

Marián Mešter

Simulácia elektrizačných sústav: od heuristiky ku kvantovému výpočtom

Abstrakt Energetické trhy čelia významným výzvam v dôsledku bezprecedentných technologických inovácií a rýchleho vývoja systémov, procesov a technológií potrebných na výrobu a dodávku energie na celom svete. Riadenie, kontrola a simulácia rozsiahlych a komplexných fyzikálno-kybernetických systémov ako sú elektrizačné sústavy predstavuje jednu z najväčších výziev súčasného priemyslu. Článok podáva základný prehľad budúcich technológií pre simuláciu elektrizačných sústav s dôrazom na nedeterministické postupy, heuristiky a neexaktné metódy riešenia. Ako najslubnejšie sa v súčasnosti javia kvantové technológie, ktoré môžu ponúknuť riešenia mnohých z týchto výziev. Kvantová komunikácia, simulácia, výpočty a snímanie pokročili za hranice laboratórií a postupne si ich osvojujú koncoví používatelia.

Kľúčové slová: heuristika, metódy simulácie a analýzy elektrizačných sústav, kvantové technológie, zložitosť

Abstract Energy markets are facing significant challenges due to unprecedented technological innovation and the rapid development of systems, processes and technologies needed to produce and deliver energy worldwide. The management, control and simulation of large-scale and complex physical-cyber systems such as power systems represents one of the greatest challenges facing the industry today. This paper gives a basic overview of future technologies for power system simulation with an emphasis on non-deterministic procedures, heuristics and non-exact solution methods. Quantum technologies appear to be the most promising at present and may offer solutions to many of these challenges. Quantum communication, simulation, computation, and sensing have advanced beyond the laboratory and are gradually being adopted by end-users. **(Simulation of power systems: from heuristics to quantum computing)**

Keywords: heuristics, power system simulation and analysis methods, quantum technologies, complexity

I. ÚVOD

Energetický priemysel prechádza bezprecedentnou technologickou inováciou a rýchly vývoj systémov, procesov a technológií, ktoré pomáhajú úspešným spoločnostiam vyvíjať a dodávať energiu na celom svete, predstavuje pre podniky významné výzvy. Zabezpečiť, aby všetky tieto zložky boli dobre integrované, dobre fungovali a prinášali výsledky, je náročná úloha.

Kvantová technológia je oblasť inovácií, ktorá v posledných rokoch priťahuje celosvetovú pozornosť. Dve iniciatívy, každá v hodnote jednej miliardy eur, boli nedávno spustené v rámci EÚ a USA. Podobné programy, všetky iniciované v poslednom desaťročí, existujú v Kanade, Japonsku, Austrálii, Spojenom kráľovstve, Rusku a Číne [1]. Celkové plánované investície prostredníctvom takýchto iniciatív na celom svete v súčasnosti predstavujú približne 20 miliárd Euro [2]. Hlavným cieľom týchto programov je uľahčiť prechod kvantových technológií z laboratória do praxe. Tieto snahy možno považovať za súčasť prebiehajúcej "druhej kvantovej revolúcie", ktorá zahŕňa rôzne technológie založené na kvantovej informatike. Kľúčové podoblasti kvantovej technológie sa zvyčajne definujú ako kvantová komunikácia/šifrovanie, kvantové výpočty/simulácie a kvantová metrologia/snímanie.

Kvantové technológie a kvantová veda sú dnes zaradzované medzi najzásadnejšie úspechy ľudskej spoločnosti v 20. storočí s významnými praktickými dôsledkami pre spoločnosť a hospodárstvo [1]. Samotná definícia kvantových technológií je veľmi diskutovaná a často nesprávne interpretovaná. Medzi základné myšlienky, vychádzajúce z kvantovej fyziky je možné zaradiť (i) superpozíciu, pri ktorej sa častica môže nachádzať v dvoch stavoch, resp. miestach

súčasne, (ii) kvantové previazanie, pri ktorom skupina častíc vznikne alebo spolu interaguje spôsobom, ktorý vylučuje, aby ich kvantové stavy boli popísané nezávisle, (iii) kvantové tunelovanie, pri ktorom častica porušuje princíp klasickej fyziky tým, že prechádza potenciálovou bariérou, ktorá je vyššia ako energia častice, alebo (iv) nahradenia absolútnej pravdy pravdepodobnostnými odhadmi.

II. KVANTOVÉ PRINCÍPY

Princípy kvantovej mechaniky spôsobili revolúciu v našom chápaní fyzikálneho sveta na základnej úrovni. Kvantová teória opisuje správanie sa hmoty a energie na atómovej a subatómovej úrovni a viedla k mnohým technologickým pokrokom v oblastiach, ako sú elektronika, telekomunikácie a výpočtová technika. Kvantová mechanika však môže byť aj neveriteľne kontraintuitívna, pretože porušuje mnohé naše klasicke intuície o svete. Hlavným cieľom kvantovej technológie je poskytnúť praktické aplikácie a zariadenia, ktoré využívajú princípy kvantovej mechaniky, medzi ktoré patria:


- Kvantovanie, postup systematického prechodu od klasického chápania fyzikálnych javov k novšiemu chápaniu známemu ako kvantová mechanika. Je to postup konštrukcie kvantovej mechaniky z klasickej mechaniky.
- Princíp neurčitosti, ktorý hovorí, že pre každý daný kvantový stav existuje vždy aspoň jedno meranie s úplne istým výsledkom a aspoň jedno meranie s prevažne náhodným výsledkom.
- Kvantová superpozícia, ktorá umožňuje, aby systém existoval vo viacerých stavoch súčasne.
- Tunelovanie, čo je schopnosť častice nachádzať sa v oblastiach, ktoré sú podľa klasickej mechaniky normálne zakázané.

- Kvantové previazanie, čo je nelokálna korelácia medzi kvantovými systémami, kde stav systému je superpozíciou všetkých možných korelácií.
- Dekoherencia, ku ktorej dochádza pri meraní kvantovej superpozície, ktorá sa stáva superpozíciou klasických pravdepodobností. Tento jav je jedinečný pre kvantovú mechaniku a nemá klasickú analógiu.

Hoci týmto princípom rozumieme už mnoho desaťročí, len nedávno sa podarilo skonštruovať zariadenia podľa týchto princípov. Okrem základných princípov kvantovej mechaniky si kvantová technológia bude vyžadovať súbor špecifických nástrojov, ktoré sú generické: kvantová metrologia, kvantové riadenie, kvantová komunikácia a kvantové výpočty [3].

III. KVANTOVÉ TECHNOLOGIE

V rámci hlavného výskumného projektu európskej vlajkovej iniciatívy EÚ Quantum Flagship [4] boli identifikované štyri základné oblasti kvantového výskumu a vývoja (obr. 1).



Obr. 1. Štruktúra oblastí výskumu kvantových technológií [4]

Kvantová komunikácia. Význam zabezpečenia našej spoločnosti založenej na informáciách rýchlo rastie. Z dlhodobého hľadiska je nevyhnutné bezpečne spravovať údaje pri prenose aj v pokoji, pretože to má mimoriadny význam nielen pre spoločnosť a hospodárstvo, ale aj pre našu infraštruktúru, služby, prosperitu a politickú stabilitu. Riziká spojené s týmito faktormi sa ešte znásobujú vznikom technologických hrozieb, ako je napríklad vývoj kvantových počítačov, ktoré spôsobujú zraniteľnosť bežne používaných asymetrických kryptografických algoritmov a predstavujú systémovú hrozbu pre dlhodobú bezpečnosť. Kvantová komunikácia poskytuje riešenia, ktoré možno bez problémov integrovať do existujúcej infraštruktúry a protokolov a zároveň vytvára nové možnosti uplatnenia.

Kvantové výpočty. S rastúcou zložitou energetických systémov zvyčajne exponenciálne rastie množstvo prostriedkov potrebných na reprezentáciu ich stavov na klasickom počítači. Kvantové počítače však majú potenciál reprezentovať tieto stavy pomocou polynomiálneho škálovania. Okrem toho, vysoko previazané stavy, ktorých modelovanie je pre klasické počítače mimoriadne náročné, sa dajú ľahko reprezentovať na kvantových počítačoch. To naznačuje, že zložité problémy energetických systémov, ktoré sa v súčasnosti považujú za náročné aj pre pokročilé simulátory v reálnom čase alebo vysoko výkonné počítače, by sa pri vhodnej formulácii mohli na kvantových počítačoch riešiť oveľa efektívnejšie [4].

Kvantová simulácia. Myšlienka kvantovej simulácie siaha až k Richardovi Feynmanovi, ktorý navrhol, že interagujúce kvantové systémy by sa mohli efektívne simulovať s využitím iných presne ovládateľných kvantových systémov, a to aj v mnohých prípadoch, v

ktorých sa očakáva, že takáto simulačná úloha bude pre štandardné klasické počítače neefektívna [5]. Vo všeobecnosti si simulácia kvantových systémov pomocou klasických metód vyžaduje veľké množstvo zdrojov, keďže veľkosť základného Hilbertovho priestoru rastie exponenciálne s veľkosťou systému. Toto škálovanie je však možné upraviť použitím vhodných reprezentácií kvantového stavu, ktoré sú použiteľné v konkrétnych situáciách. Podobne aj hľadanie riešení niektorých klasických optimalizačných problémov - najmä tých, ktoré sú **NP-ťažké** alebo **NP-úplné** si môže vyžadovať exponenciálne zdroje. Našťastie existujú numerické techniky, ako sú tenzorové siete, renormalizačná skupina matíc hustoty a kvantové vzorkovanie Monte Carlo, ktoré môžu za určitých okolností pomôcť pri výpočte vlastností základného stavu. Napriek tomu sú tieto klasické simulačné metódy často obmedzené pri ich aplikácii na špecifické triedy problémov. Napríklad veľkosti systémov, ktoré možno numericky študovať na klasických počítačoch, sú zvyčajne pomerne malé a je nepravdepodobné, že tieto klasické nástroje budú dostatočne robustné na to, aby poskytli dôkladné pochopenie zložitosti spojených s kvantovými javmi mnohých telies [3,6].

Kvantové snímanie/metrologia. Kvantové senzory majú potenciál významného a rozsiahleho vplyvu. K dispozícii sú rôzne platformy, ktoré umožňujú kvantové meranie času, priestoru, rotácie, ako aj gravitačných, elektrických a magnetických polí. Tieto technológie sa uplatňujú v dôležitých oblastiach, ako je fyzika, chémia, biológia, medicína a ukladanie a spracovanie údajov.

IV. TEÓRIA ZLOŽITOSTI

Riadenie, kontrola a simulácia takých rozsiahlych a komplexných fyzikálno-kybernetických systémov ako sú elektrizačné sústavy predstavuje jednu z najväčších výziev súčasného priemyslu. V kontexte analýzy zložitosti takýchto sústav je dôležité objasniť si, s akým druhom zložitosti máme dočinenia. V prvej polovici 20. storočia si vedci pri konštrukcii nových algoritmov začali uvedomovať, že nie každá úloha má rovnakú časovú náročnosť riešenia a že medzi úlohami existujú veľké rozdiely. Výpočtové zariadenia, ktoré navrhnuté algoritmy spracovávajú majú jednak obmedzenú veľkosť pamäte, ako aj maximálnu rýchlosť realizácie vykonávaných inštrukcií. Navrhované algoritmy preto musia byť prispôbované pre výpočtové zariadenia, aby ich chod bol čo najefektívnejší. Aj napriek snahe odborníkov sa ale pre niektoré typy úloh nepodarilo žiadny efektívny algoritmus nájsť. Jednou z dôležitých tém teoretickej informatiky sa preto stala otázka, čo robí tieto úlohy takými zložitými a či nejaký efektívny algoritmus môže existovať [7, 8].

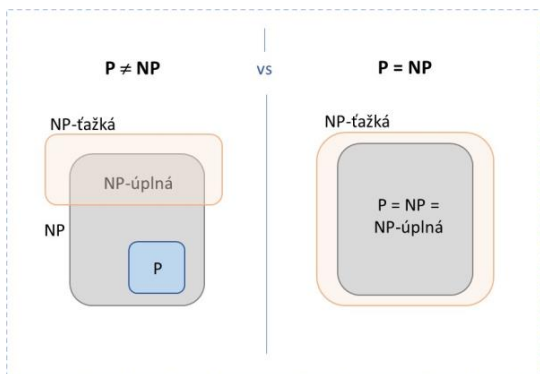
Pod pojmom teória zložitosti rozumieme časť teoretickej informatiky zaoberajúcu sa množstvom požadovaných zdrojov potrebných pre výpočet daného problému. Najčastejšou metrikou je čas (koľko krokov je potrebných na vyriešenie problému) a priestor (koľko pamäti je potrebnej na vyriešenie problému). Teória zložitosti sa odlišuje od teórie vypočítateľnosti, ktorá skúma len či sa problém dá vyriešiť alebo nie, bez uvažovania o potrebných zdrojoch.

Problém sa považuje za prirodzene zložitý, ak jeho riešenie vyžaduje rozsiahle zdroje, bez ohľadu na použitý algoritmus. Teória formalizuje túto intuíciu zavedením matematických modelov výpočtov na štúdium týchto problémov a kvantifikáciou ich výpočtovej zložitosti, t.j. množstva zdrojov potrebných na ich vyriešenie, ako je čas a skladovanie. Používajú sa aj iné miery zložitosti, ako je množstvo komunikácie (používané pri zložitosti komunikácie), počet brán v obvode (používané pri zložitosti obvodu) a počet procesorov (používané pri paralelných výpočtoch) [7, 8].

Stupeň zložitosti modelovania elektrizačnej sústavy bol analyzovaný napr. v [9]. Autori analyzovali problém nasadenia decentralizovaných OZE (obnoviteľných zdrojov energie). Cieľom analýzy bola identifikácia (ekonomicky) optimálneho energetického systému, teda najlepší možný výber technológií pre konverziu energie s optimálnymi rozmermi výrobných jednotiek a súčasne zohľadnenie ich optimálnej prevádzky. Autori hľadali odpovede na otázky (i) koľko energetických výrobných jednotiek a akého typu treba postaviť, (ii) ako nastaviť ich technické špecifikácie, napríklad kapacitu, (iii) ako majú byť jednotky prevádzkované v každom prípade zaťaženia. Tieto tri úrovne rozhodnutí sa ovplyvňujú navzájom, a tak sa globálne optimálne riešenia dajú dosiahnuť iba vtedy, ak sú všetky tri úrovne zohľadnené súčasne v rámci integrovaného optimalizačného prístupu.

Autori [9] podávajú matematický dôkaz, že „neexistuje žiadny algoritmus s polynomiálnym časom, teda žiadny efektívny, na riešenie problému nasadzovania decentralizovaných energetických systémov, pokiaľ neplatí $P = NP$. Navyše dokazujú, že „neexistuje žiadny algoritmus s polynomiálnym časom, ktorý by zaručoval konštantný faktor aproximácie pre uvažovaný problém syntézy, pokiaľ neplatí $P = NP$.“

Dve najčastejšie používané triedy zložitosti sú trieda P a trieda NP . Obe sú definované ako triedy zahrňujúce rozhodovacie problémy, ktoré sa dajú riešiť v polynomiálnom čase. Hlavný rozdiel spočíva v tom, že pre algoritmy z triedy P existuje riešiaci algoritmus pre deterministický Turingov stroj, zatiaľ čo pre triedu NP existuje takýto algoritmus len pre nedeterministický Turingov stroj. Deterministický Turingov stroj je taký stroj, ktorý v každom okamihu zaberá práve jeden stav. U nedeterministického Turingovho stroja toto obmedzenie neplatí a stroj môže zaberat ľubovoľný počet vnútorných stavov súčasne. Je zrejme, že deterministický stroj je len špeciálnym prípadom nedeterministického stroja, a preto všetky problémy z triedy P sú zároveň aj v triede NP (obr. 2).



Obr.2 Grafická reprezentácia problému $P=NP$

V teórii zložitosti je NP (nedeterministický polynomiálny čas) trieda zložitosti používaná na klasifikáciu rozhodovacích problémov. NP je množina rozhodovacích problémov, pre ktoré majú príklady problémov, kde je odpoveď „áno“, dôkazy overiteľné v polynomiálnom čase deterministickým Turingovým strojom, alebo alternatívne množina problémov, ktoré možno vyriešiť v polynomiálnom čase nedeterministickým Turingovým strojom. Polynomiálny čas označuje, ako rýchlo rastie počet operácií potrebných pre algoritmus v pomere k veľkosti problému. Ide teda o mieru účinnosti algoritmu.

NP je množina rozhodovacích problémov riešiteľných v polynomiálnom čase nedeterministickým Turingovým strojom.

NP je súbor rozhodovacích problémov overiteľných v polynomiálnom čase deterministickým Turingovým strojom.

Prvá definícia je základom pre skratku NP . Tieto dve definície sú ekvivalentné, pretože algoritmus založený na Turingovom stroji pozostáva z dvoch fáz, z ktorých prvá pozostáva z odhadu riešenia, ktorý je generovaný nedeterministickým spôsobom, zatiaľ čo druhá fáza pozostáva z deterministického algoritmu, ktorý overuje, či hádanie je riešením problému. [9]


Z obrázka vidieť, že trieda zložitosti P (všetky problémy riešiteľné, deterministicky, v polynomiálnom čase) je obsiahnutá v NP , pretože ak je problém riešiteľný v polynomiálnom čase, potom riešenie je tiež overiteľné v polynomiálnom čase jednoduchým riešením problému. Ale NP obsahuje oveľa viac problémov a najťažšie z nich sa nazývajú NP -úplné problémy. Algoritmus riešiaci takýto problém v polynomiálnom čase je tiež schopný vyriešiť akýkoľvek iný NP problém v polynomiálnom čase. Najdôležitejšia otázka problému P verus NP (teda či „ $P = NP$?“) sa dá zformulovať nasledovne: existujú polynomiálne časové algoritmy na riešenie NP -úplných, a teda všetkých NP problémov? Všeobecne sa verí, že to tak nie je.

Práca [9] dokazuje, že (i) už problém prevádzky jednej výrobnej energetickej jednotky patrí do triedy (slabá) NP -ťažká. Ďalej dokazuje, že (ii) problém nasadenia viacerých jednotiek OZE je (silne) NP -ťažká. Keďže sa navyše uvažuje aj so zohľadnením nákladov, ukazuje sa, že (iii) je dokonca ťažké aproximovať optimálne riešenie konštantným aproximáčnym faktorom. Analyzované práce [10], [11], [12] poskytujú pevne zakotvené dôkazy o výpočtovej zložitosti prevádzky elektrizačných sústav. Zverejnené výsledky odôvodňujú používanie a vývoj heuristik a algoritmov s exponenciálnym časom na výpočet realizovateľných riešení alebo dokonca na optimálne alebo približné riešenie problému nasadzovania OZE.

Teoretický popis zložitosti algoritmu a klasifikácia problémov do vhodných tried je stále aktuálna vedecká téma. Na základe nových výskumov sa neustále definujú nové triedy zložitosti, ktoré zoskupujú problémy podľa potrebných vlastností. Aktuálny zoznam tried je možné nájsť napríklad na stránkach komunitného projektu [13], kde je v súčasnosti uvedených až 495 rôznych tried zložitosti. Tieto triedy sa líšia typom výsledku, časovou a priestorovou náročnosťou, typom Turingovho stroja a ďalšími vlastnosťami.

V. METÓDY RIEŠENIA

Z uvedeného je zrejme, že pre rôzne úlohy existujú rôzne náročné spôsoby riešenia. Existujú dokonca úlohy, pre ktoré v súčasných možnostiach neexistuje žiadny efektívny spôsob riešenia. Mnoho reálnych aj teoretických problémov však vyžaduje nájsť riešenie aj pre takto zložitú úlohu, preto ich nemožno ponechať bez pozornosti. Ak sa zameriame len na problémy spojené s optimalizáciou, môžeme identifikovať niekoľko rôznych prístupov k ich riešeniu (obr. 3).



Obr.3 Rozdelenie algoritmov (metód riešenia) spojených s optimalizáciou

Exaktné algoritmy (deterministické metódy). Cieľom simulácie reálneho systému je vytvorenie algoritmov, ktorých výstupom je

požadovaný výsledok a ktoré ho dokážu spoľahlivo a opakovane dosiahnuť. Avšak takýto algoritmus nemusí byť vôbec nájdený, alebo jeho náročnosť môže byť taká vysoká (časová alebo priestorová), že je prakticky nepoužiteľný. Exaktné algoritmy vychádzajú vždy z presného porozumenia tvorby stavového priestoru. Musia byť vždy známe vlastnosti jednotlivých riešení a vzťahy medzi nimi. Ak je účelová funkcia popísaná analyticky s existujúcou deriváciou, potom môžeme ľahko nájsť všetky jej stacionárne body (body, v ktorých má funkcia nulovú deriváciu.), a tým následne odhaliť aj to, kde sa nachádza optimum. Táto úloha však nie je vždy triviálna, ale vďaka poznaniu funkčného predpisu pre celý definovaný obor môžeme spozorovať ich zákonitosti, z ktorých môžeme odvodiť všetko potrebné [8]. Niekedy však derivácia nie je z niektorých dôvodov užitočná. Pri úlohe lineárneho programovania je účelová funkcia síce analyticky popísaná a derivácia existuje na celom definovanom obore, ale nikde nie je nulová. Neexistujú v nej žiadne stacionárne body a optimum sa nachádza v niektorom z rohov oblasti určenej obmedzujúcimi podmienkami. Vďaka znalosti zákonitostí lineárneho programovania však existujú algoritmy, ktoré presné riešenie vždy nájdu. Príkladom môže byť známy simplexový algoritmus, ktorý postupne prechádza spomenuté rohové body, kým nenájde hľadané optimum. Akonáhle algoritmus nájde lokálne optimum, môže výpočet ukončiť, pretože v lineárnej optimalizácii je lokálne optimum zároveň aj globálne [8].

Existuje mnoho exaktných prístupov k optimalizácii, ktoré zaručujú nájdenie optimálnych hodnôt, ale všetky vyžadujú hlboké štúdium a náročnú matematickú prácu, ktorá však v praktických aplikáciách nemusí byť vždy rentabilná. Za exaktnú metódu je možné označiť aj jednoduché prehľadávanie všetkých možných bodov stavového priestoru. Takzvané prehľadávanie hrubou silou je účinný nástroj pre rýchle riešenie malých úloh. Avšak počet možností zložitejších úloh môže rásť tak rýchlo, že by takéto prehľadávanie prekročilo únosnú mieru.

Takmer exaktné algoritmy. Do tejto skupiny možno zaradiť veľmi široké spektrum algoritmov. Ich spoločným rysom je, že nájdené riešenia nie sú úplnými optimami, ale pohybujú sa niekde v blízkosti. Konkrétna vzdialenosť od optimálneho riešenia nemusí byť presne definovaná, ale mala by byť nejakým spôsobom riaditeľná. Pred spustením algoritmu si teda používateľ zvolí, akú chybu je ochotný tolerovať a algoritmus mu ju zaručí.

Jeden z najstarších algoritmov tohto typu je metóda bisekcie. Klasická numerická metóda pre hľadanie nulových bodov spojitej funkcie funguje na princípe iteratívneho zúženia intervalu, v ktorom sa môže nachádzať nulový bod. Za predpokladu, že spojitá funkcia má práve jeden nulový bod, algoritmus postupným overovaním znamienok funkčných hodnôt v poloviciach uvažovaného intervalu dokáže dospieť k veľmi malej chybe riešenia. Chyba je priamo riaditeľná ukončovacou podmienkou, teda ak je dĺžka deleného intervalu menšia ako preddefinované, algoritmus výpočet ukončí. Táto chyba sa však týka iba maximálnej vzdialenosti od hľadaného bodu v definičnom obore funkcie, nie však funkčnej hodnoty samotnej. Priamou aplikáciou metódy bisekcie na optimalizačné problémy môže byť hľadanie nulových bodov derivácie účelovej funkcie. Riadenie maximálnej odchýlky od optima z hľadiska funkčných hodnôt však tak priamo nie je dosiahnuteľné a musia byť použité iné metódy.

Veľkú množinu úloh je možné riešiť aj pomocou pravdepodobnosti prostredníctvom (pseudo)náhodných čísel, teda tzv. pravdepodobnostných algoritmov. Príkladom je už spomenutá metóda Monte Carlo, ktorá generuje náhodné riešenia s rovnakou

pravdepodobnosťou v celom stavovom priestore a vyberá z nich to najlepšie. Pri konečnom behu algoritmu však nie je garantované, že algoritmus nájde optimum v priestore s nekonečným množstvom bodov. To nie je možné zaručiť ani pre priestory s konečným množstvom bodov, pretože vždy existuje šanca, že použitý zdroj náhodných čísel sa bude vyhybať hľadanému optimu. S dostatočne dlhým časom však možno dosiahnuť hodnotu pravdepodobnosti nájdenia $p = 1$ alebo veľmi blízku tejto hodnote. Metóda Monte Carlo má vopred definovaný rozsah použiteľných zdrojov (čas, počet vyskúšaných bodov atď.), a preto nie je garantované nájdenie optimálneho riešenia. Obdobou tejto metódy, ale s garantovaným nájdením riešenia, je metóda Las Vegas. Tá však naopak nemá predom známy čas svojho behu a môže tak "skĺznuť" až k úplnému prehľadávaniu celého stavového priestoru.

Neexaktné metódy. Ide o také metódy, ktoré nie sú založené na žiadnom exaktno overiteľnom postupe a nemôžu tak garantovať žiadne výsledné vlastnosti nájdených riešení. Tieto metódy vznikajú z dvoch hlavných dôvodov. Buď pre daný problém neexistuje nič presnejšie, alebo exaktnější spôsob riešenia by vyžadoval príliš veľa úsilia. Typickým zástupcom týchto metód sú jednoúčelové heuristiky. V priebehu histórie ľudia veľmi často riešili problémy pomocou metód, ktoré vznikli zo skúseností predchádzajúcich generácií a jednoducho fungovali. Pri heuristikách teda nie možné z metódy identifikovať, akú kvalitu riešenia poskytuje, teda napríklad ako ďaleko je riešenie od optima. Kvalitu takéhoto riešenia posúdi až výsledok (užívateľ). Ak je užívateľ spokojný a riešenie mu vyhovuje, pravdepodobne použije heuristiku aj na budúce [8]. Príkladom takýchto heuristik môže byť hladový algoritmus (greedy search), ktorý napríklad rieši problém obchodného cestujúceho prechádzaním miest v poradí najbližších susedov. Začína teda v jednom meste, potom sa presúva do najbližšieho a tak ďalej, kým sa nevráti späť na začiatok.

Iným smerom sa rozhodli ísť tzv. softcomputingové metódy. Ide o niekoľko samostatných algoritmičných tried, ktoré sa vyznačujú veľkou všeobecnosťou, robustnosťou a hlavne toleranciou k nepresnostiam výsledku aj zadania. Používajú sa predovšetkým pre úlohy triedy **NP-úplná** a zložitejších a ich snahou je poskytovať dostatočne dobré riešenia v polynomiálnom čase.

Zástupcom softcomputingových metód sú umelé neurónové siete. Ich modelom sú biologické princípy objavené pri skúmaní fyziológie mozgu a procesu myslenia. Ľudský mozog tvoria miliardy jednoduchých neurónových buniek, ktoré sú navzájom prepojené a schopné prenášať si elektrické impulzy. Každá bunka je pripojená na niekoľko susedných, a ak jej sú cez neurónové spojenia prenášané nejaké impulzy, tak všetky prichádzajúce sčíta a pošle ďalej. Vďaka nepravidelnej topológii buniek vznikajú veľmi zložité spojenia, ktoré mozgu poskytujú schopnosť vnímania a spracovania informácií. Umelé neurónové siete, ktoré zjednodušujú biologický model a sprostredkovávajú implementačnú logiku, boli preto pôvodne vyvíjané pre rozpoznávacie a klasifikačné aplikácie. Priebeh výpočtu ovplyvňuje topológia zapojenia buniek a váhy priradené jednotlivým spojeniam medzi bunkami. Pre každú úlohu je tak potrebné nájsť najvhodnejšiu topológiu, váhy a systém reprezentácie zadania a riešenia. Aj keď pôvodnou aplikačnou oblasťou neurónových sietí boli klasifikačné a aproximačné úlohy, dnes sa používajú pre celý rad úplne odlišných úloh, vrátane optimalizácie [14].

Medzi ďalšie neexaktné metódy možno zaradiť fuzzy matematiku, ktorá sa stala obľúbeným nástrojom na rozširovanie už existujúcich výpočtových postupov. V kategórii softcomputingu je však zväčša zaradená iba jedna z ich špeciálnych aplikácií - fuzzy logika. Prístup

fuzzy matematiky spočíva v práci so všeobecnými pojmami, ako sú napríklad "blízko", "ďaleko", "rýchly", "pomalý", atď. Fuzzy logika definuje odvodzovacie pravidlá pre tieto pojmy, ako napríklad: ak je objekt blízko a pohyb je rýchly, potom čas je krátky. Fuzzy logika je samotná o sebe exaktne definovanou matematickou disciplínou, no to, čo ju robí neexaktnou, sú práve fuzzy pojmy, ktoré umožňujú definovať neexaktné odvodzovacie pravidlá.

Treťou témou softcomputingu sú metaheuristické algoritmy. Zjednodušene povedané, metaheuristiky poskytujú rozumný spôsob prehľadávania veľkých stavových priestorov s významnou pomocou hrubej výpočtovej sily [14].

VI. HEURISTICKÉ METÓDY V ENERGETIKE

V oblasti energetiky sa (meta)heuristická optimalizácia aplikuje na riešenie mnohých problémov týkajúcich sa prevádzky, plánovania, riadenia, prognózovania, spoľahlivosti, bezpečnosti apod. Súbor typických problémov, ktoré sa riešia pomocou metaheuristickej optimalizácie je uvedený v Tab.1.

TABUĽKA I

Najpoužívanejšie metaheuristické algoritmy používané na riešenie vybraných typov problémov v energetike [15,16, 17]

Oblasť nasadenia v energetike	Najpoužívanejšie metaheuristiky
Problém nasadzovania výrobných jednotiek	Genetický algoritmus, optimalizácia roja častíc, evolučné algoritmy
Obchodný dispečing	Genetický algoritmus, optimalizácia roja častíc, diferenciálna evolúcia, evolučné algoritmy
Optimálne rozdelenie tokov výkonu	Genetický algoritmus, optimalizácia roja častíc, evolučné algoritmy, diferenciálna evolúcia
Rekonfigurácia distribučných systémov	Genetický algoritmus, optimalizácia roja častíc, simulované žihanie, optimalizácia kolónie mravcov
Plánovanie rozširovania prenosových sústav	Genetický algoritmus, simulované žihanie, vyhľadávanie tabu, optimalizácia roja častíc
Plánovanie distribučnej sústavy	Genetický algoritmus, vyhľadávanie tabu, optimalizácia roja častíc
Predpoveď výroby a spotreby	Genetický algoritmus, optimalizácia roja častíc, evolučné algoritmy, simulované žihanie
Plánovanie údržby	Genetický algoritmus, simulované žihanie, optimalizácia roja častíc, vyhľadávanie tabu

Z tohto súboru problémov vyplýva, že genetický algoritmus je najpoužívanejšou alebo najčastejšie spomínanou metódou pre všetky problematiky, po ktorej nasleduje optimalizácia časticovým rojom (alebo simulované žihanie v dvoch prípadoch, alebo tabu vyhľadávanie v ďalšom prípade). Vo všeobecnosti však platí, že záleží na veľkosti problému. Ak je veľkosť problému limitovaná a prehľadávanie stavového priestoru mohlo byť uskutočniteľné, alebo nástroje matematického programovania sú schopné poskytnúť presné riešenia, potom použitie metaheuristického algoritmu nie je odôvodnené. Jedinou výnimkou je prípad, keď sa metaheuristický algoritmus testuje na probléme so známym globálnym optikom na overenie jeho účinnosti pri hľadaní globálneho optima pred použitím na rozsiahle problémy. Ak algoritmus nedokáže nájsť globálne optimum pri riešení problému malej veľkosti (napr. so stovkami alebo

tisícami krokov), potom bude jeho implementácia pravdepodobne neúčinná.

VII. NEKONVENČNÉ VÝPOČTOVÉ ZARIADENIA

Opísané metódy a algoritmy sú navrhované pre klasické počítače. Existujú však aj iné spôsoby, ako získať potrebnú výpočtovú kapacitu. Ak neberieme do úvahy paralelné superpočítače a podobné rozšírenia konvenčných strojov, potom je možné dosiahnuť zaujímavé výsledky aj pomocou úplne odlišných výpočtových paradigiem.

Fotonické počítače [18], [19] napríklad dokážu riešiť grafické úlohy, ako je nájdenie Hamiltonovej kružnice alebo problému obchodného cestujúceho pomocou vzájomne prepojených optických káblov. Problém obchodného cestujúceho je riešený tak, že mestá sú reprezentované fyzickými uzlovými bodmi a vzdialenosti medzi nimi sú reprezentované pomerne dlhými optickými kábovými spojeniami. V počiatočnom meste je vybudovaný svetelný impulz a v každom uzlovom bode je svetlo unikátne označené a rozoslané do všetkých ostatných pripojených miest. V počiatočnom uzle sa potom meria, kedy dorazí prvý svetelný impulz označený všetkými uzlami.

Ďalším nekonvenčným prístupom vytvoreným špeciálne na riešenie úloh s rozsiahlym stavovým priestorom je tzv. **biocomputing**, alebo **biologické počítače**. Do tejto skupiny je možné zaradiť DNA počítače a organoidnú inteligenciu. DNA počítače [18] fungujú na princípe miešania veľkého objemu deoxyribonukleovej kyseliny (DNA). DNA je biologická makromolekula, ktorá sa skladá z dlhého lineárneho reťazca základných stavebných prvkov (nukleotidov). Tieto prvky je možné umelo spájať podľa jednoduchých pravidiel a vytvárať tak zložitejšie štruktúry. Problém obchodného cestujúceho je teda možné riešiť jednou veľkou nádobou naplnenou DNA rôznych typov. Každému mestu zodpovedá jeden typ DNA a miešaním tekutiny sa jednotlivé typy môžu spájať. Pri dostatočnom premiešaní dostatočne veľkého objemu DNA je vysoká pravdepodobnosť, že vznikne veľa rôznych postupností miest. Potom stačí iba prefiltrovať tie DNA, ktoré obsahujú každé mesto iba raz, a vybrať z nich tú najkratšiu. DNA počítače fungujú na princípe obrovského paralelizmu, no pre veľké úlohy sa tento postup tiež stretáva s problémami (hmotnostná bariéra, chybovosť výroby DNA, nedostatočné premiešanie atď.).

Nedávne pokroky v oblasti mozgových organoidov odvodených z ľudských kmeňových buniek sľubujú reprodukciu kritických molekulárnych a bunkových aspektov učenia a pamäti a možno aj aspektov kognície in vitro. V [18] autori navrhli termín **organoidná inteligencia** (OI), ktorý pokrýva tento nový multidisciplinárny obor. Cieľom je ustanoviť organoidnú inteligenciu ako formu skutočného biologického výpočtu, ktorý využíva mozgové organoidy pomocou vedeckých a bioinžinierskych pokrokov eticky zodpovedným spôsobom. OI využíva samoorganizujúce sa mechanizmy 3D kultúr ľudských mozgových buniek (mozgové organoidy) na zapamätanie a výpočet vstupov. Mozgové organoidy lepšie opisujú architektúru a funkčnosť orgánov ako tradičné 2D kultúry. Môžu obsahovať myelinizované axóny a preukazujú nielen spontánnu elektrickú aktivitu, ale tiež prejavujú komplexné oscilačné správanie a prezentujú vysokú hustotu buniek a vzorov vrstvenia, čo ich robí lepšími než tradičné monovrstvové kultúry.

Ľudský mozog je pri porovnaní so výpočtovou technikou pomalší pri spracovaní jednoduchých informácií, ako je napríklad aritmetika, ale ďaleko prevyšujú stroje v spracovaní zložitých informácií, pretože mozog si lepšie poradí s malým počtom a/alebo neistými údajmi. Mozog dokáže vykonávať sekvenčné aj paralelné spracovanie (zatiaľ čo klasické počítače dokážu len to prvé) a prekonávajú počítače pri rozhodovaní o veľkých, vysoko heterogénnych a neúplných súboroch údajov a iných náročných formách spracovania. Spracovateľský výkon mozgu ilustruje pozorovanie, pri ktorom štvrtý najväčší počítač na svete potreboval 40 minút na modelovanie 1 sekundy 1 % činnosti ľudského mozgu [19]. Okrem toho má každý mozog pamäťovú kapacitu odhadovanú na 2 500 TB, na základe jeho 86 - 100 miliárd neurónov, ktoré majú viac ako 10^{15} spojení.

Základné rozdiely medzi biologickým a strojovým učením v mechanizmoch implementácie a ich cieľoch vedú k dvom drasticky odlišným dopadom na efektívnosť. Po prvé, biologické učenie využíva oveľa menej energie na riešenie výpočtových problémov. Napríklad larva ryby Danio pružkovanej (Danio rerio) spotrebúva pri pohybe a navigácii energiu iba 0,1 mikrowattu, zatiaľ čo dospelý človek spotrebuje 100 wattov, z čoho spotreba mozgu predstavuje 20 % [18, 19]. Naopak, klastre používané na zvládnutie najmodernejších modelov strojového učenia zvyčajne pracujú s výkonom okolo 106 W. Pre porovnanie parametre superpočítača Frontier, ktorý dosahuje 1102 petaFlopsov: spotreba energie tohto nového (2022) superpočítača je 21 megawattov, pričom ľudský mozog pracuje s odhadovanou rovnakou spotrebou 1 exaFlop a spotrebuje len 20 wattov [19].

Kvantové počítače predstavujú najrozsiahlejšiu, najkomplexnejšiu a v tomto okamihu aj najslubnejšiu oblasť nekonvenčných výpočtových zariadení.

VIII. KVANTOVÉ VÝPOČTY V ENERGETIKE

V oblasti prenosu a distribúcie elektriny existujú dve základné výzvy: (i) súčasné výpočtové možnosti energetických sietí nedokážu zvládnuť obrovské množstvo generovaných údajov a príkazov potrebných na prevádzku prepojených sietí v reálnom čase, (ii) existujúce algoritmy analýzy vrátane pravdepodobnostného toku energie a programu elektromagnetických prechodných javov nedokážu poskytnúť hodnoverné výsledky v reálnom čase, ktoré sú potrebné na riadenie rozsiahlych distribuovaných zdrojov energie a zabezpečenie odolnej prevádzky, a to z dôvodu bezprecedentných výpočtových požiadaviek, ktoré ich robia neškálovateľnými [20]. Ako bolo už uvedené, komplexné stavy energetických systémov je ťažké reprezentovať na klasických počítačoch, pretože veľkosť problému exponenciálne narastá. Na kvantovom počítači sa však rozsah problému dá reprezentovať polynomiálne. To znamená, že problémy energetických systémov, ktoré sú v súčasnosti neriešiteľné na výkonných a drahých simulátoroch v reálnom čase alebo vysokovýkonných počítačoch, môžu byť oveľa lepšie riešiteľné na kvantových počítačoch, ak sú správne formulované. Prehľad hlavných komerčne dostupných poskytovateľov a platforiem kvantových počítačov uvádza viac ako 30 globálnych hráčov (2022) [21].

Kvantové počítače sú schopné vytvárať a udržiavať zložité superpozície kvantových stavov v mnohých kvantových stupňoch voľnosti, ako aj umožniť previazanie medzi stavmi v systéme. V dôsledku toho majú mnohé modely kvantových počítačov potenciál dosiahnuť exponenciálne zlepšenie rýchlosti spracovania v porovnaní s klasickými modelmi. Súčasný vývoj kvantových technológií v energetike je možné rozdeliť do štyroch základných smerov (obr.

4.): kvantový hardvér, základná analytika elektrizačnej sústavy, prevádzka elektrizačnej sústavy a komunikačná bezpečnosť.



Obr.4 Schématický prehľad kvantových technológií v energetike [20, 22]

V oblasti výpočtov a simulácii elektrizačnej sústavy bol dosiahnutý významný pokrok a základné analytické postupy pre výpočty ustáleného stavu sústavy, ako aj prechodné deje boli teoreticky odvodené. V tab.II je uvedený prehľad základných výpočtových analytík pre riešenie elektrizačných sústav, ku ktorým už bol odvodený teoretický základ na báze kvantových technológií.

TABUĽKA II

Základné analytické postupy a algoritmy pre prevádzku elektrizačných sústav založené na báze kvantových technológií (2022)

A Kvantové výpočty pre základnú analýzu elektrizačnej sústavy	
A1 Kvantová statická analýza	A11 Kvantový výpočet ustáleného stavu
	A12 Kvantová estimácia stavu
A2 Kvantová analýza prechodných dejov	A21 Kvantovo kódovaná formulácia EMTP
	A22 QEMTP s podporou HHL ¹
	A23 QEMTP s podporou VQLS ²
A3	
B Kvantové výpočty pre prevádzku elektrizačnej sústavy	
B1 Prevádzka elektrizačnej sústavy prostredníctvom kvantovej optimalizácie	
B2 Hodnotenie stability energetického systému prostredníctvom kvantového strojového učenia	
B3 Odolné riadenie energetických systémov prostredníctvom kvantového distribuovaného riadenia	
B4 Generovanie scenárov energetických systémov prostredníctvom kvantového generatívneho učenia	

¹ Harrow-Hassidim-Lloyd kvantový algoritmus EMTP: bezšumový prístup

² Varičné kvantové lineárne riešenia s algoritmom EMTP: prístup v strednom rozsahu šumu

Analýza elektrizačných sústav (A) sa vo veľkej miere spolieha na statickú analýzu, ktorá zahŕňa tok výkonu (A11 výpočet ustáleného stavu) a odhad (estimáciu) stavu (A12). Táto analýza je kľúčová pre pochopenie jednotlivých aspektov správania sa elektrizačnej sústavy. So zvýšenou penetráciou obnoviteľných zdrojov energie vzniká potreba značného množstva statických analýz na posúdenie vplyvu neurčitosti. Tradičné iteračné algoritmy používané na túto analýzu však vedú k výpočtovej zložitosti, ktorá exponenciálne rastie s veľkosťou problému. Algoritmus Harrow-Hassidim-Lloyd (HHL) je pozoruhodným úspechom v oblasti kvantových výpočtov, pretože poskytuje spôsob riešenia lineárnych rovníc v kvantovom priestore [20]. Pomocou kvantového obvodu dosahuje algoritmus HHL jednotkovú transformáciu kvantovej superpozície lineárneho riešenia. Hlavnou výhodou algoritmu HHL a jeho variantov je, že dokáže exponenciálne urýchliť analýzu riedkych systémov/matíc v porovnaní

s klasickými metódami, čo sa dokonale hodí na analýzu energetických systémov.

Moderné energetické systémy čelia výzve zníženia zotrvačnosti v dôsledku integrácie zdrojov založených na invertoroch a vyradenia synchronných točivých generátorov. Na presné zachytenie širokého spektra elektromagnetických prechodových javov výkonových elektronických zariadení je nevyhnutné používať algoritmy zachytávajúce správny časový rozsah týchto javov (EMTP – Electromagnetic Transient Program). Napriek presnému sledovaniu elektromagnetických priebehov sa výpočtová zložitosť EMTP výrazne zvyšuje s veľkosťou systému, čo sťažuje jeho použitie v rozsiahlych energetických systémoch. Tento problém sa dá vyriešiť algoritmi QEMTP, ktoré využívajú kvantové výpočty na riešenie problému výpočtu elektromagnetických prechodných javov (A22, A23). Takáto analytika vytvára základ pre analýzu prechodných javov v elektrizačných sústavách, ako na súčasne dostupných technológiách NISQ (noisy-intermediate-scale quantum computers), tak aj na tzv. bezšumových kvantových počítačoch vzdialenej budúcnosti. Pre podrobné štúdium kvantových algoritmov je možné odporučiť napr. [23, 24, 25].

Kvantové počítače so stredne veľkým šumom (NISQ) sú typom kvantového počítača, ktorý sa v súčasnosti vyvíja a používa na úlohy kvantových výpočtov. Pojem "šum/hluk" sa vzťahuje na skutočnosť, že tieto počítače sú náchylné na chyby v dôsledku účinkov šumu v kvantovom hardvéri. Tento šum môže vznikáť z rôznych zdrojov, napríklad z kolísania teploty alebo elektromagnetického rušenia. Pojem "stredne veľký" sa vzťahuje na skutočnosť, že tieto počítače majú relatívne malý počet qubitov (zvyčajne desiatky až stovky), čo ešte nestačí na vykonávanie zložitých kvantových výpočtov, ktoré by si vyžadovali tisíce alebo milióny qubitov. Napriek svojim obmedzeniam sa už ukázali počítače NISQ ako sľubné pri vykonávaní určitých kvantových algoritmov a simulácií, ktoré presahujú možnosti klasických počítačov.

Praktickosť kvantových výpočtov je jednou z hlavných prekážok pri implementácii kvantovej technológie v energetických systémoch. Hoci kvantové počítače preukázali svoju schopnosť riešiť zložité optimalizačné problémy a simulácie, táto technológia je stále v počiatkovom štádiu vývoja a súčasné kvantové počítače často nemajú dostatočný počet qubitov potrebných na riešenie reálnych problémov. Okrem toho implementácia kvantových technológií v energetických systémoch predstavuje ďalší súbor výziev, pretože si vyžaduje špecializovaný hardvér, softvér a odborné znalosti, ktoré nie sú bežne dostupné. To môže mať za následok zvýšenú zložitosť a náklady, čo pôsobí ako významná prekážka ich prijatia. Okrem toho integrácia kvantových komunikačných sietí do existujúcej infraštruktúry energetických systémov môže byť náročná z dôvodu nedostatku všeobecne prijatých špecializovaných zariadení a protokolov. Napokon, problémom je aj nedostatočná štandardizácia a regulácia používania kvantových technológií v energetických systémoch. Pre spoločnosti môže byť náročné určiť, ako implementovať kvantové technológie spôsobom, ktorý je v súlade s predpismi a priemyselnými normami.

POĎAKOVANIE

Táto práca vznikla s podporou Agentúry na podporu výskumu a vývoja SR na základe zmlúv APVV-19-0576 a APVV-21-0312 a Slovenskej akadémie vied na základe zmluvy VEGA 1/0757/21.

LITERATÚRA

- [1] Z. C. Seskir, "Global innovation and competition in quantum technology, viewed through the lens of patents and artificial intelligence" in *Int. J. Intellectual Property Management*, vol. 13, no. 1, 2023, <https://doi.org/10.1504/IJIPM.2023.129076>.
- [2] "Overview on quantum initiatives worldwide" Quantum Resources & Careers, <https://www.quareca.com> (accessed March 28, 2023)
- [3] J. P. Dowling, G. J. Milburn, "Quantum technology: The second quantum revolution" in <https://doi.org/10.48550/arXiv.quant-ph/0206091>
- [4] "Quantum Technologies Flagship Final Report" <https://era.gv.at/public/documents/3365/Finalreport.pdf> (accessed March 28, 2023)
- [5] R. Feynman, "Simulating physics with computers" *Int. J. Theor. Phys.* 1982, <https://doi.org/10.1007/BF02650179>
- [6] A. Acín, et al., "The quantum technologies roadmap: a European community view" 2018 *New Journal of Physics*, <https://iopscience.iop.org/article/10.1088/1367-2630/aad1ea>,
- [7] I. Wegner, *Complexity Theory: Exploring the Limits of Efficient Algorithms*. Springer, 2005
- [8] Č. Šandera, "Hybrid model of metaheuristic algorithms." <https://dspace.vutbr.cz/xmlui/handle/11012/35853>
- [9] *Computational complexity theory*, Wikipedia, the free encyclopedia. <http://en.wikipedia.org/w/index.php?title=Computational%20complexity%20theory&oldid=1171104056>, 2023. (accessed 20-August-2023)
- [10] S. Goderbauer, M. Comis, F.J.L. Willanowski, "The synthesis problem of decentralized energy systems is strongly NP-hard", volume 124, pages 343–349. *Computers & Chemical Engineering*, 2019.
- [11] F. Marechal a B. Kalitventzeff, "Targeting the integration of multi-period 380 utility systems for site scale process integration", volume 23, pages 1763–1784. *Applied Thermal Engineering*, 2003.
- [12] M. Jennings a D. Fisk a N. Shah, "Modelling and optimization of retrofitting residential energy systems at the urban scale", volume 64, pages 220–233. *Energy*, 2014.
- [13] MediaWiki, <http://complexityzoo.uwaterloo.ca/>
- [14] T. Mauder, Č. Šandera, J. Štetina, M. Šeda, "A fuzzy-based optimal control algorithm for a continuous casting process", volume 46, pages 325–328. *Materiali in tehnologije*, 2017.
- [15] K.Y. Lee, Z.A. Vale, "Applications of Modern Heuristic Optimization Methods in Power and Energy Systems"; Wiley: Hoboken, NJ, USA, 2020
- [16] G. Chicco, A., Mazza, "Heuristic optimization of electrical energy systems: Refined metrics to compare the solutions". *Sustain. Energy Grids Netw.* 2019.
- [17] Y. Del Valle, G. Venayagamoorthy, S. Mohagheghi, J.C. Hernandez, R.G. Harley, "Particle Swarm Optimization: Basic Concepts, Variants and Applications in Power Systems." *IEEE Trans. Evol. Comput.* 2008
- [18] L. Smirnova L. et al., "Organoid intelligence (OI): the new frontier in biocomputing and intelligence-in-a-dish." *Front Sci* 1:1017235, 2023.
- [19] T. Hornyak, "Fujitsu. Supercomputer simulates 1 second of brain activity". *CNET*, 2013.
- [20] Y. Zhou et al., "Quantum computing in power systems," in *iEnergy*, vol. 1, no. 2, pp. 170-187, June 2022, doi: 10.23919/IEN.2022.00201.
- [21] D. Shaw, "Quantum hardware outlook 2022. Technical report" <https://www.factbasedinsight.com/quantumhardware-outlook-2022/> (accessed March 28, 2023)
- [22] A. Ajagekar, F. You, "Quantum computing and quantum artificial intelligence for renewable and sustainable energy", *Renewable and Sustainable Energy Reviews*, vol. 165, September 2022, <https://doi.org/10.1016/j.rser.2022.112493>
- [23] A. D. Córcoles et al., "Challenges and Opportunities of Near-Term Quantum Computing Systems," in *Proceedings of the IEEE*, vol. 108, no. 8, pp. 1338-1352, Aug. 2020, doi: 10.1109/JPROC.2019.2954005
- [24] A. Pitchai, "Quantum Computing, in *Emerging Computing Paradigms: Principles, Advances and Applications* ", Wiley, 2022, pp.41-61, doi: 10.1002/9781119813439.ch3
- [25] A. Ajagekar, F. You, "Quantum computing and quantum artificial intelligence for renewable and sustainable energy", *Renewable and Sustainable Energy Reviews*, vol. 165, September 2022, <https://doi.org/10.1016/j.rser.2022.112493>

ADRESY AUTOROV

Ing. Marián Mešter, PhD. Technická Univerzita Košice, Katedra elektroenergetiky, Mäsiarska 74, Košice, SK 04210, Slovenská Republika, marian.mester@tuke.sk, Východoslovenská distribučná, a.s. Mlynská 31, Košice SK 042091, Slovenská Republika, mester_marian@vsdas.sk