

NVIDIA DGX systémy pro pokročilé aplikace strojového učení

Prof. Ing. Pavel Václavek, Ph.D.

23.10.2024

CEITEC – Central European Institute of Technology

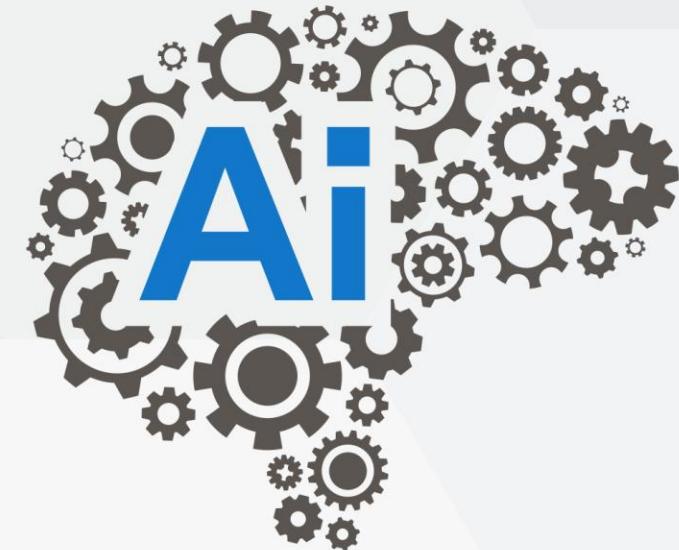
- CEITEC založen 2011 jako evropské centrum excelence
- CEITEC VUT je vysokoškolským ústavem VUT v Brně
- Multidisciplinární institut – materiálové vědy, nano-technologie, engineering, přírodní vědy



Kybernetika a robotika

Základní a aplikovaný výzkum

- Řídicí a automatizační systémy
- Robotika – mobilní roboty
- Senzory a měřicí systémy
- Průmyslové komunikace
- Instrumentace, PLC, průmyslové řídicí systémy



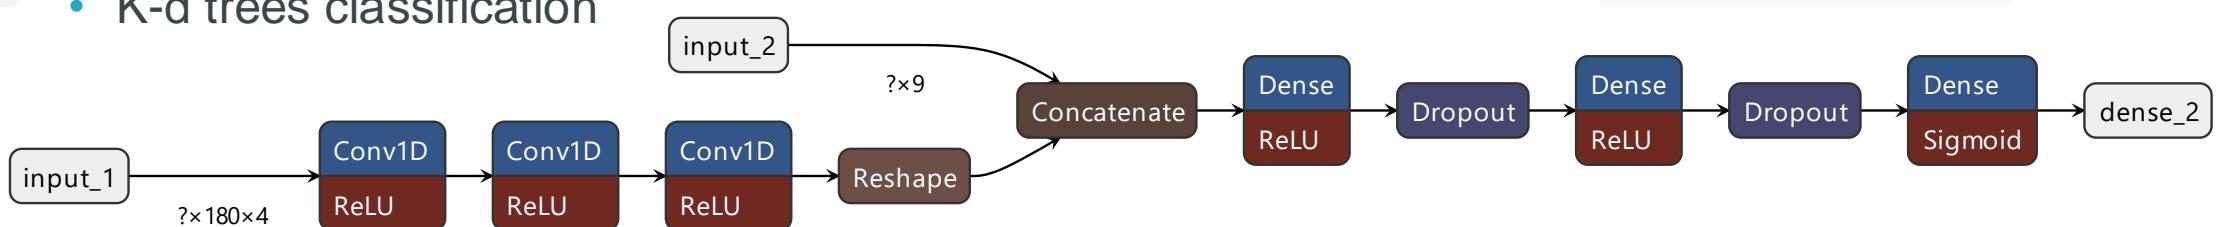
Fail-operational application

- Industry
 - Fully automatic production lines
- Automotive
 - Autonomous vehicles
- Aerospace
 - High reliable electrical propulsion
- Traction systems
 - Public transport systems



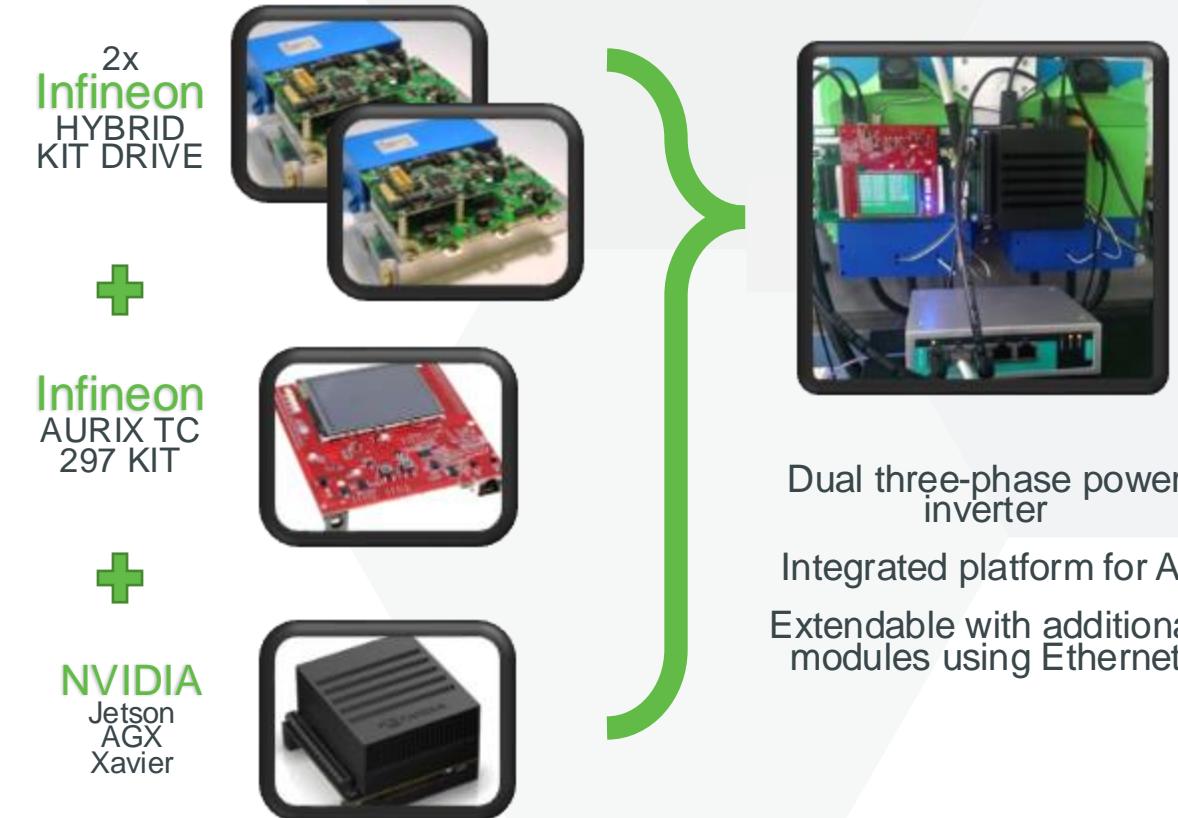
Fault detection

- Various faults require various detection time
- Undetected faults without appropriate action lead to other faults – fault propagation
 - Interturn short-circuit causes the temperature increase → temperature damages other coil turns of the winding
- Motor fault can be detected using various methods
 - Detection methods based on motor model
 - Parameter and state observers prepared for specific fault
 - Statistical methods
 - Machine learning methods
 - Artificial Neural Networks classification
 - K-d trees classification



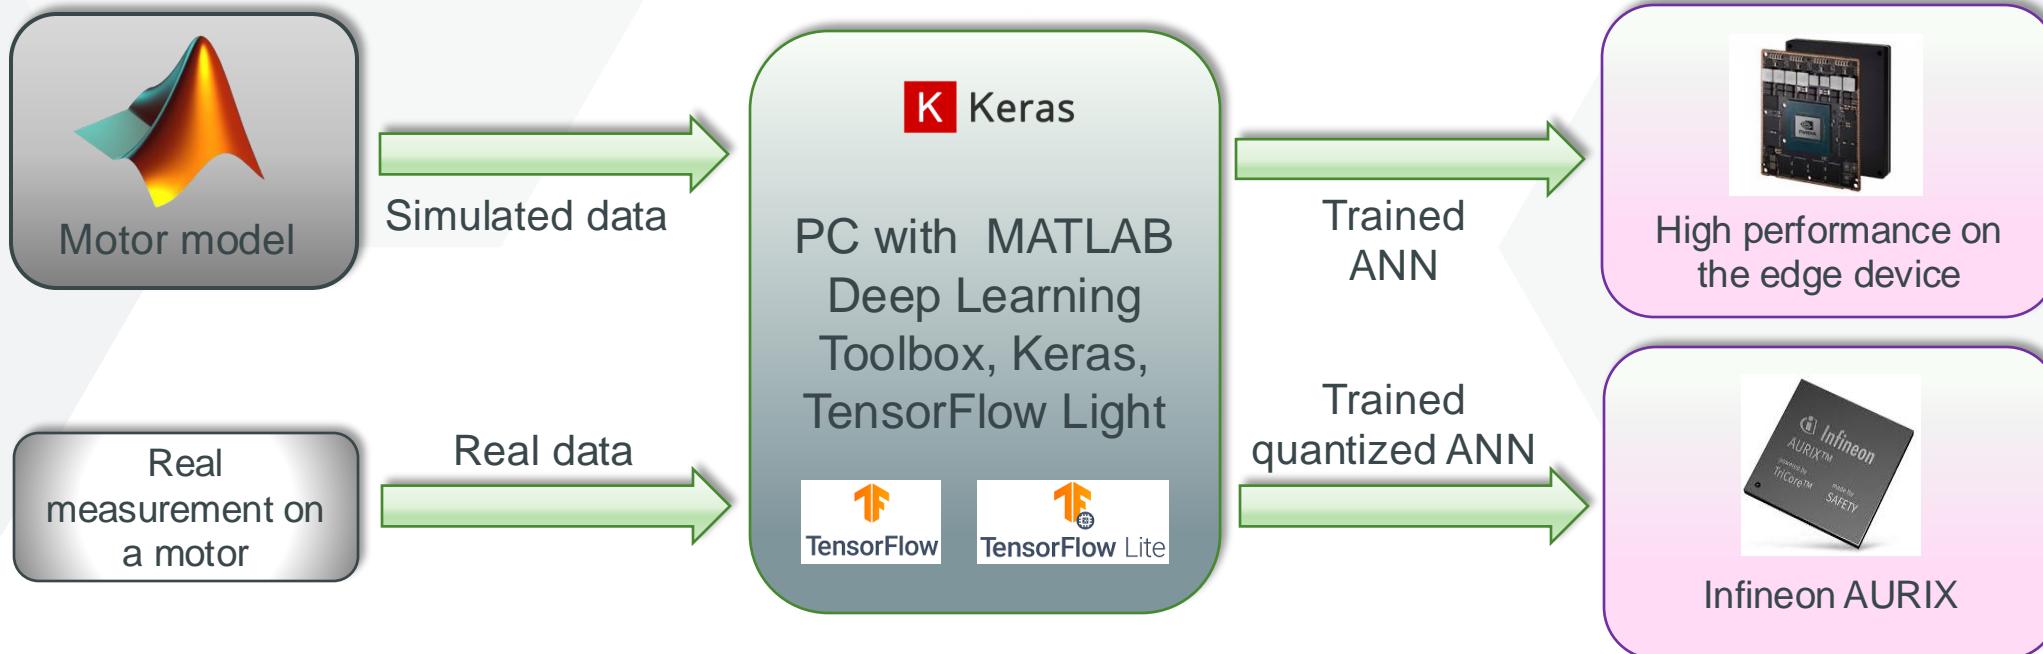
ANN experimental platform

- The power inverter consists of Hybrid kit drive, AURIX TC297 Application kit and Jetson AGX Xavier.
- Jetson AGX Xavier with 512-core Volta GPU with Tensor Cores and 8-core ARM v8.2 64-bit CPU accelerates AI computation
- AURIX and Xavier are interconnected using Ethernet
- Inverter is connected to customized configurable PMSM
- PMSM can be loaded using dynamometer
- The whole system is controlled from MATLAB



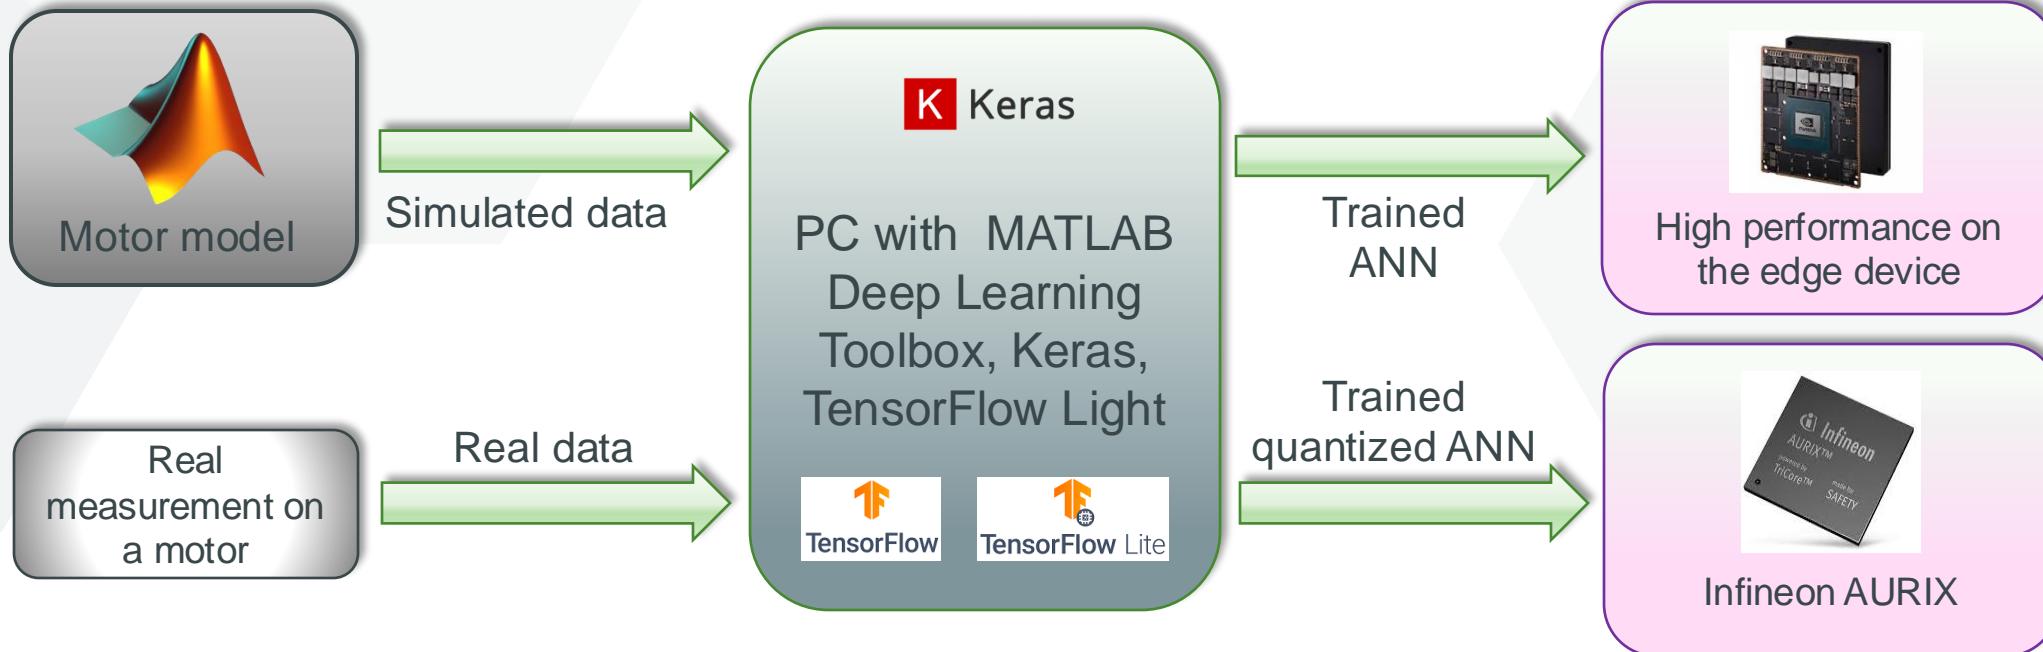
ANN preparation

- ANN is prepared in TensorFlow using combination of measured and simulated data
 - Simulated data are required for faults which can not be emulated and measured
 - Using only simulated data for training is also possible



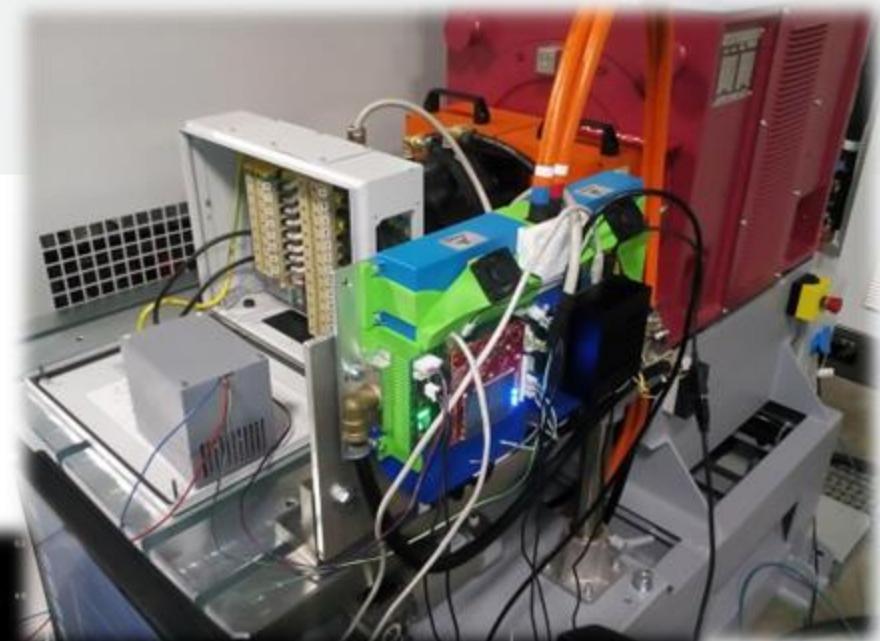
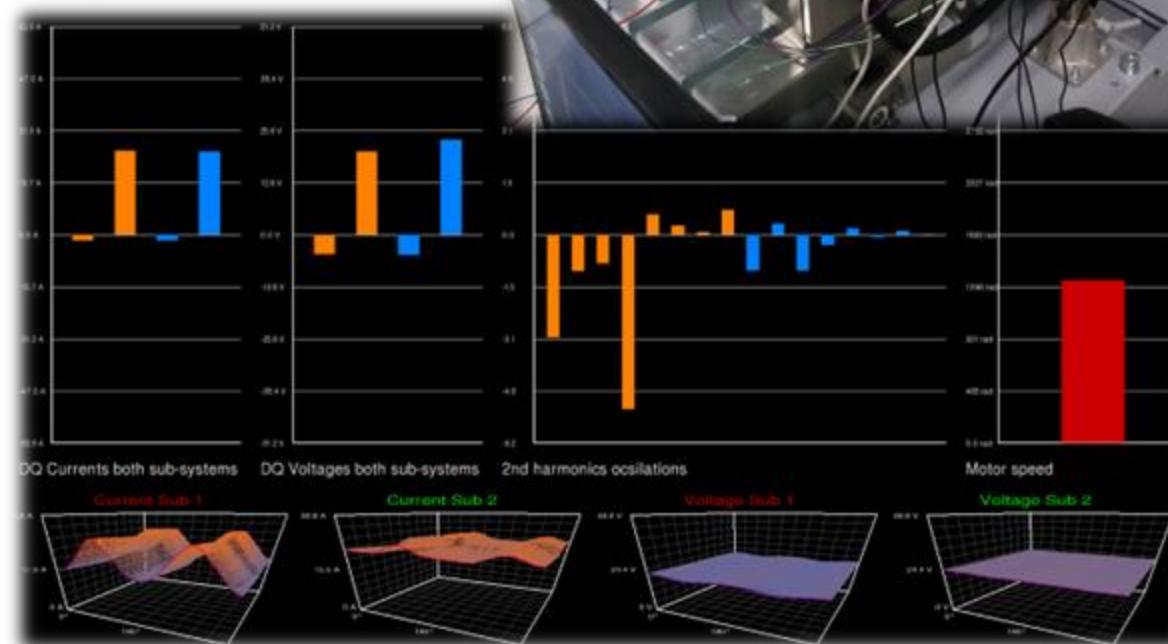
ANN preparation

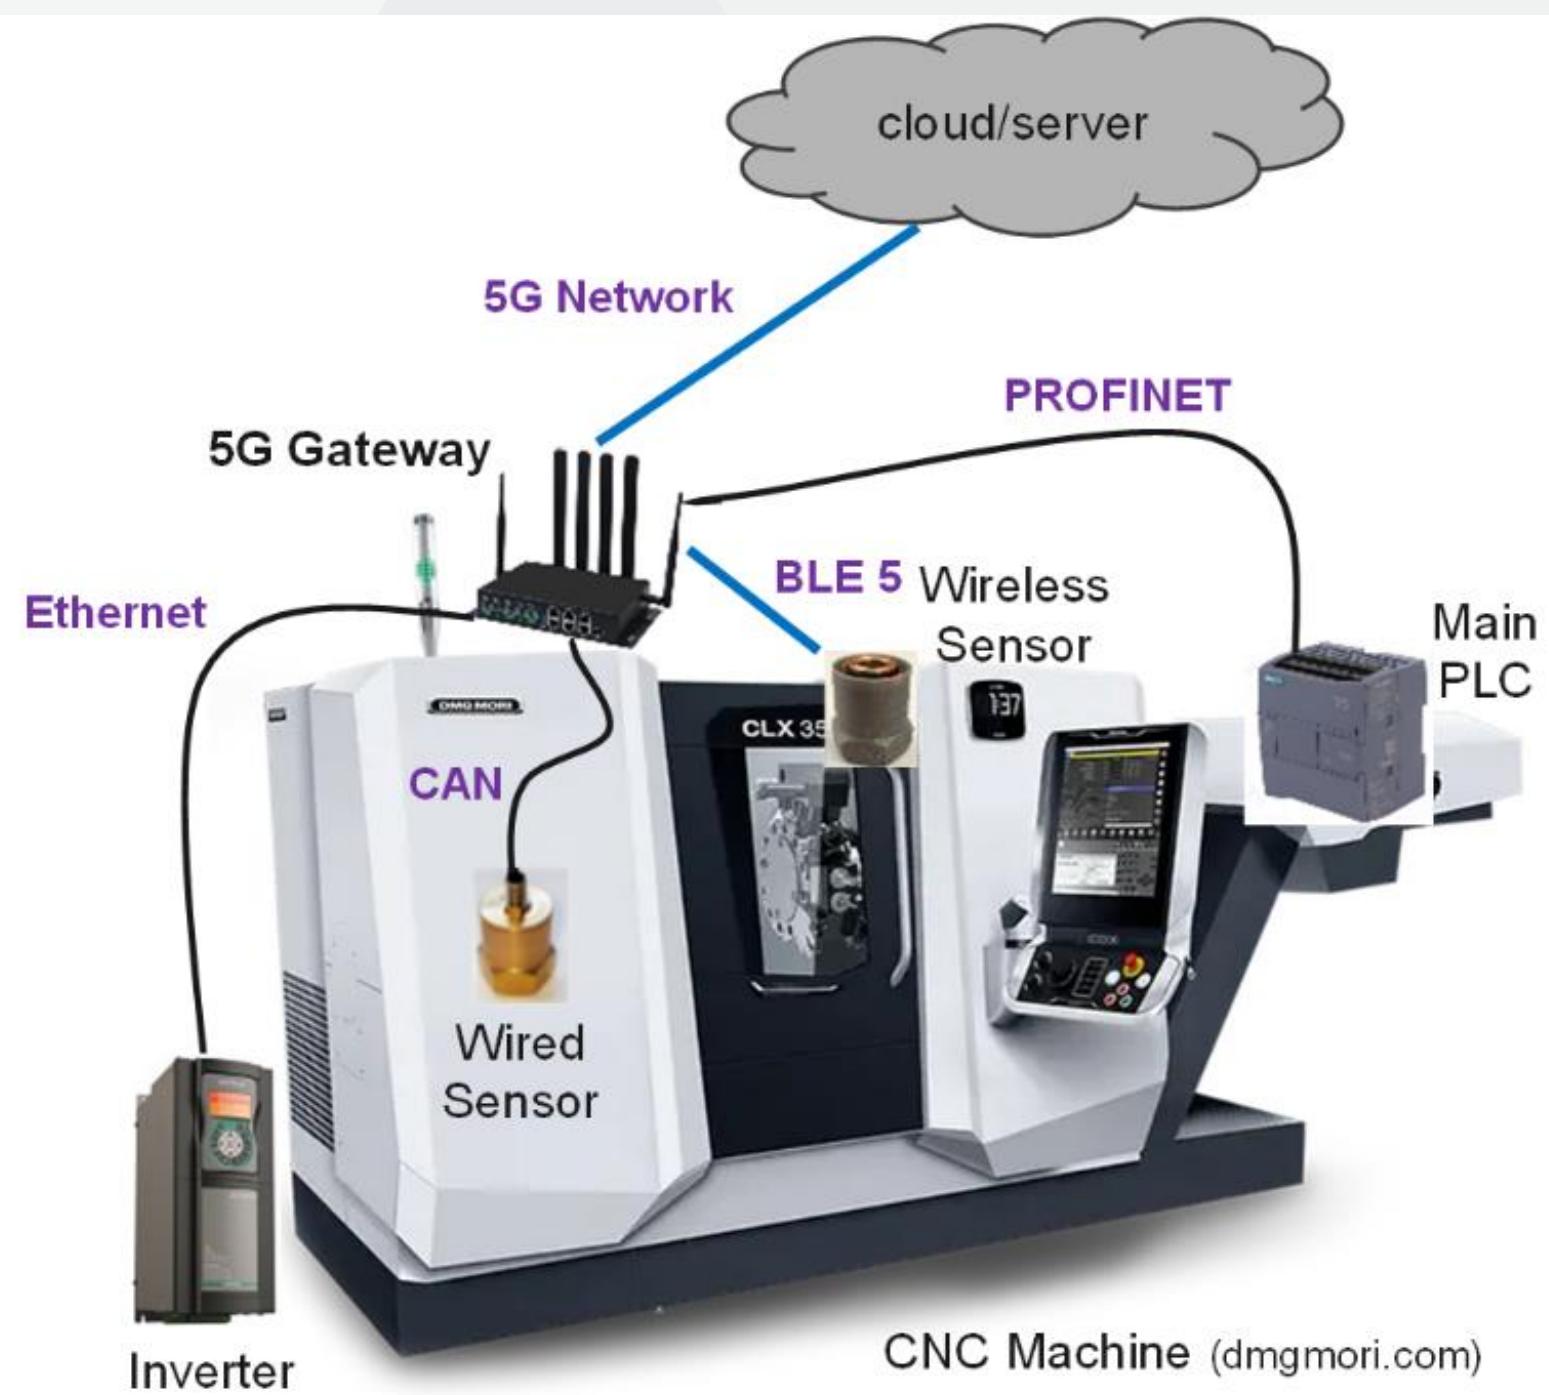
- Prepared ANN is integrated into target platform
 - Powerful AI platform can operate in **float32** or **float16**
 - Microcontrollers typically require ANN quantization into **int** for best performance



Achieved classification results

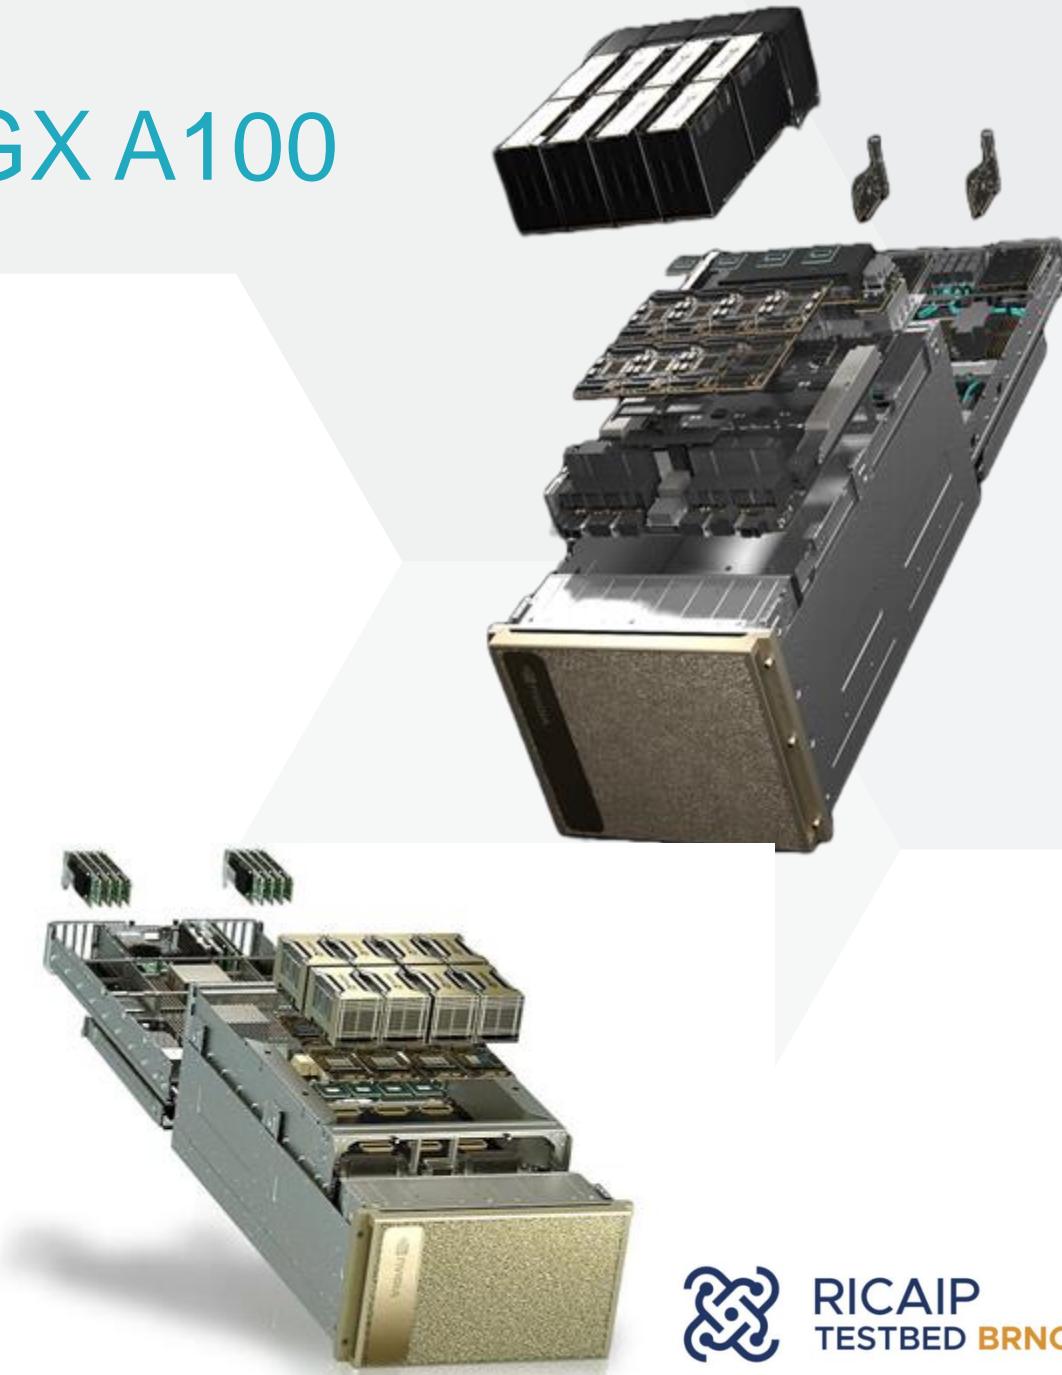
- Prepared ANN can successfully detect fault at steady state
- Classification using on the edge implementation of ANN in less than 5 ms (including data preprocessing and communication delays)
 - ANN inference time around 1ms
- Combination of convolutional and dense layers
 - One input for oversampled motor voltages and currents
 - Second input for motor speed, setpoints, and extracted features





Cluster NVIDIA DGX H100 + DGX A100

| PARAMETR | NVIDIA DGX H100 640 GB | NVIDIA DGX A100 640 GB |
|------------------------|--|--|
| GPUs | 8x NVIDIA H100 SXM5 80 GB | 8x NVIDIA A100 SXM4 80 GB |
| GPU memory | 640 GB total | 640 GB total |
| CPU | 2x Intel Xeon Platinum 8480C CPU, (112 jader) 2.00 GHz | 2x AMD Epyc 7742 (128 jader, 2.25GHz) |
| Výkon (tensor operace) | 32 PetaFLOPS (FP8) | 5 PetaFLOPS (FP16) |
| # CUDA jader | 135 168 | 55 296 |
| # Tensor jader | 4 224 | 3 456 |
| Multi-instance GPU | 56 instancí | 56 instancí |
| RAM | 2 TB | 2 TB |
| HDD | OS: 2x 1.92 TB NVMe data: 30 TB (8x 3.84 TB) NVMe | OS: 2x 1.92 TB NVMe data: 30 TB (8x 3.84 TB) NVMe |
| Network | 8x ConnectX-7 400Gb/s InfiniBand 4x ConnectX-7 200Gb/s Ethernet | 8x ConnectX-7 200Gb/s InfiniBand 4x ConnectX-7 200Gb/s Ethernet |
| Max. spotřeba | 10,2 kW | 6.5 kW |
| Provedení | rack, 8U | rack, 6U |



Infrastruktura testbedu CEITEC VUT

Průmyslová hala – skutečné průmyslové prostředí

Vybavení

- 3D tisk
- Robotický sklad
- Laserové řezání/svařování
- 5osé a 3osé frézování, CNC soustruh
- Přesné 3D skenování
- Vybavení pro AR/VR
- Referenční optický lokalizační systém
- Automatizační HW, PLM SW
- Vše směrové mobilní roboty,
průmyslové manipulátory, coboty
- Kráčející roboty (Boston Dynamics)
- Privátní 5G síť
- Dynamometry



RICAIP
TESTBED BRNO

 RICAIP

Research and Innovation Centre
on Advanced Industrial Production

EDIH DIGIMAT

- **Evropský digitální inovační hub** podporující digitalizaci výrobních podniků
- Konsorcium - Intemac, VUT, JIC a Effectivity
- Zaměření na robotiku, automatizaci včetně využití AI
- Služby
 - **Test before invest**
 - **Experimenty na testbedu**
 - **Pomoc s nasazením digitálních technologií**
 - **Poradenství**
 - **Vzdělávací a popularizační aktivity (Digitální akademie)**
- Široké spektrum oblastí experimentů – robotika, 3D tisk, diagnostika strojů, aktuátory, UGV/AGV, AR/VR, lokalizace strojů/lidí, 5G komunikace, HPC,....
- Pro SME a small mid-caps (do 499 zaměstnanců) sleva 100%

TEF AI-MATTERS

The European Testing and Experimentation Facilities for AI in Manufacturing

- Sít' evropských testbedů – Francie, Německo, Nizozemí, Česká republika, Španělsko, Dánsko, Itálie, Řecko
- TEF poskytuje služby pro celou EU
- Zaměření na nasazení AI ve výrobních firmách
 - Experimenty s AI v průmyslovém prostředí
 - Vývoj ukázkových aplikací AI
 - Příprava datasetů
 - Podpora při vývoji aplikací AI pro výrobní technologie
- Plánované významné další rozšíření technologií testbedu
- Poskytování služeb SME se slevou 100%



Financováno
Evropskou unií
NextGenerationEU



NÁRODNÍ
PLÁN OBNOVY



Spolufinancováno
Evropskou unií





CEITEC Vysoké učení technické v Brně

Brno, Purkyňova 656/123

pavel.vaclavek@ceitec.vutbr.cz