Махнист Л.П., к.ф.-м.н., доцент Каримова Т.И.*

### О МОМЕНТАХ РАСПРЕДЕЛЕНИЯ ПУАССОНА И НЕКОТОРЫХ ЦЕЛОЧИСЛЕННЫХ ПОСЛЕДОВАТЕЛЬНОСТЯХ

Распределение Пуассона – распределение вероятностей случайной величины  $X$ , принимающей целые неотрицательные значения  $k = 0, 1, 2, \dots$  с вероятностями

$$P(X = k) = p_k = e^{-\lambda} \frac{\lambda^k}{k!},$$

где  $\lambda > 0$  – параметр.