

Bakalářská práce



České
vysoké
učení technické
v Praze

F3

Fakulta elektrotechnická
Katedra řídicí techniky

Optimalizace algoritmů pro hledání časových vzorů v komponentech modelů prostředí pro autonomní roboty

Lubor Šída

Školitel: Ing. Tomáš Votr
Květen 2023

I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Šída** Jméno: **Lubor** Osobní číslo: **492375**
Fakulta/ústav: **Fakulta elektrotechnická**
Zadávající katedra/ústav: **Katedra řídicí techniky**
Studijní program: **Kybernetika a robotika**

II. ÚDAJE K BAKALÁŘSKÉ PRÁCI

Název bakalářské práce:

Optimalizace algoritmů pro hledání časových vzorů v komponentech modelů prostředí pro autonomní roboty

Název bakalářské práce anglicky:

Optimization of algorithms for finding temporal patterns in environment model components for autonomous robots

Pokyny pro vypracování:

- 1) Seznamte se s algoritmy používanými v mobilní autonomní robotice pro tvorbu a údržbu reprezentací dynamických prostředí.
- 2) Seznamte se s datovými sadami a s experimenty, na kterých jsou výše uvedené metody testovány.
- 3) Identifikujte další datové sady pro evaluaci efektivity těchto metod.
- 4) Proveďte analýzu efektivity vybraných metod na nových a stávajících datasetech.
- 5) Proveďte analýzu nastavení parametrů těchto metod a navrhněte způsob jejich nastavení v závislosti na charakteru analyzovaných dat.

Seznam doporučené literatury:

- [1] Hawes, N., Burbridge, C., Jovan, F., Kunze, L., Lacerda, B., Mudrova, L., ... & Hanheide, M. (2017). The strands project: Long-term autonomy in everyday environments. *IEEE Robotics & Automation Magazine*, 24(3), 146-156.
- [2] Kucner, T. P., Lilienthal, A. J., Magnusson, M., Palmieri, L., & Swaminathan, C. S. (2020). Probabilistic mapping of spatial motion patterns for mobile robots. Springer International Publishing.
- [3] Vintr, T., Blaha, J., Rektoris, M., Ulrich, J., Rouček, T., Broughton, G., ... & Krajník, T. (2022). Toward benchmarking of long-term spatio-temporal maps of pedestrian flows for human-aware navigation. *Frontiers in robotics and AI*, 9.
- [4] Krajník, T., Fentanes, J. P., Santos, J. M., & Duckett, T. (2017). Fremem: Frequency map enhancement for long-term mobile robot autonomy in changing environments. *IEEE Transactions on Robotics*, 33(4), 964-977.
- [5] Krajník, T., Vintr, T., Molina, S., Fentanes, J. P., Cielniak, G., Mozos, O. M., ... & Duckett, T. (2019). Warped hypertime representations for long-term autonomy of mobile robots. *IEEE Robotics and Automation Letters*, 4(4), 3310-3317.
- [6] Vintr, T., Blaha, J., Ulrich, J., Rouček, T., Broughton, G., Duckett, T. and Krajník, T. (2023) Towards a Generalisation of Frequency Map Enhancement for Long-Term Autonomous Mobile Robot Deployment to Unexplored Natural Environments. *Robotics and Autonomous Systems*. In review.

Jméno a pracoviště vedoucí(ho) bakalářské práce:

Ing. Tomáš Vintr centrum umělé inteligence FEL

Jméno a pracoviště druhého(ho) vedoucí(ho) nebo konzultanta(ky) bakalářské práce:

Datum zadání bakalářské práce: **20.01.2023**

Termín odevzdání bakalářské práce: **26.05.2023**

Platnost zadání bakalářské práce:

do konce letního semestru 2023/2024

Ing. Tomáš Vintr
podpis vedoucí(ho) práce

prof. Ing. Michael Šebek, DrSc.
podpis vedoucí(ho) ústavu/katedry

prof. Mgr. Petr Páta, Ph.D.
podpis děkana(ky)

III. PŘEVZETÍ ZADÁNÍ

Student bere na vědomí, že je povinen vypracovat bakalářskou práci samostatně, bez cizí pomoci, s výjimkou poskytnutých konzultací. Seznam použité literatury, jiných pramenů a jmen konzultantů je třeba uvést v bakalářské práci.

Datum převzetí zadání

Podpis studenta

Poděkování

Chtěl bych poděkovat Ing. Tomáši Vintrovi za jeho odborné vedení, trpělivost a ochotu, které se mi od něj při psaní této práce dostalo. Také děkuji mojí rodině a přítelkyni za jejich dlouhotrvající podporu.

Prohlášení

Prohlašuji, že jsem předloženou práci v její úplnosti vypracoval samostatně a uvedl veškerou použitou literaturu.

V Praze, 26. května 2023

Lubor Šída

Abstrakt

Obsahem této bakalářské práce je komparativní analýza algoritmů používaných v mobilní autonomní robotice pro dynamické mapování a návrh možných postupů pro zlepšení jejich výkonnosti. Popisuje výběr vhodného datasetu a návržení scénářů s cílem nalezení oblastí, ve kterých zkoumané algoritmy dosahují neuspokojivých výsledků, provedení odpovídajících experimentů a analýzu jejich chování v těchto oblastech. Následně jsou v ní představeny postupy při návrhu zacílení těchto nedostatků a ty jsou experimentálně ověřeny v kontextu s předem učiněnými experimenty.

Klíčová slova: dlouhodobá autonomie, predikce časových řad, komparativní analýza

Školitel: Ing. Tomáš Víntr
Laboratoř chronorobotiky
Centrum umělé inteligence
Katedra počítačů FEL

Abstract

This bachelor's thesis contains a comparative analysis of algorithms used in the field of mobile autonomous robotics for dynamical mapping and proposal of possible approaches to improve their performance. It describes the selection of an appropriate dataset and the design of scenarios with the goal of identifying areas where the investigated algorithms perform unsatisfactory results, the execution of corresponding experiments and the analysis of their behaviour in these areas. Furthermore, it presents the design of tried procedures for targeting these deficiencies, and these are experimentally verified in the context of prior experiments.

Keywords: long-term autonomy, time-series forecasting, comparative analysis

Title translation: Optimization of algorithms for finding temporal patterns in environment model components for autonomous robots

Obsah

1 Úvod	1		
1.1 Motivace a cíle práce	1		
Struktura práce	1		
1.2 Neperiodicky koncipované přístupy mapování dynamik	2		
1.3 Modelování periodických dynamik v lidském prostředí	2		
1.4 Obecný přístup k modelování periodických dynamik	3		
2 Použité algoritmy	5		
2.1 FreME _n	5		
2.2 SEARCH	6		
2.2.1 Hyperparametry metody SEARCH	8		
2.3 Metrika pro hodnocení prediktivního modelu	8		
3 Dataset	11		
3.1 Dostupné datasey z oblasti mobilní robotiky	11		
3.2 Výběr datasetu	12		
3.3 Předzpracování dat	13		
3.3.1 Výběr stanic pro tvorbu časových řad	13		
4 Srovnání použitých metod	15		
4.1 Výsledky	15		
4.1.1 Různé trénovací epochy, předpověď následujících 35 dní	15		
4.1.2 Různé trénovací epochy, předpověď následujících 245 dní po týdnech	17		
4.1.3 Různé trénovací epochy, předpověď následujících 980 dní po lunárních měsících	18		
4.2 Analýza nalezených periodicit metodou SEARCH	20		
4.2.1 Počet periodicit	20		
4.2.2 Nalezené periodicity	21		
5 Zacílení hyperparametrů metody SEARCH	25		
5.1 Oblasti potenciálního zlepšení	25		
Kvalita predikce víkendu	25		
Kvalita dlouhodobé predikce při krátké trénovací době	25		
5.2 Návrh možných řešení	26		
		Funkce generování pozic napříč frekvenčním spektrem pro prohledávání	26
		Optimalizace hyperparametrů Success Rate a velikosti prohledávaných intervalů	27
		5.3 Výsledky	28
		6 Závěr a diskuze	31
		A Seznam příloh	33
		Bibliografie	35

Kapitola 1

Úvod

Schopnost porozumět svému okolí je zásadní dovedností autonomních mobilních robotů nasazených v reálném prostředí. V případě robotů, kteří operují v prostředích s dynamickými prvky je značnou výhodou zahrnout existenci a proměnlivost těchto prvků nejen při konání robota v reálném čase, ale i jako součást budoucího rozhodování.

Jeden z úspěšných přístupů v modelování dynamických součástí prostředí v autonomní robotice stojí na předpokladu, že chování těchto dynamik je periodického charakteru a úlohu predikce jejich stavu v čase řeší jako úlohu hledání dominantních frekvencí tvořících časovou řadu. Tato práce se zabývá srovnáním, analýzou a návrhem vylepšení výkonnosti algoritmu, který zobecňuje známé a ověřené postupy modelování periodických dynamik pro jeho budoucí využití v oblastech, o jejichž proměnlivosti nemá autonomní robot předchozí znalosti.

1.1 Motivace a cíle práce

V současnosti vyvíjený algoritmus pro hledání dominantních frekvencí neznámých periodických dynamik (dále referovaný jako SEARCH) slibuje zobecnění state-of-the-art metody FreMEn. Na cestě k tomuto cíli proto vzniká motivace srovnat výkonnost těchto algoritmů v doménách, do kterých je FreMEn určen a z rozdílných výsledků indetifikovat a odstranit nedostatky nové obecné metody.

Struktura práce

Popis použitých algoritmů a metrika použitá při jejich testování je v kapitole 2. Kapitola 3 popisuje proces výběru a charakter zvoleného datasetu pro trénování a testování a jeho předzpracování. Základní série provedených experimentů se nachází v kapitole 4, která má dva cíle: identifikaci/nalezení relevantních scénářů, ve kterých obecnější metoda SEARCH dosahuje znatelně horších výsledků nebo zcela selhává oproti specifitější metodě FreMEn a následnou analýzu chování obecnější metody v těchto situacích s motivací nalezení příčin tohoto chování. V kapitole 5 jsou poznatky z kapitoly 4 využity k nalezení oblastí, ve kterých by výkonnost SEARCH algoritmu

mohla být zlepšena, podoba navržených řešení a výsledky, kterých dosahují. Cílem této kapitoly je přiblížení výsledků metody SEARCH těm, kterých dosahuje FreMEn.

1.2 Neperiodicky koncipované přístupy mapování dynamik

Úspěšné zahrnutí proměnlivých prvků okolí při mapování zvyšuje celkovou efektivitu práce autonomních robotů oproti užití pouze statických map [29], [20], vede například ke zlepšení kvality utvářených statických map odebráním pohyblivých objektů z dlouhodobé reprezenrace prostoru [10], nebo umožňuje tvorbu více statických map, které popisují různé stavy téhož prostoru v závislosti na přítomném dynamickém prvku, například stavu otevření dveří [26]. Přítomnosti dynamických elementů lze také využít ke zlepšení lokalizace robota [32]. Komplexnější přístupy zahrnují aktualizaci již získaných map na základě předchozích a nových zkušeností ve stejných místech a vyvíjející se schopností se v nich lokalizovat ([13]) nebo utvářením pravděpodobností rozdělení popisujících pozici a směr pohybu dynamických objektů v prostředí [17], [18].

1.3 Modelování periodických dynamik v lidském prostředí

Přítomnost lidí je častým a velice relevantním zdrojem proměnlivosti prostředí, ve kterých operují autonomní roboti. Množství lidí a charakter jejich aktivit má zásadní vliv na schopnost robota vykonávat svůj úkol, často vzniká motivace k synchronizaci podúkolů a plánování tras robota s cílem minimalizovat či maximalizovat počet střetnutých osob. Vzhledem k tomu, že lidé (na úrovni individuální i kolektivní) vykazují určité pravidelnosti ve svém chování, nabízí se řešení přesunout úlohu mapování a modelování s nimi spojených dynamik z časové domény do frekvenční.

Autoři [15] pracují s grid-based reprezentací okolí robota, kde každá buňka má sobě náležící časovou funkci, která popisuje stav dynamického prvku v místě, které reprezentuje. Tyto funkce je pak možné převést do frekvenční domény Fourierovou transformací a provést modelování a předpověď budoucích stavů každé buňky v podobě nalezení dominantních frekvencí těchto funkcí. Díky zpětné Fourierově transformaci lze vytvořený budoucí průběh převést zpět na časovou řadu. Tento přístup vykazoval slibné výsledky, avšak součástí této implementace bylo využití rychlé Fourierovy transformace (FFT), která sice kládě nízké výpočetní nároky, ale vyžaduje, aby byla vstupní časová funkce vzorkována po pravidelných intervalech. Tato podmínka je v praxi velice těžko splnitelná nejen z technické stránky — zásadně snižuje i volnost návrhu konkrétních postupů aktivit robota.

Frequency Map Enhancement, neboli FreMEn [14], řeší tento nedostatek

využitím neuniformní Fourierovy transformace (NUDFT) [4]. Tento algoritmus je dnes hojně využívanou metodou při dynamickém mapování ([28], [24], [22], [11]).

Omezení, které FreMEn přináší (a které plyne z jeho návrhu s cílem užití v lidských prostředích) je jeho snížená obecnost. Tento algoritmus pracuje s množinou periodicit postavených na hodinových až denních cyklech (standardně až 7 dní) a jeho úspěšnost v nasazených prostředích je úzce spojena s podobou této operační množiny periodicit. V prostředích jiného charakteru je tedy při jeho užití třeba přizpůsobit tento výběr frekvencí, což vyžaduje předchozí znalosti o zkoumaných dynamikách. V praxi ale tyto znalosti nemusí být vždy správné nebo kompletní.

1.4 Obecný přístup k modelování periodických dynamik

Úspěšné nasazení algoritmu FreMEn a jeho dobré výsledky v prostředích se známými dynamikami vykazující periodické průběhy vede k motivacím nalézt obecný přístup založený na stejném principu.

V laboratořích chronorobotiky na ČVUT FEL [19] vzniká algoritmus (referovaný pod názvem SEARCH) se záměrem rozšířit ověřenou metodu FreMEn o schopnost nalezení relevantní množiny dominantních frekvencí sledovaných dynamik přímo z dat a bez nutnosti předchozích znalostí. Prvotní experimenty naznačují, že v případě modelování dynamik, kde dominují lidmi dodržované periodicity (den, týden) je SEARCH schopen vytváření modelů, které se svojí spolehlivostí blíží těm, které vytváří FreMEn — za předpokladu, že trénovací množina je dostatečně dlouhá pro umožnění nalezení těchto periodicit. V jiném prostředí (hledání dominantních periodicit v hustotách a rychlostech proudění protonů z měření slunečních větrů satelitem NOAA [9]) uspěl SEARCH nejlépe v porovnání s celou řadou ostatních metod (včetně FreMEn) [31].

Kapitola 2

Použité algoritmy

2.1 FreMEn

Frequency Map Enhancement (FreMEn) [14] predikuje budoucí průběh stavu dynamického prvku z předchozích měření jeho stavu za předpokladu, že jeho proměnlivost má periodický charakter. Hodnoty s_1, \dots, s_n popisující stav modelované dynamiky naměřené v časech t_1, \dots, t_n představují diskrétní signál, který je za použití neuniformní diskrétní Fourierovy transformace převeden do frekvenční domény. Ve vlastní implementaci metody FreMEn tento algoritmus za použití operační množiny úhlových frekvencí Ω a pro zvolený řád modelu m hledá m dominantních úhlových frekvencí $\omega \in \Omega$, m amplitud α a fází φ jim náležících komplexních čísel (jakožto funkčních hodnot těchto frekvencí) postupem popsáním v algoritmu 1. Ze získaných množin $\Omega^m = \{\omega_1, \dots, \omega_m\}$, $A^m = \{\alpha_1, \dots, \alpha_m\}$, a $\phi^m = \{\varphi_1, \dots, \varphi_m\}$ je budoucí hodnota s časové řady v čase t_t modelována jako

$$s(t_t) = \mu + \sum_{j=1}^m \alpha_j \cos(\omega_j t_t - \varphi_j), \quad (2.1)$$

kde μ je průměr předchozích hodnot stavu $s(t)$.

Při experimentech prováděných v kapitole 4 byla zvolena množina operačních periodicit Ω_{168} , která obsahuje nejdelší periodicitu 168 hodin, tedy jeden týden. V dalších částech textu je proto na tuto metodu někdy referováno jako na F_{1W} .

Pro výpočet neuniformní Fourierovy transformace při praktické implementaci byla využita funkce `nu_t1d3` z knihovny `finu_t` [5] pro Python.

Algoritmus 1 FreMEEn algoritmus s rozšířením pro reálná čísla

Input

- S ▷ množina měření
- T ▷ množina časů měření
- Ω ▷ operační množina frekvencí
- m ▷ počet hledaných dominantních úhlových frekvencí

Output

- Ω^m ▷ m vybraných dominantních úhlových frekvencí
- A^m ▷ amplitudy jim náležících funkčních hodnot
- ϕ^m ▷ fáze jim náležících funkčních hodnot

- 1: **Init**
- 2: $N \leftarrow \text{len}(s)$
- 3: $\mu \leftarrow \text{mean}(s)$
- 4: $k \leftarrow 1$
- 5: **for** each $\omega \in \Omega$ **do**
- 6: $f_k \leftarrow \sum_{j=1}^N (s_j - \mu) e^{i\omega t_j}$
- 7: $\alpha_k \leftarrow 2|f_k|/N$
- 8: $\varphi_k \leftarrow \text{angle}(f_k)$
- 9: $k \leftarrow k + 1$
- 10: **end for**
- 11: $A^s \leftarrow \text{sort}(A)$
- 12: $\phi^s \leftarrow \text{sort}(\phi, \text{key}=(A))$
- 13: $\Omega^s \leftarrow \text{sort}(\Omega, \text{key}=(A))$
- 14: $\Omega^m \leftarrow \Omega^s[\text{start} : m]$
- 15: $A^m \leftarrow A^s[\text{start} : m]$
- 16: $\phi^m \leftarrow \phi^s[\text{start} : m]$
- 17: **Return** Ω^m, A^m, ϕ^m

2.2 SEARCH

SEARCH algoritmus [31] je metoda postavená na stejném principu jako FreMEEn, s tím rozdílem, že nevyžaduje množinu operačních frekvencí Ω ani řád požadovaného modelu m na svém vstupu. Jedná se o iterativní algoritmus, který dominantní frekvence hledá přímo z dat. Množiny Ω^m , A^m a ϕ^m vytváří postupně z chyb modelů řádů $0, \dots, m - 1$. V každé iteraci i je cílem najít frekvenci, v jejíchž funkčních hodnotách dochází k největší chybě při modelování časové řady modelem o řádu i a tuto frekvenci a jí náležící funkční hodnotu zaznamenat a zahrnout do množin Ω^m , A^m , a ϕ^m . V každé iteraci algoritmu se tedy řád modelu zvyšuje. Dokud nedojde k ukončovací podmínce, tento proces se opakuje až do finální iterace m , což je i výsledný řád modelu.

Nalezení této frekvence, které náleží největší chyba vytvořeného modelu je klíčová část SEARCH algoritmu, popisuje jí algoritmus 2.

Algoritmus 2 Searching algorithm

an iterative approach to find the best frequency element. Upravená verze původního popisu [31].

Input

S ▷ množina měření

T ▷ množina časů měření

SR ▷ hyperparametr success rate

N ▷ hyperparametr N

NH ▷ hyperparametr vi ci ni ty

$Iters$ ▷ maximální počet iterací

$P_{suspect}$ ▷ vybrané periody z předchozí inicializace (nepovinné)

1: **Init**

2: P_{max} polovina délky času pokrytého množinou T

3: P_{min} dvojnásobek medianu periody měření

4: \mathbf{P} $rnd^2(P_{min}, P_{max})$ N -krát NEBO $P_{suspect}$

5: N_{succ} 0

6: **repeat**

7: $|\gamma|$ amplitudy náležící periodám v \mathbf{P}

8: $\bar{|\gamma|}$ $\frac{1}{N} \sum_i^N |\gamma|_i$

9: N_{succ} 0

10: Idx 0

11: **for** i 0, N **do**

12: $scale$ $|\gamma|_i / \bar{|\gamma|}$

13: **if** $scale > 1$ **then**

14: N_{succ} $N_{succ} + scale$

15: **for** s 0, $scale$ **do**

16: $radius$ P_i / NH

17: P_{Idx} $rnd^2(P_i - radius, P_i + radius)$

18: Idx $Idx + 1$

19: **end for**

20: **end if**

21: **end for**

22: **for** i Idx, N **do**

23: P_i $rnd^2(P_{min}, P_{max})$

24: **end for**

25: $Iters$ $Iters - 1$

26: **until** $N_{succ} < SR \cdot N$ or $Iters > 0$

27: P_{best} periody patří k $\max_{|\gamma|} |\gamma|_i$

28: $radius$ P_{best} / NH

29: \mathbf{P} $rnd(P_{best} - radius, P_{best} + radius)$ for each N

30: $|\gamma|$ amplitudy náležící periodám v \mathbf{P}

31: **return** Informace k úhlové frekvenci patří k $\max_{|\gamma|} |\gamma|_i$

2.2.1 Hyperparametry metody SEARCH

Vnitřní fungování algoritmu je ovlivněno nastavením několika hyperparametrů. Počet vzorků N označuje, kolik je prohledáno náhodných vzorků z přípustného intervalu (P_{\min}, P_{\max}) . V případě úspěšného nalezení je tento vzorek v původní množině nahrazen novým vzorkem z jeho okolí (ostatní vzorky jsou nahrazeny zcela novými). Velikost tohoto okolí je určena hyperparametrem ν či η . Hodnota hyperparametru SR — success rate udává, jaké procento zrovna nalezených vzorků musí splnit podmínku $\alpha > 2\bar{\alpha}$, aby došlo k ukončení iterativního hledání. Z podstaty podmínky platí $SR \leq 0.5$. Funkce, která generuje pozice těchto vzorků v intervalu (P_{\min}, P_{\max}) má tvar $p = r^2(P_{\max} - P_{\min}) + P_{\min}$, kde $r \in \mathbb{R}$ je náhodné číslo z intervalu $(0, 1)$ a pro zhuštění generování hodnot bližších P_{\min} je v generovací funkci umocněno na druhou. Toto rozhodnutí je motivováno skutečností, že ve vyšších frekvencích (nižších periodách) utváří jejich absolutní funkční hodnoty větší množství lokálních maxim.

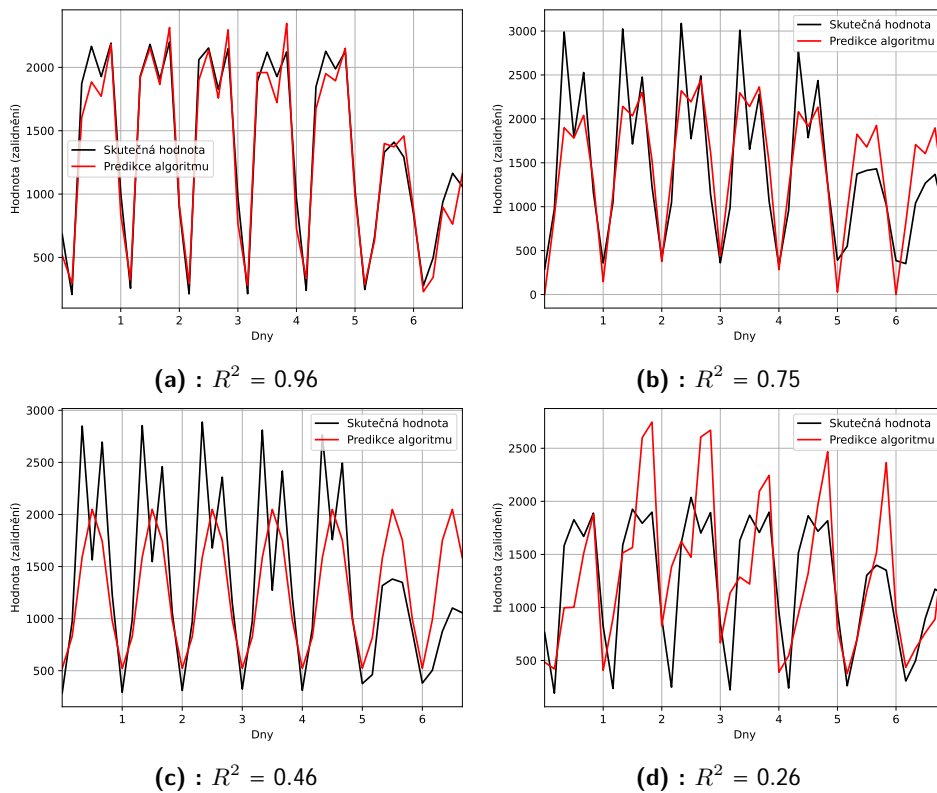
Ve výchozí implementaci algoritmu SEARCH nejsou hodnoty parametrů systematicky odladěny. Jejich hodnoty jsou v tabulce 2.1.

Hyperparametr	Výchozí nastavení
N	100
SR	0.4
ν či η	0.005
$p(P_{\min}, P_{\max})$	$r^2(P_{\max} - P_{\min}) + P_{\min}$, $r \in (0, 1)$

Tabulka 2.1: Výchozí nastavení hyperparametrů algoritmu SEARCH.

2.3 Metrika pro hodnocení prediktivního modelu

Zvolenou metrikou pro hodnocení modelů vytvořených testovanými algoritmy byl zvolen koeficient determinace R^2 [27], který je ve statistice běžně užívanou a doporučovanou metrikou pro posuzování kvality regresních modelů [12]. Interpretace hodnoty R^2 modelu predikující časovou řadu je na obrázku 2.1



Obrázek 2.1: Porovnání skutečnosti a predikce časové řady pro různé hodnoty R^2 .

Kapitola 3

Dataset

Požadované vlastnosti datasetu vhodného pro komparativní experimenty zvolených algoritmů jsou:

1. Popis lidmi způsobené dynamiky — k vytvoření scénářů, které odhalí nedostatky zobecněného přístupu k frekvenčnímu mapování oproti specifickému přístupu je třeba zvolit doménu, do které je určen specifický přístup. FreMEn je určen k využití v lidmi řízených dynamických prostředích.
2. Dlouhodobost — příslib dosažení obecného mapování nabízí budoucí využití v doménách, kde jsou prominentní periodicity značně delší než ty, se kterými tyto metody běžně pracují. I v lidské společnosti se dají hledat výrazné časové pravidelnosti v mnohem delších časových úsecích, než je týden.
3. Dostatečně vysoká frekvence měření — perioda měřených dat určuje spodní hranici periodicit, které lze pomocí zvolených metod modelovat. Při očekávání denních periodicit (které v lidských prostředích očekáváme) je třeba, aby perioda měření nebyla delší než 12 hodin.

3.1 Dostupné datasety z oblasti mobilní robotiky

University of Lincoln, pod záštitou projektu STRANDS [11] pořizuje a uschovává datasety s účelem využití pro mapování v oblasti mobilní robotiky [16]. Původní FreMEn algoritmus a další metody z něj odvozené byly testovány na několika z těchto datasetů (např. *MHT Lecturer O ce*, *MHT RGB-D*), tyto datasety zpravidla mají výše zmíněné vlastnosti 1 a 3 — zaznamenávají přítomnost člověka/lidí nebo předmětů používaných lidmi (např. v kancelářském prostředí). Většina z nich ale popisuje průběh těchto jevů v řádech měsíců nebo méně. Dataset *MHT Lecturer O ce*, který pokrývá celkovou délku dvou let byl využit ke srovnávacímu experimentu při vývoji algoritmu SEARCH [31], jeho využití je proto v případě celistvé nezávislé komparativní analýzy nevhodný. To samé platí pro *UTBM* dataset [22], který sloužil s využitím těchto metod k vytváření modelů pro praktické experimenty s fyzickým robotem [30]. Problémové jsou i datasety, u kterých systematicky chybí důležité

časové úseky. Objemný a podrobný *ATC shopping center* dataset [8], který sleduje pohyb lidí v nákupním centru, obsahuje data pouze ze střed a nedělí a jen v době, kdy je obchodní centrum otevřeno veřejnosti.

V poslední době vznikají v oblasti robotiky nové a informačně bohaté časoprostorově orientované datasey, např. *L-CAS* [33], *THÖR* [23], nebo *Magni* [25], které ale ve svých délkách nepřesahují dobu jedné hodiny. Datasey pokrývající časová období několik let nejsou v oblasti mobilní robotiky běžné, jednak kvůli dobám nasazení mobilních robotů v praxi a charakteru, která jimi měřená data mají — často se jedná o fotografie, videa nebo záznamy z hloubkových kamer. Uschovávat často měřená dlouhodobá data v těchto formátech je velice paměťově náročné.

S vyhovujícími datasey se častěji pracuje v oblastech jako jsou ekonometrie či epidemiologie, ve kterých je statistické modelování dlouhodobých trendů častým středem zájmu [7], [1], [34], v těchto oblastech jsou ale často zkoumaná data spíše důsledkem nebo dopadem lidské činnosti, ne činnost samotná. Není tedy jisté, že v takových oblastech bude metoda *FreMEn* zcela vhodná jako etalon kvality predikce.

3.2 Výběr datasetu

Zvolený dataset obsahuje údaje z turniketů u vstupů New Yorkských stanic metra. Pokrývá časové období zhruba 8.5 let (3064 dní) od 18. 10. 2014 do 7. 4. 2023. Dataset je volně dostupný ze stránek Metropolitan Transportation Authority [3] [2].

Klíčovými údaji v datasetu jsou počty vstupů a výstupů, které jednotlivé turnikety zaznamenaly a na jaké jsou umístěny stanici. Součet počtu vstupů a výstupů na jednotlivé stanici za časovou jednotku lze interpretovat jako množství lidí, kteří se na stanici za daný časový úsek pohybovali, ať už pro ně byla stanice cílovou nebo startovní destinací. Takto sestavená časová řada splňuje základní předpoklady pro provedení zvolených experimentů — mapuje lidské chování v čase takového charakteru, který vykazuje různorodost v řádu hodin (ranní/noční zaplněnost hromadné dopravy) dní (pracovní týden/víkend) až měsíců (ekonomické cykly). Celá množina těchto časových řad má pak i prostorovou interpretaci, stanice a linky, které je spojují, reprezentují uzly a hrany v grafu a vývoj časových řad popisuje tok v síti. Tato prostorová analýza je nad rámec této práce.

Množství různých stanic umožňuje vytvářet množství časových řad popisujících stejný fenomén, který bude vykazovat očekávané charakteristiky v každé z nich a zároveň přináší experimentům potřebnou variaci vzniklou různým umístěním stanic, které je zodpovědné za jejich rozdílné vytížení (střed/okraje města). Ze všech dostupných stanic bylo vybráno 50 náhodných, na kterých byly experimenty provedeny.

3.3 Předzpracování dat

Data by měla být z turniketů nahrávána v pravidelných intervalech po čtyřech hodinách, ale vyskytují se v nich nesystematické nepravidelnosti převážně technického původu, tedy způsobené poruchami, správou zařízení, zpožděním apod., v některých stanicích došlo k dlouhodobé chybě synchronizace turniketů a data tedy nejsou v pravidelných intervalech po 4 hodinách — určité množství turniketů bylo oproti ostatním zpožděno o jednu až tři hodiny, což vede na vznik časové řady s i dvojnásobným množstvím měření. Tyto časové nepravidelnosti nejsou vzhledem k algoritmům použitých v experimentech komplikací a proto jsou v datech ponechány, i když někdy vedou k rozdílným výsledkům (větší množství hodnot za stejný časový úsek dovoluje podrobnější model). Schopnost vypořádat se s těmito nepravidelnostmi v datech je klíčový rozdíl zvolených metod založených na neuniformní Fourierově transformaci oproti ostatním přístupům dynamického mapování.

3.3.1 Výběr stanic pro tvorbu časových řad

Při vytváření časových řad pro různé stanice metra se vyskytl zásadní problém způsobený nekonzistentním pojmenováním těch samých stanic, nejčastěji způsobené cílenou změnou zapisování jejich názvů, např. zkracování slova *AVENUE* — v datech se vyskytovaly různé variace, včetně celého slova, zkratk *AVE*, *AV*. Vzhledem k vysoké četnosti názvů, ve kterých se vyskytovalo slovo *AVENUE* a jeho různé variace, byl název u těchto stanic sjednocen s využitím zkratky *AV*, ostatní variace byly přepsány na tuto podobu. Dalšími příklady přítomnými v datasetu je (ne)zkracování slov *STREET*, *BOULEVARD*, *ROAD*, zaměňování mezery v názvech ulic za pomlčku nebo symbol lomítka.

Dále byl výběr stanic omezen na takové, u nichž počet měření dosahoval přibližně očekávaného počtu pro patřičnou délku datasetu. Pro 3094 dní, během kterých jsou údaje nahrávány každé 4 hodiny každý den to znamená celkem 18564 hodnot na časovou řadu. Tento krok omezil výběr stanic na takové, u nichž byla po celou dobu konzistentní podoba názvu. Nejmenší počet měření ve finálním vybraném datasetu pro jednu časovou řadu je 18438 a největší je 40281 (Případ popsany v sekci 3.3). Na jiné vlastnosti stanic nebyl při jejich výběru brán ohled.

Kapitola 4

Srovnání použitých metod

S cílem srovnání metod popsaných v předchozím textu bylo vytvořeno několik scénářů pro provedení základních srovnávacích experimentů. Z předchozích experimentů vyplývá, že denní periodičita se v časových řadách stabilně projevuje po uplynutí zhruba 35 dní [31], což je první ze zvolených trénovacích epoch. V podobném duchu byly zvoleny další dvě trénovací epochy — 35 týdnů (245 dní) a 35 lunárních měsíců (980 dní). Testovací epochy mají stejné délky, pro predikci 35 dní jsou predikce dělány po dnech (tedy 35 predikcí, každá na následující den) pro predikci na 35 týdnů a 35 lunárních měsíců jsou stejným způsobem predikce vytvářeny na týdny a měsíce. Ve všech případech začíná první predikce hned po trénovací epoše (den 0 po trénování). Z časové řady každé stanice bylo (pseudo)náhodně vybráno 10 výřezů všech požadovaných trénovacích a testovacích délek. 50 stanic metra tímto způsobem generuje 500 časových řad pro každou délku trénovací epochy. Výřezy z časových řad začínají vždy ve stejný den v týdnu (pondělí, čtvrtek, neděle). Počáteční den pro trénování i predikci je vždy shodný, protože všechny tři trénovací období jsou násobky týdnů.

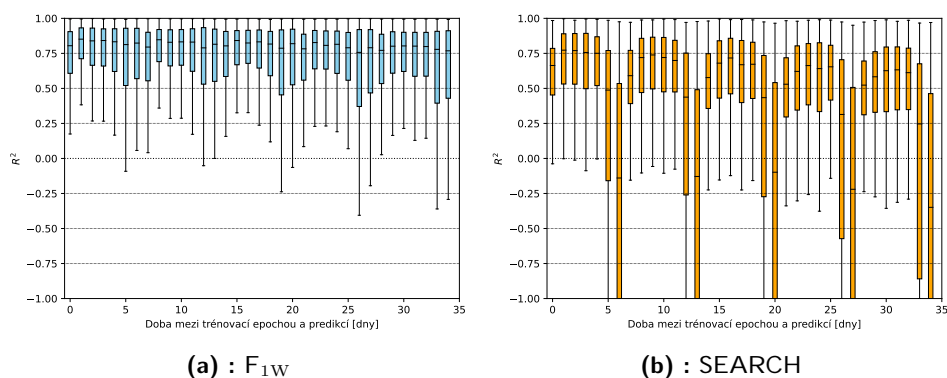
Výsledky z těchto experimentů jsou brány jako srovnávací úroveň pro provedení pozdějších analýz a cílů následujících experimentů. Z teorie a charakteru metod vyplývá, že při nasazení v prostředích, kde se projevují periodicity známé pro FreMEn, bude tato metoda statisticky překonávat SEARCH.

4.1 Výsledky


4.1.1 Různé trénovací epochy, předpověď následujících 35 dní

Z obrázků 4.1 a 4.2 je zřejmý očekávatelný výsledek srovnání algoritmů FreMEn a SEARCH. FreMEn překonává SEARCH v předpovědích po celou dobu testovacího období. Méně očekávaným výsledkem je zásadní rozdíl v kvalitě předpovědi neděle — oba algoritmy predikují neděli hůř než ostatní dny, ale zhoršení u algoritmu SEARCH je zásadní. Medián R^2 predikce neděle je pro případ trénování na 35 dnech menší než 0, v případě trénování na 245 dnech se pohybuje mezi hodnotami 0 a 0.25. V obou případech se jedná o neuspokojivé predikce. Zlepšení kvality predikce nedělí (víkendů) je jedním z

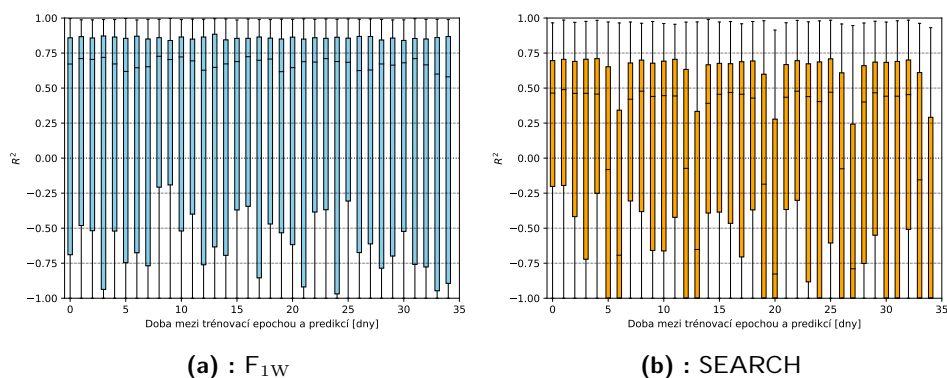
4. Srovnání použitých metod



Obrázek 4.1: R^2 modelů vytvořených algoritmy F_{1W} a SEARCH. Trénovací epocha 35 dní, predikce na každý následující den po dobu 35 dní. Začátek testovací epochy v pondělí.



Obrázek 4.2: R^2 modelů vytvořených algoritmy F_{1W} a SEARCH. Trénovací epocha 245 dní, predikce na každý následující den po dobu 35 dní. Začátek testovací epochy v pondělí.



Obrázek 4.3: R^2 modelů vytvořených algoritmy F_{1W} a SEARCH. Trénovací epocha 980 dní, predikce na každý následující den po dobu 35 dní. Začátek testovací epochy v pondělí.

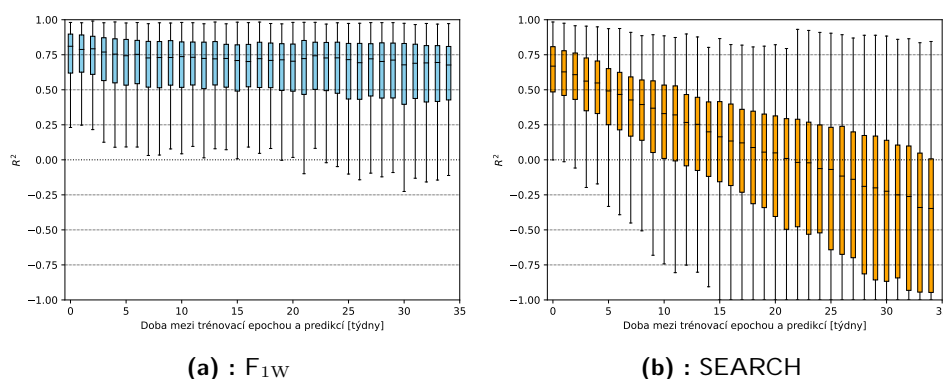
cílů experimentů popsaných v sekci 5.

Obrázek 4.3 vyobrazuje výsledek, ve kterém se spodní polovina hodnot

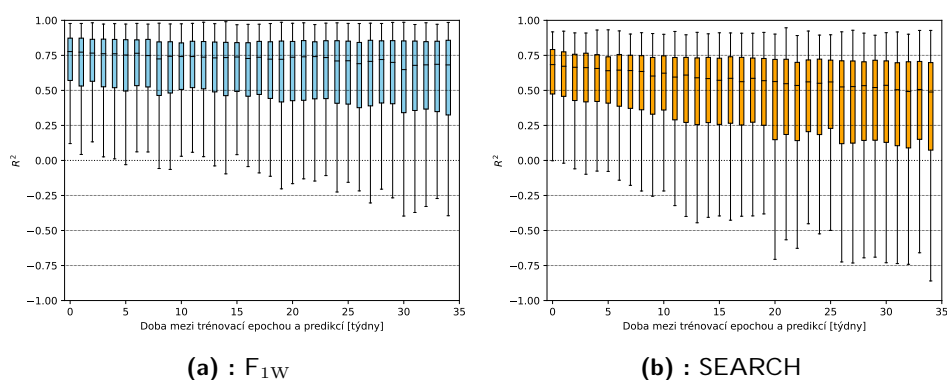
nachází v rozsáhlém intervalu pro všechny predikované dny. Původem tohoto jevu by mohla být přítomnost neperiodických, speciálních událostí, které se v datech projeví jako nevysvětlitelný skok hodnot směrem nahoru (výjimečná sportovní či kulturní událost v blízkosti stanice, která je časovou řadou reprezentována) nebo dolu (technická porucha metra, zavření stanice). Pravděpodobnost výskytu těchto jevů se s délkou trénovací doby zvyšuje. Tento jev avšak nebyl v experimentech hlouběji zkoumán a jeho původ nebyl zjištěn.

4.1.2 Různé trénovací epochy, předpověď následujících 245 dní po týdnech

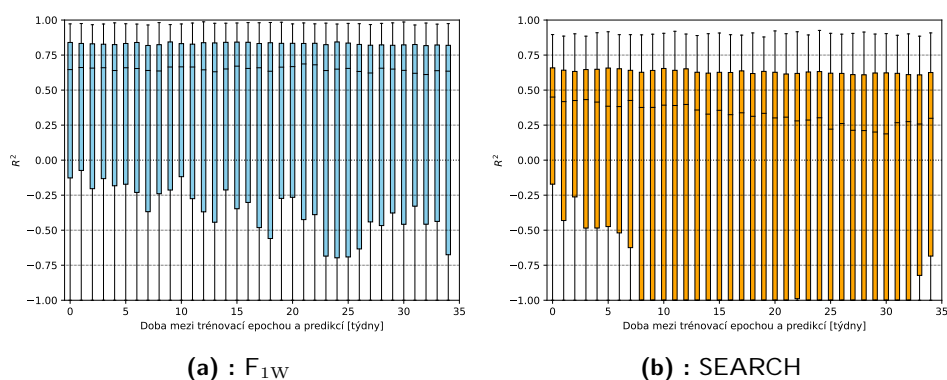
U týdenních predikcí v rozsahu 1 až 35 týdnů od trénovacího období lze pozorovat průběžné zhoršení výsledku algoritmu SEARCH při krátké době trénovacího datasetu. Modely získané metodou FreMEn z tohoto trénovacího období vykazují minimální snížení kvality v čase. V experimentu stejné předpovědi po trénování na 245 dnech dosahuje SEARCH výsledků velmi blízkých těm, které můžeme vidět u modelů vytvořených metodou FreMEn. Současná existence těchto výsledků motivuje ke snahám docílit toho, aby se i pro kratší trénovací datasety dlouhodobá předpověď SEARCH algoritmu blížila svojí přesností těm, které vytváří FreMEn, nebo nalezení potenciálních zdrojů limitace SEARCH algoritmu, kvůli kterým dosahuje značně horších výsledků v prvním zmíněném experimentu. Zlepšení přesnosti předpovědi na střednědlouhá časová období při krátkém trénovacím datasetu je jedním z cílů experimentů popsaných v sekci 5



Obrázek 4.4: R^2 modelů vytvořených algoritmy F_{1W} a SEARCH. Trénovací epocha 35 dní, predikce na každý následující týden po dobu 35 týdnů. Začátek testovací epochy v pondělí.



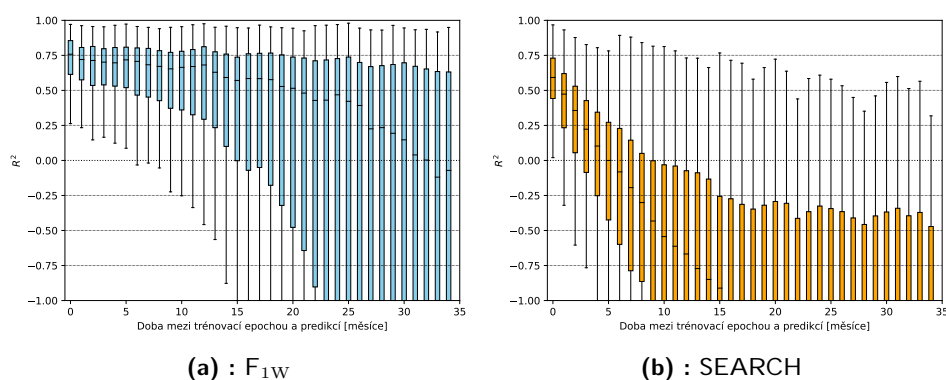
Obrázek 4.5: R^2 modelů vytvořených algoritmy F_{1W} a SEARCH. Trénovací epocha 245 dní, predikce na každý následující týden po dobu 35 týdnů. Začátek testovací epochy v pondělí.



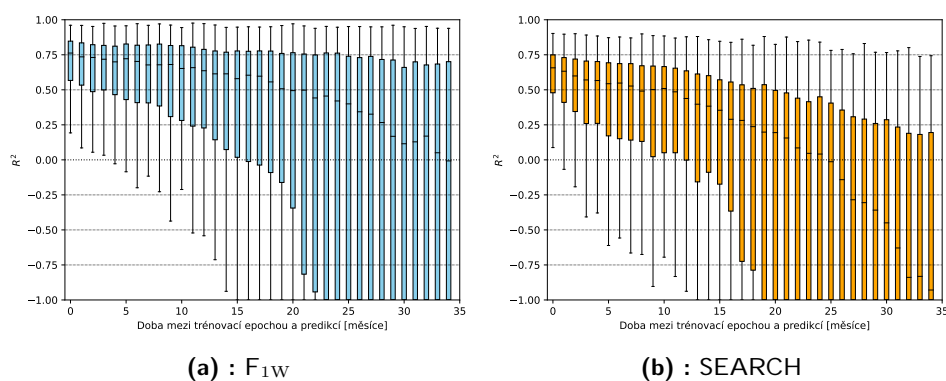
Obrázek 4.6: R^2 modelů vytvořených algoritmy F_{1W} a SEARCH. Trénovací epocha 980 dní, predikce na každý následující týden po dobu 35 týdnů. Začátek testovací epochy v pondělí.

4.1.3 Různé trénovací epochy, předpověď následujících 980 dní po lunárních měsících

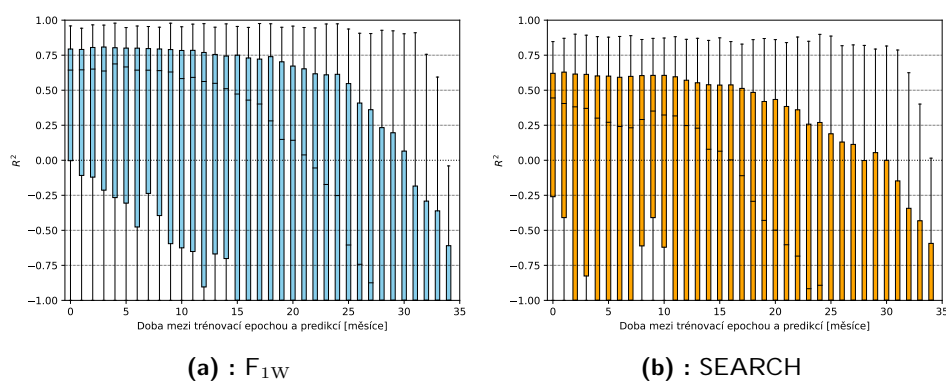
Trend pozorovatelný na obrázcích 4.7 a 4.8 se shoduje s tím, který lze pozorovat v předchozích experimentech (při předpovědi na 245 dní). SEARCH při krátké trénovací době selhává ve své předpovědi ztelně dřív než FreMen. Tyto výsledky také potvrzují předchozí domněnku, že SEARCH benefituje z delší trénovací množiny více, než FreMen — zlepšení metody SEARCH při dlouhodobé předpovědi se střednědlouhou trénovací dobou (245 dní) oproti krátké trénovací době (35 dní) je zásadní.



Obrázek 4.7: R^2 modelů vytvořených algoritmy F_{1W} a SEARCH. Trénovací epocha 35 dní, predikce na každý následující lunární měsíc po dobu 35 lunárních měsíců. Začátek testovací epochy v pondělí.



Obrázek 4.8: R^2 modelů vytvořených algoritmy F_{1W} a SEARCH. Trénovací epocha 245 dní, predikce na každý následující lunární měsíc po dobu 35 lunárních měsíců. Začátek testovací epochy v pondělí.



Obrázek 4.9: R^2 modelů vytvořených algoritmy F_{1W} a SEARCH. Trénovací epocha 980 dní, predikce na každý následující lunární měsíc po dobu 35 lunárních měsíců. Začátek testovací epochy v pondělí.

4.2 Analýza nalezených periodicit metodou SEARCH


Zásadní rozdíl mezi funkcí algoritmů FreMEn a SEARCH, který spočívá v jejich statickém (FreMEn) a dynamickém (SEARCH) nalézání periodicit vede na otázku, jaké periodicity SEARCH algoritmus nalézá a jak se nalezená množina periodicit projeví na kvalitě vytvořeného modelu. Byla proto provedena analýza se zaměřením na vliv počtu nalezených periodicit na výslednou kvalitu modelu a rozdělení periodicit do podmnožin podle kvality modelu, který generují.

Analýza byla aplikována na experimenty ve všech délkách trénovacích epoch jak jsou popsány v 4. Testovací období bylo vždy jeden den, a to následující den po konci trénovací epochy. Velké rozdíly kvality predikce pro různé dny v týdnu (pracovní dny/víkendy) vedly ke snaze nalezení rozdílných množin periodicit (či jejich četností) podle jejich schopnosti konkrétní dny správně predikovat. Tyto experimenty byly proto také prováděny pro časové řady začínající v náhodná pondělí, čtvrtky a neděle a výsledky seskupeny podle těchto dní.


V experimentech nebyl kladen důraz na celistvou podobu množin nalezených periodicit a na pořadí, ve kterých byly periodicity nelezeny, pouze na jejich celkovou četnost (a to jak četnost těchto množin, tak četnost konkrétních nalezených dominantních periodicit v nich napříč vytrénovanými modely). Tímto způsobem získané poznatky jsou tedy velmi limitující a lze z nich vyvozovat minimální závěry. Dalším krokem v oblasti analýzy nalezených periodicit, který už není součástí této práce, by proto bylo zkoumání podoby těchto ucelených množin a jejich vlivu na kvalitu vytvořeného modelu (např. jak se absence konkrétních periodicit projeví na kvalitě predikce za přítomnosti jiných, zda a do jaké míry jsou podmnožiny periodicit schopny úspěšně modelovat průběhy s pravidelnostmi, které samostatně nepopisují).

4.2.1 Počet periodicit

Výsledky experimentů s trénovacím obdobím 35 dní (obrázek 4.10) vykazují podobný trend v počtu periodicit vůči dosaženému R^2 pro předpověď pondělí i neděle, a to i za skutečnosti, že medián hodnot R^2 predikce neděle je značně horší, než hodnot predikce pondělí — větší počet nalezených periodicit přináší lepší kvalitu modelu. Konkrétně zajímavá je oblast mezi dvanácti a dvaceti nalezenými periodicitami, ve kterých se nachází v řádu jednotky predikcí s $R^2 < 0$. Toto pozorování však nelze učinit pro delší trénovací období, v obou následujících experimentech se vyskytují stabilnější shluky vyšších hodnot R^2 v oblasti počtu šesti až osmi nalezených periodicit.




(a) : Predikce na pond lí




(b) : Predikce na ned li

Obrázek 4.10: R^2 modelů vytvořených algoritmem SEARCH v závislosti na počtu nalezených periodicit pro trénovací epochu 35 dní.




(a) : Predikce na pond lí




(b) : Predikce na ned li

Obrázek 4.11: R^2 modelů vytvořených algoritmem SEARCH v závislosti na počtu nalezených periodicit pro trénovací epochu 245 dní.



(a) : Predikce na pond lí




(b) : Predikce na ned li

Obrázek 4.12: R^2 modelů vytvořených algoritmem SEARCH v závislosti na počtu nalezených periodicit pro trénovací epochu 980 dní.

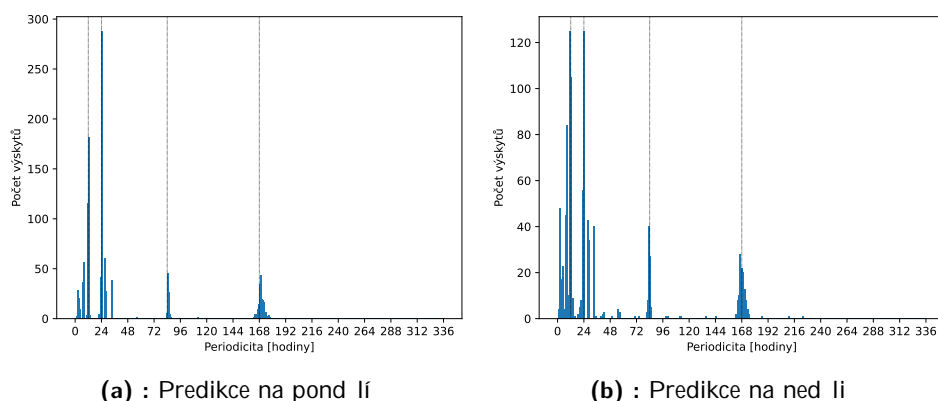
4.2.2 Nalezené periodicity

Při analýze nalezených periodicit a jejich vlivu na kvalitu modelu byly zkoumány pouze výsledky z modelů vytvořených pro trénovací epochu 35 dní,

protože vykazují největší rozdíly mezi množstvím nalezených periodicit a kvalitou výsledné predikce. Nalezené periodicity jsou rozděleny do 3 podmnožin, podle toho, k jakým výsledným hodnotám R^2 za jejich využití model vedl.




Obrázek 4.13: Histogram nalezených periodicit tvořící modely s hodnotou $R^2 > 0.8$, trénovací epocha 35 dní.



Obrázek 4.14: Histogram nalezených periodicit tvořící modely s hodnotou $0.0 < R^2 < 0.8$, trénovací epocha 35 dní.

Na první pohled zřejmým poznatkem, který tato analýza přináší, je výhoda většího množství nalezených periodicit v nižších hodnotách — úspěšné modely vykazují častější nalezení periodicit čtyřhodinových (nalezených pouze v případech, ve kterých jsou časové řady jemněji vzorkovány, jak je popsáno v 3.3) a dalších periodicit kratších než 12 hodin. Důležitost nalezení 24 hodinové periodicity je očekávatelná, v případě úspěšných predikcí na neděli (obrázek 4.13b) je však znatelně častější 12 hodinová periodicita. Jev, který lze pozorovat ve všech třech vyobrazených případech je častá nepřesnost nalezení 7 denní periody (168 hodin). Tento deficit však není v dalších kapitolách cílen.



(a) : Predikce na pond lí

(b) : Predikce na ned lí

Obrázek 4.15: Histogram nalezených periodicit tvořící modely s hodnotou $R^2 < 0.0$, trénovací epocha 35 dní.

Kapitola 5

Zacílení hyperparametrů metody SEARCH

Algoritmus SEARCH, jak popsán v 2.2, disponuje škálou hyperparametrů, které ovlivňují jeho iterační průběh. Výsledky experimentů popsanych v sekci 4 jsou brány jako výchozí výkonnost algoritmu SEARCH a slouží jako srovnávací úroveň pro následující snahy o nalezení efektivnějšího nastavení algoritmu. Z těchto výsledků (popsány v sekci 4.1) byly vybrány dvě oblasti, ve kterých SEARCH algoritmus dosahuje horších výsledků v porovnání s původním FreMEn a ladění hyperparametrů algoritmu bylo motivováno jejich zlepšením:

5.1 Oblasti potenciálního zlepšení

Kvalita predikce víkendu

Výsledky základní série experimentů (sekce 4.1) ukazují značné zhoršení predikcí sobot a nedělí algoritmem SEARCH (obrázky 4.1b a 4.2b), a to jak v porovnání s predikcemi ostatních dní v týdnu, tak v porovnání s predikcemi nedělí vycházejících z modelů vytvořených algoritmem FreMEn. Původ tohoto zhoršení je z podstaty charakteru časové řady zřejmý — množství lidí pohybujících se ve stanicích metra velkého města je bezpochyby ovlivněno průběhem pracovní doby, která konzistentně vytváří nepoměr zátěže hromadné dopravy během pracovních dní vůči víkendům. Z podstaty fungování algoritmu je jev těžší vysvětlit, základní FreMEn obsahuje periodicity do jednoho týdne (168 hodin) a kratší, které by správně fungující iterační SEARCH algoritmus měl také odhalit. Zacílenými hyperparametry s cílem zlepšení tohoto nedostatku jsou inicializační funkce generování pozic frekvencí, množství jí generovaných pozic/vzorků N . Popis parametrů a jejich výchozí hodnoty je v sekci 2.2.1

Kvalita dlouhodobé predikce při krátké trénovací době

Obrázek 4.4b, na kterém je zachycena kvalita generovaných modelů SEARCH algoritmem získaných z trénovacího období 35 dní, zachycuje postupné horšení kvality predikcí s jejich rostoucí vzdáleností od trénovací epochy. Oproti tomu výsledky algoritmu FreMEn při podstoupení těch samých experimentů (obrázek 4.4a) jsou v čase mnohem víc stabilní. Při delší trénovací době (245

dní, pro výsledky viz obrázek 4.5) je toto zhoršení kvality značně menší a SEARCH je svými výsledky velmi blízko těm, kterých dosahuje FreMEn. Dalším z cílů ladění hyperparametrů algoritmu SEARCH je proto dosažení lepšího výsledku středně dlouhodobé predikce (245 dní) při nejkratší z trénovacích epoch, tedy 35 dní, zacílením inicializační funkce generování pozic frekvencí, množství jí generovaných pozic/vzorků N , velikostí prohledávaných intervalů v okolí generovaných pozic (více níže) a poměr úspěšnosti (Success Rate/SR) nalezení lokálního maxima v okolí vygenerovaných pozic. Popis parametrů a jejich výchozí hodnoty je v sekci 2.2.1

5.2 Návrh možných řešení

Funkce generování pozic napříč frekvenčním spektrem pro prohledávání

Jak popsáno v 2.2.1, v původní implementaci algoritmu SEARCH dochází k prvotnímu hledání dominantních periodicit v okolí náhodně vybraných vzorků z intervalu P_{\min} až P_{\max} . K dosažení podrobnějšího hledání v nižších periodicitách má funkce pro generování těchto vzorků tvar

$$p = r^2 (P_{\max} - P_{\min}),$$

kde $r \in \mathbb{R}$ je náhodné číslo z intervalu $(0, 1)$.

Nově navržená funkce pro generování N náhodných čísel sloužících k tomuto účelu rozdělí interval $(0, 1)$ na $\lfloor \frac{N}{2} \rfloor + 1$ podintervalů nalezením jejich hranic způsobem popsaným v algoritmu 3. Z každého z takto vytvořených intervalů jsou vygenerována dvě náhodná čísla, s výjimkou prvního a posledního, ze kterých je generováno jedno číslo. V případě, že N je liché, je jedno náhodné číslo generováno navíc rovnoměrně z celého intervalu $(0, 1)$. Příklad množiny vygenerovaných čísel pro $N = 115$ je na obrázku 5.1

Algoritmus 3 Nalezení hranic pro rozdělení intervalu $(0, 1)$.

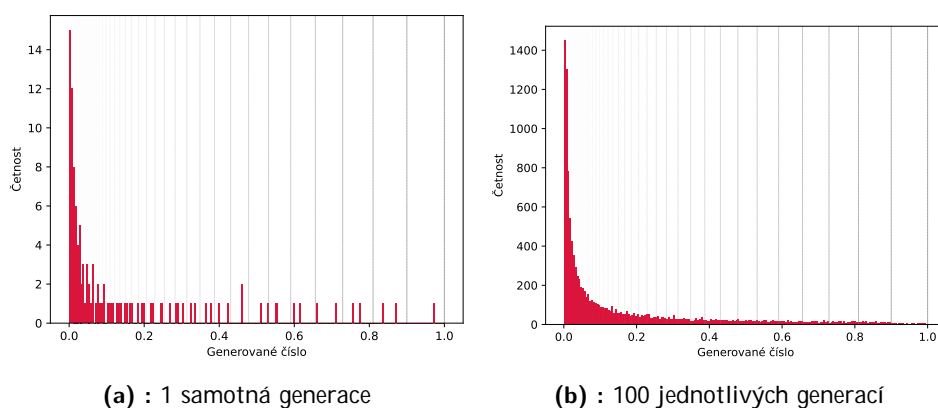
Input

N — počet čísel k vygenerování

```

1:  $n\_bounds \leftarrow \text{floor}(N/2)$ 
2: if  $N \leq 90$  then
3:    $bound\_gen \leftarrow 0.9$ 
4: else
5:    $bound\_gen \leftarrow N/100$ 
6: end if
7:  $bounds \leftarrow bound\_gen^i \quad i : 1, 2, \dots, n\_bounds$ 

```



Obrázek 5.1: 115 náhodně vygenerovaných čísel z intervalu $(0, 1)$ pomocí nové generativní funkce.

■ Optimalizace hyperparametrů Success Rate a velikosti prohledávaných intervalů

Hyperparametry ν a ϵ a success rate (jejich funkce je popsána v sekci 2.2.1) mohou nabývat reálných hodnot a jejich vliv na výkonnost algoritmu je z principu těžko odhadnutelný, ruční ladění těchto parametrů se projevilo být značně neintuitivní. Naivním a implementačně primitivním pokusem o nalezení představy jejich vlivu bylo použití metody grid-search se zaměřením na kvalitu predikce jednoho konkrétního dne hned po trénovací epoše. Komplikace, která v těchto experimentech nastává, je rozdílná kvalita predikce napříč zvolenými časovými řadami — ty samé hodnoty parametrů vedou na zásadně rozdílné výsledky v jiných časových řadách. V dalších pokusech o jejich optimalizaci tedy byla metrika R^2 zkoumaných časových řad normována pro každou z nich do intervalu $(0, 1)$, tedy nejlepší predikce pro časovou řadu A měla stejnou hodnotu, jako nejlepší predikce pro časovou řadu B, i když jejich kvalita se mohla řádově lišit. Tímto způsobem se úloha nalezení parametrů přenesla z otázky „Jaké hodnoty hyperparametrů vedou na nejlepší predikci?“ na otázku „Jaké hodnoty hyperparametrů vykazují nejlepší výsledky v poměru k ostatním hodnotám při modelování stejného jevu?“

Pro účely testování byla původní množina 50 stanic rozdělena na 30 trénovacích a 20 testovacích, jelikož zaměření se na optimalizaci v kontextu řad má přímý vliv na výsledky výkonu algoritmu při užití na těchto řadách. Grid-search metoda byla nahrazena Bayesovským optimalizačním algoritmem [21], který je používán pro optimalizaci algoritmů s vysokou výpočetní náročností [6]. Byly prohledány celkem 3 prostory různých rozměrů hodnot těchto parametrů S_1 , S_2 a S_3 (jak jsou zaneseny v tabulce 5.1)

Bohužel ani takto navržené pokusy nevedly na nalezení vlivu nastavení těchto parametrů na kvalitu predikce.

-	interval v i c i n i t y	interval SR
S_1	(0.001, 0.100)	(0.300, 0.450)
S_2	(0.001, 0.040)	(0.380, 0.420)
S_3	(0.005, 0.015)	(0.040, 0.415)

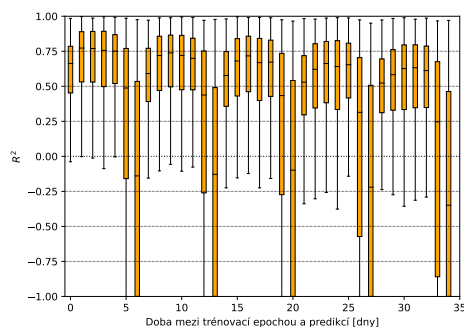
Tabulka 5.1: Prohledávané prostory nastavení parametrů v i c i n i t y a success rate

5.3 Výsledky


Nasazení nově navržené funkce pro generování náhodných čísel pro prohledávání spektra potenciálních dominantních periodicit se projevilo zlepšením predikce víkendů a ze všech testovaných hyperparametrů mělo na tento jev největší vliv. S generující funkcí úzce souvisí množství prohledávaných vybraných vzorků N , ve výchozí verzi algoritmu (s původní generující funkcí) byla hodnota nastavena na $N = 100$. Při experimentech s nově navrženou generující funkcí byly vyzkoušeny různé hodnoty pro N od 75 do 150. Při hodnotách $N > 110$ byla kvalita modelu dostatečně stabilní (a vyšší než za využití původní generující funkce), a protože vyšší hodnoty tohoto parametru vedou na větší výpočetní náročnost algoritmu, byl počet prohledávaných vzorků N v dalších experimentech nastavena na 115. Obrázek 5.2 obsahuje srovnání výsledků experimentů s původním a novým nastavením generující funkce.

Při trénovacím období 35 dní dochází s nově vytvořenou generující funkcí k celkovému zlepšení, tedy všední dny i víkendy jsou modelovány lépe, než s původní generující funkcí. Pro trénovací období 245 (obrázek 5.2d) dochází k současnému zhoršení predikce všedních dní a zlepšení víkendů. Stabilně nejlépe predikovaným dnem je v těchto experimentech sobota. Příčina těchto výsledků není známá.


Snahy o zlepšení kvality střednědobé predikce (245 dní) při krátké trénovací době (35 dní) nebyly úspěšné. Minimální pozitivní vliv na výsledky má zlepšení předtím špatných predikcí víkendu, ale degradující trend zůstává stejný, viz obrázek 5.3.




(a) : Výchozí SEARCH, trénovací období 35 dní



(b) : Nov navržená funkce generování pozic, trénovací období 35 dní




(c) : Výchozí SEARCH, trénovací období 245 dní




(d) : Nov navržená funkce generování pozic, trénovací období 245 dní

Obrázek 5.2: Srovnání R^2 modelů vytvořených algoritmem SEARCH s původní (vlevo) a nově navrženou (vpravo) funkcí pro prohledávání spektra periodicit. Predikce následujících 35 dní.



(a) : Výchozí SEARCH.



(b) : Nová funkce generování pozic.

Obrázek 5.3: Srovnání R^2 modelů vytvořených algoritmem SEARCH s původní (vlevo) a nově navrženou (vpravo) funkcí pro prohledávání spektra periodicit. Trénovací období 35 dní, předpověď 35 následujících týdnů.

Kapitola 6

Závěr a diskuze

Tato práce se zabývá výběrem a analýzou metod používaných v mobilní robotice pro dynamické mapování a snahám o navržení postupu pro jejich zlepšení.

V kapitole 2 jsou vybrány dva algoritmy založené na stejném principu a popsány jejich rozdíly, které plynou z různé úrovně jejich obecnosti. Je zde také představena metrika, která je použita při hodnocení jejich výkonnosti. Kapitola 3 obsahuje seznámení s podobou datasetů běžně používaných v oblasti mobilní robotiky a uvádí vlastnosti datasetu, na kterém lze provést hlubší analýzu zvolených metod. Je zde také popsán konečný zvolený dataset a jakým způsobem byl připraven na provedení následujících experimentů. Základní série experimentů, jejich návrh a výsledky, jsou v kapitole 4. Tato kapitola obsahuje také nalezení oblastí, ve kterých jeden ze zvolených algoritmů (SEARCH) dosahuje horších výsledků v porovnání s konkurentním algoritmem a slouží tak jako výchozí bod pro snahy v kapitole 5, ve kterých jsou testována vnitřní nastavení metody SEARCH a následná snaha o jejich zlepšení. Jeden ze dvou zvolených přístupů (nalezení nové funkce pro účely náhodného hledání vzorků napříč spektrem periodicit) dosahuje v následných experimentech lepších výsledků než původní nastavení algoritmu. Pokusy o nalezení optimálních hodnot dvou hyperparametrů algoritmu SEARCH pomocí metody grid-search a Bayesovské optimalizace nebyly úspěšné.

V práci lze pokračovat několika směry: je možné provést hlubší analýzu fungování metody SEARCH ve scénářích, ve kterých oproti ověřené metodě FreMEEn selhává. Konkrétněji, přesná podoba množin nalezených periodicit a pořadí, v jakém jsou dominantní periodicity nalezeny jsou oblasti, které v této práci nebyly zkoumány. Z již vykonaných experimentů je také možné identifikovat nové oblasti, ve kterých zkoumané algoritmy dosahují nekonzistentních výsledků.



Příloha A

Seznam příloh

codes. zip Zdrojové kódy s implementací v jazyce Python



Bibliografie

- [1] P. Allen a Bernard Morzuch. “Twenty-five years of progress, problems, and conflicting evidence in econometric forecasting. What about the next 25 years?” In: *International Journal of Forecasting* 22 (ún. 2006), s. 475–492. DOI: 10.1016/j.ijforecast.2006.03.003.
- [2] Metropolitan Transportation Authority. *Developers Turnstile Data Description*. 2010. (Cit. 10.05.2023).
- [3] Metropolitan Transportation Authority. *Developers Turnstile Data Source*. 2010. (Cit. 10.05.2023).
- [4] S. Bagchi a S. K. Mitra. “The Nonuniform Discrete Fourier Transform”. In: *Nonuniform Sampling: Theory and Practice*. Ed. Farokh Marvasti. Boston, MA: Springer US, 2001, s. 325–360. DOI: 10.1007/978-1-4615-1229-5_7. URL: https://doi.org/10.1007/978-1-4615-1229-5_7.
- [5] Alexander Barnett, Jeremy Magland a Ludvig af Klinteberg. “A Parallel Nonuniform Fast Fourier Transform Library Based on an “Exponential of Semicircle” Kernel”. In: *SIAM Journal on Scientific Computing* 41 (led. 2019), s. C479–C504. DOI: 10.1137/18M120885X.
- [6] James Bergstra et al. “Algorithms for Hyper-Parameter Optimization”. In: *Proceedings of the 24th International Conference on Neural Information Processing Systems*. NIPS’11. Granada, Spain: Curran Associates Inc., 2011, s. 2546–2554. ISBN: 9781618395993.
- [7] Krishnan Bhaskaran et al. “Time series regression studies in environmental epidemiology”. In: *International Journal of Epidemiology* 42.4 (čvn. 2013), s. 1187–1195. ISSN: 0300-5771. DOI: 10.1093/ije/dyt092.
- [8] Brscic D. et al. “Person position and body direction tracking in large public spaces using 3D range sensors”. In: *IEEE Transactions on Human-Machine Systems* 43, No. 6 (2013), s. 522–534.
- [9] *DSCOVER: Deep Space Climate Observatory*. (Cit. 10.05.2023).
- [10] D. Hähnel, Dirk Schulz a Wolfram Burgard. “Map Building with Mobile Robots in Populated Environment”. In: sv. 17. Ún. 2002, 496–501 vol.1. ISBN: 0-7803-7398-7. DOI: 10.1109/IRDS.2002.1041439.

- [11] Nick Hawes et al. “The STRANDS Project: Long-Term Autonomy in Everyday Environments”. In: *CoRR* abs/1604.04384 (2016). arXiv: 1604.04384. URL: <http://arxiv.org/abs/1604.04384>.
- [12] Davide Chicco, Matthis J. Warrens a Giuseppe Jurman. “The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation”. In: *PeerJ Comput Sci.* (čvc. 2021). DOI: 10.7717/peerj-cs.623.
- [13] Winston Churchill a Paul Newman. “Experience-based navigation for long-term localisation”. In: *International Journal of Robotics Research* 32 (pros. 2013), s. 1645–1661. DOI: 10.1177/0278364913499193.
- [14] Tomáš Krajník et al. “FreMEEn: Frequency Map Enhancement for Long-Term Mobile Robot Autonomy in Changing Environments”. In: *IEEE Transactions on Robotics* PP (srp. 2017), s. 1–14. DOI: 10.1109/TR0.2017.2665664.
- [15] Tomáš Krajník et al. “Spectral Analysis for Long-Term Robotic Mapping”. In: květ. 2014. DOI: 10.1109/ICRA.2014.6907396.
- [16] Tomáš Krajník et al. *STRANDS public datasets*. URL: <https://linc.n.ac.uk/nextcloud/shared/datasets/index.html> (cit. 10.05.2023).
- [17] Tomasz Kucner et al. “Conditional transition maps: Learning motion patterns in dynamic environments”. In: *2013 IEEE/RSJ International Conference on Intelligent Robots and Systems*. 2013, s. 1196–1201. DOI: 10.1109/IR0S.2013.6696502.
- [18] Tomasz Kucner et al. *Probabilistic Mapping of Spatial Motion Patterns for Mobile Robots*. Květ. 2020. ISBN: 978-3-030-41807-6. DOI: 10.1007/978-3-030-41808-3.
- [19] *Laboratory of Chronorobotics, CTU FEE*. 2020. (Cit. 10.05.2023).
- [20] Chris Linegar, Winston Churchill a Paul Newman. “Made to Measure: Bespoke Landmarks for 24-Hour, All-Weather Localisation with a Camera”. In: *2016 IEEE International Conference on Robotics and Automation (ICRA)*. Stockholm, Sweden: IEEE Press, 2016, s. 787–794. DOI: 10.1109/ICRA.2016.7487208.
- [21] J. Močkus. “On bayesian methods for seeking the extremum”. In: *Optimization Techniques IFIP Technical Conference Novosibirsk, July 1–7, 1974*. Ed. G. I. Marchuk. Berlin, Heidelberg: Springer Berlin Heidelberg, 1975, s. 400–404. ISBN: 978-3-540-37497-8.
- [22] Sergi Molina et al. “Modelling and Predicting Rhythmic Flow Patterns in Dynamic Environments”. In: pros. 2017, s. 26–28. DOI: 10.31256/UKRAS17.9.
- [23] Andrey Rudenko et al. “THÖR: Human-Robot Navigation Data Collection and Accurate Motion Trajectories Dataset”. In: *IEEE Robotics and Automation Letters* 5.2 (dub. 2020), s. 676–682. DOI: 10.1109/Lra.2020.2965416.

