

ҚАЗАҚСТАН РЕСПУБЛИКАСЫ ҒЫЛЫМ ЖӘНЕ ЖОҒАРЫ БІЛІМ МИНИСТРЛІГІ

«Л.Н. ГУМИЛЕВ АТЫНДАҒЫ ЕУРАЗИЯ ҰЛТТЫҚ УНИВЕРСИТЕТІ» КЕАҚ

**Студенттер мен жас ғалымдардың
«GYLYM JÁNE BILIM - 2023»
XVIII Халықаралық ғылыми конференциясының
БАЯНДАМАЛАР ЖИНАҒЫ**

**СБОРНИК МАТЕРИАЛОВ
XVIII Международной научной конференции
студентов и молодых ученых
«GYLYM JÁNE BILIM - 2023»**

**PROCEEDINGS
of the XVIII International Scientific Conference
for students and young scholars
«GYLYM JÁNE BILIM - 2023»**

**2023
Астана**

УДК 001+37
ББК 72+74
G99

**«GYLYM JÁNE BILIM – 2023» студенттер мен жас ғалымдардың
XVIII Халықаралық ғылыми конференциясы = XVIII
Международная научная конференция студентов и молодых
ученых «GYLYM JÁNE BILIM – 2023» = The XVIII International
Scientific Conference for students and young scholars «GYLYM JÁNE
BILIM – 2023». – Астана: – 6865 б. - қазақша, орысша, ағылшынша.**

ISBN 978-601-337-871-8

Жинаққа студенттердің, магистранттардың, докторанттардың және жас ғалымдардың жаратылыстану-техникалық және гуманитарлық ғылымдардың өзекті мәселелері бойынша баяндамалары енгізілген.

The proceedings are the papers of students, undergraduates, doctoral students and young researchers on topical issues of natural and technical sciences and humanities.

В сборник вошли доклады студентов, магистрантов, докторантов и молодых ученых по актуальным вопросам естественно-технических и гуманитарных наук.

УДК 001+37
ББК 72+74

ISBN 978-601-337-871-8

**©Л.Н. Гумилев атындағы Еуразия
ұлттық университеті, 2023**

Ряды в (6) сходятся абсолютно и равномерно, причем

$$|A_2(x)| \leq C \sum_{n=0}^{\infty} |\rho_n - \tilde{\rho}_n|$$

Ряды в (5) сходятся в $L_2(0, 2\pi)$ и $\|A_1(x)\|_{L_2(0, 2\pi)} \leq C\Omega$. Используя эти оценки, получаем утверждения леммы.

Восстановление дифференциального оператора по спектральным данным. Рассмотрим краевую задачу $L = L(q(x), h, H)$. Пусть $\{\lambda_n, \alpha_n\}_{n \geq 0}$ – спектральные данные L , $\rho_n = \sqrt{\lambda_n}$. Будем решать обратную задачу восстановления L по заданным спектральным данным $\{\lambda_n, \alpha_n\}_{n \geq 0}$. Было показано, что спектральные данные обладают следующими свойствами:

$$\rho_n = n + \frac{\omega}{\pi n} + \frac{\kappa_n}{n}, \quad \alpha_n = \frac{\pi}{2} + \frac{\kappa_{n1}}{n}, \quad \{\kappa_n\}, \{\kappa_{n1}\} \in l_2$$

$$\alpha_n > 0, \lambda_n \neq \lambda_m \quad (n \neq m)$$

Более точно:

$$\kappa_n = \frac{1}{2\pi} \int_0^{\pi} q(t) \cos 2nt \, dt + o\left(\frac{1}{n}\right)$$

$$\kappa_{n1} = -\frac{1}{2} \int_0^{\pi} (\pi - t)q(t) \sin 2nt \, dt + o\left(\frac{1}{n}\right)$$

т.е. главные части зависят линейно от потенциала.

Рассмотрим функцию

$$F(x, t) = \sum_{n=0}^{\infty} \left(\frac{\cos \rho_n x \cos \rho_n t}{\alpha_n} - \frac{\cos nx \cos nt}{\alpha_n^0} \right)$$

где $\alpha_n^0 = \pi/2$ при $n > 0$ и $\alpha_n^0 = \pi$ при $n = 0$.

Список использованных источников

1. Юрко В. А. Введение в теорию обратных спектральных задач. – М.: ФИЗМАТЛИТ, 2007, 384 с.
2. Левитан Б.М. Введение в спектральную теорию. – М.: Наука, 1970.

ӘОЖ 004.93

БЕЙНЕЛЕРДІ ТАҢУ ЖҮЙЕСІН ҚҰРУ ҮШІН НЕЙРО ЖЕЛІНІҢ ҚОЛДАНЫЛУЫ

Наурызханов Ербота Мырзағалиұлы

erbota999@mail.ru

7М06112 «Жасанды интеллект технологиялары» мамандығының 2-ші курс магистранты,
«Л.Н.Гумилев ат. ЕҰУ» КЕАҚ, Астана, Қазақстан

Ғылыми жетекшісі: Шәріпбай Алтынбек Әмірбекұлы, т.ғ.д., профессор

Кілттік сөздер: нейронные сети, обучение с помощью нейронных сетей, распознавание изображений, парадигма локального восприятия.

Бейнелерді тану мәселесі күрделі және ерекше процесс. Тануды орындау кезінде объект адам тұлғасы, қолжазба цифры, сондай-ақ сәйкестендіру процесін айтарлықтай қиындататын бірқатар бірегей белгілермен сипатталатын көптеген басқа объектілер болуы мүмкін.

Бұл мақалада нейрондық желінің қолжазба таңбаларын тануды үйрену және құру алгоритмін қарастырылады. Кескінді нейрондық желінің кірістерінің бірі оқиды, ал шығыстардың бірі нәтижені көрсету үшін пайдаланылады.

Нейрондық желілердің классификациялары [1]:

- конвульсиялық нейрондық желілер (CNN);
- рекурентті желілер (deep learning);
- қосымша оқытуды.

Нейрондық желіні құрудың көп тараған мысалдарының бірі – классикалық нейрондық желі топологиясы. Мұндай нейрондық желіні толығымен қосылған граф ретінде көрсетуге болады, оның сипатты ерекшелігі ақпараттың алға таралуы және қате сигналының кері таралуы болып табылады. Бұл технологияның рекурсивті қасиеттері жоқ.

Бұл желілік топологияның анық маңызды кемшіліктерінің бірі – артықшылық. Артықшылыққа байланысты деректер, мысалы, екі өлшемді матрица түрінде берілгенде, кірісте бір өлшемді векторды алынуы мүмкін. Сонымен, 34x34 матрицасы арқылы сипатталған қолжазба латын әрпінің кескіні үшін 1156 кіріс қажет. Бұл осы алгоритмнің бағдарламалық-аппараттық шешімін жүзеге асыруға жұмсалатын есептеу қуаты тым үлкен болатынын көрсетеді.

Мәселені американдық ғалым Я.Л. Кун медицина саласындағы Нобель сыйлығының лауреаттары Т.Втесель мен Д.Гюбельдің еңбектеріне талдау жасап шешті [1, 2, 3]. Олар жүргізген зерттеу аясында зерттеу нысаны мысықтың миының қыртысы болды. Нәтижелерді талдау ми қыртысында қарапайым жасушалар қатары да, күрделі жасушалар да қатары бар екенін көрсетті. Қарапайым жасушалар визуалды рецепторлардан алынған түзу сызықтардың кескініне жауап берді, ал күрделі жасушалар бір бағытта алға қозғалысқа жауап берді. Нәтижесінде конвульсиялық деп аталатын нейрондық желілерді құру принципі жасалды. Бұл принциптің идеясы нейрондық желінің жұмыс істеуін жүзеге асыру үшін әдетте $C - \text{Layers}$ деп белгіленетін конвульсиялық қабаттардың кезектесуі қолданылады, ішкі үлгілеу қабаттары $S - \text{Layers}$ және толық қосылған қабаттар $F - \text{Layers}$.

Осындай желіні құрудың негізінде үш парадигма жатыр – бұл жергілікті қабылдау парадигмасы, ортақ салмақтар парадигмасы және субдискретизация парадигмасы.

Жергілікті қабылдау парадигмасының мәні әрбір кіріс нейронға бүкіл кескін матрицасы емес, оның бір бөлігі беріледі. Қалған бөліктер басқа кіріс нейрондарына беріледі. Бұл жағдайда параллелизация механизмін байқауға болады, ұқсас әдісті қолдана отырып, кескін топологиясын қабаттан қабатқа сақтауға, оны көп өлшемді өңдеуге болады, яғни өңдеу процесінде нейрондық желілердің белгілі бір жиынтығын қолдануға болады.

Ортақ салмақ парадигмасы бойынша салмақтардың шағын жиынтығын көптеген сілтемелер үшін пайдалануға болады. Бұл жиынтықтарды «ядролар» деп те атайды. Кескінді өңдеудің соңғы нәтижесі үшін ортақ салмақтар нейрондық желінің қасиеттеріне оң әсер етеді, оның әрекетін зерттеу кескіндердегі инварианттарды табу және оларды өңдеусіз шу компоненттерін іріктеу мүмкіндігін арттырады.

Ядро негізінде кескінді конвульсиялау процедурасын қолдану кезінде элементтері іріктеуге сәйкестік дәрежесінің негізгі сипаттамасы болатын шығыс кескіні пайда болады, яғни мүмкіндіктер картасы жасалады.

Субдискретизация парадигмасы кіріс кескіні оның математикалық эквивалентінің – n өлшемді матрицаның кеңістіктік өлшемін азайту арқылы азайтылады. Субдискретизация қажеттілігі бастапқы кескіннің масштабына өзгермейтін түрде көрсетіледі. Қабаттарды ауыстыру әдісін қолдану кезінде бұрыннан барлардан жаңа мүмкіндіктер карталарын құру мүмкін болады, яғни бұл әдістің практикалық жүзеге асырылуы көпөлшемді матрицаны векторлық мәнге, содан кейін толығымен кескінге айналдыру мүмкіндігінде жатыр. скалярлық мәнге ие болады.

Ауыспалы қабаттар әдісін қолдану кезінде бұрыннан барлардан жаңа мүмкіндік карталарын жасауға болады, яғни бұл әдістің практикалық жүзеге асуы көпөлшемді матрицаны векторға, содан кейін толығымен скалярлық мәнге айналдыруға болады.

Нейрондық желіні оқытуды жүзеге асыру. Қолданыстағы желілер оқу тұрғысынан архитектураның 3 класқа бөлінеді: бақыланатын оқу (перцептон); бақылаусыз оқыту (бейімделетін резонансты желілер); аралас оқыту (радиалды негізді функциялардың желілері).

Кескінді тану жағдайында нейрондық желінің өнімділігін бағалаудың маңызды критерийлерінің бірі кескінді тану сапасы болып табылады. Нейрондық желінің жұмысы арқылы кескінді тану сапасын сандық бағалау үшін көбінесе орташа квадрат қателік алгоритмі қолданылады [3]:

$$E^p = \frac{1}{2} (D^p - O(I^p, W))^2$$

мұндағы E^p жұп нейрондар үшін p -ші тану қатесі, D^p – нейрондық желінің күтілетін өнімі, ал $O(I^p, W)^2$ конструкциясы желі шығысының квадраты болып табылады, ол p -ші кірісі бойынша және белгіленген W салмақ коэффициенттері. Бұл конструкция конвульсиялық ядроларды да, барлық қабаттардың салмақ коэффициенттерін де қамтиды. Қатені есептеу нейрондардың барлық жұптары үшін орташа арифметикалық мәнді есептеуден тұрады.

Талдау нәтижесінде қате мәні минималды болған кезде салмақтың номиналды мәнін тәуелділік негізінде есептеуге болатын заңдылық алынды:

$$W_{\min} = W_{\varepsilon} - \left(\frac{d^2 E(W_{\varepsilon})}{dW^2} \right)^{-1} \frac{dE(W_{\varepsilon})}{dW}$$

Осы тәуелділіктен оптималды салмақты есептеу есебі бірінші ретті қателік функцияның туындысының салмаққа қатысты арифметикалық айырмасын екінші ретті қателік функцияның туындысына бөлу [1].

Берілген тәуелділіктер шығыс қабатында болатын қатені тривиальды есептеуге мүмкіндік береді. Нейрондардың жасырын қабаттарындағы қателерді есептеу қателерді кері тарату әдісі арқылы жүзеге асырылуы мүмкін. Әдістің негізгі идеясы – ақпаратты қате сигналы түрінде шығыс нейрондардан кірістерге, яғни нейрондық желі арқылы сигналдың таралуына қарама-қарсы бағытта тарату [4].

Желілік оқыту сыныптардың үлкен санына жіктелген арнайы дайындалған кескін деректер базасында орындалады және жеткілікті ұзақ уақытты алады.

Нейрондық желілер бейнені тану мәселесінде де, мәтінді тану мәселесінде де қолданылуы мүмкін. Бұл теория модельдердің жаңа перспективалық класын, атап айтқанда интеллектуалды модельдеуге негізделген модельдерді құру туралы айтуға мүмкіндік береді. Нейрондық желіні зерттеу арқылы үлгіні тану алгоритмін бағалау сандық мәнге ие болуы мүмкін, сәйкесінше қажетті салмақ коэффициенттерін есептеу арқылы параметрлерді қажетті мәнге келтіру механизмдері бар.

Пайдаланылған әдебиеттер

- 1 Y. LeCun and Y. Bengio: Convolutional Networks for Images, Speech, and Time-Series, in Arbib, M. A. (Eds) // The Handbook of Brain Theory and Neural Networks. – 2005. – 150 p.
- 2 Жигалов К.Ю. Подготовка техники к использованию в системах автоматизированного управления строительства автодорог // Естественные и технические науки. – М., 2014. – № 1 (69). – С. 285–287.
- 3 Y. LeCun and Y. Bengio: Convolutional Networks for Images, Speech, and Time-Series, in Arbib, M. A. (Eds) // The Handbook of Brain Theory and Neural Networks. – 2005. – 150 p.

Y. LeCun, L. Bottou, G. Orr and K. Muller: Efficient BackProp, in Orr, G. and Muller K. (Eds)/Neural Networks: Tricks of the trade. – 2008. – 200 p.

УДК 519.62

PYTHON-ДА УАҚЫТ ҚАТАРЛАРЫН БОЛЖАУ ҮШІН ARIMA МОДЕЛІН ҚҰРУ

Рахимова Айгерим Акылбековна

rakhimovaigerim@gmail.com

Қазақстан, Астана, Л.Н.Гумилев атындағы ЕҰУ «Математикалық және компьютерлік модельдеу» мамандығының 1 курс магистранты

Ғылыми жетекші – т.ғ.к., PhD, доцент Абденова Г. А.

Абстракт

Бұл зерттеуде Қазақстан Республикасының Қысқа Мерзімді Экономикалық Индикаторының болашақ мәндерін болжау үшін уақыт қатарларын модельдеу бір тәсілі Бокс-Дженкинстің ARIMA моделі пайдаланылды. ҚР Ұлттық Статистика Бюросының сайтынан 2009 жылғы қаңтар мен 2021 жылғы шілде аралығындағы деректер алынды. ARIMA моделі Python бағдарламасының көмегімен әзірленді. Уақыт қатарларын талдау оқиғаларға және олардың уақыт бойынша өзгеруіне түсініктеме береді. Модельді тексеру үшін 2021 жылдың тамызынан 2022 жылдың шілдесіне дейінгі деректер пайдаланылды. Әрі қарай болжау үшін деректер мезгіл-мезгіл жаңартылып отыруы керек.

Кілт сөздер: стационарлық емес уақыт қатарлары, маусымдық деректер, қысқа мерзімді болжамдар, ARIMA.

1. Кіріспе

Уақыт қатарлары экономика, қаржы, медицина және саясат сияқты көптеген салаларда маңызды талдау объектісі болып табылады. Олар уақыт бойынша дәйекті түрде жиналған деректер жиынтығы және трендтер, маусымдық және кездейсоқ ауытқулар сияқты әртүрлі құбылыстар туралы ақпаратты қамтуы мүмкін.

Уақыт қатарларын болжау деректерді талдаудың маңызды міндеттерінің бірі болып табылады. Бұл бизнес шешімдерін қабылдау, бюджетті анықтау, өндірісті жоспарлау және сатуды болжау үшін пайдалы болуы мүмкін. Уақыт серияларын болжаудың танымал әдістерінің бірі - ARIMA моделі. Көптеген іскери болжау қосымшалары күнделікті, апталық, айлық, тоқсандық және жылдық деректерді пайдаланады. Мысалы, бір ай ішінде өнімнің жалпы сатылымы немесе бұл уақыт кезеңіндегі шаманың белсенділігін көрсететін статистика, мысалы, биржадағы акцияның жабуадағы күнделікті бағасы.

ARIMA (авторегрессиялық интегралды жылжымалы орташа) - уақыт қатарларын талдау, бағалау және болжау үшін пайдалануға болатын уақыт қатарларын модельдеу әдісі. Ол үш негізгі компоненттен тұрады: авторегрессиялық (AR), интеграцияланған (I) және жылжымалы орташа (MA). AR компоненті ағымдағы мән мен қатардың алдыңғы мәндері арасындағы байланысты көрсетеді. MA компоненті ағымдағы мән мен алдыңғы кадамдағы кездейсоқ қате арасындағы байланысты көрсетеді. I-компонент қатарды біріктіруге жауап береді және трендті жою үшін қолданылады.