



„Podporujeme výskumné aktivity na Slovensku/Projekt je spolufinancovaný zo zdrojov EÚ

Metodologický prehľad štatistických nástrojov použiteľných pri tvorbe a testovaní modelov predikcie a optimalizácie výroby a spotreby elektrickej energie na Slovensku.

Predmetom prvej analýzy v rámci projektu bolo jeho metodologické usmernenie. Táto správa je len formálnym výstupom analýzy vhodnosti rôznych prognostických metód a štatistických nástrojov na predikovanie vývoja viacerých časových radov, vybraných na základe ich prítomnosti v dátových štruktúrach systému súčasného sledovania pohybu výroby a spotreby elektrickej energie na Slovensku. Cieľom analýzy bolo nájsť a popísať metodologicky vhodné prístupy k tvorbe inteligentných systémov, podporujúcich alebo nahradzujúcich analytickú stranu súčasného bilančného modelu estimácie odchýlky výroby a spotreby.

Pri tomto zadání sme prihliadali:

- na charakteristiky súčasného systému poskytovania, evidencie a využitia údajov o výrobe a spotrebe elektrickej energie,
- na hodnotu meta-dát získaných analýzy,
- na bezpečnosť jednotlivých prístupov z pohľadu anonymity dát,
- na možnosť interpretácie výsledkov
- na jednoduchosť implementácie metód do aktuálne bežiacich systémov.
- na efektivitu modelov pri cieľoch krátkodobej predikcie (hodinový, denný interval) a cieľoch dlhodobej predikcie (týždenný mesačný interval) spotreby a výroby elektrickej energie.

Pri analýze potenciálu metodologických prístupov boli brané do úvahy dáta o evidencii sústav, výrobcov elektriny a odberných a odovzdávacích miest pripojených do sústav (v rátane TDO

hodnôt a nameraných údajov odberu a dodávky elektriny). Predpokladali sme tiež prístup k ďalším dátam o odberných a odovzdávacích miestach (PSČ, Druh, Napätová úroveň, Typ merania, Trieda TDO, Predpokladané ročné množstvo, Zaradenie do sústavy), o ich odbere a dodávke elektriny zo a do sústavy. Pre potreby prvej správy, sme predpokladali aj prístup k dátam o priradení výrobní k odberným a odovzdávacím miestam

Predspracovanie dát

Dáta, získané zo systému v surovej podobe, je pred analýzou potrebné skontrolovať a upraviť do formátu, ktorý uľahčí ich manipuláciu a interpretáciu. Pre väčšinu testovaných metód predikcie je najvhodnejším vstupným (učiacim) profilom taký profil, ktorý má dlhodobu charakter stabilného toku dát v štandardne sa vyskytujúcich hodnotách, bez významných posunov. Trénovacie profily s nepravidelným (resp. neprirodzeným) charakterom hodnôt a skokovými zmenami spomaľujú tréning systému a v horšom prípade, znemožňujú štatisticky robustnú predikciu.

Tvorba algoritmických modelov sa nezaobíde bez primárnej kontroly kvality získaných dát. Je dôležité, aby dáta neobsahovali evidentné chyby (e.g. teplota +100°C, podozrivo vysoká spotreba). Šetrenie takýchto chýb môže prebiehať dvoma spôsobmi. Ak stavíme model na citlivých dátach, v ktorých je minimálna chybovosť esenciálna alebo na malých vzorkách dát, snažíme sa takéto infekty vyhľadať a po jednom ošetriť. V prípade, že model stavíme na dostatočne veľkých vzorkách dát, môžeme takéto extrémne hodnoty ošetriť nastavením hodnotovej hranice, ktorú získame pomocou indikátorov deskriptívnej štatistiky - priemeru, mediánu, maxima minima a štandardnej odchýlky. Neštandardné zmeny tvaru dát, ktoré je potrebné odfiltrovať, je možné detekovať prostredníctvom validačnej funkcie.

Pre potreby kvalitnej analýzy je taktiež dôležité, aby väčšina vstupov mala podobný rozsah (i.e. nie je dobré, keď teploty sú z rozsahu desiatok a spotreby z rozsahu tisícok, desať tisícok). Štandardný postup je každý vstup preškálovať do rozsahu 0 až 1, prípadne tak, aby mal priemer 0 a štandardnú odchýlku 1. Medzi ďalšie štandardné úpravy dát patrí definovanie rozdielu vo významoch nulovej hodnoty a prázdnej hodnoty, kde prázdna hodnota zväčša označuje nevalidnú hodnotu (e.g. výpadok merania) a nulová hodnota označuje meranie hodnoty 0.0, aj napriek tomu, že priemer viacerých meraní v hodnote 0.0 nie je frekventovaný.

Kritickým predpokladom validity a reliability záverov je dostatočná veľkosť vzorky (počet dátových profilov, dĺžka ich trvania a frekvencia zberu bodových meraní). V niektorých prípadoch je možné získané dáta matematicky extrapolovať, pokiaľ je vzorka nedostatočná na získanie štatisticky významných prípadov. Takto rozšírená dátová vzorka však musí spĺňať veľmi striktné požiadavky robustnosti, internej konzistentnosti a dynamiky v čase.

Tréning takýchto systémov môže byť realizovaný off-line, na tzv. mŕtvej vzorke dát alebo on-line, na tréningových dátach z bežiacieho dátového toku. Napriek tomu, že pri off-line tréningu je šanca, že takto trénovaný systém nezoberie do úvahy všetky signály manipulujúce predikciu v reálnom dátovom toku (lebo off-line vzorka tréningových profilov ich neobsahovala), prístup dovoľuje intenzívnejšie testovanie modelu a prípadné chyby nemajú priamy a dopad na aktuálne bežiacie systémy. On-line tréning je intenzívnejší, predstavuje istotu započítania všetkých existujúcich signálov v aktuálne bežiacich dátových profiloch do tvorby modelu. Hrozbou je, dopad prvotnej chybovosti modelu na bežiaci systém a fakt, že množstvo irelevantných informácií v dátovom toku a profily s dlhším časom vyhodnotenia by značne spomaľovali výpočet predikcie. V kontexte energetiky je akceptovateľným kompromisom prístup dvoj krokovej

analýzy, pri ktorej sa na tréning predikcie on-line dátových profilov používajú ich uložené verzie a bodové merania, ktoré sa v potrebnom časovom horizonte (napr. denne) pred výpočtom predikcií aktualizujú podľa hodnôt počítaného dátového profilu. V nasledujúcej časti správy si popíšeme vybrané predikčné modely, ktoré budeme v rámci projektu estimácie výroby a spotreby elektrickej energie testovať.

Validácia modelu

Pri tréningu modelu netrénujeme tak, aby sa dobre správal na tréningových dátach, pretože nemáme záruku, že sa bude dobre správať na nových dátach. Pri niektorých modeloch je častý jav tzv. pretrénovanie, t.j. stav kedy sa model veľmi dobre správa na tréningových dátach, ale má vysokú chybovosť na nových dátach. Na odhalenie tohto fenoménu a odhadnutie skutočnej chybovosti modelu na nových dátach sa používajú obvykle nasledujúce postupy:

- z tréningových dát vyčleníme tzv. testovaciu vzorku na ktorej model netrénujeme, ale po tréningu na nej overíme chybovosť modelu
- K-fold cross-validácia – tréningovú vzorku rozdelíme na K častí, v každom kroku jednu z častí vyčleníme z tréningovej vzorky a použijeme ako testovaciu, následne natrénujeme model a overíme jeho výkonnosť; výsledný odhad výkonnosti modelu je priemer z K overení.

Metódy strojového učenia a ich efektivita v kontexte modelov predikcie výroby a spotreby elektrickej energie.

Pri strojovom učení vytvárame model, ktorý sa snaží predikovať cieľovú premennú na základe iných vstupných premenných (napríklad spotrebu energie pomocou teploty vzduchu, ročného obdobia, toho, či je víkend, atď.). Základom tohto analytického prístupu je databáza takzvaných vstupných a výstupných profilov, definovaných bodovými meraniami (stavmi) v časovom slede ohraničujúcom analyzovaný jav. Bodové merania v týchto profiloch sú organizované do jednotlivých premenných alebo faktorov (skupín premenných), ktoré pre systém fungujú ako tréningové dáta. Pomocou tréningových dát automatizovane a dynamicky nastavujeme parametre modelu tak, aby zodpovedali týmto profilom. Potom už môžeme pomocou získaného modelu vykonávať predikciu.

Lineárna regresia

Pri modeloch založených na lineárnej regresii sa spotreba predikuje ako lineárna kombinácia viacerých vstupov (predchádzajúca spotreba, teplota, binárne indikátory o dni v týždni, voľných dňoch, známe časové rady). Pomocou týchto vstupných dát sú pri tejto metóde identifikované modely neznámych parametrov pomocou lineárnych funkcií. V kontexte lineárnej regresie sa tieto parametre nazývajú vstupné atribúty (features) a snažia sa predikovať sériu cieľových premenných (target variables) v priestore všetkých možných funkcií (hypotheses). Cieľom modelu je popísať takú hypotézu, ktorá najlepšie predikuje pohyb cieľovej premennej.

Efektivitu vybranej hypotézy môžeme merať pomocou jednoduchých chybových funkcií, napríklad funkciu ktorá sleduje štvorec rozdielu reálnej hodnoty z tréningových dát a predikovanej

hodnoty. Cieľom je teda o čo najnižšiu sumu funkčných hodnôt chybovej funkcie na vzorke všetkých vstupných atribútov. Druhou alternatívou sú chybové funkcie na základe lineárneho programovania. Tieto sú síce komutačne náročnejšie, no majú výhodu, ak distribúcia dát nie je normálna.

Výhodou lineárnej regresie je relatívne nízka časová náročnosť tréningovania a možnosť distribuovaného tréningovania v prípade veľkého množstva dát. Dosť často sa ale stáva, že závislosti medzi vstupmi a spotrebou nie sú lineárne (napr. teplota & spotreba; najvyššia spotreba je práve pri veľmi nízkych a veľmi vysokých teplotách). Na odstránenie tohto problému sa obvykle používa niekoľko rôznych postupov. Jednou z alternatív riešenia, ktorú budeme testovať je, že sa teplota na vstupe uvedie vo viacerých vyšších mocninách (aby sme mohli modelovať aj nelineárnu závislosť). Druhým validným prístupom k zadaniu je rozloženie dát o spotrebe na spotrebu závislú a nezávislú od teploty a tieto časti modelovať separátne (vzťah premenných teplota a celková spotreba tu používame ako príklad). O nameranej efektívnosti týchto a alternatív a ostatných prístupov spomenutých v tejto správe budeme informovať v správach v ďalšej fáze projektu. Samostatnou otázkou, ktorú sa budeme snažiť zodpovedať je, či je vhodné mať separátne modely pre jednotlivé časové horizonty (napr. hodiny, dni, mesiace), alebo jeden model, ktorý dostane konkrétny časový horizont ako premennú. Lineárna regresia predstavuje jeden z klasických prístupov s relatívne slabými, no stabilnými modelmi. Jej neschopnosť zachytiť nelineárne závislosti sa dá parciálne obísť pridaním binárií atribútov.

Pri podpore tejto metódy nám môže byť nápomocná metóda generalizovanej lineárnej regresie, ktorá sa líši tým, že množinu atribútov najprv predspracujeme bázovými funkciami, čo umožní cieľovým premenným mať inú ako normálnu distribúciu chybovosti. Ďalšou alternatívou s potenciálom je proces lokálnej váhovanej aproximácie. Táto metóda definuje kľúčový stav v tréningových dátach a aj keď akceptuje všetky ostatné stavy vo vzorke, váži ich vplyv podľa funkcie ich vzdialenosti od kľúčového stavu. Príkladom takto využiteľnej funkcie je napr. známa bázová funkcia Kernel. V kontexte takejto grafovej interpretácie sa klasická lineárna regresia snaží optimálne vykresliť priamku cez všetky tréningové stavy, bez váženia tréningových stavov. Nedostatkom lokálnej váhovej aproximácie je fakt, že pre každé nové tréningové dáta musíme definovať špecifickú sústavu kľúčových stavov.

Otázkou, ktorú testovaním metód zodpovieme, je akým spôsobom optimálne zdefinovať kľúčové stavy v tréningových dátach v predikcii spotreby elektrickej energie. Ak by boli dáta rozvrhnuté rovnomerne, kľúčové stavy by bolo možné rozmiestniť v štruktúre pravidelného gridu. Pokiaľ máme dostatočný veľký počet dátových profilov, kľúčové stavy je možné vybrať aj náhodne. Posledným prístupom, je dynamicky vyberať optimálnu polohu kľúčových stavov pomocou metód reinforcement learning a analýzy zhlukov, čo je náročnejšie na výpočet ale pokiaľ v predikcii je dostatočná časová rezerva, metóda je veľmi efektívna aj pri menších, nerovnomerne rozvrhnutých dátových vzorkách.

Umelé neurónové siete

Neurónové siete predstavujú komplexný výpočtový systém, tvorený sériou jednoduchších efektívne prepojených elementov, ktoré spracovávajú informácie prostredníctvom ich dynamickej odpovede na externé vstupy, na základe ich aktuálneho stavu. Štandardne pozostávajú z väčšieho počtu vzájomne prepojených rozhodovacích uzlov, ktoré sa riadia aktivačnou funkciou. Uzly sú organizované do vrstiev. Dáta sú vložené do vstupnej vrstvy, ktorá

ich komunikuje viacerým skrytým vrstvám, v ktorých prebieha ich spracovávanie. Neurónové siete majú viaceré špecifiká. Nie sú klasicky sekvenčné a nevyhnutne deterministické. V klasických modeloch v tomto prístupe absentuje centrálny procesor, ktorý je nahradený paralelnými odpoveďami uzlov na prezentované vstupy. Neexistujú tu ani oddelené pamäťové adresy na ukladanie dát počas analýzy, finálna informácia je obsiahnutá v celkovom aktivačnom nastavení všetkých uzlov v sieti. Novo získané poznatky sú teda reprezentované stavom siete samotnej, ktorý má väčšiu interpretačnú silu, ako súčet stavov všetkých uzlov v nej. Konexie medzi uzlami sa váhujú a výsledok je prezentovaný na výstupnej vrstve uzlov. Váhy uzlov sa nastavujú podľa dopredu zadaného pravidla učenia. Týchto pravidiel je niekoľko, najfrekvencovanejšie v klasických modeloch je tzv. delta pravidlo, ktoré administruje spätnú propagáciu chyby z jednej vrstvy, do uzlov vrstvy predchádzajúcej. Na základe pravidla učenia sa umelá neurónová sieť posúva na učiacej krivke od náhodného typovania, k expertnému výberu. Efektivitu posilňuje aplikácia sigmoidálnych aktivačných funkcií, ktoré polarizujú aktivitu siete a pomáhajú ju stabilizovať.

Umelá neurónová sieť je v princípe metóda univerzálnej aproximácie, ktorá modeluje najlepšie také systémy, ktoré majú dostatočnú toleranciu k prvotnej chybovosti. Je ideálna na zachytávanie asociácií a detekovanie pravidelností v setoch dátových profilov, na identifikovanie vzťahov medzi premennými, ktoré sú neúplne popísané, na analýzu dátových štruktúr, ktoré disponujú veľkým počtom premenných, poprípade veľkými objemami. Po tom, čo sa nám podarí natrénovať sieť na požadovanú úroveň, môže byť použitá ako analytický nástroj na iných vzorkách dát. V tomto stave už nešpecifikujeme tréning a pustíme na neurónovej sieti iba propagáciu vpred. Výstupom takto nastavenej siete (forward propagation run) je predikčný model pre dáta, ktorý môže byť následne použitý v komplexnejšej analýze, či interpretácii.

Okrem všeobecných metodologických limitácií spomenutých pri popise metód lineárnej regresie, neurónové siete založené na princípe spätnej propagácie (ale aj viaceré iné typy) predstavujú v princípe čiernu skrinku. Okrem definovania primárnej architektúry siete a prvých testov s náhodnými číslami, nemá administrátor inú kompetenciu, ako kŕmiť sieť vstupnými dátami a zapracovávať výstupy. Niektoré nástroje (napr. NevProp, poprípade, Mactivation) dovoľujú získavať vzorky postupu siete v definovaných intervaloch, ale učiacu krivku siete sa rozvíja samostatne. Finálnym produktom tohto procesu je sieť sama, a teda nie rovnica alebo séria koeficientov (ako pri lineárnej regresii) ktoré by popisovali vzťahy premenných mimo architektúry siete. Potenciálnym limitom je, že neurónové siete je možné pretrénovať, t.j. sieť bude dávať dobré výsledky na tréningových dátach, ale jej výsledky na nových dátach budú slabé. Na odstránenie tohto fenoménu sa používajú nasledovné postupy: predčasné zastavenie tréningovania, regulácia (ku chybe pripočítame aj vhodne pre násobenú hodnotu parametrov siete a túto hodnotu sa snažíme minimalizovať), dropout (počas tréningovania náhodne vypneme niektoré neuróny), dropconnect (počas tréningovania náhodne vypneme niektoré spojenia). Neutrálne siete a ich modely sú citlivé na voľbu parametrov a ich výber sa vo vedeckej komunite neradi striktnými pravidlami. Preto je jedným z dôležitých cieľov nášho projektu testovať viaceré parametrické nastavenia neurónových sietí, ktoré budú tvoriť model predikcie spotreby elektrickej energie na Slovensku. Výzvou v projekte teda zostáva voľba vstupných parametrov a ich počet, ako aj veľkosť a typ skrytých vrstiev v sieti tak, aby mal systém dostatočnú predikčnú silu, stabilitu a boli zároveň časovo efektívne.

Hlavnou výhodou neurónových sietí je, že sú schopné modelovať nelineárne a dynamické závislosti. Sú tiež presnejšie ako metódy lineárnej regresie a rýchlo sa trénujú. Keďže sú schopné zachytiť rôzne druhy vzťahov medzi premennými môžeme pomocou nich modelovať komplexné

fenomény, ktoré by bolo náročné (niekedy až nemožné) modelovať klasickými štatistickými nástrojmi. Od roku 2006 sa do popredia dostávajú takzvané *deep networks*. Sú to neurónové siete s veľkým počtom vrstiev. Napriek tomu, že nie je presne popísané akým spôsobom ich skryté vrstvy fungujú, majú potenciál byť presnejšie ako obyčajné neurónové siete. Predbežné výsledky ukazujú, že pri dostatku dát majú vysokú efektivitu skoro v ľubovoľnej oblasti. Ich nedostatkom je, že sa ich niekedy skrátka nepodarí natréňovať.

Support vector machines

Support vector machines fungujú tak, že v tréningových dátach nájdú množinu dôležitých vzoriek (support vectors) a následne sledujú podobnosti medzi vstupom a dôležitými vzorkami, na základe čoho predikujú výsledok. Formálnejšie, táto metóda konštruuje nadroviny v priestore s veľkým, alebo nekonečným počtom dimenzií. Tieto nadroviny môžu byť následne použité na riešenie regresie alebo klasifikačných problémov. Support vector machines detekujú funkčné krajnice, dátové body jednej s klás, ktoré majú najväčšiu vzdialenosť k okrajovým dátovým bodom ostatných klás (lem). Čím väčšie sú tieto vzdialenosti, tým menšia je generalizačná chyba klasifikátora. S využitím kernelu v hľadaní nadrovín s maximálnym lemom, je touto metódou možné vytvoriť aj nelineárne klasifikátory. Využívajú sa aj multi-klasové support vector machines, ktoré pripisujú inštanciam znaky, ktoré sú vyberané s konečného počtu dopredu identifikovaných elementov. Atraktívne sú najmä návrhy modelov, ktoré sa pozerajú na multi-klasový problém klasifikácie ako na jeden optimalizačný problém a nerozbíjajú ho na sériu problémov klasifikácie binárnych stavov (napr. Crammerova a Singerova metóda). Jedinečnou vlastnosťou support vector machines je, že maximalizovanie geometrického lemu medzi klasami a minimalizovanie klasifikačnej chyby prebieha zároveň. Nevýhodou je ich vysoká časová náročnosť pri tréningu (väčšinou kvadratická od počtu vzoriek), vďaka čomu sa nedajú použiť na veľké vzorky dát. V praxi sa úspešne používajú napríklad ako klasifikátory hypertextov, na kategorizovanie obrázkov, rozpoznávanie písaného textu, či klasifikovanie proteínov v medicíne.

Smartmetering a metodologický prístup k predikcii spotreby v domácnostiach

Pri téme smartmeteringu sa dostávame do polohy, ktorá má svoje metodologické špecifiká, na ktoré je nutné reagovať. Fakt, že zberné systémy budú kumulovať masívne množstvá dát znamená, že nebude možné vložiť všetky merania do jedného algoritmu ako jednorazový vstup. Je preto vhodné zberné jednotky (napr.. domácnosti) najprv zmysluplne klastrovať a na tvorbu modelov používať agregované dáta zhlukov dátových profilov. Pridanou hodnotou tohto prístupu je aj to, že sa v rámci klastrov dajú deskriptívne sledovať rôzne spotrebiteľské trendy (ich stabilita, intenzita rastu/klesania), ktoré môžu ovplyvniť vývoj v ďalšom období. Príkladom je sledovanie vývoja geografických oblastí a sledovať a predikovať vývoj spotreby v nich. V projekte prinesieme odpoveď na otázku, akým kľúčom je možné vytvárať dátové klastre najoptimálnejšie. Na efektívne klastrovanie dát existuje viac štatistických nástrojov, tie akceptovateľné v kontexte profilu dátových setov, s ktorými počítame po nástupe smartmeteringu, si v krátkosti predstavíme.

K-means

K-means je metóda pôvodom z teórie venujúcej sa spracovávaniu signálov v šume. Jej princípom je rozdeľovanie dátových bodov do k-klastrov podľa ich podobnosti. Podobnosť tu definujeme na

základe body s najbližším priemerom, ktorý v každom klastrí funguje ako prototyp. K-means je rýchla a dobre paralelizovateľná metóda. Jej nevýhodou je citlivosť na škálovanie a korelované vstupné dáta.

Sparse coding

Táto metóda hľadá sadu vzorov v dátových setoch, ktorých naskladaním sa dáta vysvetlia. Optimálne, chceme každý dátový bod vysvetliť pomocou iba niekoľkých vzorov (preto sparse coding). Proces učenia prebieha autonómne, bez supervízora. Metóda nám umožní ľahšie interpretovať niektoré pohyby v dátach. Sparse coding sa dá použiť na získanie hlbšieho vhľadu do dát o správaní spotrebiteľov a výrobcov. Je ním možné napríklad tvorba profilov spotrebiteľských jednotiek, či detekovať aktivitu zapnutých elektrických spotrebičov (napr. za akú časť odberu zodpovedajú ktoré spotrebiče a za akých podmienok ich ľudia zapínajú). Tieto zistenia nielenže posilnia celkový predikčný model spotreby, ale majú aj samostatnú interpretačnú silu smerom k sledovaným vzťahom. Tu je kritickou premennou frekvencia dát (e.g. čím častejšie meriame, tým viac spotrebičov vieme odlíšiť). Pri malej frekvencii vieme sledovať len zmeny celkovej spotreby. Tradične sa v dátovom toku odlišujú len zariadenia s veľkou spotrebou, resp. sa zariadenia delia na spotrebné kategórie. Existuje niekoľko pomerne komplikovaných modelov, napríklad faktorizované skryté markovove modely, ktoré môžu finálnemu modelu zdvihnúť efektivitu, no ich popis v tejto fáze projektu nie je potrebný.

Optimalizačné nástroje

Predikcia ja síce dôležitou zložkou projektu, no nie je jedinou. Výstupné dáta z aplikovaných predikčných modelov spotreby nám môžu slúžiť ako interpretačné médium pri poradenstve (optimalizácii) smerom k výrobcovi a spotrebiteľom. Štatistické nástroje používané na optimalizáciu procesov a systémov nám umožnia túto úlohu do veľkej miery automatizovať. Ponúkame tu tri prístupy, ktoré budeme počas projektu testovať.

Integer linear programming

Integer linear programming predstavuje štandardnú techniku, ktorá sa vie adaptovať na riešenie problémov rôznych typov a štruktúr. Primárne sa zadajú premenné ako cieľ, ktorý treba optimalizovať (lineárna funkcia premenných), obmedzenia pre hodnoty premenných (tiež lineárne) a konkretizujúca inštrukcia niektorým premenným (napr. že môžu byť iba celočíselné). Metóde nevaďí linearita a v závislosti na charaktere dátovej vzorky je schopná namodelovať aj nelineárne závislosti s použitím vhodných transformácií.

Heuristické metódy

Heuristické metódy prehľadávajú stavový priestor riešení a robia malé lokálne optimalizácie. Heuristické riešenie predstavuje sériu nenáročných procedúr, ktorých cieľom je poskytnúť v závislosti na zadaní akceptovateľné, no nie nevyhnutne najlepšie riešenie z optimálnych riešení problému s vysokou komplexitou. Jedným z najpoužívanejších skupín optimalizačných heuristik sú genetické algoritmy. Tie sú založené na prepozíciách ako možnosť iterácie testovania, miera akceptovanej mutácie, pravidla prirodzenej selekcie (preferencia vhodnejších vlastností pred menej vhodnými) a pravidla ohraničeného počtu vstupov, agentov, či parametrov. Genetické

parametre sú schopné optimalizovať veľké počty parametrov jedného agenta. Heuristické riešenia sú väčšinou šité na konkrétne zadaný problém.

Reinforcement Learning

Metódy Reinforcement Learning predstavujú komplexnú zbierku algoritmov a pomocných modulov, ktoré sa snažia optimalizovať cestu agenta cez problémový priestor, tvorený množinou akcií (transferov) a problémových stavov. Hlavnou motiváciou agenta je vyhýbanie sa trestom a/alebo získavanie odmeny. Týmto štýlom vie systém identifikovať optimálne riešenie poznaného problému, rozdeliť komplexný problém na jednoduchšie problémy tak, aby každé riešenie menšieho problému signifikantné zvýšilo pravdepodobnosť dosiahnutia celkového riešenia alebo popísať problémový priestor, priradiť hodnoty jednotlivým akciám a stavom. Výhodou tohto prístupu je jeho pomerne jednoduchá skladba, kontrola efektivity riešenia, absencia pred-trénovania a fakt, že (na rozdiel od neurónových sietí) je celý proces viditeľný, popísaný vo výsledku a supervízor do procesu môže hocikedy priamo zasiahnuť. Systémy budované touto metódou sú schopné sa dynamicky prispôbiť zmene problémového priestoru alebo parametrov. Výsledkom nie je len finálna stratégia, ale skôr zoznam alternatív riešenia daného problému s hodnotami o ich efektivite a popis problémového priestoru a všetkých jeho zložiek, s ich impaktom na stratégiu riešenia. Nevýhodou je potreba iterácií (čas), ktorá narastá s komplexitou problémového stavu.

Záver

Cieľom analýzy bolo nájsť a popísať metodologicky vhodné prístupy k tvorbe inteligentných systémov, podporujúcich alebo nahradzujúcich analytickú stranu súčasného bilančného modelu estimácie odchýlky výroby a spotreby. Vymenované predikčné aj optimalizačné expertné systémy a predovšetkým ich kombinácie majú potenciál posunúť súčasné spracovanie dát v slovenskej energetike na novú úroveň a zároveň reagovať na očakávané zmeny v kontexte dátovej štruktúry, ktorá bude analytickým subjektom k dispozícii v blízkej budúcnosti (smartmetering). Výsledky testov efektivity jednotlivých metód a popísaných nástrojov na reálnych dátach budú nemalou časťou ďalších správ k projektu.