



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA INFORMAČNÍCH TECHNOLOGIÍ

FACULTY OF INFORMATION TECHNOLOGY

ÚSTAV POČÍTAČOVÉ GRAFIKY A MULTIMÉDIÍ

DEPARTMENT OF COMPUTER GRAPHICS AND MULTIMEDIA

**AUTOMATIZOVANÁ DETEKCE VAD PANELŮ
FOTOVOLTAICKÝCH ELEKTRÁREN Z TERMOKA-
MERY DRONU**

AUTOMATED DETECTION OF PHOTOVOLTAIC POWER PLANT PANEL DEFECTS FROM A
DRONE THERMAL IMAGING CAMERA

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. MATĚJ GOTZMAN

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. DANIEL BAMBUŠEK

BRNO 2025

Zadání diplomové práce



162840

Ústav: Ústav počítačové grafiky a multimédií (UPGM)
Student: **Gotzman Matěj, Bc.**
Program: Informační technologie a umělá inteligence
Specializace: Počítačové vidění
Název: **Automatizovaná detekce vad panelů fotovoltaických elektráren z termokamery dronu**
Kategorie: Zpracování obrazu
Akademický rok: 2024/25

Zadání:

1. Prostudujte základy zpracování obrazu a zaměřte se na práci s radiometrickými snímky.
2. Seznamte se se stávajícími přístupy inspekcí fotovoltaických elektráren pomocí dronů a následné analýzy konkrétních vad na fotovoltaických panelech.
3. Vyberte vhodné metody a nástroje a navrhnete uživatelský proces, který s pomocí počítačového vidění usnadní a urychlí analýzu vad na fotovoltaických elektrárnách.
4. Navržený proces implementujte.
5. Proveďte experimenty a vyhodnoťte vlastnosti výsledného řešení.
6. Vytvořte video prezentující klíčové vlastnosti výsledného řešení.

Literatura:

- Richard Szeliski: Computer Vision: Algorithms and Applications, Springer, 2nd, 2022
- Andriy Burkov: The hundred-page machine learning book, Large Print Book, 2019
- Goodfellow, Bengio, Courville: Deep Learning, MIT Press, 2016
- Gary Bradski, Adrian Kaehler: Learning OpenCV; Computer Vision with the OpenCV Library, O'Reilly Media, 2008
- Elisa Păduraru, *Fundamentals of Creating a Great UI/UX*, Creative Tim, 2022
- Dále dle pokynů vedoucího.

Při obhajobě semestrální části projektu je požadováno:

Body 1, 2, 3 a rozpracovaný bod 4.

Podrobné závazné pokyny pro vypracování práce viz <https://www.fit.vut.cz/study/theses/>

Vedoucí práce: **Bambušek Daniel, Ing.**
Vedoucí ústavu: Černocký Jan, prof. Dr. Ing.
Datum zadání: 1.11.2024
Termín pro odevzdání: 21.5.2025
Datum schválení: 12.11.2024

Abstrakt

Tato diplomová práce se zabývá automatizací inspekce fotovoltaických elektráren pomocí termokamery dronu. V současné době je kontrola nasnímaných termosnímků prováděna ručně, což zabírá spoustu času. Proto byl v rámci této práce navržen proces, který z pořízených termosnímků vytvoří multispektrální ortofoto, z něj segmentuje jednotlivé panely pomocí natrénované neuronové sítě Mask R-CNN, které následně klasifikuje podle přítomnosti a typu vady. Součástí práce bylo vytvoření webové aplikace, která uživatele provede celým procesem zpracování datasetu a interaktivně mu zobrazí výsledky. Kromě toho aplikace umožňuje uživateli kontrolovat detekované vady, měřit teplotu povrchu panelů a případně upravit či doplnit predikce ručně. Systém byl otestován na datasetech z inspekci českých fotovoltaických elektráren, na kterých dokázal odhalit 98 % všech vadných panelů.

Abstract

This thesis focuses on the automation of photovoltaic power plant inspections using drone-based thermal imaging. Currently, the inspection of captured thermal images is performed manually, which is time consuming. Therefore, this thesis proposes a process that generates a multispectral orthophoto from the captured thermal images, segments individual panels from it using a trained Mask R-CNN neural network and then classifies them according to the presence and type of defect. As part of this work, a web application was developed that guides the user through the entire dataset processing workflow and present the results interactively. The application also enables users to verify detected defects, measure panel surface temperatures and manually adjust or add predictions when necessary. The system was evaluated on datasets obtained from inspections of Czech photovoltaic power plants, where it successfully detected 98 % of all defective panels.

Klíčová slova

Fotovoltaická elektrárna, dron, termokamera, segmentace instancí, Mask R-CNN, Vision Transformer, klasifikace obrazu, FLIR, Django, Angular

Keywords

Photovoltaic power plant, drone, thermal camera, instance segmentation, Mask R-CNN, Vision Transformer, image classification, FLIR, Django, Angular

Citace

GOTZMAN, Matěj. *Automatizovaná detekce vad panelů fotovoltaických elektráren z termokamery dronu*. Brno, 2025. Diplomová práce. Vysoké učení technické v Brně, Fakulta informačních technologií. Vedoucí práce Ing. Daniel Bambušek

Automatizovaná detekce vad panelů fotovoltaických elektráren z termokamery dronu

Prohlášení

Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně pod vedením pana Ing. Daniela Bambuška. Uvedl jsem všechny literární prameny, publikace a další zdroje, ze kterých jsem čerpal.

.....
Matěj Gotzman
19. května 2025

Poděkování

Rád bych poděkoval svému vedoucímu práce Ing. Danielu Bambuškoví za pomoc a ochotu při vedení mé diplomové práce. Dále děkuji Ing. Davidovi Balharovi za poskytnutí datasetů inspekcí českých fotovoltaických elektráren.

Obsah

1	Úvod	2
2	Detekce vad fotovoltaických panelů	3
2.1	Fotovoltaická elektrárna	3
2.2	Hardware	7
2.3	Software	9
2.4	Modely pro zpracování obrazu	12
2.5	Data	14
2.6	Současná řešení	16
3	Posouzení současného stavu a návrh jeho automatizace	23
3.1	Zhodnocení současného stavu	23
3.2	Návrh řešení	24
4	Návrh a implementace klíčových částí systému	27
4.1	Architektura webové aplikace	27
4.2	Příprava datasetu	31
4.3	Tvorba ortofota	35
4.4	Segmentace fotovoltaických panelů	37
4.5	Klasifikace fotovoltaických panelů	44
4.6	Anotace fotovoltaických panelů	48
5	Evaluace systému	51
5.1	Dataset Sychrov	51
5.2	Ostatní datasety	53
5.3	Konzultace s odborníkem z praxe	55
6	Závěr	57
	Literatura	58

Kapitola 1

Úvod

Mezi hlavní společenská a politická témata současnosti patří globální oteplování, energetická krize a proměna energetického mixu jednotlivých států tak, aby obnovitelné zdroje co nejvíce nahradily výrobu energie z uhlí a dalších neekologických zdrojů. Dle přírodních podmínek lze energii získávat z hydroelektráren, větrných elektráren a dalších. Jedním ze zdrojů, který je však využitelný téměř všude, a tedy i v České republice, je solární energie. V roce 2024 energetici připojili do české sítě fotovoltaické elektrárny o celkovém výkonu 967 megawatt-peaků (MWp). Instalovaný výkon meziročně vzrostl o 28 % [18].

Sluneční záření je nevyčerpatelný zdroj energie a při její přeměně na energii elektrickou pomocí fotovoltaických článků nevznikají žádné skleníkové plyny ani hluk. Fotovoltaické panely nemají žádné pohyblivé součástky a i díky tomu výrobci inzerují poměrně dlouhou životnost přesahující 25 let. Výzkum zaměřující se na životnost fotovoltaických panelů v Evropě však naznačuje, že jejich reálná životnost může být poloviční a již po 10 letech se na panelech začínají objevovat závažné defekty [13].

Jako poměrně efektivní forma inspekce fotovoltaické elektrárny se ukázalo měření povrchové teploty panelů pomocí termokamery. Značná část defektů totiž vede k lokálnímu zvýšení teploty daného místa oproti jeho zdravým částem. Pracovníci s kamerou nemusí chodit mezi panely a ručně snímat jejich teplotu. Termokameru lze totiž připojit k dronu, je-li muž je pomocí programu zadána plocha, kterou má nasnímat, a dron již sám létá a pořizuje termální snímky podle vygenerované dráhy letu.

V současné době je však potřeba, aby zaměstnanec procházel jednotlivé snímky, určil, které panely se na snímku nacházejí, a případně detekoval jejich defekty. Tento proces zabere pro jednu elektrárnu několik dní. Zpracování snímků však lze provádět také algoritmicky, což má potenciál celý proces značně urychlit.

Tato práce se právě algoritmizací tohoto procesu zabývá, a proto jsem vytvořil systém, který z termosnímků vytváří multispektrální ortofoto, z něj jsou pomocí natrénované neuronové sítě Mask R-CNN segmentovány jednotlivé fotovoltaické panely, a ty jsou následně klasifikovány do tříd defektů dvěma klasifikačními modely. Součástí řešení je webová aplikace, která uživatele provede celým procesem zpracování datasetu, interaktivně zobrazuje klasifikované panely a umožňuje měření povrchové teploty i manuální úpravy predikcí.

V kapitole 2 je popsán princip fungování fotovoltaických elektráren, detekovatelné vady fotovoltaických panelů, současné přístupy řešení tohoto problému a další informace, které bylo potřeba vyhledat pro vypracování této práce. V kapitole 3 jsou dosavadní přístupy zhodnoceny a na základě zjištěných informací je zde vypracován návrh řešení. V kapitole 4 je pak popsána samotná implementace navrženého systému a v kapitole 5 jsou popsány výsledky jeho evaluace.

Kapitola 2

Detekce vad fotovoltaických panelů

Před začátkem navrhování nového řešení problému stanoveného zadáním této práce bylo potřeba nastudovat všechny relevantní informace na tohle téma. V této kapitole jsou proto postupně popsány jednotlivé prvky, na kterých tato práce staví. Nejprve bylo potřeba pochopit samotné fungování fotovoltaických panelů a určit, jaké chyby na nich lze detekovat. Následně se seznámit se softwarovými a hardwarovými prvky, které jsou momentálně k inspekci využívány, zjistit jejich možnosti a limitace a tyto poznatky využít k vytvoření návrhu řešení. Kromě toho bylo také potřeba vyhledat a nastudovat již existující přístupy řešení k tomuto problému a podrobně se seznámit s aktuálním postupem inspekce.


2.1 Fotovoltaická elektrárna

Fotovoltaická elektrárna přeměňuje sluneční energii na energii elektrickou. Je složena z velkého množství panelů a ty jsou zase složeny z fotovoltaických článků. V této sekci je popsán základní princip fungování těchto panelů a také výčet defektů, které na nich lze detekovat pomocí termokamery.

2.1.1 Fotovoltaický článek

Fotovoltaický článek se skládá z křemíkové destičky s vodivostí typu P, na kterou je při výrobě nanесena tenká vrstva polovodiče typu N [1]. Na spoji těchto vrstev vzniká P-N přechod. Do vrstvy P je přidávána příměs bóru, zatímco do vrstvy N je přidáván fosfor. Vrstva N obsahuje přebytek záporných elektronů a ve vrstvě P je zase přebytek kladných děr. Na přechodu PN je díky tomu vytvořena elektrická bariéra. Dopadem paprsků světla na tyto fotočlánky předávají fotony svou energii atomům v krystalické mřížce křemíku, díky čemuž dojde k uvolňování elektronů a vzniku nových párů negativních elektronů a pozitivních děr. Uvolněné elektrony ve vrstvě N nemohou kvůli PN přechodu přejít do vrstvy P, a proto se zde začnou hromadit. Naopak uvolněné elektrony z vrstvy P mohou přecházet do vrstvy N, a díky tomu je jejich hromadění ve vrstvě N ještě vyšší.


Pokud připojíme na obě strany tohoto fotočlánku kontakty a k nim spotřebič, vytvoříme uzavřený obvod, který umožní nahromaděným elektronům z N části přesun do P části, kde dojde ke sloučení s kladnými dírami, jak je možné vidět na obrázku 2.1. Tento proces se neustále opakuje po dobu dopadu světelného záření. Vnější vrstva článku bývá navíc ošetřena antireflexní vrstvou za účelem zvýšení absorpce sluneční energie.



Obrázek 2.1: Zleva: diagram znázorňující stavbu fotovoltaického článku a fotografie reálného článku zblízka.

2.1.2 Fotovoltaický Panel

Fotovoltaické články jsou spojovány do panelů. Jeden panel je složen z přibližně 60 článků, ale tato hodnota se může měnit v závislosti na jeho velikosti. Propojení fotovoltaických článků v jednom panelu bývá v sérii, kdy je kladný kontakt jednoho článku připojen na záporný kontakt článku následujícího. Celkové napětí takového panelu je součet napětí jednotlivých článků.



Obrázek 2.2: Diagram zapojení fotovoltaických článků v rámci jednoho panelu. Zelené šipky znázorňují tok elektrického proudu obvodem. List na jednom článku symbolizuje zastínění části panelu a tím vyřazení třetiny výkonu panelu.

Nastává zde však problém, když jeden z článků generuje nižší proud než ostatní, což může být způsobeno například zastíněním části panelu. V sériovém propojení odpovídá výsledný proud celého modulu proudu nejslabšího článku, což není efektivní. Zároveň může dojít k poškození daného článku, protože hromaděním proudu u slabšího článku dochází

k nárůstu jeho teploty, čímž vzniká takzvaný „hotspot“, který je podrobněji rozebrán v sekci 2.1.3. Řešením tohoto problému může být přidání ochranné propojky s diodou (anglicky bývá nazývána bypass diode), která umožní proudu obejít problematický článek, čímž jsou minimalizovány ztráty výkonu, a zároveň tato propojka chrání článek před již popsaným přehříváním [20]. Tyto propojky však výrobci kvůli náročnosti takového řešení a také z ekonomických důvodů nedávají okolo každého článku, ale okolo větších sérií. Na diagramu 2.2 lze vidět, že daný panel je složen z článků, které jsou sériově propojeny a současně panel disponuje třemi propojkami, jež dělí všechny články do tří skupin po 8 článcích. Pokud tedy bude zastíněn některý z článků, daná třetina panelu bude propouštět nízký proud, ale zbylé dvě třetiny panelu stále mohou fungovat na plný výkon. V případě, že by byly zastíněny některé články ze všech tří skupin panelu, výroba energie v tomto panelu bude sice minimální, ale stále bude umožněn průchod proudu z okolních panelů v rámci elektrárny a jednotlivé články panelu budou před tímto proudem chráněny.

Fotovoltaické panely lze různě sériově nebo paralelně propojovat pro dosažení potřebného napětí a proudu elektrárny jako celku. Tyto elektrárny lze tedy poměrně jednoduše škálovat od malých domácích elektráren na střechách domů až po velké výkonné elektrárny zabírající celé lány polí.

2.1.3 Detekovatelné chyby fotovoltaických panelů

Na fotovoltaických panelech se časem mohou objevit vady. Vznikají většinou kvůli vnějším vlivům, ale některé mohou vzniknout také při výrobě. Různé typy vad mají odlišný vliv na celkový výkon daného panelu či řady panelů. V následujících odstavcích budou některé tyto vady popsány. Vybrány byly typy vad, které lze detekovat termokamerou, tedy takové vady, jejichž detekce nevyžaduje žádnou manipulaci s panely. Ještě předtím je však důležité vysvětlit pojem hotspot.

Hotspot — Hotspot není přímo vada samotná, ale spíše důsledek některé z níže popsaných vad. Jedná se o lokální ohnisko vysoké teploty na fotovoltaickém panelu a na termosnímčích je dobře viditelný, jak je možné pozorovat na obrázku 2.3. Hotspoty lze rozdělit na několik kategorií podle rozdílu maximální teploty tohoto bodu panelu se „zdravou“ teplotou, která je zpravidla získávána ze stejné řady panelů. Hotspoty budou v rámci této práce rozděleny do tří kategorií, jak je popsáno v tabulce 2.1. Dané rozdělení bylo zadáno jako součást rozšířeného zadání této práce a je již v praxi využíváno. Kromě teplotního rozdělení tabulka také znázorňuje navrhovaná řešení problému pro každou kategorii.

Kategorie	Teplotní rozdíl [°C]	Ztráta výkonu	Navrhované řešení
1	(10; 15)	Nízká	Sledování
2	< 15; 30 >	> 5 %	Sledování
3	(30; ∞)	Až 20 %	Výměna

Tabulka 2.1: Rozdělení hotspotů do kategorií v závislosti na maximální teplotě.


Praskliny ve fotovoltaických článcích — Při výrobě článku mohou v křemíkové destičce vzniknout mikropraskliny, které z počátku nemusí mít negativní efekt na výkon článku. Časem však mohou tyto praskliny růst, což již snižuje výkonnost daného článku a v některých případech vede i k vytvoření hotspotu [25].

Stínění — Na množství dopadajícího světla není závislý pouze výkon článku, ale také jeho vodivost. Jak již bylo zmíněno v sekci 2.1.2, fotovoltaické články jsou v rámci jednoho panelu zapojeny sériově. Pokud je jeden z článků zastíněn, nepropouští dostatečné množ-



Obrázek 2.3: Ukázka hotspotů.

ství proudu vygenerovaného v okolních článcích, čímž dochází ke zvyšování napětí a také teploty. Dosažením průrazného napětí dojde ke zničení přechodu P-N a průchodu proudu článkem, což již způsobuje velmi vysoké teploty a zanechává trvalé následky [6]. Příčinou stínění bývají okolní budovy, stromy, či mraky. Častou příčinou také mohou být traviny a jiná zeleň zarůstající část panelu.




Obrázek 2.4: Ukázka prasklých fotovoltaických panelů.

Porušená schránka panelu — Za účelem ochrany před vnějšími vlivy jsou fotovoltaické články v rámci panelu zapouzdřeny do několika ochranných vrstev tak, aby byla zajištěná dostatečná ochrana a zároveň nedocházelo k vysoké ztrátě propustnosti světelných paprsků. Z horní strany jsou proto panely opatřeny skleněnou deskou. Prasknutí schránky panelu se projevuje vysokým množstvím vytvořených hotspotů, které jsou tvořeny z důvodu proniknutí vlhkosti dovnitř panelů [24]. Jak takové panely vypadají na termosnímčích je možné vidět na obrázku 2.4.

Porucha ochranné diody — Jak bylo popsáno v sekci 2.1.2, fotovoltaické články panelu jsou rozděleny do několika sérií, které jsou paralelně propojeny ochrannými propojkami. Každá propojka je vybavena diodou, která umožňuje průtok proudu pouze jedním

směrem. Tyto diody však mohou selhat, což vede ke snížení výkonnosti panelu a také k ohrožení fotovoltaických článků. V literatuře [2] autoři popisují dva typy selhání diody. Jedním z nich je případ, kdy dioda nedokáže propouštět žádný proud. Tato závada nemusí být hned detekovatelná, pokud jsou všechny články v dané části panelu bez závad. Obvod se totiž chová, jako by zde žádná ochranná propojka nebyla. V případě zastínění nebo jiných defektů jsou již články namáhány a hrozí vznik hotspotu. Druhý typ závady diody vzniká jejím zkratováním, kdy dioda ztrácí svou klíčovou vlastnost propustnosti proudu pouze jedním směrem a začne fungovat jako vodič, umožňující průtok oběma směry. V tomto případě vykazuje vyšší teplotu celý sloupec fotovoltaických článků, zabírající zpravidla jednu třetinu plochy panelu, jak je možné vidět na obrázku 2.5a. Tato vada nesnižuje pouze výkon daného panelu, ale také okolních panelů zapojených ve stejné sérii. Panel s touto vadou je tedy vhodné vyměnit či opravit, aby neubíral na výkonnosti ostatním zdravým panelům.



(a) Selhání diody na ochranné propojce.

(b) Příklad nefunkční řady panelů.

Obrázek 2.5: Detekovatelné typy vad fotovoltaických panelů, které se projevují jiným způsobem než hotspoty.

Nefungující řada fotovoltaických panelů — Z důvodu defektu v propojení nebo kombinací některých vad zmíněných výše může nastat situace, kdy elektřinu nevyrábí celá řada panelů, které jsou seřazeny v sérii. V tomto případě mají nevyrábějící panely opět vyšší teplotu než okolní panely. Takovýto případ je možné pozorovat na obrázku 2.5b.

2.2 Hardware

K provádění inspekce fotovoltaických elektráren je využíván dron, který snímá termosnímky a také barevné fotografie. V této sekci jsou popsány základní specifikace využitého dronu a kamery.

2.2.1 Dron

K provádění inspekce fotovoltaických elektráren je obecně zapotřebí dron, který je vybavený termokamerou, a který dokáže spolehlivě nasnímat celou plochu elektrárny tak, aby šlo z pořízených termosnímků vytvořit ortofoto. Datasets, které byly zpracovávány v této diplomové práci, byly pořízeny pomocí dronu DJI Matrice 200, který je možné vidět na

obrázku 2.6. (Pořízení datasetů nebylo součástí této práce.) Je to profesionální dron s vysokou kapacitou baterie, díky které zvládá létat až půl hodiny. Dron disponuje sedmi senzory, které slouží pro autonomní létání. Mezi ně patří přední stereovizuální systém, který dokáže detekovat překážky až do třiceti metrů. Infračervené senzory pak detekují překážky do vzdálenosti pěti metrů a vizuální senzor směřující dolů zase umožňuje precizní vznášení a přistávání dronu [15]. Tyto vlastnosti jsou důležité, jelikož při inspekci elektrárny není dron manuálně řízen. Místo toho je mu stanovena plocha, kterou má pokrýt, a na základě těchto informací je naplánovaná trasa, již má dron absolvovat, aby dokázal celou plochu rovnoměrně nasnímat. Dron pak autonomně létá po zadané trase a připojená kamera v pravidelných intervalech pořizuje snímky. Plánování trasy je prováděno pomocí pozemní stanice určené k ovládání dronu s názvem DJI PC Ground Station¹. Tento oficiální software společnosti DJI disponuje různými ovládacími prvky pro řízení dronu. Jeho výhodou je využití 3D Google map, díky kterým může uživatel snadno pozorovat aktuální polohu dronu nebo právě stanovovat plochu, kterou má dron nasnímat. Uživatel nastaví parametry kamery, požadovanou výšku snímání a také překrývání snímků ve vertikálním i horizontálním směru. Algoritmus pak automaticky na základě zvolených parametrů naplánuje misi dronu.



Obrázek 2.6: Dron DJI Matrice 200, který je využíván k inspekci fotovoltaických elektráren.

2.2.2 Termokamera

Na rozdíl od běžných barevných kamer snímá termokamera pro lidi neviditelnou část elektrického záření, konkrétně infračervené záření [21]. Toto záření bývá také nazýváno jako termální nebo tepelné záření. Čím teplejší je povrch tělesa, tím vyšší tepelné záření vyzařuje. Studená tělesa, jako například led, však také emitují detekovatelné množství tepelného záření, a proto je možné pomocí termokamer vidět všechny okolní objekty. Základní konstrukce termokamery se příliš neliší od barevných kamer. Také obsahuje čočky, které usměrňují paprsky záření tak, aby dopadaly na obrazový senzor. Vlnová délka infračerveného záření je vyšší než viditelné spektrum, a proto musí být také jednotlivé pixely senzoru termokamery větší. Kvůli tomu tyto kamery zpravidla disponují nižším rozlišením. Termokamera, kterou byly nasnímány datasety využité v této diplomové práci, byla vyrobena společností DJI a kombinuje její technologie stabilizace leteckých kamer s termovizními technologiemi společnosti FLIR. Termokamery FLIR dokáží snímat teplotu s přesností až 0,01 °C [5]. Výstupem kamery jsou snímky ve formátu JPEG, do kterého jsou teplotní infor-

¹DJI PC Ground Station: <https://www-v1.dji.com/pc-ground-station.html>

mace zapsány v rámci metadat a pro jejichž extrakci je potřeba využít dostupné knihovny pro práci s termovizními snímky. Fotografie termokamery FLIR se nachází na obrázku 2.7.



Obrázek 2.7: Termokamera DJI Zenmuse XT.

2.3 Software

K analýze termosnímků zkoumané elektrárny je v současné době využíván software FLIR Tools, přičemž ortofotomapy jsou z těchto snímků vytvářeny pomocí softwaru Agisoft. V této části jsou oba programy popsány. Dále je zde popsán software OneDroneMap, což je alternativa pro software Agisoft. Program Exiftool a knihovnu Flir Image Extractor lze zase využít pro načítání teplotních dat z termosnímků. Součástí této práce bylo také vytvoření anotací pro segmentaci fotovoltaických panelů, a proto je v této sekci stručně popsána také knihovna OpenCV, která byla využita mimo jiné pro vytvoření skriptu, jež snímky anotuje, a tyto anotace pak byly ručně opravovány pomocí nástroje Label Studio.

2.3.1 Agisoft

Firma Agisoft byla založena v roce 2006 jako inovativní výzkumná společnost zaměřující se na počítačové vidění. Aktuálně je jejím produktem stejnojmenný software², který umožňuje rekonstrukci 3D modelů objektů ze série pořízených fotografií. Daný software má mnoho funkcí, ale v kontextu inspekce fotovoltaických elektráren je využíván pro tvorbu ortofota. Ortofoto je druh mapy, na které jsou objekty geometricky zarovnány, čehož je dosaženo vytvořením 3D modelu snímaného povrchu [22]. Software Agisoft prokázal ve tvorbě ortofota velmi dobré výsledky. V současné době je při ručním zpracování termosnímků elektráren využíván.

2.3.2 OpenDroneMap

Tento projekt³ poskytuje celý ekosystém nástrojů pro sběr, zpracování a zobrazení leteckých dat. S jeho pomocí je tedy možné vytvářet ortofoto stejně jako s již dříve zmíněným programem společnosti Agisoft. Celý projekt je zpracováván jako open source, což znamená, že jej lze bezplatně využít a zároveň je zveřejněn jeho zdrojový kód, takže si lze případně také upravit jeho funkcionalitu.


²Software Agisoft je dostupný zde: <https://www.agisoft.com>

³Projekt OpenDroneMap je dostupný zde: <https://www.opendronemap.org>

OpenDroneMap i Agisoft software dokáže z nahraných fotek vytvořit 3D model celé snímané plochy a na tento model namapovat pořízené fotografie. Ortofoto je pak zachycením pohledu na daný model se shora. Tento přístup vykazuje mnohem lepší výsledky než například pouhé sešívání obrázků, nehledě na to, že umožňuje na jednotlivé fotky ručně přidávat kontrolní body a jinak interaktivně upravovat vygenerovaný model za účelem dosažení co nejvyšší přesnosti. Software OpenDroneMap lze využívat pomocí příkazového řádku anebo nabízí uživatelské rozhraní ve formě webové aplikace a kromě toho také sady nástrojů pro různé programovací jazyky, aby jej šlo jednoduše integrovat do dalších projektů. Podporuje také zpracování multispektrálních snímků. Díky tomu má výsledné ortofoto kromě obrazové vrstvy také například termální vrstvu s reálnými teplotními daty.

2.3.3 FLIR

Společnost Teledyne FLIR se zaměřuje na vývoj a výrobu technologií v oboru termografie. Její produkty dodává vládním organizacím, jako jsou obranné a záchranné složky, nebo do průmyslu. Hlavním produktem jsou tedy termokamery a software pro obsluhu těchto kamer a také pro zpracovávání nasnímaných dat [23].



Obrázek 2.8: Ukázka možných měření v programu FLIR Tools.

V kontextu inspekce fotovoltaických elektráren je právě termokamera společnosti Teledyne FLIR využita a v současném stavu je pro zkoumání pořízených termofotografií po-

užíván software FLIR Tools, který je zdarma dostupný ke stažení⁴. Software FLIR Tools načte pořízené termosnímký ze zvoleného adresáře a ihned při načítání veškeré fotografie zpracovává za účelem vyčtení teplotních dat pro jednotlivé pixely. Dostupné nástroje pro práci s fotografií by šlo rozdělit do dvou skupin, a to na globální a lokální. Mezi globální operace spadá nastavení některé z dostupných barevných palet pro vylepšení viditelnosti rozdílných teplot, nebo lze barvy obrázku nastavit dle zadaného intervalu. Samozřejmě je také ořezání naměřených hodnot nastavením maximální a minimální teploty, se kterými chce uživatel pracovat. Mezi lokální operace náleží měření teploty zvoleného bodu, nebo plochy ve tvaru obdélníku, kruhu nebo úsečky. Všechna měření jsou vypsaná v postranní tabulce, jak je možné vidět na obrázku 2.8. Výsledek měření lze exportovat jako zprávu, do které lze dále přidávat textová pole a další prvky.

2.3.4 ExifTool

ExifTool⁵ je nástroj nezávislý na platformě a slouží ke čtení, zápisu a úpravě metadat různých typů souborů, jako jsou JPG, PDF, TIFF a další. V kontextu této práce je využíván pro načítání teplotních metadat z termosnímků, nebo k úpravě metadat vygenerovaných snímků, aby je bylo možné zpracovat softwarem Open Drone Map v multispektrálním módu. Lze jej spouštět z příkazového řádku, ale existuje také Python balíček PyExifTool⁶, který jeho funkcionalitu integruje do jazyka Python.

2.3.5 Flir Image Extractor

Termokamery společnosti FLIR ukládají termosnímký do formátu JPG. Aby byly objekty nasnímané kamerou dobře viditelné, teplotní data jsou mapována na 256 odstínů šedi tak, aby pokryla co největší rozsah. Hodnota pixelu v tomto obrázku tedy neodpovídá reálné teplotě objektu. Teplotní data jsou však v těchto souborech také uložena, a to ve formě metadat, a programy společnosti Teledyne FLIR je pak umí načíst.

Knihovna Flir Image Extractor⁷ byla implementována pro jazyk Python a její hlavní funkcionalitou je právě vyčtení reálných teplotních dat z metadat termosnímků. Metadata z termosnímků získává pomocí nástroje ExifTool.

2.3.6 OpenCV

OpenCV (Open Source Computer Vision Library) je open source knihovna zaměřující se na počítačové vidění a strojové učení. Obsahuje více než 2500 optimalizovaných implementací zastupující obsáhlou sadu klasických i nejmodernějších algoritmů v oblasti počítačového vidění [16]. Tato knihovna je napsaná v jazyce C++ a disponuje také rozhraními pro jazyky Python, JAVA a MATLAB. Samozřejmě je podpora všech běžných operačních systémů. Využívána je velkými firmami, jako jsou Google nebo Microsoft, ale také různými startupy. V této práci byly algoritmy knihovny OpenCV využity ke zpracování termosnímků pro dosažení vyšší kvality ortofota, nebo například k vytvoření pomocných skriptů k vytvoření anotací pro segmentaci panelů.

⁴Software FLIR Tools: <https://support.flir.com/SwDownload/app/RssSWDownload.aspx?ID=1247>

⁵Nástroj Exiftool je dostupný zde: <https://exiftool.org/>

⁶Balíček PyExifTool je dostupný zde: <https://github.com/sylikc/pyexiftool>

⁷Knihovna Flir Image Extractor: <https://github.com/nationaldronesau/FlirImageExtractor>

2.3.7 Label Studio


Label Studio⁸ je opět open source projekt, který vyvíjí nástroj pro vytváření anotací, jež lze následně využít k trénování neuronových sítí. Jde o pokročilý nástroj, který mimo jiné umožňuje týmovou spolupráci a podporuje široké spektrum anotací textu, obrazových dat či videí. Umožňuje také napojení přímo na trénovaný model a jiné užitečné funkce. Zároveň také podporuje integraci do jazyka Python a díky tomu lze některé procesy automatizovat pomocí skriptů.

2.4 Modely pro zpracování obrazu

Některé části této diplomové práce budou využívat natrénované modely pro zpracování obrazu. V této sekci jsou tedy stručně popsány základní principy modelů, které byly v této práci použity.

2.4.1 ResNet

ResNet, neboli Residual Network, je architektura neuronové sítě, která řeší problémy při trénování modelů s velkým množstvím vrstev. U předchozích modelů se objevoval problém s propagací užitečných informací, pokud měl daný model příliš mnoho vrstev. He a kol. [9] ve svém článku přišli s řešením tohoto problému, a to pomocí přidání takzvaných skip connections. Jedná se o propojky, které obcházejí jednu nebo více vrstev, a díky nim se mohou užitečné informace dostat i k hlubším vrstvám. Data z této propojky jsou přičtena k výstupu z vrstev, které obcházejí. ResNet má mnoho variant podle počtu bloků a je zakomponován do mnoha dalších modelů. Graficky je jeden blok modelu ResNet znázorněn na obrázku 2.9.




Obrázek 2.9: Ukázka principu propojky v jednom bloku modelu s ResNet architekturou. Převzato z [9]

2.4.2 Mask R-CNN

Tento model slouží k segmentaci instancí objektů a vychází z modelu Faster R-CNN, který však detekuje pouze obalové obdélníky objektů. He a kol. [8] tento model vylepšili tak, že výstupem Mask R-CNN modelu jsou také masky jednotlivých objektů. Díky tomu lze pro každý pixel určit, zdali je součástí daného objektu, nebo ne.

Vstupní obrázek je nejprve zpracován backbone, neboli páteřní sítí. Zde je využit model typu ResNet, který z obrázku extrahuje důležité informace. Ty jsou poté předány na vstup

⁸Projekt Label Studio je dostupný zde: <https://labelstud.io>



Obrázek 2.10: Znázornění principu fungování modelu Mask R-CNN. Převzato z [8]

části Region Proposal Network, která na jejich základě vytipuje takzvané oblasti zájmu, ve kterých by se mohl nacházet objekt pro segmentaci. Tyto oblasti jsou nazývány jako Region of Interest (RoI). Pro každou takovou oblast jsou pak v sekci modelu nazvané RoIAlign z informací, které byly na výstupu sítě ResNet, vybrány ty informace, které se vztahují k dané předpovězené oblasti zájmu. Oblasti s přiřazenými informacemi jsou následně zpracovávány paralelně ve dvou větvích. Výstupem jedné je predikovaná třída objektu a jeho obalový obdélník a druhá větev zase vygeneruje již zmíněnou masku daného objektu.


Tento model lze poměrně snadno trénovat a využívat pomocí frameworku Detectron2⁹, který vyvíjí společnost Meta Platforms (dříve Facebook).

2.4.3 Vision Transformer

Vision Transformer je model aplikující architekturu modelu Transformer, který byl navržen pro zpracovávání přirozeného jazyka, na obrazová data [3]. Je to přímý konkurent konvolučních sítí a dokáže mít lepší výsledky, pokud je trénován na dostatečném množství dat.

Obrázek na vstupu je rozdělen na menší části, zpravidla 16 x 16 pixelů, nebo 32 x 32 pixelů. S každou takovou částí je pracováno podobně jako s tokenem v případě zpracování přirozeného jazyka. Tyto části obrázku jsou následně zakódovány do vektorového prostoru, je jim přidána informace o původní poloze a následně jsou předány původnímu modelu Transformer. Transformer využívá mechanismus self-attention, pomocí kterého modeluje závislosti mezi jednotlivými tokeny. V případě Vision Transformeru jsou tedy modelovány závislosti mezi různými částmi obrázku. Tyto závislosti jsou zkoumány globálně v rámci celého obrázku, což je rozdíl od konvolučních sítí, které se zaměřují spíše na lokální závislosti. Na výstup transformeru je přidána klasifikační hlava, která určuje, s jakou pravděpodobností vstupní obrázek spadá do jednotlivých tříd. Grafické znázornění fungování tohoto modelu je možné vidět na obrázku 2.11.

⁹Framework Detectron2 je dostupný zde: <https://github.com/facebookresearch/detectron2>



Obrázek 2.11: Znázornění principu fungování modelu Vision Transformer. Převzato z [3]

2.5 Data

Součástí této práce je trénování neuronových sítí, které budou využity k segmentaci fotovoltaických panelů z termosnímků a následné klasifikaci panelů podle typu vad. Z toho důvodu bylo potřeba vytvořit nebo získat dva různé datasety, které jsou popsány v této sekci. Kromě anotovaných datasetů pro trénování tato diplomová práce používá také datasety termosnímků, které byly pořízeny snímáním několika českých solárních elektráren pomocí termokamery a dronu externím pracovníkem. Ten pak tyto datasety poskytl fakultě na výzkumné účely.


2.5.1 Segmentace fotovoltaických panelů

Segmentace instancí objektu (Instance Segmentation) je typem segmentace, kde je každému pixelu přiřazena jeho příslušnost k nějaké instanci neboli objektu. V tomto případě je danou instancí jeden fotovoltaický panel. Úloha segmentace instancí panelů z termosnímků nejspíše není nejběžnější, jelikož se v rámci průzkumu dosavadních řešení nepodařilo nalézt veřejný dataset, který by vyhovoval pro tuto úlohu.

Filip Haužvic ve své bakalářské práci [7], která je podrobněji popsána v sekci 2.6.3, vytvořil malý dataset, jehož anotace lze využít. Daný dataset byl vytvořen ze snímků pořízených měřením pouze jedné elektrárny, což není dostačující, jelikož natrénovaný model na tomto datasetu má problém se zpracováním snímků z jiných elektráren. Proto musí být tento dataset doplněn o další anotované snímky pořízené z měření ostatních elektráren. Ukázka anotací se nachází na obrázku 2.12.

2.5.2 Klasifikace vad fotovoltaických panelů

K detekci vad fotovoltaických panelů lze přistupovat minimálně dvěma způsoby. Jedním z nich je detekce jednotlivých hotspotů, jako to bylo implementováno v bakalářské práci po-



Obrázek 2.12: Ukázka anotovaných snímku pro trénování segmentace instancí panelů.


psané v sekci 2.6.3, nebo lze natrénovat model pro klasifikaci panelů, který dokáže rozlišovat různé druhy vad fotovoltaických panelů, se kterými se lze podrobněji seznámit v sekci 2.1.3.

Existuje veřejně dostupný dataset [14], který slouží právě ke klasifikaci panelů. Ten obsahuje 20 000 obrázků panelů o velikosti 24 x 40 pixelů. Rozlišení obrázků je v rozmezí 3–15 cm/pixel, jelikož byly nasnímány z různých letových výšek. Obrázky v datasetu jsou rozděleny do celkem 12 tříd, kdy jedna je zdravý panel a zbylých 11 jsou různé typy vad. V tabulce 2.2 jsou všechny třídy popsány. Důležitým údajem v tabulce je počet obrázků v každé třídě. Je zřejmé, že třídy zde nejsou vyvážené, a dle autorů datasetu je to záměr. Rozložení obrázků do tříd odpovídá rozložení výskytů daných defektů panelů v reálném světě.

Název třídy	Počet	Popis
Cell	1 877	Vadný fotovoltaický článek
Cell-Multi	1 288	Vícero vadných fotovoltaických článků
Cracking	941	Poškození obálky panelu
Diode	1 499	Porucha ochranné diody
Diode-Multi	175	Porucha dvou ochranných diod
Hot-Spot	251	Hotspot na tenkovrstvém fotovoltaickém panelu
Hot-Spot-Multi	247	Vícero hotspotů na tenkovrstvém fotovoltaickém panelu
No-Anomaly	10 000	Funkční panel
Offline-Module	828	Odpojený panel
Shadowing	1 056	Stínění panelu
Soiling	205	Špinavý panel
Vegetation	1 639	Panely porostlé vegetací

Tabulka 2.2: Výpis všech tříd datasetu.

Třídy Hot-Spot a Hot-Spot-Multi nebudou v této práci využity, protože označují chyby vyskytující se pouze na tenkovrstvých solárních panelech, které nejsou instalovány ani v jedné ze zkoumaných elektráren. Na obrázku 2.13 je možné pozorovat ukázky panelů z každé třídy.



Obrázek 2.13: Ukázka panelů jednotlivých tříd z datasetu určeného pro klasifikaci fotovoltaických panelů. Obrázky byly převedeny z odstínu šedi do barevného spektra za účelem zvýraznění detailů.


2.6 Současná řešení

V této sekci jsou popsány některé přístupy řešení podobného problému, které jsou dostupné z literatury. Ne všechny navrhované postupy lze v rámci této práce využít, jelikož samotná práce s dronem a řešení pořizování termosnímků fotovoltaické elektrárny není součástí zadání této práce. Některé informace z této sekce však mohou posloužit jako inspirace pro budoucí práce a případná vylepšení nebo rozšíření celého systému.

2.6.1 Článek *Failure detection of solar panels using thermographic images captured by drone*

Higuchi a kol. [11] zkoumají různé metody detekce vad z pohledu jejich přesnosti a časové náročnosti. Měření provedli na fotovoltaické elektrárně o výkonu 4 MW. Ruční měření bylo složeno ze dvou částí. První z nich je měření odporu řady dvanácti panelů, což však nedokáže přesně lokalizovat vadný panel, a proto bylo toto odporové měření doplněno měřením magnetického pole na povrchu jednotlivých panelů. Druhou metodou bylo měření za pomoci termokamery a dronu. Ruční měření jim zabralo okolo 20 hodin a detekovali 45 vad, inspekci za pomoci termokamery a dronu detekovali 38 vad za 4 hodiny. (Zde je nutno dodat, že v tomto případě není sada rozlišovaných defektů tak rozsáhlá a měření není tak podrobné, takže i ruční kontrola zabrala kratší dobu, než při metodě, kterou se snaží algoritmizovat tato diplomová práce.) Došli tedy k závěru, ze kterého vychází i zadání této práce, že je efektivnější provádět měření dronem, i když nemusí být tak přesné.

Dále se autoři pokusili automatizovat detekci vad. Za tímto účelem vyzkoušeli dvě metody. První z nich sestává z předzpracování termosnímků a následnou klasifikaci jednotlivých panelů pomocí konvoluční neuronové sítě. Pro předzpracování byla využita knihovna OpenCV. Předzpracování obnášelo binarizaci obrázku, detekování kontur jednotlivých panelů a následně rozřezání obrázku tak, že každý panel měl okolo sebe ponechán prostor pro jeho sousedící panely. Výsledkem je tedy obrázek s mřížkou o velikosti 3x3 panely. V případě panelu, který se nacházel na okraji obrázku, byla do jeho okolí doplněna neutrální hodnota. Panely byly také v rámci oříznutého obrázku vždy zarovnány, jak je možné vidět na obrázku 2.14. Detekovatelné defekty rozdělili pouze do dvou tříd, a to defekt části panelu a nefunkční celý panel. Tímto předzpracováním získali dataset obsahující 1382 normálních panelů, 892 panelů s defektem jejich části a 56 celkově nefunkčních panelů. Pro trénování využili 95 % obrázků datasetu a na verifikaci ponechali 5 %. Po 18. epoše dosáhl jejich model 100% přesnosti. Zároveň se však tato metoda ukázala jako problematická, jelikož jejich proces předzpracování nefungoval na všechny termosnímky. Pokud bylo v době snímání slabé sluneční záření, rozdíl teplot mezi fotovoltaickými panely a jejich okraji nebyl dostatečný, a proto se autorům článku nepodařilo provést binarizaci v požadované kvalitě, a tím pádem ani nalézt kontury jednotlivých panelů. Metoda binarizace se celkově projevila jako poměrně nestabilní, jelikož zde bylo potřeba stanovit správný práh, který se však v rámci jednotlivých snímků měnil v závislosti na povětrnostních podmínkách, výšce letu a dalších proměnných.



Obrázek 2.14: Ukázka předzpracování termosnímku pro klasifikační model. Vlevo nahoře se nachází původní obrázek, vlevo dole binarizace obrázku, (a, b) zdravé fotovoltaické panely, (c, d) defekt zabírající část panelu, (e, f) nefunkční celý panel. [11]

Druhým pokusem bylo využití metody strojového učení s názvem single shot detection (SSD). Jako trénovací data jsou zde původní termosnímky, pro které vytvořili anotace. Mezi anotované třídy v tomto případě opět patřily defekty části panelu a nefunkční panel. K těmto třídám přidali v anotacích jejich pozice na obrázcích pomocí souřadnic levého horního rohu a pravého dolního rohu. Výsledný dataset sestával z 1060 obrázků, které obsahovaly 1412 defektů částí panelu, 17 nefunkčních panelů a 114 nefunkčních řad panelů. Natrénovaný model vykazoval problémy s detekcí nefunkčních panelů, což bylo dle autorů

způsobeno nedostatkem trénovacích dat této třídy. Validační dataset obsahoval 299 defektů zabírajících část panelu a 14 nefunkčních panelů. Model detekoval 314 částečných defektů a 1 nefunkční panel. Je zřejmé, že v některých případech model predikoval vadu i na funkčním panelu a celé nefunkční panely zahrnul do třídy s částečnými defekty. Pro evaluaci modelu autoři zvolili metriku mean average precision (mAP), která udává průměrnou přesnost v rámci všech tříd, která dosáhla hodnoty 49,11 %. Hlavním nedostatkem této metody tedy byl nevyvážený trénovací dataset.

Poslední metodou testovanou v tomto článku bylo vytvoření ortofota. Pro tento úkol využili software OpenDroneMap. Výsledná mozaika však obsahovala chyby připomínající defekty zabírající část plochy panelu, které vznikly v důsledku různé úrovně jasu v jednotlivých snímcích, což může být způsobeno například mraky, které mohly v okamžiku vyfocení jedné fotky snížit sluneční záření anebo se mohlo jednat o prostý odraz způsobený různou pozicí dronu s kamerou.

Z tohoto článku tedy vyplývá, že metoda inspekce fotovoltaických elektráren pomocí termokamery a dronu je efektivní metodou. Pouhou binarizací nelze spolehlivě segmentovat fotovoltaické panely a při tvorbě orthografické mozaiky zase mohou vzniknout chyby podobající se detekovatelným defektům. Zároveň by však mělo být možné natrénovat model pro detekci defektů panelů, pokud bude k dispozici dostatek trénovacích dat.

2.6.2 Článek *Automatic Detection System of Deteriorated PV Modules Using Drone with Thermal Camera*

Henry a kol. [10] vytvořili poměrně robustní postup inspekce fotovoltaických elektráren pomocí dronu. Zabývají se nejen zpracováním nasnímaných snímků, ale také plánováním dráhy letu dronu a konstrukcí duální kamery.

Pro plánování dráhy dronu navrhují buďto využití dostupných leteckých map, nebo nasnímaní celé plochy elektrárny barevnou kamerou a vytvoření vlastního ortofota. Z dostupného ortofota poté segmentují jednotlivé řady panelů, k čemuž doporučují využít prahování v HSV barevném systému, následující nalezením kontur a jejich filtrací v závislosti na velikosti. Výsledkem by měly být kontury ohraničující celé řady panelů a dráha letu dronu by měla procházet nad každou řadou.

Snímání elektrárny vylepšili vytvořením duální kamery, která je složena z termokamery a barevné kamery. Obě jsou ovládány pomocí počítače Raspberry Pi, který zajišťuje, že jsou snímky obou kamer pořízeny ve stejný okamžik. Doplnění termosnímků o snímky barevné využívají k přesnější segmentaci fotovoltaických panelů a poté také ke klasifikaci příčiny defektů. Během analýzy pořízených dvojic snímků je nejprve segmentována řada fotovoltaických panelů z barevných snímků. Následně je provedeno zarovnání termosnímků s tím barevným, což je potřeba, protože jsou zpravidla lehce posunuty, jelikož čočky kamer jsou od sebe pár centimetrů vzdálené. Poté autoři přidávají krok zarovnání panelu do vodorovné polohy pro lehčí orientaci a následně rozdělení řady panelů na jednotlivé panely a klasifikaci, zdali některý z panelů obsahuje defekt.

Zajímavý je také jejich návrh grafického rozhraní vytvořené aplikace, kdy je uživateli zobrazeno ortofoto, na kterém jsou vyznačeny pozice pořízených snímků a barevně zvýrazněny snímky, na kterých byl detekován defekt. Uživatel si poté rozkliknutím dané značky snímku může zobrazit barevnou fotografii, stejně jako termosnímek a také výstup analýzy vyznačující, na kterém panelu se defekt nachází. Snímek grafického rozhraní je možné vidět na obrázku 2.15. Tento přístup se jeví jako intuitivní a nápomocný při identifikaci přesné polohy poškozeného panelu v rámci celé elektrárny. Zároveň lze díky přítomnosti



Obrázek 2.15: Ukázka grafického rozhraní představeného v článku [10].

barevného snímku zjistit, zdali není příčina hotspotu například zeleň, či jestli nemá panel viditelné praskliny.

2.6.3 Detekce a klasifikace vad panelů fotovoltaických elektráren z termokamery dronu

Filip Haužvic řeší ve své bakalářské práci [7] podobné zadání jako tato diplomová práce a jeho práce také vznikla na stejné fakultě. Tato práce se nezabývá tvorbou ortofota a proces jeho vytvoření je tedy přenechán na uživateli. Pro jeho práci využil ortofoto vytvořené nástrojem společnosti Agisoft, která byla součástí poskytnutého datasetu termosnímků solární elektrárny.

Zaměřuje se na segmentaci panelů z již hotové mozaiky a také detekci hotspotů. Pro segmentaci panelů využívá model Mask R-CNN, který trénoval na datasetu, jenž sám vytvořil anotováním některých dostupných snímků. K detekci vad panelů přistupuje jako k problému sémantické segmentace, kdy se snaží ze snímků segmentovat jednotlivé hotspoty pomocí neuronové sítě architektury U-Net. Pro trénování si opět vytvořil vlastní anotace. Výsledné řešení nezpracovává jednotlivé termosnímky, ale místo toho rozřezává ortofoto na menší díly, a ty dává na vstup neuronovým sítím, díky čemuž je celý proces rychlejší.

Pan Haužvic pracuje s daty získanými z jedné elektrárny a na nich má velmi dobré výsledky. Při testování jeho řešení se však objevily určité problémy při zpracování dat z jiných elektráren. Přesto však zejména část segmentace fotovoltaických panelů byla využita jako základ, ze kterého vychází i tato diplomová práce. Součástí jeho práce byla také tvorba jednoduché webové aplikace, která zapouzdřuje jeho navržený proces detekce vad. Umožňuje interaktivně zobrazit detekované panely a hotspoty a případně ručně přidat další anotace, jak je možné vidět na obrázku 2.16.




Obrázek 2.16: Ukázka grafického rozhraní vytvořeného v rámci bakalářské práce [7].

2.6.4 Článek *An innovative transformer neural network for fault detection and classification for photovoltaic modules*

Ramadan a kol. [19] se zabývají problémem klasifikace vad fotovoltaických panelů za pomoci modelu typu Vision Transformer. Využívají k tomu veřejný dataset termosnímků fotovoltaických panelů, které jsou roztrženy do dvanácti tříd. V sekci 2.5.2 je tento dataset podrobněji popsán. Autoři článku navrhuji před samotným trénováním zvýraznit detaily na snímcích. Toho je docíleno s využitím metody `ImageFilter.UnsharpMask()`, která je dostupná v Python balíčku Pillow.

Počet obrázků v jednotlivých třídách se pohybuje v rozmezí 175 až 10 000 obrázků. Autoři článku proto navrhuji vyrovnat rozložení tříd tak, aby každá třída obsahovala 2 100 snímků. Ve třídách s nižším počtem snímků toho dosáhli s využitím metody oversampling, neboli převzorkování. Tato metoda spočívá v aplikování augmentací na původní snímky, ze kterých jsou poté vygenerovány snímky nové, které byly upraveny pomocí definovaných augmentačních funkcí. Konkrétně se jedná o náhodné vertikální nebo horizontální překlopení obrázku a úpravu jasu. Vyrovnání počtu snímků v jednotlivých třídách by dle autorů mělo pomoci s rovnoměrným trénováním všech typů vad. Takto vygenerovaný dataset poté rozdělili na trénovací, validační a testovací sety v poměru 80 %, 10 % a 10 %.

Navržený model využívá architekturu Vision Transformer, konkrétně ViT-B32. Tento model vstupní obrázek rozdělí na části o velikosti 32x32 pixelů a obsahuje 12 vnitřních Transformer Encoder vrstev. K tomu autoři přidali paralelní větev. Tou je prakticky druhý Vision Transformer, jenž vstupní obrázek rozdělí na části o velikosti 8x8 pixelů a má pouze jednu Transformer Encoder vrstvu. Výstupy obou větví jsou pak spojeny a poslány do klasifikační hlavy, jejímž výstupem jsou již pravděpodobnosti příslušnosti snímku do jednotlivých tříd. Graf tohoto modelu se nachází na obrázku 2.17. Vytvořený model využívá předtrénované vrstvy v původní větvi a druhá větev je trénována od nuly. Natrénovaný




Obrázek 2.17: Graf modelu navrženého autory článku: An innovative transformer neural network for fault detection and classification for photovoltaic modules [19].

model dle článku dosahuje 95% přesnosti pro 12 tříd a až 98% přesnost pro dvě třídy, tedy funkční panel, nebo vadný panel.

2.6.5 Článek *Thermal inspection of photovoltaic modules with deep convolutional neural networks on edge devices in AUV*

Le a kol. [12] se opět zabývají úlohou klasifikace vad fotovoltaických panelů z termosnímků. Využívají k tomu stejný dataset jako předchozí článek (2.6.4). Navržený model je však čistě konvoluční a poměrně malý. Autoři jej totiž navrhovali tak, aby mohl vstupní snímky zpracovávat v reálném čase, a to na modulu Jetson Nano, který je připevněn k dronu.

Zmíněný dataset sice nemá stejný počet snímků v každé třídě, ale to je dle jeho autorů záměr, jelikož takové rozložení odpovídá četnosti reálnému výskytu jednotlivých chyb [14]. Autoři tohoto článku tedy neprovádí oversampling, ale pouze dataset rozdělili na trénovací část, která obsahuje 80 % datasetu, a zbytek připadl validační části. Rozdělení bylo uděláno v každé třídě zvlášť, aby se zachoval jejich poměr.



Obrázek 2.18: Graf modelu navrženého autory článku: Thermal inspection of photovoltaic modules with deep convolutional neural networks on edge devices in AUV [12].

Navržený model je složen ze 4 bloků, kde každý blok obsahuje konvoluční vrstvu, aktivační vrstvu ReLU, Maxpooling vrstvu a batch normalization vrstvu. Vstupní obrázek má rozměry 40 x 24 pixelů a každý blok zmenší jeho velikost na polovinu, zatímco zdvojnásobí počet kanálů. Za těmito čtyřmi bloky se nachází Global Average Pool vrstva, následovaná plně propojenou vrstvou, která slouží jako klasifikační hlava. Grafické znázornění modelu je možné pozorovat na obrázku 2.18. Tento model nevyužívá předtrénované vrstvy, ale vzhledem k jeho velikosti ho lze poměrně rychle natrénovat od nuly. Natrénovaný model dosahuje 85% přesnosti pro dvanáct tříd.

Kapitola 3

Posouzení současného stavu a návrh jeho automatizace

V předchozí kapitole byly popsány různé druhy přístupu k řešení problému inspekce fotovoltaických elektráren pomocí termokamery a dronu. V této kapitole jsou předchozí přístupy zhodnoceny a na základě získaných poznatků byl stanoven návrh řešení, který bude implementován a testován v této diplomové práci.

3.1 Zhodnocení současného stavu

V současné době je detekce vad fotovoltaických panelů prováděna ručně. Nejprve je elektrárna nasnímána dronem s termokamerou a následně musí zaměstnanec ručně procházet jednotlivé snímky, měřit v nich teplotu pomocí nástroje Flir Tools (2.3.3) a hledat na panelech případné vady. Poměrně náročnou úlohou je určení polohy vadného panelu v kontextu celé elektrárny, jelikož na jeden snímek se vleze pouze její malá část. S určováním polohy pomáhá vytvoření ortofota z pořízených snímků. K tomu je v současné době využíván software společnosti Agisoft (2.3.1). Kvalita výsledné mapy je velmi dobrá, problémem však je vysoká cena licence, kvůli čemuž tento software nelze v rámci této práce použít. Variantou k nástroji firmy Agisoft je software projektu OpenDroneMap (2.3.2), který je vyvíjen jako open source. Odpadá zde tedy problém s licencí. Tento software byl testován a kvalita výsledných ortofotomap je pro tuto práci dostačující. Ruční proces zpracování pořízených termosnímků je velmi pracný a zabere spoustu hodin, proto je nevyhovující.

Autoři Higuchi a kol. [11] se ve své práci (blíže popsané v sekci 2.6.1) snažili segmentovat fotovoltaické panely pomocí binarizace. Tato metoda není dostatečně robustní, jelikož uživatel musí nastavit správný práh pro binarizaci, který se navíc může měnit v závislosti na povětrnostních podmínkách nebo například výšce letu. Detekci vadných panelů zkoušeli řešit také pomocí natrénované konvoluční sítě, na jejíž vstup předkládali celé termosnímky. Trénovali na vlastním vytvořeném datasetu, který však neměl dostatečný počet vadných panelů, a proto natrénovaný model nedosahoval uspokojivé přesnosti. Pokusili se také vyřešit problém určení polohy jednoho panelu v kontextu celé elektrárny. Vytvořili tedy ortofoto a na něm detekovali vadné panely. Narazili však na problém, když sousedící termosnímky měly různou úroveň jasu, což pak způsobovalo na mapě artefakty, které byly mylně vyhodnoceny jako defekty panelů.

Rozsah článku od autorů Henry a kol. [10], který je popsán v sekci 2.6.2, je poměrně obsáhlý a součástí této diplomové práce není řešení hardwarové části inspekce. Proto není

možné vytvořit duální kameru, která by snímala jak teplotní, tak barevná data. Některé dostupné datasety českých fotovoltaických elektráren sice byly nasnímány také barevně, ale z mnohem větší výšky, než v jaké byly pořízeny termosnímkami, takže metoda dvojic snímků pro detekci vad fotovoltaických panelů zde nelze využít. Na druhou stranu postupy, jako například plánování trasy dronu na základě pozice jednotlivých řad panelů, by mohly být zadáním pro budoucí práce.

Filip Haužvic ve své bakalářské práci [7] popsané v sekci 2.6.3 očekává, že si uživatel vytvoří ortofoto sám, a to pak nahraje do jeho aplikace. Přenechává tak část práce na uživateli. Zároveň pracuje pouze s obrazovými daty a z ortofota není možné zpětně vyčíst reálnou teplotu pro daný pixel. Pracuje s daty získanými pouze z jedné elektrárny a na nich má velmi dobré výsledky. Při testování jeho řešení na datasetech inspekci jiných elektráren však byla přesnost detekce horší. Z toho vyplývá, že by bylo potřeba rozšířit datasety pro trénování, aby měly natrénované modely vyšší míru generalizace. Výsledné řešení také není schopné rozlišovat mezi různými druhy vad a místo toho pouze detekuje jednotlivé hotspoty a je opět na uživateli, aby klasifikoval, o jakou závadu se jedná. Přesto by však minimálně řešení segmentace fotovoltaických panelů mohlo být využito jako základ pro tuto diplomovou práci.

Autoři Ramadan a kol. [19] a Le a kol. [12] se ve svých článcích (popsaných v sekcích 2.6.4 a 2.6.5) zabývají úlohou klasifikace vad fotovoltaických panelů a v obou případech využívají stejný dataset pro trénování (2.5.2). Tento dataset pokrývá všechny důležité typy defektů fotovoltaických panelů, a proto by mohl být přístup trénování klasifikace lepší než pouhá detekce hotspotů. Konvoluční model dosahuje nižší přesnosti, ale na druhou stranu je značně menší a rychlejší než Vision Transformer. Proto byla vyzkoušena obě řešení a jejich výsledky byly porovnány.

3.2 Návrh řešení

Návrh řešení zadání této diplomové práce by šlo rozdělit do pěti bloků, a to na přípravu datasetu, tvorbu ortofota, segmentaci fotovoltaických panelů, klasifikaci fotovoltaických panelů a vytvoření aplikace, která všechny části zapouzdří.

V prvním bloku je potřeba připravit pořízený dataset tak, aby z něj šlo vytvořit kvalitní multispektrální ortofoto. Je zapotřebí implementovat algoritmus, který vstupní snímky nejdříve normalizuje tak, aby byly co nejvíce eliminovány případné nežádoucí artefakty na výsledném ortofotu. Zároveň je potřeba z metadat termosnímků vyčíst teplotní data a převést je do formátu, který bude se softwarem OpenDroneMap¹ kompatibilní. Software OpenDroneMap spouští tvorbu ortofota v multispektrálním módu pouze v případě, kdy v metadatech zdrojových snímků detekuje více druhů signálů. Kamera, kterou jsou snímány fotovoltaické elektrárny při jejich inspekcích, není multispektrální, a proto systém musí metadata vygenerovaných snímků upravit algoritmicky, aby multispektrální mód správně fungoval.

Pro tvorbu ortofota byl zvolen nástroj OpenDroneMap, protože je zdarma a výsledné mapy jsou dostatečně kvalitní. Jeho výhodou je také to, že umožňuje zpracovávat snímky v multispektrálním módu, čehož lze v této práci využít. Díky tomu totiž nebude výsledné ortofoto složeno jen z obrazových dat, ale bude mít také vrstvu s reálnými teplotními daty. Uživatel tedy o tato termální data nepříjde a bude moci například provádět ruční měření teploty některých hotspotů, bude-li to potřeba. Software OpenDroneMap poskytuje mimo


¹Projekt OpenDroneMap je dostupný zde: <https://www.opendronemap.org/>

jiné knihovnu, která umožňuje integraci jeho funkcionality do implementovaného systému, díky čemuž bude mít uživatel vše na jednom místě.

Segmentaci panelů lze provést dvěma přístupy a na základě testů vybrat ten lepší. Prvním přístupem je vytvoření robustnějšího algoritmu, založeného na prahování a dalších metodách zpracování obrazu. Druhý přístup vychází z řešení bakalářské práce [7] popsané v sekci 2.6.3. Původní dataset pro trénování segmentace instancí panelů je potřeba rozšířit o anotované snímky z dalších elektráren a model Mask R-CNN přetrénovat, aby spolehlivě segmentoval panely na snímcích ze všech dostupných datasetů.

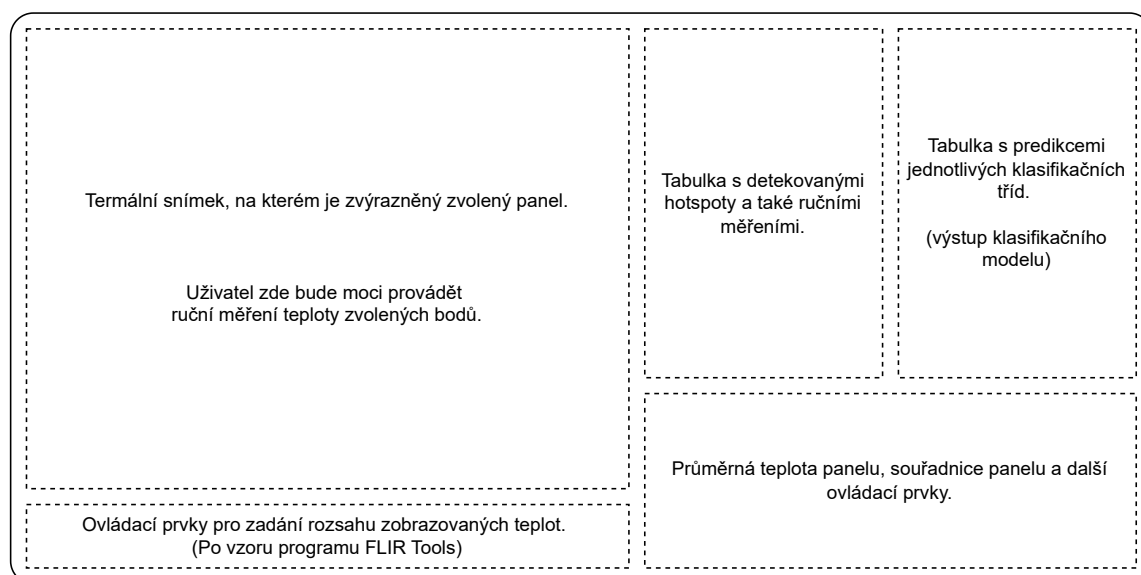
Detekce vad panelů bude řešena formou klasifikace jednotlivých panelů po vzoru článků [19] a [12] popsaných v kapitolách 2.6.4 a 2.6.5. Proto je potřeba natrénovat Vision Transformer i konvoluční model a porovnat úspěšnost obou modelů. Vision Transformer je robustnější a kvůli tomu také pomalejší, a proto je důležité porovnat, jestli se vyplatí v praxi využívat.

Všechnu funkcionalitu pak uživateli zpřístupní webová aplikace s přehledným a intuitivním grafickým rozhraním, která uživatele provede celým procesem zpracování pořízených datasetů. Každý krok by měl mít své zobrazení, které umožní uživateli nastavit parametry daného procesu a bude ho průběžně informovat o aktuálním stavu zpracování. Návrh takového zobrazení je možné pozorovat na obrázku 3.1. Ve stavové navigační liště bude zvýrazněn název aktuálně zobrazeného kroku. (Na obrázku je zvýrazněn krok segmentace.) Dále bude tato lišta zobrazovat aktuální stav zpracování, a to tak, že kroky, které byly úspěšně dokončeny, budou mít zelenou barvu. V případě chyby se naopak název daného kroku zabarví do červena. Uživatel bude moci provést zpracování datasetu vícekrát, aniž by přišel o předchozí výsledky. V tabulce nalevo budou vypsána všechna spuštění (běhy) a uživatel bude mít stále k dispozici informace o nastavení zpracování v každém běhu a možnost zobrazit si jeho výsledky. To je výhodné zejména pro krok tvorby ortofota, jelikož uživatel nemusí být spokojený s výsledkem prvního pokusu. Zároveň není žádoucí, aby o tyto výsledky přišel, jelikož není zajištěno, že další pokus bude úspěšnější.



Obrázek 3.1: Návrh rozvržení grafických prvků uživatelského prostředí aplikace, které bude sloužit ke zpracování datasetu.

Výsledky segmentace a klasifikace budou interaktivně prezentovány na vytvořeném ortofotu, na kterém budou vyznačeny všechny segmentované panely a vhodně zvýrazněny ty, které byly klasifikovány jako vadné. Uživatel si bude moci rozkliknout každý panel a zobrazit si jeho detail. Návrh zobrazení detailu panelu se nachází na obrázku 3.2. Výrazným prvkem tohoto zobrazení bude vykreslení termální dlaždice, která bude vyřiznuta z termální vrstvy ortofota. Ta bude zaměřena tak, aby byl zvolený panel uprostřed okna a dostatečně přiblížený. Zvolený panel bude zvýrazněný vykreslením jeho hranice na zmíněnou dlaždici a pokud systém na povrchu panelu detekuje hotspoty, také je zde označí. V tabulce napravo pak bude seznam všech detekovaných hotspotů s jejich maximální naměřenou teplotou. Uživatel bude moci provádět ruční měření teploty, a ty budou také vypsány v této tabulce. Ve druhé tabulce bude vypsán výstup klasifikačního modelu. Tedy jednotlivé klasifikační třídy a pravděpodobnost, že zvolený panel náleží právě do nich. Systém uživateli zobrazí také průměrnou teplotu povrchu panelu a další užitečné informace. Poté bude na uživateli, aby určil, zdali byla predikce klasifikačního modelu správná a případně ji opravil. Zároveň aplikace uživateli poskytne nástroj na jednoduché zadávání souřadnic panelů v souřadném systému elektrárny.



Obrázek 3.2: Návrh rozvržení grafických prvků pro zobrazení detailu segmentovaného fotovoltaického panelu.

Poslední částí této práce bude otestování celého systému. Využity k tomu budou dostupné datasety inspekce elektráren z České republiky. Dataset inspekce elektrárny v obci Sychrov je jako jediný anotovaný odborníkem z praxe. Proto při evaluaci systému na ostatních datasetech bude potřeba ručně zkontrolovat správnost výsledků segmentace a klasifikace panelů.

Kapitola 4

Návrh a implementace klíčových částí systému

V této kapitole je podrobně popsán postup implementace všech částí této diplomové práce podle návrhu z kapitoly 3.2. Nejprve je tedy popsána obecná architektura vytvořeného systému a poté již jednotlivé kroky zpracování datasetu. Pořadí popsanych implementovaných částí odpovídá postupu, kterým by měl uživatel zpracovávat pořízený dataset.

4.1 Architektura webové aplikace

Cílem této práce bylo vytvořit aplikaci, která uživateli umožní zpracovat pořízené datasety z inspekci fotovoltaických elektráren. V dnešní době bývá většina aplikací implementována jako aplikace webové. Výhodou tohoto řešení je, že uživatel k jejímu použití nemusí instalovat žádný software a zároveň by taková aplikace měla bez problémů fungovat na všech operačních systémech. Z popsanych důvodů bylo rozhodnuto, že aplikace vyvinutá v této práci bude také webová. Prvním důležitým krokem byl výběr vhodných technologií a frameworků pro serverovou i frontendovou část aplikace. Aplikace využívá natrénované modely k segmentaci a klasifikaci fotovoltaických panelů, a tyto modely jsou implementovány v jazyce Python, stejně tak krok přípravy datasetu pro tvorbu ortofota byl implementován ve stejném jazyce, a proto byl pro serverovou část aplikace zvolen Python framework Django¹. Mezi výhody tohoto frameworku patří jednoduchost zprovoznění aplikace, škálovatelnost aplikace, integrace databáze nebo například poskytovaná logika pro správu uživatelů a relací přihlášených uživatelů. Umožňuje také jednoduché napojení na e-mailový server a díky tomu dokáže implementovaný systém rozesílat uživatelům různé notifikace o stavu inspekce elektrárny. Pro tyto účely byl vytvořen nový účet u společnosti Google a skrze něj byly e-maily rozesílány. Nastavení připojení e-mailového serveru je k dispozici v souboru `.env`, který slouží k lokálnímu nastavení prostředí frameworku Django.

Frontend část aplikace byla implementována v jazyce TypeScript s využitím frameworku Angular². Tento framework umožňuje aplikaci rozdělit do samostatných znovu použitelných komponent a při používání aplikace se vždy načítají pouze aktuálně využívané komponenty, díky čemuž by aplikace neměla zabírat příliš paměti. Aplikace využívá knihovnu komponent PrimeNG³, která nabízí celistvý vzhled velkého množství různých ovládacích prvků, které

¹Framework Django je dostupný zde: <https://www.djangoproject.com>

²Framework Angular je dostupný zde: <https://angular.dev>

³Knihovna PrimeNG dostupná zde: <https://primeng.org>

lze do aplikace zakomponovat, a díky tomu bylo dosaženo moderního a jednotného vzhledu. Většina stránek aplikace byla implementovaná tak, aby na nich zobrazené komponenty zabíraly celou obrazovku, ale aby nepřesahovaly mimo ni. Stránky tedy často disponují okny, kterým lze dle potřeby ručně měnit velikost, a které se automaticky přizpůsobují velikosti prohlížeče. Této funkcionality bylo dosaženo pomocí knihovny Angular gridster 2⁴. Je však nutno podotknout, že implementovaná aplikace není přizpůsobena k zobrazení na mobilních telefonech, protože její účel a obsah se k tomuto použití nehodí. V následujících sekcích budou popsány důležité prvky implementované aplikace.

4.1.1 Ukládání dat

Persistentní ukládání dat bylo zajištěno pomocí databáze SQLite. Django poskytuje nadstavbu pro práci s databází, a proto není při implementaci pracováno přímo s SQL dotazy. Místo tabulek databáze jsou definovány modely, které se nacházejí v souboru `models.py`. Struktura dat byla navržena tak, že hlavním prvkem je solární elektrárna a k jednotlivým elektrárnám je uživatelům přidělován přístup. Elektrárna může mít N inspekci. Předpokládá se totiž, že inspekce budou probíhat pravidelně. Každá inspekce poté disponuje svým datasetem termosnímků a případně i datasetem barevných snímků, pokud byly pořízeny. Každá inspekce může disponovat několika pokusy o zpracování pořízeného datasetu (`PipelineRun`). Model `PipelineRun` obsahuje všechny důležité informace ze zpracování datasetu, jako jsou konfigurační soubory, logovací soubory, vytvořené ortofoto a také soubor s anotacemi.

Anotace, kterými jsou v tomto kontextu myšleny informace o segmentovaných panelech, výsledky klasifikace a také ručně přidávané anotace uživateli, jsou ukládány do JSON souboru, a to pro každý pokus zvlášť. Tyto informace nemá smysl ukládat do databáze, jelikož segmentovaný panel bude vždy patřit pouze jednomu ortofotu a dané ortofoto zase jednomu pokusu o zpracování. Bylo by zbytečné mít v databázi tisíce záznamů o panelech a pak z nich filtrovat ty, které zrovna uživatel potřebuje. Data uložená v JSON souboru však mají pevně definovaný tvar, čehož bylo dosaženo definováním modelů podobných těm, které do databáze ukládány jsou. Tyto modely jsou definovány v souboru `json_models.py`.

Termosnímků, konfigurační soubory, logovací soubory a další jsou v systému ukládány v adresářové struktuře, jejíž vzor vypadá takto: `id_elektrárny/id_inspekce/id_pokusu`. Soubory jsou tedy přehledně roztříděny a v případě potřeby je lze snadno dohledat. Jednotlivé inspekce je možné také exportovat a importovat, čímž je umožněn přenos dat na jiný server, pokud by to bylo potřeba.

4.1.2 API

Komunikace mezi serverem a aplikací v prohlížeči uživatele je prováděna pomocí REST API. K tomu bylo pro Django využito rozšíření Django REST framework⁵. V souboru `serializers.py` byly implementovány serializéry, které mají na starost převod modelů a dat do JSON podoby v případě, kdy server vrací daná data v odpovědi. Serializéry slouží také k definici očekávaného formátu dat, které může frontend serveru posílat například metodou POST. Díky balíčku `drf-spectacular`⁶ je pro jednotlivé endpointy REST API automaticky generována dokumentace, která udává, jaký formát dat daný endpoint očekává,

⁴Knihovna Angular gridster 2 je dostupná zde: <https://github.com/tiberiuzuld/angular-gridster2>


⁵Rozšíření Django REST framework je dostupné zde: <https://www.django-rest-framework.org>

⁶Balíček `drf-spectacular` je dostupný zde: <https://github.com/tfranzel/drf-spectacular>

v jakém formátu mohou být jeho odpovědi atd. Přímo v kódu byly také dodány dodatečné anotace, které ještě blíže popisují funkcionalitu daných endpointů, a celou tuto dokumentaci lze zobrazit pomocí nástroje Swagger⁷⁸. Nástroj OpenAPI Generator⁹ pak zajišťuje konzistenci metod volajících REST API a také modelů zastupujících formáty dat na frontendu s aktuálním stavem na serveru. Po jakékoliv úpravě některého z endpointů stačí spustit nástroj OpenAPI Generator a ten již automaticky rozpozná změny a vygeneruje odpovídající metody a rozhraní pro frontend.

4.1.3 Správa uživatelů

Systém vytvořený v této diplomové práci podporuje práci s uživateli. Implementaci pro ukládání dat o uživateli má v sobě zahrnutou přímo framework Django. Správa relací přihlášených uživatelů je prováděna pomocí balíčku Simple JWT¹⁰, který zajišťuje rotaci JSON Web Tokenů (JWT). Systém využívá dvojici tokenů. Prvním z nich je přístupový token, který je přikládán do hlavičky všech dotazů na server a nemá dlouhou životnost. Druhým typem je obnovovací token, pomocí kterého může frontend požádat o vygenerování nové dvojice tokenů. Prošlé tokeny jsou na serveru ukládány na blacklist a pokud by se někdo pokusil autentizovat starým tokenem, systém zneplatní také aktuální platnou dvojici tokenů a požádá uživatele o opětovné přihlášení, což by mělo zvýšit bezpečnost systému. Na straně frontendu je správa a přidávání těchto tokenů do hlaviček dotazů implementována v souboru `ui/src/app/interceptor/auth.interceptor.ts`.



Obrázek 4.1: Ukázka zobrazení správy uživatelů ve webové aplikaci.

Aplikace poskytuje zobrazení pro správu uživatelů, jehož ukázka je zachycena na obrázku 4.1. Tohle zobrazení mají k dispozici pouze uživatelé s administrátorskými právy. Administrátor může vytvořit nový uživatelský účet zadáním přihlašovacího jména a e-mailu nového uživatele. Systém vygeneruje odkaz obsahující jednorázový token umožňující nast-

⁷Nástroj Swagger je dostupný zde: <https://swagger.io>

⁸Po spuštění Django serveru například jako localhost je dokumentace dostupná na této url: <http://127.0.0.1:8000/api/schema/swagger-ui/>

⁹Nástroj OpenAPI Generator je dostupný zde: <https://openapi-generator.tech>


¹⁰Balíček Simple JWT: <https://github.com/jazzband/djangorestframework-simplejwt>

vení nového hesla, který je zaslán na e-mail nového uživatele. Kliknutím na odkaz nový uživatel potvrdí svou e-mailovou adresu a zároveň má možnost zvolit si své heslo. Podobným způsobem funguje také proces obnovení zapomenutého hesla, který již však zvládne uživatel sám bez potřeby asistence administrátora.

Data v systému jsou rozdělená na jednotlivé elektrárny a ty mají své inspekce. Administrátor má možnost přiřadit uživateli přístup pouze k těm elektrárnám, jež jsou pro něj relevantní. Systém rozesílá notifikace o průběhu zpracování datasetu. Ty však nejsou rozesílány všem uživatelům, kteří mají k dané elektrárně přístup, ale pouze uživateli, který daný proces spustil.

4.1.4 Nahrávání datasetů

Datasety termosnímků jsou poměrně rozsáhlé, a proto bylo potřeba vyřešit problém nahrávání velkých souborů na server. K tomu byl zvolen protokol **tus**¹¹, který podporuje obnovitelný upload souborů postavený na HTTP komunikaci. Soubory jsou rozděleny na menší dávky, které jsou postupně zasílány na server. Systém ukládá informace o stavu nahrávání souborů, a díky tomu dokáže například po výpadku signálu nahrávání obnovit. Na straně serveru je k tomu využíván balíček **drf-tus**¹² a v Angular aplikaci byl využit balíček **tus-js-client**¹³. Uživatel má možnost datasety nahrát v zobrazení datasetů, kde vidí 3 tabulky souborů, jak je možné pozorovat na obrázku 4.2. Kromě termálních snímků může systému poskytnout také RGB snímky, které mu pak bude systém zobrazovat k detailu fotovoltaiického panelu.



Obrázek 4.2: Ukázka zobrazení správy datasetů ve webové aplikaci.

Uživatel může nahrávat jednotlivé snímky anebo také zip archiv obsahující celý dataset. Stav nahrávání je uživateli živě zobrazován a po dokončení nahrávání jsou soubory vypsány v tabulkách. Po rozkliknutí řádku tabulky se uživateli zobrazí daný snímek, má zde také možnost mazání snímků. V tabulce se zobrazuje také status zpracování snímku. Ihned po nahrání snímku se z něj systém pokusí vyčíst GPS data, která jsou později využívána.

¹¹Informace o protokolu tus jsou dostupné zde: <https://tus.io>

¹²Balíček drf-tus je dostupný zde: <https://github.com/dirkmoors/drf-tus>

¹³Balíček tus-js-client je dostupný zde: <https://github.com/tus/tus-js-client>

Pokud se tato data nepodaří načíst, v tabulce se zobrazí křížek značící chybu a po najetí kurzorem na něj se uživateli vypíše chybová hláška. Na zobrazení lze vidět také tabulku s ortofoty. Aplikace momentálně nepodporuje nahrávání vlastního ortofota, jelikož systém vyžaduje multispektrální ortofoto a zajištění kompatibility s jinými nástroji by mohlo být problémové. Do budoucna by však mohla být přidána podpora také této funkcionality.

4.2 Příprava datasetu

Před vytvořením ortofota je potřeba dataset, který byl pořízen při provádění inspekce elektrárny, na danou úlohu správně připravit. Software Open Drone Map při spuštění v multispektrálním módu vyžaduje na vstupu páry snímků. Jeden snímek je ve formátu RGB a pomocí něj je ortofoto tvořeno. Druhý snímek může obsahovat další data, která chce uživatel do mapy zakomponovat. V tomto případě to jsou termální data zakódovaná do datového typu `uint16`.

4.2.1 Termální data

Datasety, které jsou v této práci zpracovávány, byly pořízeny termokamerou vyrobenou společností Teledyne FLIR. Termosnímky byly uloženy ve formátu JPEG, kdy kamera automaticky mapuje teplotní data na ta vizuální tak, aby bylo dosaženo co nejlepšího kontrastu. Pixely tedy nabývají hodnot 0 až 255 a nerepresentují reálnou teplotu ve stupních Celsia. Termální data jsou ve snímcích uložena ve formě metadat, které je potřeba nejdříve načíst a zpracovat. V systému byla definována abstraktní třída `ImageLoader` a pokud by v budoucnu bylo potřeba zpracovávat termosnímky uložené v jiném formátu, než jak je ukládají termokamery FLIR, stačí přidat další implementaci této abstraktní třídy a systém ji již automaticky detekuje a zobrazí ji uživateli jako možnost k výběru. Aktuálně tedy systém disponuje jednou implementací třídy `ImageLoader` a ta využívá balíček `Flir Image Extractor`¹⁴, který pro čtení metadat využívá nástroj `ExifTool`¹⁵. Výstupem je dvourozměrné pole datového typu `float`, které má stejné rozměry jako termosnímek. Prvky pole uvádí teplotu objektu zachycenou odpovídajícími pixely. Pro každý obrázek je vytvořen dočasný soubor ve formátu TIFF, do kterého jsou termální hodnoty uloženy. Zároveň je průběžně ukládána celková minimální teplota celého datasetu.

Po dokončení extrakce termálních dat následuje převod hodnot datového typu `float` na hodnoty typu `uint16`. Tento datový typ byl zvolen ze dvou důvodů. Prvním z nich je úspora úložiště, jelikož jeden pixel datového typu `uint16` zabírá 16 bitů, zatímco pixel datového typu `float` může zabírat 32 až 64 bitů. Druhým důvodem byly potíže, které se vyskytly při tvorbě ortofota v případech, kdy nebyla vstupní data celočíselná. Software Open Drone Map sice podporuje multispektrální mód a také soubory ve formátu TIFF, některé jeho součásti však podporují jenom celočíselný vstup. Datový typ `uint16` umožňuje uložit hodnoty v rozmezí 0 až 65 535. Termokamery FLIR snímají teplotu s přesností na jednu setinu stupně a pokud jsou tedy teplotní data vynásobena koeficientem rovnajícím se 100, do datového typu `uint16` je možné bezpečně uložit teploty v rozmezí 0 až 654 stupňů, aniž by došlo ke ztrátě informací. Maximální teploty naměřené na snímcích z dostupných datasetů nepřesahují 200 °C, a tím pádem je tento rozsah dostatečný. Pokud se v datasetu vyskytují hodnoty nižší než nula, k teplotním datům je ještě připočten offset, který se rovná absolutní hodnotě minimální teploty celého datasetu. Rovnice pro zakódování teplotních dat

¹⁴Flir Image Extractor dostupný zde: <https://github.com/ITVRoC/FlirImageExtractor>

¹⁵ExifTool dostupný zde: <https://exiftool.org>

vypadá takto:

$$img_uint16 = (img_float + o) * 100, o = \begin{cases} |min(dataset)|, & min(dataset) < 0 \\ 0, & min(dataset) \geq 0 \end{cases} \quad (4.1)$$

Kde *img_uint16* značí zakódovaná teplotní data do datového typu *uint16*, *img_float* jsou originální termální data ve formátu *float*, *o* značí offset a *min(dataset)* je nejnížší naměřená teplota napříč všemi snímky v datasetu. Výsledný obrázek je uložen do souboru ve formátu PNG.

Dekódování teplotních dat je v dalších částech systému prováděno pomocí rovnice:

$$img_float = \frac{img_uint16}{100} - o \quad (4.2)$$

Zde jsou *img_float* teplotní data, která jsou zpátky dekodovaná do datového typu *float*, *img_uint16* značí zakódovaná teplotní data do datového typu *uint16* pomocí rovnice 4.1 a *o* značí offset, který byl při zakódování uložen do databáze.

4.2.2 Obrazová data

Během kontroly dostupných datasetů bylo zjištěno, že snímky z jednoho datasetu mohou mít různý jas. Nejvíce je to patrné na snímcích pořízených při inspekci solární elektrárny v obci Rudoltice, jak je možné pozorovat na obrázku 4.3. Příčinou je způsob, jakým termokamera mapuje teplotní data na ta obrazová. Pokud snímek zachycuje objekt s velmi vysokou teplotou, okolí tohoto objektu může být příliš tmavé. U zmíněného datasetu však tento problém není způsoben tím, že by se na snímcích nacházela spousta solárních panelů, které mají velmi vysokou teplotu. Problém způsobuje odraz slunce, který byl nejspíše zapříčiněn špatnou kombinací naklonění kamery dronu a aktuální polohou slunce během snímání elektrárny. Na obrázku 4.3 je možné pozorovat rozdílný jas dvou termosnímků, které zachycují téměř stejnou oblast. Na obrázku 4.3b však není odlesk přítomný, protože se v místě odlesku aktuálně nenachází panel. Na tmavých snímcích, jako je obrázek 4.3a, dochází k přílišné ztrátě informací a byl by problém z nich vytvářet ortofoto anebo z nich segmentovat panely. Proměnlivost jasu snímků u ostatních datasetů sice není až tak výrazná, ale je zde také přítomna, a proto je normalizaci vhodné využít vždy. Proto byl implementován algoritmus, který RGB snímky generuje z termálních dat, nad kterými provede normalizaci jasu snímků a také zvýrazní jejich detaily, což přispívá k lepším výsledkům následujících kroků.

Prvním krokem generování RGB snímku je tedy zarovnání teplotních dat napříč celým datasetem tak, aby průměrná teplota snímku byla rovna průměrné teplotě celého datasetu. Toho je dosaženo zjištěním rozdílu průměrné teploty snímku a datasetu, který je následně přičten k termálním datům snímku. Poté je potřeba určit rozsah hodnot, které budou mapovány na obrazová data. Minimální teplota je zvolena jako průměrná minimální teplota datasetu a maximální teplota je vypočtena jako průměrná teplota datasetu, ke které je připočten rozdíl průměrné a minimální teploty. Následně jsou termální data namapována na 256 odstínů šedi pomocí rovnice:


$$grayscale_img = \frac{thermal_norm - min_temp}{max_temp - min_temp} * 255 \quad (4.3)$$

kde *thermal_norm* jsou zarovnaná teplotní data, *min_temp* a *max_temp* jsou pak hodnoty, které byly zvoleny při určení rozsahu teplot.


Druhým krokem generování RGB snímků je zvýraznění detailů. K tomu je využit Laplaceův filtr, jehož výstupem jsou zvýrazněné hrany v obrázku. Tento výstup je zkombinován s původními obrazovými daty pomocí rovnice:

$$edge_img = grayscale_img - 1.5 * laplacian_img \quad (4.4)$$


a výsledný obrázek je normalizován tak, aby opět nabýval hodnot v rozsahu 0–255. Paralelně je provedena ekvalizace histogramu původního snímku, čímž je zvýšen jeho kontrast a tento výstup je následně přičten k obrázku se zvýrazněnými hranami. Výstupem je tedy vysoce kontrastní snímek se zvýrazněnými hranami a ten je přičten k původnímu snímku v poměru 0,6 původního snímku a 0,4 kontrastního snímku. Díky této kombinaci působí snímek stále přirozeně, ale zároveň došlo k jeho zaostření oproti původnímu snímku. Snímek je pak uložen jako RGB do souboru ve formátu JPEG.



(a) Originální termosnímek s nízkým jasnem.



(b) Originální termosnímek s běžným jasnem.



(c) Vygenerovaný snímek z termosnímků (a).



(d) Vygenerovaný snímek z termosnímků (b).

Obrázek 4.3: Obrázky (a) a (b) znázorňují termosnímky pořízené při inspekci elektrárny v obci Rudoltice. Tyto snímky byly pořízeny bezprostředně po sobě a zachycují téměř stejnou oblast. Obrázky (c) a (d) znázorňují vygenerované RGB snímky z originálních termosnímků pomocí algoritmu popsaneho v sekci 4.2.2.

Nově vygenerované soubory neobsahují metadata o poloze pořízení snímku a další potřebné informace, a z toho důvodu je potřeba tato metadata zkopírovat z původního termosnímků. Ke kopírování metadat je využíván nástroj ExifTool, s pomocí Python balíčku s názvem PyExifTool¹⁶.

Aby bylo možné vytvářet ortofoto v multispektrálním módu, je potřeba do metadat snímku přidat informaci o druhu signálu, jaký daný snímek obsahuje. Pro RGB snímky jsou přidány parametry:


- `FLIR:BandName=RGB`
- `Camera:RigCameraIndex=0`

Pro termální snímky jsou pak přidány parametry:

- `FLIR:BandName=Thermal`
- `Camera:RigCameraIndex=1`

Software OpenDroneMap díky tomu rozpozná, že dataset obsahuje dva typy signálu a přepne se do multispektrálního módu.

Posledním krokem je smazání všech dočasných souborů a uložení informace o minimální teplotě datasetu do databáze. Výstupem tohoto procesu pro každý vstupní termosnímek tedy je dvojice snímků, jeden obsahuje RGB signál a druhý převedená teplotní data.



Obrázek 4.4: Ukázka webové aplikace ve stavu po dokončení procesu přípravy datasetu.

4.2.3 Grafické rozhraní

Implementovaná webová aplikace pro tento krok zpracování datasetu poskytuje dvě zobrazení. Na prvním si má uživatel možnost zvolit snímky, které chce zpracovat. Může se stát, že dataset obsahuje například snímky, které byly pořízeny během vzletu nebo přistání dronu, a ty není žádoucí do tvorby ortofota zahrnovat. Následně má uživatel možnost zvolit, jakou

¹⁶Balíček PyExifTool je dostupný zde: <https://github.com/sylikc/pyexiftool>

implementaci abstraktní třídy `ImageLoader` chce využít. V současné době systém disponuje pouze jednou implementací, ale aplikace je implementovaná tak, aby byla připravená na případné rozšíření v budoucnu. Po spuštění procesu přípravy datasetu se aplikace přepne do druhého zobrazení disponující tabulkou, která obsahuje záznamy všech obrázků a u každého z nich zobrazuje jejich stav. Pokud by došlo k chybě zpracování, například kdyby se ze zdrojového snímku nepodařilo načíst termální data, zobrazí se vedle názvu obrázku ikona křížku a po najetí na něj kurzorem se uživateli vypíše chybová hláška. Další částí zobrazení je výpis log zpráv, které server vysílá do aplikace v uživatelské prohlídce pomocí `StreamingHttpResponse`, což poskytuje Django framework jako způsob, jak průběžně zasílat data ze serveru k uživateli pomocí protokolu `Server-Sent Events`. Ukázku druhého zobrazení je možné pozorovat na obrázku 4.4.

4.3 Tvorba ortofota

Jak již bylo několikrát zmíněno, pro tvorbu ortofota bylo zvoleno řešení, které poskytuje projekt OpenDroneMap (ODM). Jelikož bylo cílem této diplomové práce vytvořit webovou aplikaci, z OpenDroneMap portfolia byl zvolen software NodeODM¹⁷, který funguje ve virtuálním prostředí Docker a poskytuje REST API, pomocí kterého lze komunikovat s celým ODM systémem. Jelikož je backend aplikace vytvořen v programovacím jazyce Python, společně s NodeODM je využívána knihovna PyODM¹⁸, která zapouzdřuje práci s REST API a poskytuje sadu tříd a metod, které celý proces ulehčují.

4.3.1 Důležité parametry nastavení

Software ODM poskytuje velké množství různých parametrů. Aby správně fungovalo zpracování datasetu v multispektrálním módu, na čemž tato práce stojí, je potřeba mít vždy nastavený parametr `primary-band` na hodnotu `"RGB"`. Tohle nastavení specifikuje, že má být ortofoto tvořeno z RGB snímků, jejichž generování je popsáno v sekci 4.2.2. Druhý parametr, který by neměl být změněn, je `skip-band-alignment`. Ten by měl být nastaven na hodnotu `True`. Funkcionalita `band-alignment` se snaží zarovnat snímky z ostatních signálů na RGB snímek. Lze jej využít například při použití reálné multispektrální kamery, kde se může stát, že na jednotlivých signálech dochází k mírnému posunu obrazu v závislosti na konstrukci kamery. V tomhle případě jsou však oba signály generovány z jednoho zdroje, a proto jsou pixely u obou druhů snímků již zarovnané.

Z provedených testů vyplývá, že pro dobrou kvalitu ortofota vytvořeného z dostupných datasetů je vhodné software ODM spouštět s těmito parametry:

- `auto-boundary: True` – Automaticky stanovuje hranice pro generované ortofoto pomocí pozic kamer při pořízení snímků, což pomáhá odstranit nechtěné deformace na krajích ortofota.
- `dsm: True` – Vytvoří digitální model povrchu země a objektů na ní za využití progresivního morfologického filtru, čímž je dosaženo větší přesnosti ortofota.
- `pc-quality: "high"` – Vytvoří hustší mračno bodů, ze kterého bude vytvořen 3D model snímané plochy.

¹⁷Software NodeODM je dostupný zde: <https://github.com/OpenDroneMap/NodeODM>

¹⁸Knihovna PyODM je dostupná zde: <https://github.com/OpenDroneMap/PyODM>

- **split: 300** – Tvorba ortofota vyžaduje poměrně velkou kapacitu paměti RAM a ne vždy lze celý dataset zpracovat najednou. Tímto parametrem lze nastavit, že bude dataset rozdělený na menší celky. Z každého z nich budou vytvořeny submodely a ty budou nakonec spojeny do výsledného ortofota. Při multispektrálním módu software ODM počítá termální i RGB snímky zvlášť, takže hodnota 300 odpovídá 150 originálním snímkům. Ortofota byla tvořena na notebooku s operačním systémem Windows 11 a RAM o velikosti 16 GB, pročež se ukázalo 300 snímků na submodel jako optimální hodnota. Čím větší submodely jsou, tím lepší bude i výsledné ortofoto.
- **split-overlap: 100** – Tento parametr určuje jak moc se mají jednotlivé submodely překrývat. Na základě testů se ukázal překryv 100 metrů jako dostačující.

4.3.2 Poznatky z testování

NodeODM pro Docker existuje ve dvou verzích. Primární verze provádí všechny výpočty pouze na procesoru počítače. Pak existuje také verze umožňující přesunutí části výpočtů na grafickou kartu, čímž je celý proces urychlen. U této verze se však vyskytovala chyba při spuštění v multispektrálním módu a s nastaveným parametrem **split**. Proces selhával ve fázi spojování submodelů. Primární verze fungovala bez problémů, a proto byla použita i za cenu delšího času zpracování datasetu. Tvorba jednoho ortofota trvala 5 až 7 hodin v závislosti na velikosti datasetu.

Proces tvorby ortofota je náročný také na úložiště počítače. Zvláště když jsou data ukládána na virtuální disk Dockeru. Tento virtuální disk se během procesu neustále zvětšuje a během pokusu o zpracování datasetu s 1000 snímky (RGB i termální) o celkové velikosti 308 MB došlo ke zvětšení virtuálního disku o více než 60 GB a poté byl proces raději ukončen. Řešením tohoto problému je nastavení úložiště pro NodeODM úlohy mimo Docker. NodeODM tuto funkcionalitu umožňuje nastavit parametrem při spuštění Docker kontejneru. Toto nastavení bez problémů funguje také na externí disk, který je připojený přes USB, a takto byly vytvořeny ortofota pro tuto práci.


Výstupem ODM procesu je ortofoto, které je uloženo ve formátu TIFF, a protože jsou termální data ve formátu **uint16**, ODM tak uloží i obrazovou vrstvu. Implementovaný systém proto z TIFF souboru extrahuje obrazovou vrstvu, převede ji zpět na 256 odstínů šedi a uloží ve formátu PNG. Z obrazové vrstvy je vytvořena ještě její menší verze, která je uložena ve formátu JPEG a slouží jako náhled, který se zobrazuje jako záhlaví karty dané elektrárny. Následně je z TIFF souboru extrahována termální vrstva, která je také uložena v PNG formátu.

V následujících krocích bude probíhat segmentace a klasifikace panelů. Pro tyto účely jsou ortofota rozřezána na dlaždice o velikosti 640 x 512 pixelů s 75% překryvem jednotlivých dlaždic. Informace o ortofotech i dlaždicích jsou uloženy do databáze, všechny dočasné soubory smazány a tím tento krok zpracování končí. Po ukončení procesu systém zašle uživateli, který proces spustil, notifikaci formou emailu, ve kterém ho informuje, zdali byl proces úspěšný, a pokud byl ukončen chybou, přiloží do emailu také chybovou hlášku.

4.3.3 Grafické rozhraní

Pro tvorbu ortofota bylo vytvořeno jedno zobrazení, které uživateli umožňuje nastavit si všechny dostupné parametry ODM. NodeODM poskytuje seznam všech dostupných parametrů, ve kterém specifikuje také jejich datové typy, obory hodnot, výchozí hodnoty a krátkou dokumentaci. Pro každý datový typ je parametru přiřazena odpovídající kom-

ponenta umožňující zadání správných hodnot. Po najetí kurzorem na danou komponentu se uživateli zobrazí dokumentace daného parametru. Zobrazení disponuje dvěma seznamy parametrů. Jeden seznam zobrazuje parametry, jejichž nastavení není možné změnit. Parametry v druhém seznamu si může uživatel měnit dle vlastního uvážení. Po spuštění tvorby ortofota je aktuální nastavení ODM uloženo a automaticky se tak nastaví i po opětovném načtení tohoto zobrazení. Uživatel tedy i zpětně uvidí, s jakými parametry proces spouští, a pokud by ho chtěl spustit znovu, nemusí vše opět nastavovat. Dominantním prvkem zobrazení je stejně jako u kroku přípravy datasetu komponenta, která uživateli živě zobrazuje log zprávy. NodeODM umožňuje číst log zpráv při tvorbě ortofota, takže zobrazované zprávy obsahují kompletní popis celého procesu včetně jeho aktuálního progresu. Ukázku webové aplikace s tímto zobrazením lze pozorovat na obrázku 4.5.



Obrázek 4.5: Ukázka webové aplikace ve stavu po dokončení procesu tvorby ortofota.

4.4 Segmentace fotovoltaiických panelů


Při pořizování termosnímků fotovoltaiické elektrárny je dronu stanovena plocha, která má být pokryta, a podle toho je naplánována jeho mise. Snímky jsou pořizovány ve výšce 25–30 metrů nad zemí, a proto na nich nejsou pouze samotné fotovoltaiické panely, ale také objekty, které se nacházejí v jejich okolí. Aby byla automatizovaná inspekce úspěšná, je potřeba přesně segmentovat jednotlivé panely a podrobit detekci vad pouze jejich plochu. V rámci této práce byly implementovány dva přístupy k této úloze. Jeden pomocí tradičních metod zpracování obrazu a druhý pomocí natrénovaného segmentačního modelu Mask R-CNN.

4.4.1 Využití tradičních metod zpracování obrazu

První pokus o segmentaci byl proveden pomocí tradičních metod zpracování obrazu a v následujících řádcích je tento proces popsán.

Kopie vstupního obrázku je rozmazána s využitím Gaussova kernelu za účelem odstranění šumu. Následně je provedena binarizace s využitím metody Otsu [17]. Tato metoda automaticky zvolí vhodný práh, který rozdělí pixely obrázku do dvou skupin na základě

jejich intenzity. Výsledek binarizace je možné vidět na obrázku 4.6b. V takto binarizovaném obrázku je poté odstraněn případný šum pomocí kombinace funkcí eroze a dilatace. Následně jsou získány kontury jednotlivých objektů, které byly na obrázku detekovány. Jedná se o jednotlivé řady panelů, ale může se zde také objevit například střecha budovy, či jiné nežádoucí objekty, které však budou v následujících krocích odstraněny. Aby se zamezilo detekování velkého množství příliš malých objektů, které s vysokou pravděpodobností nejsou fotovoltaické panely, byla v tomto kroku stanovena konstanta `MIN_PANEL_LINE_SIZE` a všechny objekty s menší plochou jsou vyfiltrovány, jak je možné vidět na obrázku 4.6c. V dalších krocích jsou jednotlivé objekty zpracovávány iterativně každý zvlášť.



Obrázek 4.6: Vizualizace segmentačního algoritmu. (a): vstupní termosnímek, (b): Otsu binarizace, (c): vyfiltrované kontury, (d): oříznutá maximální teplota, (e): adaptivní binarizace, (f): vyfiltrované kontury, (g): nalezení přesných hran panelu pomocí Sobelova operátoru, (h): výsledné kontury

Pro každý objekt je vytvořena maska, na které je plocha objektu zvětšena pomocí dilatace tak, aby šlo v následujících krocích pracovat i s pixely v těsné blízkosti detekovaného objektu pro přesnější určení hranic jednotlivých panelů. Pomocí této masky je z původního obrázku vyříznuta plocha zájmu, která bude dále zkoumána. Fotovoltaické panely mají v barevném spektru stejnou barvu. V případě termosnímků však nemusí platit, že má jejich povrch homogenní teplotu kvůli hotspotům a jiným vadám, které se mohou na fotovoltaických panelech vyskytnout. V rámci segmentace panelů jsou však tyto vady nežádoucím šumem, který snižuje přesnost binarizace, a proto je lepší stanovit maximální teplotu, která je nastavena všem pixelům s teplotou vyšší a tím tento šum odstranit. Hranice byla stanovena rovnicí: $1.2 * mean$, kde *mean* je střední hodnotou intenzity pixelů ve

zkoumané oblasti obrázku. Takto upravený obrázek (4.6d) je opět binarizován, ale tentokrát s využitím metody `adaptiveThreshold` [17], která nestanovuje práh rozdělující pixely globálně pro celý obrázek, ale lokálně podle okolí daného pixelu, což vykazuje dobré výsledky, jak je možné vidět na obrázku 4.6e. Opět je zde odstraněn šum pomocí kombinace dilatace a eroze a zároveň jsou odstraněny objekty s plochou menší než konstanta `MIN_PANEL_SIZE`. Z průzkumu vyplývá, že fotovoltaické panely mají minimálně v rámci jedné řady panelů stejné rozměry. Na termosnímčích sice jejich plocha není úplně přesně na pixel stejná, protože zde hraje roli naklonění kamery, ale v rámci určitého rozmezí by měla být jejich plocha podobná. Tento fakt byl v této části algoritmu využit pro filtraci detekovaných objektů. Konkrétně byla podmínka pro akceptování objektu na další zpracování stanovena následovně: $abs(cv2.contourArea(cont) - median_size) < 0.6 * median_size$. Konstanta 0.6 byla stanovena na základě testů na dostupných datasetech a medián je zase méně náchylný na odlehlé hodnoty, což je zde žádoucí, protože v rámci binarizace bývá detekována také kontura celé zkoumané oblasti, a to by značně ovlivnilo například průměr. Posledním testem v této části je výsledný počet detekovaných objektů. Mise dronu a frekvence snímkování je stanovena tak, že se jednotlivé snímky překrývají, a proto není potřeba detekovat vady na řadě panelů, která má na daném snímku méně než 4 viditelné panely. Stanovení minimálního počtu detekovaných objektů v rámci jedné řady lze také využít k odfiltrování již dříve zmíněných střech budov a jiných nežádoucích objektů.

Detekované kontury fotovoltaických panelů pomocí binarizace nejsou přesné, jak je možné vidět na obrázku 4.6f. Proto byla navržena ještě poslední část segmentačního algoritmu, která využívá Sobelův operátor. Díky němu lze získat aproximaci derivace obrázku v horizontálním a vertikálním směru. Pomocí této derivace je možné detekovat místo největší změny intenzity pixelů, tedy hrany. Pro každý detekovaný panel je vypočítán jeho střed a následně jsou od středu směrem k hraně panelu hledány pixely s maximální derivací v daném směru pomocí funkce `argmax`. Tyto pixely jsou poté protnuty přímkou a takto jsou detekovány všechny čtyři hrany fotovoltaického panelu, jak je možné vidět na obrázku 4.6g. Kontura panelu je následně definována jeho rohy, které jsou vypočteny jako průsečíky získaných přímek. Výsledkem jsou již poměrně přesně segmentované fotovoltaické panely, zobrazené na obrázku 4.6h.

Segmentace panelů touto metodou se vyznačuje přesnější detekcí hran panelů díky protínáním přímek. Celkově je však tento proces poměrně pomalý, protože je složen z velkého množství kroků a každý panel musí být zpracováván zvlášť. Navíc zde chybí určitá míra generalizace, kdy tato metoda funguje velmi dobře jen na některých z dostupných datasetů. Proto aktuální systém toto řešení nevyužívá.

4.4.2 Segmentace pomocí natrénované neuronové sítě

Druhým přístupem k řešení problému segmentace fotovoltaických panelů bylo natrénování segmentačního modelu. K tomu bylo potřeba získat dostatečně obsáhlý a kvalitní dataset, jak již bylo popsáno v sekci 2.5.1. V této sekci je popsán proces tvorby datasetu a poté samotné trénování a evaluace segmentačního modelu.

Anotace datasetu

Anotace snímků pro trénování segmentace panelů byly vytvořeny pomocí nástroje Label Studio, jenž je blíže popsán v sekci 2.3.7. Algoritmus popsáný v sekci 4.4.1, který k segmentaci využívá tradiční metody zpracování obrazu, byl zakomponován do procesu vytváření anotací.

Snímky rozšiřující stávající dataset byly nejprve zpracovány tímto algoritmem, jehož výstupem byly anotace ve formátu COCO. Takto anotované snímky pak byly importovány do nástroje Label Studio, kde prošly ruční kontrolou a případné chyby v anotacích byly opraveny. Na jednom termosnímku se může vyskytovat i více než sto panelů, a proto toto řešení značně urychlilo celý proces vytváření datasetu.

Nástroj Label Studio poskytuje knihovnu pro integraci jeho funkcí do jazyka Python¹⁹. Tato knihovna byla využita k automatizaci importování fotek do tohoto nástroje a dalších funkcionalit. Vše, co je potřeba k vytvoření anotací pro segmentaci instancí panelů v nástroji Label Studio, je obsaženo ve skriptu `label_studio_manager.py`. Pomocí argumentů při spuštění skriptu z příkazového řádku lze zvolit, jakou funkcionalitu uživatel potřebuje. Mezi základní funkce patří:

Spuštění Label Studia – aby bylo možné pracovat s obrázky, které má uživatel ve svých adresářích a nemusely se znovu „nahrávat“, i když tento nástroj běží na lokálním počítači, je potřeba před startem nástroje upravit proměnné prostředí.

Generování anotací – tato funkce pomocí již zmíněného algoritmu automaticky vytvoří anotace pro segmentaci panelů. Výstupem jsou COCO anotace, které lze následně nahrát do nástroje Label Studio.

Import datasetů – skript automaticky importuje všechny datasety ze zvoleného umístění do nástroje Label Studio. Manuální import není úplně přímočarý a s importem původního datasetu z bakalářské práce [7] byly problémy. Proto tohle může pomoci případnému zájemci o rozšíření datasetu v budoucnu.

Export datasetu – funkce upraví exportovaný dataset tak, aby v něm byly všechny cesty k umístění souborů relativní a aby byly použitelné na operačním systému Linux, i když byly anotace vytvořeny na systému Windows.

Celý výpis funkcí i s jejich detailním popisem lze najít v souboru `Readme.md`, který je odevzdán s ostatními soubory této práce. Původní dataset obsahoval sto snímků a k nim bylo přidáno dalších sto snímků z ostatních elektráren. Ukázka anotací se nachází na obrázku 2.12. Panely, které nemají na zkoumaném snímku celou svou plochu, nejsou záměrně anotovány. Je žádoucí segmentovat pouze celé panely.


Trénování segmentačního modelu

Pro účely segmentace fotovoltaických panelů byl zvolen model Mask R-CNN s využitím projektu Detectron2. Podrobný popis modelu se nachází v sekci 2.4.2. Model byl trénován v prostředí Google Colab za využití grafické karty NVIDIA Tesla T4. Anotovaný dataset obsahující 200 snímků byl rozdělen na trénovací a testovací části, kdy testovací část zabírá 20 % datasetu, tedy 40 snímků. Testovací část datasetu byla použita také k průběžné validaci modelu, k čemuž bylo přistoupeno z důvodu poměrně malého počtu anotovaných snímků. Trénování bylo spuštěno s následujícími parametry: rychlost učení: 0,001; velikost dávky (batch size): 7; počet iterací: 2300. Platforma Detectron2 využívá k nastavení délky trénování počet iterací místo počtu epoch. Jedna epocha odpovídá průchodu celým trénovacím datasetem. V případě platformy Detectron2 je však jednou iterací považováno zpracování jedné dávky (batch). Trénovací dataset obsahoval 160 snímků a velikost jedné dávky byla nastavena na hodnotu 7. Z toho vyplývá, že 2300 iterací odpovídá přibližně 100 průchodům celým datasetem. Pro zvýšení úspěšnosti trénování byly na snímky datasetu aplikovány náhodné augmentace. Konkrétně se jednalo o náhodné překlopení ob-

¹⁹Knihovna Label Studio SDK je dostupná zde: <https://github.com/HumanSignal/label-studio-sdk>

rázku v horizontálním i vertikálním směru, otočení obrázku o náhodný úhel v rozmezí 0° až 90° a také náhodná změna velikosti obrázku.

Proces trénování modelu trval přibližně 2 hodiny. Již po 300 iteracích dosahoval model průměrné přesnosti 76 % a na konci trénování model dosahoval přesnosti (AP) 82,6 %. Průběh trénování je zachycen na grafu 4.7.



Obrázek 4.7: Průběh trénování segmetačního modelu Mask-RCNN.

Dataset byl anotovaný pomocí anotací ve formátu COCO a z toho důvodu byl model také evaluován podle stejnojmenného standardu. Při úloze segmentace objektů bývá měřena velikost průniku plochy masky objektu, která se nachází v anotacích (tedy ground truth) s plochou masky, kterou predikoval natrénovaný model. V odborné literatuře bývá tato hodnota nazývána jako Intersection over Union (IoU). Stanovuje se hranice, jak velký průnik musí být, aby byla detekce považována za úspěšnou. Dále COCO standard využívá metriku Average Precision (AP). Tato metrika hodnotí, jak dobře model segmentuje objekty a vychází ze dvou pojmů. Prvním je Precision neboli přesnost, která udává poměr správně detekovaných objektů k celkovému počtu detekovaných objektů. Druhý pojem se nazývá Recall a udává poměr počtu správně detekovaných objektů k celkovému počtu objektů, které jsou obsaženy v anotacích, tedy ground truth. Jinými slovy, Precision udává přesnost předpovědí modelu a Recall jejich úplnost. Average Precision je pak vypočteno jako průměr hodnot Precision při různých úrovních Recall. V tabulce 4.1 pak sloupec AP značí průměrnou Average Precision pro IoU v rozmezí 50 % až 95 %. AP50 odpovídá úspěšnosti segmentace pro IoU 50 % a AP75 zase pro IoU 75 %. APs odpovídá úspěšnosti segmentace malých objektů do plochy 30 pixelů² a APm zase úspěšnosti segmentace objektů s plochou menší než 96 pixelů². [4]

AP	AP50	AP75	APs	APm
82,59	96,99	96,99	82,14	91,89


Tabulka 4.1: Výsledky trénování segmentačního modelu Mask-RCNN.

Z tabulky lze tedy vyčíst, že natrénovaný model hůře segmentuje menší panely, a může proto vykazovat horší úspěšnost u datasetů inspekcí elektráren, které byly pořízeny z příliš vysoké letové výšky. Zároveň se ukazuje, že přesnost již není tak dobrá při vysoké IoU

(sloupec AP), tedy že predikované masky mají trochu jiné tvary než ty v anotacích. Zde je však nutno podotknout, že tyto anotace také nejsou úplně přesné, protože byly vytvářeny ručně, nebo pomocí algoritmu z kapitoly 4.4.1.

Proces segmentace

Během kroku tvorby ortofota byla výsledná mapa rozřezána na dlaždice o velikosti 640 x 512 pixelů s 75% překryvem jednotlivých dlaždic. Pro segmentaci je využívána vrstva, která byla vytvořena z normalizovaných RGB snímků. Panely na všech dlaždicích jsou postupně segmentovány. Mezi segmentovanými panely by se nacházela spousta duplicitních výskytů kvůli překryvu dlaždic, a proto je potřeba panely během segmentace třídit. K tomu je využíváno prostorové vyhledávání pomocí ukládání panelů do R-stromu. R-strom je stromová struktura, která dokáže indexovat vícerozměrné prostory, a díky tomu lze rychle najít překrývající se panely. Konkrétně byla za tímto účelem využita Python knihovna `rtree`²⁰. Před uložením nového panelu do R-stromu jsou nejprve nalezeny všechny panely, se kterými se nový panel překrývá, a pro každou dvojici je vypočtena míra překryvu, tedy IoU. Pokud je IoU vyšší než 30 %, vybere se ze dvojice ten panel, který je blíže středu své zdrojové dlaždice. Díky tomu by nemělo docházet k ukládání neúplných panelů z okrajů dlaždic.



(a) Ukázka spojení špatné dvojice.

(b) Ukázka spojení správné dvojice.

Obrázek 4.8: Znáznornění velikosti obálky, která by vznikla sloučením zvýrazněných panelů. Tento proces slouží k rozhodnutí, zdali mají být panely sloučeny, nebo ne. Obálka je vyznačena červeným obdélníkem.

Občas nastával problém, že model detekoval dva menší panely na ploše jednoho panelu. Stávalo se to například, když byl panel postižený vícero defekty, a ty zřejmě způsobovaly šum, který vedl k této chybě. Popsanou chybu lze ve většině případů detekovat a opravit. Proto pokud byl detekován panel, který se s jiným panelem nepřekrývá, ale jeho obsah je menší než 50 % průměrného obsahu všech segmentovaných panelů, je uložen do seznamu kandidátů na již zmíněnou chybu. Poté jsou pro každého kandidáta v R-stromu nalezeni nejbližší sousedé a pro každou dvojici je prováděna kontrola velikosti obalového obdélníku nového panelu, který by vznikl jejich sloučením. Pokud oba sousedé ve skutečnosti tvoří jeden panel, obsah obalového obdélníku by měl být podobný průměrné hodnotě obsahů všech ostatních panelů, jak je možné vidět na obrázku 4.8b. Při pokusu o sloučení části

²⁰Knihovna `rtree` dostupná zde: <https://github.com/Toblerity/rtree>

panelu se sousedním velkým panelem by byl obsah obalového obdélníku značně větší, jak je znázorněno na obrázku 4.8a. Takovýmto způsobem jsou tedy zkontrolovány všechny podezřelé panely a ve většině případů dojde k úspěšnému opravení těchto chyb.

Jakmile jsou všechny dlaždice zpracovány, dojde ještě k poslednímu kroku kontroly, a to je filtrace panelů na základě jejich velikosti. Uživatel má totiž v aplikaci možnost zadat minimální a maximální velikost panelů, čímž může odfiltrovat nechtěné objekty. Anotace samotných panelů již nejsou ukládány do databáze, ale pro každé zpracování inspekce solární elektrárny je vytvořen JSON soubor, kde jsou tato data uchovávána. Tohle rozhodnutí je zdůvodněno tím, že segmentované panely budou vždycky spadat pouze k jednomu ortofotu, a proto by bylo zbytečné mít v databázi tisíce záznamů o panelech, ve kterých by se muselo pokaždé vyhledávat požadované instance. Data v souboru však mají přesně stanovený formát, protože pro každý typ instance byla vytvořena třída podobná těm, které ve frameworku Django definují modely ukládané do databáze.

4.4.3 Grafické rozhraní

Pro krok segmentace fotovoltaických panelů byly ve webové aplikaci implementovány dvě zobrazení. První zobrazení slouží podobně jako u předchozích kroků k nastavení parametrů. Uživatel může upravit maximální a minimální plochu detekovaných panelů v jednotkách cm^2 . Aplikace umožňuje uživateli otestovat zvolené nastavení na náhodně vybrané dlaždici ortofota. Testování je možné provádět opakovaně a uživatel má také možnost si vyžádat jinou dlaždici. Po spuštění úplné segmentace je plocha, kde byl zobrazen výsledek otestování, přepnuta na již známou komponentu, která uživateli vypisuje aktuální log zprávy.



Obrázek 4.9: Ukázka zobrazení ortofota se segmentovanými panely.

Po dokončení procesu segmentace má uživatel možnost zobrazení jeho výsledků, kdy již uvidí celé ortofoto a na něm graficky znázorněné segmentované panely, jak je zobrazeno na obrázku 4.9. Uživatel má možnost si ortofoto různě přiblížit a dle potřeby jej posouvat. Grafika obrysu panelu je vykreslována metodou **pixel line**, díky čemuž mají vykreslené čáry vždy tloušťku jednoho pixelu monitoru. Jejich tloušťka tedy není ovlivněna mírou přiblížení, a tím pádem budou vždy zaostřené. Pro lepší viditelnost je plocha segmentovaných panelů navíc zvýrazněna zelenou barvou s vysokou mírou průhlednosti. Míra průhlednosti

je snížena při najetí kurzorem na daný panel, čímž je graficky znázorněno, že je vykreslená grafika interaktivní. Uživatel má v tomto kroku možnost úpravy tvaru segmentovaného panelu. Po najetí na roh panelu je uživateli zobrazena tečka znázorňující možnost úpravy jeho polohy. Uživatel má také možnost dokreslit nové panely, pokud segmentační model některé vynechal. Kresba panelu je provedena posloupností 4 kliků na ortofoto, jejichž pozice definují rohy nového panelu. Samozřejmostí je také možnost smazání panelu.

4.5 Klasifikace fotovoltaických panelů

Jakmile jsou všechny panely segmentovány, přichází na řadu klasifikace, která určí, jestli je panel vadný nebo ne a o jakou vadu se jedná. K tomuto účelu byly provedeny pokusy s trénováním celkem tří klasifikačních modelů, které byly trénovány pomocí datasetu popsáném v sekci 2.5.2.

4.5.1 Trénování klasifikačních modelů

Trénovací proces jednotlivých klasifikačních modelů byl značně podobný, a proto bude vše popsáno hromadně v této sekci. Trénování probíhalo na školním výpočetním serveru Sophie, kde byla pro trénování využívána jedna grafická karta Nvidia RTX A5000 s 24 GB RAM. Trénované modely vycházejí z článků popsáných v kapitolách 2.6.4 a 2.6.5. Jako referenční pro trénování byl zvolen článek o konvolučním modelu z kapitoly 2.6.5. Dataset byl rozdělen na trénovací, validační a testovací části v poměru 80 % pro trénovací část a 10 % pro validační a testovací část. Tohle rozdělení bylo uděláno stejně pro všechny trénované třídy. Původní dataset obsahoval 12 tříd, avšak v této práci bylo využito devět z nich, protože třídy *Hot-Spot* a *Hot-Spot-Multi* jsou určeny pro tenkovrstvé panely, které v dostupných datasetech nejsou přítomny. Další třídou, která byla vyloučena, je třída *Soiling*, tedy znečištění panelu, a to z důvodu nedostatečného počtu trénovacích obrázků.

Trénovací skript využívá framework Hugging Face²¹, který poskytuje velké množství předtrénovaných modelů. Průběh trénování byl ukládán na cloud pomocí nástroje *Weights & Biases*²². Trénovací skript byl napsán tak, že je stejný pro všechny 3 modely a při spuštění je mu jako parametr předán konfigurační soubor. Tento konfigurační soubor je ve formátu JSON a pro každý pokus trénování byl vytvořen nový. Díky tomuto přístupu lze snadno zpětně dohledat, s jakými parametry bylo dané trénování spuštěno, což zvyšuje přehlednost a zároveň lze lehce dané trénování replikovat.

Prvním trénovaným modelem byl model Vision Transformer, který byl předtrénovaný společností Google. Konkrétně jej lze v Hugging Face frameworku nalézt pod jménem `google/vit-base-patch32-224-in21k`. Tento model očekává na vstupu obrázek o velikosti 224x224 pixelů, které rozdělí na části o velikosti 32x32 pixelů, které dále zpracovává. Natrénovaný model dosahoval celkové přesnosti 87 %. Kompletní výsledky jsou vypsány v tabulce 4.2.

Druhým pokusem bylo natrénovat modifikovaný Vision Transformer po vzoru autorů článku z kapitoly 2.6.4. K běžnému modelu je přidána paralelní větev, která rozdělí vstupní obrázek na části o velikostech 8x8 pixelů a ty dále zpracovává, což mělo vést k lepší predikci. Natrénovaný model však ve skutečnosti nevykazoval lepší výsledky, a proto bylo od tohoto přístupu upuštěno.

²¹Framework Hugging Face je dostupný zde: <https://huggingface.co>

²²Nástroj Weight & Biases je dostupný zde: <https://wandb.ai>

Obecně data z trénování obou Vision Transformerů nasvědčovala tomu, že je tato úloha pro tyto modely příliš jednoduchá a u trénování na zvoleném datasetu docházelo k jejich přetrénování. Podporuje to taky fakt, že běžně bývají na vstupu modelů celé fotografie, které byly zmenšeny na rozměr 224x224, zatímco v trénovacím datasetu mají obrázky rozměry 24x40 pixelů, takže musí dojít k jejich zvětšení. Velikost modelu způsobuje také pomalejší klasifikaci panelů.

Z výše popsaných důvodů byl natrénován také třetí model, který je mnohonásobně menší a jedná se o model konvoluční z článku popsaného v sekci 2.6.5. Tento model nevyužívá předtrénované vrstvy a byl tedy trénován od nuly. Vzhledem k jeho velikosti však přesto trénování trvalo kratší dobu, než trénování předtrénovaných Vision Transformerů, i když byl trénován více epoch. Natrénovaný model dosahuje téměř totožných výsledků jako Vision Transformer. Kompletní výsledky pro jednotlivé třídy jsou popsány v tabulce 4.2. Výsledky odpovídají referenčním hodnotám z článku 2.6.5.

Třída	Vision Transformer				Konvoluční model			
	AUC	Precision	Recall	F1-score	AUC	Precision	Recall	F1 score
Cell	0,96	0,82	0,71	0,76	0,96	0,73	0,81	0,77
Cell-Multi	0,93	0,54	0,62	0,58	0,92	0,67	0,47	0,55
Cracking	0,95	0,72	0,71	0,72	0,96	0,76	0,79	0,77
Diode	0,99	0,99	0,97	0,98	0,99	0,97	0,97	0,97
Diode-Multi	0,99	0,95	0,99	0,97	0,99	0,99	0,94	0,97
No-Anomaly	0,99	0,96	0,99	0,97	0,99	0,94	0,99	0,96
Offline-Module	0,98	0,94	0,80	0,86	0,97	0,91	0,72	0,81
Shadowing	0,95	0,88	0,70	0,78	0,97	0,83	0,71	0,77
Vegetation	0,97	0,75	0,79	0,77	0,97	0,77	0,75	0,76


Tabulka 4.2: Výsledky trénování konvolučního modelu a modelu Vision Transformer pro jednotlivé klasifikační třídy.

Na obrázku 4.10 je možné pozorovat matici záměn (confusion matrix), která poskytuje přehled o tom, jaké třídy si mezi sebou natrénovaný model plete. Řádky matice reprezentují skutečnou třídu, tedy tu, která je danému panelu přiřazena během anotace datasetu. Sloupce pak reprezentují předpovědi modelu. Řekněme, že zvolený panel má v anotacích přiřazenou třídu Cell a model predikuje třídu Cell-Multi. V tomto případě dojde k inkrementaci hodnoty matice, která má jako souřadnice řádek 0 a sloupec 1. Matice na obrázku je pro lepší přehlednost normalizovaná a nabývá tedy hodnot 0-1. Zobrazená matice byla vytvořena při evaluaci konvolučního modelu, ale je velmi podobná také matici Vision Transformeru, a proto je v tomto textu zobrazena jen jedna z nich.

Z matice záměn vyplývá, že natrénované modely nejčastěji mezi sebou zaměňují třídy Cell, Cell-Multi, Cracking a Vegetation, které si však jsou značně podobné, jelikož se vyznačují výskytem jednoho či více hotspotů. Zato třídy Diode a Diode-Multi modely rozlišují spolehlivě a stejně je to také u zdravých panelů (No-Anomaly). V dostupných datasetech inspekce elektráren v ČR zaměstnanci při ruční kontrole snímků rozlišují tři hlavní třídy panelů, a to právě vady vyznačující se hotspoty, vady značící vadnou diodu a zdravé panely, což natrénované modely splňují.

4.5.2 Zakomponování klasifikace do webové aplikace

Natrénované klasifikační modely přidělují panelům jednu z 9 tříd. Je možné, že uživatel nebude vyžadovat takto přesnou klasifikaci a bude chtít některé třídy sloučit. Nabízí se




Obrázek 4.10: Matice záměn evaluace konvolučního modelu.

k tomu například třídy `Diode` a `Diode-Multi` nebo třídy `Cell` a `Cell-Multi`. Webová aplikace proto uživateli poskytuje zobrazení, ve kterém má možnost nastavení klasifikačních tříd. Nastavení je realizováno pomocí tabulky, kde lze rozbalit jednotlivé řádky představující skupiny tříd a zobrazit jejich konkrétní obsah. Proces sloučení tříd do skupiny vyžaduje vybrání požadovaných tříd zaškrtnutím jejich checkboxů a kliknutím na tlačítko **Group**, nad nímž se objeví input, do kterého uživatel zadá jméno nové skupiny a potvrdí její vytvoření. Poté je možné tuto skupinu kdykoliv rozpustit kliknutím na křížek na pravé straně. Pro každou třídu si uživatel může zobrazit krátký popis dané vady včetně ukázky panelu disponujícího touto vadou, nebo změnit zobrazovanou barvu nastavované třídy.

Poslední možností nastavení je třídu kompletně vypnout. Klasifikační model předpovídá pro každou třídu pravděpodobnost, že zkoumaný panel spadá právě do ní. Výstupem je tedy pole pravděpodobností a finální třídou je zvolena ta s pravděpodobností nejvyšší. Vypnutí třídy v kontextu této práce znamená, že při výběru ze seznamu pravděpodobností bude ignorována. Pokud by model přisoudil nejvyšší pravděpodobnost vypnuté třídě, systém místo ní vybere třídu, která má druhou nejvyšší pravděpodobnost. Důvod přidání této funkcionality byly problémy s detekcí třídy `Shadowing`, tedy panelů, které jsou zčásti zastíněné. Panely v datasetech z českých elektráren často vrhají mírné odrazy, což na termosnímcích připomíná právě stínění panelu, a model pak často klasifikoval panel třídou `Shadowing`, i když reálně o stínění nešlo. Model si však zpravidla nebyl touto predikcí příliš jistý a pravděpodobnost druhé nejpravděpodobnější třídy byla taky vysoká a ve většině případů správná. Předpověď pravděpodobností jednotlivých tříd má uživatel k dispozici v zobrazení

podrobností o panelu, které je popsáno v sekci 4.6. Vypnutí třídy je tedy krajní řešení, které by měl uživatel využít pouze v případě, kdy model chybně klasifikuje spoustu panelů danou třídou, ale další třídy v pořadí již určuje správně. Například pokud si uživatel přeje, aby model detekoval pouze panely s hotspoty, zatímco všechny ostatní panely by spadaly do druhé třídy, měl by vytvořit dvě skupiny tříd a příslušné třídy do nich přiřadit. Neměl by postupovat tak, že vypne všechny třídy kromě tříd Cell a No-Anomaly, protože výsledná predikce by pak nebyla přesná.



Obrázek 4.11: Ukázka zobrazení nastavení klasifikace panelů.

Uživatel má dále možnost výběru natrénovaného modelu, který chce pro klasifikaci využít. Na výběr má k dispozici konvoluční model a Vision Transformer. Podobně jako u kroku přípravy datasetu, který je popsán v sekci 4.2.1, i tady byl systém navržen tak, aby do něj šlo v budoucnu jednoduše přidávat nové klasifikační modely. Konkrétně byla za tímto účelem definována abstraktní třída `PanelClassifier`, jejíž implementace zaobaluje práci s natrénovaným modelem. Pro přidání nového modelu tedy stačí přidat implementaci této abstraktní třídy a systém ji automaticky rozpozná, a to včetně frontend aplikace, která danou implementaci uživateli ukáže jako další model k výběru. Po spuštění klasifikace se opět uživateli vypisují log zprávy. Ukázka zobrazení pro nastavení klasifikace je přiložena na obrázku 4.11.

Po spuštění klasifikace začne systém postupně zpracovávat jednotlivé dlaždice ortofota. V tomto kroku jsou využity dlaždice nesoucí teplotní data, která jsou namapována na obrazová data pomocí formule:

$$tile_grayscale = \frac{tile_thermal}{max(tile_thermal)} * 255 \quad (4.5)$$

Kde $max(tile_thermal)$ je maximální hodnota naměřená na dané dlaždici. Následně jsou pro danou dlaždici načteny anotace segmentovaných panelů a každý panel je potřeba z obrázku extrahovat a upravit tak, aby měl stejné rozměry jako panely v trénovacím datasetu, tedy 24x40 pixelů. Panel je v anotacích definován sérií bodů. Tyto body jsou ohrazeny natočeným obdélníkem pomocí funkce `minAreaRect()` knihovny OpenCV. Extrakce a úprava velikosti takto ohrazeného panelu je pak provedena pomocí perspektivní transformace.

Výstupem je tedy panel o správné velikosti, který je předán klasifikačnímu modelu ke zpracování.



Obrázek 4.12: Ukázka zobrazení výsledků klasifikace panelů.


Výsledky klasifikace jsou uživateli prezentovány podobně jako výsledky segmentace. Zobrazí se mu tedy celé ortofoto, které má graficky znázorněné panely a jednotlivé třídy jsou barevně odlišený. Vlevo se nachází tabulka tříd, ve které jsou zobrazeny údaje o počtu panelů dané třídy a uživatel má možnost zvolené třídy skrýt. Najetím kurzorem na řádek tabulky tříd zvýrazní odpovídající panely na mapě, což může přispět k lepší přehlednosti.

4.6 Anotace fotovoltaických panelů

V předchozím kroku systém klasifikoval segmentované fotovoltaické panely a nyní je na uživateli, aby provedl kontrolu výsledků a přidal anotace souřadnic panelů. Uživatel má před sebou celé ortofoto s vyznačenými panely, které jsou barevně odlišené podle klasifikovaných tříd. Uživatel může ortofoto přibližovat a pohybovat se v něm. Po kliknutí na panel je aktivováno okno, které poskytuje detailní informace o daném panelu, jak je možné vidět na obrázku 4.13.

Největší část okna zabírá vykreslená dlaždice ortofota s termálními daty, na které jsou vyznačeny hranice panelu. Vespod se nachází posuvník, pomocí kterého může uživatel upravovat rozsah zobrazovaných teplot a tím měnit kontrast. Tato funkcionality je stejná jako v originálním nástroji Flir Tools popsaném v sekci 2.3.3, který je využíván k prohlížení termosnímků při ručním zpracování datasetu. Uživatel má možnost měření teploty na zvolené pozici a tato měření jsou ukládána a vypisována v tabulce napravo.


Během klasifikace panelů jsou na panelech detekovány hotspoty. Nejprve je zjištěn medián teplot daného panelu a následně je tato teplota odečtena od hodnot všech pixelů panelu. Následuje detekce kontur oblastí panelu, kde zůstaly hodnoty pixelů vyšší než nula a pro každou oblast je získána její maximální teplota. V dosavadním řešení zaměstnanci při inspekci rozlišovali 3 typy hotspotů podle toho, jak moc se jejich teplota liší od běžné teploty panelu. Rozsahy teplot jsou popsány v tabulce 2.1. Stejným způsobem jsou přiřazeny kategorie detekovaným hotspotům a tyto informace jsou uloženy do anotací společně



Obrázek 4.13: Ukázka zobrazení detailu panelu.

s predikovanými třídami, průměrnou teplotou a mediánovou teplotou panelu. V zobrazení detailu panelu pak má uživatel tyto hotspoty již zaměřené a v tabulce měření jsou vypsány společně s jejich kategoriemi a teplotami.

Pod tabulkou měření jsou uživateli k dispozici již zmíněná průměrná teplota a mediánová teplota panelu. V druhé tabulce se nachází výstup klasifikačního modelu, tedy jednotlivé klasifikační třídy a jejich pravděpodobnosti. Je na uživateli, aby na základě všech dostupných informací rozhodl, zdali byl panel klasifikován správně, a pokud ne, může tuto chybu jednoduše opravit.




Obrázek 4.14: Ukázka zobrazení pro nastavení souřadnic více panelům najednou.

V zobrazení detailu panelu se nachází také políčka pro zadání jeho souřadnic. Ty však uživatel nemusí zadávat pro každý panel zvlášť. Tato práce se snaží anotaci co nejvíce zjednodušit a urychlit, a proto byla implementována funkcionalita, pomocí které uživatel

označí nejlépe celý stojan s panely najednou a aplikace automaticky rozpozná kolik řad a sloupců bylo označeno, jak je možné vidět na obrázku 4.14. Této funkcionality bylo dosaženo pomocí shlukování pozic středů panelů na osách x a y s předpokladem, že hranice pro přijetí pozice panelů do daného shluku odpovídá 70 % průměrné výšky, respektive šířky označených panelů. Pokud tedy mají pozice středů panelů podobnou hodnotu na ose x, znamená to, že tyto panely patří do stejného sloupce, a podobně panely s podobnou hodnotou pozice na ose y patří do stejného řádku. Tento přístup ovšem funguje pouze v případě, kdy jsou panely na ortofotu horizontálně zarovnané, což není pravidlem. Proto je ještě před shlukováním pozic panelů detekován dominantní úhel náklonu, což je provedeno metodou podobnou analýze hlavních komponent (PCA), a následně jsou souřadnice převedeny tak, aby byl úhel náklonu řad panelů roven nule.

Na okně, které po označení panelů vyjede ze spodní části aplikace, jsou pak vykresleny čtverce symbolizující označené panely a každý čtverec má barvu odpovídající třídě daného panelu, což by mělo uživateli pomoci s kontrolou správnosti detekce sloupců a řádků. Poté stačí zadat čísla stojanu, horní řady a levého sloupce ze zvolené oblasti a všem ostatním panelům jsou z těchto informací vypočteny jejich souřadnice. Po uložení souřadnic je na anotovaných panelech vykreslen diagonální kříž, čímž jsou označeny jako plně anotované.



Obrázek 4.15: Ukázka grafického rozhraní pro schválení výsledků zpracované inspekce.

Ke kontrole anotací lze pozvat i další uživatele, k čemuž bylo implementováno poslední zobrazení aplikace. Uživatel, který doposud prováděl zpracování datasetu, může zvoleným uživatelům, kteří mají k dané elektrárně také přístup, jednoduše zaslat notifikace ve formě e-mailu. Aplikace umožňuje do této notifikace přidat vlastní text. Pozvaní uživatelé se následně zobrazí v tabulce, kde je znázorněn také stav jejich kontroly. Výsledky této inspekce je možné přijmout, nebo odmítnout. Zároveň mohou přidávat komentáře buďto k celé inspekci, nebo k jednotlivým panelům. V tomto kroku by nejspíše mělo také dojít k reálné výměně vadných panelů, či jinak opravit detekované závady. Tento krok je však spíše návrh, jak by mohla být inspekce zakončena. Pokud jsou všechny nedostatky vyřešeny, zbývá už jen celou inspekci označit jako hotovou, a tím končí celý proces zpracování datasetu. Ukázka popisovaného zobrazení se nachází na obrázku 4.15.

Kapitola 5

Evaluace systému

Implementovaný systém byl otestován dvěma způsoby. Prvním způsobem bylo testování výsledků predikcí podle anotací, které ručně vytvořil odborník z praxe, zatímco ve druhém případě byly anotace vytvořeny samotným autorem této práce. Systém byl také předveden odborníkovi, který se inspekcemi fotovoltaických zařízení zabývá, a ten poté poskytl své dojmy a také návrhy na možná rozšíření v budoucnu.

5.1 Dataset Sychrov


V době psaní práce byl k dispozici pouze jeden odborně anotovaný dataset, který byl pořízen při inspekci fotovoltaické elektrárny v obci Sychrov. Anotace datasetu byla provedena ručně za využití nástroje FLIR Tools, ve kterém byly na termosnímčích vyznačeny očíslované podezřelé body. Tyto body byly zapsány do tabulky, která obsahuje shrnutí celé inspekce. U každého zdrojového termosnímku jsou uvedeny všechny označené body. K nim jsou přiřazeny souřadnice odpovídajících panelů a třída určující typ vady, kterou je daný panel pravděpodobně postižen. Tyto anotace bylo potřeba převést do formátu, který bude zpracovatelný a porovnatelný s výsledky predikcí systému. Dataset byl proto zpracován pomocí implementovaného systému, jenž z něj vytvořil ortofoto, a z toho segmentoval panely. Poté bylo zkontrolováno, zda systém některé panely nepřehlédl, a chybějící panely byly označeny ručně. Elektrárna disponuje celkem 2208 solárními panely a pouze 8 z nich nebylo detekováno.

Dalším krokem byla klasifikace panelů. V anotacích vytvořených expertem byly obsaženy pouze 4 třídy panelů, a proto bylo nastavení klasifikace v systému upraveno odpovídajícím způsobem. Například třídy `cell`, `cell-multi` a `cracking` byly sloučeny do třídy `hotspot` atd. Poté byla spuštěna klasifikace a výsledky byly ručně opraveny tak, aby přesně odpovídaly anotacím z tabulky. Systém anotace ukládá do souboru ve formátu JSON a tento soubor byl využíván jako ground truth anotace. Následně byl proces klasifikace spuštěn znovu a s výslednými predikcemi již nebylo nijak manipulováno. Každý detekovaný panel má v anotacích svůj jednoznačný identifikátor, který není během klasifikace nijak měněn, čehož bylo využito při implementaci evaluačního skriptu. Tento skript načte ground truth anotace, predikované anotace a také aktuální nastavení klasifikace (aktuální sloučení klasifikačních tříd atd.). Skript páruje panely z obou anotací pomocí jejich identifikátoru a porovnává jejich reálné a predikované třídy. Pomocí knihovny `scikit-learn` je z výsledků vytvořena matice záměn (confusion matrix) a také výstup evaluace klasifikačních modelů.

Třída	Vision Transformer		Konvoluční model	
	Precision	Recall	Precision	Recall
Diode	0,26	0,75	0,38	0,64
Hotspot	0,68	0,85	0,68	0,94
No-Anomally	0,98	0,83	1	0,91
Vegetation	0,11	0,35	0,19	0,18

Tabulka 5.1: Výsledky evaluace klasifikačních modelů.

V tabulce 5.1 jsou vypsané výsledky evaluace a na obrázku 5.1 je zase znázorněna matice záměn konvolučního modelu. Z výsledků vyplývá, že natrénované modely mají problémy s rozlišením mezi vegetací a jinými vadami, které se vyznačují hotspoty na ploše panelu. Je však nutno podotknout, že i pouhým okem je z termosnímků těžko rozeznatelné, zdali je hotspot na okraji způsobený stíněním zeleně, nebo se pouze jedná o vadnou buňku, která se shodou náhod nachází na okraji panelu. Konvoluční modely navíc zkoumají převážně lokální závislosti obrázku, a proto při klasifikaci nejspíše zanikne informace o tom, že je daný hotspot na okraji panelu, což by vysvětlovalo horší výsledky oproti Vision Transformeru. K vylepšení detekce této vady by mohlo přispět pořízení dalšího datasetu pomocí RGB kamery a využití i této vrstvy ke klasifikaci. Zároveň by šlo do vstupu konvoluční sítě zakomponovat informaci o poloze jednotlivých pixelů. V několika případech byly panely s vadnou diodou přiřazeny do třídy hotspot. Někdy se na panelu mohou nacházet vady obou tříd, a model většinou určí vyšší prioritu vadě typu hotspot, protože ta je více jednoznačná. Z celkových 435 vadných panelů konvoluční model mylně označil za zdravé pouze 6 z nich, takže Recall pro odhalení vadného panelu přesahuje 98 %. Precision pro klasifikaci vadných panelů je nižší, což znamená, že model označil vadnými i ty panely, které expert označil za zdravé. Je to z velké míry způsobeno tím, že expert nebere v potaz slabé hotspoty, tedy ty, které nemají příliš vysokou teplotu. Model však defekty odhaluje s vyšší citlivostí. Tento problém by bylo možné vyřešit například kontrolou rozdílů teplot hotspotů od zdravé teploty panelu, což by šlo začlenit do procesu klasifikace.



Obrázek 5.1: Matice záměn vytvořená z výsledků evaluace Vision Transformeru a konvolučního modelu na datasetu elektrárny Sychrov.

5.2 Ostatní datasety

V době psaní práce nebyly pro ostatní datasety dostupné anotace vytvořené expertem, a proto byly vytvořeny autorem této práce. Tyto výsledky tedy nejspíše nemají takovou váhu, ovšem jsou zde zahrnuty alespoň pro lepší představu, jak byl systém úspěšný při zpracování datasetů z ostatních elektráren.


5.2.1 Dataset Hustopeče

Tvorba anotací pro evaluaci probíhala podobně jako u datasetu Sychrov, ale tentokrát bylo pro zajímavost rozlišováno více klasifikačních tříd.

Třída	Vision Transformer		Konvoluční model	
	Precision	Recall	Precision	Recall
Cell	0,26	0,22	0,74	0,78
Cell-Multi	0,15	0,53	0,76	0,74
Cracking	0,34	0,85	0,59	0,94
Diode	0,59	0,66	0,98	0,54
No-Anomaly	1	0,86	1	0,97
Vegetation	0,10	0,56	0,23	0,33

Tabulka 5.2: Výsledky evaluace klasifikačních modelů.

Při segmentaci systém vynechal 58 z celkových 4617 fotovoltaiických panelů a úspěšnost segmentace tedy přesahuje 98 %.




Obrázek 5.2: Matice záměn vytvořená z výsledků evaluace Vision Transformeru a konvolučního modelu na datasetu elektrárny Hustopeče nad Bečvou.

Z tabulky 5.2 je patrné, že konvoluční model dosahuje lepších výsledků než Vision Transformer. Matice záměn na obrázku 5.2 však napovídá, že predikce Vision Transformeru není tak špatná, jak by se na první pohled mohlo zdát. Vision Transformer v tomto případě ve

velkém zaměňuje třídy ze skupiny hotspot, ale například panelů s vadnou diodou správně odhalil více než konvoluční model. Celkový Recall pro odhalení vadného panelu jakékoliv chyby u obou modelů přesahuje 98 %, jelikož Vision Transformer neodhalil pouze 4 z celkového počtu 668 vadných panelů a konvoluční model jich neodhalil 12.

5.2.2 Dataset Rudoltice

Dataset pořízený při inspekci fotovoltaické elektrárny v obci Rudoltice má velmi špatnou kvalitu. Na velkém množství snímků jsou viditelné odlesky slunce, což způsobuje tmavé termosnímky. Tento problém sice řeší normalizace datasetu, ale i na normalizovaných snímcích jsou odlesky viditelné a vzhledově připomínají velmi silné a rozsáhlé hotspoty na panelech. Tyto problémy značně komplikují tvorbu ortofota, protože odlesk se nachází vždy přibližně uprostřed snímku. To znamená, že na jednom snímku vypadá panel, který je zrovna uprostřed, jako vadný, ale na druhém snímku, který se s tím prvním překrývá, již zmíněný panel tento „defekt“ nemá. Místo toho je odlesk opět na jiném (pravděpodobně zdravém) panelu, nacházejícím se uprostřed druhého snímku. Při tvorbě ortofota to pak způsobuje problémy s hledáním párů významných bodů, podle kterých má probíhat rekonstrukce 3D modelu, protože stejný panel vypadá na různých snímcích úplně jinak.



Obrázek 5.3: Ukázka části ortofota, které bylo vytvořeno z datasetu inspekce elektrárny v obci Rudoltice.

Kvalitě datasetu odpovídá také kvalita výsledného ortofota, které obsahuje spoustu nežádoucích artefaktů, jak je možné pozorovat na obrázku 5.3. Zdá se, že problémy způsobuje také rozdělení datasetu na submodely a jejich následné spojování, protože na ortofotu jsou patrné hranice jednotlivých submodelů. Tento problém by možná vyřešilo zvýšení dostupné paměti RAM, díky čemuž by šlo tvořit větší submodely. Problémy s odlesky to však nevyřeší. Nutno podotknout, že pro tento dataset nebylo vytvořeno ortofoto ani pomocí programu Agisoft, takže se nejedná pouze o problém systému, který byl implementován k této diplomové práci. Tento dataset je však poměrně starý, jelikož vznikl v roce 2020, zatímco

datasety elektráren v obcích Sychrov a Hustopeče vznikly v roce 2022. Je tedy možné, že se jednalo o jednorázovou chybu nastavení dronu.

Na vytvořeném ortofotu byla otestována segmentace panelů, která dopadla překvapivě dobře. Při evaluaci segmentace nebyly brány v potaz velmi deformované panely, ale jinak systém dobře segmentoval přes 98 % panelů. Po vizuální kontrole bylo zjištěno, že drtivá většina panelů této elektrárny se jeví jako zdravá a skoro všechny detekovatelné defekty jsou způsobeny již zmíněnými odlesky. Proto byla evaluace klasifikačního modelu na tomto datasetu vynechána.

5.3 Konzultace s odborníkem z praxe

Výsledky této práce byly konzultovány s odborníkem z praxe, který inspekce fotovoltaických elektráren v Česku provádí a který také fakultě poskytl datasety z inspekci elektráren, na nichž je celá práce postavená. Během schůzky byl systém předveden tak, jak by ho běžně využíval uživatel a cílem bylo získat informace, zdali by toto řešení mohlo být využitelné v praxi, jestli má dle jeho názoru potenciál urychlit a usnadnit proces inspekce, a také jaké jsou jeho návrhy na možná rozšíření a vylepšení systému v budoucnu.

Ohlasy na práci byly vesměs pozitivní. Odborníka zajímaly informace jako například jak dlouho trvá vytvoření ortofota, zdali případné fragmenty, které se občas na ortofotu objevují po krajích panelů, neovlivňují jejich segmentaci, či s jakou přesností systém dokáže odhalit vadný panel. Výsledky evaluace klasifikace panelů a zejména fakt, že Recall pro odhalení vadného panelu dosahuje 98 %, považuje za velice dobré a srovnatelné s přesností, které je možné dosáhnout při ručním procházení snímků.

Jednou z úprav, kterou by dle názoru experta bylo dobré udělat, je přidání možnosti konfigurace formátu souřadnicového systému panelů. Každá elektrárna jej může mít nastavený jinak, a proto by bylo výhodné, kdyby si mohl uživatel sám nastavit jednotlivá pole, jako například část elektrárny, řada, stojan nebo sloupec. Aplikace totiž momentálně umožňuje zadávat pouze obecné souřadnice ve formátu stojan, řada a sloupec, jelikož v době jejího vytváření nebyly informace o souřadných systémech z ostatních elektráren k dispozici. Dalším podnětem pro budoucí práci by bylo rozšíření logiky procesu klasifikace panelů, protože například společnost ČEZ má údajně přísné standardy, které určují minimální teplotu hotspotu, který se bere v potaz, anebo také vyžaduje, aby byla na základě výsledků klasifikace odhadnuta míra ztráty výkonu daného panelu. Systém byl implementován tak, že přidání takovýchto funkcionalit by nemělo představovat velký problém.

Vedla se také diskuse o formátu, ve kterém zaměstnancům elektrárny předat výsledky inspekce. Jednou z možností je z anotací vygenerovat tabulku podobnou těm, které jsou aktuálně vytvářeny při ruční kontrole termosnímků. Další možností je zobrazení panelů na ortofotu, tak jak je to implementováno v této práci. Nejlepší by dle názoru odborníka bylo, kdyby se v budoucnu ještě vytvořila mobilní aplikace, kterou by měl zaměstnanec elektrárny v mobilu nebo tabletu, a kde by se na ortofotu živě zobrazovala také jeho aktuální poloha. Orientace ve velkých elektrárnách je prý značnou výzvou a tohle rozšíření systému by opět mohlo přispět k vyšší efektivitě údržby solárních elektráren. Ortofota generována implementovaným systémem obsahují GPS anotace, takže lze pro každý pixel dopočítat jeho souřadnice. Vyhodnocení jejich přesnosti by však už muselo být součástí některé z navazujících prací.

Celkově byla konzultace konstruktivní a pozitivní. Implementovaný systém má dle názoru odborníka z praxe velký potenciál pro usnadnění a urychlení procesu inspekci a myslí si, že by o takovéto řešení mohly mít zájem firmy, které fotovoltaické elektrárny vlastní,

nebo provádějí jejich údržbu. Proto doporučuje tuto diplomovou práci v budoucnu nadále rozvíjet a pokusit se vytvořit ještě komplexnější řešení, které by mohlo navíc zahrnovat i již zmíněnou mobilní aplikaci napomáhající orientaci údržbářům v elektrárně.

Kapitola 6

Závěr

Cílem této diplomové práce bylo vytvořit systém, který urychlí a usnadní zpracování datasetů termosnímků pořízených při inspekci fotovoltaických elektráren, jelikož v současné době probíhá detekce vadných panelů ručně.

Řešení této práce zahrnuje všechny klíčové kroky k vyhodnocení inspekci. Vstupem je dataset, z jehož termosnímků jsou načtena teplotní data a z nich generovány snímky s normalizovanou úrovní jasu, což přispívá ke kvalitnějšímu multispektrálnímu ortofotu. Ortofoto je tvořeno pomocí nástroje OpenDroneMap integrovaného do systému, a díky multispektrálnímu módu obsahuje vrstvu s reálnými teplotními daty. Fotovoltaické panely jsou z ortofota segmentovány pomocí modelu Mask R-CNN a následně klasifikovány až do 9 tříd podle typu vady. Uživatel má na výběr ze dvou klasifikačních modelů – Vision Transformeru a konvolučního modelu. Výsledky klasifikace jsou interaktivně zobrazeny na ortofotu a systém umožňuje detailní náhled na jednotlivé panely s automatickou detekcí podezřelých bodů a zobrazením jejich teplot. Uživatel může doplnit vlastní měření a na jejich základě posoudit správnost predikce. Systém rovněž usnadňuje zadávání souřadnic panelů v rámci koordinačního systému elektrárny. Celé řešení je realizováno jako webová aplikace, což zajišťuje přístup odkudkoliv bez zátěže pro počítač uživatele. Podporováno je také napojení na e-mailový server pro zaslání upozornění o stavu zdoluhavých procesů, jako je tvorba ortofota. Díky podpoře správy uživatelů lze zaměstnancům elektráren zřídit účty s přístupem pouze k relevantním datům.

Implementovaný systém byl testován na datasetech z českých fotovoltaických elektráren, kde jeden z nich byl anotován expertem z praxe. Úspěšnost segmentace panelů se pohybuje okolo 98 %. Natrénované klasifikační modely mají nižší přesnost při rozlišování některých typů vad (například pod 20 % pro třídu vegetace), ale celkově systém na testovaných datasetech odhalil 98 % všech vadných panelů.

Systém byl předveden odborníkovi z praxe, který jej označil jako přínosný a s velkým potenciálem využití v provozu. Tato diplomová práce byla také prezentována na konferenci Excel@FIT, kde získala 2 ceny za výjimečnou práci od společností Honeywell a Ysoft.

Dosažené výsledky této diplomové práce mohou být v budoucnu využity k dalšímu rozvoji v této oblasti. Systém jsem se snažil navrhnout tak, aby byl modulární. Díky tomu do něj lze jednoduše přidávat další natrénované modely, případně jiné implementace pro klasifikaci panelů, nebo například jiné implementace pro načítání termálních dat z termosnímků. Budoucí práce se mohou zaměřit na tvorbu mobilní aplikace, jak bylo zmíněno v sekci 5.3, na nové přístupy ke klasifikaci, nebo například na akceleraci tvorby ortofota.

Literatura

- [1] AL EZZI, A. S. a ANSARI, M. N. M. Photovoltaic Solar Cells: A Review. *Applied System Innovation*. 1. vyd. 2022, sv. 5, č. 4. DOI: 10.3390/asi5040067. ISSN 2571-5577.
- [2] ANDREWS, R. a SINCLAIR, K. *Issues with bypass diodes*. Sep 2017. Dostupné z: <https://pv-magazine-usa.com/2017/09/27/issues-with-bypass-diodes/>.
- [3] DOSOVITSKIY, A., BEYER, L., KOLESNIKOV, A., WEISSENBORN, D., ZHAI, X. et al. An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale. *ICLR*. 2021.
- [4] DUBEY, V. Evaluation Metrics for Object detection algorithms. *Medium*. 2020. Dostupné z: <https://medium.com/@vijayshankerdubey550/evaluation-metrics-for-object-detection-algorithms-b0d6489879f3>.
- [5] FLIR. *How Do Thermal Cameras Work?* Jun 2020. Dostupné z: <https://www.flir.com/discover/rd-science/how-do-thermal-cameras-work/>.
- [6] FOUAD, M., SHIHATA, L. a IMAM MORGAN, E. An integrated review of factors influencing the performance of photovoltaic panels. *Renewable and Sustainable Energy Reviews*. Prosinec 2017, sv. 80, s. 1499–1511. DOI: 10.1016/j.rser.2017.05.141.
- [7] HAUŽVIC, F. *Detekce a klasifikace vad panelů fotovoltaických elektráren z termokamery dronu*. Brno, 2024. Bakalářská práce. Vysoké učení technické v Brně, Fakulta informačních technologií. Vedoucí práce Ing. Daniel Bambušek.
- [8] HE, K., GKIOXARI, G., DOLLÁR, P. a GIRSHICK, R. Mask r-cnn. In: *Proceedings of the IEEE international conference on computer vision*. IEEE, říjen 2017, s. 2961–2969. DOI: 10.1109/ICCV.2017.322.
- [9] HE, K., ZHANG, X., REN, S. a SUN, J. Deep Residual Learning for Image Recognition. In: *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2016, s. 770–778. DOI: 10.1109/CVPR.2016.90.
- [10] HENRY, C., POUDEL, S., LEE, S.-W. a JEONG, H. Automatic Detection System of Deteriorated PV Modules Using Drone with Thermal Camera. *Applied Sciences*. 2020, sv. 10, č. 11. DOI: 10.3390/app10113802. ISSN 2076-3417.
- [11] HIGUCHI, Y. a BABASAKI, T. Failure detection of solar panels using thermographic images captured by drone. In: *2018 7th International Conference on Renewable Energy Research and Applications (ICRERA)*. říjen 2018, s. 391–396. DOI: 10.1109/ICRERA.2018.8566833. ISSN 2572-6013.

- [12] LE, M., LE, D. a HA THI VU, H. Thermal inspection of photovoltaic modules with deep convolutional neural networks on edge devices in AUV. *Measurement*. 2023, sv. 218, s. 113135. DOI: <https://doi.org/10.1016/j.measurement.2023.113135>. ISSN 0263-2241.
- [13] LIBRA, M., MRÁZEK, D., TYUKHOV, I., SEVEROVÁ, L., POULEK, V. et al. Reduced real lifetime of PV panels – Economic consequences. *Solar Energy*. Freiburg, Germany: Elsevier Ltd. Červenec 2023, sv. 259, s. 229–234. DOI: <https://doi.org/10.1016/j.solener.2023.04.063>. ISSN 0038-092X.
- [14] MILLENDORF, M., OBROPTA, E. a VADHAVKAR, N. INFRARED SOLAR MODULE DATASET FOR ANOMALY DETECTION. *ICLR 2020, AI for Earth Sciences workshop*. Somerville, USA: [b.n.]. Duben 2020.
- [15] NOVÁK, J. A. *Telink Předvedl Nové Drony Dji matrice 200 a 210*. Droneweb, Sep 2017. Dostupné z: <http://www.droneweb.cz/aktuality/item/171-dji-matrice-telink>.
- [16] OPENCV. *About*. Dostupné z: <https://opencv.org/about/>.
- [17] OPENCV. *Image thresholding*. 2023. Dostupné z: https://docs.opencv.org/4.9.0/d7/d4d/tutorial_py_thresholding.html.
- [18] *Počet připojených zdrojů do elektrizační soustavy se loni zvýšil o čtvrtinu. Celkový instalovaný výkon v ČR vzrostl o Temelínský blok*. Ministerstvo průmyslu a obchodu, leden 2025. Dostupné z: <https://mpo.gov.cz/cz/rozcestnik/pro-media/tiskove-zpravy/pocet-pripojenych-zdroju-do-elektrizacni-soustavy-se-loni-zvysil-o-ctvrtinu--celkovy-instalovany-vykon-v-cr-vzrostl-o-temelinsky-blok--285522/>.
- [19] RAMADAN, E., MOAWAD, N. M., ABOUZALM, B. A., SAKR, A. A., ABOUZAIID, W. F. et al. An innovative transformer neural network for fault detection and classification for photovoltaic modules. *Energy Conversion and Management*. 2024, sv. 314, s. 118718. DOI: <https://doi.org/10.1016/j.enconman.2024.118718>. ISSN 0196-8904.
- [20] SKAALAND, A., RICKE, M., WALLEVIK, K., STRANDBERG, R. a IMENES, A. G. Potential and Challenges for Building Integrated Photovoltaics in the Agder Region. *Agderforskning*. Gimlemoen 19, N-4630 Kristiansand: Agderforskning. Červen 2011. ISSN 0808-5544.
- [21] WIKIPEDIA. *Thermography — Wikipedia, The Free Encyclopedia* [<http://en.wikipedia.org/w/index.php?title=Thermography&oldid=1193379275>]. 2024. [Online; accessed 15-January-2024].
- [22] WIKIPEDIA CONTRIBUTORS. *Orthophoto — Wikipedia, The Free Encyclopedia* [<http://en.wikipedia.org/w/index.php?title=Orthophoto&oldid=1288631357>]. 2025. [Online; accessed 09-May-2025].
- [23] WIKIPEDIA CONTRIBUTORS. *Teledyne FLIR — Wikipedia, The Free Encyclopedia* [https://en.wikipedia.org/w/index.php?title=Teledyne_FLIR&oldid=1269125397]. 2025. [Online; accessed 18-January-2025].
- [24] WU, Z., HU, Y., WEN, J. X., ZHOU, F. a YE, X. A Review for Solar Panel Fire Accident Prevention in Large-Scale PV Applications. *IEEE Access*. 2020, sv. 8, s. 132466–132480. DOI: 10.1109/ACCESS.2020.3010212.

- [25] ZEFRI, Y., ELKETTANI, A., SEBARI, I. a AIT LAMALLAM, S. Thermal Infrared and Visual Inspection of Photovoltaic Installations by UAV Photogrammetry—Application Case: Morocco. *Drones*. 2018, sv. 2, č. 4. DOI: 10.3390/drones2040041. ISSN 2504-446X.