



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY
A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV ELEKTROTECHNOLOGIE

DEPARTMENT OF ELECTRICAL AND ELECTRONIC TECHNOLOGY

AUTOMATICKÉ VYHODNOCOVÁNÍ TERMOVIZNÍCH SNÍMKŮ FOTOVOLTAICKÝCH PANELŮ

THERMOVISION OF PHOTOVOLTAIC MODULES AUTHOMATIC ANALYSIS

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Jakub Klíma

VEDOUCÍ PRÁCE

SUPERVISOR

doc. Ing. Jiří Vaněk, Ph.D.

BRNO 2016



Diplomová práce

magisterský navazující studijní obor **Elektrotechnická výroba a materiálové inženýrství**

Ústav elektrotechnologie

Student: Bc. Jakub Klíma

ID: 125478

Ročník: 2

Akademický rok: 2015/16

NÁZEV TÉMATU:

Automatické vyhodnocování termovizních snímků fotovoltaických panelů

POKyny PRO VYPRACOVÁNÍ:

Seznamte se s principy činnosti solárních článků a s metodami detekce defektů ovlivňujících jejich kvalitu. Seznamte se s detekcí vad pomocí termovizní kamery.

Vytvořte software pro automatické detekování vad fotovoltaických panelů ze snímků pořízených termovizní kamerou. Funkčnost softwaru ověřte ve spolupráci s firmou Eicero s.r.o. a výsledky vyhodnoťte.

DOPORUČENÁ LITERATURA:

Podle zadání vedoucího práce.

Termín zadání: 8.2.2016

Termín odevzdání: 26.5.2016

Vedoucí práce: doc. Ing. Jiří Vaněk, Ph.D.

Konzultant diplomové práce:

doc. Ing. Petr Bača, Ph.D., předseda oborové rady

UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

ABSTRAKT

Práce se zabývá diagnostikou fotovoltaických panelů, zejména diagnostikou pomocí termovizní kamery. Jsou zde popsány defekty, které můžeme termovizní kamerou zkoumat a je vysvětlena příčina jejich vzniku. Praktická část je věnovaná tvorbě programu na automatické detekování defektů z termovizních snímků.

KLÍČOVÁ SLOVA

Fotovoltaické panely, defekty, diagnostika, termokamera, termovize, počítačové vidění, automatická detekce defektů.

ABSTRACT

This thesis deals with diagnostics of photovoltaic panels especially with infrared diagnostics. There are described defects which we can examine using thermovision and also this thesis explains the cause of their formation. Practical part deals with the design of the program that automatically detects defects on infrared images.

KEYWORDS

Photovoltaic panels, defects, diagnostics, infrared camera, thermovision, computer vision, automatic defects detection.

KLÍMA, J. *Automatické vyhodnocování termovizních snímků fotovoltaických panelů*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2016. 66 s. Vedoucí diplomové práce doc. Ing. Jiří Vaněk, Ph.D..

PROHLÁŠENÍ

Prohlašuji, že svou diplomovou práci na téma Automatické vyhodnocování termovizních snímků fotovoltaických panelů jsem vypracoval samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této diplomové práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědom následků porušení ustanovení § 11 a následujících zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

V Brně dne

.....

(podpis autora)

PODĚKOVÁNÍ

Děkuji vedoucímu diplomové práce doc. Ing. Jiřímu Vaňkovi, Ph.D. za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé diplomové práce. Dále bych chtěl poděkovat rodině a přítelkyni za podporu během studia.

V Brně dne

.....

(podpis autora)

OBSAH

1 ÚVOD	3
2 DIAGNOSTICKÉ METODY ZJIŠŤOVÁNÍ STAVU FV PANELŮ	4
2.1 SLUNEČNÍ SIMULÁTOR S TESTEREM	4
2.2 MĚŘENÍ V-A CHARAKTERISTIK TESTEREM PROVA 210	4
2.3 LBIC	4
2.4 ELEKTROLUMINISCENCE	4
2.5 DALŠÍ METODY	5
3 DIAGNOSTIKA POMOCÍ TERMOVIZNÍ KAMERY	6
3.1 SLOŽENÍ TERMOKAMERY	6
3.1.1 OPTIKA	7
3.1.2 DETEKTOR	7
3.1.3 ZPRACOVÁVACÍ ELEKTRONIKA	8
3.2 ZÁKLADNÍ PARAMETRY TERMOKAMERY	8
3.2.1 TEPLOTNÍ ROZSAH	8
3.2.2 SPEKTRÁLNÍ ROZSAH.....	8
3.2.3 PŘESNOST MĚŘENÍ.....	8
3.2.4 TEPLOTNÍ CITLIVOST	8
3.2.5 ROZLIŠENÍ DETEKTORU	8
3.2.6 FIELD OF VIEW	8
3.3 PODMÍNKY MĚŘENÍ FV PANELŮ TERMOKAMEROU	9
3.4 FYZIKÁLNÍ PODSTATA TERMOVIZNÍHO MĚŘENÍ	9
3.4.1 PLANCKŮV VYZAŘOVACÍ ZÁKON	9
3.4.2 WIENNŮV ZÁKON	10
3.4.3 STEFAN-BOLTZMANNŮV ZÁKON.....	11
3.4.4 PRVNÍ KIRCHHOFFŮV ZÁKON	12
3.4.5 DRUHÝ KIRCHHOFFŮV ZÁKON	12
4 DEFEKTY FV PANELŮ	13
4.1 VLIV ZASTÍNĚNÍ ČLÁNKŮ	13
4.1.1 FOTOVOLTAICKÝ JEV.....	13
4.1.2 PŘÍČINY OTEPLOVÁNÍ ČLÁNKŮ.....	15
4.2 DRUHY DEFEKTŮ ODHALITELNÝCH POMOCÍ TERMOVIZNÍ KAMERY	16
5 POČÍTAČOVÉ VIDĚNÍ	19
5.1 PŘEDZPRACOVÁNÍ OBRAZU	20
5.2 SEGMENTACE	20
5.2.1 SEGMENTACE PRAHOVÁNÍM.....	20
5.2.2 SEGMENTACE NA ZÁKLADĚ DETEKCE HRAN	21

5.2.3 SEGMENTACE NARŮSTÁNÍM OBLASTÍ	22
5.2.4 SEGMENTACE SROVNÁNÍM SE VZOREM.....	22
5.3 POPIS OBJEKTŮ	22
5.4 KLASIFIKACE OBJEKTŮ - NEURONOVÉ SÍŤE	24
5.4.1 ANALOGIE UMĚLÝ A BIOLOGICKÝ NEURON	24
5.4.2 DĚLENÍ NEURONOVÝCH SÍŤÍ.....	25
5.4.3 ZPĚTNÉ ŠÍŘENÍ CHYBY (BACKPROPAGATION).....	25
PRAKTICKÁ ČÁST.....	26
6 ANALÝZA PROBLÉMU	26
6.1 ARCHITEKTURA PROGRAMU.....	27
6.2 POPIS JEDNOTLIVÝCH ČÁSTÍ PROGRAMU	28
6.2.1 PŘEDZPRACOVÁNÍ – TRÍDA SHAPEFINDER.....	28
6.2.2 SEGMENTACE – TRÍDA SHAPEFINDER	29
6.2.3 POPIS – TRÍDA UNIDENTIFIEDOBJECT	29
6.2.4 POPIS – TRÍDA XMLMANAGER	30
6.3 POPIS – TRÍDA DEFECTSINTELLIGENCE.....	30
6.4 POPIS UŽIVATELSKÉHO ROZHRAŇÍ	31
6.5 PRVNÍ SPUŠTĚNÍ PROGRAMU.....	34
7 EXPERIMENT	36
7.1 HLEDÁNÍ PŘÍZNAKOVÉHO VEKTORU.....	36
7.2 POSTUP EXPERIMENTU	36
7.2.1 PŘÍZNAKOVÝ VEKTOR 35	38
7.2.2 PŘÍZNAKOVÝ VEKTOR 7	40
7.2.3 PŘÍZNAKOVÝ VEKTOR 22	42
7.2.4 PŘÍZNAKOVÝ VEKTOR 10	44
7.2.5 PŘÍZNAKOVÝ VEKTOR 56	46
7.3 SHRNUŤÍ EXPERIMENTU	48
8 DISKUZE.....	49
9 ZÁVĚR.....	50
SEZNAM SYMBOLŮ A ZKRATEK.....	51
SEZNAM OBRÁZKŮ.....	51
SEZNAM TABULEK	55
POUŽITÁ LITERATURA	56
PŘÍLOHY	58

1 ÚVOD

Diagnostika stavu fotovoltaických (FV) panelů je nedílnou součástí provozního života solárních elektráren. Včasné odhalení defektů nebo dokonce i začínajících defektů pomáhá provozovatelům naplánovat údržby a revitalizace, čímž samozřejmě předchází neplánovaným odstávkám. Diagnostických metod pro FV panely existuje celá řada, podle místa provádění zkoušek je můžeme rozdělit na laboratorní a venkovní. Podle podstaty jednotlivých metod můžeme tyto rozřadit do dvou skupin:

1. Diagnostika elektrických parametrů – pomocí těchto metod určujeme elektrické parametry článků,
2. diagnostika pomocí optických metod – pomocí těchto metod můžeme zobrazit defekty v ploše panelu.

Metody se samozřejmě liší cenou, dobou realizace, náročností na provedení i vybavení. V této práci bude pojednáno o diagnostice pomocí termovizního. Metoda je v podstatě jednoduchá na provedení a vzniká při ní velké množství termovizních snímků, které je pak třeba jednotlivě vyhodnocovat. Cílem této práce bude navrhnout software, který by automaticky snímky rozřídil podle toho, zda obsahují nebo neobsahují některé časté vady.

Po úvodní části si krátce shrneme některé existující diagnostické metody, abychom si poté podrobněji rozebrali diagnostiku pomocí termovizní kamery.

V příslušných kapitolách si rozebereme, z čeho se termovizní kamera skládá a jaké parametry ovlivňují termovizní měření.

Následně si krátce popíšeme fyzikální podstatu termovizního měření a fyzikální zákony, kterých je při měření využíváno.

S nabytými znalostmi se zaměříme na defekty panelů, které můžeme pomocí termovizního měření odhalit a ukážeme se ukázky těchto defektů.

Pátá kapitola pojednává o počítačovém vidění a pokládá tak teoretické základy pro návrh softwaru.

Šestá kapitola popisuje jednotlivé části programu, uživatelské rozhraní a vysvětluje ovládání programu.

Sedmá kapitola pojednává o experimentálním hledání vhodného příznakového vektoru pro klasifikaci.

V závěru zhodnotíme výstupy programu, nastíníme jeho slabé stránky a možnosti vylepšení.

2 DIAGNOSTICKÉ METODY ZJIŠŤOVÁNÍ STAVU FV PANELŮ

Důležitost diagnostikování FV panelů byla popsána již v úvodu, v této kapitole bude krátce pojednáno o některých metodách.

2.1 Sluneční simulátor s testerem

Metoda slunečního simulátoru s testerem, tzv. Flash test, sloužící k diagnostikování elektrických parametrů využívá speciálních zdrojů světla, která co nejdříve simulují spektrum slunečního záření v celém viditelném spektru. Pro tyto účely se jako zdroje často užívají xenonové nebo halogenidové výbojky. V principu jde o to, že FV panely jsou ozařovány kolmo dopadajícími rovnoběžnými svazky paprsků. Během celého testu jsou udržovány parametry a to intenzita záření $1\,000\text{ W/m}^2$ a konstantní teplota 25 °C .

Výstupem testu je poté V-A charakteristika, výstupní špičkový výkon, napětí naprázdno, proud nakrátko, pracovní proud, napětí a výkon, účinnost a fill faktor.

2.2 Měření V-A charakteristik testerem PROVA 210

Oproti flash testu lze tuto metodu provádět venku na denním světle. Princip metody je připojování jednotlivých článků na tester a jejich rychlé vyhodnocování pomocí počítačového softwaru. V softwaru je třeba před měřením nastavit aktuální klimatické podmínky. Nevýhodou této metody je, že prakticky nelze opakovat měření, kvůli nemožnosti zaručit shodné podmínky.

Výstupem testu je opět V-A charakteristika, výstupní špičkový výkon, napětí naprázdno, proud nakrátko, pracovní proud, napětí a výkon, účinnost a fill faktor.

2.3 LBIC

Metoda Light Beam Induce Current je laboratorní optická diagnostická metoda, která umožňuje vizuální zobrazení rozložení fotoproudu v článku. Během této metody se nad článkem krokově pohybuje laserový zdroj světla, který postupně osvětluje jednotlivé body článku. Tímto postupem získáváme plošnou charakteristiku rozložení proudu – proudovou mapu. Proudovou mapu následně používáme k určení lokálních defektů článků. Vzhledem k podstatě metody je tato časově náročná.

2.4 Elektroluminiscence

Optická diagnostická metoda, která podobně jako LBIC slouží k vizualizaci defektů, jde na to však z opačné strany. Články nejsou ozařovány laserem, ale jsou připojeny na zdroj elektrického proudu v propustném směru. Proud procházející přechody PN vyvolává zářivou rekombinaci


křemíku, vyzářené fotony jsou poté zachyceny CCD kamerou a převedeny do výsledného obrazu ve stupních šedi.

2.5 Další metody

- LBIV (Light Beam Induced Voltage) – podobné LBIC, optická, laboratorní metoda,
- EBIC (Electron Beam Induced Current) - optická, laboratorní metoda,
- Rychlého rastrování - optická, laboratorní metoda,
- Mikroplasma - optická, laboratorní metoda,
- Měření FV v klimatické komoře,
- diagnostika pomocí termovizní kamery – optická venkovní metoda.

3 DIAGNOSTIKA POMOCÍ TERMORIZNÍ KAMERY

Měření termovizní kamerou patří mezi optické diagnostické metody, výhodou je, že je lze provádět venku na instalovaných panelech. Jedná se o bezkontaktní měření teploty založené na principech infračervené termografie. Každé těleso, jehož termodynamická teplota je vyšší, než 0 K, vyzařuje radiaci tepelnou energií v podobě elektromagnetických vln do okolí. Tyto vlny se svou vlnovou délkou 760 nm až 1 mm nespádají do viditelného spektra záření nýbrž do infračervené oblasti záření. Infračervená termografie poté toto záření detekuje a převádí je na teplotu. Výstupem tohoto měření je infračervený snímek neboli *termogram*.

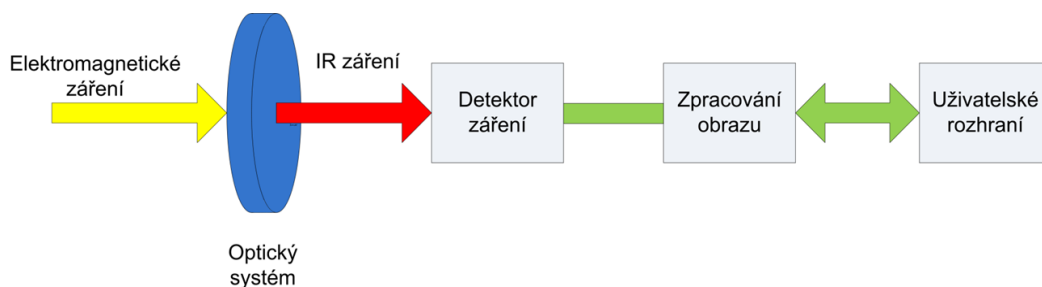


Obr. 3.1 Termogram FV panelu

Z termogramu je díky barevnému odlišení teplot možné udělat si hned napoprvé představu o rozložení teplot měřeného objektu, odhalit horká místa a pomocí softwaru je možné určit i teplotu jednotlivých bodů snímku.

3.1 Složení termokamery

Termokamera se typicky skládá z optiky, detektoru, zpracovávací elektroniky, softwaru pro zpracování dat, displeje, prostoru pro ukládání dat a ovládacích prvků.



Obr. 3.2 Blokové schéma termokamery [1]

3.1.1 Optika



Optika termokamery slouží k soustředění dopadajícího infračerveného záření na detektor. Pro jejich výrobu se nejčastěji používá germania. Pro viditelné světlo jsou čočky obecně neprůhledné. Čočky jsou pro zlepšení přenosu záření potaženy tenkou antireflexní vrstvou, aby bylo zabráněno nežádoucí odrazům infračerveného záření od povrchu čočky.

3.1.2 Detektor

V termokamerách lze v zásadě použít dva základní typy detektorů: fotonové a tepelné.

Fotonové detektory pracují na principu počítání kvant energie dopadajících fotonů elektromagnetického záření. Výhodou je velmi vysoká citlivost, která je však vykoupená nutností chladič detektor, což ústí ve složitější manipulaci s termokamerou a hlavně také vyšší cenu. Z těchto důvodů jsou termokamery s fotonovými detektory používány hlavně v laboratořích.

Tepelné detektory jsou oproti fotonovým v termokamerách hojně rozšířené. Nejčastěji se jako detektor používá mikrobolometr, přesněji 2D pole mikrobolometrů. Mikrobolometr funguje na principu, že mění svoji teplotu v závislosti na intenzitě dopadajícího záření a při tom se mění jeho elektrický odpor. Jako materiál na výrobu se používá monolitický křemíkový substrát umístěný v evakuovaném pouzdře.



Obr. 3.3 Schéma mikrobolometru, mikrobolometrové 2D pole [2]

3.1.3 Zpracovávací elektronika

Změna odporu mikrobolometru je dalšími obvody převedena na elektrický signál, který je dále zpracováván pomocí softwaru termokamery a dále zobrazen na displeji. Mimo tohoto převáděcího obvodu obsahují termokamery také obvody pro automatickou kalibraci kamery, korekce obrazu, apod. .

3.2 Základní parametry termokamery [3]

3.2.1 Teplotní rozsah

Rozsah termokamer se obecně pohybuje od $-40\text{ }^{\circ}\text{C}$ do cca $3\ 500\text{ }^{\circ}\text{C}$. Tento široký rozsah vcelku však kamery měří jenom výjimečně, obvykle je tento rozsah rozdělen na několik podrozsahů, mezi kterými je možné přepínat.

3.2.2 Spektrální rozsah

Spektrální rozsah udává vlnové délky, na které je kamera citlivá. Termokamery, které využívají tepelného detektoru, mají v naprosté většině případů spektrální rozsah $8\ \mu\text{m}$ až $14\ \mu\text{m}$, což se shoduje s propustností germaniové optiky. U termokamer s fotonovými detektory lze měřit širší pásma vlnových délek.

3.2.3 Přesnost měření

V současné době je obvyklá přesnost termokamer $\pm 2\text{ }^{\circ}\text{C}$ nebo $\pm 2\%$ z naměřené hodnoty, přičemž platí, že se v úvahu bere vyšší hodnota z těchto dvou. Laboratorní kamery se s přesností dostávají až k hodnotám $\pm 1\text{ }^{\circ}\text{C}$ nebo $\pm 1\%$ z naměřené hodnoty [4].

3.2.4 Teplotní citlivost

Noise equivalent temperature difference (NETD) neboli teplotní citlivost udává nejmenší rozdíl teplot, který vyvolá signál větší, než je vlastní šum systému. NETD se udává v milikelvinech většinou při teplotě $30\text{ }^{\circ}\text{C}$, u kamer se běžně pohybuje od 150 mK do 15 mK u laboratorních modelů.

3.2.5 Rozlišení detektoru

Obrazové body. Pohybuje se od $60\text{ x }60$ do $1\ 240\text{ x }768$ pixelů a údaj také znamená, jak velké je 2D pole z mikrobolometrů.

3.2.6 Field of View

FOV neboli zorný úhel úzce souvisí s rozlišením detektoru. Čím větší je úhel zorného pole, tím větší část prostoru je promítnuta na detektor a tím, zjednodušeně řečeno, menší detaily jsou detektorem zachyceny.

3.3 Podmínky měření FV panelů termokamerou

Nejpříhodnější podmínky pro detekci tohoto typu problému jsou v době, kdy má panel největší výkon, standardně uprostřed jasného dne. Za těchto podmínek je možné detekovat články s teplotami dosahujícími až 111°C [5]. K dosažení lepšího kontrastu snímku je vhodné, aby teplota okolí byla nízká. V ideálním případě by také mělo být bezvětrí, aby nedocházelo k nerovnoměrnému ochlazování panelů. Intenzita záření tepelného toku musí být dostatečně velká, minimální doporučená hodnota je 500 W/m².

Fotovoltaické panely je možné pomocí termokamery kontrolovat z přední nebo zadní strany. Při měření z přední strany dochází k odrazu tepelného toku emitovaného okolními objekty, abychom tomuto předcházeli, tak je vhodné měřit pod úhlem 5 až 60 ° [6]. Druhý způsob kontroly, tedy ze zadní strany panelů je zvláště výhodný, protože se vyhneme problémům s odrazem slunečního záření nebo odrazem kvůli emisivitě (intenzitě vyzařování) spojené s krystalickým povrchem panelů.

3.4 Fyzikální podstata termovizního měření

Abychom mohli adekvátně vyhodnocovat snímky pořízené termovizní kamerou, je vhodné se orientovat v několika fyzikálních zákonech. Mezi základní zákony, o které se opírá termovizní měření, patří:

- Planckův vyzařovací zákon,
- Wienův zákon,
- Stefan-Boltzmannův zákon,
- 1. Kirchhoffův zákon,
- 2. Kirchhoffův zákon.

3.4.1 Planckův vyzařovací zákon

Planckův zákon nám říká, že elektromagnetické záření o frekvenci f může být vyzařováno, nebo pohlcováno pouze po kvantech energie E o velikosti

$$E = h \cdot f \quad , \quad (3.1)$$

kde h je Planckova konstanta. Pro dokonale černé těleso, které vyzařuje kvanta energie ve vakuu, potom můžeme odvodit vztah pro jeho spektrální hustotu zářivého toku $E_{0\lambda}$

$$E_{0\lambda} = \frac{d E_0}{d\lambda} = \frac{2\pi c^2 h}{\lambda^5 \left(e^{\frac{c \cdot h}{kT\lambda}} - 1 \right)} \quad . \quad (3.2)$$

Na vztahu (3.2) vidíme, že spektrální hustota zářivého toku absolutně černého tělesa závisí na jeho termodynamické teplotě T a vlnové délce vyzařovaného elektromagnetického záření λ .

Dále se ve vztahu (3.2) vyskytují symboly rychlosti světla c , Planckovy konstanty h a Boltzmannovy konstanty k .


Vztah (3.2) se v literatuře někdy udává s použitím konstant c_1 a c_2 viz. (3.5)

$$c_1 = 2\pi c^2 h \quad , \quad (3.3)$$

$$c_2 = \frac{c \cdot h}{k} \quad , \quad (3.4)$$

$$E_{0\lambda} = \frac{c_1}{\lambda^5 \left(e^{\frac{c_2}{T\lambda}} - 1 \right)} \quad , \quad (3.5)$$

Matematickou formulaci vztahu (3.2) lze vyjádřit graficky (Obr. 3.4).



Obr. 3.4 Planckův vyzařovací zákon [7]


Na obrázku (Obr. 3.4) vidíme jednak grafický průběh vztahu (3.2), ale hlavně také to, že se zvětšující se termodynamickou teplotou zdroje zvyšuje jeho spektrální hustota zářivého toku a dále je také patrné, že zvětšující se teplota posouvá maximální hodnotu spektrální hustoty zářivého toku směrem ke kratším vlnovým délkám.

3.4.2 Wiennův zákon

Na obrázku (Obr. 3.1) je vidět, že se zvětšující se teplotou zářiče se posouvá maximum průběhu spektrální hustoty zářivého toku směrem ke kratším vlnovým délkám. Tento jev nazýváme Wiennův posunovací zákon. Pokud zderivujeme podle vlnové délky a položíme nule Planckův vyzařovací zákon, získáme matematické vyjádření Wienova posunovacího zákona:

$$\lambda_{max} = \frac{b}{T} \quad , \quad (3.6)$$

kde b je Wienova konstanta ($b = 2,898 \cdot 10^{-3}$ m.K). Graficky je Wiennův posunovací zákon zobrazen na následujícím obrázku (Obr. 3.5).



Obr. 3.5 Wienův posunovací zákon [7]

3.4.3 Stefan-Boltzmannův zákon

Pokud za konstantní teploty integrujeme spektrální hustotu zářivého toku absolutně černého tělesa přes celý rozsah vlnových délek, tak získáme Stefan-Boltzmannův zákon, který říká, že všechna tělesa, která vyzařují s nenulovou teplotou, mají hustotu zářivého toku úměrnou čtvrté mocnině absolutní teploty.


$$E_0 = \sigma_0 T^4 \quad , \quad (3.7)$$

kde σ je Stefan-Boltzmannova konstanta ($\sigma_0 = 5,6697 \cdot 10^{-8} \text{ W} \cdot \text{m}^{-2} \cdot \text{K}^{-4}$).

Vztah (3.7) platí pro absolutně černá tělesa, abychom mohli tento vztah aplikovat v reálných podmínkách, tak jej rozšíříme o parametr ε , který bude kvantitativně určovat schopnost daného tělesa vyzařovat teplo. Parametr ε se nazývá emisivita povrchu, s jejím použitím můžeme Stefan-Boltzmannův zákon používat i pro šedá tělesa.

$$E_0 = \varepsilon \sigma_0 T^4 \quad , \quad (3.8)$$

Pro úplnost dodejme, že emisivita povrchu je bezrozměrná veličina, pro absolutně černé těleso nabývá hodnoty 1 a pro reálná tělesa nabývá hodnot menších než 1 až do 0. Emisivita pro daný povrch není konstantní, nýbrž je závislá např.: na struktuře a barvě povrchu, teplotě povrchu, vyzařovaná vlnové délce, nebo úhlu naklonění povrchu.



Obr. 3.6 Stefan-Boltzmannův zákon [7]

3.4.4 První Kirchhoffův zákon

Tento zákon řeší energetickou bilanci dopadajícího záření, můžeme v něm vidět analogii se zákonem o elektrickém proudu do uzlu. V oblasti elektromagnetického záření nám 1. Kirchhoffův zákon říká, že energie dopadající na dané těleso se může buďto odrazit, projít nebo absorbovat.


$$E = E_r + E_t + E_a \quad , \quad (3.9)$$

Pokud celou rovnici (3.9) vydělíme dopadající energií získáme

$$1 = r + t + a \quad , \quad (3.10)$$

kde r je reflektance, t je transmitance, a je absorptance a tyto 3 parametry popisují vlastnosti povrchů, u kterých můžeme rozlišit některé extrémní případy, které se však v praxi nevyskytují.

- $r = 1$, potom je těleso dokonale bílé, tedy všechnu dopadající energii odrazí,
- $t = 1$, potom je těleso dokonale transparentní, tedy všechnu energii propustí,
- $a = 1$, potom je těleso dokonale černá, tedy všechnu energii pohltí.




Obr. 3.7 První Kirchhoffův zákon [7]

3.4.5 Druhý Kirchhoffův zákon

Tento zákon nám říká, že těleso je pouze tak dobrým zářičem, jak dokáže energii absorbovat.

$$\epsilon = a \quad (3.11)$$

4 DEFEKTY FV PANELŮ



Obr. 4.1 FV panel s hot spotem [8]

Termokamerou odhalíme defekty, které se projevují zvýšením teploty. Na obrázku (Obr. 4.1) je vidět defekt článku, který se zobrazuje jako teplé místo (hot spot). Na FV panelu rozlišujeme několik zdrojů oteplení:


- Oteplení od pohlceného slunečního záření,
- Oteplení od přechodového odporu kontaktů,
- Oteplení od zastíněných článků,
- Oteplení od ostatních zdrojů (odrazy mraků, budov, komínů, apod...).

4.1 Vliv nedostatečné výroby energie způsobené vadou nebo zastíněním článků

4.1.1 Fotovoltaický jev

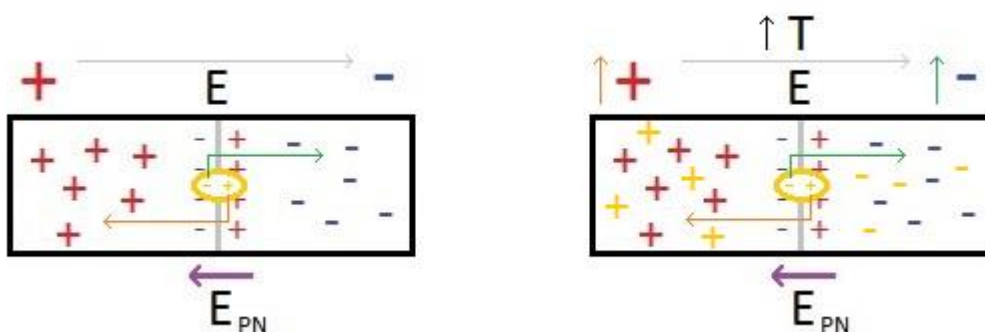
Přechod PN je tvořen nepohyblivými kladnými ionty v oblasti N a nepohyblivými zápornými ionty v oblasti P, které vznikly vlivem difúze volných elektronů respektive děr z oblasti blízké přechodu PN hned po spojení polovodičů typu P a N. Tato oblast se také nazývá vyprázdňená a z její podstaty zde na krátkou vzdálenost působí velké elektrostatické síly, které tvoří potenciálovou bariéru pro pronikání volných elektronů z oblasti N do oblasti P a volných děr z oblasti P do oblasti N (Obr. 4.2).

$$E_{pn} > E \quad (4.1)$$




Obr. 4.2 Neozářený přechod PN (vlevo), ozářený přechod PN (vpravo)

Pokud foton dopadne v blízkosti přechodu PN a má dostatečnou energii, aby vygeneroval pár elektron-díra. Tak je tento pár odseparován vlivem silného elektrostatického pole v oblasti přechodu PN a to tak, že elektron je silně odpuzován od záporně nabitých iontů přechodu PN a tedy se přemísťuje do záporně nabitě oblasti N, jejíž odpuzivé síly jsou menší. Koncentrace volných elektronů v oblasti roste. Podobně jsou separované i díry. Generované díry jsou silně odpuzovány kladně nabitými ionty přechodu PN a přemísťují se do kladně nabitě oblasti P, ve které je však vlivem volných děr a větších vzdáleností odpuzivá síla menší [9]. Koncentrace volných děr v oblasti P roste. Růst koncentrací volných vodičů se navenek projevuje zvyšováním teploty polovodičů vlivem většího počtu srážek volných nosičů s krystalovou mřížkou (Obr. 4.3).



Obr. 4.3 Separace páru elektron-díra vlivem silného elektrického pole v oblasti přechodu PN (vlevo), růst koncentrace volných nosičů náboje v článku a teploty článku (vpravo)


Připojením elektrod FV článku na spotřebič začne spotřebičem protékat proud I , způsobený přemísťováním nahromaděných volných nosičů náboje do oblasti s opačnou polaritou. Tím, že mohou volné nosiče odcházet z dané přeplněné oblasti, tak v oblasti klesá počet srážek volných nosičů s krystalickou mřížkou a teplota oblasti klesá. Pokud tedy článek připojíme na zátěž, tak je ochlazován průchozím proudem (Obr. 4.4).



Obr. 4.4 Připojení článku na zátěž, pokles koncentrace volných nosičů náboje, pokles teploty článku

4.1.2 Příčiny oteplování článků

Proud článku je přímo úměrný intenzitě slunečního záření. Články jsou spojené v sérii, jejich napětí se tedy sčítá, přičemž proud zůstává stejný. Pokud je z některých článků vadný, zastíněný nebo poškozený, tak na něm dojde k obrácení polaritě napětí. Z článku s obrácenou polaritou napětí se stává spotřebič energie, což způsobí, že proud ostatních článků v sérii teče do článku s obrácenou polaritou a způsobuje jeho ohřev. Jeden nevyrábějící článek tedy způsobuje nefunkčnost celého panelu, mimoto dochází k extrémnímu oteplení nevyrábějícího článku, které může vést až k jeho roztavení, navazujícím efektem je, že jsou také ohřívány sousední články, škody se tedy navyšují.



Obr. 4.5 Schéma zapojení s bypasseovou diodou

Předcházení výše popsaným nežádoucím jevům se realizuje pomocí tzv. bypassových diod. Série FV článků se rozdělí na části, které jsou překlenuty právě bypassovou diodou. Za nominálního provozu, kdy jsou osvětleny všechny články, je bypassová dioda připojena v závěrném směru. Přes diodu teče pouze malý závěrný proud, který však snižuje výstupní proud dodávaný panelem. Závěrný proud společně s vyšší cenou bypassových diod jsou důvody proč se bypassovou diodou překlene část panelu a nikoliv každý jednotlivý článek.


Aby bypassová dioda připojená v závěrném směru přešla do směru propustného, je třeba na ni přiložit prahové napětí asi $-0,6\text{ V}$ (dle typu diody). Toto záporné napětí se objeví, jakmile je napětí zastíněného solárního článku rovno součtu napětí nezastíněných solárních článků a napětí bypassové diody [10]. Zapojení s bypassovou diodou je na obrázku (**Chyba! Nenalezen zdroj odkazů.**).

4.2 Druhy defektů odhalitelných pomocí termovizní kamery


Pozn.: obrázky v této kapitole čerpány z [11].




Obr. 4.6 Vada hotspot




Obr. 4.7 Rozdíl teplot cca 40 °C (vlevo), rozdíl teplot cca 20 °C (vpravo)




Obr. 4.8 Vada vícenásobný hotspot (vlevo), vady hotspot snímané zezadu (vpravo)




Obr. 4.9 Vada: 1/3



Obr. 4.10 Vada: 2/3



Obr. 4.11 Vada: 3/3



Obr. 4.12 Články rozehřáté vlivem zastínění

5 POČÍTAČOVÉ VIDĚNÍ

Počítačové vidění je vědní disciplína, která se zabývá získáváním a interpretováním informací ze vstupních dat, ať už se jedná o obrázky nebo videa. Z technického hlediska stojí počítačové vidění na čtyřech pilířích (viz. Obr. 5.1) [12]:

1. Pochopení lidského vidění,
2. vědě o počítačích,
3. teorii signálů,
4. rozpoznávání.




Obr. 5.1 Čtyři pilíře počítačového vidění [12]

S aplikacemi počítačového vidění se v reálném životě setkáváme stále častěji. Sociální sítě dokáží rozpoznávat obličeje lidí na fotkách, můžeme vyhledávat obrázky, které obsahují konkrétní věci například stromy, kamerové systémy automobilů dokáží rozpoznávat značky a upozorňovat řidiče při překročení rychlosti, kamerové systémy herních konzolí umožňují ovládat hry pomocí pohybu těla. Počítačového vidění bývá využíváno v aplikacích rozšířené reality a v neposlední řadě také při vývoji robotů.

Proces počítačového vidění se snaží napodobit vidění lidské, můžeme jej rozdělit do několika navazujících kroků:

1. snímání obrazu,
2. předzpracování obrazu,
3. segmentace,
4. popis objektů,
5. klasifikace objektů.



Obr. 5.2 Blokové schéma popisující počítačové vidění

Tato práce je zaměřena na analyzování termovizních snímků. Proces získávání snímků byl popsán v kapitole 3. V této kapitole si popíšeme zbývající kroky počítačového vidění.

5.1 Předzpracování obrazu

Hlavní cíl tohoto kroku spočívá ve zvýraznění hledaných informací a v potlačení neužitečných informací, během tohoto kroku není získána žádná nová informace [13]. Pro předzpracování se využívá nadbytečnosti údajů, například sousední pixely snímku mají většinou podobnou hodnotu jasu. Nejčastější operace jsou [14]:


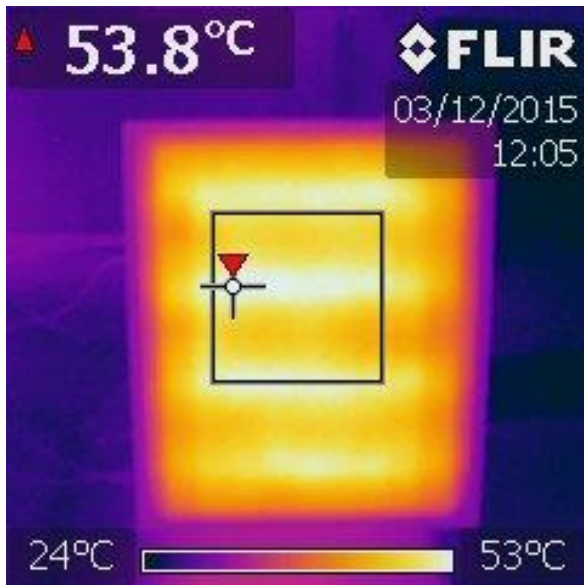
1. Potlačení šumu,
2. Odstranění zkreslení,
3. Zvýraznění příznaků.

5.2 Segmentace

Předzpracovaný obraz je potřeba segmentovat, tedy analyzovat jeho obsah a oddělit objekty, které jsou předmětem zájmu od pozadí. Tento krok je výpočetně náročný, protože obvykle zahrnuje procházení snímku pixel po pixelu a provádění výpočtů nad každým jednotlivým pixelem a pixely z jeho blízkého okolí. Od kvality segmentace obrazu se dále odvíjí úspěšnost klasifikace objektů [14]. V praxi se pro segmentaci využívají následující metody.


5.2.1 Segmentace prahováním

Segmentace prahováním zkoumá vlastnosti pixelů, jako jsou hodnoty červené, zelené a modré složky, barevný tón, sytost barvy a jas. Poté na základě hodnoty vybrané vlastnosti (vlastnosti) rozděluje pixely do tříd. V nejjednodušším případě se využívá dvou tříd, segmentovaný snímek je potom binární, tedy obsahuje pouze černou a bílou barvu, přičemž černá většinou reprezentuje pozadí, neužitečné informace a bílá zobrazuje hledané objekty jak je vidět na obrázku (Obr. 5.3).



Obr. 5.3 Snímek z laboratorního měření (vlevo), tentýž snímek binarizovaný (vpravo)

Prahovat lze snímek i do více tříd, za pomoci například filtrování složek barev. Hodnotu prahu lze v případě dobré znalosti problému zadat pevně, nebo ji určovat dynamicky například z histogramu.



Obr. 5.4 Filtrováno podle hodnoty zelené barvy. Odfiltrovány jsou pixely s hodnotou zelené barvy 0 až 135.

5.2.2 Segmentace na základě detekce hran

Hrany nalezené hranovým operátorem v kroku předzpracování obrazu jsou spojovány do řetězců, které vystihují hranice objektu.

Hranice objektu můžeme získat například sledováním osmi-okolí pixelů, na základě prohledávání grafů – množiny uzlů a spojnic mezi nimi, na základě vlastní znalosti, kdy například známe tvar hledaného objektu nebo pomocí Houghovy transformace.

5.2.3 Segmentace narůstáním oblastí


Tato metoda využívá spojování sousedních pixelů, které splňují zadané kritérium do souvislých oblastí. Jako kritéria se používají podobně jako u segmentace prahováním hodnoty zvolených obrazových vlastností pixelů RGB nebo HSV. K segmentaci narůstáním oblastí můžeme přistupovat buďto spojováním nebo štěpením oblastí, případně kombinací přístupů.

Při spojování rozdělíme obraz nejlépe do jednotlivých pixelů, které následně na základě kritéria spojujeme do oblastí. Při štěpení začínáme naopak od jediné oblasti – celého obrazu – a oblast dělíme na podoblasti, dokud není splněno kritérium. Oba dva přístupy mohou na stejném snímku podávat různé výsledky.

5.2.4 Segmentace srovnáním se vzorem

V některých případech je vhodné snímek nechat projet tzv. pohyblivým oknem a oblast pohyblivého okna porovnávat se vzory. Pohyblivé okno je matice o zvolených rozměrech x a y , kdy jsou na její jednotlivé pozice nahrávány hodnoty na základě relativní polohy vůči zkoumanému pixelu.

Takto vzniklé výřezy jsou porovnávány s uloženými vzory a v případě shody jsou vyznačovány nalezené oblasti (viz. Obr. 5.5).



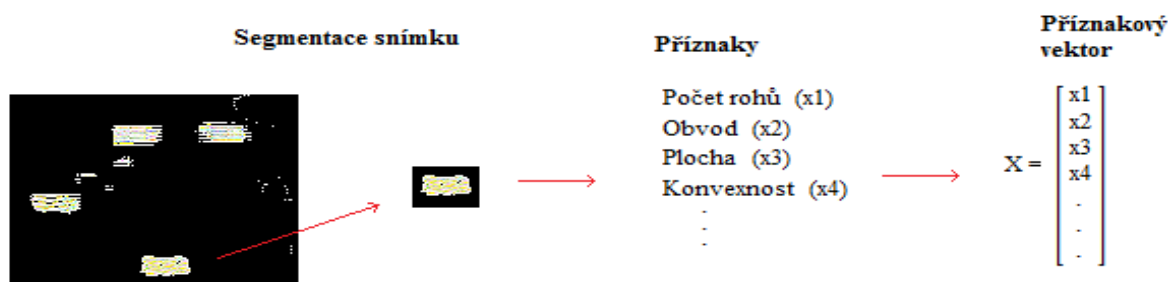
Obr. 5.5 Ilustrace zkoumání snímku pomocí pohyblivého okna

5.3 Popis objektů

Aby bylo možné objekty vzniklé segmentací obrazu vůbec nějak klasifikovat, je třeba popsat jejich charakteristické rysy pomocí příznakového vektoru. Příznakový vektor je množina číselných hodnot, která popisuje objekt tak, aby byl rozeznatelný od ostatních objektů. Proces sestavování příznakových vektorů je vyobrazen na obrázku (Obr. 5.6). Mezi základní požadavky na příznaky patří [14], [15], [16]:

1. Zachycuje nezbytnou informaci – kupříkladu počet rohů, zdali se analyzovaný objekt podobá spíše kruhu nebo čtyřúhelníku, nebo například podlouhlost respektive čtveratost objektu.
2. Efektivita výpočtu – protože výpočty nad všemi pixely obrázku mohou být časově náročné, tak je pro kvalitní příznak důležité, aby byl snadno a rychle vypočítatelný.
3. Invariantnost na změně jasu, kontrastu, translaci, rotaci a změně měřítka – jedna z nejdůležitějších vlastností kvalitního příznaku. Pokud je invariantnost splněna, tak velice zpřesňuje klasifikační proces.
4. Spolehlivost příznaku – malé změny tvaru objektu způsobené například deformací, nebo šumem obecně neznamenají, že se jedná o jiný objekt. Například lidský mozek dokáže rozeznat lidskou postavu i na fotce s horším rozlišením. Cílem je tedy vytvořit takový příznak, který vykazuje podobné hodnoty i pokud je daný objekt kreslen drobným šumem.
5. Diskriminabilita – ačkoliv bylo v předchozím požadavku deklarovali, že od příznaku požadujeme spolehlivost, tak samozřejmě existují limity. Příznak by měl být dostatečně citlivý na změny ve tvarech objektů. Při stejné ploše a obvodu dvou objektů se může jednat o velice rozdílné objekty.

Z výše uvedených požadavků je patrné, že v některých případech jdou požadavky proti sobě.



Obr. 5.6 Sestavování příznakového vektoru

Příznaky můžeme dělit podle domény popisované vlastnosti, podle oblasti výpočtu nebo podle oblasti popisu [14]:

Dělení dle domény popisované vlastnosti.

- i. Fotometrické – vychází z optických vlastností objektu. Může se jednat například a minimální, maximální hodnotu jasu, její rozptyl a průměr. Případně se může jednat o diferenci mezi průměrnou hodnotou jasu uvnitř zkoumaného objektu a průměrnou hodnotou jasu v jeho nejbližším okolí.
- ii. Radiometrické – vychází z geometrických vlastností objektu, ať už se jedná o šířku, výšku objektu, plochu, obvod, apod.

Dělení dle oblasti výpočtu.

- i. Regionální – na základě hodnot jasu rozděluje objekt do podoblastí.
- ii. Hraniční – příznaky vycházející s jednotlivých pixelů tvořících hranici objektu

Dělení podle oblasti popisu.

- i. Globální deskriptory obrazu - lineární integrální transformace (FT, DCT, Wavelet), nevýhodou je nepřítomnost individuálních znaků objektů.
- ii. Globální deskriptory objektu - jeden příznak je přiřazen celému objektu, jedná se o jednoduché deskriptory jako například: velikost, podlouhlost, konvexnost.
- iii. Lokální deskriptory objektu – příznak je vypočítán pouze z části objektu.


5.4 Klasifikace objektů - neuronové sítě

Závěrečným krokem počítačového vidění je klasifikování objektu. Klasifikování můžeme provádět například pomocí jednoduchých podmínek typu: je-li průměrná hodnota barvy objekty x , tak se jedná o objekt kategorie y . Podmínky lze přidávat, vnořovat a vytvářet tak složité rozhodovací stromy. Výsledné stromy jsou však většinou nepřehledné a odhalování chyb značně náročné. Dalším řešením klasifikace objektů může být použití neuronových sítí.

Neuronová síť je algoritmus, který se snaží napodobit fungování lidského mozku. Dnešní algoritmy musejí řešit rozličné problémy, ať se jedná o obecné úlohy nebo komplexní problémy. Vytvořit algoritmus, který by dokázal pokrýt veškeré aspekty řešeného problému a zároveň dokázal podat výsledek v přijatelném čase je velmi náročné. V některých případech však lze využít neuronových sítí [17].

5.4.1 Analogie umělý a biologický neuron

Základním elementem neuronové sítě je umělý neuron, který vychází z biologického neuronu. Vstupy umělého neuronu odpovídají dendritům biologického neuronu, váhy reprezentují synapse respektive váhu synapsí. Přenosová funkce neuronu umělého je v jeho biologické předloze realizována tělem neuronu a výstupní informace axonem. Analogie mezi umělým a biologickým neuronem je na následujícím obrázku (Obr. 5.7).



Obr. 5.7 Ilustrace analogie mezi biologickým a umělým neuronem [18]

Pokud si zjednodušeně popíšeme proces učení, tak v mozku se jedná o to, že jsou posilovány určité synapse, tedy jejich synaptická váha se zvyšuje. Obdobně je tomu i u umělé neuronové sítě,

jejím učením se upravuje hodnota určitých vah tak, aby se hodnota na výstupu neuronové sítě rovnala požadované hodnotě.

5.4.2 Dělení neuronových sítí

Neuronové sítě můžeme dělit z pohledu učení, případně topologie [19][18].

Podle způsobu učení:

- s učitelem – síť je předkládána tréninková množina, tedy soubor vstupů a ke každému vstupu taky požadovaný výstup (perceptronová síť),
- bez učitele – síť není předkládána tréninková množina, musí data třídit sama podle jejich vlastností (Hopfieldova, Kohonenova síť).

Podle stylu učení:

- deterministické učení,
- stochastické učení.

Podle topologie:

- síť s jednou vrstvou,
- síť s více vrstvami.

5.4.3 Zpětné šíření chyby (Backpropagation)

Zjednodušeně je backpropagation algoritmus učení, při kterém je výstup sítě porovnáván s požadovaným výstupem a je spočítána jejich odchylka. Pokud je odchylka vyšší než požadovaná, tak jsou zpětně upraveny hodnoty všech vah a je spuštěno další kolo učení. Tento algoritmus probíhá tak dlouho, dokud síť nedosáhne požadované hodnoty na výstupu se zadanou přesností.

PRAKTICKÁ ČÁST

6 ANALÝZA PROBLÉMU


V rámci praktické části byl na základě teoretických základů uvedených v předchozích kapitolách naprogramován program, jehož cílem je automatická detekce defektních článků na termovizních snímcích FV panelů. Jako programovací jazyk byl použit vysokoúrovňový objektově orientovaný programovací jazyk C# společně s .NET frameworkem [20] a vývoj probíhal v IDE Visual Studio 2016. Dále byl při vývoji použit Framework AForge.NET [21], který obsahuje dostatečné nástroje pro filtrování snímků a neuronové sítě.

Zkoumaná data pochází z termovizních video záznamů z měření prováděného firmou EICERO (viz. příloha CD 1). Z videa byly vytvořeny snímky, na kterých byly zachyceny defekty a artefakty. V první fázi bylo potřebné oddělit všechny podezřelé objekty od pozadí a následně nalezené objekty klasifikovat.

Problém detekce obecného defektu nebo vady na termovizním snímku je složitá záležitost hlavně z důvodu možných tvarů defektů jak je vidět na obrázku (Obr. 6.1). Protože je pro detekci nezbytné matematicky popsat nalezený tvar pomocí příznaků byly defekty a artefakty pracovními rozděleny do čtyřech skupin.

- a. D1 defekty – jeden samostatný vadný článek,
- b. Dn defekty – n-násobné defektní články spojené do souvislého nebo nesouvislého pole
- c. Dj defekty – jiné defekty, často vady vztahující se k celému FV panelu, avšak ne nutně defektu, tento druh defektů může být obtížné určit i pro lidského operátora.
- d. A – artefakty, například rozehřáté konstrukce, odrazy oblohy, země, střech a dalších objektů, artefakty vzniklé digitalizací obrazu.

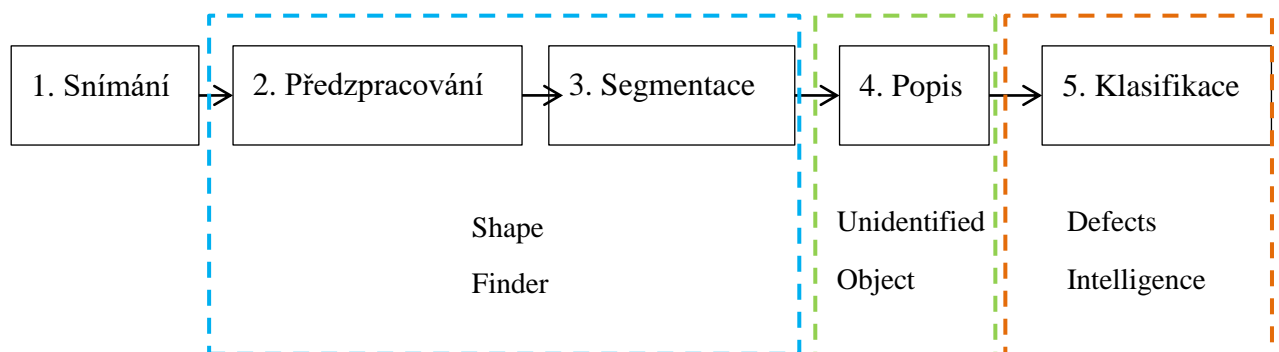
Pro každou z těchto skupin je třeba zvolit jiný příznakový vektor. Zmíněná složitost detekce všech možných naznačených druhů defektů vedla k rozhodnutí zaměřit program na jednu oblast „D1“ a dosáhnout co nejlepších výsledků u této kategorie defektů. Možnosti detekce ostatních druhů defektů budou diskutovány v závěru práce.



Obr. 6.1 Demonstrace zvolených skupin, písmeno a označuje D1 defekty - samostatný rozehrátý článek, písmeno b označuje násobné spojené defektní články, písmenem c je označena rozehrátá přechodová krabice, která prosvítá ze zadní strany, písmeno d označuje artefakty na obrázku – rozehrátou konstrukci, vadu digitalizace. Snímek byl poskytnut firmou EICERO.

6.1 Architektura programu

Architektura programu vychází z teorie o počítačovém vidění (kapitola 5) a obrázku (Obr. 5.2). Pokrývá krok 2 až 5. Každý jednotlivý snímek je reprezentován třídou *LoadedImage*, která zajišťuje i logiku zobrazování výsledků uživateli programu. Předzpracování a segmentace snímku probíhá v rámci třídy *ShapeFinder*. Popis každého segmentovaného objektu probíhá v rámci třídy *UnidentifiedObject*. A konečně o klasifikaci objektů se stará třída *DefectsIntelligence*, která v sobě zahrnuje u metody zahrnující učení neuronové sítě, její uložení do externího xml souboru a opětovné načtení.



Obr. 6.2 Rozdělení kroků počítačového vidění dle jednotlivých tříd

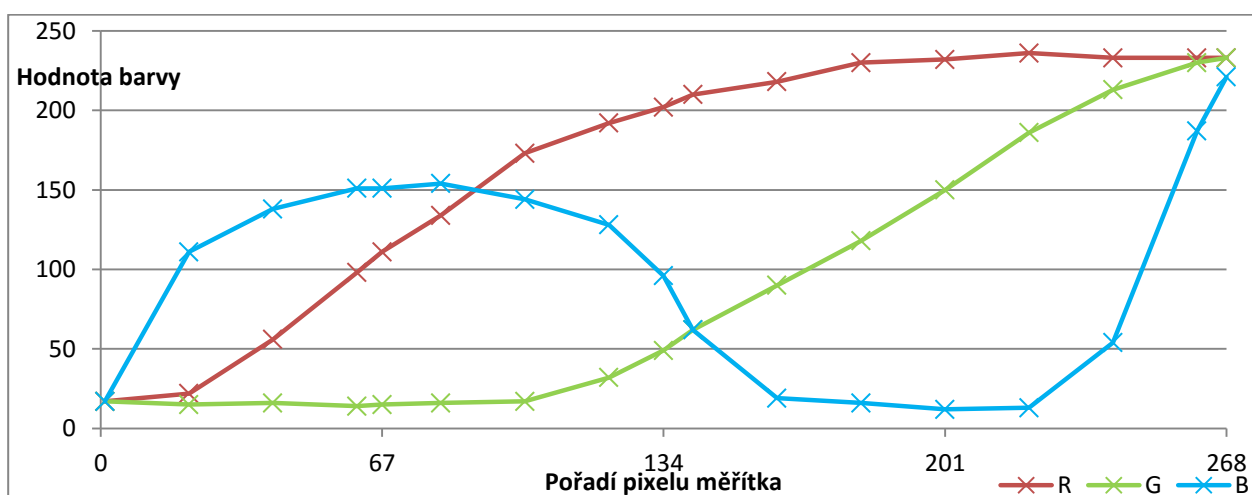
Jak již bylo naznačeno v předchozím odstavci, tak lze vytvářet a ukládat neuronové sítě dle potřeby, čili byly položeny základy pro budoucí možný rozšíření programu o detekci ostatních diskutovaných skupin defektů.

Mimo zmíněné třídy byly vytvořeny podpůrné třídy a to třída *XmlManager*, umožňující ukládání příznakových vektorů do xml souborů a jejich následné načtení pro učení neuronových sítí a dále třída *Line*, pomocí které jsou matematicky popsány hrany segmentovaných objektů.

6.2 Popis jednotlivých částí programu


6.2.1 Předzpracování – třída ShapeFinder

Předzpracování je prováděno pomocí filtrů z knihovny AForge.NET [21]. Po několika experimentech byl sestaven následující filtrovací postup. Protože konzultací s pracovníkem firmy EICERO bylo zjištěno, že nejčastěji se při termovizním snímkování FV panelů používá barevná paleta *Iron*, což ostatně demonstrují i poskytnuté snímky, tak bylo nejprve zkoumáno použité barevné měřítko právě této barevné škály. Vývoj hodnot jednotlivých barev je demonstrován na obrázku (Obr. 6.3), z něj je patrné, že hodnota zelené barvy je po délce měřítka rostoucí. Tedy čím je daný bod teplejší, tím má vyšší hodnotu zelené barvy.



Obr. 6.3 Vývoj hodnot barev měřítka Iron

Na základě tohoto zjištění bylo rozhodnuto, že se u každého snímku použije histogram pro zelenou barvu, nalezne se medián její hodnoty a provede se odfiltrování pixelů s hodnotou zelené barvy pod mediánem. Následně je takto filtrovaný snímek zaostřen a filtrován podle svítivosti jednotlivých pixelů. Mimoto, je ještě od snímku oříznuté samotné barevné měřítko. Postup je znázorněn na obrázku (Obr. 6.4) a ve vyšším rozlišení v příloze 1.



Obr. 6.4 Postup filtrování snímku. 1. Originální snímek. 2. Odfiltrované pixely s hodnotou zelené barvy nižší než je její medián. 3. Zaostření vyfiltrovaného snímku. 4. Vybrání pixelů s nejvyšší hodnotou svítivosti.

6.2.2 Segmentace – třída ShapeFinder

Na filtrovaný snímek je použita metoda *ProcessImage*, která zabezpečí nalezení všech BLOBů na snímku, což jsou v praxi všechny možné artefakty nebo defekty na snímku. Každý BLOB slouží k vytvoření objektu *UnidentifiedObject*.

6.2.3 Popis – třída UnidentifiedObject

Každý nalezený tvar na snímku je širě popsán pomocí třídy *UnidentifiedObject*, která pro popis využívá jednak vlastností BLOBů a jednak tento výčet doplňuje o nově vymyšlené vlastnosti. V teorii počítačového vidění jsou vlastnosti tohoto objektu reprezentovány příznaky. Tato třída disponuje i metodami umožňujícími generování příznakových vektorů. Sestavení vhodného příznakového vektoru bylo předmětem dalších zkoušek. Dále bylo vytvořeno několik příznaků:

- *cornersCount* – počet rohů objektu,
- *rectSquarelikeness* – určuje, na kolik se čtyřúhelníkový obal nalezeného objektu podobá čtverci.
- *blobSquarelikeness* - určuje, na kolik se samotný nalezený objekt podobá čtverci.
- *AtoO* – poměr plochy ku obvodu nalezeného objektu.
- *compactness* – kompaktnost objektu.
- *convexity* – konvexnost obalu objektu.
- *fullness* – plnost objektu.
- *piCoef* – podíl plochy objektu a druhé mocniny vzdálenosti nejvzdálenějšího bodu od jeho středu.
- *furthestNearestPointRatio* – podíl vzdálenosti od středu nejvzdálenějšího a nejbližšího bodu.
- *blobRoundLikeness* – určuje, na kolik se nalezený objekt podobá kružnici jemu opsané.
- *horizontalParallelism* / *verticalParallelism* – tyto ukazatele určují, na kolik jsou protější přímky prokládající hrany čtyřúhelníku rovnoběžné.
- *lineTop(/Bottom/Left/Right)* – prokládá hrany nalezeného čtyřúhelníku pomocí přímky, každá přímka je reprezentována směrnici a posunem vůči počátečním souřadnicím, součástí jsou tedy 2 prvky.

- *min/max/avg Deviation* – minimální, maximální a průměrná hodnota odchylky bodu od přímky proložené hranou. Počítá se pro všechny hrany objektu.
- *normalizedEdgeHistogramTop(/Bottom/Left/Right)* – reprezentuje histogram četností změn osmisměru v rámci dané hrany tvaru normalizován na délku dané hrany. Jedná se vektory o osmi prvcích.

Z těchto jednotlivých příznaků bylo vytvořeno celkem 5 příznakových vektorů. Výsledky zabývající se hledáním nejvhodnějšího příznakového vektoru jsou v kapitole 7.

6.2.4 Popis – třída XmlManager

Slouží k ukládání a načítání tréninkových dat. Data jsou ukládány do souboru ve formátu .xml ve tvaru:

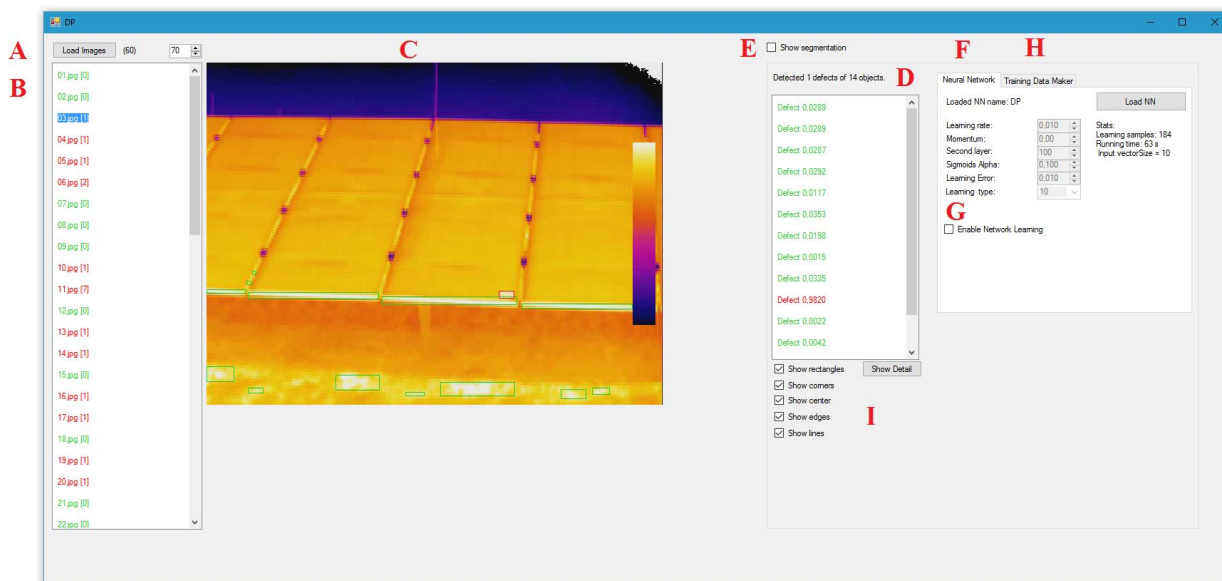
<pre> <object> <is_defect> ... </is_defect> <input7> ... </input7> <input35> ... </input35> <input22> ... </input22> <input10> ... </input10> <input56> ... </input56> </object> </pre>	<p>Zda se jedná o defekt nebo artefakt</p> <p>Příznakové vektory o 7, 35, 22, 10 a 56 prvcích.</p>
---	--

Obr. 6.5 Ukázka ukládání tréninkových dat

6.3 Popis – třída DefectsIntelligence

Srdcem této třídy je vícevrstvá neuronová síť, jedná se o síť učenou učitelem pomocí algoritmu *backpropagation*. Třída dále zabezpečuje její ukládání a načítání již vytvořené. Mimo to zabezpečuje učení nové sítě. Učení probíhá v samostatném vlákně.

6.4 Popis uživatelského rozhraní



Obr. 6.6 Ukázka uživatelského rozhraní programu

A: Načítání složek s obrázky

Kliknutím bude nabídnuto okno pro výběr složky s obrázky. Pokud jsou ve složce další soubory jiného formátu nebo podsložky, tak nebudou načteny.

B: Seznam načtených snímků

Zobrazuje seznam načtených obrázků. U jednotlivých položek seznamu je použito barevné kódování. V případě, že není načtena žádná neuronová síť, tak jsou položky vypsány černě, pokud je neuronová síť načtena, tak zelenou barvou jsou označeny položky, na kterých neuronová síť nenalezla žádné defekty, červeně jsou vypsány položky, na kterých neuronová síť našla defekt. Položka je vypsána ve tvaru „název položky“ a v hranaté závorce je uveden počet nalezených defektů. Klikem na položku se tato zobrazí v prohlížeči snímků a nalezené objekty jsou vypsány do seznamu objektů.

C: Prohlížeč snímků

V této oblasti jsou zobrazeny snímky vybrané poklikem ze seznamu snímků. Na snímku jsou barevným obdélníkem zobrazeny nalezené objekty. Barevná konvence zůstává stejná. Pokud je neuronová síť načtena, tak zelenou barvou jsou označeny defekty, červeně jsou označeny artefakty.

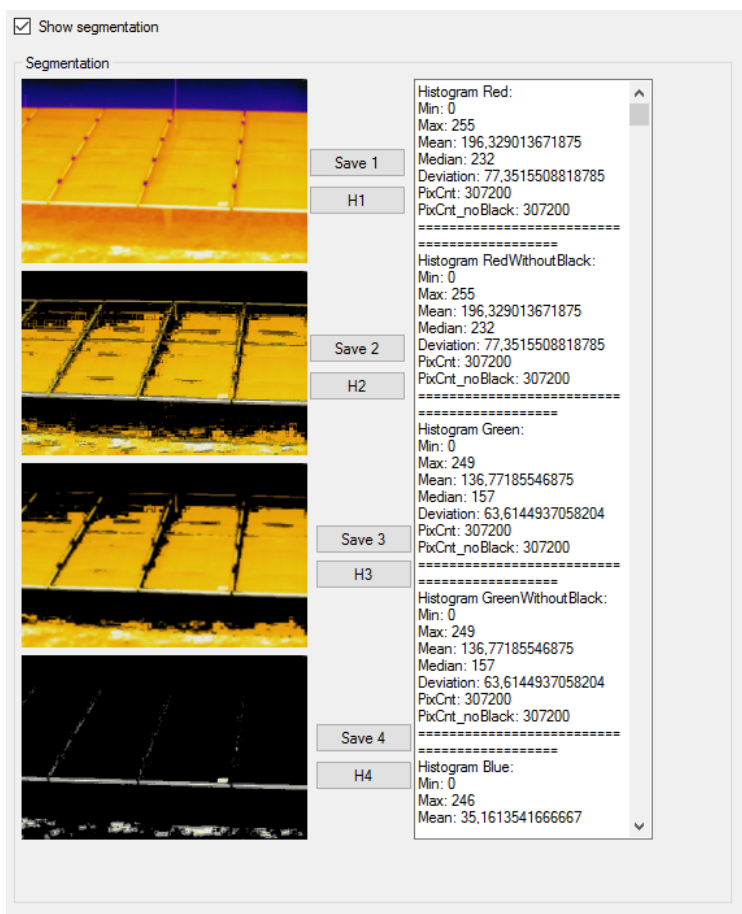
D: Seznam objektů

Zobrazuje nalezené objekty na vybraném snímku. V seznamu je zachována stanovená barevná konvence. Zelenou barvou jsou označeny defekty, červeně jsou označeny artefakty. Název položky je tvořen následovně. Pokud není načtena neuronová síť, tak se vypíše pouze jako

„Object“. Pokud je neuronová síť načtena, tak se vypíše jako „Defect“ a číslo reprezentující pravděpodobnost s jakou se jedná o defekt.

E: Zobrazení segmentace

Zaškrtnutím políčka *Show segmentation* se zobrazí postup segmentace, statistické hodnoty snímku a možnost uložení jednotlivých kroků segmentace a zobrazení statistických hodnot pro jednotlivé kroky segmentace.



Obr. 6.7 Zobrazení segmentace snímku a vypsání statistických hodnot snímku

F: Neuronová síť

V této části se nachází veškeré nastavení neuronové sítě. Vpravo nahoře se nachází tlačítko pro načtení již vytvořených neuronových sítí. Načítání probíhá pevně ze složky NN umístěné v rootu aplikace a nelze ji měnit. Po jejím načtení se její vlastnosti vypíší do příslušných políček a pod tlačítkem se zobrazí stručná statistika z průběhu jejího učení. Jednotlivé položky znamenají následující:

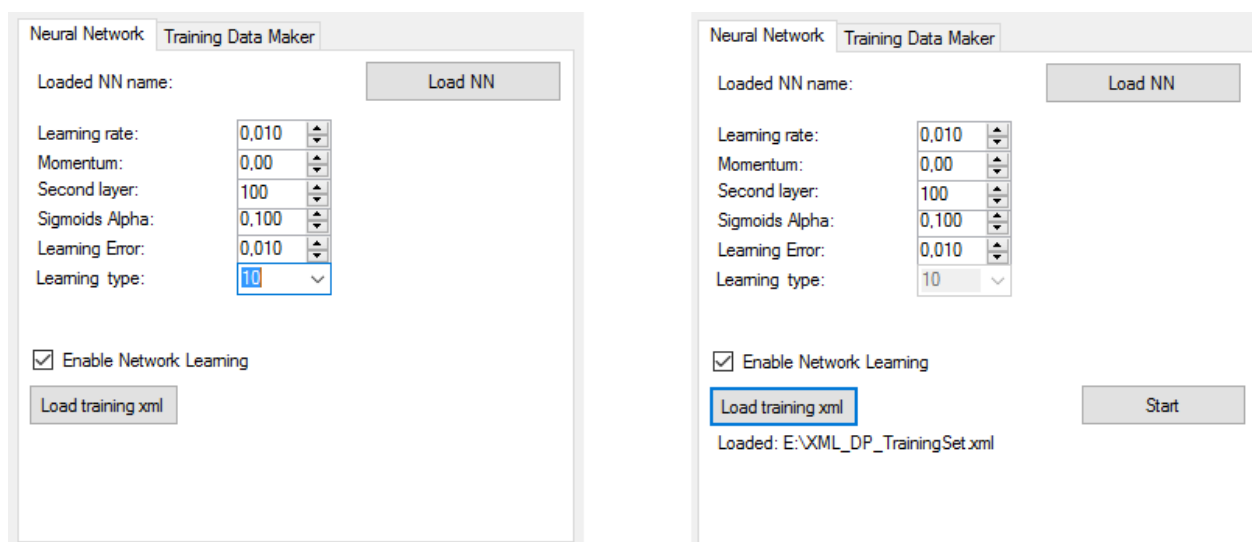
- *Learnig rate* - rychlost učení.
- *Momentum* – hodnota určuje, jaká část předchozího aktualizování vah se použije v aktuální iteraci. Může nabývat hodnot 0 až 1.

- *Second Layer* – počet neuronů v druhé vrstvě,
- *Sigmoids Alpha* – hodnota ovlivňuje strmost sigmoidy, čím je hodnota vyšší, tím více se podobá klasické prahové funkci.
- *Learning Error* – požadovaná přesnost respektive chybovost sítě, ve výchozím stavu nastavená na 0,01 tedy 1 %.
- *Learning Type* - volba příznakového vektoru.

Ve výchozím stavu jsou položky deaktivované, k jejich aktivaci dojde po zaškrtnutí políčka *Enable network learning*.

G: Mód učení nové neuronové sítě

Zaškrtnutím políčka *Enable network learning* se zpřístupní nastavení pro učení nové neuronové sítě. V první řadě se aktivují položky nastavení neuronové sítě viz. předchozí bod a obrázek (Obr. 6.8). Dále se zpřístupní tlačítko pro zvolení tréninkové množiny „*Load training xml*“.

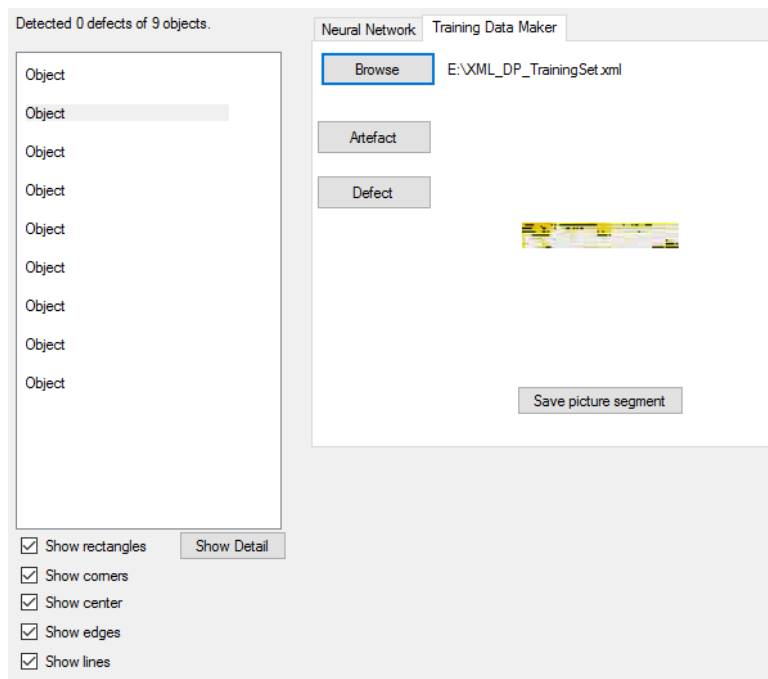


Obr. 6.8 Aktivovaný mód učení neuronové sítě

Vybráním tréninkové množiny se tato množina vypíše pod tlačítko a dále se zobrazí tlačítko pro zahájení učení. Po dokončení učení se tlačítko start změnilo na ukládací tlačítko.

H: Tvorba tréninkových dat

Slouží k vytváření tréninkové množiny pro neuronové sítě. Tlačítko *Browse* slouží k vybrání xml souboru, do kterého budou ukládána tréninková data. Samotné vytváření tréninkové množiny se provádí výběrem objektu ze Seznamů objektů a kliknutím na tlačítko *Defect* nebo *Artefact* podle toho o jaký objekt se jedná. Na učení fungují i klávesové zkratky „A“ pro artefakt a „D“ pro defekt. Detail objektu se zobrazuje napravo od tlačítek. Pod detailem je tlačítko *Save picture segment* sloužící pro uložení vybrané části snímku.



Obr. 6.9 Detail z vytváření tréninkové množiny

I: Nastavení zobrazení nalezených objektů

Zaškrtnutými políčky lze upravit, jak se budou objekty vybrané se seznamu nalezených objektů zobrazovat.

- *Show rectangles* – zobrazuje ohraničující obdélníky o nejmenší možné velikosti, které uzavřou celý objekt.
- *Show corners* – vyznačí rohy objektu.
- *Show center* – vyznačí střed objektu.
- *Show edges* – vyznačí hraniční pixely objektu.
- *Show lines* – vyznačí přímky prokládající hrany objektu.

6.5 První spuštění programu

Po prvním spuštění je třeba vytvořit neuronovou síť. Nejprve je nutné stisknutím tlačítka *Load images* (A) vybrat složku se snímky. Dále je potřeba přepnout rozhraní na *Training Data Maker* (H) a zvolit soubor pro ukládání tréninkové množiny. Nyní procházením jednotlivých snímků respektive objektů v nich nalezených a určováním, zda se jedná o defekt nebo artefakt, dojde k vytvoření tréninkové množiny.

Poté co je vytvořena tréninková množina, je možné přejít k vytvoření samotné neuronové sítě. Nejprve je třeba přepnout rozhraní zpět na *Neural Network*, a dále zaškrtnout pole *Enable network learning*. Zpřístupní se možnosti nastavení budoucí sítě, experimentem bylo zjištěno optimální nastavení pro učení a toto optimální nastavení je přednastaveno ve výchozím stavu. Ovšem v případě, že při učení nebude chybovost sítě konvergovat k požadované hodnotě, je záhodno nastavení upravit. Po spuštění učení sítě je zobrazován aktuální čas a hodnota chyby.

V průběhu je možné učení kdykoliv přerušit tlačítkem Stop. Po zastavení bude spolehlivost sítě odpovídat aktuální chybě v době zastavení.

Jakmile je proces učení dokončen nebo je přerušen uživatelem, tak je nabídnuto uložení sítě. Uložení probíhá pouze zvolením jména a potvrzením. Konvence pojmenování je následující k zadanému jménu se přidá předpona „NN_“ a číslo reprezentující velikost použitého příznakového vektoru. Pokud tedy uživatel učí síť pomocí 22 příznaků a zadá název „univerzita“, tak bude celý název vypadat následovně:

NN_22_univerzita

Po uložení se vytvoří ve složce NN v rootu aplikace celkem tři soubory:

- NN_22_univerzita.bin – který reprezentuje samotnou síť.
- NN_22_univerzita.xml – který obsahuje odkaz na síť a parametry s jakými byla síť učena, tyto parametry slouží pouze k vypsání do aplikace.
- NN_22_univerzita_errors.csv – ve kterém je uložen časový vývoj chyby z učení sítě.

Uloženou síť je možné načíst a nově načtené snímky již budou analyzovány pomocí této sítě.

7 EXPERIMENT

7.1 Hledání příznakového vektoru

Cílem práce bylo vytvořit software, který by automaticky vyhodnocoval defekty na snímcích. Protože prostou segmentací snímku bychom získali všechny druhy objektů na snímku bez jakékoliv informace, o jaký typ objektu se jedná, bylo potřeba vytvořit klasifikátor. Jednoduchou klasifikaci objektů by bylo možné provádět například na základě souřadnice jejich středu, plochy a rozměrů objektu.

Jako klasifikátor byly zvoleny neuronové sítě, a to hlavně z důvodu déle trvajícího zájmu o problematiku umělé inteligence a aktuálnosti tématu. Neuronová síť učená učitelem mohla být v tomto případě použita, protože je k dispozici velké množství dat. Řešení neuronovou sítí je obecnějšího rázu, tedy ne třeba vytvářet složitě větvené rozhodovací stromy. Nevýhodou je však nutnost nejprve investovat čas k vytvoření tréninkové množiny a učení neuronové sítě. Aby byly tyto operace co nejvíce usnadněny, tak bylo vytvořeno rozhraní popsané v kapitole 6.4, postup při vytváření a učení je popsán v kapitole 6.5. Dále také hrozí riziko, že bude tréninková množina vytvořena špatnými daty a v takovém případě nelze očekávat správné výsledky podané neuronovou sítí.

V kapitole 6.2.3 bylo naznačeno, že bylo pro objekty vytvořeno několik příznaků popisujících jeden nalezený objekt. Kombinací těchto příznaků vzniklo 5 příznakových vektorů. Tato kapitola se věnuje nalezení takového vektoru, který dává nejpřesnější výsledky při hledání samostatných defektů na snímku.

7.2 Postup experimentu

Nejprve byla vytvořena experimentální množina snímků pomocí snímkování videí poskytnutých firmou Eicero (příloha 1). Tato množina byla rozdělena na dvě části:

1. Tréninkové snímky (30 ks, příloha 2),
2. Ověřovací snímky (60 ks, příloha 3).

Tréninkové snímky budou sloužit k vytvoření tréninkových dat pro učení neuronových sítí. Ověřovací snímky budou snímky, které daná síť uvidí poprvé, aby bylo ověřeno, že dokáže defekty detekovat na neznámých snímcích. Tato množina bude složena z 30 ks snímků s defektem a 30 ks snímků bez defektu. Bude vytvořeno celkem 5 neuronových sítí, přičemž každá bude přijímat na vstupu určitý příznakový vektor. Každá síť zpracuje množinu ověřovacích snímků a ručně bude vyhodnoceno, zda-li síť určila defekty na snímku správně. Data budou graficky a tabelárně zpracována. Výsledky jednotlivých neuronových sítí budou shrnuty a bude vybrán optimální příznakový vektor.

Protože experimentální množina snímků neobsahuje dostatečné množství defektů, tak byly některé defekty vytvořeny ručně a to kopírováním defektů mezi snímky. Aby bylo zajištěno, že se nejedná stále o tentýž tvar, tak byla každá kopie ručně deformovaná v grafickém programu.

Tab. 7.1 Tabulka skutečného počtu defektů na snímcích ověřovací množiny

Počet defektů na snímcích														
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0	1	1	1	1	1	1	0	0	1	7	1	1	1	0
16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
1	1	0	1	1	1	0	0	1	2	0	1	8	0	2
31	32	33	34	35	36	37	38	39	40	41	42	43	44	45
0	0	0	0	2	1	0	0	0	0	0	2	0	0	0
46	47	48	49	50	51	52	53	54	55	56	57	58	59	60
0	1	0	3	0	1	0	0	0	0	1	0	1	6	0

V tabulce výše (Tab. 7.1) jsou shrnuty skutečné počty defektů na vybraných ověřovacích snímcích. Každý experiment s vybraným příznakovým vektorem bude obsahovat tabulku s vybranými příznaky, tabulku defektů nalezených neuronovou sítí, tabulku s počtem chyb na každém snímku a tabulku porovnávající výsledky neuronové sítě s tabulkou (Tab. 7.1).

Příznakové vektory nejsou upořádány dle velikosti nýbrž podle toho v jakém pořadí vznikaly.

7.2.1 Příznakový vektor 35

První vytvořený příznakový vektor popisuje hlavně hranice objektu. Obsahuje údaj o počtu rohů objektu, obvod, plnost objektu a popis každé hrany z hlediska její přímosti. Použité příznaku jsou shrnuty v tabulce (Tab. 7.2), výsledek zpracování NS v tabulce (Tab. 7.3), chyby NS v tabulce (Tab. 7.4) a správnost výsledků je shrnuta v tabulce (Tab. 7.5).

Tab. 7.2 Tabulka příznaků použitých v příznakovém vektoru 35

1.	cornersCount
2. - 9.	normalizedEdgeHistogramTop
10. - 17.	normalizedEdgeHistogramBottom
18. - 25.	normalizedEdgeHistogramLeft
26. - 33.	normalizedEdgeHistogramRight
34.	perimeter
35.	fullness

Tab. 7.3 Výsledky analýzy ověřovacích snímků NS za použití příznakového vektoru 35


Počet defektů [ks]														
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0	0	1	1	1	1	0	0	0	1	5	1	1	1	0
16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
1	1	0	1	1	1	0	0	2	0	0	2	1	0	2
31	32	33	34	35	36	37	38	39	40	41	42	43	44	45
0	0	0	0	2	0	0	0	0	1	3	2	4	1	0
46	47	48	49	50	51	52	53	54	55	56	57	58	59	60
0	1	0	1	0	0	0	2	0	0	1	0	0	2	1

Tab. 7.4 Tabulka počtu chyb u jednotlivých snímků za použití příznakového vektoru 35

Počet chyb [ks]														
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0	1	0	0	0	0	1	0	0	0	2	0	0	0	0
16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
0	0	0	0	0	0	0	0	1	0	0	1	7	0	0
31	32	33	34	35	36	37	38	39	40	41	42	43	44	45
0	0	0	0	0	1	0	0	0	1	3	0	4	1	0
46	47	48	49	50	51	52	53	54	55	56	57	58	59	60
0	0	0	2	0	1	0	2	0	0	0	0	1	4	1
Celkový počet chyb [ks]														
34														

Tab. 7.5 Tabulka úspěšnosti určení snímku s defektem za použití příznakového vektoru 35

Správné určení počtu defektu (1), nesprávné určení počtu defektu (0)														
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	0	1	1	1	1	0	1	1	1	0	1	1	1	1
16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
1	1	1	1	1	1	1	1	0	1	1	0	0	1	1
31	32	33	34	35	36	37	38	39	40	41	42	43	44	45
1	1	1	1	1	0	1	1	1	0	0	1	0	0	1
46	47	48	49	50	51	52	53	54	55	56	57	58	59	60
1	1	1	0	1	0	1	0	1	1	1	1	0	0	0
Správnost určení														
0,7167														



Obr. 7.1 Sloupcový graf správnosti určení a rozdílu oproti skutečnému stavu pro vektor 35

7.2.2 Příznakový vektor 7

Druhý příznakový vektor popisuje podobnost objektu čtyřúhelníku. Obsahuje údaj o počtu rohů objektu, podobnosti objektu a jemu opsanému obdélníku čtverci, plnost, kompaktnost a konvexnost objektu a poměr plochy ku obvodu. Použité příznaku jsou shrnuty v tabulce (Tab. 7.6), výsledek zpracování NS v tabulce (Tab. 7.7), chyby NS v tabulce (Tab. 7.8) a správnost výsledků je shrnuta v tabulce (Tab. 7.9).

Tab. 7.6 Tabulka příznaků použitých v příznakovém vektoru 7

1.	cornersCount
2.	rectSquarelikeness
3.	blobSquarelikeness
4.	AtoO
5.	compactness
6.	convexity
7.	fullness

Tab. 7.7 Výsledky analýzy ověřovacích snímků NS za použití příznakového vektoru 7


Počet defektů [ks]														
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0	0	1	1	1	2	0	0	1	1	7	1	1	1	0
16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
1	1	0	1	1	0	0	0	2	0	0	0	6	0	2
31	32	33	34	35	36	37	38	39	40	41	42	43	44	45
0	0	0	0	2	1	0	0	1	0	1	2	0	0	0
46	47	48	49	50	51	52	53	54	55	56	57	58	59	60
0	1	0	2	0	0	0	0	0	0	1	0	0	4	1

Tab. 7.8 Tabulka počtu chyb u jednotlivých snímků za použití příznakového vektoru 7

Počet chyb [ks]														
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0	1	0	0	0	1	1	0	1	0	0	0	0	0	0
16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
0	0	0	0	0	1	0	0	1	0	0	1	2	0	0
31	32	33	34	35	36	37	38	39	40	41	42	43	44	45
0	0	0	0	0	0	0	0	1	0	1	0	0	0	0
46	47	48	49	50	51	52	53	54	55	56	57	58	59	60
0	0	0	1	0	1	0	0	0	0	0	0	1	2	1
Celkový počet chyb [ks]														
17														

Tab. 7.9 Tabulka úspěšnosti určení snímku s defektem za použití příznakového vektoru 7

Správné určení počtu defektu (1), nesprávné určení počtu defektu (0)														
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	0	1	1	1	0	0	1	0	1	1	1	1	1	1
16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
1	1	1	1	1	0	1	1	0	1	1	0	0	1	1
31	32	33	34	35	36	37	38	39	40	41	42	43	44	45
1	1	1	1	1	1	1	1	0	1	0	1	1	1	1
46	47	48	49	50	51	52	53	54	55	56	57	58	59	60
1	1	1	0	1	0	1	1	1	1	1	1	0	0	0
Správnost určení														
0,7500														



Obr. 7.2 Sloupcový graf správnosti určení a rozdílu oproti skutečnému stavu pro vektor 7

7.2.3 Příznakový vektor 22

Třetí příznakový vektor popisuje podobnost objektu a jemu opsanému obdélníku čtverci, přidává vyhodnocování rovnoběžnosti protějších hran a také přímosti hran, kompaktnost, konvexnost a podobnost objektu kruhu. Použité příznaku jsou shrnuty v tabulce (Tab. 7.10), výsledek zpracování NS v tabulce (Tab. 7.11), chyby NS v tabulce (Tab. 7.12) a správnost výsledků je shrnuta v tabulce (Tab. 7.13).

Tab. 7.10 Tabulka příznaků použitých v příznakovém vektoru 22

1.	cornersCount	8.	blobRoundLikeness
2.	rectSquarelikeness	9.	horizontalParallelism
3.	blobSquarelikeness	10	verticalParallelism
4.	AtoO	11. – 13.	min/max/avgDeviation horní hrany
5.	compactness	14. – 16.	min/max/avgDeviation spodní hrany
6.	convexity	17. – 19.	min/max/avgDeviation levé hrany
7.	fullness	20. – 22.	min/max/avgDeviation pravé hrany

Tab. 7.11 Výsledky analýzy ověřovacích snímků NS za použití příznakového vektoru 22


Počet defektů [ks]														
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0	0	1	1	1	2	0	0	0	1	6	0	1	1	0
16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
0	1	0	1	1	0	0	0	0	0	0	1	6	0	2
31	32	33	34	35	36	37	38	39	40	41	42	43	44	45
0	0	0	0	2	0	0	0	0	0	0	2	0	0	0
46	47	48	49	50	51	52	53	54	55	56	57	58	59	60
0	1	0	2	0	0	0	0	0	0	1	0	0	2	0

Tab. 7.12 Tabulka počtu chyb u jednotlivých snímků za použití příznakového vektoru 22

Počet chyb [ks]														
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0	1	0	0	0	1	1	0	0	0	1	1	0	0	0
16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
1	0	0	0	0	1	0	0	1	0	0	0	2	0	0
31	32	33	34	35	36	37	38	39	40	41	42	43	44	45
0	0	0	0	0	1	0	0	0	0	0	0	0	0	0
46	47	48	49	50	51	52	53	54	55	56	57	58	59	60
0	0	0	1	0	1	0	0	0	0	0	0	1	4	0
Celkový počet chyb [ks]														
18														

Tab. 7.13 Tabulka úspěšnosti určení snímku s defektem za použití příznakového vektoru 22

Správné určení počtu defektu (1), nesprávné určení počtu defektu (0)														
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	0	1	1	1	0	0	1	1	1	0	0	1	1	1
16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
0	1	1	1	1	0	1	1	0	1	1	1	0	1	1
31	32	33	34	35	36	37	38	39	40	41	42	43	44	45
1	1	1	1	1	0	1	1	1	1	1	1	1	1	1
46	47	48	49	50	51	52	53	54	55	56	57	58	59	60
1	1	1	0	1	0	1	1	1	1	1	1	0	0	1
Správnost určení														
0,7667														



Obr. 7.3 Sloupcový graf správnosti určení a rozdílu oproti skutečnému stavu pro vektor 22

7.2.4 Příznakový vektor 10

Čtvrtý příznakový vektor popisuje opět podobnost objektu čtyřúhelníku jako vektor 7 a přidává vyhodnocování podobnosti kruhu. Poměr mezi plochou a druhou mocninou vzdálenosti od středu nejvzdálenějšího bodu, poměr mezi od středu nejbližším a nejvzdálenějším bodem. Použité příznaku jsou shrnuty v tabulce (Tab. 7.14), výsledek zpracování NS v tabulce (Tab. 7.15), chyby NS v tabulce (Tab. 7.16) a správnost výsledků je shrnuta v tabulce (Tab. 7.17).

Tab. 7.14 Tabulka příznaků použitých v příznakovém vektoru 10

1.	cornersCount	8.	convexity
2.	rectSquarelikeness	9.	fullness
3.	blobSquarelikeness	10.	piCoef
4.	AtoO	11. – 13.	blobRoundLikeness
5.	compactness	14. – 16.	furthestNearestPointRatio

Tab. 7.15 Výsledky analýzy ověřovacích snímků NS za použití příznakového vektoru 10

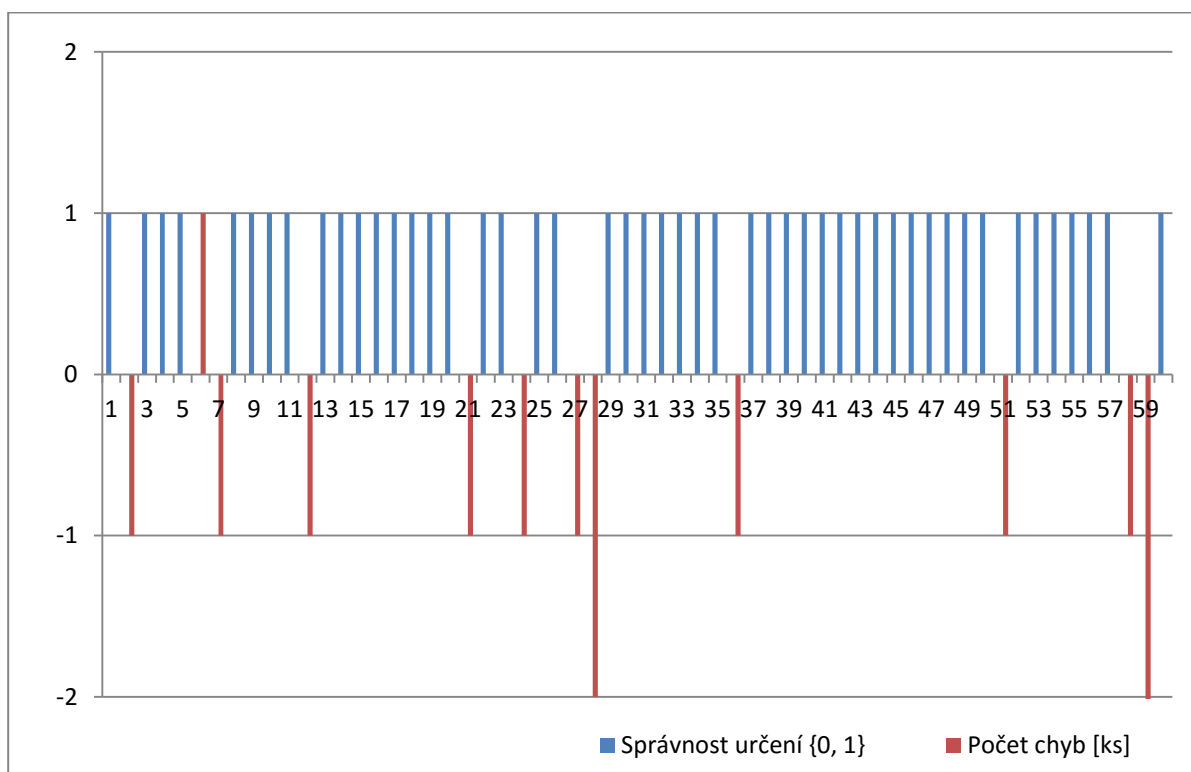
Počet defektů [ks]														
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0	0	1	1	1	2	0	0	0	1	7	0	1	1	0
16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
31	32	33	34	35	36	37	38	39	40	41	42	43	44	45
31	32	33	34	35	36	37	38	39	40	41	42	43	44	45
46	47	48	49	50	51	52	53	54	55	56	57	58	59	60
46	47	48	49	50	51	52	53	54	55	56	57	58	59	60
0	1	0	3	0	0	0	0	0	0	1	0	0	3	0

Tab. 7.16 Tabulka počtu chyb u jednotlivých snímků za použití příznakového vektoru 10

Počet chyb [ks]														
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0	1	0	0	0	1	1	0	0	0	0	1	0	0	0
16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
0	0	0	0	0	1	0	0	1	0	0	1	2	0	0
31	32	33	34	35	36	37	38	39	40	41	42	43	44	45
0	0	0	0	0	1	0	0	0	0	0	0	0	0	0
46	47	48	49	50	51	52	53	54	55	56	57	58	59	60
0	0	0	0	0	1	0	0	0	0	0	0	1	3	0
Celkový počet chyb [ks]														
15														

Tab. 7.17 Tabulka úspěšnosti určení snímku s defektem za použití příznakového vektoru 10

Správné určení počtu defektu (1), nesprávné určení počtu defektu (0)														
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	0	1	1	1	0	0	1	1	1	1	0	1	1	1
16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
1	1	1	1	1	0	1	1	0	1	1	0	0	1	1
31	32	33	34	35	36	37	38	39	40	41	42	43	44	45
1	1	1	1	1	0	1	1	1	1	1	1	1	1	1
46	47	48	49	50	51	52	53	54	55	56	57	58	59	60
1	1	1	1	1	0	1	1	1	1	1	1	0	0	1
Správnost určení														
0,8000														



Obr. 7.4 Sloupcový graf správnosti určení a rozdílu oproti skutečnému stavu pro vektor 10

7.2.5 Příznakový vektor 56

Poslední příznakový vektor kombinuje všechny dříve použité příznaky. Použité příznaky jsou shrnuty v tabulce (Tab. 7.18), výsledek zpracování NS v tabulce (Tab. 7.19), chyby NS v tabulce (Tab. 7.20) a správnost výsledků je shrnuta v tabulce (Tab. 7.21).

Tab. 7.18 Tabulka příznaků použitých v příznakovém vektoru 56

1.	cornersCount	11.	horizontalParallelism
2.	rectSquarelikeness	12.	verticalParallelism
3.	blobSquarelikeness	13. – 15.	min/max/avgDeviation horní hrany
4.	AtoO	16. – 18.	min/max/avgDeviation spodní hrany
5.	compactness	19. – 21.	min/max/avgDeviation levé hrany
6.	convexity	22. – 24.	min/max/avgDeviation pravé hrany
7.	fullness	25. – 32.	normalizedEdgeHistogram horní hrany
8.	piCoef	33. – 40.	normalizedEdgeHistogram spodní hrany
9.	furthestNearestPointRatio	41. – 48.	normalizedEdgeHistogram levé hrany
10	blobRoundLikeness	49. – 56.	normalizedEdgeHistogram pravé hrany

Tab. 7.19 Výsledky analýzy ověřovacích snímků NS za použití příznakového vektoru 56

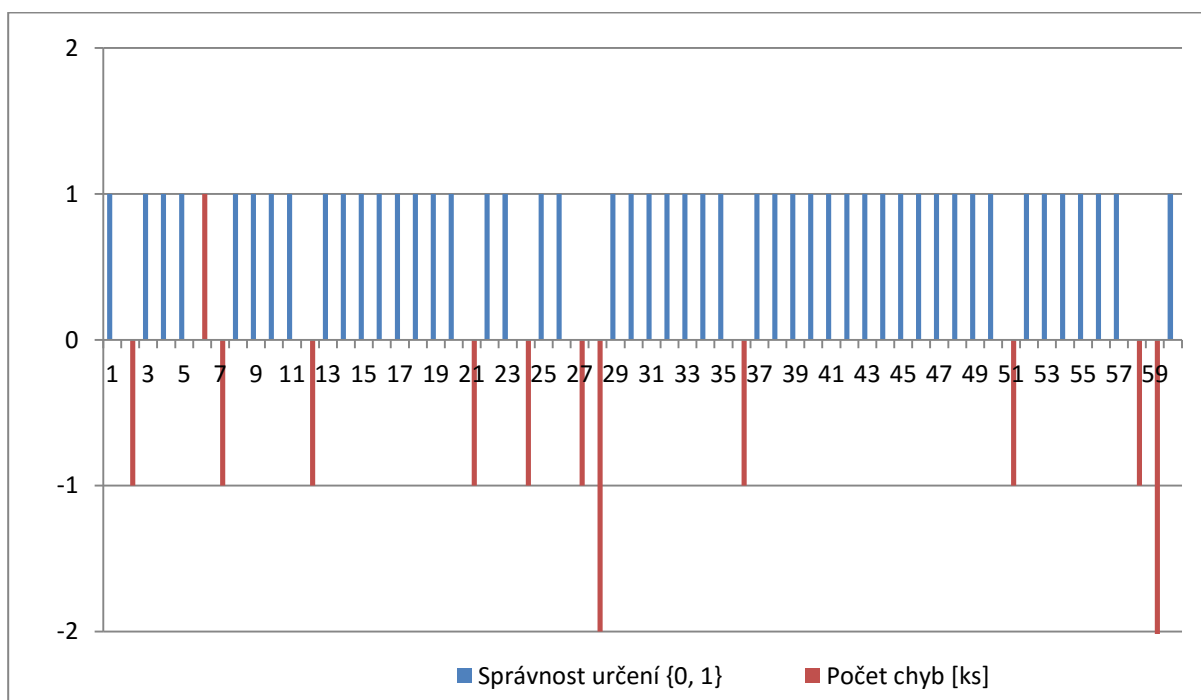
Počet defektů [ks]														
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0	0	1	1	1	2	0	0	0	1	7	0	1	1	0
16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
0	1	0	1	1	0	0	0	0	0	0	1	6	0	2
31	32	33	34	35	36	37	38	39	40	41	42	43	44	45
0	0	0	0	2	0	0	0	0	0	0	2	0	0	0
46	47	48	49	50	51	52	53	54	55	56	57	58	59	60
0	1	0	2	0	0	0	0	0	0	1	0	0	3	0

Tab. 7.20 Tabulka počtu chyb u jednotlivých snímků za použití příznakového vektoru 56

Počet chyb [ks]														
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0	1	0	0	0	1	1	0	0	0	0	1	0	0	0
16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
1	0	0	0	0	1	0	0	1	0	0	0	2	0	0
31	32	33	34	35	36	37	38	39	40	41	42	43	44	45
0	0	0	0	0	1	0	0	0	0	0	0	0	0	0
46	47	48	49	50	51	52	53	54	55	56	57	58	59	60
0	0	0	1	0	1	0	0	0	0	0	0	1	3	0
Celkový počet chyb [ks]														
16														

Tab. 7.21 Tabulka úspěšnosti určení snímku s defektem za použití příznakového vektoru 56

Správné určení počtu defektu (1), nesprávné určení počtu defektu (0)														
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
1	0	1	1	1	0	0	1	1	1	1	0	1	1	1
16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
0	1	1	1	1	0	1	1	0	1	1	1	0	1	1
31	32	33	34	35	36	37	38	39	40	41	42	43	44	45
1	1	1	1	1	0	1	1	1	1	1	1	1	1	1
46	47	48	49	50	51	52	53	54	55	56	57	58	59	60
1	1	1	0	1	0	1	1	1	1	1	1	0	0	1
Správnost určení														
0,7833														



Obr. 7.5 Sloupcový graf správnosti určení a rozdílu oproti skutečnému stavu pro vektor 56

7.3 Shrnutí experimentu

Tab. 7.22 Shrnutí výsledků experimentu

Název vektoru	Správně určené snímky [ks]	Počet chyb [ks]	Správnost určení [%]
Vektor 35	43	34	71,67
Vektor 7	45	17	75,00
Vektor 22	46	18	76,67
Vektor 10	48	15	80,00
Vektor 56	47	16	78,33

Výsledky experimentů jsou shrnuty v tabulce výše (Tab. 7.22). Na základě této tabulky je patrné, že pro určování defektů D1 je nejvhodnější použít příznakový vektor 10. Neuronová síť naučená na tento vektor správně určila největší počet snímků z ověřovací množiny a to 48. Zároveň udělala nejméně chyb 15. Chybami je myšleno, jak neurčení defektu z objektu, který byl opravdu defekt, tak určení defektu u objektu, který defekt nebyl. Z toho plyne i nejvyšší správnost určování na ověřovací množině. U správnosti je nutno podotknout, že tento ukazatel je nastaven přísně. Snímek je považován za správně určený pouze v případě, že jsou na něm určeny všechny defekty. Pokud tedy například neuronová síť určí správně 6 ze sedmi defektů, tak se celý snímek považuje za špatně určený.

8 DISKUZE

Protože vytvoření programu, který by zvládl klasifikovat veškeré možné druhy defektů je poměrně náročná záležitost, tak bylo v této práci přistoupeno k několika zjednodušením. Nyní budou diskutovány možné způsoby překonání těchto problémů.

První možné zlepšení úspěšnosti se samozřejmě pojí se zlepšením samotného procesu snímání. Použití termokamery s vyšším rozlišením se pozitivně projeví na kvalitě snímků, tedy i na přesnějším zobrazení defektů. Dalším zlepšením by bylo snímání každého panelu nejlépe ze stejného úhlu, což může být pro člověka někdy neřešitelný úkol, hlavně u fotovoltaických elektráren umístěných na střeších domů. Zde už firmy, zabývající se diagnostikou těchto elektráren, začínají ke snímání používat dronů. Jelikož drony mohou létat po operátorem předem nastavených drahách, tak by bylo možné dosáhnout toho, aby snímek panelu byl vytvořen právě v okamžiku, kdy by se dron nacházel přímo nad zkoumaným panelem. V kombinaci s kvalitní kamerou by pak hrany defektů byly rovnoběžky a kolmice, což by se pozitivně projevilo na přesnosti určování.

Další oblast možného zlepšení je předzpracování snímků. Zde bylo experimentálně zjištěno, že nejlepších výsledků dosáhneme odfiltrováním všech pixelů s hodnotou zelené barvy nižší, než je medián jejího výskytu. Bylo ověřeno, že na snímku zůstanou informace o všech defektech. Avšak mohou nastat případy, kdy se na snímku může vyskytovat více defektních článků různé teploty, což se projeví zobrazením teplejšího defektního článku bíle. Další defektní článek však může mít takovou teplotu, že se zobrazí jako o odstín světlejší místo, než je nejčastější barva na snímku. Takové případy by bylo možné řešit pomocí dynamického prahování. Zbývající barevné rozpětí by se rozdělilo na několik úseků a postupně by se tyto barevné úseky aplikovaly na snímek. A nalezených objektů by se muselo kontrolovat, zda se nejedná o část již nalezeného objektu.

Poslední možné zlepšení by se mohlo týkat popisu nalezených objektů, tak aby bylo možné úspěšně detekovat i násobné defekty. Jednalo by se o vymyšlení nových příznaků a sestavení nových příznakových vektorů. Jeden z možných příznaků by třeba mohl zkoumat hranu násobného defektu, která by se na snímku zobrazovala jako po částech lomená křivka, změny směru by však v případě správného úhlu snímání byly o 90° . Hrany objektu by byly po částech proloženy úsečkami a jejich směrnice by byly shrnuty do jednoho parametru normovaného na počet těchto úseček. Další možností by bylo násobný defekt zobrazit na mřížku s krokem mříže o šířce jednoho článku a počítalo by se, zda se celková plocha násobného defektu přibližuje celému násobku plochy samostatného článku.

Z nových příznaků by se vytvořil příznakový vektor a k němu nová neuronová síť. Dále by se při vyhodnocování nalezených objektů přidalo vyhodnocování další neuronovou sítí a ve výsledném vypsání by se vypsaly výsledky od všech aplikovaných neuronových sítí.

9 ZÁVĚR

V teoretické části práce byly zmíněny metody pro defektoskopické měření FV panelů. Dále byly popsány termovizní kamery, jejich složení a princip fungování. Byly popsány defekty odhalitelné termovizní kamerou, příčina jejich vzniku a jejich ukázka. Zbývající teoretická kapitola se zabývala počítačovým viděním.

V praktické části práce byl naprogramován software na automatickou detekci samostatných defektních článků (příloha 4). Ke zjednodušení bylo přistoupeno s ohledem na rozmanitost tvarů při násobných defektech. Klasifikování defektů je řešeno pomocí více vrstvé neuronové sítě. Kapitola 6 je věnována programu, vysvětluje jeho fungování, popisuje uživatelské rozhraní a jakým způsobem lze vytvářet tréninkovou množinu a neuronové sítě.

V průběhu programování vzniklo celkem 5 příznakových vektorů popisujících nalezené objekty. Hledání příznakového vektoru je popsáno v kapitole 7. V rámci hledání byla vytvořena sada 30 snímků (příloha 2), ze kterých bylo vytvořeno 184 tréninkových vzorků (příloha 5) pro následnou tvorbu neuronových sítí. Pro každý příznakový vektor byla vytvořena neuronová síť. Každé z těchto sítí potom byla předložena sada 60 ověřovacích snímků (příloha 3). Pro každý příznakový vektor byly vytvořeny tři tabulky.

V první byly vyčteny defekty nalezené danou neuronovou sítí na snímcích. V druhé tabulce byly shrnuty počty chybných určení na příslušných snímcích. V poslední třetí tabulce byly shrnuty správně určené snímky. Defekty na snímku spočítané neuronovou sítí byly porovnány se skutečným počtem defektů vypočítaným ručně. V případě, že síť našla všechny defekty správně, tak byl snímek označen číslem jedna jako správně vyhodnocený, pokud síť udělala chybu, tak byl snímek označen nulou.

Ke každému příznakovému vektoru byl také vytvořen sloupcový graf. Na tomto grafu jsou modře vyznačeny správně vyhodnocené snímky a červeně jsou vyznačeny počty chyb na špatně vyhodnocených snímcích. Kladné hodnoty reprezentují chybně určené defekty z nalezených objektů, které ve skutečnosti defekty nejsou. Záporné hodnoty reprezentují neurčené defekty. Experimenty pro jednotlivé příznakové vektory jsou popsány v kapitolách 7.2.1 až 0.

Nejlépeších výsledků bylo dosaženo za použití příznakového vektoru 10, kdy bylo správně určeno 80 % snímků z ověřovací množiny.

SEZNAM SYMBOLŮ A ZKRATEK

FV	fotovoltaický
CCD	Charge-coupled device
FOV	Field of View – zorný úhel
E	Energie [J], [eV]
f	Frekvence [Hz]
h	Planckova konstanta [J.s], $h = 6,626 \cdot 10^{-23}$ J.s
$E_{0\lambda}$	Spektrální hustota zářivého toku
λ	Vlnová délka [m]
c	Rychlost světla [m.s^{-1}], $c = 299\,792\,458$ m.s^{-1}
k	Boltzmannova konstanta [J.K^{-1}], $k = 1,381 \cdot 10^{-23}$ J.K^{-1}
T	Termodynamická teplota [K]
b	Wienova konstanta, $b = 2,898 \cdot 10^{-3}$ m.K
σ_0	Stefan-Boltzmannova konstanta [$\text{W.m}^{-2}.\text{K}^{-4}$], $\sigma_0 = 5,670 \cdot 10^{-8}$ $\text{W.m}^{-2}.\text{K}^{-4}$
ε	Emisivita materiálu [-]
E_r	Energie odražená [J]
E_t	Energie procházející [J]
E_a	Energie absorbovaná [J]
r	Reflektance [-]
t	Transmitance [-]
a	Absorptance [-]
R	Red – červená složka barvy
G	Green – zelená složka barvy
B	Blue – modrá složka barvy
RGB	Red-Green-Blue tři složky barvy
H	Hue - barevný tón
S	Saturation – sytost barvy
L	Lightness - světelnost

<i>V</i>	Value - jas
<i>HSL</i>	Hue-Saturation-Lightness tři složky barvy
<i>HSV</i>	Hue-Saturation-Value tři složky barvy
<i>NS</i>	Neuronová síť
<i>BLOB</i>	Binary Large Object

SEZNAM OBRÁZKŮ

<i>Obr. 3.1 Termogram FV panelu.....</i>	<i>6</i>
<i>Obr. 3.2 Blokové schéma termokamery [1]</i>	<i>7</i>
<i>Obr. 3.3 Schéma mikrobolometru, mikrobolometrové 2D pole [2]</i>	<i>7</i>
<i>Obr. 3.4 Planckův vyzařovací zákon [7]</i>	<i>10</i>
<i>Obr. 3.5 Wiennův posunovací zákon [7]</i>	<i>11</i>
<i>Obr. 3.6 Stefan-Boltzmannův zákon [7]</i>	<i>12</i>
<i>Obr. 3.7 První Kirchhoffův zákon [7]</i>	<i>12</i>
<i>Obr. 4.1 FV panel s hot spotem [8].....</i>	<i>13</i>
<i>Obr. 4.2 Neozářený přechod PN (vlevo), ozářený přechod PN (vpravo)</i>	<i>14</i>
<i>Obr. 4.3 Separace páru elektron-díra vlivem silného elektrického pole v oblasti přechodu PN (vlevo), růst koncentrace volných nosičů náboje v článku a teploty článku (vpravo).....</i>	<i>14</i>
<i>Obr. 4.4 Připojení článku na zátěž, pokles koncentrace volných nosičů náboje, pokles teploty článku</i>	<i>15</i>
<i>Obr. 4.5 Schéma zapojení s bypassovou diodou</i>	<i>15</i>
<i>Obr. 4.7 Vada hotspot</i>	<i>16</i>
<i>Obr. 4.8 Rozdíl teplot cca 40 °C (vlevo), rozdíl teplot cca 20 °C (vpravo)</i>	<i>16</i>
<i>Obr. 4.9 Vada vícenásobný hotspot (vlevo), vady hotspot snímané zezadu (vpravo)</i>	<i>17</i>
<i>Obr. 4.10 Vada: 1/3.....</i>	<i>17</i>
<i>Obr. 4.11 Vada: 2/3.....</i>	<i>17</i>
<i>Obr. 4.12 Vada: 3/3.....</i>	<i>18</i>
<i>Obr. 4.13 Články rozehráté vlivem zastínění</i>	<i>18</i>
<i>Obr. 5.1 Čtyři pilíře počítačového vidění [12]</i>	<i>19</i>
<i>Obr. 5.2 Blokové schéma popisující počítačové vidění.....</i>	<i>20</i>
<i>Obr. 5.3 Snímek z laboratorního měření (vlevo), tentýž snímek binarizovaný (vpravo).....</i>	<i>21</i>
<i>Obr. 5.4 Filtrováno podle hodnoty zelené barvy. Odfiltrovány jsou pixely s hodnotou zelené barvy 0 až 135.</i>	<i>21</i>
<i>Obr. 5.5 Ilustrace zkoumání snímku pomocí pohyblivého okna.....</i>	<i>22</i>
<i>Obr. 5.6 Sestavování příznakového vektoru</i>	<i>23</i>
<i>Obr. 5.7 Ilustrace analogie mezi biologickým a umělým neuronem [18]</i>	<i>24</i>

<i>Obr. 6.1 Demonstrace zvolených skupin, písmeno a označuje D1 defekty - samostatný rozehřátý článek, písmeno b označuje násobné spojené defektní články, písmenec c je označena rozehřátá přechodová krabička, která prosvítá ze zadní strany, písmeno d označuje artefakty na obrázku – rozehřátou konstrukci, vadu digitalizace. Snímek byl poskytnut firmou EICERO.....</i>	<i>27</i>
<i>Obr. 6.2 Rozdělení kroků počítačového vidění dle jednotlivých tříd</i>	<i>27</i>
<i>Obr. 6.3 Vývoj hodnot barev měřítka Iron</i>	<i>28</i>
<i>Obr. 6.4 Postup filtrování snímku. 1. Originální snímek. 2. Odfiltrované pixely s hodnotou zelené barvy nižší než je její medián. 3. Zaostření vyfiltrovaného snímku. 4. Vybrání pixelů s nejvyšší hodnotou svítivosti.</i>	<i>29</i>
<i>Obr. 6.5 Ukázka ukládání tréninkových dat</i>	<i>30</i>
<i>Obr. 6.6 Ukázka uživatelského rozhraní programu</i>	<i>31</i>
<i>Obr. 6.7 Zobrazení segmentace snímku a vypsání statistických hodnot snímku.....</i>	<i>32</i>
<i>Obr. 6.8 Aktivovaný mód učení neronové sítě.....</i>	<i>33</i>
<i>Obr. 6.9 Detail z vytváření tréninkové množiny.....</i>	<i>34</i>
<i>Obr. 7.1 Sloupcový graf správnosti určení a rozdílu oproti skutečnému stavu pro vektor 35.....</i>	<i>39</i>
<i>Obr. 7.2 Sloupcový graf správnosti určení a rozdílu oproti skutečnému stavu pro vektor 7.....</i>	<i>41</i>
<i>Obr. 7.3 Sloupcový graf správnosti určení a rozdílu oproti skutečnému stavu pro vektor 22.....</i>	<i>43</i>
<i>Obr. 7.4 Sloupcový graf správnosti určení a rozdílu oproti skutečnému stavu pro vektor 10.....</i>	<i>45</i>
<i>Obr. 7.5 Sloupcový graf správnosti určení a rozdílu oproti skutečnému stavu pro vektor 56.....</i>	<i>47</i>

SEZNAM TABULEK

<i>Tab. 7.1 Tabulka skutečného počtu defektů na snímcích ověřovací množiny</i>	37
<i>Tab. 7.2 Tabulka příznaků použitých v příznakovém vektoru 35</i>	38
<i>Tab. 7.3 Výsledky analýzy ověřovacích snímků NS za použití příznakového vektoru 35</i>	38
<i>Tab. 7.4 Tabulka počtu chyb u jednotlivých snímků za použití příznakového vektoru 35</i>	38
<i>Tab. 7.5 Tabulka úspěšnosti určení snímku s defektem za použití příznakového vektoru 35</i>	39
<i>Tab. 7.6 Tabulka příznaků použitých v příznakovém vektoru 7</i>	40
<i>Tab. 7.7 Výsledky analýzy ověřovacích snímků NS za použití příznakového vektoru 7</i>	40
<i>Tab. 7.8 Tabulka počtu chyb u jednotlivých snímků za použití příznakového vektoru 7</i>	40
<i>Tab. 7.9 Tabulka úspěšnosti určení snímku s defektem za použití příznakového vektoru 7</i>	41
<i>Tab. 7.10 Tabulka příznaků použitých v příznakovém vektoru 22</i>	42
<i>Tab. 7.11 Výsledky analýzy ověřovacích snímků NS za použití příznakového vektoru 22</i>	42
<i>Tab. 7.12 Tabulka počtu chyb u jednotlivých snímků za použití příznakového vektoru 22</i>	42
<i>Tab. 7.13 Tabulka úspěšnosti určení snímku s defektem za použití příznakového vektoru 22</i>	43
<i>Tab. 7.14 Tabulka příznaků použitých v příznakovém vektoru 10</i>	44
<i>Tab. 7.15 Výsledky analýzy ověřovacích snímků NS za použití příznakového vektoru 10</i>	44
<i>Tab. 7.16 Tabulka počtu chyb u jednotlivých snímků za použití příznakového vektoru 10</i>	44
<i>Tab. 7.17 Tabulka úspěšnosti určení snímku s defektem za použití příznakového vektoru 10</i>	45
<i>Tab. 7.18 Tabulka příznaků použitých v příznakovém vektoru 56</i>	46
<i>Tab. 7.19 Výsledky analýzy ověřovacích snímků NS za použití příznakového vektoru 56</i>	46
<i>Tab. 7.20 Tabulka počtu chyb u jednotlivých snímků za použití příznakového vektoru 56</i>	46
<i>Tab. 7.21 Tabulka úspěšnosti určení snímku s defektem za použití příznakového vektoru 56</i>	47
<i>Tab. 7.22 Shrnutí výsledků experimentu</i>	48

POUŽITÁ LITERATURA



- [1] Konstrukce termokamery. *Termokamera.cz* [online]. 2013 [cit. 2015-12-11]. Dostupné z: <http://www.termokamera.cz/princip-a-funkce/konstrukce-termokamery/>
- [2] SOVA, J. *Základy práce s IČT kamerou* [online]. Praha, 2015, 2015 [cit. 2015-12-11]. Dostupné z: http://kps.fsv.cvut.cz/file_download.php?fid=3354. Prezenční materiály.
- [3] SOVA, Jan a Jan KOVÁŘ. Termokamery a pyrometry. *Automa* [online]. 2014, 2014(2): 7 [cit. 2015-12-11]. Dostupné z: <http://automa.cz/termokamery-a-pyrometry-52891.html>
- [4] BAYER, R. *Úvod do principů termografie* [online]. Brno [cit. 2015-12-11]. Dostupné z: https://www.vutbr.cz/www_base/zav_prace_soubor_verejne.php?file_id=65646. Překlad.
- [5] Údržba fotovoltaických elektráren: Sledování stavu jednotlivých panelů optimalizuje životnost elektrárny Zdroj: <http://oze.tzb-info.cz/fotovoltaika/10154-udrzba-fotovoltaickych-elektraren>. *TZB-info.cz*[online]. 2013, 19.7.2013 [cit. 2015-12-11]. Dostupné z: <http://oze.tzb-info.cz/fotovoltaika/10154-udrzba-fotovoltaickych-elektraren>
- [6] STRNADEL, J. *Využití termovize při detekci defektních panelů ve fotovoltaických systémech*: diplomová práce. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav Elektrotechnologie, 2013. 98 s. Vedoucí diplomové práce doc. Ing. Jiří Vaněk, Ph.D.
- [7] PAVELEK, Milan. *TERMOMECHANIKA: 19. Přenos tepla zářením* [online]. Brno [cit. 2015-12-11]. Dostupné z: http://ottp.fme.vutbr.cz/~pavelek/termo/19_Zareni.pdf. Učební texty. Vysoké učení technické v Brně.
- [8] APEXENERGIES. Apexenergie [online]. [cit. 23.5.2016]. Dostupné z: <http://www.apexenergies.fr/>.
- [9] KLADIVA, R. *Dlouhodobé sledování parametrů fotovoltaických panelů*: diplomová práce. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav Elektrotechnologie, 2012. 74 s. Vedoucí diplomové práce Ing. Roman Gvritishvili
- [10] CHOCHOLÁČ, J. *Využití bypassových diod ve fotovoltaických panelech*: diplomová práce. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2011. 68. Vedoucí diplomové práce Ing. Petr Křivík, Ph.D.
- [11] *Typy vad*. Eicero s.r.o., Brno, 2014
- [12] HLAVÁČ, V.: *Digitální zpracování obrazu, počítačové vidění, zakotvení*: přednáška [online]. <http://cmp.felk.cvut.cz/~hlavac/TeachPresCz/11DigZprObr/012IntroDigImProcVsCompVisionCz.pdf>, [cit. 2016-03-03].
- [13] HLAVÁČ, V., ŠONKA, M. *Počítačové vidění*. Praha: Grada, 1992. ISBN 80-85424-67-3.


-
- [14] HORÁK, K., KALOVÁ, I., PETYOVSKÝ, P., RICHTER, M. *Počítačové vidění*. Elektronické přednášky. Brno: FEKT VUT v Brně.
- [15] DE VRIES, J. *Object Recognition: A Shape-Based Approach using Artificial Neural Networks*. Utrecht, 2006. University of Utrecht. Vedoucí práce Marco Wiering.
- [16] TOSHEV, A, Ben TASKAR a Kostas DANIILIDIS. *Object Detection via Boundary Structure Segmentation*. Philadelphia, 2010. University of Pennsylvania.
- [17] HANSEN, A. *Neural Networks and Shape Identification*. Jefferson City, 2010. Vedoucí práce Henry Suters.
- [18] NAGYOVÁ, L. Aplikace neuronových sítí ve zpracování obrazu. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií. Ústav radioelektroniky, 2014. 50 s., 3 s. příloh. Diplomová práce. Vedoucí práce: Ing. Libor Boleček.
- [19] JIRSÍK, V., HRÁČEK, P. *Neuronové sítě, expertní systémy a rozpoznávání řeči*. Elektronické skriptum. Brno: FEKT VUT v Brně.
- [20] Microsoft .NET Framework 4.6. *Microsoft* [online]. [cit. 2016-05-08]. Dostupné z: <https://www.microsoft.com/cs-cz/download/details.aspx?id=48130>
- [21] AForge.NET Framework 2.2.5. *AForge.NET* [online]. [cit. 2016-05-08]. Dostupné z: <http://www.aforgenet.com/framework/downloads.html>

PŘÍLOHY

1. příloha

Obrázek (Obr. 6.4) ve větším rozlišení.



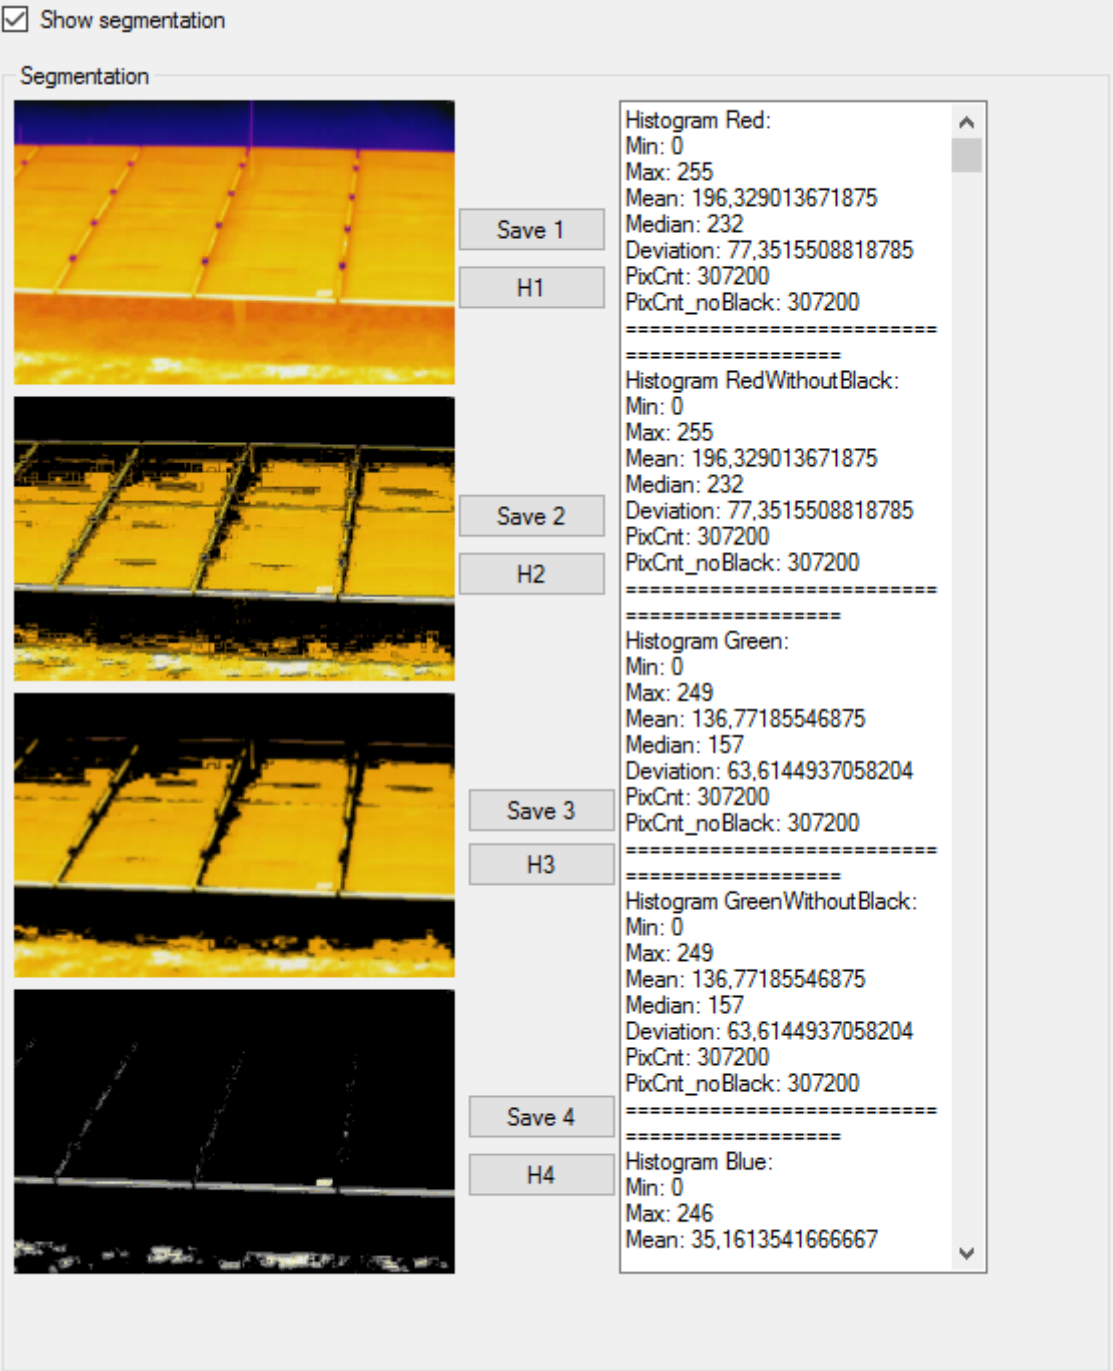


2. příloha

Obrázek (Obr. 6.7) ve větším rozlišení.

Show segmentation

Segmentation



Save 1
H1

Save 2
H2

Save 3
H3

Save 4
H4

Histogram Red:
Min: 0
Max: 255
Mean: 196,329013671875
Median: 232
Deviation: 77,3515508818785
PixCnt: 307200
PixCnt_noBlack: 307200
=====

Histogram RedWithoutBlack:
Min: 0
Max: 255
Mean: 196,329013671875
Median: 232
Deviation: 77,3515508818785
PixCnt: 307200
PixCnt_noBlack: 307200
=====

Histogram Green:
Min: 0
Max: 249
Mean: 136,77185546875
Median: 157
Deviation: 63,6144937058204
PixCnt: 307200
PixCnt_noBlack: 307200
=====

Histogram GreenWithoutBlack:
Min: 0
Max: 249
Mean: 136,77185546875
Median: 157
Deviation: 63,6144937058204
PixCnt: 307200
PixCnt_noBlack: 307200
=====

Histogram Blue:
Min: 0
Max: 246
Mean: 35,1613541666667

Obsah CD

- 1. Zdrojové video**
- 2. Tréninkové snímky**
- 3. Ověřovací snímky**
- 4. Zdrojové kódy programu**
- 5. Tréninkové vzorky pro neuronové sítě, celkem 184 ks**