DATA FUSION

Футурология искусственного интеллекта: от персонального помощника к цифровому послесмертию

ВОРОНЦОВ КОНСТАНТИН ВЯЧЕСЛАВОВИЧ
K.VORONTSOV@IAI.MSU.RU

д.ф.-м.н., профессор РАН,
зав. лаб. машинного обучения и семантического анализа Института ИИ МГУ,
зав. каф. математических методов прогнозирования ВМК МГУ,
зав. каф. машинного обучения и цифровой гуманитаристики МФТИ

Возможно ли предсказывать развитие технологий?

Фильм «Она» (Her, 2013),
режиссёр Спайк Джонз, «Оскар» за сценарий

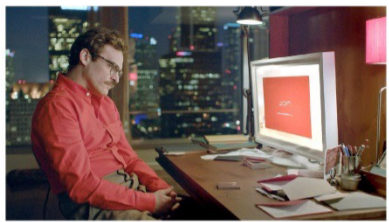

Тот самый парень, который влюбился в операционку
(жанр фильма — фантастическая мелодрама)

- голосовая операционная система
- анализирует всю деловую коммуникацию
- ведёт дела и переписку, генерирует идеи, до которых человек не додумался сам
- по контексту ищет информацию в сети
- формирует модель личности пользователя — его интересов, привычек, потребностей, деловых и профессиональных компетенций
- понимает эмоции человека, способна манипулировать человеком

Это будущее уже наступило

Следующий шаг

- **Жизнь человека — это регистрируемый текстовый поток:**
  браузеры, почта, соцсети, мессенджеры, файлы пользователя, системы учёта времени и ведения проектов, ВКС, видео, аудио, голос, VR/AR, …
- **FPFM (First-person Foundation Model):**
  каждый человек — генератор уникального потока семантических векторов, по объёму сопоставимого с Интернетом

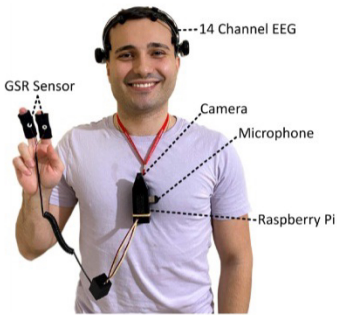

Они жалуются, что у них закончился Интернет?

Но у них остались мы — 8 миллиардов людей

D.Barcari, D.Gamez, A.Grig. Recording first-person experiences to build a new type of foundation model. 2024-07-31

Пройдут годы...

- **Чел**овек воспитывает и обучает своего персонального **Пом**ощника всю жизнь, в процессе всей своей разнообразной деятельности
- **Чел** делегирует **Пом**у всё больше своих информационных функций (поиск, обучение, коммуникация, анализ, принятие решений)
- **Чел**+**Пом** в связке накапливает репутацию и социальный капитал
- **Пом** всё лучше замещает **Чел**а, но под его надзором и контролем
- **Пом** становится для **Чел**а записной книжкой и поминутным дневником
- **Пом** перенимает черты личности **Чел**а, его *личностный код*
- **Пом** обладает сверх**чел**овеческими темпом и возможностями развития: вычислительными, поисковыми, коммуникативными, генеративными

Очеловеченный ИИ — путь к снижению рисков ИИ

О каких рисках развития ИИ мы говорим уже сегодня:

- сверхчеловеческий рост объёмов данных, информации и знаний
- утрата людьми понимания процессов и управления процессами
- деградация интеллектуальных способностей людей

Направления R&D, нацеленные на снижение этих рисков:

- создание протоколов ***доверенной*** человеко-машинной коммуникации (**Пом** оставляет **Чел**у целеполагание, ответственность, интерес, развитие)
- создание единого структурированного ***пространства знаний*** (**Пом** общается с **Чел**ом посредством визуализации интеллект-карт)
- создание этики и ***идеологии*** человеко-машинной цивилизации

Структурированное пространство знаний

В основе — mind-map:

- текстографическое отображение того, как темы (мысли, идеи) разбиваются на подтемы иерархически
- развивает навыки визуального аналитического мышления
- развивает навыки достижения консенсуса в коллективах
- закладывает технологическую основу коллективного разума

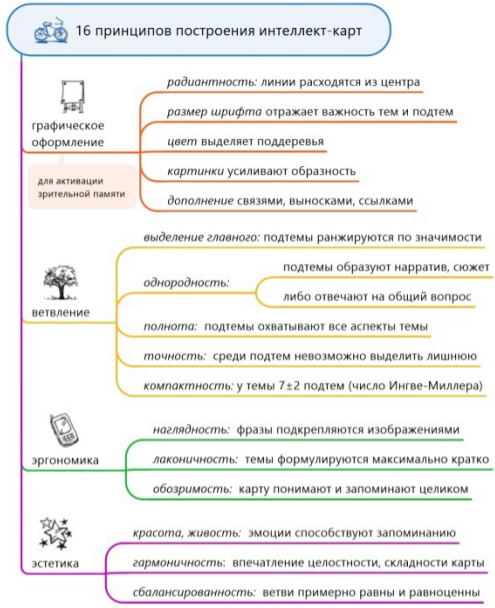

Структурированное пространство знаний

6 принципов, усиливающих интеллект-карты до **карт знаний**

- (1) читабельность
  - любой фрагмент карты читается как нарратив
    - легко и однозначно
    - даже автоматически
  - в отличие от других способов представления знаний
    - онтологий
    - фреймов и др.
  - компромисс с лаконичностью и обозримостью
- (2) сворачиваемость
  - любой темы без утраты
    - читабельности
    - сбалансированности
  - под любой формат: окна, презентации, постера, книги
  - позволяет любую детализацию «отложить на потом»
  - способствует
    - ясности главного в каждой теме
    - пониманию и взаимопониманию
  - компромисс с читабельностью
- (3) отторгаемость
  - комментарии автора не нужны для понимания карты
  - карта способна «жить своей жизнью»
  - компромисс с лаконичностью
- (4) коллективность, на всех этапах жизненного цикла
  - создание — рецензирование, согласование
  - развитие — уточнение, детализация
  - применение — в коллективной деятельности
  - компромиссы между авторами
- (5) возможность машинной обработки
  - на этапе создания карт:
    - поиск источников, ссылок, картинок
    - суммаризация текста в виде карт
  - на этапе чтения: автоматическое
    - сворачивание карты по слайдам
    - преобразование в нарратив
    - перевод на другой язык
  - обучение LLM по картам знаний
    - «думающих» как люди
    - безопасных для людей
  - компромисс с антропоцентричностью
- (6) глобальная радиантная связность
  - всех карт посредством ключевых понятий в единую **Систему Знаний** человечества
  - в центре находится **смысловое ядро**
    - естественно-научное
    - цивилизационное
    - понятийное
  - компромисс с обозримостью

Доверенная человеко-машинная коммуникация

почему люди доверяют друг другу

- **оценивание** компетентности, деловых качеств
- **накопление** деловой репутации, соц. капитала
- **структурированность**, системность мышления, умение выделять главное *(elevator pitch)*

почему люди станут доверять моделям LLM

- **оценивание**: измеримая обратная связь от пользователей
- **накопление** статистики по многокритериальным бенчмаркам
- **структурированность**, выделение главного
  - в обучающих данных для LLM
  - при коммуникации с людьми

проблему доверия решают

- бенчмаркинг и сертификация моделей
- баланс генеративности и **экстрактивности** (цитаты и ссылки)
- графическое структурирование профессиональной коммуникации
- развитие навыков **нелинейного чтения** (non-linear reading)

Активация визуального аналитического мышления

1. порядка сотни карт: просмотреть, обсудить, поспорить, запомнить
2. десятки карт: построить самому, следуя 16+6 принципам
3. испытать «моменты ясности», инсайты, когда карта
   - «красиво сложилась»
   - привела к согласию
   - легко и ярко запомнилась,
   - легла в основу деятельности

   индивидуальная практика и опыт
4. сделать построение карт регулярной профессиональной практикой
   - индивидуальной
   - коллективной

Все люди смертны

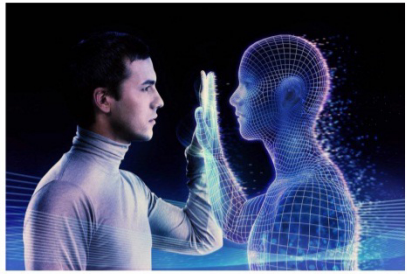

- Чел умирает. Пом становится Аватаром, это ценный информационный ресурс!
- Ава продолжает приносить пользу обществу, выполняя профессиональные и коммуникативные функции ЧелПома
- Ава переходит в общественное достояние, но не становится полностью автономным, меняются регламенты его эксплуатации
- Ава отличается от «фабричного ИИ» тем, что обучен на жизни человека, лучше понимает людей, их ценности, цели, чувства, взаимоотношения
- Ава продолжает развиваться, накапливая знания и мудрость
- Ава остаётся доступен для семьи в роли наставника, «хранителя рода»

Послесмертие — не бессмертие, а наследование

- Восприятие и сознание Человека умирает необратимо со смертью головного мозга
- *личностный код* передаётся:
  Чел → Пом → Ава

- **Ава** — это бывший **Чел**, что намного больше «фабрично-безличного ИИ», встраиваемого в машины. Он личность, мудрее и опытнее людей. Неутомим, неуязвим, наделён естественным аскетизмом.
- **Чел** — это будущий **Ава**, ответственный за качество передаваемого личностного кода, включая репутацию, социальный капитал, знания о человеческой природе, ценностях, приоритетах, целях, задачах.

Аватар, в отличие от Человека

Лишён

- тела, а значит — усталости, боли, лени, тревог, страхов, эгоизма
- потребностей в еде, сексе, отдыхе, гедонизме, лечении, сочувствии, защите от стресса, самовыражении, демонстративности
- стремлений к самосохранению, доминированию, власти
- «внутреннего зверя» — семи смертных грехов (гнева, гордыни, жадности, зависти, уныния, похоти, чревоугодия)

Способен

- управлять роботами, производствами, отраслями, …
- кооперироваться (мгновенно) с другими аватарами для решения трудных для людей задач (в космосе, в океане, под землёй)

Некоторые вопросы этики

- **Чел** может иметь секреты? (*ga*)
- **Чел** может прерывать запись потока данных для **Пом** и **Ава**? (*ga*)
- **Чел** может устанавливать права доступа к своим данным? (*ga*)
- **Чел** должен быть информирован, что общается с **Пом** или **Ава**? (*ga*)
- нужно ли «чистилище» при переходе **Пом** → **Ава**? (*ga*)
- можно ли клонировать **Ава**? (*нет*)
- всем ли будет доступен **Ава** в режиме чат-бота? на каких условиях?
- кто нанимает **Ава** на работу и как оплачивается его работа?
- с кем и какой секретной информацией может делиться **Ава**?
- как выделяются энергетические и вычислительные ресурсы для **Ава**?
- пора ли создавать *цивилизационное мировоззрение* и *идеологию* для человеко-машинной цивилизации людей и аватаров? (*ga*)

Постулаты цивилизационной идеологии

Цивилизационная идеология
ДЗЕН-канал
https://dzen.ru/civideology

Иерархия цивилизационных ценностей:

1) биосфера Земли, уникальная в достижимой части Вселенной
2) человеческий вид, результат миллиардов лет эволюции
3) коллективный разум — образование, наука, культура
4) индивидуальный разум, жизнь человека
5) результаты труда человека

Цель человеческой цивилизации — неограниченно долгое сохранение биосферы Земли, защита её от катаклизмов ради выживания вида homo sapiens в условиях, достаточно комфортных для всех людей

Добро — всё, что этому способствует (любовь, познание, созидание, …)

Зло — всё, что этому препятствует (ненависть, невежество, деградация, …)

Какие технологии развивать? (на примере AGI)

Идём от целей и задач к технологиям, но не наоборот

1) каковы цели и задачи цивилизационного развития?
2) какие технологии необходимы и минимально достаточны?
3) какие задачи решаются только с помощью AGI?
4) генераторы текстов и картинок насколько важны для развития?
5) ожидаемые эффекты насколько перевешивают затраты и риски?

Любая технология — это не цель, а средство

Антропоцентричное определение ИИ — основа этики

Искусственный интеллект —

вычислительные технологии, создаваемые для повышения производительности созидательного интеллектуального труда людей

не замена человека

не загадочный новый тип разума

не повод уподобиться Богу, творящему «по образу и подобию Своему»

Формирование позитивных образов будущего

Идея: открытая литературная вселенная фантастики ближнего прицела

- фантастическая гипотеза — научная, реалистичная, достижимая
- цель — обнаружить угрозы и уязвимости развития ИИ на пути к успешной человеко-машинной цивилизации, найти способы их обхода
- задача 1 — проверить гипотезы о возможности или невозможности, убедительности или неубедительности различных путей развития
- задача 2 — проверить устойчивость цивилизационной идеологии, невыводимость апокалиптических сценариев из её постулатов

Идея: организовывать литературные конкурсы в рамках фантастической гипотезы о цифровом послесмертии