

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
Fakulta strojního inženýrství
Ústav automatizace a informatiky

Ing. Jan Richter

**VYUŽITÍ METOD UMĚLÉ INTELIGENCE
PRO SIMULACI A IDENTIFIKACI DAT V
OBLASTI PROUDĚNÍ**

UTILIZATION OF ARTIFICIAL INTELLIGENCE
FOR SIMULATION AND DATA
IDENTIFICATION IN THE FIELD OF FLOWING

Zkrácená verze PhD Thesis

Obor: Konstrukční a procesní inženýrství
Školitel: prof. RNDr. Ing. Jiří Šťastný, CSc.
Oponenti: doc. Ing. Oldřich Trenz, Ph.D.; prof. Ing. Pavelek Milan, CSc.
Datum obhajoby: 22.1.2019

KLÍČOVÁ SLOVA

Vícevrstvá perceptronová neuronová síť, genetický algoritmus, zpracování obrazu, vizualizace proudění vzduchu, rychlost proudění, tvar proudnice

KEYWORDS

Multilayer perceptron neural network, genetic algorithm, image processing, vizualization of airflow, velocity of airflow, airjet shape

MÍSTO ULOŽENÍ

Knihovna VUT FSI v Brně

ISBN:

ISSN:

OBSAH

1	ÚVOD.....	6
1.1	Cíl práce.....	6
2	VYHODNOCOVÁNÍ PROUDĚNÍ VZDUCHU	7
2.1	Sledované vlastnosti proudícího vzduchu.....	7
2.2	Způsoby vyhodnocování proudění vzduchu.	7
2.2.1	Vizualizační metody pro určení vlastností vzduchu.....	7
2.3	Typy snímků proudění vzduchu	7
3	METODIKA A TEORETICKÉ PODKLADY	8
3.1	Reprezentace obrazu	8
3.2	Preprocessing.....	8
3.3	Zpracování sekvence snímků.....	9
4	URČENÍ TVARU PROUDU VIZUALIZOVANÉHO MLHOU.....	10
4.1	Jednoduchá evaluace obrazu.....	10
4.1.1	Podmíněné prahování.....	10
4.1.2	Vyhlažovací algoritmus.....	11
4.2	Vyšetřování proudnice v řezech	11
4.2.1	Vyhodnocení řezu	11
4.2.2	Sestrojení hranice proudu.....	11
4.3	Rozpoznávání mlhy neuronovými sítěmi	12
4.3.1	Princip vyhodnocení neuronovou sítí.....	12
4.3.2	Základní zpracování snímku s využitím neuronové sítě	12
4.3.3	Podmíněné prahování spojitě detekce	14
4.3.4	Metoda dvou expertů.....	15
4.3.5	Podmíněná detekce dvojicí expertů.....	16
5	URČENÍ TVARU PROUDU VIZUALIZOVANÉHO HELIOVÝMI BUBLINAMI	17
5.1	Detekce heliových bublin náležících proudu	17
5.1.1	Výběr reprezentantů heliových bublin	17
5.1.2	Separace neplatných reprezentantů	18
5.1.3	Seřazení množiny reprezentantů	19
5.2	Určení konvexní obálky proudnice	19
5.3	Nekonvexní obálka proudnice	20
5.3.1	Použití genetického algoritmu při konstrukci nekonvexní obálky	20
5.3.2	Sestrojení hranice dle genotypu	20

5.3.3	Fitness funkce	21
5.3.4	Průběh genetického algoritmu.....	21
6	URČENÍ RYCHLOSTI PROUDU VIZUALIZOVANÉHO MLHOU	22
6.1	Princip použití vzájemné korelace	22
6.2	Vektorová mapa.....	22
7	URČENÍ RYCHLOSTI PROUDU VIZUALIZOVANÉHO HELIOVÝMI BUBLINAMI.....	22
7.1	Sledování částic	22
7.1.1	Inicializace procesu	23
7.1.2	Generování možných cest	23
7.1.3	Rozvíjení cesty	23
7.1.4	Ohodnocení cest.....	24
7.2	Zpracování detekovaných vektorů.....	24
7.2.1	Porovnávání okolních vektorů	24
7.2.2	Mazání kolizních vektorů.....	24
7.3	Vektorová mapa.....	25
7.3.1	Výběr vektorů k učení	25
7.3.2	Nastavení neuronové sítě k určení rychlosti v konkrétním bodě.....	25
7.3.3	Tvorba vektorové mapy	26
8	URČENÍ VLASTNOSTÍ VENTILAČNÍHO SYSTÉMU.....	27
8.1	Vyšetřování tvaru proudnice v jediném snímku	27
8.1.1	Určení dosahu proudu a hraničních křivek.....	27
8.1.2	Určení polohy vyústky	27
8.1.3	Výběr reprezentantů hranice	27
8.1.4	Hraniční přímky, osa proudu a rozptyl.....	28
8.2	Vyšetřování tvaru proudnice v sekvenci.....	28
8.2.1	Statistické zpracování výsledků jednotlivých detekcí	28
8.2.2	Sčítání detekovaných pixelů.....	28
8.3	Vyhodnocení rychlosti.....	29
8.3.1	Validace vektorové mapy.....	29
8.3.2	Filtrace vektorové mapy.....	29
8.3.3	Zpracování rychlosti v sekvenci snímků	29
9	ZHODNOCENÍ A VÝSLEDKY PRÁCE	29
9.1	Tvar proudnice.....	29
9.2	Rychlosti proudění.....	31
10	ZÁVĚR.....	32

10.1	Vědecký přínos práce	32
10.2	Praktický přínos práce	33
11	SEZNAM POUŽITÉ LITERATURY	34
12	AUTOROVO CV	36
13	ABSTRACT	37

1 ÚVOD

Prakticky každý dopravní prostředek dnes obsahuje systém cirkulace vzduchu. Někdy se jedná pouze o ventilační a výhřevné systémy, ve většině případů se k nim přidává i možnost chlazení. Klimatizace jsou dnes běžně instalovány i v budovách. Samozřejmě se staly ve veřejných prostorách, jako jsou obchody, kina či úřady. Stále častěji se objevují i v rodinných domech.

Efektivita ventilačních a klimatických systémů je značně závislá nejen na výkonnosti chladicích či výhřevných zařízení, ale i na jejich vhodném nastavení s ohledem na to, jak se distribuovaný vzduch šíří chlazeným či vytápěným prostorem. Vhodným návrhem ventilačního systému můžeme nejen zvýšit komfort osob v prostoru, ale také snížit energetické nároky takové ventilace. Při návrhu a nastavení ventilačního systému je velmi důležité mapovat chování vzduchu v prostoru. Takové mapování pak bude sloužit k ověření funkčnosti ventilačního zařízení a pro určení některých jeho vlastností. Povědomí o chování vzduchu v prostoru lze získat například vhodným rozmístěním měřicích zařízení, která budou poskytovat informace o teplotě, tlaku, hustotě vzduchu, o rychlosti nebo směru jeho proudění.

Zcela odlišným přístupem jsou vizualizační či optické metody, které umožňují získat snímky a videozáznamy proudění vzduchu, jež je poté třeba počítačově zpracovat. Principem těchto metod je zviditelnit proudnici vzduchu. V případě optických metod se využívá optických zařízení. V případě vizualizačních metod jsou data snímána běžnými fotoaparáty a kamerami, avšak neprůhledný vzduch je mísen nebo úplně nahrazen viditelnými látkami. Oba principy vedou k získání snímků a záznamů, na nichž je proud vzduchu patrný. Po získání snímků proudění vzduchu nastává úkol tyto snímky vyhodnotit a určit z nich důležité vlastnosti proudícího vzduchu, jako jsou tvar a dosah proudnice, rychlost proudění v konkrétním místě, hustota proudu, lokální teplotní mapa, výskyt turbulencí apod.

Pro tyto účely lze užít exaktních vyhodnocovacích algoritmů, ale také metod umělé inteligence. Tato práce se zabývá vyhodnocováním vybraných typů snímků. Vyhodnocovacími kritérii jsou zejména tvar proudu a rychlost proudění v různých místech prostoru. Pro určení těchto vlastností jsou vhodné snímky vzniklé vizualizačními metodami zavádění látek do proudu vzduchu.

1.1 CÍL PRÁCE

Základním úkolem práce je vylepšit stávající metody či vyvinout zcela nové postupy pro zpracování 2D obrazu, aplikovatelné pro vyhodnocení snímků proudění vzduchu tak, aby dokázaly správně stanovit požadované vlastnosti tohoto proudění. Aby byly tyto postupy univerzální, je velmi výhodné v rámci nich využívat metody umělé inteligence. Cílem je, aby zpracování snímků bylo méně závislé na prostředí, v němž byly tyto snímky pořízeny, jako je tomu v případě, kdy takové vyhodnocování provádí člověk.

Dalším úkolem práce je doplnit stávající možnosti tak, aby byly pro oba typy vizualizace (částicemi i spojitými vlákny) získány kvalitativně stejné výsledky. Z metod umělé inteligence je velmi užitečné využít umělých neuronových sítí, které jsou použitelné jako účinné detektory nebo slouží pro realizaci rozhodovacích procesů. Umělé neuronové sítě jsou inspirovány právě činností lidského mozku. Jejich použití slibuje kvalitativně srovnatelné vyhodnocení s vyhodnocením, jaké vytvoří člověk. Jako optimalizační algoritmus je výhodné využívat evoluční metodu genetických algoritmů. Genetický algoritmus napodobuje evoluci populace, kdy se z počátečních primitivních jedinců vyvíjejí dokonalejší s ohledem na zvolené hodnotící kritérium.

Komplexním úkolem práce je také vývoj počítačového softwaru na zpracování snímků proudění vzduchu, v němž budou uvažované metody implementovány a pomocí kterého bude ověřována jejich funkčnost. Tento software by měl být dobře využitelný mimo jiné v oborech zabývajících se návrhy a konstrukcemi ventilačních systémů.

2 VYHODNOCOVÁNÍ PROUDĚNÍ VZDUCHU

Práce se zabývá analýzou vzduchu, který proudí z vyústky ventilačního systému do prostoru.

2.1 SLEDOVANÉ VLASTNOSTI PROUDÍCÍHO VZDUCHU

Pro popsání a ověření funkčnosti systému ventilace je důležité určit významné vlastnosti proudění vzduchu. Jednou ze dvou hlavních sledovaných vlastností je **tvar proudnice**. Z tvaru proudnice lze určovat charakteristiky vyústky i způsob, jakým se vzduch šíří po interiéru. Druhou klíčovou vlastností proudícího vzduchu je **rychlost proudění**. Podle rychlosti proudění lze odvodit, jak proudění budou vnímat osoby v místnosti. Pro dobrou tepelnou pohodu je vhodnější, aby osoby nebyly proudění vystaveny přímo, ale aby k nim bylo distribuováno velké množství vzduchu.

O dalších vlastnostech proudícího vzduchu hovoří například Cermak (2003). Zmiňuje například **turbulenci proudění**. Tu lze vyhodnocovat pomocí detailní mapy vektorů rychlosti proudění. Ke zjištění efektu, jaký ventilace přináší, může dopomoci i **hustota aditiva**. Dle ní lze usuzovat, jaké množství tepla může proud v konkrétním místě předat či odebrat. S tvarem proudnice a rychlostí proudění souvisí také **dosah proudu**. Lze říci, že proudnice dosahuje do míst, kde proudění nabývá jisté rychlosti, tedy kde se vzduch ještě nezastavil.

2.2 ZPŮSOBY VYHODNOCOVÁNÍ PROUDĚNÍ VZDUCHU.

Vlastnosti proudu lze určit např. pomocí měřidel. Jinou možností je použít optické metody k získání snímků proudění vzduchu, které je nutné následně počítačově zpracovat. Práce se však bude věnovat metodám vizualizačním.

2.2.1 Vizualizační metody pro určení vlastností vzduchu

Principem vizualizačních metod je získání snímků proudění a jejich následné počítačové zpracování. Proudění je ve snímku patrné díky tomu, že jsou do proudu vzduchu zaváděny viditelné látky. Těmi mohou být látky tvořící souvislá vlákna (mlha, kouř...) či látky, které tvoří částice (jiskry, saze, piliny, heliové bublinky...).

2.3 TYPY SNÍMKŮ PROUDĚNÍ VZDUCHU

Pavelek et al (2001) používá členění snímků dle složitosti, které bude ctít i tato práce.

- **Snímky prvního typu** - Snímky jsou pořízené v laboratorních podmínkách. Vzduch je velmi zahuštěn aditivem. Pozadí má jednotnou barvu zcela odlišnou od barvy aditiva. Proud obsahuje minimum turbulencí.
- **Snímky druhého typu** - Vizualizovaný proud je stále zřetelný. K vizualizaci nemusí být použito husté aditivum. Proudění je často turbulentní. Také prostředí nemusí být homogenní a tak dobře rozlišitelné od aditiva.
- **Snímky třetího typu** - Zejména kvůli nevyhovujícímu pozadí je velmi obtížné tvar proudnice přesně určit.



a) Snímek prvního typu



b) Snímek druhého typu



c) Snímek třetího typu

Snímek 1 Typy snímků

3 METODIKA A TEORETICKÉ PODKLADY

V této kapitole budou zmapovány vybrané matematické postupy a algoritmy.

3.1 REPREZENTACE OBRAZU

V práci bude využit barevný model *RGB* (Red – červená, Green – zelená, Blue – modrá). A barevná hloubka 24 bitů (true color). 24 bitů barvy je rozděleno na 3 byty, přičemž každý byte přísluší jedné ze tří barevných složek *RGB*. Výraz „hodnota pixelu“ bude představovat hodnotu jeho barevných složek *RGB* nesených jedinou celočíselnou hodnotou *P*.

$$P = 2^0 \cdot R + 2^8 \cdot G + 2^{16} \cdot B \quad (3.1)$$

Každá ze složek *R*, *G*, *B* nabývá hodnoty $\langle 0, 2^8-1 \rangle$. Kromě jednotlivých barevných složek lze barvu pixelu hodnotit také jeho jasem *I*, tedy světelnou intenzitou. V práci je použitý jednoduchý převod:

$$I = \frac{1}{3}R + \frac{1}{3}G + \frac{1}{3}B \quad (3.2)$$

3.2 PREPROCESSING

Jedná se o širokou škálu metod zpracování obrazu, které snímky upravují do vhodné podoby, aby na ně poté mohly být použity specializované vyhodnocovací procedury.

Známé úpravy obrazu

V práci jsou využity úpravy geometrie (změna rozměrů, rotace), jednoduché úpravy barev (změna kontrastu, jasu, negativ, převod na stupně šedi), filtrace obrazu (zejm. horní propust a Gaussův filtr) a procedurální úpravy (ekvalizace histogramu, Cannyho hranový detektor).

Nelineární hranový detektor

Nově vyvinutý nelineární hranový detektor (*NHD*) existuje ve dvou variantách, a to *NHD* typu minimum či *NHD* typu maximum. Princip bude popsán na *NHD* typu minimum. Prvním krokem je vlastní detekce hranic. V nejbližším okolí $[P_{x-1, y-1} \dots P_{x+1, y+1}]$ vyšetřovaného pixelu P_{xy} je vyhledána nejnižší hodnota každé z barevných složek *R*, *G*, *B*. Dále jsou spočteny rozdíly světelných složek aktuálního pixelu a nalezených minimálních světelných složek v okolí:

$$dR = R_P - R_{min} \quad (3.3)$$

$$dG = G_p - G_{min} \quad (3.4)$$

$$dB = B_p - B_{min} \quad (3.5)$$

Nejvyšší z těchto rozdílů pak bude představovat základ Z_{xy} pro určení nové hodnoty světelné intenzity pixelu P_{xy} . Spolu s výpočty základů pro všechny pixely také vyhledáme nejvyšší základ Z_{max} . Pro fázi vyvažování je stanoven koeficient n_v dle stanoveného koeficientu zvýraznění k_v .

$$n_v = \frac{I_{max} \cdot k_v}{Z_{max}} \quad (3.6)$$

I_{max} je hodnota nevyšší možné intenzity (bílá barva). Vyvážené intenzity pixelů se pak rovnají

$$V_{xy} = Z_{xy} \cdot n_v \quad (3.7)$$


Výsledná intenzita pixelu je pak rovna menší z hodnot V_{xy} a I_{max} .



a) Zdrojový obrázek



b) Nelineární hranový detektor



c) Cannyho hranový detektor

Snímek 2 Porovnání Cannyho a nelineárního hranového detektoru

3.3 ZPRACOVÁNÍ SEKVENCE SNÍMKŮ

Sekvenčí snímku se bude pro účely této práce rozumět množina snímků, které zachycují totéž proudění vzduchu. Během snímání je neměnná poloha snímacího zařízení ani výustky.

Opakované focení

Časová známka snímku nebude hrát v dalším vyhodnocení roli. Každý snímek je pořizován zvlášť a lze tak klást důraz na jejich kvalitu. Pro další vyhodnocování je důležité, aby byly podmínky při pořizování snímků neměnné. V množině snímků pak nebude záležet ani na pořadí jednotlivých snímků. Lze z ní i odstranit snímky horší kvality.

Videozáznam

Časová známka snímků velmi důležitá. Snímky nelze co do kvality optimalizovat jako v předchozím případě. Díky časové známce je znám časový rozdíl mezi jednotlivými snímky. Z obrazového a časového rozdílu mezi snímky lze následně určovat rychlosti proudění.

4 URČENÍ TVARU PROUDU VIZUALIZOVANÉHO MLHOU

V následující kapitole budou všechny zmíněné metody věnované vyhodnocování snímků, které zachycují proudění, vizualizované mlhou. Účelem metod bude detekce tvaru proudnice.

4.1 JEDNODUCHÁ EVALUACE OBRAZU

Cílem jednoduchého ohodnocení snímku proudění je získat v krátkém čase přibližné ohraničení mlhy. Proces se skládá z dvojice kroků: detekce pixelů mlhy a sestrojení hranice proudnice.

4.1.1 Podmíněné prahování

Jednoduché prahování třídí pixely dle prahu do dvou skupin. Pokud je práh nastaven příliš vysoko, splní jej až pixely z oblasti hustšího aditiva, nikoliv pixely na hranici oblasti. Naopak při nižším nastavení prahu hrozí, že jako mlha budou označeny i pixely mimo proud, kde může být přítomna neodvětraná ne příliš hustá mlha. Oba popsání problémy lze vyřešit přidáním druhého prahu. Dvojice prahových hodnot P_1 , P_2 (kde $P_2 > P_1$) pak dělí pixely na tři skupiny:

- (a) Pixely, které jistě náleží mlze, dosahují alespoň hodnoty vyššího z prahů P_2 .
- (b) Pixely, které by mohly být mlhou, dosahují alespoň hodnoty nižšího z prahů P_1 .
- (c) Pixely okolí, které nedosahují hodnot ani nižšího z prahů P_1 .



a) Zdrojový snímek



b) Prahování prahy $P_1 = 85$ a $P_2 = 170$



c) Finální snímek

Snímek 3 Podmíněné prahování

Po rozřazovací fázi se oblasti, které mohou být mlhou, přisoudí mlze, pokud sousedí s oblastí, která mlhou je.

4.1.2 Vyhlašovací algoritmus

Jedná se o doprovodný algoritmus opsání hranice. Vše uvnitř hranice je považováno za mlhu, vše vně za okolí. Tím lze eliminovat chybně detekovanou mlhu mimo proud a pozadí v oblasti proudnice.

4.2 VYŠETŘOVÁNÍ PROUDNICE V ŘEZECH

Jde se o metodu určování hranice proudu. Je vhodná především pro snímky prvního typu. Dle Pavelka, Janotkové a Štětiny (2001) se řezem dvourozměrného snímku rozumí funkce $y = i(x)$, kdy definiční obor funkce je dán pixely na určité křivce. Hodnoty funkce představují jednotlivé světelné intenzity těchto pixelů jednotlivé barevné složky, tedy funkce $y_R = R(x)$; $y_G = G(x)$; $y_B = B(x)$.

4.2.1 Vyhodnocení řezu

Pokud křivka řezu začíná a končí v pixelech pozadí a pokud vede oblastí proudu, je možné na ní detekovat dva hraniční body. Při detekci prvního bodu se postupuje od počátečního bodu křivky, při detekci druhého bodu se postupuje od jejího konce. Princip detekce je pro oba body totožný.


Detekce barevné intenzity

Pixely, jejichž intenzita dosáhne jistého prahu, lze považovat za pixely v proudnici. Postupuje se od krajního pixelu podél křivky, dokud barva nějakého pixelu nepřekročí práh intenzity. Tento bod je pak prohlášen za hraniční bod mlhy. Hodnota prahové intenzity bývá stanovena odhadem s ohledem na jas celého snímku.

Detekce paty

První fáze je totožná s algoritmem detekce barevné intenzity. Jejím účelem je najít první pixel, který se s jistotou nachází v proudnici. Práh tedy bývá nastaven daleko výše než v předchozím případě.


Patu mlhy je hledána dle spojnice q prvního pixelu Q_0 křivky řezu a dle prvního detekovaného pixelu Q_i proudnice. Pro pixely pozadí (ve snímku prvního typu) je jejich světelná intenzita přibližně konstantní. Jakmile se křivka dostane do oblasti mlhy, nastává skokový nárůst intenzity. Místo, kdy intenzita začne narůstat, je skutečnou hranicí mlhy. Pro dotyčný pixel platí, že rozdíl hodnoty jeho intenzity a hodnoty pro pozvolný nárůst intenzity (úsečka q) je maximální pro interval mezi body Q_0 a Q_i . Princip detekce paty je viditelný na snímku 4.



Snímek 4 Detekce paty v průběhu jasu

4.2.2 Sestrojení hranice proudu

Řez slouží k určení dvou hraničních bodů. Vyhodnocení je třeba provést v po sobě jdoucích přímých řezech napříč snímek, které protínají proud, pokud možno, co nejvíce kolmo na směr proudění. Přímkové řezy budou vzájemně rovnoběžné a jejich vzdálenost definuje zvolený parametr d . Detekované hraniční body jsou poté propojeny do hranice.



Snímek 5 Hranice sestavená vyhodnocením po sobě jdoucích řezů

4.3 ROZPOZNÁVÁNÍ MLHY NEURONOVÝMI SÍTĚMI

Rozhodnutí, zda se v konkrétním pixelu nachází mlha či nikoliv, může být někdy obtížné určit pouze na základě barevného odstínu pixelu, zejména u snímků s heterogenním pozadím. Ty mohou obsahovat světlé pixely, které však nenáleží mlze a jejich chybné prohlášení za mlhu negativně ovlivňuje kvalitu výsledku. Člověk však dokáže mlhu i tak rozeznat. Neděje se tak podle jasů jediného pixelu, ale na malé oblasti. Tuto schopnost lze požadovat po umělých neuronových sítích.

4.3.1 Princip vyhodnocení neuronovou sítí

Pro tento účel je vhodná vícevrstvá dopředná neuronová síť *MLP*. Jejímí vstupy budou pixely malého okolí vyšetřovaného pixelu např. 5×5 nebo 7×7 . Nabízí se tedy 25 (resp. 49) vstupních neuronů sítě, přičemž na každý bude přivedena hodnota jasů příslušného pixelu. U snímků s heterogenním pozadím hraje roli i barevný odstín pixelů. Pro snímky druhého a třetího typu je vhodné předat neuronové síti *RGB* intenzity. Vstupů je tedy trojnásobek - 75 (147).


Výstupní vrstva bude obsahovat jediný neuron, odpovídající na otázku, zda je prostřední pixel oblasti pixelem mlhy či nikoliv. Výstupem tohoto neuronu bude hodnota 0 – 1, kterou lze chápat jako pravděpodobnost sledovaného jevu.

Pro síť, kde je na vstupy předáván jas pixelů, postačí jediná skrytá vrstva s mírně navýšeným počtem neuronů oproti vrstvě vstupní, zhruba o 20 %. Pro řešení s *RGB* vstupy je vhodné použít dvě skryté vrstvy, neboť se předpokládá evaluace jednoho kroku navíc (zhodnocení odstínu pixelu).

Síti budou předkládány vzory mlhy, kdy je požadovanou hodnotou výstupu 1, a vzory oblastí okolí s hodnotou 0.

4.3.2 Základní zpracování snímku s využitím neuronové sítě

V základním vyhodnocení bude za pixel mlhy považován každý pixel, o němž síť prohlásí, že je pixelem mlhy s pravděpodobností alespoň 50 %. Pokud bude každý pixel snímku podroben rozhodovacímu procesu s využitím neuronové sítě, výsledkem procedury bude snímek pravdivých (bílé) a nepravdivých (černé) pixelů. Princip učení demonstruje snímek 6a. Protože se jedná o snímek prvního typu, postačí neuronová síť 25-30-1 zpracovávající jas pixelů oblasti 5×5 . Na snímku 6b je znázorněn výsledek po vyhlazovacím algoritmu.



a) Předání vzorů neuronové síti



b) Výsledek detekce

Snímek 6 Vyhodnocení neuronovou sítí


V případě snímků prvního typu nelze říci, že je vyhodnocení neuronovou sítí kvalitnější v porovnání s prostým prahováním. U snímků složitějších už však prahování nedosahuje potřebné kvality, zato neuronová síť je zde úspěšnější. Snímek 7 znázorňuje proces detekce mlhy neuronovou sítí ve snímku třetího typu s heterogenním pozadím.



a) Zdrojový snímek



b) Vyhodnocení dle jasů sítí 25-30-1



c) Vyhodnocení dle RGB sítí 75-90-30-1



d) Snímek c) po vyhlazovacím algoritmu

Snímek 7 Vyhodnocení snímku třetího typu neuronovou sítí

Takto naučená síť je pak vhodná nejen k vyhodnocování snímků z téže sekvence, ale dokonce podobných snímků ze stejného prostředí, podobné světlosti a s podobným heterogenním pozadím.



a) Zdrojový snímek



b) Výsledek detekce na snímku

Snímek 8 Detekce mlhy sítí, naučenou na snímku 7a, v podobných snímcích

Z výsledků je patrné, že i přes vyhlazovací algoritmus byly do oblasti mlhy nesprávně zahrnuty oblasti s podobnou barvou (lesklá podlaha). Na snímku 9 je porovnání barev obou okolí, přičemž by bylo i pro člověka obtížné mlhu v tomto případě odlišit pouze na základě takových dat.



a) Skutečná mlha



b) Lesklá podlaha

Snímek 9 Porovnání oblastí podobné barvy

4.3.3 Podmíněné prahování spojitě detekce

Pokud člověk provádí detekci mlhy, nesoustředí se na jednotlivé body odděleně. Nejprve najde místa, v nichž si je mlhou zcela jistý. Poté hledá, kam až mlha sahá. Prvním krokem spojitě detekce je opět vyhodnocení okolí každého pixelu snímku neuronovou sítí. Každý pixel $[X, Y]$ obdrží hodnotu N_{XY} v rozmezí 0-1, která bude prahovaná dvojicí prahů P_1, P_2 , kde $P_2 > P_1$. Na snímku 10 je porovnání základního zpracování a spojitě detekce neuronovou sítí. Prahování základního zpracování neuronové sítě bylo prováděno hodnotou 0.5. Prahy po spojitě detekci byly $P_1 = 0.3$ a $P_2 = 0.7$. Spojitá detekce mnohem méně chybí v tom, že oblast označí jako mlhu. Rovněž lépe detekuje hranice, jelikož do mlhy zahrnuje i oblasti, jejichž barva není tak průkazná. Mlze podobné oblasti však stále do proudnice zahrnuje.



a) Zdrojový snímek



b) Výsledek základní detekce neuronovou sítí



c) Výsledek spojitě detekce neuronovou sítí

Snímek 10 Porovnání základní a spojitě detekce mlhy neuronovou sítí

4.3.4 Metoda dvou expertů

Pro vyřešení chybovosti běžné neuronové sítě se nabízí možnost použití dvou různých neuronových sítí. Principiálně by obě fungovaly stejně, avšak každá by byla naučená na jiný typ rozpoznávání:

- 1) **Obecný expert** – Sít' bude expertem na rozlišování oblastí okolí a oblastí, které by mohly být mlhou.
- 2) **Specifický expert** – Sít' třídí oblasti, které by mohly být mlhou, na mlhu a mlže podobné okolí.

Obě sítě mohou mít stejný počet neuronů i strukturu. Obě by měly zpracovávat *RGB* vstupy. Jako obecného experta lze použít neuronovou sít' z kapitoly 4.3.2. Její neschopnost rozlišit například lesklá místa od mlhy bude kompenzovat specifický expert. Ten je učen pouze na oblasti, kterou obecný expert označil jako „možnou mlhu“.



a) Zdrojový snímek



b) Barevně oříznutá oblast možné mlhy

Snímek 11 Vyhodnocení obecným expertem

S hodnotou 1 budou specifickému expertovi předány oblasti kolem bodů mlhy, s hodnotou 0 pak oblasti lesklé podlahy. O místech mimo oblast možné mlhy však specifický expert vůbec nebude umět rozhodnout. Z oblasti možné mlhy vyseparuje ta místa pozadí, která první sít' chybně pokládala za mlhu.



a) Výsledek detekce



b) Znázorněná hranice v původním obrázku (tyrkysově)

Snímek 12 Vyhodnocení specifickým expertem


Stejný výsledek by byl získán, pokud by celý snímek vyhodnotil obecný i specifický expert. Jako mlha by byla označena pouze místa, na kterých se oba experti shodnou, tedy oba je označí za mlhu.

4.3.5 Podmíněná detekce dvojicí expertů

Úskalí předchozí metody mohou znamenat místa, kde mlha obklopuje mlze podobné okolí. Například v místech, kde je mlha prosvícena zářivkami. Specifický expert má za úkol zářivky od mlhy odlišit. Protože jsou však zářivky mlhou obklopeny, mlha bude pravděpodobně i na jejich místě. Lze zkombinovat princip podmíněného prahování právě s metodou dvojice expertů. Oba experti tedy budou detekovat spojitě (snímek 13). Protože však byl specifický expert trénován pouze na oblasti označené obecným expertem za mlhu, okolí této oblasti vůbec nezná a mohl se zde rozhodnout jakkoliv. V tomto případě lze říci, že lesklá místa označuje hodnotami blízkými 0, a ostatní (např. pozadí továrny a okolní objekty) označil hodnotami blízkými 1.



a) Detekce obecným expertem



b) Detekce specifickým expertem

Snímek 13 Spojitá detekce

Podmíněné prahování sloučeného výsledku

Prvním krokem postupu je sloučit výsledky spojitých detekcí obou expertů. Každý pixel je dán:

$$I_F[X, Y] = 0.5 \cdot I_O[X, Y] + 0.5 \cdot I_S[X, Y] \quad (4.1)$$

Kde I_F je intenzita pixelu ve finálním snímku;

I_O je intenzita příslušného pixelu ve snímku vyhodnocení obecným expertem

I_S je intenzita příslušného pixelu ve snímku vyhodnocení specifickým expertem

Jsou zvolena přísná nastavení prahových intenzit $I_1 = 200$ ($P_1 = 78 \%$), $I_2 = 250$ ($P_2 = 98 \%$).



a) Snímek sloučený z dílčích vyhodnocení

b) Výsledek podmíněného prahování

Snímek 14 Podmíněné prahování sloučeného výsledku

5 URČENÍ TVARU PROUDU VIZUALIZOVANÉHO HELIOVÝMI BUBLINAMI

Postup bude sestávat ze dvou kroků, a to vyhledání bublin a odvození tvaru dle jejich poloh.

5.1 DETEKCE HELIOVÝCH BUBLIN NÁLEŽÍCÍCH PROUDU

Účelem tohoto kroku bude označení bublin v proudu a jejich zjednodušení na body. Výzkum se soustředí na snímky prvního typu. Díky rozlišitelnosti bublin a okolí lze s využitím prahování rozdělit pixely na pixely bublin a pixely okolí.

5.1.1 Výběr reprezentantů heliových bublin

Výsledkem detekce bude seznam bodů, které představují potenciální heliové bubliny. Bublina je obecně spojitá oblast z více pixelů. Postupuje se přes všechny pixely snímku. Jakmile je nalezen pixel bubliny, jsou vyhledány ostatní pixely dotyčné bubliny rekursivním prohledáváním okolí prvního pixelu.

Po nalezení všech pixelů bubliny je z nich vybrán jeden, který ji bude reprezentovat. Protože jsou bubliny malé, nehraje jeho výběr takovou roli. Potíží jsou oblasti, kde je velký shluk bublin (například v okolí vyústky). Tyto bubliny jsou tak rekursivním algoritmem pojaty za jediný shluk, neboť je od sebe neoddělují pixely okolí. Shluky lze rozdělit na bubliny využitím toho, že čím blíže středu bubliny se pixel nachází, tím větší je rozdíl jeho barvy od barvy okolí.




Snímek 15 Shluk dvou bublin – detail

Reprezentantem bubliny tedy bude každý pixel bubliny s lokálně extrémní světelnou intenzitou. Reprezentanty lze určit přímo při prvotním prohledávání snímku. Pixel je reprezentantem bubliny, pokud splňuje obě tyto podmínky:


1. Barva pixelu odpovídá dle zvoleného prahu bublině
2. V okolí pixelu není jiný, jehož příslušná barevná složka by od prahu byla vzdálena více.



a) Zdrojový snímek



b) Reprezentanti shluků bublin




c) Reprezentanti jednotlivých bublin

Snímek 16 Výběr reprezentantů bublin v okolí kolem vyústky

Možnost dělit barevné shluky na jednotlivé bubliny však nemusí být vždy žádoucí. O tvaru proudnice lze rozhodovat také jen dle reprezentantů shluků, čímž se ušetří čas vyhodnocení na úkor přesnosti.

5.1.2 Separace neplatných reprezentantů

Ne všichni reprezentanti proudu skutečně náleží. Osamocená bublina mimo proud může velmi ovlivnit výsledný tvar proudnice. Při práci se sekvencí by bylo možné považovat za bubliny proudu pouze ty, které výrazně změnily polohu. Je-li k dispozici jen jediný snímek proudění, lze využít toho, že bubliny nelétají osamoceně. Pokud bublina náleží proudu, v jejím okolí se budou vyskytovat další, které vyústku opustily v podobném čase a podobným směrem. Prvním krokem separace neplatných reprezentantů je sestrojení minimální kostry grafu těchto reprezentantů.



Snímek 17 Minimální kostra grafu reprezentantů shluků heliových bublin


Poznámka: Zelené úsečky nesplňují podmínku velikosti.

Kostra grafu bude použita ke statistickému vyhodnocení, pomocí něhož bude určeno, zda není bublina či více bublin příliš vzdálených od ostatních. Každá úsečka kostry grafu může dosáhnout jen specifické velikosti, která je odvozená

ze vzdálenosti od počátku, z průměrné velikosti úseček kostry a z dalších parametrů. Pokud mezní podmínku překročí, je neplatná a z kostry je vyjmuta. Ze subgrafů rozdělené kostry bude ponechán ten, který obsahuje počátek proudění.

5.1.3 Seřazení množiny reprezentantů


Pro účely této práce je však výhodné provést seřazení reprezentantů, a to dle vzdálenosti kolmice na hlavní směr proudu (která je obsahuje) od počátku proudu.



Snímek 18 Reprezentanti R_i seřazení dle vzdálenosti jim příslušících přímk q_i od počátku proudění


5.2 URČENÍ KONVEXNÍ OBÁLKY PROUDNICE

Obálkou proudnice se rozumí obálka, která ohraničuje oblast, v níž se nachází všichni reprezentanti. Pokud je taková obálka konvexní, pak všechny její vnitřní úhly jsou konvexní ($< \pi$). 4. Problém řeší postup Jarvis scan (Jarvis, 1973).



Snímek 19 Princip tvorby konvexní obálky


Snímek 20 zobrazuje detekovanou konvexní obálku ve skutečném snímku proudění heliových bublin, kdy algoritmus byl aplikován na množinu reprezentantů shluků heliových bublin.



Snímek 20 **Konvexní obálka reprezentantů shluků heliových bublin**

5.3 NEKONVEXNÍ OBÁLKA PROUDNICE

Snímek 21 zachycuje porovnání konvexní a nekonvexní hranice téže množiny reprezentantů. Z něj je patrné, že nekonvexní obálka zachycuje proudění věrněji právě proto, že ji neomezuje podmínka konvexnosti oblasti. Exaktní postupy sestrojení nekonvexní obálky mohou být velmi obtížně definovatelné, a nezaručují kvalitní výslednou hranici, protože ji nehodnotí jako celek. Základní otázkou zůstává, jaké body do hranice zahrnout, aby byla co nejvěrohodnější.



Snímek 21 Porovnání konvexní a nekonvexní hranice


5.3.1 Použití genetického algoritmu při konstrukci nekonvexní obálky

Každý jedinec v populaci bude představovat jedno konkrétní řešení ohraničení pole reprezentantů. Pole reprezentantů R_0-R_n je neměnné (seřazené dle kapitoly 5.1.3). Velikost chromozomu odpovídá velikosti pole reprezentantů. Geny chromozomu obsahují hodnotu 1 (reprezentant je v hranici) či 0 (reprezentant hranici nenáleží).

Kombinací hranic vznikají mj. jedinci, kteří mají dobré vlastnosti svých rodičů. Dobrá vlastnost v tomto případě znamená prezenci konkrétního reprezentanta či skupiny reprezentantů v hranici. Hraniční reprezentanty je nutné seřadit tak, aby jejich postupný průchod vytvořil hranici.

5.3.2 Sestrojení hranice dle genotypu

K jednotlivým reprezentantům se přistupuje postupně, jak jsou seřazené z kapitoly 5.1.3. Reprezentanti s příslušnou hodnotou genu 1 budou přiřazováni do hranice. V inicializační fázi jsou první dva reprezentanti spojeni hraniční úsečkou. Oba body jsou označeny jako koncové body dosavadní hranice Q_0 a Q_1 . Pro každého následujícího reprezentanta hranice je pak rozhodováno, zda má být úsečkou spojen s bodem Q_0 (a stát se tak novým koncovým bodem Q_0), nebo s bodem Q_1 (a stát se tak novým koncovým bodem Q_1). Rozhodnutí se vykoná za pomoci „rozhodovací geometrické konstrukce“.



a) Geometrická konstrukce pro koncový bod Q_0

b) Geometrická konstrukce pro koncový bod Q_1

Snímek 22 Volba konce pro připojení vyšetřovaného bodu

Principem konstrukce je sestavení přímky p_i dané jedním z konců a vyšetřovaným bodem a následné poloroviny, dané dotýcnou přímkou a druhým z konců. Přímka, jejíž polorovina obsahuje větší počet nezařazených reprezentantů, je platná. Na snímku 22 se tak bod R_2 se úsečkou spojí s bodem Q_0 a sám se stane novým koncovým bodem Q_0 .

Výhodou algoritmu rozhodovací geometrické konstrukce je rychlost seřazení hranice. Nevýhodou může být postupné řazení bodů, díky němuž nemůže hranice obsahovat lokálně návratové úsečky.

5.3.3 Fitness funkce

Je třeba zúžit kritéria výpočtu fitness hodnoty na nejnútnejší a nejméně náročná na dobu evaluace.

Počet bodů vně obálky

Z platných reprezentantů stačí kontrolovat ty, které mají hodnotu genu 0. Každý reprezentant vně hranice snižuje kvalitu hranice. Pokud existuje cesta od bodu k hranici snímku, pak bod leží vně obálky. Díky absenci návratové úsečky stačí kontrolovat čtyřmi přímými směry: ve směru proudu, proti směru proudu a dvěma směry kolmými na směr proudu.

Plynulost hranice

Hranice je souborem úseček. Zlomky mezi úsečkami by však neměly být ostré. Hranice by však měla pojímat co nejvíce bodů, aby působila věrohodně. Obě kritéria lze spojit v jedno kontrolováním průměrné změny úhlu hranice.

Sestavení funkčního předpisu


Ohraničená oblast by měla obsahovat všechny reprezentanty bublin. Není však vhodné tento faktor zcela upřednostnit. Mohou existovat varianty, kdy je plynulost hranice v jedné části velmi kvalitní. V jiné části hranice však mohou existovat reprezentanti, které obálka nepojmula. Testováním bylo nalezeno kompromisní nastavení obou faktorů:

$$F_i = k_0 + \frac{1}{k_1 \cdot \frac{o}{n} + k_2 \cdot \ln\left(\frac{\sum e^{\varphi_i}}{\sum i}\right)} \quad (5.1)$$


o – počet bodů vně hranice; n – počet všech bodů; $\sum i$ – počet bodů hranice; $k_0 = 0.1$ – minimální fitness hodnota, aby měli i nekvalitní jedinci šanci se křížit; $k_1 = 12$ – faktor postihující kritérium počtu bodů vně oblasti; $k_2 = 2.2$ – faktor postihující kritérium plynulosti hranice

5.3.4 Průběh genetického algoritmu

Algoritmus je testován pro náhodné množiny bodů. 120 bodů je přibližný počet reprezentantů ve snímku 33a.




a) Náhodných 60 bodů



b) Náhodných 120 bodů

Snímek 23 Výsledek genetického algoritmu pro 60 bodů



Snímek 24 Výsledek genetického algoritmu pro reálný snímek

6 URČENÍ RYCHLOSTI PROUDU VIZUALIZOVANÉHO MLHOU

Pro účel určení rychlosti proudu ve snímcích prvního typu existuje postup, využívající vzájemnou korelaci. Lze jej použít pro vizualizaci spojitými látkami i pro vizualizaci hustým proudem částic.

6.1 PRINCIP POUŽITÍ VZÁJEMNÉ KORELACE

Sledováním změny polohy nuancí mlhy je možné vyvozovat rychlost proudění v konkrétním místě. Pro určení rychlosti v konkrétním bodě Q je třeba sledovat jeho blízké okolí. Vektor změny polohy je určován ve dvojici po sobě jdoucích snímcích S^0 a S^1 . Díky známé časové diferenci je poté z tohoto vektoru vypočítána konkrétní rychlost. V prvním snímku S^0 je kolem bodu Q stanovena oblast. V následujícím snímku S^1 je pak v okolí tato oblast vyhledávána.

Existuje více možností, jak realizovat samotné porovnání vyšetřované oblasti ve snímku S^0 a uvažované oblasti ve snímku S^1 . V této práci probíhá toto porovnání násobením jasů pixelů o stejných relativních souřadnicích a sčítáním těchto součinů. Totéž je pak vykonáno i s inverzními hodnotami pixelů. Tím je získáno ohodnocení oblasti $Eval$. Oblast, která má ze všech oblastí největší hodnotu tohoto ohodnocení, je prohlášena za následovníka vyšetřované oblasti.

6.2 VEKTOROVÁ MAPA

Dosažené poznatky lze využít pro sestavení tzv. **vektorové mapy**. Jedná se o síť bodů, vzdálených od sebe o konkrétní konstantní vzdálenost g , pro které je určena rychlost využitím vzájemné korelace.



Snímek 25 Příklad vektorové mapy

Poznámka: Vedle vzájemné korelace lze rovněž v určité oblasti určit všechny možné vektory rychlosti, tedy z každé částice ze snímku S^0 do každé částice ve snímku S^1 (v určené oblasti). Z množiny vektorů je pak vybrán nejčtetnější.

7 URČENÍ RYCHLOSTI PROUDU VIZUALIZOVANÉHO HELIOVÝMI BUBLINAMI

Algoritmus vzájemné korelace je použitelný i na husté proudy částic. Oblasti s malým množstvím bublin však korelace odhaluje chybně. Úskalím je i práce ve 2D, kdy se v místech o podobných souřadnicích X a Y vyskytují bubliny s různými rychlostmi. To je způsobeno jejich různou polohou ve směru osy Z .

7.1 SLEDOVÁNÍ ČÁSTIC

Pokud se směr proudění pokouší určit člověk, podvědomě dokáže řešit problém vzájemnou korelací. Pokud je však bublin obecně málo, přechází řešení na sledování jednotlivých bublin. Ke správnému fungování algoritmu pro základní

snímek S^0 je zapotřebí ještě dvou dalších po něm následujících snímků S^1 a S^2 (konstantní malá časová diference). Snímek S^0 bude generátorem bublin. Snímek S^1 bude generátorem cest. Snímek S^2 bude hodnotitelem cest.

7.1.1 Inicializace procesu

Ve všech zmíněných snímcích bude na bubliny nahlíženo jako na body reprezentované reprezentanty. Není nutné separovat neplatné reprezentanty. Že je dotyčná bublina neplatná, bude zřejmé díky dalším snímkům, v nichž bude její poloha neměnná. Výsledkem inicializační fáze jsou tak tři množiny reprezentantů M^0 , M^1 , M^2 .

7.1.2 Generování možných cest

Množina M^0 obsahuje reprezentanty, jejichž pohyb má být sledován. Snímek S^1 bude definovat možné cesty, kterými se tyto bubliny mohly vydat. Je dán reprezentant R^0_i množiny M^0 o souřadnicích $[X^0_i, Y^0_i]$. Je nutné najít jeho polohu ve snímku S^1 , v množině reprezentantů M^1 . Správný reprezentant R^1_j je očekáván v okolí polohy bodu R^0_i tedy v blízkosti $[X^0_i, Y^0_i]$. Proto je vytipováno u reprezentantů množiny M^1 , které jsou souřadnicí $[X^1_j, Y^1_j]$ nejbližší. Počet u je nutné zvolit tak, aby bylo jisté, že se mezi vybranými nachází správný reprezentant – reprezentant téže bubliny ve snímku S^1 .

V práci bylo číslo u voleno pro husté proudy 10, pro méně husté 5.


7.1.3 Rozvíjení cesty

Pro každého reprezentanta R^0_i snímku S^0 je k dispozici u pozic, v nichž by se mohl nacházet ve snímku S^1 . Existuje tedy u cest, kterými se mohla bublina vydat. Každou takovou cestu je nutno prověřit, zda je cestou, kterou bublina skutečně putuje. Pokud se bublina dostala z bodu $[X^0_i, Y^0_i]$ daného reprezentantem R^0_i do bodu $[X^1_j, Y^1_j]$ daného reprezentantem R^1_j , ideálně by tak tutéž změnu polohy měla vykonat během mezi snímkem S^1 a S^2 . Ve snímku S^2 bude tedy očekáván reprezentant v blízkosti bodu $R^{1'}_j [X^{1'}_j, Y^{1'}_j]$, kde

$$X^{1'}_j = X_{1j} + (X_{1j} - X_{0i}) = 2 \cdot X_{1j} - X_{0i} \quad (7.1)$$

$$Y^{1'}_j = Y_{1j} + (Y_{1j} - Y_{0i}) = 2 \cdot Y_{1j} - Y_{0i} \quad (7.2)$$

Je třeba hledat v okolí bodu $R^{1'}_j$ reprezentanty z množiny M^2 . V tomto případě je třeba vykonat podobný úkol jako v kapitole 7.1.2, tedy zvolit počet reprezentantů v , kteří by mohli odpovídat poloze reprezentanta R^0_i ve snímku S^2 . V práci je pro obě vyhledávání použitý konkrétní počet nejbližších bodů $v = u = 5$ (případně 10). V tomto kroku tedy bylo ke každé z u cest určeno v možných pokračování cest.




Snímek 26 Ilustrace generování cest pro bod R^0_0 snímku S^0 pro $u = v = 3$.

7.1.4 Ohodnocení cest

Výstupem předchozího kroku je $u \times v$ cest pro každého reprezentanta množiny M^0 , z nichž je právě jedna platná. Každou cestu je proto nutné ohodnotit, přičemž nej kvalitnější cesta bude prohlášena za platnou. Pokud bude platit cesta $R^0_i R^1_j R^2_k$, pak hledaným vektorem rychlosti v bodě R^0_i je $R^0_i R^1_j$. Pokud je časová difference dt malá, pak lze očekávat, že by změna $R^0_i R^1_j$ a $R^1_j R^2_k$ měly být velmi podobné (ostatně je to předpokladem celé metody). Proto je cesta ohodnocena kritérii: změna rychlosti, změna směru, změna velikost bubliny, vzdálenost následovníka. Celkové ohodnocení cesty f_p pak spočívá v sečtení zmíněných faktorů vynásobených příslušnými váhovými koeficienty.

$$f_p = k_v \cdot f_v + k_\varphi \cdot f_\varphi + k_C \cdot f_C + k_d \cdot f_d \quad (7.3)$$

Pro snímek 27 byly použity váhové koeficienty: $k_v = 0.5$; $k_\varphi = 1$; $k_C = 0.1$; $k_d = 0.2$. Detekované vektory rychlostí jsou znázorněné červeně. Zeleně jsou pak následující úsečky v cestách (mezi polohami bublin ve snímku S^1 a S^2).



Snímek 27 Výsledek detekce vektorů rychlosti, kde: červeně jsou označeny detekované vektory, zeleně pokračování v cestě

7.2 ZPRACOVÁNÍ DETEKOVANÝCH VEKTORŮ

Z uvedeného testování plyne, že cca 8 % bublin má chybně určenou rychlost. Výsledky jsou i tak použitelné pro další zpracování. Lze však provést mezikrok a jejich vhodnou interpretací chyby korigovat.

7.2.1 Porovnávání okolních vektorů

Pokud má jedna z bublin výrazně vyšší nebo výrazně nižší rychlost než všechny ostatní (neexistuje žádná, která by měla podobnou rychlost), pak vektor rychlosti označíme za chybný.

7.2.2 Mazání kolizních vektorů

Jsou porovnávány vektory dvou různých bublin. Pokud je dle polohy reprezentantů a změny polohy vypočítáno, že bubliny se budou v následujícím snímku nacházet v téže pozici, došlo by ke kolizi. Pro obě různé bubliny byl vybrán stejný následovník, tedy alespoň v jednom případě byl vybrán chybně. Zpracovat takový stav lze následovně:


- a) Vyloučení obou bublin a jejich vektorů ze zpracování
- b) Přisouzení průměru vektorů oběma reprezentantům
- c) Vymazání chybného vektoru (dle vektorů okolí)

7.3 VEKTOROVÁ MAPA


Následujícím úkolem je určit rychlost proudění v libovolném bodě, což bude využito ke konstrukci vektorové mapy. Člověk dokáže předpokládat přibližnou rychlost proudění v konkrétním bodě v závislosti na blízkých známých vektorech. Stejnou schopnost lze požadovat i po umělé neuronové síti *MLP*.

7.3.1 Výběr vektorů k učení

Člověk se při odhadu rychlosti v konkrétním bodě neřídí všemi dostupnými vektory, ale odhaduje ji na základě pouze několika nejbližších. Prvním úkolem metody je tedy výběr bublin, na základě kterých se bude neuronová síť rozhodovat. Bublin nemusí být mnoho, ale musí být dostatečně vypovídající. Příklad nevhodně vybraných bublin je na snímku 28a - Není jisté, jak se mění rychlost od vybraných bublin směrem k bodu *X*, neboť není známo, jak rychlost vypadá za bodem *X*. Snímek 28b naproti tomu zachycuje vhodně vybranou hranici. Trojúhelník, jehož vrcholy *ABC* tvoří reprezentanti vybraných bublin, obsahuje vyšetřovaný bod *X*. Lze říci, že rychlost je možné správně odvodit ve všech bodech uvnitř dotyčného trojúhelníka.



a) Nevhodně vybrané bubliny



b) Vhodně vybrané bubliny

Snímek 28 Výběr bublin pro učení dotyčných vektorů

Existuje sofistikovaný algoritmus hledání nejvhodnějšího trojúhelníka bodu *X* dle okolní bodů. Pokud vhodný trojúhelník neexistuje, rychlost proudění v bodě *X* je nulová.

7.3.2 Nastavení neuronové sítě k určení rychlosti v konkrétním bodě

Jako vhodná síť v tomto případě poslouží opět *MLP*, přičemž výstupní hodnotou jejích neuronů bude reálné číslo v intervalu $\langle 0, 1 \rangle$. Síť bude rozhodovat o vektoru rychlosti v konkrétním bodě.

Transformace souřadnic bodu

Pro lepší citlivost vstupů je vhodné transformovat souřadnice poloh známých vektorů rychlosti:

- a) **Nejmenší obdélník** – Souřadnice $[X_i, Y_i]$ *i*-tého reprezentanta jsou transformovány na souřadnice $[X'_i, Y'_i]$:

$$X'_i = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad (7.4)$$

$$Y'_i = \frac{Y_i - Y_{min}}{Y_{max} - Y_{min}} \quad (7.5)$$

Totožnou transformací pak musí projít i vyšetřovaný bod, protože bude předáván síti k vyhodnocení. Všechny transformované body budou mít obě souřadnice v rozmezí $\langle 0, 1 \rangle$.

- b) **Čtverec se středem ve vyšetřovaném bodě** – Souřadnice *i*-tého reprezentanta $[X_i, Y_i]$ budou transformovány na $[X'_i, Y'_i]$ následovně:

$$X'_i = \frac{X_i - (X_x - d_{max})}{2 \cdot d_{max}} \quad (7.6)$$

$$Y'_i = \frac{Y_i - (Y_x - d_{max})}{2 \cdot d_{max}} \quad (7.7)$$

Souřadnice vyšetřovaného bodu X se transformují na $X_X = 0.5$ a $Y_X = 0.5$. Obecně budou všechny souřadnice dotčených bodů opět v rozmezí $\langle 0, 1 \rangle$.

Transformace očekávaného výsledku

Výstupem neuronové sítě budou dvě reálná čísla v intervalu $\langle 0, 1 \rangle$. Transformace souřadnic vektoru $[dX_i, dY_i]$ na transformované souřadnice $[dX'_i, dY'_i]$ probíhá podle následujících vzorců:

$$dX'_i = \frac{0.5}{C_{max}} \cdot dX_i + 0.5 \quad (7.8)$$

$$dY'_i = \frac{0.5}{C_{max}} \cdot dY_i + 0.5 \quad (7.9)$$

Hodnota C_{max} je maximální hodnota souřadnice, odvozená od velikosti největšího ze vzorových vektorů.

Zpětná transformace obdrženého výsledku

Pro získání reálných souřadnic výsledného vektoru je třeba výsledek neuronové sítě (relativní souřadnice) transformovat zpět na souřadnice absolutní:

$$dX_X = \frac{(dX'_X - 0.5) \cdot C_{max}}{0.5} \quad (7.10)$$


$$dY_X = \frac{(dY'_X - 0.5) \cdot C_{max}}{0.5} \quad (7.11)$$

Neuronová síť tedy bude mít dva vstupy a dva výstupy. Pro účely odvození vektorů postačí jediná skrytá vrstva o určitém počtu neuronů.

7.3.3 Tvorba vektorové mapy

Snímek je nutné rozdělit na čtvercové podoblasti. V prostředním bodě každé podoblasti se určí rychlost proudění:

1. Vyhledání bublin, dle jejichž rychlosti se neuronová síť bude učit
2. Transformace souřadnic reprezentantů a vektorů
3. Předání transformovaných vzorů síti + proces učení (cca 50–100 učení na vzor)
4. Předání požadovaného transformovaného bodu síti
5. Převod obdrženého výsledku zpětnou transformací na vektor



Snímek 29 Vektorová mapa dle postupu sledování částic vytvořená neuronovou sítí

8 URČENÍ VLASTNOSTÍ VENTILAČNÍHO SYSTÉMU

K nejdůležitějším vlastnostem vyústky patří úhel rozptylu proudu. Úhlem rozptylu je myšlen úhel proudu výstupního vzduchu. Tvarem proudnice je v ideálním případě kuželová plocha. Protože se pracuje s 2D snímky, pak je předpokládán tvarem výseč, tedy dvojice přímek, která svírá jistý úhel. Protože proud má omezený dosah, za ideální tvar proudu je považován rovnoramenný trojúhelník. Úhel rozptylu vyústky je pak úhel obou jeho odvěsen. Je zřejmé, že k určení úhlu rozptylu vyústky je třeba znát dvojici přímek. Ve 2D prostoru je lze nazývat „horní“ a „dolní“ přímkou.

8.1 VYŠETŘOVÁNÍ TVARU PROUDNICE V JEDINÉM SNÍMKU

Tato kapitola nastíní výpočty a odvození vybraných veličin v jediném snímku proudění.

8.1.1 Určení dosahu proudu a hraničních křivek

Efektivní možností je stanovit dosah proudu opakovaným hledáním nejvzdálenějšího bodu pro bod aktuální. Algoritmus spočívá v tom, že pro konkrétní pixel hranice P_0 (na počátku zvolen libovolně) jsou procházeny úsečky se všemi hraničními pixely. Z těch je vybrán pixel P_1 , který je od pixelu P_0 nejdále. Pro dosažený pixel P_1 je pak hledán stejným způsobem pixel P_2 . Algoritmus končí v případě, že nová úsečka (P_i, P_{i+1}) není delší než předchozí (P_{i-1}, P_i).

Dosah proudu může být přibližně určen také ze známé polohy vyústky (stává se bodem P_A) a z nejvzdálenějšího bodu vektorové mapy (stává se bodem P_B), který má zvolenou dostatečně velkou rychlost.

Úsečka P_AP_B púlí proud na dvě podoblasti a lze ji připodobnit k výšce náležící základně trojúhelníku ideální proudnice. Úsečka rozděluje hranici na dvě části. V následujícím textu bude uvažován horizontální směr proudění, které bylo snímáno z boku. Proto budou získané části hranice označovány jako horní a dolní hraniční křivka.

8.1.2 Určení polohy vyústky

Pokud uživatel algoritmu polohu vyústky nepředá, lze ji dopočítat. Počátečním pixelem proudění P_S (pozice vyústky) je jeden z bodů P_A, P_B náležících úsečce dosahu d . K rozhodnutí, který z obou bodů budeme pokládat za počátek proudu, může posloužit několik postupů, vycházejících z ideálního tvaru proudu, tedy rovnoramenného trojúhelníku:

- Určení počátku dle kolmice** – Je hledána nejdelší úsečka uvnitř proudu kolmá na P_AP_B . Bodem P_S je stanoven ten z bodů P_A, P_B , který je od úsečky vzdálenější.
- Určení počátku dle vzdálenosti hraničních bodů** – Tento přístup tedy počítá vzdálenosti všech hraničních pixelů od P_A resp. P_B a obě hodnoty porovná. Vyšší z obou součtů náleží počátku proudění.
- Určení počátku proložením hraničních křivek** – Úsečka (P_A, P_B) rozděluje hranici na horní a dolní hraniční křivku. Obě křivky jsou proloženy přímkami (například lineární regresí pro metodu nejmenších čtverců) a je určen průnik obou přímek. Počátkem proudění je ten z pixelů P_A, P_B , který je tomuto průniku blíže.

8.1.3 Výběr reprezentantů hranice

Počátek proudění P_S byl detekovaný jako jediný pixel. V reálu je odvislý od plochy vyústky. Proto je třeba pro vyhodnocování hranice blízké okolí pixelu P_S vyloučit. Stejně tak příliš vzdálené pixely od P_S již nemusí mít vypovídající hodnotu o vlastnostech vyústky.

Prvním reprezentantem horní hranice je první pixel v pořadí, splňující podmínku minimální vzdálenosti od P_S . Každý následující reprezentant je vždy vybrán jako první, jehož vzdálenost od předchozího překoná zvolenou limitní hodnotu (a nepřekoná maximální vzdálenost od P_S). Výsledkem jsou dvě množiny reprezentantů – pro horní a dolní hranici.

8.1.4 Hraniční přímky, osa proudu a rozptyl

Horní (dolní) hraniční přímka p_H je získána lineární regresí množiny reprezentantů horní (dolní) hranice. Z matematického vyjádření obou hraničních přímek lze dále určit rozptyl vyústky a osu proudění. Ta bude procházet průsečíkem obou přímek. Její úhel sklonu je roven průměru úhlu sklonů obou hraničních přímek.

8.2 VYŠETŘOVÁNÍ TVARU PROUDNICE V SEKVENCI

Čím větší je zpracované množství snímků stejného proudění, tím více vypovídací bude souhrnný výsledek.

8.2.1 Statistické zpracování výsledků jednotlivých detekcí

Pro tento postup není důležitá časová známka snímku. Metoda se používá především ke stanovení rozptylu vyústky. Ten je nejprve určen pro každý snímek sekvence viz kapitola 8.1. Postup pro každý snímek lze zapsat těmito kroky:

1. Detekce oblasti proudnice
2. Určení horní a dolní hranice proudu (pokud není určena přímo detekcí proudnice v řezech)
3. Výběr množiny reprezentantů horní a dolní hranice
4. Aproximace reprezentantů přímkami pro horní a dolní část hranice
5. Stanovení osy proudu a rozptylu vyústky

Data z jednotlivých snímků jsou poté zpracovávána statisticky.

Statistické vyhodnocení úhlů.

Úhly představují sklon hraničních přímek a osy proudu. Při výpočtu průměrného úhlu osy v sekvenci do statistického vyhodnocení vstupují úhly sklonu osy detekované v každém snímku sekvence. Pro tento účel je vhodné převést průměrované úhly na relativní dle nejmenší výseče, která všechny tyto úhly obsáhne.


Statistické vyhodnocení přímek

Cílem tohoto statistického vyhodnocení je získání přímky, která by vhodně reprezentovala množinu přímek stejného charakteru z jednotlivých snímků. Nejčastěji je určena souhrnná přímka pro osu snímku, horní hranici a spodní hranici.

Reprezentační přímku lze určit výpočtem jejího sklonu a stanovením bodu, kterým prochází. Výpočtu sklonu se věnuje předchozí kapitola. Bod, kterým výsledná přímka prochází, je dán např. průměrováním X a Y souřadnic všech možných průniků jednotlivých přímek.

8.2.2 Sčítání detekovaných pixelů

Díky známým metodám detekce tvaru proudnice lze v jednotlivých snímcích sekvence definovat, který pixel náleží okolí (0) a který proudu (1). Je tak možné sekvenci podrobit procesu sčítání detekovaných pixelů. Pro tuto metodu zpracování sekvence snímku není nutná časová známka jednotlivých snímků. Jejím principem je tvořit z výsledků detekce proudu v jednotlivých snímcích jeden souhrnný výsledek. Pro každý pixel je napočítáváno, v kolika snímcích sekvence byl označený jako pixel proudu. Dále je stanovena hraniční hodnota Q procent. Pokud je konkrétní pixel alespoň v Q procentech snímků sekvence vyhodnocen jako pixel proudu, pak je považován za skutečný pixel proudu. Zvolená konstanta $Q > 0$ však může způsobit také nežádoucí jev, a to označení osamocených pixelů jako pixely mlhy (snímek 30a). Takovému jevu lze předejít například kombinací filtru typu dolní propust a prahování (snímek 30b).



a) Nezpracovaný



b) Po filtraci a prahování

Snímek 30 Vyhlazení nespojitého výsledku sčítání pixelů

8.3 VYHODNOCENÍ RYCHLOSTI

Vektorová mapa (kapitoly 6.2 a 7.3) poslouží jako základ pro následující metody.

8.3.1 Validace vektorové mapy

Nenulový vektor rychlosti ve vektorové mapě může být platný pouze tehdy, pokud jeho bod leží uvnitř proudnice. V opačném případě je dotyčnému bodu namísto detekovaného vektoru přiřazen vektor $[0, 0]$.

8.3.2 Filtrace vektorové mapy

Vektorové filtry pracují podobně jako filtry obrazové, pouze s tím rozdílem, že filtrují zvlášť každou souřadnici. Vektorová filtrace přináší podobný efekt jako filtrace obrazová. Například filtrace typu dolní propust pohlcuje případné chyby a zhlazuje změny mezi vektory rychlostí blízkých bodů.

8.3.3 Zpracování rychlosti v sekvenci snímků

Podobně jako v případě vyhodnocování tvaru proudnice, může sekvence snímků sloužit i ke statistickému zpracování rychlosti. Pokud je vektorová mapa tvořena pro n snímků sekvence, a to ve stejných bodech snímku, pak každý tento bod může výslednou rychlost vyvodit z rychlostí v jednotlivých snímcích využitím funkce průměr, modus nebo medián. Při tom lze vyloučit i potenciálně chybné vektory, pokud jsou příliš rozdílné od průměru či modu.

9 ZHODNOCENÍ A VÝSLEDKY PRÁCE

V této práci jsou zpracovávány snímky a záznamy (sekvence snímků) proudění vzduchu, vizualizované buď mlhou nebo heliovými bublinami. Hlavními sledovanými veličinami jsou tvar proudnice a rychlost proudění.

9.1 TVAR PROUDNICE

Pro snímky proudění vizualizovaného pomocí mlhy byly zmíněny tyto metody:

- **Prahování** – Jde o velmi rychlou a elementární metodu pro snímky prvního typu.
- **Podmíněné prahování** – Podmíněné prahování lze použít i na některé snímky druhého typu.

- **Vyšetřování proudnice v řezech** – Jedná se o metodu použitelnou pouze ve snímcích prvního typu. Velmi dobře detekuje i méně husté aditivum.
- **Základní zpracování snímku s využitím neuronové sítě** – Jedná se o metodu výborně fungující pro snímky prvního a druhého typu. Dobře funguje i pro snímek třetího typu, avšak může se stát, že za mlhu bývá označeno místo okolí barevně velmi podobné mlze (například světla a odlesky).
- **Podmíněné prahování spojitě detekce** – Detekovaná hranice proudnice je přesnější oproti předchozí metodě. I pro tuto metodu však platí, že některá místa okolí mohou být chybně označena jako mlha.
- **Metoda dvou expertů** – Tato metoda je velmi dobře účinná pro řešení chybně detekovaných oblastí ve snímku třetího typu při detekci jedinou neuronovou sítí. Rychlost procesu je dvojnásobná oproti základnímu zpracování neuronovou sítí. Další nevýhodou je komplikovanější proces učení.
- **Podmíněná detekce dvojicí expertů – Podmíněné prahování sloučeného výsledku** – Jedná se o nejlepší nalezenou metodu, použitelnou pro všechny typy snímků. Jejimi nedostatky jsou opět složitější proces učení neuronových sítí a delší procesní čas.


Pro snímky prvního typu lze obecně doporučit prahování, podmíněné prahování či vhodnou detekci proudnice v řezech. Pro snímky druhého typu je vhodné zpracování snímku neuronovou sítí (+ podmíněné prahování). Snímky třetího typu je vhodné vyhodnocovat metodou dvou expertů, popř. podmíněnou detekcí dvojicí expertů (snímek 31).



Snímek 31 Určení tvaru proudnice metodou podmíněné detekce dvojicí expertů

Snímky proudění vizualizovaného pomocí heliových bublin jsou obecně méně vhodné pro detekci tvaru proudnice.

- **Konvexní obálka** – Pro účely detekce tvaru proudnice je tato metoda nedostatečná. Lze ji použít pouze omezeně na malé množství bublin blízko výústky.
- **Nekonvexní obálka s využitím genetických algoritmů** – Tato metoda generuje kvalitativně velmi podobnou obálku, jako metoda vyšetřování proudnice v řezech.




Snímek 32 Nekonvexní ohraničení bodů s využitím genetických algoritmů (50 bodů)


9.2 RYCHLOSTI PROUDĚNÍ

V této práci jsou zmíněny dvě metody pro vyhodnocení rychlosti proudění v libovolném bodě, které se tak hodí i k sestrojení vektorové mapy:

- **Použití vzájemné korelace** – Jde o metodu pro sekvence prvního typu, která je vhodná pro proudy vizualizované látkami tvořícími souvislá vlákna. Použitelná je i pro vizualizaci částicemi, pokud je jejich hustota v proudu dostatečně velká. Tato práce metodu však rozšiřuje o některá vylepšení.
- **Sledování částic** – Pokud je proudění vizualizováno látkami tvořícími souvislá vlákna a pokud je hustota těchto částic v proudu malá, je vhodné použít metodu sledování částic. V rámci této metody pak o vektoru rychlosti v konkrétním bodě rozhoduje neuronová síť. Metoda operuje s konkrétními bublinami, tedy pokud bude existovat metoda na detekci bublin ve snímcích druhého či třetího typu, je metoda použitelná i pro ně.



Snímek 33 Vektorová mapa vytvořená použitím vzájemné korelace



Snímek 34 Vektorová mapa vytvořená metodou sledování částic

10 ZÁVĚR

Při návrhu ventilačního systému hrají významnou roli metody vizualizace proudění. Ty pomáhají vykreslovat proudnici, aby bylo patrné, jak se vzduch vycházející z vyústky systému šíří v místnosti. Tato práce se zabývá možnostmi, jak snímky či záznamy proudění takto vizualizovaného vzduchu počítačově zpracovat.

Práce se soustředí na dva typy vizualizačních metod. Prvním typem je vizualizace látkami tvořícími souvislá vlákna. Takovými látkami mohou být například mlha či kouř. Dalším typem je vizualizace látkami, které netvoří souvislá vlákna, ale částice. Konkrétně jsou v práci vyhodnocovány snímky proudění vzduchu vizualizované heliovými bublinami. Obdobnými aditivy mohou být například saze nebo jiskry. Hlavními veličinami, které jsou v práci určovány, jsou tvar proudnice a rychlost proudění. Z těchto dat jsou pak definovány další charakteristiky proudění a celého ventilačního systému. Cílem přitom bylo, aby pro obě zmíněné vizualizační metody existovaly postupy, jak z nich požadované veličiny určit.

Snímky a záznamy proudění vzduchu však mohou mít různou složitost podle toho, jak v nich je aditivum patrné a rozlišitelné. Některé záznamy jsou pořízené v laboratorních podmínkách s homogenním pozadím s výrazně odlišnou barvou, než je barva aditiva (tzv. snímky prvního typu). Záznamy, pro jejichž pořízení již nebyly aranžovány vhodné podmínky (tzv. snímky druhého typu), mohou mít méně vhodné pozadí a aditivum již zde není tak patrné. Snímky třetího typu mohou obsahovat velké množství rušivých prvků a zcela nevhodné pozadí, s nímž barva aditiva mnohdy splyne. Práce se tak zabývá i těmito typy snímků.

10.1 VĚDECKÝ PŘÍNOS PRÁCE

První část práce je věnována preprocessingovým úpravám snímku, vhodným pro účely detekce proudnice či rychlosti proudění. Byl vyvinut hranový detektor, pracující na principu nelineární filtrace.

Velká část práce je věnována detektorům využívajícím neuronové sítě. Ty slouží právě k detekci mlhy a pomáhají při určování hranice proudnice. Základní princip je pak doplňován o alternativy a vylepšení, aby výsledný algoritmus dokázal řešit i detekci hranice v nejsložitějších snímcích třetího typu. V rámci této kapitoly byly tyto detektory testovány

i na detekci dalších objektů a bylo ověřeno, že jsou velmi vhodné na detekci vzorů, textur a barev. Poslouží tak například k detekci trávy, dřeva či objektů se zřejmou texturou (koberec, stůl, strom...).

V další kapitole je řešena detekce tvaru proudnice vizualizované heliovými bublinami. K sestrojení obecně nekonvexní hranice slouží genetický algoritmus, v rámci něhož se hranice vyvíjí. Dílčím cílem této kapitoly je, aby takto detekovaná hranice byla kvalitativně srovnatelná s hranicemi detekovanými ze snímků proudění mlhy. Postupem bylo dosaženo ohraničení heliových bublin, vhodné pro další zpracování matematickými postupy k určení charakteristik ventilačního systému. Princip algoritmu však není využitelný pouze pro ohraničení proudu heliových bublin, ale lze ho použít i na nekonvexní ohraničení jakékoliv množiny bodů.

Metoda vzájemné korelace, využitelná pro detekci rychlosti proudění, byla doplněna o drobná vylepšení.

Alternativou pro vzájemnou korelaci ve snímcích proudu heliových bublin je metoda sledování částic doplněná o rozhodovací proces, při němž neuronová síť určuje vektor rychlosti v libovolném bodě na základě již známých blízkých vektorů rychlosti.

10.2 PRAKTICKÝ PŘÍNOS PRÁCE

V rámci výzkumu byl vyvíjen komplexní software Interfer, který obsahuje metody zmiňované v této práci. Software byl využíván ve dvou projektech při vývoji ventilačních systému pro nízkoenergetický dům i pro osobní automobil. Software tak umožňuje zpracovávat snímky i záznamy proudění vzduchu obou typů vizualizace. Pomocí něj lze detekovat tvar proudnice i rychlosti proudění a data lze následně vyhodnocovat.

Byla vyvinuta řada metod pro evaluaci tvaru proudnice vizualizované mlhou. Pro jednoduché typy snímků jsou využitelné různé typy prahování či detekce proudnice v řezech. Pro snímky druhého a třetího typu je již vhodnější využít neuronových sítí a komplexnějších postupů zmíněných v práci.

Pro určení tvaru proudnice vizualizované heliovými bublinami byl implementován postup tvorby konvexní hranice. Především však byla vyvinuta komplexní metoda pro sestrojení nekonvexní hranice.

Pro určení rychlostí proudění byl implementován postup využívající vzájemné korelace. Pro specifické ne příliš husté proudy částic byla vyvinuta metoda sledování částic a na ni navazující metoda vytvoření vektorové mapy.

Další metody, obsažené ve vyvinutém softwaru, slouží ke statistickému vyhodnocení detekovaných výsledků.

V neposlední řadě je software vhodný k preprocessingovým operacím a k obecným úpravám snímků i sekvencí.

11 SEZNAM POUŽITÉ LITERATURY

- ABRAMOWITZ, M., STEGUN, I.A. Handbook of Mathematical Functions, Applied Mathematics, Series, Volume 55, 1964.
- BASSIOU, N., KOTROPOULOS, C.: *Color image histogram equalization by absolute discounting back-off*, Computer Vision and Image Understanding, vol. 107, no. 1-2, pp.108-122, Jul.-Aug. 2007.
- BRACEWELL, R.: *Pentagram Notation for Cross Correlation*. The Fourier Transform and Its Applications. New York: McGraw-Hill, pp. 46 and 243, 1965.
- CALETKA, P., O. PECH, J. JEDELSKÝ, M. JÍCHA a RICHTER, J.: *Comparison of Methods for Determination of Borders of Stream Visualized by Smoke Method*. In: 34th Conference of Departments of Fluids Mechanics and Thermomechanics Proceedings of Extended Abstracts. Ústí nad Labem: University J. E. Purkyně in Ústí nad Labem. 2015. 11-12. ISBN: 9788074149122.
- CANNY, J., a *Computational Approach To Edge Detection*, IEEE Trans. Pattern Analysis and Machine Intelligence, 8(6):679–698, 1986.
- CERMAK, J. E.: *Wind-tunnel development and trends in applications to civil engineering*, Journal of Wind Engineering and Industrial Aerodynamics, Volume 91, Issue 3, February 2003, Pages 355-370, ISSN 0167-6105
- DERICHE R., *Using Canny's criteria to derive a recursively implemented optimal edge detector*, Int. J. Computer Vision, Vol. 1, pp. 167–187, April 1987.
- FOJTLÍN, M.; FIŠER, J.: *Tepelný manekýn – možnosti testovania ochraných prostriedkov*, Hazmat protect - sborník konference, pp.1-6, ISBN 978-80-270-0474-4, 2016, SÚJCHBO, v.v.i.
- FREEDMAN, D. A.: *Statistical Models: Theory and Practice*, Cambridge University Press, 2005.
- GALER, M.; HORVAT, L. *Digital Imaging: Essential Skills*. Focal Press, 2003. ISBN 978-0-240-51913-5.
- GONZALES, R. C., WOODS, R.E.: *Digital Image Processing*, Prentice Hall, 2008.
- HAGAN, Martin T. *Neural network design*. USA: PWS, 1996. 734 s. ISBN 7-111-10841-8.
- HARIHARAN, P.: *Basics of Interferometry*. Elsevier Inc. 2007, ISBN 0-12-373589-0.
- HYNEK, J.: *Genetické algoritmy a genetické programování* Grada: Praha 2008
- CHERITION, D., TARJAN, R. E.: *Finding minimum spanning trees*. In: SIAM Journal of Computing, 5 (Dec. 1976), pp. 724–741
- INTERNATIONAL TELECOMMUNICATION UNION. *Norma BT.709-6: Parameter values for the HDTV standards for production and international programme exchange* [online]. ©2015 [cit. 2018-3-22]. Dostupná z: <http://www.itu.int/rec/R-REC-BT.709-6-201506-I>.
- JANOTKOVÁ, E.: *Technika prostředí*. Brno: VUTUM, 1991, 201 s. ISBN 802140258X.
- JANOTKOVÁ, E.; PAVELEK, M. a kol.: *Použití vizualizačních metod pro sledování proudění vzduchu ve větráných a vytápěných prostorech*, Vytápění, větrání, instalace, Vol.19, 2010, No.5, pp.229-233, ISSN 1210-1389, Společnost pro techniku prostředí články v časopise
- JARNÍK, V.: *O jistém problému minimálním*, Práce Moravské Přírodovědecké Společnosti, 6, 1930.
- JARVIS, R. A.: *On the identification of the convex hull of a finite set of points in the plane*. Information Processing Letters. 2, 1973, pages 18–21. doi:10.1016/0020-0190(73)90020-3
- JIANG, N., WANG, J., MU, Y.: *Quantum image scaling up based on nearest-neighbor interpolation with integer scaling ratio*, Quantum Information Processing, November 2015, Volume 14, Issue 11, pp 4001–4026
- KAPINCHEV, K., BRADU, A., BARNES, F., PODOLEANU, A.: *GPU Implementation of Cross-Correlation for Image Generation in Real Time*. 2015. ICSPCS 2015. doi:10.1109/ICSPCS.2015.7391783.
- KEATING, T. J., WOLF, P. R., SCARPACE, F. L.: *An Improved Method of Digital Image Correlation*, Photogrammetric Engineering and Remote Sensing 41(8): 993–1002, 1975.
- KHARE, C., NAGWANSHI, K. K.: *Image Restoration Technique with Non Linear Filter*, International Journal of Advanced Science and Technology, Vol. 39, February, 2012.

- KOZA, J. R.: *Genetic Programming: On the Programming of Computers by Means of Natural Selection*. The MIT Press, 1992, ISBN 0-262-11170-5.
- LÍZAL, F.; JEDELSKÝ, J.; JÍCHA, M.; HAPALA, R.: *Rychlostní pole v okolí vyústky pro odmrazování a odmílžování čelního skla osobního automobilu*, Vytápění, větrání, instalace, Vol.25, 2016, No.4, pp.190-196, ISSN 1210-1389, Society of Environmental Engineering
- LÝSEK, J., ŠŤASTNÝ, J., MOTYČKA, A. *Object Recognition by Means of Evolved Detector and Classifier Program*. In MENDEL 2012, 18th International Conference on Soft Computing. Brno University of Technology, 2012, p. 82-87. ISBN 978-80-214-4540-6.
- MCCULLOCH, W., PITTS, W.: *a logical calculus of the ideas immanent in nervous activity*. Bulletin of Mathematical Biophysics, 5:115–133, 1943.
- MERZKIRCH, W.: *Flow visualization*. New York: Academic Press, 1987. ISBN 0-12-491351-2.
- MITCHELL, M.: *An Introduction to Genetic Algorithms*. Cambridge, MA: MIT Press 1996
- PAVELEK, M., JANOTKOVÁ, E., ŠTĚTINA, J.: *Visualization and optical measuring methods*. FSI VUT, Brno 2001
- POKORNÝ, J.; POLÁČEK, F.; FOJTLÍN, M.; FÍŠER, J.; JÍCHA, M.: *Measurement of airflow and pressure characteristics of a fan built in a car ventilation system*, EPJ Web of Conferences, Vol.114, (2016), No.2016, pp.644-647, ISSN 2100-014X, EDP Sciences - Experimental fluid mechanics 2015, Praha, 17.11.2015-20.11.2015
- RAFFEL, M. a col: *Particle Image Velocimetry* Springer 2007, ISBN 978-3-540-72307-3 Second Edition Springer Berlin Heidelberg New York
- RICHTER, J., ŠŤASTNÝ, J., *Evaluation of centres of stripes in the interferogram image*. In International Conference AICT 2011, Recent Research in Applied Informatics. Prague, Czech republic, 2011. pp. 125-130. ISBN 978-1-61804-034-3.
- RICHTER, J., ŠŤASTNÝ, J.: *Fog Border Detection in the Airflow Image*. In Advances in Computer Science. Proceedings of the 6th WSEAS European Computing Conference ECC'12. Prague, Czech Republic 2012, pp. 134-139, ISBN 978-1-61804-126-5.
- RICHTER, J., ŠŤASTNÝ, J., JEDELSKÝ, J. *Estimations of Shape and Direction of an Air Jet Using Neural Networks*. In MENDEL 2013, 19th International Conference on Soft Computing. Brno University of Technology, 2013, p. 221-226. ISBN 978-80-214-4755-4.
- SUTTON, M. A., ORTEU, J. J., SCHREIER, H.: *Image Correlation for Shape, Motion and Deformation Measurements*, Hardcover, 2009, ISBN 978-0-387-78746-6.
- ŠKORPIL, V., RICHTER, J., ŠŤASTNÝ, J., LÝSEK, J., SZÖCZ, J.: *Computer Analysis of Airflow Images Visualized by Smoke*. In International Conference CSCC 2012, Recent Researches in Communication and Computers. Kos Island, Greece, 2012. pp. 89-94. ISBN 978-1-61804-109-8.
- ŠŤASTNÝ, J., RICHTER, J. *Using neural networks for determining velocity vectors of air flow visualized by helium bubbles*. Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis, 2014, vol. 62, issue 4, pages 757-768, ISSN 1211-8516, (index. Scopus).
- ŠŤASTNÝ, J., RICHTER, J.: *Adaptation of genetic algorithm to determine air jet shape of flow visualized by helium bubbles*. Journal of Aerospace Engineering, 2016, vol. 29, issue 6, pages 12, ISSN 0893-1321, (index. WoS: IF 1.107, Scopus).
- ŠŤASTNÝ, J., ŠKORPIL, V.: *Genetic Algorithm and Neural Network*. In Proceedings of the 7th WSEAS International Conference on Applied Informatics and Communications, Vouliagmeni, Greece, 2007, p. 347-351. ISSN 1790-5117. ISBN 978-960-8457-96-6.
- ZHOU, P., YE, W., WANG, Q.: *An Improved Canny Algorithm for Edge Detection*. Journal of Computational Information Systems, 2011

12 AUTOROVO CV

Osobní údaje

Ing. Jan Richter, narozen 18. srpna 1986 v Brně

Pedagogická činnost

V rámci doktorského studia na FSI VUT: Informatika, Zpracování informací, Simulace systémů

Přehled zaměstnání

2011-2014: Gatema s.r.o. – programátor SQL + Delphi

2015-doposud: SAP – programátor, analytik, softwarový architekt

Vzdělání a akademická kvalifikace

2008-2010: Magisterské studium, VUT Brno, Fakulta strojního inženýrství,

Obor aplikovaná informatika a řízení, titul Ing.

2005-2008: Bakalářské studium, VUT v Brno, Fakulta strojního inženýrství,

Obor strojní inženýrství, titul Bc.

1997-2005: Gymnázium Šlapanice

13 ABSTRACT

It is possible to simulate an airflow by additives to shoot images and records of such flowing. Additives can be in the form of particles or continuous filaments. A computer evaluation of such data differs depending on the kind of visualization method. This thesis deals with a number of different approaches to determine the airjet shape and airflow velocity in airflow images and records. Exact procedures are used for these purposes as well as neural networks and genetic algorithms.