

# КОМП'ЮТЕРНІ ЗАСОБИ, МЕРЕЖІ ТА СИСТЕМИ

E.N. Chichirin

## INTELLIGENT METHODS IN SIMULATION OF DECISION- MAKING PROCESSES

*Recommendations are received on the applicability of intelligent methods for modeling decision-making processes. Approaches for the adaptation of the modeling domain of training data are considered.*

*Key words: decision trees, neural networks.*

*Отримано рекомендації про застосування інтелектуальних методів для моделювання процесів прийняття рішень. Розглянуто підходи для адаптації області моделювання навчальних даних.*

*Ключові слова: дерева рішень, нейронні мережі.*

*Получены рекомендации о применимости интеллектуальных методов для моделирования процессов принятия решений. Рассмотрены подходы для адаптации области моделирования обучающих данных.*

*Ключевые слова: деревья решений, нейронные сети.*

© Е.Н. Чичирин, 2018

УДК 004.852

Е.Н. ЧИЧИРИН

## ИНТЕЛЛЕКТУАЛЬНЫЕ МЕТОДЫ В МОДЕЛИРОВАНИИ ПРОЦЕССОВ ПРИНЯТИЯ РЕШЕНИЙ

**Введение.** В работе рассматривается применение современных информационных технологий, а именно, методов машинного обучения на решающих деревьях и искусственных нейронных сетях (НС) для моделирования в системах поддержки принятия решений – СППР (Decision Support Systems – DSS) при стратегическом планировании, управлении процессами производства товаров, услуг и взаимоотношениями с клиентами.

По совокупности существующих определений СППР – это система, которая помогает менеджеру или лицу, принимающему решение, осуществлять проверки, манипулировать данными, использовать эвристики и строить математические модели, в том числе с применением функциональных возможностей искусственного интеллекта. Связанное с СППР понятие Business Intelligence Tools (инструментальные средства бизнес интеллекта) – программное обеспечение, которое помогает пользователям наблюдать и использовать большие объемы сложных данных.

СППР системы призваны помочь с решениями при обслуживании процессов, связанных с:

- людьми (клиенты и персонал);
- процессами (закупки, поставки, производство, реализация);
- стратегиями (на основе анализа рынков, финансов, истории, рисков);
- технологиями (с учетом эволюционного и революционного их развития).

Рынок СППР систем, который возник только в середине 90-х годов, на сегодня

оценивается суммой порядка 10 млрд. долларов и имеет рост порядка 30 % в год по сравнению с 25 млрд. рынком и 10 – 15 % ростом ERP-систем планирования ресурсов предприятия [1].

В настоящее время СППР применяются в финансовом секторе, крупноформатной торговле и телекоммуникациях. Наблюдается внедрение функциональных возможностей и соответственно методов СППР в системы ERP-класса и управления операциями, например, при определении сроков профилактических ремонтов, управлении складскими запасами и загрузкой оборудования.

Обширная область применения методов СППР для моделирования и, в идеале, полной автоматизации процессов является работа с клиентами (CRM-системы) в промышленности и сфере услуг. Сегодня 64 из 100 успешных компаний являются сервисными компаниями, и время ожидания в сервисных центрах составляет до 95 % от общего времени обработки типичного процесса обслуживания [1].

В итоге наблюдаемый в последние годы взрывной рост Интернет технологий: рекламы, торговли, финансовых операций, социальных сетей, сфер развлечений – связан не только с их доступностью, но и с привлекательностью такого массового рынка потребления для бизнеса.

Интернет технологии обладают уникальной возможностью анализа индивидуальных предпочтений потребителя и целенаправленного влияния на эти предпочтения. Так, переход от пассивной контекстной к активной таргетированной рекламе (не инициируемой запросом клиента), а также негласный кредитный скоринг возникли как результат статистического анализа латентных (скрытых) ассоциативных связей в контекстах поведения клиентов (и их друзей) в самых, казалось бы, несвязанных областях их Интернет деятельности.

Таким образом, за счет достижения качества, соответствующего допустимой стоимости ошибки, компьютерные модели, аналогичные используемым в СППР, начинают применяться непосредственно в контуре управления процессами, имеющих массовый (либо опасный для человека) характер.

На рис. 1 на основании данных McKinsey Global Institute analysis представлены доли компаний в различных сферах производства и услуг, использующих методы искусственного интеллекта (ИИ) и планирующих повышение на них затрат [2].

Все вышесказанное стало возможным благодаря инициированному возросшей мощностью компьютеров развитию методов обработки больших данных (BigData), в том числе методов композиции деревьев решений и оптимизации нейросетевых моделей, с помощью стохастического градиентного спуска (Stochastic gradient descent – SGD). При этом в многочисленных работах отмечается преимущество стохастических моделей СППР в связи с необходимостью поддержания минимально необходимых резервов для быстрого реагирования на сбои в производстве, поставках комплектующих и реализации готовой продукции в условиях изменчивости запросов потребителя [3].

Различают следующие типы интеллектуальных инструментальных средств поиска скрытых зависимостей (знаний) в больших данных:

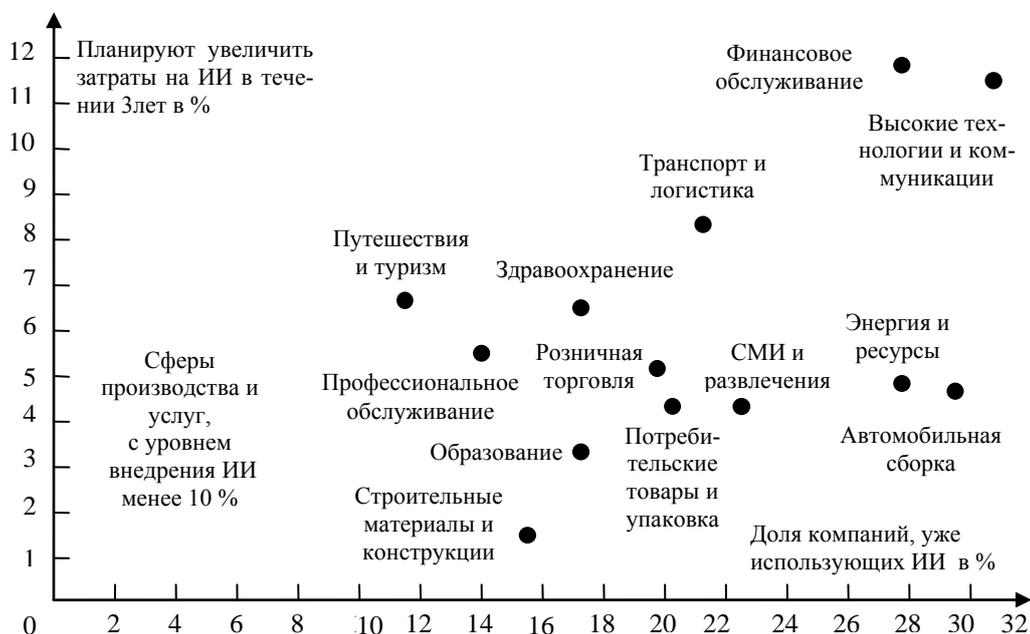


РИС. 1. Доля компаний использующих методы ИИ и планирующих их развитие

1. Средства многомерного анализа – OLAP (On-Line Analytical Processing), которые дают возможность наблюдать данные в различных измерениях, направлениях или сечениях.

2. Инструментальные средства запросов (Query Tools) – позволяют формировать запросы к данным по содержанию или образцу.

3. Инструментальные средства "добычи" данных (Data Mining Tools) – осуществляют автоматический поиск образцов или зависимостей в данных.

Средства Data Mining заимствуют классические методы:

- статистической обработки с целью выявления закономерностей в данных (линейный и нелинейный регрессионный, дискриминантный, корреляционный и факторный анализы, прогноз на основе временных рядов и т. п.);

- методы решения оптимизационных задач – вариационные методы, методы исследования операций (линейное, нелинейное, целочисленное и динамическое программирование), методы теории систем массового обслуживания.

Из методов собственной разработки условно можно выделить:

- построение деревьев решений (экспертом или методами дихотомической классификации) и их композиций (бэггинг, бустинг) для последовательного логического выбора решения;

- машины опорных векторов (SVM), методы оптимизации на основе систем машинного обучения (Machine Learning – ML) нейронных сетей, и эволюционного программирования.

Аналитические методы в средствах Data Mining Tools помогают осуществить весь цикл работы с исходными данными большого объема и поддерживают различные типы моделей – нейронные сети, классификационные и регрессионные деревья решений (ДР), ближайшие k-окрестности и байесовское обучение.

Основными критериями выбора типа модели для систем СППР являются:

- время и связанные с ним затраты на обучение модели, возможность распараллеливания процесса на многоядерных системах (масштабируемость);
- склонность к переобучению и соответственно, необходимость в тестовой выборке или кросс-валидации;
- необходимый объем и качество (релевантность распределения, пропуски в данных) набора данных для обучения модели;
- качество получаемых решений (точность, обобщающая способность);
- время отклика (получения решения) и масштабируемость этого процесса;
- интерпретируемость результатов модели для пользователя СППР.

Рассмотрим кратко с этих позиций возможности применения в СППР современных интеллектуальных моделей, т. е. моделей обладающих способностью к самообучению (оптимизации) на аналитических, эвристических или исторических данных в сферах обслуживания и производства.

В соответствии с не столь давней историографией, показанной на рис. 2 [4] начнем с метода опорных векторов (SVM – support vector machine) для линейной классификации и регрессионного анализа. В основе SVM – перевод исходных векторов в пространство высокой размерности и поиск разделяющей гиперплоскости с максимальным зазором в этом пространстве. Для линейно неразделимых пространств используется алгоритм с "мягким" зазором, либо нелинейные

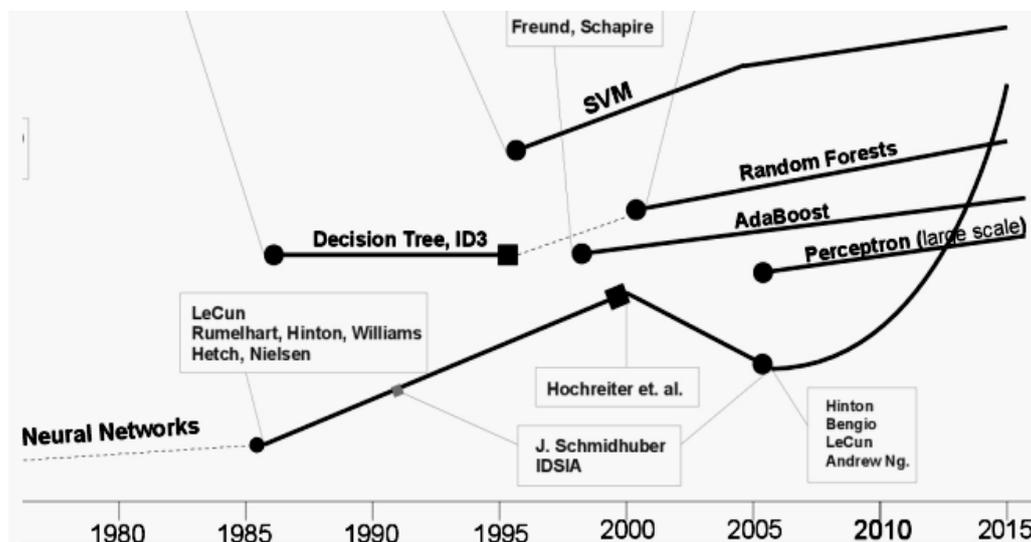


РИС. 2. Хронология популярности методов машинного обучения

ядерные функции. Итерации с выбором зазора и, тем более типа ядра существенно усложняют исходно простой и быстрый SVM метод.

Дерево решений (Decision trees) – популярная древовидная модель классификации и прогнозирования состояний объектов и процессов на основе простой дихотомической классификации входных переменных (атрибутов) по цепочке правил («да» – «нет»). Модель "белого ящика" – проста, интерпретируема (понятна), не требует предварительной подготовки входных данных, в том числе категориальных. Может быть построена экспертом вручную. Недостатки: низкое качество решений, вследствие локального (жадного) алгоритма построения дерева и переобучение с необходимостью сложной регуляции глубины дерева.

Существенно лучшее качество решений достигается в случае применения композиций сравнительно простых деревьев: параллельных, с финальным усреднением решений всех деревьев и последовательных, с улучшением предыдущих решений. В первом случае обучающие данные для различных деревьев размножаются путем бутстрепа – выборки с возвращением из входного датасета (бэггинг) дополняемой случайной выборкой подмножества переменных – претендентов для каждого узла (Random Forest – случайный лес). Во втором – путем увеличения весов данных с неверно предсказанными решениями (бустинг) и дополнительно с приближением общего градиента целевой функции (градиентный бустинг). Предсказуемая расплата за повышение качества решений – плохая интерпретируемость. Для СППР лучше применять леса деревьев, так как они хорошо работают на малых датасетах с большим числом переменных, а градиентный бустинг – наоборот.

Лидером по качеству решений и худшей интерпретируемостью являются глубокие НС, пока единственные, способные самостоятельно строить в скрытых слоях многоуровневую иерархию промежуточных признаков (регрессоров) входных образов (переменных) от огромного числа входных переменных.

Продвинутые структуры НС (автоэнкодеры, сверточные, рекуррентные, состязательные сети, Residual, Softmax, ReLu и т. п. слои и функции активации), и масштабируемые технологии SGD-оптимизации (Adam, batch-нормализация, dropout), обеспечивают возможность обучения глубоких слоев с допустимым уровнем переобучения и за приемлемое время. На совершенствование применяемых для обучения видеокарт и специализированных ASIC- ИИ процессоров, в том числе мобильных, брошены огромные силы и средства.

На основании представленных в таблице результатов исследования можно сделать следующие выводы:

- случайные леса деревьев целесообразно применять в СППР и системах управления процессами, прежде всего, с высокой стоимостью ошибочного решения (на текущий момент до 70 % реализованных проектов);
- SVM – для простых процессов с понятным характером нелинейности;
- градиентный бустинг – для СППР и систем управления в масштабных проектах с низкой стоимостью ошибки;
- глубокие НС – в текущих и перспективных решениях высокой точности.

ТАБЛИЦА

Модель	Параметр						
	Качество решений	Интерпретируемость	Время обучения	Переобучение	Обучающая выборка	Масштабируемость	Время отклика
Дерево принятия решений	Низкое	Хорошая	Небольшое	Большое, плохое обобщение	Небольшая	Плохая	Небольшое
Случайный лес деревьев	Хорошее	Плохая	Большое	Нет	Небольшая	Хорошая	Большое
Градиентный бустинг на деревьях	Хорошее	Плохая	Среднее	Большое, необходимо тестировать	Большая	Плохая	Среднее
Нейронная сеть	Среднее	Плохая	Среднее	Большое, необходимо тестировать	Большая	Хорошая	Среднее
Глубокая нейронная сеть	Очень хорошее	Очень плохая	Очень большое	Большое, необходима кросс-валидация	Очень большая	Хорошая	Большое
SVM	Хорошее	Средняя	Небольшое	Небольшое	Небольшая	Средняя	Небольшое

Главным условием для успешной реализации алгоритмов машинного обучения современных моделей в любой области приложений является наличие обучающего набора – датасета (DataSet) исходных данных. К настоящему времени в транзакционных системах управления оперативной деятельностью компаний накоплен огромный объем информации. Но ее мало в открытом доступе, как картинок и текстов. Это в немалой степени тормозит прогресс внедрения глубокого обучения в производственную сферу силами открытых сообществ разработчиков. Исследования и опытные разработки, конечно ведутся. Особенно в области промышленного, бытового (IoT) и военного роботостроения. И данные для обучения находят, реальные или заимствованные в 2D и 3D игровых мирах, или синтезируемые методами Монте-Карло и различными генерирующими ИС.

Особую проблему создает необходимость ручной разметки или маркировки образцов в соответствии с их принадлежностью различным классам (позициям). Далее предлагается подход к решению проблемы маркировки похожих наборов образцов деталей, использующий возможности доменной адаптации ИС [5].

Пусть имеются два датасета  $N1$  и  $N2$  одинаковых или похожих образцов деталей, подготовленных на разных этапах производства, хранения или транспортировки. Причем маркированным является только первый из них. Как из-

вестно, при обучении информация  $I_y$  об образцах сохраняется в модели в виде вероятностного распределения параметров (весовых коэффициентов)  $\theta_y$  сети относительно меток классов  $y$ . При этом в каждом образце эта информация имеет как минимум две составляющих  $I_y = I(y) + I(N_y)$ , где  $I(y)$  – информация о существенных характеристиках  $y$  образца (форма, цвет, штрих-код и т. п.);  $I(N_y)$  – информация о характеристиках датасета (аппаратура и место съемки, окружение предметами, освещение и т. п.).

Вторая составляющая  $I(N_y)$  в лучшем случае является бесполезной, а в основном является шумом и снижает качество распознавания и прогнозирования. В нашем случае именно отличие между  $I(N1)$  и  $I(N2)$ , ограничивает возможность применения обученной на датасете  $N1$  модели для классификации образцов из  $N2$ . Адаптировать модель к датасету  $N2$  можно с помощью дополнительной НС – классификатора номера датасета.

Общая схема НС для адаптации датасета  $N2$  по маркированному датасету  $N1$  показана на рис. 3. Классификатор номера датасета здесь включен в разрыв основной НС после слоя выделения промежуточных признаков, и обучается распознавать очевидно известный источник подаваемых на вход основной НС образцов из  $N1$  и  $N2$ . Основная сеть обучается классифицировать образцы  $N1$ , попутно улучшая распознавание образцов из  $N2$ . Для этого вся НС охвачена контурами обратного распространения градиентов ошибок:

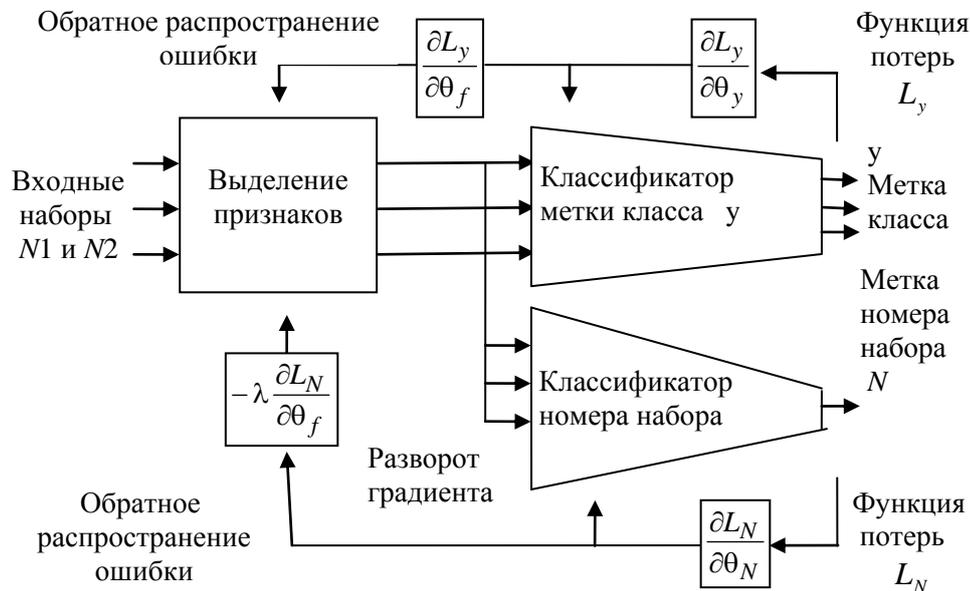


РИС. 3. Адаптация НС-модели к новому набору данных

- $\frac{\partial L_y}{\partial \theta_y}$  – для минимизации функции потерь  $L_y$  и максимизации информации о классах  $I(y)$  в параметрах  $\theta_y$  классификатора метки класса;
- $\frac{\partial L_N}{\partial \theta_N}$  – для минимизации потерь  $L_N$  и максимизации информации о датасетах  $N1$  и  $N2$  в параметрах  $\theta_N$  классификатора номера датасета;
- $\frac{\partial L_y}{\partial \theta_f}$  – для минимизации потерь  $L_y$  и максимизации информации о классах  $I(y)$  в параметрах  $\theta_f$  в слоях выделения признаков (features);
- $-\lambda \frac{\partial L_N}{\partial \theta_f}$  – для максимизации потерь  $L_y$  и минимизации информации о датасетах  $N1$  и  $N2$  в параметрах  $\theta_f$  в слоях выделения признаков.

Таким образом классификатор датасета обучается различать источник предъявляемых образцов (пока может), одновременно подавляя эту возможность в предшествующих слоях НС, т. е. "рубит ветку, на которой сидит". Классификатор классов в это время старается поддерживать способность различать образцы из маркированного датасета  $N1$ . Одновременно с этим, за счет подавления на выходах первичных слоев признаков номера датасета, снижается влияние отличий в  $I(N1)$  и  $I(N2)$  на качество распознавания образцов из  $N2$ .

Механизм адаптации исходного распределение параметров ранее обученной модели к новому целевому распределению положен в основу генеративных состязательных сетей (Generative Adversarial Nets – GAN). GAN содержат конкурирующие генеративную и дискриминантную сети и наряду с методами Monte Carlo (MCMC) могут быть применены для получения обучающих данных в управлении производством. Открытая задача – как продлить стабильную работу дискриминатора, т. е. классификатора источника входных данных.

Вторая, не менее важная проблема машинного обучения – интерпретируемость результатов моделирования, т. е. понятность человеку выявленных моделью зависимостей от входных данных не только выходной, но и промежуточных переменных. На рис. 4 показано примерное соотношение точности прогноза и его интерпретируемости для различных методов машинного обучения [6].

Суммируя решения, поддержанных DARPA исследований (слои семантических меток, стохастические And-Or графы, LIME и Байесовские модельные индукции) можно заключить, что для интерпретируемости промежуточных переменных, они должны представлять собой известные в моделируемой области понятия, такие же, например, как выходная величина. И должна быть доступна иерархия их зависимостей от предыдущих интерпретируемых величин. И тогда есть надежда, что человек поймет модель, и модель наберется "ума", как "мыслить" логически, а не только образно, как она уже почти умеет.

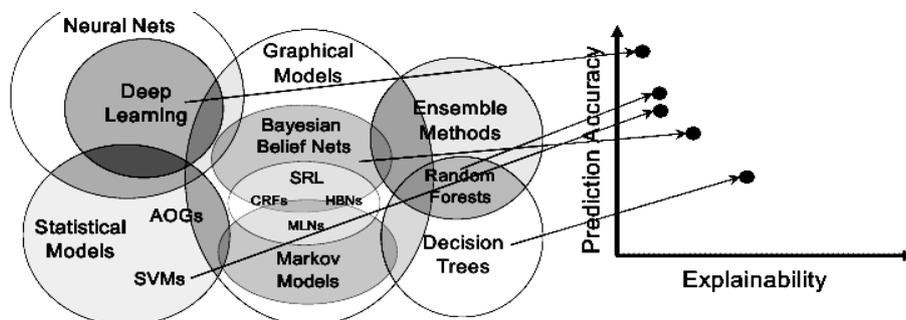


Рис. 4. Сравнительная зависимость точности прогнозирования (Prediction Accuracy) и интерпретируемости (Explain ability) методов машинного обучения

При возможности такой реализации модели в значительной степени решаются третья и четвертая проблемы машинного обучения, а именно проблема one-shot обучения, т. е. обучения по малому количеству входных примеров, и проблема сбоя модели в случае сильной зависимости выхода от "несущественных" признаков (например, условий съемки деталей). Для этого нужно сохранять и в дальнейшем использовать уже наработанные промежуточные понятия-признаки. Что и как сохранять, и в каких контекстах использовать – это уже ближе к рекуррентным сетям, методам обучения с подкреплением, вниманием и разреженному векторному кодированию понятий (embedding).

**Выводы.** На основании исследования возможностей современных интеллектуальных методов машинного обучения получены рекомендации о их применимости для моделирования процессов принятия решений в СППР, системах управления производством и в сфере обслуживания. Рассмотрены подходы для адаптации области моделирования обучающих данных и улучшения интерпретируемости результатов модельных решений.

#### СПИСОК ЛИТЕРАТУРЫ

1. Корнеев С. Системы поддержки принятия решений в бизнесе. К.: Сети и бизнес. 2005. № 6 (25). С. 102–110.
2. <https://www.mckinsey.com/business-functions/mckinsey-analytics-business>
3. Чічірін Є.М., Сосненко К.П., Самолук Т.А. Моделювання процесів прийняття рішень в системі моніторингу гідрологічної обстановки Abstracts at the XXV In.conf "Problems of decision making under uncertainties -PDMU-2015. Skhidnytsia. 2015. С. 147–148.
4. [http://www.ziti.uni-heidelberg.de/ziti/uploads/ce\\_group/seminar/2014-Daniel\\_Schlegel-presentation.pdf](http://www.ziti.uni-heidelberg.de/ziti/uploads/ce_group/seminar/2014-Daniel_Schlegel-presentation.pdf)
5. Ganin Y., Lempitsky V. Unsupervised Domain Adaptation by Backpropagation ArXiv: 1409.7495 v2 [stat. ML], 27.02.2015.
6. David Gunning Explainable Artificial Intelligence (XAI) DARPA / I2O 15.09.2017 [https://www.cc.gatech.edu/~alanwags/DLAI2016/\(Gunning\)%20IJCAI-16%20DLAI.pdf](https://www.cc.gatech.edu/~alanwags/DLAI2016/(Gunning)%20IJCAI-16%20DLAI.pdf).

Получено 05.10.2018