

УДК 004.932.2

Ю.И. Бабич, канд. техн. наук, Н.И. Бабич, канд. техн. наук,  
А.А. Якимов, д-р техн. наук, Л.В. Бовнегра, канд. техн. наук,  
Одесса, Украина

## **МОДЕЛЬ ПОИСКА ПРИЧИННО-СЛЕДСТВЕННЫХ СИГНАЛОВ НА ИЗОБРАЖЕНИЯХ**

*У статті проаналізовано причинно-наслідкові сигнали в наборі статичних зображень. Побудовано класифікатор пошуку, який забезпечує стан часових характеристик при пошуку причинного напрямку між парами випадкових величин і використовується для ефективного пошуку відмінності між особливостями об'єктів і особливостями їх контекстів у наборі статичних зображень.*

**Ключові слова:** зображення, причинно-наслідковий зв'язок, об'єкт, контекст, причинна характеристика об'єкта, безпричинна характеристика об'єкта, класифікатор

*В статье проанализированы причинно-следственные сигналы в наборе статических изображений. Построен поисковик-классификатор, который обеспечивает состояния временных характеристик при поиске причинно-следственного направления между парами случайных величин и используется для эффективного поиска отличия между особенностями объектов и особенностями их контекстов в наборе статических изображений.*

**Ключевые слова:** изображение, причинно-следственная связь, объект, контекст, причинная характеристика объекта, беспричинная характеристика объекта, классификатор

*The article analyzes causal signals in the set of static images. Built a search engine, a classifier that provides the status of temporal search for the causal direction between pairs of random variables and is used to efficiently find the differences between the features of objects and their contexts in the set of static images.*

**Keywords:** image, causation, object, context, causal characteristics of the object, nameless object description, classifier

Изображения, сделанные различными оптико-электронными системами и зарегистрированные с помощью разнообразных приёмников искажаются действием помех. Искажения изображения вносятся разными компонентами отображающего прибора и называются электронный шум. Помехи затрудняют визуальный анализ изображения и его компьютерную обработку.

В качестве примера в статье рассмотрено изображение моста над рекой, по которому едет автомобиль по правой полосе. Вопрос: «*Есть ли автомобиль на изображении?*»

Чаще всего для ответа на подобные вопросы используются алгоритмы усиления взаимосвязи между пикселями и характеристиками изображения. При анализе изображения необходимо учитывать, как оно будет изменяться при разного рода вмешательствах. В данной статье в качестве вмешательства используется удаление объекта.

С этой целью рассмотрены два гипотетических вопроса: *«Как выглядело бы изображение, если убрать автомобиль?»* и *«Как бы выглядело изображение, если убрать мост?»*. В первом случае можно утверждать, что другие детали изображения (река, мост) останутся такими же, если автомобиль убрать. С другой стороны, при втором вмешательстве, если убрать мост, то нет смысла в автомобиле, подвешенном над рекой. Таким образом, удаление моста с изображения отразится на автомобиле, находящемся на нём. На основании этого возникает другой вопрос: *«Почему на этом изображении есть автомобиль?»*.

Ответ заключается в причинно-следственных связях между мостом и автомобилем [1].

Причинные характеристики – это те, что являются причиной наличия интересующего нас объекта на изображении (то есть те особенности, которые обуславливают причину метки класса объекта), в то время как непрчинные характеристики вызваны присутствием объекта на изображении (то есть, вызваны меткой класса объекта).

Существует вероятность того, что объект на изображении распространяет асимметричные причинные связи. Эти причинные связи могут существенно отличаться от тех, которые используют современные алгоритмы компьютерной обработки изображений. Например, большинство изображений с автомобилем содержат дорогу. Таким образом, в данном случае, характеристики автомобилей и характеристики дорог будут взаимосвязаны, и, следовательно, характеристики дорог частично характеризуют автомобиль, что является независимыми одинаковыми распределениями (НОР) настроек [1]. Однако, должен ли автомобиль, тонущий в реке, получить низкую «оценку автомобиля» от предложенного алгоритма распознавания объектов, если это нестандартный контекст? Ответ зависит от применения. Если цель – максимизировать среднюю оценку распознавания объекта в тестовом наборе, который имеет то же распределение, что и тренировочный набор, тогда нужно использовать контекст принятия решения. Цель данной статьи – исследовать не НОР ситуации, которые требуют вмешательства.

Существующие алгоритмы распознавания объектов предоставляют неполную информацию о причинно-следственных связях между характеристиками изображения. По этим причинам, обнаружение причинно-следственных сигналов в изображениях представляет большой интерес.

При отсутствии каких-либо предположений, определение причинных связей между случайными величинами искомых объектов из их совместного распределения в принципе невозможно [2]. В частности, любое совместное распределение по двум случайным величинам  $A$  и  $B$  согласуется с любой из следующих трех причинно-следственных структур:  $A$  вызывает  $B$ ,

$B$  вызывает  $A$ , и  $A$  и  $B$  вызваны ненаблюдаемым фактором  $C$ , влияющим на результат [1].

В реальных ситуациях в совместных распределениях разные причинные интерпретации могут происходить с неодинаковой вероятностью. Эти данные используются для построения классификатора определения причинно-следственных связей между двумя случайными переменными из их совместного распределения.

Эксперименты показали, что статистика наборов данных более высокого порядка указывает на причинно-следственные отношения.

Введём предположение, что причинные характеристики объекта и беспричинные характеристики тесно связаны между собой. Характеристики контекста и причинные характеристики не должны быть обязательно связаны между собой. Эмпирические доказательства в поддержку предположения подтверждаются причинно-следственной связью и наличием отличий между объектами и их контекстами.

$f \sim P_f$	$f \sim P_f$
for $j = 1, \dots, m$ do	for $j = 1, \dots, m$ do
$x_j \sim P_c$	$y_j \sim P_c$
$e_j \sim P_c$	$e_j \sim P_c$
$y_i \leftarrow f(x_j) + e_j$	$x_i \leftarrow f(y_j) + e_j$
end for	end for
returns $S = \{(x_j, y_j)\}_{j=1}^m$	returns $S = \{(x_j, y_j)\}_{j=1}^m$
Модель, где $X \rightarrow Y$	Модель, где $X \leftarrow Y$

Рисунок 1 – Дополнительные причинно-следственные модели шума

Наилучшим образом для изучения причинно-следственных связей служат смешанные эксперименты как стандарт причинного вывода [2]. Однако, в большинстве случаев, эксперименты являются финансово затратными. В таких ситуациях, мы должны различать причины и следствия только по данным наблюдений без возможности вмешательства [3]. Это область наблюдательного причинного логического вывода.

В своей простейшей форме, наблюдательные причинные логические выводы [2, 3] рассматривают данные наблюдений и стремятся сделать вывод в случаях  $X \rightarrow Y$  или  $Y \rightarrow X$ .

$$Q = \{(x_i, y_j)\}_{j=1}^m \sim P^m(X, Y). \quad (1)$$

В частности, предполагается, что  $Q$  принадлежит одной из двух моделей: причинной модели, где  $X \rightarrow Y$  или беспричинной модели, где  $Y \rightarrow X$ . Рис. 1 иллюстрирует такие модели [2], в которых переменной действия является шумовая реализация нелинейной функции от переменной причины. Если не делаются предположений о распределении  $P_f$ ,  $P_c$ , и  $P_e$ , представленная на рис. 1 проблема наблюдения причинно-следственных отношений не идентифицируется [3]. Для решения этой проблемы, мы предполагаем, что всякий раз, если  $X \rightarrow Y$ , то причины, шумы и механизмы взаимно независимы. Первая независимость между причиной и механизмом (НПМ) [1, 4], которая оформляется не как независимость между вводимой переменной  $x$  и механизмом  $f$ , а как независимость между источником данных (то есть, распределением  $P(X)$  и механизмом  $P(Y|X)$ ), отображая причину действия. Это может быть оформлено или с помощью вероятности, или с точки зрения алгоритмической сложности [1]. Вторая независимость – между причиной и шумом. Это стандартное предположение в моделировании структурных уравнений, и это связано с причинной достаточностью. Если это предположение нарушено, то в причинную модель необходимо включить дополнительные переменные [2].

Для большинства вариантов ( $P_c$ ,  $P_e$ ,  $P_f$ ) НПМ будут нарушены в не причинной области. Это нарушение связано со статистической обработкой, когда исходя из наблюдений, причины и следствия являются разными. Существует несколько типов причинных следов.




Рисунок 2 – Примеры причинных следов

Во-первых, в линейной аддитивной шумовой модели  $Y \leftarrow f(X) + E$ , где  $X$  – причина,  $E$  – шум, эти переменные являются независимыми случайными величинами с ограниченным диапазоном, и механизм  $f$  является линейной функцией. (Рис. 2а). Невозможно представить линейную аддитивную шумовую модель  $X \leftarrow f'(Y) + E'$ , где новая причина  $Y$  и новый шум  $E'$  – две независимые случайные величины (за исключением вырожденных случаев). Это представлено на рис. 2б, где дисперсия новой переменной шума  $E'$

появляется в разных местах новой переменной причины  $Y$  и обозначается красными линиями. Таким образом, в НПМ допущение удовлетворяет корректному направлению причины  $X \rightarrow Y$ , но оно нарушается при неправильном причинном направлении  $X \leftarrow Y$ . Благодаря этой асимметрии, причины отличаются от следствий [5]. Важным моментом здесь является отсутствие зависимости между  $X$  и  $E^2$ .

Во-вторых, при  $X \rightarrow Y$ , где  $f$  – это монотонная функция, и где  $Y = f(X)$  детерминировано. Причинно-следственная связь  $X \rightarrow Y$  является детерминированной, и поэтому следы, основанные на шуме, из предыдущих примеров являются бесполезными. Предположим, что  $P(X)$  – это равномерное распределение. Тогда функция вероятности плотности воздействия  $Y$  возрастает каждый раз, когда наклон  $f$  убывает, как показано на рис. 2в. Форма воздействия распределения  $P(Y)$  зависима от механизма  $f$ . В данном примере НПМ удовлетворяет корректному причинному направлению  $X \rightarrow Y$ , но оно нарушается при неверном причинном направлении  $X \leftarrow Y$ . Следовательно, из-за данной асимметрии, понятия причины и следствия различны [1].

Чтобы изучить причинные следы из данных, мы следуем [3] и представляем причинно-следственные логические выводы в виде двоичной задачи классификации. Наши входные модели  $Q_i$  – это эффективные графики рассеивания, похожие на те, что были показаны на рис. 2а и 2б, то есть каждая точка данных представляет собой набор образцов  $(x_{ij}, y_{ij}) \in R^2$ , обращенных НОР из распределения  $P(X_i, Y_i)$ . Метка класса  $l_i$  указывает на причинно-следственное направление между  $X_i$  и  $Y_i$ .

$$\begin{aligned}
 D &= \{(S_i, l_i)\}_{i=1}^n, \\
 Q_i &= \{(x_{ij}, y_{ij})\}_{j=1}^{m_i} \sim P^{m_i}(X_i, Y_i), \\
 l_i &= \begin{cases} 0 & \text{if } X_i \rightarrow Y_i \\ 1 & \text{if } X_i \leftarrow Y_i \end{cases}
 \end{aligned} \tag{2}$$

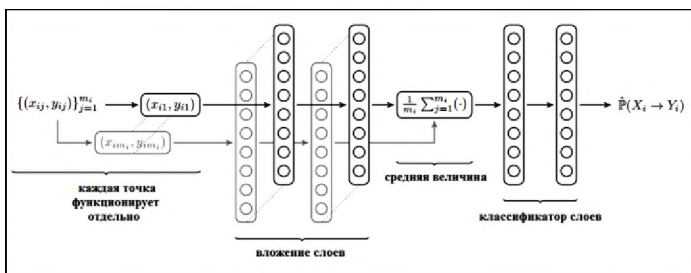


Рисунок 3 – Схема нейронной причинной обусловленности коэффициента (NCC-архитектура)

Используя данные из этой формулы, необходимо обучить нейронную сеть систематизировать выборки из распределений вероятности на причинные и непрчинные. Так как входные модели  $Q_i$  являются не фиксированными мерными векторами, а набором точек, что описывает его, как вложенный классификатор [4].

$$NCC \left( \{(x_{ij}, y_{ij})\}_{j=1}^{m_i} \right) = \Psi \left( \frac{1}{m_i} \sum_{j=1}^{m_i} \varphi(x_{ij}, y_{ij}) \right). \quad (3)$$

В предыдущем уравнении,  $\varphi$  – это карта особенности, и средний показатель всех  $\varphi(x_{ij}, y_{ij})$  – это среднее внедрение эмпирического распределения  $\frac{1}{m_i} \sum_{i=1}^{m_i} \delta_{(x_{ij}, y_{xj})}$ . Функция  $\psi$  – это бинарный классификатор, принимающий фиксированную длину среднего вложения как входящую [3].

В методах ядра,  $\varphi$  фиксируется априорно и определяется с учетом нелинейного ядра [3]. Однако, наша карта особенностей  $\varphi: R^2 \rightarrow R^h$  и классификатор  $\psi: R^h \rightarrow \{0,1\}$  – оба многослойные перцептроны, которые изучаются совместно с данными. Рис. 3 иллюстрирует предложенную архитектуру, который называется нейронный коэффициент причинности (НКП). Чтобы классифицировать образец  $Q_i$  как причинный или непрчинный, НКП располагает каждую точку  $(x_{ij}, y_{ij})$  в образце  $Q_i$  для представления  $\varphi(x_{ij}, y_{ij}) \in R^h$ , рассчитывает встроенный вектор  $\frac{1}{m_i} \sum_{i=1}^{m_i} \varphi(x_{ij}, y_{xj})$  по всем точкам  $(x_{ij}, y_{ij}) \in Q_i$  и классифицирует встроенный вектор  $\varphi S_i \in R^h$  как причинный или непрчинный, используя классификатор нейронных сетей  $\psi$ . Важно, что предложенная нейронная архитектура не ограничивается причинно-следственными умозаключениями и может быть использована для представления и изучения в общих распределениях.

НКП имеет положительные свойства. Во-первых, прогнозирование причинно-следственных связей для нового набора образцов во время теста может быть эффективно завершено с единственным проходом через статистическую сеть. В отличие от вычислительной сложности аддитивной модели шума алгоритмов вывода, основанной на ядре, является кубической в числе образцов  $m_i$ . Во-вторых, НКП могут быть обучены использованию сочетаний разных причинных и беспричинных генеративных моделей, таких как линейные, нелинейные, шумовые и детерминированные механизмы, связывающие причины с их следствием. В-третьих, для дифференцируемых функций активации, НКП – это дифференциальная функция, что позволяет размещать НКП в больших нейронных архитектурах или использовать его в качестве регуляризации, чтобы стимулировать изучение причинных и беспричинных моделей.

В последующем, описывается процесс создания искусственных причинно-следственных данных вместе с подготовкой процедуры к НКП, что

позволит представить результативность НКП в причинно-следственных данных из реального мира.

Построим  $n$  искусственных обозреваемых образцов,  $i$  –ый обозреваемый образец содержит  $m_i$  точек. Точки, используемые в обозреваемом образце  $Q_i = \{(x_{ij}, y_{ij})\}_{j=1}^{m_i}$  взяты из аддитивной модели шума  $y_{ij} \leftarrow f_i(x_{ij}) + v_{ij}e_{ij}$  для всех  $j = 1, \dots, m_i$ .

Условия причины  $x_{ij}$  взяты из сочетания  $k_i$  гауссовских дистрибутивов. Мы строим каждый гауссиан путем выборки среднего значения из гауссиана  $(0, r_i)$ , его стандартного отклонения и гауссиана  $(0, s_i)$  с последующим абсолютным значением, и его ненормированного сочетания веса и гауссиана  $(0, 1)$  с последующим абсолютным значением. Мы производим выборку  $k_i \sim RandomInteger[1, 5]$  и  $r_i, s_i \sim Uniform[0, 5]$ . Нормализуем сочетание весов, чтобы свести их к одному, нормализуем  $\{x_{ij}\}_{j=1}^{m_i}$  в среднее нулевое значение и единичную дисперсию.

Механизм  $f_i$  является кубическим сплайном Эрмита с поддержкой и  $d_i$  узлы взяты из гауссиана  $(0, 1)$ , где  $d_i \sim RandomInteger(4, 5)$ .

$$\left[ \min \left( \{x_{ij}\}_j^{m_i} \right) - std \left( \{x_{ij}\}_j^{m_i} \right), \max \left( \{x_{ij}\}_j^{m_i} \right) + std \left( \{x_{ij}\}_j^{m_i} \right) \right] \quad (4)$$

Бесшумный эффект условия  $\{f(x_{ij})\}_j^{m_i}$  нормализован, чтобы получить среднее нулевое значение и единичную дисперсию.

Шумовое условие  $e_{ij}$  выбирается из гауссиана  $(0, v_i)$ , где  $v_i \sim$  однородность  $[0, 5]$ . Для обобщения НПМ, мы предполагаем для гетероскедастического шума следующее: умножаем каждый  $e_{ij}$  на  $v_{ij}$ , где  $v_{ij}$  – значение сглаживающего сплайна с поддержкой, показанной в (3) и  $d_i$ , случайными узлами, взятыми из однородности  $[0, 5]$ . Шумовое условие  $\{x_{yj}\}_{j=1}^{m_i}$ , нормализовано для получения среднего нулевого значения и единичной дисперсии.

Этот процесс выборки производит учебный набор из  $2n$  образцов:

$$D = \left\{ \left\{ \left( \{x_{ij}, y_{ij}\}_{j=1}^{m_i}, 0 \right) \right\}_{i=1}^n \cup \left\{ \left\{ (y_{ij}, x_{ij}) \right\}_{j=1}^{m_i}, 0 \right\}_{i=1}^n \right\} \quad (5)$$

Мы готовим НКП с двумя встроенными слоями и двумя слоями классификации с последующими выходными слоями. Каждый скрытый слой представляет собой набор из пакетной нормализации [2], 100 скрытых нейронов, выпрямленного линейного соединения и 25% выпадающего [4]. Подготавливаем его для 10000 итераций, используя RMSProp с параметрами по умолчанию, где каждая мини-партия имеет вид, приведенный в (4) и имеет

размер  $2n = 32$ . Соблюдаем симметрию  $P(X \rightarrow Y) = 1 - P(Y \rightarrow X)$ , благодаря образованию составного классификатора:

$$\frac{1}{2} \left( 1 - NCC \left( \{(x_{ij}, y_{ij})\}_{j=1}^{m_i} \right) + NCC \left( \{(y_{ij}, x_{ij})\}_{j=1}^{m_i} \right) \right), \quad (6)$$

где НКП  $\left( \{(x_{ij}, y_{ij})\}_{j=1}^{m_i} \right)$  стремится к 0, если классификатор полагает, что  $X_i \rightarrow Y_i$ , и стремится к единице, если классификатор полагает, что  $X_i \leftarrow Y_i$ . Выбираем параметры путём мониторинга ошибки при проверке НКП на удерживаемом наборе из 10000 искусственных обозреваемых образцов. Используя этот набор, мы перекрёстно выбираем процент отсева из  $\{0,1; 0,25; 0,3\}$ , количество скрытых слоёв из  $\{2,3\}$  и количество скрытых соединений в каждом из слоёв из  $\{50,100,500\}$ .

Проведены эксперименты с двумя наборами данных: PASCAL VOC 2012 [2] и MS COCO [4]. Эти наборы содержат разнородные изображения, собранные с изображением природы. В массивах данных в PASCAL рассмотрены двадцать классов, таких как самолет, собака, мотоцикл, человек, телевизор и др. Этот массив данных содержит 11541 изображений. В массивах данных MS COCO исследованы те же классы. Этот выбор составляет около 99,309 изображений. Предварительно обработав изображения, установили размер в 224x224 пикселей.



а) Исходное изображение  $x_j$



б) Изображение объектов  $x_j^0$



в) Изображение контекста  $x_j^c$

Рисунок 4 – Процесс затемнения объекта «собака» фото

Исходное изображение  $x_j$  создает особенности  $\{f_{jl}\}_l$  и класс-вероятность  $\{c_{jk}\}_k$ . Изображение объектов  $x_j^0$  создает особенности  $\{f_{jl}^0\}_l$ . Изображение контекста  $x_j^c$  создает особенности  $\{f_{jl}^c\}_l$ . Процессы затемнения выполняются после нормализации изображения, чтобы получить «чёрный ноль» пикселей. Используем последние скрытые представления глубоких нейронных



свёрточных сетей из 18 слоев [3], как источников признаков. Эта сеть была подготовлена на всем массиве данных ImageNet [3].

Обозначим  $f_j = f(x_j) \in R^{512}$ , как вектор вещественных функций, полученный из изображения  $x_j \in R^{3 \times 224 \times 224}$ , которое использует эту сеть.

Формируем классификатор нейронной сети из двух скрытых слоев из 512 наборов каждый. Через  $c_j = c(x_j) \in R^{20}$  обозначим вектор непрерывных коэффициентов регистрации, полученный из изображения  $x_j \in R^{3 \times 224 \times 224}$ , которое использует этот классификатор. Далее описываем вычисления для каждой особенности  $l = 1, 512$  четырьмя разными оценками: оценкой объекта, контекста, причинности и беспричинности. Оценки объекта рассчитываются независимо от оценки причинности/беспричинности.

Далее описывается процесс подсчёта оценок объекта  $k$  для всех двадцати объектов из эксперимента.

Каждое изображение  $x_j$  в массиве данных MS COCO описывается тремя разными способами для всех  $j = 1, \dots, m$ . Начальное изображение  $x_j$  описывается, как  $f_j = f(x_j)$ . Произведено затемнение контекста интересующего объекта  $k$  в  $x_j$ , размещая нулевые пиксели вне ограничивающих его прямоугольников. Благодаря этому появляется изображение объекта  $x_j^o$ , как показано на рис. 2б. Произведено затемнение объект  $k$  в  $x_j$ , поместив нулевые пиксели во внутрь ограничивающих их прямоугольников. Благодаря этому появляется изображение контекста  $x_j^c$ , как показано на рис. 4в.

Используя три предыдущие характеристики, для каждой особенности  $l = 1, \dots, 512$  рассчитываем их оценку объекта:

$$s_l^o = \frac{\sum_{j=1}^m |f_{jl}^o - f_{jl}|}{\sum_{j=1}^m |f_{jl}|}$$

и оценку контекста:

$$s_l^c = \frac{\sum_{j=1}^m |f_{jl}^c - f_{jl}|}{\sum_{j=1}^m |f_{jl}|}.$$

Особенности с высокими оценками объекта реагируют на то, когда объект удаляется с изображения. Кроме того, рассчитано коэффициенты регистрации на наличие интересующего объекта  $k$  по отношению к исходному изображению  $x_j$  как  $c_{jk} = c(x_j)_k$ .




Рисунок 5 – Оценки объекта и контекста для беспричинных и причинных характеристик

Для каждой особенности  $l$  рассчитана оценка причинности: 1-НКП ( $\{(f_{jl}, c_{jk})\}_{j=1}^m$ ) и беспричинности: 1-НКП ( $\{(c_{jk}, f_{jl})\}_{j=1}^m$ ). Во избежание обнаружения причинности между независимыми случайными величинами необходимо использование НКП с дополнительным обучающим набором: в дополнение к каждой представленной диаграмме рассужения во всех причинных направлениях, как на (4), подобрана случайная перестановка  $\sigma$ , для создания дополнительного некоррелированного набора  $\{x_{i,\sigma(j)}, y_{ij}\}_{j=1}^{m_i}$  с отметкой  $\frac{1}{2}$ . Модель такого рода после проверки на точность выдаёт 79% в массиве данных Тюбингена.

Таким образом, на рис. 5 показано среднее значение и среднее отклонение оценки особенностей объекта и оценки особенностей контекста с 1% беспричинных оценок и 1% причинных оценок. Как и предполагалось, характеристика объекта связана с беспричинной характеристикой. В частности, характеристики с наибольшим беспричинным значением показывают большую оценку объекта, чем характеристики с наибольшей причинной оценкой. Этот эффект подтверждается на всех 20 интересующих классах, при выборе 1% причинных/беспричинных характеристик, и остается последовательным в 16 из 20 интересующих классов при отборе 20% тех же характеристик. Результаты показывают, что необходимость использования беспричинных характеристик объектов в устойчивом порядке, вне зависимости от их контекста. Как сказано в предположении, невозможно

найти последовательные отношения между характеристиками контекста и причинными характеристиками. Эксперименты показали наличие статистически обозримых сигналов причинно-следственных связей в наборе статических изображений.

**Список использованной литературы:** 1. *P. Daniusis, D. Janzing, etc.* Inferring deterministic causal relations. In UAI, 2010. 2. *Сальников И. И.* Анализ пространственно-временных параметров удаленных объектов в информационных технических системах / Сальников И.И. – М.: Физматлит, 2011. – 252 с. 3. *Timofeev A. V., Andreev V., etc.* Design and implementation of multi-agent manmachine interface on the base of virtual reality models. – 9th International Conference SPEECOM'2004 (September 20-22, 2004, St.Petersburg), pp. 670-675. 4. *Belhumeur P. N., Hespanha J. P., Kriegman D. J.* Eigenfaces vs Fisherfaces: Recognition Using Class Specific Linear Projection. IEEE Transactions on Pattern Analysis and Machine Intelligence 1997, Vol. 19, pp. 711-720. 5. *Косенко Ю. І., Рослякова С. В., Носов П. С.* Система ідентифікації функціональної ентропії суб'єкта критичної інфраструктури [Текст] // Сборник научных трудов по материалам международной научно-практической конференции/ Современные направления теоретических и прикладных исследований. – Вип. 2. – Одесса, 2013. – С. 50 – 54.

**Bibliography (transliterated):** 1. *P. Daniusis, D. Janzing, etc.* Inferring " deterministic causal relations. In UAI, 2010. 2. *Sal'nikov I. I.* Analiz prostranstvenno-vremennyh parametrov udalennyh ob'ektov v informacionnyh tehniceskikh sistemah / *Sal'nikov I.I.* – M.: Fizmatlit, 2011. – 252 s. 3. *Timofeev A. V., Andreev V., etc.* Design and implementation of multi-agent manmachine interface on the base of virtual reality models. – 9th International Conference SPEECOM'2004 (September 20-22, 2004, St.Petersburg), pp. 670-675. 4. *Belhumeur P. N., Hespanha J. P., Kriegman D. J.* Eigenfaces vs Fisherfaces: Recognition Using Class Specific Linear Projection. IEEE Transactions on Pattern Analysis and Machine Intelligence 1997, Vol. 19, pp. 711-720. 5. *Kosenko Ju. I., Rosljakova S. V., Nosov P. S.* Sistema identifikacii funkcional'noi entropii sub'ekta kritichnoi infrastrukturi [Tekst] // Sbornik nauchnyh trudov po materialam mezhdunarodnoj nauchno-prakticheskoi konferencii/ Sovremennye napravlenija teoreticheskikh i prikladnyh issledovanij. – Vip. 2. – Odessa, 2013. – S. 50 – 54.