


Užití metod hlubokého učení v řešení úloh strojového vidění

MIROSLAV MECA

atesystem 
FOCUSED ON DETAIL

Využití samoučících algoritmů ve zpracování obrazu

Konvenční přístup



Program 1
Extrakce vzorů



Program 2
Extrakce vlastností





Program 3
Klasifikátor



OK / NG

Hluboké učení



Natrénovaný model konvoluční
neuronové sítě (CNN)



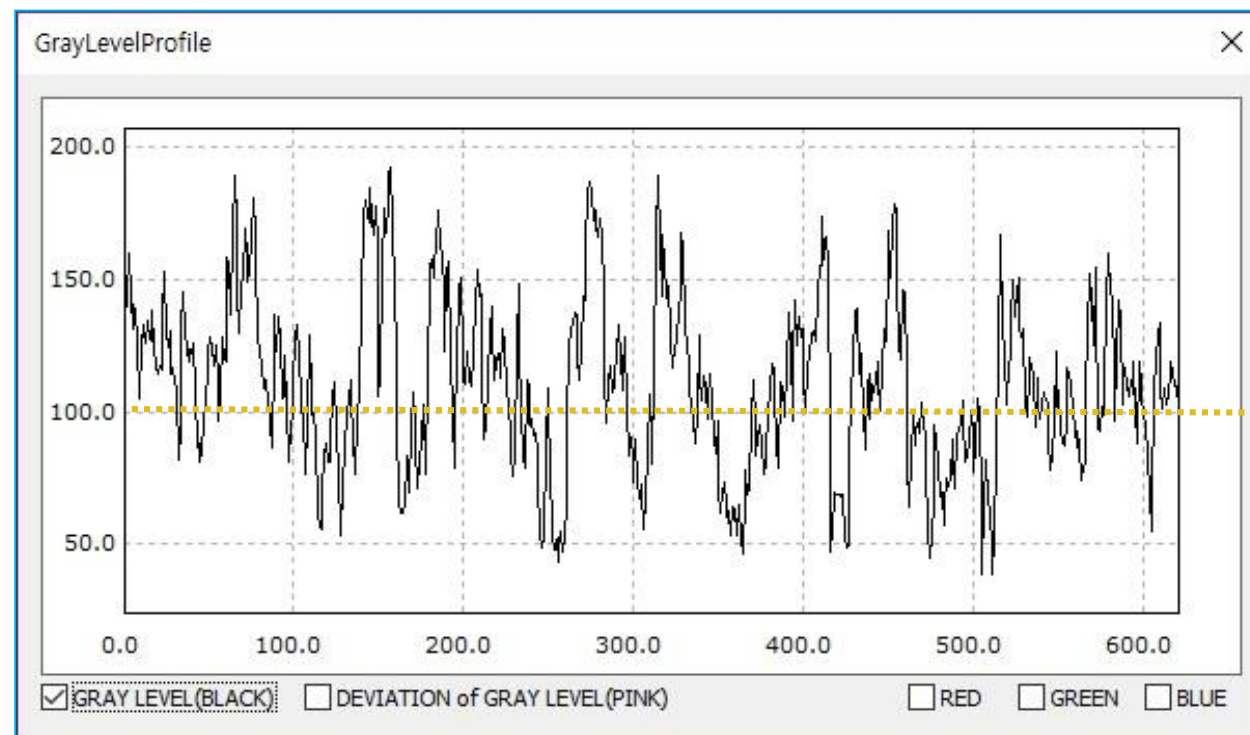
OK / NG

Výhody

- ✓ Rychlejší realizace algoritmů
- ✓ Možnost řešit i úlohy obtížně řešitelné konvenčními metodami zpracování obrazu

Omezení klasických metod inspekce ve strojovém vidění

Klasické metody strojového vidění nemohou smysluplně analyzovat nepravidelné snímky, kde defekty nejsou přesně definovány.

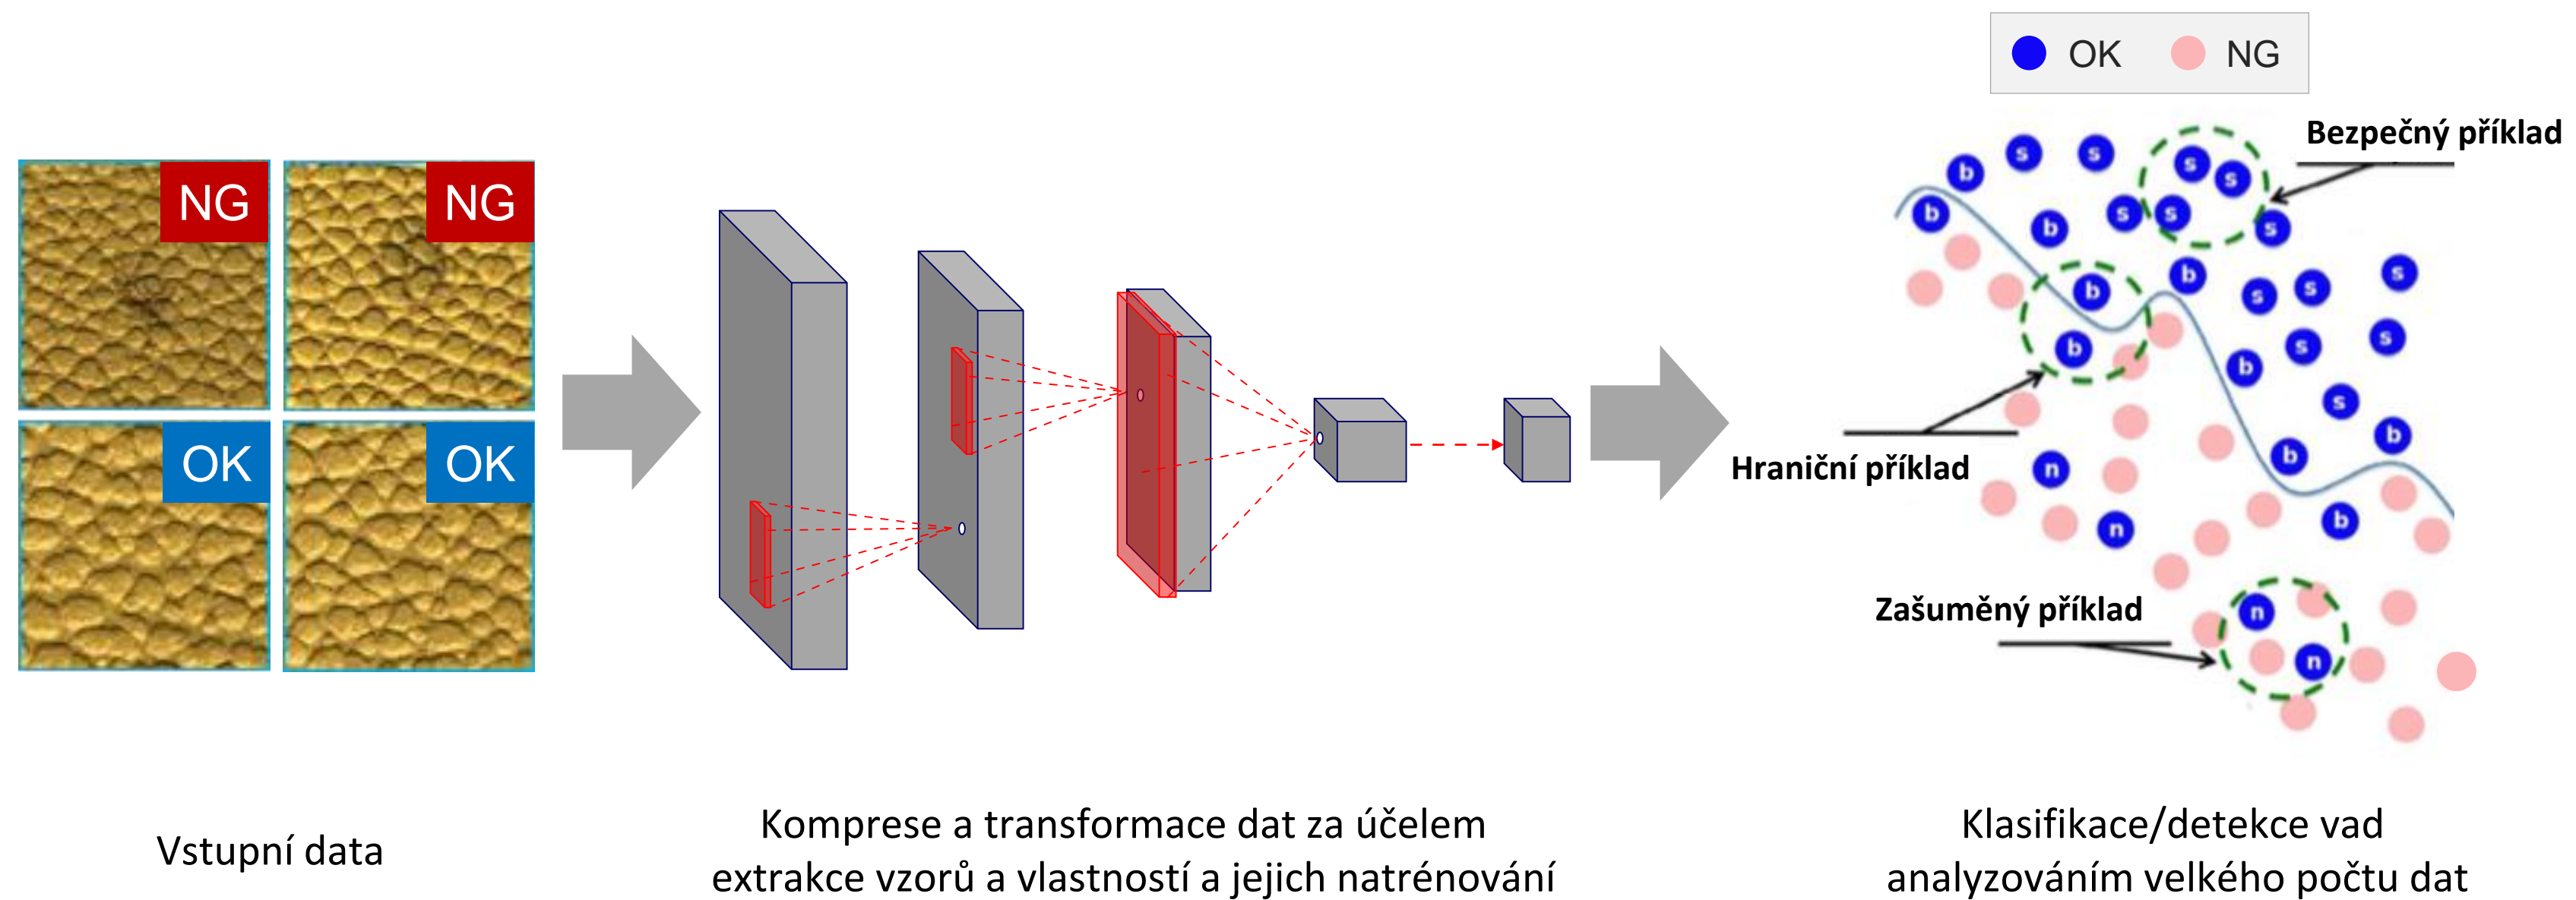


※ Zdroj: Výzkumná databáze fy
SUALAB

Inspekce pomocí metod hlubokého učení

Metody hlubokého učení extrahují části snímku a rozloží je do vrstev.

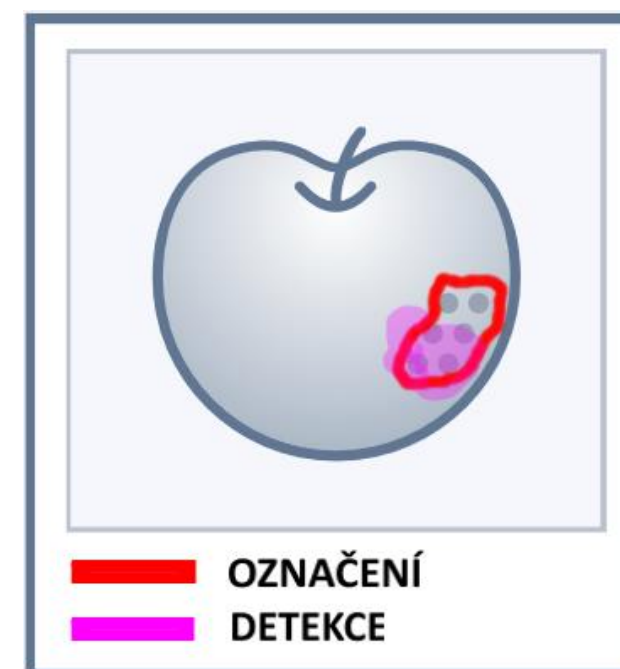
Samy se naučí důležité vzory a vlastnosti díky analýze interakcí mezi jednotlivými vrstvami a tím naleznou správná řešení.



Řešení úloh strojového vidění pomocí metod hlubokého učení – základní „workflow“

1. Získání sady obrázků
2. Označení obrázků (labelling) - např. **OK** / **NG**
3. Rozdělení sady na trénovací a testovací
4. Naučení modelu na trénovací sadě
5. Otestování modelu vyhodnocením obrázků z testovací sady
6. Ověření přesnosti modelu

VYHOVUJÍCÍ



NEVYHOVUJÍCÍ

7. Integrace modelu do funkční aplikace

Rozšíření sady obrázků a opakování postupu

Celý postup můžeme vícekrát iterativně opakovat

SuaKIT – softwarový nástroj k řešení úloh strojového vidění pomocí hlubokého učení



The screenshot displays the SuaKIT 2.3 software interface. On the left, a file list table shows various test files with columns for No., Filename, Set, Tag, Label#, Detect#, Probabil, and Uncertain. The file 'defect_0000093_0000' is highlighted. The central area shows a dark image with a white bounding box and a red crosshair. The right panel displays model training and evaluation statistics, including a table for 'Detect' results and a 'Confusion Matrix'.

No.	Class	Probabil	Uncertainty	Width	Height
1	Defect	0.92	0.25	8	19
2	Defect	0.95	0.16	13	9
3	Defect	0.95	0.14	12	15
4	Defect	0.55	0.99	4	2

Actual Class (0)	Labeled	Unlabeled	Avg. IOU
Labeled	22	0	0.69
Unlabeled	13	10	0
Sum	35	10	

Grafické uživatelské rozhraní SuaKIT v. 2.3

SuaKIT – softwarový nástroj k řešení úloh strojového vidění pomocí hlubokého učení

Developer



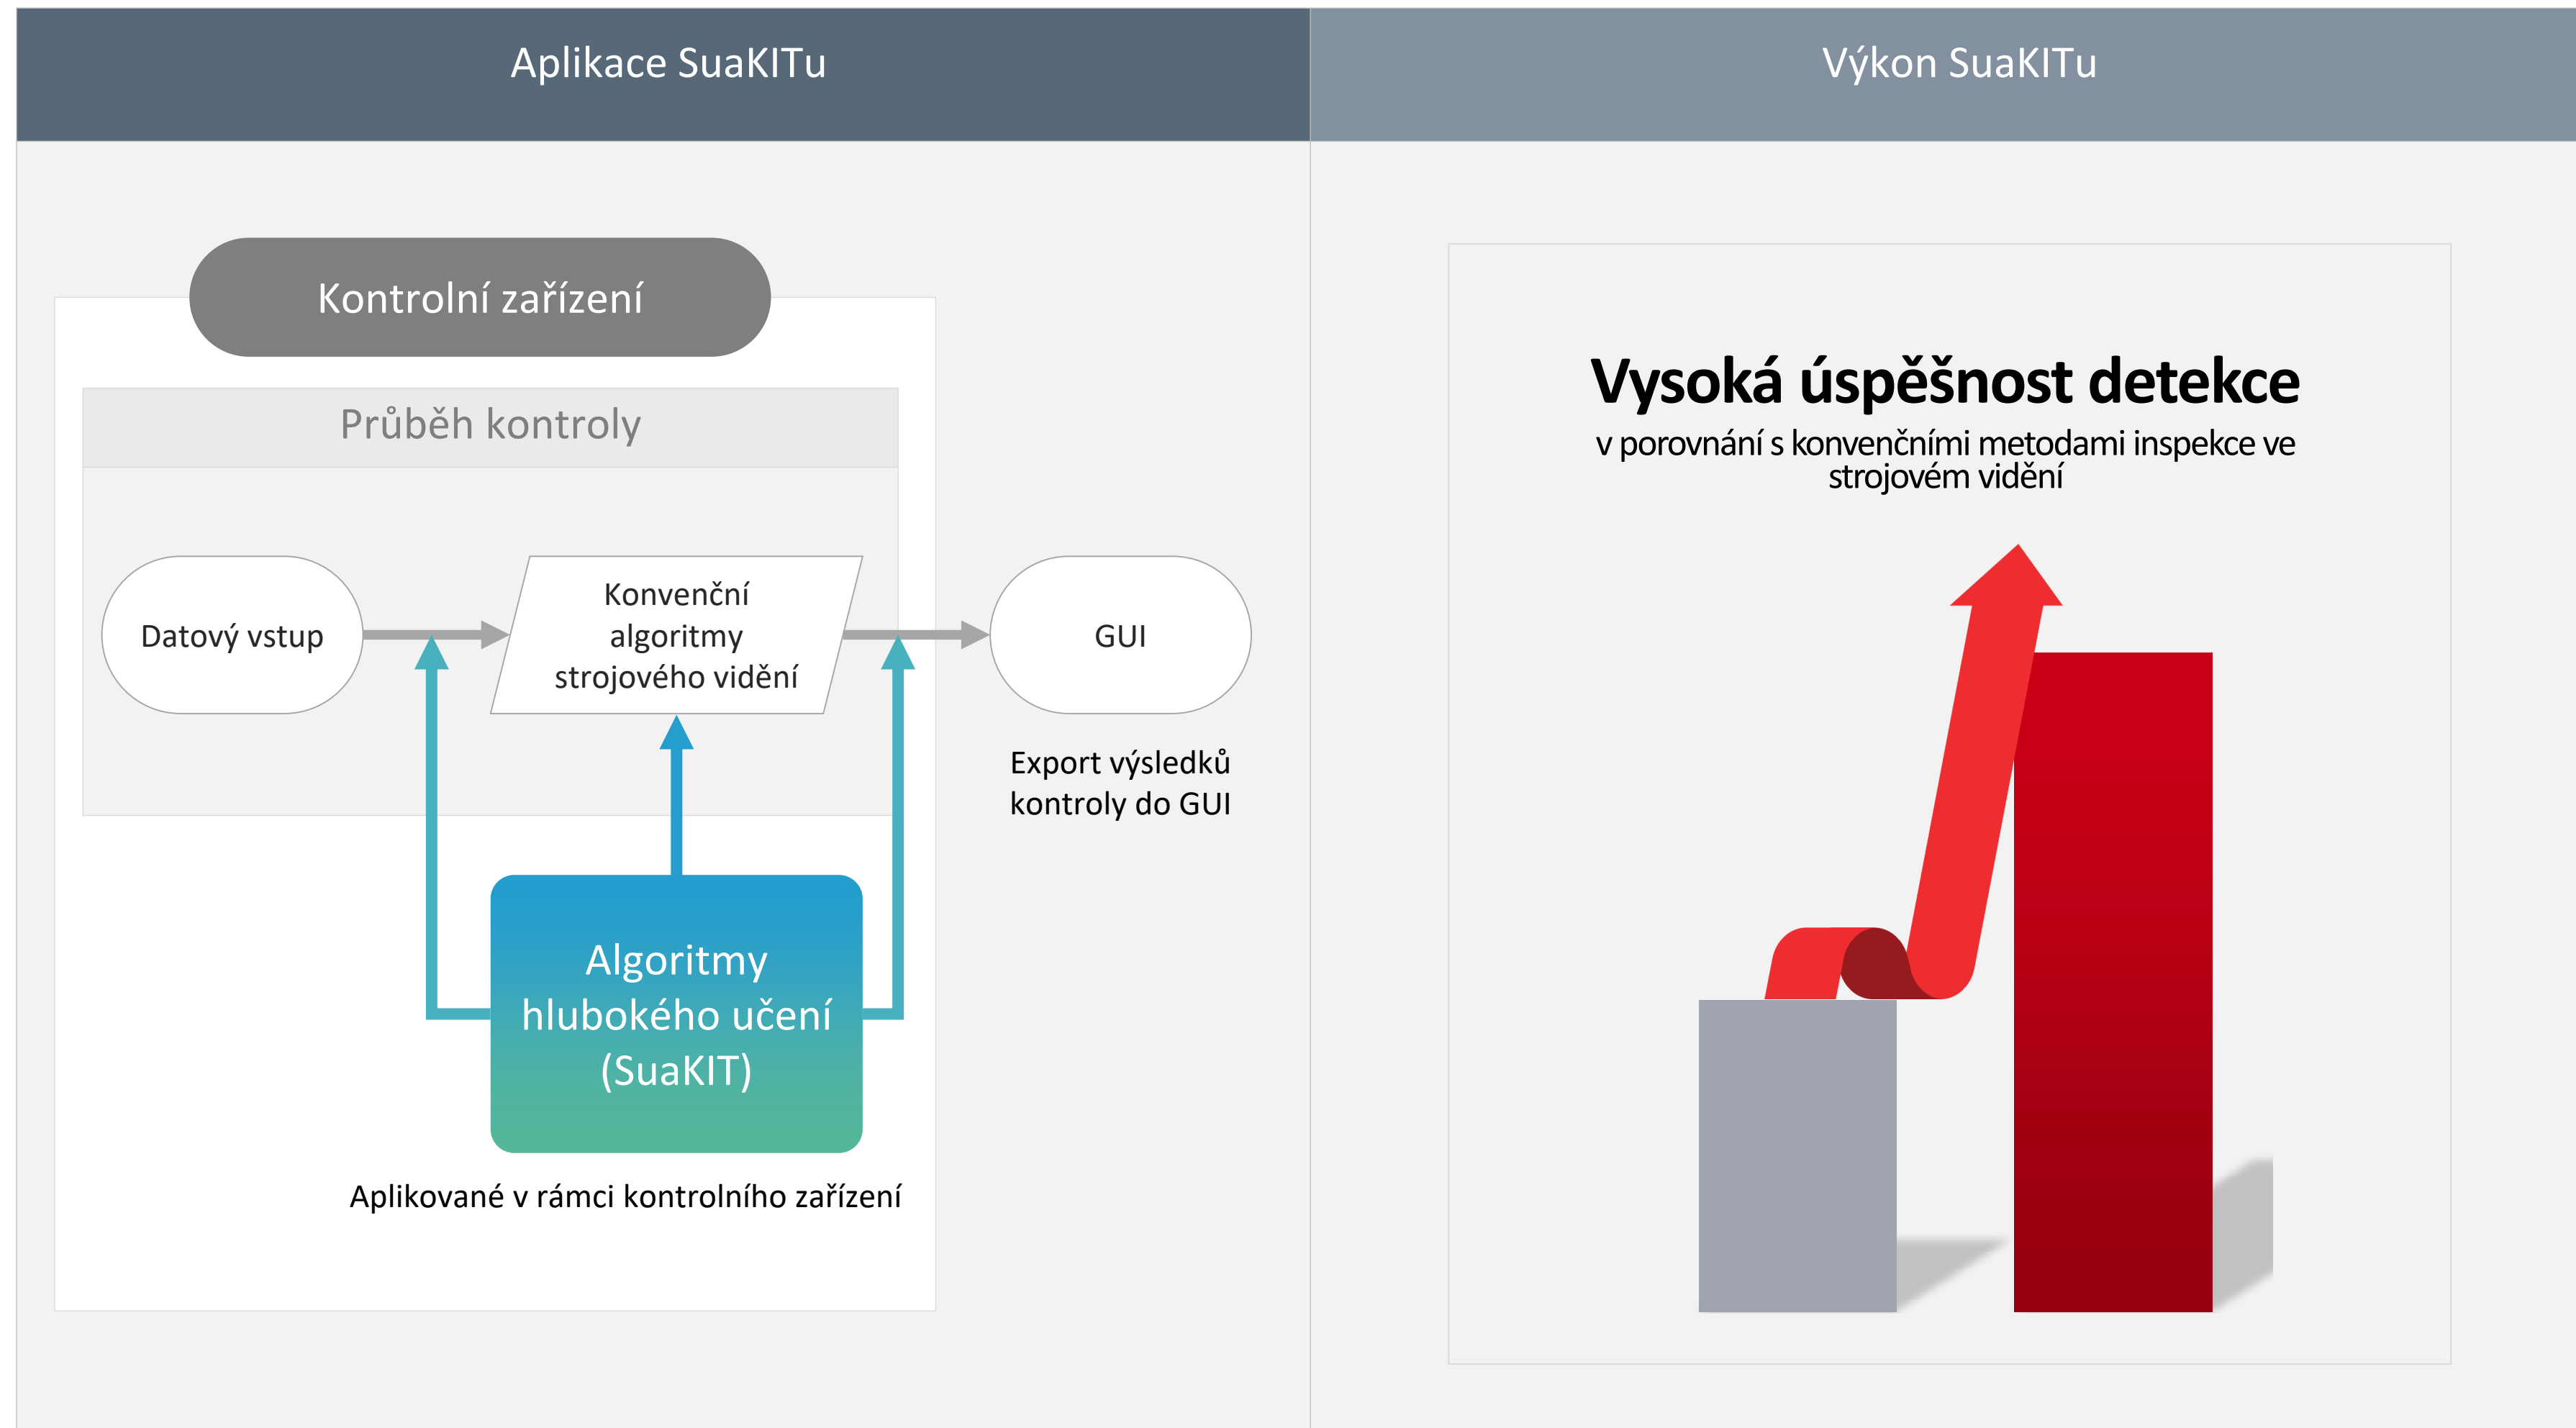
- Trénování a testování modelu v GUI
- Exportování vytvořeného modelu (C++, C#)

Runtime




- Aplikování vytvořeného modelu na skutečnou produkční linku
- Schopnost propojení s originálním inspekčním zařízením

SuaKIT – softwarový nástroj k řešení úloh strojového vidění pomocí hlubokého učení




Funkce SuaKITu




Segmentace

Detekuje a označí defektní oblasti



Klasifikace

Klasifikuje typy vad a normální / defektní obrázky



Detekce



Detekuje objekty v obrázku (jejich počet, třídu a polohu)

Funkce SuaKITu

Trénování

Testování

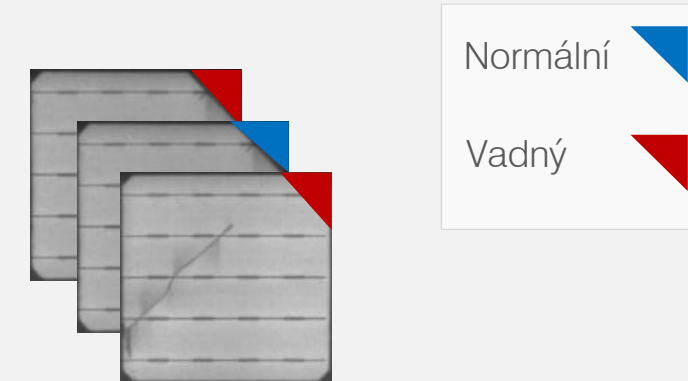
Segmentace




Označení defektních oblastí a natrénování modelu

Detekce defektních oblastí, které se co nejvíce shodují s označenými

Klasifikace



Normální + vadné obrázky



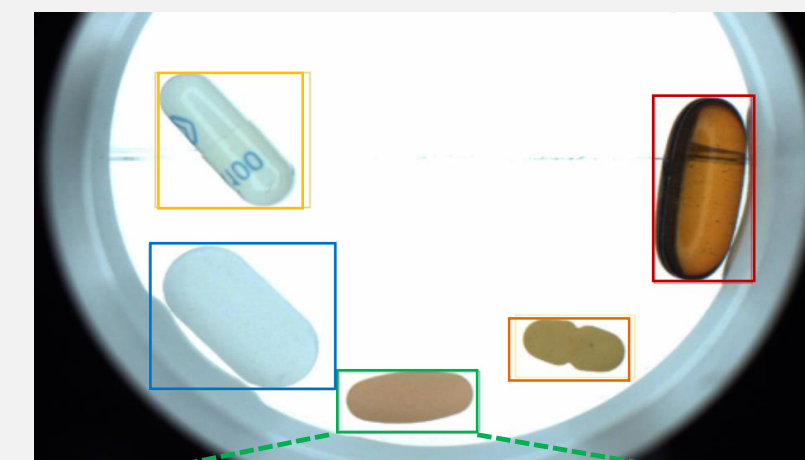
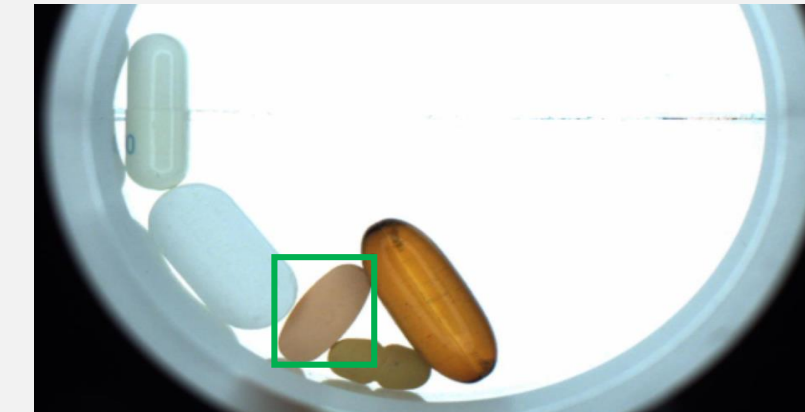
Normální


Vadné

Trénování po označení normálních a vadných obrázků

Roztřídění na normální a vadné na základě označení při trénování

Detekce



Třída	Počet	Souřadnice
	1	135, 312

Trénování po ohraničení a označení objektů

Detekuje typ objektů, lokalizace a jejich počet

Architektury hlubokého učení v SuaKITu

SuaKIT nabízí čtyři metody trénování modelu založené na různých konfiguracích obrázků



Analýza jediného obrázku

Trénování a detekce vlastností každého obrázku




Porovnávání obrázků

Učení a detekování rozdílů mezi dvěma obrázky



Analýza více obrázků

Trénování a detekce defektů na základě analýzy závislostí mezi různými obrázky

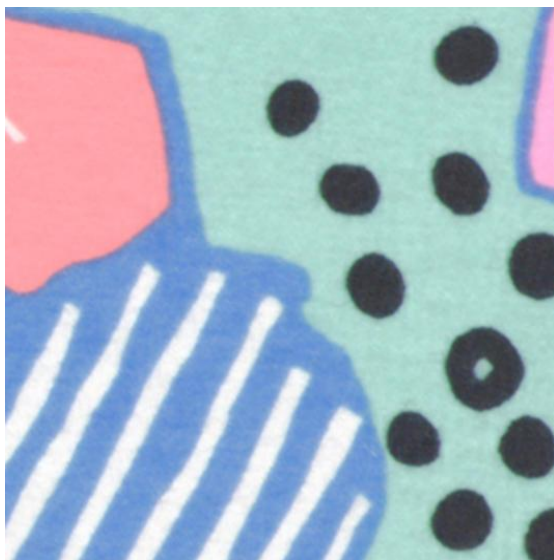
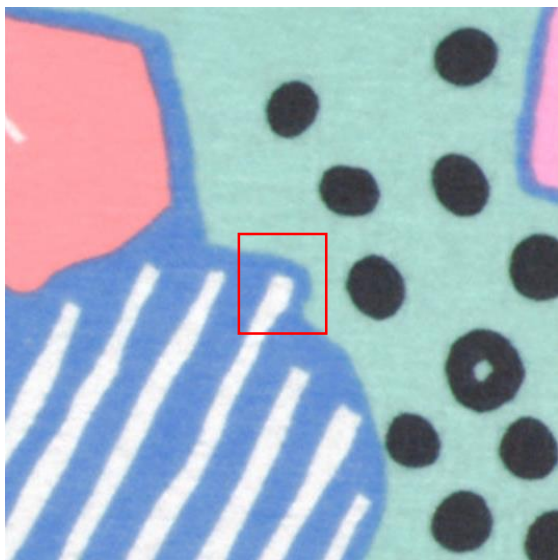
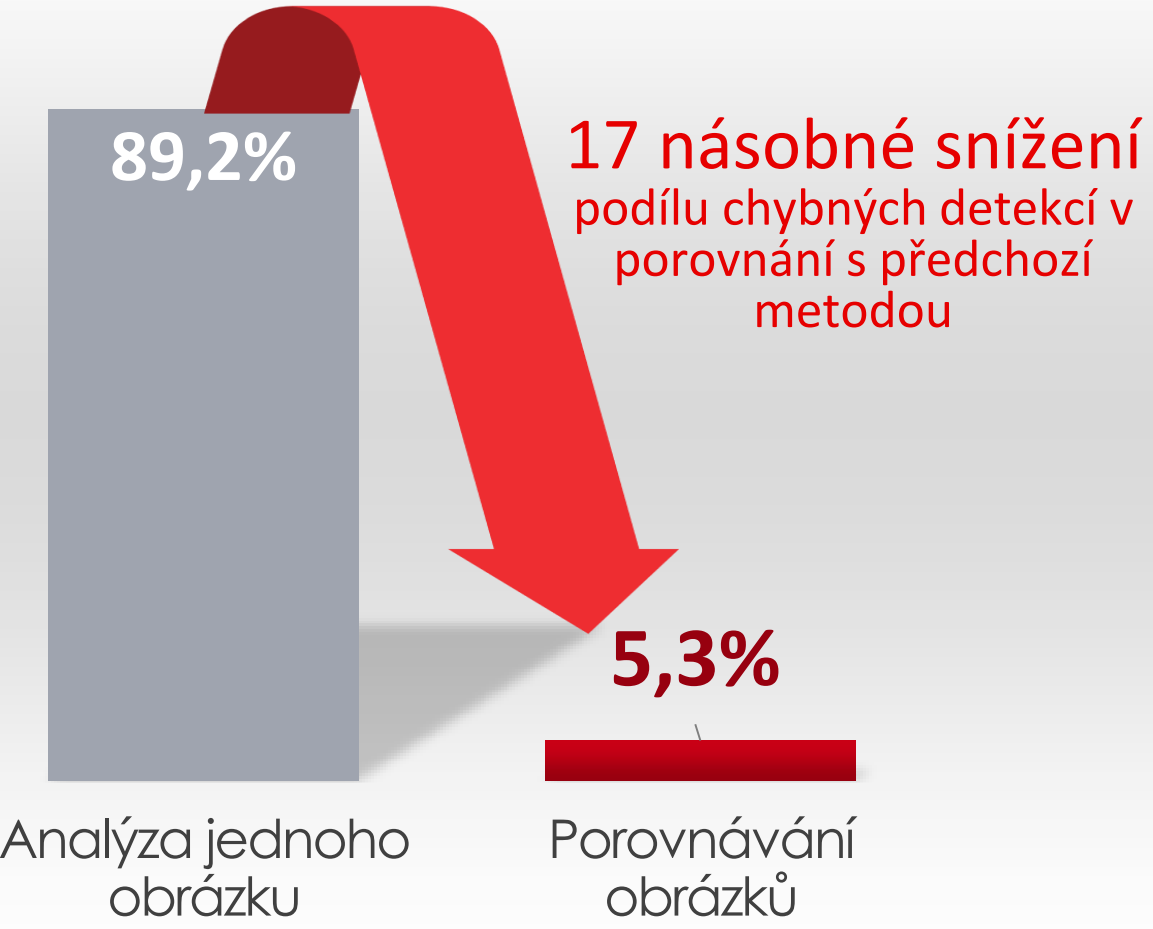


Trénování jediné skupiny

Detekuje defekty pouze na základě natrénování normálních obrázků (bez defektů)

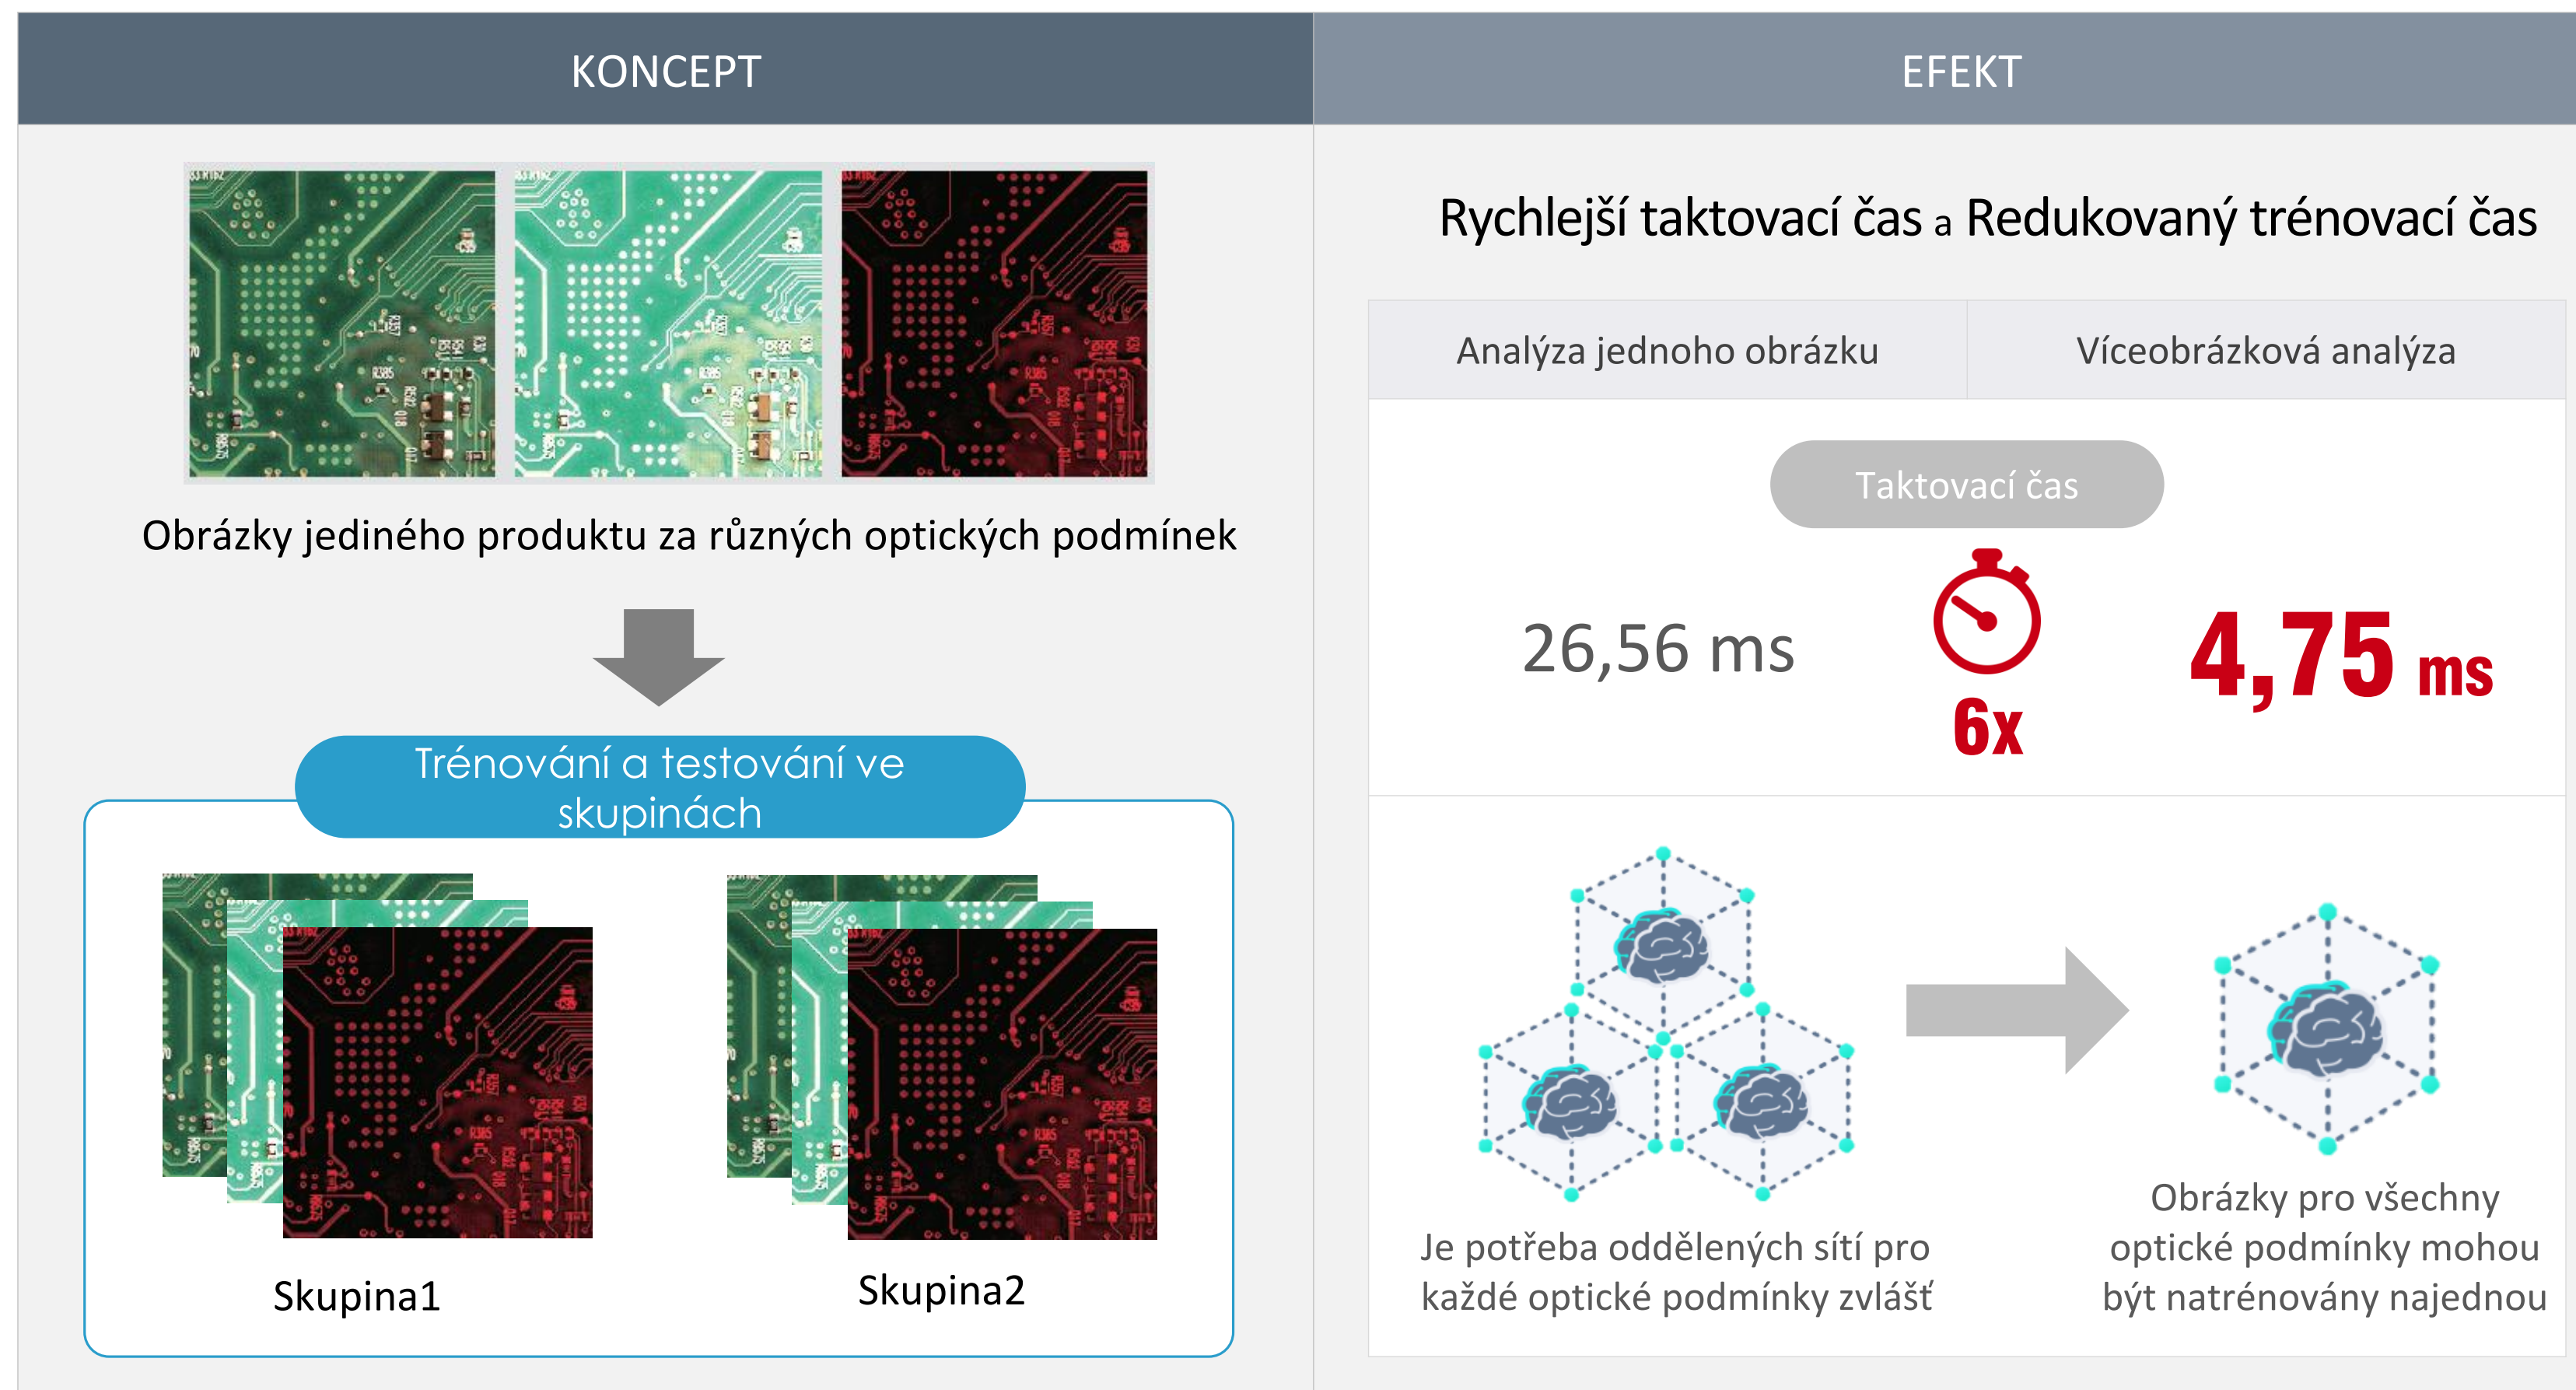
Trénovací metoda SuaKITu: Porovnávání obrázků

Natrénováním rozdílů mezi dvěma obrázky je možné detekovat defekty i na proměnlivém pozadí a přitom současně dosahovat vysoké spolehlivosti detekce

KONCEPT	EFEKT
<ul style="list-style-type: none"> • Obtížné nalezení vady při použití jediného obrázku • Obtížné rozlišení vady na složitém pozadí • Proměnlivost pozadí a optických podmínek <p style="text-align: center;">↓</p> <p style="text-align: center;">Trénování a testování v párech</p> <div style="display: flex; justify-content: space-around; align-items: center;">  +  </div> <p style="display: flex; justify-content: space-around;"> Referenční obrázek Cílový obrázek </p>	<p style="text-align: center;">Konkrétní příklad z kontroly textilií</p> <p style="text-align: center;">Podíl chybných detekcí</p> <div style="text-align: center;">  <p>89,2%</p> <p>17 násobné snížení podílu chybných detekcí v porovnání s předchozí metodou</p> <p>5,3%</p> <p>Analýza jednoho obrázku Porovnávání obrázků</p> </div> <p style="text-align: center;">Maximalizace přesnosti kontroly díky zaměření se na podstatné rozdíly mezi dvěma obrázky (defektní oblasti)</p>

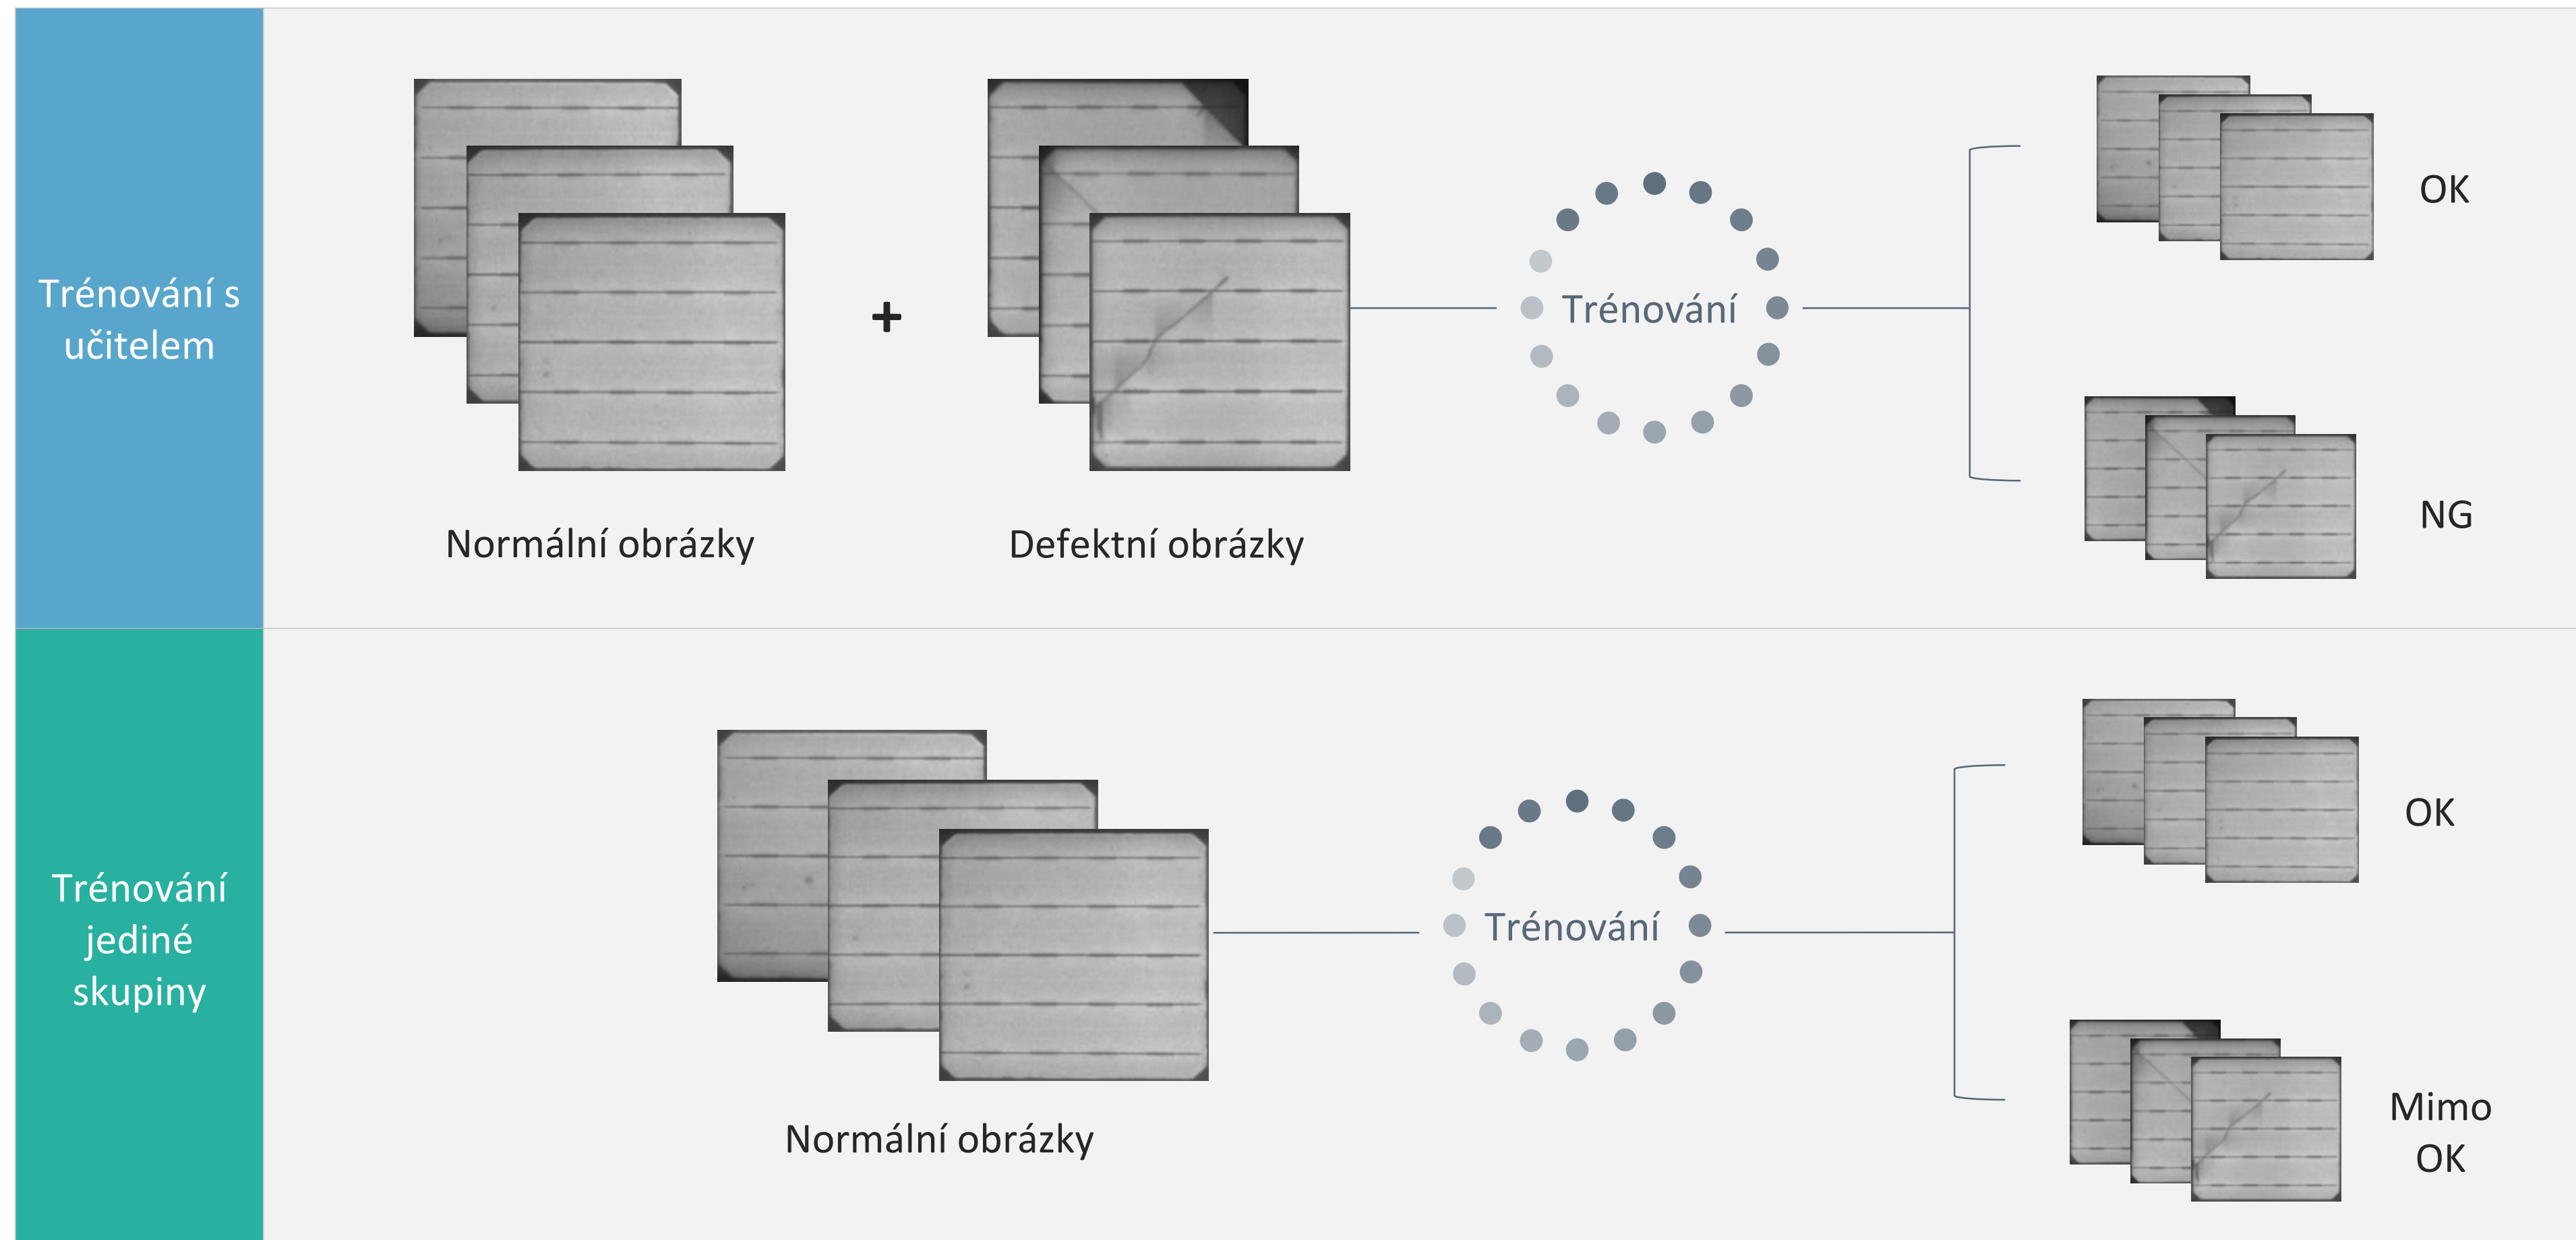
Trénovací metoda SuaKITu: Analýza více obrázků

Pokud je výrobek nasnímán několikrát za různých optických podmínek, pak tato funkce analyzuje závislosti mezi vzájemně svázanými obrázky, čímž se dosáhne výrazného zkrácení vyhodnocovacího času a může být navýšena kapacita kontrolní linky.



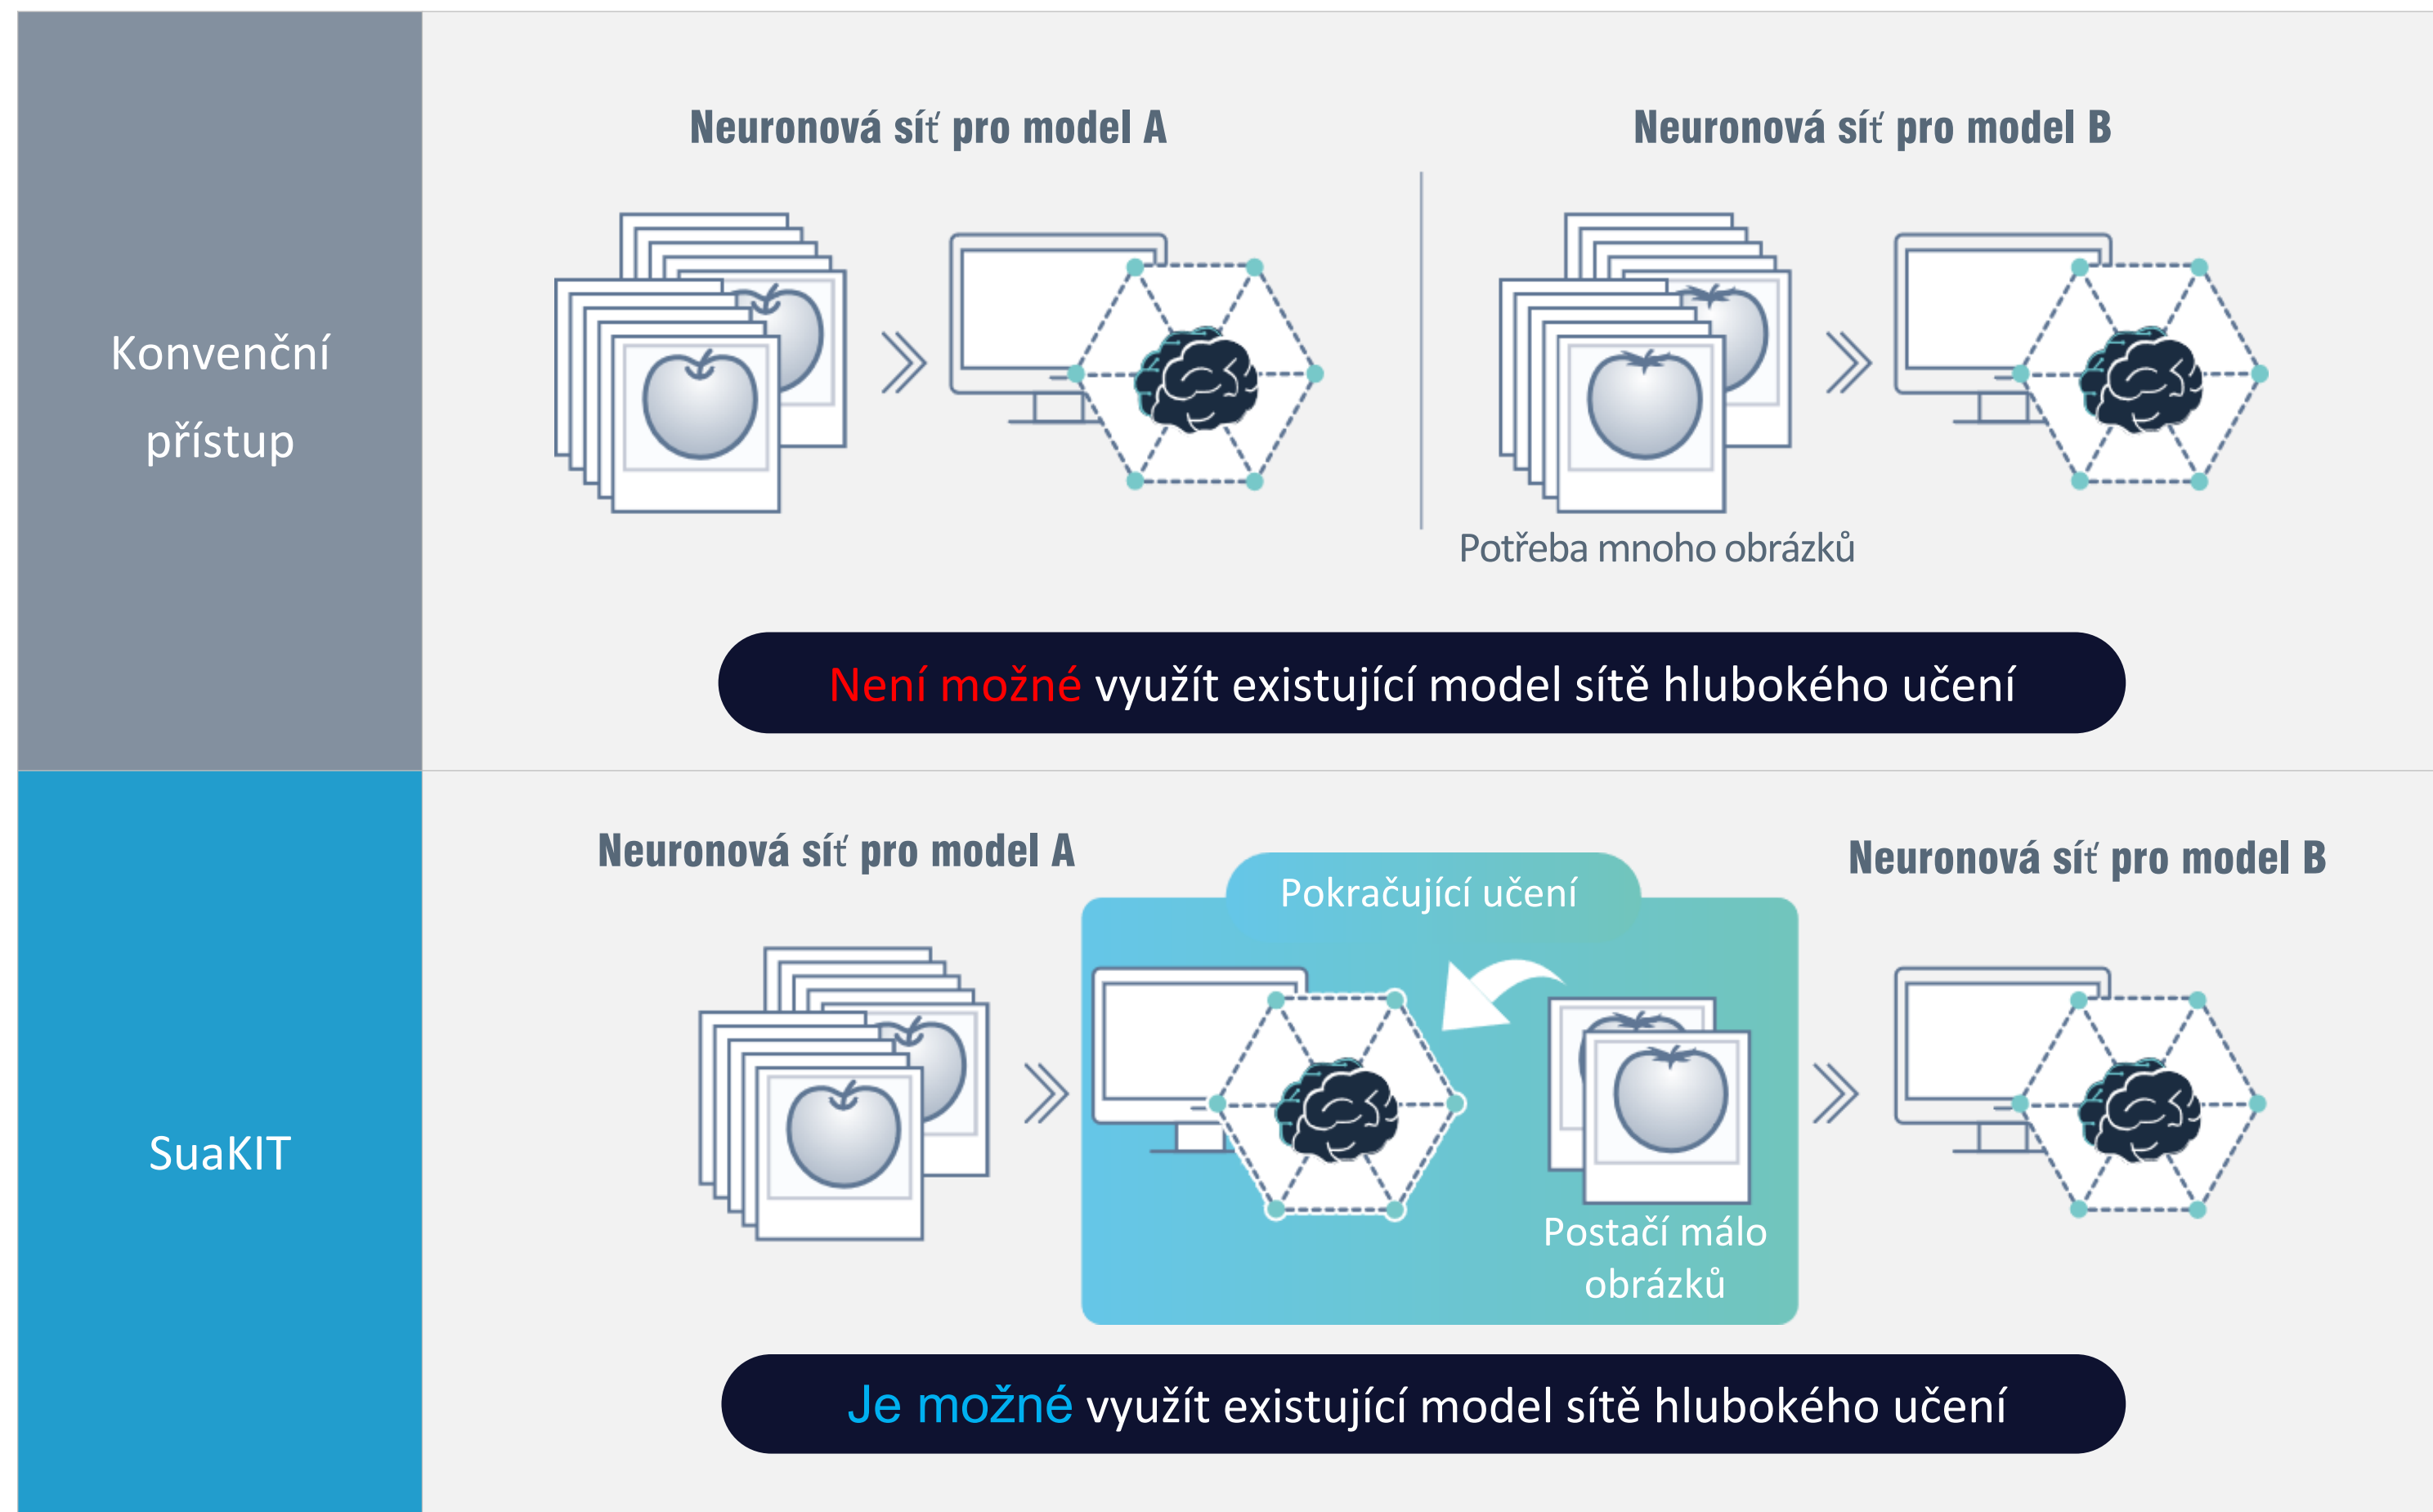
Trénovací metoda SuaKITu: Trénování jediné skupiny

Tato metoda trénování používá pouze jedinou skupinu. Je možné identifikovat vady natrénováním pouze normálních obrázků, tzn. že nutnost potřeby defektních obrázků je zde minimalizována.



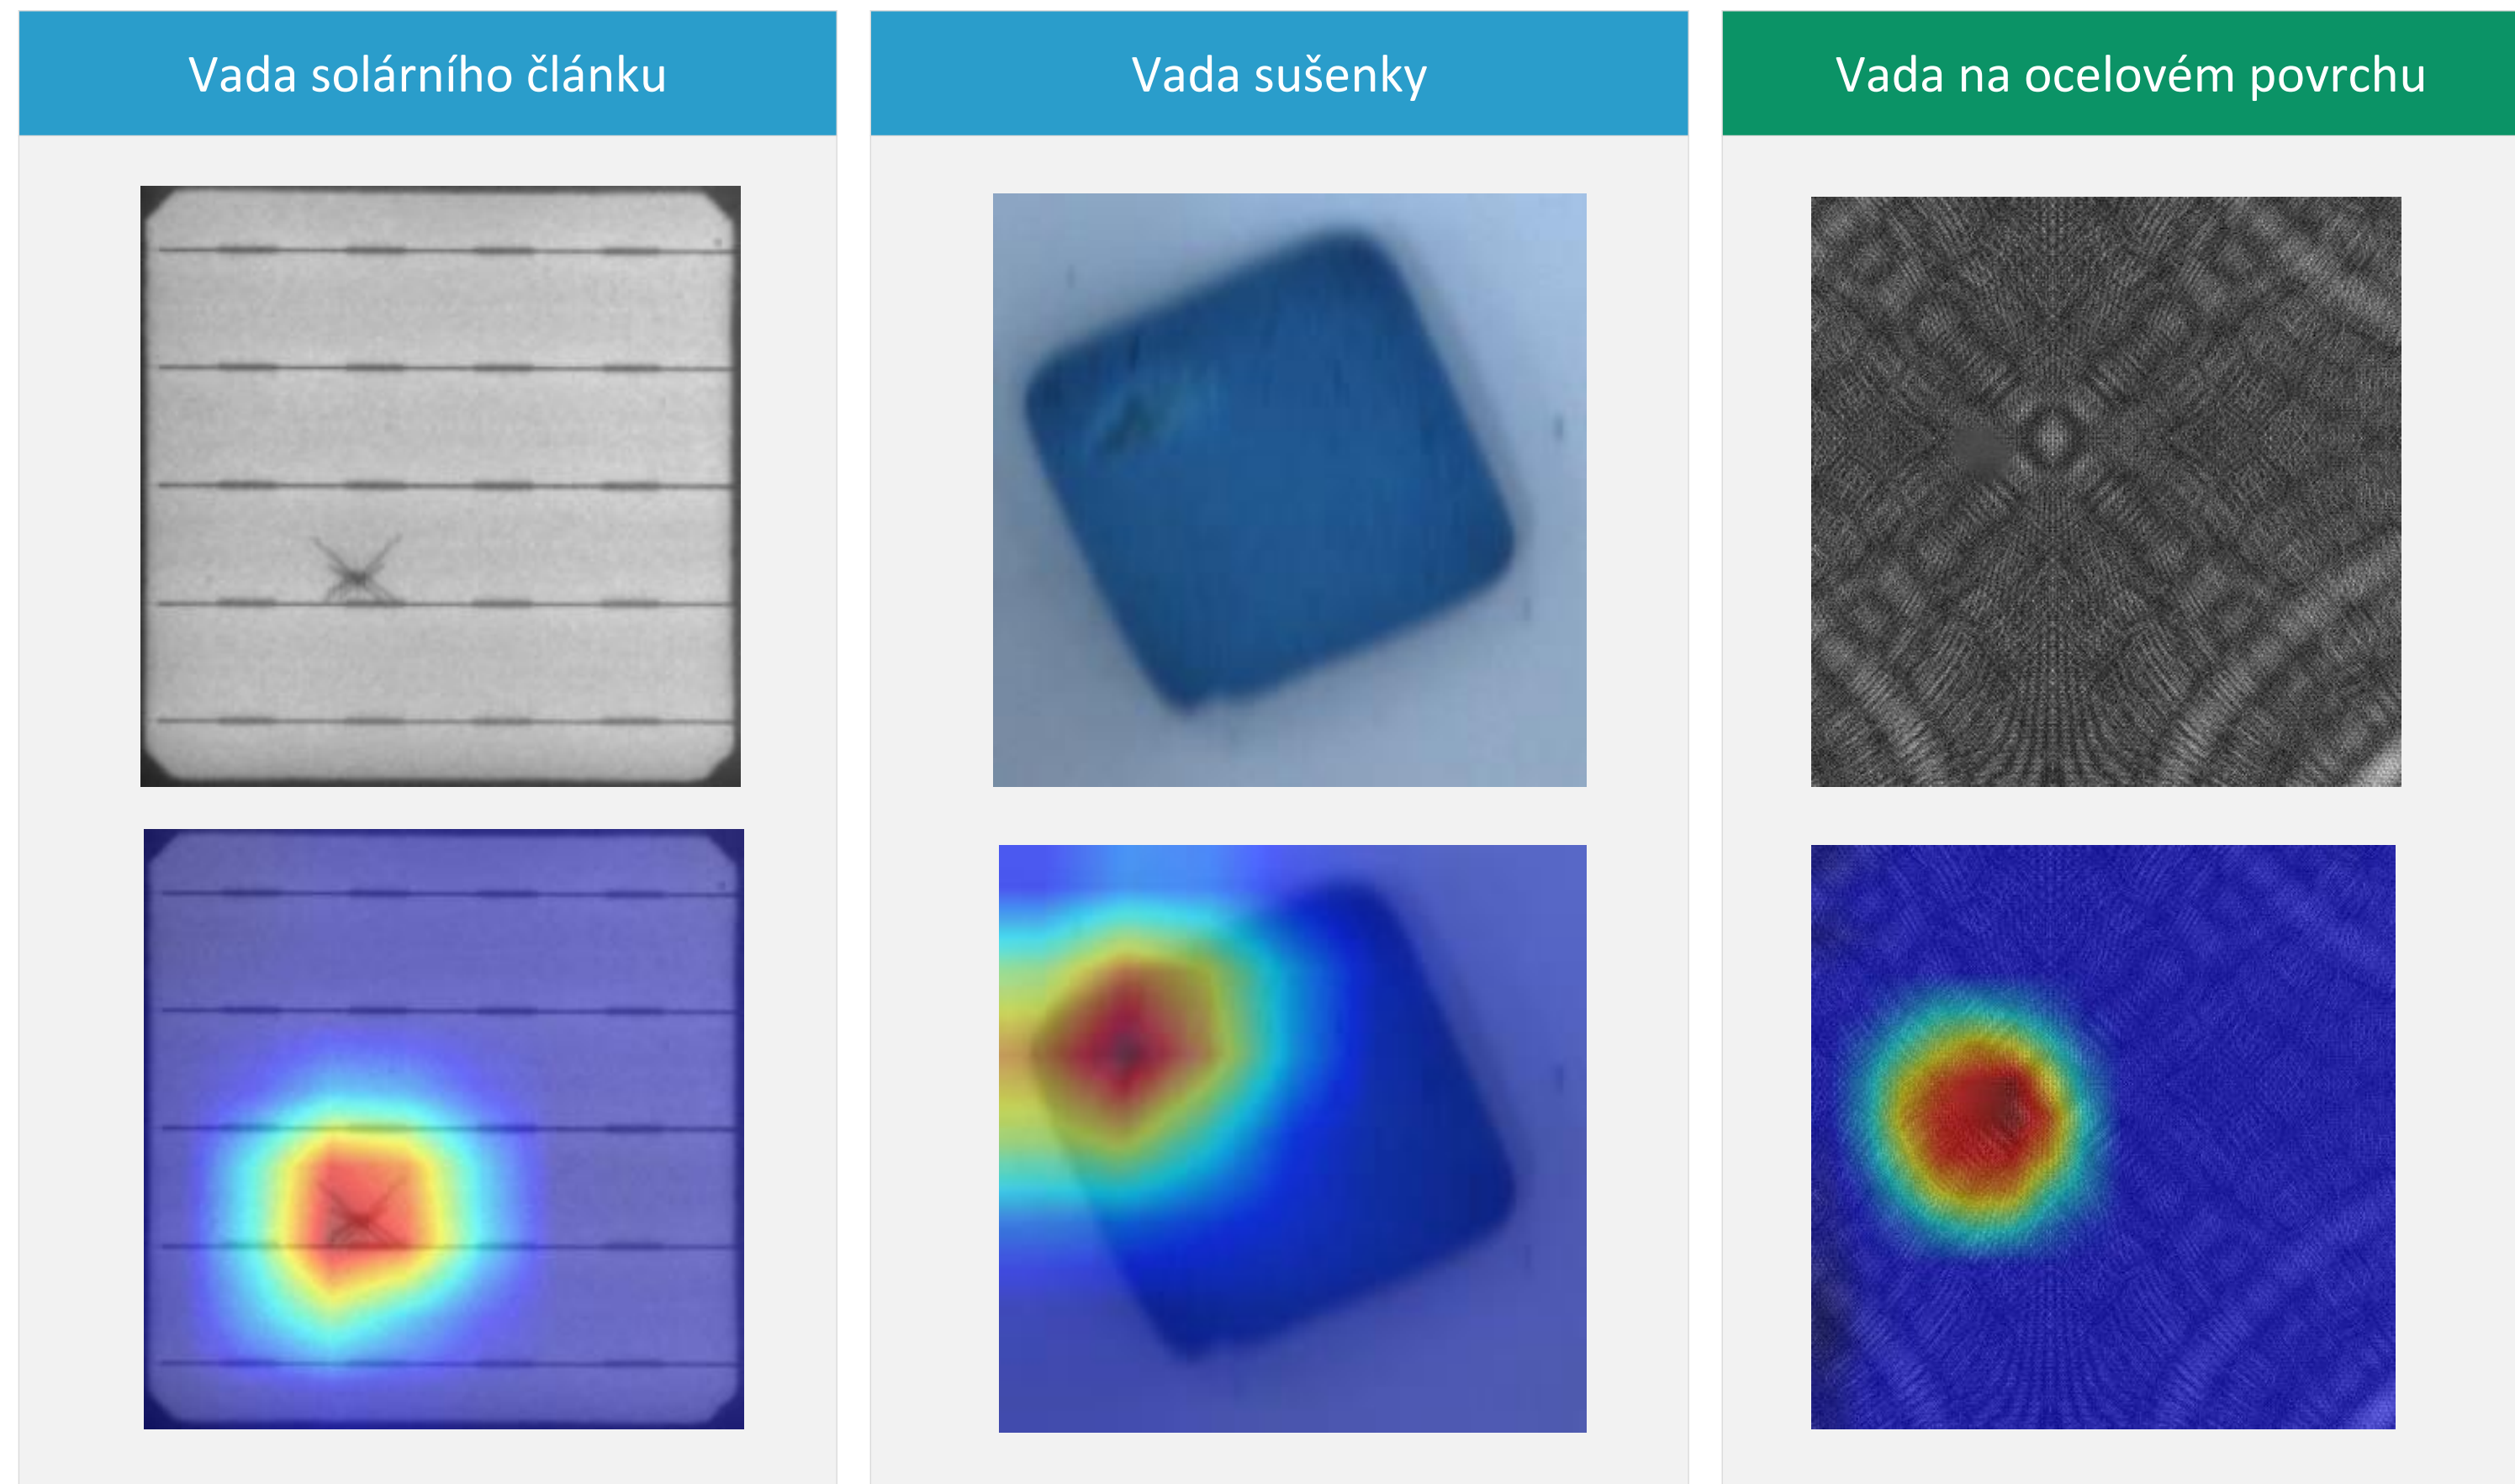
Pokračující učení (doučování)

Při analýze podobných produktů ve stejném odvětví průmyslu se může trénovací čas a potřebný počet obrázků zredukovat využitím existujících modelů



„Vizuální debugger“

Jedná se o metodu identifikace oblasti obrázku, na kterou se zaměřuje model při jeho klasifikaci. Tato funkce vizualizuje vnitřní část neuronové sítě, jež funguje navenek jako „černá skříňka“.



Díky nástroji „Detekce šumu v označení“ můžeme automaticky vytržít nejednoznačné obrázky a tím zvýšit přesnost při trénování modelu

Koncept detekce šumu v označení obrázků (Label Noise Detection - LND)



Šum v označení

Nízký
(jednoznačná "KOČKA")

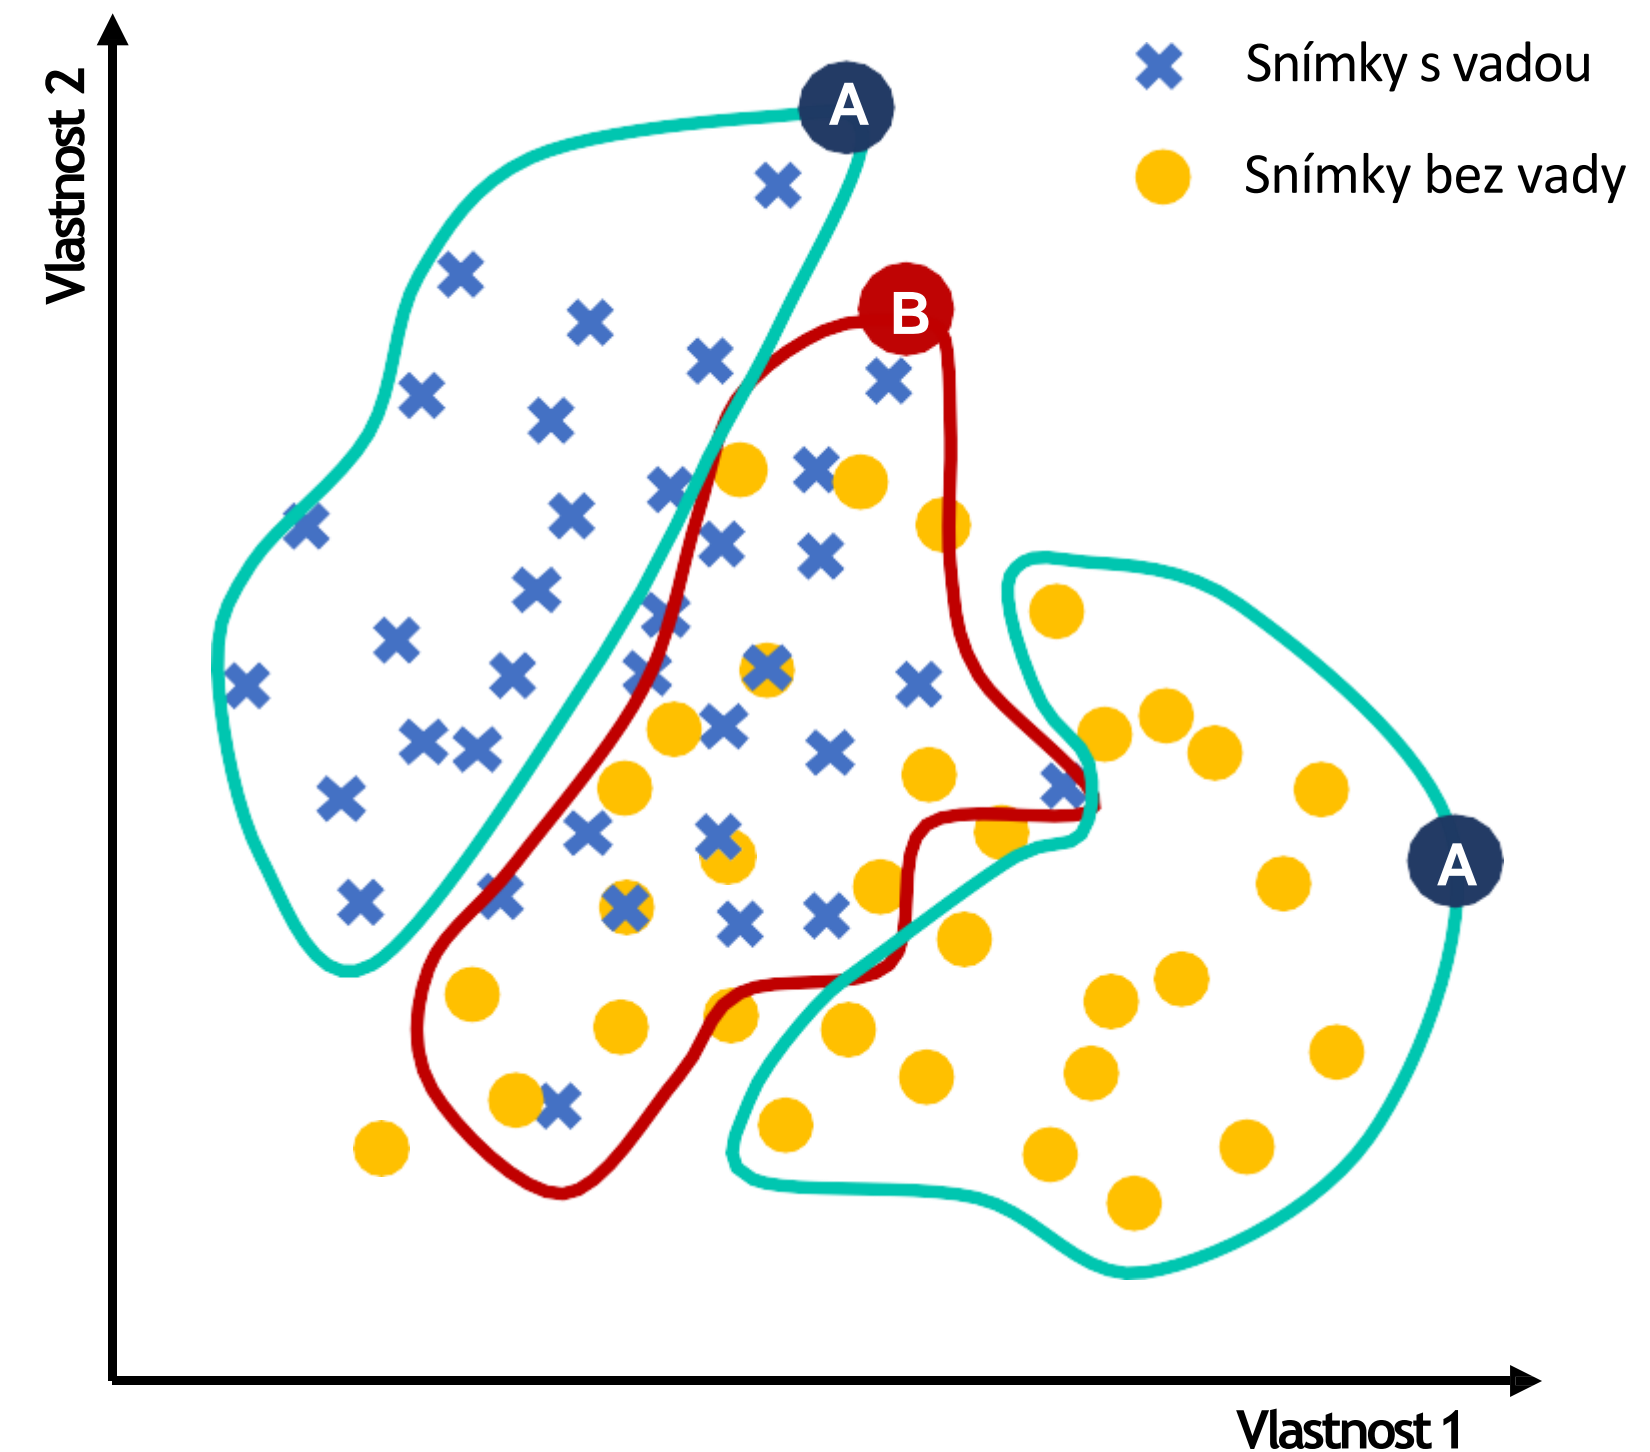


? **Vysoký**
(nejednoznačný "PES")



Nízký
(jednoznačný "PES")

- LND roztřídí "Nejednoznačné" snímky a znovu klasifikuje
- Umožní maximalizovat trénovací výkon **přidáním filtru "jednoznačných" snímků**



- Filtrací špatně označených/nejednoznačných snímků dojde k lepším trénovacím výsledkům
- Snížení času na kontrolu snímku / zvýšení přesnosti


Očekávaný efekt 1: Detekce vad nedetekovatelných klasickým strojovým viděním

[Příklad solárního panelu s detekcí vad]



Detekované pomocí hlubokého učení


Rozvětvené trhliny



Nepřipájené

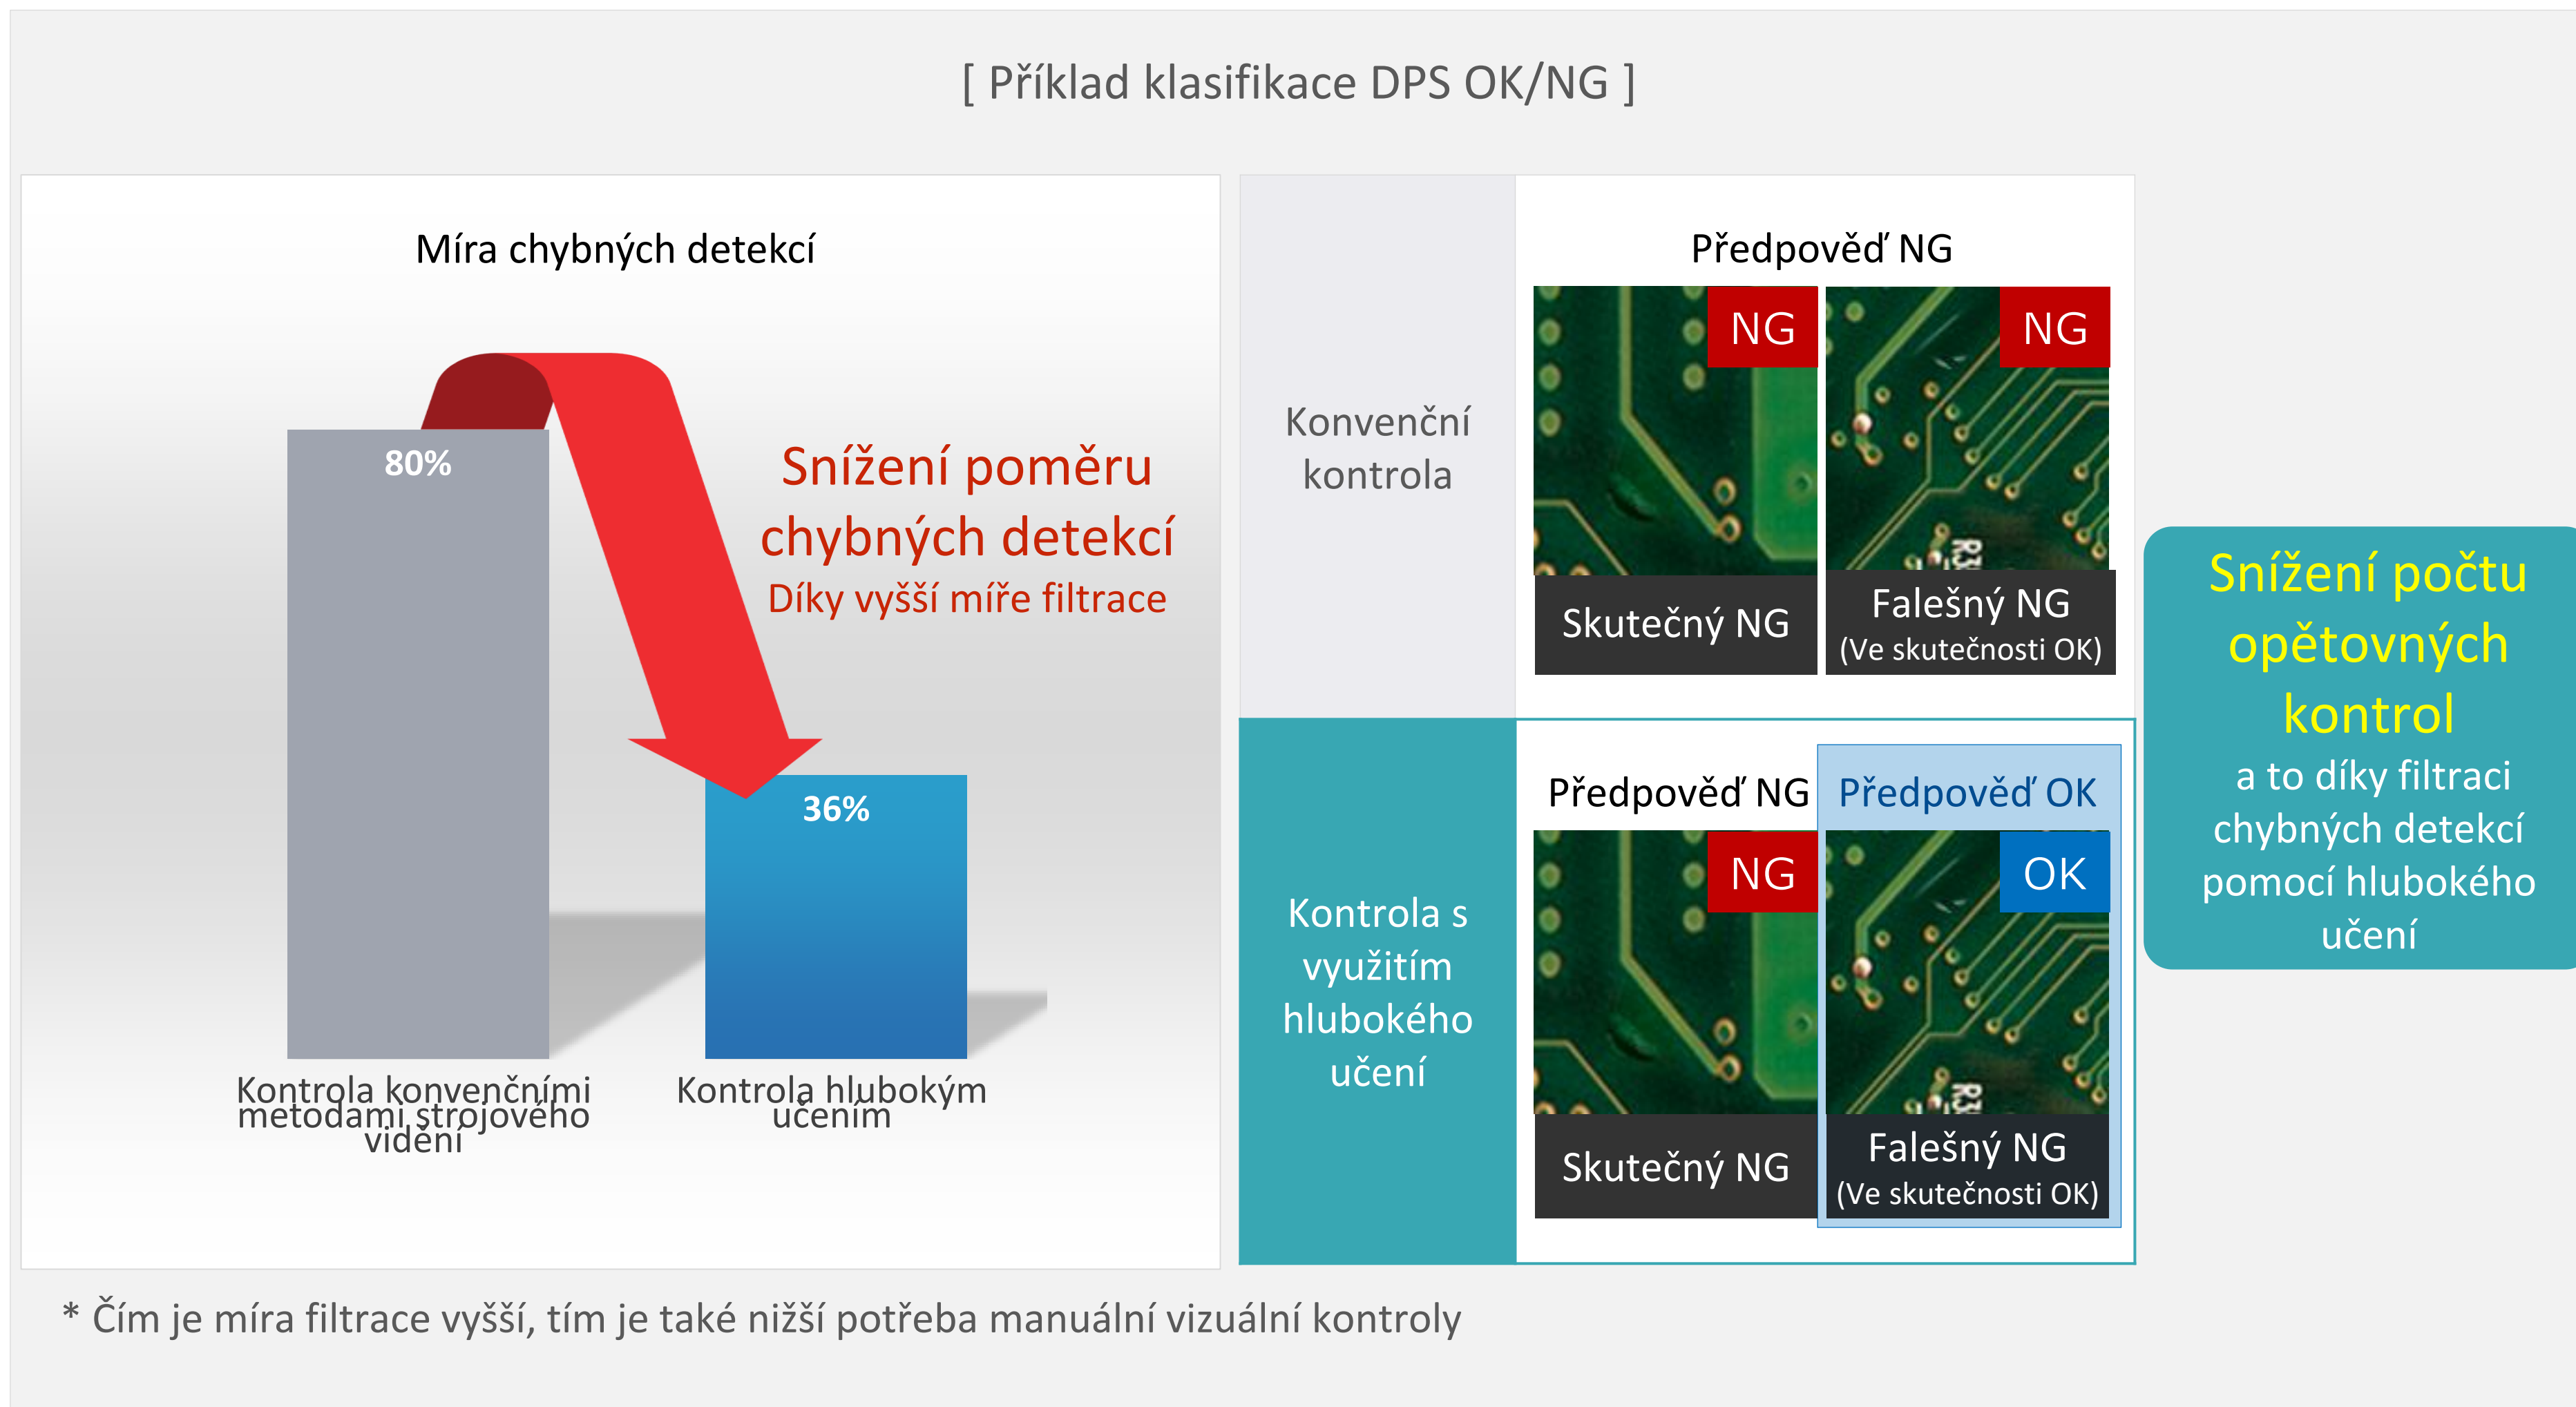


Lineární trhliny



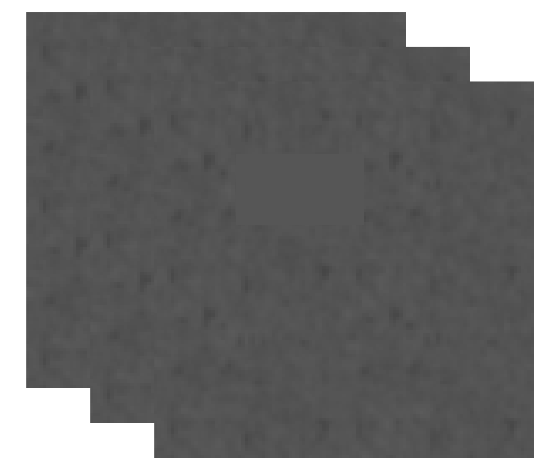
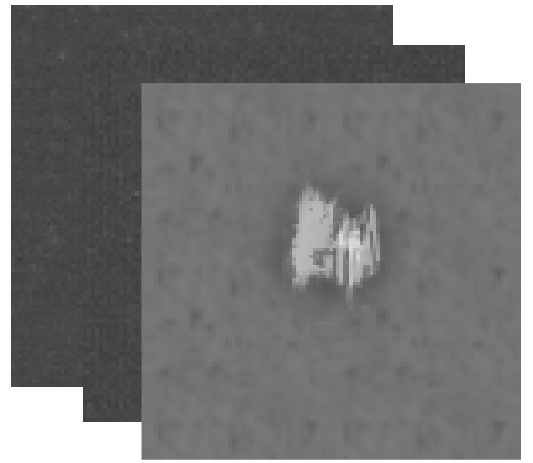
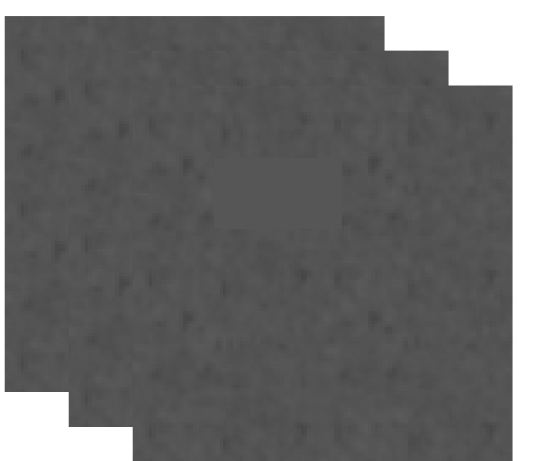
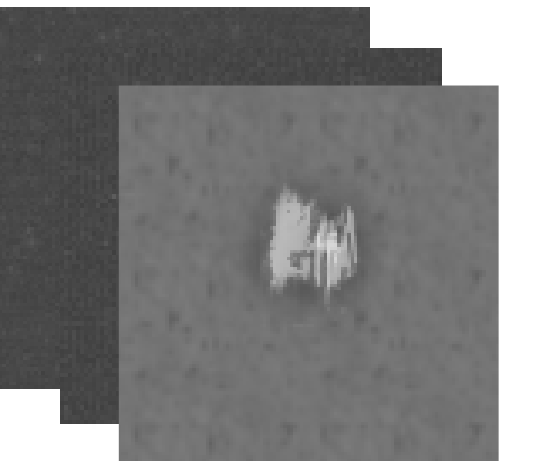
Očekávaný efekt 2: Filtrace chybných detekcí

[Příklad klasifikace DPS OK/NG]

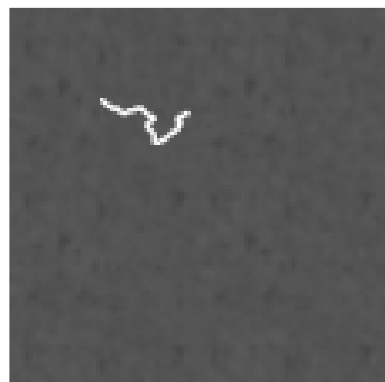

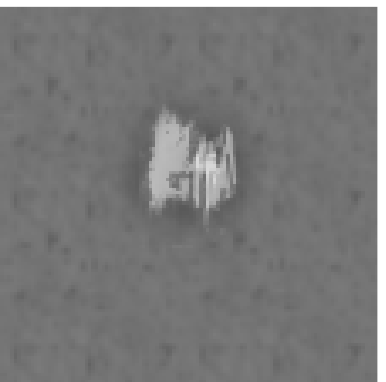
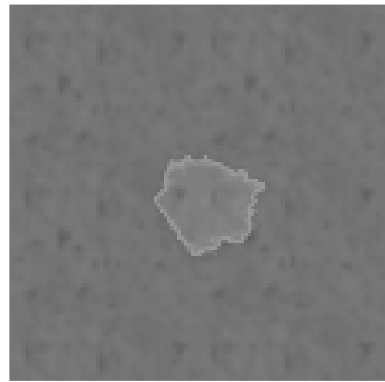
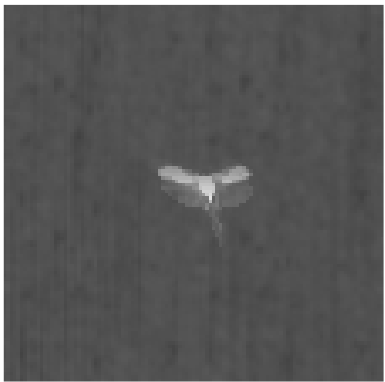
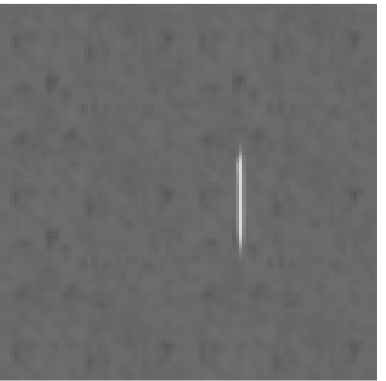
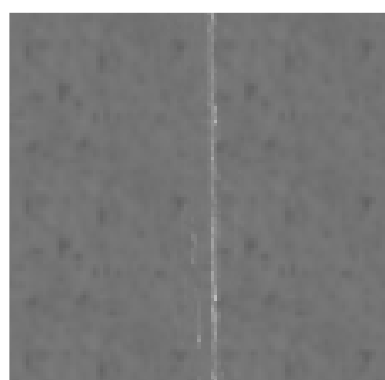
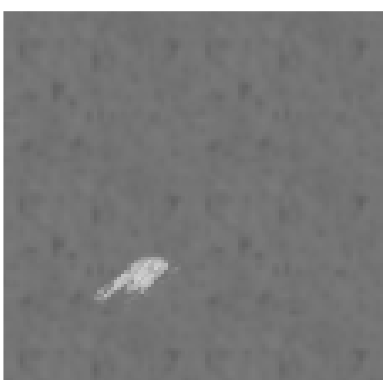
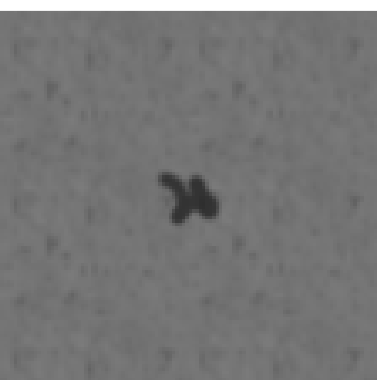


Očekávaný efekt 3: Klasifikace typů vad

[Příklad klasifikace vad na povrchu]

Konvenční kontrola	Je dostupná pouze klasifikace OK/NG	
	 OK	 NG
Kontrola s využitím hlubokého učení	Je dostupná klasifikace vad	
	 OK	 NG


Zlepšení procesu je dostupné prostřednictvím analýzy vad

 Prach	 Bílá čára	 Karbid
 Olej	 Hmyz	 Vertikální rýha
 M-linie	 Chyba nátěru	 Černá skvrna

Očekávaný efekt 4: Nahrazení konvenčních algoritmů strojového vidění

[Příklad kontroly cizích látek v nápoji]

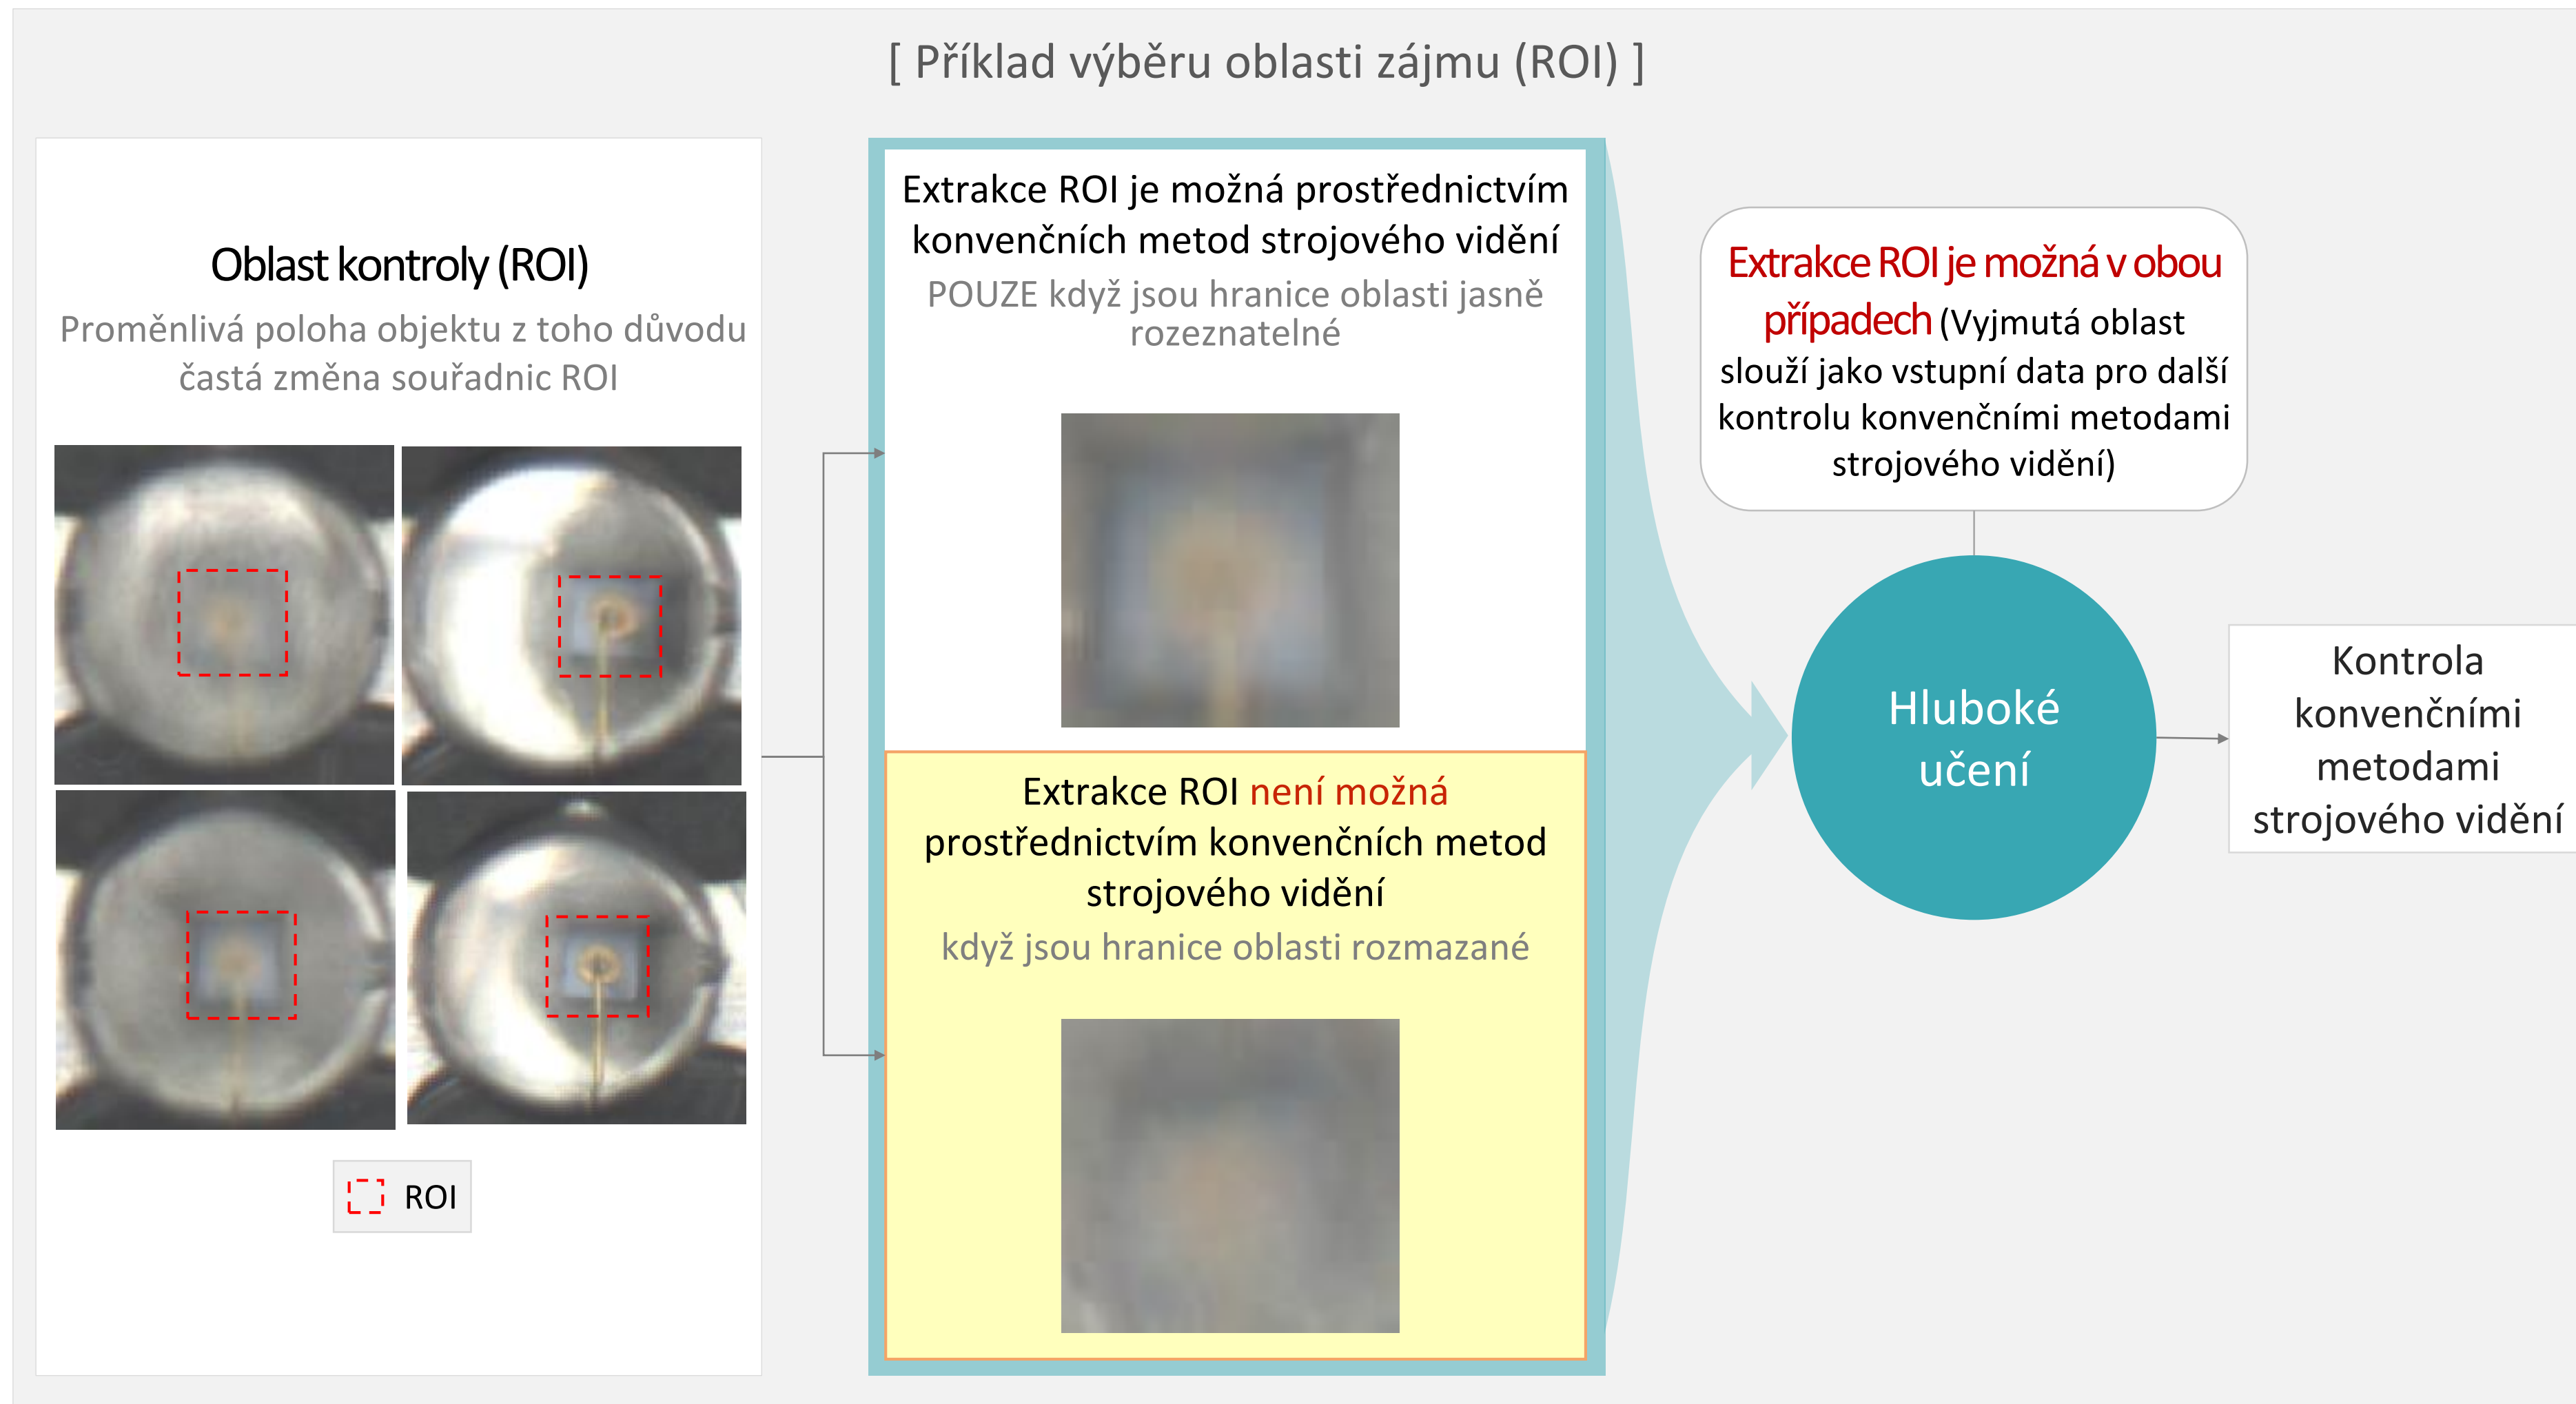
Míra detekce cizích látek



Zvýšená míra detekce cizích látek prostřednictvím kontroly hlubokým učením



Očekávaný efekt 5: Nastavení ROI pomocí hlubokého učení





=



- **Systemy strojového vidění na klíč**
(také s využitím metod hlubokého učení)
- **Aplikace metod hlubokého učení do stávajících kontrolních linek**
(a tím zvýšení jejich výkonu a přesnosti)
- **Komplexní studie proveditelnosti systémů strojového vidění**
(včetně testování modelů hlubokého učení na reálných datech)

***Děkuji za pozornost
a těším se na případnou spolupráci***

**Miroslav Meca, ATEsystem s.r.o.
miroslav.meca@atesystem.cz
mobile: +420 739 011 258**

atesystem 
FOCUSED ON DETAIL