

Didžiųjų duomenų ir dirbtinio intelekto technologijų pritaikymo galimybių viešojo valdymo srityje ir socialinėje politikoje analizė

Adomas Vincas Rakšnys

Kazimiero Simonavičiaus universiteto Verslo mokykla, Dariaus ir Girėno g. 21, Vilnius
Kazimieras Simonavičius university, Business School, Dariaus ir Girėno str. 21, Vilnius
Mykolo Romerio universiteto Viešojo administravimo institutas, Ateities g. 20, Vilnius
Mykolas Romeris university, Institute of Public Administration, Ateities str. 20, Vilnius
El. paštas: e_cnv@yahoo.com

Dangis Gudelis

Mykolo Romerio universiteto Viešojo administravimo institutas, Ateities g. 20, Vilnius
Mykolas Romeris university, Institute of Public Administration, Ateities str. 20, Vilnius
Tel. 8 610 27509
El. paštas: dgudel@mruni.eu

Arvydas Guogis

Mykolo Romerio universiteto Viešojo administravimo institutas, Ateities g. 20, Vilnius
Mykolas Romeris university, Institute of Public Administration, Ateities str. 20, Vilnius
El. paštas: arvydasg@mruni.eu

Santrauka. Šiame tarpdisciplininiame straipsnyje pateikiama XXI amžiaus ketvirtosios pramonės revoliucijos fenomenų – didžiųjų duomenų ir dirbtinio intelekto technologijų – samprata ir aptariamos jų naudojimo viešojo valdymo srityje ir socialinėje politikoje galimybės, nagrinėjami didžiųjų duomenų pranašumai ir trūkumai, jų rinkimo, patikimumo ir naudojimo problemos. Didieji duomenys gali būti naudojami su viešuoju valdymu ir socialine politika susijusių reiškinių analizei ir jiems modeliuoti. Didieji duomenys apima tris duomenų tipus: a) istorinius duomenis, b) dabarties duomenis su mažu pavėlavimu, c) prognostinius duomenis ateičiai prognozuoti. Galima apibrėžti šias didžiųjų duomenų kategorijas: a) duomenis iš socialinių tinklų, b) valdymo sistemų duomenis, c) mašinų generuojamus duomenis, pavyzdžiui, vandens gavybos, užterštumo, palydovų informaciją. Straipsnyje yra analizuojami didžiųjų duomenų pranašumai ir trūkumai. Galimi tokie didžiųjų duomenų iššūkiai, kaip antai: duomenų saugumas, bendradarbiavimo stoka valstybės tarnyboje, labai retai nutinkančios situacijos, duomenų fragmentacija, nebaigtumas ir klaidingumas, etiniai duomenų analizės ir naudojimo viešojo valdymo srityje ir socialinėje politikoje klausimai. Didieji duomenys ir jų analizė naudojant dirbtinio intelekto technologijas gali prisidėti prie viešojo valdymo ir socialinės politikos sprendimų adekva-

Received: 2021-04-05. Accepted: 2021-07-03

Copyright © 2021 Adomas Vincas Rakšnys, Dangis Gudelis, Arvydas Guogis. Published by Vilnius University Press. This is an Open Access article distributed under the terms of the [Creative Commons Attribution Licence](https://creativecommons.org/licenses/by/4.0/), which permits unrestricted use, distribution, and reproduction in any medium, provided the original author and source are credited.

tumo ir objektyvumo, veiksmingai pažaboti korupciją ir nepotizmą didinant viešojo sektoriaus organizacijų autoritetą ir pasitikėjimą valdžia, o jo šiuolaikiniame pasaulyje taip trūksta.

Pagrindiniai žodžiai: didieji duomenys, duomenų analitika, dirbtinis intelektas, viešasis valdymas ir socialinė politika

The Analysis of Opportunities of the Application of Big Data and Artificial Intelligence Technologies in Public Governance and Social Policy

Summary. This interdisciplinary article presents a concept of the 21st century and phenomena that are products of the 4th industrial revolution – big data and Artificial Intelligence technologies – as well as the opportunities of their application in public governance and social policy. This paper examines the advantages and disadvantages of big data, problems of data collection, its reliability and use. Big data can be used for the analysis and modeling of phenomena relevant to public governance and social policy. Big data consist of three main types: a) historical data, b) present data with little delay, c) prognostic data for future forecasting. The following categories of big data can be defined as: a) data from social networks, b) traditional data from business systems, c) machine-generated data, such as water extraction, pollution, satellite information. The article analyzes the advantages and disadvantages of big data. There are big data challenges such as data security, lack of cooperation in civil service and social work, in rare situations – data fragmentation, incompleteness and erroneous issues, as well as ethical issues regarding the analysis of data and its use in social policy and social administration.

Big data, covered by Artificial Intelligence, can be used in public governance and social policy by identifying “the hot spots” of various phenomena, by prognosing the meanings of variables in the future on the basis of past time rows, and by calculating the optimal motion of actions in the situations where there are possible various alternatives. The technologies of Artificial Intelligence are used more profoundly in many spheres of public policy, and in the governance of COVID-19 pandemics too.

The substantial advantages of the provided big data and Artificial Intelligence are a holistic improvement of public services, possibilities of personalization, the enhancement of citizen satisfaction, the diminishing of the costs of processing expenditure, the targeting of adopted and implemented decisions, more active involvement of citizens, the feedback of the preferences of policy formation and implementation, the observation of social phenomenas in real time, and possibilities for more detailed prognosing.

Challenges to security of data, necessary resources and competences, the lack of cooperation in public service, especially rare instances of data fragmentation, roughness, falseness, and ethical questions regarding data analysis and application can be evaluated as the most significant problems of using big data and Artificial Intelligence technologies.

Big data and their analytics conducted using Artificial Intelligence technologies can contribute to the adequacy and objectivity of decisions in public governance and social policy, effectively curbing corruption and nepotism by raising the authority and confidence of public sector organizations in governance, which is so lacking in the modern world.

Keywords: big data, data analytics, Artificial Intelligence, public governance, social policy

Įvadas

XXI amžiaus technologinė aplinka neišvengiamai keičia ir keis viešojo valdymo ir socialinės politikos sistemas. Vienas iš ketvirtosios pramonės revoliucijos fenomenų yra didieji duomenys ir dirbtinio intelekto technologijos. Didieji duomenys ir jų veiksmingas valdymas tampa kritiniu ne tik verslo organizacijų, bet ir valstybės valdymo ir viešosios politikos formavimo ištekliumi. Didžiųjų duomenų analitika panaudojant dirbtinio intelekto technologijas teikia galimybių institucijoms tobulinti viešąsias paslaugas ir jų teikimo būdus, gali paskatinti inovacijas, sukurti žinių dalijimosi aplinką tarpinstituciniu ir tarpsektoriniu lygmenimis, padėti valdyti globalias ir nacionalinio lygmens krizes, pavyzdžiui, COVID-19 pandemiją, didinti piliečių pasitenkinimą viešosiomis paslaugo-

mis, mažinti procesines išlaidas, užtikrinti priimamų ir įgyvendinamų sprendimų tikslumą, politikų ir valstybės tarnautojų atskaitomybę (Anshari and Lim, 2016; Hasnat, 2018; Maciejewski, 2016; Desouza and Jacob, 2014). Didieji duomenys gali padėti institucijų personalo skyriams valstybės tarnyboje identifikuoti ir pritraukti reikalingus išteklius ir talentus, analizuoti ir sistemiškai vertinti esamų tarnautojų veiklos rodiklius, mažinti biurokratiją (Rogge et al., 2017). Vis dėlto didžiųjų duomenų analitika politinių sprendimų priėmėjams dar yra naujas konceptas, o jos pritaikymo galimybės ir teikiama nauda nėra aiškiai suvokiami (Hasnat, 2018).

Kita vertus, didžiųjų duomenų ir dirbtinio intelekto technologijų naudojimas viešojo valdymo srityje ir socialinėje politikoje atveria ne tik galimybių, bet ir kelia grėsmių, susijusių su etinėmis šių technologijų taikymo problemomis, duomenų apsaugos ir asmens privatumo iššūkiais, taip pat juos naudojant kyla kliūčių dėl reikalingų išteklių ir kompetencijų trūkumo, bendradarbiavimo stokos valstybės tarnyboje, politikos formavimo proceso ypatumų, kokybiško duomenų trūkumo ir fragmentacijos (Gillingham and Graham, 2016; Pencheva et al., 2018; Santiago and Smith, 2019). Vis dėlto dabartinės tendencijos atskleidžia, kad viešąją politiką formuojančios ir įgyvendinančios institucijos tolydžio prisitaiko prie technologinių pokyčių teikiamų galimybių naudodamos šias technologijas priimti geresnius duomenimis pagrįstus sprendimus, mažinti biudžeto išlaidas, spręsti socialines ir ekonomines problemas, teikti kokybiškesnes viešąsias paslaugas, užtikrinti atskaitomybę ir kurti didesnę vertę piliečiams (Zetino and Mendoza, 2019). Didžiųjų duomenų ir dirbtinio intelekto technologijos gali padėti viešosios politikos sprendimų priėmėjams laiku ir tinkamai reaguoti į kylančius XXI amžiaus iššūkius: ekonomines, politines, saugumo, sveikatos ir klimato krizes, kartu su biurokratijos mažinimu kylantį efektyvaus valstybinio reguliavimo poreikį, socialinę nelygybę ir atskirtį, smurtą artimoje aplinkoje, lygių galimybių ir teisingumo užtikrinimą, sveikatos paslaugų prieinamumą, terorizmo grėsmę, benamystę ir kt. (Coulton et al., 2015).

Straipsnyje nagrinėjamos didžiųjų duomenų ir jiems apdoroti ir analizei naudojamų dirbtinio intelekto technologijų pritaikymo galimybės įvairiose viešojo valdymo ir socialinės politikos srityse ir jų taikymo problemos. Straipsnyje naudojami aprašomasis, mokslinės literatūros analizės, kritinės analizės, sintezės ir apibendrinimo metodai.

Didžiųjų duomenų ir dirbtinio intelekto technologijų naudojimo viešojo valdymo ir socialinės politikos srityje galimybės

Didžiųjų duomenų (angl. *big data*) terminas pradėtas vartoti apytikriai 1990 metais, tačiau daugiau apie juos imta diskutuoti tik apie 2000 metus. Dažniausiai jie apibrėžiami kaip didžiulis struktūruotų ir nestruktūruotų duomenų, kurie yra generuojami, užfiksuojami ir išsaugojami ypatingu greičiu, siekiant iš jų gauti vertę atliekant organizacinį prognozavimą ir sprendimams priimti, kiekis. Šie duomenys renkami iš labai plataus spektro šaltinių: mobiliųjų telefonų, vaizdo įrašymo įrenginių, sensorių, įvairių išmaniųjų prietaisų, miestuose esančių vaizdo kamerų ir kitų šaltinių. Jie teikia galimybę institucijoms prognozuoti piliečių elgseną, analizuoti ekonomikos ir statistinius reišk-

kinius. Remiantis Jungtinių Tautų siūloma klasifikacija¹, galima išskirti šiuos didžiųjų duomenų šaltinius: a) socialinių tinklų, t. y. žmonių sugeneruotus, duomenis, tokius kaip antai *Twitter*, *YouTube* ir kt. socialinių medijų, paieškų sistemų, blogų įrašų, mobiliųjų telefonų žinučių, elektroninio pašto ir kt. informacija; b) valdymo sistemų duomenis (tokių procesų, pavyzdžiui, verslo operacijos, elektroninė prekyba, kredito kortelės ir kt., sugeneruotus duomenis); c) daiktų interneto (angl. *Internet of Things*), t. y. mašinų sugeneruotus tokius duomenis: pastatų, vandens gamybos, taršos, apsaugos kamerų sensorių, automobilių, palydovų, kompiuterinių sistemų informacija ir kt. Pretty² skiria tris didžiųjų duomenų šaltinius: a) istorinius laiko eilučių duomenis; b) esamojo laiko (angl. *real-time*) duomenis kelių valandų ar minučių laikotarpiu, atspindinčius esamą ar artimą esamai situaciją; c) prognostinius duomenis, kurie atskleidžia, kas gali įvykti ateityje, o institucijos priima sprendimus remdamosi ateities projekcijomis (Maciejewski 2016).

Didieji duomenys dažnai apibūdinami pasitelkiant 3 V perspektyvą (Hasnat, 2018; Anshari and Lim, 2016; Rogge et al., 2017; Maciejewski, 2016). Šis akronimas reiškia tris esmines dimensijas: a) didžiųjų duomenų apimtį (angl. *Volume*), dažniausiai matuojamą terabaitais ar petabaitais; b) įvairumą (angl. *Variety*), kuris susijęs su duomenų pobūdžiu ir jų struktūriniu heterogeniškumu (pvz., struktūruoti, pusiau struktūruoti, nestruktūruoti duomenys); c) didžiųjų duomenų dinamiškumą (angl. *Velocity*) ir jų rinkimo, išsaugojimo bei analizavimo greitį. Kai kuriuose sektoriuose jau artėjama prie to, kad duomenis galima rinkti, išsaugoti ir analizuoti beveik realiuoju laiku. Tik nedidelė dalis duomenų yra struktūruoti (Rogge et al., 2017). Susisteminę įvairius tyrimus, autoriai Anshari ir Lim (2016), linkdami prie klasikinės 3 V didžiųjų duomenų perspektyvos, dar mini vertybių dimensiją (angl. *Value*), variacijas (angl. *Variability*), autentiškumą (angl. *Veracity*).

Didieji duomenys naudojami kaip įvesties (angl. *input*) ir išvesties (angl. *output*) duomenys apmokant ir tikrinant dirbtinio intelekto modelius. Europos Komisija³ apibrėžia dirbtinį intelektą kaip „sistemas, kurios demonstruoja protingą elgesį, analizuodamos savo aplinką ir atlikdamos iš dalies autonomiškus veiksmus tam, kad pasiektų konkrečius tikslus“. Dirbtinio intelekto tyrimų laukas apima tokias technologijas, kaip antai: mašininis mokymasis (angl. *machine learning*) (skiriamos trys mašininio mokymosi sritys: mokymasis be mokytojo (angl. *unsupervised learning*), mokymasis su mokytoju (angl. *supervised learning*) ir sustiprintas mokymasis (angl. *reinforcement learning*), dirbtinių neuroninių tinklų (angl. *artificial neural networks*) algoritmais pagrįstas gilusis mokymasis (angl. *deep learning*), mašininis samprotavimas (angl. *machine reasoning*) ir robotika (Campion et al., 2020).

Didžiųjų duomenų ir dirbtinio intelekto technologijų naudojimas verslo ir viešojo valdymo bei socialinės politikos srityje galimas keturiais būdais (Zetino and Mendoza,

¹ Classification of Types of Big Data. Steven Vale, last modified by Taeke Gjaltema on 19 Jun, 2020, <https://statswiki.unece.org/display/bigdata/Classification+of+Types+of+Big+Data>; Žiūrėta 2021 06 08

² Pretty I. (2013). Big Data in the Public Sector. Capgemini, <https://www.capgemini.com/sc-en/resources/big-data-in-the-public-sector/>; Žiūrėta 2020 06 09

³ European Commission (2019). A definition of AI: Main capabilities and scientific disciplines. High-Level Expert Group on Artificial Intelligence; <https://digital-strategy.ec.europa.eu/en/library/definition-artificial-intelligence-main-capabilities-and-scientific-disciplines>; Žiūrėta 2020 06 09

2019). Aprašomoji analitika (angl. *descriptive analytics*) yra orientuota į siekį identifikuoti, koks reiškinys vyksta, kur jis vyksta, kas yra jo paveiktieji ir kokios yra jų demografinės charakteristikos. Ji yra naudojama nustatyti karštuosius taškus (angl. *hotspots*), kurie parodo, koku intensyvumu reiškiiasi įvairūs fenomenai, sudaryti tokių karštųjų taškų žemėlapius. Tai teikia galimybę suprasti, kaip tam tikri elgesio modeliai yra susiję su bendruomenių turima infrastruktūra, gyventojų sveikata, išsilavinimu, socialiniu ir ekonominiu statusu. Aprašomosios analitikos pavyzdys yra COVID-19 pandemijos metu *Google* kompanijos parengtos įvairių šalių gyventojų mobilumo ataskaitos, kurios buvo naudojamos suprasti SARS-CoV-2 virusui plisti įtaką darančius veiksnius⁴.

Diagnostinė analitika (angl. *diagnostic analytics*) gali padėti nustatyti probleminius reiškinius, kurie savo savybėmis išsiskiria iš normalių reiškinių (t. y. diagnozuoti problemas), ir paaiškinti, kodėl probleminiai reiškiniai įvyksta, išryškinti esminius su jais susijusius kintamuosius. Platus tyrimų laukas yra COVID-19 ligos atvejų diagnozavimas naudojant mašininio mokymosi (angl. *machine learning*) ir neuroniniais tinklais pagrįstus giliojo mokymosi (angl. *deep learning*) metodus ir algoritmus (pvz., konvoliucinius neuroninius tinklus (angl. *convolutional neural networks (CNN)*)), šioje srityje paskelbta daug mokslinių publikacijų (pvz., Oh et al., 2020; Narin et al., 2020; Apostolopoulos and Mpesiana, 2020; ir kt.).

Prognostinė analitika (angl. *predictive analytics*) identifikuoja įvykių tendencijas remdamasi praeities laiko eilučių duomenimis ir tų tendencijų pagrindu modeliuoja ateities įvykių raidą. Nuo pandemijos pradžios publikuota daug mokslinių straipsnių, kuriuose pristatomi užsikrėtimų SARS-CoV-2 virusu prognozavimo remiantis įvairiais prognostiniais modeliais rezultatai (Wieczorek et al., 2020; Hawas, 2020; Chandra et al., 2021; Muhammad Adnan Khan, 2020; Papastefanopoulos et al., 2020). SARS-CoV-2 viruso plitimui prognozuoti naudojami klasikiniai epidemiologiniai modeliai (SIR, SEIR ir šių modelių modifikacijos (Bahloul et al., 2020; Torkey et al., 2020; Leipus and Štikonienė, 2020), logistinis modelis (Wu et al., 2020; Aviv-Sharon and Aharoni, 2020), ARIMA modelis (Devaraj et al., 2021; Chakraborty and Ghosh, 2020), kelių kintamųjų tiesinė regresija (Suganya et al., 2020), taip pat neuroniniais tinklais pagrįsti modeliai (Holt–Winters⁵, TBAT (Livera et al., 2011), Prophet⁶ (Taylor and Letham, 2017), DeepAR⁷ (Salinas et al., 2019), N-Beats (Oreshkin et al., 2020) modeliai (Papastefanopoulos et al., 2020), ilgalaikės trumposios atminties tinklai (angl. *Long Short-Term Memory (LSTM)*) (Devaraj et al., 2021; Chandra et al., 2021; Chimmula and Zhang, 2020; Yudistira, 2020; Pal et al., 2020), rekurentiniai neuroniniai tinklai (angl. *recurrent neural networks (RNN)*) (Villegas et al., 2020; Hawas, 2020), daugiasluoksnis perceptronas

⁴ COVID-19 Community Mobility Reports. Google; <https://www.google.com/covid19/mobility/>; Žiūrėta 2020 06 08

⁵ Hyndman, R.J., & Athanasopoulos, G. (2018) Forecasting: principles and practice, 2nd edition, OTexts: Melbourne, Australia. <https://OTexts.com/fpp2>; Žiūrėta 2021 06 08

⁶ Facebook Prophet. Start it up, Aug 23, 2020; <https://medium.com/swlh/facebook-prophet-426421f7e331>; Žiūrėta 2021 06 08

⁷ DeepAR Forecasting Algorithm. AWS; <https://docs.aws.amazon.com/sagemaker/latest/dg/deepar.html>; Žiūrėta 2021 06 08

(angl. *Multilayer Perceptron*) (Wieczorek et al., 2020), giliosios ekstremalaus mokymosi mašinos (angl. *Deep Extreme Learning Mashines (DELIM)*) (Muhammad Adnan Khan, 2020), grafiniai neuroniniai tinklai (angl. *Graph Neural Networks (GNN)*) (Kapoor et al., 2020). Tačiau reikia pasakyti, kad daugelyje šių tyrimų COVID-19 pandemijos rodiklių prognozavimas buvo vykdomas remiantis vieno kintamojo laiko eilučių analize (t. y. buvo sudaryti modeliai, kuriais, pvz., užsikrėtimų virusu atvejų skaičius prognozuojamas remiantis duomenimis apie užsikrėtimų atvejų skaičiaus reikšmių pokyčius ankstesniu laikotarpiu). Daug mažiau paskelbta tyrimų, kuriuose prognozavimas rėmėsi kelių kintamųjų laiko eilučių analize ir į prognostinius modelius buvo įtraukiami duomenys apie kitų veiksmų (pvz., karantino priemonių) poveikį užsikrėtimų atvejų skaičiaus ar kitų COVID-19 pandemijos rodiklių pokyčiams (Lai et al., 2020; Brauner et al., 2020; Liu et al., 2020). Dažniausiai prognostiniuose modeliuose prognozėms naudojami COVID-19 pandemijos rodiklių duomenys šalių mastu, tačiau taip pat buvo atlikta COVID-19 pandemijos prognozavimo tyrimų, kuriuose buvo tiriama pandemijos dinamika įvairių šalių regionuose (pvz., JAV valstijose (Anon, 2020), Kinijos provincijose (Wu et al., 2020)). Kita vertus, dar menkiausiai buvo tirta pandemijos dinamika skirtingose gyventojų grupėse (tokio tyrimo pavyzdį galima paminėti (Radulescu et al., 2020)).

Preskriptyvioji analitika (angl. *prescriptive analytics*) apima sprendimų paramos ir optimizavimo sistemas (Frazzetto et al., 2019; Delen, 2019; Lepenioti et al., 2020). Sprendimai ir veiksmai rekomenduojami panaudojant matematinius algoritmus ir apdorojant prognostinės analitikos išvesčių duomenis. Tokia analitika suteikia galimybę pasirinkti tinkamiausius sprendimus iš daugelio alternatyvų (Zetino and Mendoza, 2019). Vienas iš didžiųjų duomenų panaudojimo pavyzdžių verslo organizacijose yra klientų vairavimo duomenų analitika, kurią naudoja draudimo kompanija „Aviva“⁸. Kompanija, pasitelkdama duomenis, gaunamus iš mobiliųjų telefonų, stebi klientų vairavimo įpročius, šių duomenų pagrindu vairuotojai klasifikuojami į skirtingas rizikos grupes. Vairuotojai, kurie priskiriami mažesnės rizikos vairuotojų grupei, už draudimo paslaugas moka mažiau nei tie, kuriuos mašininio mokymosi algoritmai priskiria aukštesnės rizikos grupei (Maciejewski, 2016). Kiti sėkmingo duomenų pavertimo vertę kuriančiais sprendimais pavyzdžiai verslo organizacijose yra klientų sandorių duomenų panaudojimas optimizuojant klientų segmentavimą ir tikslinių grupių nustatymą (Nair et al., 2017) arba sprendimų palaikymo įrankių kūrimas, siekiant optimizuoti priežiūros užduotis (Angalakudati et al., 2014; Brandt et al., 2021).

Tačiau ne tik verslo organizacijos, bet ir viešojo sektoriaus įstaigos savo veikloje vis plačiau naudoja didžiųjų duomenų ir dirbtinio intelekto technologijų teikiamas galimybes. Sveikatos priežiūros įstaigos, analizuodamos pacientų sveikatos duomenis realiuoju laiku, gali pacientams pasiūlyti personalizuotas paslaugas (Rogge et al., 2017). Athey (2017) ir Glaeser, Hillis, Kominers ir Luca (2016) pateikia analitinių sistemų panaudojimo miestuose pavyzdžių – pastatų ir sveikatos inspektorių veiklos

⁸ Gray A. Democratising finance: Big data homes in on insurance. Financial Times 1 February, 2015. <https://www.ft.com/cms/s/0/0e19375c-a316-11e4-9c06-00144feab7de.html#slide0>; Žiūrėta 2020 06 09

optimizavimą, remiantis numatoma pažeidimų tikimybe. Prognostinės policijos sistemos (Gerber, 2014; Mohler et al., 2015; Shapiro, 2017) naudojamos policijos veiklai optimizuoti, iš anksto paskirstant išteklius numatomų nusikaltimų vietoms. Atliekų tvarkymo sistemos (Perera et al., 2013) padeda miestams efektyviau atlikti atliekų surinkimą ir šalinimą. Tokios analitinės sistemos naudoja didžiuosius duomenis ir daiktų internetą, kad pagerintų veiklos efektyvumą. Analitika taip pat naudojama ir kaip viešojo sektoriaus ir socialinės politikos strateginių sprendimų priėmimo priemonė. Pavyzdžiui, Brandtas, Bendleris ir Neumannas (2017) parodo, kaip savivaldybės panaudoja socialinių medijų analizę kurdamos miesto turizmo plėtros strategijas. Ilgalaičiai strateginiai sprendimai viešajame sektoriuje, ypač vietos savivaldos sprendimai, dažnai yra susiję su investicijomis į infrastruktūrą (pvz., keliais ar viešuoju transportu) ir miesto plėtra (Ooijen et al., 2019).

Paminėtini keli optimalių sprendimų paieškos ir rekomendavimo pavyzdžiai ir COVID-19 pandemijos valdymo srityje. Prasidėjus COVID-19 pandemijai, šalių vyriausybėms kilo uždaviniai nustatyti optimalų skirtingų priemonių taikymo lygį, kad būtų pasiekta didžiausia nauda (kuo labiau sumažintas užsikrėtimų SARS-CoV-2 virusu atvejų ir mirčių nuo COVID-19 ligos atvejų skaičius) su kuo mažesnėmis sąnaudomis ir neigiamomis pasekmėmis gyventojams ir verslui. Matrajt ir kt. (2020) parengė matematinį modelį ir pritaikė optimizavimo algoritmus, pagal kuriuos galima apskaičiuoti, kokios skirtingų amžiaus grupių gyventojų vakcinavimo strategijos yra optimalios siekiant minimizuoti tokius rodiklius, kaip antai užsikrėtimų atvejų skaičius, hospitalizuotų asmenų skaičius, asmenų intensyvios terapijos skyriuose skaičius, mirčių nuo COVID-19 atvejų skaičius. Tiesa, šis straipsnis buvo paskelbtas dar iki prasidedant masiniam gyventojų vakcinavimui, todėl nebuvo galimybių šio modelio apmokyti faktiniais gyventojų vakcinavimo duomenimis. Awasthi ir kt. (2021) straipsnyje pristatytas veiksmingų COVID-19 vakcinų strategijų paieškos modelis VacSIM, pagrįstas „giliuoju Q mokymusi“ (angl. *Deep Q Learning*) ir tokiais algoritmais, kaip antai „kontekstiniai banditai“ (angl. *contextual bandits*) ir „veikėjo kritika panaudojant Kroneckerio faktorizuotą pasitikėjimo regioną“ (angl. *Actor-Critic using Kronecker-Factored Trust Region (ACKTR)*). Uddin ir kt. (2020) parengė modelius, pagrįstus sustiprinto mokymosi (angl. *reinforcement learning*) ir giliojo mokymosi algoritmais, kuriuos galima pritaikyti optimalių sprendimų dėl gyventojų testavimo, dezinfekavimo ir karantinavimo paieškai. Palyginus modelius buvo nustatyta, kad tokie giliojo mokymosi algoritmai, pavyzdžiui, „gilusis Q tinklas“ (angl. *Deep Q Network (DQN)*) ir „gilusis deterministinis politikos gradientas“ (angl. *Deep Deterministic Policy Gradient (DDPG)*) veikia geriau nei įprasti sustiprinto mokymosi algoritmai – „Q mokymasis“ arba „būsena-veiksmas-atlygis-būsena-veiksmas“ (angl. *State-Action-Reward-State_Action (SARSA)*) (Uddin et al., 2020, 1).

Didžiųjų duomenų analizė padeda geriau suprasti kompleksines socialines problemas, į kurias būtų sudėtinga reaguoti remiantis vienu duomenų šaltiniu. Tokia analizė gali būti tinkama numatyti tam tikrų grupių charakteristikas, pavyzdžiui, iš mokyklų iškrisiančių mokinių skaičių, įvairių reiškinių plėtros galimybes, pavyzdžiui, ligų protrūkių, ar gyventojų lokacijas žemės drebėjimų areale. Didieji duomenys taip pat teikia galimybę stebėti įvairių reiškinių vystymosi kryptis, pavyzdžiui, skurdo rodiklių poky-

čius tam tikruose teritoriniuose vienetuose (Hasnat, 2018). Svarbiausia, kad veiksmingas didžiųjų duomenų panaudojimas gali pagerinti paslaugų efektyvumą, leidžia pasiekti didesnę rezultatą mažesnėmis sąnaudomis (Rogge et al., 2017).

Didžiųjų duomenų analitika viešojo sektoriaus institucijoms suteikia ir gali suteikti ir kitų pranašumų. Pažymėtinas perėjimas nuo popierine dokumentacija paremtų prie skaitmeninių paslaugų, užtikrinant didesnę duomenų integraciją, judėjimą ir dalijimąsi iš skirtingų institucijų. Pabrėžtinos ir viešųjų paslaugų tobulinimo galimybės, pasitelkiant didžiuosius duomenis, kai yra analizuojama piliečių nuomonė apie viešųjų paslaugų kokybę. Pavyzdžiui, paieškos raktažodžiai gali suteikti naudingą grįžtamąjį ryšį ir padėti tobulinti viešąsias paslaugas, kad jos geriau atitiktų piliečių poreikius (Rogge et al., 2017). Toks grįžtamasis ryšys paslaugų teikėjams sukuria strateginę reagavimo galimybę (Anshari and Lim, 2016). Kaip aiškina mokslininkai Gillingham ir Graham (2016), didžiųjų duomenų apie piliečių elgseną ir jų aktyvumą naudojantis paslaugomis rinkimas, institucijoms ir politinių sprendimų priėmėjams sukuria naujas paslaugų planavimo, teikimo ir jų fokusavimo tobulinimo prielaidas.

Didieji duomenys gali prisidėti ir prie reikšmingesnio piliečių įsitraukimo į viešosios politikos programų plėtotę, įgyvendinimą ir vertinimą. Didieji duomenys gali atskleisti realias visuomenės preferencijas įvairiais viešosios politikos klausimais, ir todėl viešosios politikos formavimo procesas gali tapti mažiau priklausomas nuo viešojo valdymo ekspertų, kurių nuomonė ne visada atitinka realius visuomenės poreikius, ir interesų grupių poveikio (Desouza and Jacob, 2014). Didieji duomenys gali būti naudojami piliečių nuostatų ir nuotaių analizei, išsiaiškinti, kaip visuomenė vertina konkrečią viešąją politiką. Šiuo atveju didieji duomenys yra naudojami kaip tam tikras grįžtamojo ryšio apie politikos sprendimus ir jų įgyvendinimą būdas (Maciejewski, 2016).

Vis dėlto yra mokslininkų, pavyzdžiui, Coulton ir kt. (2015), kurie pažymi, kad, nepaisant technologijų pažangos, tam tikros viešojo gyvenimo sritys, pavyzdžiui, socialinių paslaugų sektorius, vis dar lėtai integruoja duomenų analitiką į politikos formavimo ir įgyvendinimo procesus. Tokią situaciją galima paaiškinti sudėtingai išmatuojama ilgalaikė verte, kuriai kurti, pasitelkiant didžiuosius duomenis, reikia didelių investicijų. Prognostinė analizė viešojo sektoriaus institucijų veikloje taip pat turi būti vertinama atsargiai. Nepaisant didelio patikimumo, neapibrėžtumų ir klaidos tikimybė visada egzistuoja (Maciejewski, 2016).

Didžiųjų duomenų ir dirbtinio intelekto technologijų taikymo viešojo valdymo ir socialinės politikos srityje problemos

Vertinant didžiųjų duomenų taikymo trūkumus, moksliniame diskurse dažniausiai minimos šios problemos. Dėl savo turimų įsipareigojimų viešojo sektoriaus institucijos, pradedant sveikatos apsauga ir socialinėmis paslaugomis, surenka daugybę jautrios informacijos apie savo piliečius. Šiuos duomenis naudojant kartu, būtų galima susidaryti beveik pilną individo gyvenimo vaizdą, tokiu būdu kėsinantį į asmeninio gyvenimo privatumą. Organizacijos gali rinkti duomenis tik tada, kai to reikia įgyvendinti jų misiją, tačiau toks „informacinis delegavimas“ dažnai yra neaiškus, nestabilus ir gali būti įvai-

riai interpretuojamas. Clarke ir Margetts (2014) kelia retorinį klausimą – jeigu sudėtingi prognozavimo modeliai gali būti panaudoti nusikaltimams numatyti jiems dar neįvykus, ar būtų teisinga panaudoti šiuos duomenis, siekiant prevenciškai nubausti potencialius nusikaltėlius? (Pencheva et al., 2018). Kita vertus, analizuojant kompleksinius istorinius duomenis, galima rasti įvairių ryšių net ir tarpusavyje nesusijusių kintamųjų, todėl šie duomenys, tinkamai panaudoti valstybės institucijų, galėtų padėti sukurti tokius modelius, kurie suteiktų galimybę įvairiu socialiniu kontekstu numatyti ateities įvykius (Zetino and Mendoza, 2019). Vertinant iš etinės perspektyvos, dėl vartotojų duomenų panaudojimo galėtų būti labai sudėtinga arba net neįmanoma institucijoms gauti paslaugų vartotojų sutikimą. Dar vienas klausimas kyla dėl to, kad net jeigu ir pavyktų sutikimą gauti, tai ar ir kiek vartotojai galėtų būti informuojami apie jų duomenų panaudojimą (pvz., suprantant, kam ir kaip jie bus naudojami), nes labai dažnai didieji duomenys gali būti renkami turint vieną tikslą, o panaudojami visai kitam tikslui (Gillingham and Graham, 2016). Yra grėsmė, kad, turint „didžiuosius duomenis“, gali būti peržengta „raudonoji linija“ vartotojų atžvilgiu, pavyzdžiui, pasitaikius klaidų, kai į rinką rinkodaros būdu būtų pristumiami kenksmingi jiems produktai (Coulton et. al., 2015). Didieji duomenys yra susiję ir su pačių piliečių socialiniu aktyvumu. E. Hargittai (2015) atkreipia dėmesį į situacijas, kai pasikliovimas tik didžiais duomenimis gali sukurti papildomų sunkumų, kai tam tikri svarbūs reiškiniai gali likti nepastebėti, nes jie susiję su tuo gyventojų segmentu, kuris nepalieka reikšmingo skaitmeninio pėdsako. Vyresni žmonės ir individai, gaunantys mažesnes pajamas, taip pat – individai, stokoiantys išsilavinimo, nėra tinkamai reprezentuojami socialinės medijos duomenyse, o jaunimas ir aukštesniam socialiniam sluoksniui priklausantys individai yra per daug atspindimi duomenimis apie viešųjų paslaugų vartojimą (Coulton et. al., 2015).

Veiksmingai naudoti didžiuosius duomenis būtinos ir tokios specifinės valstybės tarnautojų kompetencijos: programavimo, modeliavimo, statistikos, duomenų valdymo, analitikos įgūdžiai, mašininio mokymosi procesų supratimas, taip pat technologinė infrastruktūra (Maciejewski, 2016). Šie veiksniai yra ypač svarbūs besivystančioms valstybėms, nes jiems įsigyti, įdiegti ir palaikyti reikia laiko, finansinių ir žmogiškųjų išteklių, o jų besivystančioms valstybėms gali būti sudėtinga suformuoti (Hasnat, 2018). Būtina paminėti ir institucinio bendradarbiavimo stokos problemas. Nors viešojo sektoriaus institucijos surenka daug duomenų, dažnai jie būna fragmentiniai, yra daugybė skirtingų sistemų, kurios stokoja tarpinstitucinio suderinamumo. O instituciniam bendradarbiavimui duomenų integracijos atžvilgiu yra būtina ne vien technologinė infrastruktūra, bet ir tinkama organizacinė kultūra (Desouza and Jacob, 2014; Pencheva et al., 2018). Ši problema yra aktuali net ir analizuojant tos pačios specifikos institucijų duomenis, kurie gali būti neskaitmenizuoti, todėl jie nėra lengvai prieinami. Ši problema yra ypač aktuali mažoms institucijoms, turinčioms itin ribotų žmogiškųjų, technologinių ir finansinių išteklių. Kai su duomenimis greta savo papildomų funkcijų turi dirbti menkai apmokyti tarnautojai, tada įvedami duomenys gali būti nepilni, o kartais net ir klaidingi (Santiago and Smith, 2019).

Politikai ir valstybės tarnautojai priimdami viešojo valdymo sprendimus pagal dirbtinio intelekto algoritmų rekomendacijas privalo suprasti, kad tai nėra panacėja, ir kri-

tiškai vertinti duomenų, kurių pagrindu tos rekomendacijos buvo parengtos, patikimumą. Didieji duomenys dažnai yra kitų sudėtingų procesų produktas, ir jie nebūtinai yra renkami tam tikslui, kuriam bus naudojami, todėl atrankai ir analizei reikia specifinių kompetencijų (Coulton et al., 2015).

Analizuojant esminius trūkumus, svarbu paminėti ir pačių duomenų skaitmenizavimo procesų sudėtingumą, skirtingą duomenų pobūdį ir su jais susijusį netikrumą. Institucijos gali susidurti su iššūkiais numatydamos duomenų saugojimo vietų kūrimą, duomenų sistemų, kurios galėtų duomenis sujungti iš skirtingų šaltinių, pvz., kitų viešojo sektoriaus institucijų ar net nevyriausybinių bei verslo struktūrų, surinkimo kūrimą ir įdiegimą. Paminėtinas ir veiksmingas duomenų analizės metodų ir technikų poreikis, siekiant užtikrinti kompleksinį duomenų valdymą (Rogge et al., 2017). Dirbant su didžiaisiais duomenimis, tradicinių duomenų valdymo metodų nepakanka (Coulton et al., 2015).

Išvados

Didžiaisiais duomenimis apmokyti dirbtinio intelekto modeliai viešojo valdymo ir socialinės politikos srityje gali būti naudojami identifikuojant įvairių reiškinų „karštuosius taškus“, rengiant jų žemėlapius, diagnozuojant problemas ir nustatant jas lėmusius veiksnius, praecities laiko eilučių duomenų pagrindu prognozuojant kintamųjų reikšmes ateityje, apskaičiuojant optimalią veiksmų eigą situacijomis, kuriomis galimos įvairios alternatyvos. Dirbtinio intelekto technologijos vis plačiau naudojamos daugelyje viešosios ir socialinės politikos sričių, taip pat valdant COVID-19 pandemiją.

Esminiai didžiųjų duomenų ir dirbtinio intelekto technologijų teikiami pranašumai viešojo valdymo institucijoms yra holistinis viešųjų paslaugų tobulinimas, personalizavimo galimybės, piliečių pasitenkinimo didinimas, procesinių išlaidų mažinimas, priimamų ir įgyvendinamų sprendimų tikslumas, politikų ir valstybės tarnautojų atskaitomybė, didesnė duomenų integracija ir dalijimasis, aktyvesnis piliečių įsitraukimas, grįžtamasis ryšys dėl politikos formavimo ir įgyvendinimo preferencijų, socialinių fenomenų stebėseną realiuoju laiku, tikslesnio prognozavimo galimybės.

Vertinant svarbiausias didžiųjų duomenų ir dirbtinio intelekto technologijų panaudojimo problemas galima išskirti duomenų apsaugos iššūkius, reikalingų išteklių ir kompetencijų, bendradarbiavimo stoką valstybės tarnyboje, itin retai nutinkančias situacijas, duomenų fragmentaciją, duomenų neišbaigtumą, klaidingumą, etinius duomenų analizės ir taikymo klausimus.

Galima teigti, kad didieji duomenys ir jų naudojimas pasitelkiant dirbtinio intelekto technologijas gali leisti pasiekti reikalingą viešojo valdymo ir socialinės politikos sprendimų adekvatumą ir objektyvumą, veiksmingai pažaboti korupciją ir nepotizmą, didinti viešojo sektoriaus organizacijų autoritetą ir pasitikėjimą valdžia, o jo šiuolaikiniame pasaulyje taip trūksta.

Literatūra

- Angalakudati, M., Balwani, S., Calzada, J., Chatterjee, B., Perakis, G., Raad, N., and Uichanco, J. (2014). “Business analytics for flexible resource allocation under random emergencies”. *Management Science* 60(6): 1552–1573.
- Anon. (2020). “Modeling COVID-19 scenarios for the united states”. *Nature Medicine* 27(1): 94–105.
- Anshari, M., and Lim, S. A. (2016). “E-government with Big data enabled through smartphone for public services: Possibilities and challenges”. *International Journal of Public Administration* 40(13): 1143–1158.
- Apostolopoulos, I. D., and Mpesiana, T. A. (2020). “COVID-19: Automatic detection from x-ray images utilizing transfer learning with convolutional neural networks”. *Physical and Engineering Sciences in Medicine* 43(2): 635–640.
- Athey, S. (2017). “Beyond prediction: Using big data for policy problems”. *Science* 355(6324): 483–485.
- Aviv-Sharon, E., and Aharoni, A. (2020). “Generalized logistic growth modeling of the COVID-19 pandemic in Asia”. *Infectious Disease Modelling* 5: 502–509.
- Awasthi, R., Guliani, K. K., Khan, S. A., Vashishtha, A., Gill, M. S., Bhatt, A., Nagori, A. Gupta, A., Kumaraguru, P., and Sethi, T. (2021). “VacSIM: Learning effective strategies for COVID-19 vaccine distribution using reinforcement learning”, an e-print.
- Bahloul, M. A., Chahid, A., and Laleg-Kirati, T.-M. (2020). “Fractional-order SEIQRDP model for simulating the dynamics of COVID-19 epidemic”. *IEEE Open Journal of Engineering in Medicine and Biology* 1: 249–256.
- Brandt, T., Bendler, J., and Neumann, D. (2017). “Social media analytics and value creation in urban smart tourism ecosystems”. *Information & Management* 54(6): 703–713.
- Brandt, T., Wagner, S., and Neumann, D. (2021). “Prescriptive analytics in public-sector decision-making: A framework and insights from charging infrastructure planning”. *European Journal of Operational Research* 291(1): 379–393.
- Brauner, J. M., Mindermann, S., Sharma, M., Johnston, D., Salvatier, J., Gavenčiak, T., Stephenson, T. B., ... Kulveit, J. (2020). “Inferring the effectiveness of government interventions against COVID-19”. *Science* 371(6531): 9338.
- Campion, A., Gasco-Hernandez, M., Mikhaylov, S. J. and Esteve, M. (2020). “Overcoming the challenges of collaboratively adopting artificial intelligence in the public sector”. *Social Science Computer Review*.
- Chakraborty, T., and Ghosh, I. (2020). “Real-time forecasts and risk assessment of novel coronavirus (COVID-19) cases: A data-driven analysis”. *Chaos, Solitons & Fractals* 135: 109850.
- Chandra, R., Jain, A., and Chauhan, D. S. (2021). “Deep learning via LSTM models for COVID-19 infection forecasting in india”.
- Chimmula, V. K. R., and Zhang, L. (2020). “Time series forecasting of COVID-19 transmission in Canada using LSTM networks”. *Chaos, Solitons & Fractals* 135: 109864.
- Clarke, A., and Margetts, H. (2014). “Governments and citizens getting to know each other? Open, closed, and big data in public management reform”. *Policy & Internet* 6(4): 393–417.
- Coulton, C. J., George, R., Putnam-Hornstein, E., De Haan, B. (2015). “Harnessing Big Data for Social Good: A Grand Challenge for Social Work Initiative, Working Paper No. 11”. *American Academy for Social Work and Social Welfare*, 1–20.
- Delen, D. (2019). *Prescriptive analytics: The final frontier for evidence-based management and optimal decision making*. Pearson Education.
- Desouza, K. C., and Jacob, B. (2014). “Big data in the public sector: Lessons for practitioners and scholars”. *Administration & Society* 49(7): 1043–1064.

- Devaraj, J., Madurai Elavarasan, R., Pugazhendhi, R., Shafiqullah, G., Ganesan, S., Jeysree, A., Khan, I., and Hossain, E. (2021). "Forecasting of COVID-19 cases using deep learning models: Is it reliable and practically significant?" *Results in Physics* 21.
- Frazzetto, D., Nielsen, T. D., Pedersen, and T. B., Šikšnys, L. (2019). "Prescriptive analytics: A survey of emerging trends and technologies". *The VLDB Journal* 28(4):575–595.
- Gerber, M. S. (2014). "Predicting crime using twitter and kernel density estimation". *Decision Support Systems* 61: 115–125.
- Gillingham, P., and Graham, T. (2016). "Big data in social welfare: The development of a critical perspective on social works latest "Electronic turn"". *Australian Social Work* 70(2): 135–147.
- Glaeser, E. L., Hillis, A., Kominers, S. D., and Luca, M. (2016). "Crowdsourcing city government: Using tournaments to improve inspection accuracy". *American Economic Review* 106(5): 114–18.
- Hargittai, E. (2015). "Is bigger always better? Potential biases of big data derived from social network sites". *The ANNALS of the American Academy of Political and Social Science* 659(1): 63–76.
- Hasnat, B. (2018). "Big data: An institutional perspective on opportunities and challenges". *Journal of Economic Issues* 52(2): 580–588.
- Hawas, M. (2020). "Generated time-series prediction data of COVID-19s daily infections in Brazil by using recurrent neural networks". *Data in Brief* 32: 106175.
- Kapoor, A., Ben, X., Liu, L., Perozzi, B., Barnes, M., Blais, M., and O'Banion, S. 2020. "Examining COVID-19 forecasting using spatio-temporal graph neural networks". *CoRR* abs/2007.03113.
- Lai, S., Ruktanonchai, N. W., Zhou, L., Prosper, O., Luo, W., Floyd, J. R. Wesolowski, A.,... Tatem, A. J. (2020). "Effect of non-pharmaceutical interventions to contain COVID-19 in china". *Nature* 585(7825):410–413.
- Leipus, R., and Štikonienė, O. (2020). "Apibendrinto SEIR modelio taikymas covid-19 ilgalaikėms prognozėms", <http://www.lma.lt/uploads/COVIN-19/SEIR.pdf>; Žiūrėta 2020 06 09.
- Lepenioti, K., Bousdekis, A., Apostolou, D., and Mentzas, G. (2020). "Prescriptive analytics: Literature review and research challenges". *International Journal of Information Management* 50: 57–70.
- Liu, M., Thomadsen, R., and Yao, S. (2020). "Forecasting the spread of COVID-19 under different reopening strategies". *Scientific Reports* 10(1).
- Livera, A. M. D., Hyndman, R. J. and Snyder, R. D. (2011). "Forecasting time series with complex seasonal patterns using exponential smoothing". *Journal of the American Statistical Association* 106(496): 1513–1527.
- Maciejewski, M. (2016). "To do more, better, faster and more cheaply: Using big data in public administration". *International Review of Administrative Sciences* 83: 120–135.
- Matrajt, L., Eaton, J., Leung, T., and Brown, E. R., 2020. "Vaccine optimization for COVID-19: Who to vaccinate first?" *Science Advances* 7(6): 1374.
- Mohler, G. O., Short, M. B., Malinowski, S., Johnson, M., Tita, G. E., Bertozzi, A. L., and Brantingham, P. J. (2015). "Randomized controlled field trials of predictive policing". *Journal of the American Statistical Association* 110(512): 1399–1411.
- Muhammad Adnan Khan, K. M. K., Sagheer Abbas. (2020). *Computers, Materials & Continua* 64(3):1329–1342.
- Nair, H. S., Misra, S., Hornbuckle, W. J., Mishra, R., and Acharya, A. (2017). "Big data and marketing analytics in gaming: Combining empirical models and field experimentation". *Marketing Science* 36(5): 699–725.
- Narin, A., Kaya, C., and Pamuk, Z. 2021. "Automatic detection of coronavirus disease (COVID-19) using x-ray images and deep convolutional neural networks". *Pattern Analysis and Applications*.
- Oh, Y., Park, S., and Ye, J. C. (2020). "Deep learning COVID-19 features on CXR using limited training data sets". *IEEE Transactions on Medical Imaging* 39(8): 2688–2700.
- van Ooijen, C., Ubaldi, B., and Welby, B. (2019), "A data-driven public sector: Enabling the stra-

tegie use of data for productive, inclusive and trustworthy governance”, *OECD Working Papers on Public Governance*, No. 33, OECD Publishing, Paris.

Oreshkin, B. N., Carpov, D., Chapados, N., and Bengio, Y. 2019. “N-BEATS: neural basis expansion analysis for interpretable time series forecasting”. *CoRR* abs/1905.10437.

Pal, R.; Sekh, A. A.; Kar, S.; Prasad, D. K. Neural Network Based Country Wise Risk Prediction of COVID-19. *Preprints* 2020, 2020040421.

Papastefanopoulos, V., Linardatos, P., and Kotsiantis, S. (2020). “COVID-19: A comparison of time series methods to forecast percentage of active cases per population”. *Applied Sciences* 10(11).

Pencheva, I., Esteve, M., and Mikhaylov, S. J. (2018). “Big data and AI a transformational shift for government: So, what next for research?” *Public Policy and Administration* 35(1):24–44.

Perera, C., Zaslavsky, A., Christen, P., and Georgakopoulos, D. (2013). “Sensing as a service model for smart cities supported by internet of things”. *Transactions on Emerging Telecommunications Technologies* 25(1): 81–93.

Radulescu, A., Williams, C., and Cavanagh, K. (2020). “Management strategies in a SEIR-type model of COVID 19 community spread”. *Scientific Reports* 10(1).

Rogge, N., Agasisti, T., and Witte, K. D. (2017). “Big data and the measurement of public organizations’ performance and efficiency: The state-of-the-art”. *Public Policy and Administration* 32(4): 263–281.

Salinas, D., Flunkert, V., Gasthaus, J., and Januschowski, T. 2020. “DeepAR: Probabilistic forecasting with autoregressive recurrent networks”. *International Journal of Forecasting* 36(3): 1181–1191.

Santiago, A. M., and Smith, R. J. (2019). “What can “Big data” methods offer human services research on organizations and communities?” *Human Service Organizations: Management, Leadership & Governance* 43(4): 344–356.

Shapiro, A. (2017). “Reform predictive policing”. *Nature* 541(7638): 458–460.

Suganya, R., Arunadevi, R., and Buhari, S. M. 2020. “COVID-19 forecasting using multivariate linear regression”, *Research Square*.

Taylor, S. J., and Letham, B. 2017. “Forecasting at scale”. *PeerJ Preprints* 5: e3190v2.

Torky, M., Ahmed, M. Sh. A., Ella, A., and Said, W. (2020). “Investigating epidemic growth of COVID-19 in saudi arabia based on time series models”. *International Journal of Advanced Computer Science and Applications* 11(12).

Uddin, M. I., Shah, S. A. A. , Al-Khasawneh, M. A. , Alarood, A. A., and Alsolami, E. (2020). “Optimal policy learning for COVID-19 prevention using reinforcement learning”. *Journal of Information Science*: 016555152095979.

Villegas, M., Gonzalez-Agirre, A., Gutiérrez-Fandiño, A., Armengol-Estapé, J., Carrino, C. P., Fernández, D. P., Soares, F., Serrano, P., Pedrera, M., García, N., Valencia, A. (2020). “Predicting the evolution of COVID-19 mortality risk: A recurrent neural network approach”. *medRxiv*.

Wieczorek, M., Silka, J., Polap, D., Wozniak, M., and Damaševičius, R. (2020). “Real-time neural network based predictor for cov19 virus spread”. *PLoS ONE* 15:12.

Wu, K., Darcet, D., Wang, Q., and Sornette, D. (2020). “Generalized logistic growth modeling of the COVID-19 outbreak: Comparing the dynamics in the 29 provinces in china and in the rest of the world”. *Nonlinear Dynamics* 101(3): 1561–1581.

Yudistira, N. 2020. “COVID-19 growth prediction using multivariate long short term memory”. *CoRR* abs/2005.04809.

Zetino, J., and Mendoza, N. (2019). “Big data and its utility in social work: Learning from the big data revolution in business and healthcare”. *Social Work in Public Health* 34(5): 409–417.