



ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ
БЮДЖЕТНОЕ УЧРЕЖДЕНИЕ НАУКИ
**ИНСТИТУТ
ПРОБЛЕМ
УПРАВЛЕНИЯ**
ИМ. В.А. ТРАПЕЗНИКОВА
РОССИЙСКОЙ АКАДЕМИИ НАУК

Нейросетевые и нечеткие методы оценивания и распознавания стохастических процессов

Амосов Олег Семенович, д.т.н., г.н.с.

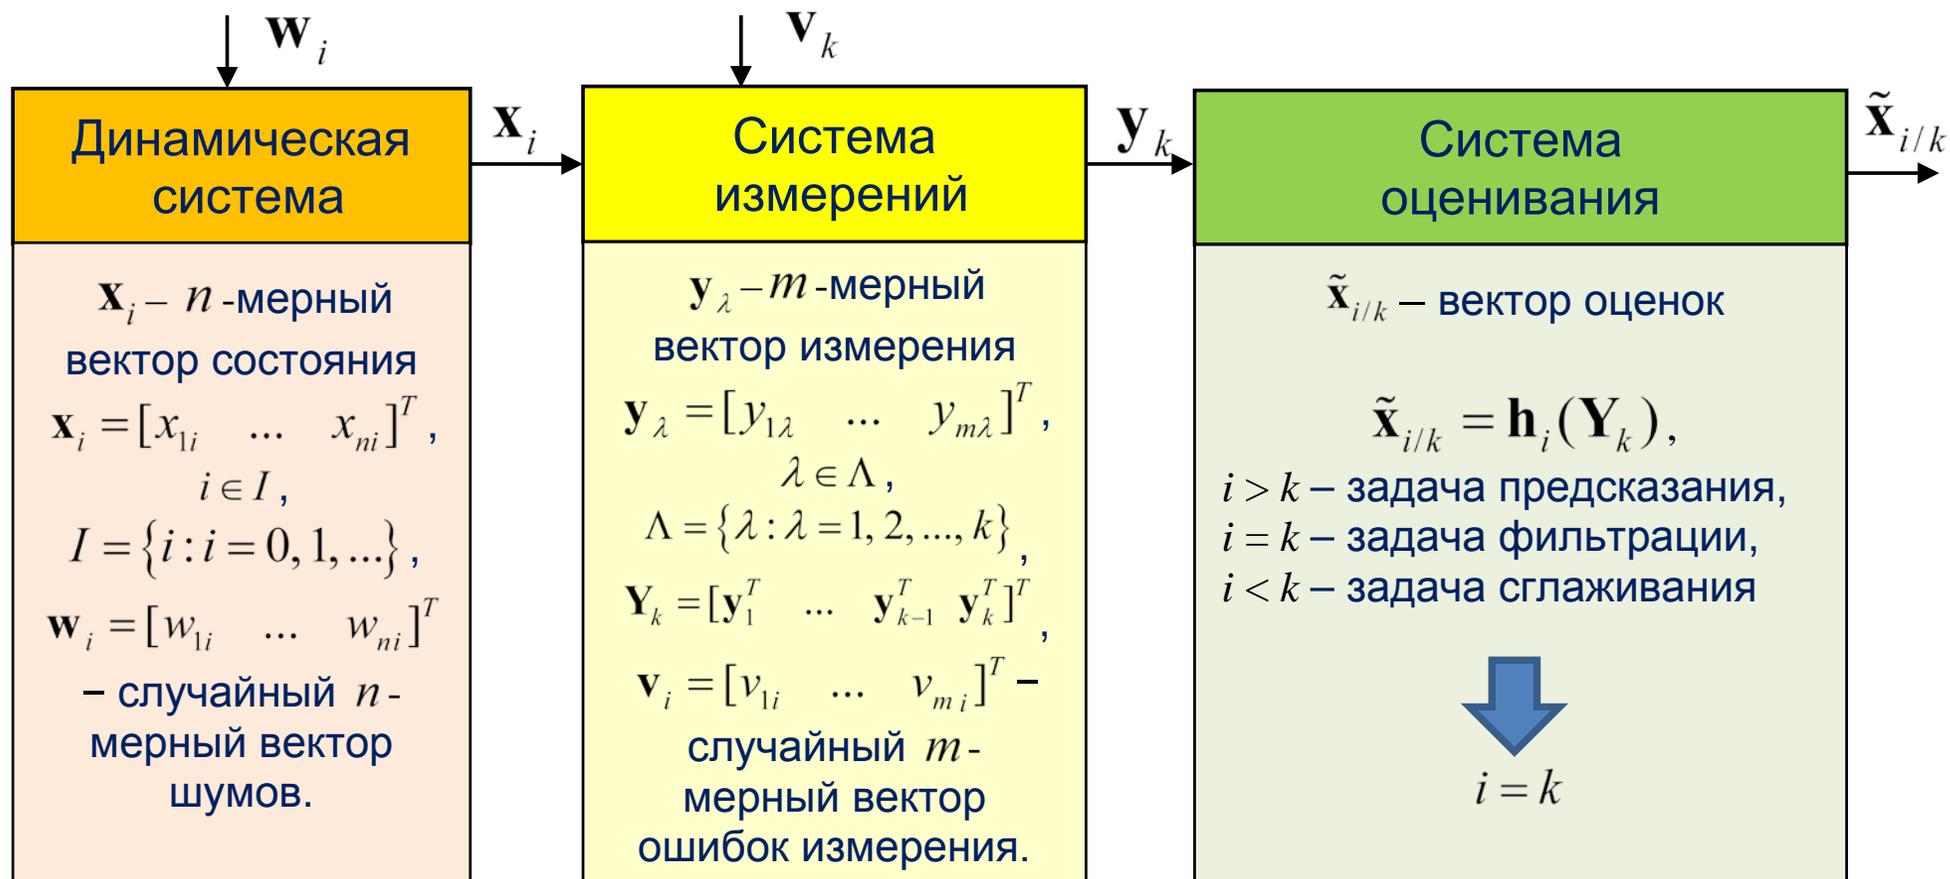
Лаборатория № 40

**«Интеллектуальные системы управления и
моделирования»**

Содержание

Задача оценивания	Задача распознавания образов
Постановка задачи. Оптимальное решение	Постановка задачи
Субоптимальные алгоритмы	Вычислительный метод распознавания образов
Нейросетевой подход	Особенности применения глубоких НС
Утверждения	Адаптация глубоких НС под решаемые задачи
Пример нелинейной задачи	Постановка задачи контроля и управления доступом объектов
Оценка процессов с памятью	Структурная схема СКУД объектов слежения
Оценивание и системы нечеткой логики. Синтетические системы	Нечеткий регулятор. База знаний
Вычислительный метод. Байесовский подход. Нерекуррентное оценивание. Рекуррентное оценивание. Оценивание при отсутствии обучающего множества	Примеры
Декомпозиция синтетических систем	
Заключение и перспективы	

Задача оценивания



Задача оценки – определение функции \mathbf{h}_i некоторым рациональным обоснованным способом.

Для упрощения математических записей введем обозначения: $\mathbf{x} \equiv \mathbf{x}_i, \mathbf{y} \equiv \mathbf{Y}_i = [\mathbf{y}_1^T, \dots, \mathbf{y}_{i-1}^T, \mathbf{y}_i^T]^T$.

Постановка задачи оценивания в рамках байесовского подхода

Необходимо найти оценку неизвестного

случайного вектора $\mathbf{x} \in R^n$

с использованием вектора измерений

$\mathbf{y} \in R^m$

$$\mathbf{y} = \mathbf{s}(\mathbf{x}) + \mathbf{v}, \quad (1)$$

где $\mathbf{s}(\mathbf{x})$ - известная нелинейная функция,

$\mathbf{v} \in R^m$ - случайный вектор ошибок измерения.

Предполагается, что ф.п.р.в.

$f(\mathbf{x}, \mathbf{y})$ - известна

и используется критерий

$$J = M \left\| (\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y})) \right\|^2 \Rightarrow \min. \quad (2)$$

Оптимальное решение

Оптимальная оценка $\tilde{\mathbf{x}}^{opt}(\mathbf{y})$, условная $\mathbf{P}_{cond}(\mathbf{y})$

и безусловная \mathbf{G} матрицы ковариаций определяются как

$$\tilde{\mathbf{x}}^{opt}(\mathbf{y}) = \int \mathbf{x} f(\mathbf{x} / \mathbf{y}) d\mathbf{x} , \quad (3)$$

$$\mathbf{P}_{cond}(\mathbf{y}) = \int (\mathbf{x} - \tilde{\mathbf{x}}^{opt}(\mathbf{y}))(\mathbf{x} - \tilde{\mathbf{x}}^{opt}(\mathbf{y}))^T f(\mathbf{x} / \mathbf{y}) d\mathbf{x} , \quad (4)$$

$$\mathbf{G} = \int \int (\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y}))(\mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y}))^T f(\mathbf{x}, \mathbf{y}) d\mathbf{x} d\mathbf{y} , \quad (5)$$

где $f(\mathbf{x} / \mathbf{y}) = f(\mathbf{x}, \mathbf{y}) / f(\mathbf{y})$ - апостериорная ф.п.р.в.

$$\tilde{\mathbf{x}}^{lin}(\mathbf{y}) = \bar{\mathbf{x}} + \mathbf{K}[\mathbf{y} - \bar{\mathbf{y}}], \quad (6)$$

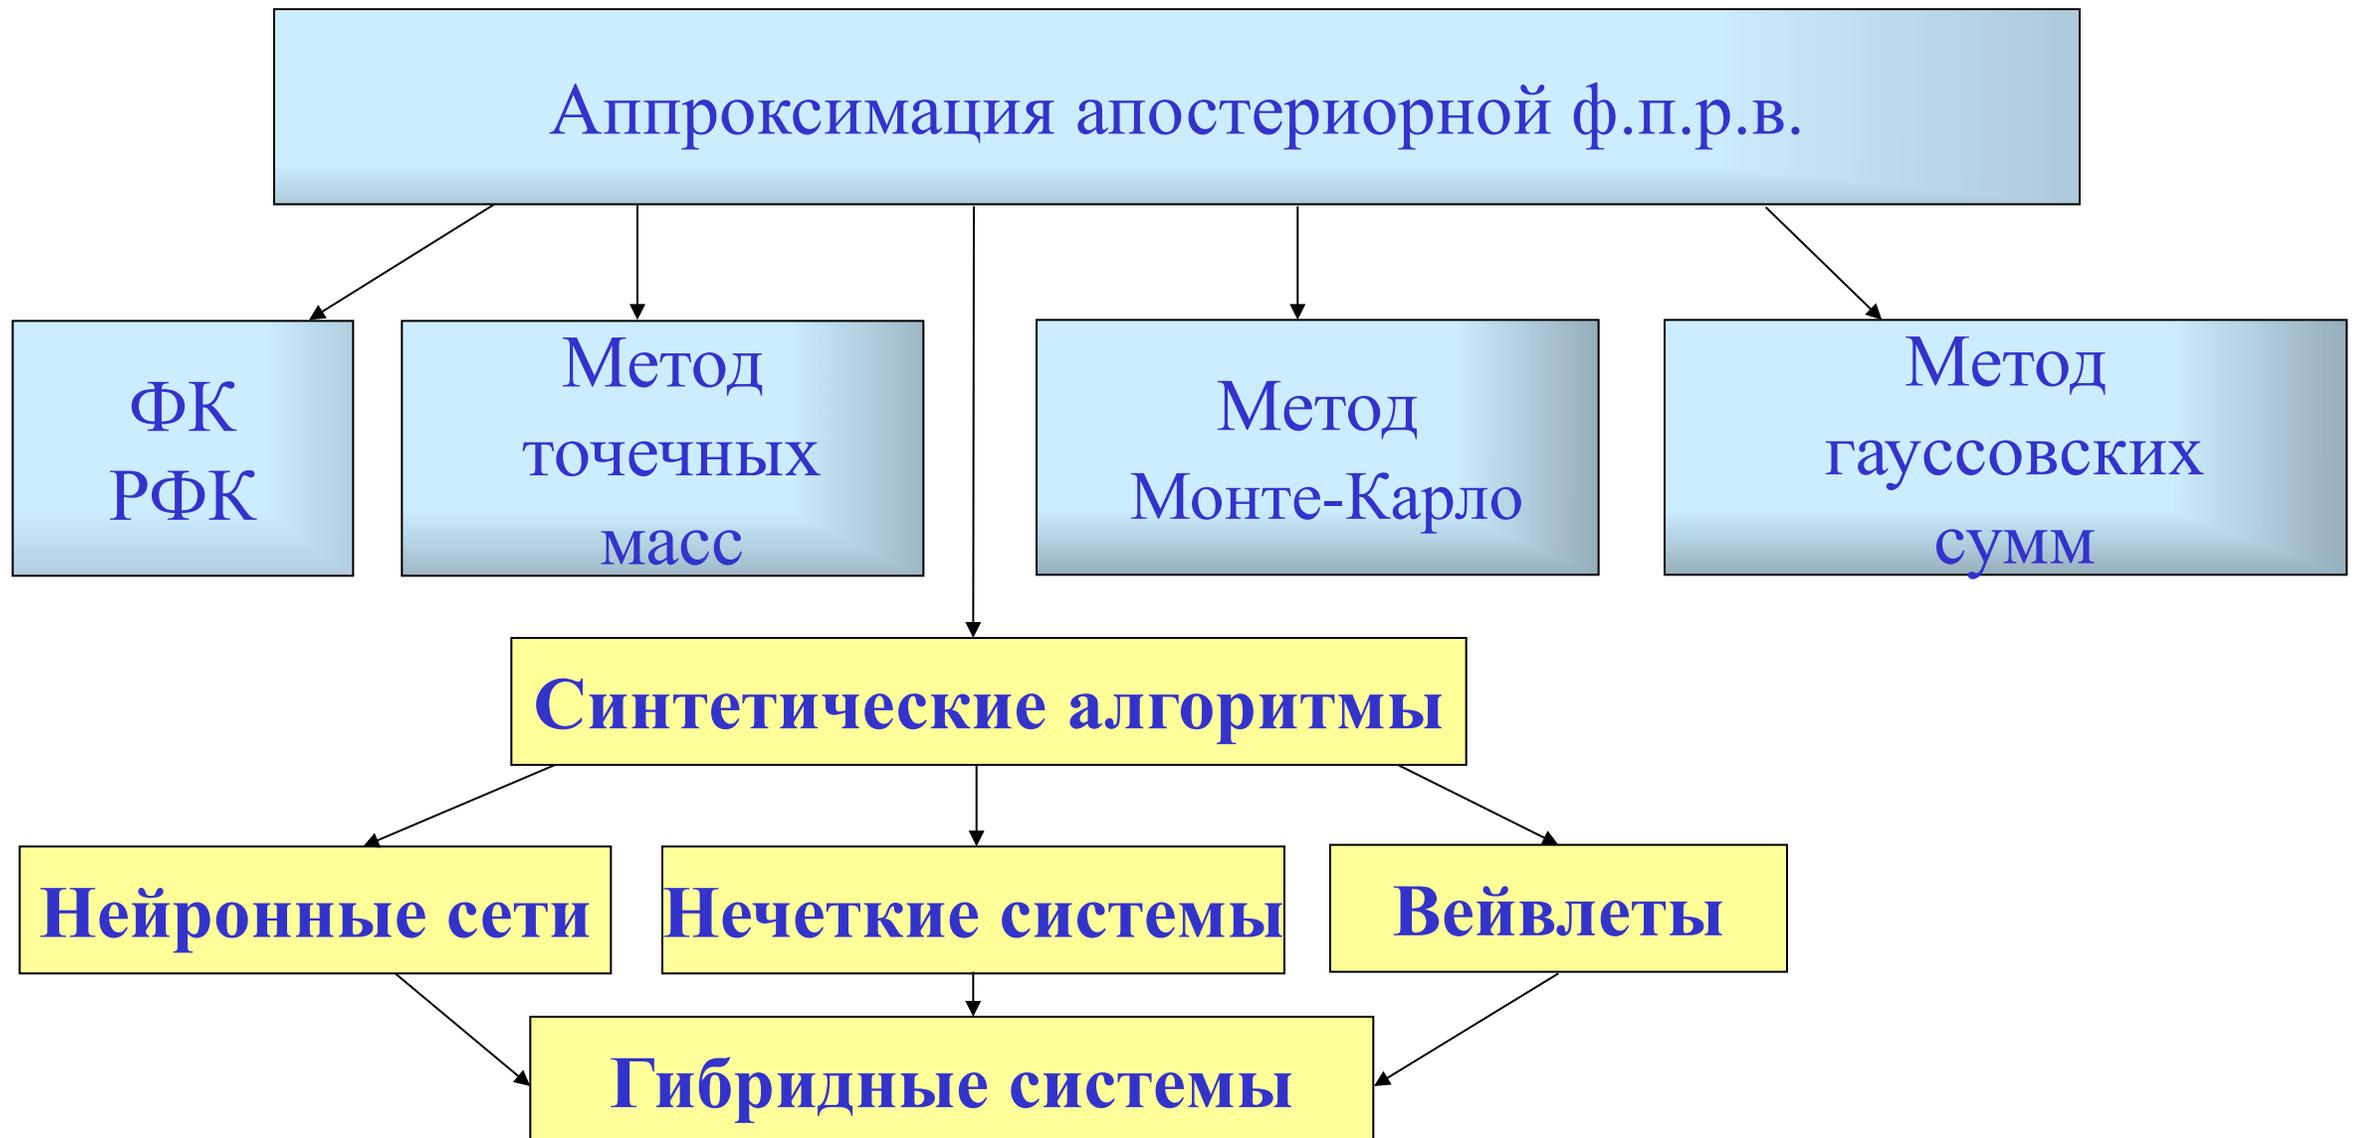
$$\mathbf{K} = \mathbf{P}_{\mathbf{x}\mathbf{y}} \mathbf{P}_{\mathbf{y}\mathbf{y}}^{-1},$$

$$\mathbf{P}^{lin} = \mathbf{G}^{lin} = \mathbf{P}_{\mathbf{x}\mathbf{x}} - \mathbf{P}_{\mathbf{x}\mathbf{y}} \mathbf{P}_{\mathbf{y}\mathbf{y}}^{-1} \mathbf{P}_{\mathbf{y}\mathbf{x}}. \quad (7)$$

$$\bar{\mathbf{y}} = \int \mathbf{s}(\mathbf{x}) f(\mathbf{x}) d\mathbf{x}, \quad (8)$$

$$\mathbf{P}_{\mathbf{y}\mathbf{y}} = \int \mathbf{s}(\mathbf{x}) \mathbf{s}(\mathbf{x})^T f(\mathbf{x}) d\mathbf{x} - \overline{\mathbf{y}\mathbf{y}}^T + \mathbf{P}_{\mathbf{v}}, \quad (9)$$

$$\mathbf{P}_{\mathbf{x}\mathbf{y}} = \int \mathbf{x} \mathbf{s}(\mathbf{x})^T f(\mathbf{x}) d\mathbf{x}. \quad (10)$$



Почему выбраны нейронные сети, нечеткие и гибридные системы?

1. Традиционные байесовские методы требуют исчерпывающей априорной информации. Возникают значительные трудности при синтезе нелинейных алгоритмов.
2. Альтернативные гибридные системы сочетают в себе гибкость и обучаемость нейронных сетей, возможности компактного описания сигналов в частотной и временной областях, присущее вейвлетам, и возможность построения прозрачных правил вывода решений на основе аппарата нечеткой логики.
3. Рассматриваемые системы способны к обучению и дообучению в режиме реального времени.

Синтез нейросетевых алгоритмов

В качестве параметризованной функции $\tilde{\mathbf{x}}(\mathbf{y}, \tilde{\mathbf{W}})$ используется следующая НС

$$\tilde{\mathbf{x}}^{NN}(\mathbf{y}) = \mathbf{K}^{NN}(\mathbf{y}, \mathbf{W}). \quad (11)$$

Для ее обучения используется критерий

$$\mathbf{W}^* : J(\mathbf{W}^*) = \min_{\tilde{\mathbf{W}}} \frac{1}{n_{tr}} \sum_{j=1}^{n_{tr}} \left\| \mathbf{x}^{(j)} - \mathbf{K}^{NN}(\mathbf{y}^{(j)}, \mathbf{W}) \right\|^2, \quad (12)$$

где $\mathbf{y}^{(j)}, \mathbf{x}^{(j)}, j = \overline{1..n_{tr}}$ - независимые реализации с ф.п.р.в. $f(\mathbf{x}, \mathbf{y})$.

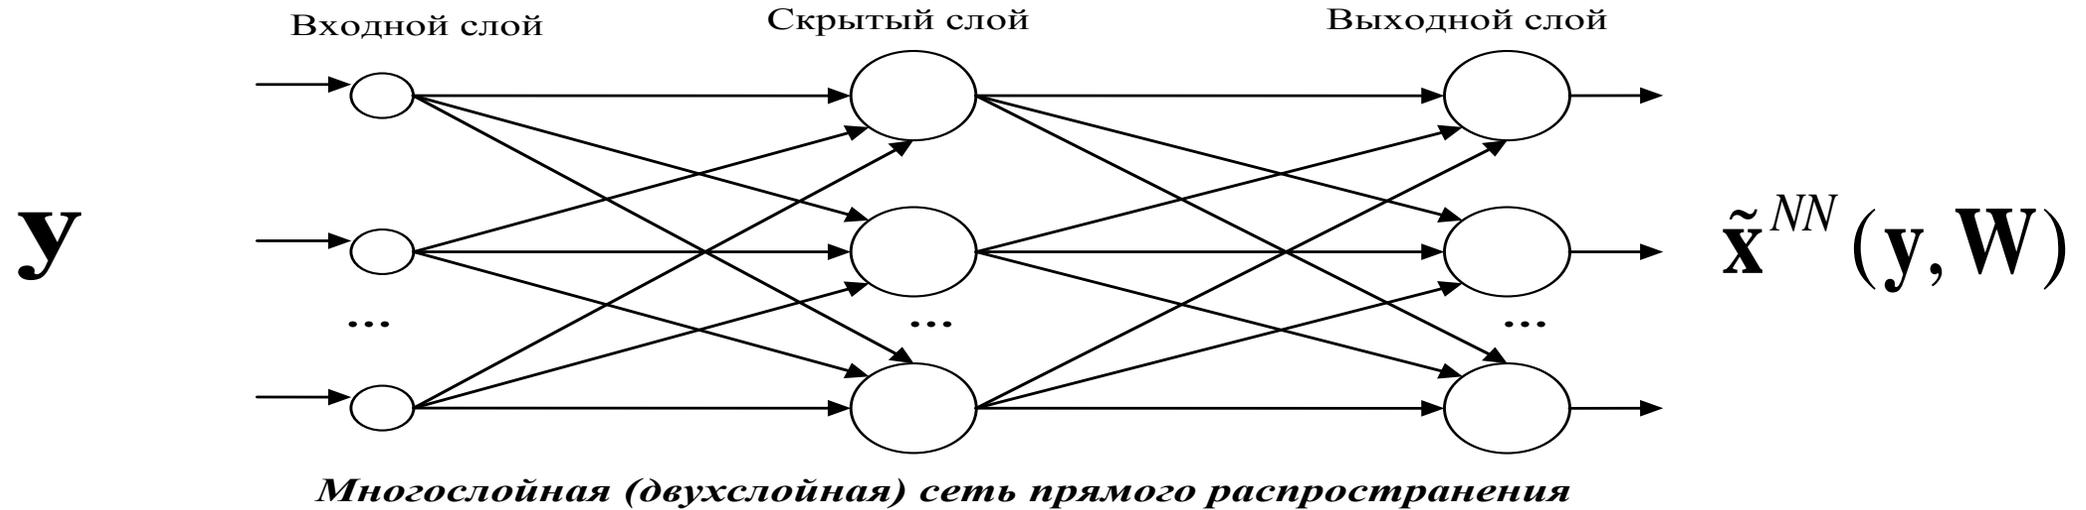
Решение: нелинейная нейросетевая оценка

$$\tilde{\mathbf{x}}^{NN} = \mathbf{K}^{NN}(\mathbf{y}, \mathbf{W}^*). \quad (13)$$

Задачи: синтез структуры НС;
выбор алгоритма обучения.

НС – для оптимальных оценок

В качестве параметризованной функции $\tilde{\mathbf{x}}(\mathbf{y}, \tilde{\mathbf{W}})$ используется следующая НС $\tilde{\mathbf{x}}^{NN}(\mathbf{y}, \mathbf{W}) = \mathbf{K}^{NN}(\mathbf{y}, \mathbf{W})$. (14)



Структура НС определяется: числом слоев, числом нейронов в слое, типом активационных функций, связями между нейронами и слоями.

$$\tilde{x}_i(\mathbf{y}) = \psi \left(\sum_{\mu=1}^N \left(w_{i\mu}^2 \varphi \left(\sum_{j=1}^m (w_{\mu j}^1 y_j) + w_{\mu 0}^1 \right) \right) + w_{i0}^2 \right), \quad i = \overline{1..n} \quad (15)$$

Линейная нейросетевая оценка

$$\tilde{\mathbf{x}}^{NN} = \mathbf{K}^{NN} (\mathbf{y}, \tilde{\mathbf{W}}) = \mathbf{w}_0 + \mathbf{W}\mathbf{y}. \quad (16)$$

Можно показать, что линейная нейросетевая оценка определяется как

$$\tilde{\mathbf{x}}^{NN} (\mathbf{y}, \tilde{\mathbf{W}}) = \bar{\mathbf{x}}^* + \mathbf{K}[\mathbf{y} - \bar{\mathbf{y}}^*], \quad \mathbf{K} = \mathbf{P}_{\mathbf{x}\mathbf{y}}^* (\mathbf{P}_{\mathbf{y}\mathbf{y}}^*)^{-1}. \quad (17)$$

где $\bar{\mathbf{x}}$, $\bar{\mathbf{y}}^*$, $\mathbf{P}_{\mathbf{y}\mathbf{y}}^*$, $\mathbf{P}_{\mathbf{x}\mathbf{y}}^*$

являются выборочными значениями математических ожиданий и соответствующих матриц ковариаций, например

$$\bar{\mathbf{x}}^* = \frac{1}{n_2} \sum_{j=1}^{n_2} \mathbf{x}^{(j)}. \quad (18)$$

Утверждение 1

Если имеется набор данных (обучающая выборка)

$$\{(\mathbf{y}^{(j)}, \mathbf{x}^{(j)})\}, j = \overline{1..n_o}, \quad (19)$$

в котором пары $\mathbf{y}^{(j)}, \mathbf{x}^{(j)}, j = \overline{1..n_o}$, представляют независимые между собой реализации случайного составного вектора $\mathbf{z} = [\mathbf{x}^T \ \mathbf{y}^T]^T$ с ф.п.р.в. $f(\mathbf{x}, \mathbf{y})$, то линейная НС

$$\hat{\mathbf{x}}^{\text{HC}}(\mathbf{y}, \tilde{\mathbf{W}}) = \mathbf{w}_0 + \mathbf{W}\mathbf{y}, \quad (20)$$

при выборе для ее обучения с учителем в качестве критерия обучения функции

$$\tilde{J}^*(\tilde{\mathbf{W}}) = \frac{1}{n_o} \sum_{j=1}^{n_o} \left\| \mathbf{x}^{(j)} - \hat{\mathbf{x}}^{\text{HC}(j)}(\mathbf{y}^{(j)}, \tilde{\mathbf{W}}) \right\|^2 \quad (21)$$

обеспечивает при увеличении числа используемых для обучения реализаций n_o получение оценок, близких по своим свойствам к оценкам, получаемым с помощью байесовского алгоритма, оптимального в классе линейных алгоритмов:

$$\hat{\mathbf{x}}^{\text{HC}}(\mathbf{y}, \tilde{\mathbf{W}}) = \bar{\mathbf{x}}^* + \mathbf{P}_{\mathbf{xy}}^* \left(\mathbf{P}_{\mathbf{yy}}^* \right)^{-1} [\mathbf{y} - \bar{\mathbf{y}}^*], \quad (22)$$

где $\bar{\mathbf{x}}^* = \mathbf{m}_{\mathbf{x}}^*$; $\bar{\mathbf{y}}^* = \mathbf{m}_{\mathbf{y}}^*$; $\mathbf{P}_{\mathbf{yy}}^*$, $\mathbf{P}_{\mathbf{xy}}^*$ представляют собой выборочные значения математических ожиданий и соответствующих матриц ковариаций.

Это позволяет трактовать оптимальный в линейном классе алгоритм как нейронную сеть, обучаемую в соответствии с приведенным критерием.

Утверждение 2

Если известно, что уравнение измерений имеет вид

$$\mathbf{y} = \mathbf{H}\mathbf{x} + \mathbf{v} \quad (23)$$

при отсутствии априорной информации о матрице измерений \mathbf{H} и шумах измерения \mathbf{v} , и имеется набор данных (обучающая выборка)

$$\{(\mathbf{y}^{(j)}, \mathbf{x}^{(j)})\}, j = \overline{1..n_o}, \quad (24)$$

в котором пары $\mathbf{y}^{(j)}, \mathbf{x}^{(j)}, j = \overline{1..n_o}$, согласованы, в том смысле, что они представляют независимые между собой реализации случайного составного вектора $\mathbf{z} = [\mathbf{x}^T \quad \mathbf{y}^T]^T$ с ф.п.р.в. $f(\mathbf{x}, \mathbf{y})$, то линейная нейронная сеть

$$\tilde{\mathbf{y}}^{\text{HC}}(\mathbf{x}, \tilde{\mathbf{H}}^{\text{HC}}) = \mathbf{h}_0^{\text{HC}} + \mathbf{H}^{\text{HC}}\mathbf{x} \quad (25)$$

при выборе для ее обучения с учителем в качестве критерия обучения функции

$$J(\tilde{\mathbf{H}}^{\text{HC}}) = \frac{1}{n_o} \sum_{j=1}^{n_o} \left\| \mathbf{y}^{(j)} - \tilde{\mathbf{y}}^{\text{HC}(j)}(\mathbf{x}^{(j)}, \tilde{\mathbf{H}}^{\text{HC}}) \right\|^2 \quad (26)$$

обеспечивает при увеличении числа используемых для обучения реализаций n_o идентификацию матрицы измерения \mathbf{H} и характеристик шумов измерения \mathbf{v} в виде

$$(\mathbf{H}^{\text{HC}})^T = (\mathbf{P}_{\mathbf{xx}}^*)^{-1} \mathbf{P}_{\mathbf{xy}}^*; \quad \mathbf{P}_{\mathbf{vv}}^* = \mathbf{P}_{\mathbf{yy}}^* - \mathbf{H}^{\text{HC}} \mathbf{P}_{\mathbf{xx}}^* (\mathbf{H}^{\text{HC}})^T \quad (27)$$

где $\mathbf{P}_{\mathbf{xx}}^*$, $\mathbf{P}_{\mathbf{xy}}^*$ и $\mathbf{P}_{\mathbf{yy}}^*$ представляют собой выборочные значения соответствующих матриц ковариаций.

Утверждение 3

Если считаются известными уравнения динамики и измерений в виде

$$\begin{aligned} \mathbf{x}_i &= \mathbf{\Phi}_i \mathbf{x}_{i-1} + \mathbf{n}_i; \\ \mathbf{y}_i &= \mathbf{H}_i \mathbf{x}_i + \mathbf{v}_i, \end{aligned} \quad (28)$$

без задания априорной информации о свойствах возмущений \mathbf{n}_i , \mathbf{v}_i и имеется n_o независимых между собой реализаций случайных векторов $\{(\mathbf{x}_0^{(j)}), \mathbf{Y}_i^{(j)}, \mathbf{X}_i^{(j)}\}$, $j = \overline{1, n_o}$ с ф.п.р.в. $f(\mathbf{x}_0, \mathbf{X}_i, \mathbf{Y}_i)$, то линейная рекуррентная НС

$$\hat{\mathbf{x}}_i^{\text{HC}}(\mathbf{z}_i, \tilde{\mathbf{W}}_i) = \mathbf{w}_{0i} + \mathbf{W}_i \mathbf{z}_i, \quad \mathbf{z}_i = [z_{1i}, \dots, z_{qi}]^T \equiv \left[\left(\hat{\mathbf{x}}_{i/i-1}^{\text{HC}} \right)^T, \left(\boldsymbol{\varepsilon}_i^{\text{HC}} \right)^T \right]^T \quad (29)$$

при выборе для ее обучения с учителем в качестве критерия обучения на шаге i функции

$$J_i(\tilde{\mathbf{W}}_i) = \frac{1}{n_o} \sum_{j=1}^{n_o} \left\| \mathbf{x}_i^{(j)} - \hat{\mathbf{x}}_i^{\text{HC}(j)}(\mathbf{z}_i^{(j)}, \tilde{\mathbf{W}}_i) \right\|^2 \quad (30)$$

обеспечивает оптимальную текущую оценку $\hat{\mathbf{x}}_i^{\text{HC}}$, которая описывается рекуррентным соотношением

$$\hat{\mathbf{x}}_i^{\text{HC}} = \hat{\mathbf{x}}_{i/i-1}^{\text{HC}} + \mathbf{K}_i^* (\mathbf{y}_i - \mathbf{H}_i \hat{\mathbf{x}}_{i/i-1}^{\text{HC}}), \quad i = 1, 2, \dots, \quad (31)$$

где $\hat{\mathbf{x}}_{i/i-1}^{\text{HC}} = \mathbf{\Phi}_i \hat{\mathbf{x}}_{i-1}^{\text{HC}}(\mathbf{z}_{i-1}, \tilde{\mathbf{W}}_{i-1})$, и при увеличении числа используемых для обучения реализаций n_o будет стремиться к оптимальной оценке фильтра Калмана;

$$\mathbf{K}_i^* = \mathbf{P}_{i/i-1}^* \mathbf{H}_i^T (\mathbf{H}_i \mathbf{P}_{i/i-1}^* \mathbf{H}_i^T + \mathbf{R}_i^*)^{-1}, \quad (32)$$

где

$$\mathbf{P}_{i/i-1}^* = \mathbf{\Phi}_i \mathbf{P}_{i-1}^* \mathbf{\Phi}_i^T + \mathbf{Q}_i^*; \quad \mathbf{Q}_i^* = \frac{1}{n_o} \sum_{j=1}^{n_o} \left\| \mathbf{x}_i^{(j)} - \mathbf{\Phi}_i \mathbf{x}_{i-1}^{(j)} \right\|^2; \quad \mathbf{R}_i^* = \frac{1}{n_o} \sum_{j=1}^{n_o} \left\| \mathbf{y}_i^{(j)} - \mathbf{H}_i \mathbf{x}_i^{(j)} \right\|^2 \quad (33)$$

– выборочные значения матриц ковариаций.

Рекуррентный фильтр Калмана можно трактовать как обученный «с учителем» в соответствии с описанной процедурой нейросетевой алгоритм.

Утверждение 4

Если считаются известными уравнения динамики и измерений в виде

$$\mathbf{x}_i = \Phi_i(\mathbf{x}_{i-1}) + \mathbf{n}_i, \quad \mathbf{y}_i = \mathbf{s}_i(\mathbf{x}_i) + \mathbf{v}_i. \quad (34)$$

без задания априорной информации о свойствах возмущений \mathbf{n}_i , \mathbf{v}_i и имеется n_o независимых между собой реализаций случайных векторов $\{(\mathbf{x}_0^{(j)}), \mathbf{Y}_i^{(j)}, \mathbf{X}_i^{(j)}\}$, $j = \overline{1, n_o}$ с ф.п.р.в. $f(\mathbf{x}_0, \mathbf{X}_i, \mathbf{Y}_i)$, то рекуррентная НС

$$\hat{\mathbf{x}}_i^{\text{HC}}(\mathbf{z}_i, \tilde{\mathbf{W}}_i) = \mathbf{w}_{0i} + \mathbf{W}_i \mathbf{z}_i, \quad (35)$$

$$\mathbf{z}_i = [z_{1i}, \dots, z_{qi}]^T \equiv \left[\left(\hat{\mathbf{x}}_{i/i-1}^{\text{HC}} \right)^T, \left(\boldsymbol{\varepsilon}_i^{\text{HC}} \right)^T \right]^T \quad (36)$$

при выборе для ее обучения с учителем в качестве критерия обучения на шаге i функции

$$J_i(\tilde{\mathbf{W}}_i) = \frac{1}{n_o} \sum_{j=1}^{n_o} \left\| \mathbf{x}_i^{(j)} - \hat{\mathbf{x}}_i^{\text{HC}(j)}(\mathbf{z}_i^{(j)}, \tilde{\mathbf{W}}_i) \right\|^2 \quad (37)$$

обеспечивает оптимальную текущую оценку $\hat{\mathbf{x}}_i^{\text{HC}}$, которая описывается рекуррентным соотношением

$$\hat{\mathbf{x}}_i^{\text{HC}} = \hat{\mathbf{x}}_{i/i-1}^{\text{HC}} + \mathbf{K}_i^* [\mathbf{y}_i - \mathbf{s}_i(\hat{\mathbf{x}}_{i/i-1}^{\text{HC}})], \quad i = 1, 2, \dots, \quad (38)$$

где $\hat{\mathbf{x}}_{i/i-1}^{\text{HC}} = \Phi_i[\hat{\mathbf{x}}_{i-1}^{\text{HC}}(\mathbf{z}_{i-1}, \tilde{\mathbf{W}}_{i-1})]$, и при увеличении числа используемых для обучения реализаций n_o будет стремиться к оптимальной оценке расширенного фильтра Калмана;

$$\mathbf{K}_i^* = \mathbf{P}_{i/i-1}^* \mathbf{H}_{\mathbf{x}i}^T (\mathbf{H}_{\mathbf{x}i} \mathbf{P}_{i/i-1}^* \mathbf{H}_{\mathbf{x}i}^T + \mathbf{R}_i^*)^{-1}, \quad (39)$$

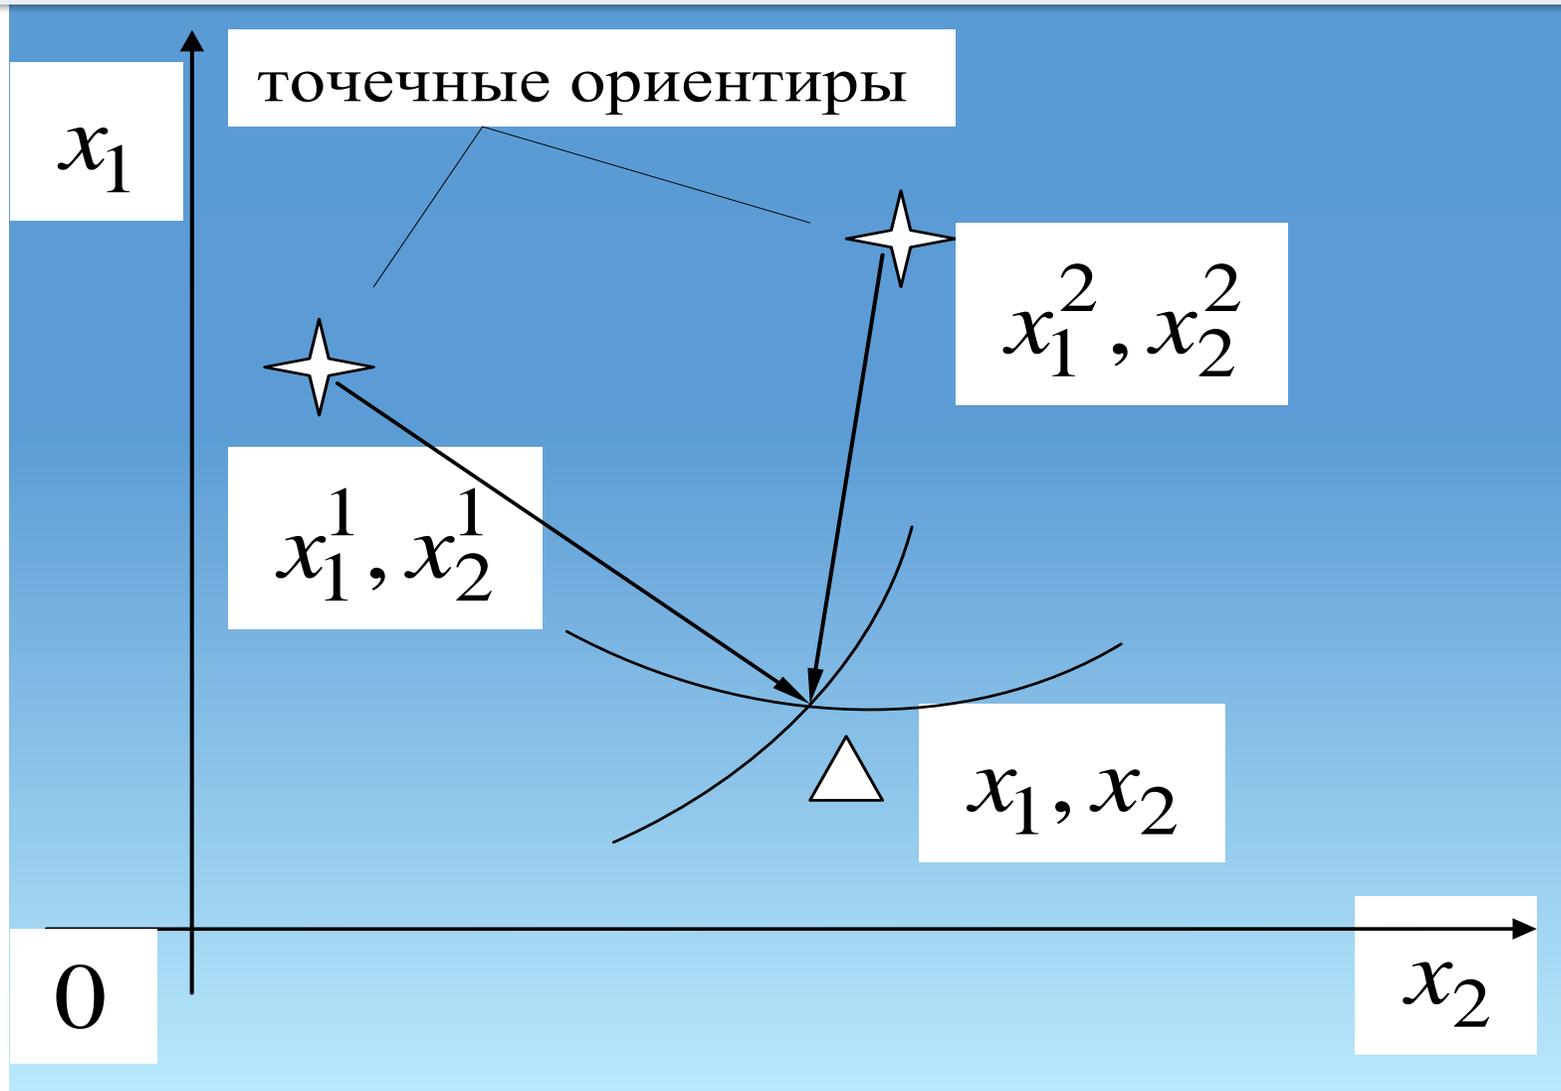
где

$$\mathbf{P}_{i/i-1}^* = \Phi_{\mathbf{x}i} \mathbf{P}_{i-1}^* \Phi_{\mathbf{x}i}^T + \mathbf{Q}_i^*; \quad \mathbf{Q}_i^* = \frac{1}{n_o} \sum_{j=1}^{n_o} \left\| [\mathbf{x}_i^{(j)} - \Phi_i(\mathbf{x}_{i-1}^{(j)})] \right\|^2; \quad \mathbf{R}_i^* = \frac{1}{n_o} \sum_{j=1}^{n_o} \left\| [\mathbf{y}_i^{(j)} - \mathbf{s}_i(\mathbf{x}_i^{(j)})] \right\|^2 \quad (40)$$

– выборочные значения матриц ковариаций.

Рекуррентный расширенный фильтр Калмана можно трактовать как обученный «с учителем» в соответствии с описанной процедурой нейросетевой алгоритм.

Применение к задаче навигации, использующей эталонные маяки



Навигация с использованием измерений до двух точечных ориентиров

Пример нелинейной задачи

Необходимо оценить $\mathbf{x} = (x_1, x_2)^T$ по нелинейным измерениям
 $\mathbf{y} = (y_1, y_2)^T$ до двух точечных ориентиров

$$\mathbf{x}^1 = (x_1^1 = 3000 \text{ м}, x_2^1 = 0 \text{ м})^T, \quad \mathbf{x}^2 = (x_1^2 = 0 \text{ м}, x_2^2 = 3000 \text{ м})^T$$

с использованием одной, двух и более пар (k) измерений

$$y_k^i = s_k^i(x) + v_k^i = \sqrt{(x_1 - x_1^i)^2 + (x_2 - x_2^i)^2} + v_k^i, \quad i = \overline{1,2},$$
$$\mathbf{x} \sim N\left(0, \begin{bmatrix} \sigma_0^2 & 0 \\ 0 & \sigma_0^2 \end{bmatrix}\right), \quad \sigma_0 = \text{var}, \quad v_i \sim N(0, r^2), \quad r = 30 \text{ м}. \quad (41)$$

Число реализаций:

для метода Монте-Карло и для обучения ИНС равно 3000;

для тестирования – 300.

Метод Монте-Карло:

Вычисление нелинейных оптимальных оценок
и условной матрицы ковариаций

$$\tilde{\mathbf{x}}(\mathbf{y})$$
$$\mathbf{P}_{\mathbf{x}}(\mathbf{y})$$

$$\tilde{\mathbf{x}}(\mathbf{y}) \approx \frac{\sum_{j=1}^{n_1} \mathbf{x}^{(j)} f(\mathbf{y} / \mathbf{x}^{(j)})}{\sum_{j=1}^{n_1} f(\mathbf{y} / \mathbf{x}^{(j)})}, \quad (42)$$

$$\mathbf{P}_{\mathbf{x}}(\mathbf{y}) = \frac{\sum_{j=1}^{n_1} \mathbf{x}^{(j)} [\mathbf{x}^{(j)}]^T f(\mathbf{y} / \mathbf{x}^{(j)})}{\sum_{j=1}^{n_1} f(\mathbf{y} / \mathbf{x}^{(j)})} - \tilde{\mathbf{x}}(\mathbf{y}) \tilde{\mathbf{x}}(\mathbf{y})^T. \quad (43)$$

где $\mathbf{x}^{(j)}$, $j = \overline{1..n_1}$ - независимые реализации с ф.п.р.в. $f(\mathbf{x})$;
 $f(\mathbf{y} / \mathbf{x}^{(j)})$ - условная ф.п.р.в. измерений.

Вычисление линейных оптимальных оценок с помощью метода Монте-Карло:

Задача состоит в том, чтобы найти

$$\bar{\mathbf{y}}, \mathbf{P}_{\mathbf{x}\mathbf{y}}, \mathbf{P}_{\mathbf{y}\mathbf{y}}.$$

Для $\bar{\mathbf{x}} = \mathbf{0}, \bar{\mathbf{v}} = \mathbf{0}$

$$\bar{\mathbf{y}} \approx \frac{1}{n_1} \sum_{j=1}^{n_1} \mathbf{s}(\mathbf{x}^{(j)}), \quad (44)$$

$$\mathbf{P}_{\mathbf{x}\mathbf{y}} \approx \frac{1}{n_1} \sum_{j=1}^{n_1} \mathbf{x}^{(j)} \mathbf{s}(\mathbf{x}^{(j)})^T - \bar{\mathbf{x}} \bar{\mathbf{y}}^T, \quad (45)$$

$$\mathbf{P}_{\mathbf{y}\mathbf{y}} \approx \frac{1}{n_1} \sum_{j=1}^{n_1} \mathbf{s}(\mathbf{x}^{(j)}) \mathbf{s}(\mathbf{x}^{(j)})^T - \bar{\mathbf{y}} \bar{\mathbf{y}}^T + \mathbf{P}_{\mathbf{v}}. \quad (46)$$

Для задач навигации параметры

$$\bar{\mathbf{x}}, \mathbf{P}_{\mathbf{v}}$$

считаются известными.

Расчетные СКО оценок:

$$\mathbf{P}^{lin} = \mathbf{P}_{\mathbf{xx}} - \mathbf{P}_{\mathbf{xy}} \mathbf{P}_{\mathbf{yy}}^{-1} \mathbf{P}_{\mathbf{yx}}, \quad (47)$$

$$\sqrt{p^{lin}} \sim \mathbf{P}^{lin} (\mu, \mu);$$

Выборочные СКО оценок:

$$\tilde{\sigma}^s = \left(\frac{1}{L} \sum_{j=1}^L (x^j - \tilde{x}^s(y^j))^2 \right)^{1/2}, \quad (48)$$

где $x^j, y^j, j = \overline{1..L}$ -реализации случайных векторов
- с ф.п.в. $f(\mathbf{x}, \mathbf{y});$
 $s = opt, lin, NN, Alin$

Результаты моделирования примера

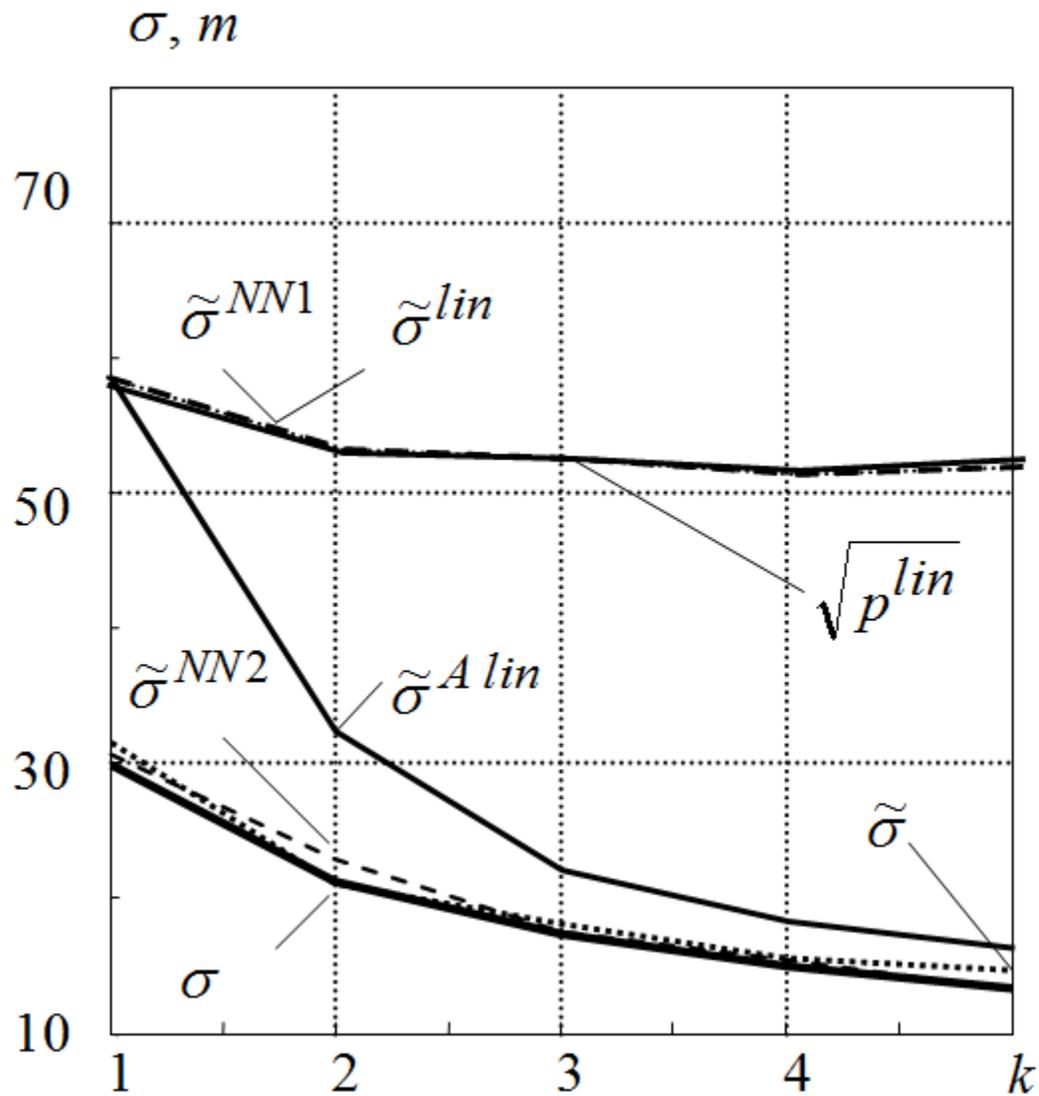


Рис. СКО при $x_l, l = \overline{1,2}$
($\sigma_0 = 500 m$).

Расчетные СКО оценок:

- σ — для границы Рао-Крамера;
- $\sqrt{p^{lin}}$ — для линейных оценок.

Выборочные СКО оценок:

- σ_z — для оптимальной;
- σ_z^{NN1} — для линейной НС;
- σ_z^{NN2} — для нелинейной НС;
- σ_z^{lin} — для линейной оптимальной;
- $\sigma_z^{A lin}$ — для линейных оценок при использовании апостериорной ф.п.р.в.

Выводы:

Заметные преимущества вычислительного характера для нейросетевого подхода проявляются лишь при использовании нелинейной НС.

Для метода Монте-Карло требуются значительные вычислительные затраты между текущими измерениями.

Процедура же вычисления оценок обученной НС тривиальна.

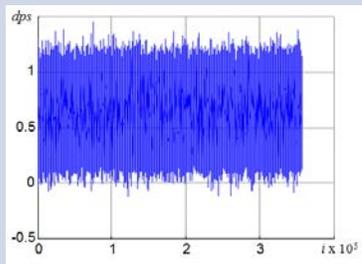
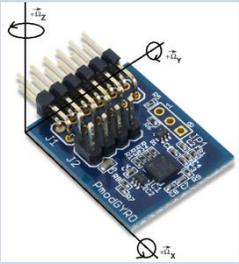
Каких-либо значительных преимуществ алгоритмов, основанных на линейных НС, не выявлено.

К недостатку линейной НС можно отнести то, что в отличие от традиционного подхода в нейросетевом не предусмотрена процедура вычисления матрицы ковариаций.

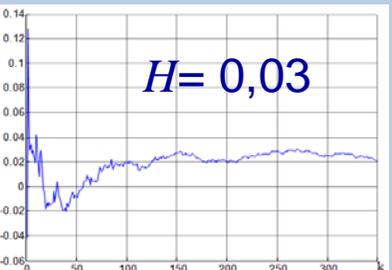
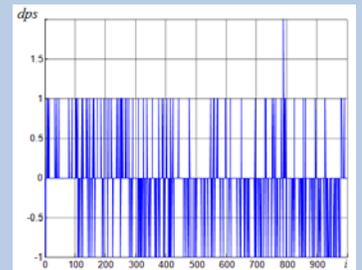
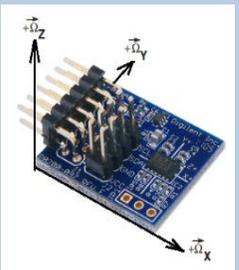
Процессы с памятью

ИНЕРЦИАЛЬНЫЕ НАВИГАЦИОННЫЕ СИСТЕМЫ

Цифровой гироскоп
PmodGYRO
STMicroelectronics L3G4200D



Трехкоординатный акселерометр
PmodACL
Analog Devices ADXL 345

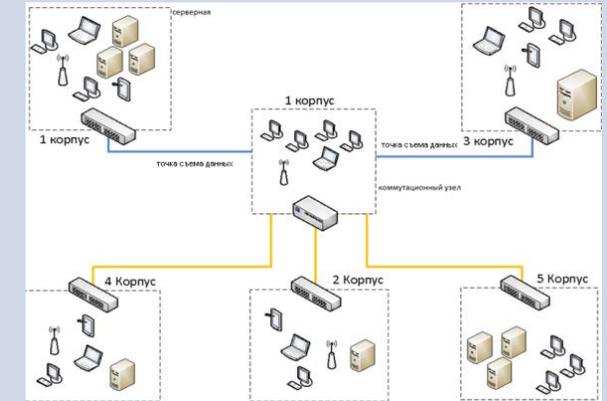


ТРАЕКТОРНОЕ ДВИЖЕНИЕ ПОДВИЖНОГО ОБЪЕКТА

Фрактальность проявляется в поведении воздушной и морской среды (например, турбулентность)

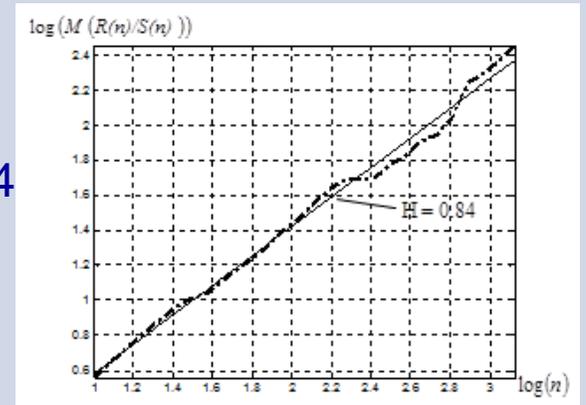
ИНФОРМАЦИОННО-ТЕЛЕКОММУНИКАЦИОННАЯ СИСТЕМА

Трафик в компьютерных сетях



2 мес., пакеты

$H = 0,84$



Определение ФБД (не является марковским процессом первого порядка)

Гауссовский процесс $B(t)$ называется **фрактальным броуновским движением** с параметром H , $0 < H < 1$, если он обладает следующими свойствами.

1) $B(0) = 0$ и функция $B(t)$ почти всегда непрерывна.

2) Свойство гауссовости приращений: приращение $\Delta B = B(t_2) - B(t_1)$ имеет гауссовское распределение с нулевым математическим ожиданием и дисперсией

$$M[(B(t_2) - B(t_1))^2] = \sigma^2 (t_2 - t_1)^{2H}, \quad (49)$$

где $t_2 > t_1$, M – символ математического ожидания; σ – положительная константа, то есть вероятность

$$P(\Delta B < x) = \frac{1}{\sqrt{2\pi\sigma(t_2 - t_1)^H}} \int_{-\infty}^x \exp\left[-\frac{1}{2}\left(\frac{u}{\sigma(t_2 - t_1)^H}\right)^2\right] du. \quad (50)$$

3) Приращения $\Delta B = B(t_2) - B(t_1)$ стационарны.

4) $B(t)$ имеет зависимые приращения (за исключением случая $H = 1/2$): случайные величины $B(t) - B(0)$ и $B(t + \Delta t) - B(t)$, $\Delta t > 0$, зависимы.

Пример оценивания процессов с памятью

Необходимо оценить скалярную последовательность для фрактального винеровского процесса (ФВП) x_i

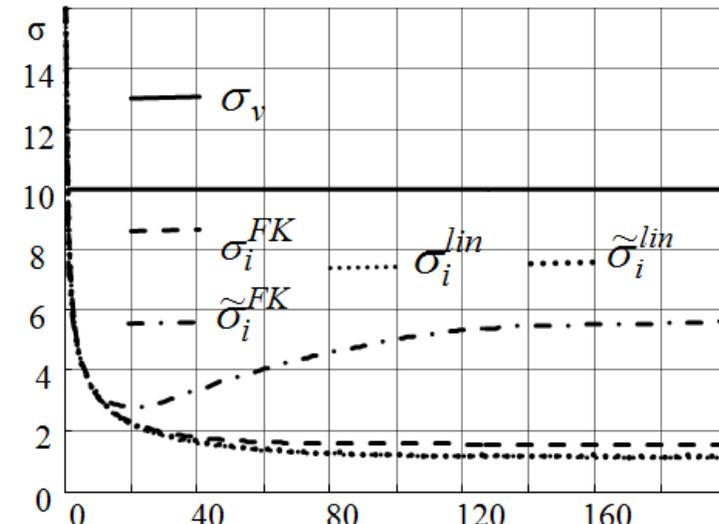
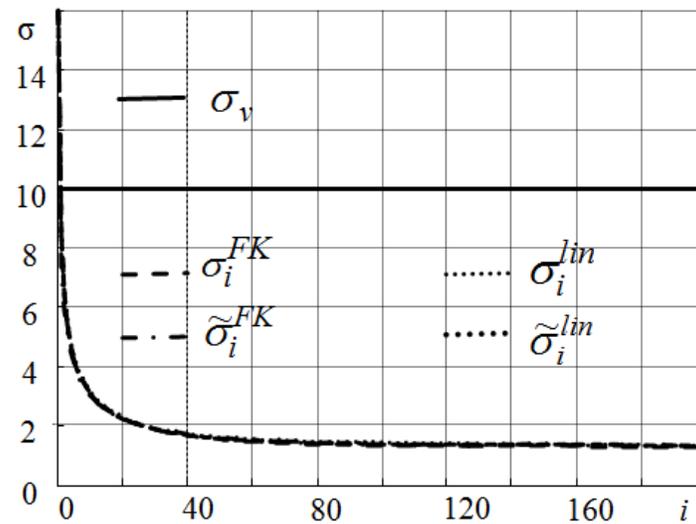
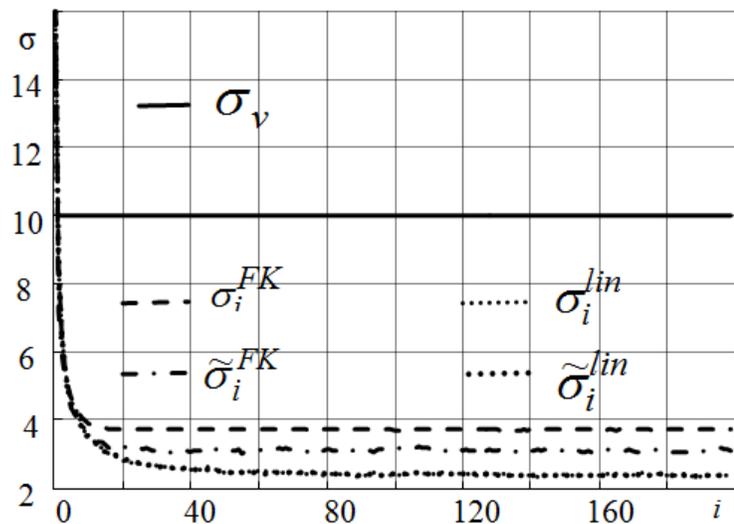
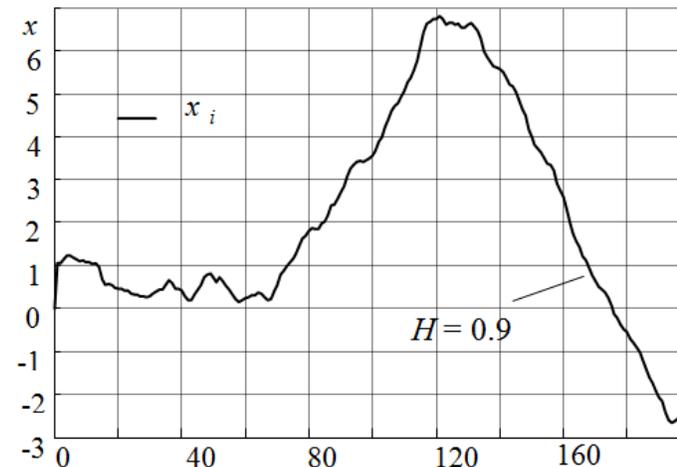
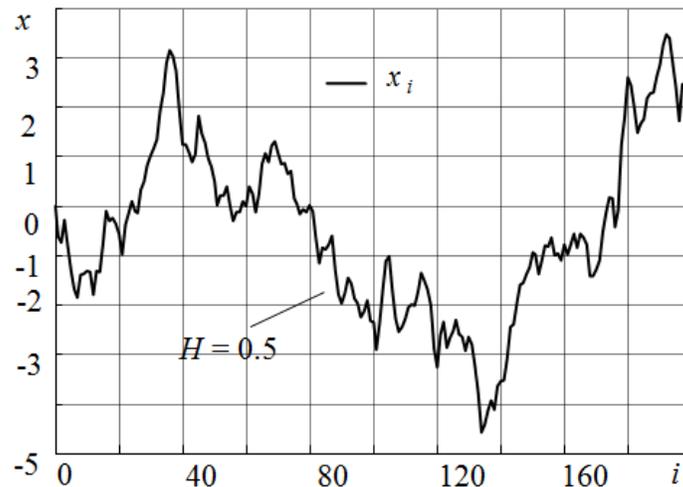
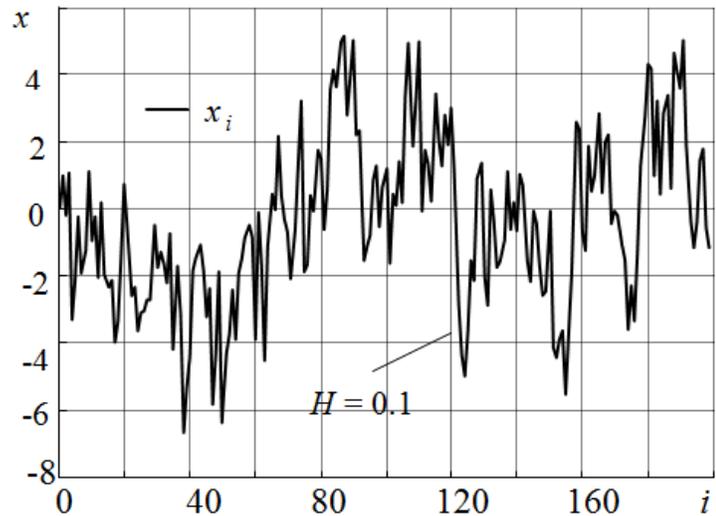
по линейным измерениям вида $y_i = x_i + v_i$,

где $i = 0, 1, \dots, N - 1$;

v_i – центрированные г.с.в., независимые между собой и от x_i с ковариацией $R = \sigma_v^2$;

x_0 представляет собой центрированную г.с.в. с ковариацией $P_0 = \sigma_0^2$.

Оценивание фрактального процесса с различным показателем Херста H



Оценивание и системы нечеткой логики

Основные соотношения	ПОДХОД НА ОСНОВЕ НЕЧЕТКОЙ ЛОГИКИ
Критерий	$\tilde{J}^*(\tilde{\mathbf{W}}) = \frac{1}{n_o} \sum_{j=1}^{n_o} \left\ \mathbf{x}^{(j)} - \hat{\mathbf{x}}^{\text{НЛ}}(\mathbf{y}^{(j)}, \tilde{\mathbf{W}}) \right\ ^2$
Априорная информация	<p>Эталонные реализации $\{(\mathbf{y}^{(j)}, \mathbf{x}^{(j)})\}, j = \overline{1..n_o}$.</p>
Предикатные правила	<p>Π_j: если \mathbf{y} есть \mathbf{A}_j, то $\hat{\mathbf{x}}^{\text{НЛ}}$ есть \mathbf{B}_j; $j = \overline{1..n}$</p>
Алгоритм оценивания	$\hat{\mathbf{x}}^{\text{НЛ}}(\mathbf{y}) = \mathbf{K}^{\text{НЛ}}(\mathbf{y}, \tilde{\mathbf{W}}).$
Методы нахождения оценок	<p>Алгоритмы нечеткого вывода: Mamdani, Tsukamoto, Sugeno, Larsen, упрощенный</p>
Точность оценивания	$\mathbf{P}_e^{\text{НЛ}} = \frac{1}{n_o} \sum_{j=1}^{n_o} \left(\mathbf{x}^{(j)} - \hat{\mathbf{x}}^{\text{НЛ}}(\mathbf{y}^{(j)}, \tilde{\mathbf{W}}) \right) \left(\mathbf{x}^{(j)} - \hat{\mathbf{x}}^{\text{НЛ}}(\mathbf{y}^{(j)}, \tilde{\mathbf{W}}) \right)^T$

(51)

(52)

1. Решение нелинейных задач оценивания.
2. Оценивание нестационарных процессов.
3. Негауссовский характер случайных процессов.
4. Оценивание случайных процессов с памятью – марковских процессов высшего порядка.

Вычислительный метод.

Байесовский подход. Нерекуррентное оценивание.

- 1) Вводится класс параметрически заданных функций $\tilde{\mathbf{x}}(\mathbf{y}, \tilde{\mathbf{W}})$.
- 2) Используется имеющееся в наличии обучающее множество $\{(\mathbf{y}^{(j)}, \mathbf{x}^{(j)})\}_{j=1}^N$.
- 3) Определяется среднеквадратический критерий оптимизации

$$\tilde{J}^*(\tilde{\mathbf{W}}) = \frac{1}{N} \sum_{j=1}^N \left(\mathbf{x}^{(j)} - \tilde{\mathbf{x}}^{(j)}(\mathbf{y}^{(j)}, \tilde{\mathbf{W}}) \right)^T \left(\mathbf{x}^{(j)} - \tilde{\mathbf{x}}^{(j)}(\mathbf{y}^{(j)}, \tilde{\mathbf{W}}) \right), \quad (53)$$

где $\tilde{\mathbf{x}}^{(j)}(\mathbf{y}^{(j)}, \tilde{\mathbf{W}})$ – формируемая оценка.

- 4) Критерий оптимизируется на основе минимизации эмпирического риска

$$P \left\{ \sup_{\tilde{\mathbf{W}}} \left| J(\tilde{\mathbf{W}}) - \tilde{J}^*(\tilde{\mathbf{W}}) \right| > \varepsilon \right\} \rightarrow 0, \quad \text{при } N \rightarrow \infty, \quad (54)$$

где ε – заданная точность; $J(\tilde{\mathbf{W}}) = M \left\| \mathbf{x} - \tilde{\mathbf{x}}(\mathbf{y}, \tilde{\mathbf{W}}) \right\|^2$.

- 5) Минимизация реализуется с помощью нейронных сетей, нечетких систем, вейвлетов и гибридных систем

$$\tilde{\mathbf{x}}^\mu(\mathbf{y}) = \mathbf{K}^\mu(\mathbf{y}, \tilde{\mathbf{W}}), \quad \mu = NN, FS, W, GS, \quad (55)$$

где $\tilde{\mathbf{W}}$ – матрица, отвечающая за параметры синтетических систем; \mathbf{y} – вход синтетических систем; NN – нейронные сети; FS – нечеткие системы; W – вейвлеты, GS – гибридные системы.

Вычислительный метод. Рекуррентное оценивание

Дано уравнение вида

$$\mathbf{x}_i = \Phi_i (\mathbf{x}_{i-1}) + \mathbf{w}_i, \quad (56)$$

которое задается по проводимым в каждый i -й момент времени m -мерным измерениям, определяемым как

$$\mathbf{y}_i = \mathbf{s}_i (\mathbf{x}_i) + \mathbf{v}_i, \quad (57)$$

где $\Phi_i (\mathbf{x}_{i-1})$ и $\mathbf{s}_i (\mathbf{x}_i)$ – n - и m -мерные векторные функции, в общем случае нелинейные относительно своих аргументов; \mathbf{w}_i и \mathbf{v}_i – n - и m -мерные независимые между собой и от \mathbf{x}_0 случайные последовательности.

$$\text{Шаг прогноза: } \tilde{\mathbf{x}}_{i/i-1} = \Phi_i (\tilde{\mathbf{x}}_{i-1/i-1}^\mu); \quad \tilde{\mathbf{y}}_{i/i-1} = \mathbf{s}_i (\tilde{\mathbf{x}}_{i/i-1}),$$

где $\tilde{\mathbf{x}}_{i/i-1}$, $\tilde{\mathbf{y}}_{i/i-1}$ – прогнозы состояния и измерения; $\tilde{\mathbf{x}}_{i-1/i-1}^\mu$ – оценка состояния на выходе алгоритма, синтезируемого с использованием синтетических систем $\mu = NN, FS, W, GS$.

$$\text{Шаг обновления: } \tilde{\mathbf{x}}_{i/i}^\mu = \mathbf{K}_i^\mu (\tilde{\mathbf{x}}_{i/i-1}, \mathbf{Y}_i, \mathbf{E}_i, \tilde{\mathbf{W}}_i),$$

где $\mathbf{Y}_i = [\mathbf{y}_i^T, \mathbf{y}_{i-1}^T, \dots, \mathbf{y}_{i-n_y}^T]^T$ – вектор, содержащий текущее и прошлые измерения; $\mathbf{E}_i = [\boldsymbol{\varepsilon}_i^T, \boldsymbol{\varepsilon}_{i-1}^T, \dots, \boldsymbol{\varepsilon}_{i-n_\varepsilon}^T]^T$ – вектор, содержащий настоящую и прошлые невязки измерений $\boldsymbol{\varepsilon}_i = \mathbf{y}_i - \tilde{\mathbf{y}}_{i/i-1}$, n_y и n_ε – число предыдущих измерений и невязок измерений соответственно; \mathbf{K}_i^μ – нелинейная функция, построенная с использованием синтетических систем; $\tilde{\mathbf{W}}_i$ – массив коэффициентов синтетических систем.

1) Вводим класс параметрически заданных функций $\tilde{\mathbf{x}}(\mathbf{y}, \tilde{\mathbf{W}})$.

2) Отсутствует обучающее множество $\{(\mathbf{y}^{(j)}, \mathbf{x}^{(j)})\}_{j=1}^N$.

3) Среднеквадратический критерий оптимизации

$$\tilde{I}^*(\tilde{\mathbf{W}}) = \{\mathbf{y} - \mathbf{s}[\tilde{\mathbf{x}}(\mathbf{y}, \tilde{\mathbf{W}})]\}^T \{\mathbf{y} - \mathbf{s}[\tilde{\mathbf{x}}(\mathbf{y}, \tilde{\mathbf{W}})]\} = \sum_{i=1}^m \{y_i - s_i[\tilde{\mathbf{x}}(\mathbf{y}, \tilde{\mathbf{W}})]\}^2, \quad (58)$$

где $\tilde{\mathbf{W}}$ - вектор или матрица, определяющая ряд свободных параметров, которые определяют функцию $\tilde{\mathbf{x}}(\mathbf{y}, \tilde{\mathbf{W}})$.

4) Критерий оптимизируется на основе минимизации эмпирического риска

$$P \left\{ \sup_{\tilde{\mathbf{W}}} |I(\tilde{\mathbf{W}}) - \tilde{I}^*(\tilde{\mathbf{W}})| > \varepsilon \right\} \rightarrow 0, \quad \text{при } N \rightarrow \infty,$$

где ε – заданная точность; $I(\tilde{\mathbf{W}}) = M \|\mathbf{y} - \mathbf{s}[\tilde{\mathbf{x}}(\mathbf{y})]\|^2$.

5) Реализация с помощью синтетических систем

$$\tilde{\mathbf{x}}^\mu(\mathbf{y}) = \mathbf{K}^\mu(\mathbf{y}, \tilde{\mathbf{W}}), \quad \mu = NN, FS, W, GS.$$

Декомпозиция синтетических систем с использованием трех базовых представлений подсистем

Каскадное соединение: Каждая система $S \subset (X_1 \times X_2) \times (Y_1 \times Y_2)$ допускает декомпозицию в соединенные каскадно элементы.

Параллельное соединение: Пусть система $S \subset (X_1 \times X_2) \times (Y_1 \times Y_2)$ и пусть $S(x) = \{y : (x, y) \in S\}$, где $X = X_1 \times X_2$, а $Y = Y_1 \times Y_2$. Система S допускает декомпозицию на системы S_1 и S_2 , в том и только в том случае, когда для любых $x \in D(S)$ справедливо равенство $S(x) = \Pi_1(S(x)) \times \Pi_2(S(x))$ и операторы проектирования:

$$\Pi_1 : (X_1 \times X_2) \times (Y_1 \times Y_2) \rightarrow (X_1 \times Y_1),$$

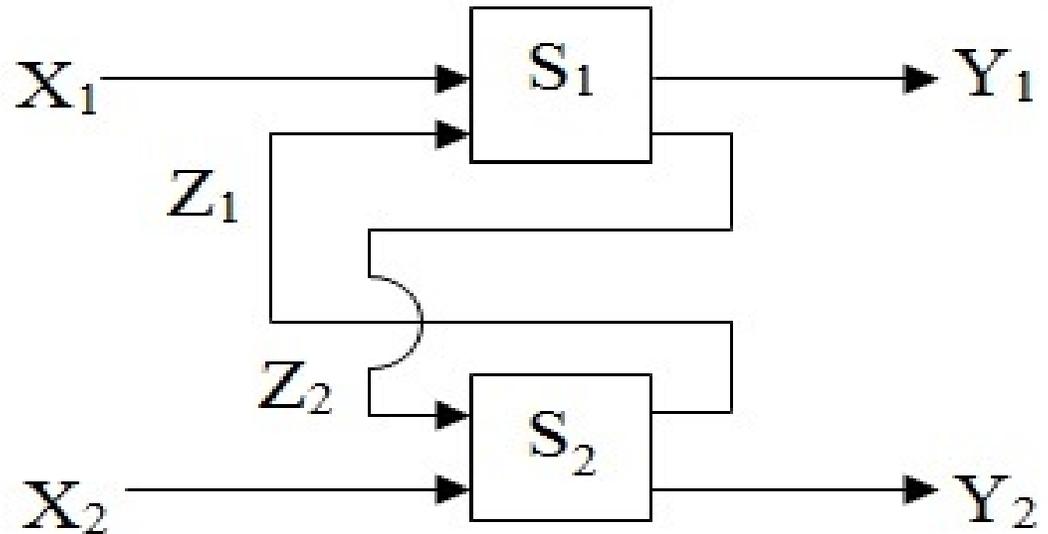
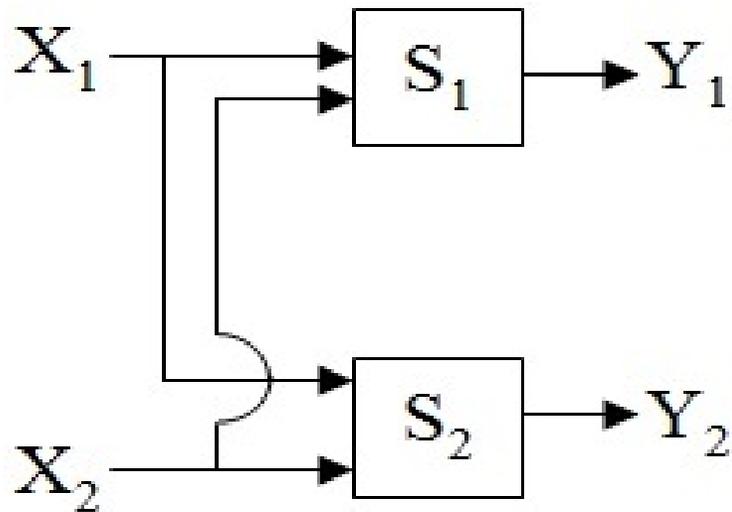
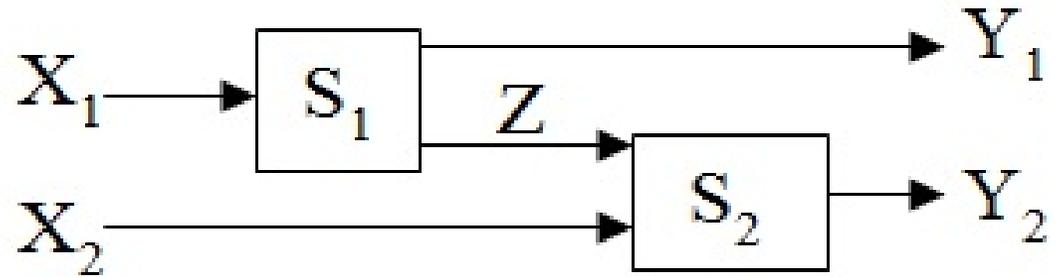
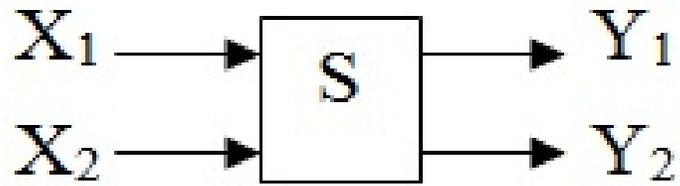
$$\Pi_2 : (X_1 \times X_2) \times (Y_1 \times Y_2) \rightarrow (X_2 \times Y_2),$$

такие, что $\Pi_1(x_1, x_2, y_1, y_2) = (x_1, y_1)$ и $\Pi_2(x_1, x_2, y_1, y_2) = (x_2, y_2)$.

Замыкание обратной связи: Любая система $S \subset (X_1 \times X_2) \times (Y_1 \times Y_2)$ допускает декомпозицию $S = F(S_1 \circ S_2)$ в соединенные каскадно и охваченные обратной связью элементы, где $S_1 \subset (X_1 \times Z_1) \times (Y_1 \times Z_2)$, $S_2 \subset (X_2 \times Z_2) \times (Y_2 \times Z_1)$, а Z_1 и Z_2 – вспомогательные множества.

Базовые представления подсистем

Каскадное, параллельное соединение и соединение с замыканием обратной связи



Иерархическая синтетическая система оценивания типа MIMO, представленная совокупностью систем типа MISO

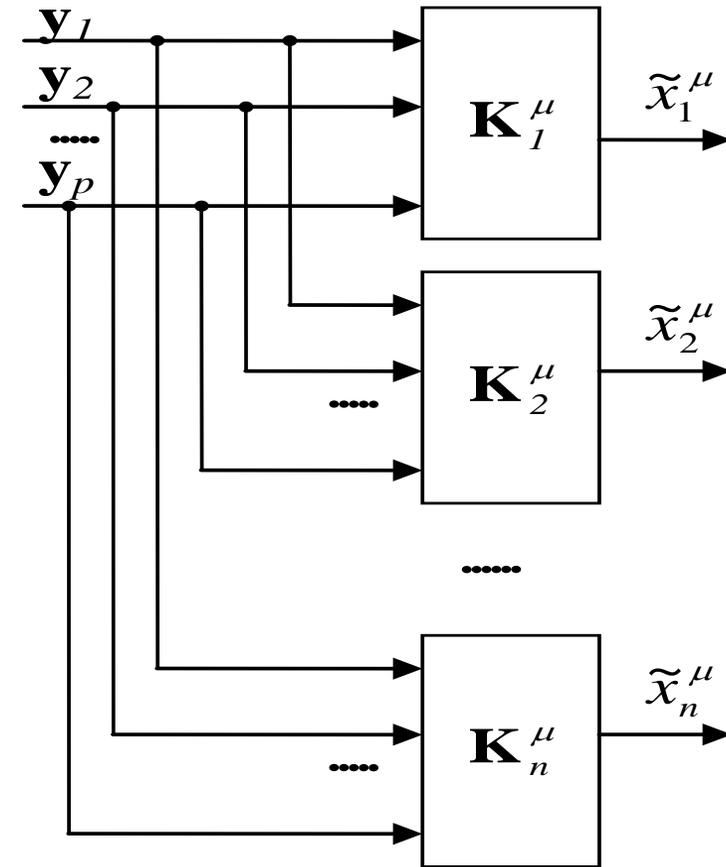
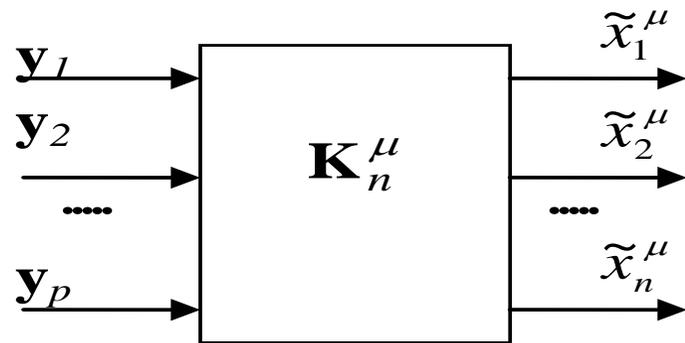
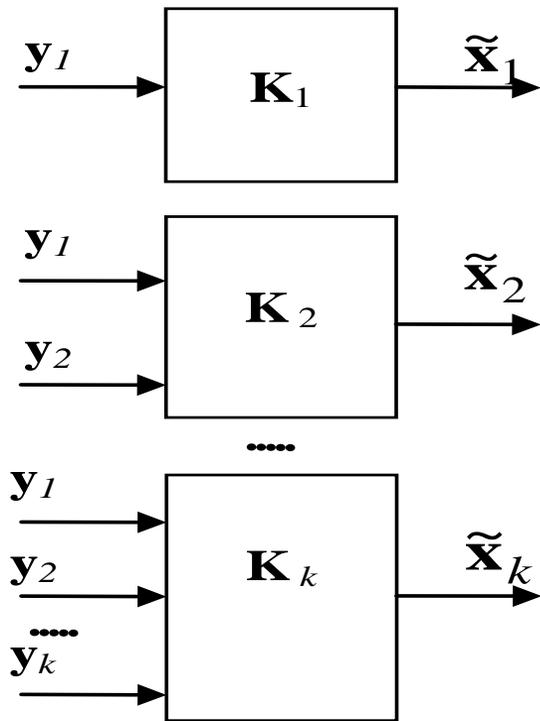


Схема нерекуррентного и рекуррентного оценивания

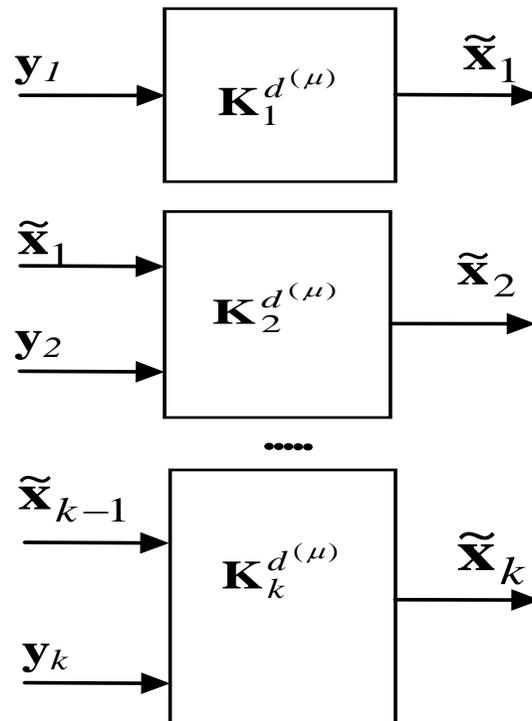
а) нерекуррентное оценивание;

б) рекуррентное оценивание с использованием декомпозиции с одним измерением;

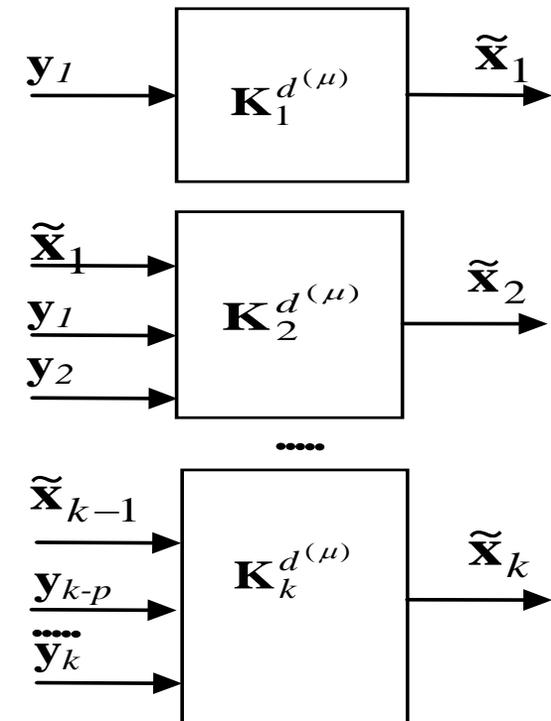
в) рекуррентное оценивание с использованием декомпозиции с несколькими измерениями



а)

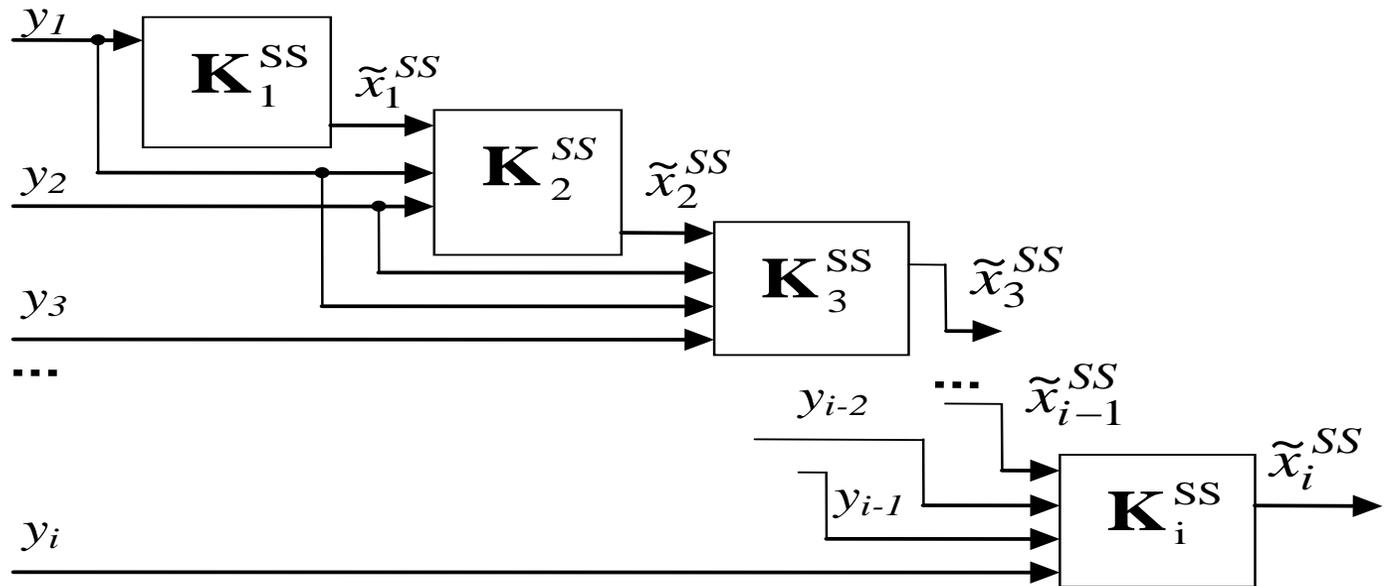
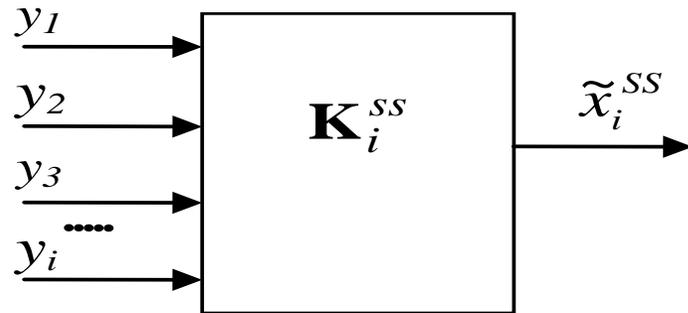


б)



в)

Иерархическая синтетическая система для устройства оценивания с растущей памятью



На рисунке представлен пример СС оценивания, которая использует два принципа – каскадное и параллельное соединение. В этой системе каждый из узлов (кроме первого), использует для оценивания как соответствующий набор измерений, так и оценку, полученную на предыдущем шаге вычислений.

Оценка производительности систем с декомпозицией.

Задача нелинейного оценивания с негауссовской ф.п.р.в. переменной состояния и негауссовскими шумами измерений

Оценить равномерно распределенную на $[0, b]$ случайную величину x , используя измерения $\mathbf{y} \equiv [y_1 \ \dots \ y_l]^T$, где

$$y_i = x + v_i, \quad i = \overline{1, l},$$

v_i – случайные величины, равномерно распределенные в интервале $[-a/2, a/2]$.

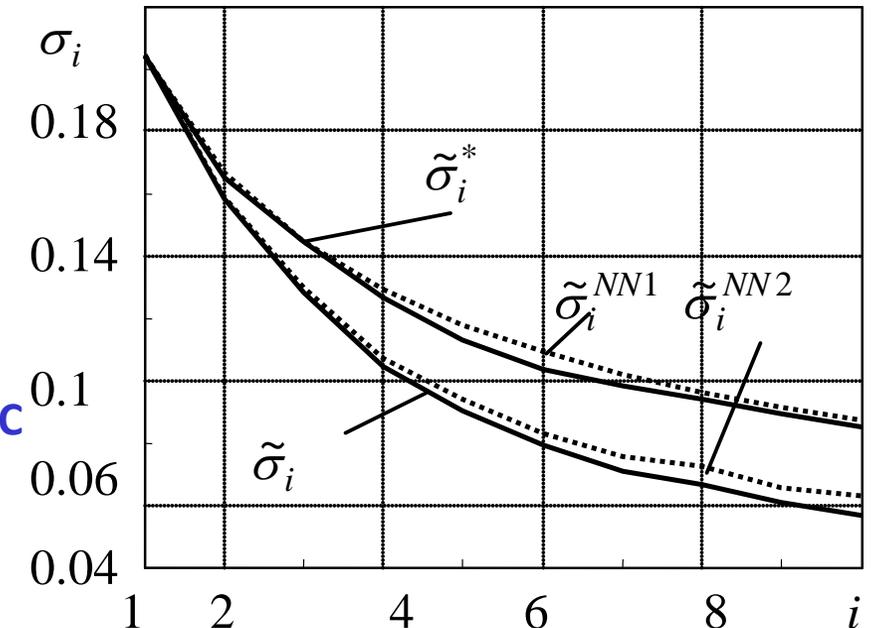
СКО:

$$\tilde{\sigma}_i^* \approx \sqrt{P_e^*} \quad \text{— для линейной оптимальной;}$$

$$\tilde{\sigma}_i \quad \text{— для нелинейной оптимальной;}$$

$$\tilde{\sigma}_i^{NN1} \quad \text{— для линейной НС;}$$

$$\tilde{\sigma}_i^{NN2} \quad \text{— для нелинейной НС}$$

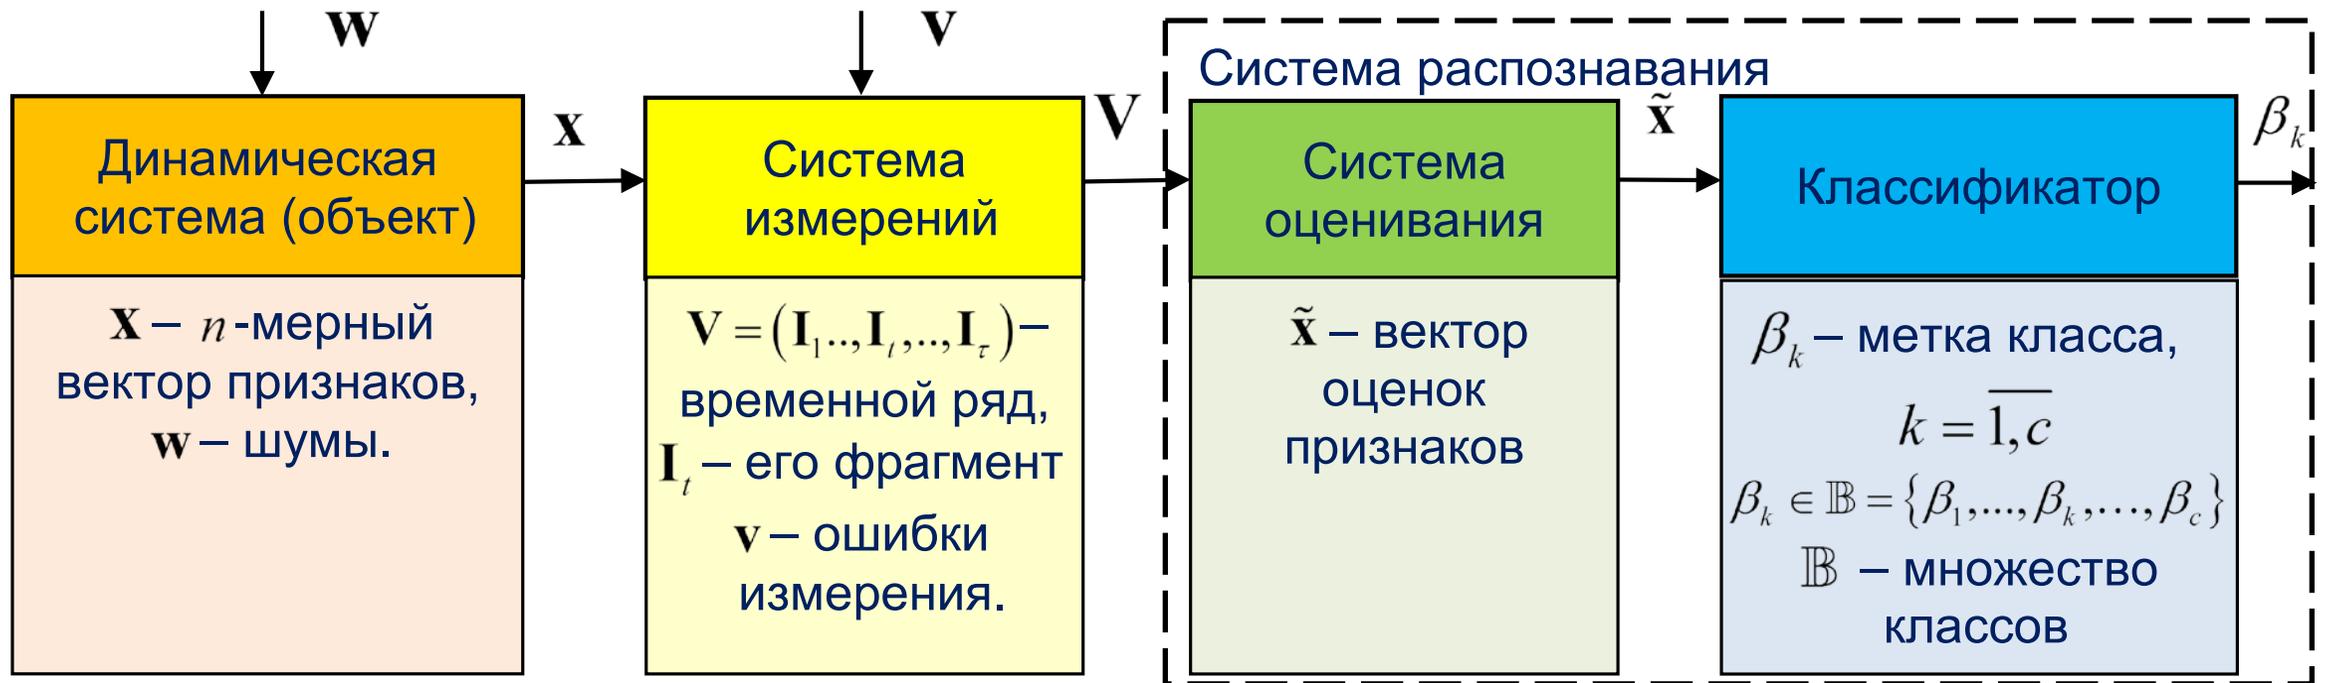


Результаты обучения систем с декомпозицией

Кол -во вхо дов	Время обучения алгоритма оценивания, с.							
	Искусственные нейронные сети						Нечеткая система	
	Сеть прямого распространения			Сеть с радиальными базисными функциями				
	LM		BR		RBF		ANFIS	
	исход- ная	с деком- пози- цией	исход- ная	с деком- пози- цией	исход- ная	с деком- пози- цией	исход- ная	с деком- пози- цией
1	50	7,22	7,063	7,25	$1,17 \times 10^4$	347,9	2,98	3,07
2	100	13,96	7,031	37,7	$1,2 \times 10^4$	280,4	10,19	9,31
3	90	15,07	41,55	16,27	$1,2 \times 10^4$	295,1	19,77	9,73
4	80	6,95	21,44	20,64	$1,19 \times 10^4$	309,9	67,61	9,7
5	90	15,98	27,28	39,47	$1,18 \times 10^4$	307,9	330,6	9,85
6	200	10,35	30,55	25,28	$1,17 \times 10^4$	285,9	2959	9,76
7	350	7,25	40,03	33,31	$1,19 \times 10^4$	308,4	$2,6 \times 10^4$	9,79
8	450	11,03	74,52	12,52	$1,2 \times 10^4$	313,5	-	9,72
9	350	7,21	17,25	13,14	$1,2 \times 10^4$	300	-	9,79
10	800	10,25	41,81	13,63	$1,2 \times 10^4$	300,4	-	9,64
Ср.	256	10,5	30,85	21,92	11940	304,9	4229	9

Скорость обучения декомпозиционных синтетических систем значительно, в несколько раз для НС (5–7) и порядков для НчС (3), выше скорости обучения исходных синтетических систем без декомпозиции.

Задача распознавания образов



Предметная область

1. Системы контроля и управления доступом (СКУД) транспортных средств и физических лиц.
2. Навигация и управление движением: траекторное слежение.
3. Информационная безопасность: распознавание аномальных ситуаций.

Образы для распознавания

- 1) транспортные средства и их номерные знаки;
- 2) люди и их лица;
- 3) штатные и нештатные, критические ситуации;
- 4) подвижные объекты траекторного слежения;
- 5) сетевые атаки.

Постановка задачи распознавания образов

Пусть имеются: – множество образов $\omega \in \Omega$, заданных признаками x_i , $i = \overline{1, n}$, совокупность которых для образа ω представлена векторными описаниями $\Phi(\omega) = (x_1(\omega), x_2(\omega), \dots, x_n(\omega)) = \mathbf{x}$;

– множество классов $\mathbb{B} = \{\beta_1, \beta_2, \dots, \beta_c\}$, c – количество классов.

Априорная информация представлена обучающим множеством (датасетом) $\mathbb{D} = \{(\mathbf{x}^j, \beta^j)\}$, $j = \overline{1, L}$, заданным таблицей, каждая строка j которой содержит векторное описание образа $\Phi(\omega)$ и метку класса β_k , $k = \overline{1, c}$.

Требуется по поступающим фрагментам \mathbf{I}_t временного ряда $\mathbf{V} = (\mathbf{I}_1, \dots, \mathbf{I}_t, \dots, \mathbf{I}_\tau)$ и априорной информации $\mathbb{D} = \{(\mathbf{x}^j, \beta^j)\}$, $j = \overline{1, L}$ для глубокого обучения НС с учителем, решить задачу распознавания образов: обнаружить образы ω в виде оценки признаков $\tilde{\mathbf{x}}$ с помощью отображения $\mathbf{F}_1: \mathbf{I}_t \rightarrow \tilde{\mathbf{x}}$ и классифицировать их с использованием отображения $\mathbf{F}_2: \tilde{\mathbf{x}} \rightarrow \beta_k$, $k = \overline{1, c}$ в соответствии с заданным критерием $P(\tilde{\mathbf{x}})$, минимизирующим вероятность ошибки. Таким образом, необходимо найти отображение $\mathbf{F}: \mathbf{I}_t \rightarrow \beta_k$, $k = \overline{1, c}$.

Вычислительный метод распознавания образов

1. Выделение из непрерывного видеопотока $\mathbf{V} = (\mathbf{I}_1, \dots, \mathbf{I}_t, \dots, \mathbf{I}_\tau)$ текущего кадра \mathbf{I}_t размером $w^{\mathbf{I}_t} \times h^{\mathbf{I}_t}$, где t – номер текущего кадра.

➤ 2. Поиск объектов слежения ω на кадре $\mathbf{f}_1: \mathbf{I}_t \rightarrow \mathbf{G}_t$, где \mathbf{G}_t – массив элементов, содержащий n обнаруженных объектов, их координаты и метки классов в кадре видеопотока.

3. Выделение областей интереса, содержащих объекты слежения $\mathbf{R}^{(1)} = \text{crop}(\mathbf{I}_t, x^\omega, y^\omega, w^\omega, h^\omega)$, где x^ω, y^ω – координаты центра ω -го объекта, w^ω, h^ω – его размеры, crop – операция вырезания из \mathbf{I}_t подматрицы по координатам $(x^\omega - w^\omega/2, y^\omega - h^\omega/2)$, $(x^\omega + w^\omega/2, y^\omega + h^\omega/2)$.

4. Локализация значимых областей объекта слежения. Уточнение области интереса для детализации информации об объекте $\mathbf{f}_2: \mathbf{R}^{(1)}, t \rightarrow \mathbf{R}^{(2)}$.

5. Выполнение предобработки каждой локализованной на этапе 4 области интереса, которая заключается в нормализации фрагментов изображения: $\mathbf{R}^{(2*)} = \mathbf{f}_3(\mathbf{R}^{(2)}, \mathbf{M}, \mathbf{g})$, где \mathbf{M} – матрица геометрических линейных и аффинных преобразований $\mathbf{R}^{(2)}$, \mathbf{g} – набор матричных функций и их параметров для яркостных и контрастных преобразований $\mathbf{R}^{(2)}$.

Вычислительный метод распознавания образов

В случае с видеофрагментом необходимо выполнить предобработку каждого кадра из $\mathbf{R}_k^{(2)} = [\mathbf{I}_t, \mathbf{I}_{t+1}, \dots, \mathbf{I}_{t+i-1}]$ при помощи алгоритма устранения помех и нечеткой логики, результатом которых будет предобработанная область интереса $\mathbf{R}_k^{(2*)} = [\mathbf{R}_{k_t}^{(2*)}, \mathbf{R}_{k_{t+1}}^{(2*)}, \dots, \mathbf{R}_{k_{t+i-1}}^{(2*)}]$.

➤ 6. Выделение информативных признаков из $\mathbf{R}^{(2*)}$ путем обработки кадра сверточной НС: $\Phi^{\text{НС}} : \mathbf{R}^{(2*)} \rightarrow \tilde{\mathbf{x}}$, где $\tilde{\mathbf{x}}$ – область интереса, переведенная в признаковое пространство сверточной НС.

➤ 7. Классификация объекта в соответствии с заданным критерием: отнесение вектора признаков объекта к одному из классов с помощью отображения $\mathbf{f}_4 : \tilde{\mathbf{x}} \rightarrow \mathbf{p}_{\tilde{\mathbf{x}}}$, где $\mathbf{p}_{\tilde{\mathbf{x}}}$ – вектор размером $c \times 1$, содержащий вероятности классификации, c – количество классов.

Критерий классификации определяется как $J(\mathbf{f}_4) = \max \mathbf{p}_{\tilde{\mathbf{x}}}$. Если $J(\mathbf{f}_4) \geq \varepsilon$, где ε – заданный порог, то $\beta_k = \arg \max_{k \in 1..c} (\mathbf{p}_{\tilde{\mathbf{x}}_k})$, в противном случае классификация считается ошибочной.

Классификация ситуаций, связанных с перекрытием и исчезновением объектов, выполняется в соответствии с условиями из базы знаний:

$$s = \mathbf{F}_4(\mathbf{G}_t) = \begin{cases} 1, & \text{если } \mathbf{G}_t \in \mathbf{D}^{\text{normal}} \\ 0, & \text{если } \mathbf{G}_t \notin \mathbf{D}^{\text{normal}} \end{cases} .$$

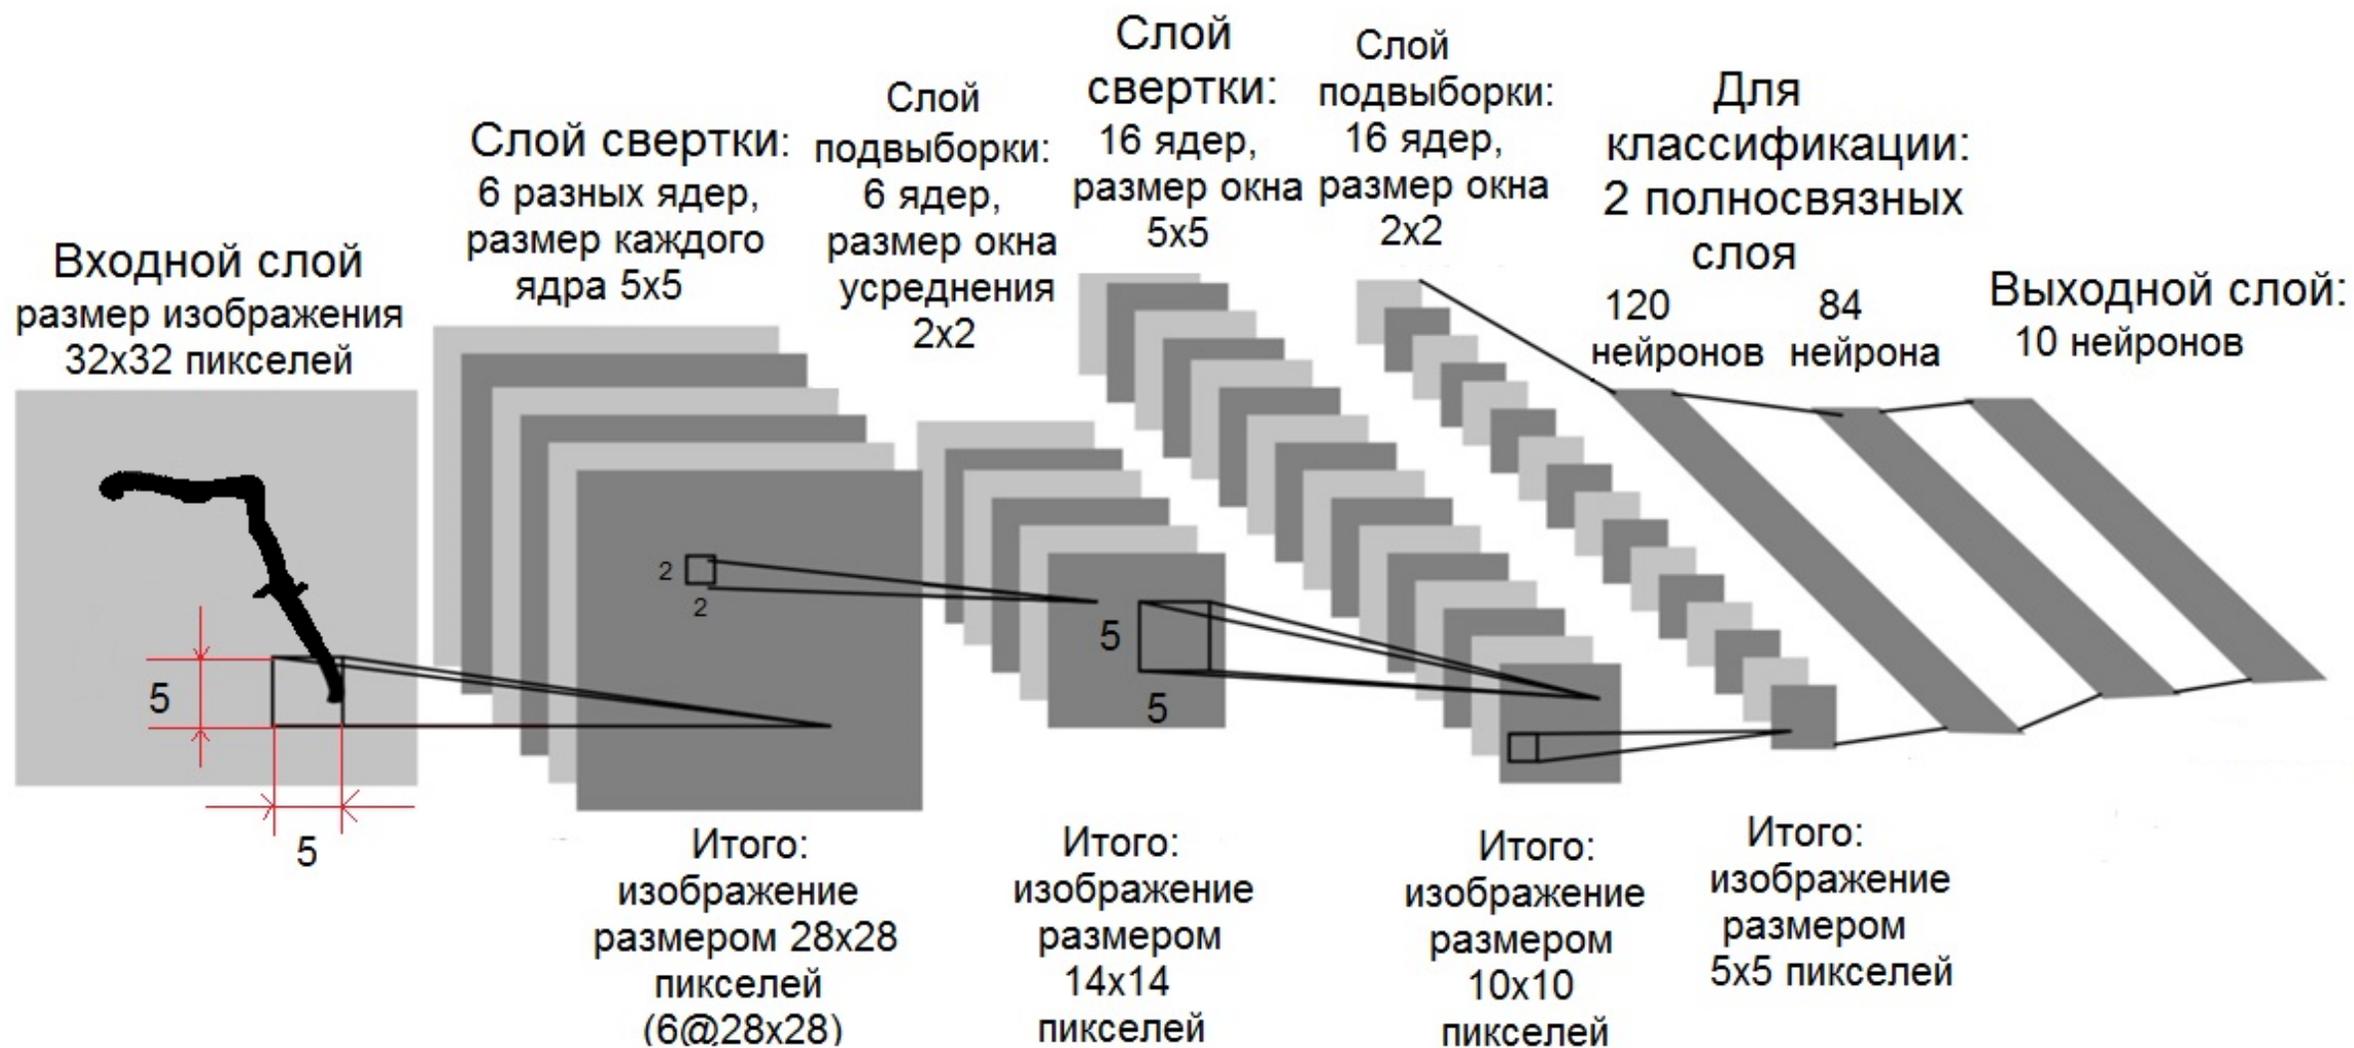
Характеристики точности метода

Точность (англ. Precision)	$M^{Pr}(TP, FP) = \frac{TP}{TP + FP}$	Площадь под кривой ошибок (англ. Area Under Curve, AUC)	$M^{AUC}(TP, FN, FP, TN) = \int_0^1 M^{TPR} dM^{FPR}$
Общая точность (англ. Accuracy)	$M^{AC}(TP, TN, FN) = \frac{TP + TN}{TP + TN + FP + FN}$	Полнота (англ. Recall)	$M^{Rec}(TP, FN) = \frac{TP}{TP + FN}$
Доля истинно-положительных срабатываний (англ. True positive rate, TPR)	$M^{TPR}(TP, FN) = \frac{TP}{TP + FN}$	F-мера	$M^F(TP, TN, FN) = 2 \frac{M^{Pr} \cdot M^{Rec}}{M^{Pr} + M^{Rec}}$
Доля ложно-положительных срабатываний (англ. False positive rate, FPR)	$M^{FPR}(FP, TN) = \frac{FP}{TN + FP}$	<p>TP – количество истинно-положительных решений, TN – количество истинно-отрицательных решений, FP – количество ложноположительных решений, FN – количество ложноотрицательных решений.</p>	

Почему НС глубокого обучения?

1. Дают высокую точность распознавания.
2. Способны к обучению и дообучению. Обучение с подкреплением (метод проб и ошибок).
3. Способность выявлять существенные признаки из больших массивов данных.

Пример глубокой сверточной сети LeNet-5 (Ян Лекун)



Слои глубоких НС

Слой свертки	$\mathbf{h}_{conv}^l = \sigma (\mathbf{h}^{l-1} \cdot \mathbf{K} + b_{conv}),$ <p>где \mathbf{h}_{conv}^l – выход слоя свертки, σ – функция активации, b_{conv} – коэффициент сдвига, \mathbf{K} – ядро свертки</p>
Слой подвыборки	$\mathbf{h}_{pool}^l = \sigma(a_{pool} \cdot s^{MaxPool}(\mathbf{h}^{l-1}) + b_{pool}),$ <p>где \mathbf{h}_{pool}^l – выход слоя, σ – функция активации, a_{pool}, b_{pool} – коэффициенты, s – операция выборки, в данном случае операция выборки локальных максимальных значений</p>
Слой полносвязанной нейронной сети	$h_{conn_j}^l = \sigma \left(\sum_i h_i^{l-1} \cdot W_{ij}^{l-1} + b_{conn_j}^{l-1} \right)$ <p>где h_i^{l-1} – выходной сигнал нейрона предыдущего слоя размером $L \times 1$; b_{conn_j} – скалярный коэффициент сдвига; \mathbf{W} – матрица весовых коэффициентов размером $i \times j$; σ – функция активации.</p>
Слой нормализации	$\mathbf{h}_{bn}^l = a_{bn} \frac{\mathbf{h}^{l-1} - \frac{1}{m} \sum_{i=1}^m \mathbf{h}^{l-1}}{\sqrt{\frac{1}{m} \sum_{i=1}^m \left(\mathbf{h}^{l-1} - \frac{1}{m} \sum_{i=1}^m \mathbf{h}^{l-1} \right)^2 + e}} + b_{bn},$ <p>где \mathbf{h}^{l-1} – выход предыдущего слоя; m – количество примеров, обработанных предыдущим слоем; b_{bn} – коэффициент сдвига; a_{bn} – коэффициент масштабирования.</p>
Слой выравнивания	$\mathbf{h}_{flat}^l = vec(\mathbf{h}^{l-1})$ <p>vec – операция векторизации, т.е. линейного преобразования матрицы в вектор-столбец; \mathbf{h}_{flat}^l – выход слоя векторизации l;</p>

LSTM	GRU
Долгая краткосрочная память (Long short-term memory)	Управляемые рекуррентные нейроны (Gated recurrent units)
Сеть, способная запоминать значения как на короткие, так и на длинные промежутки времени.	Сеть, способная заменять старые значения на новые. Фильтр «забывания» и фильтр входа объединен в один фильтр «обновления» (update gate).

Особенности применения глубоких НС в вычислительном методе

Этапы Тип объекта	2 этап: Обнаружение типа объекта	6 и 7 этапы: Оценка признаков и классификация объекта
ТС	НС YOLO (80 классов), AlexNet (1000 классов)	Адаптированная глубокая НС MobileNet v2 с функцией активации Softmax для классификации.
Человек	НС YOLO (80 классов), AlexNet (1000 классов)	Адаптированная глубокая НС MobileNet v2 с функцией активации Sigmoid для классификации.
Ситуации	НС SegNet	Предобученная (англ. pretrained) глубокая НС Inception v3 для кодирования видеопоследовательностей и глубокая НС с комбинациями слоев свертки и независимых рекуррентных слоев IndRNN для классификации.

Адаптация глубоких НС под решаемые задачи

Характеристики	Наименование базовой глубокой нейронной сети			
	MobileNet v2 для номерного знака ТС	MobileNet v2 для лица человека	Для ситуаций	
			Inception v3	IndRNN
Особенность	Не требует больших вычислительных ресурсов. Разработана для мобильных приложений.		Выделение признаков	Ограниченный объем данных. Не требует значительных вычислительных ресурсов. Позволяет выявить закономерности в последовательности векторов фиксированного размера.
Адаптация	1. Адаптация входного слоя под объекты задач. 2. Изменение количества слоев. 3. Переобучение.		Добавление к последнему слою операции GlobalAveragePooling	Сеть составлена комбинацией слоев свертки и рекуррентных слоев IndRNN
Обучающее множество	Собственный промаркированный датасет для символов H3 15489, тестирующая выборка по символам H3 3089 и 2453 видеофрагментов с ТС и без	Датасет CASIA-WebFace	Датасет UCF Crime для формирования множества классов, содержащий 1800 видеофрагментов штатных и нештатных ситуаций продолжительностью от 7 до 900 с. Датасет был адаптирован под 5 классов	Датасет MS COCO для аннотирования

Постановка и решение задачи контроля и управления доступом объектов

Пусть имеются вектор состояний СКУД $\mathbf{x} = (\mathbf{x}_{\text{ОД}}^T, \mathbf{x}_{\text{КН}}^T, x_{\text{УПУ}}, x_{\text{УВП}}, \mathbf{x}_{\text{ВС}}^T)^T$ и вектор выходных сигналов (измерений) $\mathbf{y} = (\mathbf{y}_{\text{ОД}}^T, y_{\text{НВ}}, y_{\text{УПУ}}, y_{\text{УВП}}, \mathbf{y}_{\text{ВС}}^T)^T$. Необходимо по результатам наблюдений \mathbf{y} состояний ОД \mathbf{x} выработать оценки состояний $\tilde{\mathbf{x}}$ и необходимые управляющие воздействия \mathbf{u} на объект управления, $\mathbf{u} = (u_{\text{УПУ}}, u_{\text{УВП}}, u_{\text{БД}})^T$. $\mathbf{x} \in \mathbb{X}$, $\tilde{\mathbf{x}} \in \tilde{\mathbb{X}}$, видеопоток $\mathbf{V} \in \mathbb{V}$, $\mathbf{y} \in \mathbb{Y}$ и $\mathbf{u} \in \mathbb{U}$. \mathbb{T} – множество моментов времени, тогда $t \in \mathbb{T}$ – произвольный момент времени. Функциональные зависимости на \mathbb{X} , \mathbb{Y} и \mathbb{U} могут быть представлены в виде отображений «вход-состояние» $\mathbf{F}_1: \mathbb{T} \times \mathbb{U} \rightarrow \mathbb{X}$ и «состояние-выход» $\mathbf{F}_2: \mathbb{T} \times \mathbb{X} \rightarrow \mathbb{Y}$, то есть: $\mathbf{y}(t) = \mathbf{F}_2(\mathbf{F}_1(\mathbf{u}(t)))$.

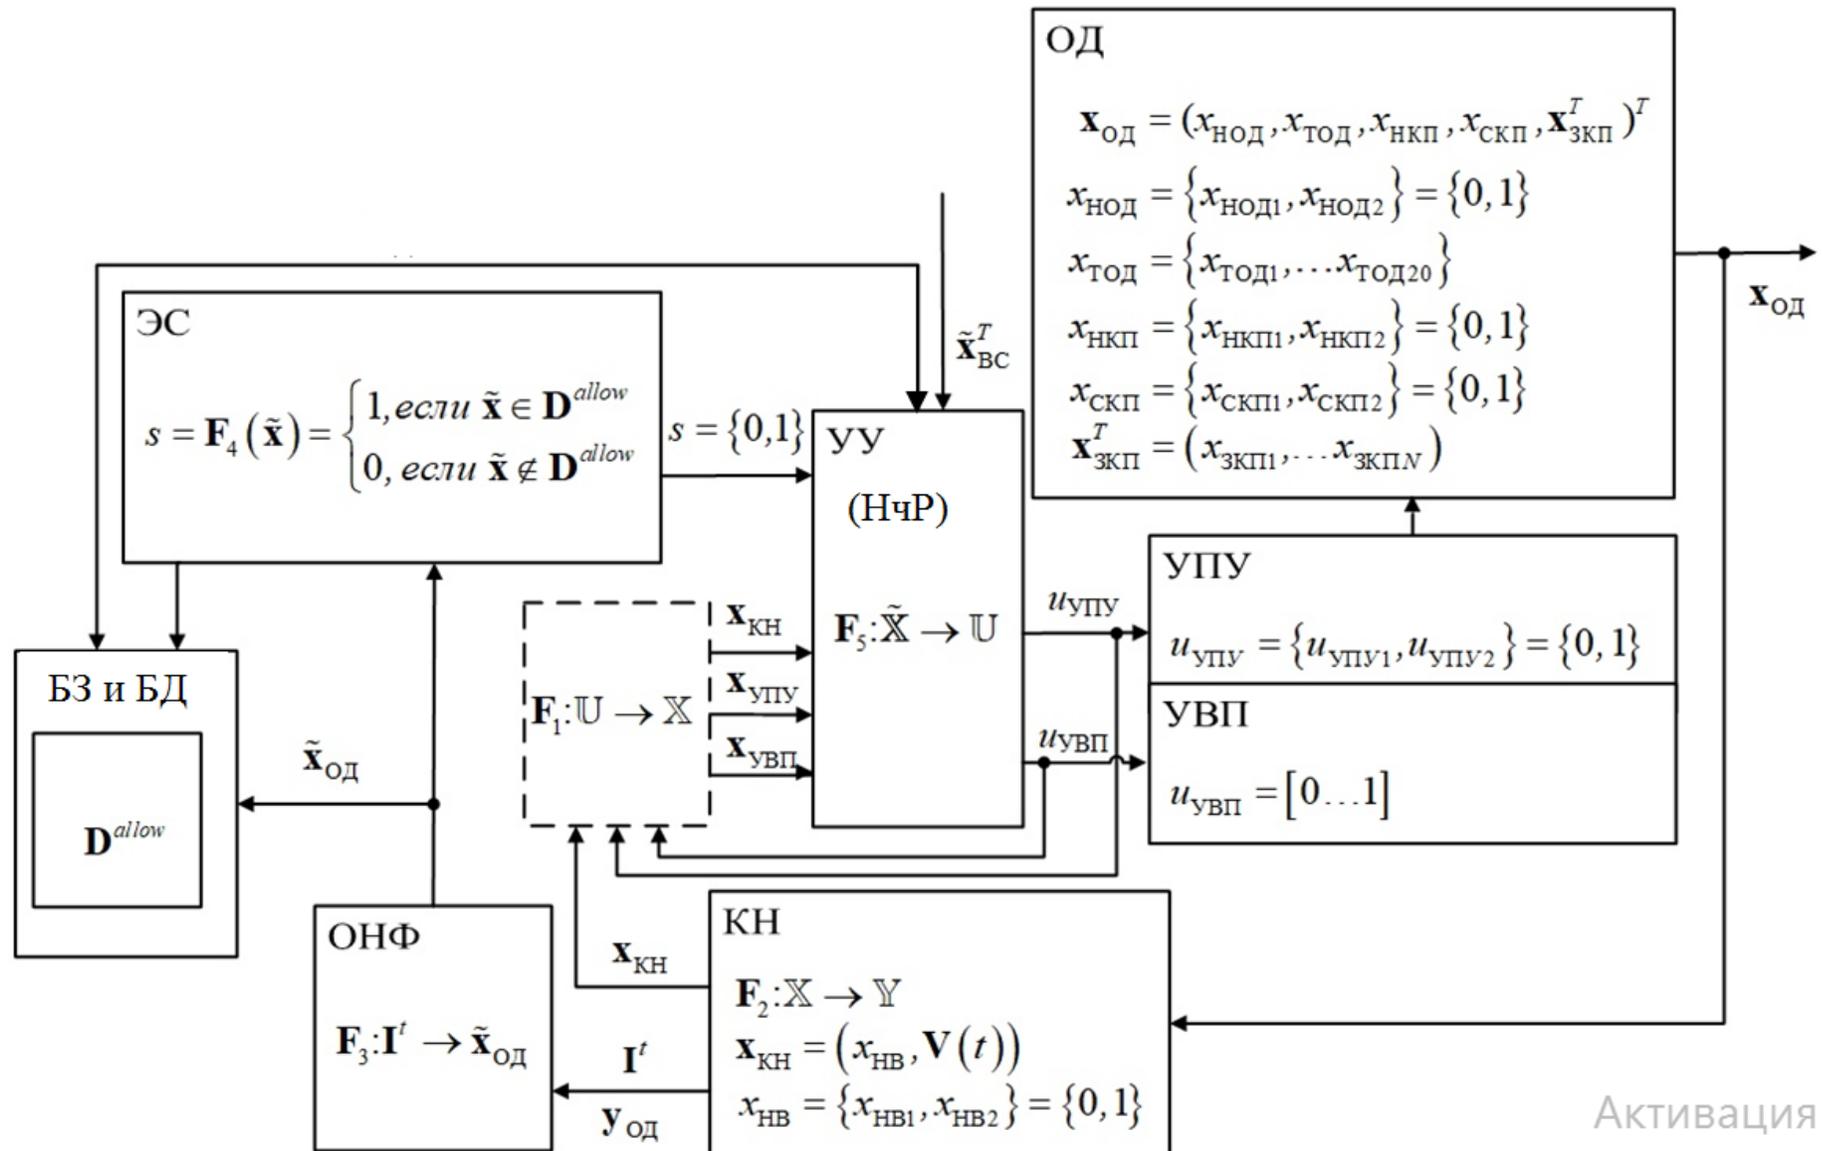
Таким образом, ставится задача по кадру видеопотока определить состояние системы, включающее наличие объекта доступа (НОД), тип объекта доступа (ТОД), наличие кодового признака (НКП), состояние качества кодового признака (СКП) и его значение (ЗКП) с использованием отображения: $\mathbf{F}_3: \mathbb{V} \rightarrow \tilde{\mathbb{X}}$. Тогда отображение \mathbf{F}_3 , реализующее функцию оптимального нелинейного фильтра (НФ) для оценки состояния ОД, можно представить в виде $\tilde{\mathbf{x}}_{\text{ОД}} = \mathbf{F}_3(\mathbf{I}^t)$,

$$\tilde{\mathbf{x}}_{\text{ОД}} = (\tilde{x}_{\text{НОД}}, \tilde{x}_{\text{ТОД}}, \tilde{x}_{\text{НКП}}, \tilde{x}_{\text{СКП}}, \tilde{\mathbf{x}}_{\text{ЗКП}}^T)^T.$$

Воздействия \mathbf{u} на устройства управления УВП и УПУ описываются отображением $\mathbf{F}_5: \tilde{\mathbb{X}} \rightarrow \mathbb{U}$.

$\mathbf{x}_{\text{ОД}}^T$ – вектор состояний объекта доступа; $y_{\text{НВ}}$ – наличие кадра с КН; $\mathbf{I}^t = \mathbf{V}(t)$ – видеопоток с КН; $\mathbf{x}_{\text{КН}}^T$ – вектор состояний камеры наблюдения; \mathbf{V} – представленного многомерным массивом; $x_{\text{УПУ}}$ – состояние управляемого устройства; $\mathbf{y}_{\text{ОД}}^T$ – сигнал с КН, причем $\mathbf{y}_{\text{ОД}}^T = \mathbf{I}^t$; $x_{\text{УВП}}$ – состояние устройства внешней подсветки; $y_{\text{УПУ}}$ – сигнал с УПУ; $y_{\text{УВП}}$ – сигнал с УВП; $\mathbf{x}_{\text{ВС}}^T$ – вектор состояний внешней среды; $\mathbf{y}_{\text{ВС}}^T$ – вектор сигналов с датчиков, фиксирующих состояние ВС. $u_{\text{УПУ}}$ – сигнал на открытие или закрытие УПУ; $u_{\text{УВП}}$ – сигнал на УВП; $u_{\text{БД}}$ – сигнал на запись события в БД.

Структурная схема СКУД объектов слежения



Активация '
Чтобы активир

Нечеткий регулятор. База знаний

Пусть имеются входные X_1 – "Погода", X_2 – "Время суток", X_3 – "Освещение", X_4 – "Движение", X_5 – "Температура" и выходные лингвистические переменные Y_1 – "Зашумленность", Y_2 – "Режим день или ночь", Y_3 – "Подсветка", Y_4 – "Обогрев", Y_5 – "Автофокус", Y_6 – "Очистка от шумов". Введем терм-множества:

- 1) $X_1 = \{\text{ясно, пасмурно, дождь, сильный дождь, снег, сильный снег}\}$ или $X_1 = [x_{11}, x_{12}, \dots, x_{16}]$,
- 2) $X_2 = \{\text{утро, день, вечер, ночь}\}$ или $X_2 = [x_{21}, x_{22}, \dots, x_{24}]$,
- 3) $X_3 = \{\text{светло, сумеречно, темно}\}$ или $X_3 = [x_{31}, x_{32}, x_{33}]$,
- 4) $X_4 = \{\text{низкое, высокое}\}$ или $X_4 = [x_{41}, x_{42}]$,
- 5) $X_5 = \{\text{очень холодно, холодно, не очень холодно, нормально}\}$ или $X_5 = [x_{51}, x_{52}, \dots, x_{54}]$

- 6) $Y_1 = \{\text{шум, средний шум, высокий шум}\}$ или $Y_1 = [y_{11}, x_{12}, y_{13}]$,
- 7) $Y_2 = \{\text{ночь, день}\}$ или $Y_2 = [y_{21}, x_{22}]$,
- 8) $Y_3 = \{0, 1, 2, 3\}$ (номер отвечает за уровень подсветки) или $Y_3 = [y_{31}, x_{32}, \dots, y_{34}]$,
- 9) $Y_4 = \{0, 1, 2, 3, 4\}$ (номер отвечает за уровень обогрева) или $Y_4 = [y_{41}, y_{42}, \dots, y_{45}]$,
- 10) $Y_5 = \{0, 1\}$ или $Y_5 = [y_{51}, x_{52}]$,
- 11) $Y_6 = \{0, 1\}$ или $Y_6 = [y_{61}, x_{62}]$.

Алгоритм вывода Мамдани, состоит из 85 правил и реализуется в среде MatLab.

Соответствующая база правил состоит из набора нечетких «*If-then*» правил в следующей

форме:

$R_k : \text{If } X \text{ is } X_k, \text{ then } Y \text{ is } Y_k ; k = \overline{1, \lambda}$

Пример: *Если* погода – дождь или снег, время суток – утро или день, или вечер, освещенность – сумеречно, движение – высокое, *то* зашумленность – шум, режим на камере – день, внешняя подсветка – 2, автофокус – 1 и очистка от шумов – 1.

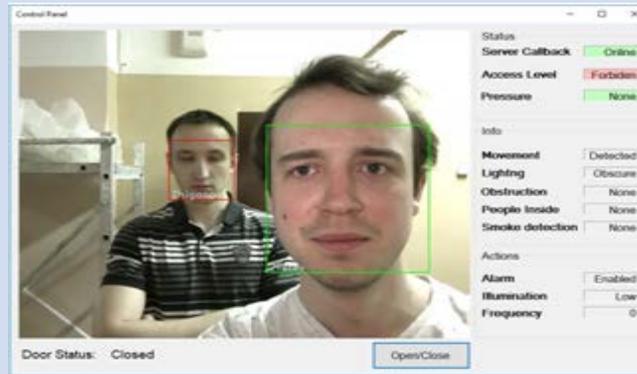
Задачи распознавания образов

Контроль и управление доступом трансп. средств



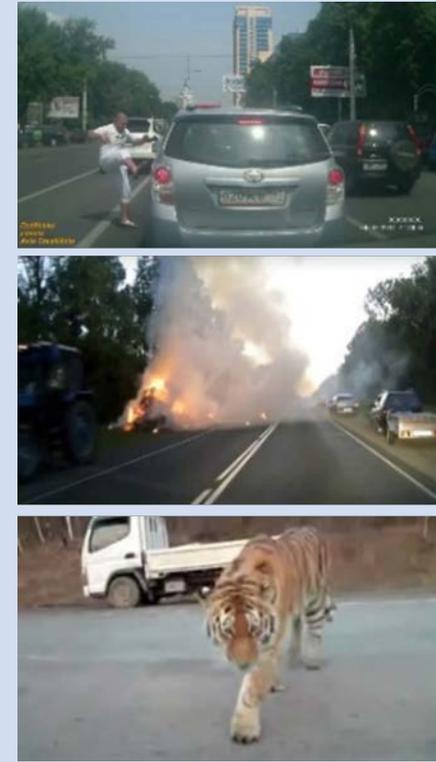
$M^{AC} = 96\%$

Контроль и управление доступом физических лиц



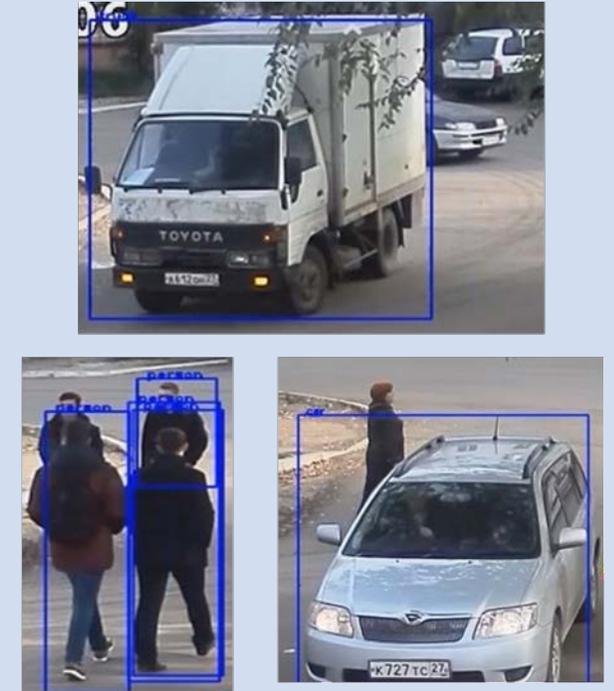
$M^{AC} = 93\%$, $M^{Pr} = 98\%$,
 t обучения = 5 дней

Критические ситуации



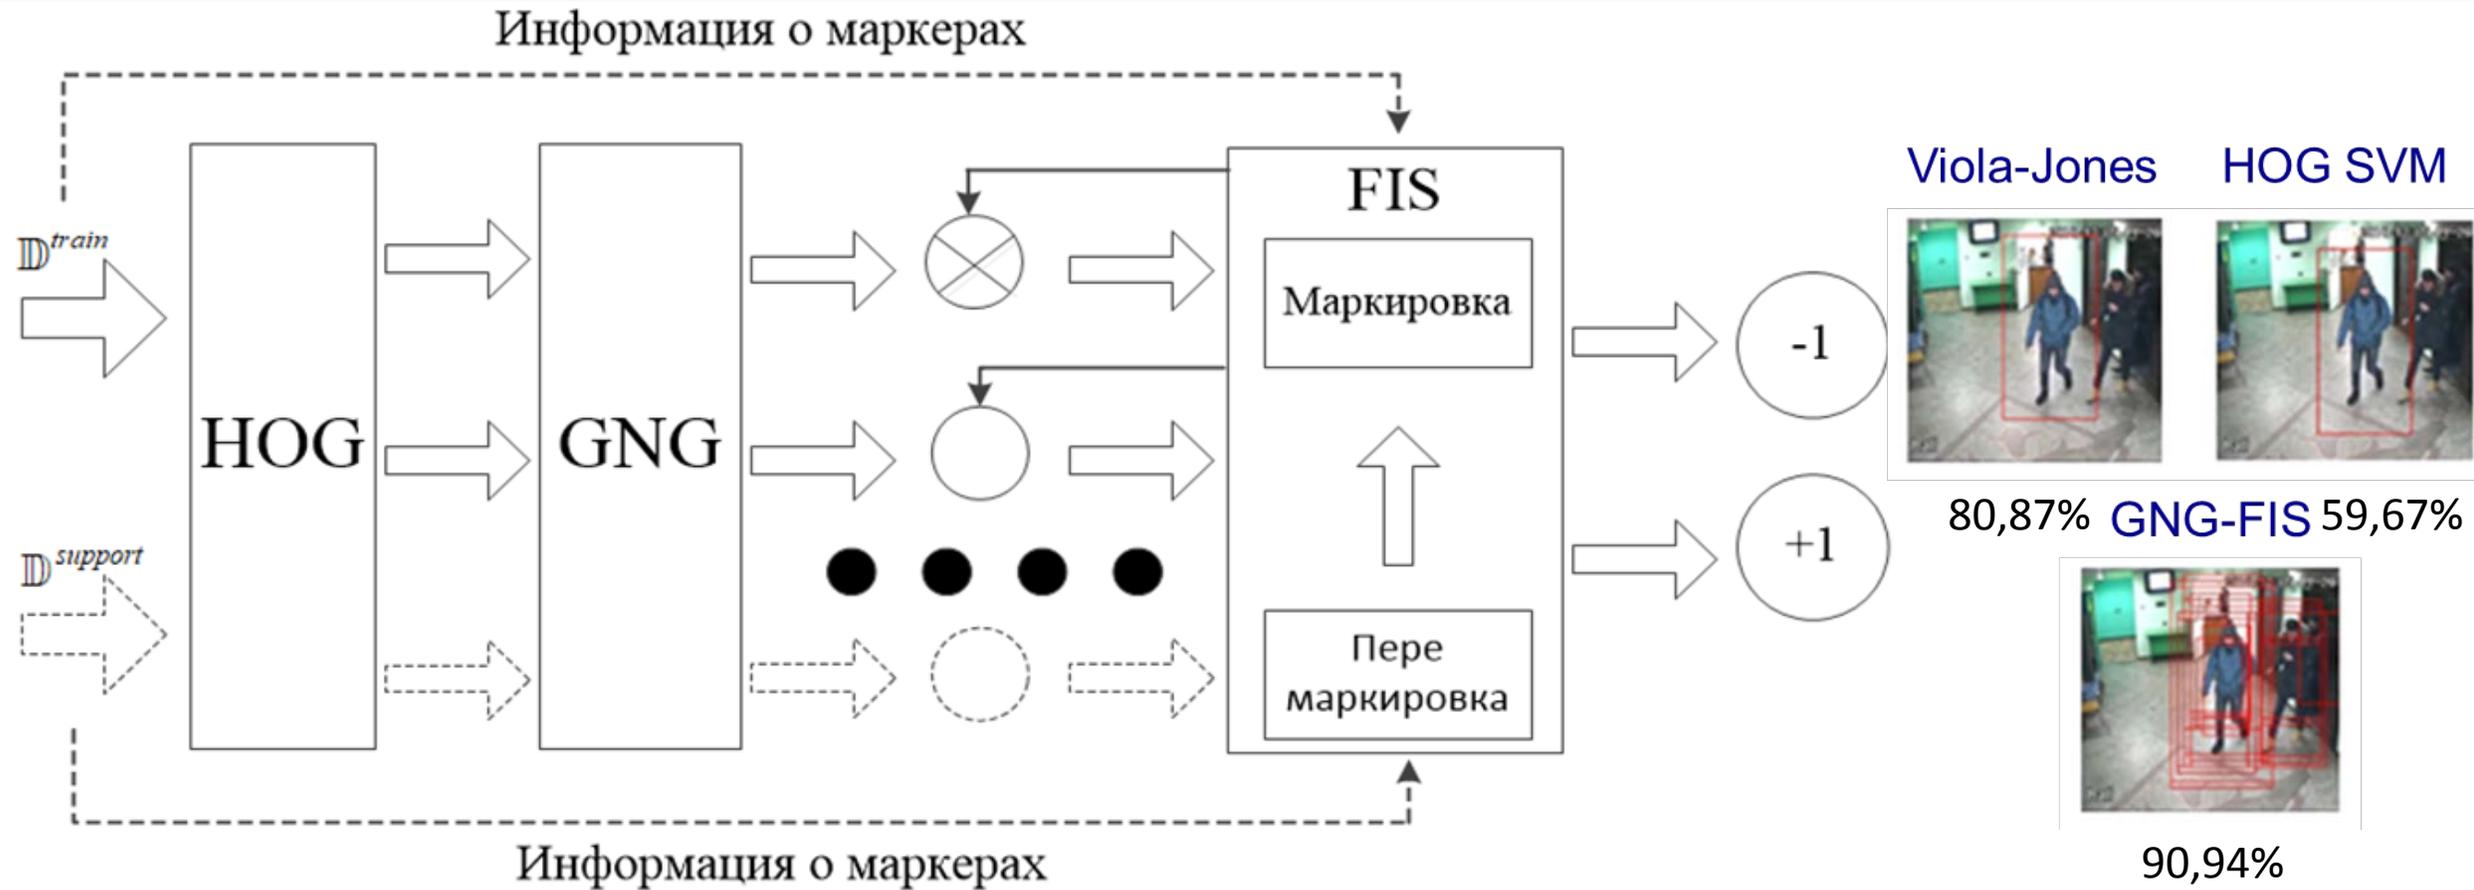
Точность бинарной классификации составила 80%,
 t обучения = 24 ч. $M^{AC} = 65\%$

Траекторное слежение за объектами



Конфигурация ПК: центральное и графическое процессорных устройств Intel Core i7-5820K и Nvidia GeForce 1080Ti, объем видеопамати 11 Гб . GPU Nvidia Jetson TX2. Raspberry pi. Управляемая видеокамера (Full HD 1920*1080)

Задача локализации объекта



Локализация человека в кадре видеопотока с помощью нейросетевого алгоритма расширяющегося нейронного газа (GNG) и признакового описания на основе гистограмм ориентированных градиентов (HOG) с его модификацией за счет нечеткой логики (FIS), отличающегося использованием двухпроходного обучения с нечеткой перемаркировкой классов и построением тепловой карты.

Заключение и перспективы

1. В качестве альтернативных методов представлены нейросетевые и нечеткие методы оценивания стохастических процессов.

В дальнейшем перспективным представляется сопоставление традиционных методов оценивания с нейросетевым методом, основанном на глубоком обучении. Отдельного рассмотрения требуют глубокие рекуррентные нейронные сети.

2. Рассмотрены решения задачи распознавания образов на основе глубоких нейронных сетей.

Необходима дальнейшая теоретическая проработка нейросетевого метода распознавания на основе глубоких нейронных сетей с целью его сопоставления с традиционными методами для выявления их достоинств и недостатков.



ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ
БЮДЖЕТНОЕ УЧРЕЖДЕНИЕ НАУКИ
**ИНСТИТУТ
ПРОБЛЕМ
УПРАВЛЕНИЯ**
ИМ. В.А. ТРАПЕЗНИКОВА
РОССИЙСКОЙ АКАДЕМИИ НАУК

Нейросетевые и нечеткие методы оценивания и распознавания стохастических процессов

В работах по данной тематике принимали участие:

Амосова С.Г., к.т.н.

Магола Д.С., к.т.н., доцент

Иванов Ю.С., к.т.н.

Жиганов С.В., аспирант

Зверев Д.А., программист



ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ
БЮДЖЕТНОЕ УЧРЕЖДЕНИЕ НАУКИ
**ИНСТИТУТ
ПРОБЛЕМ
УПРАВЛЕНИЯ**
ИМ. В.А. ТРАПЕЗНИКОВА
РОССИЙСКОЙ АКАДЕМИИ НАУК

Спасибо за внимание!

Ученый совет ИПУ РАН, 01.04.2019