

Правительство Российской Федерации

**Федеральное государственное автономное образовательное учреждение
высшего образования
«Национальный исследовательский университет
«Высшая школа экономики»**

Факультет Компьютерных наук
Департамент больших данных и информационного поиска
Базовая кафедра Яндекс

**Рабочая программа дисциплины «Обучение представлений и глубокое
обучение»**
для образовательной программы «Науки о данных»
направления подготовки 01.04.02 "Прикладная математика и информатика"
уровень магистра

Разработчик(и) программы
Бабенко М.А., к.ф.-м.н. (maxim.babenko@gmail.com)

Одобрена на заседании базовой кафедры Яндекс
«__»_____ 2016 г.

Заведующий Кафедрой
М.А. Бабенко _____

Утверждена Академическим советом образовательной программы
«__»_____ 2016 г., № протокола _____

Академический руководитель образовательной программы
С.О. Кузнецов _____

Москва, 2016

*Настоящая программа не может быть использована другими подразделениями университета
и другими вузами без разрешения подразделения-разработчика программы.*



1. Область применения и нормативные ссылки

Настоящая программа учебной дисциплины устанавливает требования к образовательным результатам и результатам обучения студента и определяет содержание и виды учебных занятий и отчетности.

Программа предназначена для преподавателей, ведущих дисциплину «Обучение представлений и глубокое обучение», учебных ассистентов и студентов направления подготовки 01.04.02 «Прикладная математика и информатика», обучающихся по образовательной программе «Науки о данных».

Программа учебной дисциплины разработана в соответствии с:

- Образовательным стандартом федерального государственного автономного образовательного учреждения высшего профессионального образования «Национального исследовательского университета «Высшая школа экономики»;
- Образовательной программой подготовки магистра по направлению 01.04.02 «Прикладная математика и информатика», специализации «Анализ Интернет-данных».
- Объединенным учебным планом университета по образовательной программе «Науки о данных», утвержденным в 2016 г.

2. Место дисциплины в структуре образовательной программы

Дисциплина «Обучение представлений и глубокое обучение» предназначена для подготовки магистров 01.04.02 – Прикладная математика и информатика.

Курс посвящен "глубокому обучению", т.е. новому поколению методов, основанному на нейронных сетях и позволившему радикально улучшить работу систем распознавания образов и искусственного интеллекта.

В начале курса мы рассмотрим основы глубокого обучения (и, отчасти, "крупномасштабного" машинного обучения вообще). Следующие несколько занятий будут посвящены детальному рассмотрению сверточных нейросетей и их применениям в области компьютерного зрения (на данный момент сверточные нейросети в компьютерном зрении -- самый бесспорный и громкий успех глубокого обучения). Затем мы рассмотрим рекуррентные нейросети и то, как они применяются в задачах, связанных с естественным языком, а также совсем недавно появившиеся модели, направленные на моделирование более универсального искусственного интеллекта и делающие первые шаги в этом направлении.

Программа курса предусматривает лекции (30 часов) и практические занятия (30 часов).

3. Цели освоения дисциплины

Целью данного курса является ознакомление слушателей с основными идеями «глубокого обучения». Студенты научатся проектировать и обучать собственные нейросети и применять их для решения практических задач. Все темы курса снабжены как теоретическими заданиями, позволяющими глубже понять суть рассматриваемых понятий и методов, так и практическими заданиями, призванными дать возможность сопоставить теорию с практикой.



4. Тематический план дисциплины «Обучение представлений и глубокое обучение»

№	Название темы	Всего часов по дисциплине	Аудиторные часы		Самостоятельная работа
			Лекции	Сем. и практика	
1	Введение. Большие данные.	14	2	2	10
2	Кластеризация	14	3	3	10
3	Квантизация и поиск ближайших соседей в очень больших базах	14	2	2	10
4	Обучение с учителем и минимизация эмпирического риска	14	3	3	10
5	Стохастический градиентный спуск. Онлайн-обучение.	18	2	2	10
6	Глубокие нейросети	18	3	3	10
7	Нейросети в компьютерном зрении	16	2	2	15
8	Нейросети в распознавании речи, рекуррентные нейросети	16	3	3	15
9	Нейросети и анализ естественного языка	18	2	2	10
10	Нелинейные методы снижения размерности и построения многообразия	16	3	3	10
11	Автоэнкодеры, глубокие автоэнкодеры, предобучение	18	3	3	10
12	Биологические нейросети	14	2	2	10
	Итого	190	30	30	130



6. Формы контроля и структура итоговой оценки

Текущий контроль - домашняя работа в первом модуле, контрольная работа в первом модуле.

Итоговый контроль – письменный экзамен (120 мин.)

Итоговая оценка вычисляется следующим образом:

$0,1 \cdot \text{оценка за домашнюю} + 0,2 \cdot \text{оценка за контрольную} + 0,7 \cdot \text{оценка за экзамен}$.

Таблица соответствия оценок по десятибалльной и системе зачет/незачет

Оценка по 10-балльной шкале	Оценка по 5-балльной шкале
1	Незачет
2	
3	
4	Зачет
5	
6	
7	
8	
9	
10	

Таблица соответствия оценок по десятибалльной и пятибалльной системе

По десятибалльной шкале	По пятибалльной системе
1 – неудовлетворительно 2 – очень плохо 3 – плохо	неудовлетворительно – 2
4 – удовлетворительно 5 – весьма удовлетворительно	удовлетворительно – 3
6 – хорошо 7 – очень хорошо	хорошо – 4
8 – почти отлично 9 – отлично 10 - блестяще	отлично – 5



6. Программа дисциплины «Обучение представлений и глубокое обучение»

Тема 1. Введение. Большие данные.

Обучение без учителя, информационный поиск и задача поиска похожих, задачи классификации, обучения метрики, регрессии и структурированной регрессии. Обнаружение структуры в многомерных данных. Метод главных компонент.

Тема 2. Кластеризация.

Метод к средних и его эффективная реализация, разреженное кодирование и обучение словарей

Тема 3. Квантизация и поиск ближайших соседей в очень больших базах.

Инвертированный индекс. Произведение квантизаций. Векторизованная продукт-квантизация.

Тема 4. Обучение с учителем и минимизация эмпирического риска.

Функции потерь: "один-ноль", hinge, логистическая, формулировки функционалов для стандартных задач. Связь с методом опорных векторов. Нахождение градиента в задачи классификации, построение классификатора методом градиентного спуска.

Тема 5. Стохастический градиентный спуск. Онлайн-обучение.

Примеры применения для классификации, обучения метрики, ранжирования.

Тема 6. Глубокие нейросети.

Обратное распространение, приёмы стохастического градиентного спуска при тренировки глубоких сетей. Библиотеки для глубинного обучения.

Тема 7. Нейросети в компьютерном зрении.

Свёрточные нейросети, визуальная классификация и структурированное предсказание в компьютерном зрении.

Тема 8. Нейросети в распознавании речи, рекуррентные нейросети.

Библиотека для нейросетевой обработки сигналов.



Тема 9. Нейросети и анализ естественного языка.

Векторные представления для естественного языка. Библиотека для нейросетевого анализа естественного языка.

Тема 10. Нелинейные методы снижения размерности и построения многообразия.

Методы LLE, tSNE, SOM, Isomap, лапласовские собственные вектора. Сравнение методов снижения размерности из scikit-learn

Тема 11. Автоэнкодеры, глубокие автоэнкодеры, предобучение.

Реализация. Визуализация активаций автоэнкодера.

Тема 12. Биологические нейросети.

Зрительная кора, схожести и различия с искусственными нейросетями.

7. Учебно-методическое и информационное обеспечение дисциплины

Список литературы

- **Книги**
 - Deep Learning, Yoshua Bengio, Ian Goodfellow, Aaron Courville, MIT Press, In preparation.
- **Обзорные статьи**
 - Representation Learning: A Review and New Perspectives, Yoshua Bengio, Aaron Courville, Pascal Vincent, Arxiv, 2012.
 - The monograph or review paper Learning Deep Architectures for AI (Foundations & Trends in Machine Learning, 2009).
 - Deep Machine Learning – A New Frontier in Artificial Intelligence Research – a survey paper by Itamar Arel, Derek C. Rose, and Thomas P. Karnowski.
 - Graves, A. (2012). *Supervised sequence labelling with recurrent neural networks*(Vol. 385). Springer.
 - Schmidhuber, J. (2014). Deep Learning in Neural Networks: An Overview. 75 pages, 850+ references, <http://arxiv.org/abs/1404.7828>, PDF & LATEX source &

complete public BIBTEX file under <http://www.idsia.ch/~juergen/deep-learning-overview.html>.

- LeCun, Yann, Yoshua Bengio, and Geoffrey Hinton. “Deep learning.” *Nature* 521, no. 7553 (2015): 436-444.
- **Обучение с подкреплением**
 - Mnih, Volodymyr, Koray Kavukcuoglu, David Silver, Alex Graves, Ioannis Antonoglou, Daan Wierstra, and Martin Riedmiller. “Playing Atari with deep reinforcement learning.” *arXiv preprint arXiv:1312.5602* (2013).
 - Volodymyr Mnih, Nicolas Heess, Alex Graves, Koray Kavukcuoglu. “Recurrent Models of Visual Attention” ArXiv e-print, 2014.
- **Компьютерное зрение**
 - ImageNet Classification with Deep Convolutional Neural Networks, Alex Krizhevsky, Ilya Sutskever, Geoffrey E Hinton, NIPS 2012.
 - Going Deeper with Convolutions, Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, Andrew Rabinovich, 19-Sept-2014.
 - Learning Hierarchical Features for Scene Labeling, Clement Farabet, Camille Couprie, Laurent Najman and Yann LeCun, IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013.
 - Learning Convolutional Feature Hierarchies for Visual Recognition, Koray Kavukcuoglu, Pierre Sermanet, Y-Lan Boureau, Karol Gregor, Michaël Mathieu and Yann LeCun, Advances in Neural Information Processing Systems (NIPS 2010), 23, 2010.
 - Graves, Alex, et al. “A novel connectionist system for unconstrained handwriting recognition.” *Pattern Analysis and Machine Intelligence, IEEE Transactions on* 31.5 (2009): 855-868.
 - Cireşan, D. C., Meier, U., Gambardella, L. M., & Schmidhuber, J. (2010). Deep, big, simple neural nets for handwritten digit recognition. *Neural computation*, 22(12), 3207-3220.
 - Ciresan, Dan, Ueli Meier, and Jürgen Schmidhuber. “Multi-column deep neural networks for image classification.” *Computer Vision and Pattern Recognition (CVPR), 2012 IEEE Conference on*. IEEE, 2012.
 - Ciresan, D., Meier, U., Masci, J., & Schmidhuber, J. (2011, July). A committee of neural networks for traffic sign classification. In *Neural Networks (IJCNN), The 2011 International Joint Conference on* (pp. 1918-1921). IEEE.
- **Обработка текстов и речи**
 - Joint Learning of Words and Meaning Representations for Open-Text Semantic Parsing, Antoine Bordes, Xavier Glorot, Jason Weston and Yoshua Bengio (2012), in: Proceedings of the 15th International Conference on Artificial Intelligence and Statistics (AISTATS)
 - Dynamic pooling and unfolding recursive autoencoders for paraphrase detection. Socher, R., Huang, E. H., Pennington, J., Ng, A. Y., and Manning, C. D. (2011a). In NIPS’2011.
 - Semi-supervised recursive autoencoders for predicting sentiment distributions. Socher, R., Pennington, J., Huang, E. H., Ng, A. Y., and Manning, C. D. (2011b). In EMNLP’2011.
 - Mikolov Tomáš: Statistical Language Models based on Neural Networks. PhD thesis, Brno University of Technology, 2012.

- Graves, Alex, and Jürgen Schmidhuber. “Framewise phoneme classification with bidirectional LSTM and other neural network architectures.” *Neural Networks* 18.5 (2005): 602-610.
- Mikolov, Tomas, Ilya Sutskever, Kai Chen, Greg S. Corrado, and Jeff Dean. “Distributed representations of words and phrases and their compositionality.” In *Advances in Neural Information Processing Systems*, pp. 3111-3119. 2013.
- K. Cho, B. van Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk, Y. Bengio. Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation. EMNLP 2014.
- Sutskever, Ilya, Oriol Vinyals, and Quoc VV Le. “Sequence to sequence learning with neural networks.” *Advances in Neural Information Processing Systems*. 2014.
- **Теоретические работы**
 - Hinton, Geoffrey E. “Deterministic Boltzmann learning performs steepest descent in weight-space.” *Neural computation* 1.1 (1989): 143-150.
 - Bengio, Yoshua, and Samy Bengio. “Modeling high-dimensional discrete data with multi-layer neural networks.” *Advances in Neural Information Processing Systems* 12 (2000): 400-406.
 - Bengio, Yoshua, et al. “Greedy layer-wise training of deep networks.” *Advances in neural information processing systems* 19 (2007): 153.
 - Bengio, Yoshua, Martin Monperrus, and Hugo Larochelle. “Nonlocal estimation of manifold structure.” *Neural Computation* 18.10 (2006): 2509-2528.
 - Hinton, Geoffrey E., and Ruslan R. Salakhutdinov. “Reducing the dimensionality of data with neural networks.” *Science* 313.5786 (2006): 504-507.
 - Marc’Aurelio Ranzato, Y., Lan Boureau, and Yann LeCun. “Sparse feature learning for deep belief networks.” *Advances in neural information processing systems* 20 (2007): 1185-1192.
 - Bengio, Yoshua, and Yann LeCun. “Scaling learning algorithms towards AI.” *Large-Scale Kernel Machines* 34 (2007).
 - Le Roux, Nicolas, and Yoshua Bengio. “Representational power of restricted boltzmann machines and deep belief networks.” *Neural Computation* 20.6 (2008): 1631-1649.
 - Sutskever, Ilya, and Geoffrey Hinton. “Temporal-Kernel Recurrent Neural Networks.” *Neural Networks* 23.2 (2010): 239-243.
 - Le Roux, Nicolas, and Yoshua Bengio. “Deep belief networks are compact universal approximators.” *Neural computation* 22.8 (2010): 2192-2207.
 - Bengio, Yoshua, and Olivier Delalleau. “On the expressive power of deep architectures.” *Algorithmic Learning Theory*. Springer Berlin/Heidelberg, 2011.
 - Montufar, Guido F., and Jason Morton. “When Does a Mixture of Products Contain a Product of Mixtures?.” *arXiv preprint arXiv:1206.0387* (2012).
 - Montúfar, Guido, Razvan Pascanu, Kyunghyun Cho, and Yoshua Bengio. “On the Number of Linear Regions of Deep Neural Networks.” *arXiv preprint arXiv:1402.1869* (2014).
- **Supervised Feedforward Neural Networks**
 - The Manifold Tangent Classifier, Salah Rifai, Yann Dauphin, Pascal Vincent, Yoshua Bengio and Xavier Muller, in: NIPS’2011.
 - “Discriminative Learning of Sum-Product Networks.”, Gens, Robert, and Pedro Domingos, NIPS 2012 Best Student Paper.
 - Goodfellow, I., Warde-Farley, D., Mirza, M., Courville, A., and Bengio, Y. (2013). Maxout networks. Technical Report, Université de Montréal.

- Hinton, Geoffrey E., et al. “Improving neural networks by preventing co-adaptation of feature detectors.” *arXiv preprint arXiv:1207.0580* (2012).
- Wang, Sida, and Christopher Manning. “Fast dropout training.” In *Proceedings of the 30th International Conference on Machine Learning (ICML-13)*, pp. 118-126. 2013.
- Glorot, Xavier, Antoine Bordes, and Yoshua Bengio. “Deep sparse rectifier networks.” In *Proceedings of the 14th International Conference on Artificial Intelligence and Statistics. JMLR W&CP Volume*, vol. 15, pp. 315-323. 2011.
- ImageNet Classification with Deep Convolutional Neural Networks, Alex Krizhevsky, Ilya Sutskever, Geoffrey E Hinton, NIPS 2012.
- **Large Scale Deep Learning**
 - Building High-level Features Using Large Scale Unsupervised Learning Quoc V. Le, Marc’Aurelio Ranzato, Rajat Monga, Matthieu Devin, Kai Chen, Greg S. Corrado, Jeffrey Dean, and Andrew Y. Ng, ICML 2012.
 - Bengio, Yoshua, et al. “Neural probabilistic language models.” *Innovations in Machine Learning* (2006): 137-186. Specifically Section 3 of this paper discusses the asynchronous SGD.
 - Dean, Jeffrey, et al. “Large scale distributed deep networks.” *Advances in Neural Information Processing Systems*. 2012.
- **Рекуррентные сети**
 - Training Recurrent Neural Networks, Ilya Sutskever, PhD Thesis, 2012.
 - Bengio, Yoshua, Patrice Simard, and Paolo Frasconi. “Learning long-term dependencies with gradient descent is difficult.” *Neural Networks, IEEE Transactions on* 5.2 (1994): 157-166.
 - Mikolov Tomáš: Statistical Language Models based on Neural Networks. PhD thesis, Brno University of Technology, 2012.
 - Hochreiter, Sepp, and Jürgen Schmidhuber. “Long short-term memory.” *Neural computation* 9.8 (1997): 1735-1780.
 - Hochreiter, S., Bengio, Y., Frasconi, P., & Schmidhuber, J. (2001). Gradient flow in recurrent nets: the difficulty of learning long-term dependencies.
 - Schmidhuber, J. (1992). Learning complex, extended sequences using the principle of history compression. *Neural Computation*, 4(2), 234-242.
 - Graves, A., Fernández, S., Gomez, F., & Schmidhuber, J. (2006, June). Connectionist temporal classification: labelling unsegmented sequence data with recurrent neural networks. In *Proceedings of the 23rd international conference on Machine learning* (pp. 369-376). ACM.
- **Гиперпараметры**
 - “Practical Bayesian Optimization of Machine Learning Algorithms”, Jasper Snoek, Hugo Larochelle, Ryan Adams, NIPS 2012.
 - Random Search for Hyper-Parameter Optimization, James Bergstra and Yoshua Bengio (2012), in: *Journal of Machine Learning Research*, 13(281–305).
 - Algorithms for Hyper-Parameter Optimization, James Bergstra, Rémy Bardenet, Yoshua Bengio and Balázs Kégl, in: NIPS’2011, 2011.
- **Оптимизация**
 - Training Deep and Recurrent Neural Networks with Hessian-Free Optimization, James Martens and Ilya Sutskever, *Neural Networks: Tricks of the Trade*, 2012.
 - Schaul, Tom, Sixin Zhang, and Yann LeCun. “No More Pesky Learning Rates.” *arXiv preprint arXiv:1206.1106* (2012).

- Le Roux, Nicolas, Pierre-Antoine Manzagol, and Yoshua Bengio. “Topmoumoute online natural gradient algorithm.” *Neural Information Processing Systems (NIPS)*. 2007.
- Bordes, Antoine, Léon Bottou, and Patrick Gallinari. “SGD-QN: Careful quasi-Newton stochastic gradient descent.” *The Journal of Machine Learning Research* 10 (2009): 1737-1754.
- Glorot, Xavier, and Yoshua Bengio. “Understanding the difficulty of training deep feedforward neural networks.” *Proceedings of the International Conference on Artificial Intelligence and Statistics (AISTATS’10)*. Society for Artificial Intelligence and Statistics. 2010.
- Glorot, Xavier, Antoine Bordes, and Yoshua Bengio. “Deep Sparse Rectifier Networks.” *Proceedings of the 14th International Conference on Artificial Intelligence and Statistics. JMLR W&CP Volume*. Vol. 15. 2011.
- “Deep learning via Hessian-free optimization.” *Martens, James. Proceedings of the 27th International Conference on Machine Learning (ICML)*. Vol. 951. 2010.
- Hochreiter, Sepp, and Jürgen Schmidhuber. “Flat minima.” *Neural Computation*, 9.1 (1997): 1-42.
- Pascanu, Razvan, and Yoshua Bengio. “Revisiting natural gradient for deep networks.” *arXiv preprint arXiv:1301.3584* (2013).
- Dauphin, Yann N., Razvan Pascanu, Caglar Gulcehre, Kyunghyun Cho, Surya Ganguli, and Yoshua Bengio. “Identifying and attacking the saddle point problem in high-dimensional non-convex optimization.” In *Advances in Neural Information Processing Systems*, pp. 2933-2941. 2014.
- **Unsupervised Feature Learning**
 - Salakhutdinov, Ruslan, and Geoffrey E. Hinton. “Deep boltzmann machines.” *Proceedings of the international conference on artificial intelligence and statistics*. Vol. 5. No. 2. Cambridge, MA: MIT Press, 2009.
 - Scholarpedia page on Deep Belief Networks.
 - **Deep Boltzmann Machines**
 - An Efficient Learning Procedure for Deep Boltzmann Machines, Ruslan Salakhutdinov and Geoffrey Hinton, *Neural Computation* August 2012, Vol. 24, No. 8: 1967 — 2006.
 - Montavon, Grégoire, and Klaus-Robert Müller. “Deep Boltzmann Machines and the Centering Trick.” *Neural Networks: Tricks of the Trade* (2012): 621-637.
 - Salakhutdinov, Ruslan, and Hugo Larochelle. “Efficient learning of deep boltzmann machines.” *International Conference on Artificial Intelligence and Statistics*. 2010.
 - Salakhutdinov, Ruslan. *Learning deep generative models*. Diss. University of Toronto, 2009.
 - Goodfellow, Ian, et al. “Multi-prediction deep Boltzmann machines.” *Advances in Neural Information Processing Systems*. 2013.
 - **RBMs**
 - Unsupervised Models of Images by Spike-and-Slab RBMs, Aaron Courville, James Bergstra and Yoshua Bengio, in: ICML’2011
 - Hinton, Geoffrey. “A practical guide to training restricted Boltzmann machines.” *Momentum* 9.1 (2010): 926.



- **Автоэнкодеры**

- Regularized Auto-Encoders Estimate Local Statistics, Guillaume Alain, Yoshua Bengio and Salah Rifai, Université de Montréal, arXiv report 1211.4246, 2012
- A Generative Process for Sampling Contractive Auto-Encoders, Salah Rifai, Yoshua Bengio, Yann Dauphin and Pascal Vincent, in: ICML'2012, Edinburgh, Scotland, U.K., 2012
- Contracting Auto-Encoders: Explicit invariance during feature extraction, Salah Rifai, Pascal Vincent, Xavier Muller, Xavier Glorot and Yoshua Bengio, in: ICML'2011
- Disentangling factors of variation for facial expression recognition, Salah Rifai, Yoshua Bengio, Aaron Courville, Pascal Vincent and Mehdi Mirza, in: ECCV'2012.
- Vincent, Pascal, et al. "Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion." *The Journal of Machine Learning Research* 11 (2010): 3371-3408.
- Vincent, Pascal. "A connection between score matching and denoising autoencoders." *Neural computation* 23.7 (2011): 1661-1674.
- Chen, Minmin, et al. "Marginalized denoising autoencoders for domain adaptation." *arXiv preprint arXiv:1206.4683* (2012).