

Strojové učení ve svařování

3.12.2025 - Marie Kolaříková | Fakulta strojní ČVUT v Praze

Na Ústavu mechaniky, biomechaniky a mechatroniky Fakulty strojní ČVUT v Praze nyní probíhá vývoj vysvětlitelných a fyzikálně informovaných neuronových modelů, které propojují principy strojového učení s fyzikálními zákonitostmi technických systémů.

S těmito modely lze nejen predikovat chování procesů, tj. využívat, co se tyto neuronové modely naučí, ale také inovativně zkoumat využití samotného procesu učení. Výzkum navazuje na koncept entropie učení, tj. inovativní míry informace založené na strojovém učení, kde míra novosti dat je kvantifikována jako překvapení učícího se systému (zatímco klasická pravděpodobnostní informace zohledňuje jen četnost výskytu dat). **Ve spolupráci s Ústavem strojírenské technologie Fakulty strojní ČVUT v Praze se pak výsledky aplikují například v oblasti odporového svařování, kdy tak lze včas detekovat změny stavu elektrod, optimalizovat parametry, prodlužovat jejich životnost a snižovat zmetkovitost.**

Vysvětlitelné a fyzikálně informované modely strojového učení propojují principy umělé inteligence s matematicko-fyzikální analýzou technických systémů. Vysvětlitelné neuronové architektury se učí z reálných dat a zároveň respektují to, co je nám známo o fyzikálních principech reálného procesu (například typ nelinearity, řád dynamiky, počet stupňů volnosti, omezení, okrajové podmínky apod). Následně se nabízí využití dalších nástrojů a metod strojového učení, od kterých si slibujeme další pokroky ve vysvětlitelnosti dat a informací, které z fyzikálně-informovaných neuronových modelů získáváme. A samozřejmě, nabízí se nám znalostní podpora velkou umělou inteligencí, tj. velkými jazykovými modely (LLM), kterými už běžně řešíme např. jednodušší programovací úlohy nebo se snažíme porozumět rychleji tématům, která jsou pro nás nová, nebo to aspoň zkoušíme, a vidíme, jak schopnosti těchto velkých AI rostou.

Na rozdíl od velké AI či obecně hlubokých neuronových sítí, které fungují jako „černé skříňky“, lze u našich analyzovatelných modelů přímo sledovat a vysvětlovat, jak třeba i jednotlivé datové vzorky ovlivňují chování učícího se systému v reálném čase a umožňují vysvětlovat tyto změny modelu vzhledem k procesu. Využitelnost takto koncipovaných neuronových modelů pak zkoumáme pro monitorování technologických procesů, například pro svařování elektrickým odporem nebo elektrickým obloukem, kde studujeme nejen predikci kvality svaru, ale i prodloužení životnosti elektrod, a tedy snížení frekvence jejich energeticky náročné výroby.

Tento výzkum vychází z dizertační práce doc. Ivo Bukovského, v níž jsou promítnuty poznatky z jeho pobytů na kanadské University of Saskatchewan, ve které zkonsolidoval koncept polynomiálních neuronových architektur a položil i základ konceptu Learning Entropy (LE) – inovativní informační míry (kvantifikace novosti dat), která sleduje, jak učící systém v čase reaguje na nově příchozí data, tj. s jakou mírou překvapení již předučeného ale stále se učícího modelu. Na rozvoji a aplikacích těchto metod doc. Bukovský dlouhodobě spolupracoval i s University of Manitoba, dodnes spolupracuje s Japonskou Tohoku University a dalšími výzkumnými institucemi.

Využití fyzikálně vysvětlitelných modelů přináší nový rozměr i do svařovacího procesu monitorováním a predikcí kvality svaru a detekcí opotřebení elektrod při bodovém svařování elektrickým odporem. Důsledek nekvalitních svarů se pak třeba projeví jako selhání pevnosti svarů při nárazových testech automobilu. Kontaktní plochy elektrod vlivem difúze prvků během svařovacího procesu mění svoje mechanické a elektrické vlastnosti. To vede ke změně geometrie kontaktní plochy a v důsledku toho i k čtenějšímu výskytu vnitřních vad v bodových svarových spojkách. V průmyslové praxi se tedy kontaktní plochy po určitém počtu provedených svarů

preventivně obrobí (frézují), aby se udržely optimální okrajové podmínky procesu a tím se předešlo vzniku vnitřních vad. Vzhledem k tomu, že elektrody jsou vyrobeny ze slitin mědi, každé prodloužení jejich životnosti vede k významné finanční úspoře a tím i k šetření životního prostředí. Další možnou úlohou řešenou v oblasti odporového svařování je autonomní reálnodobé řízení svařovacího procesu s využitím kamerových systémů spojených s knihovnami procesních dat nebo využití počítačového vidění a konvolučních neuronových sítí pro nedestruktivní kontrolu kvality.

Vyvíjené a zkoumané neuronové modely se vyznačují relativní jednoduchostí a matematickou přehledností, což umožňuje studentům Fakulty strojní pochopit jejich principy už v základním studiu a propojovat tak metody strojového učení s matematickými, fyzikálními a technologickými znalostmi. Mezioborová spolupráce slučující inženýrské znalosti a originální výzkum strojového učení nám otevírá další otázky a cesty pro výzkum a aplikace s využitím dalších nástrojů AI a analýzy dat s dnes již téměř neodmyslitelnou podporou velkou umělou inteligencí (LLM) jako znalostního nástroje podporujícího vzdělávací a výzkumnou činnost.

doc. Ing. Marie Kolaříková, Ph.D.

Ústav strojírenské technologie, Fakulty strojní ČVUT v Praze

<https://www.fs.cvut.cz/aktuality/3132-212/strojove-uceni-ve-svarovani>