


10.9.2026 Technical Computing Camp 2026

Embedded AI s prostředím MATLAB a Simulink



Jaroslav Jirkovský


jirkovsky@humusoft.cz

www.humusoft.cz


info@humusoft.cz

www.mathworks.com

Vývoj metodou Model-Based Design



Modelování, simulace a testování



Automatické generování kódu

```

Code
Control_System.c
Search

/* Model version : 0.0
 * Simulink Code version : 0.0 (R2020a) 19-Nov-2020
 * C/C++ source code generated on : Tue Apr 25 11:56:44 2023
 */

/* Target selection: ert-tic
 * Embedded hardware selection: Texas Instruments-C2000
 * Code generation objectives: unspecified
 * Validation result: not run
 */

#include "Control_System.h"
#include "math.h"
#include "rt_nonfinite.h"
#include "rttypes.h"
#include "string.h"

/* Block signals (default storage) */
BlockSignals_Control_System_B;

/* Block states (default storage) */
BlockStates_Control_System_B;

/* External inputs (root input signals with default storage) */
ExternalInputs_Control_System_U;

/* External outputs (root outputs fed by signals with default storage) */
ExternalOutputs_Control_System_Y;

/* Real-time model */
static #ifdef _CONTROL_SYSTEM_
#include "Control_System.h"
#endif

/* Model step function */
void Control_System_step(void)
{
    /* ... */
}


```

Nasazení




Vývoj metodou Model-Based Design


Systematické využití simulačních modelů
napříč vývojovým procesem



Vývojový cyklus V pro standardní (ne-AI) embedded systémy



Mapa nasazení metody MBD



Typy AI

Diskriminativní AI

klasifikace a predikce
výstupu na základě
vstupních dat

zaměření dnešního semináře

~~Generativní AI~~

AI Chat

generování a simulace nových
dat podobných tomu, co se AI
model naučil

AI Copilot

+ integrace a kooperace v
rámcí daného prostředí

Agentic AI

+ aktivní provádění akcí k
dosažení zadaných cílů

Diskriminativní AI ~ machine learning a deep learning

	Machine learning	Deep learning
Typ dat	tabulková data časové řady / signály obrázky / video	

Cloud AI, Edge AI, Embedded AI a tinyML

Cloud AI

AI modely, které jsou spouštěny na výkonných serverech ve vzdálených datových centrech. Ideální pro učení komplexních modelů a spouštění LLM.



Edge AI

Provozování AI modelu se odehrává na lokálním hardware, v blízkosti zdroje dat.

Lokální servery

Průmyslová PC



Embedded AI


AI modely které jsou spouštěny na zařízeních s omezenými zdroji jako součást vyvíjeného systému

Embedded GPU

Mikrokontroléry

NPU

FPGA



tinyML

Mikroprocesory


Latence, zpracování, energie

Typický příklad: Asistenční systém automobilu

AI algoritmus
detekce jízdních pruhů a vozidel

Řídicí systém


Model dynamiky vozidla
pro testování chování systému



Senzorická fúze


AI modely a jejich využití

machine learning
deep learning



Vývojový cyklus W: Adapte V-cyklu pro AI


Credit: EASA, Daedalean.



Správa požadavků




- Požadavky na celkový návrh systému
- Požadavky specifické pro AI komponenty
- Requirements Toolbox
 - vytváření, propojení a trasování požadavků
 - Requirements Editor
 - Traceability Matrix
 - Traceability Diagrams
- Klíčové otázky
 - jsou všechny požadavky implementovány?
 - jak budou požadavky testovány?
 - lze vysvětlit chování modelu?



Správa dat




- Správa dat určených pro učení AI modelu
- Označování dat pro účely učení
 - Image Labeler, Signal Labeler
- Manipulace s daty
 - přímé načítání dat – pro malé datové sady
 - objekty datastore: `imageDatastore`, `signalDatastore`, ...
 - úprava dat: `TransformedDatastore`, `augmentedImageDatastore`, ...
- Rozsáhlá data
 - tall arrays





```

imds = ImageDatastore with properties:
    Files: {
        '...\matlab\toolbox\matlab\demos\example.tif';
        '...\matlab\toolbox\matlab\matlab_images\tif\corn.tif'
    }
    Folders: {
        '...\matlab\toolbox\matlab'
    }
    Labels: [demos; imagesci]
    AlternateFileSystemRoots: {}
    ReadSize: 1
    SupportedOutputFormats: ["png" "jpg" "jpeg" "tif" "tiff"]
    DefaultOutputFormat: "png"
    ReadFcn: @readDatastoreImage
  
```

Správa procesu učení




- Přípravná fáze před vlastním učením
- Výběr AI modelu / architektury sítě
- Nastavení možností pro učení
 - učící algoritmus, ztrátová funkce, hyperparametry
- Interaktivní nástroje nebo funkce
 - Deep Network Designer
 - Classification Learner
 - Regression Learner
- Hledání optimálních hyperparametrů
 - nastavení experimentů
 - Experiment Manager



AI modely v prostředí MATLAB

Machine learning


Deep learning




SVM




Clustering




Decision trees




FC



CNN




LSTM




MATLAB a spolupráce s dalšími nástroji


- Import AI modelů z prostředí TensorFlow, PyTorch a v otevřeném formátu ONNX





- Export AI modelů




Učení AI modelu



- Učení zvoleného modelu / skupiny modelů
- Posouzení dosažené přesnosti modelu
- Hledání optimálních hyperparametrů
 - spuštění experimentů
 - výběr nejlepšího modelu
- Iterativní proces v rámci W-cyklu
 - změny nastavení v případě nedostatečných výsledků
 - výběr odlišných metod pro učení, ...



Verifikace procesu učení






- Testování AI modelu
 - důležité je testovat s nezávislou sadou dat
 - metriky pro vyhodnocení úspěšnosti sítě
- Pochopení chování AI modelu (XAI)
 - interpretovatelnost modelu, vysvětlitelnost modelu
 - vizualizační techniky pro pochopení chování modelu
- Ověření robustnosti AI modelu
 - adversarial examples, formální verifikace
 - detekce „out-of-distribution“ dat


Accuracy: 90.71%

confusionchart(T,Y)



True Class	Predicted Class	
	normal	pneumonia
normal	193	41
pneumonia	17	373



Implementace AI modelu




- Příprava AI modelu pro implementaci
 - komprese modelu (hluboké neuronové sítě)
- Automatické generování kódu
 - generování kódu z naučených AI modelů
 - optimalizovaný kód pro cílovou platformu
 - C/C++, CUDA, HDL
- Simulink jako platforma pro implementaci a integraci
 - implementace řešena současně s fází integrace a verifikace
 - propojení AI modelu s dalšími algoritmy (řídící systém, ...)
 - testování prostřednictvím simulace
 - společná implementace (automatické generování kódu)




Kompresa AI modelu

- Cíl: snížit paměťovou náročnost a výpočetní nároky hluboké neuronové sítě
- Dva hlavní faktory přispívající k velikosti neuronové sítě:
 - Stavy
 - informace vypočítané během operací s vrstvami
 - uchovávají se pro použití v následných průchodech vrstvou
 - např. vnitřní stavy LSTM vrstev
 - Učitelné parametry
 - obsahují vlastnosti, které se síť naučila
 - např. váhy konvolučních a plně propojených vrstev



Způsoby komprese AI modelu v prostředí MATLAB


- Strukturální komprese – pruning, projekce
 - snížení počtu stavů a učitelných parametrů
- Komprese datových typů – kvantizace
 - převod stavů a parametrů na datové typy s nižší přesností
- Kompresní techniky lze kombinovat ~ je dobré aplikovat ve tomto pořadí



- K dosažení optimálních výsledků po každém kroku neuronovou síť dotrénovat

Analýza možností komprese AI modelu


- Analýza zobrazuje informace:
 - maximální možná úspora paměti
 - podpora pruningu, projekce a kvantizace pro danou síť
 - omezení pruningu jednotlivých vrstev z důvodu architektury sítě



- Slouží k rozhodnutí, kterou techniku ke kompresi sítě použít

Pruning (prořezávání)

- Systematické odstranění nejméně důležitých parametrů sítě, aby se zmenšila velikost sítě a zároveň se zachovala kvalita jejích predikcí



- Měření významu skupiny parametrů
 - dle změny hodnoty ztrátové funkce po odstranění parametru
- Iterativní proces
 - 1. určení důležitosti filtrů, 2. odstranění nejméně důležitých filtrů, 3. doučení sítě
- Funkce (all-in-one): `compressNetworkUsingTaylorPruning`

Taylor Pruning – na čem je založen


- Určení důležitosti parametrů pomocí Taylorova rozvoje (aproximace)
 - ztráta (loss) jako funkce jednotlivých parametrů sítě θ
 - odstranění parametru je ekvivalentní nastavení jeho hodnoty na 0

$$|\Delta loss(X, \theta)| = |loss(X, \theta = 0) - loss(X, \theta)|$$

- Taylorův rozvoj: $loss(X, \theta) = loss(X, \theta = 0) + \frac{\delta loss}{\delta \theta} \theta$
- Změna ztráty je funkce gradientu: $|\Delta loss(X, \theta)| = \left| \frac{\delta loss}{\delta \theta} \theta \right|$
- Gradient počítán při učení sítě $\Rightarrow$ využijeme je znovu

Projekce

- Způsob převodu velkých vrstev s mnoha učitelnými parametry na jednu nebo více menších vrstev s nižším celkovým počtem učitelných parametrů




- K redukci velikosti využívá PCA (principal-component analysis)
- Po provedení projekce následuje doučení sítě
 - k obnovení přesnosti predikce ztracené projekcí
- Funkce: `compressNetworkUsingProjection`

Projekce – na čem je založena

- V neuronových sítích jsou data reprezentována jako více-rozměrné vektory W
 - ne všechny dimenze jsou pro danou úlohu stejně důležité
- PCA umožňuje vyjádřit data v podobě dimenzí seřazených podle důležitosti
- Princip projekce: Wx nahradí za $WQQ^T x$
 - Q matice projekce do méně-rozměrného prostoru
 - vrstva (*projected layer*) ukládá Q a $W' = WQ$ namísto původní matice W
- Postup
 - 1. určí podprostor učitelných parametrů s nejvyšším rozptylem v aktivacích neuronů (PCA)
 - 2. promítne vstup vrstvy do prostoru nižší dimenze (N nejdůležitějších směrů)
 - 3. provede funkci dané vrstvy v prostoru nižší dimenze
 - 4. vrátí se do prostoru vyšší dimenze

Kvantizace


- Technika komprese datových typů, která snižujete numerickou přesnost parametrů v síti, ale množství parametrů a architektura sítě zůstávají stejné



- Postup kvantizace
 - nalezení dynamických rozsahů parametrů sítě pomocí reprezentativního vzorku dat
 - převedení parametrů všech vrstev na celá čísla dle dynamického rozsahu z předchozího kroku
- Funkce (objekt): **dlquantizer**
 - postup: 1. vytvoření a příprava objektu, 2. kalibrace, 3. kvantizace, 4. validace
- Aplikace: **Deep Network Quantizer**

Co poskytuje aplikace Deep Network Quantizer




- Vizualizace dynamických rozsahů konvolučních vrstev
- Výběr vrstev pro kvantizaci
- Posouzení chování kvantizované sítě
- Generování kódu
 - C++ pro ARM Cortex-A
 - GPU pro grafické akcelerátory
 - HDL pro FPGA



- Generování simulovatelné kvantizované sítě
 - lze prozkoumat v prostředí MATLABu bez generování kódu nebo nasazení na hardware

Ukázka: Komprese AI modelu pro klasifikaci sekvencí

- AI model určený pro detekci vad na vozovce
 - typ modelu: neuronová síť, 1D konvoluční vrstvy
- Data z akcelerometru při jízdě po vozovce
 - přesnost detekce poškozených úseků: 97 %
- Komprese: pruning, projekce, kvantizace




Další techniky


- Destilace znalostí (*knowledge distillation*)
 - využívá velkou a přesnou síť učitele k naučení menší sítě studenta
 - umožňuje navrhnout malou síť tak, aby vyhovovala paměťovým požadavkům
- Kvantizace pomocí knihovny NVIDIA TensorRT (GPU Coder)
 - kód pro 8bitovou celočíselnou predikci generovaný pomocí knihovny NVIDIA TensorRT
- Kvantizace pomocí kódu bfloat16 (MATLAB Coder)
 - bfloat16 je zkrácená verze formátu single
 - zabírá pouze 16 bitů (oproti 32), přibližně stejný rozsah čísel (stejný počet bitů exponentu)
- Řídkost
 - lze použít k prořezání sítě pomocí vlastní metriky důležitosti
 - nejméně důležité parametry nastavit na nulu a výsledné matice vah uložit jako řídké matice

Automatické generování kódu


- Generování kódu z naučených a komprimovaných AI modelů
 - z prostředí MATLAB
 - z prostředí Simulink
- Jazyky a cílové platformy
 - C/C++ pro CPU a μ P
 - CUDA pro GPU
 - HDL pro FPGA a SoC
- Nastavení generátoru kódu
 - vzhled a struktura kódu
 - optimalizace pro cílovou platformu
 - reporty a trasovatelnost




Verifikace a integrace modelu pro inferenci



- Dvě důležité provázané fáze nasazení AI modelu
 - přechod modelu z teoretické roviny do prakticky provozovaného nástroje
- Verifikace implementovaného modelu
 - ověření přesnosti modelu v implementované podobě
 - zásadní zejména pro bezpečnostně kritické aplikace
- Integrace modelu
 - zapojení modelu do širšího návrhu
 - propojení s dalšími algoritmy
 - testování v kontextu celkové funkčnosti
- Simulink jako platforma pro integraci
 - integrace bývá řešena současně s předchozí fází implementace
 - testování prostřednictvím simulací a nástrojů pro tvorbu a správu testů (Simulink test)




Nezávislé ověření dat a procesu učení




- Následuje po důkladném ověření inferenčního modelu na cílové platformě
- Ověření, zda byly datové sady v průběhu vývoje řádně spravovány
 - nezávislé přezkoumání které potvrdí, že trénovací, validační a testovací datové sady:
 - a) splňují striktní požadavky na správu dat
 - b) jsou úplné a reprezentativní pro vstupní datový prostor dané aplikace
- Ověření procesu učení
 - ověření, zda byl trénovaný model uspokojivě verifikován, včetně nezbytných analýz pokrytí



Verifikace požadavků




- Závěrečná část W-cyklu
- Ověření, že byly veškeré požadavky
 - a) implementovány v podobě navrhované funkčnosti
 - b) splněny v podobě provedených testů
- Provázání požadavků s implementovanými funkcemi a testy
 - klíčové pro uzavření smyčky vývojového procesu
 - spuštěním všech definovaných testů ověříme, že požadavky byly adekvátně implementovány



Index	ID	Summary	Implemented	Verified
> XRPD_System				
▼ XRPD_SystemMLC...				
▼ 1	XRPD_ML_HLR	ML component requirement for X-Ray Pneumonia Detector (XRPD)		
1.1	XRPD_ML_INT...	Introduction		
1.2	XRPD_ML_DES...	ML component description		
▼ 1.3	XRPD_ML	ML component requirements		
▼ 1.3.1	XRPD_ML_1	ML component input		
1.3.1.1	XRPD_ML_1_1	ML component input should be 28x28x1		
1.3.1.2	XRPD_ML_1_2	ML component input data (training) should be 28x28x1		


Shrnutí: Vývojový cyklus W ~ propojení AI a MBD



Další informace a příklady

- Série článků
 - [část 1. úvod](#)
 - [část 2. požadavky a modelování](#)
 - [část 3. verifikace učení](#)
 - [část 4. implementace a verifikace požadavků](#)


- Ukázky:
 - [End-to-End AI Workflows](#)



Credit: EASA, Daedalean.

Vybrané uživatelské reference

- AI-Powered Virtual Sensor Delivers Real-Time Cabin Air Mass Flow Estimation
 - Mercedes-Benz Research & Development
- TinyML to Enhance Performance of Field-Oriented Control
 - STMicroelectronics
- Implementing a Workflow for Deploying and Integrating Deep Learning Networks on PLCs for Industrial Automation
 - Beckhoff Automation GmbH & Co. KG



Děkuji za pozornost

Kontakty



- Pro technické dotazy využijte naši technickou podporu
 - email: support@humusoft.cz
 - tel.: +420 602 231 500
 - <https://www.humusoft.cz/matlab/support/>
- Všeobecné dotazy
 - email: info@humusoft.cz
 - tel.: +420 284 011 730
- Nebo můžete využít náš kontaktní formulář
 - <https://www.humusoft.cz/contact/#contact>

Adresa:

Pobřežní 20
186 00 Praha 8
Česká republika

Web:

www.humusoft.cz

