

Technická zpráva k výsledku projektu NCK KUI v 2020

Identifikační číslo výsledku	TN01000024/8-V1
Název	Automated visual quality inspection based on AI, Machine learning, Deep learning of Artificial Neural Network
Druh výsledku dle RIV	R
Skutečný termín dosažení	12 / 2020

Popis výsledku

Ve shodě s aktivitami plánovanými v projektové žádosti byly implementovány a ověřeny vybrané architektury pro klasifikaci objektů v průmyslové kontrole. Kromě klasických, dobře popsaných, známých a v praxi již používaných metod, se jednalo také o metody využívající strojového učení. Jmenovitě byly analyzovány modely YOLO, VGG16, ResNet50, Inception v3, MobileNet, DenseNet121, NASNetMobile a SVDD. Chování modelů bylo analyzováno v úlohách vícetřídních klasifikátoru i detektorů anomálií. Posledně zmíněné úlohy se od obvyklé klasifikační úlohy liší tím, že není k dispozici explicitní specifikace vad výrobků, tj. vstupní obrazová data relevantní vadným výrobkům postrádají anotaci.


Výsledek typu RIV-R reprezentuje balík implementovaného zdrojového kódu a datových souborů využitých pro simulaci a analýzu chování algoritmů zpracování obrazu a strojového učení v úlohách průmyslové kontroly kvality. Výše listované implementované modely byly využity k evaluaci výkonnosti na reálných datasetech průmyslových výrobků. Jednotlivé modely zpravidla pracují na bázi konvoluční sítě, některé jako např. architektura SVDD (Support vector Data Description) na bázi auto-enkodéru a následného NN klasifikátoru. Chování modelů bylo vyhodnoceno nad vstupními obrazovými daty obsahující jak objekty několika definovaných tříd (dichotomické OK/NOK a multi-class), tak pouze jedné třídy (zpravidla OK kusy definovaného výrobku, definice třídy vadných kusů je z principu problematická).

Pro ověření funkcionality detekčního mechanismu byl kromě veřejně dostupných datasetů vytvořen a použit vlastní dataset Industrial Biscuit obsahující přes 1200 původních snímků, tj. snímků bez augmentace, a to pro třídy OK i NOK. Pouze třída OK byla následně použita pro fázi učení modelů v případě one-class klasifikace.



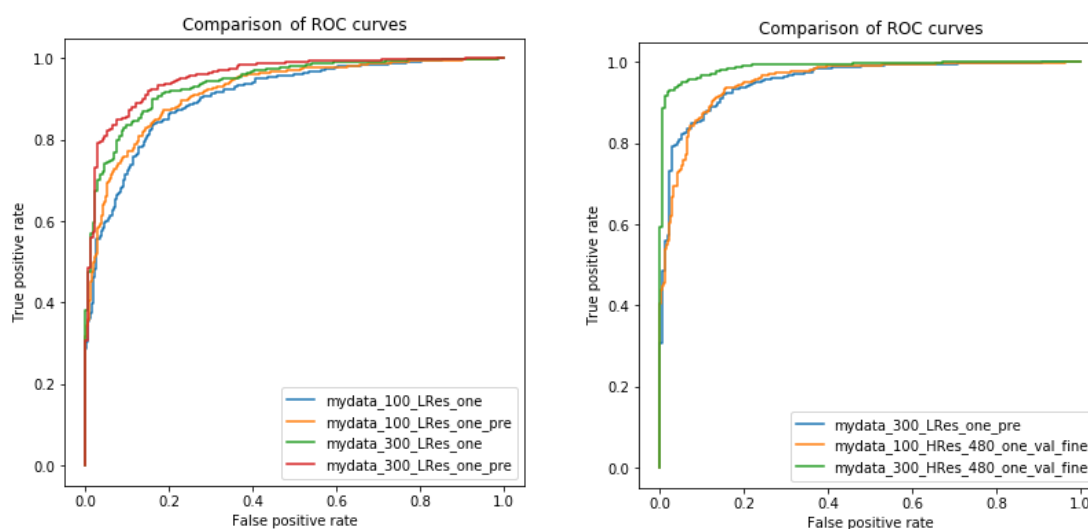
Obr.: příklad vstupních obrazových dat pro fázi učení i verifikace modelů ve formě snímků třídy OK s výrobky biskvit na dopravníkovém pásu.

Technická zpráva k výsledku projektu NCK KUI v 2020



Obr.: příklad vstupních obrazových dat pro fázi verifikace modelů ve formě snímků třídy NOK s výrobky biskvit na dopravníkovém pásu.

Vyhodnocení sestavených modelů bylo provedeno standardizovaným postupem pomocí ROC křivky výpočtem parametru AUC (Area under curve).




Obr.: grafy ROC křivek pro čtyři (vlevo) a tři (vpravo) vybrané odlišné experimenty provedené na modelu SVDD lišící se velikostí použitého datasetu a typem transfer learningu – grafy slouží pro nastavení pracovního bodu klasifikátoru.

V rámci vyhodnocení modelu SVDD bylo provedeno devět hlavních experimentů označených písmeny „a“ až „i“ lišících se v rozlišení vstupních dat, typu transfer learningu a velikostí vstupního datasetu. Na základě provedení fází učení i vyhodnocení byly sestaveny ROC křivky odpovídající uvedeným devíti experimentům. Z každé jednotlivé ROC křivky pak byly extrahovány parametry nastavení klasifikátoru s tím, že konstantním zvoleným parametrem byl TPR na hladině 90 %. Výsledky dosažené takto nastavenými klasifikátory jsou pro tři vybrané experimenty uvedeny v následující tabulce ve formě čtyřpolní tabulky.

Technická zpráva k výsledku projektu NCK KUI v 2020

Experiment	Threshold	Class	Predicted	
		Real	OK	NOK
g	0.4035	OK	149	25
		NOK	68	683
h	5.7926	OK	158	16
		NOK	66	685
i	23.7610	OK	172	2
		NOK	61	690

Tab.: výsledky tří vybraných experimentů (značení g, h, i) modelu SVDD s uvedením klasifikačního prahu a rozdělením výsledků do klasifikací TP, TN, FP a FN – testování modelů je limitováno pouze omezenou množinou vstupních anotovaných dat.



Obr.: vizualizace klasifikace vstupních vzorků ze tříd OK i NOK modelem SVDD v režimu detektoru anomálií pro úlohu biskvit.

Provedenými experimenty byla potvrzena předpokládaná funkčnost implementovaných modelů za definovaných podmínek, zejména definice vstupních dat pro učení modelů. Pro architekturu SVDD a experiment typu „i“ reprezentující typické podmínky průmyslové kontroly byla např. na stanovené hladině sensitivity (zmiňené TPR) 90% dosažena specifická (TNR) 99.7% a přesnost (ACC) 93.2%, tj. počet správně klasifikovaných OK i NOK vzorků vzhledem ke všem klasifikovaným.

Výsledek tímto technicky sestává z balíku souborů obsahující implementované kódy, meta-soubory a datové soubory parametrů.