

PREDIKTÍVNA ÚDRŽBA A MONITOROVANIE STAVU ZARIADENÍ V PROSTREDÍ MATLAB

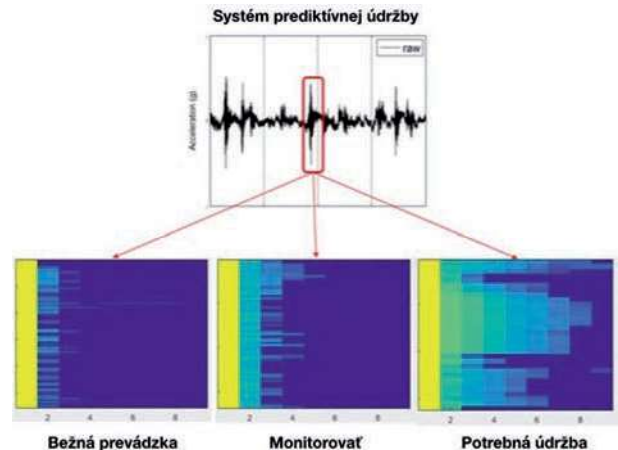
Správna a spoľahlivá práca zariadení je dôležitou súčasťou výrobných procesov. Významnú úlohu pri chode zariadení zohráva ich efektívna údržba. Znalosť momentu, v ktorom treba vykonať údržbu, je pri prevádzke kľúčová. Moderné metódy dokážu odhadnúť čas, kedy je vhodné údržbu uskutočniť. MATLAB ponúka skupinu nástrojov, ktoré pomáhajú pri vytvorení algoritmov prediktívnej údržby, a špecializovanú nadstavbu zameranú na túto oblasť – Predictive Maintenance Toolbox.

V každodennom živote sa stretávame so zariadeniami, ktoré sa časom pokazia, pokiaľ sa na nich nevykonáva údržba. Spoločnosti využívajú niekoľko stratégií údržby na dosiahnutie spoľahlivosti a zníženia nákladov. Prvou stratégiou je reakčná údržba, kde sa zariadenie opravuje až po poruche. Pri komplexných a drahých systémoch je tento prístup veľmi drahý a časovo náročný. Preto je častejšie využívanou stratégiou vykonávanie údržby v pravidelných intervaloch. V tomto prípade je ťažké určiť správny čas údržby; často sa údržba vykonáva priskoro, teda aj keď je zariadenie v poriadku. Pokiaľ by sme boli schopní predikovať, kedy nastane porucha, vedeli by sme naplánovať údržbu v správny moment. Prediktívna údržba umožňuje odhadnúť čas do poruchy na základe dát vytvorením predikčného modelu. Na druhej strane monitorovanie stavu zariadenia využíva dáta senzorov na zistenie zmien, ktoré indikujú začínajúcu sa poruchu.

Základom vývoja algoritmov prediktívnej údržby a monitorovania stavu sú dáta. Tie môžu pochádzať z viacerých zdrojov, môžu byť v rôznych formátoch a časoch. Keďže väčšinou zaznamenávame dlhšie obdobie prevádzky zariadenia od bežnej prevádzky po poruchové stavy, dát môže byť mnoho a práca s nimi nemusí byť vždy jednoduchá. Predictive Maintenance Toolbox poskytuje nástroje na správu dát zo senzorov, ktoré sú uložené lokálne alebo vzdialene. Opačným extrémom je, keď máme dát málo alebo nemáme žiadne poruchové dáta. V tomto prípade môžeme využiť výhody metódy Model-based design a poruchové dáta pre algoritmy prediktívnej údržby si vygenerovať pomocou modelu zariadenia v nástrojoch, ako je Simulink alebo Simscape.

Ďalším dôležitým krokom pri vývoji algoritmov prediktívnej údržby a monitorovania stavu je predspracovanie dát. To zahŕňa úpravu dát, ako je odstránenie alebo náhrada chýbajúcich, prípadne odľahčenie dát. Pokročilejšie metódy predspracovania dát zahŕňajú filtráciu signálov. Niekedy je vhodnejšie transformovať signál do inej domény, ako je napríklad frekvenčná oblasť. Veľkú pomoc pri pokročilejšom predspracovaní dát poskytujú nástroje ako Signal Processing Toolbox alebo Wavelet Toolbox. Predspracovanie pomáha jednoduchšie určiť indikátory stavu, ktoré sú dôležité na odlišenie bežnej a poruchovej prevádzky. Indikátory zohrávajú významnú úlohu pri vytvorení algoritmu prediktívnej údržby alebo monitorovania stavu.

Jadrom algoritmu prediktívnej údržby je vytvorenie predikčného modelu. Medzi hlavné súčasti Predictive Maintenance Toolbox patria metódy na výpočet zostávajúcej životnosti zariadenia (remaining useful life – RUL). Modely založené na podobnosti (similarity models) predikujú životnosť na základe známeho správania sa podobných zariadení z historických dát od spustenia až po poruchu. Tieto modely teda porovnávajú trendy v aktuálnych testovaných dátach alebo indikátoroch, ktoré vykazujú podobné degradačné správanie. Modely založené na prežití (survival models) využívajú štatistické metódy. Sú výhodné, keď nemáme historické dáta, ale len dáta



z času poruchy alebo údržby. Na základe týchto dát model odhaduje pravdepodobnostnú distribúciu času porúch. Modely založené na degradácii (degradation models) využívajú predchádzajúce správanie zariadenia na predikovanie budúcich stavov. Táto metóda sa snaží natréňovať lineárny alebo exponenciálny model degradácie na predikovanie zostávajúcej životnosti. Tento model tiež poskytuje konfidenčné intervaly a pravdepodobnosť poruchy.

Monitorovanie stavu rozlišuje medzi chybou na zariadení a bežným stavom. Na vytvorenie algoritmu monitorovania stavu využívame podobne ako pri prediktívnej údržbe indikátory stavu. Prvý typ modelov na monitorovanie stavu môže zahŕňať jedno alebo viac ohraničení indikátora, ktoré signalizujú poruchu, pokiaľ sú ohraničenia prekročené. Ďalší model využíva pravdepodobnostné rozloženie, ktoré opisuje pravdepodobnosť, že indikátor naznačuje typ poruchy. Posledná skupina modelov využíva strojové učenie na natréňovanie klasifikátora, ktorý porovnáva aktuálne hodnoty a vracia pravdepodobnosť chybového stavu.

Po vytvorení algoritmu prediktívnej údržby alebo monitorovania stavu možno algoritmus nasadiť na produkčný systém, cloud alebo koncové zariadenie. Nasadenie na cloud je výhodné, pokiaľ tam zbierate a ukladáte vaše dáta. Odpadá tak potreba presunu dát medzi cloudom a lokálnymi počítačmi, na ktorých by bežali algoritmy. Nasadením na koncové zariadenia sú algoritmy bližšie strojom a odpadá tak potreba presunu veľkých dát a informácie o stave zariadenia sú dostupné okamžite. Poslednou možnosťou je kombinácia oboch prístupov. Spoločnosť MathWorks aj v tomto prípade poskytuje nástroje na nasadenie na lokálny systém (MATLAB Production Server), prípadne cloudové riešenia, ako je Amazon Web Services (AWS) a Microsoft Azure.



HUMUSOFT, s.r.o.

Cabanova 13/D
841 02 Bratislava
Tel.: +421 905 478 990
info@humusoft.sk
www.humusoft.sk