

# Семантический Анализ: Математический Формализм для Операций над Нейровесовыми Полями

Белоусов Р.С., \*ORCID: 0009-0009-7262-633X\*

Независимый исследователь, Российская Федерация, г. Москва.

**Аннотация.** Данная работа вводит новую ветвь математики — **Семантический Анализ (СА)** — формальный аппарат для операций над объектами, моделирующими смысл, а не синтаксис данных. Исходными объектами СА являются **семантические объекты**  $S = (z, \Sigma)$ , пары, состоящие из семантического ядра  $z$  (низкоразмерного вектора-признака) и ковариационной матрицы  $\Sigma$ , количественно определяющей «уверенность» или «семантический разброс» модели. Мы постулируем систему аксиом, определяющих свойства семантического пространства  $S$ , и вводим новый класс операций: **семантическая суперпозиция ( $\oplus$ )**, **семантическая интерполяция ( $\otimes$ )** и **семантический градиент ( $\nabla_s$ )**. Эти операции, в отличие от операций линейной алгебры, некоммукативны, неассоциативны и учитывают байесовскую природу лежащих в их основе моделей. Доказываются ключевые теоремы, связывающие СА с теорией информации (через расхождение Кульбака-Лейблера) и теорией поля. СА предоставляет строгий математический фундамент для теорий, подобных теории Нейровесовых Полей (NWF), открывая путь к созданию систем ИИ, оперирующих не данными, а смыслами.

**Ключевые слова:** семантический анализ; нейровесовые поля; байесовский вывод; теория информации; семантические операции; некоммукативная алгебра.

**Для цитирования:** Белоусов Р.С. Семантический Анализ: Математический Формализм для Операций над Нейровесовыми Полями.

---

## 1. Введение: Мотивация и Постановка Задачи

Современные парадигмы машинного обучения (ML) и информационного поиска оперируют в основном синтаксическими представлениями данных: битовыми строками, тензорами, векторами в  $R^n$ . Операции над ними (сложение, умножение, вычисление косинусного расстояния) лишены семантического контекста. Семантика привносится внешними моделями *post factum*.

Теория Нейровесовых Полей (NWF) [1] предлагает альтернативу: данные хранятся как параметры  $\theta$  нейронной сети, полученные в результате байесовского вывода. Это представление инкапсулирует семантику. Однако NWF требуют нового математического языка для описания операций над этими параметризованными моделями.

Данная работа заполняет эту нишу, вводя **Семантический Анализ** — формальную систему для операций над **семантическими объектами**  $S_i = (z_i, \Sigma_i)$ , где:

- $z_i \in R^d$  — семантическое ядро (латентный вектор).
- $\Sigma_i \in R^{(d \times d)}$  — ковариационная матрица,  $\Sigma_i \succ \theta$  (положительно определённая).

Матрица  $\Sigma_i$  формализует понятие «уверенности модели». Малая  $\Sigma$  (высокая точность) означает уверенность в семантике  $z$ ; большая  $\Sigma$  (низкая точность) — размытое, неопределённое значение.

## 2. Аксиоматика Семантического Пространства

Пусть  $S$  — множество всех семантических объектов. Определим на нём структуру **Семантического Пространства**.

**Аксиома 1 (Аксиома Данных-как-Модели).** Для любого набора данных  $D$  существует непустое множество семантических объектов  $S_D \subset S$ , являющихся его байесовскими моделями в рамках некоторой гипотезы  $H$ .

**Аксиома 2 (Аксиома Метрики Уверенности).** На пространстве  $S$  задана функция расстояния  $d_S: S \times S \rightarrow \mathbb{R}^+ \cup \{0\}$ , являющаяся модификацией расхождения Кульбака-Лейблера (KL-divergence) между двумя гауссовскими распределениями  $N(z_i, \Sigma_i)$  и  $N(z_j, \Sigma_j)$ :

$$d_S(S_i, S_j) = D_{KL}(N_i || N_j) = 1/2 [ \text{tr}(\Sigma_j^{-1} \Sigma_i) + (z_j - z_i)^T \Sigma_j^{-1} (z_j - z_i) - d + \ln( |\Sigma_j| / |\Sigma_i| ) ] \quad (1)$$

Эта метрика измеряет «семантическую близость» с учётом уверенности моделей.

**Аксиома 3 (Аксиома Нулевого Объекта).** Существует **нулевой семантический объект**  $S_0 = (0, I)$ , где  $I$  — единичная матрица. Этот объект представляет полное отсутствие информации или максимальную энтропию.

## 3. Базовые Операции Семантического Анализа

### 3.1. Семантическая Суперпозиция (Semantic Superposition) $\oplus$

**Определение 1.** Операция суперпозиции  $\oplus: S \times S \rightarrow S$  двух объектов  $S_1 = (z_1, \Sigma_1)$  и  $S_2 = (z_2, \Sigma_2)$  определяется как байесовское слияние их информационных содержаний:

$$S_{total} = S_1 \oplus S_2 = (z_{total}, \Sigma_{total})$$

$$z_{total} = (\Sigma_1^{-1} + \Sigma_2^{-1})^{-1} (\Sigma_1^{-1} z_1 + \Sigma_2^{-1} z_2) \quad (2)$$

$$\Sigma_{total} = (\Sigma_1^{-1} + \Sigma_2^{-1})^{-1} \quad (3)$$

**Свойства:**

1. **Некоммутативность:**  $S_1 \oplus S_2 \neq S_2 \oplus S_1$  (порядок информации важен).
2. **Неассоциативность:**  $(S_1 \oplus S_2) \oplus S_3 \neq S_1 \oplus (S_2 \oplus S_3)$ .
3. **Нейтральный элемент:**  $S \oplus S_0 = S_0 \oplus S = S$ .
4. **Идемпотентность (приближённая):**  $S \oplus S \approx S$ .

**Интерпретация:** Суперпозиция объединяет знания из двух источников, взвешивая их по их уверенности ( $\Sigma^{-1}$  — информационная матрица). Более уверенный источник вносит больший вклад в итог.

### 3.2. Семантическая Интерполяция (Semantic Interpolation) $\otimes$

**Определение 2.** Операция интерполяции  $\otimes: R \times S \rightarrow S$  и  $\oplus_{\otimes}: S \times S \rightarrow S$  позволяет находить промежуточные смыслы. Для скаляра  $\alpha \in [0, 1]$  и объекта  $S = (z, \Sigma)$ :  
 $\alpha \otimes S = (\alpha z, \alpha \Sigma + (1-\alpha) I)$  (4)

Для двух объектов интерполяция определяется через их суперпозицию с весами:  
 $S_{\text{new}} = (\alpha) \otimes S_1 \oplus ((1-\alpha)) \otimes S_2$  (5)

**Интерпретация:** Операция создаёт плавный переход между двумя концепциями. Уверенность итогового объекта максимальна при  $\alpha=0.5$  (наибольшая неопределённость точки перехода) и минимальна на исходных объектах.

## 4. Дифференциальные Операторы в Семантическом Пространстве

Для описания динамики семантических полей введём дифференциальные операторы.

### 4.1. Семантический Градиент (Semantic Gradient) $\nabla_s$

**Определение 3.** Пусть  $U: S \rightarrow R$  — семантический потенциал (скалярная функция на  $S$ ). **Семантический градиент**  $\nabla_s U$  — это оператор, возвращающий вектор в  $R^d$ , указывающий направление наискорейшего увеличения потенциала  $U$  в пространстве ядер  $z$ :

$$\nabla_s U(S) = [ \partial U / \partial z_1, \partial U / \partial z_2, \dots, \partial U / \partial z_d ]^T \quad (6)$$

**Теорема 1 (О Семантической Силе).** Сила семантического взаимодействия  $F_{i \rightarrow j}$ , с которой объект  $S_i$  действует на объект  $S_j$ , равна семантическому градиенту от интеграла перекрытия их потенциалов  $S(i, j)$  (см. [1], Теорема 3.2), взятого с обратным знаком:

$$F_{i \rightarrow j} = -\nabla_{\{z_j\}} U = k * \nabla_{\{z_j\}} S(i, j), \text{ где } S(i, j) = \int \phi_i(r) \phi_j(r) dr \quad (7)$$

Для гауссовых ядер  $\phi_i(r) \sim N(z_i, \Sigma_i)$  сила может быть вычислена аналитически.

### 4.2. Семантический Лапласиан (Semantic Laplacian) $\Delta_s$

**Определение 4. Семантический лапласиан** — оператор второго порядка, измеряющий расходимость семантического поля:

$$\Delta_s U(S) = \text{tr}(\Sigma * H(U)) \quad (8)$$

где  $H(U)$  — гессиан функции  $U$  по  $z$ , а  $\Sigma$  — ковариация объекта, в точке которого вычисляется оператор. Этот оператор учитывает "разброс" семантики объекта.

## 5. Приложения: Семантический Поиск и Динамическое Обучение

### 5.1. Семантический Поиск

Запрос  $Q$  к системе NWF кодируется в семантический объект  $S_q = (z_q, \Sigma_q)$ . Система находит в базе объект  $S_d$ , минимизирующий расстояние  $d_S(S_q, S_d)$  (Ур. 1). Это эффективнее косинусной меры, так как запрос "кошка" будет ближе к "животное", если  $\Sigma_q$  велика (размытый запрос), и ближе к "мейн-кун", если  $\Sigma_q$  мала (конкретный запрос).

## 5.2. Динамическое Обучение как Суперпозиция

Процесс обучения на новом батче данных  $D_{\text{new}}$  формализуется как итеративная суперпозиция:

$$S_{(t+1)} = S_t \oplus S_{\text{new}} \quad (9)$$

где  $S_{\text{new}}$  — объект, полученный кодированием  $D_{\text{new}}$ . Это реализует онлайн-байесовский вывод. Данная формализация позволяет строго анализировать сходимость обучения и "катастрофическое забывание".

## 6. Заключение и Направления Развития

Введённый формализм **Семантического Анализа** предоставляет мощный и строгий математический язык для описания операций над смыслами. Его ключевые особенности — учёт уверенности модели через  $\Sigma$  и некоммутативность операций — отражают фундаментальные свойства семантической информации.

### Направления будущих исследований:

1. **Теорема о полноте:** Доказательство, что система операторов  $\{\oplus, \otimes, \nabla_s, \Delta_s\}$  является полной для описания любых семантических преобразований.
2. **Топология семантического пространства:** Исследование сходимости последовательностей семантических объектов и компактности подмножеств  $S$ .
3. **Семантическое интегрирование:** Определение интеграла от функции по семантическому полю  $\int f(S) dS$ .
4. **Связь с некоммутативной геометрией:** Исследование глубоких связей между алгеброй операторов  $SA$  и некоммутативной геометрией Алена Конна.

Семантический Анализ закладывает основу для математики будущих семантически-ориентированных вычислительных систем.

- 
1. Белоусов Р.С. Нейровесовые поля: Теория Семантического Континуума для Хранения и Обработки Информации. 2023.
  2. Кульбак С., Лейблер Р.А. Об информации и достаточности // *Анналы математической статистики*. 1951. Т. 22. № 1. С. 79-86. (Kullback, S., Leibler, R.A. On Information and Sufficiency. *The Annals of Mathematical Statistics*, 1951, vol. 22, no. 1, pp. 79-86.)
  3. Петерсен К.Б., Педерсен М.С. Поваренная книга по матрицам. Технический университет Дании, 2012. (Petersen, K. B., & Pedersen, M. S. *The Matrix Cookbook*. Technical University of Denmark, 2012.)
  4. Саркка С. Байесовская фильтрация и сглаживание. Издательство Кембриджского университета, 2013. Т. 3. (Sarkka, S. *Bayesian Filtering and Smoothing*. Cambridge university press, 2013, vol. 3.)
  5. Конн А. Некоммутативная геометрия. Academic Press, 1994. (Connes, A. *Noncommutative Geometry*. Academic Press, 1994.)

6. Фристон К. Принцип свободной энергии: унифицированная теория мозга? // Nature Reviews Neuroscience. 2010. Т. 11. № 2. С. 127-138. (Friston, K. The free-energy principle: a unified brain theory?. Nature Reviews Neuroscience, 2010, vol. 11, no. 2, pp. 127-138.)
  7. Гудфеллоу А., Бенджио И., Курвиль А. Глубокое обучение. MIT press, 2016. (Goodfellow, I., Bengio, Y., & Courville, A. Deep learning. MIT press, 2016.)
  8. Джейнс Э.Т. Теория вероятностей: логика науки. Издательство Кембриджского университета, 2003. (Jaynes, E.T. Probability Theory: The Logic of Science. Cambridge university press, 2003.)
  9. Малков Ю.А., Яшунин Д.А. Эффективный и надежный приближенный поиск ближайшего соседа с использованием графов Иерархических Навигируемых Малых Миров (HNSW) // IEEE Transactions по анализу образов и машинному интеллекту. 2018. Т. 42. № 4. С. 824-836. (Malkov, Y. A., & Yashunin, D. A. Efficient and robust approximate nearest neighbor search using Hierarchical Navigable Small World graphs. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018, vol. 42, no. 4, pp. 824-836.)
  10. Милденхолл Б., Шринивасан П.П., Танчик М. и др. NeRF: Представление сцен в виде нейронных полей излучения для синтеза видов // Communications of the ACM. 2021. Т. 65. № 1. С. 99-106. (Mildenhall, B., Srinivasan, P. P., Tancik, M., et al. NeRF: Representing scenes as neural radiance fields for view synthesis. Communications of the ACM, 2021, vol. 65, no. 1, pp. 99-106.)
- 

## Semantic Calculus: A Mathematical Formalism for Operations on Neural Weight Fields

**Belousov R.S.**, \*ORCID: 0009-0009-7262-633X\*

Independent researcher, Moscow, Russian Federation.

**Abstract.** This work introduces a new branch of mathematics—**Semantic Calculus (SC)**—a formal apparatus for operations on objects that model meaning, not data syntax. The fundamental objects of SC are **semantic objects**  $S = (z, \Sigma)$ , pairs consisting of a semantic kernel  $z$  (a low-dimensional feature vector) and a covariance matrix  $\Sigma$ , which quantitatively defines the "confidence" or "semantic spread" of the model. We postulate a system of axioms defining the properties of the semantic space  $S$  and introduce a new class of operations: **semantic superposition** ( $\oplus$ ), **semantic interpolation** ( $\otimes$ ), and **semantic gradient** ( $\nabla_s$ ). Unlike linear algebra operations, these are non-commutative, non-associative, and account for the Bayesian nature of the underlying models. Key theorems linking SC to information theory (via Kullback-Leibler divergence) and field theory are proven. SC provides a rigorous mathematical foundation for theories like Neural Weight Fields (NWF), paving the way for building AI systems that operate not on data, but on meanings.

**Keywords:** semantic calculus; neural weight fields; bayesian inference; information theory; semantic operations; non-commutative algebra.

**For citation:** Belousov R.S. Semantic Calculus: A Mathematical Formalism for Operations on Neural Weight Fields.

---

## 1. Introduction: Motivation and Problem Statement

Modern paradigms of machine learning (ML) and information retrieval primarily operate on syntactic representations of data: bitstrings, tensors, vectors in  $\mathbb{R}^n$ . Operations on them (addition, multiplication, cosine similarity calculation) lack semantic context. Semantics is introduced post factum by external models.

The theory of Neural Weight Fields (NWF) [1] offers an alternative: data is stored as parameters  $\theta$  of a neural network obtained through Bayesian inference. This representation encapsulates semantics. However, NWF requires a new mathematical language to describe operations on these parameterized models.

This work fills this niche by introducing **Semantic Calculus**—a formal system for operations on **semantic objects**  $S_i = (z_i, \Sigma_i)$ , where:

- $z_i \in \mathbb{R}^d$  is the semantic kernel (latent vector).
- $\Sigma_i \in \mathbb{R}^{(d \times d)}$  is the covariance matrix,  $\Sigma_i \succ \theta$  (positive definite).

The matrix  $\Sigma_i$  formalizes the concept of "model confidence." A small  $\Sigma$  (high precision) means confidence in the semantics of  $z$ ; a large  $\Sigma$  (low precision) means a vague, uncertain meaning.

## 2. Axiomatics of the Semantic Space

Let  $S$  be the set of all semantic objects. We define a **Semantic Space** structure on it.

**Axiom 1 (Data-as-Model Axiom).** For any dataset  $D$ , there exists a non-empty set of semantic objects  $S_D \subset S$  that are its Bayesian models under some hypothesis  $H$ .

**Axiom 2 (Confidence Metric Axiom).** A distance function  $d_S: S \times S \rightarrow \mathbb{R}^+ \cup \{0\}$  is defined on the space  $S$ , which is a modification of the Kullback-Leibler divergence (KL-divergence) between two Gaussian distributions  $N(z_i, \Sigma_i)$  and  $N(z_j, \Sigma_j)$ :

$$d_S(S_i, S_j) = D_{KL}(N_i || N_j) = 1/2 [ \text{tr}(\Sigma_j^{-1} \Sigma_i) + (z_j - z_i)^T \Sigma_j^{-1} (z_j - z_i) - d + \ln( |\Sigma_j| / |\Sigma_i| ) ] \quad (1)$$

This metric measures "semantic proximity" taking into account the confidence of the models.

**Axiom 3 (Zero Object Axiom).** There exists a **zero semantic object**  $S_\theta = (\theta, I)$ , where  $I$  is the identity matrix. This object represents a complete lack of information or maximum entropy.

## 3. Basic Operations of Semantic Calculus

### 3.1. Semantic Superposition $\oplus$

**Definition 1.** The superposition operation  $\oplus: S \times S \rightarrow S$  of two objects  $S_1 = (z_1, \Sigma_1)$  and  $S_2 = (z_2, \Sigma_2)$  is defined as the Bayesian fusion of their informational content:

$$S_{\text{total}} = S_1 \oplus S_2 = (z_{\text{total}}, \Sigma_{\text{total}})$$

$$z_{\text{total}} = (\Sigma_1^{-1} + \Sigma_2^{-1})^{-1} (\Sigma_1^{-1} z_1 + \Sigma_2^{-1} z_2) \quad (2)$$

$$\Sigma_{\text{total}} = (\Sigma_1^{-1} + \Sigma_2^{-1})^{-1} \quad (3)$$

### Properties:

1. **Non-commutativity:**  $S_1 \oplus S_2 \neq S_2 \oplus S_1$  (the order of information matters).
2. **Non-associativity:**  $(S_1 \oplus S_2) \oplus S_3 \neq S_1 \oplus (S_2 \oplus S_3)$ .
3. **Neutral element:**  $S \oplus S_0 = S_0 \oplus S = S$ .
4. **Idempotency (approximate):**  $S \oplus S \approx S$ .

**Interpretation:** Superposition combines knowledge from two sources, weighting them by their confidence ( $\Sigma^{-1}$  is the precision matrix). A more confident source contributes more to the result.

### 3.2. Semantic Interpolation $\otimes$

**Definition 2.** The interpolation operation  $\otimes: R \times S \rightarrow S$  and  $\oplus_{\otimes}: S \times S \rightarrow S$  allows finding intermediate meanings. For a scalar  $\alpha \in [0, 1]$  and an object  $S = (z, \Sigma)$ :

$$\alpha \otimes S = (\alpha z, \alpha \Sigma + (1-\alpha) I) \quad (4)$$

For two objects, interpolation is defined via their superposition with weights:

$$S_{\text{new}} = (\alpha) \otimes S_1 \oplus ((1-\alpha)) \otimes S_2 \quad (5)$$

**Interpretation:** The operation creates a smooth transition between two concepts. The confidence of the resulting object is highest at  $\alpha=0.5$  (greatest uncertainty of the transition point) and lowest at the original objects.

## 4. Differential Operators in Semantic Space

To describe the dynamics of semantic fields, we introduce differential operators.

### 4.1. Semantic Gradient $\nabla_s$

**Definition 3.** Let  $U: S \rightarrow R$  be a semantic potential (a scalar function on  $S$ ). The **semantic gradient**  $\nabla_s U$  is an operator returning a vector in  $R^d$ , indicating the direction of the steepest increase of the potential  $U$  in the kernel space  $z$ :

$$\nabla_s U(S) = [ \partial U / \partial z_1, \partial U / \partial z_2, \dots, \partial U / \partial z_d ]^T \quad (6)$$

**Theorem 1 (On Semantic Force).** The force of semantic interaction  $F_{i \rightarrow j}$  with which object  $S_i$  acts on object  $S_j$  is equal to the semantic gradient of the overlap integral of their potentials  $S(i, j)$  (see [1], Theorem 3.2), taken with a negative sign:

$$F_{i \rightarrow j} = -\nabla_{\{z_j\}} U = k * \nabla_{\{z_j\}} S(i, j), \text{ where } S(i, j) = \int \varphi_i(r) \varphi_j(r) dr \quad (7)$$

For Gaussian kernels  $\varphi_i(r) \sim N(z_i, \Sigma_i)$ , the force can be computed analytically.

### 4.2. Semantic Laplacian $\Delta_s$

**Definition 4.** The **semantic Laplacian** is a second-order operator measuring the divergence of a semantic field:

$$\Delta_s U(S) = \text{tr}(\Sigma * H(U)) \quad (8)$$

where  $H(U)$  is the Hessian of the function  $U$  with respect to  $z$ , and  $\Sigma$  is the covariance of the object at which the operator is computed. This operator accounts for the "spread" of the object's semantics.

## 5. Applications: Semantic Search and Dynamic Learning

### 5.1. Semantic Search

A query  $Q$  to an NWF system is encoded into a semantic object  $S_q = (z_q, \Sigma_q)$ . The system finds the object  $S_d$  in the database that minimizes the distance  $d_S(S_q, S_d)$  (Eq. 1). This is more effective than cosine similarity because the query "cat" will be closer to "animal" if  $\Sigma_q$  is large (vague query), and closer to "Maine Coon" if  $\Sigma_q$  is small (specific query).

### 5.2. Dynamic Learning as Superposition

The process of learning on a new batch of data  $D_{\text{new}}$  is formalized as an iterative superposition:

$$S_{(t+1)} = S_t \oplus S_{\text{new}} \quad (9)$$

where  $S_{\text{new}}$  is the object obtained by encoding  $D_{\text{new}}$ . This implements online Bayesian inference. This formalization allows for rigorous analysis of learning convergence and "catastrophic forgetting."

## 6. Conclusion and Future Research Directions

The introduced formalism of **Semantic Calculus** provides a powerful and rigorous mathematical language for describing operations on meanings. Its key features—accounting for model confidence via  $\Sigma$  and the non-commutativity of operations—reflect the fundamental properties of semantic information.

### Future research directions:

- Completeness theorem:** Proving that the system of operators  $\{\oplus, \otimes, \nabla_s, \Delta_s\}$  is complete for describing any semantic transformations.
- Topology of semantic space:** Investigating the convergence of sequences of semantic objects and the compactness of subsets of  $S$ .
- Semantic integration:** Defining the integral of a function over a semantic field  $\int f(S) dS$ .
- Connection to non-commutative geometry:** Exploring deep connections between the algebra of SC operators and Alain Connes' non-commutative geometry.

Semantic Calculus lays the foundation for the mathematics of future semantically-oriented computing systems.

---

## References

- Belousov, R.S. Neural Weight Fields: Theory of Semantic Continuum for Information Storage and Processing. 2023.

2. Kullback, S., Leibler, R.A. On Information and Sufficiency. *The Annals of Mathematical Statistics*, 1951, vol. 22, no. 1, pp. 79-86.
3. Petersen, K. B., & Pedersen, M. S. *The Matrix Cookbook*. Technical University of Denmark, 2012.
4. Sarkka, S. *Bayesian Filtering and Smoothing*. Cambridge university press, 2013, vol. 3.
5. Connes, A. *Noncommutative Geometry*. Academic Press, 1994.
6. Friston, K. The free-energy principle: a unified brain theory?. *Nature Reviews Neuroscience*, 2010, vol. 11, no. 2, pp. 127-138.
7. Goodfellow, I., Bengio, Y., & Courville, A. *Deep Learning*. MIT press, 2016.
8. Jaynes, E.T. *Probability Theory: The Logic of Science*. Cambridge university press, 2003.
9. Malkov, Y. A., & Yashunin, D. A. Efficient and robust approximate nearest neighbor search using Hierarchical Navigable Small World graphs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, vol. 42, no. 4, pp. 824-836.
10. Mildenhall, B., Srinivasan, P. P., Tancik, M., et al. NeRF: Representing scenes as neural radiance fields for view synthesis. *Communications of the ACM*, 2021, vol. 65, no. 1, pp. 99-106.