

УДК 004.89

DOI: 10.31673/2412-9070.2021.023439

Г. О. ГРИНКЕВИЧ, канд. техн. наук, доцент,
Державний університет телекомунікацій, Київ

МЕТОД БЕЗМОДЕЛЬНОЇ ОНЛАЙН-ОПТИМІЗАЦІЇ ЧАСУ ОБЧИСЛЕНЬ КІНЦЕВИХ ІОТ-ПРИСТРОЇВ ІЗ ЗАБЕЗПЕЧЕННЯМ КРИТИЧНО ВАЖЛИВИХ ЗАТРИМОК УСІХ РІВНІВ ВЗАЄМОДІЇ

Розглянуто проблему керування мережними ресурсами з погляду опуклої онлайн-оптимізації (ОоО) з урахуванням як втрат, так і обмежень. Надано загальне формулювання ОоО з довгостроковими обмеженнями в часі і відповідні показники для оцінювання алгоритму ОоО. У підґрунті вирішення проблеми оптимізації використано елементи глибокого машинного навчання.

Досліджено ОоО з різними в часі обмеженнями, які мають бути задоволені в довгостроковій перспективі. Згідно з цим параметром той, хто навчається, спочатку виконує певну дію, не знаючи апріорі ні суперечливих втрат, ані змінних у часі обмежень, які виявляються згодом природно. Також було узагальнено стандартну структуру ОоО, беручи до уваги втрати, щоб врахувати як конкурентні втрати, так і обмеження. На противагу наявним роботам основну увагу приділено налаштуванню, в якому деякі обмеження виявляються після вжиття заходів — вони допустимі для миттєвих порушень, але в середньому мають задовольнятися.

Далі впроваджується модифікований метод динамічної оптимізації мережних ресурсів (ДОМР) в інтелектуальних мережах у цій новій структурі ОоО, де елемент навчання має справу з різними в часі втратами, а також різними в часі, але довгостроковими обмеженнями. У цілому доведено, що метод ДОМР забезпечує сублінійне зростання динамічних втрат і результативності, якщо при цьому нагромаджені варіації мінімізаторів та обмежень, відомих як сублінійні, зростають.

Докладно описано процес розроблення і характеристики розробленого алгоритму ДОМР.

Ключові слова: Інтернет речей; якість обслуговування; опукла онлайн-оптимізація; штучний інтелект; глибоке машинне навчання; інтелектуальні мережі.

ВСТУП

У статті розглядається проблема керування мережними ресурсами з погляду опуклої онлайн-оптимізації (ОоО) з урахуванням як втрат, так і обмежень. На відміну від наявних робіт основну увагу приділено налаштуванню, в якому деякі обмеження виявляються після вжиття заходів. Вони допустимі для миттєвих порушень, але зазвичай мають задовольнятися. Опукла онлайн-оптимізація — це методологія послідовного судження з добре задокументованими достоїнствами, особливо коли послідовність опуклих функцій втрат змінюється в невідомий спосіб [1; 2].

У цьому контексті досліджується ОоО з різними в часі обмеженнями, які мають бути задоволені в довгостроковій перспективі. Згідно з цим параметром той, хто навчається, спочатку виконує певну дію, не знаючи апріорі ні суперечливих втрат, ані змінних у часі обмежень, які виявляються згодом природно. При цьому ефективність діяльності оцінюється за такими параметрами:

- динамічними втратами, тобто втратою оптимальності щодо послідовності миттєвих мінімізаторів із відомими втратами та обмеженнями;
- динамічною відповідністю, яка нагромаджує порушення обмежень, спричинені онлайн-користувачем через відсутність знань про майбутні обмеження.

Далі впроваджується модифікований метод динамічної оптимізації мережних ресурсів (ДОМР) в інтелектуальних мережах у цій новій структурі ОоО, де елемент навчання має справу з різними в часі втратами, а також різними в часі, але довгостроковими обмеженнями. Аналітично встановлено, що ДОМР одночасно досягає сублінійних динамічних втрат і пристосування за умови, що нагромаджені варіації як мінімізаторів, так і обмежень зростають сублінійно з часом. Цей результат дає цінну інформацію для ОоО з довгостроковими обмеженнями: коли динамічне середовище, що включає в себе як втрати, так і обмеження, не змінюється в середньому, і порядок варіацій відомий, рішення в Інтернеті, надані ДОМР, є такими ж хорошими, як найкраще динамічне рішення протягом тривалого періоду часу.

Щоб продемонструвати вплив цих результатів, далі застосовується запропонований підхід ДОМР до завдання динамічного розподілу мережних ресурсів, де відшукується мережне керування ресурсами, не знаючи майбутніх станів мережі.

Для фіксації часових варіацій мережних ресурсів широко проводилося стохастичне формулювання розподілу мережних ресурсів [3], а також застосовувався відомий стохастичний метод подвійного

градієнта [4]. Ці підходи, ґрунтуючись на стохастичному наближенні, передбачають, що змінні в часі втрати — це взагалі зразки стаціонарного ергодичного стохастичного процесу [5]. Однак ефективність більшості стохастичних схем встановлюється в асимптотичному сенсі, беручи до уваги ансамбль середніх показників на один слот або нескінченних зразків у часі. Вочевидь, що стаціонарність може не виконуватися на практиці, особливо коли стохастичний процес передбачає участь людини. Успадковуючи достоїнства ОоО, запропонований підхід ДОМР працює в повністю онлайн-режимі лише з інформацією за попередні часові інтервали і додатково допускає аналіз результатів із кінцевою вибіркою за послідовністю детермінованих або навіть змагальних втрат та обмежень у рамках часового бюджету.

Порівняно з наявними роботами, основні здобуті внески можна узагальнити в такий спосіб:

- ♦ розроблено метод динамічної оптимізації мережних ресурсів (ДОМР) в інтелектуальних мережах для вирішення цієї нової проблеми ОоО і аналітично встановлено, що ДОМР одночасно дає сублінійні динамічні втрати та пристосування за умови, що нагромаджені варіації мінімізаторів та обмежень за слотом зростають сублінійно з часом;

- ♦ запроновано новий підхід, розроблений для завдань розподілу ресурсів в Інтернеті, де ДОМР порівнюється з популярним стохастичним підходом подвійного градієнта. Щодо останнього, ДОМР продовжує працювати в більш широкому практичному середовищі без імовірнісних припущень. Чисельні тести демонструють переваги ДОМР порівняно з наявними альтернативами.

У цій статті подано загальне формулювання ОоО з довгостроковими обмеженнями в часі, а також відповідні показники для оцінювання алгоритму ОоО.

Мета статті — розроблення модифікованого методу динамічної оптимізації мережних ресурсів (ДОМР) в інтелектуальних мережах.

ОСНОВНА ЧАСТИНА

Аналіз налаштування ОоО

Усе починається з класичного налаштування ОоО, де обмеження є інваріантними щодо часу і мають строго виконуватися. ОоО можна розглядати як повторну гру між учнем та природою [1]. Уважається, що час дискретний і індексується u . За слот u елемент навчання вибирає дію x_u з опуклої множини $X \subseteq S_j$, а згодом природа вибирає функцію втрат $g_u(\cdot): S_j \rightarrow S$, через яку елемент навчання зазнає втрати $g_u(x_u)$. Опукла множина X апіорі відома і фіксована протягом усього часового проміжку. Хоча цей стандартний параметр ОоО є привабливим для різних застосувань, таких як онлайн-регресія та класифікація [2], він не враховує потенційні зміни (можливо зараз невідомих) обмежень і не має справу з обмеженнями, які можуть бути задоволені в довгостроковій, а не на окремій основі. Інтернет-оптимізація з різними в часі та довгостроковими обмеженнями мотивована для таких додатків, як навігація, відстеження, локалізація та розподіл ресурсів [6]. Беручи як приклад розподіл ресурсів, довгострокові обмеження, що змінюються в часі, зазвичай накладаються на миттєві порушення, коли доступні ресурси не можуть задовольнити запити користувачів, а отже, залучення можливостей ОоО дають змогу отримувати гнучку адаптацію рішень в Інтернеті до часових варіацій доступності ресурсів.

Щоб розширити застосовність ОоО до цих сценаріїв, вважається, що для слота u елемент навчання вибирає дію x_u з відомого та фіксованого опуклого набору $X \subseteq S_j$, і тоді природа виявляє не лише функцію втрат $g_u(\cdot): S_j \rightarrow S$, а також змінну в часі (можливо, змагальну) функцію штрафу $h_u(\cdot): S_j \rightarrow S_j$. Ця функція призводить до часового обмеження $h_u(x) \leq 0$, яке зумовлене невідомою динамікою в різних додатках, наприклад надходження запитів даних на вимогу під час розподілу ресурсів. На відміну від відомого та фіксованого множини X змінне в часі обмеження $h_u(x) \leq 0$ може змінюватися довільно або навіть змагально від слота до слота. Це виявляється після того, як елемент навчання приймає своє рішення, і тому важко бути задоволеним у кожному часовому інтервалі. Це справді велика різниця порівняно з установками, де обмежуються часом обмеження, що виявляються перед прийняттям рішень. Отже, метою у цьому контексті є пошук послідовності мережних рішень $x_u \in X$, які мінімізують сукупні втрати та гарантують, що обмеження $h_u(x_u) \leq 0$ виконуються в середньому в довгостроковій перспективі. Зокрема, реалізується прагнення вирішити таку проблему оптимізації в Інтернеті:

$$\min_{\{x_t \in \Omega, \forall t\}} \sum_{u=1}^U f_u(x_u); \quad (1a)$$

$$\sum_{u=1}^U h_u(x_u) \leq 0, \quad (1b)$$

де U — часовий проміжок; $x_u \in S_j$ — змінна рішення; f_u — функція втрат; $h_u = (h_1, \dots, h_j)$ позначає функцію обмеження з i -м записом $h_j: S_j \rightarrow S$, а $X \in S_j$. Формулювання (1) розширює стандартну струк-

туру ОоО, щоб врахувати різноманітні часові обмеження, які мають бути задоволені в довгостроковій перспективі.

Показники ефективності та результативності

Що стосується ефективності рішень в Інтернеті (x_u) U , то статичні втрати взято як метрика за стандартом.

Статичні втрати вимірюють різницю між втратою алгоритму ОоО в Інтернеті та найкращим фіксованим рішенням [2]. Розширюючи визначення статичної втрати над U -слотами, щоб урахувати різні часові обмеження, це можна записати так:

$$Reg_U^t := \sum_{u=1}^U f_u(x_u) - \sum_{u=1}^U f_u(x_u^*), \tag{2}$$

де найкраще статичне рішення x^* можна здобути з виразу

$$x^* \in \operatorname{arg\,min}_{x \in \omega} \sum_{u=1}^U f_u(x) \quad s.t \quad h_u(x) \leq 0, \forall u. \tag{3}$$

Бажаним ОоО-алгоритмом у цьому разі є той, що дає підлінійні втрати, значення $Reg_{su} = O(U)$. Отже, $\lim_{U \rightarrow \infty} Reg_{su}/U = 0$ означає, що алгоритм увімкнено середнє «не шкодує», або іншими словами, не гірше асимптотичного, ніж найкраще фіксоване рішення x^* .

Незважаючи на те, що зазначені статичні втрати широко використовуються в різних програмах ОоО, проте мають кілька обмежень. Наприклад, алгоритм не може зафіксувати збіжність рішень x_u в Інтернеті щодо виправленого найкращим рішенням x^* , оскільки невеликих втрат також можна досягти, коли $g_u(x_u)$ коливається навколо $g_u(x^*)$ [2].

Навіть коли сублінійна статична втрата означає, що x_u наближається до x^* , націлювання на досить грубий орієнтир може бути менш корисним, особливо в динамічних пристосуваннях. Крім того, оскільки варіаційне обмеження часу $h_u(x_u) \leq 0$ не дотримується до прийняття рішення x_u , його результативність не можна перевірити миттєво.

У відповідь на пошуки вдосконалених тестів у цій динамічній установці розглядаються дві метрики: динамічні втрати та динамічна відповідність. Поняття динамічних втрат (яке також називають відстеженням або адаптивними витратами) було нещодавно введено в [7], щоб запропонувати показник конкурентоспроможності алгоритмів ОоО за часових обмежень. Останнє приймається в обстановці (1) через включення змінних у часі обмежень

$$Reg_U^e := \sum_{u=1}^U f_u(x_u) - \sum_{u=1}^U f_u(x_u^*), \tag{4}$$

де еталон тепер формується через послідовність найкращих динамічних рішень x_u^* для миттєвої задачі мінімізації втрат, яка підлягає миттєвим обмеженням, а саме:

$$x_u^* \in \operatorname{arg\,min}_{x \in \omega} f_u(x) \quad s.t \quad h_u(x) \leq 0, \tag{5}$$

де контрольний показник тепер формується через послідовність найкращих динамічних рішень x_u^* для миттєвої задачі мінімізації втрат. Очевидно, динамічні втрати завжди більші, ніж статичні у (2), тобто $Reg_U \leq Rege_U$, оскільки $QU g_u(x^*)$ завжди не менше за $QU g_u(x_u^*)$ згідно з визначеннями x^* і x_u^* . Отже, підлінійні динамічні втрати означає сублінійні статичні втрати, але не навпаки.

Динамічні втрати підходять для випадків, коли метою є відстеження змін, що змінюються в часі, наприклад потік змінного струму та політика керування енергією.

Для забезпечення результативності прийняття рішень в Інтернеті введено поняття динамічної придатності для вимірювання нагромадженого порушення обмежень; за незмінними в часі довгостроковими обмеженнями або за варіюючими за часом обмеженнями. Це визначається як миттєве обмеження, а саме:

$$Fit_U^e := \left\| \left[\sum_{u=1}^U h_u(x_u) \right]^+ \right\|. \tag{6}$$

Є сенс брати до уваги, що динамічна відповідність дорівнює нулю, якщо нагромаджене порушення $QU h_u(x_u)$ є вхідним менше нуля. Однак застосування $QU h_u(x_u) \leq 0$ відрізняється від обмеження x_u для задоволення $h_u(x_u) \leq 0$ у кожному слоті. Довгострокове (сукупне) обмеження дозволяє адаптувати рішення в Інтернеті до динаміки середовища; як результат, допустимо мати $h_u(x_u) \geq 0$ і $h_{u+1}(x_{u+1}) \leq 0$. При цьому визначення динамічного припасування в (6) неявно передбачає, що миттєві порушення обмежень можуть бути компенсовані пізніше за допомогою строго здійснених рішень. Коли це стосується

розподілу ресурсів в енергетичних та хмарних мережах, потрібні додаткові модифікації, щоб врахувати інші типи обмежень, які виходять за рамки даного обговорення.

Ідеальним алгоритмом у цій ширшій системі ОоО є той, який забезпечує як сублінійні динамічні втрати, так і сублінійне динамічне пристосування. Підлінійні динамічні втрати означають «відсутність втрат» щодо очевидного динамічного рішення в довгостроковому середньому; тобто $\lim U \rightarrow \infty \text{Rege}/U = 0$; а підлінійна динамічна відповідність вказує на те, що онлайн-стратегія також в середньому здійснена; тобто $\lim U \rightarrow \infty \text{Fitd}/U = 0$. Але сублінійні динамічні втрати недосяжні загалом, навіть за особливим випадком (1), коли змінне в часі обмеження відсутнє [7]. З цієї причини бажано розробити та проаналізувати онлайн-стратегію, яка генерує послідовність (x_i) T , що забезпечує сублінійні динамічні втрати та відповідність, за помірних умов, які мають бути задоволені варіаціями вартості та обмежень.

Далі для розв'язання (1) розроблено модифікований онлайн-метод мережі, а його ефективність та результативність проаналізовано за допомогою метрик динамічних витрат та відповідності.

Розроблення алгоритму

Розглядається тепер проблема на слот (5), яка містить поточну мету $g_u(x)$, поточні обмеження $g_u(x) \leq 0$, а також інваріантне щодо часу обмеження X з $\mu \in S_j$, що позначає множник Лагранжа, пов'язаний з часом, що змінюється. При цьому онлайн-лагранжіан (частковий) (5) можна подати виразом

$$F_u(x, \mu) := g_u(x) + \mu^{T^*} h_u(x), \quad (7)$$

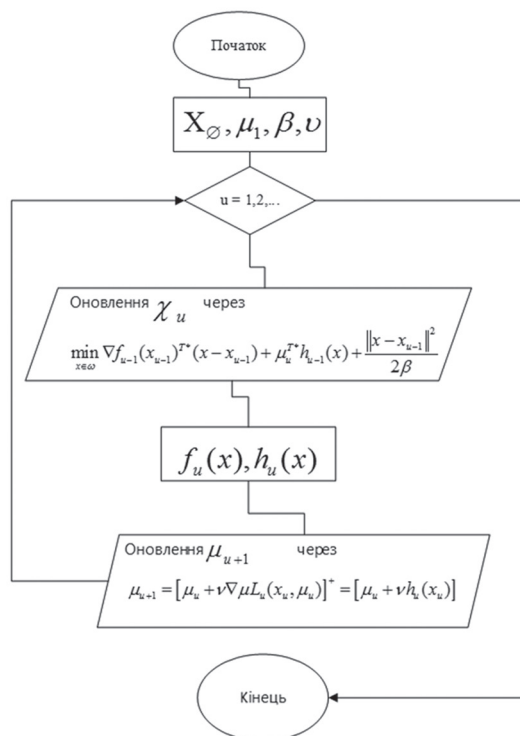
де $x \in X$ залишається неявним. Для онлайн-лагранжіана (7) вводиться модифікований підхід до онлайн-точки (ДОМР), який виконує змінений крок спуску в первинному домені та подвійний крок підйому в кожному часовому інтервалі u в режимі Гаусса-Зайделя. Зокрема, зважаючи на попередній первинний ітератор x_{u-1} і поточний подвійний ітератор μ_u у кожному слоті u , поточне рішення x_u є мінімізатором наступної задачі оптимізації

$$\min_{x \in \Omega} \nabla f_{u-1}(x_{u-1})^{T^*} (x - x_{u-1}) + \mu_u^{T^*} h_{u-1}(x) + \frac{\|x - x_{u-1}\|^2}{2\beta}, \quad (8)$$

де β — позитивний розмір кроку; $\nabla g_{u-1}(x_{u-1})$ — градієнт 1 первинної мети $g_{u-1}(x)$ при $x = x_{u-1}$. Після прийняття поточного рішення x_u спостерігаються $g_u(x)$ та $h_u(x)$, і подвійне оновлення набирає вигляду

$$\mu_{u+1} = [\mu_u + v \nabla \mu L_u(x_u, \mu_u)]^+ = [\mu_u + v h_u(x_u)], \quad (9)$$

де v — також позитивний розмір кроку, а $\nabla \mu F_u(x_u, \mu_u) = g_u(x_u)$ — градієнт онлайн-лагранжіана (7) щодо w.r.t. μ при $\mu = \mu_u$. Очевидно, що для оновлення μ_u і x_u у слоті u потрібна лише інформація про вагу та обмеження в попередньому слоті (рисунок).



Алгоритм ДОМР

Крок первинного градієнта класичного підходу до сідлової точки в [8] рівнозначний мінімізації наближення $F_{u-1}(x, \mu_u)$ першого порядку при $x = x_{u-1}$ плюс проксимальний доданок. Це дістало назву рекурсії (8) і (9) модифікованим підходом до точки сідла, оскільки основне оновлення (8) не є точним кроком градієнта, коли обмеження $h_u(x)$ нелінійне w.r.t. x . Подібно до первинного оновлення ОоО з довгостроковими, але інваріантними до часу обмеженнями, мінімізація в (8) карає точне порушення обмеження $g_u(x)$ замість наближення першого порядку, що покращує контроль за порушеннями обмежень та полегшує аналіз ефективності ДОМР. Проте, коли $g_u(x)$ є лінійним, (8) та (9) зводяться до підходу в режимі онлайн-сідла, використовуючи оновлення Гаусса-Зейделя, яке відрізняється від тих, що застосовуються до методу Якобі [8].

Якщо $h_u(x)$ лінійний або квадратний, то обчислювальна складність (8) є досить низькою, і доступні рішення замкненої форми. Коли $h_u(x)$, як правило, опукла функція, втрати за точне обмеження в (8) має вищу обчислювальну складність, ніж метод сідлової точки. Однак, оскільки (8) сильно опукла, ітеративні розв'язувачі можуть знайти мінімізатор при лінійній швидкості збіжності. Також можуть бути застосовані методи лінеаризації для полегшення її реалізації за швидкої динаміки. У цьому разі точність залежить від плавності $h_u(x)$ та мінливості x_u (що може контролюватися, наприклад, вибором кроку b).

ВИСНОВКИ

У статті розглянуто ОоО з різними в часі обмеженнями, які мають бути задоволені в довгостроковій перспективі. Згідно з цим параметром той, хто навчається, спочатку виконує певну дію, не знаючи апріорі ні суперечливих втрат, ані змінних у часі обмежень, які виявляються згодом природно. Описуючи загальне формулювання ОоО з довгостроковими обмеженнями в часі, а також відповідні показники для оцінювання алгоритму ОоО, запропоновано метод ДОМР, за якого динамічні втрати і забезпечення результативності зростають сублінійно, якщо при цьому нагромаджені варіації мінімізаторів та обмежень, відомих як сублінійні, зростають.

Список використаної літератури

1. **Методы оптимизации в машинном обучении: курс лекций. 2021** [Електронний ресурс]. URL: <http://www.machinelearning.ru/wiki/index.php?title=Мото/> (дата звернення: 11.02.2021).
2. **Online Convex Optimization** [Електронний ресурс]. URL: https://www.cs.ubc.ca/labs/lci/mlrg/slides/online_optimization.pdf/ (дата звернення: 21.01.2021).
3. **Степенко І. В. Моделювання систем** [Електронний ресурс]. URL: http://web.kpi.kharkov.ua/auts/wp-content/uploads/sites/67/2017/02/MOCS_Kachanov_posobie.pdf/ (дата звернення: 25.02.2021).
4. **Вітлінський В. В., Терещенко Т. О., Савіна С. С. Економіко-математичні методи та моделі оптимізації: навч. посібник. Київ: КНЕУ, 2016. 303 с.**
5. **CORE The world's largest collection of open access research papers** [Електронний ресурс]. URL: <https://core.ac.uk/download/pdf/14053513.pdf/> (дата звернення: 15.02.2021).
6. **Йоханн ван Тондер. Оптимізація інтернет-магазину: Чому 95% посетителів вашого сайту нічого не купують і як це виправити** [Електронний ресурс]. URL: <https://epicentrk.ua/shop/kniga-yokhann-van-tonder-optimizatsiya-internet-magazina-pochemu-95-posetiteley-vashego-sayta-nichego-ne-rokuyayut-i-kak-eto-ispr-978-5-9614-7131-1.html/> (дата звернення: 16.02.2021).
7. **Besbes O., Gur Y., Zeevi A. Non-stationary stochastic optimization // Operations Research. Sep. 2015. Vol. 63, no. 5. P. 1227–1244.**
8. **Mahdavi M., Jin R., Yang T. Trading regret for efficiency: Online convex optimization with long term constraints // Journal of Machine Learning Research. Sep. 2012. Vol. 13. P. 2503–2528.**

А. А. Гринкевич

МЕТОД БЕЗМОДЕЛЬНОЙ ОНЛАЙН-ОПТИМИЗАЦИИ ВРЕМЕНИ ВЫЧИСЛЕНИЙ КОНЕЧНЫХ IoT-УСТРОЙСТВ С ОБЕСПЕЧЕНИЕМ КРИТИЧЕСКИ ВАЖНЫХ ЗАДЕРЖЕК ВСЕХ УРОВНЕЙ ВЗАИМОДЕЙСТВИЯ

Рассмотрена проблема управления сетевыми ресурсами с точки зрения выпуклой онлайн-оптимизации (VoO) с учетом как потерь, так и ограничений. Предоставлена общая формулировка VoO с долгосрочными ограничениями во времени и соответствующие показатели для оценки алгоритма VoO. В основе решения проблемы оптимизации использованы элементы глубокого машинного обучения.

Исследована ВоО с различными во времени ограничениями, которые должны быть удовлетворены в долгосрочной перспективе. Согласно этому параметру обучающийся сначала выполняет определенное действие, не зная априори ни противоречивых потерь, ни переменных во времени ограничений, которые оказываются впоследствии естественно. Также была обобщена стандартная структура ВоО с учетом потерь, чтобы учесть как конкурентные потери, так и ограничения. В отличие от существующих работ, основное внимание уделяется настройке, в которой некоторые ограничения оказываются после принятия мер, они допустимы для мгновенных нарушений, но в среднем должны удовлетворяться.

Далее внедряется модифицированный метод динамической оптимизации сетевых ресурсов (ДОСР) в интеллектуальных сетях в этой новой структуре ВоО, где элемент обучения имеет дело с различными во времени потерями, а также различными во времени, но долгосрочными ограничениями. В целом доказано, что метод ДОСР гарантирует сублинейный рост динамических потерь и результативности, если при этом накопленные вариации минимизаторов и ограничений, известных как сублинейные, растут.

Подробно описывается процесс разработки и характеристики разработанного алгоритма ДОСР.

Ключевые слова: Интернет вещей; качество обслуживания; выпуклая онлайн-оптимизация; искусственный интеллект; глубокое машинное обучение; интеллектуальные сети.

G. Grynkevych

METHOD OF MODELLESS ONLINE OPTIMIZATION OF TIME CALCULATION OF FINITE IoT DEVICES WITH PROVISION OF CRITICALLY IMPORTANT DELAYS FOR ALL LEVELS OF INTERACTION

The problem of managing network resources considered in terms of convex online optimization (COO) based both losses and limitations. A general wording of the COO with long-term time constraints and relevant indicators for evaluating the COO algorithm are also provided. The solution to the optimization problem is based on elements of deep machine learning.

This considers the COO with different time constraints that must be met in the long run. According to this parameter, the learner first performs a certain action, not knowing a priori neither contradictory losses nor time-varying constraints, which later appear naturally. Also, the standard loss-based COO structure was generalized to take into account both competitive losses and constraints. Unlike existing work, the focus is on a setting in which some limitations are detected after action is taken, they are acceptable for instantaneous violations, but on average must be met.

Next, a modified method of dynamic optimization of network resources in intelligent networks (DONR) is introduced in this new COO structure, where the learning element deals with different time losses, as well as different time but long-term constraints. In general, it is proved that the DONR method ensures that dynamic losses and pre-results increase sublinearly, if the accumulated variations of minimizers and constraints known as sublinear increase.

The process of development and characteristics of the developed DONR algorithm are described in detail.

Keywords: Internet of Things; quality of service; convex online optimization; artificial intelligence; deep machine learning; intelligent networks.

