

Карпов В.Э.

# **Эмоции роботов**

# Постановка задачи (о чем это)

- Рассматривается реализация механизма эмоций мобильного робота на базе гибридной нейро-продукционной системы
- Описывается влияние эмоций на поведение робота.
- В модели реализованы обобщенные отрицательные и положительные эмоции, причем основной акцент сделан на влияние отрицательных эмоций.

# Эмоции в ИИ

- Роль эмоций в процессе рассуждений, наличие эмоциональных правил - [Поспелов, 1989]
- Описание модели личности, поведение которой основывается во многом на эмоциональных оценках - [Гаазе-Рапопорт и др., 1987].
- Формальный механизм описания эмоций и их классификация. Алгебра эмоций - [Фоминых, 2006, 2007] .

- 
- **Вывод:** с теориями эмоций (доведенных до формализма) в ИИ дело обстоит весьма успешно.

# Эмоции в робототехнике

- Основная задача исследований в этом направлении - создание эффективного человеко-машинного **интерфейса**, удобной, **комфортной** среды общения. Речь идет о **внешней** имитации эмоций и некоторых психических процессов.



1. **Распознавание** эмоций человека
2. **Внешняя** имитация эмоций и некоторых психических процессов.

# Примеры «внешнего очеловечения»

**Проект CB2** (Япония, Osaka University).

Вес - 33 кг., высота - 1,3 м. 51 пневматическим привод, микрофоны, видеокамеры, 200 тактильных датчиков.

---




**Проект Nexi** (Массачусетский технологический институт, США)

---

**Задачи:**

- Комфортный интерфейс
- Задачи обучения



# Эмоции в робототехнике и ИИ

**ИИ** интересуют эмоции прежде всего как внутренние процессы, а **робототехника** занимается в основном внешними проявлениями эмоций (внешнем отражении эмоциональных состояний). *И в том, и в другом случае до реального эмоционального поведения обычно дело не доходит.*

Здесь мы будем говорить не о внешней, имитационной стороне эмоций, а об их внутреннем «техническом» содержании, но не в «ИИ-смысле», а интересуясь прежде всего поведенческой составляющей Э.

# Эмоции

- Эмоции (emovere – возбуждать, волновать) – состояния, связанные с субъективной оценкой значимости для индивида действующих на него факторов, оценочное отношение к существующим или возможным ситуациям или поведению. У человека эмоции порождают переживания *удовольствия, неудовольствия, страха, робости* и т.п., играющие роль ориентирующих субъективных сигналов. В отличие от **чувств**, Э не имеют объектной привязки: они возникают по отношению к ситуации в целом.
- Э относятся к психическим процессам человека и высших позвоночных. Имеет ли смысл говорить об Э применительно к такому примитивному объекту, как робот?
- Видимо, да, т.к. дальше речь будет идти об имитации роботом **сложных поведенческих актов** и сложных входных сигналов. Сложными являются и те, и другие, поскольку это модель, и задаются в уже готовом виде, а не реализуются детально естественным путем.

*Когда мы говорим о том, что субъект «видит» препятствие, то подразумевается наличие очень сложного процесса обработки визуальной информации. Здесь же, у робота, мы имеем простой сигнал, выдаваемый дальномером, причем этот сигнал поступает сразу в систему управления высокого уровня.*

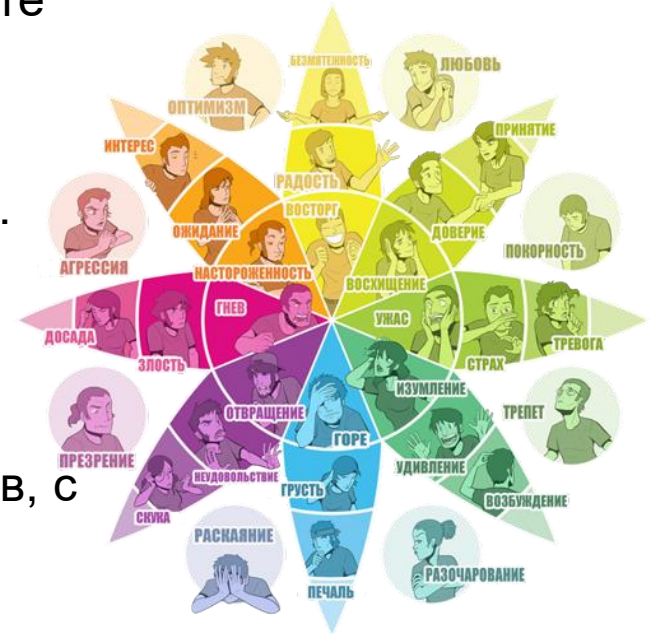
То же самое касается и сложных действий – вместо сложного многоуровневого управления защитной реакцией организма, робот просто реализует заложенную программу избегания препятствий.

В определенном смысле рассматриваемые ниже модели оперируют именно **высокоуровневыми** реакциями и стимулами, что позволяет на этом уровне включать в рассмотрение некоторые психические процессы и явления.

# Теории эмоций

Практически все теории Э сводятся к тому, что эмоциональное чувство возникает в результате сопоставления субъектом желаемых и достигнутых результатов действия.

- **Биологическая теория эмоций, П.К. Анохин.** Объясняет возникновение положительных (отрицательных) эмоций тем, что нервный субстрат эмоций активизируется в тот момент, когда обнаруживается совпадение (рассогласование) акцептора действия, как афферентной модели *ожидаемых* результатов, с одной стороны, и сигнализации о *реально достигнутом эффекте*, с другой.
- **Теория активации эмоций (М.В. Arnold, G. Lindsey, 1951)** Здесь более подчеркнута роль **внутренних структур мозга**. Сенсорные раздражители поступают от периферии к кортексу, *оцениваются*; там присоединяются чувственные оценки и заложенные в таламусе образцы поведения. После этого происходит переход к органу реализации. Оттуда идет обратное сообщение, которое снова проходит *оценивание* и очувствование.





# Потребностно–информационная теория

**Потребностно–информационная теория** эмоций П.В. Симонова (1964). «*Э. есть отражение мозгом человека и животных какой-либо актуальной потребности (ее качества и величины) и вероятности (возможности) ее удовлетворения*». Последнюю мозг оценивает на основе генетического и ранее приобретенного индивидуального опыта.

$$\mathbf{\text{Э}} = f(\mathbf{\text{П}}, \mathbf{p}(\mathbf{\text{Ин}}, \mathbf{\text{Ис}})) \quad (1)$$

- Здесь **Э** - эмоция, ее степень, качество и знак;
- **П** - сила и качество актуальной потребности;
- $\mathbf{p}(\mathbf{\text{Ин}}, \mathbf{\text{Ис}})$  - оценка возможности удовлетворения потребности;
- **Ин** - информация о средствах, прогностически необходимых для удовлетворения потребности;
- **Ис** - информация о существующих средствах, ресурсах и времени, которыми реально располагает субъект в данный момент времени.

Это – сугубо качественная, принципиальная формула.



---

Рассмотрим далее Э с двух сторон:

- Э, как индикатор состояния работа.
- Э, как усилитель мотивации и как фактор, оказывающий влияние на поведение работа.

# Задача

Мобильный робот и среда его обитания – полигон. Препятствия, зеленые («корм») и темные («опасность») пятна.



**Сенсорика**: дальномер, датчик цвета.

«Чувство голода». «Голод» утоляется, когда робот находится на зеленом пятне.

**Неблагоприятные факторы**: темные участки, приближение робота к препятствиям.

Чем ближе к препятствию, тем сильнее чувство опасности (дискомфорт).

**Задача**: робот должен вести себя как можно более *целесообразно*, минимизируя свой дискомфорт:

*Если робот «сыт», то он избегает препятствий, если голоден, то он идет искать пищу, невзирая на стремление находиться на открытом месте.*

**Действия**: высокоуровневые, т.е. сложные поведенческие акты: «убегать от препятствия», «идти к препятствию», «избегать темных участков», «питаться» (ЦМП).

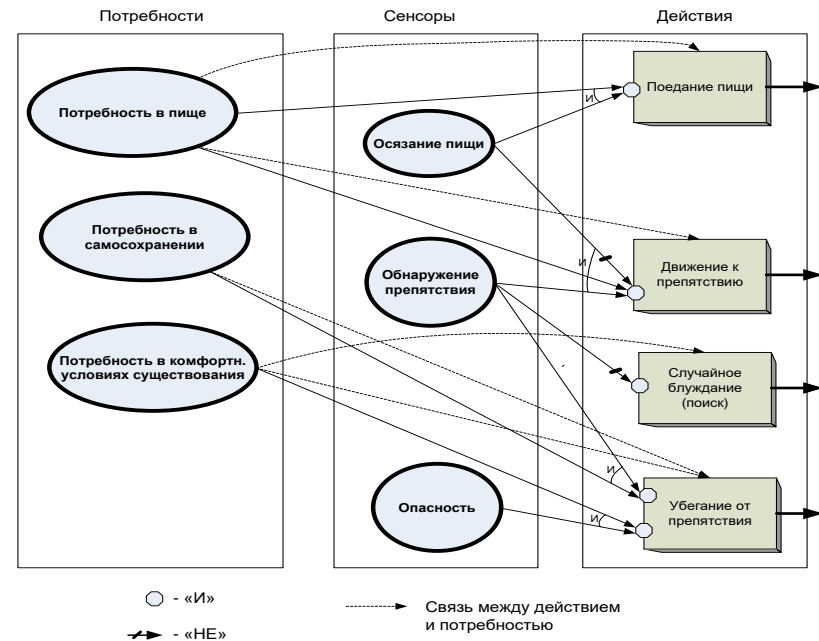
Рассмотрим далее некоторые модели, задающие такое целесообразное поведение робота

# Модель 1. Продукционная система

Правила поведения робота.

- Значения всех входных сигналов нормируются к значению на отрезке [0..1].
- Модель поведения в терминах коэффициентов определенности (КО) - MYCIN-подобная продукционная модель.
- Результирующий КО заключения:  $\omega = \omega_c \omega_R$ .  $\omega_R$  - априорный вес (значимость, приоритетность), приписанный правилу(КО правила)
- Механизм вычислений КО не использует биполярные шкалы.
- Отрицание:  $\neg\omega = 1 - \omega$ , И и ИЛИ: min, max, подтверждающие правила:

$$\omega_{12} = \omega_1 + \omega_2 - \omega_1 \cdot \omega_2$$



**Пример:**

Если «Потребность в самосохранении» и «Обнаружено препятствие», то «Убегать»

и

Если «Потребность в комфортных условиях» и «Обнаружена опасность», то «Убегать»

# Введение эмоциональной составляющей

С каждым действием связывается некоторая **потребность** (пунктирные линии на схеме).

Представим оценочную формулу (1) в следующем виде:

$$\mathcal{E} = \Pi \cdot (\mathbf{I}_c - \mathbf{I}_n)$$

Здесь  $\mathcal{E}$  - эмоция;  $\Pi$  - потребность,  $\mathbf{I}_n$  - информация о средствах, необходимых для удовлетворения потребности,  $\mathbf{I}_c$  - информация о ресурсах, которыми реально располагает робот.

Каждая вершина-действие характеризуется некоторой величиной активности  $a_i$ , т.е. в каждый момент времени существует вектор активности вершин действий

$$\mathbf{A} = (\mathbf{a}_1, \dots, \mathbf{a}_n)$$

где  $n$  - количество действий робота.

$a_i$  играет роль  $\mathbf{I}_c$  - оценки наличия существующих средств;  $\mathbf{I}_n$ , (наличие необходимых средств для удовлетворения потребности) может быть определена как оценка посылки правила.

Правило для выполнения действия «Поедание пищи»:

Если «Потребность в пище» ( $\Pi_n$ ) и «Осязание пищи» ( $S_n$ ), то «Поедание пищи» ( $a_n$ )

Или:

$$\Pi_n \text{ и } S_n \rightarrow a_n$$

$\Pi_n$  и  $S_n$  - оценки «Потребность в пище» и «Осязание пищи» (КО посылки). Величина выходной активности правила  $a_n = \min(\Pi_n, S_n)$

$a_n$  - прогностически необходимая активность действия, т.е. величина  $\mathbf{I}_n$ .

**Фактическая** активность правила  $\mathbf{a}^\Phi_n$  может не совпадать с  $a_n$ , т.к. робот может выполнять лишь одно из нескольких действий в данный момент времени (либо убежать, либо питаться). В простейшем случае после формирования вектора  $\mathbf{A}$  в нем выбирается элемент  $a_k = \max(\mathbf{A})$ , т.е. робот выберет действие  $k$ . В этом случае формируется вектор фактических действий

$$a_i^\Phi = \begin{cases} 1, & \text{если } i = k \\ 0 & \text{иначе} \end{cases} \quad \mathbf{A}^\Phi = (\mathbf{a}^\Phi_1, \dots, \mathbf{a}^\Phi_n)$$

Здесь

Тогда для каждого действия  $i$  определяется его **эмоциональная оценка**  $\mathcal{E}_i = \Pi_i (\mathbf{a}_i - \mathbf{a}^\Phi_i)$

**Общее эмоциональное состояние робота**  $\mathcal{E}$  определяется как

$$\mathcal{E} = \sum_{i=1}^n \mathcal{E}_i$$

# Вывод 1

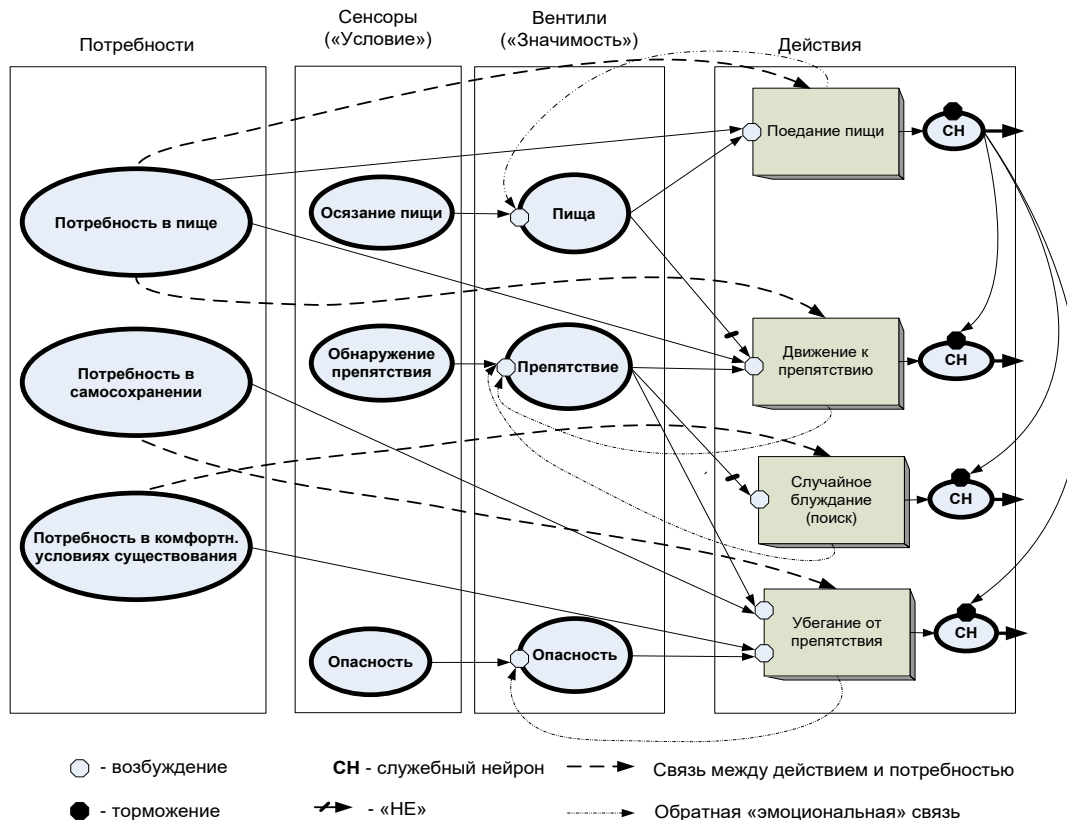
- Здесь Э действительно относятся ко всей текущей ситуации в целом.
  - Величины  $\mathcal{E}_i$  носят характер «локальных», «частных» эмоций. Т.о., к действиям привязаны как потребности, так и эмоциональные оценки.
- 

- Итак, получен механизм эмоциональной оценки состояния работа. Здесь Э привязываются к *действию*, а не к *потребностям*. Полученная схема позволяет лишь оценивать эмоциональное состояние системы.

- -----  
Следующий вопрос: как эмоции могут влиять на *поведение* работа.

# Модель 2. Нейро-продукционная система

- Обоснование для введения нейроподобных элементов: рассматривается поведение робота в *реальном физическом мире*. Как входные сигналы, так и действия робота развернуты во *времени*, причем существенными являются естественная инерционность протекающих процессов. В этом смысле нейрон является прежде всего удобной элементной базой для описания этих процессов.



Базовые элементы - генератор и «упрощенный нейрон».

Генератор - создает импульсации, частота которых пропорциональна величине сигнала от сенсора или соответствующей потребности.

Входы вентиля - сигналы от генераторов сенсоров, а также сигналы эмоций, вырабатываемых правилами-действиями.


**Именно в этом и заключается реализация механизма эмоций, как управляющих воздействий (обратная эмоциональная связь).** Величина этой обратной эмоциональной связи определяется коэффициентом (КЭ).

Задача нейронов выходной группы (служебных нейронов) - стабилизировать выходной вектор (в каждый момент времени робот совершает лишь одно действие). Сигнал с выхода каждого служебного нейрона поступает на вход торможения остальных нейронов группы, подавляя их активность.

# Нейрон

## Большой пирамидный нейрон (Вальцев В.Б.)

- Частота импульсации  $\omega = \Omega \Delta \varphi + \Omega_0$
- Потенциал нейрона  $\varphi_n(t) = \varphi_{n0} - (\varphi_n(t_0) - \varphi_{n0}) \frac{1}{\alpha_{\varphi_n}} e^{-(t-t_0)}$
- Импульс, приходящий на **вход возбуждения**  $I_E = I_{E \max} \cdot \left(1 - \frac{\varphi_n}{(\psi_0 - \varphi_0) \cdot q}\right)$



# Эксперименты. Преамбула 1

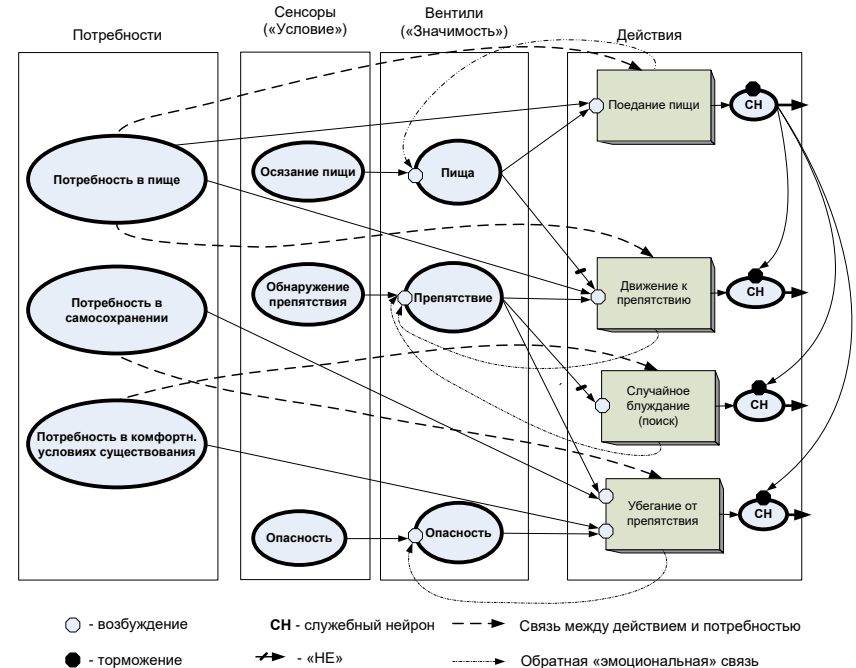
Некоторые аспекты эмоций с точки зрения психологии:

- *отражательно-оценочная роль эмоций* (средство определения значимости тех или иных условий для удовлетворения своих потребностей);
- *мотивационная роль эмоций* (оценка значимости внешнего раздражителя);
- *эмоции как сигнал о появившейся потребности* (отражательно-оценочная роль эмоций в их связи с потребностями, как внутренних стимулов);
- *эмоции как способ маркировки значимых целей* (субъект действует не с самими потребностями, а с теми предметами, которые им отвечают - целями);
- *эмоции как механизм, помогающий принятию решения* (замещение информации, недостающей для принятия решения, оценка будущих событий) и проч.



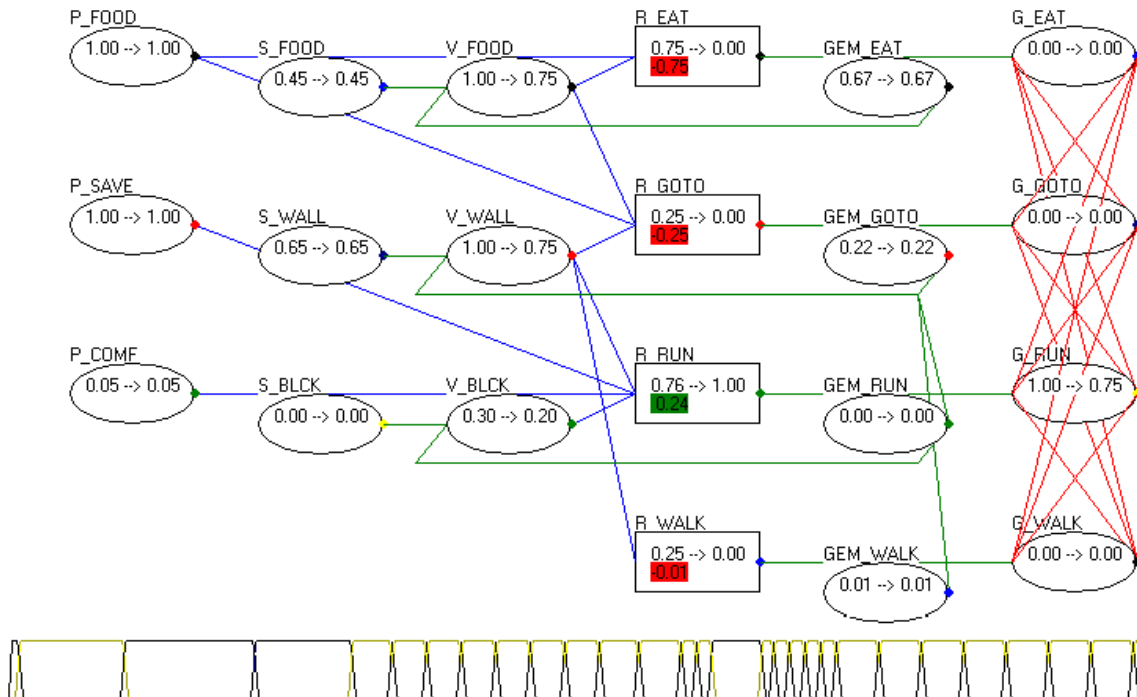
# Эксперименты. Преамбула 2: Особенности СУ

- полученная система нелинейна;
- выходные сигналы правил-действий, поступающие на вход вентильных нейронов, образуют контуры положительной обратной связи (ПОС);
- структура входящих в состав системы элементов такова, что мы имеем дело с временными задержками
- в системе неизбежно образуются сложно формализуемые процессы, в частности – колебательные.



# Режим автогенераций

- Введение эмоций в контур ПОС приводит к тому, что в системе начинаются колебательные процессы. Период колебаний зависит, в частности, от коэффициента эмоциональности (КЭ): при уменьшении этого коэффициента частота колебаний увеличивается.

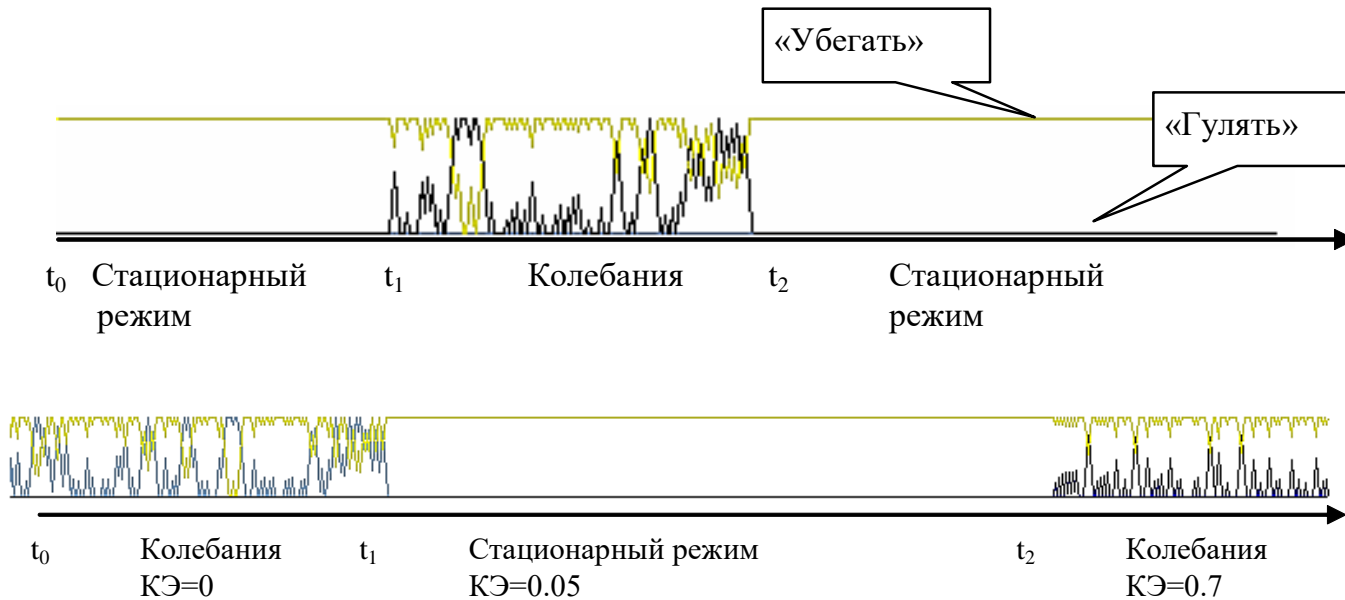


Робот пытается то есть, то убежать от опасности. Здесь потребности в еде ( $P_{\text{FOOD}}$ ) и в самосохранении ( $P_{\text{SAVE}}$ ) максимальны и равны 1. При этом робот видит как еду (сенсор «Пища»  $S_{\text{FOOD}}=0.45$ ), так и стену (сенсор «Стена»  $S_{\text{WALL}} = 0.65$ ).

# Шум

- Шум в 10-20% - нормальное явление.
- При определенных соотношениях между уровнем шума и коэффициентом эмоциональной связи могут возникать любопытные явления.

Пример: Робот видит стену (сенсор «Стена»: 0.05) и темное пятно (сенсор «Пятно»: 0.3). Робот должен или убежать от стены (пятна), или гулять (значения раздражителей малы).



- $t_0-t_1$ :  $КЭ = 0$ , шумов нет ( $Ш=0$ ) и робот находится в стационарном режиме - совершается действие «Убегать».
- $t_1-t_2$ :  $Ш=0.2$ . Эмоций нет ( $КЭ=0$ ). Здесь возникают колебания. Робот пытается то гулять, то убежать.
- $>t_2$ : Вводим эмоциональную связь ( $КЭ = 0.5$ ). Робот вновь переходит в стационарный режим - совершает действие «Убегать».

## Зависимость колебательного процесса от силы эмоций (КЭ).

Шум постоянен, а меняются эмоции:

- $t_0-t_1$ :  $КЭ = 0$  (колебания)
- $t_1-t_2$ :  $КЭ = 0.05$  (стационарный режим)
- $>t_2$ :  $КЭ = 0.7$ , вновь возникают колебания

# Режим насыщения и «встряхивание» сети

- Наличие ПОС приводит к тому, что элементы начинают работать в режиме **насыщения** и в некоторых ситуациях система перестает реагировать на изменения внешних сигналов.
- Становится критичным то, каким было состояние системы в предыдущие моменты времени.
- Одним из подобного рода ситуаций является своего рода «встряхивание» системы. Здесь «встряхивание» осуществляется шумом. Подобное «встряхивание» в ИНС - это весьма распространенный механизм, который выводит систему из локального экстремума («паралич» сети).


# Фантомные сигналы

*Компенсаторная функция эмоций.*

Ситуация, в которой роботу вновь приходится выбирать действие - либо принимать пищу, либо убегать (робот видит стену и видит пищу). Все потребности максимальны и равны 1.

Время	Сенсоры	КЭ	Действие
$t_0-t_1$	«Пища»=1, «Стена» = 0	0	Блуждание
$t_1-t_2$	«Пища»=1, «Стена» = 0.2	0	Прием пищи
$t_2-t_3$	«Пища»=1, «Стена» = 0.2	0.2	Колебания: прием пищи-убегание
$t_3-t_4$	«Пища»=1, «Стена» = 0	0.2	Колебания: прием пищи-убегание.
После $t_4$	«Пища»=1, «Стена» = 0	0.2	Блуждание

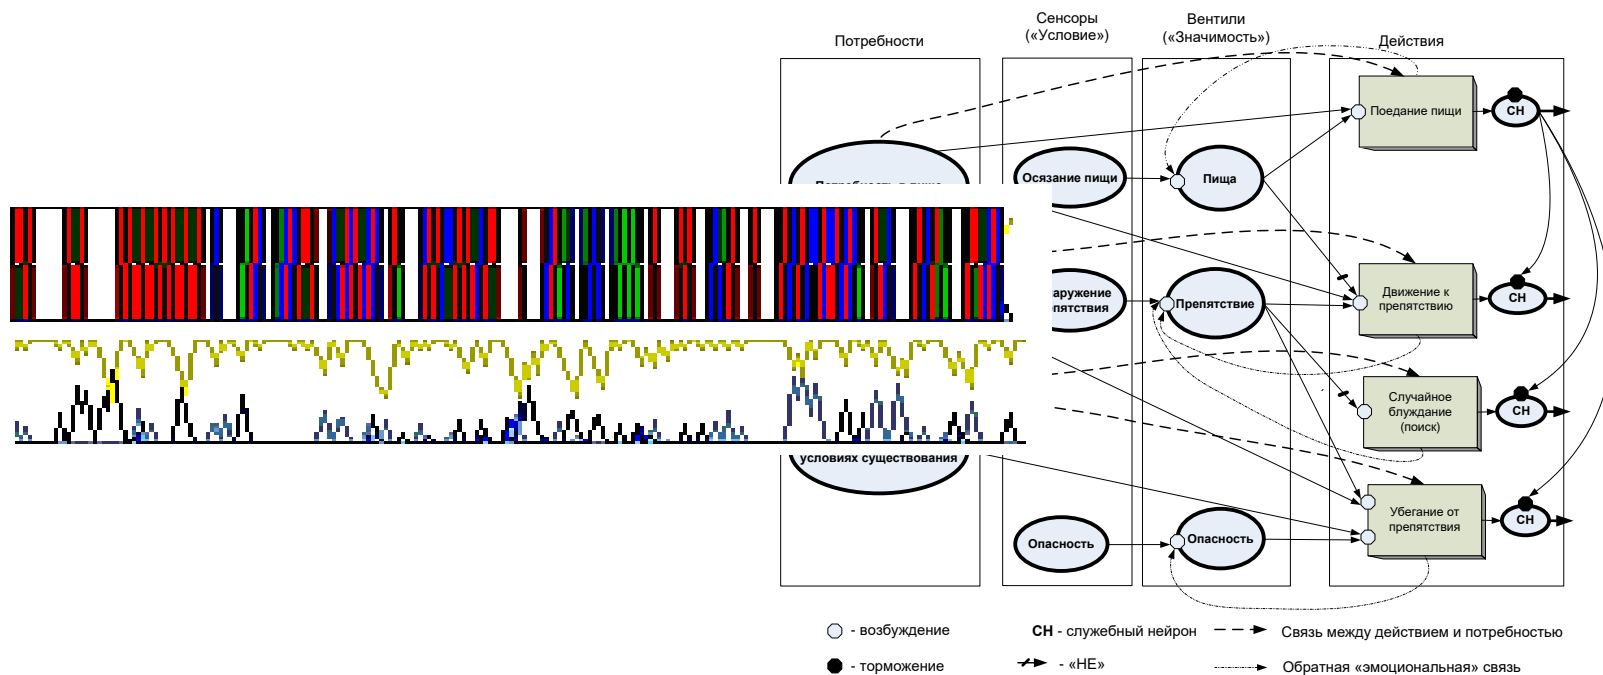
Робот меняет свое поведение в зависимости от сигналов датчиков и значения КЭ.



- $t_3-t_4$ : робот уже не видит стены, однако колебания продолжают (будто стена еще есть). Это - реакция на «фантомный» сигнал. Далее эти колебания прекращаются, и система вновь переходит в стационарный режим.

# Выходные нейроны как фильтр


- Если ограничиться лишь выходными сигналами от решающих правил, то мы получим высокочастотные колебания.
- В этом смысле служебные нейроны выходной группы играют роль своеобразного фильтра низких частот.
- Введение обратных тормозящих связей нейронов этой группы приводит к уменьшению времени релаксации системы.



# Отражательно-оценочная роль эмоций

- Введение эмоциональной связи бывает полезным и в стационарных режимах.
- Эксперимент: потребность в еде максимальна (робот «голоден») и при этом робот обнаружил пищу (правило «Питаться»). Вместе с тем робот не видел препятствий, и поэтому также было актуально правило «Гулять». Превалирующим правилом в данной конфигурации является именно «Гулять» (такова структура сети), поэтому голодный робот вместо приема пищи занимался случайными блужданиями. Введение ненулевого КЭ вызывает большие отрицательные Э («хочется есть, а приходится гулять») => потенциал возбуждения правила «Питаться» оказывается выше потенциала правила «Гулять».

Эмоции и значимость факторов



До момента  $t_1$  эмоций нет и робот «гуляет». В момент времени  $t_1$  ( $K=0.2$ ) робот меняет свое поведение - начинает есть. Здесь допустимо рассматривать проявление Э, как средство определения значимости тех или иных условий для удовлетворения своих потребностей. Отрицательные эмоции явным образом **усиливают значимость вызвавших их факторов.**

# Заключение

- Целью работы вовсе не являлось вскрытие механизма эмоций, его формализация и т.п. Речь шла о том, чтобы продемонстрировать механизм работы эмоций в **реальном техническом устройстве** - роботе.
- **Основной вывод**: механизм эмоций может быть реализован достаточно простыми средствами. При этом действительно эмоциональное состояние робота самым непосредственным образом может влиять на его поведение.
- Кроме того, показано, что для робота:
  - Эмоции - это естественный индикатор состояния системы. Более того, в некотором смысле эмоции могут определять критерии обучения организма (цель обучения - уменьшение отрицательных эмоций).
  - Эмоции контрастируют сенсорное восприятие и стабилизируют поведение.
  - Существенна роль эмоций в условиях неполноты информации.



# Заключительные замечания 1

- **Виды эмоций.** Все многообразие Э было сведено к двум - положительным и отрицательным. При этом рассматривались лишь отрицательные Э. Разумеется, положительные Э оказывают влияние на поведение, однако для их рассмотрения необходима более сложная модель.
- **Темперамент.** Рассмотренные эмоциональные проявления целиком и полностью были функцией СУ, структура и параметры которой являлись фиксированными. Но стоит заинтересоваться зависимостью поведения робота от параметров системы, как мы приходим к вопросу темперамента робота. Действительно, согласно учению И.П.Павлова именно соотношение основных свойств нервной системы - силы, уравновешенности и подвижности процессов возбуждения и торможения, - определяет ее тип. В этом смысле вполне можно говорить о темпераменте робота (*робот-флегматик, холерик, сангвиник и меланхолик*).
- **Обучение, поощрение и наказание.** Одним из основных вопросов в процедуре обучения является организация поощрения-наказания. Многообещающим является введение понятия рефлексии в обучении, т.е. возможности оценивать некую предысторию действий, приведших к текущему результату - поощрению или наказанию. Для этого необходимо иметь интегральную оценку состояния системы. Такой оценкой является **дискомфорт** - некая обобщенная числовая характеристика, увеличивающаяся при неблагоприятном воздействии на систему и уменьшающаяся при благоприятном. В этом случае целью поведения системы будет реализация такого поведения, которое будет минимизировать дискомфорт.
- Т.о., степень целесообразности поведения робота сводится к уменьшению дискомфорта, что с точки зрения психологических особенностей поведения можно свести к уже достаточно понятному механизму минимизации отрицательных Э.

## Заключительные замечания 2

- **Сложность демонстрации.**  
Длительные наблюдения.  
Проще наблюдать внутренний мир, а не внешнее поведение.
- Индикация эмоционального состояния
- **Нерешенные вопросы:**
  - Положительные эмоции.
  - Дифференциация эмоций.
  - Память. Являются ли фантомные сигналы прообразом механизма памяти?

