

DOI: <https://doi.org/10.30898/1684-1719.2026.3.14>

УДК: 621.396.96.001 (07)

СРАВНИТЕЛЬНЫЙ АНАЛИЗ ЭФФЕКТИВНОСТИ ОБНАРУЖЕНИЯ СИГНАЛОВ И ОЦЕНИВАНИЯ ИХ ПАРАМЕТРОВ КЛАССИЧЕСКИМИ МЕТОДАМИ И НЕЙРОСЕТЯМИ

Л.Г. Доросинский

Уральский федеральный университет имени первого президента России Б.Н. Ельцина,
620002, Россия, Екатеринбург, ул. Мира, 19

Статья поступила в редакцию 26 февраля 2026 г.

Аннотация. Рассматривается задача обнаружения случайного гауссовского сигнала на фоне белого гауссовского шума при неизвестных уровне SNR и корреляционной функции сигнала. Сравняются энергетический детектор, непараметрические методы (kNN, Парзеновские окна) и нейросетевой детектор. Показано, что применение обеления (whitening) и метода главных компонент позволяет существенно повысить эффективность непараметрических методов. При сильно коррелированном сигнале они достигают характеристик, близких к оптимальному байесовскому детектору и превосходят нейросеть. Эффективность методов определяется структурой сигнала и его эффективным рангом. Вторая часть работы посвящена решению аналогичной проблемы в задаче оценки параметра сигнала, например, его задержки, линейно связанной с дальностью до обнаруженного объекта наблюдения

Ключевые слова: обнаружение, оценка параметров, характеристики обнаружения, отношение сигнал/шум, нейронная сеть.

Автор для переписки: Доросинский Леонид Григорьевич L.Dorosinsky@mail.ru

Введение

Одной из самых актуальных и до конца нерешённых задач современной обработки сигналов в условиях априорной неопределённости является выбор между традиционными непараметрическими правилами решения, основанными на оценивании многомерной плотности вероятности наблюдаемых данных, и методами глубокого машинного обучения, а проще говоря, нейронными сетями. Дело в том, что алгоритмически очевидная методология непараметрических методов встречается, зачастую, с более эффективными, но менее прозрачными алгоритмами нейронной сети. В данном разделе мы проведём названный сравнительный анализ на примере широко распространённой задачи обнаружения случайного гауссовского сигнала на фоне белого шума. Во втором разделе мы проиллюстрируем решение этой проблемы на примере оценки параметра сигнала – запаздывания

1. Постановка задачи

Рассматривается задача обнаружения случайного гауссовского сигнала на фоне аддитивного белого гауссовского шума [1-3]. Вектор наблюдений $x \in \mathbb{R}^N$ подчиняется одной из гипотез:

$$H_0 : x = n, n \sim N(0, I), \quad (1)$$

$$H_1 : x = n + s, s \sim N(0, R_s), \quad (2)$$

где R_s – неизвестная корреляционная матрица сигнала. Отношение сигнал/шум (SNR) также считается неизвестным.

Цель работы заключается в том, чтобы сравнить энергетический детектор (алгоритм, принимающий решение на основании анализа различий мощностей сигнала с шумом и только шума), непараметрические методы (K-ближайших соседей – kNN, окна Парзена) и нейросетевой детектор (MLP) по вероятности обнаружения P_d при фиксированной вероятности ложной тревоги $P_f \approx 0.05$.

2. Методы обнаружения

Далее рассмотрим более подробно собственно алгоритмы обнаружения. Начнём с энергетического детектора. В качестве решающей статистики используется энергия наблюдаемого вектора:

$$T(x) = \|x^2\| = \sum_{i=1}^N x_i^2. \quad (3)$$

Решение принимается в результате сравнения статистики (3) с порогом:

$$T(x) \geq \frac{H_1}{H_0} \gamma, \quad (4)$$

причём значение порога γ выбирается по заданной вероятности ложной тревоги P_f .

Обсуждаемый алгоритм не требует знания корреляционной функции сигнала R_s ; он робастен, так как не использует корреляционную структуру сигнала и, кроме того, служит базой для сравнения с другими непараметрическими алгоритмами и нейронными сетями [4-8].

Среди непараметрических методов рассматривается, в первую очередь, метод k -ближайших соседей (kNN). В этом случае апостериорная вероятность оценивается как доля соседей класса H_1 среди k ближайших соседей:

$$\hat{P}(H_1 / x) = \frac{k_1}{k}. \quad (5)$$

Другим непараметрическим методом является метод окон Парзена, каждое из которых представляет собой гауссову функцию. В результате наблюдения в окрестности каждой наблюдаемой точки реализуется гауссова функция с центром в этой точке:

$$\hat{p}(x / H_j) = \frac{1}{n_j h^N} \sum_{i \in H_j} \exp\left(-\frac{\|x - x_i\|^2}{2h^2}\right). \quad (6)$$

В пространстве сравнительно высокой размерности ($N = 20$) эти методы страдают от «проклятия размерности» и неадекватности евклидовой метрики при наличии корреляции сигнала.

В связи с этим применяемые непараметрические методы нуждаются в сокращении числа признаков путём выделения наиболее значимых из них методами обеления (whitening) и выделения главных компонент (Principal Component Analysis (PSA)).

Сначала устраняется корреляция шума:

$$\begin{aligned}\tilde{x} &= R_n^{-\frac{1}{2}} x, \\ R_n &= M \{nn^T\}.\end{aligned}\quad (7)$$

После операции whitening шум становится изотропным:

$$n \sim N(0, I) \quad (8)$$

Для класса H_1 вычисляется ковариационная матрица whitened-данных, после чего выполняется алгоритм PCA:

$$\tilde{x} \rightarrow z = U_m^T \tilde{x} \quad (9)$$

где U_m – матрица собственных векторов, соответствующих m наибольшим собственным значениям.

Таким образом, исходное пространство размерности N проецируется в подпространство размерности m . Число компонент m может выбираться автоматически по энергетическому критерию:

$$\begin{aligned}\frac{\sum_{i=1}^m \lambda_i}{\sum_{i=1}^N \lambda_i} &\geq \eta, \\ \eta &= 0,9 - 0,95,\end{aligned}$$

где λ_i – собственные значения ковариационной матрицы.

Физический смысл алгоритма РСА заключается в оценивании сигнального подпространства, размерность которого связана с эффективным рангом матрицы R_s .

Для сравнения в работе используется многослойный персептрон (MLP) с одной скрытой прослойкой. Нейросеть обучается непосредственно в исходном пространстве размерности N и аппроксимирует нелинейную (в общем случае квадратичную) границу между гипотезами.

Для сравнения четырёх названных выше алгоритмов был поставлен численный эксперимент со следующими параметрами.

- $N = 20$;
- Обучающие выборки – 2000 реализаций для каждой гипотезы;
- Отношение сигнал/шум (SNR) от -10 до $+10$ дБ;
- Вероятность ложной тревоги $P_f \approx 0.05$;
- Размерность сигнального подпространства, связанного с m наибольшими собственными значениями: $m = 5$.

Рассматриваются два типа сигнала:

- 1) слабо коррелированный $\rho = 0.3$;
- 2) сильно коррелированный с экспоненциальной корреляцией:

$$R_s(i, j) = \exp(-\rho|i - j|),$$
$$\rho = 0.95$$

Результаты моделирования иллюстрируют рисунки (1 и 2).

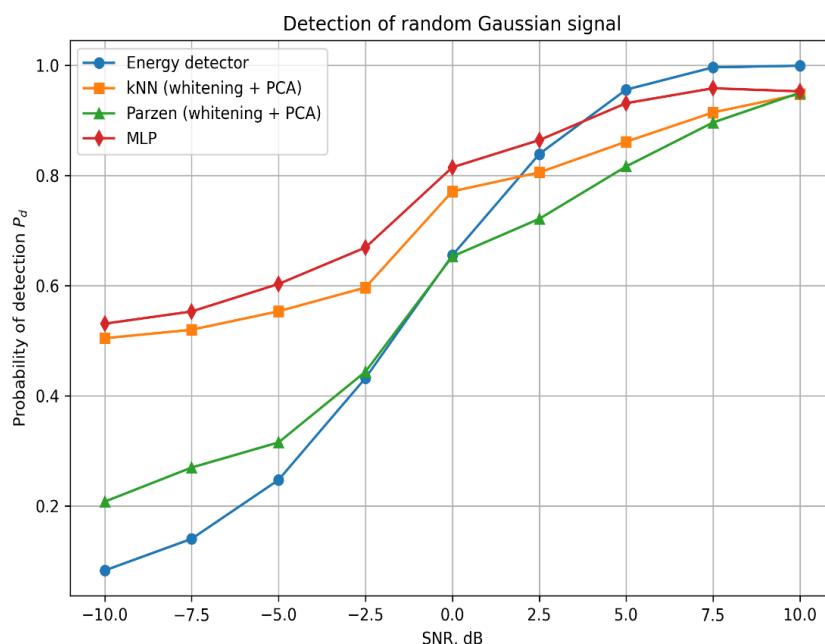


Рис. 1. Сравнение алгоритмов (зависимость вероятности правильного обнаружения от отношения сигнал/шум) при невысокой корреляции (0,3).

При сравнительно небольшой корреляции (0,3):

- MLP демонстрирует наилучшую вероятность обнаружения при низких SNR;
- kNN и Парзен, даже после whitening и PCA, уступают нейросети;
- энергетический детектор остаётся стабильным, но менее эффективным алгоритмом.

Энергия сигнала распределена по нескольким направлениям, и явное сигнальное подпространство выражено слабо.

Аналогичные результаты при сильной корреляции демонстрирует рисунок 2.

В этом случае могут быть сделаны следующие выводы:

- энергия сигнала сосредоточена в маломерном подпространстве;
- PCA эффективно выделяет это подпространство;
- Парзенский детектор достигает почти идеального обнаружения даже при низких SNR;
- kNN остаётся конкурентоспособным;
- MLP теряет преимущество, так как работает в полном пространстве.

Анализ рисунков показывает, что эффективность непараметрических методов принципиально зависит от корреляционной структуры сигнала и эффективного ранга R_s .

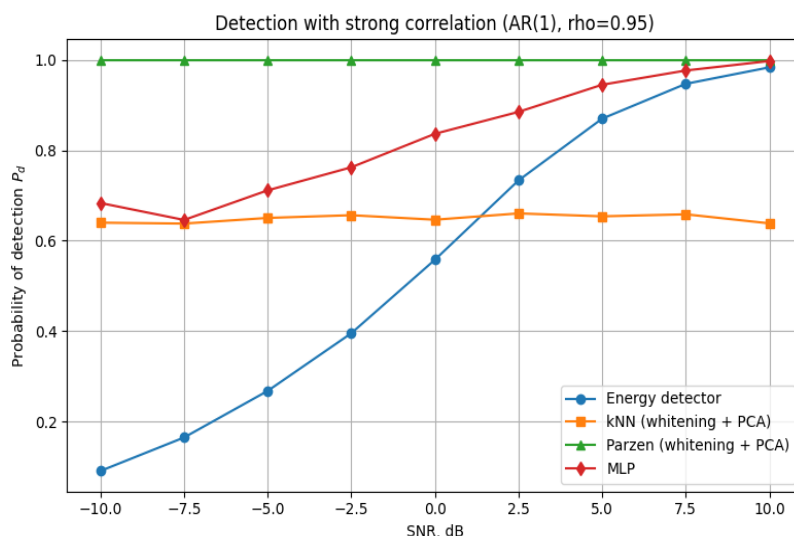


Рис. 2. Сравнение алгоритмов (зависимость вероятности правильного обнаружения от отношения сигнал/шум) при высокой корреляции (0,95).

На рисунке 3 представлены спектры собственных значений корреляционной матрицы сигнала для умеренной ($\rho = 0.3$) и сильной ($\rho = 0.95$) корреляции. В случае сильной корреляции наблюдается резкое доминирование первых одной-двух компонент, что указывает на малый эффективный ранг сигнала. Это объясняет высокую эффективность PCA и последующих непараметрических методов в низкоразмерном подпространстве. При умеренной корреляции спектр более равномерный, и выигрыш от снижения размерности существенно меньше.




Рис. 3. Спектры собственных значений.

Анализ результатов позволяет сделать следующие выводы.

- 1) Энергетический детектор является простой и робастной базовой схемой, но не использует структуру сигнала.
- 2) Непараметрические методы в исходном пространстве страдают от высокой размерности.
- 3) Whitening и PCA превращают kNN и Парзеновские методы в эффективные подпространственные детекторы.
- 4) При сильно коррелированном (низкоранговом) сигнале непараметрические методы в информативном подпространстве достигают эффективности, близкой к оптимальному байесовскому детектору и превосходят нейросеть.
- 5) Нейросеть наиболее эффективна при сложной, распределённой структуре сигнала.

Таким образом можно утверждать, что не существует универсально лучшего детектора: оптимальность метода определяется структурой сигнала и корректным выбором признакового пространства.

3. Оценка параметра классическими методами и НС

Далее рассмотрим решение задачи измерения (оценивания) неизвестного параметра сигнала традиционными классическими методами, основанными на критерии максимального правдоподобия, и методами, основанными на использовании нейронных сетей.

Пусть требуется оценить параметр сигнала, например, дальность R (или задержку τ). Наблюдаемые данные представлены выражением:

$$x(t) = s(t - \tau, \theta) + n(t), \quad (10)$$

где $s(t, \theta)$ – полезный сигнал, θ – вектор параметров сигнала (форма, длительность, спектр и т.п.), $n(t)$ – белый гауссов шум.

Если все параметры сигнала (за исключением оцениваемого) априори точно известны (форма сигнала известна, шум – аддитивный белый гауссовский – AWGN),

то оптимальный алгоритм оценки дальности: оценка максимального правдоподобия (MLE) или согласованный фильтр. В том и другом случае функциональная операция над наблюдаемыми данными:

$$\tau = \arg \max_{\tau} \int x(t) s(t - \tau) dt. \quad (11)$$

Минимально достижимая дисперсия: (граница Крамера–Рао) для AWGN:

$$\sigma_{\tau}^2 \cong \frac{1}{8\pi^2 \beta^2 SNR}, \quad (12)$$

где β^2 – эффективная ширина спектра сигнала.

Оптимальный алгоритм асимптотически эффективен, достигает CRLB, но только при точном знании модели сигнала.

Если параметры сигнала априори неизвестны:

$$x(t) = s(t - \tau, \theta),$$

где θ неизвестны.

Если: используется «не тот» согласованный фильтр, параметры сигнала заданы приближённо, то: максимум корреляции смещается, растёт дисперсия оценки, появляется систематическая ошибка. Другими словами, MLE становится несовпадающим, шум – AWGN, возникает model mismatch (несоответствие модели).

Алгоритм, оптимальный в условиях априорной определённости «деградирует». Так называемая деградация возможна: при изменении формы импульса, при наличии неизвестной доплеровской скорости, при нестабильной ширине спектра, при коррелированных помехах.

Нейросеть в этих условиях фактически реализует оценку по множеству обучающих выборок с широким диапазоном возможных задержек (дальностей):

$$\hat{\tau} = f_{NN}(x(t)).$$

Нейронная сеть не требует явного знания и/или оценки параметра θ , обучается на множестве реализаций: $\{x(t), \tau\}$.

Эффективная работа нейросети связана с тем, что она:

- аппроксимирует условное математическое ожидание $\hat{\tau} \approx M\{x(t), \tau\}$,
- усредняет по неопределённым параметрам сигнала,
- фактически реализует байесовскую оценку с неявными априорными данными.

НС оптимальна не для фиксированной модели, а в среднем по классу сигналов. Основные сравнительные параметры функционирования оптимального алгоритма и нейросети приведены в таблице 1.

При априорной неопределённости параметров сигнала оптимальные алгоритмы, основанные на точной модели, демонстрируют значительную деградацию точности оценки дальности. Нейросетевые методы, обученные на ансамбле реализаций сигналов, обеспечивают более устойчивую оценку за счёт неявного учёта вариабельности параметров и реализации байесовского подхода.

Таблица 1. Сравнение точности

Условия	Оптимальный алгоритм	Нейросеть
Идеальные	Лучший (CRLB)	Чуть хуже
Параметры неточны (ошибочны)	Быстро деградирует	Почти без потерь
Сильная вариабельность сигнала	Плохо	Лучше
Реальный сигнал	Часто неадекватен	Устойчива

Нейросетевая модель обеспечивает более устойчивую оценку и превосходит классический алгоритм в условиях рассогласования между реальной моделью сигнала и моделью, принятой в алгоритме обработки (неизвестная форма импульса, спектр, длительность, доплеровский сдвиг и т.п.) – model mismatch.

Результаты сравнительного анализа точности измерения задержки отражённого сигнала приведены на рисунках 4-6.

При известной модели сигнала оптимальный алгоритм достигает границы Крамера-Рао. При неопределённости параметров сигнала наблюдается деградация точности и появление «полки». Нейросетевая оценка демонстрирует

более устойчивую работу и превосходит классический алгоритм в условиях model mismatch.

В случае, когда форма сигнала и все его параметры точно известны, оптимальной оценкой дальности является оценка максимального правдоподобия, эквивалентная использованию согласованного фильтра.

Для аддитивного белого гауссова шума СКО ошибки оценки дальности асимптотически приближается к границе Крамера-Рао

На графике эта зависимость представлена монотонно убывающей кривой, являющейся нижней границей для всех остальных методов. При корректной модели сигнала данный алгоритм является наилучшим по точности.




Рис. 4. Зависимость СКО ошибки оценки дальности от отношения сигнал/шум. Известные параметры сигнала (логарифмическая шкала).

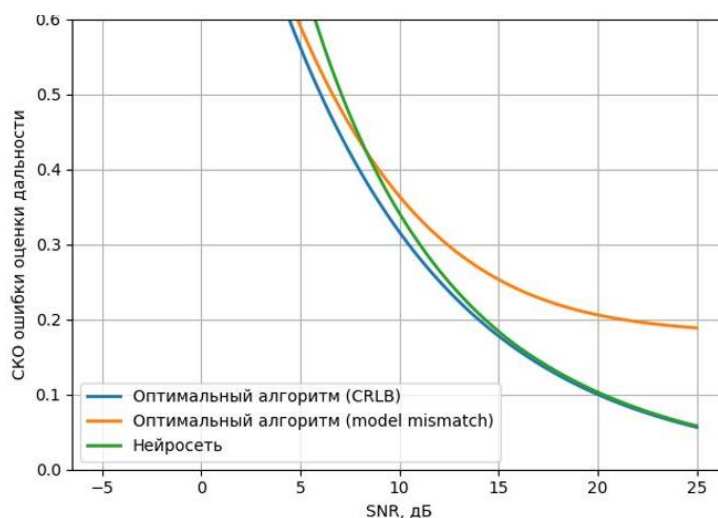


Рис. 5. Зависимость СКО ошибки оценки дальности от отношения сигнал/шум. Параметры сигнала неизвестны (model mismatch).

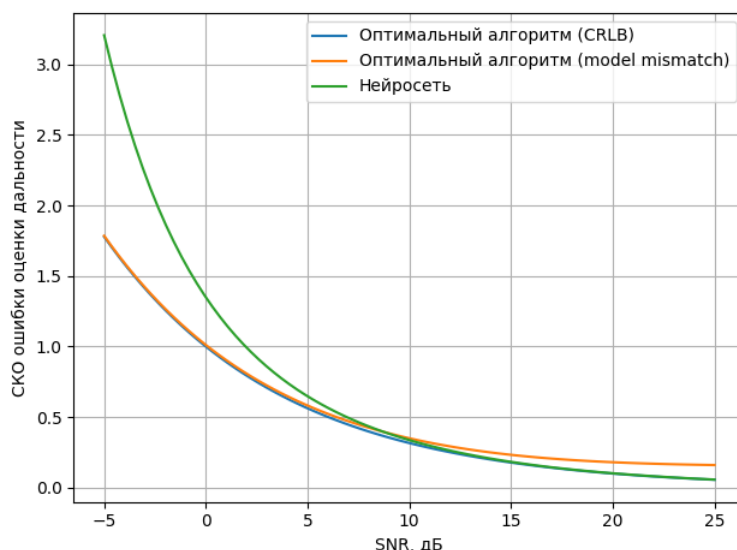


Рис. 6. Зависимость СКО ошибки оценки дальности от отношения сигнал/шум. Известные параметры сигнала (линейная шкала).

Если параметры сигнала неизвестны или заданы с ошибкой, используемый «оптимальный» алгоритм перестаёт быть действительно оптимальным. В этом случае возникают:

- снижение чувствительности корреляционного отклика;
- смещение максимума функции правдоподобия;
- систематическая ошибка оценки дальности.

На графике это проявляется в виде:

- совпадения с оптимальной кривой при малых SNR (доминирует шум);
- существенного ухудшения точности при средних SNR;
- появления «полки» при больших SNR, обусловленной систематической составляющей ошибки.

При априорной неопределённости параметров сигнала классические оптимальные алгоритмы быстро теряют эффективность.

Нейросеть обучается на наборе реализаций сигналов с различными параметрами и уровнями шума. Она не использует явную аналитическую модель сигнала и фактически аппроксимирует условное математическое ожидание. При малых SNR нейросеть уступает оптимальному алгоритму (ограничение информативности данных); при средних и высоких SNR нейросеть превосходит

алгоритм с model mismatch; при больших SNR её точность приближается к оптимальному случаю.

Заключение

Основные выводы о применимости нейросетей могут быть сформулированы следующим образом.

- 1) Классические оптимальные алгоритмы являются оптимальными только при точном знании модели сигнала.
- 2) При model mismatch наблюдается существенная деградация точности, не устранимая увеличением SNR.
- 3) Нейросетевые методы не требуют явного задания параметров сигнала и обладают высокой робастностью.
- 4) В реальных радиотехнических системах, где параметры сигнала меняются или неизвестны, нейросети могут обеспечивать более высокую практическую точность, чем модельно-ориентированные алгоритмы.
- 5) Нейросеть следует рассматривать не как замену оптимальных алгоритмов, а как эффективный инструмент обработки в условиях априорной неопределённости.

Литература

1. Г. В. Трис, Теория обнаружения, оценок и модуляции, т. 1, Москва: Советское радио, 1972, р. 744.
2. Справочник по радиолокации / Под ред. М.И. Сколника. Пер. с англ. под общей ред. В.С. Вербы. В 2 книгах. Книга 2. - Москва: Техносфера, 2014. - 680 с.
3. Доросинский Л.Г., Оптимальная обработка радиолокационных изображений, формируемых в РСА, Москва: Издательский дом Академии Естествознания, 2017, 212с.
4. Тархов Д. А. Нейронные сети. Модели и алгоритмы / Д. А. Тархов – М.: Радиотехника, 2005. – 256 с.
5. Хайкин С. Нейронные сети / С. Хайкин. – М.: Издательский дом «Вильямс», 2006. – 1103с.

6. Рутковская Д. Нейронные сети, генетические алгоритмы и нечеткие системы / Д. Рутковская, М. Пилиньский, Л. Рутковский. – М.: Горячая линия – Телеком, 2006. – 452с.
7. Бишоп К.М. Распознавание образов и машинное обучение. Диалектика, 2020.- 962с.
8. Мереди Бруссард. Искусственный интеллект. Пределы возможного. — М.: Альпина, 2020.-258с.

Для цитирования:

Доросинский Л.Г. Сравнительный анализ эффективности обнаружения сигналов и оценивания их параметров классическими методами и нейросетями. // Журнал радиоэлектроники. – 2026. – №. 3. <https://doi.org/10.30898/1684-1719.2026.3.14>