

Задача моделирования когнитивной эволюции*

В.Г. Редько

Аннотация. Аргументируется, что моделирование когнитивной эволюции может служить естественнонаучной основой разработок искусственного интеллекта (ИИ). Характеризуются философские предпосылки исследований когнитивной эволюции. Анализируется направление исследований Адаптивное Поведение (Анимат-подход к ИИ), модели которого могут рассматриваться, как задел исследований когнитивной эволюции. Кратко характеризуется оригинальный проект «Мозг Анимата». В порядке обсуждения предлагается программа будущих исследований когнитивной эволюции.

Ключевые слова: когнитивная эволюция, моделирование, естественный и искусственный интеллект, проблема эволюционного происхождения интеллекта

The task of modeling of cognitive evolution

V.G. Red'ko

Institute of Optical Neuron Technologies, RAS

E-mail: redko@iont.ru

Abstract. It is argued that modeling of cognitive evolution can be a natural scientific base of artificial intelligence (AI) developments. Philosophical background for modeling of cognitive evolution is characterized. The field of investigations “Simulation of Adaptive Behavior” (Animat approach to AI) that can be considered as a first step towards modeling of cognitive evolution is analyzed. Original project “Animat Brain” is outlined. The program for further investigations of cognitive evolution is proposed.

Key words: cognitive evolution, modeling, natural and artificial intelligence, problem of evolutionary origin of intelligence

1. Философские предпосылки исследований когнитивной эволюции – пролегомены к теории происхождения мышления

1.1. О термине «пролегомены»

Когда И. Кант написал свою знаменитую «Критику чистого разума» (1781 г.) [1], то он ожидал, что с ним будут спорить, его будут критиковать, ругать или, наоборот, будут соглашаться с ним. Но ожидаемого им отклика не было: не было ни возражений, ни одобрений, а все жаловались на трудность понимания этого сочинения. И тогда Кант написал небольшую брошюру «Пролегомены ко всякой будущей метафизике, могущей появиться как наука» (1783 г.) [2], в которой популярно растолковал свою позицию. Термин пролегомены означает предварительные рассуждения, введение в изучение. Данный раздел как раз хорошо соответствует термину «пролегомены».

* Работа выполнена при финансовой поддержке РАН (Программа "Интеллектуальные компьютерные системы", проект 2-45) и РФФИ (проект 04-01-00179).

1.2. Сверхзадача

Основные проблемы, на которых хотелось бы заострить внимание, – это проблема применимости человеческого мышления в научном познании и связанная с ней проблема эволюционного происхождения мышления. Здесь мы не будем особенно акцентировать внимание на термине "мышление". Примерно с равным успехом можно было бы использовать вместо термина "мышление" термины "интеллект", "логика", "логика человеческого мышления", можно было бы пытаться уточнить эти термины. Но можно пока воспринимать эти термины достаточно интуитивно, причем для определенности остановимся на термине "мышление".

Итак, в чем проблема?

Существует наука. Наука – это познание природы. Но способен ли человек познавать законы природы?

Рассмотрим физику, наиболее фундаментальную из естественнонаучных дисциплин. Мощь физики связана с эффективным применением математики. Но математик строит свои теории совсем независимо от внешнего мира, используя свое мышление (в тиши кабинета, лежа на диване, в изолированной камере...). Почему же результаты, получаемые математиком, применимы к реальной природе?

Можно ли конструктивно подойти к решению этих вопросов? Скорее всего, да. По крайней мере, можно попытаться это сделать. Почему можно ожидать положительный ответ на этот вопрос? А давайте попробуем рассуждать следующим образом.

Рассмотрим одно из элементарных правил, которое использует математик в логических заключениях, правило *modus ponens*: "если имеет место A , и из A следует B , то имеет место B ", или $\{A, A \rightarrow B\} \Rightarrow B$.

А теперь перейдем от математика к собаке И.П. Павлова. Пусть у собаки вырабатывают условный рефлекс, в результате в памяти собаки формируется связь "за УС должен последовать БС" (УС - условный стимул, БС - безусловный стимул). И когда после выработки рефлекса собаке предъявляют УС, то она, "помня" о хранящейся в ее памяти "записи": УС \rightarrow БС, делает элементарный "вывод" $\{УС, УС \rightarrow БС\} \Rightarrow БС$. И у собаки, ожидающей БС (скажем, кусок мяса), начинают течь слюнки.

Конечно, применение правила *modus ponens* (чисто дедуктивное) математиком и индуктивный "вывод", который делает собака, явно различаются. Но можем мы ли думать об эволюционных корнях логических правил, используемых в математике? Да, вполне можем – умозаключение математика и индуктивный "вывод" собаки качественно аналогичны.

Мы можем пойти и дальше – можем представить, что в памяти собаки есть *семантическая сеть*, сеть связей между понятиями, образами. Например, мы можем представить, что у собаки есть понятия "пища", "опасность", "другая собака". С понятием "пища" могут быть связаны понятия "мясо", "косточка". При выработке пищевого условного рефлекса, например, на звонок (скажем, УС = "звонок", БС = "мясо") у собаки, по-видимому, формируется простая семантическая связь: «за звонком следует мясо».

Можно далее представить процессы формирования разнообразных семантических сетей в процессе жизни собаки и накопления ей жизненного опыта. Такие семантические сети, формируемые в памяти собаки, по-видимому, аналогичны семантическим сетям, исследуемым разработчиками искусственного интеллекта [3].

Итак, мы можем думать над эволюционными корнями логики, мышления, интеллекта. И более того, было бы очень интересно попытаться строить модели эволюционного происхождения мышления. По-видимому, наиболее четкий путь такого исследования – построение математических и компьютерных моделей "интеллектуальных изобретений" биологической эволюции, таких как безусловный рефлекс, привыкание, классический условный рефлекс, инструментальный условный рефлекс, цепи рефлексов, ..., логика [4]. То есть, целесообразно с помощью моделей представить общую картину эволюции когнитивных способностей животных и эволюционного происхождения интеллекта человека.

Естественно, что такие исследования – это огромный фронт работы, и задачу построения теории происхождения мышления, задачу моделирования когнитивной эволюции можно пока рассматривать как сверхзадачу. Исследования этой проблемы могли бы обеспечить определенное обоснование применимости нашего мышления в научном познании, т. е. укрепить фундамент всего величественного здания науки. Чтобы вести эту работу серьезно, целесообразно идти именно по пути построения математических и компьютерных моделей когнитивной эволюции.

Но прежде чем строить модели, давайте посмотрим, кто еще думал над близкими вопросами. Проследим цепочку: Д. Юм -> И. Кант -> К. Лоренц.

1.3. Д. Юм -> И. Кант -> К. Лоренц

В "Исследовании о человеческом познании" (1748) Давид Юм подверг сомнению понятие причинной связи [5]. А именно, он задался вопросом: почему когда мы видим, что за одним явлением *A* постоянно следует другое *B*, то мы приходим к выводу, что *A* является причиной *B*? Например, когда мы многократно наблюдаем, что Солнце освещает камень, и камень нагревается, то мы говорим, что солнечный свет есть причина нагревания камня.

Фактически Юм задался вопросом: что нас заставляет делать выводы о происходящих в природе явлениях? Что лежит в основе этих выводов? Юм попытался понять, откуда мы берем основание заключать, что *A* есть причина *B*. Он посмотрел на этот вопрос, как он пишет, со всех сторон и не нашел никакого другого основания, кроме некоторого внутреннего чувства привычки. Т.е., есть какое-то наше внутреннее свойство, которое заставляет нас утверждать, что если за *A* постоянно следует *B*, то *A* есть причина *B*. И это внутреннее чувство заставляет нас после того, когда мы сделали такое умозаключение, и снова видим событие *A*, ожидать, что за *A* вновь последует и событие *B*.

Юм взглянул на наш познавательный процесс со стороны, извне. Он как бы вышел на некий мета-уровень рассмотрения наших собственных познавательных процессов и задался вопросом о том, откуда взялись эти познавательные процессы и почему они работают. Острота сомнений Юма была в том, что он задался вопросом о принципиальной способности человека познавать мир.

Остроту сомнений Юма очень хорошо почувствовал Иммануил Кант. Но Кант также видел мощь и силу современной ему науки. Тогда уже была глубокая, серьезная и развитая математика, мощная ньютоновская физика, дающая **картину мира**, позволяющая объяснить множество явлений на основе немногих четких предположений, использующая многозвенные и сильные математические дедуктивные выводы. Что было делать Канту? Подвергнуть сомнению все эти познавательные процессы? И развивая сомнения Юма дальше, отвергнуть всю науку? Ведь на самом деле – драма!!!

Конечно же, Кант, как научно образованный человек, не стал отвергать современную ему науку, а постарался разобраться, как же работают познавательные процессы. В результате появились знаменитая "Критика чистого разума" [1] и ее популярная интерпретация – "Пролегомены ко всякой будущей метафизике, могущей появиться, как наука" [2]. Кант провел исследование познавательных процессов в определенном приближении – приближении фиксированного мышления взрослого человека. Он не задавался вопросом, **откуда** берутся познавательные способности, он просто констатировал факт, что они существуют, и исследовал, **как** они работают. В результате этого анализа Кант пришел к выводу, что существует система категорий, концепций, логических правил и методов вывода (таких как заключения относительно причинных связей между событиями), которые используются в познании природы. Эта система "чистого разума" имеет априорный характер – она существует в нашем сознании прежде всякого опыта – и является основой научного познания природы.

Естественно, что приближение фиксированного мышления человека наложило свой отпечаток: Кант утверждает – и вполне логично (!) – что так как "чистый разум" априорен, то наш рассудок в познавательном процессе предписывает свои законы природе:
" ... хотя в начале это звучит странно, но, тем не менее, верно, если я скажу: рассудок не черпает свои законы (a priori) из природы, а предписывает их ей" [2].

Наверно, во времена Канта было разумно ограничиться приближением фиксированного мышления взрослого человека – все сразу не охватишь. Кроме того, не было еще теории Чарльза Дарвина. Скорее всего, если бы Кант знал теорию происхождения видов, то он явно бы задумался об эволюционном происхождении "чистого разума". Тем более что эволюционные идеи были явно не чужды Канту – вспомним его знаменитую гипотезу происхождения Солнечной системы. Но приближение фиксированного мышления взрослого человека накладывает свои ограничения – оно не позволяет ответить на вопросы – откуда же взялись познавательные способности, познаем ли мы истинные законы природы или наш рассудок "предписывает их ей". Фактически Кант ушел от наиболее острой части вопроса, поставленного Юмом – он не задавался вопросом, откуда взялся "чистый разум", а только тщательно и детально исследовал свойства "чистого разума" и применение его в научном познании.

Естественно, что после появления теории происхождения видов Дарвина должна была произойти ревизия концепции априорного "чистого разума". И она произошла. Очень четко ее выразил Конрад Лоренц в знаменитой статье "Кантовская доктрина априорного в свете современной биологии" [6]. Согласно Лоренцу, кантовские априорные категории и другие формы "чистого разума" произошли в результате естественного отбора: "Наши категории и формы восприятия, данные до индивидуального опыта, адаптированы к внешнему миру точно по той же причине, по какой копыто лошади адаптировано к почве степи и плавник рыбы адаптирован к воде до того, как рыба вылупится из икринки" [6].

То есть, составляющие "чистого разума" возникали постепенно в процессе эволюции, в результате многочисленных взаимодействий с внешним миром. В эволюционном контексте "чистый разум" совсем **не априорен**, а имеет явные эволюционные **эмпирические** корни.

Но это – только общая критика позиции Канта, которая лишь намекает, как подойти к решению проблемы, поставленной Юмом, но далеко не решает эту проблему.

1.4. Немного о взглядах современных философов

Есть такое направление в современной философии – эволюционная эпистемология, два основных тезиса которой состоят в следующем (цитируем работу Карла Поппера, которая так и называется "Эволюционная эпистемология") [7]:

"Первый тезис. Специфически человеческая способность познавать, как и способность производить научное знание, являются результатами естественного отбора. Они тесно связаны с эволюцией специфически человеческого языка".

"Второй тезис. Эволюция научного знания представляет собой в основном эволюцию в направлении построения все лучших и лучших теорий. Это – дарвинистский процесс. Теории становятся лучше приспособленными благодаря естественному отбору. Они дают нам все лучшую и лучшую информацию о действительности. (Они все больше и больше приближаются к истине.) Все организмы – решатели проблем: проблемы рождаются вместе с возникновением жизни".

При этом первый тезис считается почти тривиальным, а второй – разворачивается и всесторонне исследуется. То есть, эволюционная эпистемология занимается изучением того, каковы познавательные процессы и насколько их можно сопоставить с процессами накопления информации в процессе биологической эволюции. Но она практически не занимается изучением эволюционного происхождения познавательных способностей человека.

В какой-то степени этим занимается философское направление, которое можно назвать исследования когнитивной эволюции. На эту тему есть хорошая книга И.П. Меркулова "Когнитивная эволюция" [8]. Предмет этой книги частично перекрывается с известной книгой В.Ф. Турчина "Феномен науки" [9]. Особое внимание в [8] уделяется анализу процесса формирования логического мышления на этапах перехода от примитивного мышления первобытных племен к формальному логическому (от племен охотников до Аристотеля).

Но в работах философов как-то не ощущается понимания остроты проблемы о принципиальной способности человека познавать мир. Проблемы: почему с помощью нашего **человеческого** мышления, нашей логики, нашего интеллекта, нашего "чистого разума" мы в принципе способны познавать **природу**. Автор настоящей работы читал множество статей в журнале "Вопросы философии". Но нигде не видел именно такой постановки проблемы, не говоря уже о конструктивных подходах к ее решению. Как правило, много говорится о том, каковы методы познания, формализуются эти методы, говорится о том, что трудно формализовать все их особенности, но нигде не ставится задача – разобраться в том, почему они применимы в принципе. Нет прямо такой постановки проблемы ни в "Феномене науки" Турчина, ни в "Когнитивной эволюции" Меркулова. Хотя,

конечно, в обеих книгах есть очень хорошие и глубокие подходы к исследованию эволюционного происхождения познавательных способностей человека.

А на самом деле ведь есть драма! Примерно такая же, какую, возможно, ощутил И. Кант перед созданием "Критики чистого разума". Надо либо подвергнуть сомнению все научные знания – которые получены с помощью человеческого мышления, в применимости которого к научному познанию можно сомневаться – либо заняться обоснованием самого мышления. И естественный подход к решению проблемы – исследовать биологические корни наших познавательных способностей и постараться разобраться, почему эти способности возникли, и почему в процессе их эволюционного возникновения появилась возможность познания природы. Наиболее четкий путь такого исследования – построение математических и компьютерных моделей когнитивной эволюции. То есть, хотелось бы с помощью моделей представить общую картину эволюции когнитивных способностей животных и эволюционного происхождения интеллекта человека. Причем здесь, как это ни удивительно, можно попытаться поставить "неестественную" науку – эпистемологию – на твердую естественнонаучную почву.

Как же конкретно подойти к исследованию происхождения интеллекта? Есть ли задел таких исследований? Что здесь сделано и делается сейчас? В следующем разделе мы обсудим такой задел – направление исследований «Адаптивное поведение».

2. Модели адаптивного поведения – задел исследований когнитивной эволюции

2.1. From Animal to Animat – исследование общих принципов поведения животного и робота

С начала 1990-х годов активно развивается направление "Адаптивное поведение" (АП) [10]. Основной подход этого направления – конструирование и исследование искусственных (в виде компьютерной программы или робота) "организмов", способных приспособиваться к внешней среде. Эти организмы называются "*аниматами*" (от англ. animal + robot = animat). Также часто используется термин "автономный агент".

Поведение аниматов имитирует поведение животных. Исследователи направления "Адаптивное поведение" стараются строить именно такие модели, которые применимы к описанию поведения как *реального животного, так и искусственного анимата* [11,12].

Программа-минимум направления «АП» – исследовать архитектуры и принципы функционирования, которые позволяют животным или роботам жить и действовать в переменной внешней среде.

Программа-максимум этого направления – попытаться проанализировать эволюцию когнитивных способностей животных и эволюционное происхождение человеческого интеллекта [13].

Программа максимум как раз и соответствует очерченной выше задаче моделирования когнитивной эволюции.

Для исследований АП характерен *синтетический подход*: здесь конструируются архитектуры, обеспечивающие "интеллектуальное" поведение аниматов. Причем это

конструирование проводится как бы с точки зрения инженера: исследователь сам "изобретает" архитектуры, подразумевая конечно, что какие-то подобные структуры, обеспечивающие адаптивное поведение, должны быть у реальных животных.

При этом направление исследований АП рассматривается как бионический подход к разработке систем искусственного интеллекта [14].

Хотя «официально» направление АП было провозглашено в 1990 году, были явные провозвестники этого направления. Приведем примеры из истории отечественной науки.

В 1960-х годах блестящий кибернетик и математик М.Л. Цетлин предложил и исследовал модели автоматов, способных адаптивно приспосабливаться к окружающей среде. Работы М.Л. Цетлина инициировали целое научное направление, получившее название "коллективное поведение автоматов" [15,16].

В 1960-70-х годах под руководством талантливого кибернетика М.М. Бонгарда был предложен интересный проект "Животное", направленный на моделирование адаптивного поведения искусственных организмов с иерархией целей и подцелей [17,18].

Хороший обзор ранних работ по адаптивному поведению, представлен в книге М.Г. Гаазе-Рапопорта, Д.А. Пospelова "От амебы до робота: модели поведения" [18].

В исследованиях АП используется ряд нетривиальных компьютерных методов:

- нейронные сети,
- генетический алгоритм [19,20] и другие методы эволюционной оптимизации,
- классифицирующие системы (Classifier Systems) [21],
- обучение с подкреплением (Reinforcement Learning) [22].

2.2. Исследователи адаптивного поведения

Исследования по адаптивному поведению ведутся в ряде университетов и лабораторий, таких как:

- AnimatLab (Париж, руководитель – один из инициаторов данного направления Жан-Аркадий Мейер) [13,23]. Подход AnimatLab предполагает, что система управления анимата может формироваться и модифицироваться посредством 1) *обучения*, 2) *индивидуального развития* (онтогенеза) и 3) *эволюции*.
- Лаборатория искусственного интеллекта в университете Цюриха (руководитель Рольф Пфейфер) [24,25]. Основной подход этой лаборатории – познание природы интеллекта путем создания ("understanding by building"). Он включает в себя 1) построение моделей биологических систем, 2) исследование общих принципов естественного интеллекта животных и человека, 3) использование этих принципов при конструировании роботов и других искусственных интеллектуальных систем.
- Лаборатория искусственной жизни и роботики в Институте когнитивных наук и технологий (Рим, руководитель Стефано Нолфи) [26,27], ведущая исследования в области эволюционной роботики и принципов формирования адаптивного поведения.
- Лаборатория информатики и искусственного интеллекта в Массачусетском технологическом институте (руководитель Родни Брукс) [28,29], которая ведет исследования широкого спектра интеллектуальных и адаптивных систем, включая создание интеллектуальных роботов.

- Институт нейронаук Дж. Эдельмана, где ведутся разработки поколений моделей работы мозга (Darwin I, Darwin II, ...) и исследования поведения искусственного организма NOMAD (Neurally Organized Mobile Adaptive Device), построенного на базе этих моделей [30,31].

В России исследования АП пока ведутся скромными усилиями ученых-энтузиастов, среди этих работ следует отметить:

- модели поискового адаптивного поведения на основе спонтанной активности [11,12,32] (В.А. Непомнящих, Институт биологии внутренних вод им. И.Д. Папанина РАН);
- концепции и модели автономного адаптивного управления на основе аппарата эмоций [33] (А.А. Жданов, Институт системного программирования РАН);
- разработку принципов построения систем управления антропоморфных и гуманоидных роботов [34] (Л.А. Станкевич, Санкт-Петербургский политехнический университет);
- разработку нейросетевых моделей поведения роботов и робототехнических устройств [35] (А.А. Самарин, НИИ нейрокибернетики им. А.Б. Когана РГУ);
- модели АП на основе эволюционных и нейросетевых методов, в частности, модели эволюционного возникновения целенаправленного адаптивного поведения [36-38] (В.Г. Редько, М.С. Бурцев, О.П. Мосалов, Институт оптико-нейронных технологий РАН, Институт прикладной математики им. М.В. Келдыша РАН).

2.3. Проект «Мозг Анимата» [39]

Анализ исследований в рамках анимат-подхода показывает, что разработанные модели пока еще очень фрагментарны и иллюстрируют только отдельные стороны адаптивного поведения. Поэтому было бы целесообразно предложить общую «платформу» для систематического построения моделей адаптивного поведения. В работах [39,40] предложен проект «Мозг Анимата», который нацелен на формирование общей схемы построения таких моделей. Проект основан на теории функциональных систем П.К. Анохина [41]. Кратко опишем данный проект, следуя [39], где предложена архитектура системы управления аниматом, основанная на нейросетевых адаптивных критиках. Нейросетевые адаптивные критики – схемы автономного адаптивного управления, основанные на методе обучения с подкреплением [22].

Предполагается, что система управления аниматом имеет иерархическую архитектуру. Базовым элементом системы управления является отдельная функциональная система (ФС). Верхний уровень соответствует основным потребностям организма: питания, размножения, безопасности, накопления знаний. Более низкие уровни соответствуют тактическим целям поведения. Блоки всех этих уровней реализуются с помощью ФС. Управление с верхних уровней может передаваться на нижние уровни (от «суперсистем» к «субсистемам») и возвращаться назад. Предполагается, что система управления аниматом функционирует в дискретном времени $t = 1, 2, \dots$, и каждый такт времени активна только одна ФС.

Предполагается простая формализация ФС на основе адаптивных критиков. Формальная ФС моделирует следующие важные особенности ее биологического прототипа: а) прогноз результата действия, б) сравнение прогноза и результата, и в) коррекцию прогноза путем обучения в соответствующих нейронных сетях.

Схема адаптивного критика. Рассматриваемая схема адаптивного критика состоит из двух нейронных сетей: Модель и Критик. Предполагается, что производные по весам синапсов нейронных сетей могут быть вычислены обычным методом обратного распространения

ошибки [42]. Также предполагается, что адаптивный критик предназначен для выбора одного из нескольких действий. Например, при управлении движением действиями могут быть: двигаться вперед, поворачивать вправо, поворачивать влево, стоять на месте. В каждый момент времени t адаптивный критик должен выбрать одно из возможных действий.

Цель адаптивного критика – максимизировать функцию суммарной награды $U(t)$:

$$U(t) = \sum_{j=0}^{\infty} \gamma^j r(t_j), \quad t = t_0, t_1, t_2, \dots,$$

где $r(t_j)$ – текущее подкрепление (награда $r(t_j) > 0$, или наказание $r(t_j) < 0$), полученное адаптивным критиком в данный момент времени t_j , γ – коэффициент забывания, $0 < \gamma < 1$. $\tau = t_{j+1} - t_j$ – шаг по времени. Коэффициент забывания учитывает, что чем дальше анимат «заглядывает» в будущее, тем меньше у него уверенность в оценке награды («рубль сегодня стоит больше, чем рубль завтра»).

Модель имеет два типа входов: 1) входы, характеризующие текущую ситуацию $S(t)$ (сигналы из внешней и внутренней среды анимата), и 2) входы, характеризующие действия. Предполагается, что число возможных действий n_a невелико. Роль Модели – прогноз следующей ситуации $S^{Pr}_i(t+\tau)$ для всех возможных действий a_i , $i=1,2,\dots, n_a$.

Роль Критика – оценка качества ситуаций $V(S)$, в частности, прогнозируемых ситуаций $S^{Pr}_i(t+\tau)$ для всех возможных действий. Величина $V(S)$ есть оценка аниматом функции суммарной награды $U(t)$, которую можно получить в будущем, исходя из данной ситуации S . Эта оценка постепенно уточняется в процессе обучения.

При выборе действия применяется ε -жадное правило [22]:

- с вероятностью $1 - \varepsilon$ выбирается действие с максимальным значением $V(S^{Pr}_i(t+\tau))$:

$$k = \arg \max_i \{V(S^{Pr}_i(t+\tau))\},$$

- с вероятностью ε выбирается произвольное действие a_k , $0 < \varepsilon \ll 1$,

k – индекс выбираемого действия.

Применение этого правила означает, что с большой вероятностью выбирается действие, для которого максимальна оценка суммарной награды $U(t)$, ожидаемой в будущем.

Обучение Модели проводится обычным методом обратного распространения ошибки [42]. Смысл обучения Модели – уточнение прогнозов будущих ситуаций.

Обучение Критика проводится методом ошибки временной разности [22]. Смысл обучения Критика состоит в том, чтобы итеративно уточнять оценки качества ситуаций $V(S(t))$ в соответствии с поступающими подкреплениями r .

Функционирование системы управления аниматом. Предполагается следующая схема работы ФС в рамках функционирования всей системы управления аниматом. Каждая ФС представляет собой адаптивный критик, имеющий связи с некоторой суперсистемой (системой более высокого уровня иерархии) и, возможно, одной или несколькими подсистемами (системами более низкого уровня иерархии). ФС активизируется командой от суперсистемы; Модель и Критик функционируют так, как описано выше. В результате осуществляется выбор действия a_k . Дальнейшее зависит от вида действия a_k . Если действие – команда для исполнительных элементов, то такое действие выполняется сразу. Далее анимат получает подкрепление r из внешней или внутренней среды, и производится обучение в нейронных сетях Модели и Критика.

Другой тип действий – команды для subsystem. Для такого действия подается команда активизации определенной subsystem (выбор конкретной subsystem определяется номером действия a_k). В этом случае сравнение прогноза и результата, оценка подкрепления r и обучение нейронных сетей откладывается до получения отчета от subsystem.

После выполнения всех этих действий ФС посылает отчет об окончании своей работы суперсистеме.

Описанный способ работы ФС представляет собой обычный режим функционирования. Вводится также экстраординарный режим, который имеет место, если прогноз существенно отличается от фактического результата. В экстраординарном режиме величина ε (вероятность выбора случайного действия) в данной ФС и ее subsystem резко возрастает, и поиск новых решений включает большую случайную компоненту. Этот поиск может сопровождаться случайным формированием и селекцией новых функциональных систем, аналогично селекции нейронных групп в теории нейродарвинизма Дж. Эдельмана [43]. Таким образом, обычный режим функционирования может рассматриваться как тонкая настройка системы управления аниматором, в то время как экстраординарный режим – это грубый поиск подходящего поведения в чрезвычайных ситуациях.

Подробнее о работе данной схемы Мозга Анимата см. в [20,39].

2.4. Выводы по моделям адаптивного поведения

Исследования адаптивного поведения – актуальное, содержательное и конструктивное направление, которое непосредственно связано с моделированием когнитивной эволюции. Также это направление исследований важно как биологически инспирированная научная основа разработок систем искусственного интеллекта. Это направление использует серьезные математические и компьютерные методы, и здесь построено множество интересных и содержательных моделей. Однако, в целом, результаты этих исследований пока еще далеки от решения стратегически задач, поставленных при инициировании этого направления.

Один из значительных и достаточно неожиданных выводов этих исследований состоит в том, что часто нетривиальное поведение может быть сформировано простой системой управления [11]. Причем, такой системой управления, до которой сам исследователь может и не догадаться – система управления (в частности, нейронная сеть) может формироваться в процессе эволюционной самоорганизации, например, с помощью генетического алгоритма.

3. Моделирование когнитивной эволюции - естественнонаучная основа разработок искусственного интеллекта

Направление исследований Искусственный интеллект (ИИ), скорее всего, можно рассматривать как прикладное – применение принципов естественного интеллекта в искусственных практически важных для человека компьютерных системах. Судьба прикладных разработок зависит от наличия достаточно серьезного научного фундамента, на котором базируются такие разработки. Например, научной базой развития микроэлектроники во второй половине 20-го века была физика твердого тела. При этом для физиков чисто научные исследования твердого тела были интересны фактически независимо от применения их исследований, в результате чего научная основа микроэлектроники

интенсивно развивалась. И результаты микроэлектроники, как наукоемкой технологии, впечатляющи.

Моделирование когнитивной эволюции чрезвычайно интересно и важно с точки зрения научного миропонимания. Следовательно, можно ожидать, что такие исследования, которые предоставили бы картину возникновения и эволюционного формирования естественного интеллекта, будут очень интересны для ученых. Но эти исследования могут быть тесно связаны и с разработками ИИ. И, следовательно, могло бы быть взаимное обогащение фундаментальных и прикладных исследований природы интеллекта. И, тем самым, исследования когнитивной эволюции могли бы служить научной основой разработок систем ИИ.

4. Контуры программы будущих исследований

Итак, очерчены модели и задел исследования когнитивной эволюции. Видно, что хотя проделана большая работа, ученые еще очень далеки от понимания того, как возникали и развивались системы управления живых организмов, как развитие этих систем способствовало эволюции когнитивных способностей животных, и как процесс когнитивной эволюции привел к возникновению интеллекта человека. То есть, есть огромная область чрезвычайно интересных исследований, которые только-только начинаются.

Очень хороший задел к исследованию когнитивной эволюции – модели адаптивного поведения (раздел 2), дальняя цель которых как раз и состоит в осмыслении эволюции когнитивных способностей животных в контексте эволюционного происхождение человеческого интеллекта. Поэтому предложим план исследований, отталкиваясь от работ по моделям адаптивного поведения.

- 1. Разработка схем и моделей адаптивного поведения анимата на базе проекта «Мозг Анимата».** Воплощение в конкретные модели конструкций Мозга Анимата разумно начать с анализа целостного адаптивного поведения простых агентов, имеющих естественные потребности: питания, размножения, безопасности. Эволюционная схема формирования нейросетевой системы управления подобных агентов, обеспечивающей достаточно нетривиальную структуру целей и подцелей, была исследована М.С. Бурцевым [37]. Теперь было бы полезно промоделировать подобные системы управления в рамках проекта «Мозг анимата».

Дальнейшая работа могла бы включать в себя анализ интеллектуальных изобретений биологической эволюции, таких как привыкание и условные рефлекс (раздел 1), на основе исследований проекта «Мозг анимата».

- 2. Исследование перехода от физического уровня обработки информации в нервной системе животных к уровню обобщенных образов.** Такой переход можно рассматривать, как появление в "сознании" животного свойства "понятие". Обобщенные образы можно представить как мысленные аналоги наших слов, не произносимых животными, но реально используемых ими. Например, у собаки явно есть понятия "хозяин", "свой", "чужой", "пища". И важно осмыслить, как такой весьма нетривиальный переход мог произойти в процессе эволюции.
- 3. Исследование процессов формирования причинной связи в памяти животных.** По-видимому, запоминание причинно-следственных связей между событиями во

внешней среде и адекватное использование этих связей в поведении – одно из ключевых свойств активного познания животным закономерностей внешнего мира. Такая связь формируется, например, при выработке условного рефлекса: животное запоминает связь между условным стимулом (УС) и следующим за ним безусловным стимулом (БС), что позволяет ему предвидеть события в окружающем мире и адекватно использовать это предвидение.

Естественный следующий шаг – переход от отдельных причинных связей к «базам знаний», к логическим выводам на основе уже сформировавшихся знаний.

4. **Исследование процессов формирования логических выводов в «сознании» животных.** Фактически, уже на базе классического условного рефлекса животные способны делать «логический вывод» вида: $\{УС, УС \rightarrow БС\} \Rightarrow БС$ или «Если имеет место условный стимул, и за условным стимулом следует безусловный, то нужно ожидать появления безусловного стимула». Можно даже говорить, что такие выводы подобны выводам математика, доказывающего теоремы (раздел 1). И целесообразно разобраться в системах подобных выводов, понять, насколько адаптивна логика поведения животных и насколько она подобна нашей, человеческой логике.
5. **Исследование коммуникаций, возникновения языка.** Наше мышление тесно связано с языком, с языковым общением между людьми. Поэтому целесообразно проанализировать: как в процессе биологической эволюции возникал язык общения животных, как развитие коммуникаций привело к современному языку человека, как развитие коммуникаций и языка способствовало развитию логики, мышления, интеллекта человека.

Конечно же, перечисленные пункты формируют только контуры плана будущих исследований. Тем не менее, уже сейчас видно, сколь широк фронт исследований, и как много нетривиальной, интересной и важной работы предстоит сделать.

ЛИТЕРАТУРА

1. Кант И. Критика чистого разума. Соч. в 6-ти томах. Т.3. М.: Мысль, 1964. С. 69-695.
2. Кант И. Прологомены ко всякой будущей метафизике, могущей появиться как наука. Соч. в 6-ти томах. Т.4, часть 1. М.: Мысль, 1965. С. 67-210.
3. Semantic Networks in Artificial Intelligence, Lehmann, Fritz, ed., Pergamon Press, Oxford, 1992.
4. Воронин Л.Г. Эволюция высшей нервной деятельности. М.: Наука. 1977. 128 с.
5. Юм Д. Исследование о человеческом познании. Соч. в 2-х томах. Т.2. М.: Мысль, 1966. С. 5-169.
6. Lorenz K. Kant's doctrine of the a priori in the light of contemporary biology (1941) // In: ed. Plotkin H., Learning, Development and Culture. N.Y. 1982.
7. Поппер К. Эволюционная эпистемология // Сб. Эволюционная эпистемология и логика социальных наук: Карл Поппер и его критики. Составление Д.Г. Лахути, В.Н. Садовского, В.К. Финна. М: Эдиториал УРСС, 2000.
8. Меркулов И.П. Когнитивная эволюция. М. Наука, 1999.
9. Турчин В.Ф. Феномен науки. Кибернетический подход к эволюции. М.: Наука, 1993. 295с. (1-е изд.). М.: ЭТС, 2000. 368с (2-е изд.). См. также <http://www.refal.ru/turchin/phenomenon/>

10. Meyer J.-A., Wilson S. W. (Eds) From animals to animats. Proceedings of the First International Conference on Simulation of Adaptive Behavior. The MIT Press: Cambridge, Massachusetts, London, England. 1990.
11. Непомнящих В.А. Аниматы как модель поведения животных // IV Всероссийская научно-техническая конференция "Нейроинформатика-2002". Материалы дискуссии "Проблемы интеллектуального управления – общесистемные, эволюционные и нейросетевые аспекты". М.: МИФИ, 2003. С. 58-76. См. также <http://www.keldysh.ru/pages/BioCyber/RT/Nepomn.htm>
12. Непомнящих В.А. Поиск общих принципов адаптивного поведения живых организмов и аниматов // Новости искусственного интеллекта. 2002. N. 2. С. 48-53.
13. Donnart J.Y., Meyer J.A. Learning reactive and planning rules in a motivationally autonomous animat // IEEE Transactions on Systems, Man, and Cybernetics - Part B: Cybernetics, 1996. V. 26. N. 3. PP.381-395. See also: <http://animatlab.lip6.fr/index.en.html>
14. Wilson S.W. The animat path to AI // In: [10]. PP. 15-21.
15. Цетлин М.Л. Исследования по теории автоматов и моделирование биологических систем. – М.: Наука, 1969. 316 с.
16. Варшавский В.И., Поспелов Д.А. Оркестр играет без дирижера. М.: Наука, 1984.
17. Бонгард М.М., Лосев И.С., Смирнов М.С. Проект модели организации поведения – "Животное" // Моделирование обучения и поведения. М.: Наука, 1975. С.152-171.
18. Гаазе-Рапопорт М.Г., Поспелов Д.А. От амебы до робота: модели поведения. М.: Наука, 1987.
19. Holland J.H. Adaptation in Natural and Artificial Systems. – Ann Arbor, MI: The University of Michigan Press, 1975 (1st edn). Boston, MA: MIT Press., 1992 (2nd edn).
20. Редько В.Г. Эволюция, нейронные сети, интеллект. Модели и концепции эволюционной кибернетики. М.: УРСС, 2005. 224 с.
21. Holland J.H., Holyoak K.J., Nisbett R.E., Thagard P. Induction: Processes of Inference, Learning, and Discovery. Cambridge, MA: MIT Press, 1986.
22. Sutton R., Barto A. Reinforcement Learning: An Introduction. Cambridge: MIT Press, 1998. See also: <http://www.cs.ualberta.ca/~sutton/book/the-book.html>
23. Сайт AnimatLab: <http://animatlab.lip6.fr/index.en.html>
24. Сайт AI Laboratory of Zurich University: <http://www.ifi.unizh.ch/groups/ailab/>
25. Pfeifer R., Scheier C., Understanding Intelligence. MIT Press, 1999.
26. Сайт Laboratory of Artificial Life and Robotics: <http://gral.ip.rm.cnr.it/>
27. Nolfi S., Floreano D. Evolutionary Robotics: The Biology, Intelligence, and Technology of Self-Organizing Machines. Cambridge, MA: MIT Press/Bradford Books, 2000. 384 p.
28. Сайт MIT Computer Science and Artificial Intelligence Laboratory: <http://www.csail.mit.edu/index.php>
29. Brooks R.A. Cambrian Intelligence: The Early History of the New AI. MIT Press, 1999.
30. Сайт Neuroscience Institute: <http://www.nsi.edu/>
31. Krichmar J.L., Edelman G.M. Machine psychology: autonomous behavior, perceptual categorization and conditioning in a brain-based device, Cerebral Cortex, 2002, V. 12. PP. 818-830.
32. Nepomnyashchikh V.A., Podgornyj K.A. Emergence of adaptive searching rules from the dynamics of a simple nonlinear system // Adaptive Behavior. 2003. V.11. N.4. PP.245-265.
33. Жданов А.А. Метод автономного адаптивного управления // Известия Академии Наук. Теория и системы управления. 1999. N. 5. С. 127-134.
34. Станкевич Л.А. Нейрологические средства систем управления интеллектуальных роботов // VI Всероссийская научно-техническая конференция "Нейроинформатика-2004". Лекции по нейроинформатике. Часть 2. М.: МИФИ, 2004. С. 57-110.

35. Самарин А.И. Модель адаптивного поведения мобильного робота, реализованная с использованием идей самоорганизации нейронных структур // IV Всероссийская научно-техническая конференция "Нейроинформатика-2002". Материалы дискуссии "Проблемы интеллектуального управления – общесистемные, эволюционные и нейросетевые аспекты". М.: МИФИ, 2003. С. 106-120.
36. Бурцев М.С., Гусарев Р.В., Редько В.Г. Исследование механизмов целенаправленного адаптивного управления // Изв. РАН "Теория и системы управления" 2002. N.6. С.55-62.
37. Бурцев М.С. Модель эволюционного возникновения целенаправленного адаптивного поведения. 2. Исследование развития иерархии целей // Препринт ИПМ РАН, 2002, N. 69.
38. Red'ko V.G., Mosalov O.P., Prokhorov D.V. A model of evolution and learning // Neural Networks, 2005. V. 18. PP. 738-745.
39. Red'ko V.G., Prokhorov D.V., Burtsev M.S. Theory of functional systems, adaptive critics and neural networks // International Joint Conference on Neural Networks, Budapest, 2004. PP. 1787-1792.
40. Анохин К.В., Бурцев М.С., Зарайская И.Ю., Лукашев А.О., Редько В.Г. Проект «Мозг анимата»: разработка модели адаптивного поведения на основе теории функциональных систем // Восьмая национальная конференция по искусственному интеллекту с международным участием. Труды конференции. М.: Физматлит, 2002. Т.2. С.781-789.
41. Анохин П.К. Системные механизмы высшей нервной деятельности. М.: Наука, 1979. 453 с.
42. Rumelhart D.E., Hinton G.E., Williams R.G. Learning representation by back-propagating error // Nature. 1986. V.323. N.6088. PP. 533-536.
43. Edelman G. M. Neural Darwinism: The Theory of Neuronal Group Selection. Oxford: Oxford University Press, 1989.