

БИОЛОГИЧЕСКИЕ МОДЕЛИ РАЗВИТИЯ СЕТЕЙ ОБЕСПЕЧЕНИЯ ЭНЕРГИЕЙ НА ТРАНСПОРТЕ

Безродный А.А., He Je Peng, Huang Ricky

Белорусский государственный университет, Минск, Беларусь
bezrtodnyaa@yandex.ru, 1074273694@qq.com, Ricky867626073@gmail.com

Дранко О.И.

Институт проблем управления им. В.А. Трапезникова РАН, Москва, Россия
drankooi@ipu.ru

Аннотация. Рассматривается динамика представлений сложных систем – от теоретико-множественных к эволюционным моделям – для обеспечения энергией на транспорте.

Ключевые слова: модели структур, управление, большие кибер-физические междисциплинарные системы, каузальные связи, генетические и эволюционные алгоритмы, роевой интеллект.

Введение

Развитие представлений сложных систем говорит о современной целесообразности их логико-лингвистических моделей [1] в виде причинно-следственного (ПС) или каузального подхода [2]. С его помощью задаются правила обработки и отношения между компонентами искусственных нейронных сетей (ИНС), широко применяемых сегодня для автоматизированной обработки больших объемов данных, генерируемых многочисленными развивающимися кибер-физическими системами (КФС).

Некоторые аспекты использования биологических аналогий, определивших в 1930 гг понятие «Система», на примере сетей обеспечения энергией на транспорте (СОЭТ) как важной передаточной отрасли экономики, для развития представлений, и рассматриваются в работе.

1. Содержательное описание, постановка задачи, показатели эффективности

Естественным продолжением аналитического (функциональные зависимости показателей), статистического (временные тренды параметров) и теоретико-множественного (любые связанные элементы) подходов [3] к представлению и совершенствованию сложных систем, являются логико-лингвистический модели, отражающие смысловые компоненты и причинно-следственные отношения.

В каузальном преставлении общая задача формулируется как достижение требуемых показателей K^* посредством управления в условиях факторов функционирования и развития G :

$$\begin{array}{ccc} \text{Причина: } K, G & & \text{Следствие: } K^* \\ \rangle & A, H, X, U & \langle \\ \text{Условие 1: } w, S & & \text{Условие 2: } G^*, w^*, S^* \end{array}$$

Рис. 1. Общая каузальная постановка задачи развития сложной системы

На рис. 1 A – множества информационно-логических схем, обобщённых и вычислительных алгоритмов взаимодействия и управления (принципов, процедур и функций управления C) на периодах H , X – организационные и технические средства системы управления (СУ), U – отношения между ними, S – состояния как этапы жизненного цикла (ЖЦ), W – ресурсы (материалы, оборудование, технологии, сведения, энергия, финансы, люди), $*$ – параметры и характеристики после взаимодействия.

На следующем уровне декомпозиции задача формулируется как построение множеств X и U , которые посредством решения задач управления F позволяют достичь требуемое $K^*_{СОЭТ}$:

$$K_{СОЭТ} = \sum_{s=1}^S \left(\sum_{hi=1}^{HI_s} \left(\sum_{r=1}^{n_{hi}} \frac{R_{r,h,hi,s} - L_{r,hi,s}}{C_{r,h,hi,s}} + SEH_{HI} \right) + SES_s \right) \xrightarrow{F,G} K^*_{СОЭТ}.$$

Параметрами являются средства управления X , выбором структуры, состава и отношений U между которыми и достигается $K^*_{СОЭТ}$, SEH и SES – отражают нелинейные эффекты функциональных подсистем s ($s=1..S$), уровней иерархии hi ($hi=1..HI$) и объектов r ($r=1..R$), R, C, L – соответственно, результаты, издержки и потери нереализованных вариантов развития (для уровней и видов систем).

2. Обеспечение энергией на транспорте: модели биологических аналогий

Переход от общих моделей структуры и состава систем теории множеств к вычислительным алгоритмам реализуется посредством теории графов, формализующей каузальные связи между их компонентами. С помощью матричного исчисления далее задаются массивы данных на ЭВМ и проводится имитационное моделирование, сегодня успешно с помощью искусственных нейронных сетей. ИНС моделируют работу головного мозга человека как согласованных элементарных ячеек, скоординировано выполняющих множество простых операций, на которые можно разложить задачи вплоть до уровня, достаточного подготовленному ЛПР для обоснованных решений. Упомянутые ПС-связи задаются с помощью ранее созданных моделей Баз Данных и Знаний БД(З), определяющих правила активации узлов ИНС и формирования отношений между ними. Если ИНС позволяют находить закономерности трендов показателей, то модели биологических аналогий имитируют развитие новых объектов с наследованием параметров и коллективное поведение простейших боидов.

Таблица 1. Группы моделей искусственного интеллекта для развития кибер-физических систем

Метод	Описание	Краткая характеристика	Особенности
Искусственные нейронные сети (Artificial neural network, ANN)	Взаимодействие элементарных объектов, успешно имитируемое множеством простых операций, выполняемых современными быстродействующими ЭВМ	Рекуррентные ИНС (recurrent RNN), коррекция параметров по результатам обратной связи	Калибровка на тестовых данных, итерационное взаимодействие и коррекция (обучение с учителем и без)
		Сверточные ИНС (convolutional, CNN), снижение размерности	
		Долговременной памяти (Long Short-time memory, LSTM)	
Эволюционные (Evolution, EA) и генетические (Genetic, GA) алгоритмы	Теория эволюции Дарвина для сложных систем	Адаптация и развитие приспособленных объектов	Наследственная изменчивость и отбор
	Синтетическая теория эволюции, неodarвинизм	Управляемая вариация показателей	Направленный отбор
Роевой интеллект (РИ) (Swarm Intelligence, SI)	Рой множества простых боидов	Согласованное поведение элементарных объектов	Демонстрация самоорганизации
	Пчелиный рой	Функциональное деление, разведчики, рабочие и т.п.	Структура классической СУ
	Муравьиная колония	Наилучший путь, исходя из анализа предпочтений	Затухание при падении интереса

Ряд актуальных задач развития СОЭТ кратко представлен на рис. 2.



Рис. 2. Некоторые актуальные задачи систем обеспечения энергией на транспорте

2.1. Алгоритм оптимизации муравьиной колонии с подкреплением

В частности, алгоритм оптимизации муравьиной колонии (Ant Colony Optimization, ACO) моделирует ее обеспечение пищевыми ресурсами [4], что аналогично обслуживанию потоков клиентов СОЭТ. Муравьи выделяют феромоны, помечая успешные в смысле источников питания пути, что

соответствует заданию структур систем обслуживания на улично-дорожных сетях (УДС) в соответствии с предпочтениями клиентов G_1 при наличии конкурентов G_2 с учетом возможностей поставщиков G_3 и макроэкономических условий МЭО G_4 .

Алгоритм реализации модели АСО для СОЭТ представлен на Рис. 3.

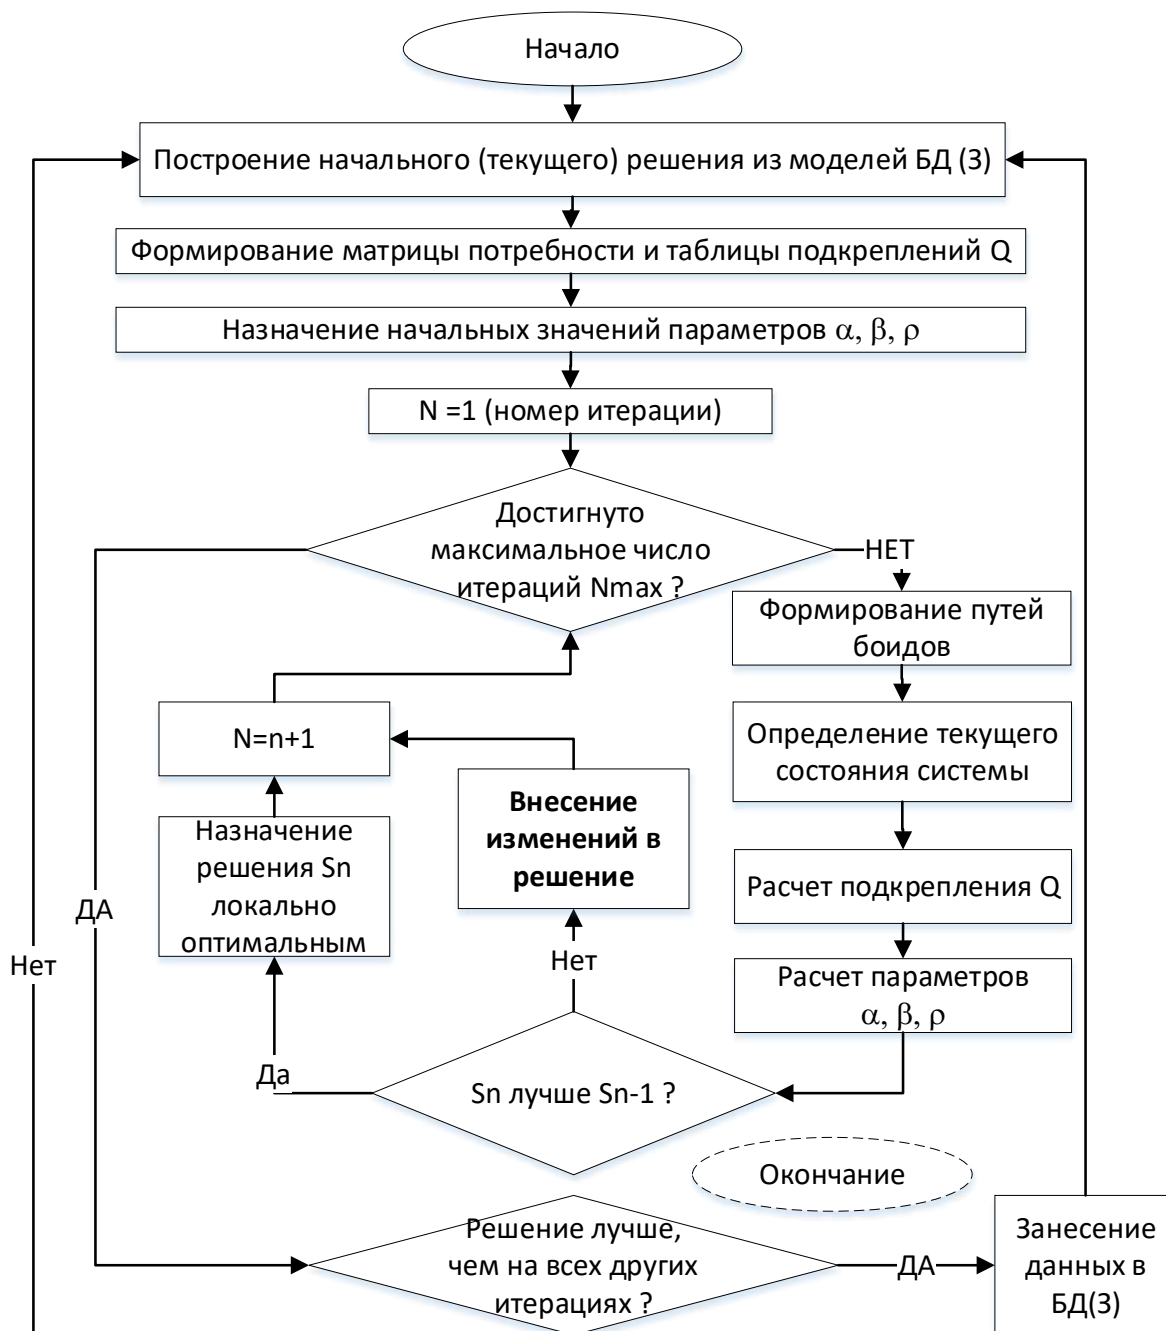


Рис. 3. Вычислительная схема оптимизации муравьиной колонии с подкреплением

Вероятность перехода между точками i и j УДС определяется как:

$$p_{ij}^k = \frac{[\tau_{ij}]^\alpha \cdot [\eta_{ij}]^\beta}{\sum_{s \in allowed_k} [\tau_{is}]^\alpha \cdot [\eta_{is}]^\beta}, \quad \tau_{ij}(0) = const,$$

где τ_{ij} – уровень предпочтений, степени удовлетворенности клиентов, η_{ij} , α и β – важность при данном взаимодействии и ранее, d_{ij} – расстояние между точками (питания) i и j

Целевая функция определяет расстояние между точками обслуживания, соответствующими предпочтениям клиентов в условия $G_{1..4}$, и с необходимостью устремляется к минимуму,

$$\min(\text{distance}) = \sum_i^n \sum_j^n d_{ij}, G_{1..4}.$$

На каждом шаге алгоритма Рис. 3 определяется степень удовлетворенности боидов Q , задающая направление их движения далее. В пространстве состояний определяются расстояния между текущими и исторически лучшими решениями, после чего направленно с учетом помех и неопределённостей в допустимых интервалах изменений α и β (фактически, параметры управления) и ρ (угасание положительного восприятия торговой марки и его подкрепление Q) задаются правила выбора:

$$(1 - \alpha)Q(s, a) + \alpha[r + \gamma \max_{a'} Q(s', a')] \rightarrow Q(s, a), r = \begin{cases} 1.0, & d_2 < d_1 \\ 0.0, & d_2 = d_1, t_2 > t \\ -0.5, & d_2 > d_1 \end{cases}$$

где s – текущее состояние, r – коэффициент, связанный с выбором направления перехода, γ – важность изменения при актуализации Q на новом шаге, d_2 – расстояние на нем, d_1 – известная наилучшая длина пути. Схема актуализации предпочтений задается как

$$\tau_{ij}(t + 1) = (1 - \rho)\tau_{ij}(t) + \Delta\tau_{ij}, \Delta\tau_{ij} = \begin{cases} \frac{2.0}{L_{\text{лучш}}}, & \text{edge}(i, j), \text{ лучший путь} \\ \frac{1.0}{L_k}, & \text{edge}(i, j) \text{ иной путь} \end{cases} \quad \Delta\tau_{ij}(t) = \sum_{k=1}^m \Delta\tau_{ij}^k(t),$$

где $\rho - \Delta\tau_{ij}$ вклад СУ, $L_{\text{лучш}}$ – наилучший путь, L_k – путь (иной) боида k .

Вычислительный алгоритм реализуется по схеме мини-макса и рассчитывает баланс затухания и поддержки предпочтений на апробированных путях по уровню феромонов (АСО) и маркетинга (СОЭТ). Обоснованность подобной (достаточно общей) оценки предпочтений реальной системы, сегодня называемая обучение с подкреплением Q-learning [5], подтверждается результатами реализованной в Чили в 1970 гг АСУ Cybersyn.

2.2. Вирусные эволюционные алгоритмы

Иным примером применения **моделей биологических аналогий** являются **Генетические алгоритмы** (ГА) эвристического поиска решений путём случайного или направленного изменения генома (набора параметров), их наследования (привнесения во вновь создаваемые или изменяемые системы), естественного и искусственного отбора наиболее приспособленных особей (алгоритмическое принятие и исполнение решений) и развития их популяций (тиражирование успешных в заданном смысле компонент).

Для преодоления трудностей классических ГА по скорости сходимости [6] и описания пилотных проектов развития СУ рассматривается Вирусный эволюционирующий генетический алгоритм ВЭГА (Virus Evolutionary Genetic Algorithm, VEGA).

Вирус как моделирующая система или генетический оператор, где программно-целевая СУ адаптируется к изменениям и развивается совместно с основной системой. Это отражает принцип взаимоувязанного совершенствования управляющей и управляемой систем и релевантных компонент среды и обеспечивает необходимое разнообразие компонент, а также устойчивость алгоритмов без их привязки к числу итераций.

Основные ПС-связи могут быть представлены следующим образом:

- выделение объектов, имеющих сродство (склонность) к вирусу (способность к изменениям системы) с соответствующим приоритетом взаимодействия (фитнес-функция);
- вычисление фитнес-функции до и после взаимодействия для определения восприимчивости к изменениям и направления их внедрения;
- необходимое ограничение распространения вируса для исключения необоснованной подмены системы вплоть до положительных результатов (апробации);
- при успешной апробации – тиражирование на иные части системы;
- моделирующее действие усиливается при блочном переносе гомологичных (сопоставимых) наборов параметров (crossing-over генома).

Информационно-логическая схема применения ВЭГА дана на Рис. 4.



Рис. 4. Информационно-логическая схема вирусного эволюционирующего ГА (ВЕГА)

Для СОЭТ как кибер-физической системы (КФС) это означает наличие наборов параметров (генама) исследуемой и экспериментальной систем (параметры планов логистики, производительность объектов, характеристики УДС и клиентов) и возможность моделирования их взаимодействия путем направленного или случайного изменения параметров (структур, воздействий, взаимодействия, управления). В простейшем случае считается, что СОЭТ состоит из P_i генерирующих энергию (топливо) и C_j ее потребляющих участков, $i=1..m, j=1..n$ с показателями поставки и спроса D_j .

Целевая функция формируется как

$$\min Z = \sum_{i=1}^m \sum_{j=1}^n (c_{ij} \cdot x_{ij} + p_{ij} \cdot \max(0, t_{ij} - T_{ij}))$$

$$\sum_{j=1}^n x_{ij} \leq S_i, \quad \forall i, \sum_{i=1}^m x_{ij} \geq D_j, \quad \forall j, t_{ij} \leq T_{ij}, \quad \forall i, j,$$

- c_{ij} – стоимость доставки от P_i до C_j , x_{ij} и p_{ij} – перевозимый объем и штрафы в единицу времени;
- t_{ij} – время доставки от P_i до C_j , T_{ij} – ограничение времени;
- временная синхронизации в δ_{ij} : если $|t_{ij} - T_{ij}| \leq \delta_{ij}$ нет штрафов, иначе – $p_{ij} \cdot (|t_{ij} - T_{ij}| - \delta_{ij})$;
- двумерный массив параметров/хромосом основной системы и вируса

$$\text{Chromosome}\{(x_{ij}, t_{ij}) \mid i = 1..m; j = 1..n\} = \begin{bmatrix} (x_{11}, t_{11}) & \cdots & (x_{1n}, t_{1n}) \\ \vdots & \ddots & \vdots \\ (x_{m1}, t_{m1}) & \cdots & (x_{mn}, t_{mn}) \end{bmatrix},$$

$$\text{Virus}\{(v_{ij}^x, v_{ij}^t) \mid i = 1..m; j = 1..n\} = \begin{bmatrix} (v_{11}^x, v_{11}^t) & \cdots & (v_{1n}^x, v_{1n}^t) \\ \vdots & \ddots & \vdots \\ (v_{m1}^x, v_{m1}^t) & \cdots & (v_{mn}^x, v_{mn}^t) \end{bmatrix}.$$

- фитнес-функция fithostk и fithostk^* – до и после взаимодействия

$$\Delta \text{Fitness}_{\text{virus}} = \sum_{k \in U} (\text{fithostk}^* - \text{fithostk}_k);$$

- соотнесение реальных и модельных KPI (dem – спрос, bud – бюджет)

$$\text{Fitness}_{\text{main}} = K - \left\{ \sum_{i=1}^m \sum_{j=1}^n (c_{ij} x_{ij} + p_{ij} \max(0, t_{ij} - T_{ij})) \right\} + P_{\text{dem}} + P_{\text{bud}};$$

- вычисления ведутся по схеме рулетки, вероятность выбора p_x соотносится с f_i для i -части из n .

$$p_x = \frac{f_x}{\sum_{i=1}^n f_i}.$$

3. Основные результаты и их обсуждение

В развитие работ [2, 7] можно говорить об успешности использования представленных моделей для решения практических задач [8, 9] В частности, модель Муравьиной колонии с подкреплением была апробирована для СОЭТ на тестовых данных (99 точек обслуживания, 30 клиентов, 100 итераций). Видно, существенное (44%) улучшение сходимости алгоритмов, в т.ч и на реальных данных (Рис. 5).

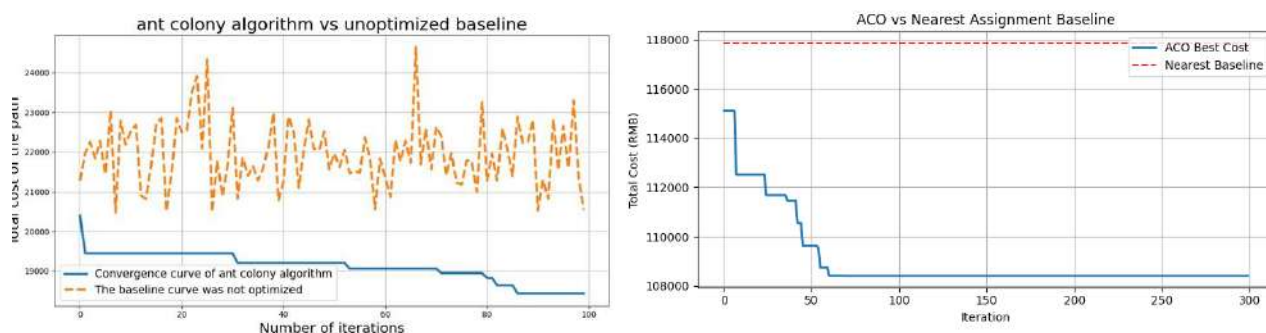


Рис. 5. Некоторые результаты применения АСО-Q для трубопроводной логистики

Рассмотренная модель ВЭГА была применена для моделирования логистики сети СОЭТ по открытым годовым отчетам социальной ответственности компаний Sinopec's и Petro-China's 2023 в отношении 3 нефтебаз (НБ), сети из 35 ЗС и автоцистерн Восточной части КНР (рис.6).

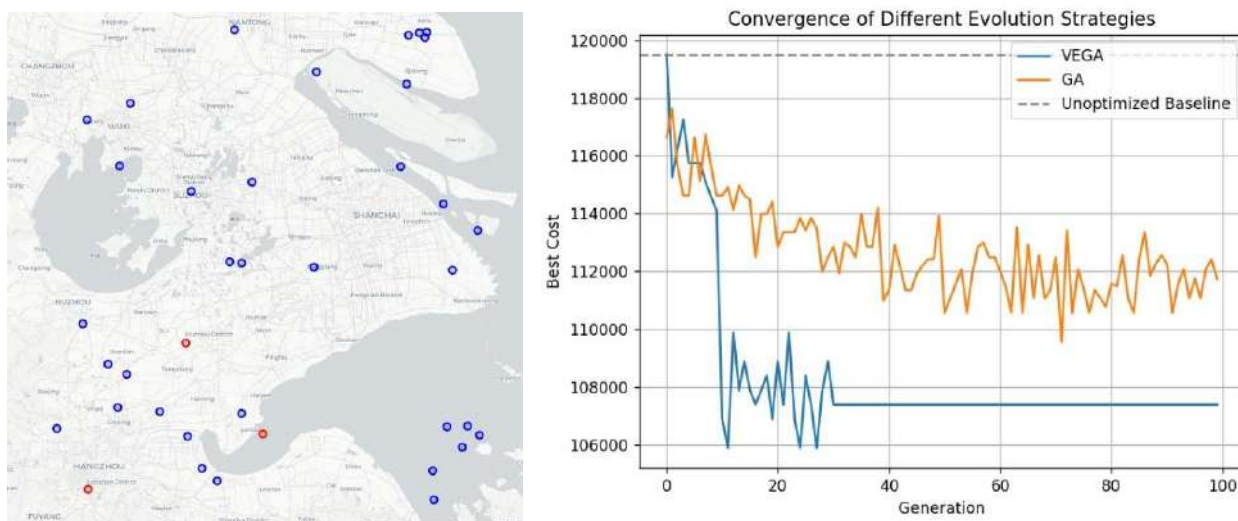


Рис. 6. Результаты моделирования логистики сети АЗС и НБ VEGA (синим) и GA (красным)

Видно, что среднее число итераций, приводящих к устойчивому решению, меньше, чем для обычного ГА. При этом переменные издержки в составе K также снижаются (до 5 %) при тех же G . В целом использование вируса позволяет ускорить адаптацию к изменениям вплоть до глобальной устойчивости (ограниченной проникновением вируса до 0,9) за счет снижения сложности КУ.

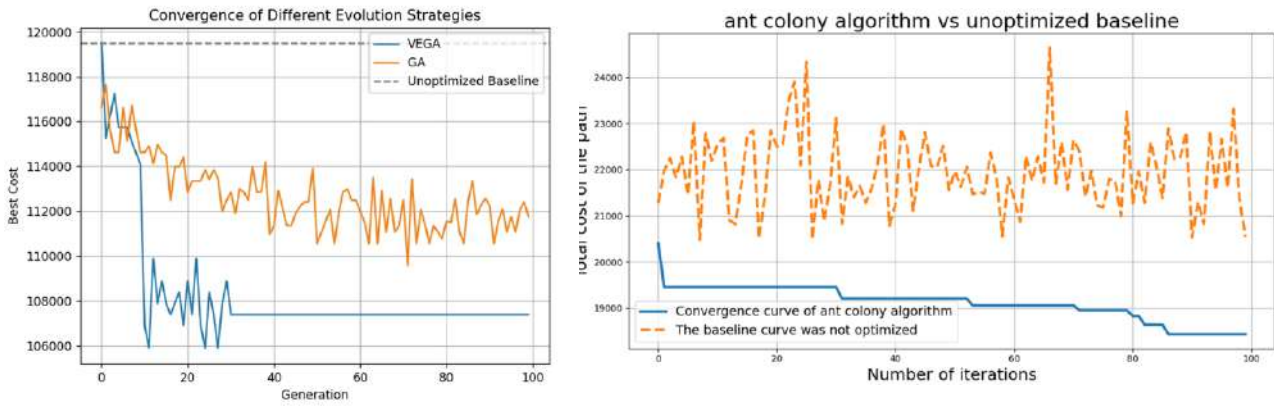


Рис. 7. Сравнение моделирования VEGA и ACO логистики 35 АЗС и 3 НБ КНР

Сравнение подходов (рис. 5 и 6) на тех же исходных данных показывает, что модель VEGA целесообразно использовать при анализе структуры и состав объектов для моделирования изменений, ACO – в случае большого объема данных и относительно простых свойств активности (рис. 7).

С учетом данных положений, обобщенный алгоритм совершенствования сложных киберфизических систем на современном этапе может быть аналогичен Рис. 8, (Т – макро-период развития).

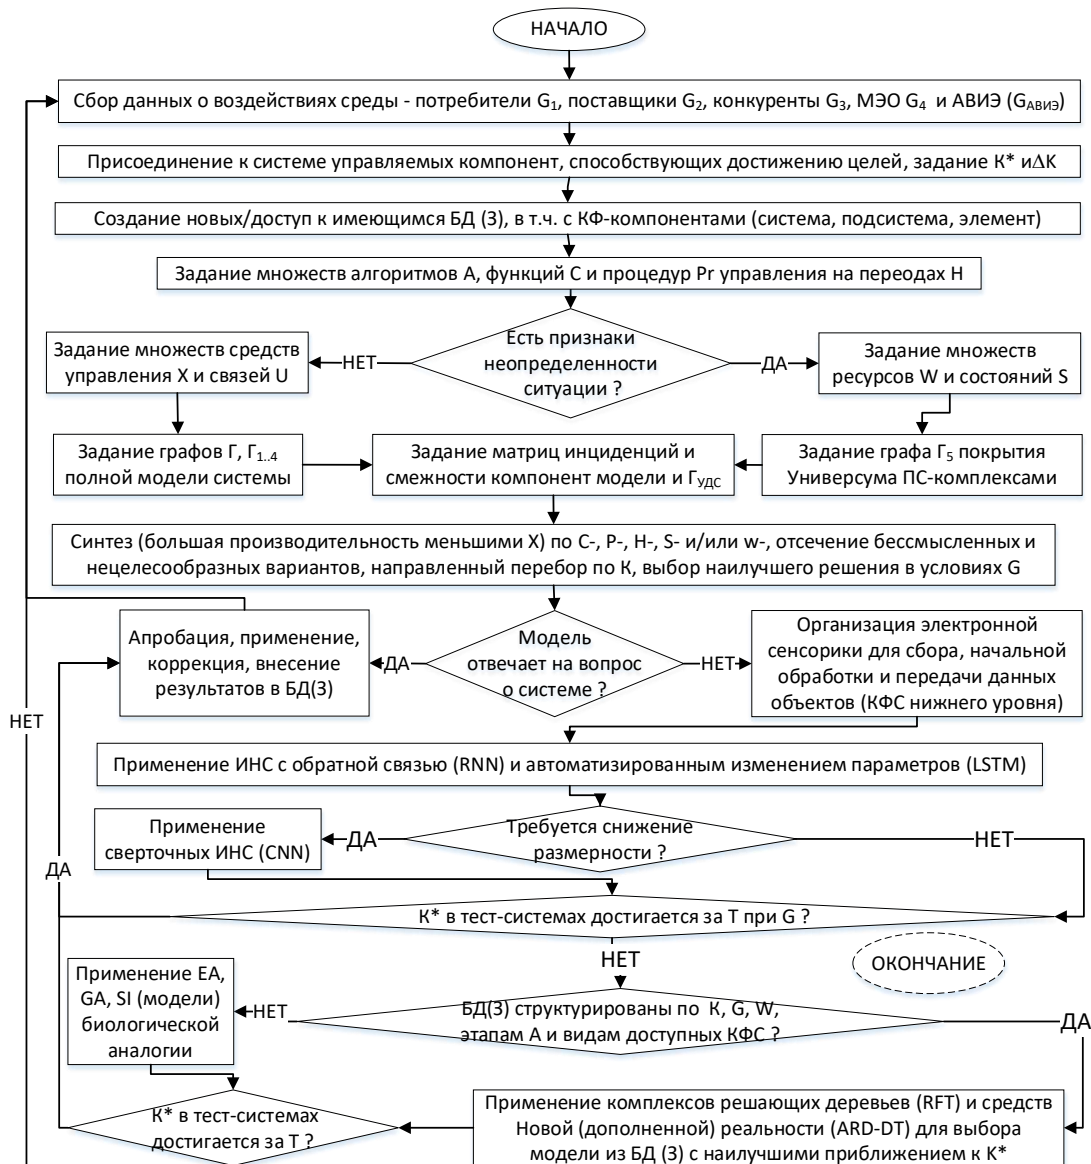


Рис. 8. Информационно-логическая схема развития сложных систем с использованием нейронных сетей и моделей биологических аналогий

4. Заключение

1. Кибер-физические модели отражают современную парадигму представления реальных сложных социально-экономических человеко-машинных систем при глубокой интеграции вычислений и управления в объекты.

2. Их создание и совершенствование целесообразно с помощью причинно-следственного подхода, в целом обоснованного естественностью развития во времени с учетом внутренних закономерностей объектов и языков предметных областей.

3. Для повышения качества исследований используются искусственные нейронные сети, структура которых схожа с каузальными моделями в алгебраической и геометрической формах.

4. Для дальнейшего снижения размерности задач применимы модели биологических аналогий – эволюционные, генетические, роевого интеллекта – из области положившей начало системотехнике.

5. В частности, интеграция схемы подкрепления в модель оптимизации муравьиной колонии и генетический алгоритм, дополненный схемами распространения вирусов, влияющих на геном объекта или его параметры управления, повышают сходимость вычислительных алгоритмов, позволяя решать задачи в реальном времени с лучшими показателями качества.

6. Представленные результаты для сетей обеспечения энергией на транспорте как естественном этапе развитии нефтепродуктообеспечения в связи с инвариантностью компонент могут быть использованы и для иных систем обеспечения и обслуживания.

7. Дальнейшее развитие возможно в части учета высокой конкурентности элементов (стая волков), 3D движения и изменения параметров (чайки), воздействия вирусов не только на систему, но и на окружающую среду и т.п.

Литература

1. *Поспелов Д.А.* Логико-лингвистические модели управления. – М: Энергоиздат, 1981. – 232 с.
2. *Резчиков А.Ф., Твердохлебов В.А.* Причинно-следственные комплексы, модели сложных систем // Мехатроника, автоматизация, управление. – 2007. – № 7. – С. 2–8.
3. Системный анализ и принятие решений / п.ред. *В.Н. Волковой.* – М: Высш. шк., 2004. – 613 с.
4. *Blum C.* ACO: Introduction, recent trends // *Physics of Life reviews* – 2005. – 2(4). – P. 353–373.
5. *Watkins C.J., & Dayan P.* Q-learning // *Machine learning.* 1992. – 8. – P. 279–292.
6. *Fleming P.J., Purshouse R.C.* Evolutionary algorithms in control systems engineering: a survey // *Control Engineering Practice* – 2002. – № 10(11). –P. 1223–1241.
7. *Bezrodniy Alexey, Rezchikov Alexander.* Hydrogen Supply Net Control for Transport Branch of Economy// *IEEE.* – 2021 – 10.1109/MLSD52249.2021.9600232.
8. *Huang Ruiqi.* Optimal control system structure formation of human-machine systems using Genetical algorithms // *CTDA–2024, Materials of IV International Scientific-practical conference.* – Minks, Belorussian state university, 2024. – P. 203–207
9. *He Zhipeng.* Swarm Ant Colony Models to Control Flows in Intellectual Systems // *Open Semantic Technologies for Intelligent Systems. Research Papers Collection. Issue 9.* – Minsk, Belarus, 2025. – P. 391–396.