

DSPA:

Вопросы применения цифровой обработки сигналов

№3

2023

СОДЕРЖАНИЕ

Волчков В.П., Санников В.Г. ФИЛЬТРОВОЙ ПОДХОД К АППРОКСИМАЦИИ ДИСКРЕТНЫХ СИГНАЛОВ НА ОСНОВЕ РЕКУРСИВНЫХ МОДЕЛЕЙ	4
Вотяков С.Ю., Детушева П.В., Мазин В.А., Фаст С.С., Можаяева А.И. БАЗА ДАННЫХ МТУСИ С ПОСТОЯННОЙ СУБЪЕКТИВНОЙ ОЦЕНКОЙ: ИССЛЕДОВАНИЕ И УСТРОЙСТВО ГЕНЕРАЦИИ ВИДЕОПОСЛЕДОВАТЕЛЬНОСТЕЙ ПОСТОЯННОГО КАЧЕСТВА	12
Вяткин М.А., Хиженкова О.В., Сафонов И.А. ЛАБОРАТОРНАЯ РАБОТА «ОТСЛЕЖИВАНИЯ ВЗГЛЯДА ЧЕЛОВЕКА ВО ВРЕМЯ ПРОСМОТРА МУЛЬТИМЕДИА КОНТЕНТА ПРИ ПОТОКОВОЙ ПЕРЕДАЧИ ДАННЫХ»	20
Гусев А.С. РАЗРАБОТКА НЕЙРОННОЙ СЕТИ ДЛЯ ОПРЕДЕЛЕНИЯ ЦЕНОВОЙ КАТЕГОРИИ АВТОМОБИЛЯ НА ОСНОВАНИИ ЕГО ХАРАКТЕРИСТИК	26
Мингалеев М.А., Белов Н.В. ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ В ОБЛАСТИ РАСПОЗНАВАНИЯ СИГНАЛОВ В ЭФИРНЫХ ШУМАХ	35
Шведов А.В., Гадасин Д.В., Клыгина О.Г., Тремасова Л.А. ОПТИМИЗАЦИЯ МАРШРУТИЗАЦИИ В СЕТИ ПРИ ПОМОЩИ ГАМИЛЬТОНОВА ЦИКЛА И МАРКОВСКОГО ПРОЦЕССА ПРИНЯТИЯ РЕШЕНИЙ	42

ФИЛЬТРОВОЙ ПОДХОД К АППРОКСИМАЦИИ ДИСКРЕТНЫХ СИГНАЛОВ НА ОСНОВЕ РЕКУРСИВНЫХ МОДЕЛЕЙ

Волчков Валерий Павлович,

Московский Технический Университет Связи и Информатики, проф., д.т.н., Москва, Россия
volchkovvalery@mail.ru

Санников Владимир Григорьевич,

Московский Технический Университет Связи и Информатики, доц., к.т.н., Москва, Россия
tes_mtuci@mail.ru

Аннотация

Для аппроксимации дискретных сигналов, заданных на бесконечном двухстороннем интервале времени, предлагается использовать каузальные и антикаузальные рекурсивные разностные модели, обычно применяемые в теории цифровой фильтрации. Разрабатывается метод оптимального оценивания параметров таких рекурсивных моделей и на его основе получены аналитические выражения для алгоритма наилучшей аппроксимации сигналов по его конечной выборке. Получены аналитические выражения, описывающие спектр аппроксимирующего сигнала. Приводятся результаты эксперимента, подтверждающие хорошее качество предложенной фильтровой аппроксимации сигнала как во временной, так и в спектральной областях.

Ключевые слова: *рекурсивные фильтр, разностные модели, дискретные сигналы, каузальные сигналы, некаузальные сигналы, метод наименьших квадратов*

Введение

Рассматривается дискретный вещественный детерминированный сигнал $s[i] \in \mathbb{R}, i \in \mathbb{Z}$ с конечной энергией $\sum_{i=-\infty}^{\infty} s^2[i] < \infty$ задан в виде последовательности отсчетов на бесконечном целочисленном интервале времени $\mathbb{Z} = \{0, \pm 1, \pm 2, \dots\}$. Предполагается, что аналитическое выражение, описывающее данный сигнал, или неизвестно или очень сложное для анализа и практического применения. Ставится задача – найти такое модельное аналитическое выражение, которое бы, с одной стороны, обеспечивало хорошую аппроксимацию дискретного сигнала $s[i], i \in \mathbb{Z}$ в смысле некоторого критерия оптимальности, а с другой – было простым для анализа во временной и спектральной области и создавала предпосылки последующего применения на практике.

Если задано аналитическое описание непрерывного сигнала $s(t), t \in \mathbb{R}$ из которого получен дискретный сигнал $s[i], i \in \mathbb{Z}$, то известные решения данной задачи часто сводятся к его разложению $s(t) \approx \sum_{n=1}^N \alpha_n \varphi_n(t)$ в ряд по системе ортогональных функций $\{\varphi_n(t)\}$, с последующим усечением этого ряда и его дискретизации [1-4]. Однако применение этого подхода не всегда бывает простым и конструктивным. Другие решения основаны на представлении сигнала $\{s[i]\}$ в дискретных конечномерных базисах, в том числе гармонических [2,3], но качество такой аппроксимации и ее сложность трудно контролировать. Кроме того, они не всегда удобны для применения на практике, поскольку не создают предпосылки для последующего синтеза эффективных алгоритмов обработки сигналов.

В работе предлагается иной подход, при котором для аппроксимации дискретного сигнала используются специальные разностные модели, которые обладают хорошими аппроксимирующими свойствами и допускают эффективный алгоритм идентификации по критерию минимальной среднеквадратической ошибки (СКО). Показано, что предлагаемый метод аппроксимации позволяет достаточно просто оценивать комплексный и амплитудный спектр сигнала, получены строгие

аналитические выражения для этих спектральных оценок. Приводятся результаты экспериментального исследования, подтверждающие эффективность фильтровой аппроксимации сигнала во временной и частотной областях.

Математическая формализация задачи и ее решение

Аппроксимацию сигнала $s[i], i \in \mathbb{Z}$ бесконечном двухстороннем интервале времени $\mathbb{Z} = \{0, \pm 1, \pm 2, \dots\}$ разобьем на две части – каузальную (при $i \geq 0$) и антикаузальную (при $i < 0$). Для аппроксимации сигнала на каждом из этих бесконечных временных полуинтервалов используем свою рекурсивную модель, задаваемую разностным уравнением:

$$y[i^+] = \sum_{l=1}^{L^+} a_l^+ y[i^+ - l] + \sum_{m=0}^{M^+} b_m^+ \delta[i^+ - m], \quad i^+ = 0, +1, +2, \dots \quad (1)$$

$$\text{Нач. усл. } y[-1] = \dots = y[-L] = 0,$$

$$y[i^-] = \sum_{l=1}^{L^-} a_l^- y[i^- + l] + \sum_{m=0}^{M^-} b_m^- \delta[i^- + m], \quad i^- = 0, -1, -2, \dots \quad (2)$$

$$\text{Нач. усл. } y[1] = \dots = y[L] = 0,$$

где параметры $\{a_l^+\}, \{b_m^+\}$ каузальной модели (1) и параметры $\{a_l^-\}, \{b_m^-\}$ антикаузальной модели (2) предполагаются вещественными;

$$\delta[i] = \begin{cases} 1, & i = 0 \\ 0, & i \neq 0 \end{cases} \quad (3)$$

– единичный импульс Кронекера;

$$\{y[i]\} = \{y[i^-]\} \cup \{y[i^+]\} / y[0], \quad i = 0, \pm 1, \pm 2, \dots \quad (4)$$

– последовательность, аппроксимирующая дискретный сигнал $s[i] \in \mathbb{R}, i = 0, \pm 1, \pm 2, \dots$ на двухстороннем целочисленном интервале времени $\mathbb{Z} = \{0, \pm 1, \pm 2, \dots\}$. Здесь $\cup, /$ – символы объединения и вычитания множеств, соответственно.

Отметим, что каузальная модель (1) рекуррентно формирует значения процесса $\{y[i]\}$ в прямом времени, а модель (2) – в обратном времени от начальной точки $i = 0$, которую мы для симметрии включаем в алгоритм формирования каждого из уравнений. Количество слагаемых L^+, L^- и M^+, M^- в соответствующих суммах правой части уравнений (1), (2) могут различаться, а параметры L^+, L^- определяют рекурсивный порядок этих уравнений. Если дискретная функция $y[i], i \in \mathbb{Z}$ четная, т.е. $y[i] = y[-i]$, то полагаем $a_l^+ = a_l^-, b_m^+ = b_m^-, L^+ = L^-, M^+ = M^-$ и описание сигнала $\{y[i]\}$ упрощается. Аналогичное упрощение получаем в случае нечетного сигнала.

Предлагаемый метод описания дискретного сигнала $\{y[i]\}$ (4) будем называть *фильтровым*, поскольку он представляет объединение процессов $\{y[i^+]\}, \{y[i^-]\}$ на выходе двух формирующих рекурсивных фильтров, работающих в прямом и обратном времени, соответственно.

Отметим, что соответствующая двухкомпонентная фильтровая модель (1), (2) обладает хорошими аппроксимирующими свойствами за счет возможности изменения количества ее параметров $\{a_l^+\}, \{b_m^+\}, \{a_l^-\}, \{b_m^-\}$ в положительной и отрицательной временной области и оптимальной подгонки их значений (выполнения процедуры идентификации)

Задача наилучшей аппроксимации сигнала $s[i], i \in \mathbb{Z}$

дискретным процессом $\{y[i]\}$ сводится к такому выбору ее параметров $\{a_l^\pm\}, \{b_m^\pm\}$, при которой ошибка аппроксимации будет минимальной.

Эту задачу удобно разбить на три этапа. Сначала решается задача оптимальной аппроксимации для каузальной части $\{y[i^+]\}$, описываемой моделью (1). Затем аналогичная задача решается для антикаузальной части $\{y[i^-]\}$, описываемой моделью (2). И, наконец, на третьем этапе оба полученных решения объединяются в соответствии с выражением (4).

Пусть известна выборка \mathbf{s}^+ из N^+ отсчетов каузальной части сигнала $\{s[i^+]\}$ и аналогичная выборка \mathbf{s}^- из N^- отсчетов антикаузальной части сигнала $\{s[i^-]\}$

$$\mathbf{s}^+ = (s[0], s[1], \dots, s[N^+ - 1])^T, \quad \mathbf{s}^- = (s[0], s[-1], \dots, s[-N^- + 1])^T. \quad (5)$$

Введем обозначения:

$$\mathbf{w}^+ = (a_1^+, \dots, a_{L^+}^+, b_0^+, \dots, b_{M^+}^+)^T, \quad \mathbf{w}^- = (a_1^-, \dots, a_{L^-}^-, b_0^-, \dots, b_{M^-}^-)^T \quad (6)$$

– векторы-столбцы параметров моделей (1), (2) размерности $(L + M + 1) \times 1$.

$$\mathbf{Q}^+ = \begin{pmatrix} 0 & 0 & \dots & 0 & 1 & 0 & \dots & 0 \\ s[0] & 0 & \dots & 0 & 0 & 1 & \dots & 0 \\ s[1] & s[0] & \ddots & 0 & 0 & 0 & \ddots & 0 \\ s[2] & s[1] & \ddots & 0 & 0 & 0 & 0 & 1 \\ \vdots & \vdots & \ddots & \vdots & 0 & 0 & \dots & 0 \\ s[N^+ - 3] & s[N^+ - 4] & \dots & 0 & \vdots & \vdots & \ddots & \vdots \\ s[N^+ - 2] & s[N^+ - 3] & \dots & s[N^+ - L^+ - 1] & 0 & 0 & \dots & 0 \end{pmatrix}$$

$$\mathbf{Q}^- = \begin{pmatrix} 0 & 0 & \dots & 0 & 1 & 0 & \dots & 0 \\ s[0] & 0 & \dots & 0 & 0 & 1 & \dots & 0 \\ s[-1] & s[0] & \ddots & 0 & 0 & 0 & \ddots & 0 \\ s[-2] & s[-1] & \ddots & 0 & 0 & 0 & 0 & 1 \\ \vdots & \vdots & \ddots & \vdots & 0 & 0 & \dots & 0 \\ s[-N^- + 3] & s[-N^- + 4] & \dots & 0 & \vdots & \vdots & \ddots & \vdots \\ s[-N^- + 2] & s[-N^- + 3] & \dots & s[-N^- + L^- + 1] & 0 & 0 & \dots & 0 \end{pmatrix}$$

– прямоугольные матрицы получаемые из рекуррентных уравнений (1), (2) при $s = y$ для значений $i^+ = 0, 1, 2, \dots, N^+$ $i^- = 0, -1, -2, \dots, -N^-$, соответственно. Причем матрица \mathbf{Q}^+ имеет размерность $N^+ \times (L^+ + M^+ + 1)$, а \mathbf{Q}^- – размерность $N^- \times (L^- + M^- + 1)$. Если бы исходный $s[i], i \in \mathbb{Z}$ сигнал совпадал с модельным сигналом $y[i], i \in \mathbb{Z}$ (4), то, очевидно, были бы справедливы векторные равенства $\mathbf{s}^+ = \mathbf{Q}^+ \mathbf{w}^+$, $\mathbf{s}^- = \mathbf{Q}^- \mathbf{w}^-$, т.е. аппроксимация на основе разностных уравнений (1), (2) будет идеальной. На практике такое возможно, если, например, дискретный сигнал $s[i], i \in \mathbb{Z}$ принадлежит экспоненциальному семейству [5,6]. Однако в большинстве случаев идеальная аппроксимация невозможна, а в каузальной и некаузальной областях наблюдаются ошибки аппроксимации

$$\varepsilon_e^+ = \|\mathbf{s}^+ - \mathbf{Q}^+ \mathbf{w}^+\|, \quad \varepsilon_e^- = \|\mathbf{s}^- - \mathbf{Q}^- \mathbf{w}^-\|,$$

где $\|\cdot\|$ – евклидова норма. Суммарный квадрат ошибки аппроксимации по двум указанным областям равен

$$\varepsilon_e^2 = \|\mathbf{s}^+ - \mathbf{Q}^+ \mathbf{w}^+\|^2 + \|\mathbf{s}^- - \mathbf{Q}^- \mathbf{w}^-\|^2 = (\varepsilon_e^+)^2 + (\varepsilon_e^-)^2. \quad (7)$$

Очевидно, чем меньше ε_e^2 тем лучше качество аппроксимации сигнала на конечном выборочном двухстороннем интервале $J_0 = \{-(N^- - 1), \dots, (N^+ - 1)\}$. Кроме того, если значения N^- , N^+ , определяющие границы этого интервала, и частота дискретизации исходного сигнала $s[i], i \in \mathbb{Z}$ выбраны правильно, то выражение (7) может служить показателем качества его аппроксимации моделью (1)-(2) на двухстороннем бесконечном интервале \mathbb{Z} .

С учетом сказанного, описанные выше этапы синтеза наилучшего алгоритма аппроксимации сводятся к решению двух экстремальных задач

$$\mathbf{w}_o^+ = \{a_{ol}^+, b_{om}^+\} = \arg \min_{\{a_l^+, b_m^+\}} \|\mathbf{s}^+ - \mathbf{Q}^+ \mathbf{w}^+\|^2, \quad (8)$$

$$\mathbf{w}_o^- = \{a_{ol}^-, b_{om}^-\} = \arg \min_{\{a_l^-, b_m^-\}} \|\mathbf{s}^- - \mathbf{Q}^- \mathbf{w}^-\|^2, \quad (9)$$

Каждая из них находит соответствующий набор оптимальных значений параметров $\{a_{ol}^+, b_{om}^+\}$ или $\{a_{ol}^-, b_{om}^-\}$ моделей (1)-(2), при которых минимизируются квадраты ошибок аппроксимации $(\varepsilon_e^+)^2$ и $(\varepsilon_e^-)^2$, а значит и суммарная ошибка (7). При этом минимум в критериях (8), (9) берется по всем возможным значениям параметров $\{a_l^+, b_m^+\}$, $\{a_l^-, b_m^-\}$, входящим в векторы \mathbf{w}^+ , \mathbf{w}^- (6)

Если оптимальные решения (8), (9) найдены, то искомая наилучшая аппроксимация $\{y_o[i]\}$ сигнала $\{s[i]\}$ может быть получена по формулам

$$y_o[i^+] = \sum_{l=1}^{L^+} a_{ol}^+ y_o[i^+ - l] + \sum_{m=0}^{M^+} b_{om}^+ \delta[i^+ - m], \quad i^+ = 0, +1, +2, \dots$$

Нач. усл. $y_o[-1] = \dots = y_o[-L] = 0,$

$$y_o[i^-] = \sum_{l=1}^{L^-} a_{ol}^- y_o[i^- + l] + \sum_{m=0}^{M^-} b_{om}^- \delta[i^- + m], \quad i^- = 0, -1, -2, \dots,$$

Нач. усл. $y_o[1] = \dots = y_o[L] = 0,$

$$y_o[i] = \begin{cases} y_o[i^+], & i \geq 0 \\ y_o[i^-], & i < 0 \end{cases}, \quad i = 0, \pm 1, \pm 2, \dots, \quad (12)$$

где (12) соответствует процедуре (4) объединения каузальной $\{y_o[i^+]\}$ и антикаузальной $\{y_o[i^-]\}$ частей аппроксимации.

Экстремальные задачи (8), (9) имеют одинаковую структуру и решаются похожим образом. Поэтому найдем сначала оптимальное решение $\mathbf{w}_o^+ = \{a_{ol}^+, b_{om}^+\}$, минимизирующее ошибку $(\varepsilon_e^+)^2 = \|\mathbf{s}^+ - \mathbf{Q}^+ \mathbf{w}^+\|^2$. Для этого используя известные свойства линейной алгебры преобразуем выражение, описывающее эту ошибку, к квадратичной форме

$$\begin{aligned} (\varepsilon_e^+)^2 &= \|\mathbf{s}^+ - \mathbf{Q}^+ \mathbf{w}^+\|^2 = (\mathbf{s}^+ - \mathbf{Q}^+ \mathbf{w}^+)^T (\mathbf{s}^+ - \mathbf{Q}^+ \mathbf{w}^+) = \\ &= \mathbf{s}^{+T} \mathbf{s}^+ - \mathbf{s}^{+T} \mathbf{Q}^+ \mathbf{w}^+ - (\mathbf{Q}^+ \mathbf{w}^+)^T \mathbf{s}^+ + (\mathbf{Q}^+ \mathbf{w}^+)^T \mathbf{Q}^+ \mathbf{w}^+ = \\ &= [\mathbf{Q}^{+T} \mathbf{s}^+ - \mathbf{Q}^{+T} \mathbf{Q}^+ \mathbf{w}^+]^T (\mathbf{Q}^{+T} \mathbf{Q}^+)^{-1} [\mathbf{Q}^{+T} \mathbf{s}^+ - \mathbf{Q}^{+T} \mathbf{Q}^+ \mathbf{w}^+] = \\ &= \mathbf{x}^T \mathbf{A}^{-1} \mathbf{x} \end{aligned} \quad (13)$$

где $\mathbf{A} = (\mathbf{Q}^{+T} \mathbf{Q}^+)$, $\mathbf{x} = \mathbf{Q}^{+T} \mathbf{s}^+ - \mathbf{Q}^{+T} \mathbf{Q}^+ \mathbf{w}^+$.

Вследствие симметричности и положительной определенности матрицы $\mathbf{A} = (\mathbf{Q}^{+T} \mathbf{Q}^+)$ значения квадратичной формы $(\varepsilon^+)^2 = \mathbf{x}^T \mathbf{A}^{-1} \mathbf{x}$ всегда неотрицательны $(\varepsilon^+)^2 \geq 0$, причем минимум равный нулю достигается только при нулевом векторе $\mathbf{x} = \mathbf{0}$ [1]. Следовательно, искомое оптимальное решение \mathbf{w}_o^+ должно удовлетворять уравнению

$$\mathbf{Q}^{+T} \mathbf{s}^+ - \mathbf{Q}^{+T} \mathbf{Q}^+ \mathbf{w}_o^+ = \mathbf{0}, \quad (14)$$

откуда находим

$$\mathbf{w}_o^+ = (\mathbf{Q}^{+T} \mathbf{Q}^+)^{-1} \mathbf{Q}^{+T} \mathbf{s}^+ \quad (15)$$

Причем, в силу новорожденности матрицы $\mathbf{A} = (\mathbf{Q}^{+T} \mathbf{Q}^+)$, обратная матрица \mathbf{A}^{-1} всегда существует, а решение (15) единственное. Векторное уравнение (14) может быть записано в скалярном виде и получило в математике название системы нормальных уравнений. Для ее решения не обязательно находить обратную матрицу $\mathbf{A}^{-1} = (\mathbf{Q}^{+T} \mathbf{Q}^+)^{-1}$. Существуют более эффективные и устойчивые вычислительные методы, например, Гаусса или Холецкого, основанные на треугольных разложениях матрицы \mathbf{A} .

Аналогично ищется решение экстремальной задачи (9). Выражение для него с точностью до обозначений будет повторять (15) и имеет вид

$$\mathbf{w}_o^- = (\mathbf{Q}^{-T} \mathbf{Q}^-)^{-1} \mathbf{Q}^{-T} \mathbf{s}^-. \quad (16)$$

Отметим, что согласно (6)

$$\begin{aligned} \mathbf{w}_o^+ &= (a_{o1}^+, \dots, a_{oL^+}^+, b_{o0}^+, \dots, b_{oM^+}^+)^T, \\ \mathbf{w}_o^- &= (a_{o1}^-, \dots, a_{oL^-}^-, b_{o0}^-, \dots, b_{oM^-}^-)^T, \end{aligned} \quad (17)$$

т.е. числовые значения коэффициентов разностных уравнений (10), (11), определяющих наилучшую аппроксимацию $\{y_o[i]\}$, найдены и представляют собой компоненты оптимальных векторов (17).

Спектр аппроксимируемого сигнала

Полученная дискретная фильтровая аппроксимация

$\{y_o[i]\}$ сигнала $\{s[i]\}$ на бесконечном целочисленном интервале времени $\mathbb{Z} = 0, \pm 1, \pm 2, \dots$ может быть использована для построения спектральной оценки сигнала в виде комплексного спектра

$$P_d(jf) = \mathcal{F}_d(y_o[i]) = \Delta \sum_{i=-\infty}^{\infty} y_o[i] e^{-j2\pi f \Delta i}, \quad f \in [-f_H, f_H] \quad (18)$$

в дискретно-непрерывном базисе Фурье $\{e^{j2\pi f \Delta i}\}$, где Δ , $f_d = 1/\Delta$ – интервал и частота дискретизации, соответственно; $f_H = f_d/2$ – частота Найквиста. Достоинством рекурсивной модели (10), (11) является возможность получить более простое аналитическое выражение для спектра (18), выразив его через найденные параметры модели $\{a_{ol}^+, b_{om}^+\}$, $\{a_{ol}^-, b_{om}^-\}$. Для этого заметим, что аппроксимирующие процессы $\{y_o[i^+]\}$, $\{y_o[i^-]\}$ могут быть представлены как решения двух рекурсивных уравнений

$$y_o[i^+] = \sum_{l=1}^{L^+} a_{ol}^+ y_o[i^+ - l] + \sum_{m=0}^{M^+} b_{om}^+ x[i^+ - m], \quad i^+ = 0, +1, +2, \dots \quad (19)$$

$$\text{Нач. усл. } y_o[-l] = 0, \quad x[-m] = 0, \quad \forall l, m > 0,$$

$$y_o[i^-] = \sum_{l=1}^{L^-} a_{ol}^- y_o[i^- + l] + \sum_{m=0}^{M^-} b_{om}^- x[i^- + m], \quad i^- = 0, -1, -2, \dots \quad (20)$$

$$\text{Нач. усл. } y_o[l] = 0, \quad x[m] = 0, \quad \forall l, m > 0,$$

когда на их вход подается сигнал $x[i] = \delta[i]$ в виде единичного импульса Кронекера (3). Последнее означает, что процессы $\{y_o[i^+]\}$, $\{y_o[i^-]\}$ по смыслу совпадают с импульсными характеристиками (ИХ) рекурсивных фильтров (19), (20), первый из которых является каузальным, а второй антикаузальным. Это позволяет воспользоваться известными методами анализа цифровых фильтров, основанными на применении \mathcal{Z} -преобразования $\mathcal{Z}(\cdot) = \sum_{i=-\infty}^{\infty} (\cdot) z^{-i}$ и его связью с дискретным преобразованием Фурье (ДНПФ) $\mathcal{F}_d(\cdot) = \Delta \cdot \mathcal{Z}(\cdot) \Big|_{z=e^{j2\pi f \Delta}}$. С учетом сказанного выше, комплексные спектры импульсных характеристик фильтров (19), (20) описываются выражениями

$$P_{od}^+(jf) = \Delta \cdot H_o^+(z) \Big|_{z=e^{j2\pi f \Delta}}, \quad H_o^+(z) = \mathcal{Z}(\{y_o[i^+]\}), \quad (21)$$

$$P_{od}^-(jf) = \Delta \cdot H_o^-(z) \Big|_{z=e^{j2\pi f \Delta}}, \quad H_o^-(z) = \mathcal{Z}(\{y_o[i^-]\}), \quad (22)$$

где $H_o^+(z)$, $H_o^-(z)$ – системные функции каузального и антикаузального фильтров, соответственно.

Применяя к правой и левой частям уравнения (19) \mathcal{Z} -преобразование и используя свойства последнего, получаем выражение для системной функции

$$H_o^+(z) = \frac{\sum_{m=0}^{M^+} b_{om}^+ z^{-m}}{1 - \sum_{l=1}^{L^+} a_{ol}^+ z^{-l}}. \quad (23)$$

Действуя аналогично по отношению к уравнению (20), находим выражение для системной функции антикаузального фильтра

$$H_o^-(z) = \frac{\sum_{m=0}^{M^-} b_{om}^- z^m}{1 - \sum_{l=1}^{L^-} a_{ol}^- z^l}. \quad (24)$$

Согласно (4) для получения системной функции $H_o(z) = \mathcal{Z}(\{y_o[i]\})$, отвечающей двухсторонней ИХ $\{y_o[i]\} = \{y_o[i^-]\} \cup \{y_o[i^+]\} / y_o[0]$, надо объединить $H_o^+(z)$, $H_o^-(z)$ и учесть, что в антикаузальной части $H_o^-(z)$ присутствует \mathcal{Z} -преобразование от отсчета в момент $i=0$

$$\mathcal{Z}(y_o[0] \cdot \delta(i)) = y_o[0],$$

которое уже входит в каузальную часть ИХ (23), а значит его надо вычесть. В результате системная функция $H_o(z)$ принимает вид,

$$H_o(z) = H_o^+(z) + H_o^-(z) - y_o[0], \quad (26)$$

а с учетом (21)-(24) комплексный спектр (18) дискретного сигнала $\{y_o[i]\}$ описывается выражением

$$P_{o\Delta}(jf) = \Delta \cdot H_o(z) \Big|_{z=e^{j2\pi f\Delta}} = \Delta \left(\frac{\sum_{m=0}^{M^+} b_{om}^+ e^{-j2\pi f\Delta m}}{1 - \sum_{l=1}^{L^+} a_{ol}^+ e^{-j2\pi f\Delta l}} + \frac{\sum_{m=0}^{M^-} b_{om}^- e^{j2\pi f\Delta m}}{1 - \sum_{l=1}^{L^-} a_{ol}^- e^{j2\pi f\Delta l}} - y_o[0] \right). \quad (27)$$

Соответствующий амплитудный спектр равен

$$P_{o\Delta}(f) = |P_{o\Delta}(jf)|, \quad f \in [-f_H, f_H], \quad (28)$$

Результаты вычислительного эксперимента

Ниже приводится пример аппроксимации сигнала $\{s[i]\}$, полученного в результате дискретизации непрерывного сигнала

$$s(t) = t \exp(-at^2), \quad t \in \mathbb{R} \quad (29)$$

с комплексным спектром

$$P_s(jf) = -j \sqrt{\frac{\pi^3}{a^3}} f \exp(-\pi^2 f^2 / a). \quad (30)$$

При $a=3.5$ каузальная $s^+(t)$ и антикаузальная $s^-(t)$ составляющие сигнала (29) дискретизировались на отрезке времени $T = [-3.5, 3.5]$ [мс] и отдельно аппроксимировались на основе описанного выше фильтрового подхода и метода наименьших квадратов Прони [1,6,7]. Рекурсивный порядок для обоих методов аппроксимации равен $L^+ = L^- = 6$, а число параметров $\{b_m^+, b_m^-\}$ в (10)-(11) выбрано $M^+ = M^- = 9$. Графики дискретных сигналов $s[i]$, $s_o[i]$, $s_{pr}[i]$ $i=0, \pm 1, \pm 2, \dots$ – исходного и двух указанных аппроксимаций, представлены на рис. 1, а соответствующие амплитудные ДНПФ-спектры $P_{\Delta}(f)$, $P_{o\Delta}(f)$, $P_{pr\Delta}(f)$ на отрезке частот $F = [-f_H, f_H]$ [кГц] изображены на рис. 2. Видно, что на этих рисунках графики практически сливаются. Поэтому для более детального анализа качества аппроксимации рассчитывались следующие ошибки:

а) во временной области:

$$\varepsilon[i] = s[i] - s_o[i], \quad \varepsilon_{pr}[i] = s[i] - s_{pr}[i], \quad (31)$$

$$\varepsilon_o = \sqrt{\sum_{i=-N/2}^{N/2+1} \varepsilon^2[i] / N}, \quad \varepsilon_{opr} = \sqrt{\sum_{i=-N/2}^{N/2+1} \varepsilon_{pr}^2[i] / N}, \quad (32)$$

б) в частотной области:

$$\eta[k] = P_{\Delta}(f_k) - P_{o\Delta}(f_k), \quad \eta_{pr}[k] = P_{\Delta}(f_k) - P_{pr\Delta}(f_k), \quad (33)$$

$$\eta_o = \sqrt{\sum_{k=-N_o/2}^{N_o/2+1} \eta^2[k] / N_o}, \quad \eta_{opr} = \sqrt{\sum_{k=-N_o/2}^{N_o/2+1} \eta_{pr}^2[k] / N_o}, \quad (34)$$

где $N=112$, $N_o=448$ – число отсчетов на интервалах T и F . Графики ошибок (31), (33) приведены на рис. 3 и рис. 4, соответственно.

Анализ этих кривых показывает, что фильтровой метод аппроксимации позволяет уменьшить текущие ошибки во временной области более чем в 10 раз, а в частотной области более чем в 20 раз. Среднеквадратические ошибки (32), (34) по времени и частоте, соответственно, равны $\varepsilon_o = 3.6e-06$, $\varepsilon_{opr} = 5.2e-05$, $\eta_o = 4.7e-06$, $\eta_{pr} = 6.9e-05$.

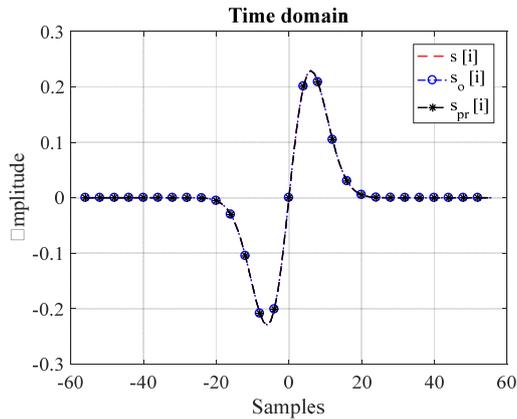


Рис. 1. Дискретные сигналы $s[i]$, $s_o[i]$, $s_{pr}[i]$.

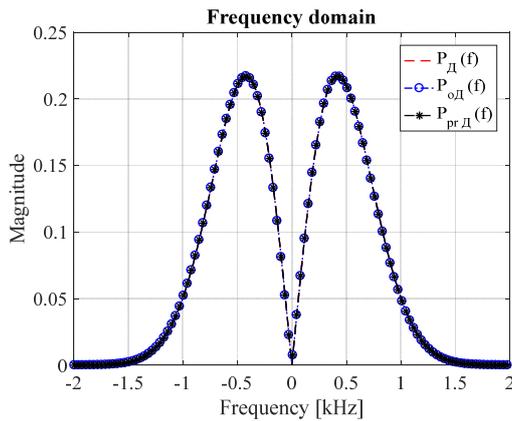


Рис. 2. Амплитудные спектры $P_d(f)$, $P_{oD}(f)$, $P_{prD}(f)$.

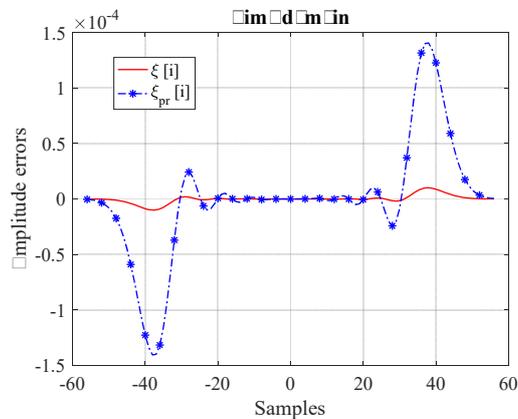


Рис. 3. Ошибки аппроксимации во временной области.

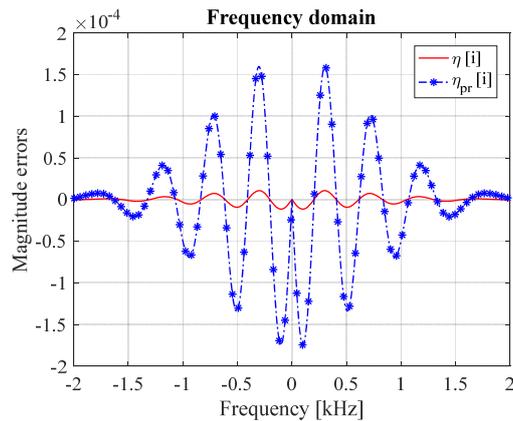


Рис. 4. Ошибки аппроксимации в частотной области.

Заключение

1. Предлагается рекурсивный фильтровой метод аппроксимации дискретных детерминированных сигналов. В отличие от известных модификаций метода Прони, решающих аналогичную задачу и описанных в [1, 5, 6], диапазон аппроксимации сигналов расширен на бесконечный двухсторонний интервал времени. Кроме того, используемые для аппроксимации рекурсивные модели имеют более общую структуру, и могут иметь кратные полюса. Поэтому аппроксимирующие возможности фильтрового подхода оказываются более широкими.

2. Получены строгие аналитические выражения, описывающие алгоритм оценивания параметров рекурсивной фильтровой модели, а также выражения для аппроксимирующего сигнала и его комплексного спектра. Это позволило провести эксперимент и оценить качество фильтровой аппроксимации во временной и спектральной областях.

3. Результаты сравнительного эксперимента показывают, что предложенный фильтровой метод позволяет более чем на порядок уменьшить ошибки аппроксимации дискретного сигнала и его спектра по сравнению с методом Прони.

4. Предложенный аппарат рекуррентного представления дискретных сигналов на основе фильтрового подхода

хорошо согласуется с практическими требованиями к синтезу оптимальных алгоритмов обработки сигналов, поскольку они также оказываются рекуррентными, а для точного расчета их временных и частотных характеристик достаточно знать только небольшой набор модельных параметров и нет необходимости привлекать численные методы.

Литература

1. Марпл С.Л. -мл. Цифровой спектральный анализ и его приложения. Пер. с англ. М.: Мир, 1990. 584 с.
2. Оппенгейм А., Шафер Р. Цифровая обработка сигналов. Москва: Техносфера, 2006. 856 с.
3. Солонина А.И., Арбузов С.М. Цифровая обработка сигналов. Моделирование в МАТЛАБ. СПб.: БХВ-Петербург, 2008. 816 с.
4. Сергиенко А.Б. Цифровая обработка сигналов. 3-е изд. СПб.: БХВ-Петербург, 2011. 768 с.
5. Volchkov V.P., Manonina I.V., Sannikov V.G. Presentation and analysis of Continuous Signals in the Space of Complex Exponential Models // 2019 Systems of Signal Synchronization, Generating and Processing in Telecommunications (SYNCHROINFO), Russia, 2019, pp. 1-6. doi: 10.1109/SYNCHROINFO.2019.8813941
6. Дрюпина Н.С., Арсеньева Д.Г., Волчков В.П. Расширение классической модели Прони на пространство непрерывных сигналов и вычисление ее основных характеристик во временной и спектральной областях // Телекоммуникации и информационные технологии. 2018. Т. 5. № 1. С. 83-88.
7. Бушуев Э.Ю., Волчков В.П. Разработка алгоритма, реализующего метод спектрального анализа Прони в среде Матлаб, и исследование чувствительности этого метода к воздействию шумовых помех // Телекоммуникации и информационные технологии. 2019. Т. 6. № 1. С. 116-125.

БАЗА ДАННЫХ МТУСИ С ПОСТОЯННОЙ СУБЪЕКТИВНОЙ ОЦЕНКОЙ: ИССЛЕДОВАНИЕ И УСТРОЙСТВО ГЕНЕРАЦИИ ВИДЕОПОСЛЕДОВАТЕЛЬНОСТЕЙ ПОСТОЯННОГО КАЧЕСТВА

Вотяков Семён Юрьевич,

Московский Технический Университет Связи и Информатики, Москва, Россия

Детушева Полина Вадимовна,

Московский Технический Университет Связи и Информатики, Москва, Россия

Мазин Владимир Андреевич,

Московский Технический Университет Связи и Информатики, Москва, Россия

vladimir.a.mazin@gmail.com

Фаст София Станиславовна,

Московский Технический Университет Связи и Информатики, Москва, Россия

Можаева Анастасия Ивановна,

Московский Технический Университет Связи и Информатики, Москва, Россия;

The University of Waikato, Hamilton, New Zealand

Аннотация

Базы данных видео с набором субъективных оценок формируют важную основу для изучения алгоритмов, тестирования и создания объективной оценки качества видео. В этой статье представлена новая база данных видео с набором субъективных оценок для тестирования качества кодированного видео, с использованием нахождения приемлемого минимального порога восприятия, который позволяет генерировать видеопоследовательности постоянного качества. Новая база данных видео с набором субъективных оценок, представляет собой видеопоследовательности постоянного качества, созданные с использованием динамически изменяющегося визуального качества типичного медиаконтента в процессе экспертизы. Такой подход позволит получать хорошо маркированные данные в большем объеме по сравнению с используемыми в настоящее время двоичными оценками. Новые базы данных с таким подходом может использоваться как для создания эффективных адаптивных кодеков, построенных по гибридной модели, так и новых, основанных на машинном обучении.

Ключевые слова: *базы данных видео, объективная оценка качества, оценка качества видео, субъективные оценки, порог восприятия*

Введение

Потоковое видео продолжает занимать растущую долю пропускной способности Интернета, в 2022 году на видео приходится 82% интернет-трафика [1]. В условиях экспоненциального роста видеотрафика можно предсказать, что в ближайшие годы усовершенствование технологий кодирования видео будут иметь решающее значение для компаний, занимающихся потоковой передачей видео. На современном этапе развития технологии системы кодирования видео показывают высококачественные, удовлетворительные результаты. Однако проблемы в сфере потокового видео, такие как создание кодеков с использованием полного или частичного машинного обучения всё ещё требуют решения. В этом аспекте решения представляют собой базы данных соответствующего различного видеоконтента и искажений, отмеченные достаточным количеством субъективных данных.

За последние годы был выпущен широкий спектр баз данных видеопоследовательностей. Адъюнкт-профессор Стефан Уинклер предоставил всесторонний обзор 11 баз [2], и сегодня, по представленным данным, количество баз данных почти удвоилось. Однако, согласно Хосу и прочим,

текущие базы данных оценки качества видеопоследовательностей (VQ□) содержат лишь небольшое количество видеопоследовательностей с небольшим разнообразием контента, что обеспечивает ограниченную поддержку для разработки и оценки методов кодирования с эффективным использованием глубокого обучения [3,4].

Следует также упомянуть, что предварительно искаженные базы данных не совсем объективны, поскольку различия в пользовательских рейтингах не дают ответа на вопрос о том, какое качество является минимально приемлемым для пользователя. Если пользователь предоставляет низкую оценку определенному моменту — невозможно угадать, как должен выглядеть контент, чтобы рейтинг был хорошим. Если предоставляется слишком высокий рейтинг — это может привести к переоценке баз [2]. Другим важным фактом является эффективность создания базы, или, другими словами, оптимизация сбора субъективных оценок [5]. До сих пор не было разработано оптимального решения для снятия субъективных оценок — самой ценной и, возможно, самой сложной части исследования. При привлечении участников к тестированию необходимо четко создать способ проведения тестов, который будет учитывать максимально возможное количество обработки артефактов при минимальном количестве экспериментов [2,5]. Такой подход поможет сократить время сбора данных, что приведет к уменьшению стоимости субъективных тестов.

Как описано выше, самой большой проблемой сейчас при создании кодеков с использованием машинного обучения является нехватка данных, или, другими словами, крупномасштабных баз данных. В этой работе представлена база данных видео, основанная на методе измерения качества, закодированного видео, использующего в основе нахождения приемлемого минимального порога восприятия, который позволяет генерировать видеопоследовательности постоянного качества [6]. База данных, предоставляет исходное видео и видео с постоянной оценкой качества, которое создается самими пользователями и к которому разработчики кодеков должны стремиться как к оптимальному для пользователей. Эта база данных учитывает различные устройства отображения - монитор, телевизор, типичные пользовательские устройства. База данных разработана для создания оптимального соотношения времени, затраченного на субъективные тесты, к количеству обработанных артефактов.

Метод для создания базы данных CSQ

В качестве исходной последовательности был выбран несжатый видеоклип созданный посредством RED Comodo 6k с оптикой Sigma. Видео, включенное в базу данных, представлено в прогрессивном формате YUV422 с фиксированным разрешением 1920×1080 , который в настоящее время является самым распространенным. Частота кадров – 24 кадра. Продолжительность видео составляет более 40 секунд, согласно рекомендациям [7].

На рисунке 1. показаны образцы кадров из эталонного видеоролика. Videopоследовательность для базы данных была профессионально записана в цифровом формате, что позволяет сделать возможным наличие искажений в видео и подвергнуть видео нескольким этапам обработки, как на самом устройстве, так и на сервере.



Рис. 1. Образцы кадров из эталонного видеоролика CSQ

Некоторые из получившихся видео должны быть отобраны для создания базы данных на основе трех критериев. Во-первых, это типичный пользовательский контент, который используется не всеми базами данных, а то есть: LIVE-NFLX [8], LIVE-NFLX-II [9], ETRI-LIVE STSVQ [10] и другими. В представленной базе данных была предпринята попытка просмотреть сцены типичного современного мультимедийного контента. Во-вторых, база данных должна обладать достаточным разнообразием по нескольким характеристикам. Был составлен список характеристик, включающих разнообразие (табл. 1), в соответствии с критериями, представленными Уинклером для оригинального контента. Представленная база данных охватывает широкий спектр характеристик, показанных в таблице 1. В-третьих, по данным Уинклера, субъективные оценки также следует принимать во внимание.

Таблица 1

Разнообразие характеристик видео

Жанры видео	Содержание видео	Изменяющиеся характеристики видео
На улице	Лица	Яркость
В помещении	Люди	Контрастность
	Снег	Текстура
	Панорама	Движение
	Объекты	Вариация цветов
	Искусственные объекты	Движение камеры
		Смена сцены

Представленная ранее настройка [6] позволяет собирать оценки субъективного уровня качества, используя идеи нахождения приемлемого минимального уровня качества для участника, или, другими словами, порога восприятия. Это позволяет оптимизировать сбор субъективных оценок для данного этапа развития современных телекоммуникационных технологий.

Было также рассмотрено такой вид искажений как артефакты сжатия. В базе данных было использовано сжатие H.264 - самый популярный видеоформат, используемый при потоковой передаче видео по сети. Было принято восемь уровней искажения для каждого видео. Для реализации данного шага использовался x264 в качестве кодера для создания сжатых видеофайлов. Двухпроходная схема кодирования использовалась для обеспечения постоянного качества восприятия кадр за кадром, для субъективной реальной оценки.

Между I и P кадрами допускается максимум два B-кадра. Разрешение входного и выходного видео поддерживается на уровне 1080p, как показано на рисунке 2. Уровни искажений регулируются целевой скоростью передачи данных. Диапазон скоростей передачи данных составляет от 0,5 Мбит/с до качества 10 Мбит/с.

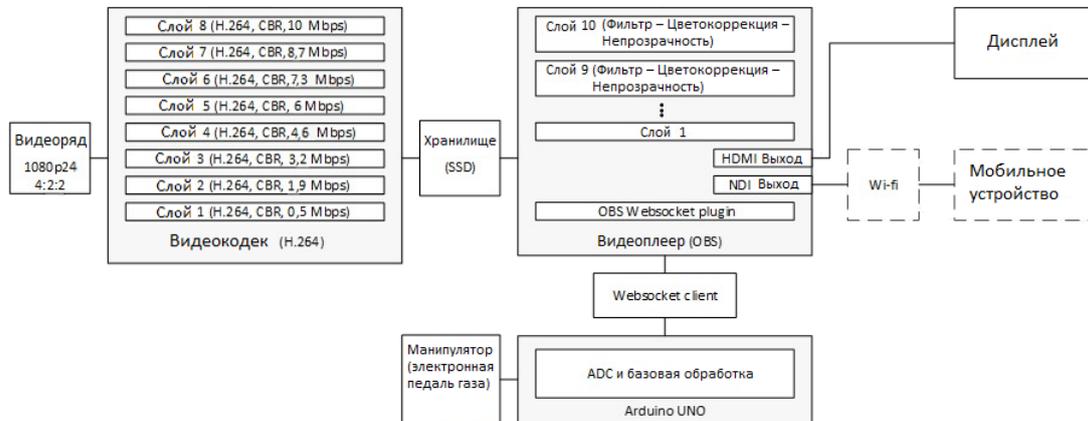


Рис. 2. Процесс измерения качества закодированного видео, основанный на нахождении приемлемого минимального порога восприятия [6].

Процесс измерения качества закодированного видео, основанный на нахождении приемлемого минимального порога восприятия

Процесс измерения качества закодированного видео, основанный на поиске приемлемого минимального порога восприятия, использует субъективную оценку путем определения приемлемого минимального уровня качества для участника. Другими словами, находится порог восприятия, который позволяет создавать видеопоследовательности постоянного качества. Данный метод сбора субъективной оценки [6] создает условия для создания базы данных с максимальным количеством артефактов и минимумом субъективных экспериментов.

Поскольку используется аналогичное время для создания базы данных (время, затраченное на все субъективные тесты, к общей продолжительности всех готовых видеопоследовательностей, включенных в базу данных вместе с оригинальными видеороликами) с такими базами данных, как LIVE [8], LIVE Wild [11], но обрабатывается значительно больше артефактов. Также такие базы данных, как VideoSet [12], KoNViD-1[13], значительно уступают данному подходу по времени, затрачиваемому на субъективные тесты при той же обработке артефактов. Структурная схема метода показана на рисунке 2.

Сначала создавались искаженные видеорядами с 9 уровнями качества, в современном потоковом видео наиболее востребованные пороговые уровни находятся на уровнях от 6 до 10 Мбит/с. Однако для точности эксперимента были необходимы как низкие, так и высокие уровни качества. На следующем шаге было предпринято закрепить 8 искаженных последовательностей. Далее идет этап отбора, когда участник может выбрать последовательность приемлемого минимального порога с плавным изменением уровней качества. Каждый участник находил минимально приемлемый порог видеоряда для одного видео, постоянно регулируя качество с помощью манипулятора, рисунок 3.

В качестве манипулятора использовалась электронная педаль газа автомобиля LADA Priora, которая обладает удовлетворительной эргономикой.



Рис. 3. Манипулятор (педаля), изменяющий качество видео

Субъективное качество контента время от времени менялось, и участнику предоставлялась возможность регулировать уровень качества с помощью манипулятора, что предполагало нажатие на педаль с разной силой при просмотре длинных видеопоследовательностей. Чтобы избежать ступенчатого изменения качества с ограниченным числом уровней (8), при установке промежуточных значений качества с помощью манипулятора обеспечивается смешивание соседних уровней качества в пропорции, определяемой силой нажатия. При таком микшировании конечное качество может оказаться хуже, чем качество видеурока без микширования. Однако это не было подтверждено на практике, поскольку использовался один и тот же кодек, и характер искажений смешанных видео был одинаковым.

Видео отображались в исходном разрешении без масштабирования монитора. Цвет неактивного экрана был установлен на светло-серый. Тесты прекратились, когда экспериментальная неопределенность, измеряемая доверительным интервалом, упала ниже 5% от текущего значения для всех тестов, выполненных в эксперименте. Общее количество испытуемых 19 человек [7].

Организация лабораторных условий и тестов.

Дисплеем является плоский экран диагональю 22", используются телевизор 42" и пользовательское устройство. Дисплей и монитор обеспечивают правильную настройку яркости и цветопередачи и калибровку с помощью профессионального измерителя освещенности.

Калибровка дисплея соответствует параметрам, определенным в соответствующей рекомендации для проводимого испытания. Освещенность 50 люкс, температура белого цвета D65.

Согласно знаниям о зрительной системе человека и области четкости, острота зрения составляет 1/60 градуса [14]. Согласно этим данным, минимально допустимое расстояние от монитора до участника для нахождения стимула в зоне четкого видения составляет 0,872 м, а максимальное - 1,149 м для монитора, расстояние для телевизора высчитывается аналогично [15]. Эксперимент по получению протокола проверки экспертами был проведен в испытательной лаборатории. Любые источники прямого или отраженного света, падающего на экран, были устранены; окружающий свет был приглушен, оставаясь как можно более низким для заполнения оценочных листов. Перед устройством воспроизведения сидел один участник. Большинство участников были студентами 1-го курса бакалавриата, что является хорошим балансом между тремя важными параметрами: физической зрелостью глаз, ежедневным использованием типичного пользовательского контента, а именно просмотром видео и изображений в Интернете, и отсутствием опыта восприятия визуальной информации. Визуальный опыт особенно способствует лучшему обнаружению артефактов и определению пространственно-временного порога. Участники не используют очки, линзы или другие медицинские устройства для коррекции своего зрения в обычной повседневной деятельности.

Сеансы наблюдения начинались со «стадии стабилизации». Это позволило участникам сразу же получить представление о диапазоне качества в начале тестовой сессии. Продолжительность тестового сеанса без перерыва не превышает 20 минут. Перед каждым экспериментом проводился короткий сеанс обучающего просмотра.

Для тренинга было использовано отдельное видео, которое не использовалось на реальных занятиях. Переход от набранной последовательности к следующей набранной последовательности происходит автоматически. Все последовательности были оценены для завершения теста. В конце каждой сессии баллы автоматически собирались анонимно и регистрировались в электронной таблице для расчета средних значений. «Пост-скрининг» участников был проведен с использованием коэффициента линейной корреляции Пирсона. Функция «корреляции» была применена ко всем баллам каждого участника по отношению к индексу среднего мнения (MOS); был установлен порог для определения каждого участника как «хорошего» и «плохого».

База данных видеопоследовательностей постоянного качества.

Полученные субъективные данные были подвергнуты обработке, а именно нахождению средней оценки для каждого кадра, как показано на рисунке 4, и доверительного интервала. На основе средних значений была сгенерирована последовательность с постоянной субъективной оценкой.

Два устройства сбора субъективных данных VQ \square сравниваются друг с другом. Для сравнения используются метод визуализации и метрика оценки качества видео. Текущая модель, используемая при оценке качества, – это максимальное отношение сигнал/шум PSNR. PSNR является наиболее распространенным [16-20] – почти все исследования качества видео, в которых могут использоваться полные эталонные значения, используют PSNR наряду с другими, потому что PSNR, основанный на стандартном отклонении, никогда не переоценивается.

Для анализа, были рассчитаны значения PSNR для последовательности постоянной субъективной оценки и последовательности максимального качества, как показано на рисунке 5. Как видно из рисунка 5, метрика качество видео стремится к значению, полученному на референсной видеопоследовательности. Другими словами, метрика оценки качество видео подтверждает, найденный порог восприятия артефактов в представленном медиа контенте. Корреляция между последовательностями составляет 0.97.

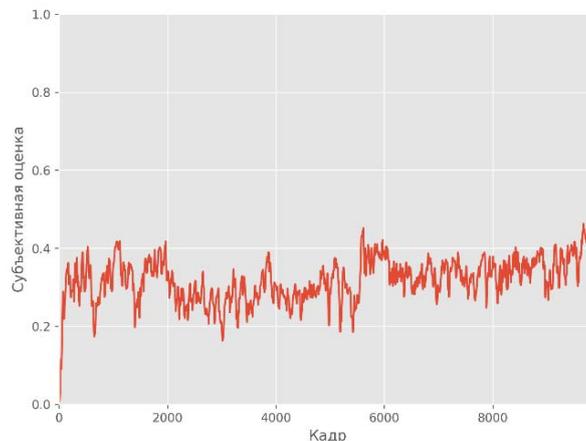


Рис. 4. Средняя субъективная оценка качества для каждого кадра.

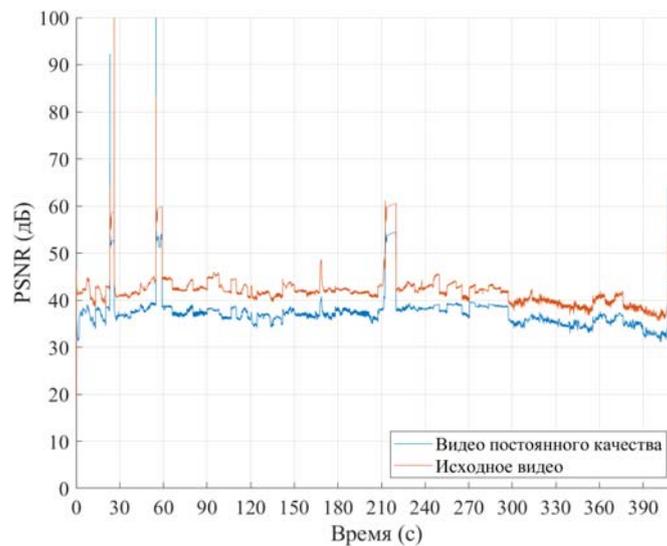


Рис. 5. Сравнение показаний объективных алгоритмов оценки качества.

Заключение

В данной работе было подробно описано создание новой базы данных видеопоследовательностей с набором субъективных оценок качества, закодированного видео, которое основано на нахождении приемлемого минимального порога восприятия, позволяющего генерировать видеопоследовательности постоянного качества. База данных будет общедоступной для будущих исследований и разработок. База данных облегчает тестирование качества алгоритмов, и является основой для создания моделей оценки качества или видеокодеков, основанных на полном или частичном машинном обучении.

Литература

1. *Nezhivleva K. I., Davydova A. A., Drebuszhan A. M., Mozhaeva A. I., Balobanov A.* Comparing of Modern Methods Used to Assess the Quality of Video Sequences During Signal Streaming with and Without Human Perception // 2022 Systems of Signal Synchronization, Generating and Processing in Telecommunications (SYNCHROINFO), 2022, pp. 1-6, doi: 10.1109/SYNCHROINFO55067.2022.9840983.
2. *Winkler S.* Analysis of Public Image and Video Databases for Quality Assessment // IEEE Journal of Selected Topics in Signal Processing, vol. 6, no. 6, pp. 616-625, Oct. 2012, doi: 10.1109/JSTSP.2012.2215007
3. *Hosu V. et al.* The Konstanz natural video database (KoNViD-1k) // 2017 Ninth International Conference on Quality of Multimedia Experience (QoMEX), 2017, pp. 1-6, doi: 10.1109/QoMEX.2017.7965673.
4. *Potashnikov A. M., Mazin V. A., Stepanov N. S., Smirnov A. P., Mozhaeva A. I.* Analysis of Modern Methods Used to Assess the Quality of Video Sequences During Signal Streaming // 2022 Systems of Signals Generating and Processing in the Field of on Board Communications, 2022, pp. 1-4, doi: 10.1109/IEEECONF53456.2022.9744294.P.
5. *Mozhaeva A., Vashenko E., Selivanov V., Potashnikov A., Vlasuyk I., Streeter L.* Analysis of current video databases for quality assessment // T-Comm. 2022. T. 16. № 2. С. 48-56. DOI 10.36724/2072-8735-2022-16-2-48-56. – EDN KRCZDN.
6. *Mozhaeva A., Potashnikov A., Vlasuyk I., Streeter L.* Constant Subjective Quality Database: The Research and Device of Generating Video Sequences of Constant Quality // 2021 International Conference on Engineering Management of Communication and Technology (EMCTECH), 2021, pp. 1-5, doi: 10.1109/EMCTECH53459.2021.9618977.
7. BT-500-11: Methodology for the Subjective Assessment of the Quality of Television Pictures, 2012.
8. *Seshadrinathan K., Soundararajan R., Bovik A. C., Cormack L. K.* Study of subjective and objective quality assessment of video // IEEE Trans. Image Process., vol. 19, no. 6, pp. 1427-1441, Jun. 2010.
9. *Bampis C. G., Li Z., Katsavounidis I., Huang TY, Ekanadham C., Bovik A. C.* Towards Perceptually Optimized End-to-end Adaptive Video Streaming // IEEE Transactions on Image Processing.
10. *Lee D., Paul S., Bampis C. G., Ko H., Kim J., Jeong S., Homan B., Bovik A. C.* Subjective and Objective Study of Space-Time Subsampled Video Quality // submitted to IEEE Transactions on Image Processing. [paper]

11. Yu X., Birkbeck N., Wang Y., Bampis C. G., Dsumilli B., Bovik G. C. Predicting the Quality of Compressed Videos With Pre-Existing Distortions // IEEE Transactions on Image Processing, vol. 30, pp. 7511-7526, 2021, doi: 10.1109/TIP.2021.3107213.
12. Wang H. et al., "VideoSet: a large-scale compressed video quality dataset based on JND measurement", J. Vis. Commun. Image Represent., vol. 46, pp. 292-302, Jul. 2017.
13. Hosu V. et al., "The Konstanz natural video database (KoNViD-1k)," 2017 Ninth International Conference on Quality of Multimedia Experience (QoMEX), 2017, pp. 1-6, doi: 10.1109/QoMEX.2017.7965673.
14. Mozhaeva A., Mazin V., Cree M.J., Streeter L. (2023). Video Quality Assessment Considering the Features of the Human Visual System. In: Yan, W.Q., Nguyen, M., Stommel, M. (eds) Image and Vision Computing. IVCNZ 2022. Lecture Notes in Computer Science, vol 13836. Springer, Cham. https://doi.org/10.1007/978-3-031-25825-1_21
15. Mozhaeva A. I., Vlasuyk I. V., Potashnikov A. M., Cree M. J., Streeter L. The Method and Devices for Research the Parameters of the Human Visual System to Video Quality Assessment // 2021 Systems of Signals Generating and Processing in the Field of on Board Communications, 2021, pp. 1-5, doi: 10.1109/IEEECONF51389.2021.9416081.
16. Можяева А.И., Власюк И.В., Поташиников А.М., Стример Ли. Эталонная объективная метрика оценки качества видео совместимая с PSNR учитывающая частотные и периферическую характеристики зрения человека // DSP: Вопросы применения цифровой обработки сигналов. 2021. Т. 11. № 2. С. 44-54.
17. Valitskaya N.S., Vlasuyk I.V., Potashnikov A.M. Video compression method on the basis of discrete wavelet transform for application in video information systems with non-standard parameters // T-Comm. 2020. Т. 14. № 3. С. 47-53.
18. Поташиников А.М., Власюк И.В. Метод построения равноконтрастного цветового пространства для заданной системы отображения информации и условий контроля // T-Comm: Телекоммуникации и транспорт. 2020. Т. 14. № 4. С. 15-22.
19. Егоров Д.А., Федоров В.Д., Лейман В.В., Власюк И.В. Методика оценки пространственно-частотной характеристики камер на основе генеративных случайных последовательностей // DSP: Вопросы применения цифровой обработки сигналов. 2021. Т. 11. № 1. С. 47-53.
20. Vyatkin M., Potashnikov A., Selivanov V., Vlasuyk I., Nezhivleva K., Mozhaeva A. Method of Preventing Leakage of Personal Data Through Eyetracking Modules of User Devices // T-Comm, vol. 16, no.7, pp. 44-51. 2022.

ЛАБОРАТОРНАЯ РАБОТА «ОТСЛЕЖИВАНИЯ ВЗГЛЯДА ЧЕЛОВЕКА ВО ВРЕМЯ ПРОСМОТРА МУЛЬТИМЕДИА КОНТЕНТА ПРИ ПОТОКОВОЙ ПЕРЕДАЧИ ДАННЫХ»

Вяткин Михаил Александрович,

Московский Технический Университет Связи и Информатики, Москва, Россия
mikhailsmkv@gmail.com

Хиженкова Олеся Вячеславовна,

Московский Технический Университет Связи и Информатики, Москва, Россия
lisforeverdead@gmail.com

Сафонов Илья Алексеевич,

Московский Технический Университет Связи и Информатики, Москва, Россия
ilya.safonov.2000@mail.com

Аннотация

Системы отслеживания взгляда всё больше используются в различных сферах жизни людей. Базы данных, предоставляемые системами отслеживания взгляда, служат основой анализа зрительного поведения людей. Как следствие, в последние годы растет интерес к разработке аппаратно-программного обеспечения систем отслеживания взгляда в научных и образовательных целях. В данной работе проведен анализ существующих устройств и обучающих комплексов, созданных в рамках системы отслеживания взгляда и предлагается новый образовательный аппаратно-программный комплекс, созданный для ознакомления студентов с основами фундаментальных ограничений человеческого зрения и статистическим анализом. Информация, содержащаяся в данной работе, поможет исследователям и студентам ознакомиться и проанализировать существующие алгоритмы работы отслеживания взгляда людей во время просмотра мультимедиа-контента при потоковой передаче данных, и определять регионы интересов пользователей на основе просмотра видеопоследовательностей.

Ключевые слова: *трекер, отслеживание взгляда, сцена кадра, регион интереса.*

Введение

Ай-трекинг (eye tracking) – технология отслеживания положения глаз, также называемая технологией отслеживания линий взгляда или точек взгляда. Отслеживание взгляда — это сенсорная технология, которая может обнаруживать присутствие людей и следить за тем, на куда пользователи смотрят в режиме реального времени. Технология преобразует движения глаз в поток данных, который содержит такую информацию, как положение зрачка, вектор взгляда для каждого глаза и точку взгляда. По сути, технология расшифровывает движения глаз и переводит это в информацию, которую можно использовать в самых разных приложениях, например, таких как дополнительный метода ввода. Трекеры можно разделить на 3 группы, в зависимости от того области применения:

- Игровые устройства. Наиболее распространенные на сегодняшний день трекеры. Данные устройства отслеживания взгляда относительно простые и имеют ограниченный функционал.
- Профессиональные устройства. Используются в нейромаркетинге, нейромедицинских исследованиях, спорте, образовании, науке и т.д.
- Реабилитационные (абилитационные) трекеры. Это трекеры, которые помогают людям с особыми потребностями управлять компьютером глазами (набирать текст, пользоваться интернетом, общаться в социальных сетях и т.д.) без посторонней помощи.

Несмотря на то, что общий принцип работы устройств отслеживания взгляда одинаков, на сегодняшний день существует несколько основных типов устройств слежения за взглядом пользователей. Выделяют три основные группы устройств:

- Носимые — к ним относятся очки с отслеживанием взгляда и гарнитуры виртуальной

реальности со встроенным отслеживанием взгляда.

- Веб-камера. Веб-камеры для отслеживания движения глаз не имеют датчиков или специализированных камер, состоят исключительно из устройства веб-камеры, подключенного или встроенного в компьютер.

- На основе экрана — это автономные, удаленные устройства, которые представляют собой либо отдельный блок, либо панель меньшего размера, которую можно подключить к ноутбуку или монитору.

На практике применяют тип устройства, наиболее подходящий для пользователя в зависимости от характера потребностей.

Устройства для отслеживания взгляда состоят как правило из аппаратной части, которая подключается к компьютеру (ноутбуку, планшету) и программного обеспечения. В трекаре используется ближний инфракрасный свет, который проецируется на глаз, а затем с помощью камеры с высоким разрешением записывается направление, в котором свет отражается от поверхности роговицы. Пример описанной технологии приведен на рисунке 1.

При этом, системы устройств отслеживания взгляда бывают 3 видов:

- 1) Системы, основанные на методе яркого зрачка;
- 2) Системы, основанные на методе тёмного зрачка;
- 3) Системы, использующие два вышеуказанных метода.

Разница между системами заключается в расположении источника инфракрасной подсветки относительно основной камеры. Если инфракрасные излучатели расположены параллельно оптической оси камеры, глаз работает как вторичный отражатель света, который поступает от подсветки и отражается от сетчатки, создавая эффект яркого зрачка. Если же источник подсветки сдвинут относительно оптической оси камеры, зрачок становится чёрным, поскольку вторичное отражение от сетчатки не поступает в камеру.



Рис. 1. Область работы трекера.

Различные факторы могут влиять на обнаружение зрачка во время дистанционного отслеживания взгляда при использовании каждого из этих двух методов [1]. Например, при использовании метода яркого зрачка факторы, влияющие на размер зрачка, такие как возраст и освещение окружающей среды, могут повлиять на возможность отслеживания движения глаз. Этническая принадлежность также является еще одним фактором, влияющим на реакцию светлых/темных зрачков: метод светлых зрачков, очень хорошо работает для выходцев из Латинской Америки и европеоидной расы. Однако этот метод оказался менее подходящим для отслеживания глаз жителей азиатских стран, для которых метод с темным зрачком обеспечивает лучшую обслуживаемость.

С помощью программного обеспечения исследователи определяют положение глаза и фокус взгляда. Указанная технология позволяет изучать мелкие движения глаз и зрительное поведение. Также с программным обеспечением, используемым для отслеживания взгляда, исследователи могут создавать визуальную карту того, как испытуемые рассматривают элементы сцены [2].

Частота захвата устройством отслеживания глаз используется для определения того, с какой скоростью устройство делает фиксацию взгляда пользователей.

Отслеживание взгляда может дать точную информацию о взгляде пользователей, которую не всегда могут выявить опросы или другие методы исследования. Например, опросы на месте могут быть эффективными для выявления того, на чем пользователи сознательно фиксируют внимания, однако люди не замечают многих вещей, которые происходят за пределами сознательного когнитивной составляющей реакции человека.

Существующие образовательные программные комплексы отслеживания взгляда

Компания Tobii разрабатывает продукты для отслеживания направления взгляда и управления устройствами с помощью глаз более 15 лет. Продукция Tobii широко используется в науке, а также для исследований и разработок. В лабораторных условиях экранные устройства отслеживания взгляда Tobii создают визуальные стимулы на экране и работают для получения информации о реакциях участников исследования [3].

В открытом доступе исследовательских установок для образования компании Tobii не существует, в то время как потребность в них только растет. Компания представляет устройства и программные комплексы для реализации образовательных комплексов, с ценовой политикой от 590 000 рублей, что затрудняет закупку данных комплексов для повседневных образовательных нужд университетов. Также данные комплексы не будут поставляться на территорию Российской Федерации с марта 2023 года. Альтернативные производители данных комплексов, такие как Google, не представляют устройства и программные комплексы для реализации образовательных комплексов даже на платной основе.

Согласно исследованию Cisco, в 2023 году онлайн-видео будет составлять 82,5% всего вебтрафика [4]. Это сделает трафик онлайн-видео самым популярным типом контента в Интернете [5]. Отсутствие в открытом доступе образовательных комплексов по исследованию и работе с подобной тематикой стало основой для разработки и презентации описанного учебного комплекса.

Лабораторный комплекс

В предлагаемом лабораторном комплексе будет использоваться трекер на основе экрана Tobii Eye Tracker 5 и монитор, разрешением 1920x1080. Данный тип устройства удаленного слежения за движением глаз предлагает широкие частоты дискретизации, а устройства с высокой частотой могут предоставлять большой объем данных и высокий уровень детализации, необходимый для образовательных нужд. Более того, экранные устройства отслеживания взгляда почти не заметны для пользователя, что позволяет получать достоверные результаты. Трекер, который применяется в данном лабораторном комплексе, использует системы, включающие методы яркого и темного зрачка. Устройства, которые используют в своей работе как темное, так и яркое отслеживание зрачка во время калибровки, сначала воздействуют на участников двумя методами, а для фактической записи координат взгляда выбирается метод, который обеспечивает наибольшую точность. Во время записи, данные устройства отслеживания глаз могут переключаться между ярким и темным отслеживанием зрачка, когда условия изменяются таким образом, что это оказывает существенное негативное влияние на возможность отслеживания. Если это произойдет, трекер будет переключаться между двумя методами до тех пор, пока снова не будут получены достоверные данные. Расстояние от экрана составляет от 0.9 до 1.2 метра, и обеспечивает максимальный угол обзора [6]. Фиксация головы не используется, так как воспроизводятся типичные пользовательские условия просмотра медиаконтента. Погрешности измерения компенсируются большим объемом собираемых данных, так как трекер производит запись с частотой 60 значений в секунду [7, 9-12].

Целью предлагаемого лабораторного комплекса является изучение студентами сцены кадра, региона интересов, отслеживания взгляда и статистическая обработка результатов.

Сцена кадра – это отдельные кадры видеоряда, объединенные единством действия, места действия и временем действия. Сцена изменяется тогда, когда меняется действие в кадре. Пример постоянной сцены кадра для 4 кадров приведен на рисунке 2.

Пример смены сцены кадра приведен на рисунке 3. При просмотре видео определенная часть изображения привлекает внимание зрителя, и человек-наблюдатель фиксирует данную часть сцены. Эта часть называется регионом интереса пользователя. Пример региона интереса представлен на рисунке 4.

Программно-аппаратный комплекс получения регионов интереса, представленный в работе, включает в себя: получение текущего подлежащего обработке кадра из последовательности кадров видеопоследовательности и алгоритмическое обнаружение интересующей области в текущем кадре, подлежащем обработке, в ответ на определение того, что текущий кадр, подлежащий обработке, является кадром обнаружения, для определения, по меньшей мере, одной области интереса (рис. 5).



Рис. 2. Пример постоянной сцены для 4 кадров.



Рис. 3. Пример смены сцены кадров.



Рис. 4. Регион интереса.

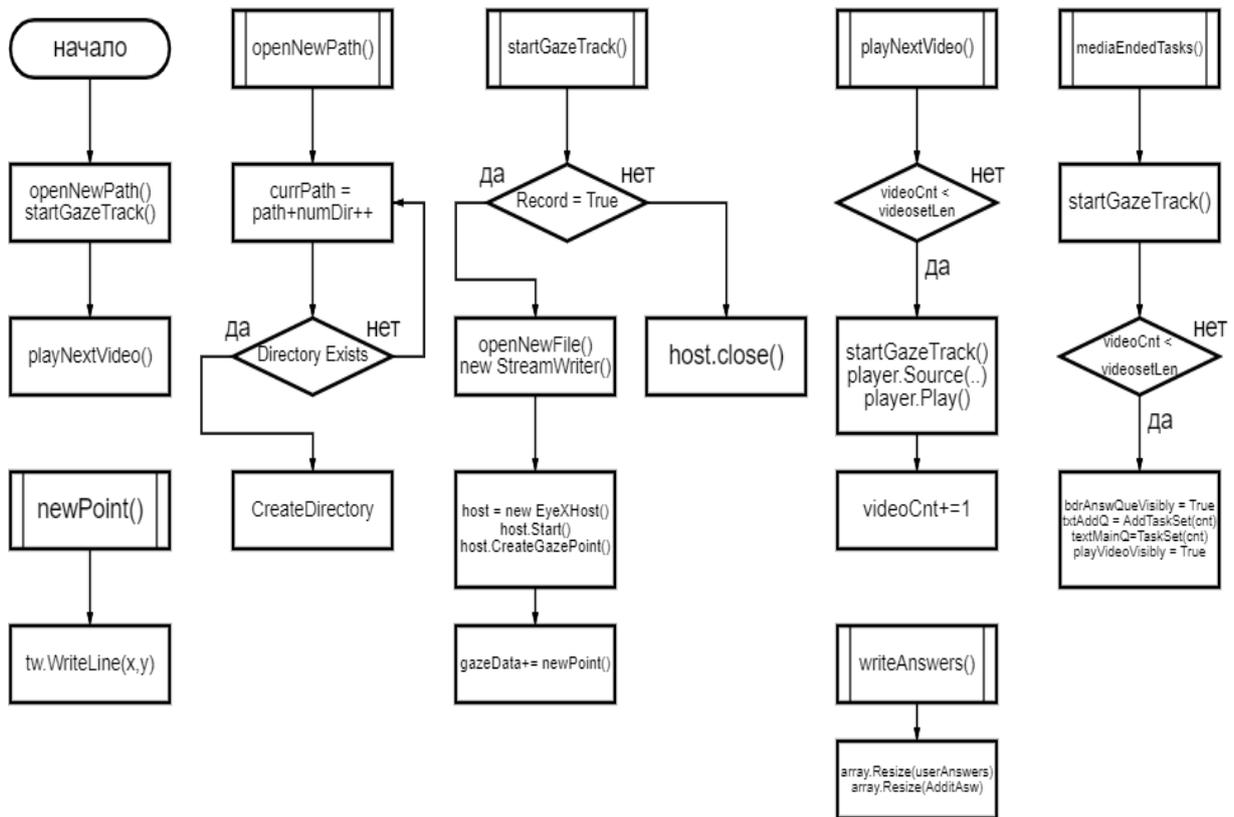


Рис. 5. Блок-схема алгоритмов работы программы.

Образовательная методология

Студенту необходимо изучить видеоряд и сформировать данные в таблицу о количестве сцен в видеопоследовательности. Далее идет сбор данных регионов интереса в каждой сцене, подлежащей обработке, и определение объект внимания пользователя. Сбор данных производится двумя путями, первый, это автоматизированный сбор данных лабораторным комплексом, или другими словами, создание визуальных карт, на основе фиксации взгляда пользователя. Второй - субъективный, где студент определяет регионы интереса в видеопоследовательности, согласно своему субъективному мнению. После сбора данных студент должен ответить на вопросы, касающиеся регионов интереса в видеопоследовательности, по собственному субъективному мнению и выделить основной регион интереса в каждой видеопоследовательности, относительно своего субъективного мнения.

Далее студент сравнивает обнаруженные субъективные регионы интереса с визуальными картами, предоставленными лабораторным комплексом, и проводит статистические вычисления отклонения реальных данных, собранных автоматически и субъективных данных, согласно представленной ранее методологии [8].

В конце программы студент проверяет свои вычисления с вычислениями, сделанными лабораторным комплексом в автоматическом режиме и делает вывод. Подобная постановка вопроса дает студенту возможность изучить регионы интереса на практике.

Заключение

В работе были рассмотрены и проанализированы особенности современных устройств для отслеживания взгляда, а также существующие алгоритмы работы отслеживания взгляда людей во время просмотра мультимедийного контента при потоковой передаче данных.

Выявлены проблемы изучения ограничений человеческого зрения, таких как изучения регионов интереса пользователей при просмотре мультимедийного контента в Университетах Российской Федерации и предложен путь решения. Представлен учебно-программный комплекс, позволяющий студентам ознакомиться с основами фундаментальных ограничений человеческого зрения и статистическим анализом.

Исследование выполнено за счет гранта Российского научного фонда № 23-29-00302 и гранта Российского научного фонда № 23-29-00299.

Литература

1. *Ehmke C., Wilson S.* Identifying web usability problems from eye-tracking data, pp. 119–128. British Computer Society (2007)
2. *Chuk T., Chan A.B., Hsiao J.H.* Understanding eye movements in face recognition using hidden Markov models. *J Vis.* 2014 Sep 16;14(11):8. doi: 10.1167/14.11.8. PMID: 25228627.
3. *Vyatkin M., Potashnikov A., Selivanov V., Vlasuyk I., Nezhivleva K., Mozhaeva A.* Method of Preventing Leakage of Personal Data Through Eyetracking Modules of User Devices // *T-Comm*, vol. 16, no.7, pp. 44-51. 2022.
4. *Nezhivleva K. I., Davydova A. A., Drebuszhan A. M., Mozhaeva A. I., Balobanov A.* Comparing of Modern Methods Used to Assess the Quality of Video Sequences During Signal Streaming with and Without Human Perception // 2022 Systems of Signal Synchronization, Generating and Processing in Telecommunications (SYNCHROINFO), 2022, pp. 1-6, doi: 10.1109/SYNCHROINFO55067.2022.9840983.
5. *Mozhaeva A., Mazin V., Cree M. J., Streeter L.* Video quality assessment considering the features of the human visual system // *Lecture Notes in Computer Science IVCNZ*, 2022, to appear.
6. *Mozhaeva A. I., Vlasuyk I. V., Potashnikov A. M., Cree M. J., Streeter L.* The Method and Devices for Research the Parameters of the Human Visual System to Video Quality Assessment // 2021 Systems of Signals Generating and Processing in the Field of on Board Communications, 2021, pp. 1-5, doi: 10.1109/IEEECONF51389.2021.9416081.
7. *Mozhaeva A., Potashnikov A., Vlasuyk I., Streeter L.* Constant Subjective Quality Database: The Research and Device of Generating Video Sequences of Constant Quality // 2021 International Conference on Engineering Management of Communication and Technology (EMCTECH), 2021, pp. 1-5, doi: 10.1109/EMCTECH53459.2021.9618977.
8. *Давыдова А.А., Можяева А.И., Хурани В.Х., Демина М.А., Русалимов М.А.* Методология исследования идентичности восприятия регионов интересов пользователей при просмотре потокового видео содержащего различный контент и артефакты сжатия // *Системы синхронизации, формирования и обработки сигналов.* 2022. Т. 13. № 6. С. 42-51. EDN IZCJOE.
9. *Valitskaya N.S., Vlasuyk I.V., Potashnikov A.M.* Video compression method on the basis of discrete wavelet transform for application in video information systems with non-standard parameters // *T-Comm.* 2020. Т. 14. № 3. С. 47-53.
10. *Поташиников А.М., Власюк И.В.* Метод построения равноконтрастного цветового пространства для заданной системы отображения информации и условий контроля // *T-Comm: Телекоммуникации и транспорт.* 2020. Т. 14. № 4. С. 15-22.
11. *Можяева А., Власюк И., Неживлева К., Комина А.* Методология создание стимула для количественной оценки эффекта мерцания при сжатии видео // *Системы синхронизации, формирования и обработки сигналов.* 2022. Т. 13. № 6. С. 29-36.
12. *Mozhaeva A., Vashenko E., Selivanov V., Potashnikov A., Vlasuyk I., Streeter L.* Analysis of current video databases for quality assessment // *T-Comm.* 2022. Т. 16. № 2. С. 48-56.

РАЗРАБОТКА НЕЙРОННОЙ СЕТИ ДЛЯ ОПРЕДЕЛЕНИЯ ЦЕНОВОЙ КАТЕГОРИИ АВТОМОБИЛЯ НА ОСНОВАНИИ ЕГО ХАРАКТЕРИСТИК

Гусев Андрей Сергеевич,

*Московский Технический Университет Связи и Информатики, магистрант 1-го года обучения,
Москва, Россия*

andrey1235594@mail.ru

Аннотация

В статье описан процесс разработки и реализации нейронной сети, используемой для классификации автомобилей по ценовой категории на основании их характеристик. Описана подготовка и предварительная обработка набора данных, реализация модели нейронной сети, ее обучение и тестирование, проведен анализ полученных результатов.

Ключевые слова: *Машинное обучение, интеллектуальный анализ данных, нейронная сеть, задача классификации, определения ценовой категории автомобиля.*

Введение

Для большинства граждан предпочтительнее купить подержанный автомобиль. Какую сумму правильно будет заплатить за этот автомобиль?

Используя нейронную сеть (НС), мы можем определить стоимость автомобиля на основе данных характеристик. Большой интерес представляет изучение возможностей применения искусственных нейронных сетей (ИНС) и машинного обучения (МО).

МО – одна из самых захватывающих современных технологий. Мы используем алгоритмы МО десятки раз в день, даже не подозревая об этом [1]. На кафедре «интеллектуальные системы в управлении и автоматизации» МТУСИ данной тематике посвящено много научных работ [2,3,4, 13, 14].

Одной из задач является оценка подержанных автомобилей, а именно, определение ценовой категории транспортных средств в связи с расширением количества интернет-площадок, увеличением доли сделок с бывшими в употреблении автомобилями, снижением спроса на новые машины из-за сложной ситуации в экономике после Covid 19. Задача, решение которой описано в данной статье, заключается в реализации НС, которая будет классифицировать автомобили по следующим характеристикам: «дешевые», «средние» и «дорогие».

Анализ предметной области

В настоящее время в интернете можно обнаружить большое количество сайтов, специализирующихся на продаже и покупке подержанных автомобилей. Это следующие ресурсы: auto.ru, drom.ru [5,6]. Можно заметить, что цена главным образом определяется по четырем основным параметрам: пробег, мощность двигателя, тип коробки передач, год выпуска автомобиля.

Существует большое количество классификаторов машинного обучения. Одним из самых важных является разделение на обучение с учителем и обучение без учителя. Под «учителем» здесь понимается сама идея вмешательства человека в обработку данных. При обучении с учителем имеются данные, на основании которых нужно что-то предсказать, и некоторые гипотезы. При обучении без учителя имеются только данные, свойства которых необходимо найти.

Наша нейронная сеть классифицируется как обучение «с учителем». В нашей сети это реализуется следующим образом: мы обрабатываем мультиклассовую классификацию. Это задача классификации с более чем двумя классами. Каждый образец можно пометить только как один класс.

Предсказуемый класс – это цена, так как раньше мы предсказали конкретную цену. Далее нам необходимо предсказать класс цен. Для этого мы используем квантиль. Квантили – это диапазон

распределения цен по нашим автомобилям [7]. 25% квантиль – это то, какую цену имеют 25% дешевых автомобилей. 75% квантиль – это то, какую цену имеют самые дорогие из первых 75% машин.

Искусственный интеллект (ИИ) сейчас востребован. Каждый год появляется огромное количество технологий и возможностей, которые двигают эту отрасль дальше. Неудивительно, что возможности ИИ активно применяют во многих сферах. Искусственная нейронная сеть (ИНС) – одно из направлений искусственного интеллекта. Области применения ИНС весьма разнообразны: распознавание и анализ текста и речи, семантический поиск, экспертные системы и системы поддержки принятия решений, предсказание курсов акций, системы безопасности.

Описание набора данных

Набор данных состоит из информации об автомобилях, полученных с сайта Kaggle. Выборка была разбита на две части для обучения и для тестирования модели. В выборке 36 000 объявлений и 20 характеристик для каждого из объектов. Столбцы набора данных: год автомобиля (year); поколение автомобиля (generation); пробег (mileage); количество владельцев (owners); объем двигателя (engine_value); тип двигателя (engine_type); тип коробки передач (gearbox); привод (transmission); комплектация (complete); тип кузова (type); цвет (color); руль (wheel); марка (brand); модель (model); метка, рестайлинговый автомобиль (restyling); цена (price) [8, 9].

В случае данного набора категориальными (не имеющими числовой ранжировки) являются признаки: бренд, модель, поколение, тип кузова, тип двигателя, тип коробки передач, комплектация, привод, руль, рестайлинг. Остальные же признаки являются ранжируемыми.

Создание обучающих данных играет особо важную роль для любого анализа данных. Важной частью машинного обучения является наличие набора данных, который описывает исследуемые объекты или процессы, и отражает присущие им свойства и закономерности [10].

Анализ данных

Далее приведены некоторые распределения параметров в наборе данных.

На Рисунке 1 представлен график распределения количества владельцев автомобиля.



Рис. 1. График распределения владельцев автомобилей

На рисунке 2 представлен график распределения цветов автомобилей в наборе данных.

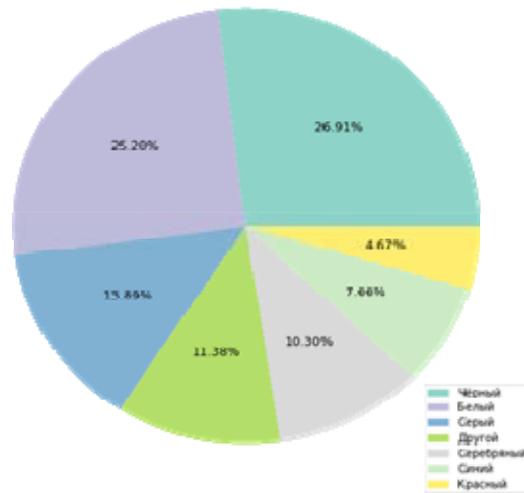


Рис. 2. График распределения цветов автомобилей

На Рисунке 3 представлен график распределения марок автомобилей в наборе данных.

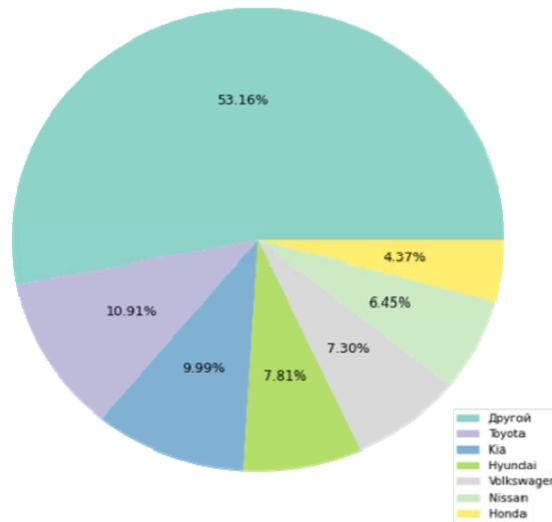


Рис. 3. График распределения марок автомобилей

Добавление признака

В связи с тем, что данные являются новыми, был добавлен признак: возраст машины, который вычисляется по следующей формуле: $age = 2022 - year$.

Кодирование признаков

Для обучения нейронной сети необходимо закодировать присутствие переменной (например, что бренд объекта – Audi). После кодирования категориальных переменных количество столбцов стало равно 2 410.

Нормализация данных

Для обучения нейронной сети также была проведена нормализация числовых данных – снижение размерности.

На рисунке 4 представлен график распределения пробега автомобиля в наборе данных.

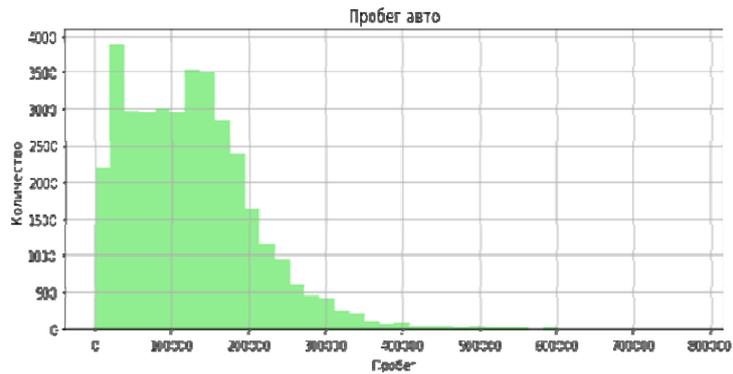


Рис. 4. График распределения пробега автомобиля

На Рисунке 5 представлен график распределения года выпуска автомобиля в наборе данных.

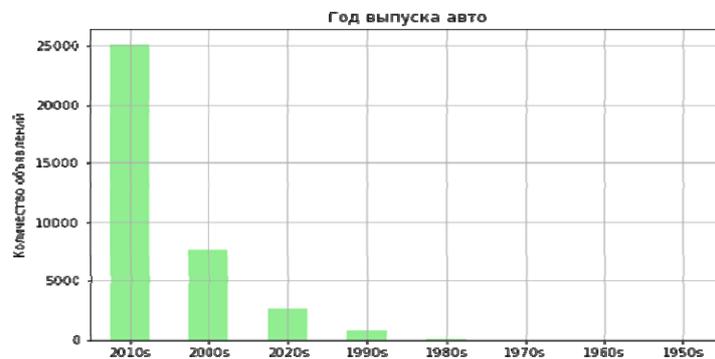


Рис. 5. График распределения года выпуска автомобиля

На Рисунке 6 представлен график распределения цены автомобиля в наборе данных.

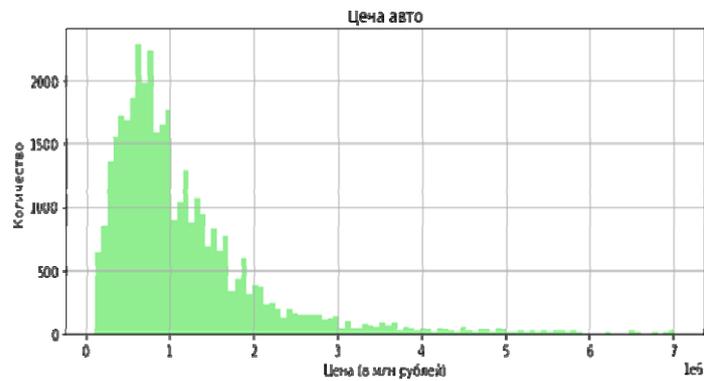


Рис. 6. График распределения цены автомобиля

Модель нейронной сети

Архитектура нейронной сети. В нейронной сети количество входных элементов равно размерности (2 410 значений). Количество скрытых слоев составляет 2, в каждом из которых также 2 410 нейронов. Количество нейронов на выходном слое 3 (по количеству классов), так как относится к одному из трех классов («дешевые», «средние» и «дорогие».) Архитектура НС на рисунке 8 включает основные шаги обработки входных данных, их преобразование в нужный формат для подачи на вход сети, а также этапы построения и исследования работы модели нейронной сети.

Построение архитектуры нейронной сети реализуется при помощи модели Keras – Sequential model [11], работающей совместно с библиотекой TensorFlow [12]. Используя метод add, можно добавлять новые слои, указывая их размерность, функцию активации, аргумент ожидаемых данных. Модель НС можно увидеть на рисунке 7.

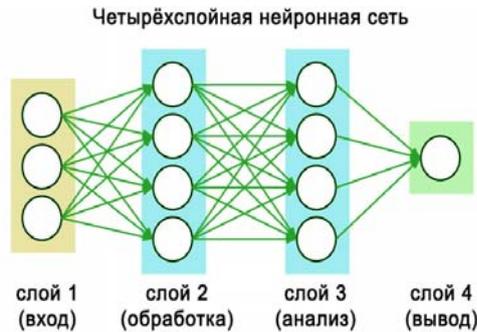


Рис. 7. Модель нейронной сети

Архитектура построенной сети представлена на Рисунке 8.

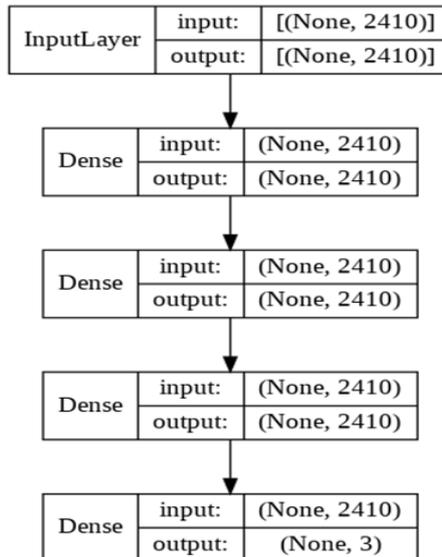


Рис. 8. Архитектура нейронной сети

Обучение и оценка точности нейронной сети

Для предсказания объектов ввели три класса: дешевые автомобили, автомобили средней цены и дорогие автомобили. Так как в нашей выборке есть цена автомобиля, посмотрим на распределение цен и создадим классы, используя 0.25 и 0.75 квантили распределения цены. Квантили распределения цены автомобилей данного набора изображены на рисунке 9.

0.25	579000.0
0.75	1420000.0

Рис. 9. Квантили распределения цены автомобиля

Таким образом, дешевыми машинами мы считаем автомобили стоимостью до 579 тысяч рублей, дорогие – свыше 1,4 миллиона рублей, остальные автомобили, находящиеся между 579 тысячами рублей и 1,4 миллионами рублей, это автомобили средней цены.

Функция преобразования отображена в Листинге 1.

Листинг 1

```
def preproc(x):
    if x <= 579_000:
        return 0
    elif 579_000 < x <= 1_420_000:
        return 1
    else:
        return 2
df['price'] = df['price'].apply(lambda x: preproc(x))
```

На Рисунке 10 изображены классы автомобилей после преобразования цены.

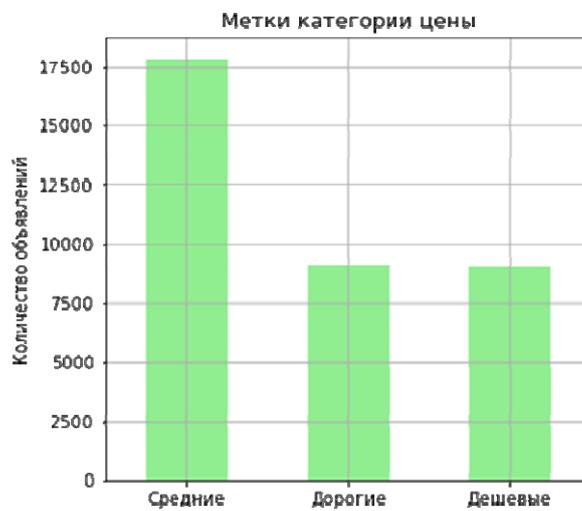


Рис. 10. График распределения категорий цен автомобиля

Обучение происходит методом обратного распространения ошибки. Цель обучения: найти набор весов и смещений, который минимизирует функцию потерь. Обучили модель при стартовом learning rate = 0.001 и количестве эпох, равным 100 объявлений о продажах автомобилей.

На рисунке 11 отображены результаты потерь после обучения сети.

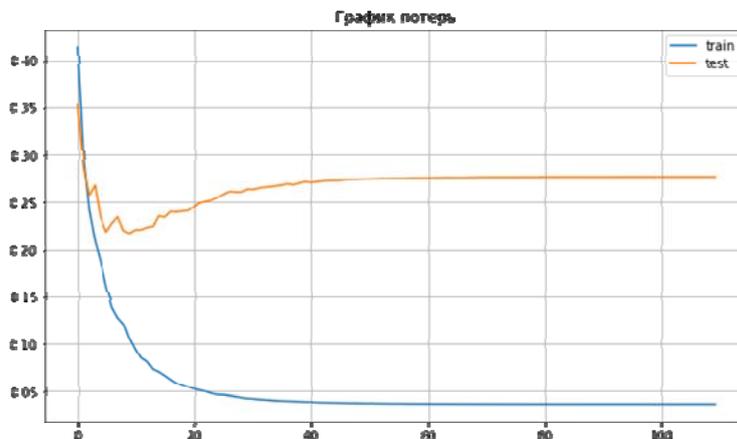


Рис. 11. График результатов потерь после обучения НС

Результаты показывают явное переобучение модели. Для получения нового результата поставили меньшее количество эпох и параметр learning rate, и задали данные параметры как: learning rate = 0.0001, а количество эпох равным 50.

Тестирование разработанной нейронной сети

Количество тестовых образцов составляет 5 396, а количество тренировочных образцов – 30 571. Для предотвращения переобучения были введены две функции, отвечающие за снижение скорости обучения и сохранение лучшего результата до переобучения (Листинг 2). Максимальное количество эпох составляет 100 (Листинг 2).

Листинг 2

```
history = model.fit(X_train, y_train, epochs=n_epochs, verbose=2, batch_size=1024,
validation_data=(X_test, y_test), callbacks=[es, lr_scheduler])
```

После обучения сети на графике отобразили результаты потерь (рис. 12) и F1 меры (рис. 13).

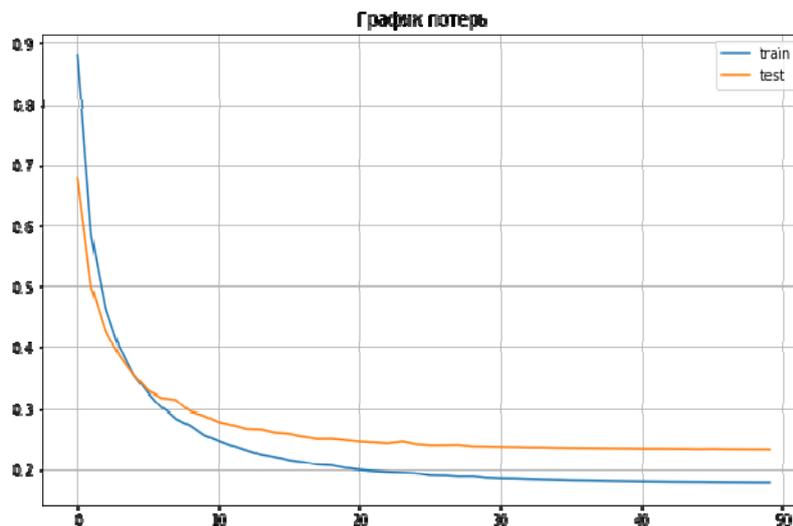


Рис. 12. График потерь обучения НС

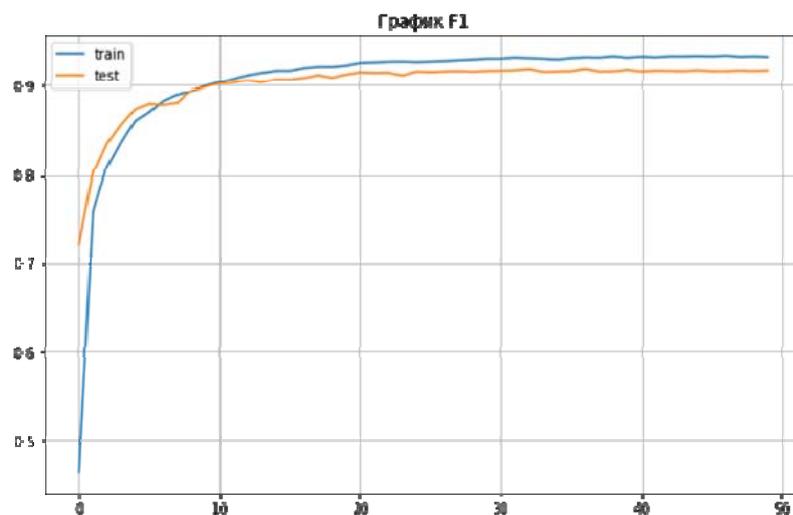


Рис.13. График F1 меры обучения НС

Проанализировав количество эпох, необходимых для обучения сети, по графикам, после 20 эпохи функция потерь тестового набора становится меньше 0.25, значение потери практически не изменяется, соответственно, можно закончить обучение на этом этапе.

Результат тестирования сети изображен на рисунке 14.

F1-мера: 0.917
Accuracy: 0.912

Рис. 14. Метрики тестирования

На рисунке 15 представлены метрики отдельно по классам.

	precision	recall	f1-score
Дешевые	0.91	0.89	0.90
Средние	0.90	0.92	0.91
Дорогие	0.94	0.91	0.92

Рис. 15. Метрики, распределенные по классам

Выводы

Результаты показывают, что полностью подключенная нейронная сеть с выходным слоем softmax и 3 классами хорошо обучена и классифицирует данные, даже с несбалансированным распределением классов. Класс с размером выборки в два раза большим может исказить результаты и создать смещение в сторону этого класса.

Несмотря на высокую точность 0,91, 0,9 и 0,94 для каждого из классов, важно оценить производительность модели для меньших классов, чтобы убедиться, что она не просто предсказывает больший класс, для этого используем F1.

Оценка F1, равная 0,9, 0,91 и 0,92 для каждого из классов, предполагает, что модель сбалансирована по своей точности и отзывчивости.

Заключение

В данной статье описано решение поставленной задачи классификации автомобилей по ценовой категории на основе их характеристик.

Поставленная задача была решена, нейронная сеть классифицирует автомобили по ценовой категории на основании их характеристик. При проведении тестирования работоспособность НС была оценена положительно.

По результатам тестирования, метрики Precision и F1 показывают высокую точность классификации в трех ценовых категориях. Значения Precision для каждой категории находятся в пределах 0.9-0.94, что указывает на то, что модель выделяет верные классы с высокой вероятностью. Аналогичные результаты можно наблюдать и по метрике F1, где значения также высокие.

Оценка Precision показала хорошие результаты, в том числе для второго класса, где показатель составил 0.9. Для других двух классов Precision достигла значений 0.91 и 0.94, что также является хорошим результатом.

F1 также показал хорошие результаты, составив 0.9 для первого класса, 0.91 для второго и 0.92 для третьего.

Таким образом, можно сделать вывод о хорошей работоспособности нейронной сети при решении задачи классификации автомобилей.

Литература

1. *Воронова Л.И., Воронов В.И.* Machine Learning: регрессионные методы интеллектуального анализа данных: учебное пособие. М.: Московский технический университет связи и информатики, 2018. 82 с. // Электронно-библиотечная система IPR BOOKS: URL: <https://www.iprbookshop.ru/81325.html> (Дата обращения: 12.01.2023).
2. *Бауэр Е.В., Воронова Л.И.* Применение систем распознавания единиц вооружения и военной техники // Телекоммуникации и информационные технологии. 2021. Т. 8. № 1. С. 87-93.
3. *Вовик А.Г., Воронова Л.И.* Исследование систем предсказания утечек в магистральном нефтепроводе. URL: <https://www.elibrary.ru/item.asp?id=43404648> (Дата обращения: 12.01.2023).
4. *Воронов В.И., Князев Е.С.* Нейросетевое распознавание объектов жилого помещения // Технологии информационного общества. Сборник трудов XVI Международной отраслевой научно-технической конференции. 2022. С. 286-288. URL: <https://elibrary.ru/item.asp?id=48522364> (Дата обращения: 12.01.2023).
5. Сайт. Легковые автомобили. URL: <https://auto.ru>. (Дата обращения: 12.01.2023).
6. Сайт. Продажа авто в России. URL: <https://www.drom.ru/>. (Дата обращения: 12.01.2023).
7. Метрики в задачах машинного обучения. URL: <https://habr.com/ru/company/ods/blog/328372/> (Дата обращения 12.01.2023).
8. Kaggle URL: <https://www.kaggle.com/datasets> (Дата обращения 12.01.2023).
9. Google Dataset search URL: <https://datasetsearch.research.google.com/> (Дата обращения 12.01.2023).
10. Подборка датасетов для машинного обучения URL: <https://habr.com/ru/post/452392/> (Дата обращения 12.01.2023).
11. Открытая библиотека машинного обучения Keras [Электронный ресурс]. URL: <https://keras.io/> (Дата обращения: 12.01.2023).
12. Открытая библиотека машинного обучения TensorFlow [Электронный ресурс]. URL: <https://www.tensorflow.org/> (дата обращения: 12.01.2023).
13. *Воронов В.И., Быков А.Д., Воронова Л.И.* Проектирование подсистемы детектирования лиц и интерфейса работы с базой данных в программно-аппаратном комплексе биометрической идентификации на основе нейросетевого распознавания лиц // Т-Comm: Телекоммуникации и транспорт. 2020. Т. 14. № 4. С. 31-38.
14. *Voronov V.I., Zharov I.A., Bykov A.D., Trunov A.S., Voronova L.I.* Designing a neural network identification subsystem in the hardware-software complex of face recognition // Т-Comm. 2020. Т. 14. № 5. С. 69-76.

ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ В ОБЛАСТИ РАСПОЗНАВАНИЯ СИГНАЛОВ В ЭФИРНЫХ ШУМАХ

Мингалеев Марат Азатович,

Московский Технический Университет Связи и Информатики, Москва, Россия
maratnismo@gmail.com

Белов Никита Вадимович,

Московский Технический Университет Связи и Информатики, ассистент каф. ИСУиА,
Москва, Россия
n.v.belov@mtuci.ru

Аннотация

В рамках исследования, описанного в статье, разработана нейросеть для обнаружения ионосферных сигналов с круговой (эллиптической) поляризацией и проведено сравнение эффективности обнаружения сигнала обученной нейросетью. Приведён подробный разбор проектирования, реализации и тестирования нейронной сети, а также сравнение полученных результатов с пороговым обнаружителем.

Ключевые слова: *Ионосферные сигналы, машинное обучение, перцептрон, пороговый обнаружитель, сигнал в шумах.*

Введение

Помимо полезного сигнала на входе любого устройства связи присутствуют шумы. Задача, решаемая в цифровых системах – отличить этот полезный сигнал от шума.

Чтобы отличить полезный сигнал от шума используется пороговый обнаружитель, как в патенте [1].

В настоящее время для улучшения показателей обнаружения сигнала в шумах могут быть применены методы искусственного интеллекта, которые за последние несколько лет получили широкое распространение во многих областях. Это стало возможным благодаря значительному увеличению вычислительных возможностей процессоров современных компьютеров. Такие системы уже доказали свою актуальность в решении задач автоматизации процессов и проведении различных исследований.

Многие исследователи применяют методы искусственного интеллекта для радиосигналов [2, 3], а также для других задач, в том числе, кафедра Интеллектуальные системы в управлении и автоматизации МТУСИ [4, 5, 6].

Анализ технологий для проектирования и реализации нейронной сети

Проведя анализ доступных технологий, выделены два способа, позволяющих реализовать поставленную задачу: облачный и локальный. Первый способ подразумевает исполнение программы в режиме онлайн на мощностях, предоставляемых каким-либо сервисом. Второй способ задействует вычислительные мощности пользовательской машины.

Каждый способ имеет свои преимущества и недостатки и подходит для определенных задач. Рассмотрим их по отдельности. Google Colab (Colaboratory) – это интерактивная облачная среда для работы с кодом, которая позволяет работать над одним проектом команде из нескольких человек. Она основана на блокноте Jupyter для работы с программным кодом на языке Python. В отличие от Jupyter Notebook все вычисления происходят на мощностях серверного оборудования компании Google, база данных необходимая для работы располагается в облачном хранилище [7].

При локальном способе используется Jupyter Notebook, который является программой, установленной непосредственно на пользовательскую машину. При работе задействуются мощности центрального процессора персонального компьютера, а необходимые данные находятся на дисковом

пространстве этого ПК. Среда разработки открывается в браузере и позволяет интерактивно исполнять программный код, написанный на языке Python, который можно разбить на несколько ячеек, исполняемых отдельно [8].

Главным недостатком разработки с использованием Jupyter Notebook является ограничение вычислительных возможностей пользовательской машины. Высокопроизводительные рабочие станции для работы с большими массивами данных доступны очень малому кругу лиц ввиду своей значительной стоимости и трудности в обслуживании. В то же время современный среднестатистический персональный компьютер обладает достаточной мощностью для работы с небольшими наборами данных, что покрывает потребности в рамках текущего исследования. Локальный способ не требует выгрузки данных на облачный сервер, предоставляет все ресурсы без прерываний при плохом соединении с сетью интернет, сеанс может остановить только пользователь и нет необходимости оплачивать подписку за приоритетный доступ [9].

По совокупности факторов удобства и простоты использования следует отдать предпочтение локальному способу реализации для тех ситуаций, когда это возможно.

Программный продукт `anaconda Jupyter Notebook` уже содержит в себе некоторые предустановленные стандартные библиотеки Python, но также имеется возможность установки дополнительных, таких как: TensorFlow и Keras – необходимых для решения задач машинного обучения [10].

Способ построения нейронной сети

Наиболее широко применимым алгоритмом для решения разнообразных задач классификации и прогнозирования на данный момент являются нейронные сети.

Структура нейронной сети состоит из нескольких слоёв. В каждом слое имеется некоторое количество нейронов, которые передают данные всем нейронам на следующем слое и т. д. Пройдя через все скрытые слои, данные достигают выходного слоя, на котором сеть выносит предположения о классификации или способе решения задачи [11].

На данный момент выделяют множество различных архитектур нейронных сетей, которые применяются для распознавания изображений. Сети, основанные на архитектуре многослойного персептрона, строятся из трёх и более слоёв и используют нелинейную функцию активации для задач классификации данных. В такой сети каждый нейрон в слое соединен с каждым узлом в последующем, что делает её полностью связанной. Модель многослойного персептрона изображена на рисунке 1.

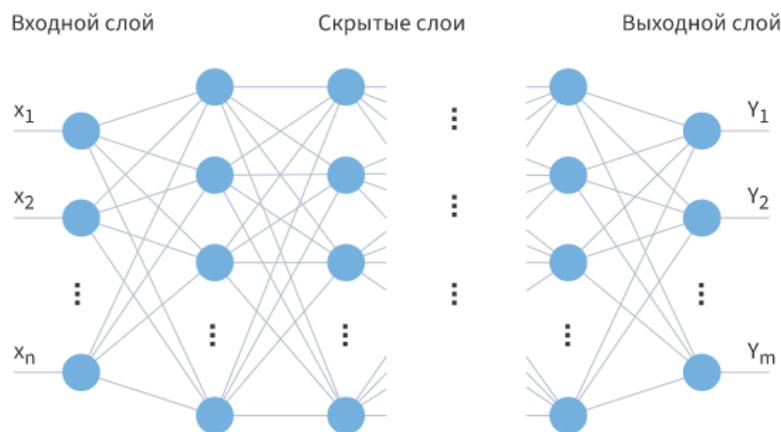


Рис. 1. Графическое представление архитектуры многослойного персептрона

Описанная выше архитектура хорошо зарекомендовала себя в задачах классификации объектов и аппроксимации сложных функций, при этом являясь, простой в реализации и легко поддающейся масштабированию в зависимости от сложности поставленной задачи [12].

Программная реализация нейронной сети для распознавания сигналов в шумах

Чтобы реализовать поставленную задачу, выбран локальный способ. В качестве основы проектируемой нейронной сети будет выступать архитектура многослойного персептрона.

Для подготовки набора данных необходимо получить графические изображения траекторий вектора электрического напряжения во вращающейся антенне при различных параметрах волн, зависящих от среды распространения.

По виду этих траекторий необходимо обнаружить и оценить требуемую волну. Для работы системы распознавания с использованием нейронной сети необходим обучающий массив данных и массив для тестирования работы сети.

Принятый сигнал характеризуется траекторией, описываемой концом электрического вектора E волны. Это может быть прямая линия (так называемая линейная поляризация), круг (круговая поляризация), эллипс (эллиптическая). Эту траекторию можно не только представить, но и нарисовать по точкам, проводя измерения выходных напряжений двух перпендикулярных антенн. В результате получается прямоугольная система координат X и Y . Если к сигналу добавляются шумы, то картинка становится размытой, зачастую такой размытой, что увидеть сигнал в шумах становится невозможно. Если начать вращать антенную систему, картинка траектории вектора E меняется, так как меняется спектральный состав принятого сигнала [13].

Распознавание полученного изображения нейронной сетью будет успешнее, чем просто искать сигнал в шумах на выходе неподвижной антенны. Для обучения нейронной сети необходимо получить изображения сигнала при разных параметрах волны и шума.

Моделирование сигнала производилось с помощью программы MathCad. Пример получившегося изображения приведен на рисунке 2.

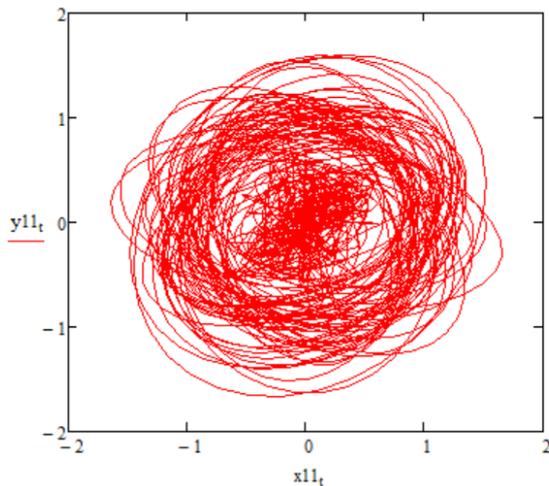


Рис. 2. Изображение, полученное в программе MathCad

В результате подготовлен набор данных, содержащий изображения с графическим представлением шумов и смеси сигнала с шумом. Изображения приведены к размеру 64x64 пкс, что ускоряет обработку и оптимизирует занимаемое ими дисковое пространство. Набор из 236 изображений разделен на 2 класса: signal, no signal. Из общего количества выделен набор для тестирования из 36 изображений, это необходимо, чтобы проверить работоспособность обученной модели на изображениях, которые не участвовали в обучении (рис. 3).

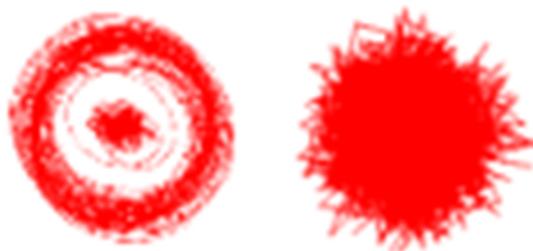


Рис. 3. Пример подготовленных изображений

Непосредственно построение архитектуры нейронной сети начинается с выбора размерности входного слоя. При преобразовании изображений, подающихся на вход, в одномерный массив получается 4096 элементов, по количеству пкс в каждом изображении, столько же нейронов в первом слое.

Информация с нейронов входного слоя поступает на нейроны скрытого слоя. Путём проведения нескольких опытов установлено, что оптимальную точность и скорость выполнения обеспечивает наличие двух скрытых слоёв с 32 и 16 нейронами соответственно.

Выходной слой состоит из 2 нейронов по количеству классов, к которым относится каждое изображение.

Размерность сети определяется с учётом объёма обучающего набора и доступных вычислительных мощностей. Для очень больших наборов данных, состоящих из множества изображений в высоком разрешении, потребуется увеличить количество нейронов в скрытых слоях и/или добавить дополнительные скрытые слои, чтобы модель имела достаточную точность классификации на выходе.

Графическое представление реализуемой архитектуры представлено на рисунке 4.

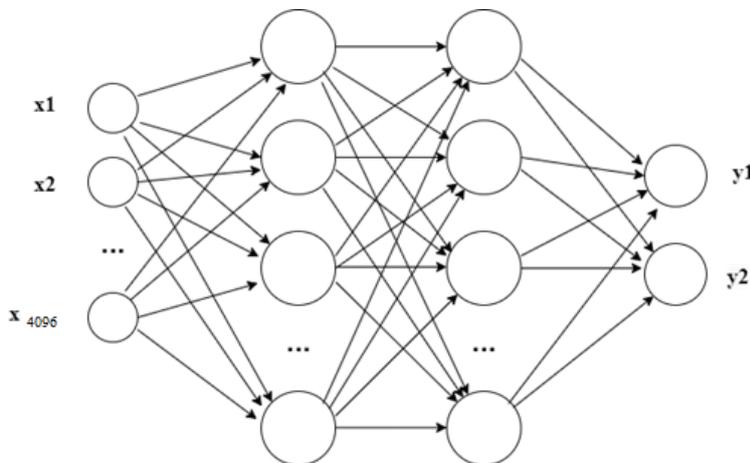


Рис. 4. Архитектура нейронной сети

Подготовив наборы данных и определив архитектуру сети, необходимо перейти к обучению. В процессе работы с обучающим набором сеть проходит через несколько эпох обучения, после прохождения каждой точность предсказания возрастает, а величина ошибки уменьшается. Проведя несколько экспериментов, выявлено, что модель показывает достаточные значения точности уже после прохождения 5 эпох.

Далее обученная нейронная сеть проходит проверку на тестовом наборе данных. Точность предсказания при тестировании выше, чем при прохождении обучения, следовательно, модель работает корректно.

После проверки результатов тестирования следует перейти к выводу изображений с присвоенными для них классами. В ходе визуального осмотра выявлено, что предсказанные классы

соответствуют содержанию изображений, следовательно, нейронная сеть адекватно проводит классификацию (рис. 5).

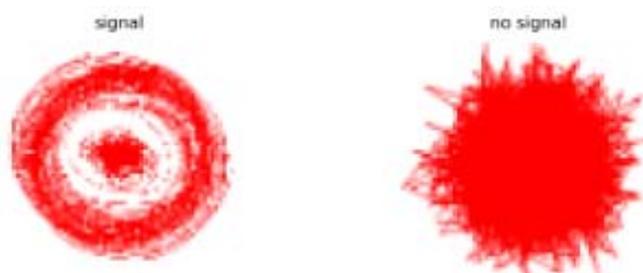


Рис. 5. Результат работы программы

Для нейронной сети, реализованной в рамках исследовательской работы, нет необходимости в увеличении числа нейронов в скрытых слоях, достаточная точность достигается с изначально подобранной архитектурой, и равна 98% на 5 эпохе. Дальнейшие тесты показали, что увеличение количества нейронов в скрытых слоях положительно сказывается на значении итоговой ошибки, но при этом существенно возрастает время, требуемое на обучение нейронной сети, при этом точность не возрастает уже после прохождения 3 эпохи, то есть увеличенное количество нейронов нецелесообразно (рис. 6).

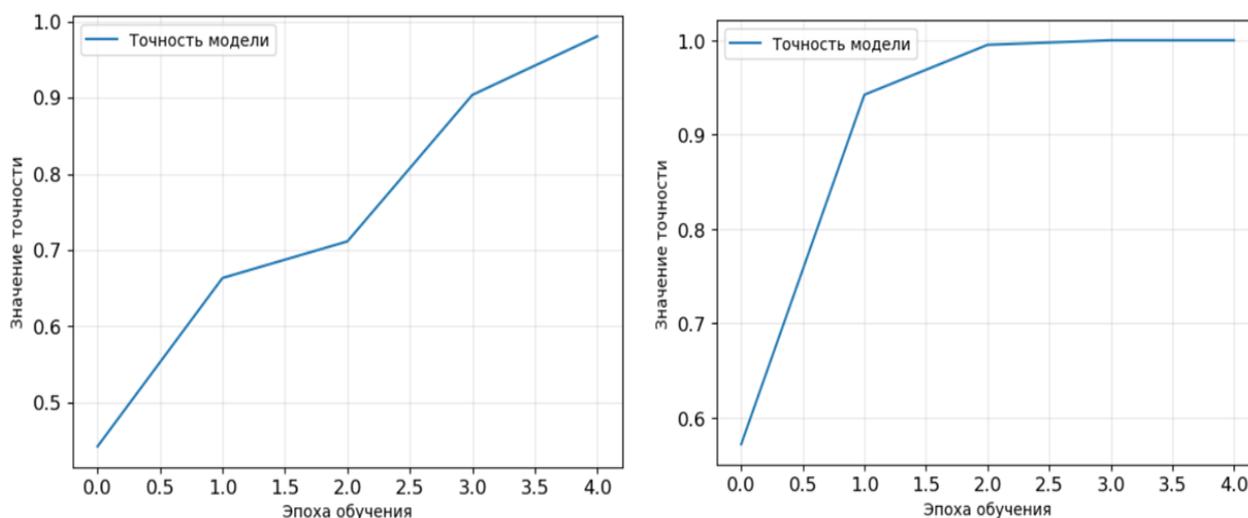


Рис. 6. Результат обучения сети до и после изменения параметров

Сравнение точности определение сигнала пороговым методом и нейронной сетью

Для определения процента обнаружения пороговым методом проведем ряд экспериментов в программе MathCad. Запустив эту программу при разном уровне шума N , получаем зависимость вероятности обнаружения для традиционного порогового метода.

Полученные результаты обоих методов внесены в таблицу 1.

Таблица 1

Результаты моделирования двух методов обнаружения сигнала

Уровень шума, N	P _о , обнаружителя сигнала порогового типа	P _о , нейросетевого обнаружителя
0,25	0,956	1
0,3	0,906	1
0,35	0,885	1
0,4	0,833	0,942
0,45	0,794	0,968
0,5	0,75	0,833
0,55	0,714	0,831
0,6	0,694	0,7667
0,65	0,657	0,7538
0,7	0,626	0,7301
0,75	0,616	0,7276
0,8	0,638	0,7259
0,85	0,584	0,7156
0,9	0,597	0,643
0,95	0,582	0,6823
1	0,569	0,6976
1,05	0,613	0,6834
1,1	0,527	0,6667
1,15	0,515	0,5638
1,2	0,579	0,5483
1,25	0,516	0,5471
1,3	0,506	0,5292
1,35	0,536	0,5026
1,4	0,522	0,5161

График зависимости уровня шума и вероятности обнаружения представлен на рисунке 7.

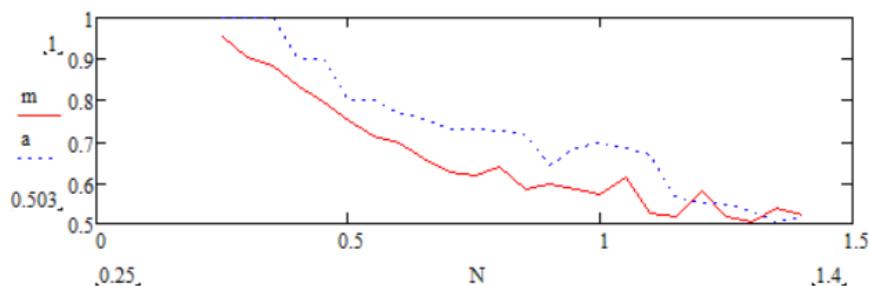


Рис. 7. График зависимости вероятности обнаружения нейросетевым (синий) и пороговым (красный) методами от уровня шума N

Как видно на рисунке 7, нейронная сеть в рассматриваемом случае при всех значениях отношения сигнал/шум лучше порогового обнаружителя.

Заключение

В статье исследована предметная область применения нейронных сетей в области распознавания сигналов. Выполнено исследование архитектур построения нейронных сетей, в результате чего выбрана архитектура многослойного персептрона. Подготовлен набор данных, каждое изображение отнесено к определённому классу.

Произведено тестирование разработанной нейронной сети, для этого использована среда Jupyter Notebook. На вход подается изображение сигнала, смешанного с шумом или чистого шума, обученная модель относит его к одному из классов. Проведено тестирование архитектуры нейронной сети с различными параметрами и сравнение с пороговым обнаружителем.

В результате при всех значениях отношения сигнал/шум нейронная сеть лучше порогового обнаружителя.

Литература

1. Капустин В. П., Казачок Д. А., Четыркин И.В. Пороговый обнаружитель. Патент США № 3479599, 1СЛ. И 04 В 1/10, 1969.
2. Adjemov S. S., Belov N. V., Repinsky V. N., Shmelev I. A. Intelligent location of a multi-beam ionospheric wave by isolating the polarization characteristics of Partial Channels // 2020 International Conference on Engineering Management of Communication and Technology, EMCTECH 2020 - Proceedings, Vienna, 20-22 октября 2020 г. Vienna, 2020. P. 9261552. DOI 10.1109/EMCTECH49634.2020.9261552. EDN QLSEZB
3. Adjemov S. S., Belov N. V., Repinsky V. N. Isolation of Interfering Wave Components in a Phased // 2020 Systems of Signals Generating and Processing in the Field of on Board Communications, Moscow, 19-20 марта 2020 г. Moscow: Institute of Electrical and Electronics Engineers Inc., 2020. P. 9078580. DOI 10.1109/IEEECONF48371.2020.9078580. – EDN IEYHGX.
4. Свидетельство о государственной регистрации программы для ЭВМ № 2022614625 Российская Федерация. Программный комплекс распознавания элементов русского жестового языка на основе технологий компьютерного зрения и глубокого машинного обучения: № 2022613736: заявл. 15.03.2022; опублик. 23.03.2022 / М. Д. Артемов, Л. И. Воронова, И. А. Челябин [и др.]; заявитель Ордена Трудового Красного Знамени федеральное государственное бюджетное образовательное учреждение высшего образования «Московский технический университет связи и информатики». – EDN UGLMEN.
5. Дводненко Ю. Э., Воронова Л. И. Нейросетевое распознавание видов пневмонии по рентгеновским снимкам // Технологии информационного общества: Сборник трудов XVI Международной отраслевой научно-технической конференции, Москва, 02-03 марта 2022 г. М.: Издательский дом Медиа Паблишер, 2022. С. 278-272. EDN LBLSGF
6. Usachev V., Brus V., Voronova L., Tarasenko E. Research of Correlation Dependencies in Russian Household Data Using Data Mining Methods // Lecture Notes in Information Systems and Organisation: 3rd, Virtual, Online. Virtual, Online, 2022. P. 151-161. DOI 10.1007/978-3-030-94252-6_11. EDN XIEW
7. Google Colab [Электронный ресурс] // Colab.research.google.com: [сайт]. [2022]. URL: <https://colab.research.google.com/notebooks/intro.ipynb/> (дата обращения: 24.11.2022).
8. Jupyter [Электронный ресурс] // jupyter.org: [сайт]. [2022]. URL: <https://jupyter.org/> (дата обращения: 26.11.2022).
9. Jupyter Notebook documentation [Электронный ресурс] // jupyter-notebook.readthedocs.io: [сайт]. [2022]. URL: <https://jupyter-notebook.readthedocs.io/en/stable/notebook.html/> (дата обращения: 27.11.2022).
10. Библиотека Keras [Электронный ресурс] // ru-keras.com: [сайт]. [2022]. URL: <https://ru-keras.com/home/?ysclid=ldhs30nwx6157552945/> (дата обращения: 29.11.2022).
11. IBM cloud [Электронный ресурс] // ibm.com: [сайт]. [2022]. URL: <https://www.ibm.com/topics/neural-networks/> (дата обращения: 01.12.2022).
12. What is a Perceptron? [Электронный ресурс] // towardsdatascience.com: [сайт]. [2022]. URL: <https://towardsdatascience.com/what-is-a-perceptron-basics-of-neural-networks-c4cfea20c590/> (дата обращения: 02.12.2022).
13. Аджемов С. С., Ретинский В. Н. Прием обыкновенной и необыкновенной волн антенной решеткой с управляемой поляризационной характеристикой // Радиотехника и электроника. 2019. Т. 64. № 5. С. 455-461. DOI 10.1134/S0033849419050012. EDN ZCYNUT

ОПТИМИЗАЦИЯ МАРШРУТИЗАЦИИ В СЕТИ ПРИ ПОМОЩИ ГАМИЛЬТОНОВА ЦИКЛА И МАРКОВСКОГО ПРОЦЕССА ПРИНЯТИЯ РЕШЕНИЙ

Шведов Андрей Вячеславович,

Московский Технический Университет Связи и Информатики, старший преподаватель кафедры СИТус, Москва, Россия
a.v.shvedov@mtuci.ru

Гадасин Денис Вадимович,

Московский Технический Университет Связи и Информатики, доцент кафедры СИТус, к.т.н., Москва, Россия
dengadiplom@mail.ru

Клыгина Олеся Григорьевна,

Московский Технический Университет Связи и Информатики, магистрант гр. М092101(75), Москва, Россия
koreeramahan@yandex.ru

Тремасова Лилия Андреевна,

Московский Технический Университет Связи и Информатики, магистрант гр. М092101(75), Москва, Россия
lila.trem@yandex.ru

Аннотация

В связи с тем, что современные сети могут включать в себя множество элементов и соединений между ними для эффективной работы, необходимо быстро реагировать и обрабатывать передаваемые данные. Одним из инструментов для этого является маршрутизация данных в сети. В то же время, учитывая природу инфокоммуникационной сети, ее можно представить в виде системы массового обслуживания. Случайный процесс характерен для системы массового обслуживания. Изучение случайного процесса, происходящего в системе, выражая его математически, является предметом теории массового обслуживания. В такой системе всегда существует поток приложений, поступающих в систему от пользователей. Система, в свою очередь, обрабатывает заявки и возвращает результат пользователю, соответственно, можно сделать вывод, что существуют как входящие, так и исходящие потоки заявок. Данная публикация посвящена оптимизации сетевой маршрутизации с использованием марковского процесса принятия решений и гамильтонова цикла.

Ключевые слова: *Маршрутизация, маршрут, метрика, протоколы маршрутизации, Марковский процесс, Гамильтонов цикл, Интернет вещей, MDP, IoT, SDN.*

Введение

По определению, инфокоммуникационная сеть – это набор связанных между собой узлов, основная цель организации которой заключается в передаче информации за определенный промежуток времени [1,2, 18-28]. Как известно, современные сети могут включать множество элементов и связей между ними. Поэтому, для эффективной работы системы необходимо оперативно реагировать и обрабатывать передаваемые данные.

Поскольку сеть является лишь инструментом, технологии применения этого инструмента к передаваемой информации могут варьироваться, т.е. алгоритмы передачи информации между узлами, выбор порядка передачи, построение маршрутов от одного узла к другому могут отличаться. При этом, принцип организации сети, а также цели передачи данных, не влияют на возможное увеличение трафика, в следствии чего нагрузка на отдельные узлы возрастает [3, 4, 5].

Часто сеть не может справиться с потоком поступающих заявок. Это приводит к образованию очередей заявок, в частности, к отказу в обслуживании этих заявок. Решение видится в нахождении возможных кольцевых маршрутов, по которым можно отправлять заявки, пока основной узел не освободится.

Случайный характер потока заявок

Предметом теории массового обслуживания является изучение случайного процесса [6], и, если рассматривать поступающие в сеть заявки как случайный процесс, то можно сделать вывод, что инфокоммуникационную сеть можно представить как систему массового обслуживания [7].

Данная система принимает поступающий (входящий) поток заявок, обрабатывает его и возвращает результат пользователю (исходящий поток заявок). Заявки, в свою очередь, поступают в систему случайным образом [8,9]. Случайный характер потока, который также можно назвать стохастическим, часто приводит к неравномерно загруженной системе. Это значит, что на каких-то узлах в определенные периоды времени заявок накапливается больше, чем на других узлах [10].

Допустим, маршрутизатор может находиться в трёх состояниях:

S_1 – свободен;

S_2 – занят, при этом очередь отсутствует;

S_3 – занят, при этом очередь присутствует.

Можно изобразить граф, в котором события S_1 , S_2 и S_3 будут представлены вершинами, а интенсивность будет являться весами рёбер (Рис. 1). Вершины соединены друг с другом в обоих направлениях, т.к. маршрутизатор может переходить, например, из состояния S_1 в S_2 , так и из S_2 в S_1 .

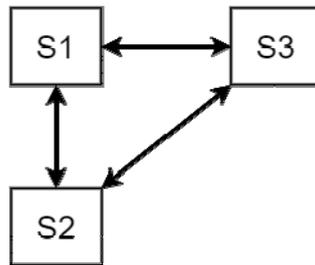


Рис. 1. Граф перехода состояний

Когда на вход маршрутизатора поступают заявки, он переходит из состояния S_1 в S_2 . Переход из S_2 в S_3 происходит, когда образуется очередь. Это связано с тем, что для обработки поступающих заявок перестаёт хватать вычислительных ресурсов. Соответственно, возникает проблема в связи с тем, что происходит переход из состояния S_2 в S_3 , возникает очередь из пакетов и появляется вопрос о том, как необходимо действовать в такой ситуации и как можно осуществить переход обратно из состояния S_3 в S_1 или S_2 .

Гамильтонов цикл в сети

Для выхода из ситуации, когда сеть не может справиться с потоком поступающих заявок, необходимо рассмотреть наличие в сети кольцевых маршрутов, по которым можно отправлять заявки, пока основной узел не освободится. Как известно, в направленном графе может быть решена задача о нахождении гамильтонова цикла [11], и, если сеть представить направленным графом, то для решения поставленной в начале задачи может быть предложен гамильтонов цикл [12].

Он представляет собой замкнутый путь, в котором заявка пройдёт через каждую вершину ровно один раз. При этом начальной вершиной можно выбрать любую вершину и рассматривать перестановки с фиксированным первым элементом. Таким образом, получается, что задачу можно рассматривать с комбинаторной точки зрения, однако в крупном графе таких перестановок может

быть очень много [13]. Также допускается простое рассмотрение всех возможных путей с поочерёдной сменой стартовой вершины до тех пор, пока не будет найден гамильтонов цикл [14].

Однако, если рассмотреть сеть в виде графа, представленного соединёнными векторами в n -мерном пространстве, где каждая вершина n -мерного куба будет представлять координату по соответствующей оси, а у соседних вершин по соединяющему их ребру будет отличаться ровно одна координата, то можно говорить о n -битном коде Грея, который соответствует Гамильтонову циклу в n -мерном кубе. Значит, если построить путь в таком кубе, то получится код, где соседние значения отличаются не более чем на один бит.

Если посмотреть на изображение четырёхмерного куба на плоскости (рис. 2), то можно отметить наличие вершин и соединяющих их рёбер.

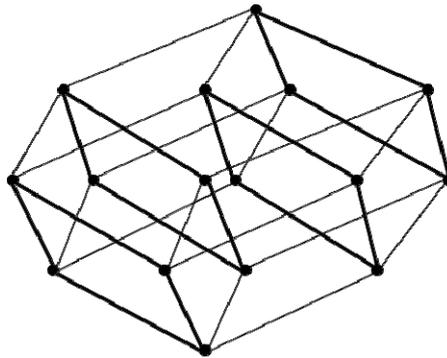


Рис. 2. Четырёхмерный куб

Отображением n -битного кода Грея на таком кубе будет соотнесение каждой вершины с набором битов, где соседние вершины отличаются лишь в одной компоненте [15]. Набор состоит из комбинации нулей и единиц и представляет собой имя вершины (рис. 3).

Пусть начальной вершиной в данном случае будет самая нижняя вершина, именем которой будет являться комбинация, состоящая только из нулей.

Далее присваиваем имена вершинам согласно алгоритму: если вершина, в которой мы находимся, уже имеет имя, и, поднимаясь из неё по какому-нибудь ребру, попадаем в безымянную вершину, то присваиваем ей имя прошлой вершины с заменой k -ой компоненты, которая была нулём, на единицу. Алгоритм должен закончиться, когда самая последняя вершина получит имя, состоящее из одних единиц.

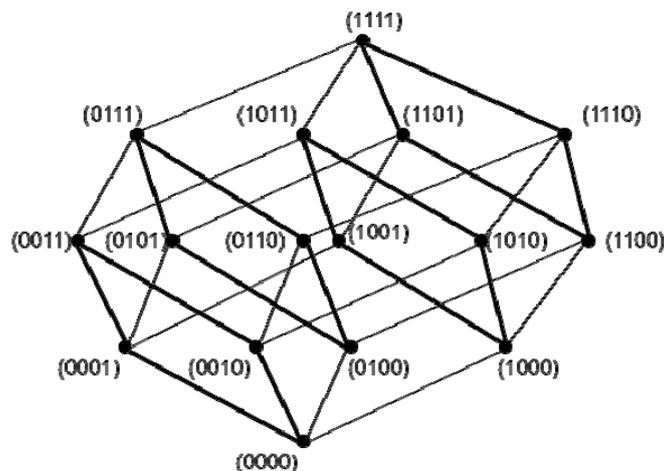


Рис. 3. Отображение n -битного кода Грея на четырёхмерном кубе

Таким образом, цикл будет представлять собой подграф в виде кольца, по которому будут направлены пакеты, которые не могут быть обработаны в данный момент времени на текущем маршрутизаторе, пока его не смогут обработать другие маршрутизаторы или пока у него не закончится время жизни (TTL – time to live) [16, 17]. Причем таких подграфов может быть несколько, и каждый представлен разным количеством узлов, поэтому, выбранный путь заявки может отличаться в зависимости от загруженности текущего маршрутизатора, скорости обслуживания, приоритетности пакета и других параметров, которые влияют на обслуживание в сети.

Размещение графа в булевом пространстве

Как известно, сеть представляет собой граф, состоящий из связанных между собой узлов. Однако, он не всегда представлен n-мерным кубом, рассмотренным выше, и для того, чтобы решать задачу с нахождением Гамильтонова цикла и отправлять пакет по кольцевому маршруту, необходимо найти возможные пути для отправки, то есть найти циклы, отразив имеющийся граф в булевом пространстве.

Рассмотрим размещение графа G в булевом пространстве минимальной размерности таким образом, чтобы после удаления лишних рёбер получить остаток в виде булевого графа. Это можно легко сделать с помощью метода квадратов.

Данный метод заключается в том, чтобы, следуя определённому алгоритму, построить последовательность конфигурации квадратов и рёбер, которые в итоге образуют гиперкуб. Будем называть цикл, образованный четырьмя рёбрами, квадратом. Противлежащие рёбра будут соседними.

Рассмотрим граф, представленный на рис. 4. В нём можно выделить квадрат (5,8,7,3), образованный двумя парами соседних рёбер: 5-8, 3-7 и 3-5, 7-8.

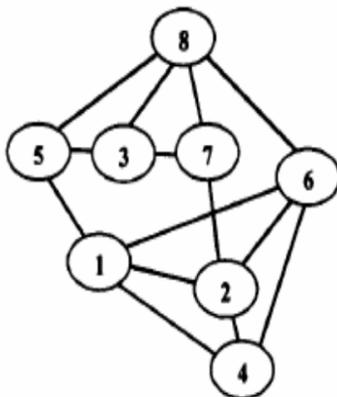


Рис. 4. Пример графа

Алгоритм заключается в том, чтобы, последовательно продвигаясь по графу, строить матричную конфигурацию квадратов, находящихся в отношении стыковки. При этом два квадрата стыкуются, если у них есть ровно одно общее ребро.

Таким образом, найденный первый квадрат (5,8,7,3) представим матричной конфигурацией $\begin{matrix} 5 & 8 \\ 3 & 7 \end{matrix}$.

Ребро 7-8 первого квадрата является соседним ребру 6-2 другого квадрата, который стыкуется с первым через ребро 7-8. Данная пара рёбер 7-8, 6-2 порождает квадрат (7,8,6,2), стыкующийся с предыдущим. Представим полученную пару квадратов матричной конфигурацией $\begin{matrix} 5 & 8 & 6 \\ 3 & 7 & 2 \end{matrix}$.

Далее, для ребра 6-2 находим соседнее: 1-4, образуя третий квадрат (6,2,1,4). Три квадрата представляются матричной конфигурацией $\begin{matrix} 5 & 8 & 6 & 1 \\ 3 & 7 & 2 & 4 \end{matrix}$ размером 2×4 , соответствующей структуре трёхмерного булевого пространства.

Как видно, все вершины графа оказались размещены на соседних элементах матрицы. При этом при составлении матрицы были задействованы не все пары вершин. Недействующие рёбра 1-2, 3-8 и 4-6 отмечены пунктиром на рисунке 5. Остальные рёбра были спроектированы на рёбра трёхмерного куба.

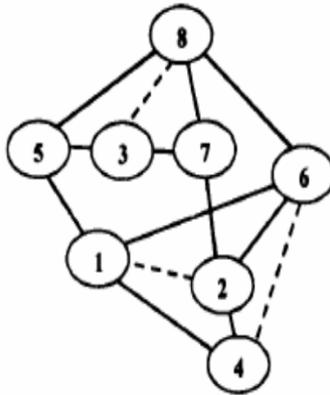


Рис. 5. Выделение булева графа

На последнем этапе остаётся закодировать вершины булевыми векторами размерности 3. Требуется только, чтобы соседним элементам матрицы соответствовали векторы, отличающиеся значением ровно в одной компоненте. Возможный вариант кодирования с использованием кода Грея представлен на рисунке 6.

	1	2	3	4	5	6	7	8
x_1	0	1	1	1	0	0	1	0
x_2	0	1	0	0	0	1	1	1
x_3	1	1	0	1	0	1	0	0

Рис. 6. Вариант кодирования вершин графа

Свойства узлов сети

Перед описанием основных свойств узлов сети необходимо ввести понятие центра обработки, который будет рассмотрен на примере программно-конфигурируемой сети SDN (Software Defined Network). Центр обработки будет представлять собой SDN-контроллер. Централизация управления на SDN-контроллере позволит снизить число операций управления и упростить их. Также, SDN позволяет вводить стандартные протоколы и модели данных, поэтому можно говорить о централизованном управлении в многоуровневой и гетерогенной сети.

Опишем основные свойства узла n_i для дальнейшего формулирования модели:

- d_{ij} : расстояние между узлами n_i и n_j . В силу подвижности узлов в системе Интернета вещей необходимо рассматривать оптимальное расстояние между двумя перемещающимися узлами;
- d_{is} : расстояние между узлом n_i и SDN (центром обработки). В силу подвижности узлов в системе Интернета вещей необходимо учитывать изменяющееся расстояние узла от центра обработки данных и находить оптимальное;
- p_i : приоритет узла n_i . Эта переменная отвечает за время жизни заявки. Чем дальше заявка находится в сети необслуженной, тем меньше становится ее время жизни, и тем приоритетнее она становится. Соответственно, все заявки в сети будут обслуживаться в соответствии со временем их жизни.

Параметры для планирования маршрута

Марковский процесс принятия решений поможет планировать маршруты поступающих в сеть заявок. Для этого необходимо ввести следующие определения:

- пространство состояний: как было рассмотрено ранее, существует определенное пространство состояний системы. Определим множество состояний как S ;
- действие: заключается в том, что необходимо выбрать дальнейший узел, на который будет отправлена необслуженная заявка. При этом узлов для отправки заявки может быть несколько. Поэтому определим набор действий как A , где a_i будет означать, что заявка направляется на узел n_i . Таким образом, выбранное действие будет влиять на весь маршрут заявки;
- приоритетность заявок (пакетов): определяется через время жизни.

Описание алгоритма принятия решения

Для того чтобы оценить результат, когда действие a_j выбрано в состоянии S_i , необходимо ввести функцию дохода $D(s_i, a_j)$, которая будет вычисляться как:

$$D(s_i, a_j) = \omega_1 \rho(s_i, a_j) + \omega_2 G(s_i, a_j) + \omega_3 P(s_i, a_j), \quad (1)$$

где $\rho(s_i, a_j)$ – это, так называемая, награда за то, что был выбран узел с высоким приоритетом, а ω_i – коэффициенты, которые оцениваются и расставляются экспертно, с их помощью можно влиять на параметры и варьировать по необходимости.

В приоритет ставится обработка заявок, у которых время жизни (TTL) ближе к нулю. Считается, что важнее обслужить заявку с меньшим TTL, и за это показатель награды увеличивается. Награда $\rho(s_i, a_j)$ вычисляется следующим образом:

Если $\rho_j(N) < \delta$, тогда $\rho(s_i, a_j) = 0$, иначе

$$\rho(s_i, a_j) = \rho_j - \rho_j(N), \quad (2)$$

где $\rho_j(N)$ – TTL, а δ – заранее определенный порог для TTL, вычисленный, как показано в (3):

$$\delta = \rho_j(D) + \rho_j(S), \quad (3)$$

где сумма складывается из значений времени, которые необходимы для принятия заявки узлом и отправки на следующий узел.

В (1) $G(s_i, a_j)$ – это награда при выборе узла, нахождение которого определяется как ближайшее к SDN. Вычисляется следующим образом:

$$G(s_i, a_j) = \begin{cases} 0, & \text{если } d_{js} > \min(d_{vs}) \\ \theta & \text{иначе,} \end{cases} \quad (4)$$

где d_{js} – расстояние между узлом и SDN, $\min(d_{vs})$ – минимальное расстояние между ожидающими обработки заявок узлами и SDN, а θ – это награда за выбор в качестве следующего шага ближайшего к SDN узла.

Также, функция дохода предусматривает определенную систему штрафов $P(s_i, a_j)$. Например, это может быть штраф за то, что узел n_j прибывает в пограничную точку мониторинга, которая определена как опасная область.

Если $r_s - \beta < d_{js} < r_s$ (где r_s – радиус зоны мониторинга, а β – радиус зоны риска), то штраф вычисляется для a_j и производится выбор другого узла в качестве следующего пункта назначения.

Таким образом, функция дохода, используемая в Марковском процессе принятия решений, позволяет экспертно задать коэффициенты, и, опираясь на приоритетные для каждой сети показатели, выстроить оптимальную стратегию по передвижению заявок в сети.

Функция дохода заявки контролируется по времени их жизни, поэтому, каждый раз поступая на обработку, TTL проверяется. Находясь в состоянии S_3 (маршрутизатор обрабатывает пакет, очередь присутствует), сравниваются значения TTL. Если TTL заявки выше нуля и на данный момент времени существуют другие необслуженные заявки с меньшим значением параметра TTL, то обслуживается заявка с наименьшим временем жизни, иначе она отправляется по существующему циклу для разгрузки системы. После прохождения через активные узлы заявка снова возвращается в очередь для проверки TTL, который с каждым прохождением цикла уменьшается за счёт времени ожидания. Маршрутизатор обновляет данные и обслуживает заявку с меньшим временем жизни. Алгоритм выполняется, пока заявка не будет обслужена или пока не истечет время ее жизни.

Заключение

Таким образом, в рассмотренной модели была предпринята попытка разработать алгоритм обслуживания заявок в системе Интернета вещей с помощью Гамильтонова цикла и Марковского процесса принятия решений.

Смыслом использования Марковского процесса принятия решений является выведение оптимальной стратегии для ожидающей обслуживания заявки.

Нахождение наилучшей последовательности узлов для таких заявок поможет разгрузить сеть и сбалансировать показатели производительности, а Гамильтонов цикл – оптимизировать трафик и управлять очередями в сети.

Литература

1. *Гадасин Д. В., Шведов А. В., Ермалович А. В.* Концепция "туманные вычисления" – эволюционный этап развития инфокоммуникационных технологий // Технологии информационного общества : Сборник трудов XII Международной отраслевой научно-технической конференции, Москва, 14-15 марта 2018 г. М.: Издательский дом Медиа Паблишер, 2018. С. 96-99. EDN XUPRRB
2. *Гадасин Д. В., Шведов А. В., Ермалович А. В.* Концепция "интернет вещей" как вектор развития информационно-коммуникационных технологий на пути к "индустрии 4.0" // Технологии информационного общества : XI Международная отраслевая научно-техническая конференция: сборник трудов, Москва, 15-16 марта 2017 г. М.: Издательский дом Медиа Паблишер, 2017. С. 352-353. EDN RPDYWX
3. *Гадасин Д. В., Пак Е. В.* Применение модели бэкмена для распределения потоков в сетях с сегментной маршрутизацией // REDS: Телекоммуникационные устройства и системы. 2020. Т. 10. № 4. С. 18-23. EDN PCGGHF.
4. *Gadasin D. V., Shvedov A. V., Koltsova A. V.* Cluster model for edge computing // 2020 International Conference on Engineering Management of Communication and Technology, EMCTECH 2020 - Proceedings, Vienna, 20-22 октября 2020 г. Vienna, 2020. P. 9261538. DOI 10.1109/EMCTECH49634.2020.9261538. EDN FGDLS□
5. *Шведов А. В.* Повышение эффективности функционирования корпоративных информационно-коммуникационных сетей с учетом теории ограничения систем // III Научный форум телекоммуникации: теория и технологии ТТТ-2019 : Материалы XXI Международной научно-технической конференции, Казань, 18-22 ноября 2019 г. Казань: Казанский государственный технический университет им. А.Н. Туполева, 2019. С. 290-291. EDN NJLIPU
6. *Гадасин Д.В., Кольцова А.В., Гадасин Д.Д., Полякова А.Н.* Оценка вероятности формирования виртуального кластера // Системы синхронизации, формирования и обработки сигналов. 2021. Т. 12. № 1. С. 4-12.
7. *Гадасин Д.В., Кольцова А.В., Полякова А.Н.* Модель построения кластера для пограничных вычислений // Труды Северо-Кавказского филиала Московского технического университета связи и информатики. 2020. № 1. С. 86-92.
8. *Гадасин Д.В., Нестерова Е.А.* Особенности проведения практических занятий по дисциплине мультимедийные информационные системы для стадии "исследование и обоснование создания информационной системы" // Методические вопросы преподавания инфокоммуникаций в высшей школе. 2021. Т. 10. № 1. С. 15-21.
9. *Shvedov A. V., Gadasin D. V., Alyoshintsev A. V.* Segment routing in data transmission networks // T-Comm. 2022. Vol. 16. No 5. P. 56-62. DOI 10.36724/2072-8735-2022-16-5-56-62. EDN V□YLJQ

10. Вакурин А. В., Цыгулева Д. В., Гадасин А. В., Шведов А. В. Свойство цикличности перехода гетерогенности в гомогенность // Перспективные технологии в средствах передачи информации : материалы 14-ой международной научно-технической конференции, Владимир, 06-07 октября 2021 г. Владимир: Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых, 2021. С. 393-396. EDN MSREEK
11. Гадасин Д. В., Шведов А. В., Алексеева Е. А. Информационная энтропия в стохастических сетях связи // Телекоммуникационные и вычислительные системы 2020 : Труды международной научно-технической конференции, Москва, 14-17 декабря 2020 г. / Московский технический университет связи и информатики. – М.: Горячая линия – Телеком, 2020. С. 108-116. EDN IOGLQH
12. Шведов А. В., Назаров М. Д. Зависимость показателей эффективности функционирования корпоративных сетей связи от показателей качества обслуживания (QoS) // Технологии информационного общества : Сборник трудов XIV Международной отраслевой научно-технической конференции, Москва, 18-19 марта 2020 г. М.: Издательский дом Медиа Паблишер, 2020. С. 302-304. EDN DXPJBJ
13. Shvedov A. V., Gadasin D. V., Alyoshintsev A. V. Segment routing in data transmission networks // T-Comm. 2022. Vol. 16. No 5. P. 56-62. DOI 10.36724/2072-8735-2022-16-5-56-62. EDN V□YLJQ
14. Ракк М.А. О применении технологии MPLS на сетях передачи данных // Бюллетень результатов научных исследований ПГУПС. СПб: Петербургский государственный университет путей сообщения Императора Александра I, 2014. С. 45-60.
15. Шведов А.В., Гадасин Д.В., Цыгулёва А.В., Вакурин И.С. Разгрузка очереди сети при помощи Гамильтонова цикла // REDS: Телекоммуникационные устройства и системы. 2021. Т. 11. № 3. С. 45-53. EDN XWXWQX
16. Свами М., Тхуласираман К. Графы, сети и алгоритмы. М.: Мир, 1984. С. 55.
17. Гадасин Д. В., Шведов А. В., Ермалович А. В. "Туманные вычисления" - эволюционный этап развития инфокоммуникационных технологий // Телекоммуникационные и вычислительные системы - 2017 : Труды международной научно-технической конференции, Москва, 22 ноября 2017 г. М.: Горячая линия – Телеком, 2017. С. 249-251. EDN YMPWHL
18. Шведов А. В., Гадасин Д. В., Клыгина О. Г. Организация взаимодействия туманных вычислений и сегментной маршрутизации для предоставления сервисов IOT в smart grid // Системы синхронизации, формирования и обработки сигналов. 2022. Т. 13. № 3. С. 40-49. EDN TRRYZN
19. Гашиков С.Б. Системы счисления и их применение // 2-е изд., испр. и доп. М.: изд-во МЦНМО, 2012. 68 с.
20. Гадасин Д. В., Шведов А. В., Усачева Д. И. Механизмы обеспечения безопасности маршрутизации в сети интернет // III Научный форум телекоммуникации: теория и технологии ТТТ-2019 : Материалы XXI Международной научно-технической конференции, Казань, 18-22 ноября 2019 г. Казань: Казанский государственный технический университет им. А.Н. Туполева, 2019. С. 292-293. EDN OS□FRG
21. Гадасин Д. В., Веденеев П. С., Шведов А. В. Уязвимости системы маршрутизации глобальной сети интернет и возможные пути их преодоления // Перспективные технологии в средствах передачи информации - ПТСПИ-2019 : Материалы XIII международной научно-технической конференции. В 2-х томах, Владимир, 03-05 июля 2019 года / Редколлегия: А.Г. Самойлов [и др.]. Владимир: Владимирский государственный университет имени Александра Григорьевича и Николая Григорьевича Столетовых, 2019. С. 94-96. EDN YFEI□H.
22. Алешинцев, А. В., Сак А. Н. Синтаксический анализ предложения с помощью функции tree в среде Matlab // Методические вопросы преподавания инфокоммуникаций в высшей школе. 2020. Т. 9. № 4. С. 43-45. EDN QTQRUT
23. Докучаев В. А., Кальфа А. А., Мытенков С. С., Шведов А. В. Анализ технических решений по организации современных центров обработки данных // T-Comm: Телекоммуникации и транспорт. 2017. Т. 11. № 6. С. 16-24. EDN Z□OKJB
24. Kalmykov N.S., Dokuchaev V.A. Segment routing as a basis for software defined network // T-Comm. 2021. Т. 15. № 7. С. 50-54.
25. Dokuchaev V.A., Maklachkova V.V., Statev V.Yu. Classification of personal data security threats in information systems // T-Comm. 2020. Т. 14. № 1. С. 56-60.
26. Докучаев В.А., Маклачкова В.В., Статьев В.Ю. Цифровизация субъекта персональных данных // T-Comm: Телекоммуникации и транспорт. 2020. Т. 14. № 6. С. 27-32.
27. Pavlov S.V., Dokuchaev V.A., Mytenkov S.S. Model of a fuzzy dynamic decision support system // T-Comm. 2020. Т. 14. № 9. С. 43-47.
28. Pavlov S.V., Dokuchaev V.A., Maklachkova V.V., Mytenkov S.S. Features of supporting decision making in modern enterprise infocommunication systems // T-Comm. 2019. Т. 13. № 3. С. 71-74.