



Učící se klasifikátory obrazu v průmyslu



FCC průmyslové systémy je technicko – obchodní společností, působící v oblasti průmyslové automatizace.

Tvoří ji dvě základní divize:

Divize průmyslových systémů



PRŮMYSLOVÉ
POČÍTAČE
A KOMUNIKACE
PRŮMYSLOVÉ
SYSTÉMY

Divize strojového vidění a robotiky



STROJOVÉ
VIDĚNÍ A
ROBOTIKA
PRŮMYSLOVÉ
SYSTÉMY




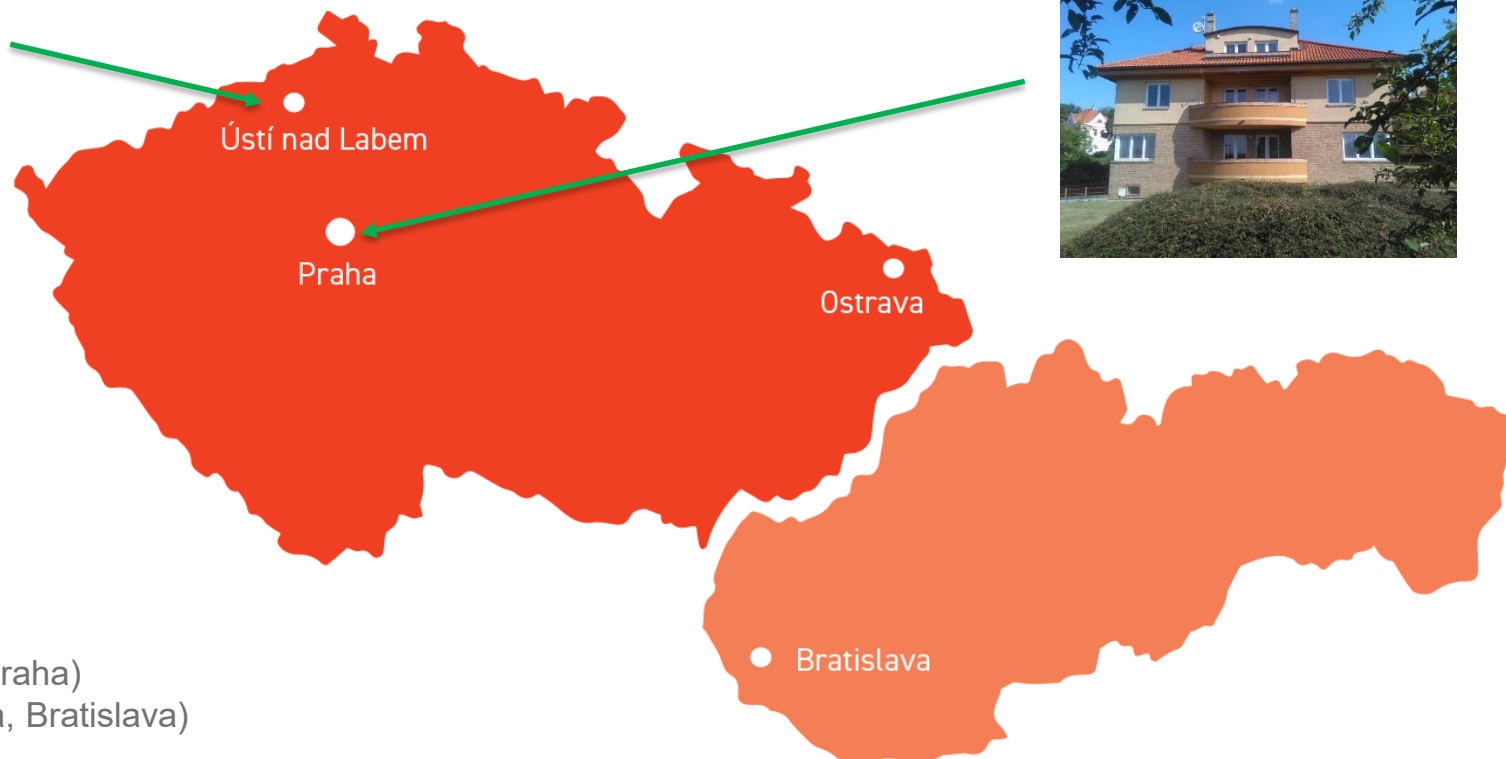


Zastupujeme významné výrobce v oblasti průmyslové automatizace a telekomunikační techniky. Od senzorových systémů přes průmyslové sběrnice a průmyslové komunikace po průmyslové výpočetní, řídicí a dispečerské systémy na bázi specializovaných PC.



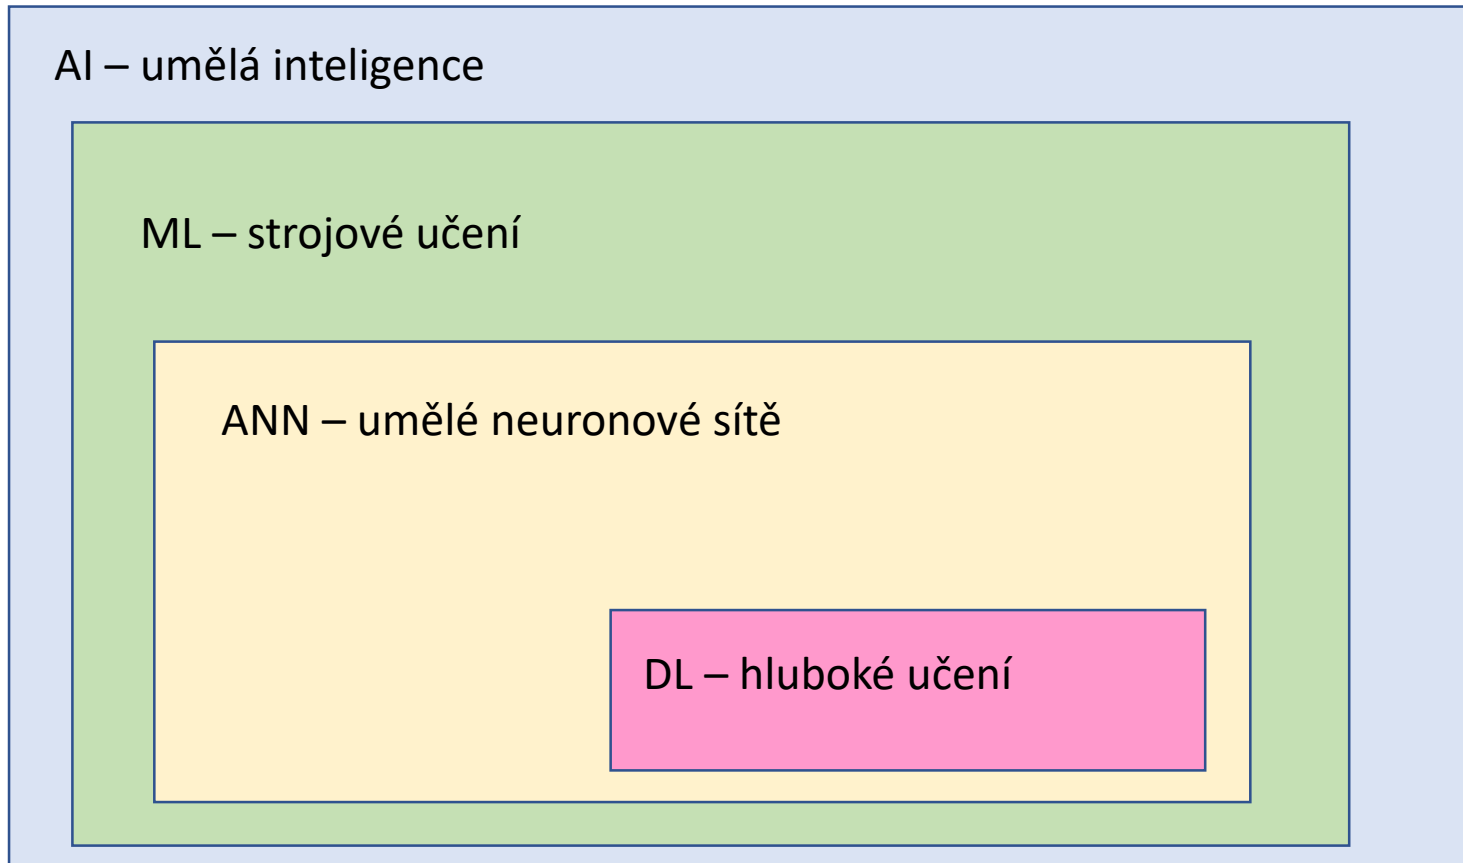
Navrhujeme, stavíme a dodáváme systémy využívané v oblasti výrobní automatizace a kontroly kvality. Aplikujeme při tom poznatky moderní robotiky a strojového vidění. Disponujeme vlastním vývojovým konstrukčním a výrobním zázemím včetně vývoje softwaru.





FCC průmyslové systémy s.r.o.

- Historie: 23 let
- 2 kanceláře (Ústí nad Labem, Praha)
- 2 obchodní zastoupení (Ostrava, Bratislava)
- 29 zaměstnanců



Nejčastější aplikace

rozpoznávání řeči
strojový překlad
dolování dat
predikce trendů

Průmyslová výroba ?

Klasifikátory objektů v obraze

Klasifikátor provádí roztrídění objektů do tříd podle vybraných příznaků – atributů
Atributy jsou pro účely třídění popsány (kvantifikovány) deskriptory

podle metod klasifikace

- symbolické
- subsymbolické
- statistické
- paměťové

podle charakteru učení

- dávkové
- inkrementální
- inkrementální se
zapomínáním

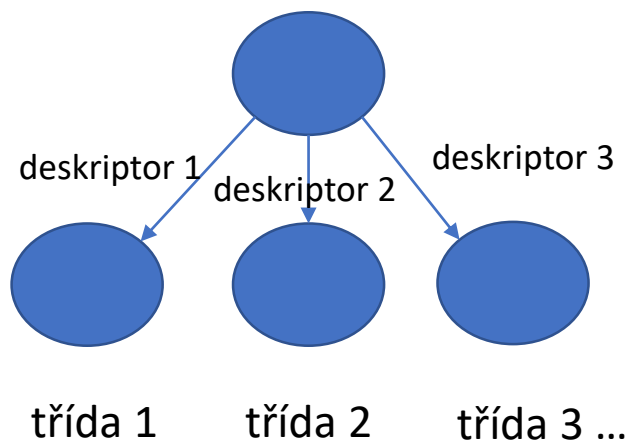
podle způsobu učení

- s učitelem
- bez učitele
(klastrování)

Symbolická metoda klasifikace – obvyklé řešení

Přímé prohledávání prostoru

typická pro současná řešení



nejistotu výsledku lze stanovit normální procedurou analýzy nejistot

Result Table: connector1_front

SoftSensor	Result	Output Value
reset_outputs	PASS	
vertical_position	PASS	Line Offset = 46.19%
vertical_pos_2	PASS	Line Offset = 62.38%
horizontal_pos_1	PASS	Line Offset = 26.50%
cont_dolni_1	PASS	Line Offset = 16.00 Pixels
cont_dolni_2	PASS	Line Offset = 19.00 Pixels
cont_dolni_3	PASS	Line Offset = 19.00 Pixels
cont_dolni_4	PASS	Line Offset = 25.08 Pixels

PWF: reset_outputs [connector1_front]

Percent: 0 to 100
History Sweep: 0 to 100


Fail Count: 0, Fail %: 0, Warn Count: 0, Warn %: 0, Pass Count: 30, Pass %: 100.0

Aproximace klasifikační funkce

je možné řešit libovolně složitý problém bez jeho podrobné znalosti, ale nedá se určit výhodnost řešení.

Navržené řešení algoritmu není konzistentní (tzn. pro jednu trénovací množinu dává různá řešení při opakovaných spuštěních)

jednou z možných metod je neuronová síť



Počet klasifikačních tříd je vysoký

počet deskriptorů je vysoký, algoritmus (program) by byl složitý na vývoj i odladění

Počítá se s tím, že se klasifikační třídy budou časem měnit

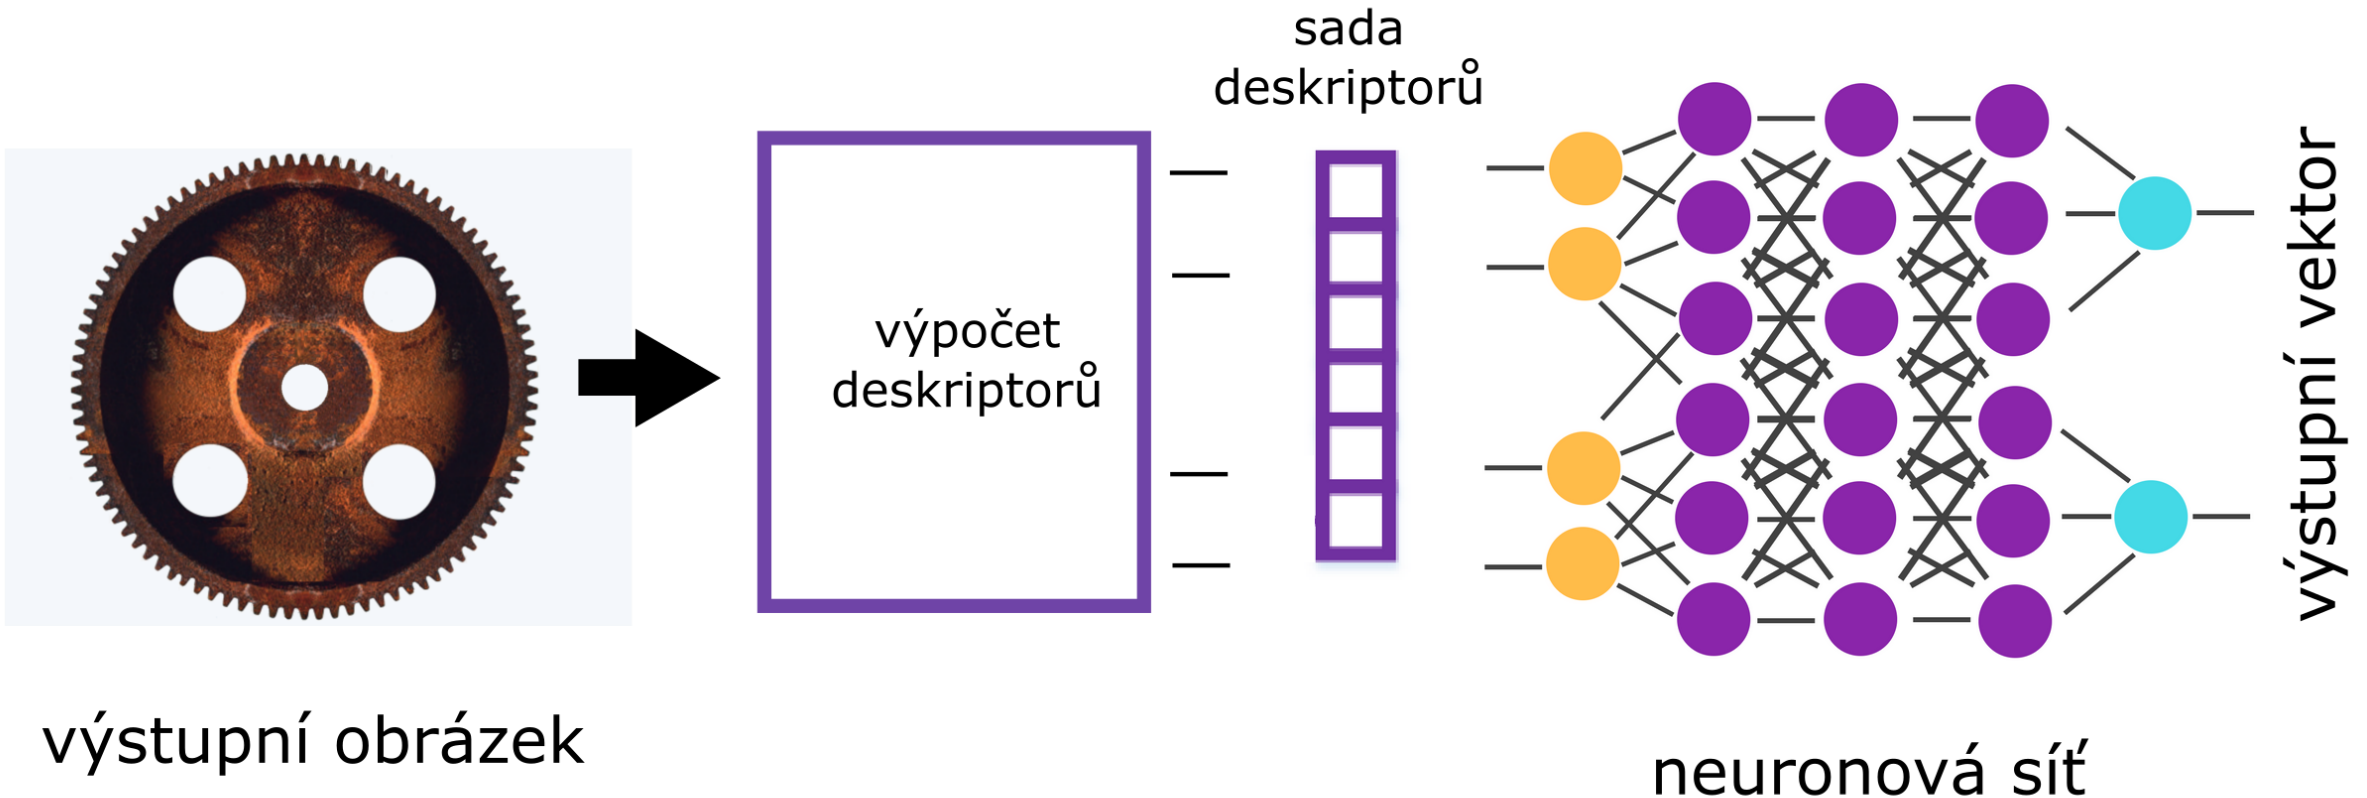
je potřeba často upravovat sestavu deskriptorů, což může být spojeno s nákladnými úpravami programu


Nejsme schopni ručně nalézt použitelné deskriptory (nízká separabilita /vysoká entropie)

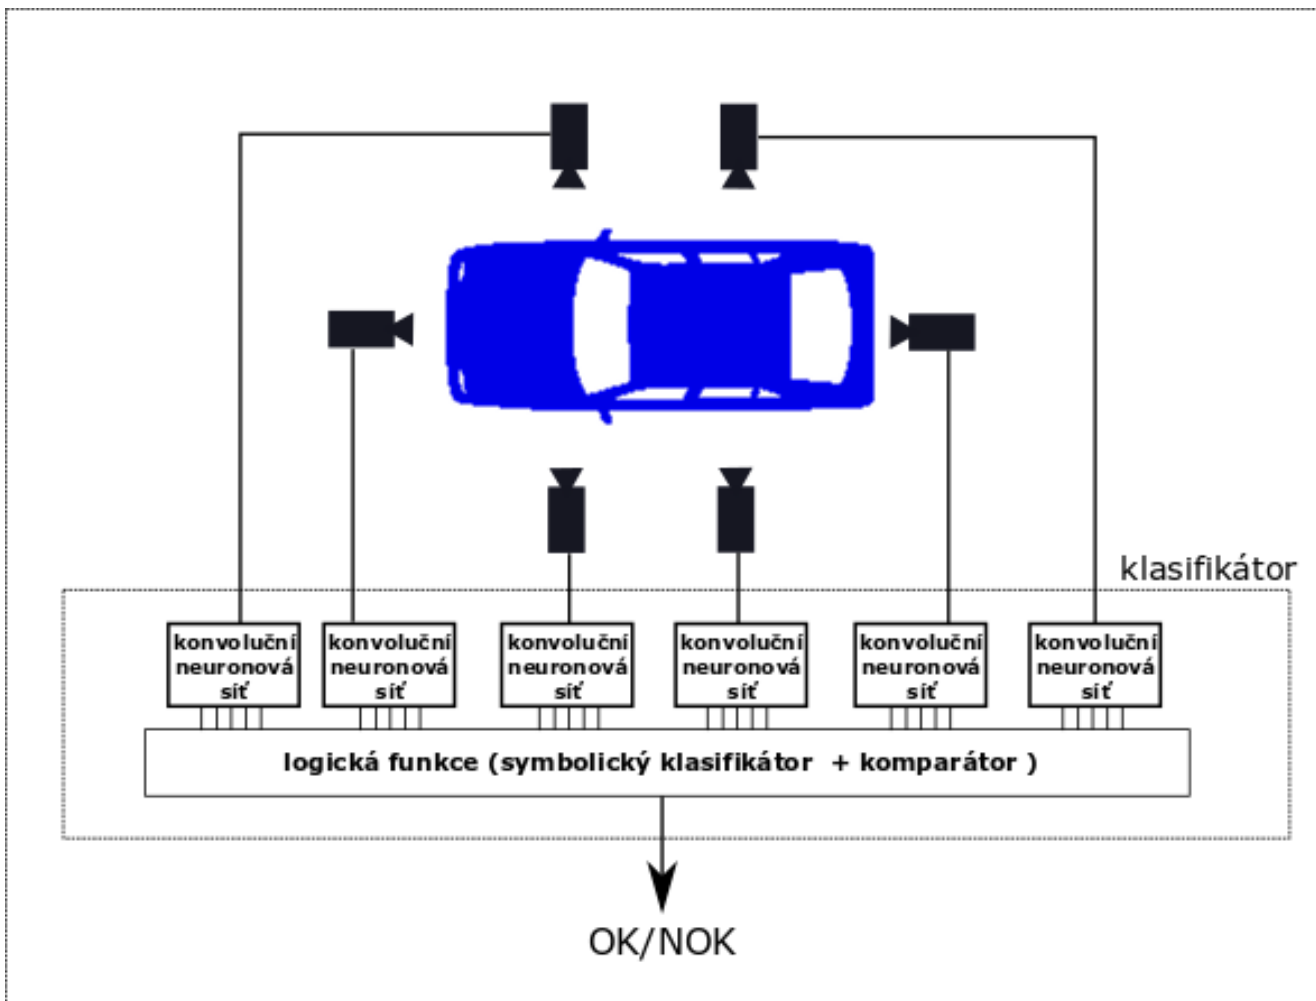
objekty se liší jen málo, nebo není možné najít deskriptory, u kterých lze jednoznačně určit stavy (rušivé vlivy)

Nemáme specialisty na strojové vidění, nahradíme je učícím se systémem

.....







Úskalí aplikace klasifikátoru ve strojovém vidění

- opatření dostatečně velkého trénovacího souboru
- rušivé vlivy
- spolehlivost klasifikace – ověření způsobilosti pro výrobu
- úloha není klasifikací

výrobky v jednotlivých třídách se obvykle vyrábějí:

- dávkově s nerovnoměrným rozložením
prodloužení dobu tréningu

- v různých počtech
pro některé třídy není dost objektů k trénování a testování

dokud není systém natrénován dostatečně na všechny možné varianty, nepracuje správně



Klasifikátor vždy zařadí objekt do některé ze tříd
Způsob, jakým rozhodne není možné znát, ani ovlivnit

Subsymbolickou metodou získané řešení třídícího algoritmu není konzistentní (tzn. pro jednu trénovací množinu dává při opakovaných spuštěních různá řešení)

natrénovaný učící se systém je pouze statistickou aproximací požadovaného modelu klasifikátoru

ověření způsobilosti klasifikátoru jako měřicího přístroje pro výrobu
(MSA, VDA, ČSN ISO 22514-7..)

Kritéria dnešních požadavků 100% reliability / zero-failure těžko plní i deterministické systémy zatížené pouze náhodnou chybou

třídění výrobků OK /NOK

třída OK je definována a lze pro ni opatřit trénovací množinu

třidu NOK obvykle není možné definovat a obvykle není možné opatřit dostatečnou trénovací množinu

Obzvláště záludné zadání:
roztřídit a vyřadit zmetky

klasifikaci OK/NOK lze realizovat symbolickým klasifikátorem

Ke klasifikaci OK/NOK subsymbolickým klasifikátorem se lépe hodí jiný typ učícího se systému: detektor anomálií

Učící se systémy mohou ve strojovém vidění řešit úlohy, které jsou jiným způsobem neřešitelné. Jejich nasazení však nevede k náhradě kvalifikované práce vývojáře prací někoho méně kvalifikovaného. Pouze ji transformuje na práci, která vyžaduje jiný okruh znalostí a praxe.

Děkuji za pozornost

Otto Havle
FCC průmyslové systémy s.r.o.