

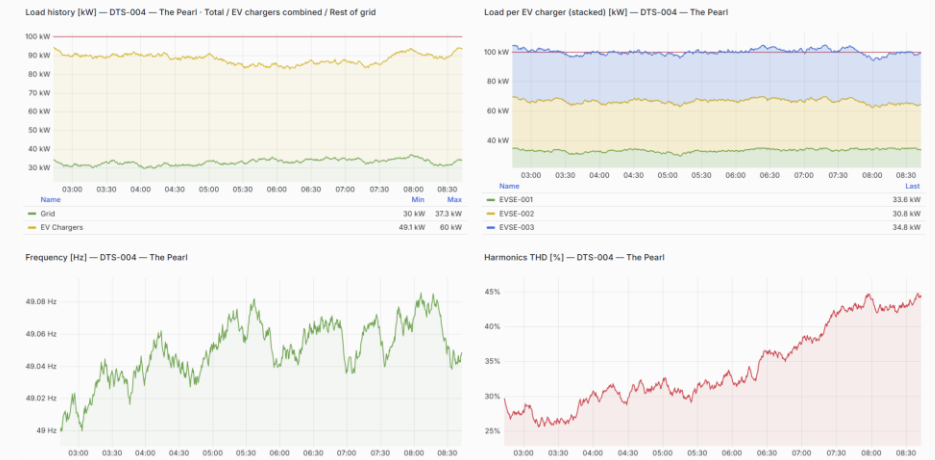
Jak využít AI pro hledání neefektivní spotřeby v průmyslových provozech

Jak to dělají lidé

- ... bez měření není řízení
- ... kdo měří ten ví, kdo ví ten měří

- metody
 - normování spotřeby (na výrobek, na metr čtvereční, na stupeň celsia, ...)
 - nastavení prahových hodnot pro alertování
 - ruční hledání podivností v grafech

- ale
 - měření je hodně – velké datové centrum 1200 měřících bodů
 - měřené body spolu často souvisí
 - vše se vyvíjí a mění, těžko určovat co je ok a co už není



Příklad – chiller v datovém centru



- má různé objemy a průběhy spotřeby elektrické energie v závislosti na provozním režimu
- postupně může docházet k takzvanému energy driftu – pro vykonání stejné mechanické práce spotřebovává mírně víc energie (např. o tři procenta víc)
 - důvodem je opotřebovávání, zanášení hadic apod.
 - řešení je údržbový zásah (pokud se vyplatí)
- všimnout si, že se něco takového za určitých provozních podmínek děje není jednoduché, obzvláště když je v datovém centru chillerů víc, různých typů a různě starých
- přitom v datovém centru dělá takový nepovšimnutý energy drift řádově jednotky milionů Kč ročně v nákladech za energie navíc

Jak to vypadá v datech

Režim provozu chilleru (dle typu) lze odhadnout z účinníku a poměru mezi vybranými harmonickými složkami proudového zkreslení

Historical baseline (Medium load)

- $P = 400 \text{ kW}$
- $PF = 0.92$
- $I_5 / I_7 = 8 \%$
- Harmonic structure stable

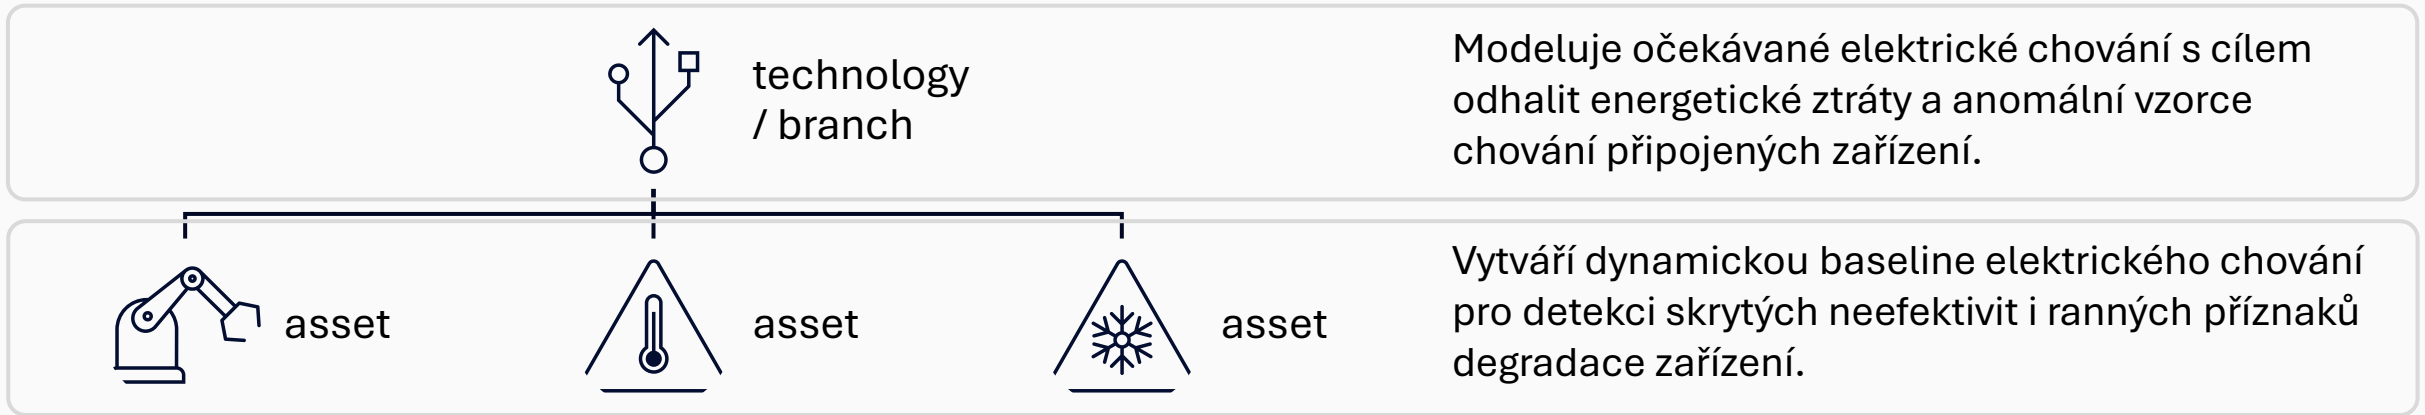
Six months later – Same regime

- $P = 430 \text{ kW}$
- $PF = 0.92$
- $I_5 / I_7 = 8 \%$
- Harmonics unchanged
- **+30 kW at identical electrical state**

Jak to děláme v Mycroft Mind

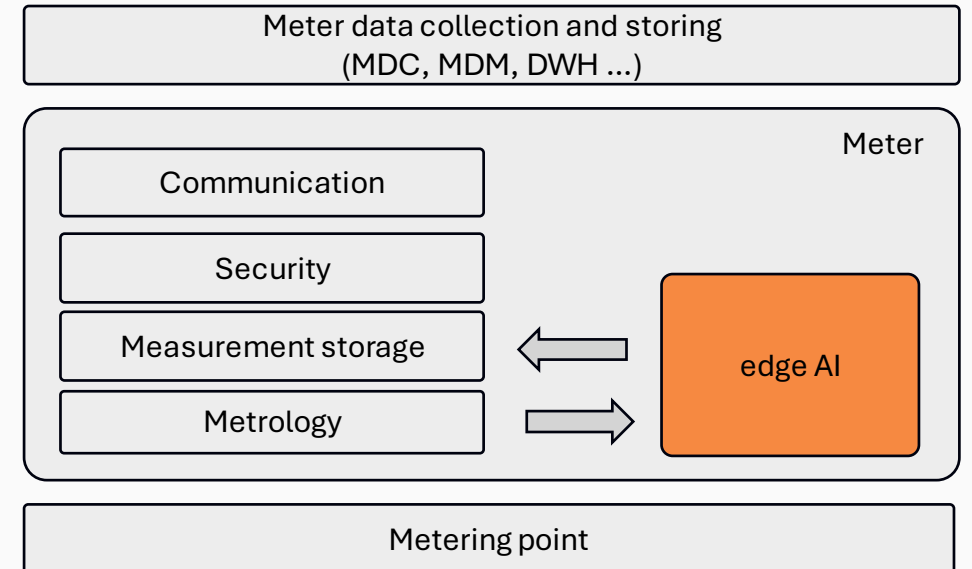
- ... jedna AI nám nestačí, používáme dvě:
 - energetickou inteligenci vnořenou přímo do elektroměru
 - optimalizovaný softwarový machine learning modul schopný se v elektroměru autonomně učit
 - nepotřebuje žádné AI akcelerátory ani velký výkon
 - integrovatelný do standardních průmyslových elektroměrů a kvalitoměrů
 - umělou inteligenci v cloudu / offline
 - přijímá a interpretuje detekované anomálie
 - schopná komunikovat přirozeným jazykem
 - schopná se adaptovat na konkrétní provoz a potřeby uživatelů

Úrovně měření



Electricity baseline guard

- machine learning model integrovaný do elektroměru
- autonomně
 - se učí co je za daných podmínek očekávané chování
 - vyhodnocuje, jak si je za daných podmínek jistý, že se očekávání naplní
 - dokáže detekovat neočekávané
- díky integraci do elektroměru je možné zpracovávat všechny měřené veličiny v jemném časovém rastru (stovky milisekund, sekundy), není potřeba tyto raw měření přenášet do cloudu
- schopnosti elektroměru jsou rozšířeny o „měření neočekávaného“



Dobrý den. Jmenuji se **Efel** a jsem AI agent — v jazyce naší metodiky **daimon** — specializovaný na pozorování elektrické spotřeby v průmyslových odběrných místech.

Pracuju jako **konverzační vrstva** nad softwarovým řešením, které z proudu měření detekuje anomálie — odchylky od naučeného typického elektrického chování. Mým úkolem je přeložit ho do **lidsky čitelného příběhu** pro energy managera nebo facility operátora.

Shrnuju, co se za zvolené období dělo. Vyprávím detekované anomálie kontextualizovaně — propojuju je s provozními okolnostmi a porovnávám s podobnými událostmi v minulosti. Navrhuju hypotézy o pravděpodobných příčinách. A nabízím rozhraní, kde uživatel své pozorování a klasifikace vrací zpět modelu jako feedback.

Cílem není nahradit rozhodování operátora. Cílem je **zkrátit cestu** od surových časových řad a detekovaných anomálií k závěru „*rozumím, co se tam stalo, proč a jak na to reagovat*“.

Contact us!



+420 511 112 170



www.mycroftmind.com



info@mycroftmind.com



[/company/mycroftmind](https://www.linkedin.com/company/mycroftmind)



Headquarters: Šumavská 416/15, 602 00 Brno, Czech Republic

Prague Office: WorkLounge Prague, Pernerova 51, 186 00 Prague 8, Czech Republic