

УДК: 004.7

EDN: FOXCPQ

DOI: <https://doi.org/10.47813/2782-2818-2024-4-1-0122-0132>

## Извлечение надежного сигнала из гетерогенных данных

Д. И. Атласов, О. Я. Кравец

*Воронежский государственный технический университет, Воронеж, Российская Федерация*

**Аннотация.** Статья посвящена исследованию извлечения общего надежного сигнала из данных, разделенных на разнородные группы. Предлагается мягкая максиминная оценка максимального значения в качестве привлекательной с вычислительной точки зрения альтернативы, направленной на достижение баланса между объединенной оценкой и (жесткой) оценкой максимального значения. Рассматривается проблема извлечения общего сигнала из разнородных данных. Поскольку гетерогенность преобладает в крупномасштабных системах, цель - эффективный в вычислительном отношении оценщик (решение) с хорошими статистическими свойствами при различной степени неоднородности данных. Использование этой оценки может привести к более надежным оценкам для разнородных данных по сравнению с оценкой, которая не учитывает группировку, то есть объединенной оценкой. В крупномасштабных системах обработки данных, где обычно встречается неоднородность данных, вычислительный аспект оценки имеет решающее значение. В обоснование данного тезиса в статье приводится анализ эффективности мягкой максиминной оценки для крупномасштабных систем обработки данных, подтверждающий эффективность примененного метода. Таким образом, оценка мягкого максимума будет практически полезна в ряде различных контекстов как способ агрегирования объясненных отклонений по группам.

**Ключевые слова:** разнородные данные, мягкая оценка максимума, общий надежный сигнал, крупномасштабные системы, неоднородность данных.

**Для цитирования:** Атласов, Д. И., & Кравец, О. Я. (2024). Извлечение надежного сигнала из гетерогенных данных. *Современные инновации, системы и технологии - Modern Innovations, Systems and Technologies*, 4(1), 0122–0131. <https://doi.org/10.47813/2782-2818-2024-4-1-0122-0132>

---

## Extracting a reliable signal from heterogeneous data

D. I. Atlasov, O. Ja. Kravets

*Voronezh State Technical University, Voronezh, Russian Federation*

**Abstract.** The article is devoted to the study of extracting a common reliable signal from data divided into heterogeneous groups. A soft maximum estimate of the maximum value is proposed as a computationally attractive alternative aimed at achieving a balance between a combined estimate and a (hard) estimate of the maximum value. The problem of extracting a common signal from heterogeneous data is considered. Since heterogeneity prevails in large-scale systems, the goal is a computationally efficient estimator (solution) with good statistical properties with varying degrees of data heterogeneity.

Using this estimate can lead to more reliable estimates for heterogeneous data compared to an estimate that does not take into account grouping, that is, a combined estimate. In large-scale data processing systems, where data heterogeneity is usually found, the computational aspect of evaluation is crucial. In substantiation of this thesis, the article provides an analysis of the effectiveness of soft maximum estimation for approval of large-scale data processing systems, confirming the effectiveness of the applied method. In summary soft maximin estimation will be practically useful in a number of different contexts, as a way of aggregating explained variances across groups.

**Keywords:** heterogeneous data, soft maximin estimation, common reliable signal, large-scale systems, data heterogeneity.

**For citation:** Atlasov, D. I., & Kravets, O. J. (2024). Extracting a reliable signal from heterogeneous data. *Modern Innovations, Systems and Technologies*, 4(1), 0122–0131. <https://doi.org/10.47813/2782-2818-2024-4-1-0122-0132>

---

## ВВЕДЕНИЕ

Извлечение общего надежного сигнала из данных, разделенных на разнородные группы, является сложной задачей, когда каждая группа - в дополнение к сигналу - содержит большие уникальные вариационные компоненты. Ранее максиминная оценка была предложена в качестве надежного метода при наличии неоднородного шума [1-3]. Предлагается мягкая максиминная оценка максимального значения в качестве привлекательной с вычислительной точки зрения альтернативы, направленной на достижение баланса между объединенной оценкой и (жесткой) оценкой максимального значения [4-6]. Метод мягкой максиминной оценки предоставляет диапазон оценок, управляемых параметром  $\xi > 0$ , который интерполирует объединенную оценку наименьших квадратов и максиминную оценку. Устанавливая соответствующие теоретические свойства, утверждается, что метод мягкой максиминной оценки является статистически обоснованным и привлекательным с точки зрения вычислений. Демонстрируется на реальных и смоделированных данных, что мягкая максиминная оценка может предложить улучшения как по сравнению с объединенными OLS, так и по сравнению с жестким максимумом с точки зрения производительности прогнозирования и вычислительной сложности. Эффективная по времени и памяти реализация предусмотрена в пакете R SMME, доступном на CRAN [4].

Рассматривается проблема извлечения общего сигнала из разнородных данных [7]. Поскольку гетерогенность преобладает в крупномасштабных системах, цель – эффективный в вычислительном отношении оценщик (решение) с хорошими статистическими свойствами при различной степени неоднородности данных.

## МАТЕРИАЛЫ И МЕТОДЫ

Чтобы конкретизировать концепцию неоднородности, рассмотрим линейную модель смеси с одномерными переменными отклика  $Y_1, \dots, Y_n$ , сгенерированными как

$$Y_i = X_i^T V_i + \varepsilon_i, \quad i = 1, \dots, n. \quad (1)$$

Здесь  $\varepsilon_1, \dots, \varepsilon_n$  и векторы признаков  $X_1, \dots, X_n$  являются  $p$ -мерными случайными величинами, а  $V_1, \dots, V_n$  - одномерными шумовыми переменными. Векторы признаков наблюдаются и предполагаются независимыми одинаково распределёнными случайными величинами, а шумовые переменные предполагаются независимыми одинаково распределёнными случайными величинами. Ненаблюдаемые переменные  $V_1, \dots, V_n$  распределены идентично распределению  $F_V$ , но не обязательно независимы [1].

Неоднородность в модели, приведенной в (1), обусловлена изменением смещения, регулируемым  $F_V$ . Поскольку  $V_i$  может быть зависимым, модель (1) может фиксировать неоднородность, вызванную структурой группы, то есть, когда данные поступают с естественной группировкой, а  $V_i$  постоянен внутри групп, но различается между группами. Даже если данные не сгруппированы или если структура группы неизвестна, полезно изучить настройку с известной структурой группы. В приведенном в [1] примере совместного использования объектов групповая структура вводится для представления временной неоднородности и [1] демонстрирует, как создавать групповые структуры как часть вывода, когда группировка не задана.

Поэтому сосредоточимся на настройке с группами  $G$  и с постоянными  $V_i$  внутри групп. Цель состоит в том, чтобы изучить один  $\beta \in \mathbb{R}^p$ , который можно разумно рассматривать как общий сигнал  $V_i$ . Объединение данных по группам и вычисление обычной оценки наименьших квадратов (OLS) может быть ненадежным, в зависимости от  $F_V$ , и в [1] введена максиминная оценка в качестве надежной альтернативы OLS для разнородных данных из модели (1). Общим сигналом, оцениваемым с помощью оценки максимина, является количество населения, называемое максиминным эффектом.

Хотя максиминная оценка надежна, она также может быть консервативной, и предлагается мягкая максиминная оценка, чтобы обеспечить хороший баланс между максиминной оценкой и объединенной оценкой OLS. Баланс контролируется параметром настройки  $\xi > 0$ , при этом  $\xi \rightarrow \infty$  соответствует максиминной оценке. На рис. 1 показан результат применения мягкой максиминной оценки для трех значений  $\xi$ , а

также объединенной оценки OLS к реальному набору данных. Это иллюстрирует, как прогностическая эффективность двух экстремальных оценок интерполируется с помощью мягкой максиминной оценки, определяемой количественно как кумулятивная среднеквадратичная ошибка (RMSE) с течением времени.

## РЕЗУЛЬТАТЫ И ОБСУЖДЕНИЕ

Далее представим методологию в постановке с заданной структурой группы и воздействуем на константу  $V_i$  внутри каждой группы. Это, в свою очередь, подразумевает конечную поддержку  $F_V$ , и эту модель, возможно, лучше понимать как тип линейной смешанной модели, поскольку группировка доступна, следовательно, больше не является частью вывода. Однако, в отличие от традиционной смешанной модели, мы избегаем явного моделирования фиксированных и случайных эффектов, поскольку цель не состоит в том, чтобы делать выводы о них. Вместо этого мы стремимся получить только оценку возможных общих эффектов, присутствующих в данных.

Чтобы ввести  $G \in \mathbb{N}$  групп для модели (1), предположим, что задано разбиение  $I_1, \dots, I_G$  набора индексов  $\{1, \dots, n\}$  такое, что  $|I_g| = n_g$ , а  $n = \sum_g n_g$ , где для каждого  $g$  и для всех  $i \in I_g$ ,  $V_i = V_g$  выполнено в группе  $g$ . Таким образом,  $F_V$  имеет конечную неизвестную поддержку с мощностью  $G$ , то есть  $\text{supp}(F_V) = \{b_1, \dots, b_G\} \subset \mathbb{R}^p$  с  $b_g := V_g(\omega)$  - неизвестным эффектом в группе  $g$ .

Используя эту дополнительную структуру, мы можем пометить отклик, ковариаты и ошибки в соответствии с группой.

Для  $g$ -й группы пусть  $\mathbf{Y}_g = (Y_{g,1}, \dots, Y_{g,n_g})^T$  - вектор отклика  $n_g \times 1$ ,  $\mathbf{X}_g = (X_{g,1}, \dots, X_{g,n_g})^T$  матрица проектирования  $n_g \times p$  и  $\boldsymbol{\varepsilon}_g = (\varepsilon_{g,1}, \dots, \varepsilon_{g,n_g})^T$  - вектор ошибки  $n_g \times 1$ . Линейная модель для  $g$ -й группы тогда представлена как

$$\mathbf{Y}_g = \mathbf{X}_g \mathbf{b}_g + \boldsymbol{\varepsilon}_g, \quad g \in \{1, \dots, G\}. \quad (2)$$

Общий сигнал в этой структуре представлен как  $\beta \in \mathbb{R}^p$  таким образом, что  $\mathbf{X}_g$  является хорошей и надежной аппроксимацией  $\mathbf{X}_g \mathbf{b}_g$  во всех группах  $G$ .

Чтобы оценить качество аппроксимации, используем критерий оптимальности [1]. Там объясненная дисперсия в группе  $g$  при использовании некоторого  $\beta \in \mathbb{R}^p$  в (2) определяется как

$$V_{bg}(\beta) := 2\beta^T \Sigma b_g - \beta^T \Sigma \beta. \quad (3)$$

Таким образом, оптимальным приближением для всех групп является так называемый эффект максимина, определяемый как  $b^* \in \mathbb{R}^p$ , который максимизирует минимум объясненных различий между группами, то есть,  $b^* := \arg \max_{\beta} \min_g V_{bg}(\beta)$ .

Поскольку  $b_g$  неизвестен, то, чтобы сделать этот критерий работоспособным, обозначим через  $\Sigma_g = X_g^T X_g / n_g$  эмпирическую матрицу Грама в группе  $g$ . Заменяв  $\Sigma$  на  $\Sigma_g$  в (3), мы получим эмпирически объясненную дисперсию в группе  $g$ :

$$V_g(\beta) := (2\beta^T \Sigma_g b_g - \beta^T \Sigma_g \beta) / n_g.$$

$$\hat{V}_g(\beta) := \frac{1}{n_g} (2\beta^T X_g^T Y_g - \beta^T X_g^T X_g \beta) \quad (4)$$

Как показано в [1], использование этой оценки может привести к более надежным оценкам для разнородных данных по сравнению с оценкой, которая не учитывает группировку, то есть объединенной оценкой. Предположение заключается в том, что максимальная оценка извлекает только те объекты, которые активны с одинаковым знаком в разных группах, при этом для объектов, специфичных для группы, устанавливается нулевое значение. Это делает ее более грубой оценкой по сравнению с оценкой, полученной с использованием методологии полной смешанной модели; однако в принципе она также более надежна и потенциально более привлекательна с точки зрения вычислений. В крупномасштабных системах обработки данных, где обычно встречается неоднородность данных, вычислительный аспект оценки имеет решающее значение.

Устраним это вычислительное препятствие, заменяя функцию максимума следующей гладкой функцией. Для  $G \in \mathbb{N}$  и  $\zeta \neq 0$  рассмотрим масштабированную экспоненциальную функцию  $\text{lse}$  логарифмической суммы

$$\text{lse}_{\zeta}(x) = \frac{\log(\sum_j e^{\zeta x_j})}{\zeta}, \quad x \in \mathbb{R}^G \quad (5)$$

Очевидно, что  $\text{lse}$  дифференцируема, она обладает дополнительными свойствами, которые делают ее хорошо подходящим для целей оптимизации. Основные свойства, изложенные далее, легко проверяются и объясняют, почему (5) является разумным выбором в качестве аппроксимации функции максимума.

**Предположение 1.** Пусть  $G \in \mathbb{N}$  и  $x \in \mathbb{R}^G$ .

(1.1) При  $\zeta > 0$

$$\max(x_1, \dots, x_G) \leq lse_\zeta(x) \leq \frac{\log(G)}{\zeta} + \max(x_1, \dots, x_G) \quad (6)$$

и, в частности,  $lse(x) \searrow \max_g \{x_g\}$  при  $\zeta \rightarrow \infty$ .

(1.2) При  $\zeta \rightarrow 0$

$$lse_\zeta(x) = \frac{1}{G} \sum_{j=1}^G x_j + \frac{\log(G)}{\zeta} + o(1)$$

Определим мягкую функцию максимальных потерь как

$$s_\zeta(\beta) = lse_\zeta(-\hat{V}(\beta)), \quad \beta \in R^p, \quad \zeta > 0$$

где  $\hat{V}(\beta) = (\hat{V}_1(\beta), \dots, \hat{V}_G(\beta))^T$ . For  $k > 0$  и  $\zeta > 0$ , оценка мягкого максимума теперь может быть определена как

$$\hat{\beta}_{smm}^k = \arg \min_\beta lse_\zeta(-\hat{V}(\beta)) \quad \text{такое, что } \|\beta\|_1 \leq k \quad (7)$$

Используя Предположение 1, можно количественно оценить влияние параметра на производительность оценки мягкого максимума (7). Следующий результат дает оценку максимальной отрицательной объясненной дисперсии оценки мягкого максимина, используя оценку теоретического эффекта максимина  $b^*$ .

**Утверждение 1.** Пусть  $D = \max_g \|\hat{\Sigma}_g - \Sigma\|_\infty$  и  $\delta = \max_g \|X_g^T \varepsilon_g\|_\infty$ . Для фиксированных  $\zeta > 0$  и  $k > 0$ , при  $k \geq \max_g \|b_g\|_1$ , выполнено

$$\max_g \left\{ -V_{b_g}(\hat{\beta}_{smm}^k) \right\} \leq \max_g \left\{ -V_{b_g}(b^*) \right\} + 6Dk^2 + 4k\delta + \frac{\log(G)}{\zeta}$$

где  $b^*$  - максимальный эффект. В частности

$$\|\hat{\beta}_{smm}^k - b^*\|_\Sigma \leq 6Dk^2 + 4k\delta + \frac{\log(G)}{\zeta}$$

Утверждение 1 доказывается путем объединения Предположения 1 и результатов [1]. В частности, потеря производительности, возникающая при использовании оценки мягкого максимума, ограничена той же величиной, что и у максиминной оценки, плюс логарифм смещения аппроксимации мягкого максимума  $\log(G)/\zeta$  из Предположения 1. Таким образом, при управлении параметром  $\zeta$  мягкая оценка максимина обладает теоретическими свойствами, аналогичными свойствам (жесткой) оценки максимина. В частности, для  $D=0$  (например, для фиксированного проекта) и фиксированного числа групп, если  $n_g \rightarrow \infty$  для всех  $g$ , оценка мягкого максимина сохраняет только смещение аппроксимации.

Утверждение 1 устанавливает связь между производительностью мягкого максимина и эффектом максимина и показывает, что для  $\zeta \uparrow \infty$  мы действительно получаем максиминную оценку производительности. Однако это также подчеркивает, что при  $\zeta \downarrow 0$  производительность мягкой оценки максимина может сколь угодно сильно отклоняться от производительности оценки максимина. Действительно, согласно Предположению 1, для малых  $\zeta > 0$ ,

$$s_{\zeta}(\beta) \approx -\frac{1}{G} \sum_{i=1}^G \hat{V}_j(\beta) + \frac{\log(G)}{\zeta} \approx \frac{1}{n} \sum_{j=1}^G \sum_{i=1}^{n_j} \frac{n}{G n_j} \left( (X_j \beta)_i - Y_{j,i} \right)^2$$

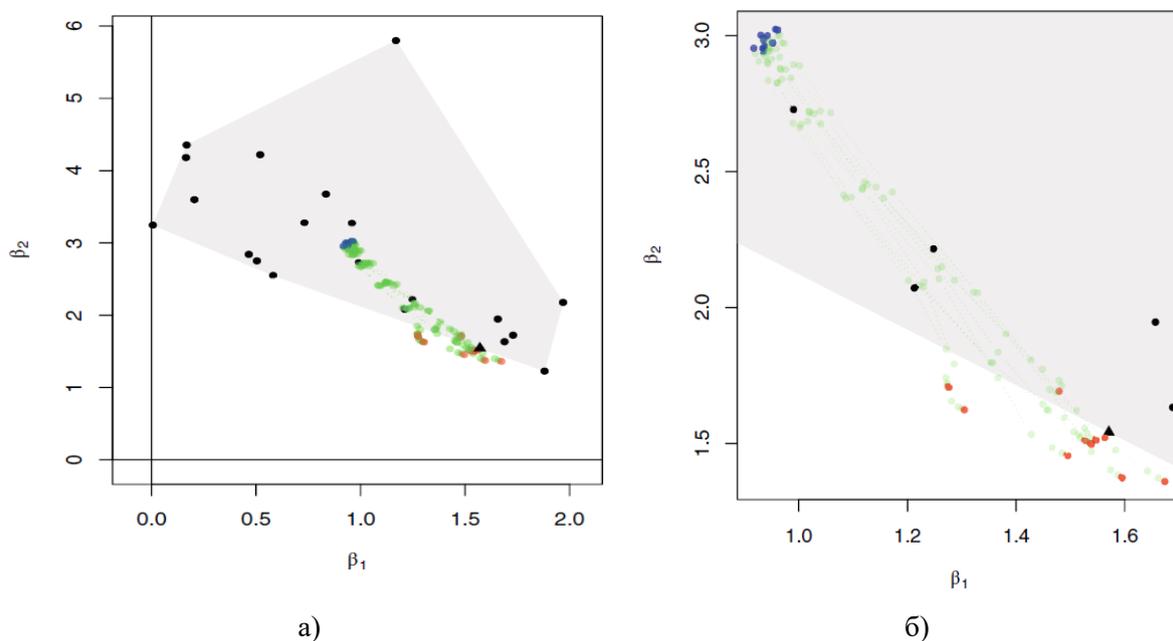
и (7) фактически становится задачей взвешенных наименьших квадратов со штрафом (PWLS) по всем  $n$  наблюдениям. Таким образом, решение (7) для малого  $\zeta = 0$  приблизительно дает объединенную оценку PWLS с весами, усиливающими наблюдения из групп меньшего размера, чем в среднем. При одинаковом количестве наблюдений в каждой группе программа оценки мягкого максимума, в свою очередь, интерполирует объединенную оценку PLS и максимальную оценку.

В этом смысле  $\zeta$  отражает неоднородность данных. При небольшой неоднородности может хорошо работать низкий или даже нулевой показатель, соответствующий тому, что группировка не является релевантной. Однако для разнородных данных малое значение может привести к прогнозам, которые будут хуже нулевого прогноза, в то время как большое значение все еще может работать хорошо.

Чтобы проиллюстрировать интерполяцию, рассмотрим небольшой пример данных, сгенерированных в соответствии с (2) с  $G=20$  группами,  $n_g=400$  наблюдений в каждой группе и двумерным (2D) пространством параметров. Для фиксированных эффектов  $\{b_1, \dots, b_{20}\} \subset \mathbb{R}^2$  мы производим выборку  $X_g$  и  $g$ ,  $M=10$  раз для каждого  $g$ , в результате чего получаем 10 различных наборов данных. Для каждого из этих десяти небольших наборов данных мы можем вычислить мягкую максиминную оценку (т.е.  $k=\infty$  в (7)) для последовательности значений  $\zeta$ .

На рис. 1 показаны пути интерполяции мягкой максиминной оценки, соединяющие оценки LS населения и оценки *maximin*. Обратите внимание, что все оценки типа *maximin* сгруппированы вокруг теоретического максиминного эффекта, обозначенного символом  $\blacktriangle$  на краю выпуклой оболочки  $\{b_1, \dots, b_{20}\}$ , в то время как объединенные оценки находятся далеко внутри выпуклой оболочки.

Важно, что другой метод регрессии, якорная регрессия, был предложен в [6] для обработки неоднородности данных в ситуациях, когда распределение ответов может смещаться, что приводит к разнице между распределением обучающих данных и распределением тестовых данных. Если эта неоднородность может быть закодирована или сгенерирована известной опорной переменной, их метод может привести к улучшенной и, в частности, более стабильной производительности прогнозирования. В частности, контролируя параметр привязки  $\gamma > 0$ , этот метод интерполирует три различных метода регрессии, где  $\gamma = 1$  дает регрессию OLS, а  $\gamma = \infty$  - регрессию инструментальной переменной.



**Рисунок 1.** (а): выпуклая оболочка (серая заштрихованная область)  $\text{supp}(F_B)$  (черные точки). Теоретический максимальный эффект  $b^*$ , максимальные оценки (красные точки), мягкие максимальные оценки (зеленые точки) для различных  $\zeta$  и популяционные оценки OLS (синие точки). (б): крупный план.

**Figure 1.** (a): convex hull (gray shaded area)  $\text{supp}(F_B)$  (black dots). Theoretical maximum effect  $b^*$ , maximum estimates (red dots), soft maximum estimates (green dots) for various  $\zeta$  and population OLS estimates (blue dots). (b): close-up.

В некотором смысле точка привязки играет роль группирующей структуры  $I_1, \dots, I_G$ , используемой в определении оценки мягкого максимума. Однако в общей настройке с неизвестными группами, учитывая определенные структурные допущения, можно построить наборы индексов  $I_1, \dots, I_G$ , как в примере выше, или путем случайной выборки.

Теоретические гарантии в этом случае даны в [1] для максимальной оценки и аналогично Утверждению 1 должны распространяться на оценку мягкого максимума.

В дополнение к математической сложности, это добавляет процедуре вывода существенный уровень вычислительной сложности, поскольку число групп  $G$  в таком случае является гиперпараметром, который необходимо вывести, например, путем перекрестной проверки (CV). Таким образом, этот уровень кластеризации только усиливает важность эффективно вычисляемой базовой оценки.

### ЗАКЛЮЧЕНИЕ

Таким образом, оценка мягкого максимума будет практически полезна в ряде различных контекстов как способ агрегирования объясненных отклонений по группам. В частности, потому, что она снижает вес групп с большой объясненной дисперсией, которые могут быть просто выбросами, что может полностью заглушить сигнал.

### СПИСОК ЛИТЕРАТУРЫ

- [1] Meinshausen N., Bühlmann P. Maximin effects in inhomogeneous large-scale data. *The Annals of Statistics*. 2015; 43(4): 17-22. <https://doi.org/10.1214/15-AOS1325>
- [2] Fanaee-T H., Gama J. Event labeling combining ensemble detectors and background knowledge. *Progress in Artificial Intelligence*. 2013; 2(2): 113-127. <https://doi.org/10.1007/s13748-013-0040-3>
- [3] Tseng P., Yun S. A coordinate gradient descent method for nonsmooth separable minimization. *Mathematical Programming*. 2009; 117(1-2): 387-423. <https://doi.org/10.1007/s10107-007-0170-0>
- [4] Lund A. SMME: Soft maximin estimation for large scale heterogeneous data. R package version 1.0.1; 2021.
- [5] Lund A., Mogensen W.S., Hansen R.N. Soft maximin estimation for heterogeneous data. *Scandinavian Journal of Statistics*. 2022; 49(4): 1761-1790. <https://doi.org/10.1111/sjos.12580>
- [6] Rothenhdusler D., Meinshausen N., Behlmann P., Peters, J. Anchor regression: Heterogeneous data meet causality. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*. 2021; 83(2): 215-246. <https://doi.org/10.1111/rssb.12398>

- [7] Atlasov D.I., Kravets O.Ja. To the formulation of the problem of extracting a common signal from heterogeneous data of heterogeneous information systems. Modern informatization problems in simulation and social technologies (MIP-2023'SCT). Proc. of the XXVIII-th Int. Open Science Conf. January 2023; Yelm, WA, USA: Science Book Publishing House; 2023: 8-13.

## REFERENCES

- [1] Meinshausen N., Bühlmann P. Maximin effects in inhomogeneous large-scale data. The Annals of Statistics. 2015; 43(4): 17-22. <https://doi.org/10.1214/15-AOS1325>
- [2] Fanaee-T H., Gama J. Event labeling combining ensemble detectors and background knowledge. Progress in Artificial Intelligence. 2013; 2(2): 113-127. <https://doi.org/10.1007/s13748-013-0040-3>
- [3] Tseng P., Yun S. A coordinate gradient descent method for nonsmooth separable minimization. Mathematical Programming. 2009; 117(1-2): 387-423. <https://doi.org/10.1007/s10107-007-0170-0>
- [4] Lund A. SMME: Soft maximin estimation for large scale heterogeneous data. R package version 1.0.1; 2021.
- [5] Lund A., Mogensen W.S., Hansen R.N. Soft maximin estimation for heterogeneous data. Scandinavian Journal of Statistics. 2022; 49(4): 1761-1790. <https://doi.org/10.1111/sjos.12580>
- [6] Rothenhdusler D., Meinshausen N., Behlmann P., Peters, J. Anchor regression: Heterogeneous data meet causality. Journal of the Royal Statistical Society: Series B (Statistical Methodology). 2021; 83(2): 215-246. <https://doi.org/10.1111/rssb.12398>
- [7] Atlasov D.I., Kravets O.Ja. To the formulation of the problem of extracting a common signal from heterogeneous data of heterogeneous information systems. Modern informatization problems in simulation and social technologies (MIP-2023'SCT). Proc. of the XXVIII-th Int. Open Science Conf. January 2023; Yelm, WA, USA: Science Book Publishing House; 2023: 8-13.

## ИНФОРМАЦИЯ ОБ АВТОРАХ / INFORMATION ABOUT THE AUTHORS

**Атласов Денис Игоревич**, аспирант, кафедра автоматизированных и вычислительных систем, Воронежский государственный университет, Воронеж, Воронежский государственный университет, Воронеж, Russian Federation

**Denis Atlasov**, postgraduate, Automation and computing Systems, Voronezh State Technical University, Voronezh, Russian Federation

технический университет, Воронеж,  
Российская Федерация

**Кравец Олег Яковлевич**, доктор  
технических наук, профессор, кафедра  
автоматизированных и вычислительных  
систем, Воронежский государственный  
технический университет, Воронеж,  
Российская Федерация

**Oleg Ja. Kravets**, Doctor of Engineering,  
Professor, Automation and computing Systems,  
Voronezh State Technical University, Voronezh,  
Russian Federation

*Статья поступила в редакцию 28.02.2024; одобрена после рецензирования 07.03.2024; принята  
к публикации 11.03.2024.*

*The article was submitted 28.02.2024; approved after reviewing 07.03.2024; accepted for publication  
11.03.2024.*