



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

Názov projektu:

Medzinárodné centrum excelentnosti pre výskum inteligentných
a bezpečných informačno-komunikačných technológií
a systémov

ITMS: 26240120039

Názov výstupu:

**MOŽNOSTI VYUŽITIA NAJVYSPELEJŠÍCH TECHNOLOGÍÍ,
VIZUALIZÁCIA A INFORMAČNÉ POSTUPY PRE VEĽKÉ
OBJEMY DÁT VRÁMCI VÝROBY A SPOTREBY
ELEKTRICKEJ ENERGIE NA SLOVENSKU,**

Obsah

Obsah	2
Zoznam skratiek	4
1. Úvod.....	5
2. Prvá časť pracovného balíka o vizualizácii dát.....	5
3. Úvod do problematiky vizualizácie dát.....	6
4. Štandardy a osvedčené postupy dátovej vizualizácie	7
5. Architektúra dátovej vizualizácie a prezentácie	9
6. Vizualizácia kvantitatívnych informácií.....	10
7. Vizualizácie do systémov pre malých výrobcov a spotrebiteľov	14
8. Vizualizačné štandardy	14
9. Modul automatickej vizualizácie	15
10. Vykresľovanie aktuálnych a historických dát pre malých výrobcov a spotrebiteľov	16
11. Zobrazenie spotrebného profilu a jeho gamifikácia	20
12. Vizualizácie do systémov pre veľkých výrobcov, spotrebiteľov a monitorovacie inštitúcie	25
13. Technické špecifikácie vizualizácií.....	30
14. Záver prvej časti	30
15. Druhá časť pracovného balíka o vizualizácii dát	31
16. Využitie všeobecných poznatkov pri výskume vizualizačných modulov pre rôzne cieľové skupiny v systéme SmartGrid	32
17. Možnosti vizualizácie monitoringu energetickej efektivity	33
18. Vizualizácie v kontexte aplikácií monitoringu energetickej efektivity	35
19. Vizualizácie v kontexte aplikácií energetického auditu.....	37
20. Vizualizácie v kontexte modelovania prevádzkových režimov distribučných sietí.....	39
21. Možnosti vizualizácií v kontexte aplikácií prediktívnej údržby	40
22. Možnosti vizualizácií v kontexte aplikácií pre inteligentné domácnosti.....	42
23. Prehľad voľne prístupných knižníc vhodných na tvorbu vizualizačných modulov pre aplikácie v systémoch SmartGrid.....	45
23.1 Knižnica D3.js	49
23.2 Knižnica NVD3	49
23.3 Knižnica Chart.js	50

23.4	Knižnica Leaflet.....	51
23.5	Knižnica dygraphs.....	52
23.6	Knižnica Sigma.js.....	53
24.	Zhodnotenie pracovného balíka 8: Vizualizácia dát a výskum vhodných postupov ...	53
24.1	Prvá fáza pracovného balíka 8: Vizualizácia dát a výskum vhodných postupov.....	54
24.2	Druhá fáza pracovného balíka 8: Vizualizácia dát a výskum vhodných postupov.....	55
25.	Záver.....	57

Zoznam skratiek

[illegible]

1. Úvod

Pracovný balík 8 (PB 8) - Vizualizácia dát a výskum vhodných postupov v zadaní projektu bol určený pre oblasť procesov získavania a použitia poznatkov o veľkých objemoch dát. Tieto procesy sa rýchlo vyvíjajú, a stále sú potrebné nové vizualizácie a vzory dotazovania. Tento pracovný balík sa v rámci zadania mal venovať použitiu dát rôznymi užívateľmi na platformách Big Data, prieskumu existujúcich nástrojov vizualizácie veľkoplošných dát, prieskumu nových vzorov a postupov vizualizácie pre rozsiahle súbory dát, mal venovať osobitnú pozornosť vizualizácii veľkých a viacnásobných tokov dát, výsledkom ich analýzy a výberu jednoduchých informačných rozhraní ako prídavok k analytickým platformám pre veľký objem dát, čím sa uľahčí proces informovania pre rôznych účastníkov.

Realizácia tohto pracovného balíka v rámci projektu postupovala v dvoch základných častiach:

Prvá časť pracovného balíka (PB) zameraného na vizualizáciu dát, bola orientovaná na základný výskum a posúdenie použitia najnovších technológií pri vizualizačných postupoch pre veľké objemy dát na obrovských dátových štruktúrach a výsledkov analýz.

Druhá časť pracovného balíka venujúceho sa vizualizácii dát - zbieraných a spracovaných v rámci systému SmartGrid - bola nasmerovaná na kompletizáciu poznatkov získaných v prvej časti PB, prieskumu aplikácií, výskumu nástrojov a implementáciu týchto do predpokladaných špecificky zadaných príkladov aplikácií, integrovaných do systémov SmartGrid na Slovensku.

2. Prvá časť pracovného balíka o vizualizácii dát

V rámci prvej časti projektového zadania, venujúceho sa vizualizácii dát a základnému výskumu vhodných postupov, sme najprv zhrnuli úvod do problematiky vizualizácie veľkého toku dát, existujúce štandardy a osvedčené postupy dátovej vizualizácie kvantitatívnych dát a podmienky, ktoré má spĺňať architektúra dátovej prezentácie. Následne sme sa zamerali na vizualizáciu v kontexte systémov a aplikácií určených pre malých výrobcov a spotrebiteľov elektrickej energie – ako rôznych užívateľov na platformách Big Data. Nasledovným krokom – v rámci prieskumu nových vzorov a postupov vizualizácie pre rozsiahle súbory dát bol teoretický výskum v oblasti modulov automatickej a semi-autonómnej vizualizácie, vykresľovania aktuálnych a historických dát pre malých výrobcov a spotrebiteľov a výskum zobrazenia

spotrebného profilu a jeho gamifikácie. Ešte v kontexte prvej časti projektového zadania venujúceho sa vizualizácii dát sme sa v ďalšom kroku zamerali na vizualizácie v rámci a v súvislosti systémov a aplikácií určených pre veľkých výrobcov, spotrebiteľov a monitorovacie inštitúcie. V tejto časti projektu prebehol aj základný výskum v oblasti technických špecifikácií vizualizácií v popísaných kontextoch.

Našou snahou bolo okrem toho prezentovať možné dátové vizualizácie, špecializované na interpretáciu dát spracovaných v rámci SmartGrid. Špecifické vizualizácie dát o spotrebe a výrobe elektrickej energie boli v projekte identifikované ako funkcie, ktoré bude potrebné vyvinúť pre správny chod systému SmartGrid. V budúcnosti je očakávateľné, že vizualizačné nástroje a aplikácie vystavané špecificky pre energetiku budú zároveň žiadané hráčmi v energetickom priemysle, nakoľko umožňujú efektívnu interpretáciu a následný manažment dát.

Kontinuálnym monitoringom prostredníctvom vizualizácií s dostatočnou interpretatívnou hodnotou je možné eliminovať možnú chybovosť v procese rozhodovania, šetria sa finančné zdroje a urýchľujú sa exekutívne procesy. Efektívna vizualizácia zbieraných dát môže do budúcnosti predstavovať značnú konkurenčnú výhodu.

1. Popísať základné princípy vizualizácie dát, podľa ktorých by sa mal vývoj vizualizačných modulov riadiť.
2. Upozorniť, na rozdiely v preferenciách vizualizácií v produktoch a službách pre:
 - i) malých výrobcov a spotrebiteľov,
 - ii) veľkých spotrebiteľov (napr. vo veľných kontroly a optimalizácie spotreby tovární, výrobných parkov a závodov) a výrobcov (napr. vo väčších elektrárnach),
 - iii) inštitúcie ako SEPS alebo OKTE a jednotlivé distribučné inštitúcie, nakoľko tieto monitorujú spotrebu na väčších geografických územiach.
3. Popísať vizualizácie vhodné pre tieto skupiny užívateľov.
4. Popísať technické špecifikácie implementácie vizualizačných modulov.

3. Úvod do problematiky vizualizácie dát

Vizualizácia dát je mnohými odborníkmi vnímaná ako moderný ekvivalent vizuálnej komunikácie. Nespadá pod jednu konkrétnu oblasť vedy alebo trhového segmentu a poskytuje

výklad dát pre mnohé oblasti. Dátová vizualizácia zahŕňa tvorbu a štúdium možností vizuálnej reprezentácie dát, teda informácií, ktoré boli zozbierané štandardizovaným procesom a následne štruktúrované, teda atribúty a vlastnosti premenných pre jednotky informácií, ktoré majú v dátovej vzorke logickú následnosť.

Primárnym cieľom vizualizácie dát je jasne a efektívne komunikovať informácie užívateľom, prostredníctvom štatistickej interpretácie vizuálnym spôsobom. Efektívna dátová vizualizácia konvertuje komplexné údaje na prístupnejšie, zrozumiteľnejšie a použiteľnejšie informácie. Zatiaľ čo tabuľky sú obvykle používané vtedy, keď užívateľ potrebuje poznať reálne hodnoty meraní, diagramy rôznych typov sú ideálne pre posúdenie trendov premenných v čase, intenzity vzťahov medzi premennými alebo sledovaním korelácií.

Vizualizácia dát je tak trochu umenie aj veda. Rýchlosť, ktorou sú v súčasnosti dáta generované sa radikálne zvýšila, tak ako aj ich objem. Obe treba brať pri interpretácii dát do úvahy. Trend „Big Data“ značne ťaží z existujúceho rozmachu nástrojov na vizualizáciu obrovského počtu dát v reálnom čase. Možnosť vizualizovať veľké objemy dát v reálnom čase samo o sebe prichádza s radou analytických, bezpečnostných a etických výziev.

4. Štandardy a osvedčené postupy dátovej vizualizácie

"...hlavný cieľ dátovej vizualizácie je komunikovať informácie jasne a efektívne prostredníctvom vizuálnych nástrojov. To však neznamená, že vizualizácia dát musí vyzeráť nudne aby bola funkčná, alebo že musí byť extrémne sofistikovaná na to, aby bola vizuálne príťažlivá."

- Friedman (2008)

Vyššie uvedený citát považujeme nielen za pravdivý, ale aj esenciálny pri tvorbe vizualizačných modulov. Optimálna vizualizácia podľa nás nielen efektívne komunikuje informácie, ale aj láka pozornosť pozorovateľa. Prostredníctvom takejto vizualizácie má pozorovateľ potenciál odhaliť trendy, analyzovať dátové zdroje alebo získať nový náhľad do problematiky. Dátová vizualizácia

musí analytikovi ponúknuť príbeh, ktorý uvidí bez väčšej námahy. Vizualne reprezentácie informácií by mali:

- Podnecovať pozorovateľa k rozmyšľaniu nad výskumnými otázkami, hypotézami a odpoveďami, ktoré priniesla vizualizovaná analýza, nie nad metodológiou, grafickým dizajnom, použitými nástrojmi alebo informáciami mimo kontextu,
- vyhnúť sa zlej interpretácii dát (napr. musí byť jasné, či v konkrétnom grafe vizualizujeme korelácie alebo kauzálny vzťah),
- akumulovať dátové body - prezentovať bohatú informáciu na malej ploche,
- štandardizovať vzťahy medzi informačnými bodmi vo veľkých dátových vzorkách,
- podnecovať pozorovateľa k porovnaniu vizualizovaných dátových bodov alebo informácií,
- popisovať dátovú vzorku a vzťahy premenných v rámci nej na niekoľkých úrovniach, od všeobecného prehľadu (deskriptívna štatistika) až po interpretáciu komplexných vzťahov premenných v rámci vzorky (napr. vizuálna interpretácia predikcií),
- slúžiť jasnému cieľu: deskripcii, explorácii, verifikácii alebo monitoringu,
- byť dobre integrovaná do štatistického, verbálneho alebo písomného kontextu.

Keď sa tvorca vizualizačného systému neriadi hore uvedenými princípmi, s najväčšou pravdepodobnosťou vytvorí grafy, na základe ktorých bude možné dáta interpretovať viacerými spôsobmi. Užívateľovi tak ponúkne zavádzajúci interpretačný výstup, umožňujúci vyvodiť nesprávne závery analýz. Medzi osvedčené postupy pri tvorbe dátových vizualizácií patrí:

- a. Poznať svoje publikum, a pochopiť, ako spracováva vizuálne informácie.
- b. Dizajnovať vizualizácie tak, aby mali interpretačnú hodnotu aj mimo kontextu reportu.
- c. Vizualizovať iba kľúčové informácie v reporte.
- d. Pochopiť dáta, ktoré sa pokúšate reportovať vizualizáciou, vrátane ich veľkosti, objemu a jedinečnosti dátových hodnôt.

- e. Mať na pamäti, čo sa snažíte vizualizovať, aký druh informácií chcete komunikovať a aké otázky chcete prezentovanou vizualizáciou zodpovedať.

Pridanou hodnotou vizualizácií v softvérovej podobe je ich možná interaktivita. Interaktívne vizualizácie vystavané na kvalitnej vzorke pomáhajú pochopiť, aké faktory ovplyvňujú dynamiku konkrétnej premennej v dátach, zachytiť signifikantné zvýšenie alebo zníženie hodnôt, predpovedať objem a frekvenciu dát alebo špecifických dátových posunov, či identifikovať oblasti zberu dát, ktoré si vyžadujú pozornosť alebo zlepšenie.

5. Architektúra dátovej vizualizácie a prezentácie

Architektúra dátovej vizualizácie a prezentácie je systém usporiadania vizualizácií, kontextuálnych informácií o grafoch, popisného textu a ovládačov (nástrojov), do ktorého je samotná vizualizácia integrovaná.

Takáto architektúra, ako celok, má dva hlavné ciele:

- a) Použiť dáta za účelom poskytnutia nových vedomostí čo najefektívnejším možným spôsobom - minimalizovať šum, zložitosť informácie a nepotrebné dáta. Zachovať interpretačný detail dát v kontexte potrieb pozorujúceho.
- b) Poskytnúť relevantné, včasné a úplné údaje, pre každého člena publika, jasným a zrozumiteľným spôsobom. Vizualizácia musí prezentovať výsledky takým spôsobom, aby z nich bolo možné odvodiť rozhodnutie alebo ďalšie kroky, ktoré je nutné podniknúť.

S uvedenými cieľmi na pamäti, môžeme pomocou nasledujúcich bodov vybudovať kvalitnú architektúru dátovej prezentácie:

- Vytvorenie nástrojov a mechanizmov, ktoré efektívne interpretujú informáciu každému členovi očakávaného publika. Tie sa môžu meniť v závislosti od jeho úlohy, role, lokácie a prístupu k technológiám.
- Identifikovanie relevantnej informácie – dôležitých výsledkov - pre každého člena publika v danom kontexte.

- Identifikácia správnych vstupov. Ktoré premenné vizualizovať a ktoré reportovať aj v texte? Treba tiež definovať historický dosah dát a šírku vzorky (t.j. počet premenných) a identifikovať dostatočnú granularitu dát, na úrovni ktorej chceme výsledky vizualizovať.
- Stanovenie správneho načasovania pre prezentáciu dát. Kedy a ako často užívateľ potrebuje aktualizovanú vizualizáciu?
- Kvalitná vizualizácia samozrejme vyžaduje správnu aplikáciu analytických nástrojov. Niektoré grafy (napr. klastrový graf) a dokonca aj celé architektúry dátovej prezentácie sa spájajú s konkrétnymi analytickými metódami (napr. forest-tree interpretácia a architektúra reportovania dát pri meta-analýze).

6. Vizualizácia kvantitatívnych informácií

Samozrejme, je rozdiel, či vizualizujeme kvalitatívne alebo kvantitatívne dáta. Pretože tento projekt sa venuje výhradne zberu, manažmentu, analýze a interpretácii kvantitatívnych dát, na nasledujúcich riadkoch si popíšeme aké kvantitatívne informácie je možné vytiahnuť z dátového setu. Kvantitatívne informácie, ktoré analytik komunikuje tretím stranám, alebo sa sám snaží pochopiť prostredníctvom vizualizácie, sa dajú rozdeliť do ôsmich typov.

1. **Nominálne porovnania:** Porovnávanie kategorických členení bez špecifického poradia kategórií degraduje porovnávané kategorické, ordinálne alebo intervalové premenné na nominálne minimum. Napriek tomu, že jednoduchosť je vo vizualizácii dát ultimátnou sofistikáciou, je nutné sledovať akým spôsobom interpretujeme takto zjednodušený popis vzťahu medzi premennými a aký inferenčný potenciál má takýto graf.
2. **Ordinálne porovnania:** Kategorické premenné môžu byť zoradené vzostupne alebo zostupne, čím sa stávajú ordinálnymi premennými. Miera výroby alebo spotreby po dobu posledných dvoch rokov môže byť transformovaná na kategorickú premennú, ak zoradíme spotrebu podľa spotreby v okresoch v SR od energeticky naj náročnejšieho okresu po najmenej náročný. Stĺpcový graf (bar chart) môže byť použitý pre demonštráciu poradia a jednotlivých rozdielov medzi skupinami dát.
3. **Pomer k celku:** Kategorické dáta môžu byť interpretované tiež ako pomer vlastného objemu k celkovému setu dát (napr. v percentách zo 100%). Koláčový graf (pie chart)

môže ukázať aký vzťah má spotreba v Bratislavskom kraji, celkovej spotrebe elektrickej energie na Slovensku.

4. **Časové rady/série:** predstavuje jednu alebo viacero premenných meraných po určitú dobu. Príkladom je miera výroby a spotreby po dobu posledných dvoch rokov. Klasický čiarový graf (line graph) môže byť použitý pre demonštráciu trendov na časových radoch.
5. **Odchýlky:** Pozorovanie kategorických alebo kontinuálnych dátových bodov môže priniesť intenzívnejší náhľad vtedy, keď sa sledujú dátové odchýlky, napríklad od priemeru vzorky alebo od očakávaných hodnôt. Príkladom v našom projekte je vizualizácia rozdielu medzi očakávanou (predikovanou) spotrebou alebo výrobou a reálne dosiahnutými hodnotami. Stĺpcový graf odporúčame pre vizualizáciu rozdielov medzi malým počtom väčších časových úsekov. Na porovnania v reálnom čase a kontinuálne vykresľované porovnania odporúčame klasický čiarový graf. Pridanú interpretačnú hodnotu v prípade vizualizácie odchýlky alebo porovnaní dvoch hodnôt pomocou čiarových grafov, má pridávanie takzvaných chybových intervalov (error bars) k jednotlivým bodom predikcie alebo pravdepodobnostného merania. Pridaním tejto vizuálnej informácie vieme ohodnotiť mieru, s akou sa popisované predikcie spresňujú. Na druhú stranu, intervaly chýb, alebo vizualizácia akejkoľvek variability meraní, vizuálne komplikuje vykreslený čiarový graf. Nepreferujeme preto ich fixnú aplikáciu, ale možnosť ich aktivácie v grafe.
6. **Distribúcia frekvencií:** Vizualizácia frekvencií a ich distribúcie informuje o počte pozorovaní konkrétnych hodnôt vybraných premenných pre daný interval. Zmysluplným príkladom v energetike môže byť reportovanie o frekvenciách výskytu extrémnych hodnôt spotreby elektrickej energie za jednotlivé mesiace. Histogram, je druh stĺpcového grafu, ktorý môže byť použitý pre túto analýzu. Pridanou hodnotou k histogramu môže byť vizualizácia očakávanej-predikovanej distribúcie. Takzvaný Boxplot graf pomáha vizualizovať základné štatistiky o distribúcii hodnôt, ako je priemer, medián, maximum, minimum alebo kvartily. Zaujímavé však je, že komplexnejšie histogramy a jednoduché boxploty sú už za hranicou intuitívnej interpretácie ľudí bez štatistického vzdelania.
7. **Korelácie:** Pre zodpovedanie otázky či a do akej miery majú dve premenné tendenciu pohybovať sa v čase spoločne, používame bodové diagramy (scatter plot). Štandardne je k týmto typom vizualizácie pridávaná numerická informácia o smere a type vzťahu. Tieto faktory sa tiež dajú vyjadriť v grafe, pomocou chybových intervalov a šípk smerovania vzťahu. Príkladom sledovania typu korelácie v energetike môže byť reportovanie vzťahu medzi teplotou ovzdušia a spotrebou. Intenzitu a smerovanie tohoto

vzťahu je dobré kontinuálne sledovať, nakoľko tu korelácia nie je lineárna a zároveň jej hodnoty majú epizodický charakter. Pre modely predikcie spotreby elektrickej energie, je dôležité sledovať aj korelácie medzi aktuálnou spotrebou, na úrovni hodín, dní, týždňov a mesiacov a minulou spotrebou, na úrovni identického časového úseku.

8. **Geografické a geo-temporálne vzťahy:** Porovnávanie premenných, ich frekvencie a distribúcie výskytu konkrétnej hodnoty na mapách predstavuje dvojsečnú zbraň. Na jednu stranu, vykresľovanie hodnôt priamo na konkrétny geografický výsek môže analytikovi ponúknuť pridanú informáciu o priestorovej distribúcii výskytu analyzovanej udalosti alebo javu a je omnoho ľahšie interpretovanejšia, ako komplexné tabuľky, ktoré by sme museli využiť ako alternatívu. Na strane druhej, dizajnéri často používajú tento typ vizualizácie dát aj tam, kde neprináša žiadnu pridanú hodnotu, len preto, lebo je vizuálne atraktívna. Typ grafu ktorý sa na takúto vizualizáciu používa sa volá kartogram. Vo vizualizácii spotreby a výroby elektrickej energie majú kartogramy široké využitie. Od sledovania a hodnotenia efektivity fotovoltaiiky a veterných elektrární, ktoré sú priamo závislé na konkrétnej geografickej polohe, cez optimalizáciu stavby nových článkov v sieti až po sledovanie porúch (väčšinou sú geograficky špecifické) a vizualizáciu kartografických častí siete. Interpretačnú hodnotu kartografu vieme zvýšiť, pokiaľ je mapa na ktorú vykresľujeme dáta trojdimenzionálna – obsahuje informáciu o nadmorskej výške geografických bodov (tieto informácie sú dôležité najmä pre fotovoltaiiku a veterné elektrárne). Dynamickou vizualizáciou vieme reportovať aj vplyv času na dáta vykreslené na mape. Na identifikovanie a vizualizáciu štatisticky významných zmien v čase, závislých na geografickej lokácii, musíme dáta podrobiť geo-temporálnej analýze. Tento typ analýzy nehľadá kauzálne vzťahy ale série temporálnych a geografických korelácií v dátach.

Pri tvorbe konkrétnej architektúry vizualizácie a prezentácie kvantitatívnych dát, by dizajnér mal zvážiť, či sú pre zodpovedanie otázok potrebné všetky alebo len niektoré z vyššie uvedených typov premenných a analýz. Použité typy vizualizácií pre konkrétne analýzy následne závisia najmä od druhu publika, ktorému budú vizualizácie interpretované. Preto aj v tomto reporte o využívaní vizualizácií v kontexte Smart Grid, považujeme za nevyhnutné popísať osobitne vhodné typy vizualizácií dát pre bežných spotrebiteľov a výrobcov na strane OOM a typy vizualizačných nástrojov vhodných pre profesionálnych analytikov veľkovýrobcov, veľkospotrebiteľov a v inštitúciách ako OKTE, SEPS alebo obchodníkov s elektrickou energiou.

7. Vizualizácie do systémov pre malých výrobcov a spotrebiteľov

Jednou z najväčších výziev ohľadne spotrebiteľov ktorejkoľvek služby, v rámci ktorej majú títo možnosť dozvedieť sa o sebe viac vďaka prístupu k dátam (v tomto prípade k dátam o vlastnej spotrebe) je rozhodnúť sa akú vizualizáciu dát pre nich zvoliť, aby bol charakter dátového toku reprezentovaný presne, aby vizualizácia dáta neskresľovala. Neodporúča sa ponúknuť technicky a metodologicky nevzdelanej cieľovej skupine len čisté dáta a ich agregáty s veľa možnosťami ich vizualizácie a spoliehať sa na to, že si budú generovať na dátach grafy, aké považujú za vhodné. Obdobný problém je aj pri interpretácii už vygenerovaných grafov. Pri testoch schopnosti priemernej populácie správne interpretovať komplexnejšie vizualizácie, táto zručnosť značne varíuje, opakovane vo viacerých štúdiách. Preto nechať na užívateľa aby generoval multi-dimenzionálne vizualizácie a následne sa ich snažil správne interpretovať, je v praxi skôr kontraproduktívne.

8. Vizualizačné štandardy

Pri tvorbe vizualizácií a vizualizačných nástrojov pre všeobecnú verejnosť teda platí, že redukcia dát a počtu funkcií nástroja za účelom štandardizácie výstupu sa oplatí aj na úkor straty prirodzenej komplexity dát a množstva rôznych grafov, ktoré by sme na dáta mohli aplikovať. V tomto kontexte je dominantným cieľom jednoduchosť nástroja, zníženie počtu jeho funkcií na minimum, dosiahnutie intuitívnej a korektnej interpretácie dát užívateľom, teda celková štandardizácia interakcie s nástrojom a jeho vizualizáciami.

Navrhujeme preto, aby komerčné analytické produkty a služby monitoringu a predikcie pre vlastníkov/užívateľov malých OOM obsahovali modul takzvanej automatickej vizualizácie. Takýto modul by mal fungovať na základe dopredu definovaných pravidiel, na princípe ktorých sa vytvorí architektúra dátovej vizualizácie pre daný produkt alebo službu. Tieto pravidlá nazývame štandardy vizualizácie. Okrem samotných potrieb užívateľov, sú jedným z kritérií ovplyvňujúcich výber funkcií reportovania dát, pri vývoji finálneho monitorovacieho produktu.

Tieto fixné pravidlá popisujú tri informačné zložky:

- i) aký typ dát (napr. konkrétna premenná, jej dátový zdroj, dátová frekvencia, jednotky premenných, temporálna charakteristika premennej, atď.), aký typ výsledkov analýz

(napr. meta-premenné) či štatistickej manipulácie (napr. sumárne premenné, ako medián alebo deskriptívne premenné ako minimum a maximum spotreby), má byť vizualizovaný,

- ii) akým typom grafu, s akými pomocnými informáciami, v akom formáte (napr. text tabuľka, legenda),
- iii) za účelom zodpovedania akej otázky užívateľa, s akou očakávanou interpretáciou. Jednoduchým príkladom takýchto pravidiel môžu byť body 1.-8. v časti „4. Vizualizácia kvantitatívnych informácií“ tohto reportu.

Z našej skúsenosti vo vývoji komerčných produktov a služieb obsahujúcich analytické a vizualizačné moduly, považujeme tvorbu štandardov vizualizácie dát za nevyhnutnú. Naša analýza pätnástich podobných produktov a služieb, ponúkaných malým spotrebiteľom a výrobcom elektrickej energie v Európe a Amerike ukázala, že tieto sa výrazne odlišujú vo svojich štandardoch vizualizácie dát (dokonca aj keď sú od jedného výrobcu) čo užívateľovi značne sťažuje ich interpretáciu. Dopredu definované štandardy značne zefektívňujú vývoj nových produktov a ich implementáciu, fungujú ako orientačný manuál pri tvorbe nových funkcionalít v zavedených produktoch, pomáhajú dlhodobo udržiavať štandardy, na ktoré sú užívatelia zvyknutí v našich produktových radách alebo službách a tým užívateľom zjednodušujú interakciu s našimi nástrojmi a samotnú interpretáciu výsledkov z našich grafov.

9. Modul automatickej vizualizácie

Ako sme spomenuli vyššie, na základe štandardov vizualizácie dát pre OOM, odporúčame vytvoriť modul automatickej vizualizácie pre každú, v budúcnosti, vyvíjanú službu alebo analytický produkt pre malých spotrebiteľov a výrobcov. Tento softvérový modul rozhodne za užívateľa, akým spôsobom sa majú optimálne vizualizovať typy premenných (alebo ich interakcií), ktorú užívateľ zvolil. Užívateľ samozrejme dostane možnosť manipulovať vizualizáciu – napríklad zvoliť nižšiu granularitu dát, pozrieť sa na konkrétny časový výsek alebo porovnať súčasné dáta s historickým priemerom, no nemal by rozhodovať o tom, v akom type grafu sa dáta vykreslia. Pokiaľ modul usúdi, že pridaním ďalšej premennej sa zmysluplnosť aktuálnej vizualizácie stráca, vyberie nový typ grafu, ktorý má lepší interpretačný potenciál. Takýto modul si nevyžaduje žiaden komplexný pravdepodobnostný rozhodovací model (umelú inteligenciu), nakoľko funguje na sériách jednoduchých pravidiel, extrahovaných z dopredu jasných vizualizačných štandardov. Samozrejme, modul systému je možné spraviť aj inteligentným, učiacim sa na základe správania sa užívateľov. Tu by malo zmysel zamerať sa


na schopnosť modulu navrhovať užívateľovi premenné, ktoré by mal pridať do vizualizácie, na ktorú sa práve pozerá, lebo majú potenciál dať mu hlbší náhľad do situácie (napr. porovnania na viacerých časových úsekoch, porovnania medzi jeho a cudzím OOM). Zmyslupnosť týchto pokročilých funkcií monitoringu je však nutné overiť, interakciou s potenciálnymi užívateľmi.

10. Vykresľovane aktuálnych a historických dát pre malých výrobcov a spotrebiteľov

Centrálnou vizualizáciou v produktoch pre malých spotrebiteľov je zobrazenie ich aktuálnej a historickej spotreby. Graf by mal byť stavaný na dátach s granularitou podľa predvoleného nastavenia - 15 minútové, hodinové, denné, dekádné dáta. Možnosť voľby granularity dát má zmysel dynamicky integrovať priamo do vizualizácie, nakoľko pri grafoch vykresľovaných kontinuálne užívatelia granularitu dát menia často. Na základe nášho prehľadu existujúcich komerčných produktov v tejto oblasti, by tento graf mal obsahovať **následné funkcie**:

Dynamické rozlíšenie grafu a analýza výseku konkrétneho obdobia:

Odporúčame, aby graf bolo možné približovať alebo vzdďaľovať, čím sa bude upravovať granularita vizualizovaných dát. Z pohľadu UI by táto funkcia mala byť ovládaná jednoduchým pohybom myši a klávesovou skratkou (napr. ctrl + rolovanie myškou), pri mobilných zariadeniach pomocou ťahania dvoch prstov od seba. Užívateľ by mal mať možnosť vizualizovať všetky premenné v ľubovoľnom časovom výseku.



Graf 1. Klasický graf zobrazenia aktuálnej a historickej spotreby užívateľa je pri požadovanom rozlíšení a zachovaní reálne nameraných hodnôt často veľmi členitý a ťažko sa z neho odčíta intenzita trendu. Odporúčame preto pridať možnosť zjemniť graf algoritmickou funkciou “graph smoothing”, ktorá eliminuje extrémne minimá a maximá.


Posun grafu pri pridávaní nových hodnôt a posun do historických meraní:

Nové hodnoty meraní sa do grafu sa majú zakresľovať kontinuálne. Užívateľ má mať možnosť prehľadávať dátovú minulosť. Ak by táto funkcia bola objemovo náročná, historické dáta od konkrétneho dátumu (napr. $t - 2$ roky) môžu byť vizualizované ako agregáty. Je dôležité, aby sa užívateľ mal možnosť pozrieť sa na všetky svoje historické dáta aspoň v agregovanej podobe.

Možnosť prejsť na graf a odčítať konkrétne charakteristiky merania:

Selektovanie konkrétneho dátového bodu v grafe by malo spustiť okno s bližšou informáciou o danom meraní (napr. nameraná spotreba, čas merania, vzťah s priemerom za posledný týždeň, atď.). Pre zvolený časový úsek, by mal graf reportovať priemernú spotrebu a mieru variability. Mala by existovať voľba, či užívateľ chce tieto informácie vizualizovať ako líniu v

priemeru alebo mediánu s intervalom minima a maxima priamo v grafe alebo ich mať v malej informačnej tabuľke mimo hlavného grafu. Napriek tomu, že väčšina nástrojov, prítomných na trhu, do grafu spotreby alebo výroby zakresľuje klasickú priemernú spotrebu alebo medián, my odporúčame, aby sa do grafov zakresľoval takzvaný plávajúci priemer. Na rozdiel od klasickej linky priemeru (ktorá by v grafe bola reprezentovaná rovnou priamkou), plávajúci priemer je konštruovaný zakresľovaním priemerných hodnôt pre jednotlivé merania na danom časovom úseku. Takýmto spôsobom vie užívateľ porovnať svoju výrobu alebo spotrebu s priemernou spotrebou užívateľov pri každom novom meraní, na rozdiel od porovnávania so svojou vlastnou históriou. Z našej skúsenosti vieme, že užívatelia majú menšie problémy pri interpretácii svojich dát ak ich porovnávajú s dátami iných ľudí a nie so svojimi vlastnými historickými dátami. Tento úkaz - že sa človek efektívnejšie porovnáva s inými ľuďmi v reálnom čase, ako so sebou samým historicky - pramení, ako mnoho iných pravidiel vizualizácie dát, z kognitívnej psychológie.




Graf 2. Graf zobrazuje historickú spotrebu užívateľa (oranžová linka) a zakresleným plávajúcim priemerom (zelená linka). Plávajúci priemer môže byť generovaný z meraní užívateľov v blízkej geografickej oblasti, z meraní užívateľov s podobným spotrebným/výrobným profilom alebo z historických dát samotného užívateľa.

Ukážka hodnôt trendu v spotrebe:

Okrem priemeru alebo mediánu, by sme malým spotrebiteľom a výrobcom mali ponúknuť možnosť vizualizovať trendy ich aktivity. Historický trend by mal byť vizualizovaný jednoducho, ako štandardizovaná linka v grafe. Kliknutím na linku v grafe (alebo sledovaním tabuľky vedľa grafu) má užívateľ dostať informáciu o tom ako intenzívne trend rastie, kedy v histórii mal najradikálnejší nárast/pokles a aké bude predikované správanie trendu do budúcnosti (napr. dni, týždne, mesiace). Ako správne vizualizovať extrapoláciu trendu na základe historických dát? Linka popisujúca historický trend sa po čase t na osi X grafu rozpadne na pole hodnôt, ktoré trend dostane s danou pravdepodobnosťou. Prirodzene, čím viac do budúcnosti bude užívateľ graf posúvať, tým širšie bude pole možných hodnôt.

Aktivácia pokročilých funkcií:

Odporúčame, aby ku grafu bol priradený panel, prostredníctvom ktorého môže užívateľ zapínať pokročilé funkcie, ako porovnávanie hodnôt spotreby/výroby, na danom časovom úseku s hodnotami pred týždňom, mesiacom alebo rokom. Tieto vymenované časové celky budú mať preddefinované voľby na paneli funkcií, ktoré automaticky vygenerujú zvolenú linku pre porovnanie s aktuálnou spotrebou aj s informáciami o rozdieloch v hodnotách týchto premenných. Užívateľ by mal mať možnosť nastaviť aj vlastný časový úsek (napr. ak chce porovnať výrobu z prvého týždňa marca s tretím týždňom januára).



Graf 3. Graf ukazuje výsek historickej spotreby porovnaný s predchádzajúcim obdobím (deň, týždeň, mesiac alebo rok). Graf je generovaný s hodinovým rozlíšením dát. Línie v grafe sú upravené funkciou “graph smoothing”.

11. Zobrazenie spotrebného profilu a jeho gamifikácia

Sekundárne vizualizácie v službách a produktoch pre malé a stredné OOM, by mali obsahovať hlavne informácie o type spotrebného či výrobného profilu užívateľa. Toto štatistické profilovanie informuje spotrebiteľov intuitívnou cestou o tom, akým štýlom spotrebovávajú elektriku a malo-výrobcov o tom ako optimalizovať výrobu. Prvým zdrojom, na základe ktorého sa profil generuje sú historické dáta užívateľa. Druhým zdrojom, sú historické dáta užívateľov s podobnou geografickou lokáciou a podobným spotrebným alebo výrobným profilom. Z pohľadu profilovania užívateľov zaujímavé sú aj sociodemografické dáta a meteorologické dáta. Profil každého užívateľa sa postupom času spresňuje. Prostredníctvom monitoringu sa v ňom sledujú a automaticky reportujú štatisticky významné zmeny v správaní užívateľa.

Okrem toho, že vizualizácie spotrebného a výrobného profilu umožňujú užívateľovi získať hlboký náhľad do svojich dát a optimalizovať tak svoje správanie, takéto profilovanie zároveň výrazne spresňuje predikcie výroby a spotreby pre konkrétneho užívateľa, alebo skupinu podobných užívateľov.

Vizualizácie profilu spotreby majú zároveň slúžiť ako interaktívna časť softvérového produktu, na rozdiel od centrálného grafu spotreby/výroby a jeho panelu pokročilých funkcií, ktorý reprezentuje skôr analytickú časť aplikácie. Na základe prehľadu aktuálne dostupných služieb na zahraničných trhoch a našej skúsenosti, by táto časť mala obsahovať tieto **interaktívne funkcie**:

Stanovenie a monitorovanie cieľov plánovanej výroby a spotreby:

Spotrebiteľ by mal mať možnosť nastaviť si plánované ciele spotreby na konkrétny časový úsek. Tak isto, malý výrobca by mal mať možnosť si vizuálnou formou priamo v grafe označiť očakávanú mieru výroby na najbližšie obdobie. Vložiť úsečku očakávanej spotreby alebo výroby priamo do grafu historickej spotreby je pre užívateľa intuitívnejšie, ako zapisovať očakávané hodnoty do tabuliek – čo je aktuálne realitou väčšiny produktov na trhu. Súčasné monitorovacie produkty nemajú ešte dve veľmi dôležité charakteristiky tejto funkcie.

Prvou je, možnosť automaticky odporúčať užívateľovi akú očakávanú hodnotu má zvoliť, respektíve v akom rozmedzí hodnôt má nastaviť svoj cieľ. Toto odporúčanie vie systém poskytnúť na základe predikcie z historických dát užívateľa, dát profilovo podobných užívateľov a predpovede počasia. Takéto odporúčanie má pre užívateľa vysokú hodnotu, nakoľko na základe neho vie aký veľký pokles/nárast spotreby/výroby môže očakávať, čo mu umožní stanoviť si realistické ciele. V aktuálnych systémoch na trhu, toto stanovenie si cieľov užívateľmi nie je kontrolované prostredníctvom reálnych dát. Užívatelia si preto nastavujú príliš optimistické ciele bez ohľadu na reálny trend ich spotreby alebo výroby. Kontinuálne nespĺňanie takto nastavených cieľov užívateľa domotivuje.

Tým prichádzame k druhej charakteristike, ktorú nemajú súčasné systémy, disponujúce možnosťou nastavenia budúcich spotrebných cieľov. Užívateľ v nich nie je systémom odmenený za splnenie svojich cieľov. Odporúčame, aby sa v tomto prípade využili nástroje gamifikácie – motivovania užívateľov prostredníctvom virtuálneho oceňovania. Tieto mechanizmy nepracujú z odmeňovaním finančným, ale inými psychologickými formami. Jedným z najefektívnejších gamifikačných mechanizmov je tvorba virtuálnej meny, ktorú

užívateľ získa za splnenie úlohy (v našom prípade za splnenie svojich cieľov spotreby). Túto menu môžu predstavovať jednoduché body z ktorých sa počíta skóre. Dôležitou súčasťou motivačného mechanizmu je potreba prezentovať toto skóre vizuálne, teda žiadne tabuľky a čísla, skôr hviezdičky (ako je tomu pri motivovaní užívateľov v on-line službách) alebo iné grafické indície. Automobilky Toyota a Hunday odmeňujú šoférov svojich elektrických aj benzínových áut za optimalizáciu spotreby energie tak, že sa im digitálna palubovka postupne dekoruje zeleným brečtanom tým viac, čím úspornejšie jazdia. Táto gamifikácia zožala veľký úspech a Toyota reportuje radikálne pozitívne a hlavne dlhodobé zmeny v správaní vodičov.

Porovnávanie s priemerom susedných OOM, alebo s OMM s podobným profilom:


Táto funkcia samozrejme vychádza z predpokladu, že centrálny systém má prístup k agregovaným informáciám o spotrebe a výrobe užívateľov v bezprostrednom okolí konkrétneho OOM. Ako sme spomínali, porovnávanie svojho správania so správaním iných, nám podobných ľudí je pre užívateľov vždy zaujímavejšie, ako porovnávanie svojho súčasného stavu s svojím stavom v minulosti. Preto v rámci profilu spotreby užívateľa odporúčame vizualizovať porovnanie jeho spotreby buď s geograficky susediacimi užívateľmi, alebo užívateľmi s podobným spotrebným/výrobným profilom. K vizualizácii tejto informácie sa priamo viaže hneď niekoľko gamifikačných nástrojov.

Prvým a asi najsilnejším je súťaž. Užívateľ by mal dostať na výber, či chce iba vidieť ako si vedie jeho okolie alebo chce aby agregát z jeho dát bol vizualizovaný iným užívateľom. Užívatelia ktorý si zvolia druhú možnosť tak robia preto, lebo sa chcú motivovať pomocou ostatných. Efektivita tohto veľmi základného ľudského motivačného mechanizmu bola potvrdená v komerčných produktoch a službách v mnohých oblastiach. Jedným spôsobom ako vizuálne prezentovať rozdiely v efektívnej spotrebe medzi užívateľmi je prostredníctvom takzvaných statusových tokenov.


Status je vec, ktorú ľudia musia budovať vždy, keď sa na to nájde príležitosť, dôvody tohto správania majú svoje opodstatnenie v evolučnej neuropsychológii. V bežnom živote sa užívatelia motivujú statusom už tradične (napr. platinové karty, v.i.p. členstvá, bronzový strieborný a zlatý bankový účet). Status (alebo postup z jedného statusu na lepší) sa v gamifikačných systémoch získava za aktivitu, ktorá je komerčne žiadúca, v našom prípade to môže byť optimalizácia spotreby na strane spotrebiteľov a optimalizácia výroby na strane malých a stredných výrobcov. Motivácia pomocou statusu má zmysel len vtedy, pokiaľ je status viditeľný v konkrétnej komunite užívateľov.

Graf porovnávania spotreby susedných OOM je veľmi dobré miesto na túto charakteristiku. Užívateľ môže získať status podľa toho ako efektívne spĺňa svoje ciele a je schopný vidieť, aké výsledky dosiahli ostatní, jemu podobný užívatelia. Ako pri skóre, aj pri statuse je pravdou, že sa má uvádzať vizuálne - napríklad ako virtuálne odznaky, ktoré užívateľ získa za splnenie cieľov, nikdy ako čistá numerická hodnota.

Samozrejme si uvedomujeme, že to do akej miery budú môcť užívatelia študovať spotrebu iných užívateľov systému je okrem ich vôle limitované aj zákonom. Hore popísaná funkcia sa vie prispôbiť týmto podmienkam buď agregovanými dátami (napr. agregovanými v čase alebo agregovanými podľa priemeru skupiny užívateľov) či obmedzením miery, do akej sa môže užívateľ porovnávať s konkrétnym užívateľom. Funkcia je schopná efektívne pracovať aj s relatívne malým počtom dát.




Graf 4. Porovnanie spotreby na selektovanom výseku historických dát s priemerom z meračov v geografickom susedstve. Graf je generovaný s hodinovým rozlíšením dát. Línie v grafe sú upravené funkciou "graph smoothing". Po selekcii tohto grafu užívateľ vidí, že jeho historická spotreba bola viac-menej priemerná.




Graf 5. Vizualizačný modul je schopný vykresliť vzťah medzi skupinami užívateľov rozdelených podľa podobnosti spotrebných profilov (faba blokov), historickou spotrebou (výška blokov) a geografickou lokáciou OOM (umiestnenie na mape). To isté platí pre malú a strednú výrobu, napríklad fotovoltaiku.

Monitorovanie financií viazaných k optimalizácii užívateľského správania.

Samozrejme, jasným indikátorom efektivity profilu je množstvo peňazí, ktoré spotrebiteľ ušetril vďaka optimalizácii jeho spotreby. To isté platí aj pre výrobcov. Do profilu odporúčame uviesť túto informáciu vo vizuálnej podobe. Hodnotu odporúčame počítať ako rozdiel aktuálnej hodnoty od dlhodobého priemeru hodnoty – tak pri ušetrených financiách pri spotrebe ako aj zárobkových rozdieloch pri výrobe. Táto funkcia predpokladá, že máme k dispozícii informáciu o cenách elektrickej energie počas dňa. Ak by sme tieto dáta zbierali, mohli by sme zároveň dať užívateľom možnosť farebne odlíšiť linky v grafe podľa aktuálnej ceny v danej hodine, alebo inom časovom úseku.





Graf 6. Vizualizačný modul bude schopný vykresliť vzťah medzi cieľmi spotreby alebo výroby nastavenými užívateľom a množstvom ušetrených (spotrebiteľ) alebo zarobených (výrobca) peňazí. Systém by podľa čísla SmartMetra vedel lokalizovať budovu na mape a zafarbiť ju podľa energetickej efektivity OOM. Užívateľovi sa zafarbí len budovy, ktoré súhlasili so zverejnením dát.

Detekcia lokálnych maxím v spotrebe:

Na základe dát o spotrebe z jednotlivých spotrebných miest – ideálne domácností, sme schopní detekovať aktivitu veľkých spotrebičov (napr. práčka, chladnička, boiler) počas dňa a navrhovať presun ich používania do časov s lepšou cenou elektrickej energie. Samozrejme, tieto časy budú limitované tak, aby neovplyvňovali beh domácností (napr. systém nebude odporúčať spúšťanie práčky o 02:00).

12. Vizualizácie do systémov pre veľkých výrobcov, spotrebiteľov a monitorovacie inštitúcie

Vizualizačné moduly postavené nad analytickými nástrojmi používanými vo väčších elektrárňach a vo veľkoch kontroly a optimalizácie spotreby veľkých spotrebiteľov, ako sú továrne, výrobné parky a závody, majú pochopiteľne odlišný charakter ako vizualizácie pre nízkokapacitné OOM. Pre potenciálnych užívateľov tohto typu sú najdôležitejšie informácie

o historických, aktuálnych a predikovaných možnostiach optimalizácie spotreby a maximalizácie výroby.

Z funkcií popísaných vyššie preto v dizajne aplikácií musíme uprednostniť hlavne automatické odporúčanie temporálnej lokalizácie spotrebných maxím, na základe historických dát o spotrebe, historických dát z meteorológie, predikcie spotreby a meteorologických predpovedí. Stabilné premenné budú reprezentované demografickými premennými a charakteristikami siete. Žiadúce je vizualizovať korelácie medzi spotrebou, výrobou a cenou elektrickej energie, či trendy v ušetrených nákladoch pre veľkých spotrebiteľov a kumulatívnych ziskoch prameniacich z optimalizácie a inteligentného nastavenia cieľov na strane výroby.

Treťou, z pohľadu potrieb vizualizácie špecifickou, skupinou sú inštitúcie ako SEPS alebo OKTE a jednotlivé distribučné inštitúcie. Títo potenciálni užívatelia systému monitorujú spotrebu na väčších geografických územiach. Zároveň je jasné, že za účelom svojej aktivity majú už v súčasnosti implementované základné vizualizačné a analytické systémy. Preto sa domnievame, že najväčšia pridaná hodnota by sa im dala ponúknuť v implementácii alternatívnych nástrojov na interpretáciu predikčných metadát a vizualizácií výsledkov korelačného a kauzálneho modelu, spájajúceho dáta z meteorológie, socio-demografie, spotreby a výroby.


Z nášho výskumu trhu je zrejmé, že obdobné inštitúcie v iných krajinách Európskej únie (napr. Holandsko, Švédsko) v Ázii (Japonsko) ale najmä v krajinách Južnej Ameriky (napr. Argentína, Brazília a Chile) pristúpili na obohatenie pôvodných monitorovacích systémov podobnými modulmi hneď po tom, čo začali zavádzať niektoré systémy kompatibilné s filozofiou Smart Grid. Z príkladov ktoré sme identifikovali, nebol ani jeden z takýchto modulov dodaný výrobcom pôvodných monitorovacích systémov. Príkladom je Chile kde CGE Group – jeden z najväčších hráčov v Južnej Amerike, je pôvodným dodávateľom monitorovacích systémov pre Ministerstvo Energetiky, no moduly vizualizujúce analýzy nad novo nasadenými bezdrôtovými SmartMetrami dodalo konzorcium menších firiem Kamstrup a TECNET.

Takéto príklady zo zahraničia sú indikátorom, že princíp Smart Grid otvára trh s aplikáciami aj pre špecializované malé a stredné podniky. Závisí však aj na schopnosti inštitúcií ako OKTE a SEPS efektívne spolupracovať na výskume a vývoji týchto aplikácií s menšími spoločnosťami. Ministerstvo hospodárstva Brazílie má napríklad program s vyčleneným rozpočtom len na podporu interakcie štátnych inštitúcií regulujúcich trh s elektrickou energiou a malých firiem, ktoré vďaka svojej dynamike dokážu prinášať požadovanú inováciu. Obdobným programom disponuje Japonsko, to sa však zameralo na podporu inovácií spojených s optimalizáciou a monitorovaním prenosovej sústavy.

Implementované inovácie, ktoré sme mali možnosť vidieť, sa z pohľadu vizualizácie jedna od druhej moc nelíšili. Kľúčovou “novinkou” vo všetkých vizualizačných moduloch bolo vykresľovanie komplexnejších štatistík rovno na geografickú mapu. Podľa nášho názoru má tento trend vo vizualizácii energetických dát veľkú budúcnosť. Z pohľadu interpretácie dát a pochopenia vzťahov medzi komplexnými premennými (napr. predikciou počasia, predikciou spotreby a sociodemografiou) je tento prístup oveľa intuitívnejší. Jeho implementačnou podmienkou je však dostatočný počítačny výkon systému, nakoľko takýto typ vizualizácie je pomerne náročný. Samozrejme, aj pri vizualizáciách tohto typu sa dá licitovať s mierou detailu, ktoré poskytujú a tak z časti eliminovať problém počítačného výkonu.



Graf 7. Dve vizualizácie vyššie ukazujú príklad vykresľovania dát na geografické mapy. Tento typ vizualizácie sa volá “heat map”. Vykreslená je tu spotreba v danej mestskej štvrti (mapa vyššie). Mapa sa dá priblížiť a vzdialiť, pri čom sa dátam mení granularita. Mapa nižšie, ukazuje objekty, ktoré majú významný nárast alebo pokles v spotrebe – vymykajú sa priemeru v oblasti. Mapa je schopná interpretovať nielen spotrebné profily jednotlivých OOM, ale aj celkový profil spotreby v danej oblasti. Takéto vizuálne riešenie je počítačne nenáročné.




Graf 8. Vizualizáciu spotreby je možné robiť aj pomocou fraktálov. Tento princíp zachováva kvality heat mapy – vieme z neho vyčítať distribúciu spotreby na geografickej mape a sledovať posuny vysokých hodnôt spotreby cez mapu v čase, no zároveň lepšie odhaduje lokáciu OOM a budov. Mapa sa dá priblížiť a vzdialiť, pri čom sa dátam mení granularita. Takéto riešenie je tiež nenáročné, čo sa počítačného výkonu týka.



Graf 9. Vizualizácie postavené na geografickom princípe môžu byť priamo použité na interpretáciu výsledkov. Takéto typy reportov sa stali v posledných rokoch veľmi populárnymi. Graf vykresľuje množstvo spotrebovanej elektrickej energie (ročné dáta) pre jednotlivé mestské smerovacie čísla. Čím

vyšší je stĺpec, tým väčšia spotreba. Ide teda o analýzu spotreby v kontexte demografie. Podobne sa dajú vykresľovať aj predikcie. Do grafov tohto typu sa dá pustiť niekoľko analýz naraz, pričom je užívateľ stále schopný intuitívne graf interpretovať. Ak by mal tento typ vizualizácie bežať v reálnom čase, vyžadovalo by si to samostatné servery pre vizualizačný modul.



Graf 10. Na tomto grafe je prezentovaný systém takzvanej vizualizačnej analýzy veľkých dát. Užívateľ tohto modulu exekvuje analýzu interakciou s premennými priamo v priestore vizualizácie výsledkov. Pomocou tohto prístupu má aj bežný užívateľ možnosť generovať komplexné analýzy bez toho, aby musel iniciovať analýzu v akomsi štatistickom programe.

Systém dovoľuje vizualizovať naozaj komplexné analýzy na veľkom počte dát a vie byť responzívny v reálnom čase (napr. brať do úvahy novo zaslané dáta). Takýto nástroj v súčasnosti vyžaduje backend centralizovanej štruktúry. Frontend môže predstavovať buď desktopovú alebo webovú aplikáciu. Tento typ vizualizácie je zároveň veľmi dobre zabezpečený proti lúpeži veľkých objemov dát. Príklad vizualizácie hore, ukazuje typ energie využívanej na konkrétnych miestach v USA, objemy energie spotrebovanej v minulom roku a zároveň predikciu na budúci rok. Mapa sa dá priblížiť a vzdialiť, pri čom sa dátam mení granularita ale výpočet premenných zostáva nemenný.

13. Technické špecifikácie vizualizácií

Krátko sa ešte vyjadríme k možnostiam technickej exekúcie vizualizačných systémov alebo modulov, ktoré vizualizujú dáta analyzované už implementovanými analytickými systémami. Dopredu tu uvádzame, že tieto špecifikácie závisia do veľkej miery od možností, ktoré má konkrétny užívateľ, od jeho požiadaviek a od podoby, do akej sa vyvinie súčasná legislatíva. Kľúčové je hlavne byť vo vývoji dostatočne agilný, aby bolo systém možné prispôbiť týmto podmienkam. Dôležité bude kvalitne zadefinovať ponúkanú produktovú radu. Frontend pre systém môže byť riešený ako desktopová aplikácia, alebo HTML5 stránka, využívajúca vhodné knižnice na vizualizáciu dát - napríklad d3. Mobilná verzia by mohla byť vybudovaná buď na technológii HTML5 ako responzívna stránka, využívajúca vhodné knižnice na mobilnú vizualizáciu alebo ako natívna mobilná aplikácia. Výhoda responzívnej stránky je, že nie je nutné programovať osobitnú verziu pre každé mobilné zariadenie. V kontexte vývoja backendu sme pracovali s najnáročnejším predpokladom - že bude potrebné dáta vykresľovať v reálnom čase a že výpočtový výkon bude limitovaný. V koncepte inteligentnej domácnosti, by sa dáta mohli ukladať aj na domáci server, ktoré sú čoraz častejšie. Ak ale chceme porovnávať domácnosť s okolím, stále treba riešiť nutnosť dodávky agregátov z okolia. Preto uprednostňujeme centrálné riešenie. Navyše je možné dáta rozdeliť podľa oblastí a mať samostatnú databázu pre každú oblasť, čo je tak komputačne jednoduchšie ako aj stabilnejšie z pohľadu kybernetickej a dátovej bezpečnosti.

14. Záver prvej časti

Naším cieľom bolo popísať možné systémy vizualizácií, vhodné pre jednotlivé cieľové skupiny integrované v plánovanom systéme SmartGrid. Pozreli sme si produkty a služby existujúce na trhu. Počas analýzy sme sa mali možnosť pozrieť aj na analytické a vizualizačné moduly, ktoré sú implementované v agentúrach na monitoring siete a obchodu s elektrickou energiou v zahraničných krajinách. Výsledkom prieskumu bolo, že napriek existujúcim a implementovaným systémom analýz, existuje značný priestor na zlepšenie v oblasti správneho reportovania a interpretácie dát, pomocou vhodných vizualizačných nástrojov.

Je veľa grafických techník, ktoré môžu byť použité na asistenciu užívateľom snažiacim sa pochopiť priebeh, ktorý im ich dáta ponúkajú. Neznamená to však, že by tieto nástroje mali byť komplexné. Základom intuitívneho systému je jeho vizuálna jednoduchosť a minimálny počet funkcií – eliminácia volieb a možností, ktoré by neboli pravidelne a často používané. Funkčná jednoduchosť systému a intuitívna vizualizácia dát však neznamená, že by systém nemal byť inteligentný.

Práve naopak, monitorovacie a interpretačné moduly by mali aktívne interagovať s užívateľom, odporúčať mu ďalšie kroky na základe historických dát, prostredníctvom vizuálnej informácie (napr. zakresliť odporúčaný cieľ spotreby na ďalší týždeň do grafu reportujúceho aktuálnu a historickú spotrebu). Systém by mal tiež monitorovať spotrebný profil užívateľa a vyvodzovať na základe týchto dát ďalšie štatistické závery.

Je to práve vizualizácia dát (a nie analýza) ktorá má ľuďom pomôcť vidieť informácie, ktoré neboli zrejmé skôr. Napriek tomu že očakávané objemy dát v Smart Grid budú veľmi veľké, pomocou kvalitne vyvinutých a nasadených vizualizačných modulov bude aj pre bežného užívateľa možné vidieť trendy rýchlo a jasne. Je dôležité, aby vizualizácia odovzdala informácie v univerzálnom spôsobe a aby ju bolo možné interpretovať aj bez širokého kontextu.

15. Druhá časť pracovného balíka o vizualizácii dát

Predmetom druhej časti projektového zadania PB 8 venujúceho sa vizualizácii dát, zbieraných a spracovaných v rámci systému SmartGrid, je zozbierať poznatky získané v prvej časti nášho prieskumu aplikácií a výskumu nástrojov a implementovať ich do špecificky zadefinovaných kazuistík – príkladov aplikácií v štruktúrach integrovaných do systémov SmartGrid na Slovensku, ktorých vznik predpokladáme.

Cieľmi realizácie bolo:

1. Identifikovať relevantné aplikácie v systéme SmartGrid, ktorých prítomnosť predpokladáme v blízkej budúcnosti.
2. Popísať štruktúru vizualizačných modulov pre tieto kazuistiky, na základe získaných teoretických poznatkov.
3. Textovať interpretačný potenciál navrhnutých vizualizácií a užívateľských prostredí pre tieto kazuistiky.

4. Realizovať výber a popísať najvhodnejšie open-source knižnice na tvorbu vizualizačných modulov pre aplikácie v systémoch SmartGrid.
5. Informovať o zhodnotení a záveroch prvej a druhej časti pracovného balíka 8: Vizualizácia dát a výskum vhodných postupov.

16. Využitie všeobecných poznatkov pri výskume vizualizačných modulov pre rôzne cieľové skupiny v systéme SmartGrid

Špecifické vizualizácie dát o spotrebe a výrobe elektrickej energie sú globálne považované za funkcie, ktoré bude potrebné vyvinúť pre správny chod systému SmartGrid, pretože jeho účastníkom umožňujú efektívnu interpretáciu a následný manažment dát. Efektívna vizualizácia zbieraných dát v jednotlivých aplikáciách bude v budúcnosti predstavovať značnú konkurenčnú výhodu. Ako sme písali vyššie, z výstupov prvej časti realizácie projektového zadania PB 8 je zrejmé, že kontinuálnym monitoringom prostredníctvom vizualizácií s dostatočnou interpretatívnou hodnotou môžu systémy v SmartGrid eliminovať možnú chybovosť v procese rozhodovania, čím šetria finančné zdroje a urýchľujú exekutívne procesy.

Na pravidlá a štandardy správnej vizualizácie veľkých dátových objemov, ktoré sme popisovali v prvej časti popisu realizácie pracovného balíka, sa môžeme pozerieť ako na generalizované odporúčania a heuristiky, ktoré odporúčame dodržiavať vo všeobecnosti. Aby sme potenciál správnej vizualizácie využili maximálne, len dodržiavať tieto pravidlá určite nebude dostatočné. Je zrejmé, že efektívna aplikácia vizualizácií na konkrétne dáta do veľkej miery závisí na kontexte, v ktorom dáta prezentujeme. Súčasťou tohto kontextu je najmä cieľová skupina užívateľov, ktorej dáta vizualizujeme, jej motivácie, ciele a následné rozhodnutia, ktoré zakladá na interpretácii vizualizovaných dát. Ďalšími časťami kontextu sú štruktúra dátového toku, ktorý má byť vizualizovaný a typ analýz, ktoré je potrebné vizualizovať.

Typy analýzy môžu byť: deskriptívny, exploratívny, verifikačný alebo analýza monitoringu. Keďže tieto kontextuálne zložky vizualizácie dát v rámci SmartGrid značne variujú, je nutné špecifikovať aplikáciu vizualizácií v SmartGrid pre jednotlivé kontexty, ktorých prítomnosť je možné v systéme SmartGrid očakávať. Jedným zo spôsobov, akým nad takouto špecifikáciou uvažovať, je spôsob prostredníctvom popísania kazuistík – prostredníctvom popisu vizualizačných techník na príkladoch so vzájomne čo najrôznorodejším kontextom.

Náš výskum sa preto zameriaval na identifikáciu potrieb, podmienok, limitov, kontextu a nárokov na vizualizačné systémy v konkrétnych vybraných aplikáciách, ktorých existenciu v rámci slovenského SmartGrid očakávame v blízkej budúcnosti. Keďže ľudský faktor, špecificky kognitívne limity človeka, sú pri testovaní a implementácii efektívnej vizualizácie dát kľúčovou premennou, na tejto časti výskumu sme spolupracovali s Ústavom Experimentálnej Psychológie Slovenskej Akadémie Vied, ktorého experti nám poskytli odbornú pomoc v oblastiach poznatkov o kapacite a limitoch ľudskej mysle a jej zmyslových orgánov v kontexte spracovávaní vizualizácií a interpretovania informácií.

17. Možnosti vizualizácie monitoringu energetickej efektivity

Prvou kazuistikou, na ktorú sme sa rozhodli aplikovať získané poznatky o vizualizácii dát o spotrebe a výrobe elektrickej energie, boli systémy riadenia spotreby elektriny orientované na stredných a väčších spotrebiteľov. Pre výber tohto príkladu sme mali niekoľko dôvodov, no najdôležitejší z nich bol fakt, že prítomnosť takýchto systémov v Slovenskom SmartGrid môžeme s istotou očakávať.

Dôvodom na takéto presvedčenie je fakt, že znižovanie spotreby energie a odstránenie plytvania elektrickou energiou nadobúda v súčasnosti pre EÚ neustále väčší význam.

Komisia EÚ vydala v roku 2006 „Akčný plán pre energetickú účinnosť: Využitie potenciálu (COM(2006)0545)“. Cieľom akčného plánu je regulovať a znížiť dopyt po energii a prijať opatrenia zamerané na spotrebu a dodávky s cieľom dosiahnuť 20 % úsporu ročnej spotreby primárnej energie do roku 2020 (v porovnaní s odhadovanou spotrebou energie v roku 2020).

Cieľom týchto opatrení je zlepšiť efektívnosť vo všetkých štádiách energetického reťazca – od dodávok energie po využívanie energie spotrebiteľmi. Novela tohto plánu z roku 2011 (COM(2011)0109) umožnila vznik smernice o energetickej efektívnosti (2012/27/EÚ), ktorá nadobudla účinnosť v decembri 2012. Smernica zahŕňa okrem iného aj tieto požiadavky na členské štáty EÚ:

- obnova minimálne 3 % z celkovej podlahovej plochy budov patriacich ústrednej štátnej správe každoročne od roku 2014, a obstarávanie budov, služieb a výrobkov s vysokou energetickou efektívnosťou, aby verejný sektor šiel príkladom;

- stanovenie národných dlhodobých stratégií na podporu investícií do obnovy bytových a komerčných budov a vypracovanie národných systémov záväzku energetickej efektívnosti alebo rovnocenných opatrení na zabezpečenie každoročnej úspory energie pre koncových spotrebiteľov vo výške 1,5 %;
- do konca roku 2015 vykonanie posúdenia potenciálu na využitie vysoko účinnej kombinovanej výroby a účinného diaľkového vykurovania a chladenia vo všetkých členských štátoch;
- povinné pravidelné energetické audity pre veľké spoločnosti, ktoré sa majú vykonávať aspoň každé štyri roky s výnimkou spoločností s certifikovanými energetickými a environmentálnymi systémami;
- zavádzanie inteligentných sietí a inteligentných meradiel a poskytovanie presných informácií o faktúrach za energiu s cieľom posilniť postavenie spotrebiteľov a podporiť efektívnejšiu spotrebu energie.

V kontexte týchto bodov, má smernica 2010/31/EÚ o energetickej hospodárnosti budov (najmä o izolácii, klimatizácii a využívaní obnoviteľných zdrojov energie) stanoviť metódy na výpočet energetickej hospodárnosti budov, minimálne požiadavky pre nové a existujúce veľké budovy a energetickú certifikáciu. Cieľom tu sprísniť požiadavky na energetickú hospodárnosť v súvislosti:

- so spoločným všeobecným rámcom pre metodiku výpočtu integrovanej energetickej hospodárnosti budov a jednotiek budov;
- s uplatňovaním minimálnych požiadaviek na energetickú hospodárnosť nových budov a nových jednotiek budov, napríklad stanovením, že do 31. decembra 2020 musia mať všetky nové budovy takmer nulovú spotrebu energie;
- s uplatňovaním minimálnych požiadaviek na energetickú hospodárnosť, a to predovšetkým: existujúcich budov, prvkov budov, ktoré sa významne obnovujú, a technických systémov budov vždy, keď sa zabudujú, nahrádzajú alebo modernizujú;
- s energetickou certifikáciou budov alebo jednotiek budov, pravidelnou kontrolou vykurovacích a klimatizačných systémov v budovách a nezávislými systémami kontroly energetických certifikátov a správ o kontrole.

Ďalšia správa uverejnená vo februári 2014 poskytuje technické usmernenia týkajúce energetickej obnovy. Členské štáty budú musieť každoročne podávať správu o pokroku pri dosahovaní národných cieľov energetickej efektívnosti. Z uvedeného je jasné, že systémami monitoringu energetickej efektivity budú musieť disponovať tak štátne a neštátne subjekty zodpovedajúce za audit energetickej efektivity ako aj strední a malí spotrebitelia, strážiaci si limity svojej spotreby.

Na základe vyššie uvedeného sme sa rozhodli skúmať potrebu vizualizácií v troch rôznych systémov riadenia efektívnej energetickej spotreby:

- vizualizácie v kontexte systémov monitoringu energetickej efektívnosti,
- vizualizácie v kontexte modelovania prevádzkových režimov distribučných sietí,
- vizualizácie v kontexte aplikácií pre energetický audit.

18. Vizualizácie v kontexte aplikácií monitoringu energetickej efektivity

Aplikácie na oboch stranách systému (t.j. štát a súkromný sektor) budú predstavovať aplikácie automatického monitoringu, čo znamená, že majú poskytovať analýzu automatickej detekcie štatisticky deviantných hodnôt a rozpoznávať trendy, vedúce k týmto hodnotám. Pre autonómny beh takýchto systémov bude preto potrebné, aby systém vizualizoval výsledky deskriptívnych a verifikačných analýz a nie exploratívnych analýz.

Používatelia týchto aplikácií – ľudia ktorí budú interpretovať vizualizované dáta – potrebujú zodpovedať v princípe dve jednoduché otázky a ich variácie.

Prvou je, či konkrétny subjekt prekračuje stanovené normy energetickej efektivity. Druhou je, aký spotrebný profil viedol alebo potenciálne bude viesť k prekročeniu tejto normy a ako optimalizovať spotrebu subjektu tak, aby k prekročeniu v budúcnosti nedochádzalo.

Monitorovanie, analýza a vizuálna interpretácia odpovedí na tieto otázky si nevyžaduje aplikáciu komplikovaných vizualizačných nástrojov pracujúcich s vyšším počtom dátových tokov (v žargóne vizuálnej analýzy – s vyšším počtom dimenzií).

Pre účely týchto systémov budú postačovať jednoduché deskriptívne grafy, ako klasický dvojdimenzionálny graf spotreby alebo porovnania viacerých spotrebných profilov vykreslených na časovej osi, koláčové, stĺpové a pomerové grafy s indikátormi štatistických odchýlok.

Čo sa týka konkrétnych typov analýz, po našom prieskume možností ktoré, sa ponúkajú v budúcnosti z prostredia SmartGrid a po testoch interpretačného potenciálu so vzorkou participantov, ktorá vo svojej náplni nepracuje s dátami, sme dospeli k záveru, že systémy riadenia spotreby elektrickej energie by mali obsahovať vizualizácie týchto analýz:

1. Nominálne a ordinálne porovnania: Porovnania kategorických premenných pre danú skupinu spotrebiteľov (napr. tri alebo päť kategórií podľa energetickej efektivity), alebo zoradenia spotrebiteľov, alebo ich celkov vzostupne/zostupne - podľa miery spotreby. Pri testoch s participantami, sa pre interpretáciu ukázala hodnotnou vizualizáciou nie len informácia o rebríčku podľa čistej spotreby ale aj informácia o rebríčku podľa indexu zefektívnenia spotreby za konkrétny časový úsek. Napríklad, informácia o tom, ktoré okresy SR zefektívnili svoju spotrebu za dobu posledných dvoch rokov, sa ukázala oveľa ľahšie interpretovateľná, ako informácia o čistých spotrebách okresov za posledné dva roky (platilo to až pre 74% participantov), napriek tomu, že oba údaje boli vizualizované identickým grafom.

2. Odchýlky: Pozorovanie kategorických alebo kontinuálnych dátových bodov spotreby môže priniesť intenzívnejší náhľad vtedy, keď sa sledujú dátové odchýlky, napríklad od priemeru vzorky alebo od očakávaných hodnôt. Príkladom v aplikáciách monitoringu energetickej efektivity je vizualizácia rozdielu medzi očakávanou (predikovanou) spotrebou alebo výrobou a reálne dosiahnutými hodnotami. Pre vizualizáciu rozdielov odporúčame jednoduchý stĺpcový graf, ktorý je vhodný aj pre ľudí s nižším štatistickým vzdelaním.

3. Časové rady/série: Klasický čiarový graf (line graph) môže byť použitý pre demonštráciu trendov spotreby danej inštitúcie alebo skupín OOM v čase. Čiarové grafy v aplikáciách manažmentu efektivity spotreby by mali mať v sebe vizuálne integrovanú linku znázorňujúcu maximálnu povolenú alebo očakávanú hranicu spotreby. V našich testoch sa ukázalo, že vizuálne zapracovaná hranica spotreby v grafe sa interpretuje oveľa jednoduchšie, ako keď je táto hranica komunikovaná v numerickej forme.

4. Korelácie: Príkladom sledovania korelácií v aplikáciách manažmentu spotreby môže byť vykresľovanie vzťahov medzi spotrebnými profilmi viacerých OOM s rôznou úrovňou energetickej efektívnosti na danom časovom úseku. Tieto faktory sa tiež dajú vyjadriť v grafe, pomocou chybových intervalov a šípk smerovania vzťahu. Ďalšou koreláciou, hodnou sledovania, je vzťah medzi aktuálnou spotrebou a historickou spotrebou, na úrovni identického časového úseku.

5. Distribúcia frekvencií: Zmysluplným príkladom v aplikáciách manažmentu spotreby môže byť vykresľovanie o frekvenciách výskytu extrémnych hodnôt spotreby pre dané OOM. Takáto vizualizácia umožňuje identifikovať zdroje nadpriemernej spotreby (t.j. ranná špička pri výťahoch vo veľkých kancelárskych budovách) a tvorbu opatrení, ktoré takéto javy obmedzia alebo im zabránia. Pridanou hodnotou k histogramu, na ktorom dáta vizualizujeme, môže byť vizualizácia očakávanej-predikovanej distribúcie. Jednoduché boxploty spotreby sa v textoch ukázali ako náročne intuitívne interpretovateľné pre ľudí bez štatistického vzdelania. Odporúčame preto zostať pri vizualizáciách pomocou histogramov.

V kontexte monitoringu energetickej efektívnosti stredných a veľkých spotrebiteľov platí, že jednoduchosť je vo vizualizácii dát ultimátnou sofistikáciou. Vizualizácie v týchto aplikáciách nemajú za cieľ podnecovať pozorovateľa k rozmyšľaniu nad výskumnými otázkami, hypotézami a odpoveďami, ktoré priniesla vizualizovaná analýza. Majú za cieľ štandardizovať vzťahy medzi aktuálnou a optimálnou spotrebou a majú podnecovať pozorovateľa k porovnaniu týchto vizualizovaných informácií.

K aplikáciám odporúčame pridať modul autonómneho sledovania spotreby, ktorý bude automaticky varovať administrátora v prípade neoptimálnej spotreby, pri čom vygeneruje report s vyššie popísanými vizualizáciami.

19. Vizualizácie v kontexte aplikácií energetického auditu

Tak, ako na strane stredných a veľkých spotrebiteľov, aj na strane štátu a kontrolných inštitúcií bude nutná implementácia aplikácie, monitorujúcej energeticke efektívnosť jednotlivých OOM. Tieto zložky budú totiž buď sami administrovať alebo aspoň facilitovať sériu auditov zameraných na energeticke efektívnosť štátnych a neštátnych OOM. Je možné, že tieto inštitúcie budú mať v budúcnosti možnosť upozorňovať jednotlivých spotrebiteľov na ich neefektívne riadenie spotreby, poprípade udeľovať sankcie a výhody na základe evidencie o nekvalitnom alebo kvalitnom manažmente spotreby. Pre takúto aktivitu musí mať inštitúcia, zodpovedná za audit, potrebné dáta a nástroje. Aplikácie detekujúce pozitívne a negatívne deviácie v spotrebe rôznych skupín spotrebiteľov dajú audítorovi dostatočnú evidenciu pre jeho aktivitu.

Základ vizualizačného modulu v takýchto aplikáciách je identický s modulmi vizualizácií pre monitorovanie spotreby pre stredných a veľkých spotrebiteľov. Pôjde o autonómny monitorovací systém, ktorý bude automaticky varovať audítora v prípade neoptimálnej spotreby skupín OOM alebo konkrétneho spotrebiteľa, pri čom vygeneruje report vizuálnej analýzy s evidenciou.

Rozdielom medzi týmito aplikáciami však je, že kým spotrebiteľ je pasívnym pozorovateľom, používateľ audítorského systému je v pozícii aktívneho analytika. Audítor sa musí rozhodnúť, s ktorými spotrebiteľmi bude interagovať (t.j. kde je limit neefektívnej spotreby pre danú skupinu spotrebiteľov), akým spôsobom (t.j. formou pozitívneho alebo negatívneho hodnotenia, upozornení alebo odporúčaní) a v akom poradí (t.j. ktoré deviácie od priemernej spotreby v danej skupine spotrebiteľov sú prioritou).

V aplikáciách auditu preto vizualizácie majú podnecovať audítora k rozmyšľaniu nad odpoveďami, ktoré priniesla vizualizovaná analýza aj k porovnaniu vizualizovaných informácií. Predmetom vizualizácií v týchto aplikáciách preto nie je len monitoring alebo detekcia kritických hodnôt (deskriptívna analýza) ale aj exploratívna a verifikačná analýza.

Aby audítor bol schopný určiť, čo je optimálna spotreba a čo nežiadúca spotreba pre dané OOM, musí prostredníctvom vizuálnej analýzy štandardizovať vzťahy medzi jednotlivými spotrebnými profilmi, medzi priemernou, očakávanou a neštandardnou spotrebou a zároveň rozdiely medzi skupinami OOM. Vizualizácia mu musí umožniť pozorovať tieto vzťahy na niekoľkých úrovniach časových radov.

Nástroje vizualizácie preto musia predstavovať dynamické prostredie schopné navoliť požadované informácie do grafov, upozorniť na zistené odchýlky v rámci analýzy a vylisovať prioritované zoznamy OOM podľa indexov spotreby alebo energetickej efektivity za predvolený časový úsek.

Čím sú systémy vizualizácií dynamickejšie, tým je väčšia pravdepodobnosť zlej interpretácie vizualizovaných dát, preto treba vizuálne riešenie testovať priamo s ich budúciimi užívateľmi.

Naše testy s participantami ukázali, že v kontexte energetického auditu OOM najlepšie funguje report vytvorený z kombinácií nominálnych a ordinálnych porovnaní prostredníctvom koláčových a bublinových grafov, schopných dekompozície na nižšie celky, grafov časových radov, grafov vizualizujúcich výsledky analýzy deviácií a distribúcie frekvencií spotreby OOM pomocou histogramu s vizualizovanými intervalmi hodnôt spotreby a kartografov na korelovanie polohy s energetickou efektivitou OOM.

Aplikácia by mala byť rozšírená o modul, zameraný na exploratívnu vizuálnu analýzu korelácií v spotrebných profiloch OOM, správjúcich sa energeticky mimoriadne efektívne alebo

mimoriadne neefektívne. Analýzou podobností medzi týmito OOM audítor môže identifikovať charakteristiky spotrebných profilov, ktoré generuje extrémne optimálne alebo neoptimálne spotrebné správanie, poprípade upraviť zle nastavené očakávania optimálnej spotreby pre dané skupiny OOM.

Systém by mal zakresľovať hodnoty priemernej a očakávanej (predikovanej) spotreby pre dané skupiny do grafov automaticky.

20. Vizualizácie v kontexte modelovania prevádzkových režimov distribučných sietí

Vyššie uvedená legislatíva, motivujúca členské štáty EU k energetickej úspore, sa priamo dotýka aj riadenia distribučných sietí. S dátami o spotrebe a výrobe OOM novej kvality - zbieranými prostredníctvom SmartMetrov - budú mať distribučné siete možnosť efektívne modelovať a spúšťať svoje prevádzkové režimy tak, aby presnejšie zodpovedali reálnej spotrebe a limitom výroby.

Predpokladáme, že v blízkej budúcnosti bude celý systém optimalizácie v rámci distribučných sietí automatizovaný a administrátor bude skôr pasívnym pozorovateľom a kontrolórom ako rozhodovacou jednotkou. Vizualizácie v systémoch modelujúcich a optimalizujúcich aplikáciu prevádzkových režimov nie sú preto hlavným modulom a prinášajú skôr informatívnu hodnotu pre administrátorov systému a pre rozhodovací proces pri spúšťaní jednotlivých prevádzkových režimov.

Informácie, ktoré sa v takýchto systémoch musia vizualizovať sú napríklad dáta o výkone algoritmov predikujúcich spotrebu a výrobu, či dáta o výkone optimalizačného algoritmu voliaceho jednotlivé prevádzkové režimy. Z našich testov s participantami vyplýva, že by sa tieto dáta mali prezentovať ako pomer k celku, teda ako pomer vlastného výkonu systému k celkovému historickému setu dát. Klasické moduly čiarových grafov s intervalmi na jednotlivých dátových bodoch by mali byť aplikované na monitorovanie historickej a aktuálnej spotreby, výroby a výkonu algoritmov.

21. Možnosti vizualizácií v kontexte aplikácií prediktívnej údržby

Systémy prediktívnej údržby sú ďalšou aplikáciou, ktorých výskyt predpokladáme na viacerých miestach slovenskej inteligentnej siete SmartGrid. Tieto systémy budú potrebné vo všetkých oblastiach, kde budú prítomné stroje a architektúra ovplyvňujúca úroveň spotrebovanej, vyrobenej alebo prenesenej elektrickej energie. Znamená to, že potenciálnymi užívateľmi týchto systémov sú inštitúcie - v rozsahu od tých, zodpovedajúcich za fyzickú prenosovú sústavu, zodpovedných za inštalované SmartMetre, až po štátnych a súkromných výrobcov a spotrebiteľov energie.

Systémy prediktívnej údržby sú zo svojej povahy systémami monitoringu a detekcie štatistických deviácií v predikovaných dátach. Vizualizačné moduly potrebné v týchto systémoch majú preto skôr deskriptívnu a verifikačnú ako exploratívnu funkciu. Vizualizácie tu majú za úlohu popisovať dátovú vzorku a vzťahy premenných formou všeobecného prehľadu. Interpretácia komplexných vzťahov premenných v rámci vzorky (napr. vizuálna interpretácia porovnaní jednotlivých alternatív predikcií údržby) tu nie je opodstatnená a potrebná.

Používatelia týchto systémov – administrátori, ktorí budú interpretovať vizualizované dáta – potrebujú zodpovedať v princípe dve otázky:

- Prvou je, ktoré zložky fyzického systému je potrebné preventívne skontrolovať, vymeniť poprípade opraviť, aké sú ďalšie kroky údržby systému.
- Druhou je, aký profil efektívneho fungovania a opotrebovania viedol ku havárii danej zložky systému alebo potenciálne bude viesť k jej kazovosti v budúcnosti a ako optimalizovať jej fungovanie a údržbu tak, aby sme minimalizovali pravdepodobnosť havárie celého systému v budúcnosti.

Monitorovanie, analýza a vizuálna interpretácia odpovedí na tieto otázky si nevyžaduje aplikáciu komplikovaných vizualizačných nástrojov. Pre účely týchto systémov budú postačovať jednoduché deskriptívne grafy ako napríklad klasický dvojdimenzionálny graf vykreslených na časovej osi.

Srdcom celej aplikácie a jej vizualizačného prostredia je modul autonómneho sledovania historicky realizovanej a predikovanej údržby, ktorý bude automaticky hlásiť očakávané ciele údržby v blízkej budúcnosti a varovať administrátora v prípade neoptimálneho postupu, pričom vygeneruje report vizualizujúci výsledky analýz, na základe ktorých bol administrátor upozornený.

Na základe našich testov s participantami sme zistili, že generovaním štandardizovaného reportu sa vieme celkom efektívne vyhnúť zlej interpretácii dát, napríklad rozdielom medzi vizualizovanou informáciou o korelácii dát (napr. že kazovosť niektorých modulov systému vzájomne súvisí v čase) a kauzálnych vzťahov (napr. že nízka údržba modulu X má za následok väčšiu kazovosť modulu Y a Z).

Testy s užívateľmi taktiež potvrdili predpoklad, že grafické logá priradené k jednotlivým modulom systému, ktorý algoritmus prediktívnej údržby monitoruje, zvýšia interpretovateľnosť vizualizovaných odporúčaní.

Testy ukázali aj to, že užívatelia takýchto systémov budú uprednostňovať interakciu s dátami vizualizovanými pomocou kartografu, nakoľko vzájomný vzťah polohy jednotlivých modulov vyžadujúcich si preventívnu kontrolu sa ukázal ako relevantná premenná v kontexte rozhodovania participantov o ďalších krokoch. Tento poznatok platí aj pre temporálnu deskriptívnu analýzu dát a preto bude nutné do kartografov v týchto aplikáciách integrovať časovú os alebo iné vizuálne odlíšenie, znázorňujúce zmeny a priority v čase (napr. zafarbenie indikátorov na kartografe).

Generovaný zoznam modulov, odporučených na údržbu, by mal obsahovať skóre kazovosti, ktoré jednotlivé moduly systému dosiali. Toto skóre sa im bude dynamicky zvyšovať v čase. Skóre predstavuje index odvodený z výpočtu predikcie kazovosti daného modulu. Pre každý modul by mal byť viditeľný aj predpovedaný bod, v ktorom sa porucha tohto modulu vyskytne s vysokou pravdepodobnosťou.

Priorizovanie zoznamov, odporučených na údržbu, by malo byť umožnené do istej miery ovplyvnením výberu rôznych pravidiel priorizácie - napríklad zoradením podľa geografickej polohy, podľa získaného skóre, podľa blízkosti bodu pravdepodobnej kazovosti alebo predpokladanej doby trvania údržby.

Po kliknutí na konkrétny modul by sa administrátorovi mali ukázať špecifickejšie informácie, napríklad profil kazovosti, profil preventívnej údržby, dátum poslednej údržby, či zoznam typov nájdených porúch na danom module.

22. Možnosti vizualizácií v kontexte aplikácií pre inteligentné domácnosti

Tretím typom aplikácií, ktorý očakávame že bude prístupný v rámci prostredia SmartGrid sú aplikácie pre inteligentné domácnosti. Plánované a existujúce s týmto zameraním sa vyznačujú svojou značnou variabilitou, nakoľko sa v kontexte funkcionality môžu uberať rôznymi smermi. Z pohľadu špecifikácie vizualizačného modulu takýchto aplikácií je preto ťažké generalizovať, ktoré charakteristiky a nástroje by modul mal obsahovať a ktoré sú nepotrebné.

Jeden z faktorov, ktorý platí pre všetky aplikácie pre inteligentné domácnosti, je, že základným predpokladom ich efektívnej implementácie a dlhodobého fungovania je vývoj štandardizovaného komunikačného protokolu, prostredníctvom ktorého bude aplikácia komunikovať s jednotlivými prístrojmi zbierajúcimi dáta.

Neprítomnosť štandardného komunikačného protokolu je v súčasnosti centrálnym nedostatkom v riešení inteligentných domácností.

Vezmime si príklad multimedialných systémov, ktoré sú na trhu prítomné. Pokiaľ chce mať užívateľ v dome inteligentný multimedialny systém, ktorý riadi ozvučenie v jednotlivých miestnostiach domu, je responzívny na hlasové inštrukcie – riadi mikrofóny, ovláda telefónne linky, manažuje kamerový systém a intenzitu osvetlenia izieb, užívateľ si musí obstarat' všetky potrebné komponenty od jedného dodávateľa (napr. Sony), aby tieto komponenty boli schopné vzájomne komunikovať. Integrovať riešenia od viacerých dodávateľov vo väčšine prípadov nie je možné.

Každý dodávateľ inteligentných technologických a elektrických zariadení a spotrebičov disponuje vlastným komunikačným protokolom, tak pri monitoringu a zbere dát ako aj pri komunikácii inštrukcií jednotlivým zariadeniam. Pokiaľ by sme chceli postaviť inteligentnú domácnosť, ktorá monitoruje spotrebu a výrobu elektrickej energie, potrebovali by sme systém, ktorý je schopný komunikovať s čo najväčším počtom rôznych typov zariadení od rôznych dodávateľov.

Naozaj inteligentná aplikácia pre inteligentnú domácnosť by do systému monitoringu elektrickej spotreby integrovala aj manažment osvetlenia budovy, manažment vyhrievania budovy, manažment výkonu bielej techniky a komunikáciu s multimedialnými zariadeniami ako sú počítače a televízory v budove.

Samozrejme, aj jednoduchá aplikácia komunikujúca medzi SmartMetrom a užívateľovým počítačom či mobilnou jednotkou, prostredníctvom aplikácie obsahujúcej informácie o aktuálnej tarife, historickej spotrebe, predikovanej spotrebe, finančných ukazovateľoch, charakteristikách spotrebného profilu užívateľa a informáciách o aktuálnych trendoch v spotrebe a výrobe (geograficky alebo profilovo) podobných užívateľov, s možnosťou zadávania inštrukcií a cieľov energetickej efektivity, by predstavovala oveľa inteligentnejšie riešenie v porovnaní so súčasným stavom informatizácie.

Kvôli problémom s integráciou komunikačných protokolov sa preto pri definovaní vizualizačného modulu pre aplikácie inteligentnej domácnosti zameriame na jednoduchšiu vyššie popísanú verziu komunikácie medzi mobilnými a desktopovými operačnými jednotkami a SmartMetrom daného OOM.

Náš popis začneme informáciou, že existujú tri typy užívateľov energetických aplikácií pre inteligentné domácnosti.

- Prvým typom je domácnosť, ktorá má pridelený vlastný SmartMeter,
- Druhým typom je OOM, ktorého SmartMeter zbiera údaje z viacerých domácností naraz
- Tretím typom sú OOM reprezentujúce domácnosti alebo skupiny domácností, ktoré nemajú len spotrebu, ale generujú aj výrobu elektrickej energie.

Svetové ako aj slovenské trendy naznačujú, že počet domácností, spadajúcich do druhej a tretej cieľovej skupiny, bude v budúcnosti narastať, zatiaľ čo počet domácností v prvej cieľovej skupine zostáva stabilný (svetový priemer) alebo ich ubúda (napr. slovenské dáta).

Tento kontext treba brať do úvahy najmä počas potenciálneho vývoja jednotlivých aplikácií v budúcnosti.

Vizualizačné moduly aplikácií pre inteligentné domácnosti by mali predstavovať osobný nástroj monitoringu a analýzy dát, ktoré užívateľ generuje svojou aktivitou.

Vizuálna analýza dát v tomto prípade prechádza cez všetky tri úrovne - od deskriptívnej analýzy monitoringu (napr. odpoveď na otázku: akým štýlom spotrebovala moja domácnosť elektrickú energiu v súčasnosti a v minulosti?), cez verifikačnú analýzu (napr. odpoveď na otázku: do akej miery sa zoptimalizoval môj spotrebný profil domácnosti, ak sme podnikli kroky smerom k efektívnejšiemu manažmentu spotreby – koľko sme ušetrili?) až po exploratívnu analýzu (napr. odpoveď na otázku: ktoré prvky poveternostných a teplotných zmien súvisia so zvýšenou spotrebou mojej domácnosti a ktoré moje aktivity majú najväčší vplyv na spotrebu v mojej domácnosti?).

Vizualizačný modul aplikácie by preto mal byť vysoko interaktívny, mal by podnecovať pozorovateľa k rozmyšľaniu nad výskumnými otázkami, hypotézami a odpoveďami, ktoré priniesla vizualizovaná analýza a k porovnaniu vizualizovaných informácií.

Po evaluácii konkrétnych typov analýz a možností, ktoré máme v rámci SmartGrid sme dospeli k záveru, že aplikácie inteligentných domácností by mali obsahovať vizualizácie týchto analýz:

1. Vizualizácie štatistických odchýlok: Pozorovanie kategorických alebo kontinuálnych dátových bodov o spotrebe domácnosti môže priniesť intenzívnejší náhľad vtedy, keď sa sledujú dátové deviácie, napríklad od priemeru vzorky alebo od očakávaných hodnôt. Príkladom v kontexte aplikácií pre inteligentné domácnosti je vizualizácia rozdielu medzi očakávanou (predikovanou) spotrebou alebo výrobou a reálne dosiahnutými hodnotami. Jednoduchý stĺpcový graf odporúčame pre vizualizáciu rozdielov v rámci aplikácií inteligentnej domácnosti.

2. Vizualizácie časových radov/sérií: Klasický čiarový graf (line graph) môže byť použitý pre demonštráciu trendov spotreby danej domácnosti alebo podobných domácností v čase. Čiarové grafy v aplikáciách inteligentnej domácnosti by mali mať v sebe vizuálne integrovanú linku znázorňujúcu maximálnu povolenú alebo očakávanú hranicu spotreby domácnosti. V našich testoch sa ukázalo, že vizuálne zapracovaná hranica v grafe sa interpretuje oveľa jednoduchšie ako hranica spotreby pre domácnosť komunikovaná v numerickej forme.

3. Vizualizácie korelácií: Príkladom sledovania korelácií v aplikáciách pre inteligentné domácnosti môže byť vykresľovanie vzťahov medzi spotrebnými profilmi viacerých domácností s rôznou úrovňou energetickej efektívnosti na danom časovom úseku (vizualizácia súvisu v spotrebných profiloch). Tieto faktory sa tiež dajú vyjadriť v grafe, pomocou chybových intervalov a šípok smerovania vzťahu. Ďalšou koreláciou, hodnou sledovania, je vzťah medzi aktuálnou spotrebou a historickou spotrebou, na úrovni identického časového úseku. Veľmi zmysluplnou sa v testoch ukázala aj vizualizácia vzťahu medzi aktuálnymi finančnými nákladmi, historickými nákladmi a predikovanými finančnými nákladmi na spotrebu, na úrovni identického časového úseku.

4. Vizualizácie distribúcia frekvencií: Zmysluplným príkladom v aplikáciách pre inteligentné domácnosti môže byť vykresľovanie grafov o frekvenciách výskytu extrémnych hodnôt spotreby (alebo aj výroby) pre danú domácnosť alebo skupinu domácností. Takáto vizualizácia následne umožňuje identifikovať zdroje nadpriemernej spotreby a tvorbu opatrení, ktoré tieto zdroje čo možno najviac eliminujú.. To isté platí o vizualizácií frekvencie hodnôt finančných nákladov na spotrebu elektrickej energie.

Pridanou hodnotou k histogramu, ktorým frekvencie vizualizujeme, môže byť vizualizácia očakávanej-predikovanej distribúcie spotreby alebo nákladov. Jednoduché boxploty nákladov sa v testoch ukázali ako obťažne interpretovateľné pre ľudí bez štatistického vzdelania. Aj tu preto odporúčame zostať pri vizualizáciách pomocou histogramov.

Čo sa týka automaticky generovaných reportov v aplikáciách pre inteligentné domácnosti, primárnym cieľom počas ich vývoja musí byť dosiahnutie takého prostredia, ktoré pomáha vyhnúť sa nesprávnej interpretácii dát. Tento stav dosiahneme tým, že v reporte štandardizujeme vzťahy medzi jednotlivými dátovými tokmi a výpočtami a akumulujeme jednotlivé informácie – prezentujeme bohatú informáciu na malej ploche.

Naše testy so skupinami participantov ukázali, že kvalitu reportu a celého modulu vizuálnej analýzy v aplikácii inteligentnej domácnosti zvýši aj dobrá integrácia jednotlivých grafov do štatistického, verbálneho alebo písomného kontextu aplikácie. Generovaný report spotreby a výroby by mal obsahovať skóre energetickej efektivity, ktoré domácnosť dosiahla a ktoré sa bude dynamicky pohybovať v čase.

Skóre predstavuje index odvodený z výpočtu predikcie spotreby/výroby domácnosti a kvality jej spotrebičov. Pre každú domácnosť by mal byť viditeľný aj predikovaný bod štatisticky alebo finančne signifikantnej zmeny v profile spotreby.

Automaticky by mali byť vizualizované aj upozornenia o výhodnej tarife spotreby alebo neplánovanej spotrebe.

Tieto gamifikačné mechanizmy a porovnávanie sa s inými OOM v našich testoch motivovali participantov zmeniť svoje spotrebné správanie.

23. Prehľad voľne prístupných knižníc vhodných na tvorbu vizualizačných modulov pre aplikácie v systémoch SmartGrid

Vo vyššie popísanej časti realizácie pracovného balíka 8 sme aplikovali naše teoretické poznatky o vizualizácii veľkého toku dát, moduloch automatickej a semi-automatickej

vizualizácie a jej technických limitoch do špecificky zadefinovaných kazuistík užívateľského prostredia.

Tieto aplikácie vizuálnych modulov sme následne testovali so skupinami participantov s cieľom zodpovedať otázku o akej miery sú dáta, takto vizualizované, intuitívne interpretovateľné.

Keďže sme zistili čo je a čo nie je možné a čo je a nie je vhodné v kontexte vizualizačných modulov v aplikáciách SmartGrid, ako ďalší krok musíme identifikovať knižnice a nástroje, na ktorých bude možné jednotlivé aplikácie v budúcnosti vyvinúť.

Ich výber sme realizovali striktnou selekciou a vybrané nástroje ako aj kritériá výberu si popíšeme nižšie. Nami akceptované nástroje museli spĺňať niekoľko podmienok:

- Nástroj alebo knižnica musela prezentovať takzvaný open-source softvér. Open-source softvér je počítačový softvér, ktorého zdrojový kód je prístupný pod takou licenciou, ktorá umožňuje študovanie, poprípade vkladanie zmien a vylepšení do zdrojového kódu a umožňuje jeho ďalšiu distribúciu v modifikovanej alebo nezmenenej forme. Open-source neznamena len prístup k zdrojovému kódu. Distribučné podmienky open-source softvéru musia spĺňať nasledujúce kritériá:
 - bezplatnú distribúciu
 - zdrojový kód
 - odvodené práce
 - integritu autorovho zdrojového kódu
 - neobsahovať diskrimináciu jednotlivcov či skupín
 - neobsahovať diskrimináciu na poli úsilia
 - distribúciu licencie
 - licencia musí byť rovnaká pre celý produkt
 - licencia nesmie obmedzovať iný softvér
 - licencia musí byť technologicky neutrálna

V prípade, že vizualizačný nástroj má licenciu tohto typu, umožňuje nám a iným subjektom na trhu takzvaný open-source vývoj pre potreby aplikácií do SmartGrid. Je nutné poznamenať, že z vizualizačných nástrojov, ktoré sme analyzovali, mnohé komunikovali ako open-source no väčšina nespĺňala všetky potrebné licenčné podmienky a preto by bola interakcia s nimi formou open-source vývoja potenciálne napadnuteľná originálnym tvorcom softvéru.

- Pri výbere sme posudzovali bezpečnosť nástroja v kontexte našej prvej podmienky (open-source). Z hľadiska bezpečnosti je využívanie open-source

nástrojov dvojsečnou zbraňou. Výhodou je, že vďaka voľnému prístupu, bezpečnostné diery a hrozby - v podobe infekcie škodlivým softvérom - môže v nástrojoch hľadať širšia skupina ľudí (alebo automatov) ako v komerčných systémoch, a je preto väčšia pravdepodobnosť na elimináciu bezpečnostného rizika. Nevýhoda open-source nástrojov vyplýva z toho istého faktu, teda diery v systéme môže nájsť a využiť väčší počet útočníkov ako pri komerčných systémoch. V súčasnom stave softvérovej bezpečnosti sa však open-source považuje za všeobecne výhodnejší. Predpokladá sa totiž, že ak je open-source softvér populárny, strana užívateľov-vývojárov disponuje väčším počtom ľudí a zdrojov (financie, čas a kvalifikácia) v porovnaní so skupinami útočníkov. Pri posudzovaní bezpečnosti sme hodnotili hlavne frekvenciu reportovaných útokov v minulosti, frekvenciu reportovaných a opravených softvérových dier a chýb, popularitu nástroja (veľkosť aktívnej komunity vývojárov a frekvenciu ich aktivity) a kvalitu zdrojového kódu nástrojov.

- Vybrané knižnice a nástroje na tvorbu vizualizácií musia byť zamerané na vývojárov a na vývoj vizualizačných modulov, nie len na generovanie konkrétneho grafu na základe nahratých dát. Touto podmienkou sme s výberu odstránili nástroje ako napríklad open-source variantu aplikácie Datawrapper, ktorý na základe zaslaných dát generuje grafy, ktoré vie implementovať do aplikácie webu užívateľa, alebo podobnej ale populárnejšej aplikácie Tableau. Takéto riešenia majú zvyčajne nižšiu softvérovú bezpečnosť a ich implementácia často slúži ako brána na krádež dát, poprípade infikovanie systému.
- Tretím kritériom na výber vhodných nástrojov vizualizácie bola ich miera softvérovej kompatibility s existujúcimi systémami v slovenskej energetike. Posudzovali sme hlavne kompatibilitu z pohľadu softvérovej architektúry a kompatibilitu s formátmi dát, ktoré očakávame ako výstup zo zberných systémov v rámci SmartGrid, ktoré predstavujú vstup do vizualizačných modulov aplikácií.
- Posledným kritériom bolo, aby vizualizačná knižnica obsahovala čo najviac vizualizácií, ktoré sa nám testovaním potvrdili ako najzmysluplnejšie implementovateľné do aplikácií v systéme SmartGrid. Nie každá knižnica je totiž schopná zakresľovať dáta do grafu v reálnom čase, spracovať veľké množstvá

dát, alebo vykresliť dáta o frekvenciách v čase (napr. spotreby) na geografickú mapu mesta Bratislavy, tvoriť komplexné kartografy.

V nasledujúcich kapitolách uvádzame knižnice, ktoré našim výberom úspešne prešli.

23.1 Knižnica D3.js

D3.js je skratkou pre 'Data Driven Documents'. D3 spĺňa všetky podmienky open-source licencie a umožňuje open-source vývoj v plnom rozsahu. Z pohľadu bezpečnosti, má knižnica D3 nízku frekvenciu reportovaných útokov, no relatívne vysokú mieru reportovaných a opravených softvérových dier a chýb. Čím je v rámci bezpečnosti unikátna, je jej vysoká miera popularity medzi vývojármi pracujúcimi v prostredí Javascript. Disponuje početnou a najmä veľmi aktívnou komunitou užívateľov-vývojárov.

Kvalita zdrojového kódu knižnice D3 variuje, no celkovo, je na dobrej úrovni. Dôležitou informáciou je, že knižnica po inštalácii neobsahuje dopredu pripravené grafy, diagramy a vizualizačné nástroje. To však neznamená, že by variabilita vizualizačných nástrojov bola nízka, práve naopak, z príkladov vizualizácií ktoré sme mali možnosť vidieť je nám jasné, že reprezentuje veľmi univerzálnu platformu.

Z pohľadu kompatibility softvérovej architektúry, má D3 určité limitácie, no kompatibilita vstupných formátov je dostačujúca. D3 používa na vykresľovanie vizualizácií najmä formáty HTML, CSS, a SVG. Treba poznamenať, že vďaka širokej komunite vývojárov, je knižnica D3 plná funkcionalít, značne interaktívna a vizualizácie z nej vykresľované sú vysoko estetické.

Nevýhodami tejto knižnice je, že od vývojára vyžaduje značný objem zručností a času, ak chce jej potenciál využiť v plnej miere a že knižnica je kompatibilná iba s modernými internetovými prehliadačmi (napr. IE 9+). Jej aplikáciu preto odporúčame iba v prípade, pokiaľ nepredpokladáme, že užívatelia budú sledovať vizualizácie na starých, neaktualizovaných systémoch.

23.2 Knižnica NVD3

NVD3 je projekt zameraný na vývoj opakovane používaných/aplikovaných grafov a vizualizačných komponentov pre platformu d3.js. Knižnica NVD3 disponuje identicky efektívnymi a softvérovo robustnými funkcionalitami tak ako d3.js, no ich editovanie vývoj a morfovanie je oveľa jednoduchšie.

Hlavnou výhodou knižnice NVD3 je jej schopnosť spracovávať komplexné dátové štruktúry a vykresľovať dynamické multi-dimenzionálne vizualizácie v reálnom čase. NVD3 je knižnicou prostredia Javascript, spĺňa všetky podmienky open-source licencie a umožňuje open-source vývoj v plnom rozsahu.

Z pohľadu bezpečnosti, má knižnica NVD3 vyššiu frekvenciu reportovaných útokov ako knižnica D3, no relatívne vysokú mieru reportovaných alebo opravených softvérových chýb. Knižnica je značne populárna medzi vývojármi pracujúcimi s veľkými a komplexnými vzorkami dát. Disponuje aktívnou komunitou užívateľov.

Kvalita zdrojového kódu je nižšia ako pri knižnici D3, no je stále na akceptovateľnej úrovni. Variabilita vizualizačných nástrojov je nižšia, ale disponuje všetkými potrebnými nástrojmi pre vizualizácie v rámci aplikácií systému SmartGrid.

Z pohľadu kompatibility softvérovej architektúry a formátov dát je knižnica NVD3 výnimočne verzatilná. NVD3 podporuje tak moderné ako aj staršie verzie webových prehliadačov. Estetický dojem vizualizácií generovaných touto knižnicou do veľkej miery závisí na investovanom čase a zručnosti vývojára.

23.3 Knižnica Chart.js

Chart.js je menšia knižnica, ktorá spĺňa všetky podmienky open-source licencie a umožňuje open-source vývoj. Knižnica síce podporuje len šesť základných typov grafov - čiarový graf, koláčový graf, kružnicový graf, graf radiačných osí, graf pólov a stĺpcový graf - no vo väčšine aplikácií SmartGrid je vykresľovanie agregátov dát v reálnom čase do týchto typov grafov presne to, čo sa od vizualizačného modulu očakáva.

Tento princíp platí najmä pre aplikácie, od ktorých sa požaduje, aby automaticky generovali vizuálne reporty za určitý časový úsek. Chart.js je Javascript-ovou knižnicou, ktorá na vykresľovanie grafov používa HTML5 canvas element. Jej formátová kompatibilita preto nie najvyššia, no softvérovou architektúrou ide o vysoko kompatibilnú knižnicu. Vizualizácie z tejto knižnice sú responzívne a používajú štandardizovaný flat design.

Knižnica Chart.js je relatívnou novinkou a preto má nízku frekvenciu reportovaných útokov, reportovaných alebo opravených softvérových chýb. Komunita využívajúca knižnicu je

zatiaľ relatívne malá, no jej veľkosť a frekvencia aktivity rastie. Je to jedna z najpopulárnejších nedávno vyvinutých knižníc.

Kvalita zdrojového kódu je dostatočná, no nevýhodou je spomínaná nízka variabilita vizualizačných nástrojov.

Chart.js sa vyznačuje vysokou kompatibilitou softvérovej architektúry, no kompatibilných formátov vstupných dát ma relatívne málo. Chart.js v podpore rôznych verzií webových prehliadačov je výnimočne univerzálna. Estetický dojem vizualizácií generovaných touto knižnicou je štandardný, ale absolútne dostačujúci.

23.4 Knižnica Leaflet

Leaflet je Javascript-ová knižnica, plne umožňujúca open-source vývoj. Knižnica bola vyvinutá Vadimírom Agafonkinom špecificky pre tvorbu interaktívnych grafov a máp podporujúcich operačné prostredie a rozhranie mobilných prístrojov (tablety a mobilné telefóny).

Hlavnou pridanou hodnotou knižnice je jej vynikajúci pomer medzi objemovou nenáročnosťou (iba 33kb) a počtom nástrojov a funkcií na plnú kustomizáciu máp a kartografických grafov.

Napriek tomu, že variabilita vizualizačných nástrojov tejto knižnice je značná, komunita vývojárov poskytuje širokú ponuku prídavných pluginov, pridávajúcich funkcie ako heatmap alebo animované geolokačné značenia. Kvalita zdrojového kódu je na veľmi dobrej úrovni.

Z pohľadu kompatibility softvérovej architektúry a formátov dát je knižnica Leaflet vo výbornom stave. Leaflet podporuje tak moderné ako aj staršie verzie webových prehliadačov a funguje na najfrekventovanejšie používaných desktopových a mobilných platformách.

Na renderovanie grafov knižnica využíva HTML5 a CSS3 formáty. Architektúra knižnice je budovaná s dôrazom na jednoduchosť, dizajn a výkon. Estetický dojem z vizualizácií generovaných touto knižnicou je nadpriemerný.

V aplikáciách systémov SmartGrid, v ktorých bude potrebné disponovať mobilnými aplikáciami s kartografickou a geografickou vizualizáciou dát je vývoj vizualizačného modulu prostredníctvom knižnice Leaflet tou najlepšou voľbou.

Z pohľadu bezpečnosti, má knižnica Leaflet nízku frekvenciu reportovaných útokov, no relatívne vysokú mieru reportovaných aj opravených softvérových chýb. Tento stav plynie najmä z faktu, že tvorba aplikácií na mobilné zariadenia je komplexnejšia ako vývoj štandardných vizualizácií. Komunita pracujúca s týmto nástrojom je malá ale veľmi aktívna v odstraňovaní chýb.

23.5 Knižnica dygraphs

Dygraphs je taktiež open-source knižnica pre JavaScript. Špecializáciou tejto knižnice je vykresľovanie grafov v reálnom čase pre nadrozmerné dátové toky. Knižnica je veľmi dobre zoptimalizovaná kvalitným zdrojovým kódom, a flexibilná v kontexte kompatibility v rámci architektúry a formátmi dát, s ktorými narába. Výnimočnou je aj jej miera prispôsobivosti, umožňujúca extrémne modifikácie vizualizácií. Dygraphs podporuje tak moderné ako aj staršie verzie webových prehliadačov.

Komunita vývojárov knižnice dygraphs je dostatočne široká a veľmi aktívna. Dôvodom je fakt, že si táto knižnica vytvorila veľmi dobre definovaný trh používateľov prostredníctvom iniciatívy BigData.

Manažment a vizualizácia veľkých tokov dát je prirodzene chýlostivá vec – hlavne ak ide o dáta citlivé. Aj z tohto dôvodu má knižnica vysokú frekvenciu reportovaných útokov, a taktiež vysokú úroveň reportovaných a opravených softvérových chýb.

Dygraphs je knižnicou s úzkou špecializáciou, ktorú v aplikáciách systémov SmartGrid budeme využívať len zriedka, no v situáciách, v ktorých ju použiť treba (t.j. manažment a vizualizácia obrovských dátových setov) nemá v súčasnosti konkurenciu.

23.6 Knižnica Sigma.js

Posledná zo špecializovaných knižníc, ktorá prešla našim výberom je knižnica Sigma. Sigma je extrémne silná knižnica z prostredia Javascript, ktorá sa zamerala na generovanie interaktívnych grafov a vizuálnych sietí pre web rozhranie.

Knižnica spĺňa všetky podmienky open-source licencie a umožňuje open-source vývoj v plnom rozsahu. Z pohľadu variability nástrojov knižnice je zrejmé že Sigma reprezentuje veľmi univerzálnu platformu. Obsahuje dokonca niekoľko knižníc a balíkov pluginov, ponúkajúcich neobvykle široký záber interaktívnych nastavení jednotlivých vizualizácií.

Z pohľadu bezpečnosti, má knižnica nízku frekvenciu reportovaných útokov, no relatívne vysokú mieru reportovaných a opravených softvérových dier a chýb. Komunita okolo tejto knižnice nie je tá z najväčších. Jej aktivita je mierna, nakoľko väčšina riešení v nej už existuje a má stabilný výkon.

Kvalita zdrojového kódu v knižnici Sigma variuje, no celkovo, je na dobrej úrovni. Z pohľadu kompatibility vstupných formátov má Sigma určité limitácie, no kompatibilita softvérovej architektúry je dostačujúca.

Vizualizácie z nej vykresľované majú vysokú estetickú kvalitu.

Aplikáciu tejto knižnice odporúčame vždy, keď je to možné, Sigma predstavuje univerzálnu a veľmi odolnú platformu na tvorbu vizualizačných modulov aj v aplikáciách systémov pre slovenský SmartGrid.

24. Zhodnotenie pracovného balíka 8: Vizualizácia dát a výskum vhodných postupov

V záverečných kapitolách uvádzame zhrnutie našich aktivít a záverov v rámci realizácie pracovného balíka 8: Vizualizácia dát a výskum vhodných postupov.

24.1 Prvá fáza pracovného balíka 8: Vizualizácia dát a výskum vhodných postupov.

V prvej časti našich aktivít sme popísali základné princípy vizualizácie dát, podľa ktorých by sa mal vývoj vizualizačných modulov riadiť.

Po teoretickom úvode do problematiky vizualizácie dát nasledoval popis praktických štandardov a osvedčených postupov pri tvorbe intuitívne interpretovaných dátových vizualizácií.

Keďže samotná architektúra prostredia dátovej vizualizácie a jej prezentácie má na interpretáciu extrémny vplyv, náš výskum sa venoval aj tejto téme.

Posledným teoretickým okruhom výskumu boli otázky špecifických limitácií pri vizualizácii kvantitatívnych informácií, nakoľko masívna väčšina dát zbieraných a komunikovaných v systéme SmartGrid bude kvantitatívneho a nie kvalitatívneho typu.

Výstupom tejto časti bol široký prehľad o teoretických, štatistických, matematických, softvérových a kognitívne-psychologických kontextoch, ovplyvňujúcich tvorbu intuitívne interpretovateľných vizualizácií.

Na základe získaných teoretických poznatkov a pozorovaní systémov SmartGrid aplikovaných v zahraničí, sme následne začali pravidlá tvorby vizualizačných modulov aplikovať do kontextu systémov monitorujúcich dáta o výrobe a spotrebe elektrickej energie.

Najprv sme opísali rozdiely v preferenciách vizualizácií v produktoch a službách pre tri cieľové skupiny:

- malých výrobcov a spotrebiteľov,
- ii) veľkých spotrebiteľov (napr. vo veľkoch kontroly a optimalizácie spotreby tovární, výrobných parkov a závodov) a výrobcov (napr. vo väčších elektrárňach),
- iii) monitoringové inštitúcie ako SEPS alebo OKTE a jednotlivé distribučné siete.

V rámci výskumu vizualizačných modulov pre malých a stredných spotrebiteľov a výrobcov sme sa zamerali aj na témy korektného zobrazenia spotrebného profilu a jeho gamifikáciu.

V rámci výskumu vizualizačných modulov pre veľkých spotrebiteľov, výrobcov a monitoringové inštitúcie, sme sa zamerali aj na témy vykresľovania pre nich špecifických aktuálnych a historických dát, ako aj na definovanie technických špecifikácií implementácie vizualizačných modulov do už zabehnutých systémov. Výstupom tejto časti bola štruktúra limitov a technologických podmienok, ktoré musia byť splnené pri implementácii vizualizačných modulov pre aplikácie do systémov SmartGrid, rozdelené podľa špecifik vyššie spomenutých troch cieľových skupín užívateľov.

Tretím, logickým, krokom nášho úsilia bolo zamerať naše aktivity na výskum možnosti automatizácie modulov vizualizácie. V rámci tejto témy sme sa najprv zamerali na posúdenie zmysluplnosti automatizácie týchto modulov v jednotlivých aplikáciách SmartGrid, nakoľko automatizácia nie je potrebná v každej aplikácii. Prebrali sme taktiež vizualizačné štandardy a technické špecifikácie automatickej vizualizácie. Kľúčovou sa ukázala najmä téma možnosti automatizácie predspracovania surových dát do štruktúry a formátov, ktoré bude potrebné vizualizovať a automatizácia generovania štandardizovaných reportov alebo správ o aktuálnom a historickom stave spotreby a výroby. Výstupom tejto časti bola štruktúra nutnosti prítomnosti modulov automatizovaných vizualizácií naprieč jednotlivými aplikáciami v SmartGrid a zároveň naprieč tromi cieľovými skupinami užívateľov.

24.2 Druhá fáza pracovného balíka 8: Vizualizácia dát a výskum vhodných postupov.

Po dokončení témy popísanej vyššie sme vstúpili do druhej fázy výskumu v rámci pracovného balíka, v ktorej sme sa zamerali na využitie získaných všeobecných poznatkov o vizualizačných systémoch pre rôzne cieľové skupiny v systéme SmartGrid.

Testovali sme teda výstupy prvej fázy výskumu na vybraných kazuistikách aplikácií, ktoré očakávame, že budú v blízkej budúcnosti súčasťou systémov v SmartGrid na Slovensku. Mieru intuitívnej interpretácie vybraných grafov pre užívateľské prostredie jednotlivých aplikácií sme testovali na vzorkách participantov s nízkou skúsenosťou interpretácie dát.

Prvou kazuistikou, na ktorú sme sa zamerali, bola evaluácia možnosti vizualizácie monitoringu energetickej efektivity. V rámci tejto analýzy sme sa zamerali na posúdenie optimálneho vizualizačného prostredia pre tri konkrétne aplikácie.

- Prvou boli vizualizačné moduly pre systémy monitoringu energetickej efektívnosti, tak na strane malých a stredných spotrebiteľov, ako aj na strane štátnych alebo štátom poverených monitorovacích inštitúcií.
- Druhou boli moduly vizualizácie v kontexte aplikácií pre energetický audit
- Treťou boli vizualizácie v kontexte modelovania prevádzkových režimov distribučných sietí.

Výstupom tejto časti bola dobre zadefinovaná softvérová štruktúra a zoznam nástrojov, potrebných pre budúci vývoj vizualizačných modulov v spomínaných aplikáciách.

Druhou skúmanou kazuistikou boli vizualizačné moduly v systémoch prediktívnej údržby. Tieto systémy budú potrebné vo všetkých oblastiach, kde sú prítomné stroje a architektúra ovplyvňujúca úroveň spotrebovanej, vyrobenej alebo prenesenej elektrickej energie. Našou analýzou sme sa pokúsili zadefinovať vizuálne interaktívne užívateľské prostredie, ktoré pomáha zodpovedať dve otázky.

- Prvou je, ktoré zložky fyzického systému je potrebné preventívne skontrolovať, vymeniť poprípade opraviť, aké sú ďalšie kroky údržby systému.
- Druhou je, aký profil efektívneho fungovania a opotrebovania viedol ku zničeniu danej zložky systému alebo potenciálne bude viesť ku kazovosti v budúcnosti a ako optimalizovať jeho fungovanie a údržbu tak, aby sme budúcnosti minimalizovali pravdepodobnosť celkovej havárie systému.

Výstupom tejto časti predstavoval dobre zadefinovanú softvérovú štruktúru a zoznam nástrojov potrebných pre budúci vývoj vizualizačných modulov aplikácií prediktívnej údržby.

Treťou skúmanou kazuistikou boli vizualizačné moduly v aplikáciách pre inteligentné domácnosti. Keďže aplikácie pre inteligentné domácnosti sa vyznačujú svojou značnou variabilitou, našim prvým krokom bolo vymedziť náš výskum v kontexte dostupných komunikačných protokolov so SmartMetrami. Pri definovaní charakteristík a nástrojov, ktoré by mal obsahovať vizualizačný modul takýchto aplikácií, sme sa riadili faktom, že na trhu existujú tri samostatné typy užívateľov, prvým sú domácnosti, ktoré majú pridelený vlastný SmartMeter, druhým typom sú OOM ktorých SmartMeter zbiera údaje z viacerých domácností a tretím typom sú OOM reprezentujúce domácnosti alebo skupiny domácností, ktoré nie sú len spotrebiteľmi elektrickej energie ale generujú aj výrobu.

Po prieskume týchto kontextov sme identifikovali konkrétne typy analýz a vizualizačných nástrojov ktoré by tieto aplikácie mali obsahovať. Išlo hlavne o grafy vizualizujúce numerické a štatistické odchýlky, časové rady a série, korelácie časových radov a

distribúcie frekvencií meraných hodnôt. Poslednou témou v rámci tejto časti výskumu boli praktické návrhy automaticky generovaných reportov pre aplikácie monitoringu spotreby a výroby inteligentných domácností.

Posledným krokom v rámci plnenia a realizácie cieľov pracovného balíka 8: Vizualizácia dát a výskum vhodných postupov, bol výskum a výber voľne prístupných knižníc a nástrojov, vhodných na tvorbu vizualizačných modulov v systéme SmartGrid.

Tento krok bolo nutné realizovať ako posledný, až po kvalitnom špecifikovaní všetkých procesných, inovačných a technologických limitov systému SmartGrid a jeho dátového manažmentu. Na realizovanie úspešného výberu bolo tiež potrebné poznať zoznam grafov vizualizácií a animácií, ktoré si budú vyžadovať jednotlivé aplikácie v SmartGrid.

Prvým krokom tejto časti bolo zadefinovanie kritérií výberu tak, aby bolo možné jednotlivé knižnice použiť na vývoj vizualizačných modulov v aplikáciách systémov SmartGrid bez legislatívnych a technologických komplikácií.

Druhým krokom výskumu bola evaluácia možných kandidátov a samotný výber. Naším striktným výberom prešla knižnica D3.js, knižnica NVD3, knižnica Chart.js, knižnica Leaflet, knižnica Dygraphs a knižnica Sigma.js. Ich kombináciami docielime dostačujúcu variabilitu vizualizačných nástrojov na pokrytie požiadaviek aplikácií, ktorých existenciu v SmartGrid predpokladáme v blízkej budúcnosti.

Tretím krokom bolo popísať vybrané knižnice a nástroje a odporučiť ich aplikáciu v konkrétnych vývojových platformách a vývojových celkoch. Výstupom tejto časti je zoznam knižníc použiteľných na stavbu vizualizačných modulov do desktopových mobilných a on-line aplikácií v systémoch SmartGrid.

25. Záver

Výstupy a závery pracovného balíka 8: Vizualizácia dát a výskum vhodných postupov, naplnili naše očakávania a podľa nášho názoru sú dôvodom k spokojnosti s realizáciou cieľov tohoto pracovného balíka. Naš výskum obsahuje tak popis historického kontextu vývoja vizualizačných nástrojov aplikovaných v energetike, ako aj široký popis ich súčasného stavu.

Z týchto informácií je zrejmé, že vizualizácie monitorovacích a predikčných systémov v energetickom priemysle značne zaostávajú za systémami používanými v iných oblastiach, ako je napríklad marketing, finančníctvo alebo telekomunikácie.

V energetike preto existuje priestor na inováciu užívateľských prostredí, ktorej dopad vo vyššie menovaných oblastiach by bol ďalekosiahly.

Predpokladáme, že inovácia užívateľských prostredí v oblasti optimalizačných monitorovacích a predikčných systémov prostredia SmartGrid bude mať značne pozitívny impakt na prijatie nových technológií a systémov tak odbornou ako aj širokou verejnosťou.

Náš výskum načrtol smerovanie, ktorým by sa táto inovácia mala uberať a ponúkol nástroje, prostredníctvom ktorých sa dá dosiahnuť v dohľadnej dobe.

Získané poznatky sú dostatočne široké a zároveň obsahujú dostatočný detail aplikačného rámca na to, aby na ich základe mohol byť v budúcnosti vybudovaný aplikovaný výskum a vývoj vizualizačných modulov pre konkrétne aplikácie v systémoch SmartGrid.