

# **Využití neuronových sítí pro vyhodnocování sazenic stromků**

Benjamín Chrástek

---

Bakalářská práce  
2025



Univerzita Tomáše Bati ve Zlíně  
Fakulta aplikované informatiky

---



Univerzita Tomáše Bati ve Zlíně

Fakulta aplikované informatiky  
Ústav automatizace a řídicí techniky

Akademický rok: 2024/2025

# ZADÁNÍ BAKALÁŘSKÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

|                      |                                                               |
|----------------------|---------------------------------------------------------------|
| Jméno a příjmení:    | Benjamín Chrástek                                             |
| Osobní číslo:        | A22170                                                        |
| Studijní program:    | B0714A150006 Aplikovaná informatika v průmyslové automatizaci |
| Specializace:        | Průmyslová automatizace                                       |
| Forma studia:        | Prezenční                                                     |
| Téma práce:          | Využití neuronových sítí pro vyhodnocování sazenic stromků    |
| Téma práce anglicky: | Use of neural networks for evaluating tree seedlings          |

## Zásady pro vypracování

1. Popište problematiku třídění sazenic lesních stromků. Zaměřte se především na problémy týkající se morfologické stavby rostliny.
2. Vytvořte literární rešerši zaměřenou na třídění sazenic rostlin a využití neuronových sítí pro tento účel.
3. Vytvořte přehled dostupných počítačových aplikací zaměřených na kontrolu a klasifikaci výrobků.
4. Popište SW produkty dostupné pro studenty Fakulty aplikované informatiky, které slouží pro klasifikaci a třídění na základě kamerových snímků a jsou založené na využití neuronových sítí.
5. Na základě existující obsáhlé databáze snímků vytvořte ve vybraných SW produktech aplikace pro klasifikaci sazenic lesních stromků. Případně navrhněte vlastní alternativní řešení.
6. Zhodnoťte vytvořené aplikace z různých hledisek. Zaměřte se především na možnost nasazení v průmyslové praxi

Forma zpracování bakalářské práce: **tištěná/elektronická**

**Seznam doporučené literatury:**

1. DEY, Sandipan. *Python Image Processing Cookbook*. [Place of publication not identified]: Packt Publishing, 2020. ISBN 9781789537147. Dostupné také z: <https://proxy.k.utb.cz/login?url=https://app.knovel.com/hotlink/toc/id:kpIPCO00D/python-image-processing?kpromoter=marc>
2. GRAUPE, Daniel. *Deep learning neural networks: design and case studies*. New Jersey: World Scientific, [2016]. ISBN 9789813146457.
3. GUPTA, S. Dutta a IBARAKI, Yasuomi. *Plant image analysis: fundamentals and applications*. Boca Raton, FL: CRC Press/Taylor and Francis, [2014]. ISBN 9781466583023. Dostupné také z: <https://proxy.k.utb.cz/login?url=http://marc.crcnetbase.com/isbn/9781466583023>.
4. HASAL, Ondřej. *Software pro zpracování obrazu pro třídící linku na sazenice*. 2019. Dostupné také z: <http://hdl.handle.net/10563/44607>.
5. PETROU, Maria a PETROU, Costas. *Image processing: the fundamentals*. 2nd ed. Chichester: Wiley, 2010. ISBN 9780470745861.
6. RIVAS, Dr. Pablo. *Deep Learning for Beginners*. [S.l.]: Packt Publishing, 2020. ISBN 9781838647582. Dostupné také z: <https://proxy.k.utb.cz/login?url=https://app.knovel.com/hotlink/toc/id:kpDLB00001/deep-learning-for?kpromoter=marc>.

Vedoucí bakalářské práce:

**Ing. Petr Chalupa, Ph.D.**  
Ústav automatizace a řídicí techniky

Datum zadání bakalářské práce: **13. prosince 2024**

Termín odevzdání bakalářské práce: **27. května 2025**

**doc. Ing. Jiří Vojtěšek, Ph.D. v.r.**  
děkan



**prof. Ing. Vladimír Vašek, CSc. v.r.**  
ředitel ústavu

Ve Zlíně dne 13. prosince 2024

# PROHLÁŠENÍ AUTORA BAKALÁŘSKÉ PRÁCE

## Beru na vědomí, že

- odevzdáním bakalářské práce souhlasím se zveřejněním své práce podle zákona č. 111/1998 Sb., v platném znění bez ohledu na výsledek obhajoby;
- bakalářská práce bude uložena v elektronické podobě v univerzitním informačním systému a bude dostupná k nahlédnutí;
- jedno vyhotovení bakalářské práce v listinné podobě bude ponecháno Univerzitě Tomáše Bati ve Zlíně k uložení;
- na moji bakalářskou práci se plně vztahuje zákon č. 121/2000 Sb. o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon) ve znění pozdějších právních předpisů, zejm. § 35 odst. 3;
- podle § 60 odst. 1 autorského zákona má Univerzita Tomáše Bati ve Zlíně právo na uzavření licenční smlouvy o užití školního díla v rozsahu § 12 odst. 4 autorského zákona;
- podle § 60 odst. 2 a 3 mohu užít své dílo – bakalářskou práci – nebo poskytnout licenci k jejímu využití jen s předchozím písemným souhlasem Univerzity Tomáše Bati ve Zlíně, která je oprávněna v takovém případě ode mne požadovat přiměřený příspěvek na úhradu nákladů, které byly Univerzitou Tomáše Bati ve Zlíně na vytvoření díla vynaloženy (až do jejich skutečné výše);
- pokud bylo k vypracování bakalářské práce využito softwaru poskytnutého Univerzitou Tomáše Bati ve Zlíně nebo jinými subjekty pouze ke studijním a výzkumným účelům (tj. k nekomerčnímu využití), nelze výsledky bakalářské práce využít ke komerčním účelům;
- pokud je výstupem bakalářské práce jakýkoliv softwarový produkt, považují se za součást práce rovněž i zdrojové kódy, popř. soubory, ze kterých se projekt skládá; neodevzdání této součásti může být důvodem k neobhájení práce.

## Prohlašuji, že

- jsem na bakalářské práci pracoval(a) samostatně a použitou literaturu jsem řádně citoval(a); v případě publikace výsledků budu uveden(a) jako spoluautor;
- odevzdaná verze bakalářské práce a verze elektronická nahraná do IS/STAG jsou obsahově totožné.

Ve Zlíně, dne .....

.....

podpis autora



## **ABSTRAKT**

V této práci bylo vytvořeno několik modelů klasifikačních neuronových sítí pro účel třídění sazenic stromků. Práce se nejdříve zabývá problematikou třídění sazenic a tím, jak jsou sazenice hodnoceny. Je vytvořena literární rešerše různých aplikací používající neuronové sítě k provedení kontroly produktů. Je popsán přesný postup tvoření těchto modelů, od trénování až po inferenci. Výstupem práce bylo několik modelů dosahující F1-score nad hodnotu 95 %, což lze považovat za úspěšné vytvoření aplikací pro třídění sazenic pomocí neuronových sítí.

Klíčová slova: sazenice, třídění, strojové učení, neuronové sítě

## **ABSTRACT**

In this paper, several classification neural network models were developed for the purpose of tree seedling classification. The paper first deals with the problem of seedling classification and how seedlings are evaluated. A literature search is made of various applications using neural networks to perform product inspection. The exact process of forming these models, from training to inference, is described. The work resulted in several models achieving F1-scores above 95 %, which can be considered as a successful creation of seedling grading applications using neural networks.

Keywords: nursery plants, sorting, machine learning, neural networks

Přednostní poděkování patří vedoucímu práce panu Ing. Petru Chalupovi, Ph.D. za poskytnutí cenných rad a zpětné vazby během průběhu práce.

Největší poděkování patří mé blízké rodinně za neutuchající podporu během celého studia.

# OBSAH

|                                                     |           |
|-----------------------------------------------------|-----------|
| <b>ÚVOD.....</b>                                    | <b>13</b> |
| <b>I TEORETICKÁ ČÁST .....</b>                      | <b>15</b> |
| <b>1 TŘÍDĚNÍ A MORFOLOGIE SAZENIC STROMKŮ .....</b> | <b>16</b> |
| 1.1 VÝŠKA SAZENICE .....                            | 16        |
| 1.2 TLOUŠŤKA KMENE.....                             | 16        |
| 1.3 KOŘENOVÝ SYSTÉM .....                           | 16        |
| 1.4 POMĚR NADZEMNÍ A PODZEMNÍ ČÁSTI.....            | 17        |
| 1.5 DALŠÍ MORFOLOGICKÉ ZNAKY .....                  | 17        |
| 1.6 NORMY PRO HODNOCENÍ SAZENIC .....               | 17        |
| 1.7 VÝZVY VIZUÁLNÍHO HODNOCENÍ SAZENIC .....        | 17        |
| <b>2 LITERÁRNÍ REŠERŠE .....</b>                    | <b>19</b> |
| <b>3 PŘEHLED DOSTUPNÝCH APLIKACÍ.....</b>           | <b>25</b> |
| 3.1 PLEORA TECHNOLOGIES.....                        | 25        |
| 3.2 ISRA VISION .....                               | 25        |
| 3.3 KEYENCE.....                                    | 26        |
| 3.4 ROBOVISION .....                                | 26        |
| 3.5 PEKAT VISION .....                              | 27        |
| 3.6 SICK NOVA .....                                 | 27        |
| 3.7 COGNEX VISIONPRO .....                          | 27        |
| 3.8 HALCON .....                                    | 28        |
| 3.9 ZEBRA AURORA .....                              | 28        |
| <b>4 STROJOVÉ VIDĚNÍ.....</b>                       | <b>30</b> |
| 4.1 DEFINICE.....                                   | 30        |
| 4.2 VÝVOJ.....                                      | 30        |
| 4.3 ROZDÍL STROJOVÉHO A POČÍTAČOVÉHO VIDĚNÍ .....   | 30        |
| 4.4 DÍLČÍ ČÁSTI.....                                | 31        |
| 4.5 TYPY SYSTÉMŮ STROJOVÉHO VIDĚNÍ.....             | 32        |
| 4.5.1 Jednorozměrný systém vidění .....             | 32        |
| 4.5.2 Dvourozměrný systém vidění .....              | 32        |
| 4.5.3 Trojrozměrný systém vidění .....              | 33        |
| 4.5.4 Systémy barevného vidění .....                | 33        |
| 4.5.5 Systémy rozpoznávání vzorů .....              | 33        |
| 4.5.6 Systémy analýzy pohybu.....                   | 33        |
| 4.6 APLIKACE.....                                   | 33        |
| 4.6.1 Výrobní procesy .....                         | 33        |

|           |                                                                                                |           |
|-----------|------------------------------------------------------------------------------------------------|-----------|
| 4.6.2     | Logistika.....                                                                                 | 34        |
| 4.6.3     | Zdravotnictví .....                                                                            | 34        |
| 4.6.4     | Zemědělství .....                                                                              | 34        |
| 4.7       | VÝHODY A NEVÝHODY .....                                                                        | 34        |
| <b>5</b>  | <b>NEURONOVÉ SÍTĚ.....</b>                                                                     | <b>37</b> |
| 5.1       | HISTORIE A VÝVOJ.....                                                                          | 37        |
| 5.2       | PRINCIP HLUBOKÉHO UČENÍ .....                                                                  | 38        |
| 5.2.1     | Hluboké učení pod dohledem.....                                                                | 39        |
| 5.2.2     | Hluboké učení bez dozoru .....                                                                 | 39        |
| 5.2.3     | Hluboké učení s částečným dohledem .....                                                       | 39        |
| 5.3       | ARCHITEKTURY SÍTÍ .....                                                                        | 40        |
| 5.3.1     | Hluboká neuronová síť .....                                                                    | 40        |
| 5.3.2     | Konvoluční neuronová síť .....                                                                 | 40        |
| 5.3.3     | Rekurentní neuronová síť .....                                                                 | 41        |
| 5.3.4     | Autoenkodéry .....                                                                             | 41        |
| 5.3.5     | Generativní soupeřící sítě .....                                                               | 42        |
| 5.4       | PŘÍPRAVA DAT.....                                                                              | 43        |
| 5.4.1     | Vyčištění dat.....                                                                             | 43        |
| 5.4.2     | Škálování dat .....                                                                            | 43        |
| 5.4.3     | Augmentace dat.....                                                                            | 43        |
| 5.4.4     | Rozdělení dat.....                                                                             | 43        |
| 5.5       | VYHODNOCENÍ DAT.....                                                                           | 44        |
| 5.6       | POUŽITÍ .....                                                                                  | 45        |
| <b>II</b> | <b>PRAKTICKÁ ČÁST .....</b>                                                                    | <b>46</b> |
| <b>6</b>  | <b>PŘÍPRAVA .....</b>                                                                          | <b>47</b> |
| 6.1       | PŘÍPRAVA DAT.....                                                                              | 47        |
| <b>7</b>  | <b>PROVEDENÍ V PROGRAMU HALCON A DEEP LEARNING TOOL .....</b>                                  | <b>50</b> |
| 7.1       | DEEP LEARNING TOOL .....                                                                       | 50        |
| 7.1.1     | Příprava projektu .....                                                                        | 50        |
| 7.1.2     | Importování datového setu .....                                                                | 51        |
| 7.1.3     | Vytvoření splitu.....                                                                          | 52        |
| 7.1.4     | Nastavení trénovacího modelu .....                                                             | 52        |
| 7.1.5     | Popis evaluace vytvořeného modelu .....                                                        | 55        |
| 7.1.6     | Výsledky trénování v DLT – detekce anomálií.....                                               | 57        |
| 7.1.7     | Výsledky trénování v DLT – klasifikace .....                                                   | 59        |
| 7.2       | HALCON .....                                                                                   | 61        |
| 7.2.1     | Kód v HALCONu .....                                                                            | 62        |
| 7.2.2     | Výsledky inference v HALCONUu .....                                                            | 64        |
| 7.3       | SHRNUTÍ VÝSLEDKŮ .....                                                                         | 65        |
| <b>8</b>  | <b>PROVEDENÍ V PROGRAMU MATROX DESIGN ASSISTANT A<br/>MATROX IMAGING LIBRARY COPILOT .....</b> | <b>68</b> |

|                                                 |                                      |           |
|-------------------------------------------------|--------------------------------------|-----------|
| 8.1                                             | MATROX IMAGING LIBRARY COPILOT ..... | 68        |
| 8.2                                             | MATROX DESIGN ASSISTANT .....        | 71        |
| 8.3                                             | SHRnutí VÝSLEDKŮ .....               | 73        |
| <b>ZÁVĚR .....</b>                              |                                      | <b>75</b> |
| <b>SEZNAM POUŽITÉ LITERATURY.....</b>           |                                      | <b>77</b> |
| <b>SEZNAM OBRÁZKŮ .....</b>                     |                                      | <b>83</b> |
| <b>SEZNAM TABULEK.....</b>                      |                                      | <b>85</b> |
| <b>SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK .....</b> |                                      | <b>86</b> |



## ÚVOD

Třídění sazenic se může zdát ze začátku nepříliš zajímavé, avšak opak je pravdou. V dnešní době, kdy je automatizace v rozmachu a jsou objevovány nové postupy a metody pro zvýšení efektivity výroby, je možno využít nových technologií i v oblasti organického průmyslu.

Nejdříve se však vyskytuje otázka, proč je vůbec zapotřebí třídit sazenice, na niž se objevuje několik rozdílných názorů. Určitá skupina lidí je přesvědčena, že třídění sazenic je zbytečné, ne-li škodlivé pro životní prostředí, kde by měl, jak se říká, „přežít jen ten nejsilnější“. Hájí si tedy to, že bychom měli sázet všechny sazenice s tím, aby docházelo k přírodnímu genetickému mísení. Na druhou stranu jsou zde názory, že bychom měli sázet pouze vybrané sazenice, čímž dosáhneme zdravějších lesů.

Redukce genetické rozmanitosti stromů však není pravidlem, pokud třídění bude provedeno správně. Bude-li třídění provedeno pečlivě, může dokonce vytvořit odolnější ekosystémy a také hlavně odstranit sazenice, které by mohly později způsobit šíření chorob v lese, což není žádané. Je tedy zřejmé, že třídění sazenic pro regeneraci lesů je výhodné jak z průmyslového hlediska, kdy je motivací získat kvalitní dřevo, tak z hlediska prostého zalesnění v rámci obnovy krajiny.

Další motivace k aplikaci automatizačních technologií je časová náročnost. Sice již dnes míra odlesňování klesá, ale ne dost výrazně, proto je potřeba co nejrychleji obnovovat lesní populaci. Manuální třídění je cenově i časově náročné, a proto, jako v mnoha průmyslových oblastech, bylo zapotřebí najít způsob, jak aplikovat dostupné automatizační prostředky.

Jelikož jsou sazenice organického původu a mají nepravidelný tvar, bylo dosud obtížné sazenice zhodnotit nějakým smysluplným způsobem bez zásahu člověka. Dnes však jsou k dispozici rozvinuté technologie počítačového vidění a umělé inteligence, které jsou schopny rozpoznat různé parametry dané sazenice a podle toho je možné je také roztrždit. V praxi to většinou znamená použití jedné nebo více kamer pracujících spolu, které pořídí snímky zkoumaného předmětu. Tyto snímky jsou dále upraveny tak, aby se s nimi mohlo dále pracovat a vyhodnotit žádané parametry, nejčastěji odstranění pozadí a vyčištění šumu, aby zájmová oblast snímku měla co nejlepší kvalitu. Po všech potřebných úpravách již přichází na řadu vyhodnocovací algoritmus, který snímek analyzuje. V našem konkrétním případě je zjišťována výška sazenice, průměr stonku a jeho morfologie, což je nejdůležitější parametr.

Praktická část práce je tedy zaměřena na právě tuto morfologickou stavbu, kde bude použit již zavedený kamerový systém, resp. archivované snímky sazenic, pro trénování vybraných neuronových sítí a následné posouzení jejich účinnosti.

## **I    TEORETICKÁ ČÁST**

## 1 TŘÍDĚNÍ A MORFOLOGIE SAZENIC STROMKŮ

V úvodu bylo uvedeno, proč je výhodné třídit sazenice, nyní je vhodné uvést několik způsobů a metrik ohodnocení, jež sazenice musí splňovat, než mohou být zasazeny do přírody. Při hodnocení sazenic se běžně vychází z měřitelných morfologických vlastností nadzemní i podzemní části rostliny. Mezi nejdůležitější kontrolované parametry patří výška sazenice, tloušťka kmene, vývoj kořenového systému a poměr nadzemních i podzemních částí. Další parametry k ohodnocení kvality jsou robustnost, což je poměr výšky k průměru kmene, a tzv. „shoot-root ratio“, tedy poměr šířky koruny či hmoty výhonu k hmotě kořenů. Obecně lze říci, že vysoké a statné sazenice s relativně silným kmenem a dostatečně rozvinutým kořenovým systémem jsou považovány za kvalitní. [1], [2]

### 1.1 Výška sazenice

Výška se měří od kořenového krčku k bázi hlavního pupenu. U většiny dřevin jsou vyšší sazenice výhodné, protože mají více pupenů k rychlému růstu. Sadební normy (ČSN 48 2115 a ČSN 48 1211) a manuály uvádí minimální dolní hranici výšky, avšak některé studie [6] ukazují, že vyšší sazenice nemají vždy lepší šanci na přežití oproti malým sazenicím. Nejspolehlivějším faktorem pro vyhodnocení kvality sazenice je její průměr. [1]

### 1.2 Tloušťka kmene

Tloušťka neboli průměr kmene se měří přímo nad kořenovým krčkem, což je část nacházející se hned nad kořenovým systémem. Čím víc má sazenice široký kmen, tím je robustnější a má tak větší šanci na přežití po přesazení. Řada výzkumů a terénních zkoušek odhalila, že průměr kořenového krčku je nejsilnější identifikátor budoucího růstu a přežití. V praxi se často používá dolní limit přípustného průměru, lišící se podle typu dřeviny. [1], [2]

### 1.3 Kořenový systém

Zde se kontroluje délka, míra rozvětvení a hustota kořenů. Silné a dlouhé kořeny s mnoha postranními větvemi zvyšují šanci na dobré zapěstování sazenice. Ze studií vyplývá [7], že sazenice s vyšším počtem kořenů a kvalitnější kořenovou strukturou obvykle lépe přežívají a rostou. V praxi však nebývá praktikou měřit přímo jednotlivé kořeny kvůli riziku jejich poškození, spíše se posuzuje objem neboli hustota kořenů ve vztahu k výšce sazenice. Je však možné provést detailnější ohodnocení kořenového systému u sazenic získaných prostokořennou sadbou, jelikož kořeny kolem sebe nemají zeminu. Alternativně je

využívána technologie krytokořenné sadby, kde jsou kořeny hustě rozrosteny v zemním materiálu. V tomto případě sice nelze kořeny detailně posoudit, ale to není potřeba, jelikož krytokořenné sazenice mají velice kompaktní kořenový obal, což činní kořeny velice ujmavé a poměrně odolné na vlivy okolí. Sazenice se může považovat za kvalitní, má-li velký počet vláknitých kořenů, jelikož poskytují velkou absorpční plochu. [1]

#### **1.4 Poměr nadzemní a podzemní části**

Jedná se o kontrolu poměru hmotnosti nadzemní části k hmotnosti kořenů (tzv. shoot-root ratio). Tento parametr charakterizuje rovnováhu růstu, kde např. příliš vysoký poměr nadzemní částí vůči kořenům může znamenat nižší šanci na přežití. Spolu s robustností se jedná o jeden z hlavních ukazatelů kvality sazenic, avšak shoot-root ratio se běžně nepoužívá jako hodnotící parametr, jelikož jeho měření je pro sazenici destruktivní. [1]

#### **1.5 Další morfologické znaky**

Mezi další klíčové ukazatele kvality patří např. hustota jehličí či listů, kde méně jehličí nebo přezelenění mohou indikovat stres při pěstování. Důležité je také identifikování různých deformací, jako jsou vícenásobné vrcholy a velké zakřivení kmene. Tyto vady bývají ve standardech uváděny jako jedny z hlavních kritérií pro vyřazení sazenic. [1]

#### **1.6 Normy pro hodnocení sazenic**

Existují národní i mezinárodní normy, které definují přijatelné limity pro výše uvedené parametry. V ČR platí normy ČSN 48 2115 „Sadební materiál lesních dřevin“ [3] a ČSN 48 1211 „Lesní semenářství – Sběr, jakost a zkoušky jakosti plodů a semen lesních dřevin“ [4]. Tyto normy stanovují požadavky na kvalitu semenáčků a sazenic, tzn. minimální výška, kořenová délka, průměr sazenice, aj. Kromě norem jsou dostupné také odborné příručky a manuály od lesních školek, které popisují třídění sazenic v praxi.

#### **1.7 Výzvy vizuálního hodnocení sazenic**

Vizuální hodnocení morfologických kritérií je sice praktické, ale nese s sebou několik nevýhod. Především se jedná o nemalou manuální náročnost a subjektivnost vyhodnocení, kde třídění vyžaduje zkušené pracovníky, u kterých může docházet k lidským chybám jako u každé práce. Výhodným faktem je to, že sazenice se klasifikují pouze na vyhovující a nevyhovující, čímž se naskytuje možnost aplikace automatizačních technik do velkosériové produkce. Jelikož není praktické kontrolovat všechny parametry sazenice (shoot-root ratio,

vnitřní zásobu živin, odolnost vůči chorobám, aj.), automatická kontrola by v podstatě plnila stejnou úlohu jako člověk, tedy posoudila by parametry jako jsou výška, šířka a morfologie sazenice. [5]

Tím se tedy dostáváme k zaměření této práce, kde budou aplikovány neuronové sítě, které se budou snažit rozeznat kvalitu sazenice pouze na základě jejich morfologických charakteristik, tedy zda jsou dost vysoké a jestli nemají vícenásobné vrcholy. Pro posuzování z pohledu přesného měření výšky sazenice a šířky kořene je mnohem vhodnější aplikovat klasické metody strojového vidění, to však není cílem této práce.



Obrázek 1 Ukázka nevyhovujících sazenic (dvojné vrcholy, malá velikost)

*(zdroj: vlastní)*




Obrázek 2 Ukázka vyhovujících sazenic (jeden vrchol, dostatečná velikost)

*(zdroj: vlastní)*

## 2 LITERÁRNÍ REŠERŠE

V minulosti již byla vytvořena řada prací zabývajících se problematikou třídění sazenic a mnoho z nich se od sebe výrazně liší, jak už konkrétními požadavky úlohy nebo použitými technologiemi.

Pokud se podíváme na dnes již poměrně zastaralé práce, můžeme skutečně pochopit a pozorovat vývoj automatizačních technologií. Disertační práce z roku 1992 s názvem „*A machine vision and handling system for measurment of containerized tree seedlings*“, jejíž autor je Wing Hang Poon. Třídění realizoval tak, že měřil šířku stonku a výšku 14 sazenic najednou, kde sazenice byly položeny na dopravníkový pás a snímány optickými vláknovými senzory. V práci uvádí chybu klasifikace sazenice o velikosti 9 %, standardní odchylku průměru 0,12 mm a chybu měření výšky sazenic o velikosti 0,6 cm při rychlosti zpracování 1,75 sazenic za sekundu [8].




Obrázek 3 Prototyp skenovacího systému

(zdroj: [8])

Další vybraná práce je diplomová práce od Ondřeje Hasala s názvem „*Software pro zpracování obrazu pro třídící linku na sazenice*“ z roku 2019. Autor používá soustavu dvou kamer s objektivy a osvětlením, které pozorují sazenici pohybující se na dopravníku. Vidíme, že princip provedení je téměř totožný jako s první uvedenou prací, avšak značně se liší prakticky, kde tady je snímána pouze jedna sazenice najednou a je měřena šířka kořenového krčku. Ke zpracování snímků byl použit *Image processing toolbox* v MatLabu. Zde autor uvádí směrodatnou odchylku 0,2 mm. Vidíme, že i když je práce poměrně


aktuální, výsledky měření jsou horší než u první práce. Autor však uvádí, že přesnost lze zvýšit přiblížením kamery k sazenici nebo použitím většího rozlišení snímků [9]. Kvalita práce tedy nepřichází automaticky s lepším vybavením, ale musí být použity správné postupy pro dosažení optimálních výsledků za použití dosavadních technologií.



Obrázek 4 Testovací zařízení na měření sazenic


(zdroj: [9])

Dále se můžeme podívat na společnou práci studentů zemědělské univerzity v Číně, jak vytvořili systém na kontrolu kvality sazeniček pižmových melounů. Jejich cílem bylo vytvořit systém, který by mohl spolehlivě zkontrolovat mezeru ve stonku sazenice, která je důležitá pro zemědělské účely, konkrétně zde pro tzv. roubování. Hardwarové provedení je opět poměrně prosté, kamera s objektivem pořizuje snímky nasvícené sazenice z předem definované vzdálenosti. K rozpoznávání obrazu si zvolili moderní program HALCON v12.0, kde si vytvořili „masku“ nebo-li šablonu hledané mezery. Tuto šablonu následně použili jako porovnávací parametr při skenování dalších sazenic. Výstupem tedy byla číselná hodnota od 0 až 1, která značila, jak moc je sazenice podobná šabloně. Postupnou změnou parametrů určili minimální hodnotu podobnosti 0.58, tedy sazenice s menším skóre než tahle stanovená hodnota, byla vyhodnocena jako nevyhovující. Ve výsledcích tým studentů uvádí, že ze 100 vyhodnocovaných sazenic měl systém úspěšnost 98 % a rychlost zpracování sazenic může dosáhnout až 15/min.



Obrázek 5 Sestava pro získání snímků sazenic

(zdroj: [10])




Obrázek 6 Ukázka vyhodnocení pro nalezení (a) a nenalezení (b) šablony na fotce

(zdroj: [10])

Je také možno stručně uvést použití neuronových sítí v oblasti zemědělství i mimo konkrétní problematiku třídění sazenic, aby bylo vidět, že neuronové sítě lze aplikovat na mnoha místech a pro různé účely. Tato další aplikace je zaměřená na rozpoznání struktury větví ovocných stromů. Práce s názvem „*A real-time branch detection and reconstruction mechanism for harvesting robot via convolutional neural network and image segmentation*“ od skupiny studentů z univerzity v Číně pojednává o návrhu tohoto systému pro inteligentní roboty používaných pro sklizeň plodů z těchto ovocných stromů. Řešenou problematikou je tedy to, že roboti potřebují „vidět“ a vytvořit si mapu větví stromu pro navigaci ramene,


které se natahuje pro plody. S kombinací použití konvoluční neuronové sítě a technik zpracování obrazu dokázali vytvořit spolehlivý systém strojového vidění, který v reálném čase zobrazuje strukturu větví v koruně stromu. Výsledky v reálném prostředí, tedy ovocném sadu, uvádí F1-skóre neuronové sítě na 90 % při rychlosti zpracování obrazu 22,7 snímků za sekundu při rozlišení obrazu 960\*720 pixelů. [11]



Obrázek 7 Výsledky rekonstrukce větví za použití CNN

(zdroj: [11])

Další možné použití neuronových sítí je pro segmentaci a vyznačení jednotlivých prvků z obrazu. Přesně na tohle byla zaměřena práce „*Tree Seedlings Detection and Counting Using a Deep Learning Algorithm*“, jejíž cílem bylo vyznačit pozici a typ zasazených sazenic. Fotografie polí se sazenicemi, nafoceny shora pomocí dronu, byly upraveny různými filtry a metodami zpracování obrazu, čímž vznikl velký datový set fotek. Na tento set o velikosti 7000 fotek byla použita síť pro detekci objektů YOLOv5, jenž je dostupná v Pythonu. Výsledná přesnost modelu je uvedena na 95,1 % s mírnou odchylkou pro jednotlivé druhy sazenic a průměrná doba detekce sazenic trvala 0,7 sekund. [12]



Obrázek 8 Příklad augmentace originálních fotografií

(zdroj: [12])



Obrázek 9 Výsledná segmentace sazenic

(zdroj: [12])

Na závěr lze uvést malé množství obecných příkladů použití neuronových sítí v oblasti zemědělství. Průzkum studií s názvem „*A review of the use of convolutional neural networks in agriculture*“ se zaměřil na publikované studie v letech 2014 až 2017, z kterých může být vytvořen hrubý přehled témat, na které byly práce zaměřeny: detekce nemocí na rostlinách (3 studie), klasifikace půdního pokryvu (3 studie), rozpoznávání rostlin (3 studie), počítání plodin (4 studie), identifikace plevelu (3 studie). Většina těchto studií se zabývala klasifikací a identifikací zájmových oblastí, včetně např. detekce překážek a předpovědi velikosti sklizně plodin. Provedení prací se lišilo v mnoha ohledech, jako např. v použití různých neuronových sítí, velikostí a původem datových setů, použitých technik augmentace, aj.

Kvalita dosažených výsledků byla také různá pro každou práci, kde se vyskytovalo mnoho různých výkonnostních metrik (CA, RMSE, F1-score, aj.). Hrubý rozsah dosažených výsledků byl tedy od 90 % až 98 % přesnosti pro dané neuronové sítě. Toto obecné shrnutí bylo vzato z přehledové práce z roku 2018. Od té doby samozřejmě vznikla celá řada dalších studií využívající neuronové sítě v oblasti zemědělství. Podstatné však není vyjmenovat všechny studie a práce jednotlivě, ale pouze nastínit zkoumanou problematiku a její možné řešení. [13]

Z rešerše tedy vyplývá, že je v dnešní době k dispozici spousta možností, nástrojů a metod pro realizaci automatizačních procesů požadující pokročilé strojové vidění. Je tedy potřeba mít přehled a umět se zorientovat ve všech dostupných nástrojích, aby bylo dosaženo co nejlepší řešení dané problematiky.

### 3 PŘEHLED DOSTUPNÝCH APLIKACÍ

Na dnešním průmyslovém trhu je dostupná široká škála produktů zabývajících se rozpoznáváním a analýzou obrazu, jak jistě vyplývá z provedené rešerše. Je tedy vhodné vytvořit alespoň stručný přehled těchto produktů, aby bylo možné se od něčeho odrazit, jelikož ne všechny dostupné produkty musí být vhodné pro tuto konkrétní aplikaci analýzy rostlinného materiálu. Samozřejmě nejde jenom o srovnání toho, zda bude produkt vhodný pro danou aplikaci, ale také o další parametry, jako například cenová dostupnost, komplexnost, robustnost, aj. Vždy je lepší nasbírat co nejvíce relevantních dat a následně zvážit své možnosti než přistoupit hned na první příležitost, která se naskytne. V takovém případě by se mohlo stát, že by aplikace v praxi sice fungovala řádně, ale ekonomicky by mohla být situace mnohonásobně lepší, kdyby bylo použito jiného produktu, nebo i v tom horším případě by se mohl stát opak. Zde následuje výběr několika firem poskytující software a jiné služby zabývajících se strojovým viděním. [14]

#### 3.1 Pleora Technologies

Společnost Pleora Technologies [15] je zaměřená na výrobu vysoce výkonných real-time systémů v oblasti průmyslové automatizace, lékařského průmyslu, obrany a zabezpečení. Jejich produkty se strojovým viděním se vyskytují v mnoha oblastech jako jsou industriální kamery, rentgenové panely, robotika, transportace, monitorování, kontrola kvality výrobků a mnoho dalších. S vývojem dlouhým přes dvě dekády, tato firma přináší na trh po celém světě nové produkty rychle s minimálním rizikem a zmenšujícími se náklady.

Mezi jejich produkty patří velký výběr kamer a senzorů pro externí konstrukce, vše pomocí embedded systémů s použitím protokolů GigE Vision a USB3 Vision, zajišťující vysoce objemový přenos dat s minimální prodlevou. Vývoj, konfigurace a propojení těchto produktů je provedeno pomocí jejich softwaru eBUS SDK.

#### 3.2 Isra Vision

Software ISRA VISION od stejnojmenné společnosti [16] poskytuje širokou řadu nástrojů pro realizaci výroby pomocí strojového vidění. Tato technologie, excelující ve 3D povrchové inspekci, dokáže rozeznat i velmi malé defekty, čímž je možno dosáhnout vysokých výrobních standardů. Produkty této firmy jsou využívány v mnoha odvětvích, např. výroba automobilů, baterií nebo polovodičů.

### 3.3 Keyence

Světově známá firma Keyence [17] je jeden z největších dodavatelů senzorů, měřících systémů, mikroskopů a systémů se strojovým viděním. Usilují o konstantní vývoj inovativních a spolehlivých produktů, které najdou využití v každé průmyslové oblasti. Mimo své produkty poskytují také velikou řadu služeb pro asistenci svých zákazníků, jako jsou například návrh a řešení náročných průmyslových aplikací a široká technická podpora ke svým produktům.

V jejich inspekčním odvětví se najde mnoho druhů senzorů a softwaru používající strojové vidění vytvořené za účelem optimalizace a zvýšení účinnosti výroby. K dosažení vysoké přesnosti při kontrole kvality výrobků a detekci chyb využívají pokročilé algoritmy pro rozpoznávání obrazu, které zajišťují vysokou přesnost bez negativního dopadu na rychlost produkce. Pro tvoření a změnu nastavení produktů vizuálních systémů poskytují spoustu softwarových aplikací.

### 3.4 RoboVision

Společnost RoboVision [18] se zaměřuje na systémy strojového vidění na bázi umělé inteligence. Založena byla v roce 2009, začátky této společnosti jsou založeny na vývoji 3D hlubokého učení pro robotický systém třídění a stříhání rostlin jako tulipány a růže. Od té doby se rozrostli do dalších sektorů automatizace, jako je kontrola kvality pečených výrobků až po hledání defektů na polovodičích v měřítku nanometrů. Také působí v medicínském průmyslu, kde doktoři mohou například využít asistence od jejich pokročilé technologie rozpoznávání obrazu při stanovení diagnózy z rentgenových snímků.

Použití vysoce výkonné umělé inteligence v průmyslu je zatím spíše výjimkou, avšak RoboVision se snaží zpřístupnit tuto mocnou technologii pro širokou veřejnost. Všechny prostředky pro vytvoření aplikace mají jednotně na své softwarové platformě, kde lze vytvářet datové sady, trénovat AI modely, uvést je do provozu a v reálném čase modely monitorovat a upravovat.

### 3.5 Pekat Vision

Česká společnost Pekat Vision [19], založená v roce 2016, poskytuje robustní software zaměřený na automatizaci a kontrolu kvality výrobků. Dosahuje toho kombinací metod hlubokého učení, umělé inteligence a klasických způsobů analýzy obrazu. Rozhraní tohoto softwaru je velmi uživatelsky přívětivé a intuitivní, což jej činí ideální pro rychlé a kvalitní nasazení kompletního systému do výroby.

Robustnost tohoto systému jej umožňuje použít pro detekci defektů, kontrolu kompletnosti, třídění, navádění robotů, čtení textu a mnohem více, takže lze tento software aplikovat v široké škále průmyslových procesů od potravinářství a medicíny po automobilní a elektronický průmysl.

### 3.6 SICK Nova

Společnost SICK [20] se zaměřuje na inovativní řešení automatizačních záležitostí jak v továrních prostředích, tak také v logistice. Dodává celou řadu inteligentních senzorů do všech průmyslových oblastí po celém světě. K propojení hardware produktů používají vlastní software systém SICK Nova [21], který zajišťuje intuitivní rozhraní a robustnost při tvoření aplikací pracujících s jejich senzory. Jejich další silný nástroj je SICK dStudio [22], což je cloudové softwarové prostředí dělané přímo pro hluboké trénování umělé inteligence ve všech konvenčních směrech, jako je detekce a klasifikace objektů a hledání defektů.

### 3.7 Cognex VisionPro

Další software zaměřený na aplikaci strojového vidění je VisionPro [24] od světově známé společnosti Cognex [23]. Tento software opět poskytuje všechny konvenční metody pro analýzu obrazu pro průmyslové, i jiné oblasti, kde je zapotřebí vyhodnocování obrazu. Cognex dodává celou škálu produktů pro realizaci celého výrobního procesu, jako jsou kamery, senzory, různé sady ovládacích prvků a rozhraní, zajišťující přehlednost a kvalitní kontrolu výroby.

Cognex také poskytuje další aplikaci s názvem VisionPro Deep Learning [25], což také software pro analýzu obrazu, avšak pracuje na bázi umělé inteligence. Tato aplikace zvládá standardní úlohy jako je detekce anomálií, klasifikace, segmentace a mnohem více. Software umožňuje označování, trénování a vyhodnocení vytvořené neuronové sítě. Uvádějí také užitečnou technologii „few sample mode“, kde je k trénování neuronové sítě potřeba pouze minimální počet trénovacích dat k dosažení kvalitního provedení s malou časovou investicí.

### 3.8 HALCON

Společnost MVTec [26] poskytuje hned několik programů pro realizaci průmyslových procesů obsahující strojové vidění. Jejich produkty se vyskytují v mnoha oblastech vyžadující precizní kontrolu kvality výrobků, jako je elektronický, lékařský a automobilový průmysl. Použití jednotlivých programů záleží čistě na volbě uživatele pro danou aplikaci.

První je zde program MERLIC [27], který je založen na obsáhlých znalostech MVTecu v oblasti strojového vidění s velmi intuitivním uživatelským rozhraním. Je ideální pro rychlou a kvalitní tvorbu aplikací požadující analýzu obrazu.

Dále tu je HALCON [28], což je komplexnější vývojové prostředí, umožňující tvorbu náročných aplikací pro analýzu obrazu. Jeho flexibilní architektura je skvělá pro rychlý vývoj a nasazení strojového vidění v jakékoliv oblasti průmyslu.

Nesmírnou výhodou je rozhraní HDevelop, které slouží pro propojení softwaru MERLIC a HALCON dohromady pro plné využití potenciálu obou nástrojů. V takovém případě uživatel může využít HALCON pro vytvoření sofistikované aplikace, kterou následně použije jako nástroj v MERLICu, kde může využít jeho výhod, jako je např. intuitivní a přehledné rozhraní.

Naposled je tu samostatný nástroj Deep Learning Tool [29], poskytovaný zdarma, který je specializovaný na aplikace hlubokého učení. Umožňuje všechny standardní úkony, jako je značení dat, detekce, klasifikace, segmentace a detekce defektů. Všechny kroky pro vytvoření neuronové sítě lze provést zde až na inferenci, což je nutno provést v HALCONu nebo MERLICu.

### 3.9 Zebra Aurora

Společnost Zebra [30] dodává hned několik aplikací, každá s jiným účelem použití a stupněm komplexnosti, zaměřené na realizaci analýzy obrazu v průmyslovém prostředí. Jejich produkty, založené na mnoholetých zkušenostech v této oblasti, zajišťují nejvyšší míru kontroly kvality svým zákazníkům. Mimo aplikace strojového vidění Zebra dodává také mnoho hardwarových produktů, jako třeba čtečky, skenery, autonomní mobilní roboty a širokou škálu senzorů. Poskytují také spoustu služeb a vývoj dalšího softwaru, např. v oblasti umělé inteligence.

Jejich software dělaný přímo pro práci se strojovým viděním je zaměřený na spoustu oblastí. Aurora Vision Studio [31], vytvořené pro inženýry strojového a počítačového vidění, umožňuje uživatelům rychle tvořit, integrovat a monitorovat aplikace, dokonce bez psaní kódu. Tento software je skvělý pro ty, co nemají příliš velkou zkušenost s programováním.

Naopak Aurora Vision Library [32] je ideální pro ty, co chtějí použít programování pro tvoření svých projektů. Obsahuje vše, co Aurora Vision Studio, akorát ve formě programovacího jazyka, což umožňuje větší přizpůsobení pokročilých aplikací strojového vidění.

Aurora Imaging Library [33] je vývojová sada obsahující masivní kolekci nástrojů pro pořizování, zpracování, analýzy, zobrazení a archivaci obrazu.

Integrované vývojové prostředí Aurora Design Assistant [34] je vývojová platforma pro vývoj softwaru pro strojové vidění založená na vývojových diagramech. Obsáhlá knihovna šablon umožňuje rychlé vytváření aplikací a zavedení do výroby.

Naposled je zde Aurora Focus [35], což je software určený pro ovládání celopodnikových výrobních a logistických řešení. Toto rozhraní usnadňuje nastavení, nasazení a provoz průmyslových zařízení jako jsou industriální skenery a chytré kamery.

Z vytvořené rešerše uvedených softwarových produktů vyplývá, že na trhu je dostupných spousta možností pro řešení aplikací strojového vidění. Mnoho těchto programů má v podstatě stejný účel, tj. realizace úkonů v průmyslovém prostředí, takže už poté záleží na parametrech výhodné pro uživatele jako je cena, dostupnost, přívětivé uživatelské rozhraní, robustnost systému, aj. Tyto parametry nebyly jednotně uvedeny v rešerši, jelikož porovnávat např. uživatelské rozhraní by bylo časově intenzivní, mnohdy subjektivní a také by bylo zapotřebí mít přístup ke všem těmto programům, což je mimo dosah této práce. Cenové srovnání také není podstatné uvádět, protože se v této oblasti vyskytuje spousta variací, jakou jsou různé verze, licence, množstevní slevy, aj. Pro tyto informace je nejlepší přímo navštívit webové stránky uvedených dodavatelů těchto aplikací.

## 4 STROJOVÉ VIDĚNÍ

Strojové vidění v dnešní době zastupuje širokou oblast v průmyslu, kde umožňuje produkci výrobků v obrovském měřítku o vysoké kvalitě za jiných dob nevídané. Strojové vidění se ovšem může vyskytovat v různých formách i mimo průmyslové prostředí podle potřeb dané aplikace, např. v autonomních vozidlech. Obecně strojové vidění můžeme považovat jako technologie a metody používané pro automatickou inspekci a analýzu obrazu. [37], [39]

### 4.1 Definice

Přesná definice pro výraz strojové vidění není stanovena, avšak všechny zahrnují použití technologií a metod pro automatizované získávání informace z analyzovaného obrazu. Konkrétní informace extrahovaná z obrazu může být například pozice, orientace nebo identita objektů, vše záleží na aplikaci. Tato získaná informace může být předána dále v procesu aplikace a na jejím základě se provede další akce, např. pro vyřazení vadného výrobku, pohyb robotického ramene nebo navigace vozidel. [36], [38], [42]

### 4.2 Vývoj

Stroje mohly rozpoznávat své okolí již na začátku 70. let 20. století, i když velmi omezeně. Počítače začaly používat specifické algoritmy pro zpracování obrazu a dokázaly rozpoznat základní rysy, jako byly čárové kódy nebo také text, avšak pouze pokud byl ostrý a jasně čitelný. Rozpoznávané tvary musely být předvídatelné a dosednout na přesně definovaný vzor. Tyto algoritmy ještě nedokázaly přečíst rukopis nebo rozpoznat např. různé druhy ovoce od sebe. S postupem času se však tyto algoritmy vyvíjely a zdokonalovaly, takže jejich možnosti uplatnění v praxi začaly narůstat, čímž se dostáváme do dnešní doby, kde strojové vidění je klíčová část ve všech odvětvích průmyslu. [39]


### 4.3 Rozdíl strojového a počítačového vidění

Strojové vidění a počítačové vidění se může zdánlivě tvářit jako stejný výraz, avšak tyto dvě technologie se do sebe trochu liší. Počítačové vidění je obecný pojem odkazující se na použití počítačů nebo umělé inteligence pro pochopení a interpretování vizuálních dat s různě definovanými podmínkami. Aplikace počítačového vidění je hodně široká a může být použita třeba na rozpoznávání obličejů, obchodní analytiku nebo analýzu lékařských snímků.

Na druhou stranu strojové vidění je specificky zaměřené na úkoly, jako je identifikace a vyhodnocení kvality výrobků a robotické navádění ve výrobním prostředí. Lze také říct, že strojové vidění se zabývá navíc hardwarovou částí procesu, kde je potřeba vytvořit kompatibilní sestavu všech potřebných komponent, jako jsou kamery, osvětlení, způsob přenosu informace, aj. Se strojovým viděním dokážou roboti a jiná průmyslová zařízení konzistentně provádět autonomní akce a rozhodnutí v reálném čase. [39], [40], [42]

#### 4.4 Dílčí části

Na obrázku níže je uvedeno zjednodušené schéma provedení kontroly výrobku v průmyslovém prostředí. Jedná se pouze o obecné znázornění pro objasnění jednotlivých částí, které jako celek tvoří aplikaci strojového vidění.



Obrázek 10 Obecné schéma provedení procesu kontroly s použitím strojového vidění

(zdroj: [36])

- 1. Optický systém:** Skládá se z kamery a popřípadě objektivu což je hlavní vstupní zařízení v celém systému. Kamera zaznamenává obrazy objektů nebo scény, která má být analyzována. Podle aplikace mohou být použity různé typy kamer, jako jsou kamery pro plošné skenování (area-scan) nebo kamery pro řádkové skenování (line-scan). Objektivy mohou být použity pro zaostření obrazu nebo na změnu zorného pole pro inspekci specifické oblasti na objektu. [36]

2. **Zpracování obrazu:** Velice výkonné počítače nebo procesory, které řídí a zpracovávají pořizování snímků, předzpracování a analýzu. Zde jsou realizovány algoritmy pro vyhodnocování získaných snímků. [36]
3. **Osvětlení:** Kvalitní osvětlení je důležité pro získání snímků, kde jsou jasně viditelné všechny rysy objektu, čímž se následně zvyšuje kvalita analýzy. Obvykle se používá vysoce výkonné LED nebo halogenové osvětlení. [36]
4. **Dopravníkový systém:** Zpravidla se jedná o posuvný systém, který postupně posouvá objekty, která mají být a již byly analyzovány. Může se jednat o pouhý dopravní pás nebo také celé robotické rameno. Klíčová je synchronizace s kamerovým systémem, tedy musí být dosaženo dokončení analýzy obrazu dřív, než se objekt dá znovu do pohybu. Tohle však nemusí platit u řádkového skenování, kde se dopravník může pohybovat s konstantní rychlostí. Objekty splňující kontrolu jsou posílány dále, zatímco vadné kusy jsou odstraněny z výrobního procesu.
5. **Analyzovaný objekt:** Materiál pohybující se v řetězci výrobního procesu, jenž je podroben analýze.

## 4.5 Typy systémů strojového vidění

Typy systémů strojového vidění lze rozdělit do několika kategorií, kde každá má svou specifickou oblast použití a svoje výhody.

### 4.5.1 Jednorozměrný systém vidění

1D systém neanalyzuje celý objekt v obraze najednou, ale provádí to tak, že čte jeden řádek po druhém, často za použití kamery s řádkovým skenováním. Tento typ vidění se obvykle používá pro odhalení defektů na produktech pohybující se na dopravníku. [38]

### 4.5.2 Dvourozměrný systém vidění

2D systém analyzuje dvourozměrný obraz získaný z digitální kamery, zaměřující se na měření šířky a délky obrazu. Můžou být použity na čtení čárových kódů, sledování objektů nebo kontrolu kvality a defektů. [36], [38]

#### 4.5.3 Trojrozměrný systém vidění

3D systém vidění je schopen zpracovat i hloubku obrazu oproti 2D s použitím více kamer sledující objekt z různých úhlů pohledu nebo také pomocí LIDAR senzoru. Z těchto mnoha obrazů je vytvořen 3D model pozorovaného objektu nebo scény, což zajišťuje přesné určení lokace, velikosti a rysů objektu. Tento systém je typicky používán pro navigaci robotů v prostoru. [36], [38]

#### 4.5.4 Systémy barevného vidění

Tyto systémy jsou zaměřené na rozpoznávání barev v obrazu, což je dělá ideální pro aplikace třídění na bázi barev nebo na kontrolu kvality v potravinářském průmyslu. [36]

#### 4.5.5 Systémy rozpoznávání vzorů

Systémy rozpoznávání vzorů identifikují a přirovnávají vzory vyskytující se v obrazu. V kontextu strojového vidění jsou klíčové pro realizaci rozpoznávání obličejů a textu, avšak tyto systémy mohou najít využití také v oblastech datové analýzy, zpracování signálů a datové komprese. [36]

#### 4.5.6 Systémy analýzy pohybu

Systémy analyzující pohyb objektů v obraze jsou běžně využívány v oblasti robotiky a automatizace tam, kde stroje potřebují mít přehled o svém okolí, např. autonomní vozidla nebo robotická ramena. [36]

### 4.6 Aplikace

Jak již bylo uvedeno v literární rešerši, strojové vidění našlo uplatnění v mnoha oblastech průmyslu, zejména tam, kde bylo za potřebí dosáhnout rychlé a kvalitní kontroly velkého množství materiálu.

#### 4.6.1 Výrobní procesy

Prezence strojového vidění ve výrobních procesech je nesmírně důležitá. Jedná se o oblasti automobilního a leteckého průmyslu, kde je samozřejmé nasazení strojového vidění pro hledání defektů v klíčových částech, od šroubků po komponenty motorů. Taková kontrola se může zabývat povrchovou analýzou samotné součástky nebo také ověřením operace provedené na dané součástce, např. kontrola kvality svaru. Dalším případem použití je kontrola na konci linky, kde za průběžného čtení čárových nebo jiných kódů během

výrobního procesu je zajištěno to, že konečný produkt obsahuje všechny patřičné části, které má mít. Tyto metody pro monitorování procesů a různé technologie se vyskytují ve všech oblastech výrobního průmyslu. [36], [40]

#### 4.6.2 Logistika

V oblasti logistiky je využíváno autonomních mobilních robotů a robotických ramen při úkolech jako je třídění zásilek, dělání inventury a určování optimálních pozic úchopu a orientace při manipulaci. Běžné je také používání skenerů na dopravníkových systémech ověřující přítomnost, orientaci a integritu štítků na balících. [41]

#### 4.6.3 Zdravotnictví

Ve zdravotnictví je strojové vidění klíčové v oblasti diagnostiky. Umožňuje analýzu lékařských snímků, jako jsou rentgenové snímky, MRI a CT snímky, čímž pomáhá při diagnostice nemocí nebo odhalování abnormalit a následnému vedení lékařských postupů. Podle definice by se zde dalo říct, že se spíše jedná o počítačové vidění, avšak tyto dva termíny mají k sobě tak blízko, že v praxi strojové a počítačové vidění spolupracuje. [36]

#### 4.6.4 Zemědělství

Strojové vidění našlo svou podstatu také v zemědělství, kde je používáno pro monitorování a třídění plodin. Tyto systémy dokážou analyzovat jejich zdraví, zralost, detekovat nákazy a optimalizovat sklízecí procesy. I zde je rozsah aplikací v praxi široký. Pomocí hyperspektrálního snímání lze sledovat šíření nemocí na jednotlivých plodinách nebo rovnou celých lesních ploch za použití bezpilotních monitorovacích dronů. [36]

### 4.7 Výhody a nevýhody

Jako všechny technologie, ani strojové vidění není perfektní nástroj, který by se dal ihned implementovat do všech výrobních procesů, vždy je potřeba zvážit výhody a nevýhody, které s sebou tahle technologie přináší.

#### 1) Výhody:

1. **Zvýšení kvality produktu:** Automatická inspekce je mnohem rychlejší a přesnější oproti manuální inspekci, což zaručuje zachycení defektů z výroby a zároveň eliminuje možnost chybné kontroly od lidské obsluhy. Samozřejmě že málo systémů má stoprocentní účinnost, avšak chybování stroje je mnohonásobně menší

oproti člověku. Tím pádem výrazně klesá potřeba manuální kontroly a posudek člověka je vyhrazen pouze pro velmi složité případy. [37], [42]

2. **Dohledatelnost produktů:** Tím, že strojové vidění umožňuje číst kódy v každé části výroby od počátku až do konce, je možno snadno dohledat příčiny jakéhokoliv poškození nebo vzniklé vady, ale také třeba předpovídat zpoždění a chyby při přepravě. [37], [39]
3. **Zvýšení produktivity a celkové efektivity nástrojů:** Systémy se strojovým viděním značně urychlují prováděné operace a zkracují dobu výrobního cyklu. [37]
4. **Snížení odpadu:** Tím, že jsou systémy schopny zachytit výrobní chyby a identifikovat jejich příčiny, je mnohem snadnější sledovat materiálový tok, což vede k větší optimalizaci výroby a snížení vytvořeného odpadu. S menší produkcí odpadu se poté sníží náklady na surový materiál. [37]
5. **Překonání nedostatku pracovních sil:** Vzhledem k vysoké náročnosti některých výrobních procesů je lepší přenechat práci strojům, čímž dochází k ušetření nákladů za personál a rezervování zbývajících lidských sil na jiné činnosti s vyšší hodnotou. [37]
6. **Zvýšení kvality procesů:** Strojové vidění hned rozpozná změny v kvalitě produktu a zároveň je možno uchovávat vizuální záznamy v každém kroku výroby. Tyto nashromážděná data mohou odhalit nedostatky ve výrobním procesu a odhalit nesprávnou funkci strojů, což umožňuje postupně zdokonalovat celkový proces a tím také kvalitu produktu. [37], [42]
7. **Dodržování regulací:** Uschovaná data z výroby mohou být použita pro doložení dodržování předpisů, což je důležité v oblastech lékařství, potravinářství a mnoho dalších odvětví s přísnými regulacemi. [37], [39]
8. **Zvýšení bezpečnosti:** Díky možnosti monitorování výrobního procesu přes kamery dochází k menší potřebě interakce personálu s hlučnými a potenciálně nebezpečnými stroji. V případě výskytu závady je často možné ji diagnostikovat na dálku, čímž dochází k dalšímu poklesu rizika, které může nastat s kontaktem některých strojů. [37], [38]
9. **Monitorování a zpětná vazba v reálném čase:** Neustálé sledování klíčových výrobních parametrů pomáhá s předčasnou detekcí závad. S okamžitou zpětnou

vazbou je možno rychle provádět nápravné akce, což může značně snížit dobu zastávek ve výrobě. [42]

## 2) Nevýhody:

1. **Vysoké počáteční náklady:** Zavedení kompletního nového systému strojového vidění je ze začátku velmi cenově nákladné. Je potřeba vzít v potaz samotnou výrobní linku, ke které jsou následně přidány všechny potřebné kamery či senzory, samotné jednotky pro zpracování obrazu a jejich software. [36]
2. **Závislost na osvětlení:** Pokud není součástí procesu dostatečně kvalitní osvětlení, bude to mít zásadní dopad na výslednou analýzu snímků, což bude vést k nedokonalému výrobnímu procesu. [36]
3. **Limitovaná flexibilita při změně prostředí:** Při změně nějakého klíčového parametru ve smyčce strojového vidění by mohlo dojít k nestabilní analýze obrazu, například při změně osvětlení scény kamery. Dále může dojít k nekompatibilitě při změně hardwarových a softwarových složek. [36]
4. **Náklady na údržbu:** Vzhledem k vysoké technické náročnosti této části automatizace je potřeba mít k dispozici řádně kvalifikovaný personál, ať už pro návrh nového systému nebo udržování těch stávajících v provozu. [36]

Ze shrnutí výhod a nevýhod lze vidět, že strojové vidění zajišťuje nadřazenou formu výroby, kontrolu procesů a produktů oproti manuální výrobě. Avšak je potřeba brát ohled na správnou implementaci těchto systémů a aktivně je udržovat, aby byl zajištěn správný výrobní provoz.

## 5 NEURONOVÉ SÍTĚ

Umělé neuronové sítě (anglicky Artificial neural networks – ANNs) jsou podmnožina technologií v oblasti strojového vidění. Původní myšlenkou bylo napodobit strukturu a funkci neuronů v lidském mozku, z čehož byl odvozen název této technologie. Jak již vypovídá název, jedná se o propojení jednotek nebo uzlů zvaných umělé neurony.

Každý umělý neuron přijímá signály od sousedících připojených neuronů, které jsou zpracovány a výsledek je poslán dále v řetězci neuronů. Tento signál bývá vyjádřen jako číselná hodnota a výstupy jednotlivých neuronů jsou reprezentovány nějakou nelineární funkcí záviselou na celkové velikosti vstupního signálu. Každý signál má vlastní váhu, která se mění s procesem učení sítě. Zde je vidět podobnost funkce s lidským mozkem, avšak struktury umělých sítí mohou být velmi různé, zejména v počtu samotných neuronů a počtu vrstev, do kterých jsou neurony rozmístěny. Stručně se jedná o několik vrstev neuronů vzájemně mezi sebou propojené, kde je vstupní vrstva, n-počet skrytých vrstev, kde probíhá transformace dat, a naposledy výstupní vrstva. Vzhledem k rozsáhlosti a komplexnosti neuronových sítí bude tato kapitola sloužit jen jako náhled do tohoto tématu. [43]

### 5.1 Historie a vývoj


Práce v oblasti neuronových sítí započaly již na začátku 20. století, avšak pouze nepřímo, ve formě pokroků fyziky, psychologie a neuropsychologie. Tento vědecký rozvoj položil základy obecným teoriím učení, podmiňování, vize, aj. Moderní pohled na neuronové sítě se objevil až ve 40. letech, kdy v principu bylo dokázáno, že umělé neurony mohou vypočítat jakoukoliv aritmetickou či logickou funkci.

První praktická aplikace přišla v pozdních 50. letech ve formě perceptronu, což je nejjednodušší typ neuronové sítě. Zde Frank Rosenblatt a jeho tým demonstroval schopnost rozpoznávání vzorů za použití neuronových sítí, což vyvolalo obrovský zájem v oblasti vývoje neuronových sítí. Po odhalení limitů tehdejších sítí byl vývoj z velké části opuštěn a další znatelné pokroky nastaly v 80. letech, kdy byl nedostatek nových nápadů a dost výkonných počítačů překonán. Prvním obrovským přínosem v této době bylo použití statistických mechanik pro popis funkcí rekurentních sítí. Druhým klíčovým objevem byl vynález algoritmu zpětného šíření, využívaný pro trénování vícevrstvého perceptronu. Od této doby se vývoj neuronových sítí velice rozšířil, kdy bylo publikováno spousta vědeckých článků a neuronové sítě začaly nacházet uplatnění v praxi. [44]

## 5.2 Princip hlubokého učení

Hluboké učení je podmnožina strojového učení, která se zabývá učením neuronových sítí s velkou hloubkou. Hloubkou sítě je myšlen počet vrstev neuronů, jež jsou propojeny tak, že výstup jedné vrstvy je vstupem další vrstvy (obr. 11). Počet vrstev v hlubokých sítích se většinou pohybuje v řádu desítek, ovšem to není pravidlem. Požadované rozměry a komplexnost sítě záleží na dané aplikaci.

Jak již bylo zmíněno v úvodu, neuronové sítě jsou tvořeny jednotlivými neurony propojených mezi sebou v několika vrstvách. Každý tento neuron vytváří posloupnost aktivace reálných hodnot. Vstupní neurony jsou aktivovány přes senzory vnímající prostředí (tedy získaná data z tohoto prostředí), neurony ve vnitřních vrstvách jsou vybuzeny hodnotami z předešle aktivovaných neuronů a tak dále. Učení, neboli nastavování vah neuronů, spočívá v nalezení takových hodnot, že výsledná neuronová síť bude vykazovat požadované chování. V závislosti na řešeném problému a způsobu zapojení neuronů může takové chování vyžadovat dlouhé řetězce výpočetních kroků, kde každý krok transformuje (často nelineárně) souhrnnou aktivaci sítě. Celý proces hlubokého učení spočívá právě v tomto přiřazování vah jednotlivým neuronům. [48]



Obrázek 11 Hluboká plně propojená dopředná neuronová síť s osmi vrstvami

(zdroj: [47])

### 5.2.1 Hluboké učení pod dohledem

Pojmem učení pod dohledem (nebo také učení s učitelem) se rozumí to, že pro trénování sítí jsou použita označená data. Trénovací data jsou tedy vstupní objekty, které mají přiřazené požadované výstupní ohodnocení. V praxi můžou být data označena ve formě např. OK a NOK, tedy vstup je žádaný neboli bez chyby nebo nežádaný, tedy obsahuje vadu. Další možný způsob označení dat je třídění do jednotlivých kategorií, např. označení fotek podle typu zvířete na fotce. V případě učení pod dohledem má tedy sada vstupů odpovídající výstupy. Při učení je zpětnou vazbou hodnota ztráty (loss value). Na základě této hodnoty model iterativně upravuje parametry sítě pro získání lepší aproximace žádaného výstupu. Po úspěšném učení by měl model správně reagovat na vstupní podněty z prostředí. Existují různé přístupy pro realizaci hlubokého učení pod dohledem, jako jsou hluboké neuronové sítě (Deep neural networks – DNN), konvoluční neuronové sítě (Convolutional neural networks – CNN), rekurentní neuronové sítě (Recurrent neural networks – RNN), aj. [45]

### 5.2.2 Hluboké učení bez dozoru

Systémy učení bez dozoru (známo také jako učení bez učitele) jsou schopny fungovat bez označených vstupních dat. V tomto případě se model učí vnitřní reprezentaci a zkoumá důležité rysy, ze kterých odvozuje neznámé vazby nebo strukturu ve vstupních datech. Učení bez dozoru lze vnímat jako kompresi vstupních dat, kde data jsou zpracována např. vyhlazováním, redukcí na diskrétní body nebo snížením jejich dimenze. Učení bez dozoru tedy vykazuje samoorganizaci, jejíž výstupem je hustota pravděpodobnosti. Není zde vyhodnocována správnost výsledku, jelikož požadovaný výsledek není znám. Vstupní data jsou tedy roztržena do různých skupin a model reaguje podle jejich typického zástupce. Sítě určené pro učení bez dozoru jsou např. autoenkodéry (Auto-encoders – AE), omezené Boltzmannovy stroje (Restricted Boltzmann machines – RBM) a generativní soupeřící sítě (Generative adversarial networks – GAN). [45]

### 5.2.3 Hluboké učení s částečným dohledem

Tato forma učení pracuje pouze s částečně označenými datovými sety. Většinou je použit malý vzorek označených dat a velký zbytek dat je neoznačen. Cílem tohoto učení je získání funkce, která dokáže přesně předpovídat výstupní proměnné závislé na vstupu, podobně jako u učení s učitelem. Učení s částečným dohledem je užitečné v takových případech, kde je k dispozici velké množství neoznačených dat, jejichž označení by bylo příliš náročné nebo drahé. [46]

### 5.3 Architektury sítí


Existuje spousta typů neuronových sítí a variací na různé typy architektur, proto zde bude stručně uvedeno jen několik dominantních architektur a příklad jejich použití v praxi.

#### 5.3.1 Hluboká neuronová síť

Hluboké neuronové sítě (DNN) obsahují několik vrstev mezi vstupní a výstupní vrstvou. Dá se říci, že hluboké neuronové sítě je množina různých variací sítí, avšak všechny tyto variace mají společné základní prvky, které jsou neurony, synapse, váhy a funkce. Typický je tento typ sítí považován za dopředné sítě, tedy data postupují ze vstupní vrstvy dopředu bez žádných zpětných smyček. Ukázka možného zapojení již byla uvedena obr. 11. [49]

#### 5.3.2 Konvoluční neuronová síť

Konvoluční neuronové sítě (CNN) jsou obvykle používány pro klasifikaci obrazu díky své schopnosti určení korelace mezi blízkými pixely v obrazu. V typické architektuře CNN je několik prvních vrstev tvořeno tzv. konvolučními bloky (convolutional block), které jsou proloženy sdružujícími vrstvami (pooling layer). „Pooling“, neboli sdružování, je technika převzorkování používaná pro získání souhrnných statistik z analýzy regionů v obrazu. Nejběžněji používaná metoda je „max-pooling“, při níž je z regionu vybrána právě maximální získaná hodnota aktivace neuronu. Sdružování pomáhá snížit složitost celkového modelu a současně umožňuje učení reprezentací, které jsou neměnné vůči malým lokálním transformacím vstupních dat. Z ukázky na obr. 12 je zřejmé, že CNN nemají zpětné smyčky, jsou tedy dopředné stejně jako DNN. [49]




Obrázek 12 Ukázka architektury vrstev konvoluční neuronové sítě

(zdroj: [45])

### 5.3.3 Rekurentní neuronová síť

Rekurentní neuronové sítě (RNN) se zásadně liší od již zmíněných sítí v tom, že obsahují zpětné smyčky, tzn. data mohou cestovat od výstupní vrstvy do vstupní. Znamená to tedy, že pokud jsou vstupem do RNN data s časovou posloupností, síť si udržuje vnitřní stavy o zpracování dat z jednoho časového kroku na další. Tyto předchozí stavy ovlivňují transformaci aktuálních dat, což může být výhodné pro odhalení časových závislostí v datech. Tedy s postupem času a obměnou dat dokážou tyto sítě „zapomínat“ nerelevantní data a učit se podle aktuálních vstupů, což může být vnímáno jako výhoda ale i problém. Právě kvůli této limitaci učení se závislostí vzdálených dat vznikly další typy RNN, které řeší tento problém. Variací této sítě je systém Long short-term memory (LSTM), který dokáže detekovat závislosti mezi datovými body, jež jsou od sebe velice časově vzdáleny. Rekurentní neuronové sítě nalézají využití zejména v rozpoznávání rukopisu a řeči nebo pro realizaci generativních velkých jazykových modelů (Generative LLM). [49]




Obrázek 13 Schéma uspořádání vrstev neuronů v rekurentní neuronové síti

(zdroj: [50])

### 5.3.4 Autoenkodéry

Autoenkodér (AE) je typ neuronové sítě, která je používána pro učení kompaktní reprezentace vstupních dat, které mohou být poté znovu rekonstruovány. Celý systém se skládá z jednotlivých částí, tj. enkodérová síť, skrytý latentní vektor, což jsou prakticky komprimovaná data, a dekodérová síť. V první fázi jsou vstupní data zmapována do prostoru

rysů dat s nižší dimenzí, dokud není dosaženo požadovaného rozměru prvků. Při opačném procesu dekódování jsou původní rysy generovány z této nižší prostorové dimenze. Autoenkodéry nalézají aplikaci v oblastech bio-informatiky a kybernetické bezpečnosti, nebo jsou také používány při kódování a dekódování dat pro jiné neuronové sítě. [45] [51]




Obrázek 14 Obecná struktura autoenkodéru

(zdroj: [51])

### 5.3.5 Generativní soupeřící sítě

Tento přístup k hlubokému učení obsahuje dvě neuronové sítě, které proti sobě „soupeří“ ve hře s nulovým součtem, tedy jedna síť si přilepšuje na úkor druhé sítě. V případě generace obrazu, jedna síť (v tomto případě generátor G) začne generovat obraz pomocí Gaussovského šumu, který druhá síť (diskriminátor D) porovná se skutečným obrazem a vyhodnotí jejich podobnost. Tento proces se opakuje, dokud se generovaná data nepodobají těm skutečným. Tento typ sítě lze aplikovat např. pro zpracování obrazu, audia nebo řeči. [45]



Obrázek 15 Diagram znázorňující princip funkce generativních soupeřících sítí

(zdroj: [45])

## 5.4 Příprava dat

Klíčovou částí při trénování neuronových sítí je použití kvalitně připravených dat. Je několik způsobů a technik, jak správně předpřipravit trénovací data. Provedením správné přípravy dat je možné několikanásobně zvýšit dosaženou kvalitu trénované neuronové sítě.

### 5.4.1 Vyčištění dat

Jedná se o první krok přípravy datového setu. Zde probíhá odstranění nebo upravení chyb vyskytujících se v datech, aby se zabránilo přenosu těchto chyb do učení sítě. Chyby můžou být např. chybějící hodnoty v tabulkách nebo vada v obrazu. Také je dobré zvážit odstranění extrémních odchylek, jelikož také můžou mít nemalý vliv na funkci modelu. Je však nutné si být jistý, že tyto odchylky nejsou důležitou součástí dat, v takovém případě by po jejich odstranění model zkresleně reagoval na tato reálná data, což také není žádoucí. Naposled je vhodné odstranit duplikátní data, jelikož by mohlo dojít k nadměrné reprezentaci některých dat. [52]

### 5.4.2 Škálování dat

Je důležité, aby všechna trénovací a následně vstupní data měla stejné rozměry, jelikož většina neuronových sítí je na změnu měřítka dat senzitivní a ovlivní tak jejich funkci. Běžnou praktikou je použití technik normalizace, kde je měřítko dat upraveno do specifického rozmezí hodnot nebo metod standardizace, kde jsou data soustředěna kolem průměru s určitou směrodatnou odchylkou. [52]

### 5.4.3 Augmentace dat

Augmentace dat je velice výhodná, pokud je k dispozici malé množství trénovacích dat. Jedná se o modifikaci již existujících dat, např. oříznutí, rotace, převrácení nebo přidání šumu. Další výhodou mimo zvětšení vzorku dat je to, že síť se naučí lépe zobecňovat data, čímž se sníží riziko přeučení neuronové sítě na původním datovém setu. [52]

### 5.4.4 Rozdělení dat

Běžnou praktikou je rozdělení datového setu na trénovací set, validační set a testovací set. Trénovací a validační sety jsou použity při učení sítě, kde model je učen na trénovacím setu a následně ověří svou přesnost na validačním setu, z jehož vyhodnocení upraví učící parametry. Poslední testovací set je použit k poslední evaluaci naučené sítě na datech, které nebyly určeny k učení. Typické rozdělení na jednotlivé sety je 70 % dat pro trénování, 15 %

pro validaci a 15 % pro testování. Je důležité, aby jednotlivé sety reprezentovaly celkové rozdělení dat, aby bylo zajištěno objektivní vyhodnocení neuronové sítě. [52]

Zde byly uvedeny obecné způsoby přípravy dat, avšak dostupných metod pro přípravu dat je mnoho a každá najde svou specifickou oblast použití. Další způsoby modifikace dat jsou např. kódování kategoriálních výrazů, výplň posloupností, binární klasifikace, úprava distribuce dat, redukce dimenze dat, aj. [47], [52]

## 5.5 Vyhodnocení dat

Neuronová síť může být vyhodnocena z mnoha hledisek pomocí mnoha různých metrik, avšak ne vždy je potřeba použít všechny tyto metody ohodnocení. Důležité je umět se v dosažených výsledcích zorientovat, z čehož lze poté identifikovat možné nedostatky a chyby neuronové sítě. Jeden z hlavních nástrojů vyhodnocení kvality klasifikace neuronové sítě je tzv. matice záměn (confusion matrix).

|                                      |          | Desired target class from training data $y$ |                             |
|--------------------------------------|----------|---------------------------------------------|-----------------------------|
|                                      |          | Positive                                    | Negative                    |
| Predicted class from model $\hat{y}$ | Positive | <b>TP</b><br>True Positive                  | <b>FP</b><br>False Positive |
|                                      | Negative | <b>FN</b><br>False Negative                 | <b>TN</b><br>True Negative  |

Obrázek 16 Matice záměn o dvou hodnotách – pozitivní a negativní

(zdroj: [47])

Matice záměn obsahuje na jedné ose skutečnou hodnotu předpovídaného prvku a na druhé ose je předpovídaná hodnota od neuronové sítě. Jednotlivé buňky obsahují četnost toho, kolikrát byly data označena a jak byla označena. Všechny buňky na diagonále matice jsou považovány za správný výsledek, všechny ostatní jsou chybné. Na ukázkce je zobrazena matice pro binární klasifikaci (pouze dvě možnosti – pozitivní a negativní). Lze však vytvořit matici o větší velikosti a to případech, kdy jsou data rozdělena do více tříd. Pomocí této matice můžeme získat několik dalších metrik, které se běžně používají pro vyhodnocení kvality klasifikace neuronové sítě:

$$\text{Precision } P = \frac{TP}{TP + FP} \quad (1)$$

Parametr  $P$  je podíl pravdivě pozitivních výsledků (TP) z celkového množství relevantních výsledků, tedy součet TP a falešně pozitivních výsledků (FP).

$$\text{Recall } R = \frac{TP}{TP + FN} \quad (2)$$

Parametr  $R$  je podíl pravdivě pozitivních výsledků TP z celkového množství TP a falešně negativních výsledků (FN).

$$\text{Accuracy } Acc = \frac{TP + TN}{TP + FN + FP + TN} \quad (3)$$

Parametr  $Acc$  je míra správné předpovědi pozitiv a negativ ze všech výsledků.

$$F1 - score \ F1 = \frac{2(P * R)}{P + R} \quad (4)$$

Parametr  $F1$  je harmonický průměr parametrů  $P$  a  $R$ .

Existuje mnoho dalších hodnotících parametrů a každý nachází své použití v jiných oblastech. Pár dalších parametrů jsou třeba měření kvality (QM), střední kvadratická chyba (MSE), střední relativní chyba (MRE), střední absolutní chyba (MAE), průsečík nad sjednocením (IoU), koeficient determinace ( $R^2$  score), aj. [47], [53]

## 5.6 Použití

Neuronové sítě v dnešní době našly uplatnění ve všech dominantních oblastech průmyslu, ale i mimo průmyslové zaměření. Pokud se podíváme na neuronové sítě toho hlediska, že se jedná o podkategorii strojového vidění, může být odvozena aplikace této technologie v průmyslovém prostředí. Hluboké učení tedy lze použít pro **klasifikaci**, kde je potřeba roztrždit několik produktů na jednotlivé kategorie. Dále je zde **detekce objektů**, která může být použita pro ověření kompletnosti balení. Následuje **detekce anomálií**, klíčová technologie pro kontrolu výrobků. Další důležitá aplikace je technologie **Deep OCR**, tedy rozeznávání textu a znaků v obrazu. Dále je tu možnost **segmentace**, což je v podstatě identifikace a označení rysů v obrazu od pozadí. Všechny tyto praktiky mohou nalézt uplatnění nejen v medicínském, potravinářském, leteckém, výrobním a zemědělském průmyslu. Typické použití neuronových sítí je právě tam, kde se pracuje s obrovskými daty a je potřeba je rychle a kvalitně zpracovávat. [54]

## **II PRAKTICKÁ ČÁST**

## 6 PŘÍPRAVA

Prvním krokem praktické části byla instalace aplikací HALCON a Deep Learning Tool (dále jen DLT) z oficiálních zdrojů a patřičnými licencemi [55]. Následně byla provedena rešerše ohledně používání uvedených aplikací z volně dostupných materiálů. Jak MVTec tak Zebra Technologies poskytují spoustu návodů a dokumentace ke svým produktům. MVTec dává k dispozici videa a tutoriály zcela zdarma dostupné na jejich webu [56] spolu s dokumentací [57]. Detailnější návody a postupy pro celou řadu aplikací jsou dostupné na MVTec Academy [58], jenž je také kompletně zdarma, stačí se pouze zaregistrovat. Na druhou stranu dokumentace od Zebra Technologies není tak lehce dostupná. Dávají k dispozici spoustu videí a návodů na portálu Zebra Vision Academy [59], avšak pouze malá část z nich je dostupná zdarma, pro získání přístupu ke všem je potřeba získat přístupový klíč dodávaný s koupí produktu. Zdroje pro všechny popsané funkce a prvky v daných aplikacích v následujících kapitolách pochází z dostupných manuálů přímo v konkrétní aplikaci.

### 6.1 Příprava dat

Pro realizaci k této práci je potřeba velké množství dat, konkrétně spousta fotek sazenic. Není úplně ekonomické ani praktické použít všechny dostupné fotky sazenic o velikosti několik set gigabytů či dokonce jednotek terabytů, proto byl vytvořen jeden set fotografií, který bude postupně upravován.

Tento set se skládá z fotografií pořízených ze dvou kamer, tedy některé sazenice se můžou vyskytnout vícekrát, avšak vyfocené z jiného úhlu. Každá fotografie má stejné parametry, tedy rozlišení 1200x1920 pixelů a 24-bitovou hloubku. Pro lepší manipulaci byly fotky převedeny z formátu .bmp na formát .jpg, čistě z hlediska velikosti souborů. Níže na obr. 17 je uvedena jedna fotografie reprezentující celý neupravený datový set. Tento set fotografií je rozdělen do dvou složek nebo-li skupin, které jsou pojmenovány OK a NOK, tedy sazenice, které jsou v pořádku a které jsou určeny pro vyřazení. Skupina OK obsahuje celkem 5800 fotek a skupina NOK obsahuje 1014 fotek. Sazenice byly takto rozděleny již používaným třídícím softwarem a následně byly fotky manuálně překontrolovány, to však ale nezaručuje, že všechny sazenice mají správně přiřazenou skupinu, jelikož se vždy můžou vyskytnout chyby.



Obrázek 17 Ukázka neupravené fotografie sazenice

*(zdroj: vlastní)*

Na ukázce je již na první pohled zřejmé, že takový formát nebude úplně ideální pro trénování neuronových sítí. Prvním problémem je to, že na fotce se můžou vyskytnout dvě sazenice zároveň, což může naučená síť vyhodnotit jako vadný kus. Druhý problém je to, že většinu obrázku zabírá pozadí, takže neuronová síť by zbytečně analyzovala prázdnou oblast a také samotné rysy sazenice zde nejsou tak dominantní. Řešením je tedy oříznout všechny fotografie tak, aby byla viditelná pouze jedna sazenice a zároveň tak zvýraznit její strukturu. Rozměry všech oříznutých fotografií jsou nyní 500x1000 pixelů.



Obrázek 18 Ukázka upravené fotografie sazenice

*(zdroj: vlastní)*

Poslední krok přípravy spočívá v roztrídění fotek do jednotlivých setů s různou velikostí, aby bylo vidět, jak moc velký vliv má počet dat na trénování neuronových sítí. Všechny vytvořené sety pro trénování byly použity ve stejné formě jak v aplikaci DLT, tak v aplikaci Matrox Imaging Library Copilot. Níže je uveden popis jednotlivých setů, jejich struktura a počet fotek v každém setu.

1. **stromky\_full** – kompletní neořezané fotky (OK – 5800, NOK – 1014)
2. **stromky\_cropped** – kompletní ořezané fotky (OK – 5800, NOK – 1014)
3. **stromky\_sorted** – vychází ze setu stromky\_cropped, fotky byly ještě jednou manuálně pročištěny (OK – 5264, NOK – 959)
4. **stromky\_balanced** – vychází ze setu stromky\_sorted, zmenšený počet fotek tak, aby OK a NOK kategorie byly vyrovnané (OK – 948, NOK – 959)
5. **stromky\_balanced\_2** – vychází ze setu stromky\_balanced, redukce počtu a detailnější manuální výběr fotek (OK – 510, NOK – 461)
6. **stromky\_balanced\_3** – vychází ze setu stromky\_balanced\_2, redukce počtu fotek a rozdělení na více kategorií podle velikosti sazenic (OK\_BIG – 250, OK\_SMALL – 250, NOK\_BIG – 151, NOK\_SMALL – 149)
7. **stromky\_balanced\_4** – vychází ze setu stromky\_balanced\_3, redukce počtu fotek (OK\_BIG – 100, OK\_SMALL – 100, NOK\_BIG – 100, NOK\_SMALL – 100)
8. **inference** – náhodně vybrané fotky ze setu stromky\_cropped, tento set je určený pro finální testování všech neuronových sítí (OK – 500, NOK – 500)

## 7 PROVEDENÍ V PROGRAMU HALCON A DEEP LEARNING TOOL


Dalším krokem po vytvoření datového setu pro trénování neuronové sítě je pojmenování těchto dat. V tomto případě jsou jména složek, ve kterých se nacházejí fotky, použity pro „labeling“. Trénování tedy bude probíhat ve stylu učení pod dohledem, což již bylo popsáno v teoretické části práce. Při práci s produkty od firmy MVTec (popis produktů v kapitole 3.8) jsou zde dvě možnosti, jak postupovat. Buď může být použita aplikace DLT pouze pro vytvoření struktury datového setu, který bude poté použit při trénování, evaluaci a inferenci v aplikaci HALCON, nebo všechny kroky trénování budou provedeny v DLT, kde finální model bude exportován a využit pro inferenci v programu HALCON. Všechny 4 kroky nelze provést pouze v jedné z těchto aplikací, proto musí být použity oboje, avšak volba už spočívá na uživateli. DLT poskytuje přehlednější pracovní rozhraní, avšak HALCON může poskytnout větší flexibilitu kvůli tvoření programů pomocí kódu. V tomto případě bude HALCON použit pouze pro finální část, tedy inferenci, právě kvůli snadnějšímu použití aplikace DLT při trénování.

### 7.1 Deep Learning Tool

Následující část se zabývá popisem všech použitých nástrojů a funkcí v programu DLT. Po uvedení těchto funkcí budou uvedeny a porovnány dosažené výsledky.

#### 7.1.1 Příprava projektu

Prvním krokem při vytvoření nového projektu je výběr typu hlubokého učení, který chceme použít. V rámci této práce byly použity metody „Anomaly Detection“ a „Classification“, tedy detekce anomálií a klasifikace. Všechny možné typy jsou uvedeny na obrázku níže.




Obrázek 19 Vytvoření projektu v DLT

(zdroj: vlastní)

### 7.1.2 Importování datového setu

Dalším krokem je importování fotografií. Na obr. 20 níže v záložce Gallery (1.) lze prohlížet všechny importované fotografie a také zde můžou být upraveny jejich označení. Importovat lze přímo celou složku s fotografiemi (2.) a pokud jsou fotky rozděleny do adresářů, tak můžou být fotky přímo rozděleny podle těchto adresářů. Konkrétně zde v projektu detekce anomálií se fotky dělí do kategorií „good“ a „anomaly“. Dále je možno fotky nebo celý projekt různě upravit (3.), např. změnit jas, kontrast, velikost náhledů fotek, aj. Naposled lze podrobně prohlížet fotografie v záložkách Image a Review (4.)




Obrázek 20 Popis záložky Gallery v DLT

(zdroj: vlastní)

### 7.1.3 Vytvoření splitu

Následně je nutno vytvořit split (1.), tedy rozdělit data na trénovací, validační a testovací set. Program automaticky nabízí rozložení 70/15/15, avšak je možnost si zvolit vlastní rozdělení (2.). Níže lze vidět grafické rozložení setů podle jednotlivých kategorií (3.) a také trénovací modely, které používají daný split (4.). Split nelze editovat, pokud je již používán pro trénování.



Obrázek 21 Popis záložky Split v DLT


(zdroj: vlastní)

### 7.1.4 Nastavení trénovacího modelu

Dále je na řadě samotné nastavení trénovacího procesu, okno je opět zobrazeno na obr. 22. Je zde možno nastavovat mnoho parametrů, kde každý z nich má různý dopad na výsledek trénování. Na obrázku níže jsou uvedeny všechny nastavitelné parametry a jejich stručný popis.

1. Vytvoření trénovacího modelu
2. Výběr již vytvořeného splitu, který má být použit pro trénování
3. Nastavení neuronové sítě:
  - V záložce Pretrained model je na výběr použití globální sítě, lokální sítě nebo obojí zároveň. Globální síť je především určená pro detekci logických anomálií v rámci celého obrazu. Na druhou stranu lokální síť je dobrá při detekování anomálií na malém měřítku, zejména strukturální anomálie.

- Image width a height určují šířku a výšku použitých fotografií v pixelech. Je vhodné zmenšit velikost fotek pro rychlejší trénování a menší dobu inference, avšak anomálie musí být stále čistě rozeznatelné. Pokud jsou rozměry změněny, tak je vhodné upravit také fotografie při inferenci na stejné rozměry použité při trénování, jinak může dojít k menší přesnosti modelu.
  - Patch size: ovlivňuje velikost oblasti analyzovanou lokální sítí
  - Num channels: vybírá počet barevných kanálů, 3 pro RGB a 1 pro černobílý obraz
4. Konfigurace: zde je možno vybrat, zda má k trénování být použito CPU nebo GPU, volba seedu a možnost použít deterministické algoritmy, které můžou vyřešit problémy s pamětí na některých grafických kartách
5. Trénovací parametry:
- Number of epochs: jedná se o celkový počet epoch trénování. Jedna epocha se rovná počtu iterací provedených na celém trénovacím setu. Tato hodnota je závislá na počtu iterací
  - Number of iterations: celkový počet iterací trénování. Jedna iterace je stav, kdy jedna dávka projde celou sítí. Při detekci anomálií je velikost dávky 1, tedy jedna fotka je analyzována v jeden okamžik, avšak při klasifikaci je tento parametr nastavitelný. Základní počet iterací je 70000 a není zapotřebí ho měnit.
  - Learning Rate: parametr určující míru změny vah při učení. Příliš velké hodnoty mohou vést k divergování ztrátové funkce, naopak příliš malé hodnoty se mohou zaseknout v lokálním minimu, čímž nebudou dosaženy nejlepší možné výsledky trénování. Přednastavená hodnota je 0,0001 s tím, že po 95% trénování je tento parametr o jeden řád snížen.
  - Weight Prior: regulační parametr penalizující vysoké hodnoty vah, určený pro prevenci přeučení modelu.
6. Augmentace: je zde několik způsobů, jak modifikovat fotky při trénovacím procesu, jako je rotace, zrcadlení, změna jasu, kontrastu a saturace. Augmentace je vhodná v případech, kdy je k dispozici málo vstupních dat. Pokud je v tabulce 1 uvedeno, že při učení modelu byla použita augmentace, byly vybrány přesně takové parametry, jaké jsou vybrány na obr. 22, tedy variace jasu, kontrastu a saturace o 20 % na 100 % fotek.



Obrázek 22 Popis záložky Training – Settings v DLT

(zdroj: vlastní)

Po úspěšném nastavení trénovacího modelu lze v reálném čase sledovat průběh trénování (obr. 23), zejména průběhy ztrátové funkce (3.) a získaného F1-score z evaluačního setu (4.). Na levé straně okna jsou uvedeny parametry jako zbývající čas, hodnota ztrátové funkce, počet epoch a iterací (1.) a naposled nejvyšší hodnota F1-score (2.)



Obrázek 23 Popis záložky Training – Results v DLT

(zdroj: vlastní)

### 7.1.5 Popis evaluace vytvořeného modelu

Po dokončení trénování, popřípadě přerušení trénování v případě, že již nedochází k dosažení lepších výsledků, zbývá finální testovací část. (obr. 24)


1. Selection of images for evaluation: zde se volí všechny fotografie, které mají být použity pro evaluaci modelu. Základní nastavení a běžná praktika je použití testovacího a evaluačního set právě proto, že model nebyl na těchto datech trénován.

Inference and evaluation settings: výběr GPU nebo CPU a velikosti zpracované dávky najednou, změna těchto parametrů může urychlit evaluaci, ale limitací je hardware.

Postprocessing parameters: zde je možné upravit několik parametrů po evaluaci, jako např. upřesnit doménu hledání anomálií, změnit klasifikační hranici, segmentační hranici, aj. Lze takto lehce doladit chování modelu, avšak změny se projeví na všech fotkách stejně, takže může dojít ke zlepšení výsledků na nějakých datech a ke zhoršení na několika jiných. Z tohoto důvodu nebyly tyto parametry nijak manuálně měněny.

2. Global measures: zde jsou vidět hodnotící parametry F1-score, precision, recall a doba inference fotografie. V záložce Class overview jsou uvedeny stejné parametry pro jednotlivé třídy.
3. Score histogram: ukazuje rozdělení analyzovaných dat z hlediska jejich skóre. Jedna hranice udává zlomek dat, který byly klasifikované jako „good“, další hranice všechny data klasifikované jako „anomaly“ a mezi nimi je průseč dat, které byly klasifikovány jako „good“ i „anomaly“. V této oblasti je možno si zvolit třetí hranici „Classification threshold“, jejíž změna se projeví také na parametrech v Global measures, jelikož se mění poměr klasifikovaných dat. Tímto lze dopravit finální exportovaný model, pokud by např. bylo pro aplikaci výhodnější mít striktnější hranici klasifikace vyřazování vadných kusů na úkor vyřazení i několika dobrých kusů. Pro jednotnost výsledků bude v této práci tato hranice nastavena v průsečíku těchto dvou křivek.
4. Confusion matrix: rozdělení všech analyzovaných fotek do matice záměn

5. Images: sbírka analyzovaných fotek s informacemi např. o jejich předpovězené klasifikaci a pravdivém označení, hodnotě získaného skóre, aj. Je možno zde zapnout teplotní mapu a pozorovat regiony, kde model identifikuje anomálie.



Obrázek 24 Popis záložky Evaluation v DLT

(zdroj: vlastní)

Po nastavení všech potřebných parametrů již pouze zbývá model exportovat. Všechny modely byly vytvořeny stejným postupem a posledním krokem je tedy aplikovat tyto exportované modely do vytvořeného programu v HALCONu.

### 7.1.6 Výsledky trénování v DLT – detekce anomálií

V tabulce 1 jsou uvedeny všechny parametry použité při nastavení trénovacího procesu v DLT, jak bylo popsáno v předchozí kapitole. Sloupec „Číslo v tabulce“ slouží jako identifikátor daného modelu v následujících tabulkách, jelikož není možné vložit všechny data do jedné tabulky. V každém rozdílném typu modelu (klasifikace, detekce anomálií) je šedou barvou zvýrazněn jeden model s nejlepšími výsledky **při inferenci**. Všechny tyto modely budou v následujících kapitolách porovnány.

Tabulka 1 Všechny vytvořené projekty v DLT typu „anomaly detection“ a jejich nastavení

| Číslo v tab. | Název projektu | Dataset    | Split    | Použitý model | Rozlišení | Patch size | Learning rate | Aug. |
|--------------|----------------|------------|----------|---------------|-----------|------------|---------------|------|
| 1            | BP_trees_4-1   | full       | 70/15/15 | G&L           | 300x480   | 20         | 5E-04         | Ano  |
| 2            | BP_trees_5-1   | cropped    | 70/15/15 | G&L           | 125x250   | 15         | 5E-04         | Ano  |
| 3            | BP_trees_5-2   | cropped    | 70/15/15 | G&L           | 250x500   | 15         | 5E-04         | Ano  |
| 4            | BP_trees_5-3   | cropped    | 70/15/15 | Global        | 250x500   | /          | 1E-03         | Ne   |
| 5            | BP_trees_6-1   | balanced   | 70/15/15 | G&L           | 125x250   | 15         | 5E-04         | Ano  |
| 6            | BP_trees_6-2   | balanced   | 70/15/15 | G&L           | 250x500   | 15         | 5E-04         | Ano  |
| 7            | BP_trees_6-3   | balanced   | 70/15/15 | G&L           | 500x1000  | 25         | 5E-04         | Ano  |
| 8            | BP_trees_6-4   | balanced   | 70/15/15 | Global        | 125x250   | /          | 5E-04         | Ano  |
| 9            | BP_trees_6-5   | balanced   | 70/15/15 | Global        | 250x500   | /          | 5E-04         | Ano  |
| 10           | BP_trees_6-6   | balanced   | 70/15/15 | Global        | 500x1000  | /          | 5E-04         | Ano  |
| 11           | BP_trees_6-7   | balanced   | 70/15/15 | Global        | 250x500   | /          | 1E-03         | Ne   |
| 12           | BP_trees_7-1   | balanced_2 | 70/15/15 | G&L           | 125x250   | 10         | 5E-04         | Ano  |
| 13           | BP_trees_7-2   | balanced_2 | 70/15/15 | Local         | 250x500   | 15         | 5E-04         | Ne   |
| 14           | BP_trees_8-1   | balanced_3 | 70/15/15 | G&L           | 125x250   | 10         | 5E-04         | Ano  |
| 15           | BP_trees_8-2   | balanced_3 | 70/15/15 | G&L           | 250x500   | 15         | 5E-04         | Ano  |
| 16           | BP_trees_8-3   | balanced_3 | 70/15/15 | G&L           | 500x1000  | 33         | 5E-04         | Ano  |
| 17           | BP_trees_8-4   | balanced_3 | 70/15/15 | Local         | 125x250   | 10         | 5E-04         | Ne   |
| 18           | BP_trees_8-5   | balanced_3 | 70/15/15 | G&L           | 500x1000  | 25         | 5E-04         | Ano  |
| 19           | BP_trees_8-6   | balanced_3 | 70/15/15 | Global        | 125x250   | /          | 1E-04         | Ano  |
| 20           | BP_trees_8-7   | balanced_3 | 70/15/15 | Global        | 250x500   | /          | 1E-04         | Ano  |
| 21           | BP_trees_8-8   | balanced_3 | 70/15/15 | Global        | 500x1000  | /          | 1E-04         | Ano  |
| 22           | BP_trees_8-9   | balanced_3 | 50/50/0  | G&L           | 125x250   | 7          | 5E-04         | Ano  |
| 23           | BP_trees_8-10  | balanced_3 | 50/50/0  | G&L           | 250x500   | 15         | 5E-04         | Ano  |
| 24           | BP_trees_8-11  | balanced_3 | 50/50/0  | G&L           | 500x1000  | 25         | 5E-04         | Ano  |
| 25           | BP_trees_10-1  | balanced_4 | 70/15/15 | G&L           | 125x250   | 10         | 1E-03         | Ano  |
| 26           | BP_trees_10-2  | balanced_4 | 70/15/15 | G&L           | 250x500   | 15         | 1E-03         | Ano  |
| 27           | BP_trees_10-3  | balanced_4 | 70/15/15 | G&L           | 500x1000  | 25         | 1E-03         | Ano  |
| 28           | BP_trees_10-4  | balanced_4 | 70/15/15 | G&L           | 125x250   | 10         | 1E-03         | Ne   |
| 29           | BP_trees_10-5  | balanced_4 | 70/15/15 | G&L           | 250x500   | 15         | 1E-03         | Ne   |
| 30           | BP_trees_10-6  | balanced_4 | 70/15/15 | G&L           | 500x1000  | 25         | 1E-03         | Ne   |

(zdroj: vlastní)

V tabulce 2 níže jsou uvedeny hodnotící parametry F1-score, precision a recall. Tyto parametry budou použity pro srovnání kvality všech vytvořených modelů mezi sebou. Hodnoty ve sloupci „F1-score, graf“ a „Čas trénování“ jsou získané během trénování modelu, ostatní hodnoty jsou získané při evaluaci.

Tabulka 2 Výsledky všech evaluací provedených v DLT pro projekty „anomaly detection“

| Číslo v tab. | Čas trénování | F1-score, graf [%] | F1-score, eval. [%] | Precision [%] | Recall [%] | Inference time [ms] |
|--------------|---------------|--------------------|---------------------|---------------|------------|---------------------|
| 1            | 11:11:34      | 36,73              | 62,24               | 56,79         | 68,84      | 115,758             |
| 2            | 13:49:35      | 27,16              | 39,67               | 34,09         | 47,44      | 47,487              |
| 3            | 13:14:58      | 25,94              | 46,85               | 40,62         | 55,33      | 186,606             |
| 4            | 3:07:32       | 26,47              | 39,15               | 33,79         | 46,55      | 5,065               |
| 5            | 15:59:40      | 53,46              | 65,13               | 80,62         | 54,64      | 51,612              |
| 6            | 40:48:54      | 60,65              | 62,95               | 78,72         | 52,45      | 163,900             |
| 7            | 23:45:36      | 59,08              | 59,45               | 76,31         | 48,70      | 237,886             |
| 8            | 2:43:54       | 60,33              | 66,54               | 81,54         | 56,20      | 5,441               |
| 9            | 2:44:53       | 68,25              | 81,33               | 90,54         | 73,83      | 5,904               |
| 10           | 10:18:18      | 60,51              | 75,12               | 86,97         | 66,11      | 7,923               |
| 11           | 58:29         | 63,55              | 75,97               | 87,28         | 67,26      | 5,018               |
| 12           | 18:54:18      | 72,49              | 65,99               | 79,51         | 56,40      | 86,441              |
| 13           | 19:51:38      | 73,73              | 61,86               | 76,19         | 52,06      | 178,446             |
| 14           | 25:59:54      | 76,40              | 78,14               | 84,50         | 72,67      | 105,590             |
| 15           | 37:23:05      | 81,68              | 79,79               | 85,23         | 75,00      | 158,692             |
| 16           | 18:40:43      | 78,30              | 73,19               | 80,16         | 67,33      | 147,986             |
| 17           | 20:02:07      | 73,02              | 77,21               | 68,38         | 88,67      | 96,348              |
| 18           | 37:56:59      | 80,98              | 76,26               | 82,81         | 70,67      | 219,843             |
| 19           | 2:44:05       | 82,57              | 75,99               | 82,17         | 70,67      | 5,298               |
| 20           | 2:19:09       | 82,51              | 74,86               | 81,82         | 69,00      | 5,741               |
| 21           | 10:09:53      | 83,48              | 77,06               | 83,33         | 71,67      | 8,266               |
| 22           | 29:07:37      | 69,39              | 73,10               | 75,71         | 70,67      | 197,389             |
| 23           | 25:09:43      | 74,53              | 80,88               | 82,13         | 79,67      | 163,425             |
| 24           | 25:19:07      | 68,84              | 74,06               | 75,87         | 72,33      | 213,845             |
| 25           | 21:16:21      | 93,12              | 90,10               | 94,02         | 86,50      | 82,625              |
| 26           | 26:00:20      | 93,75              | 91,91               | 96,17         | 88,00      | 162,990             |
| 27           | 20:58:00      | 93,68              | 92,47               | 96,22         | 89,00      | 226,003             |
| 28           | 19:10:16      | 94,79              | 92,75               | 96,24         | 89,50      | 82,816              |
| 29           | 25:16:36      | 93,75              | 91,10               | 95,60         | 87,00      | 200,860             |
| 30           | 35:24:04      | 95,34              | 91,38               | 95,63         | 87,50      | 248,977             |

(zdroj: vlastní)

### 7.1.7 Výsledky trénování v DLT – klasifikace

Obdobný formát tabulek, provedení se liší pouze v typu projektu, zde se tedy jedná o klasifikační neuronovou síť, která nehledá anomálie, pouze rozděluje data do různých kategorií.

Tabulka 3 Všechny vytvořené projekty v DLT typu „classification“ a jejich nastavení

| Číslo v tab. | Název projektu | Dataset    | Split    | Použitý model | Rozlišení | Learning rate | Aug. |
|--------------|----------------|------------|----------|---------------|-----------|---------------|------|
| 1            | BP_trees_9-1   | balanced_3 | 70/15/15 | Compact       | 500x1000  | 1E-04         | Ne   |
| 2            | BP_trees_9-2   | balanced_3 | 70/15/15 | Compact       | 250x500   | 1E-04         | Ano  |
| 3            | BP_trees_9-3   | balanced_3 | 70/15/15 | Compact       | 250x500   | 1E-04         | Ne   |
| 4            | BP_trees_9-4   | balanced_3 | 70/15/15 | Enhanced      | 250x500   | 1E-04         | Ne   |
| 5            | BP_trees_9-5   | balanced_3 | 70/15/15 | ResNet-50     | 250x500   | 1E-04         | Ne   |
| 6            | BP_trees_9-6   | balanced_3 | 70/15/15 | ResNet-18     | 250x500   | 1E-04         | Ne   |
| 7            | BP_trees_9-7   | balanced_3 | 70/15/15 | MobileNetV2   | 250x500   | 1E-04         | Ne   |
| 8            | BP_trees_9-8   | balanced_3 | 70/15/15 | AlexNet       | 250x500   | 1E-04         | Ne   |
| 9            | BP_trees_9-9   | balanced_3 | 70/15/15 | Compact       | 125x250   | 1E-04         | Ano  |
| 10           | BP_trees_9-10  | balanced_3 | 70/15/15 | Enhanced      | 125x250   | 1E-04         | Ano  |
| 11           | BP_trees_9-11  | balanced_3 | 70/15/15 | ResNet-50     | 125x250   | 1E-04         | Ano  |
| 12           | BP_trees_9-12  | balanced_3 | 70/15/15 | ResNet-18     | 125x250   | 1E-04         | Ano  |
| 13           | BP_trees_9-13  | balanced_3 | 70/15/15 | MobileNetV2   | 125x250   | 1E-04         | Ano  |
| 14           | BP_trees_9-14  | balanced_3 | 70/15/15 | AlexNet       | 125x250   | 1E-04         | Ano  |
| 15           | BP_trees_11-1  | balanced   | 70/15/15 | ResNet-18     | 250x500   | 1E-03         | Ne   |
| 16           | BP_trees_11-2  | balanced   | 70/15/15 | ResNet-18     | 125x250   | 1E-03         | Ne   |
| 17           | BP_trees_11-3  | balanced   | 70/15/15 | ResNet-18     | 250x500   | 1E-03         | Ano  |
| 18           | BP_trees_11-4  | balanced   | 70/15/15 | Compact       | 250x500   | 1E-04         | Ne   |
| 19           | BP_trees_11-5  | balanced   | 70/15/15 | AlexNet       | 250x500   | 1E-04         | Ne   |
| 20           | BP_trees_12-1  | sorted     | 70/15/15 | ResNet-18     | 250x500   | 1E-03         | Ne   |

(zdroj: vlastní)

Níže jsou vypsány všechny získané výsledky z evaluace v programu DLT. Dalším krokem bude porovnání těchto hodnot se získanými hodnotami z inference v programu HALCON.

Tabulka 4 Výsledky všech evaluací provedených v DLT pro projekty „classification“

| Číslo v tab. | Čas trénování | Top-1 error, graf [%] | Accuracy [%] | Top-1 error, eval. [%] | F1-score, eval. [%] | Mean Precision [%] | Mean Recall [%] | Inference time [ms] |
|--------------|---------------|-----------------------|--------------|------------------------|---------------------|--------------------|-----------------|---------------------|
| 1            | 1:24:38       | 9,17                  | 88,33        | 11,67                  | 87,97               | 87,40              | 89,27           | 122,110             |
| 2            | 1:33          | 7,50                  | 90,00        | 10,00                  | 89,75               | 89,86              | 89,78           | 4,223               |
| 3            | 1:41          | 5,83                  | 88,33        | 11,67                  | 88,11               | 87,75              | 88,84           | 3,982               |
| 4            | 19:49         | 7,50                  | 94,17        | 5,83                   | 93,87               | 93,72              | 94,38           | 88,249              |
| 5            | 1:33:24       | 4,17                  | 95,00        | 5,00                   | 94,72               | 94,16              | 95,52           | 188,331             |
| 6            | 8:28          | 6,67                  | 86,67        | 13,33                  | 86,28               | 86,65              | 87,40           | 8,427               |
| 7            | 48:40         | 5,83                  | 91,67        | 8,33                   | 90,67               | 90,95              | 90,96           | 5,574               |
| 8            | 4:11          | 5,83                  | 92,50        | 7,50                   | 92,16               | 92,70              | 92,55           | 4,414               |
| 9            | 1:07          | 6,67                  | 91,67        | 8,33                   | 91,22               | 90,71              | 91,96           | 1,262               |
| 10           | 1:01          | 4,17                  | 95,83        | 4,17                   | 95,79               | 95,51              | 96,20           | 2,968               |
| 11           | 8:50          | 8,33                  | 95,00        | 5,00                   | 94,35               | 94,67              | 94,15           | 4,261               |
| 12           | 0:44          | 5,83                  | 96,67        | 3,33                   | 96,46               | 96,11              | 96,87           | 2,757               |
| 13           | 2:52          | 8,33                  | 92,50        | 7,50                   | 92,34               | 92,20              | 93,03           | 2,964               |
| 14           | 1:04          | 6,67                  | 92,50        | 7,50                   | 92,01               | 92,19              | 92,14           | 1,277               |
| 15           | 28:48         | 8,74                  | 91,61        | 8,39                   | 91,60               | 91,65              | 91,60           | 34,690              |
| 16           | 1:40          | 6,64                  | 88,11        | 11,89                  | 88,11               | 88,22              | 88,13           | 3,320               |
| 17           | 25:48         | 6,99                  | 89,16        | 10,84                  | 89,16               | 89,20              | 89,17           | 83,860              |
| 18           | 2:41          | 5,94                  | 91,26        | 8,74                   | 91,25               | 91,32              | 91,25           | 3,860               |
| 19           | 7:47          | 10,84                 | 89,16        | 10,84                  | 89,15               | 89,26              | 89,14           | 16,610              |
| 20           | 1:17:27       | 5,36                  | 93,90        | 6,10                   | 87,22               | 91,29              | 84,18           | 9,095               |

(zdroj: vlastní)



### 7.2.1 Kód v HALCONu

Vhledem k tomu, že celý kód má přes 100 řádků, tak zde bude uvedenou a vysvětleno pouze několik úryvků. Celý kód navíc není originální výtvar, části zabývající se inicializací modelu a předzpracováním dat byly převzaty a upraveny z ukázkového programu „dl\_anomaly\_detection\_global\_context\_inference.hdev“ dostupného v ukázkové složce v HALCONu.

```
ImageDir := 'inference'
ImageSubDirs := ['ok', 'nok']
OutputDir := './output'
GenParamDataset := dict{image_sub_dirs: ImageSubDirs}
read_dl_dataset_anomaly (ImageDir, [], [], [], GenParamDataset,
DLDataset)
split_dl_dataset (DLDataset, 0, 0, [])
read_dl_model
('D:/BP/MVTECH/Halcon_DLT/Exported_models/BP_trees_5/3/BP5_model_3.h
dl', DLModelHandle)
create_dl_preprocess_param_from_model (DLModelHandle, 'none',
'full_domain', [], [], [], DLPreprocessParam)
PreprocessSettings := dict{overwrite_files: 'true'}
preprocess_dl_dataset (DLDataset, OutputDir, DLPreprocessParam,
PreprocessSettings, DLDatasetFileName)
```

Tato první část se stará o inicializaci a načtení naučeného modelu. Nejdříve jsou načteny fotky ze složky „inference“, které jsou rozdělené do adresářů ok a nok. Všechny tyto fotky jsou následně vloženy do testovacího splitu. Funkce „read\_dl\_model“ načte model na uvedené cestě na disku. Tento exportovaný soubor obsahuje všechny potřebné parametry pro předzpracování dat, které jsou následně načteny funkcí „preprocess\_dl\_dataset“.

```
for IndexInference := 0 to |InferenceImagePaths| - 1 by 1
  read_image (Image, InferenceImagePaths[IndexInference])
  if (DLPreprocessParam.domain_handling == 'keep_domain')
    reduce_domain (Image, RestrictedDomain, Image)
  endif
  gen_dl_samples_from_images (Image, DLSample)
  preprocess_dl_samples (DLSample, DLPreprocessParam)
  apply_dl_model (DLModelHandle, DLSample, [], DLResult)
  threshold_dl_anomaly_results (InferenceSegmentationThreshold,
InferenceClassificationThreshold, DLResult)
  dev_display_dl_data (DLSample, DLResult, DLDatasetInfo,
['anomaly_result', 'anomaly_image'], [], WindowDict)
```

Po inicializaci dalších proměnných a dokončení předzpracování dat je zde for smyčka, ve které funkce „read\_image“ načte vždy jednu předzpracovanou fotku, na kterou je poté aplikován model funkcí „apply\_dl\_model“. Analyzovaná fotka a její ohodnocení je poté zobrazeno v grafických oknech pomocí funkce „dev\_display\_dl\_data“.

```
get_dict_tuple (DLResult, 'anomaly_class_id', PredClass)
tuple_split (InferenceImagePaths[IndexInference], '\\', Parts)
FolderName := Parts[|Parts| - 2]
if (FolderName == 'ok')
    GTClass := 0
elseif (FolderName == 'nok')
    GTClass := 1
else
    throw ('Unknown ground truth class folder: ' + FolderName)
endif

if (PredClass == 1 and GTClass == 1)
    TP := TP + 1
elseif (PredClass == 0 and GTClass == 0)
    TN := TN + 1
elseif (PredClass == 1 and GTClass == 0)
    FP := FP + 1
elseif (PredClass == 0 and GTClass == 1)
    FN := FN + 1
endif
endfor
```

Pokračování for smyčky obsahuje zápis výsledků do proměnných hodnot, které jsou poté použity pro výpočet metrik Accuracy, Precision, Recall a F1-score. Tyto hodnoty jsou vypočteny na konci programu po tom, co smyčka for procykluje všechny fotky. Funkce „get\_dict\_tuple“ ukládá předpovězený stav anomálie do proměnné PredClass, zatímco skutečný stav uložený do proměnné GTClass je vydedukován podle názvu složky, ve kterém se analyzovaná fotka nachází. Podle těchto získaných stavů je výsledek uložen do jedné z proměnných TP, TN, FP, FN, přesně podle označení matice záměn.

Podobný kód je vytvořen pro klasifikační modely, kde se liší pouze předzpracování a souborová struktura, jelikož model nedělí data na „good“ a „anomaly“, ale na jednotlivé třídy podle toho, na jakém setu byl model trénován. Je tam tedy řešení převod klasifikačních tříd „OK\_SMALL“ a „OK\_BIG“ pouze na „ok“ a obdobně na „nok“.

### 7.2.2 Výsledky inference v HALCONUu

V tabulce 5 jsou vypsány získané parametry všech modelů trénovaných pro detekci anomálií. Ve stejném formátu jsou uvedeny výsledky pro klasifikační modely v tabulce 6.

Tabulka 5 Výsledky inference provedené v HALCONu pro modely „anomaly detection“

| Číslo<br>v tab. | Accuracy<br>[%] | Precision<br>[%] | Recall<br>[%] | F1-score<br>[%] |
|-----------------|-----------------|------------------|---------------|-----------------|
| 1               | 68,00           | 68,22            | 67,40         | 67,81           |
| 2               | 47,70           | 47,10            | 37,40         | 41,69           |
| 3               | 48,30           | 47,79            | 36,80         | 41,58           |
| 4               | 46,70           | 46,12            | 39,20         | 42,38           |
| 5               | 54,10           | 54,53            | 49,40         | 51,84           |
| 6               | 53,30           | 53,67            | 48,20         | 50,79           |
| 7               | 50,50           | 50,58            | 43,00         | 46,83           |
| 8               | 56,40           | 56,99            | 52,20         | 54,49           |
| 9               | 83,90           | 83,97            | 83,80         | 83,88           |
| 10              | 69,70           | 69,13            | 71,20         | 70,15           |
| 11              | 71,70           | 71,40            | 72,40         | 71,90           |
| 12              | 56,90           | 56,70            | 58,40         | 57,54           |
| 13              | 51,50           | 51,47            | 52,60         | 52,03           |
| 14              | 62,50           | 64,30            | 56,20         | 59,98           |
| 15              | 64,00           | 66,13            | 57,40         | 61,46           |
| 16              | 61,20           | 65,14            | 48,20         | 55,40           |
| 17              | 48,00           | 48,86            | 85,60         | 62,21           |
| 18              | 59,00           | 62,16            | 46,00         | 52,87           |
| 19              | 62,20           | 64,01            | 46,60         | 53,94           |
| 20              | 56,20           | 57,95            | 45,20         | 50,79           |
| 21              | 58,00           | 62,35            | 40,40         | 49,03           |
| 22              | 50,30           | 50,39            | 39,20         | 44,09           |
| 23              | 53,60           | 53,98            | 48,80         | 51,26           |
| 24              | 53,60           | 54,25            | 46,00         | 49,78           |
| 25              | 56,20           | 57,35            | 48,40         | 52,49           |
| 26              | 55,60           | 55,69            | 54,80         | 55,24           |
| 27              | 61,50           | 64,56            | 51,00         | 56,98           |
| 28              | 68,10           | 69,55            | 64,40         | 66,87           |
| 29              | 69,90           | 70,10            | 64,40         | 69,75           |
| 30              | 63,80           | 65,68            | 57,80         | 61,49           |

(zdroj: vlastní)

Tabulka 6 Výsledky inference provedené v HALCONu pro modely typu „classification“

| Číslo<br>v tab. | Accuracy<br>[%] | Precision<br>[%] | Recall<br>[%] | F1-score<br>[%] |
|-----------------|-----------------|------------------|---------------|-----------------|
| 1               | 74,10           | 82,83            | 60,80         | 70,13           |
| 2               | 69,30           | 79,69            | 51,80         | 62,79           |
| 3               | 77,00           | 85,53            | 65,00         | 73,86           |
| 4               | 77,30           | 89,11            | 62,20         | 73,26           |
| 5               | 76,00           | 90,12            | 58,40         | 70,87           |
| 6               | 84,30           | 91,93            | 75,20         | 82,73           |
| 7               | 74,60           | 87,96            | 57,00         | 69,17           |
| 8               | 74,20           | 79,80            | 64,80         | 71,52           |
| 9               | 69,90           | 79,18            | 54,00         | 64,21           |
| 10              | 76,50           | 89,09            | 60,40         | 71,99           |
| 11              | 69,10           | 91,70            | 42,00         | 57,61           |
| 12              | 68,00           | 80,41            | 47,60         | 59,80           |
| 13              | 75,40           | 86,08            | 60,60         | 71,13           |
| 14              | 71,80           | 85,16            | 52,80         | 65,19           |
| 15              | 96,80           | 94,83            | 99,00         | 96,87           |
| 16              | 95,80           | 93,70            | 98,20         | 95,90           |
| 17              | 95,60           | 92,86            | 98,80         | 95,74           |
| 18              | 96,90           | 94,84            | 99,20         | 96,97           |
| 19              | 94,30           | 89,91            | 99,80         | 94,60           |
| 20              | 95,30           | 99,13            | 91,40         | 95,11           |


(zdroj: vlastní)

### 7.3 Shrnutí výsledků

Z hotové inference lze hned poznat, že klasifikační modely dosahují mnohem lepších výsledků než modely detekující anomálie. Porovnáním hodnot F1-score v tab. 5 je vidět, že průměrná hodnota se pohybuje okolo 50 % až 60 %, s nejlepší hodnotou dosahující 83,88 % u modelu č. 9. V tab. 6 lze také pozorovat podobný trend, kde se většina modelů pohybuje okolo 70 % hodnot F1-score. Posledních několik modelů však vykazuje velice dobré výsledky s F1-score pohybující se okolo 95 %, kde nejlepší z nich je model č. 18 s hodnotou 96,97 %. Porovnáme-li mezi sebou pouze tyto dvě metody tak je hned jasné, že klasifikační modely jsou mnohem přesnější. Čistě z výsledků těchto klasifikačních modelů lze pozorovat, že velikost trénovacích dat měla velký vliv na dosaženou přesnost. Klasifikační modely 1 až 14 používaly set „stromky\_balanced\_3“, který obsahuje mnohem méně fotek oproti setu „stromky\_balanced“, který byl použit pro klasifikační modely 15 až 20. Lze zde také pozorovat, že změna parametrů jako augmentace dat, rozlišení a zvolená architektura sítě neměla příliš velký vliv na přesnost, spíše pouze na čas trénování a dobu inference.


Nyní k porovnání modelů detekce anomálií. Prvním velkým překvapením může být to, že výsledky evaluace v DLT a inference v HALCONu se od sebe velice liší. Rozdíly jsou u některých modelů velmi zřejmé, např. u modelu č. 30. Zde bylo dosaženo při evaluaci F1-score o velikosti 91,38 %, avšak při inferenci pouze 61,49 %. Naopak u modelu č. 1 evaluace dosáhla hodnoty F1-score 36,73 %, ale inference dosáhla hodnoty 67,81 %. Zdá se tedy, že s postupným snižováním velikosti trénovacích dat dochází k přeučení modelu. Zřejmě proto se výsledky od sebe tak moc liší, jelikož model se přeučil na malém vzorku dat takovým způsobem, že následně není schopen rozpoznat širší variaci dat. Z hlediska vlivu dalších parametrů nelze jednoznačně určit, který má největší vliv na výslednou přesnost. Je zde však jasný vztah volby rozlišení fotek, použití globální nebo lokální sítě a také parametru „Patch size“. S rostoucím rozlišením a klesáním analyzované oblasti lokální sítě drasticky roste doba trénování až na desítky hodin. Modely bez lokální sítě byly natrénovány mnohem rychleji, v řádech hodin. V porovnání s klasifikačními modely je vidět jasný rozdíl, kde trénování trvalo mnohdy pouze několik minut a protáhlo se přes hodinu pouze tehdy, kdy muselo být použito CPU místo GPU z důvodu nedostatku paměti.

Poslední nedostatek modelů detekce anomálií je ten, že konkrétně při analýze sazenic se vyskytuje příliš velká variace vstupních dat. Model tedy není schopen příliš dobře identifikovat anomálii, jak je ukázáno na obrázcích níže.



Obrázek 26 Detekované anomálie a tepelná mapa sazenice

(zdroj: vlastní)




Obrázek 27 Detekované anomálie a tepelná mapa integrovaného obvodu

(zdroj: ukázkový příklad `dl_anomaly_detection_global_context_inference.hdev` v programu HALCON)

Je vidět zřejmý rozdíl v tepelných mapách, kdy na obr. 27 je jasně viditelný a vyznačený defekt, avšak u sazenice na obr. 26 jsou stopy velmi slabé a nenesou žádnou vypovídající informaci o anomálii. Z tohoto důvodu a kvůli dosažení nízkého F1-score lze tedy považovat modely detekce anomálií jako nevhodné pro tuto aplikaci.

Naposled je uvedena matice záměn a vizualizace metrik Precision a Recall pro nejlepší klasifikační model č. 18. Model nesprávně určil třídu sazenic pouze v 31 případech, což je v měřítku tisíce fotek velmi dobrý výsledek.



Obrázek 28 Matice záměn klasifikačního modelu č. 18

(zdroj: vlastní)


## 8 PROVEDENÍ V PROGRAMU MATROX DESIGN ASSISTANT A MATROX IMAGING LIBRARY COPILOT

Obdobně jako v předchozí kapitole, i zde budou použity dvě aplikace pro vytvoření a otestování neuronových sítí. První část se bude zabývat vytvořením modelu v aplikaci Copilot, což je jeden z nástrojů obsažených v sadě Matrox Imaging Library (nově Aurora Imaging Library). Jednotlivé produkty od společnosti Zebra Technologies byly již popsány v kapitole 3.9. Vytvořené modely budou následně otestovány v prostředí Matrox Design Assistant (nově Aurora Design Assistant) a výsledky budou mezi sebou porovnány.

### 8.1 Matrox Imaging Library Copilot

V aplikaci MIL Copilot jsou k dispozici pouze neuronové sítě pro klasifikaci a segmentaci, další typy včetně detekce anomálií jsou dostupné v novějším produktu Aurora Deep Learning, ten však nemá univerzita k dispozici. Z toho důvodu bude vytvořeno několik klasifikačních modelů, které budou srovnány s klasifikačními modely vytvořených v aplikaci DLT.


Prvním krokem při práci v MIL Copilot je vytvoření nového projektu neboli „workspace“, kde byl zvolen workspace „Image Classification Training“. V podzáložce Image Dataset (1.) na uživatelské liště je nutno importovat datový set (2.). Po načtení všech fotek je možno změnit parametry trénování (3.), jako je rozdělení splitu datového setu, maximální počet epoch, learning rate a batch size, tedy kolik fotek bude zpracováno při jednom trénovacím kroku. Vzhledem k dosažení poměrně dobrých výsledků trénování nebylo potřeba tyto parametry nijak měnit. Poslední záložkou je nastavení augmentace (4.), která bude popsána na dalším obrázku.



Obrázek 29 Záložka Image Dataset v MIL Copilot

(zdroj: vlastní)

V sekci augmentace (obr. 30) lze upravovat data přesně podle požadavků uživatele. Všechny parametry lze nastavit buď manuálně nebo nechat program zvolit vhodné nastavení volbou M\_AUTO, popřípadě lze daný parametr vypnout volbou M\_DISABLE. V okně Resize (1.) lze měnit rozlišení fotek. V okně Augmentation (2.) lze nastavit seed augmentace a počet celkových augmentací, např. pomocí parametru Augment Number Mode. V posledním okně Augmentation Presets (3.) je na výběr několik technik augmentace dat, jako např. rotace, změna velikosti, přidání šumu, aj.




Obrázek 30 Sekce augmentace dat v MIL Copilot

(zdroj: vlastní)

Po nastavení všech potřebných parametrů lze navíc manuálně projít a nastavit označení fotografií v datasetu, avšak všechny data se rozdělí do kategorií podle importované adresářové struktury, podobně jako v DLT. Následuje tedy spuštění trénování tlačítkem Train v záložce Image Dataset.

Na obr. 31 jsou uvedeny všechny parametry a hodnoty získané po úspěšném naučení modelu. Na horní liště (1.) jsou vypsány parametry trénování a několik dalších informací. Důležité jsou však průběhy učení (2.), kde lze pozorovat ztrátovou funkci na pravé straně a průběh učení na levé straně, kde výstupem jsou hodnoty Dev Error Rate a Train Error Rate. Tyto hodnoty popisují přesnost modelu během učení a nejlepší získané hodnoty jsou vypsány níže v Best Dev a Train Error Rate. Train Error Rate popisuje, jak moc je model přesný na datech z trénovacího setu a obdobně Dev Error Rate popisuje přesnost na validačním setu. Pokud jsou tyto hodnoty blízko u sebe tak je model dobře naučen a je schopen generalizovat data, na kterých nebyl naučen. Dále je zde výpis parametrů jako je Accuracy a Precision, rozdělené podle jednotlivých tříd dat (3.). Naposled je uvedena matice záměn (4.)



Obrázek 31 Výsledky trénování modelu v MIL Copilot

(zdroj: vlastní)

V tabulce níže jsou uvedeny všechny natrénované klasifikační modely a jejich výsledky budou vypsány později spolu s výsledky dosažených při inferenci, kvůli přehlednosti tabulek.

Tabulka 7 Všechny modely vytvořené v MIL Copilot a jejich nastavení


| Č. v tab. | Název projektu | Dataset    | Split [%] | Aug. | Augment number mode | Rozlišení |
|-----------|----------------|------------|-----------|------|---------------------|-----------|
| 1         | NN1            | balanced_3 | 80        | Ne   | disable             | 500x1000  |
| 2         | NN2            | balanced_3 | 80        | Ne   | disable             | 250x500   |
| 3         | NN3            | balanced_3 | 80        | Ne   | disable             | 125x250   |
| 4         | NN4            | balanced_2 | 80        | Ne   | disable             | 125x250   |
| 5         | NN5            | balanced_2 | 80        | Ne   | disable             | 250x500   |
| 6         | NN6            | cropped    | 80        | Ne   | disable             | 125x250   |
| 7         | NN7            | balanced_4 | 80        | Ne   | disable             | 250x500   |
| 8         | NN8            | balanced_4 | 80        | Ne   | disable             | 250x500   |
| 9         | NN9            | balanced_4 | 80        | Ne   | disable             | 500x1000  |
| 10        | NN10           | balanced_4 | 80        | Ano  | auto                | 250x500   |

(zdroj: vlastní)

**Pozn.** Při augmentaci byly použity funkce „Noise salt pepper“, „Intensity Multiply“ a „Gamma“ nastavené na M\_AUTO, tedy na fotky byl přidán šum a změněn jas.

## 8.2 Matrox Design Assistant


Po exportování naučených modelů je potřeba vytvořit program v Matrox Design Assistant, který použije tyto modely pro provedení inference, k čemuž bude opět použit datový set „inference“. Tato aplikace může být spuštěna v několika konfiguracích, kde každá z nich má jiný účel. V módu emulace lze tvořit programy, ale nelze načítat data ze žádných zdrojů. Dále je možno aplikaci spustit v Design-time režimu na lokálním zařízení, lze tvořit programy a načítat data jak z disku, tak v reálném čase např. z kamery. Naposled je zde režim Run-time, který je určen pouze pro nasazení programu do výrobního prostředí, nelze v něm editovat program. Po vytvoření a spuštění nového projektu v Design-time režimu je nutné importovat datový set.



Obrázek 32 Importování datového setu do Matrox Design Assistant

(zdroj: vlastní)

Na obrázku 33 níže je zobrazena pracovní plocha projektu. Programy v této aplikaci se tvoří formou stavových diagramů. Z nabídky na horní liště (1.) se tedy vyberou funkční bloky, které se skládají a propojují se mezi sebou. Program se poté vykonává ve smyčce, začínající nahoře a postupující dolů, kde se postupně vykonávají jednotlivé bloky (2.). Ve spodním okně Configuration (3.) se edituje vybraný blok v diagramu. Okno napravo od diagramu (4.) se aktualizuje za chodu programu a zobrazuje relevantní informace v právě prováděné akci. Druhé grafické okno (5.) zobrazuje informace za chodu programu pouze zvoleného diagramového bloku. Poslední část je vyhrazena pro zobrazení proměnných hodnot, ať už uživatelských nebo systémových (6.). Zde si uživatel může zvolit všechny parametry z bloků, které chce sledovat během chodu programu.



Obrázek 33 Popis uživatelského rozhraní aplikace Matrox Design Assistant

(zdroj: vlastní)

Hlavní funkční bloky v programu jsou CNNClassIndex, který načítá vytvořený model a aplikuje ho na fotky, které jsou načteny blokem Camera. Ještě před tím, než jsou fotky analyzovány jsou upraveny blokem ImageProcessing, který mění rozlišení fotek na stejné, při kterém byl model trénován. Ostatní bloky plní vedlejší funkce, kde blok TextWriter zapisuje do .csv souboru název analyzované fotky, její předpovězený stav a číslo řádku, které poskytuje blok Counter. Blok Status pouze kontroluje, zda se při běhu programu nevyskytla nějaká nečekaná chyba. Po spuštění programu se tedy resetuje čítač blokem ResetCounters a následně program jede ve smyčce, dokud nejsou zpracovány všechny fotky. Po dokončení běhu programu byly manuálně změněny parametry bloků ImageProcessing (rozlišení fotek), CNNClassIndex (další model) a TextWriter (nový .csv soubor).

### 8.3 Shrnutí výsledků

Výsledky jsou velice podobné jako u klasifikačních modelů z DLT. Lze pozorovat, že největším faktorem byl opět použitý datový set, kde modely naučené na menším počtu fotek získaly F1-score pohybující se kolem 70 %. Na druhou stranu modely s větším počtem vstupních dat dosáhly F1-score od 90 % až 95 %. Může se zdát, že modely 4 a 5 mají poměrně velký rozdíl parametrů Dev Error Rate a Train Error Rate, což může značit přeučení modelu. Avšak porovnáním stejného parametru u nejlepšího DLT modelu č. 18 lze vidět podobné chování. U tohoto modelu parametr Top-1 error (stejný princip jako zde) dosáhl při evaluaci hodnoty 8,74 %, což je podobné jako zde u nejlepšího modelu č. 5, kde hodnota Dev Error Rate dosahuje 11,34 %.


Co se týče vlivu ostatních parametrů, tak je vidět, že trénování trvalo déle s větším počtem dat, s větším rozlišením a augmentací, podobně jako u DLT. Zde se však zdá, že augmentace na malém setu u modelu č. 10 měla pozitivní vliv na F1-score oproti modelu č. 8. Jak již bylo zmíněno, ostatní parametry jako learning rate a počet epoch nebyly manuálně upraveny, jelikož trénování modelů dosahovalo uspokojivých výsledků při těchto přednastavených hodnotách.

Tabulka 8 Výsledky trénování v MIL Copilot a inference v MDA

| Č. v tab. | Copilot       |                 |                         |                           | Matrox Design Assistant |               |            |              |
|-----------|---------------|-----------------|-------------------------|---------------------------|-------------------------|---------------|------------|--------------|
|           | Čas trénování | Nejlepší epocha | Best Dev Error Rate [%] | Best Train Error Rate [%] | Accuracy [%]            | Precision [%] | Recall [%] | F1-score [%] |
| 1         | 1:24:55       | 59              | 9,40                    | 9,70                      | 71,90                   | 78,59         | 60,20      | 68,18        |
| 2         | 17:44         | 56              | 6,25                    | 0,78                      | 71,80                   | 87,33         | 51,00      | 64,39        |
| 3         | 4:19          | 43              | 9,38                    | 0                         | 73,80                   | 88,39         | 54,80      | 67,65        |
| 4         | 5:22          | 38              | 12,37                   | 0                         | 93,90                   | 89,84         | 99,00      | 94,20        |
| 5         | 21:59         | 52              | 11,34                   | 0,51                      | 94,90                   | 91,65         | 98,80      | 95,09        |
| 6         | 40:16         | 18              | 7,26                    | 6,35                      | 91,10                   | 99,28         | 82,80      | 90,29        |
| 7         | 9:39          | 51              | 2,50                    | 0                         | 78,80                   | 81,86         | 74,00      | 77,73        |
| 8         | 9:24          | 49              | 3,75                    | 0                         | 74,70                   | 76,00         | 72,20      | 74,05        |
| 9         | 41:25         | 51              | 5,00                    | 3,75                      | 61,70                   | 62,97         | 56,80      | 59,73        |
| 10        | 39:29         | 25              | 3,75                    | 0                         | 81,90                   | 85,68         | 76,60      | 80,89        |

(zdroj: vlastní)

Na závěr je uvedena matice záměn pro model s nejlepším F1-score, což je v tomto případě model č. 5 s dosaženou hodnotou 95,09 %. Model zaměnil pouze 6 dobrých sazenic za nesprávné, avšak nesprávně identifikoval 45 vadných sazenic, které označil jako OK. Nejspíš by byl lepší opačný případ, kdy by model propustil méně vadných a vyřadil více dobrých, ale i tak mohou být výsledky modelu považovány za dostatečné.



Obrázek 34 Matice záměn klasifikačního modelu č. 5

(zdroj: vlastní)

## ZÁVĚR

Cílem práce bylo pokusit se vytvořit systém pro třídění sazenic stromků za použití neuronových sítí. Tento systém by měl být schopen rozpoznat vadné sazenice nesplňující kritéria od těch vyhovujících. Podmínkou pro vyřazení sazenice bylo, pokud měla dvojné vrcholy nebo příliš malou výšku. Podrobný popis problematiky třídění sazenic je popsán v první kapitole teoretické části.

Teoretická část práce dále zahrnuje literární rešerši, kde byly prozkoumány již vytvořené aplikace využívající neuronové sítě pro různé účely. Z rešerše vyplynulo, že dnešní technologie by měly být dostatečně výkonné a sofistikované pro realizaci této úlohy.

Dále bylo vyjmenováno spoustu společností a firem zabývajících se vývojem aplikací strojového vidění, ať už se jedná o hardwarové, softwarové či jiné produkty a služby, které tyto firmy poskytují. Poslední dvě kapitoly teoretické části se zabývají tématy strojového vidění a neuronových sítí. Tyto kapitoly se zaměřují na různé aspekty těchto pojmů, zejména na definici, možnou aplikaci v praxi a porovnání výhod a nevýhod.

Praktická část se ze začátku zaměřuje na popis použitých prostředků pro realizaci této úlohy. Jedná se o softwarové produkty dostupné pro studenty na Univerzitě Tomáše Bati, což jsou produkty HALCON a Deep Learning Tool od společnosti MVTec a poté Matrox Design Assistant a Matrox Imaging Library Copilot od společnosti Zebra Technologies. Postupem práce bylo nejdříve natrénování modelů, kde se každý model od sebe lišil a poté byly mezi sebou porovnány a vyhodnoceny z několika hledisek.

Po srovnání všech modelů je zřejmé, že modely detekce anomálií natrénované v DLT nedosahují požadované kvality, jelikož nejlepší dosažený parametr F1-score byl 83,88 % u modelu č. 11. Na druhou stranu klasifikační modely si vedly mnohem lépe, kde nejlepší model z DLT č. 18 dosáhl F1-score o velikosti 96,97 % a několik dalších získalo podobné výsledky kolem 95 %. Některé modely naučené v aplikaci MIL Copilot si taky vedly slušně, kde nejlepší z nich byl model č. 5 a dosáhl F1-score o hodnotě 95,09 %. Následující podobně přesné modely byly č. 4 s F1-score o hodnotě 94,2 % a č. 6 s hodnotou 90,29 %. Ze získaných dat vychází najevo, že největší vliv na přesnost těchto modelů byla velikost trénovacích dat.

Z dosažených výsledků tedy vyplývá, že neuronové sítě mohou být použity pro třídění sazenic stromků, pokud jsou modely správně vytvořeny a otestovány



## SEZNAM POUŽITÉ LITERATURY

- [1] Durvea, M. L. (ed.). 1985. Proceedings: Evaluating seedling quality: principles, procedures, and predictive abilities of major tests. Workshop held October 16-18, 1984. Forest Research Laboratory, Oregon State University, Corvallis, ISBN 0-87437-000-0. [cit. 2025-04-28].
- [2] MAY, Jack T. CHAPTER 9-SEEDLING QUALITY, GRADING, CULLING AND COUNTING. Online. University of Georgia. <https://rngr.net/publications/spnh/PDF.2003-08-12.2552>. [cit. 2025-04-28].
- [3] ČSN 48 2115 (482115). Online. Dostupné z: <https://www.technicke-normy-csn.cz/csn-48-2115-482115-207589.html#>. [cit. 2025-04-28].
- [4] ČSN 48 1211 (481211). Online. Dostupné z: <https://www.technicke-normy-csn.cz/csn-48-1211-481211-207582.html#>. [cit. 2025-04-28].
- [5] RIGNEY, Michael P. a KRANZLER, Glenn A. Computer Vision for Grading Tree Seedlings'. Online. 1988. <https://rngr.net/publications/proceedings/1988/rigney.pdf>. [cit. 2025-04-28].
- [6] Chavasse, C.G.R. 1977. The significance of planting height as an indicator of subsequent seedling growth. New Zealand Journal of Forestry 22:283-296. [cit. 2025-05-15].
- [7] Burdett, A.N. 1976. The relationship between root fibrosity and root growth potential in bare root lodgepole pine. B.C. For. Serv. Int. Report on E.P. 746.03 pp5. [cit. 2025-05-15].
- [8] POON, Wing Hang. A machine vision and handling system for measurement of containerized tree seedlings. Online, Thesis/Dissertation. Vancouver: University of British Columbia, 1996. Dostupné z: <http://hdl.handle.net/2429/7774>. [cit. 2025-03-13].
- [9] HASAL, Ondřej. Software pro zpracování obrazu pro třídící linku na sazenice. Online, Diplomová práce. Zlín: Univerzita Tomáše Bati ve Zlíně, Fakulta aplikované informatiky, 2019. Dostupné z: <http://hdl.handle.net/10563/44607>. [cit. 2025-03-13].
- [10] Liu S, Xing Z, Wang Z, Tian S, Jahun FR (2017) Development of machine-vision system for gap inspection of muskmelon grafted seedlings. <https://doi.org/10.1371/journal.pone.0189732>. [cit. 2025-03-13].

- [11] WAN, Hao; FAN, Zeming; YU, Xiaojun; KANG, Meilin; WANG, Pengbo et al. A real-time branch detection and reconstruction mechanism for harvesting robot via convolutional neural network and image segmentation. Online, Thesis. China: School of Automation, Northwestern Polytechnical University, 2022. <https://doi.org/10.1016/j.compag.2021.106609>. [cit. 2025-04-29].
- [12] Moharram, Deema, Xuguang Yuan, and Dan Li. 2023. "Tree Seedlings Detection and Counting Using a Deep Learning Algorithm" *Applied Sciences* 13, no. 2: 895. <https://doi.org/10.3390/app13020895>
- [13] Kamilaris, A. and Prenafeta-Boldú, F.X. (2018) 'A review of the use of convolutional neural networks in agriculture', *The Journal of Agricultural Science*, 156(3), pp. 312–322. doi:10.1017/S0021859618000436.
- [14] BERKMANAS, Ramūnas. TOP 10 Machine Vision Software 2025 - EasyODM. Online. Automated Visual Inspection With EasyODM Software. 2024. Dostupné z: <https://easyodm.tech/top-10-machine-vision-software/>. [cit. 2025-03-20].
- [15] Pleora Technologies. Online. Dostupné z: <https://www.pleora.com/>. [cit. 2025-03-20].
- [16] ISRA VISION - Machine Vision Solutions. Online. Dostupné z: <https://www.isravision.com/en-en>. [cit. 2025-03-30].
- [17] KEYENCE CORPORATION OF AMERICA. Online. Dostupné z: <https://www.keyence.com/>. [cit. 2025-03-22].
- [18] Computer Vision AI Platform | Robovision. Online. Dostupné z: <https://robovision.ai/>. [cit. 2025-03-22].
- [19] PEKAT VISION. Online. Dostupné z: <https://www.pekatvision.com/cs/>. [cit. 2025-03-25].
- [20] SICK | SICK. Online. Dostupné z: <https://www.sick.com/ag/en/>. [cit. 2025-03-25].
- [21] SICK Nova - SICK SensorApps | SICK. Online. Dostupné z: <https://www.sick.com/ag/en/catalog/products/digital-services-and-software/sick-sensorapps/sick-nova/c/g576400?tab=overview>. [cit. 2025-04-09].
- [22] DStudio. Online. Dostupné z: <https://dstudio.cloud.sick.com/#uses>. [cit. 2025-04-09].
- [23] Cognex | Machine Vision and Barcode Readers. Online. Dostupné z: <https://www.cognex.com/>. [cit. 2025-04-02].

- [24] VisionPro Software | Cognex. Online. Dostupné z: <https://www.cognex.com/products/machine-vision/vision-software/visionpro-software>. [cit. 2025-04-09].
- [25] VisionPro Deep Learning | Cognex. Online. Dostupné z: <https://www.cognex.com/products/machine-vision/vision-software/visionpro-deep-learning>. [cit. 2025-04-09].
- [26] MVTec Software - Experts for Machine Vision Software. Online. Dostupné z: <https://www.mvtec.com/>. [cit. 2025-04-08].
- [27] MERLIC - the easy to use machine vision software. Online. Dostupné z: <https://www.mvtec.com/products/merlic>. [cit. 2025-04-09].
- [28] HALCON - the powerful Machine Vision Software: MVTec Software. Online. Dostupné z: <https://www.mvtec.com/products/halcon>. [cit. 2025-04-09].
- [29] Deep Learning Tool: MVTec Software. Online. Dostupné z: <https://www.mvtec.com/products/deep-learning-tool>. [cit. 2025-04-09].
- [30] Zebra Technologies | Visible. Connected. Optimized. | Zebra. Online. Dostupné z: <https://www.zebra.com/us/en.html>. [cit. 2025-04-10].
- [31] Aurora Vision Studio™ | Machine Vision Software | Zebra. Online. Dostupné z: <https://www.zebra.com/gb/en/products/oem/software/aurora-vision-studio.html>. [cit. 2025-04-09].
- [32] Aurora Vision Library™ | Zebra. Online. Dostupné z: <https://www.zebra.com/gb/en/products/oem/software/aurora-vision-library.html>. [cit. 2025-04-09].
- [33] Aurora Imaging Library | Zebra. Online. Dostupné z: <https://www.zebra.com/gb/en/software/machine-vision-and-fixed-industrial-scanning-software/aurora-imaging-library.html>. [cit. 2025-04-09].
- [34] Aurora Design Assistant | Zebra. Online. Dostupné z: <https://www.zebra.com/gb/en/software/machine-vision-and-fixed-industrial-scanning-software/aurora-design-assistant.html>. [cit. 2025-04-09].

- [35] Aurora Focus™ | Zebra. Online. Dostupné z: <https://www.zebra.com/gb/en/software/machine-vision-and-fixed-industrial-scanning-software/aurora-focus.html>. [cit. 2025-04-09].
- [36] What is Machine Vision ? | GeeksforGeeks. Online. Dostupné z: <https://www.geeksforgeeks.org/what-is-machine-vision/>. [cit. 2025-04-15].
- [37] Machine vision basics: definitions, uses, and benefits | Cognex. Online. Dostupné z: <https://www.cognex.com/what-is/machine-vision>. [cit. 2025-04-15].
- [38] What Is Machine Vision? | Built In. Online. Dostupné z: <https://builtin.com/machine-learning/machine-vision>. [cit. 2025-04-15].
- [39] What Is Machine Vision? – Intel. Online. Dostupné z: <https://www.intel.com/content/www/us/en/learn/what-is-machine-vision.html>. [cit. 2025-04-16].
- [40] Machine Vision Vs Computer Vision - What Is The Difference? | Zebra. Online. Dostupné z: <https://www.zebra.com/us/en/resource-library/faq/what-is-the-difference-between-machine-vision-computer-vision.html>. [cit. 2025-04-16].
- [41] What Is Machine Vision? | Zebra. Online. Dostupné z: <https://www.zebra.com/us/en/resource-library/faq/what-is-machine-vision.html>. [cit. 2025-04-16].
- [42] What is Machine Vision? Definition, Applications, and Trends | SOLOMON 3D. Online. Dostupné z: <https://www.solomon-3d.com/blog/what-is-machine-vision-definition-applications-and-trends/>. [cit. 2025-04-16].
- [43] Explained: Neural networks | MIT News | Massachusetts Institute of Technology. Online. Dostupné z: <https://news.mit.edu/2017/explained-neural-networks-deep-learning-0414>. [cit. 2025-04-19].
- [44] HAGAN, Martin T. Neural Network Design. Online. 2nd edition. Oklahoma State University, 2014. Dostupné z: <https://hagan.okstate.edu/NNDesign.pdf>. [cit. 2025-04-22].
- [45] Alom, Md Zahangir, Tarek M. Taha, Chris Yakopcic, Stefan Westberg, Paheding Sidike, Mst Shamima Nasrin, Mahmudul Hasan, Brian C. Van Essen, Abdul A. S. Awwal, and Vijayan K. Asari. 2019. "A State-of-the-Art Survey on Deep Learning

- Theory and Architectures" Electronics 8, no. 3: 292. <https://doi.org/10.3390/electronics8030292>. [cit. 2025-04-26].
- [46] Semi-Supervised Learning in ML | GeeksforGeeks. Online. Dostupné z: <https://www.geeksforgeeks.org/ml-semi-supervised-learning/>. [cit. 2025-04-26].
- [47] RIVAS, Dr. Pablo. Deep Learning for Beginners. [S.l.]: Packt Publishing, 2020. ISBN 9781838647582. Dostupné také z: <https://proxy.k.utb.cz/login?url=https://app.knovel.com/hotlink/toc/id:kpDLB00001/deep-learning-for?kpromoter=marc>. [cit. 2025-04-26].
- [48] SCHMIDHUBER, Juergen. Deep Learning. Online. 2015. Dostupné z: <https://doi.org/10.4249/scholarpedia.32832>. [cit. 2025-04-28].
- [49] KUMAR, Nishant and RAUBAL, Martin. Applications of deep learning in congestion detection, prediction and alleviation: A survey. Online. 2021. <https://doi.org/https://doi.org/10.1016/j.trc.2021.103432>. [cit. 2025-04-28].
- [50] MAKLIN, Cory. LSTM Recurrent Neural Network Keras Example | by Cory Maklin | TDS Archive | Medium. Online. 2019. Dostupné z: <https://medium.com/data-science/machine-learning-recurrent-neural-networks-and-long-short-term-memory-lstm-python-keras-example-86001ceaaebc>. [cit. 2025-05-01].
- [51] Alaghbari, Khaled A., Heng-Siong Lim, Mohamad Hanif Md Saad, and Yik Seng Yong. 2023. "Deep Autoencoder-Based Integrated Model for Anomaly Detection and Efficient Feature Extraction in IoT Networks" IoT 4, no. 3: 345-365. <https://doi.org/10.3390/iot4030016>. [cit. 2025-05-01].
- [52] SOUMEN, M.; OJJI, Ifeanyi a YOGESH, K. B. Best Practices for Neural Network Data Prep. Online. 2025. <https://www.linkedin.com/advice/0/what-best-practices-preparing-data-neural-network-rihke>. [cit. 2025-05-04].
- [53] KAMILARIS, Andreas a X. PRENAFETA-BOLDÚ, Francesc. Deep learning in agriculture: A survey. Online. 2018. <https://doi.org/https://doi.org/10.1016/j.compag.2018.02.016>. [cit. 2025-05-04].
- [54] RAMOS, Diana. Real-Life and Business Applications of Neural Networks. Online. 2018. <https://www.smartsheet.com/neural-network-applications>. [cit. 2025-05-04].
- [55] Download Area: MVTec Software. Online. 2025. Dostupné z: <https://www.mvtec.com/downloads>. [cit. 2025-05-07].

- [56] Videos & tutorials: MVTec Software. Online. 2025. Dostupné z: <https://www.mvtec.com/support/videos-tutorials>. [cit. 2025-05-07].
- [57] HALCON Documentation: MVTec Software. Online. 2025. Dostupné z: <https://www.mvtec.com/products/halcon/work-with-halcon/documentation>. [cit. 2025-05-07].
- [58] MVTec Academy: MVTec Software. Online. 2025. Dostupné z: <https://www.mvtec.com/academy>. [cit. 2025-05-07].
- [59] Aurora Design Assistant™ Courses | Zebra. Online. 2025. Dostupné z: <https://www.zebra.com/us/en/vision-academy/aurora-design-assistant.html>. [cit. 2025-05-07].

## SEZNAM OBRÁZKŮ

|                                                                                        |    |
|----------------------------------------------------------------------------------------|----|
| Obrázek 1 Ukázka nevyhovujících sazenic (dvojné vrcholy, malá velikost) .....          | 18 |
| Obrázek 2 Ukázka vyhovujících sazenic (jeden vrchol, dostatečná velikost) .....        | 18 |
| Obrázek 3 Prototyp skenovacího systému .....                                           | 19 |
| Obrázek 4 Testovací zařízení na měření sazenic .....                                   | 20 |
| Obrázek 5 Sestava pro získání snímků sazenic .....                                     | 21 |
| Obrázek 6 Ukázka vyhodnocení pro nalezení (a) a nenalezení (b) šablony na fotce .....  | 21 |
| Obrázek 7 Výsledky rekonstrukce větví za použití CNN .....                             | 22 |
| Obrázek 8 Příklad augmentace originálních fotografií .....                             | 23 |
| Obrázek 9 Výsledná segmentace sazenic .....                                            | 23 |
| Obrázek 10 Obecné schéma provedení procesu kontroly s použitím strojového vidění ..... | 31 |
| Obrázek 11 Hluboká plně propojená dopředná neuronová síť s osmi vrstvami .....         | 38 |
| Obrázek 12 Ukázka architektury vrstev konvoluční neuronové sítě .....                  | 40 |
| Obrázek 13 Schéma uspořádání vrstev neuronů v rekurentní neuronové síti .....          | 41 |
| Obrázek 14 Obecná struktura autoenkodéru .....                                         | 42 |
| Obrázek 15 Diagram znázorňující princip funkce generativních soupeřících sítí .....    | 42 |
| Obrázek 16 Matice záměn o dvou hodnotách – pozitivní a negativní .....                 | 44 |
| Obrázek 17 Ukázka neupravené fotografie sazenice .....                                 | 48 |
| Obrázek 18 Ukázka upravené fotografie sazenice .....                                   | 48 |
| Obrázek 19 Vytvoření projektu v DLT .....                                              | 51 |
| Obrázek 20 Popis záložky Gallery v DLT .....                                           | 51 |
| Obrázek 21 Popis záložky Split v DLT .....                                             | 52 |
| Obrázek 22 Popis záložky Training – Settings v DLT .....                               | 54 |
| Obrázek 23 Popis záložky Training – Results v DLT .....                                | 54 |
| Obrázek 24 Popis záložky Evaluation v DLT .....                                        | 56 |
| Obrázek 25 Uživatelské rozhraní v programu HALCON .....                                | 61 |
| Obrázek 26 Detekované anomálie a tepelná mapa sazenice .....                           | 66 |
| Obrázek 27 Detekované anomálie a tepelná mapa integrovaného obvodu .....               | 67 |
| Obrázek 28 Matice záměn klasifikačního modelu č. 18 .....                              | 67 |
| Obrázek 29 Záložka Image Dataset v MIL Copilot .....                                   | 68 |
| Obrázek 30 Sekce augmentace dat v MIL Copilot .....                                    | 69 |
| Obrázek 31 Výsledky trénování modelu v MIL Copilot .....                               | 70 |
| Obrázek 32 Importování datového setu do Matrox Design Assistant .....                  | 71 |
| Obrázek 33 Popis uživatelského rozhraní aplikace Matrox Design Assistant .....         | 72 |
| Obrázek 34 Matice záměn klasifikačního modelu č. 5 .....                               | 74 |



**SEZNAM TABULEK**

|                                                                                              |    |
|----------------------------------------------------------------------------------------------|----|
| Tabulka 1 Všechny vytvořené projekty v DLT typu „anomaly detection“ a jejich nastavení ..... | 57 |
| Tabulka 2 Výsledky všech evaluací provedených v DLT pro projekty „anomaly detection“ .....   | 58 |
| Tabulka 3 Všechny vytvořené projekty v DLT typu „classification“ a jejich nastavení.....     | 59 |
| Tabulka 4 Výsledky všech evaluací provedených v DLT pro projekty „classification“ .....      | 60 |
| Tabulka 5 Výsledky inference provedené v HALCONu pro modely „anomaly detection“              | 64 |
| Tabulka 6 Výsledky inference provedené v HALCONu pro modely typu „classification“            | 65 |
| Tabulka 7 Všechny modely vytvořené v MIL Copilot a jejich nastavení .....                    | 70 |
| Tabulka 8 Výsledky trénování v MIL Copilot a inference v MDA.....                            | 73 |

**SEZNAM POUŽITÝCH SYMBOLŮ A ZKRATEK**

|      |                                |
|------|--------------------------------|
| mm   | Milimetr                       |
| cm   | Centimetr                      |
| CA   | Classification Accuracy        |
| RMSE | Root Mean Square Error         |
| MRI  | Magnetic Resonance Imaging     |
| CT   | Computed Tomography            |
| ANN  | Artificial Neural Network      |
| DNN  | Deep Neural Network            |
| CNN  | Convolutional Neural Network   |
| RNN  | Recurrent Neural Network       |
| AE   | Auto-encoder                   |
| RBM  | Restricted Boltzmann Machine   |
| GAN  | Generative Adversarial Network |
| LSTM | Long Short-Term Memory         |
| LMM  | Large Language Model           |
| TP   | True Positive                  |
| TN   | True Negative                  |
| FP   | False Positive                 |
| FN   | False Negative                 |
| P    | Precision                      |
| R    | Recall                         |
| ACC  | Accuracy                       |
| QM   | Quality Measure                |
| MSE  | Mean Square Error              |
| MRE  | Mean Relative Error            |

---

|     |                               |
|-----|-------------------------------|
| MAE | Mean Absolute Error           |
| IoU | Intersection over Union       |
| OCR | Optical Character Recognition |
| DLT | Deep Learning Tool            |
| MIL | Matrox Imaging Library        |
| MDA | Matrox Desing Assistant       |
| RGB | Red-Green-Blue                |
| CPU | Central Processing Unit       |
| GPU | Graphics Processing Unit      |