

DOI: 10.12731/2070-7568-2023-12-2-191-207

УДК 330:004.7:004.032.26



Научная статья |

Математические, статистические и инструментальные методы в экономике

ПОВЫШЕНИЕ КАЧЕСТВА ФУНКЦИОНИРОВАНИЯ ТЕЛЕКОММУНИКАЦИОННЫХ СИСТЕМ НА ОСНОВЕ ИНТЕГРАЦИИ НЕЙРОННЫХ СЕТЕЙ

П.А. Сахнюк, Т.И. Сахнюк

В статье предложена интеграция нейронной сети, – как параллельной элементной базы в системы телекоммуникаций. В этом случае будет использовано их основное преимущество, способность к самообучению или адаптации к внешним условиям. Для систем телекоммуникаций в условиях помех данная способность позволит существенно повысить их помехоустойчивость, надежность, работоспособность и пр. В статье рассмотрен пример интеграции нейронной сети в дискретный согласованный фильтр сигналов. Отмечено, что применение в обработке сигналов параллельной математики, такой как система остаточных классов, приведет к максимальному эффекту повышения параметров качества таких элементов телекоммуникаций.

***Цель** – ознакомление с применением нейронных сетей в цифровой фильтрации; возможные направления интеграции технологий нейронных сетей.*

***Метод или методология проведения работы:** в статье использовались гармонический анализ, преобразование Фурье, корреляционный анализ.*

***Результаты:** внедрение массового параллелизма в телекоммуникации становится реализуемым при интеграции нейронных сетей в элементы телекоммуникации. Эффективность становится максимальной при применении одновременно параллельной математики системы остаточных классов.*

***Область применения результатов:** применение в системах цифровой обработки сигналов с параллельной математикой, такой как система остаточных классов, приведет к максимальному эффекту повышения параметров качества таких элементов телекоммуникаций.*

***Ключевые слова:** нейронная сеть; согласованный фильтр; система остаточных классов; алгоритмы обучения; функция активации; телекоммуникации*

***Для цитирования.** Сахнюк П.А., Сахнюк Т.И. Повышение качества функционирования телекоммуникационных систем на основе интеграции*

нейронных сетей // Наука Красноярья. 2023. Т. 12, №2. С. 191-207. DOI: 10.12731/2070-7568-2023-12-2-191-207

Original article | Mathematical, Statistical and Instrumental Methods in Economics

IMPROVING THE QUALITY OF THE FUNCTIONING OF TELECOMMUNICATION SYSTEMS BASED ON THE INTEGRATION OF NEURAL NETWORKS

P.A. Sakhnyuk, T.I. Sakhnyuk

The article proposes the integration of neural networks as a parallel element base in telecommunications systems. In this case, their main advantage, the ability to self-study or adapt to external conditions, will be used. For telecommunication systems in conditions of interference, this ability will significantly increase their noise immunity, reliability, operability, etc. The article considers an example of integration of a neural network into a discrete matched signal filter. It is noted that the use of parallel mathematics in signal processing, such as a system of residual classes, will lead to the maximum effect of increasing the quality parameters of such elements of telecommunications.

Purpose – introduction to neural networks; application of neural networks in digital filtering; possible directions of integration of neural network technologies.

Method or methodology of the work: harmonic analysis, Fourier transform, correlation analysis were used in the article.

Results: The introduction of mass parallelism in telecommunications becomes feasible when integrating neural networks into telecommunication elements. The efficiency becomes maximum when using simultaneously parallel mathematics of the system of residual classes

Practical implications: the use of parallel mathematics in signal processing, such as a system of residual classes, will lead to the maximum effect of increasing the quality parameters of such elements of telecommunications.

Keywords: neural network; matched filter; residual class system; learning algorithms; activation function; telecommunications

For citation. Sakhnyuk P.A., Sakhnyuk T.I. Improving the Quality of the Functioning of Telecommunication Systems Based on the Integration of Neural Networks. Krasnoyarsk Science, 2023, vol. 12, no. 2, pp. 191-207. DOI: 10.12731/2070-7568-2023-12-2-191-207

Введение

В настоящее время имеет место рост объема трафика передачи информации в сетях связи, связанный с цифровой трансформацией общества [17-19] и переходом ряда видов деятельности в цифровой формат [20-25]. Возрастают требования к показателям качества систем телекоммуникаций, таким как помехоустойчивость, скорость передачи информации, надежность, достоверность и пр. Возникают такие задачи как, «Интеграция различных видов сетей», «Построение информации под существующие каналы», «Перестройка каналов связи под конкретный вид информации», «Оптимизация сигналов относительно качества каналов» и др. [1-5].

С увеличением количества информации появляются задачи скорости ее обработки и качества передачи. До настоящего времени основным путем повышения показателей качества являлось повышение тактовых частот работы оборудования. Вместе с тем, дальнейшее повышение показателей качества в данном направлении стало невозможным. Уже на сегодняшний день достигнуты максимумы в наноструктурах по уменьшению толщины проводников и повышению частот.

Поэтому, очевидным направлением повышения показателей качества остается внедрение параллелизма в процессы передачи и обработки информации [6-8, 13]. Очевидно, что для параллельных систем передачи и обработки параллельных данных необходима «параллельная математика», например, система остаточных классов, необходима параллельная элементная база, такая как нейронные сети. Так же необходимы параллельные каналы связи на основе различных методов уплотнения, алгоритмов и пр. Данная работа посвящена вопросам внедрения массового параллелизма в телекоммуникации. Рассмотрим направления возможной интеграции нейронных сетей в элементы телекоммуникаций [2, 7, 8-11, 14, 15].

Цель исследования

Определение перспективных направлений возможной интеграции нейронных сетей в элементы телекоммуникаций для повышения качества связи.

Материалы и методы исследования

В работе использовались общенаучный метод анализ и синтеза, метод математического моделирования.

Результаты исследования

Возможные направления интеграции технологий нейронных сетей

Определим возможность использования нейронных сетей в элементах телекоммуникаций, рассмотрим базовую математику нейронных сетей и сопоставим с математическими моделями элементов телекоммуникаций [2, 4, 15].

1. Элементная база нейронных сетей

Основой построения нейронных сетей является нейрон, как физический прототип биологического нейрона мозга человека. Функционально его можно представить как (рис. 1), где x_i – входящий информационный вектор нейрона (информация с предшествующих нейронов); $w_{i,j}$ – весовые коэффициенты; $F(u)$ – функция активации (определяется типом решаемой задачи).

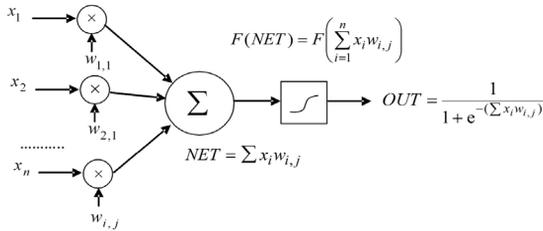


Рис. 1. Модель искусственного нейрона

Активационную функцию считают нелинейной усилительной характеристикой искусственного нейрона, математически реализующую следующую операцию

$$OUT = F\left(\sum_{i=1}^n x_i w_i\right). \quad (1)$$

Уровень возбуждения определяется через отношение увеличения уровня выхода OUT к его небольшому приращению величины входа NET , вызвавшему это приращение. Это приращение определяется наклоном кривой активационной функции. Существует множество активационных функций, например, сигмоидальная активационная функция (рис. 2), которая описывается выражением

$$F(u) = [1 + \exp(-u)]^{-1}. \quad (2)$$

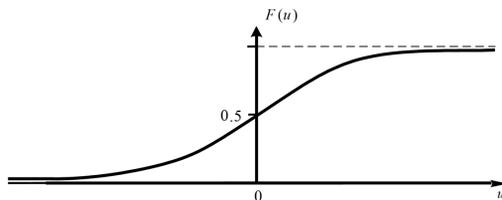


Рис. 2. Сигмоидальная логистическая функция

Другой активационной функцией, адаптированной к системе остаточных классов, является функция кусочно-непрерывного вида (рис. 3), которая оперирует в кольце целых чисел

$$F_2(u) = \left\lfloor \frac{10}{1 + e^{-0,5(u)}} \right\rfloor. \quad (3)$$

Такая функция позволяет плавно подстраивать весовые коэффициенты, исключая влияние случайных отклонений в принимаемом сигнале, т. е. более подходит для случаев возникновения постоянных помех.

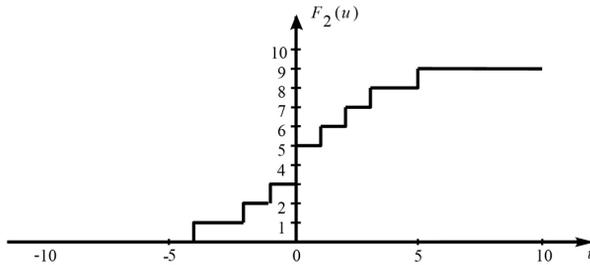


Рис. 3. Сигмоидальная кусочно-непрерывная логистическая функция

В сумматоре происходит сложение входных векторов нейрона, умноженных на векторы весовых коэффициентов, это сумма равна $NET = x_1w_1 + x_2w_2 + \dots + x_nw_n = \sum_{i=1}^n x_iw_i$. Тогда

$$OUT = F(NET) = F\left(\sum_{i=1}^n x_iw_{i,j}\right) = \left[1 + \exp\left(-\sum_{i=1}^n x_iw_{i,j}\right)\right]^{-1}. \quad (4)$$

Одним из преимуществ нейронных сетей является способность их самообучению. Т. е. способность адаптировать весовые коэффициенты w_j к реальным условиям распространения радиоволн. Очевидно, что в отличие от аналитических моделей, реальные условия распространения отличаются наличием внешних помех, влиянием внешней среды, что приводит к искажениям и т. д. Известно, что нейронная сеть способна к обучению на распознавание некоторых входных векторов, которые должны выдавать ожидаемый результат. Обучение происходит таким образом, что весовые коэффициенты подстраиваются таким образом, что выходной вектор соответствовал одному из требуемых результатов. Известно, что обучение может сопровождаться как известной копией сигнала, так и без нее. Это алгоритмы обучения с учителем и без него. Обучение с известной копией предполагает, что для всякого входного вектора должен быть исходный вектор или ожидаемый выход. Далее алгоритм сравнивает полученный результат с заранее известными копиями

сигналов. Определяется отклонение, погрешность и поправка в весовые коэффициенты нейронной сети.

В самом определении «обучение без учителя» предполагается настройка весовых коэффициентов нейронной сети без учета известных образов сигналов. Другими словами, нейронная сеть подстраивает свои весовые коэффициенты по мере повторения одного и того же образа (сигнал), поступающего на вход сети. Аналогом можно назвать выдержку фото пластины с длительной выдержкой. Обучение осуществляется лишь за счет входящей информации. Основные алгоритмы обучения нейронной сети «без учителя» разработал Д. Хэбб, в 1949 г.

Обобщение алгоритма обучения нейрона (дельта-правило) сформулировано в виде

$$w_{i,j}(n+1) = w_{i,j}(n) + \Delta_{i,j}, \quad (5)$$

где $w_{i,j}(n+1)$ – множитель связи (веса) после такта обучения, $w_{i,j}(n)$ – вес i до предыдущего такта обучения, $\Delta_{i,j}$ – поправка, связанная с i -м входом x_i

$$\Delta_{i,j} = \alpha \delta x_i, \quad (6)$$

где α – коэффициент или скорость обучения сети, δ – разница (величина ошибки) между ожидаемым вектором T и реальным вектором Y

$$\delta = (T - Y). \quad (7)$$

Затем происходит умножение δ на значение каждого входа x_i и это произведение суммируется с соответствующим весовым коэффициентом предыдущего такта обучения. Коэффициент обучения подбирается к каждой задаче в зависимости от вида задачи и типа принимаемого сигнала. Очевидно, алгоритм обучения (5–7) можно реализовать в системе остаточных классов. Чтобы использовать систему остаточных классов определим коэффициенты (множители) нейронной сети в соответствие с (5), и рассчитанные по взаимно простым основаниям p_i . Их вычисление должно быть осуществлено с учетом функций активации (рис 3). Выбирая целочисленные значения скорости обучения (6) и начальные значения коэффициентов умножения конечный результат обучения будет также целочисленным. Таким образом, можно существующие правила обучения без учителя преобразовать в итерационные формулы обучения в системе остаточных классов. Это можно выразить, преобразовав известный алгоритм к виду

$$w_{ij}(n+1) = \lfloor w_{ij}(n) + \alpha \Delta_{i,j} \rfloor, \quad w_{ij}(n+1) \equiv (w_{ij}(n) + \alpha \Delta_{i,j}) \pmod{p_i}. \quad (8)$$

Другими словами, матрица весовых коэффициентов будет иметь целочисленные значения. Очевидно, что выходные вектора нейронной сети так же будут иметь целочисленные значения.

Нельзя видеть в нейронных сетях решение всех проблем не формализуемых задач. Последний вопрос в любом случае зависит от программиста. Все зависит от его взгляда и понимания математической модели физического процесса. Важно направить нейронную сеть в правильном направлении обучения.

Рассмотрим основные пути развития в теории телекоммуникаций, в которых необходимо интегрирование нейронных сетей при разработке сигналов, схем, протоколов и пр.

2. Применение нейронных сетей в цифровой фильтрации

Известно, что цифровой фильтр – это алгоритм или устройство обработки сигнала, выполненный программно на электронно-вычислительной машине. Известно, что математическая модель цифрового фильтра описывается выражением

$$Sv(nT) = -\sum_{i=0}^{m-1} a_i \cdot Sv(nT - iT) + \sum_{j=0}^{k-1} b_j \cdot S(nT - jT), \quad (9)$$

где a_m и b_k – коэффициенты ряда и могут подбираться к конкретным задачам; $Sv(nT)$ – выходные значения дискретного сигнала; $S(nT)$ – входной сигнал, m и k – определяют глубину обратной связи. Так, например, для $m = k = 1$ схема, реализующая (9), может быть реализована одним нейроном с обратной связью [14]. При этом в качестве усилителей связей будут играть множители коэффициентов нейронной сети. Очевидно, что (9) можно реализовать в нейронной сети, т. к. оно содержит основные операции, выполняемые нейронной сетью (сложение, умножение) (4). Большая эффективность достигается при реализации цифровых фильтров в параллельной математике.

3. Корреляционная фильтрация сигналов.

При синтезе корреляционных фильтров используют свойства «схожести» сигналов или другими словами оценки их уровня взаимной коррелированности. Функция автокорреляции имеет максимальный центральный всплеск и имеет малые боковые отклики. Чтобы принять решение о приеме сигнала, достаточно оценить уровень центрального отклика, сравнив с ожидаемым согласно выражению

$$R(k) = \sum_{i=1}^n h_i x_{i+k}, \quad (10)$$

где h_i – импульсная характеристики, x_{i+k} – элементы n – разрядного сигнала с k – сдвигом, некоторого порога, аналога функции активации.

Корреляционный анализ в системе остаточных классов эквивалентен корреляционному анализу в обычной математике позиционной системы

счисления. Развитие технологий корреляционных фильтров ограничивается числом допустимых вычислений (n) и необходимостью работы в масштабе реального времени.

Также необходимо создавать непрерывные линии задержки сигнала. Устранение указанных проблем. С использованием нейронных сетей и применении системы остаточных классов можно осуществлять корреляционный любой сложности анализ сигналов в реальном времени. Анализ выражения (10) показывает, что согласованные фильтры так же являются частным случаем нейронной сетей. Аналогичные схемы могут быть выполнены результат обучения нейронных сетей. Вместе с тем, в отличие от жесткой схемной реализации нейронные сети способны к подстройке фильтра к реальным условиям.

4. Гармонический анализ, преобразование Фурье

Гармонический анализ сигналов и фильтров базируется на теории преобразования Фурье. Для дискретных сигналов оно имеет вид

$$C(k\Omega) = \frac{1}{N} \sum_{n=0}^{N-1} S(nT) \exp(-j2\pi nk); \quad S(nT) = \sum_{k=0}^{N-1} C(k\Omega) \exp(jnk\Omega T), \quad (11)$$

где $S(nT)$ – анализируемый дискретный сигнал, N – число отсчетов в периоде сигнала, T – временной интервал дискретизации, $\Omega = 2\pi/(NT)$ – частота преобразования, $C(k\Omega)$ – вычисленные коэффициенты ряда Фурье. Очевидно, что коэффициентов ряда равно числу отсчетов (N) дискретного сигнала. Ограничением существующих схем является число отсчетов в сигнале N . Повышение числа отсчетов ограничено возможностями современных вычислительных средств. Поэтому применяются быстрые алгоритмы преобразования Фурье. При этом либо увеличивается погрешность анализа, либо усложняется техническая реализация устройств анализа.

Анализ выражения (11), показывает, что дискретное (цифровое) преобразование Фурье так же содержит основные операции нейронных сетей (т.е. сложение, умножение). Поэтому для создания анализаторов спектра или устройств гармонического анализа возможно использование нейронных сетей с применением параллельной математики.

5. Помехоустойчивое кодирование

Помехоустойчивое кодирование основано на использовании избыточности в передаваемой информации. Информационные символы делятся на пересекающиеся группы и к каждой группе приписывается проверочный символ так, чтобы в каждой группе было четное число единиц. Математическая запись этой процедуры выглядит

$$b_{l_{np}} = \sum_{i=1}^k \gamma_i a_i, \text{ mod } 2, \quad (12)$$

где a_i – информационные символы, b_i – проверочные символы, $\gamma_{i,l}$ – определяется l уравнением кодирования. Анализ (12) показывает, что схема кодирования так же может быть реализована нейронной сетью в системе остаточных классов, основанной на модульных операциях. Такая реализация позволит осуществлять прием сигналов в целом, объединив первую и вторую решающие схемы.

б. Адаптированные каналы связи.

Существуют направления исследований по созданию адаптированных каналов связи на основе «обратного канала», когда реальном масштабе времени идет учет влияний волновых, дифракционных и пр. искажений во фронте волны. В дальнейшем идет их компенсация (например, метод обратной ионосферы). Т.е. данная задача является не формализуемой. Нейрокомпьютеры предназначены именно для решения подобных задач.

3.6. Фазированные антенные решетки

Синтез и эксплуатация фазированных антенных решеток основана на синхронном сложении сигналов, переданных или принятых отдельными излучателями $S_i(t) \exp(-j\varphi_i)$. Математически это записывается как

$$S(t) = \sum_{i=1}^n S_i(t) \exp\{-j(\omega t + \varphi_i)\}, \quad (13)$$

где φ_i – фазовые сдвиги каждом в i -том излучателе. Ограничение во внедрении фазированных антенных решеток – сложность аналитического описания нестандартных диаграмм направленности, адаптируемых под реальные условия. Например, формирование нулей диаграммы направленности в направлении помех при максимальном отношении сигнал-шум. Т.е. решение трудно формализуемых задач. Анализ (13) показывает, что фазированные решетки могут быть реализованы в нейросетевом базисе. Поскольку основными операциями в (13) являются сумма и произведение, то их реализация в системе остаточных классов станет еще более эффективной [16].

Модель согласованного фильтра дискретных сигналов в нейронной сети

Известно, что дискретные согласованные фильтры дискретных сигналов (рис. 4) имеют жесткую реализацию под конкретный (известный) сигнал. Это является его недостатком, вызывающим снижение помехоустойчивости из-за отсутствия учета влияния внешних постоянных искажений сигналов S_k . Они могут быть вызваны аддитивными и мультипликативными

помехами, а также техническими особенностями выполнения собственных функциональных элементов, таких как линии задержки, особенно.

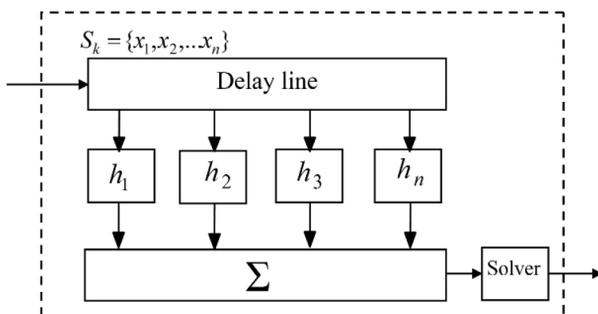


Рис. 4. Filter matched to the signal

Кроме того, жестко реализованный фильтр не способен к адаптации к реально существующим искажениям. Очевидно, что это ведет к уменьшению выхода фильтра и, следовательно, к снижению его показателей качества, таких как помехоустойчивость. Так же согласованные фильтры снижают показатели качества приема сигналов в случае возникновения несократимых ошибок, так как их импульсная характеристика h_i отражает импульсные характеристики ожидаемых сигнала. Ожидаемые сигналы заранее известны и фиксированы.

Очевидно, что для устранения указанных проблем возможно в основном за счет добавления внедрения массового параллелизма или добавлением в дискретный согласованный фильтр нейронной сети.

Далее детально рассмотрим функционирование согласованного фильтра, чтобы понять на каком уровне необходимо интегрировать в него нейронную сеть. Заметим, что структура согласованного фильтра имеет параллельный вид, а линия задержки обусловлена необходимостью приема последовательного сигнала. Известно, что согласованный фильтр вычисляет взаимно корреляционную функцию $R(k)$ для принимаемого сигнала $S = \{x_i\}$ и импульсной характеристики известного (ожидаемого) сигнала $H = \{h_i\}$ в зависимости от временного сдвига относительно друг друга k (10). В момент максимального значения $\max[R(k)]$ принимается решение обнаружения сигнала. Искажения принимаемого сигнала $S = \{x_i\}$ могут существенно снизить максимальный корреляционный отклик функции (10) $R(k)$. Рассмотрим пример такого фильтра. На рис. 4 входной дискретный сигнал $S_k = \{x_1, x_2, \dots, x_n\}$ задерживаются в элементе – (Delay line) ли-

нии задержке. Далее он поступает и проходят через аттенюаторы h_i или множители и, складываясь в сумматоре (Σ). Сумматор отклик на выходе дискретного фильтра. Значение аттенюаторов определяется импульсной характеристикой сигнала. Когда наблюдается превышение определенного уровня этим откликом, то принимается решение обнаружение сигнала. В этом случае «определяющее» устройство (Solver), настроенное на порог обнаружения, принимает решение об обнаружении сигнала. Посмотрим на структурную схему цифрового дискретного согласованного фильтра (рис. 4). то можно заметить, что она соответствует схеме обученного нейрона (рис. 1), реализующего (10). Видно, что фактически можно заменить множители самообучающейся нейронной сетью. Это повысит все основные показатели качества, какие как помехоустойчивость. Нейронная сеть обладает свойствами распознавания образов, сглаживая искажения, что позволяет компенсировать различные виды помех и искажений и повысить помехоустойчивость.

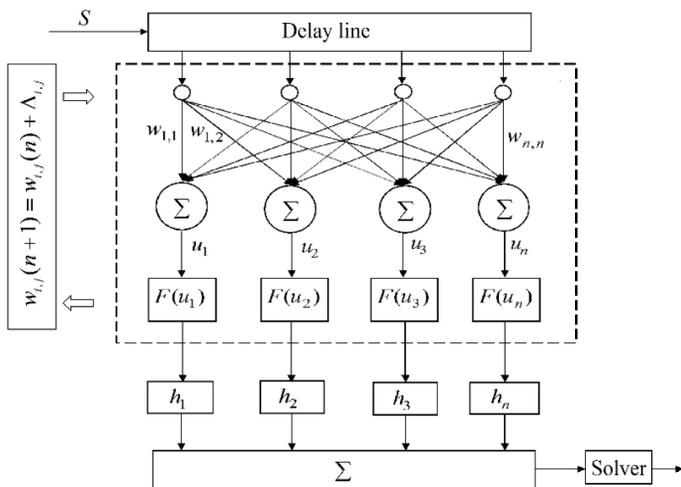


Рис. 5. Адаптивный согласованный фильтр

На рис. 5 представлен один из вариантов такой реализации, где на уровне импульсной характеристики внедрена нейронная сеть. При этом аттенюаторы, выполняющие роль импульсной характеристики h_i , можно учесть при выборе функций активации $F(u_i)$ нейронной сети. Роль выходного сумматора и решающего устройства соответственно выполняет общий выходной нейрон. Линия задержки (Delay line) необходима, чтобы

последовательный сигнал преобразовать в параллельной. Очевидно, если использовать параллельный формат данных в системе остаточных классов, то линию задержки можно исключить.

Здесь устройство (Solver) принимает решение о приеме сигнала. Одним из основных методов принятия решения является критерий Неймана-Пирсона. Данный критерий учитывает вероятность ложной тревоги. Его можно учесть в качестве выходной функции активации. Значение весовых коэффициентов связи вычисляется согласно алгоритму обучения нейронной сети по правилу Хэбба,

Окончательно математическую модель адаптивного согласованного фильтра можно получить подстановкой выражений (2) и (4) в выражение (10) для обычного согласованного фильтра. Таким образом получим окончательно

$$R(k) = \sum_{i=1}^n \left(1/1 + \exp \left[\sum_{j=1}^n x_{j+k} w_{i,j} \right] \right) h_i. \quad (14)$$

Полученное выражение (14) можно непосредственно использовать при моделировании, а также при синтезе схем адаптивной согласованной фильтрации.

Выводы

Как показывает наше исследование, внедрение массового параллелизма в телекоммуникации становится реализуемым при интеграции нейронных сетей в элементы телекоммуникации. Эффективность становится максимальной при применении одновременно параллельной математики системы остаточных классов.

Данные рекомендации могут выступать в качестве основы для разработки технологий повышения качества, устойчивости и скорости связи, что является необходимым условием для перехода к цифровой экономике

Список литературы

1. Jurgen W. Schmidhuber Deep learning in neural networks: An overview // Neural Networks. 2015. Volume 61. P. 85-117. <https://doi.org/10.1016/j.neunet.2014.09.003>
2. Funabiki N., Takefuji Y, Neural network parallel algorithm for channel assignment problems in cellular radio networks // IEEE Transactions on Vehicular Technology. 1992. Vol. 41, № 4. P. 464 – 474.

3. Funabiki Nobuo, Takefuji Yoshiyasu, Lee Cuo Chun. A neural network model for traffic control in multistage interconnection networks // IJCNN-91, Seattle, Wash., July 8-12, 1991. Vol. 2. P. 898.
4. Смирнов А.А. и др. Синтез элементов вычислительных систем в нейросетевом базисе // Современные наукоемкие технологии. 2018. № 7. С. 98-102. <https://doi.org/10.17513/snt.37086>
5. Karras D.A., Zorkadis V. On neural network techniques in the secure management of communication systems through improving and quality assessing pseudorandom stream generators // Neural Networks. 2003. Vol. 16, Issues 5–6. P. 899-905 [https://doi.org/10.1016/S0893-6080\(03\)00124-2](https://doi.org/10.1016/S0893-6080(03)00124-2)
6. Смирнов А.А. и др. Числа Мерсенна в основаниях системы остаточных классов при передаче данных в последовательных каналах связи // Итоги науки и техники. Современная математика и ее приложения. Тематические обзоры, 2019 г. Том 166. М.: ВИНТИ РАН. С. 87-94. <https://doi.org/10.36535/0233-6723-2019-166-87-94>
7. Aazhang B., Paris B.P., Orsak G. C. Neural Networks for Multiuser Detection in CDMA Communications // IEEE Trans. Comm., July 1992, Vol. 40. P. 1212-1222.
8. Atsushi H. ATM communications network control by neural networks // IEEE Transactions on Neural Networks. 1990. Vol. 1, №1. <https://doi.org/10.1109/72.80211>
9. Amirhossein T., Masoud G., Saeed Reza K., Timothée M. Deep learning in spiking neural networks // Maida Neural Networks. 2019. Vol. 111. P. 47-63, <https://doi.org/10.1016/j.neunet.2018.12.002>
10. S. Herzog, C.Tetzlaff, F.Wörgötter Evolving artificial neural networks with feedback // Neural Networks. 2020. Vol. 123. P. 153-162. <https://doi.org/10.1016/j.neunet.2019.12.004>
11. Смирнов А.А., Сахнюк П.А. Нейросетевая реализация оптимального приемника в двоичных каналах связи // Проектирование и технологии электронных средств. Владимир: ВлГУ, 2018. № 2. С. 3-9.
12. He G., Tang P., Pang X. Approaches to Implementation of Optimum Multiuser Detection in CDMA Channels // International Journal of Electronics. 1996. Vol. 80. P. 425-431. <https://doi.org/10.1080/002072196137264>
13. Смирнов А.А., Сахнюк П.А., Саиэг Т.Х., Васильченко А.С., Ярошук А.А. Оценка помехоустойчивости каналов связи с замираниями при интеграции нейронной сети // Проектирование и технологии электронных средств. ВлГУ, 2019. № 4. С. 3-9.
14. Смирнов А.А., Сахнюк П.А., Сенник В.В. Синтез схем цифровой обработки сигналов на основе обучения нерасетевых схем // Нейрокомпьютеры, разработка и применение. М.: Радиотехника. 2004, № 5-6. С. 91-94.

15. Brown T. X. Neural network for switcing. IEEE Comm. Mag., Nov., 1989, pp.72-81.
16. Zhang D., Jullien G.A. and Miller W. C. (1989). A neural-like approach to finite ring computation // IEEE Trans. Circuits and Syst., 1990. V. 37, № 8. P. 1048-1052.
17. Плотников В. А. Цифровизация как закономерный этап эволюции экономической системы // Экономическое возрождение России. 2020. № 2(64). С. 104-115. <https://doi.org/10.37930/1990-9780-2020-2-64-104-115>
18. Плотников В. А. Последствия цифровизации для современного социума / В. А. Плотников, В. Л. Нгуен // Современная наука: актуальные проблемы теории и практики. Серия: Экономика и право. 2022. № 1. С. 212-215. <https://doi.org/10.37882/2223-2974.2022.01.35>
19. Апатова Н. В. Цифровые трансформации бизнеса и социума // Вестник Тверского государственного университета. Серия: Экономика и управление. 2022. № 4(60). С. 60-71. <https://doi.org/10.26456/2219-1453/2022.4.060-071>
20. Подготовка бизнеса к цифровизации и его адаптация / Е. А. Алексеева, А. А. Гракун, Е. Д. Доморацкий, А. Д. Лычакова // Финансовый бизнес. 2022. № 1(223). С. 3-7.
21. Суворова С. Д. Цифровая трансформация бизнеса / С. Д. Суворова, О. М. Куликова // Инновационная экономика: перспективы развития и совершенствования. 2022. № 2(60). С. 54-59. <https://doi.org/10.47581/2022/IE.2.60.10>
22. Апатова Н. В. Управление процессами цифровой трансформации бизнеса // Ученые записки Крымского федерального университета имени В.И. Вернадского. Экономика и управление. 2022. Т. 8. № 2. С. 3-8.
23. Катрашова Ю. В. Использование «сквозных» цифровых технологий в сфере государственного управления / Ю. В. Катрашова, Г. Ю. Митяшин // Наука Красноярья. 2020. Т. 9. № 4. С. 85-102. <https://doi.org/10.12731/2070-7568-2020-4-85-102>
24. Катрашова Ю. В. Система социального рейтинга как форма государственного контроля над обществом: перспективы внедрения и развития, угрозы реализации / Ю. В. Катрашова, Г. Ю. Митяшин, В. А. Плотников // Управленческое консультирование. 2021. № 2(146). С. 100-109. <https://doi.org/10.22394/1726-1139-2021-2-100-109>
25. Котляров И. Д. Цифровая трансформация финансовой сферы: содержание и тенденции // Управленец. 2020. Т. 11, № 3. С. 72-81. <https://doi.org/10.29141/2218-5003-2020-11-3-6>

References

1. Jurgen W. Schmidhuber Deep learning in neural networks: An overview. *Neural Networks*. 2015. Volume 61. P. 85-117. <https://doi.org/10.1016/j.neunet.2014.09.003>

2. Funabiki N., Takefuji Y, Neural network parallel algorithm for channel assignment problems in cellular radio networks. *IEEE Transactions on Vehicular Technology*. 1992. Vol. 41, No. 4. P. 464 – 474.
3. Funabiki Nobuo, Takefuji Yoshiyasu, Lee Cuo Chun. A neural network model for traffic control in multistage interconnection networks. *IJCNN-91*, Seattle, Wash., July 8-12, 1991. Vol. 2. P. 898.
4. Smirnov A.A. and others. Synthesis of elements of computer systems in a neural network basis. *Modern science-intensive technologies*. 2018. No. 7. pp. 98-102. <https://doi.org/10.17513/snt.37086>
5. Karras D.A., Zorkadis V. On neural network techniques in the secure management of communication systems through improving and quality assessing pseudorandom stream generators. *Neural Networks*. 2003. Vol. 16, Issues 5–6. P. 899-905 [https://doi.org/10.1016/S0893-6080\(03\)00124-2](https://doi.org/10.1016/S0893-6080(03)00124-2)
6. Smirnov A.A. and others. Mersenne numbers in the bases of the system of residual classes when transmitting data in serial communication channels. *Results of Science and Technology. Modern mathematics and its applications. Thematic reviews*, 2019. Volume 166. M.: VINITI RAS. pp. 87-94. <https://doi.org/10.36535/0233-6723-2019-166-87-94>
7. Aazhang V., Paris V.P., Orsak G. S. Neural Networks for Multiuser Detection in CDMA Communications. *IEEE Trans. Comm.*, July 1992, Vol. 40. P. 1212-1222.
8. Atsushi H. ATM communications network control by neural networks. *IEEE Transactions on Neural Networks*. 1990. Vol. 1, No. 1. <https://doi.org/10.1109/72.80211>
9. Amirhossein T., Masoud G., Saeed Reza K., Timothée M. Deep learning in spiking neural networks. *Maida Neural Networks*. 2019. Vol. 111. P. 47-63, <https://doi.org/10.1016/j.neunet.2018.12.002>
10. S. Herzog, C. Tetzlaff, F. Wörgötter Evolving artificial neural networks with feedback. *Neural Networks*. 2020. Vol. 123. P. 153-162. <https://doi.org/10.1016/j.neunet.2019.12.004>
11. Smirnov A.A., Sakhnyuk P.A. Neural network implementation of an optimal receiver in binary communication channels. *Design and technology of electronic means*. Vladimir: VLGU, 2018. No. 2. P. 3-9.
12. He G., Tang P., Pang X. Approaches to Implementation of Optimum Multiuser Detection in CDMA Channels. *International Journal of Electronics*. 1996. Vol. 80. P. 425-431. <https://doi.org/10.1080/002072196137264>
13. Smirnov A.A., Sakhnyuk P.A., Sayeg T.Kh., Vasilchenko A.S., Yaroshuk A.A. Assessing the noise immunity of fading communication channels when integrat-

- ing a neural network. *Design and technology of electronic means*. VIGU, 2019. No. 4. P. 3-9.
14. Smirnov A.A., Sakhnyuk P.A., Senik V.V. Synthesis of digital signal processing circuits based on training of non-network circuits. *Neurocomputers, development and application*. M.: Radio engineering. 2004, no. 5-6. pp. 91-94.
 15. Brown T. X. Neural network for switching. *IEEE Comm. Mag.*, Nov., 1989, pp.72-81.
 16. Zhang D., Jullien G.A. and Miller W. C. (1989). A neural-like approach to finite ring computation. *IEEE Trans. Circuits and Syst.*, 1990. V. 37, No. 8. P. 1048-1052.
 17. Plotnikov V. A. Digitalization as a natural stage in the evolution of the economic system. *Economic revival of Russia*. 2020. No. 2(64). pp. 104-115. <https://doi.org/10.37930/1990-9780-2020-2-64-104-115>
 18. Plotnikov V. A. Consequences of digitalization for modern society / V. A. Plotnikov, V. L. Nguyen. *Modern science: current problems of theory and practice. Series: Economics and law*. 2022. No. 1. P. 212-215. <https://doi.org/10.37882/2223-2974.2022.01.35>
 19. Apatova N.V. Digital transformations of business and society. *Bulletin of Tver State University. Series: Economics and management*. 2022. No. 4(60). pp. 60-71. <https://doi.org/10.26456/2219-1453/2022.4.060-071>
 20. Preparing business for digitalization and its adaptation / E. A. Alekseeva, A. A. Grakun, E. D. Domoratsky, A. D. Lychakova. *Financial business*. 2022. No. 1(223). pp. 3-7.
 21. Suvorova S. D. Digital transformation of business / S. D. Suvorova, O. M. Kulikova. *Innovative economics: prospects for development and improvement*. 2022. No. 2(60). pp. 54-59. <https://doi.org/10.47581/2022/IE.2.60.10>
 22. Apatova N.V. Managing the processes of digital transformation of business. *Scientific notes of the Crimean Federal University named after V.I. Vernadsky. Economics and Management*. 2022. T. 8. No. 2. P. 3-8.
 23. Katrashova Yu. V. The use of “end-to-end” digital technologies in the field of public administration / Yu. V. Katrashova, G. Yu. Mityashin. *Science of Krasnoyarsk*. 2020. T. 9. No. 4. P. 85-102. <https://doi.org/10.12731/2070-7568-2020-4-85-102>
 24. Katrashova Yu. V. Social rating system as a form of state control over society: prospects for implementation and development, threats to implementation / Yu. V. Katrashova, G. Yu. Mityashin, V. A. Plotnikov. *Management consulting*. 2021. No. 2(146). pp. 100-109. <https://doi.org/10.22394/1726-1139-2021-2-100-109>
 25. Kotlyarov I. D. Digital transformation of the financial sector: content and trends. *Manager*. 2020. T. 11, No. 3. P. 72-81. <https://doi.org/10.29141/2218-5003-2020-11-3-6>

ДАнные ОБ АВТОРАХ

Сахнюк Павел Анатольевич, доцент, департамента бизнес-информатики, кандидат технических наук
Финансовый университет при правительстве Российской Федерации
Ленинградский проспект, 49, г. Москва, 125993, Российская Федерация
pav-sahnyuk@yandex.ru

Сахнюк Татьяна Ивановна, доцент департамента информатики, управления и технологий, кандидат экономических наук
Институт цифрового образования Московского городского педагогического университета
ул. Шереметьевская, 28, г. Москва, 129594, Российская Федерация
Tatiana-sakhnyuk@yandex.ru

DATA ABOUT THE AUTHORS

Pavel A. Sakhnyuk, Associate Professor, Department of Business Informatics, Candidate of Technical Sciences
Financial University under the government of the Russian Federation
49, Leningradsky Ave., Moscow, 125993, Russian Federation
pav-sahnyuk@yandex.ru
SPIN-code: 7192-6869
ORCID: <https://orcid.org/0000-0002-1457-0640>
ResearcherID: GRR-6444-2022
Scopus Author ID: 57191248583

Tatyana I. Sakhnyuk, Associate Professor, Department of Informatics, Management and Technology
Institute of Digital Education, Moscow City Pedagogical University
28, Sheremetevskaya Str., Moscow, 129594, Russian Federation
Tatiana-sakhnyuk@yandex.ru
SPIN-code: 5339-2920
ORCID: <https://orcid.org/0000-0003-2929-0112>
Scopus Author ID: 57191247960

Поступила 07.04.2023
После рецензирования 29.04.2023
Принята 15.05.2023

Received 07.04.2023
Revised 29.04.2023
Accepted 15.05.2023