



Česká zemědělská univerzita v Praze
**Fakulta životního
prostředí**

**ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE
FAKULTA ŽIVOTNÍHO PROSTŘEDÍ**

KATEDRA PROSTOROVÝCH VĚD

**Zhodnocení možností využití programu R k analýze
telemetrických dat**

BAKALÁŘSKÁ PRÁCE

..

**Vedoucí práce: Ing. Vojtěch Barták, Ph.D.
Bakalant: Ivo Kadlec**

2021

Prohlášení

Prohlašuji, že jsem tuto bakalářskou práci na téma: zhodnocení možností využití programu R k analýze telemetrických dat, vypracoval samostatně a citoval jsem všechny informační zdroje, které jsem v práci použil a které jsem rovněž uvedl na konci práce v seznamu použitých zdrojů.

Jsem si vědom, že na moji bakalářskou práci se plně vztahuje zákon č. 121/2000 Sb. o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů, ve znění pozdějších předpisů, především ustanovení §35 odst. 3 tohoto zákona, tj. o užití díla.

Svým podpisem rovněž prohlašuji, že elektronická práce je totožná s verzí tištěnou a že s údaji uvedenými v práci bylo nakládáno v souvislosti s GDPR.

V Praze de 31. 3. 2021

.....

Poděkování

Rád bych touto cestou poděkoval Ing. Vojtěchu Bartákovi, Ph.D. za vedení práce, jeho odborné rady, čas, a hlavně za jeho ochotu při zpracování celé práce. Dále bych rád poděkoval Iulii Piliugině za její podporu a celé rodině, které mi věřila. Děkuji.

V Praze 31. 3. 2021

Abstrakt

Práce představuje možnosti využití programu R pro analýzu GPS telemetrických dat, která je důležitou částí pro pochopení pohybu zvířat. Pohybové vzorce zvířat jsou nedílnou součástí prostorové ekologie, která se pokouší vysvětlit a popsat pohyb, jak jednotlivců, tak i populací. Pokládá si různé otázky, pokouší se na ně odpovědět a často se prolíná s behaviorální ekologií a spolu propojují vzorce chování s vzorci pohybovými.

V rešeršní práci je obecně představena prostorová ekologie samotná, různé typy pohybu a její propojení s behaviorální ekologií. Následně je popsán i monitoring zvířat, který získává potřebná pohybová data, které se následně analyzují různými způsoby. Práce popisuje analýzu dat z GPS telemetrie, která se díky rychle vyvíjecím technologiím stává čím dál více populární.

Jednou možností analýzy dat je použití různých balíčků v programu R, kterých je nesmírné množství. Pro praktickou část práce byli vybráni dva z nich. Balíček *trajr*, který slouží k vizualizaci a analýze trajektorie. A balíček *moveHMM*, používající skryté Markovovy modely. Balíček *moveHMM* byl vyzkoušen na pohybových datech samice geparda štíhlého (*Acinonyx jubatus*), která během monitoringu otěhotněla a následně porodila několik mláďat. Výsledné modely byly poté porovnány s teoretickými znalostmi o pohybu gepardů v různých reprodukčních stádiích.

Analýza pohybových dat je nesmírně složitá a je potřeba vyvíjet a zkoušet nové balíčky v programu R. Navíc je potřeba získat i další informace k pohybovým datům, které pomůžou vysvětlit určité anomálie v pohybu, které vznikají vnějšími faktory.

Klíčová slova: prostorová ekologie, behaviorální ekologie, skryté Markovovy modely, GPS technologie, monitoring, gepard štíhlý

Abstract

This project presents the possibility of using an analytical program RStudio for GPS telemetry data analysis which is an important aspect for understanding the animal movement. The movement patterns of animals are an integral part of movement ecology. Movement ecology is trying to explain and describe the movement of both individuals and populations. This work asks various questions, tries to find answers, and often intertwines with behavioural ecology, connects behaviour and movement patterns.

The research part introduces movement ecology itself, different types of movement and the connection of movement and behavioural ecology. Subsequently, the monitoring of animals which is described obtains the necessary movement data, which are further analysed in various ways. The work describes the analysis of data from GPS telemetry, a method that has become increasingly used due to rapidly evolving technologies.

One of the possibilities of data analysis is to use diversified packages in the program R. For the practical part of the work I have chosen two packages. The Trajr package, which is used to visualise and analyse the trajectory, and the moveHMM package, using hidden Markov models. The moveHMM package was tested on the movement data of a cheetah female (*Acinonyx jubatus*), which became pregnant during monitoring and subsequently gave birth to several pups. The resulting models were then compared with theoretical knowledge about the movement of cheetahs in different reproductive stages.

The analysis of movement data is extremely complex and therefore it is needed to develop, test, and evaluate new packages in the R program. Additionally, there is a need to obtain further information on movement data that will help to explain certain movement anomalies caused by external factors.

Keywords: movement ecology, behavioural ecology, hidden Markov models, GPS technology, monitoring, cheetah

Obsah

1	Úvod.....	1
2	Cíl práce	2
3	Literární rešerše.....	3
3.1	Prostorová ekologie zvířat.....	3
3.1.1	Typy pohybu	5
3.1.2	Domovské okrsky	12
3.1.3	Teritorium	13
3.1.4	Behaviorální ekologie	15
3.2	Způsoby monitoringu pohybu zvířat	16
3.2.1	Neinvazivní metody	17
3.2.2	Invazivní metody.....	22
3.3	Analýza dat z GPS telemetrie.....	26
3.3.1	Odhad domovských okrsků.....	27
3.3.2	Analýza trajektorie - pohybové vzorce	28
3.3.3	Propojení údajů o pohybu s prostředím	29
3.3.4	Propojení údajů o pohybu s módy chování	29
4	Metodika	33
4.1	Příprava dat.....	33
4.2	Analýza a vyhlazení trajektorie pomocí balíčku trajr.....	34
4.2.1	Vizualizace trajektorie	34
4.2.2	Analýza trajektorie	36
4.2.3	Náhodné generování trajektorie	38
4.3	Analýza stavů/modů chování pomocí moveHMM.....	39
5	Výsledky	44
5.1	Model pro samici geparda štíhlého před březostí.....	44

5.2	Model pro březí samici.....	46
5.3	Model pro samici s mláďaty.....	48
5.4	Srovnání modelů.....	49
6	Diskuze.....	52
6.1	Zhodnocení balíčků trajr a moveHMM.....	52
6.2	Relevance výsledků z hlediska ekologie sledovaných druhů.....	53
7	Závěr	55
8	Přehled literatury a použitých zdrojů	56
9	Seznam obrázků	63
10	Přílohy.....	65

1 Úvod

Prostorová ekologie se v tomto století dostává čím víc ke slovu a spousta vědců si pokládá otázky spojené s pohybem: Jakým způsobem se člověk či zvíře pohybují? Proč najednou změnil jedinec směr? K jakému pohybu se živočich rozhodne, pokud má hlad nebo je v ohrožení? Jakým způsobem ovlivňuje jedince jeho okolí? Jak je spojené chování jedince a jeho pohyb? Aby toho nebylo málo, prostorová ekologie se prolíná s behaviorální ekologií a dalšími disciplínami, a otázek tak přibývá víc a víc.

Důležitým posunem v prostorové ekologii byl vývoj telemetrických metod monitoringu zvířat, poskytující informace o jejich pohybu v nebývalé kvalitě a kvantitě. Dovoluje zaznamenávat pohyb jedince po dlouhé časové úseky a většinou jí nestojí v cestě ani špatná vegetace, anebo ukrytý život zvířete. Zaznamenávání a získávání dat je důležitou částí, ale analýza telemetrických dat pomáhá k získávání informací, které pomáhají pochopit pohybové vzorce jedinců, skupin, a dokonce i celých populací. K analýze dat se používá neskutečné množství metod a programů, ale program R se pomalu začíná stávat nedílnou součástí jak prostorové ekologie, tak i ekologie obecně.

Tato práce se snaží představit jak prostorovou ekologii, sběr dat, tak i balíčky v programu R sloužící k analýze GPS telemetrických dat s největším důrazem na skryté Markovovy modely.

2 Cíl práce

Cílem práce je představit a demonstrovat možnosti analýzy GPS telemetrických dat v programu R, a u konkrétních balíčků zhodnotit silné a slabé stránky. Zvláštní důraz je přitom kladen na analýzu GPS trajektorií pomocí skrytých Markovových modelů, s cílem identifikovat stavy chování zvířete na základě jeho polohové informace.

3 Literární rešerše

3.1 Prostorová ekologie zvířat

Pohyb organismů je jedním z klíčových mechanismů podílejících se na biologické diverzitě, a to na úrovni ekosystémové, druhové i genetické. K jeho studiu vznikl mezioborový předmět s názvem prostorová ekologie, který se stále více uplatňuje. Prostorovou ekologií se dnes zabývají populační ekologové, matematici, statistici a další obory, kterých postupně přibývá (Jeltsch, 2013).

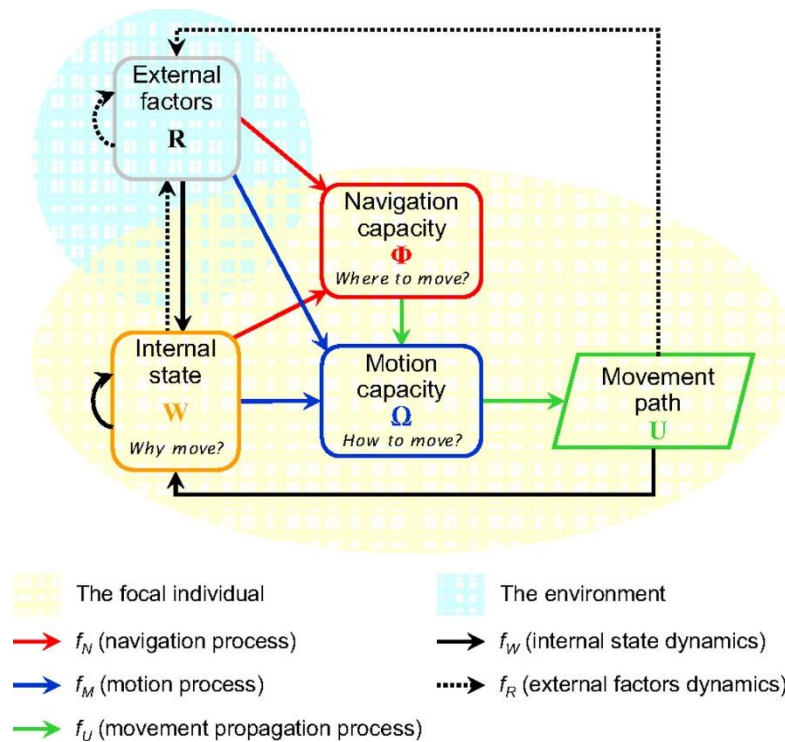
Základním pilířem prostorové ekologie je pohyb organismu a několik souvisejících otázek. Proč se organismus pohybuje? Jakým způsobem se organismus pohybuje? Kdy a jakým směrem se pohybuje? Jak ekologie a evoluce ovlivňuje pohyb? Pohyb organismů je základní charakteristikou života na zemi a lze jej definovat jako posun celého jedince v čase (Gurarie, 2016).

Práce se zabývá pohybem v říši zvířat, a proto se následující informace o prostorové ekologii budou týkat přímo zvířat, s největším důrazem na savce.

Pohyb jedince hraje velkou roli v jeho vlastním osudu, ale celkově i v dynamice populace, společenství, ekosystému, a přispívá tak i k vývoji a rozmanitosti života na zemi. K pohybu může organismus dovést určitý vnitřní stav, jako je třeba hlad, nebo například potřeba se rozmnožovat (pohyb za hledáním partnera). Může však také dojít i k podnětu zvenčí, např. velká konkurence, změna počasí, migrace potravy (spousta specializovaných predátorů se pohybuje spolu se svojí potravou). Pochopením vzorců chování a mechanismů určujících pohyb zvířete lze pohyb předpovídat, určit domovské okresky, zabránit množení invazivních druhů, ale především jde jednodušeji plánovat ochranu přírody jako celku (Gurarie, 2016).

Prostorová ekologie tedy nezkoumá jen samostatný pohyb, ale snaží se přijít také na příčiny, mechanismy a na vzorce pohybu, které by měly pomoci pochopit, jaký má pohyb důsledek na ekologii jedince, společenstev a ekosystémů. K znázornění mechanismu pohybu můžeme použít například jednoduchý „diagram“ (obr. č. 1), který znázorňuje určitého jedince charakterizovaného třemi vnitřními složkami: kapacitou pohybu, schopností navigace a vnitřním stavem a jednou vnější složkou, kterou lze chápat jako všechny vnější faktory, které mohou jedince ovlivnit (všechny abiotické i biotické aspekty). Odpovědi na všechny tyto otázky dají vzniknout nové a nejsložitější

otázce: „Jak všechny tyto složky mezi sebou interagují a vytváří pohyb?“ (Nathan, 2008).



Obr. č. 1 – Diagram mechanismu pohybu.

(Nathan, 2008)

Vnitřní stav se řídí fyziologickým a někdy i psychologickým stavem jedince, který ho vede k určitému cíli. Proto se k němu přiřazuje otázka: „Proč se pohybovat (Nathan, 2008)?“

Odpovědí na otázku může být například hlad, blízkost predátora, reprodukce. Ne vždy ale musí být odpověď viditelná, jednoznačná, a pohyb může vyvolat i nepozorovaná věc, jako je třeba změna teploty. Vnitřní stavy mohou být jednoduché, ale také mohou být vytvářeny složitějšími ději a během životního cyklu se mohou změnit (Nathan, 2008).

Kapacita pohybu ovlivňuje schopnost jedince se pohybovat v různých momentech, situacích, a souvisí přímo se schopností provádět určitý pohyb a posunout se z bodu „A“ do bodu „B“. Pohybová kapacita vychází z biomechanických vlastností umožňující například gepardovi běhat, levhartům šplhat po prudkých skalách, anebo různým vodním ptákům umožňuje více pohybů: létání, plavání a chůzi po souši.

Kapacita pohybu je vysoce provázaná s vnitřními stavy a vnějšími podněty (Nathan, 2008).

Každý jedinec má určitou schopnost orientovat se v prostoru a čase, vybrat si směr, kterým se vydá, kdy se zastaví, anebo kdy pohyb zahájí. Tato schopnost orientace se dá označit jako „schopnost navigace“. Cíl pohybu je většinou pevně daný (např. hledání útočiště, potravy, obejití překážky), ale navigace k jeho cíli může být různá a u každého organismu zcela odlišná. Většina organismů zpracovává vnější informace, poté je využívá k orientaci a rozhodnutí se „kam se pohybovat“. Vyžaduje určitou schopnost reagovat jak na tyto vlivy, tak i na jiné jedince. Například někteří hadi, jako chřestýšoví (*Crotalinae*) či, hroznýšoví (*Boidae*), používají termoreceptory umístěné nad horní čelisti k vyhledávání své kořisti pomocí tepla (Rogers, 1999). Naopak třeba někteří ptáci se dokáží přesunout z jednoho místa na druhé bez předešlé zkušenosti a bez pomoci dospělých jedinců, jen pomocí orientování se pomocí vnějších „vjemů“ (Nathan, 2008).

Prostorová ekologie je komplikovaný obor, a jak je už naznačeno výše, pohyb neovlivňuje jen mechanismus, ale také evoluční historie jedince a jeho genetika (Jeltsch, 2013).

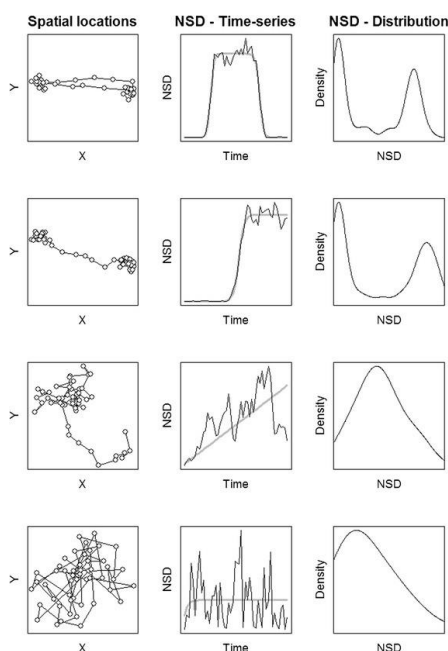
3.1.1 Typy pohybu

Mechanismus pohybu je mezi různými organismy odlišný. Zvířata, rostliny, mikroorganismy se pohybují jinými způsoby. Živočichové se pohybují primárně aktivním pohybem, který je výsledkem vlastní činnosti, a který dokáže jedinec ovládat a díky němu změnit svou pozici. Ten lze poté rozdělit na 3 typy pohybu: pohyb pomocí brv nebo bičíku, pohyb améboidní, anebo pohyb svalový. Rostliny a mikroorganismy, se na rozdíl od živočichů dokážou pohybovat jak aktivně, tak i pasivně. Pasivní pohyb se naopak popisuje jako pohyb pomocí vnějších faktorů, který jedinec nemůže ovládat. Může to být například pohyb ve vodě nebo vzduchu. Výzkum pohybu je sice rozsáhlý, ale každý pohyb lze většinou jednoznačně kvalifikovat a zařadit do už známých mechanismů pohybu podle cíle pohybu (shánění potravy, obcházení domovského okrsku, hledání partnera), pohybu souvisejícím s prostředím, stanovištěm, anebo kvůli času. Existuje spousta možných rozdělení podle mechanismů, anebo vzorců pohybu. V práci kvalifikujeme pohyb podle širších pohybových strategií a vzorců na rozmístování (dispersal), nomadismus, sedentarismus a migraci (Dingle, 2014).

Nomádské druhy – nomadismus

Mnoho zvířecích druhů vykazuje nepravidelný typ pohybu, který nepatří do tradičního rozdělení souvisejícího s pohybem zvířat. Tímto pohybem je nomadismus. Jedná se o nepravidelný pohyb na dlouhé vzdálenosti, který nejde zavést přímo pod pojem „sezonní migrace“. Nomádské druhy mohou mít jedinečný vliv na populace, společenství a ekosystém (Teitelbaum, 2019). Můžeme je najít napříč různými taxony a oblastmi. Mezi nomády patří například: orel bělohlavý (*Haliaeetus leucocephalus*) (Wheat, 2017), los evropský (*Alces alces*) (Ball, 2001), krokodýl Johnstonův (*Crocodylus johnsoni*) (Tucker, 1997). Všechny tyto druhy spojují dva důležité faktory: náhodné vysoce různorodé prostředí s omezenými zdroji a nepravidelné pohybové vzorce s velkou vzdáleností přesunu (Teitelbaum, 2019).

Dlouhou dobu byly nomádské druhy považovány za migranty, ale díky novým technologiím, jako je GPS telemetrie, bylo zjištěno, že tyto pohyby mají široký a nepravidelný vzorec. Poslední dobou se objevil i pokus rozlišit migraci a nomadismus, a to konkrétně při použití kategorizace trajektorií pomocí Net Squard Displacement (NSD). NSD je druhá mocnina přímé (tj. euklidovské) vzdálenosti mezi daným místem výskytu jedince a počátečním místem, odkud začal jeho pohyb. NSD je možné vynést do grafu jako funkci času pro celou trajektorii, přičemž jednotlivé typy pohybu lze charakterizovat typickým tvarem vzniklé křivky. U nomádických druhů se NSD zvyšuje lineárně, naproti tomu u migrantů má tvar sinusoidy. U sedentárních jedinců má tvar asymptotický a u rozmisťování tvar sigmoidu (obr. č. 2) (Bunnefeld, 2011). Dalším základním rozdílem je distribuce zdrojů, která je u nomádických druhů nepředvídatelná jak v prostoru, tak i čase. Na rozdíl od migrantů se nomádi pohybují nezávisle na sobě po cestách, které se nemusí opakovat celé roky (Mueller, 2011).



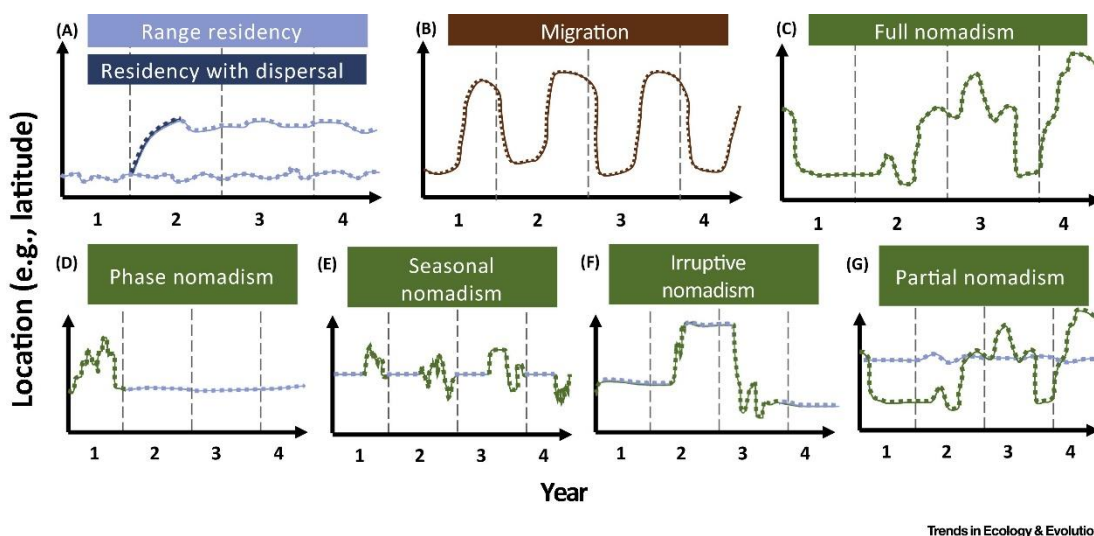
Obrázek č. 2 – Grafické zobrazení 4 strategií; první řádek = migrace, druhý řádek = dispersal, třetí řádek = nomadismus, čtvrtý řádek = sedentarismus.

(Bunnefeld, 2011)

Nomádi se pohybují mezi vzdálenými místy a jejich pohyb je mnohdy na dlouhou vzdálenost, namísto toho, aby zůstávali na jednom místě ve formě domovského okrsku. Od migrantů se rozlišují především tím, že navštěvují nová, neznámá místa, a to jak v krátké, tak i dlouhé době. K nomádkému pohybu většinou vedou určité mechanismy. Nomádi žijí v nepředvídatelném prostředí, kde může dojít k vytažení z prostředí kvůli nepředvídatelnému jevu, přírodní katastrofou, díky malému množství potravy, nebo je zde vysoký tlak predátorů či vysoký výskyt parazitů ohrožující jedince. Někdy může být mechanismem „pouze“ přesun kvůli reprodukci, anebo naopak může důvod k pohybu zcela chybět. Zvíře se rozhodne k pohybu, aby se vrátilo na dříve neznámé místo, anebo objevilo nové, které může mít lepší podmínky. Jako příklad lze uvést orla bělohlavého, který se pohybuje určitým vzorcem, který má naučený, ale přitom se každý jedinec vydává na různé nepředvídatelné cesty. Chování některých jedinců odpovídá nomádkému stylu, ale zároveň existují jedinci, kteří nikdy ten to pohyb nevykonaly a „dávají přednost“ migraci (Wheat, 2017).

Nomádké druhy zahrnují spoustu různých živočichů od ptáků, savců až k hmyzu a mořským živočichům. Díky rozmanitosti druhů a míst, kde žijí, existují také mezi nomádkým pohybem podobné rozdíly jako u migrantů. Nomádký způsob pohybu lze rozdělit na několik dalších druhů: úplný, sezonní, fázový, částečný a iruptivní

(Teitelbaum, 2019). Úplní nomádi používají svoji strategii celý svůj životní cyklus a vůbec se od ní neodchylují. Naopak je to u nomádů fázových, sezónních, částečných a iruptivních (obr. č. 3). Částečná nomádská strategie je charakterizována jen částí populace, která tuto strategii používá. Většinou tady hraje velkou roli stáří a často i vnější faktory. Částečným nomádem je například los evropský (Ball, 2001), u kterého jeho pohyb ovlivňuje jak stáří, tak i hloubka sněhu a lidská přítomnost. Částečnému nomádství je hodně podobné fázové, které ovlivňuje jenom období v životním cyklu jedince. Mladý jedinec je nomád, ale v dospělosti přechází na jiný styl života a naopak. Příkladem tohoto pohybu můžou být už výše zmínění orli bělohlaví (Wheat, 2017) nebo sladkovodní krokodýli Johnstonovi (Tucker, 1997), kteří v mládí vykazují nomádskou strategii a v dospělosti se zdržují ve svých domovských okrscích. Sezonní nomádství, jak už napovídá název, charakterizuje změna strategie podle ročního období. Nejzvláštnějším případem nomádství je iruptivní, které nemá závislost ani na věku jedince či ročním období. K iruptivnímu nomádství dochází při narušení, které donutí jedince k dlouhému pohybu, který se špatně rozeznává od iruptivní migrace (Teitelbaum, 2019).



Obrázek č. 3 – Grafické zobrazení různých typů pohybu. Zelené linie označuje období nomádství, modrá zase naopak období setrvání na určitém místě.

(Teitelbaum, 2019)

Migranti – migrace

Migrace je cyklický pohyb vedoucí k přemístění jednotlivců či až populací ve velkém prostorovém měřítku. Důvodem může být pohyb kvůli zdrojům potřebný k přežití, anebo třeba i za účelem reprodukce. Podle důvodů lze rozdělit migraci na dva typy.

Prvním je migrace reprodukční, při které se jedinci přesunují z pevného bodu „A“ do bodu „B“ za účelem reprodukce (obr. č. 2) a po reprodukci se vrátí zpět do bodu „A“. Druhým typem je migrace za zdrojem potravy, kdy migranti sledují oblasti příznivých podmínek a zdroje potravy, příkladem jsou např. někteří kopytníci (Berdahl, 2016).

V porovnání s ostatními druhy pohybu se může migrace zdát jako více specializovaný typ pohybu, který je v poslední době čím dál více zkoumaný. Migrace patří k nejvýraznějšímu příkladu pohybu živočichů v přírodním světě. Patří mezi jedny z hlavních hybatelů ekosystémových procesů, silně ovlivňuje schopnost přežití a rozmnožování jak jedinců, tak i populací. Migrující zvířata jsou schopna nenávratně změnit ekosystém, přenášet patogeny, parazity, a někdy dokonce i způsobit katastrofický zánik původního ekosystému. Podobně jako nomádské druhy tak i migranti pochází z různých taxonů, které se pohybují různými způsoby. Pohybují se jak samostatně, tak i ve skupinách. Výzkum migrace je důležitá součást ochrany přírody (Jeltsch, 2013).

Biologové a ekologové popsali nespočet typů migrací. Jedno z rozdělení může být podle pohybových vzorců. Jednosměrnou migraci provádí převážně bezobratlí živočichové, a to jen jednou za život před svou smrtí za účelem se rozmnožit¹. Naopak k migraci „dvou světů“ (opakované) dochází periodicky několikrát za život. Jedinci se vrací opakovaně na místo, kde dochází k rozmnožování. Opakovanou migrace lze ještě rozdělit na migraci roční, sezonní a iruptivní. Jak už názvy napovídají, tak roční migrace probíhá jednou za rok, sezonní naopak několikrát ročně v závislosti na období. K iruptivní migraci dochází za podobných podmínek jak u iruptivního nomádství, kdy dojde k náhlému narušení života jedince a ten je nucen opustit svoji stávající oblast. Iruptivní migrace se může řadit jak mezi jednosměrné, tak i opakované (Dingle, 2007).

Důležitým pojmem k migraci je navigace, která pomáhá jedincům najít určitou oblast (na rozdíl od nomádů). Je dokázáno, že migranti sledují velmi podobné, někdy až identické migrační cesty (Dingle, 2007). Navigační schopnost je velmi specifická, liší se napříč taxony, někdy se i mění se stářím jedince. Mladí ptáci, kteří se vydávají na

¹ Někteří autoři mluví o migraci pouze v případě periodického pohybu s návratem do výchozího místa. V takovém případě by termín "jednosměrná migrace" nedával smysl, navíc by se v tomto případě mohlo mluvit i o rozmístování (dispersal). Terminologie v tomto směru není sjednocena (viz Tkadlec, 2008).

svou první migraci, se řídí geneticky podmíněnými programy o směru a vzdálenosti, ale při dalších opakovaných cestách se orientují podle kompasového mechanismu, který není ještě detailně prozkoumán (Åkesson, 2016).

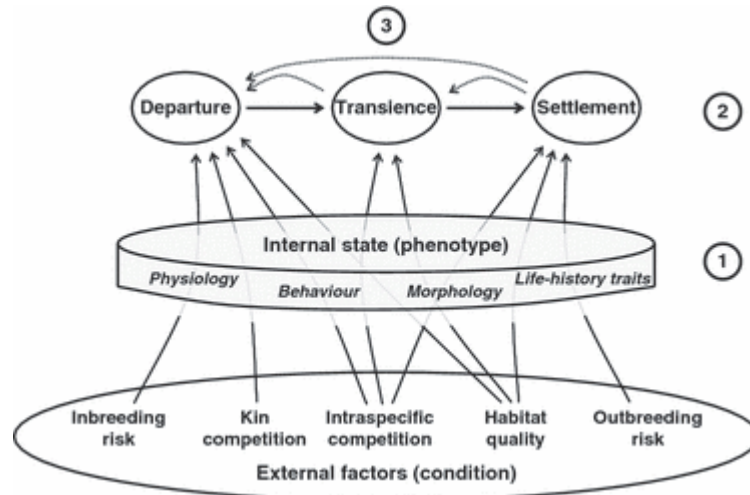
Rozmíst'ování (dispersal)

Rozmíst'ování je hlavním pohybem, který pomáhá k vyhnutí se inbreedingu, křížením mezi geneticky podobnými jedinci, určuje tok genů mezi populacemi a zajišťuje rychlý náhodný přesun při zhoršujících se podmínkách prostředí. Má velký vliv na genetickou strukturu populací, a to jak pozitivně, tak negativně. Jestliže rozmístění proběhne správně, ovlivňuje populaci pozitivně. Někdy, ale může vést k zvýšení mortality a k přesunu jedince na nevýhodné místo. Ukázalo se, že má i určitý vliv na mutualismus, šíření nemocí mutualismu, a dokonce i na zánik některých stanovišť (Jeltsch, 2013).

Rozmíst'ování je proces složený ze tří fází: rozhodnutí, přesunutí a usídlení. Velice silně souvisí i s reprodukcí. Většina organismů má schopnost rozmíst'ování a „používají“ ho většinou proto, aby našli nové stanoviště, které je pro ně vhodnější. Rozhodnout se pro rozmístění je pro jedince velice riskantní. Jedinci mohou sice najít lepší stanoviště s menší konkurencí, s lepšími podmínkami na reprodukci, ale na druhou stranu musí využít energii k pohybu, a ne vždy musí najít výhodnější stanoviště pro život. K rozhodnutí může vést více faktorů. Jedním z nich je například vysoká hustota populace nebo společenství. Při vysoké hustotě je pro jedince výhodné se přesunout a najít si nové stanoviště s nižší populační hustotou, ale i to je někdy složité. Pokud je hustota až příliš velká, tak k rozmíst'ování už s největší pravděpodobností došlo v minulosti, a pro přítomné jedince může být velmi riskantní (Calsbeek, 2009).

Mechanismus rozmíst'ování je závislý na fenotypu jedince, vnějších podmínkách, ale také na vnitřním stavu, kterým je myšleno pohlaví a fyzická zdatnost jedince. Důležitým „faktorem“ je i přímo druh zvířete. Každý živočich má svá vlastní kritéria, při kterých je pro něj výhodně hledat nové stanoviště. Rozhodnutí tedy závisí jak na vnitřním stavu, tak i na vnějších podmínkách a fenotypu. Tím pádem lze říct, že sklon k rozmíst'ování koreluje se znaky fenotypu (obr. č. 4). Podle fenotypu lze usuzovat, že existují rozdíly mezi jedinci, kteří se rozhodnou k rozmíst'ování, nebo ne. Pro úspěšnost je důležitá velká energie, která je potřebná k hledání nového stanoviště. U

jedinců, kteří jsou úspěšní, existuje buď fyziologická, morfologická, anebo behaviorální specializace, které zvyšuje jejich možnost úspěchu. Příkladem může být třeba hmyz, který má rychlý metabolismus (energie), silné svaly křídel a vhodný tvar těla (Clobert, 2009).



Obrázek č. 4 – Diagram znázorňuje propojení vnitřních stavů (fenotypu) a vnější faktorů (podmínek) na 3 fáze dispersal: rozhodnutí k pohybu, přesun, usídlení.

(Jeltsch, 2013)

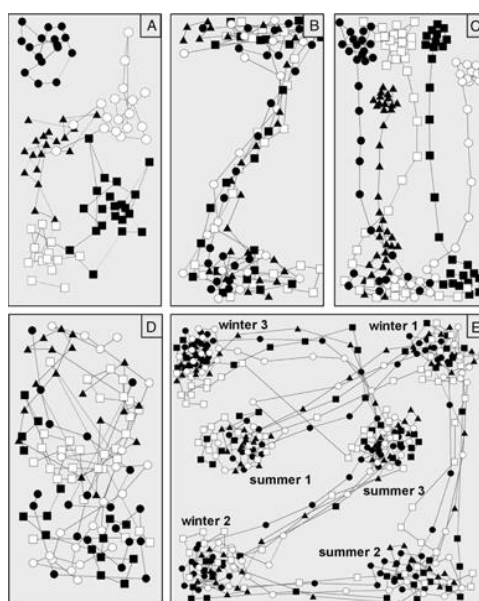
Důležité je i zmínit, že u spousty živočichů dochází k otázce, zda se přesunout nebo ne, už v útlém věku, a to buď po narození, anebo při dovršení dospělosti. Například gepardi štíhlí (*Acinonyx jubatus*) jsou po dvacátém měsíci, kdy se osamostatňují od matky, postaveni před rozhodnutím, jestli zůstat na aktuálním stanovišti a přidat se k tamní koalici (pokud se jedná o samce), anebo jít hledat nové stanoviště, které pro něj bude výhodnější kvůli menšímu množství konkurence. Takový způsob rozmíst'ování můžeme nazvat natální (Calsbeek, 2009; Durant, 2017).

Sedentarismus

Spousta jedinců upřednostňuje sedentární způsob života ve formě domovských okrsků a teritorií, tedy pokud se jedná o teritoriální taxony. Zde zvířata zůstávají skoro po celý svůj životní cyklus. Mezi sedentární druhy patří například matamata třásnitá (*Chelus fimbriatus*), jelen sika (*Cervus nippon*), vydra říční (*Lutra lutra*) a levhart skvrnitý (*Panthera pardus*). Sedentarismus může být výhodný hlavně v místech, kde jsou důležité zdroje pro život po celou dobu. Jedná se často o homogenní prostředí, které nemá tendenci se měnit. Naopak u heterogenního prostředí, kde nejsou životně důležité zdroje stále, se se sedentárními druhy moc nevyskytují (převládají tady

převažovat migranti a nomádi). Spousta druhů může za svého života přecházet mezi sedentarismem a migrací (Mueller, 2008; Bastille-Rousseau, 2017; Animalia, ©2020).

Při sedentarismu jedinec neprovádí pohyb na dlouhé vzdálenosti a žije v relativně malé oblasti v porovnání s rozsahem oblasti patřící populaci (obr. č. 5). Populace nebo jedinci se většinou nachází v přítomnosti životně důležitých zdrojů. Jediným větším pohybem v sedentarismu může být u některých druhů rozmisťování, a to jenom v raném stádiu životního cyklu (Mueller, 2008).



Obrázek č. 5 – Porovnání pohybových strategií. Pro tuto kapitolu je důležitá část A, která představuje skupiny sedentárních zvířat. Část B představuje migranty, C kombinaci A a B, D nomády.

(Mueller, 2008)

3.1.2 Domovské okrsky


W. H. Burt jako první definoval pojem „domovský okrsek“ a dal vzniknout novému konceptu, který se používá dodnes. Domovský okrsek je koncept v ekologii, který označuje plochu, kde zvíře tráví svůj čas, kde se pohybuje, kde má potravu a pečuje o svá mláďata. Při stanovování domovského okrsku je potřeba vzít v potaz i průzkumné procházky, při kterých se zvíře vydává i mimo domovský okrsek, a proto by se sem řadit neměly (Burt, 1943). Okrsky se mezi zvířaty v rámci druhů liší, a to někdy dokonce i mezi jedinci stejného druhu. Je to oblast, kde jedinci nebo skupiny žijí, a kde je největší pravděpodobnost jejich výskytu (Powell, 2012).

V minulosti se domovské okrsky odhadovaly prostým „obtažením“ zaznamenaných výskytů (tzv. metoda nejmenšího konvexního obalu, MCP – „Minimum Convex Polygon“). V současnosti se nejčastěji kvantifikují pomocí odhadu hustoty výskytu (tzv. „Utilization Distribution“) na základě bodových výskytů zvířete (Powell, 2012).

Na rozdíl od teritorií se okrsky většinou překrývají, někdy mohou obsahovat více než jedno teritorium. U některých druhů slouží jako „neutrální oblasti“, kde spolu zvířata nocují, anebo je zde společný zdroj potravy a vody (Veselovský, 2005).

3.1.3 Teritorium

Teritorium je oblast, kterou jedinec na rozdíl od domovského okrsku aktivně brání jak proti jedincům stejného druhu, tak někdy i proti jiným druhům. Teritorium leží v domovském okrsku jedince (obr. č. 6). Teritorium vytváří teritoriální jedinci, kteří mezi sebou „soutěží“, aby měli lepší podmínky k životu. Stanovit teritorium není lehké, a s jeho významem souvisí spousta otázek, na které se špatně odpovídá. Jak dlouho musí zvíře bránit své území, aby bylo bráno jako teritorium? Má teritorium určité hranice? Jak jedinec reaguje na přítomnost jiných druhů? Na tyto otázky není jednotný názor a spousta biologů by určila teritorium jinde než ostatní (Kamath, 2020).



Obrázek č. 6 –Obrázek znázorňuje domovské okrsky a jejich prolínání mezi sebou a souvislost okrsků s teritorií

(Burt, 1943)

Každý teritoriální druh si své území značí a následně hlídá. Značení vypadá u různých druhů jinak, ale většinou se nachází na hranici teritoria, a jedinec jím určuje své území. Značením oznamuje, „že tato oblast patří jemu“, a navíc díky značení může říct spoustu dalších informací, jako je například připravenost k reprodukci. Značení může být několika druhů:

1) Pachové označení – Nejvíce známým značením teritoria je pachové, které je nejvíce používané u savců v podobě moči, trusu, slin a třením se o vegetaci. Spousta savců používá k značení své pachové žlázy, které mohou uloženy jak u řitního otvoru, na hlavě, mezi prsty nebo v kopytu. Nejčastěji se používá moč, ve které se ukládají silně zapáchající látky, proteiny a feromony. Pachové značky mají další význam. Ukazují stav jedince, jeho pohlaví, staří a fyzickou zdatnost, a díky tomu mnohokrát odradí jedince stejného druhu překročit hranici (Veselovský, 2005).

2) Vizuální označení – Vizuální označení může být jak krátkodobé, tak i dlouhodobé. Nejčastěji sem patří stopy na vegetaci či výkaly (Veselovský, 2005). Levharti sněžní (*Panthera uncia/Uncia uncia*) (Fox, 2016) se opakovaně třou o kmeny či kameny, a zanechávají tak v nich chomáče chlupů. Naopak kočky divoké (*Felis silvestris*) „umísťují“ svůj trus na výrazných rostlinách (Piñeiro, 2012).

3) Akustické značení – Spousta zvířat používá k označení akustické signály, jakým může být například vytí vlka obecného (*Canis lupus*) (Dutcher, 2019).

Značení nemusí být jednoznačně jen jednoho typu. Značení ve formě trusu nebo tření o vegetaci může mít strukturu jak vizuálního, tak i pachového. Pokud dojde k překročení hranice jiným jedincem a setká se „majitelem“ teritoria, tak nejdříve dojde k „rituální agresi“, kdy jedinci používají určité pohyby a gesta k varování a ukázaní své síly. Tato „agrese“ je jednodušší, méně energeticky náročná, a především není nebezpečná. Jestliže „rituál“ neodežene nezvaného jedince, tak dojde k aktivní agresi, která končí zraněním a někdy i smrtí jednoho z jedinců (Veselovský, 2005).

Rozloha teritoria může být různorodá a většinou odpovídá velikosti jedince a jeho postavení v potravním řetězci. Velké šelmy mají z pravidla největší teritoria, a to v řádech stovek čtverečních kilometrů. Gepard štíhlí mají domovské okrsky o velikosti 500–700 km² a jejich teritoria zaujímají rozlohu 120–200 km², a to nepatří k predátorům na vrcholu potravního řetězce na jejich stanovištích (CARO, 1987). Velikost teritoria je daná ve velké míře množstvím potravy, kterou jedinci potřebují

k přežití, takže masožravci mají teritoria větší než býložravci. U všech jedinců se mění během životního cyklu, podle věku a jejich fyzické zdatnosti (Veselovský, 2005).

„Majitelem“ teritoria nemusí být jenom jeden jedinec, ale i větší počet jedinců stejného druhu. Spousta savců obhajuje svá teritoria v páru, anebo části skupin žijící v dané oblasti (Veselovský, 2005). U gepardů část samců žije samotářským životem a své teritorium obývají a brání sami. Druhá část samců tvoří složité koalice, ve kterých se jich zdržuje více a většinu koalic tvoří samci ze stejného vrhu, ale nemusí tomu tak vždy být. Spolu obývají a chrání teritorium a získávají spoustu benefitů, jako například lepší ochranu před většími a nebezpečnějšími predátory, kteří jim vytváří silnou konkurenci a další. Naopak samice žijí celý svůj život samotářsky bez daného teritoria, a mnohdy po narození mláďat nemají žádný stálý domovský okrsek (Krausman, 2005).

3.1.4 Behaviorální ekologie

Behaviorální ekologie je vědní disciplína zabývající se ekologickými faktory, které řídí chování zvířat. Klade si různé otázky: Jak se zvířata vyhýbají predátorům? Jak hledají svou potravu? Proč migrují a nezůstávají stále na jednom místě? Co ovlivňuje jejich život? Proč některá zvířata žijí samostatně a jiná ve skupinách? K odpovědi kombinuje ekologické a evoluční vzorce chování s behaviorálními procesy, vzorci, a tyto nové ekologické vzorce chování analyzuje (Pimm, 1999).

Behaviorální ekologie vznikla z etologie, a to konkrétně z otázek biologa a ornitologa Nikolaase Tinbergena, který se spolu s Konrádem Lorenzem a Karlem von Frischem zabýval organizací společenského chování živočichů. Formuloval čtyři Tinbergenovy otázky, které se dají považovat za 4 oblasti biologie:

1) Adaptace (evoluce) – Základem je Darwinova teorie evoluce přirozeného výběru, která jako jediná vysvětluje, proč je chování zvířete tak dobře přizpůsobeno k reprodukci a přežití ve svém prostředí. Zvíře se „nějak“ vyvíjelo a adaptovalo tak, aby mělo největší pravděpodobnost přežití a tím se i měnilo, upravovalo své chování. Ale proč tomu tak je?

2) Fylogeneze – Blízce souvisí s adaptací. Každý organismus nese znaky anatomické i behaviorální jak svých předků, tak i svých fylogenetických stádií. Pochopení fylogeneze vede často k pochopení jedinečné vlastnosti organismu.

3) Mechanismus (anatomie, fyziologie) – Jak fungují rysy a části daného organismu? Živý organismus je složitá soustava, která funguje určitým způsobem. Ale jak?

4) Ontogeneze – Ontogeneze se zabývá vývojem a původem jedince. Důležitou částí je tady DNA, která přenáší informace z generace na generaci. Ale proč většina zvířat dává přednost reprodukci s jedinci, které nezná (Davies, 2012), (Kundt, 2017), (Nesse, 2013)?

Tyto otázky se dají zkoumat zvlášť, anebo dohromady. Příkladem může být například hlavní otázka: Proč matka kojí své děti? Ta se dá potom rozdělit do čtyř otázek podle Tinbergena: Jaké mechanismy vedou ke kojení? Jak se matka naučila kojit? Jaká byla evoluce kojení a jak vypadá u jiných taxonů? Bylo kojení upřednostněno přírodním výběrem? Tato část etologie a behaviorální ekologie je složitá a někteří vědci ji spojují i s filozofií a Aristotelem (Hladký, 2013; Kundt, 2017).

Základem behaviorální ekologie je neustálé „soutěžení“ zvířat o přežití, která během svého života soupeří o omezené zdroje potravy, teritoria a příležitosti k rozmnožování. U spousty druhů nezáleží, jestli je soupeřem sourozenec, rodič, anebo dokonce i vlastní potomek. Vědci se snaží přijít na dílčí vzorce chování a poté je spojit dohromady. Příkladem může být studie vzorců chování u lvů pustinných (*Panthera leo*) (Davies, 2012). Lvi jako jediné kočkovité šelmy žijí ve smečkách, které se skládají z několika samců a několika samic. Existují různé vzorce chování mezi různými smečkami, ale také i mezi pohlavím ve smečce. Lvice můžou rodit mláďata jednou ročně, ale ne ve všech smečkách se tohoto mechanismu využívá. Co je vede tedy k odlišnému chování? Jedna z odpovědí může být větší potřeba získání potravy oproti reprodukci. Je ale těžké určit, proč se zrovna smečka zaměřuje více na lov či na reprodukci (Davies, 2012).

Behaviorální ekologie se poslední dobou zaměřuje více a více na stavy chování, které často propojují behaviorální ekologii s ekologií prostorovou. Dávají prostor vzniku společných otázek: Jaké chování vyvolá určitý pohyb? Mají vzorce chování něco společného s vzorci pohybu (Langrock, 2012)?

3.2 Způsoby monitoringu pohybu zvířat

Monitoring divokých zvířat je důležitý pro porozumění pohybových vzorců zvířat, odhadu jejich stanovišť, jejich počtu a porozumění ochrany všeobecně. Za posledních několik desítek let se způsoby monitoringu vyvinuly neuvěřitelnou rychlostí od

přímého pozorování, zkoumání pobytových znaků až k používání radiometrie a GPS technologie (MŽP, 2009).

Metody monitoringu lze rozdělit do dvou skupin: invazivní a neinvazivní.

3.2.1 Neinvazivní metody

Za neinvazivní metody se pokládají takové, které nevystavují zvíře manipulaci a stresu. Patří sem například přímé pozorování, zkoumání pobytových znaků a pozorování za použití fotopastí (MŽP, 2009).

Přímé pozorování

Přímé pozorování patří k nejstarším a nejjednodušším metodám monitoringu pohybu zvířat na světě. Spočívá v pozorování zvířete z určitého místa, zaznamenávání jeho vzhledu a jeho polohy „manuálně“. Nejlepším příkladem je sčítání živých jedinců mezi myslivci, kdy myslivci sedí na posedu, zaznamenávají pozorovaná zvířata a počítají tím jejich početnost v určitém rajonu. Naopak pozorování mrtvých jedinců je hojně využíváno při monitoringu velkých šelem, a to jak v České republice, tak i ve světě. Mrtvým jedincem sice nelze relativně určit velikost populace, ale často slouží jako potvrzení přítomnosti druhu (GESE, 2001). Tímto způsobem byl například tento rok potvrzen výskyt kočky divoké na území České republiky, která byla považována za vyhynulou (IVB, 2021).

Mezi další důležitá využití přímého pozorování je u sledování a monitoringu plazů. Pozorující prochází terén, hledá a prohlíží jejich úkryty, místa k odpočinku a zaznamenává jedince a druhy (Vlašín, 2005). Navíc se můžou i umístit na určité ploše s největší pravděpodobností výskytu umělé úkryty, kdy je potřeba je několikrát za rok procházet a počítat jedince ukryté v umělých krytech. Touto metodou se nestanovuje populační hustota, ale slouží spíše k průzkumu množství druhů na dané lokalitě (Gent, 2012).

Do přímého pozorování se řadí i průzkum pomocí reflektorů, který je hojně používán v Africe. Průzkum reflektory se používá pro živočichy s noční aktivitou a spočívá v jízdě v automobilu s reflektorem. Ve chvíli, když je zahlédnuto zvíře, tak se reflektor vypne a pozorující s použitím dalekohledu určí zvíře a zaznamená ho (Gese, 2001).

Zkoumaní pobytových znaků

Zkoumaní pobytových znaků lze chápat jako hledání stop na určitém místě, většinou v oblasti největšího pravděpodobného výskytu. Za stopu lze považovat stopní dráhu zvířete, jeho trus, zbytky srsti, doupata, výměšky, u teritoriálních druhů se jedná o veškeré značení ve formě moči, drápanců na vegetaci, a u predátorů je to stržená zvěř. Touto metodou lze odhadnout přibližnou velikost populace, potvrdit přítomnost druhu a jeho rozšíření. Při použití DNA u analýzy trusu, moči, případně i srsti lze získat přesnější informace o jedinci a při nejistotě určení si potvrdit, zda se jedná o námi považovaný druh, nebo se jedná o úplně jiný (Heinemeyer, 2008).

Pozorování a hledání pobytových znaků používali už naši předci v době kamenné, postupem času se tato metoda zdokonalovala. V druhé polovině 20. století se začali zoologové zabývat monitoringem stop a trusů (Lockie 1959), a ke konci století se začala zapojovat do monitoringu zvířat molekulární biologie, která dnes hraje jednu z velkých rolí v metodách monitoringu (Foran, 1997).

Největší výhodou je jeho jednoduchost, nízká realizační cena (často se využívá i dobrovolníků) a využitelnost na různých lokalitách a na velkém množství druhů. Naopak velkou nevýhodou je složitost určení a možné smíšení pobytových znaků od více druhů zvířat. Často se stane, že nalezená srst nepatří jen jednomu taxonu a může dojít k chybnému určení vzorku. V případě určování druhů podle srsti a trusu je nejvhodnější DNA analýza, která je přesnější, ale je časově náročná. Samozřejmě lze k DNA analýze použít jakoukoli tkáň živočicha, navíc analýzu trusu lze použít jako základ pro zjištění potravy daného jedince. Velkou výhodou genetické analýzy není jen identifikace jedince, určení populace, ale také i zjištění genetické variability populace na sledované lokalitě a její srovnání s dalšími populacemi. Ne vždy ale může být daný vzorek pro analýzu vhodný. Vysoká teplota, sluneční záření a velká vlhkost a přítomnost látek způsobující degradaci vzorku. Vhodným vzorkem může být například čerstvá srst obsahující kořínky, které se při nálezů umístí do plastových zkumavek, nebo případně do papírových sáčků, poté se vzorek označí a dá se lednice, do suchého a chladného prostředí, anebo se zamrazí. Dalším důležitým aspektem je vhodná doba sběru pobytových znaků. V létě na suchých místech dochází k vyšší degradaci trusu a horšímu hledání a určování stop. Vhodnou lokalitou v létě (na jaře, podzimu) pro trasování podle stop může být i mokrá terén kolem řek. Naopak je tomu

v zimě. V zasněžených lokalitách se jednodušeji trasuje a rozeznávající se stopy (Gese, 2001; MŽP, 2009).

Monitoring stop jedinců a jejich stopních drah se řídí podle určité metodiky. Vždy se měří bez drápů, provádí se minimálně dvě měření, a vzorek by se měl vyfotit s měřítkem pro pozdější analýzu (obr. č. 7). Pokud je to možné, tak se při zápisu rozlišují přední a zadní končetiny a zda se jedná o zvíře, které „čáruje“ (stopy leží v jedné linii). Měří se vždy i délka kroku (Kutal, 2018).



Obrázek č. 7 – fotka měření stopy rysa ostrovida (*Lynx lynx*)

(Kutal, 2018)

K získávání pobytových znaků, jako je srst a teritoriální značení (nejčastěji drápance na vegetaci), se používají pachová stanice a chlupové stanice. Použití pachových stanic je jednou z nejpoužívanějších metod u monitoringu šelem především v Severní Americe, ale pomalu se začíná využívat i v jiných částech světa. Do pachových stanic se umísťují pachové tabletky obsahující výrazné a přitažlivé pachy, například extrakt z fermentovaného vejce, rybí olej. Stanice se rozmísťují v předem určené lokalitě na nejvhodnější trase, kudy zvíře prochází, a jsou od sebe vzdáleny v přibližně stejných intervalech. Po několika dnech se navštíví, udělá se záznam o pobytových znacích a posbírání se vhodný materiál (Gese, 2001). Chlupové pasti fungují na podobném principu jako pachové stanice, na rozdíl od stanic se používají ve více zemích, včetně České republiky. Chlupové pasti jsou mechanická zařízení obsahující pachové látky k přilákání pozornosti šelmy a k následnému zachycení srsti na drsném povrchu pasti. Jako příklad může být dřevěný kůl nebo kmen potažený kobercem a suchým zipem,

který je napuštěn uměle vyráběnou bobrovinou a běžně dostupným extraktem z šanty kočičí (*Nepeta cataria*). Jeho účelem je přilákání kočkovité šelmy, u nás například rysa ostrovida (*Lynx lynx*). Před umístěním obou pastí je potřeba zvážit pohybové vzorce a velikost domovských okrsků zkoumaných druhů (Gese, 2001; MŽP, 2009).

Použití fotopasti k monitoringu zvířat

Fotomonitoring neboli monitoring pomocí fotopastí je v posledních pár letech více a více populární, a to především kvůli rychlému posunu technologii, ale i díky úspěšnosti při monitoringu těžko viditelných zvířat, jako jsou například levharti sněžní (Alexander, 2016). Fotopast je automatický fotoaparát, který umožňuje zachycení fotografie volně žijícího zvířete, potvrzení jeho výskytu, identifikace, a následně pomocí těchto údajů dopomáhá i k odhadnutí velikosti populace na určité ploše (Gese, 2001).

První zmínky o fotopasti jsou z roku 1863, kdy ji používal německý badatel a profesor G. Fritsch v Jižní Africe, ale své slovo a plné využití začala získávat až po roce 1900, kdy se focení divokých zvířat stalo fenoménem. Ve Velké Británii byl založen „Zoological Photographic club“. Krátce poté přišel George Shiras s vynálezem, který se nejbližší podobá dnešním fotopastem. Ke spoušti fotoaparátu připevnil napnutý drátek, o který když zvíře zavadilo, tak se vytvořil snímek. V tomto roce Shiras získal zlatou medaili na „Paris World Exhibition“ a začalo se o něm a jeho vynálezu psát v nejznámějších časopisech. I díky tomu se fotografování divokých zvířat se stalo fenoménem a zábavou. Ve 20. letech 20. století vydal William Nesbit první detailní publikaci o focení divokých zvířat. Díky všem předešlým událostem přilákala tato pozornost Franka M. Chapmana, kterého spolu se Shirasem někteří považují za „otce“ fotografování divoké přírody. Chapman se stal jedním z mála vědců, kteří používali v jeho době těžké a velké fotopasti. Ke konci 20. století se začali o fotopasti zajímat lovci, kteří je kvůli novým technologiím zdokonalili. V roce 1998 byla fotopast uznána jako plnohodnotná vědecká metoda, kdy Karanth a Nichols odhadli jako první velikost populace druhu pomocí dat z fotopastí a pomocí statistické analýzy (O’Connell, 2011).

Momentálně jsou fotopasti plně automatické, digitální a dokáží vytvářet záznamy ve formě fotografií a krátkých videích jak za světla, tak i v noci. U prvních fotopastí

se záznam uchovával ve formě svitkových fotopapírů, ale v současné době skoro všechny fotopasti používají SD karty pro ukládání většího obsahu dat (MŽP, 2009).

Existuje velké množství typů a druhů fotopastí, a to podle použití a jejich součástí. Fotopast se skládá z fotoaparátu a čidla, které nahradilo drátek a slouží k aktivaci fotoaparátu. Existují dva typy čidel:

1) Infračervené čidlo (AIR) – Čidlo funguje na principu paprsku infračerveného světla, které když zvíře přetne, tak se fotopast spustí.

2) Tepelná čidla (PIR) – Tepelná čidla fungují na bázi teploty. Čidlo snímá teplotu prostoru před sebou, a jestliže zaznamená pohybující objekt s jinou teplotou, tak fotopast aktivuje (O'Connell, 2011; MŽP, 2009).

Výběr typu fotopasti je dost důležitý a je potřeba vždy zvážit, k čemu a na jaký taxon se bude používat. Na výběr jsou v základu dva typy fotopastí:

1) IR pasti – IR pasti používají diodu vyzařující infračervené světlo. Jejich velkou výhodou je nízká spotřeba baterie, a tím pádem dlouhá životnost a možnost nastavení více než jednoho snímku. Velkou nevýhodou je však nižší kvalita záznamu, černobílé fotografie, které jsou zřetelnější ve tmě nebo při malé intenzitě světla.

2) Pasti s LED bleskem – Fotopasti obsahují blesk, mají bezesporu velkou výhodu v kvalitě fotografií, a blesk jim umožňuje vytvořit i barevný záznam ve tmě. Oproti tomu je nevýhodou velká spotřeba baterie, tím pádem malá životnost baterie. Nabití blesku způsobuje nemožnost nastavení opakovaného záznamu. Další docela důležitou částí fotopasti je i její ochrana. Ta může vypadat jako ocelová skříňka, ve které je umístěna, anebo to může zámek, který ji uchycuje k velkým stromům (O'Connell, 2011; MŽP, 2009).

Rozmístění pastí by mělo být takové, aby pokrylo co největší území sledované oblasti. Často se umisťují na místa opakovaného nálezu, kde zvíře značkuje, k zásobníkům vody, na místa odpočinku, někdy se používají i vábidla, aby daného jedince, kterého chceme vyfotit, nalákala přímo k fotopasti (GESE, 2001).

Po pořízení záznamu je ho potřeba analyzovat. To jde různými způsoby. Například vědci z Beijing Forestry University zkoumali populaci levhartů sněžných po dobu 19 měsíců za pomoci 34 fotopastí na ploše 375 km² (Alexander, 2016). Pasti byly umístěny na nejvhodnější místa tak, aby nejlíp zaznamenaly jejich obličej a ocas, a to především kvůli další analýze. Po získání dostatku informací byly záznamy

odeslány na dvě výzkumné stanice, kde podle jedinečné kresby na obličejích a na ocase byly jednotlivé záznamy rozřazeny pod jednotlivé jedince. Po rozřazení se poslaly záznamy z obou stanic do třetí, která data vyhodnotila. Pomocí softwaru stanice určila počet jedinců, a následně použila program SPACECAP a odhadla pravděpodobnost výskytu jedinců v určité lokalitě a jejich počet na 100 km² (Alexander, 2016).

3.2.2 Invazivní metody

Metody, u kterých je nutné zvíře odchytit a poté s ním manipulovat, nazýváme invazivní. Mezi ně můžeme zařadit například telemetrické metody. Důležitým termínem a biologickou metodou v monitoringu terestrických živočichů je už zmíněná telemetrie, která umožňuje bezdrátový přenos informací na velké vzdálenosti, a to jak v rádech metrů, tak i kilometrů. Vysílač neboli transmitter s vlastním napájením připevněný nejčastěji na zvířeti ve formě obojku odesílá signály s informacemi s fyzikálními veličinami k přijímači („receiver“), který zaznamenává čas a polohu zvířete. Telemetrické metody jsou v současnosti důležitou součástí analýzy trajektorií a strategií zvířat. Dají se použít u velké většiny zvířat a pomáhají získat i informace u těžce sledovatelných druhů. Hrají velkou roli u stanovení areálu výskytu, vytyčení domovských okrsků, vytváření pohybových vzorců, u stanovení sociálního chování, u reprodukce a v jejich životě celkově, což lze těžko pozorovat jinými metodami (Handcock, 2009, MŽP, 2009).

Mezi významné telemetrické metody patří radiotelemetrie a GPS telemetrie.

Radiotelemetrie

Používání radiotelemetrie začalo už v 60. letech 20. století a používá se i dnes jak v biologii, tak i třeba v meteorologii nebo v armádě. Radiotelemetrie využívá k určování polohy sledovaného jedince neviditelné a tiché rádiové signály, které patří mezi elektromagnetické vlny. Dříve se používala primárně jen na velké obratlovce, ale díky posunu technologií se dnes používá i na menší obratlovce i bezobratlé (Smithsonian's National Zoo, 2018).


Systém radiotelemetrie se skládá ze tří částí:

1) Vysílače (transmitery/tagy) – Vysílač je přístroj s vlastním zdroje energie schovaný v odolném obalu nejčastěji z plastového materiálu, který je připevněný k živočichovi. Transmitter vysílá rádiový signál o vysoké frekvenci v rozmezí 30–300 MHz. Při sledování více jedinců jsou nastaveny tak, aby měly rozdílnou frekvenci a přijímač je

mohl rozlišit. Způsob připevnění se liší podle zkoumaného živočicha. U větších obratlovců se používají obojky, ušní známky, podkožní čipy, na druhou stranu u menších živočichů, jako je hmyz, je to nemožné. Proto se vysílače nalepí na jedince (obr. č. 8). Existuje tady jedno jednoduché pravidlo, čím je vysílač větší a těžší, tím je signál silnější (MŽP, 2009; Růžičková, 2016).

2) Radiový přijímač – Přijímač má za úkol spolu s anténou přijímat signál a rozeznávat rozdílné signály vydané vysílačem. Přijímač s anténou jsou navzájem spojeny koaxiálními kabely. Některé modely mají připojená sluchátka, která blokují venkovní hluk, který by mohl znepříjemňovat práci (Whitworth, 2007).

3) Rádiová anténa – Zařízení vysílající nebo zachycující rádiové vlny. Nejdůležitější vlastností je přenositelnost, schopnost přijímat signály a její hmotnost. Lehké antény většinou drží v ruce výzkumník, ty těžší se připevňují na auta (Whitworth, 2007).



Obrázek č. 8 – Ilustrace zobracující transmitery na hmyzu

(Růžičková, 2016)

Radiotelemetrické metody se používají na odhad hustoty dané populace, odhadování domovského okrsku, na zjišťování přechodných jevů v populaci a sledování jedinců s velkým rozsahem pohybu a skrytým životem, jako je puma americká (*Puma concolor*), nebo rosomák sibiřský (*Gulo gulo*) (Hornocker, 1970; Magoun, 1998; GESE, 2001).

Velkou výhodou radiotelemetrie je její cenová dostupnost, možnost použití v entomologii kvůli nízké hmotnosti vysílačů oproti GPS technologiím, ale velkou otázkou je, jak připevněný vysílač ovlivňuje život jedince. Nevýhodou je nutná krátká vzdálenost mezi vysílačem a přijímačem. Při zkoumání ptáků může dojít ke ztrátě signálu, pokud jedinec odletí z oblasti pozorování. Dalším omezením je špatně dohledatelný signál při nepříznivém počasí a krátká životnost baterie v rozmezí několika týdnů až měsíců, která je daná tím, že vysílání rádiového signálu na krátké

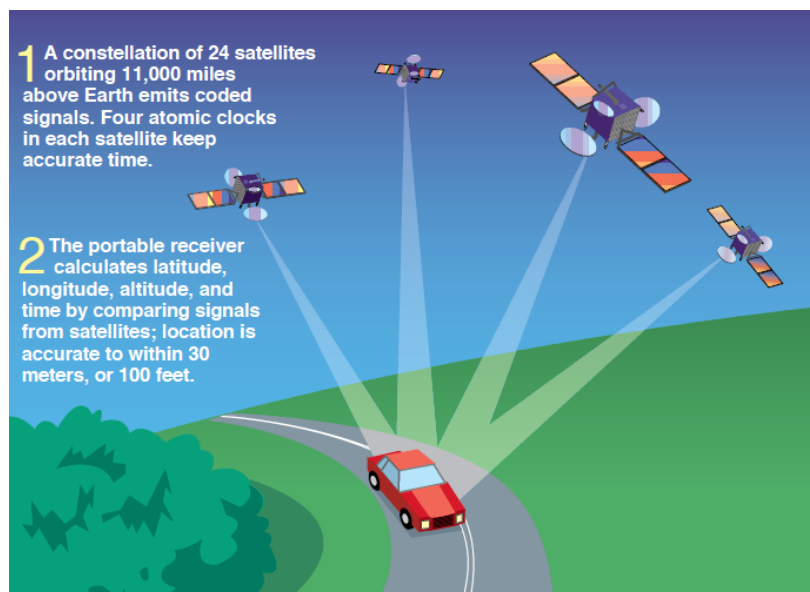
vzdálenosti vyžaduje hodně energie (Růžičková, 2016; Smithsonian's National Zoo, 2018).

GPS telemetrie

Jak už název napovídá, tak GPS telemetrie funguje na bázi GPS. GPS je navigační systém, který poskytuje vysoce kvalitní údaje o poloze po celé zeměkouli, a to pomocí 32 satelitů umístěných na oběžné dráze Země. Satelity fungují jako vysílače, které vysílají signál k přijímači. Každý satelit obsahuje stabilní atomové hodiny, které jsou synchronizovány s časem na zemi (PNAS, 1997).

GPS neboli Global Positioning System se vyvinul z původního projektu NAVSTAR GPS, který v 80. letech 20. století zahájilo Ministerstvo obrany Spojených států amerických. Za 20 let po spuštění projektu NAVSTAR GPS Spojené státy vypustily kompletní sestavu 24 družic na oběžnou dráhu Země, a tím vznik telemetrický systém založený na GPS technologii, která se částečně zpřístupnila civilnímu sektoru na začátku 21. století, a používá se dodnes ve velkém spektru oborů (Fleetistic, 2016).

V současnosti GPS telemetrie umožňuje shromažďovat velké množství dat v jakékoliv denní době a za každého počasí. Využití systému GPS a jeho přesnost určení polohy závisí na počtu viditelných družic. Viditelnost družic může významně ovlivnit hustota vegetace a povrch zkoumané lokality. Pokud jsou viditelné čtyři a více družic, tak se data zaznamenávají trojrozměrně (3D) (obr. č. 9). Jestliže jsou viditelné přesně tři satelity, které vysílají signál, jsou data o poloze dvourozměrná (2D). Když je signál vysílán dvěma nebo menším počtem satelitů, záznam o poloze nelze získat (Zweifel-Schielly, 2007). Trojrozměrné záznamy jsou kvalitnější než záznamy dvourozměrné. Dvourozměrná data obsahují záznam o zeměpisné šířce a délce, trojrozměrná data navíc obsahují i záznam o nadmořské výšce (Gamo, 1999).



Obrázek č. 9 – Obrázek znázorňuje vysílání signálu 4 satelitů. Získaná data budou poté trojrozměrná. 3 satelity se podílejí na záznamu zeměpisné šířky, délky a nadmořské výšky a 4. upřesňuje čas (PNAS, 1997)

Důležitou součástí GPS telemetrie jsou telemetrické obojky, které se nejčastěji používají jako přijímače signálu v oblasti telemetrického monitoringu. Spousta obojek nepoživuje jenom záznam o poloze daného jedince, ale díky novým technologiím může být jeho součástí teplotní senzor nebo senzor aktivity. Součástí může i být i tzv. drop-off mechanismus umožňující dálkové odepnutí obojku (MŽP, 2009). Přijímače GPS signálu fungují na principu přímé viditelnosti a na viditelnosti satelitů. Při zvýšené hustotě vegetace se může stát, že čtvrtý satelit není vidět, a záznam dat může být díky tomu zkreslený. Stejný případ může nastat i při zastínění satelitu horou (Zweifel-Schielly, 2007).

GPS telemetrie má oproti ostatním metodám velkou výhodu, a to díky záznamu dat, které nám říkají, kde se zvíře nachází, jakou má teplotou a jaká byla jeho aktivita. Dokáže zaznamenávat i migraci zvířat a další jejich pohybové vzorce. Oproti radiotelemetrii nemusí být sledující osoba blízko sledovaného jedince. Dá se použít i v horších podmínkách, a to jak vegetačních, tak i topologických. Například u radiotelemetrie v kamenité oblasti Alp by mohlo docházet k odrazení signálu, a poté špatnému příjmu signálu. Velkou nevýhodou je její cena, velikost a váha přijímačů, které nejsou vhodné pro menší živočichy. Navíc se jedná o invazivní metodu, u které je potřeba jedince odchytit a vystavit ho určitému stresu. Odchyt nemusí být vždy

nejjednodušší záležitost, například u zvířat s nízkou populační hustotou a velkým domovským okrskem (MŽP, 2009; Smithsonian's National Zoo, 2018).

3.3 Analýza dat z GPS telemetrie

Po získání dat z GPS telemetrie je důležitá jejich analýza, která pomáhá k pochopení procesů ovlivňující pohyb zvířete, jeho mechanismů a dynamiky. Analýzou dat se zabývá prostorová ekologie, a pomocí nich hledá pohybové vzorce. Často je spojuje i s vzorci chování zkoumané v behaviorální ekologii a prvky evolučních procesů. Často se k záznamu z telemetrie pohybu používají data vnějších faktorů, díky kterým lze i pochopit, jak mezi sebou různé druhy reagují, jak reagují na různá prostředí, anebo proč zvířata používají k přežití určité zdroje. Díky analýze lze předpovědět dosah zásahu lidské činnosti do přírody a pochopení vzorců a strategií, pohybových i behaviorálních, díky kterým lze lépe plánovat ochranu přírody (Demšar, 2015; Dodge, 2015).

Data získané z GPS telemetrie jsou tvořeny diskrétní časovou řadou, která obsahuje informace o poloze sledovaného jedince. Ke každému bodu (poloze) je záznamem i čas. Data získané GPS telemetrie lze považovat za vstupní data k tvorbě trajektorie. Prvním krokem je kontrola dat (v datech mohou být nepřesné, anebo chybějící záznamy) a jejich následná vizualizace ve formě trajektorie, která patří určitému zvířeti. Tak vizualizovaná trajektorie má tvar křivky, která představuje geografickou a časovou posloupnost výskytu (McArdle, 2014; Demšar, 2015). Vizualizace dat je možnými několika způsoby, mezi často používané programy patří ArcGis a Rstudio, které pomocí balíčku dokáže, jak trajektorii vizualizovat, tak vypočítat i různé parametry, jako je délka kroku, úhel otočení, zrychlení apod. (Demšar, 2015).

Existuje spousta metod a postupů k analýze dat v prostorové ekologii. Tato práce představuje jen pár z nich. V program R existuje hned několik balíčků pro práci s telemetrickými daty (tabulka č. 1), které jsou rozděleny do několika tříd podle funkce (Rocío, 2021):

- 1) Vizualizace – Balíčky sloužící k vizualizaci a k animaci dat.
- 2) Popis trajektorie – Balíčky zabývající se analýzou trajektorie. Slouží například k vypočítání vzdálenosti kroků, analýze rychlosti a určení přímosti trajektorie.

- 3) Rekonstrukce trajektorie – Balíčky používající se k úpravě trajektorie, jako je úprava časového intervalu kroku, anebo oprava chybějících dat.
- 4) Analýza vzorců chování – Balíčky používané pro analýzu trajektorie prostřednictvím pohybových a behaviorálních vzorce.
- 5) Simulace trajektorie – Balíčky umožňující simulaci trajektorie na principu Brownového pohybu, skrytých Markovových modelech, Lévyho procházkách, atd...
- 6) Popis využití prostoru a stanovišť – Balíčky obsahující funkce, které pomáhají odpovědět na otázky související s prostředím (Proč jedinec tráví čas na určitém místě? Jak ovlivňuje prostředí rozhodnutí k pohybu?)

Balíčky	Typy analýz	Současná verze
AdehabitatHR	Analýza a odhad domovského okrsku	0.4.19
AdehabitatHS	Analýza a odhad stanoviště	0.3.15
AdehabitatLT	Analýza, vizualizace a segmentace trajektorie	0.3.25
Amt	Analýza trajektorie a odhad domovských okrsků	0.1.4
BayesianAnimalTracker	Rekonstrukce trajektorie	1.2
Bsam	Bayesian state-space modely, simulace trajektorie	1.1.3
MomentuHMM	Analýzy pomocí HMM	1.5.2
MoveHMM	Analýza pomocí HMM	1.7
MoveVis	Vizualizace trajektorie	0.10.5
Rsmove*	Propojení údajů o pohybu s prostředím	0.2.8
TrackerR	Analýzy trajektorie	1.5.2
Trajr	Analýza, popis/analýza a simulace trajektorie	1.4.0

*Rsmove momentálně nefunguje na nových verzích Rstudia

Tabulka č. 1 – Nejdůležitější balíčky v programu R pro analýzu telemetrických dat
(Vlastní zdroj)

3.3.1 Odhad domovských okrsků

Pro odhad domovských okrsků se nejčastěji používají metody, které odhadují hustotu výskytu (utilization distribution). Patří sem parametrické metody, které umožňují v zásadě odhadovat pouze okrsky kruhového tvaru a metody neparametrické, které jsou celkově využívanější. Nejpoužívanější metodou pro posouzení a odhad domovského okrsku je jádrový odhad hustoty (*kernel density estimation – KDE*), který závisí na jádru a jeho šířce (*bandwidth*) (Getz, 2007; Demšar, 2015). Dalším příkladem neparametrických metod je metoda Local convex hull – LoCoH (Getz, 2007).

Jádrový odhad hustoty spočívá v přidání bodu, ke každému pozorování jedince a následného umístění „gausovského“ jádra svým středem na vzniklé bod. Následně se spočítají hodnoty hustoty výskytu zprůměrováním hodnot všech jader, které se na daném místě překrývají. Důležité je správné nastavení šířky jádra, která má vliv na

výslednou hodnotu hustoty. Při použití nízké hodnoty šířky jádra se může stát, že výsledný povrch hustoty je příliš složitý a má spoustu lokálních maxim, „kopců“ (Worton, 1989) (Demšar, 2015). Naopak je-li jádro příliš široké, výsledný tvar hustoty je příliš zhlazený a výsledné domovské okrsky mají tendenci být nerealisticky velké. O určení šířky jádra se často diskutuje, přičemž neexistují jasný konsenzus (Fieberg, 2007; Demšar, 2015).

Jedním z velkých problémů klasického odhadu hustoty jádra je nezohlednění posloupnosti časových údajů bodů v trajektorii (Demšar, 2015), což má za následek časoprostorovou autokorelaci výskytů (Fleming, 2015). V současné době se začínají implementovat pohybové údaje i do odhadu hustoty jádra, a to v podobě movement-based kernel density estimation – MKDE (Benhamou, 2012).

3.3.2 Analýza trajektorie - pohybové vzorce

Pohyb jedince je složen ze čtyř složek a to z kapacity pohybu, schopnosti navigace, vnitřním stavem a vnějšími faktory. Interakce těchto složek vede zvíře k pohybu (Nathan, 2008). Pohybové vzorce mohou být stanoveny jak pro jedince, tak i pro celou populaci. Například pohyb minimálně dvou jedinců stejného, anebo odlišného druhu může být ovlivněn vzájemnými interakcemi a asociacemi. Takový pohyb lze popsat jako dynamickou interakci, která pomáhá následně vysvětlit vzorce spojené se seskupování se, následování jiných jedinců, anebo jejich vyhýbání se.

Jestliže je pohyb dvou nebo více jedinců stejného nebo odlišného druhu ovlivněn vzájemnými interakcemi, asociacemi tak tento vzorec popisuje dynamickou interakci, která pomáhá vysvětlit vzorce vyhýbání se, přitahování, seskupování, anebo následování (Long, 2013).

K identifikaci pohybových vzorců existuje velké množství metod, které zkoumají vzorce jak krátkodobé, tak i dlouhodobé. Například migrace se zkoumá pomocí segmentace trajektorie (Demšar, 2015).

Populární a často používanou metodou k analýze trajektorie a pohybových vzorců strategií je metoda Net Squared Displacement (NSD), která se soustředí na čtvercový posun jedinců v průběhu času. Metoda měří druhou mocninu euklidovskou, kvadratické vzdálenosti mezi počátečním místem zkoumané trajektorie a každým dalším umístěním (bodem trajektorie). Po zprůměrování hodnot NSD v čase lze určit střední kvadratický posun, který se používá pro kvantifikaci zvířat v prostoru a čase.

Každý pohybový vzor či strategie má teoreticky odlišné vzory v časových řadách NSD. V průběhu používání byly navrženy parametrické modely, které představují určitý vzorec nebo strategii (Bastille-Rousseau, 2016).

K analýze pohybu zvířat se často využívají i Brownovy mosty, které byly vyvinuty pro odhad očekávané trajektorie zvířete. Brownovy mosty jsou velmi podobné jádrovému odhadu hustoty. Hlavním rozdílem je, že pohyb mezi dvěma body je popsán Brownovým pohybem (náhodný pohybem). Mezi dvěma body se poté modeluje očekávaná dráha pohybu a pravděpodobnost výskytu daného jedince v prostoru a čase, která se nazývá Brownův most. Po „spojení“ resp. zprůměrování mostů (na způsob zprůměrování jader u metody KDE) je výsledkem odhad hustoty trajektorie (Horne, 2007). Tato metoda byla dříve nesprávně používána pro odhad domovského okrsku, přestože se jedná pouze o odhad využití území v rámci konkrétní trajektorie zvířete (Fleming, 2015).

3.3.3 Propojení údajů o pohybu s prostředím

Pohyb zvířat je ovlivňován jak vnitřním stavem, tak i vnějším faktorem, který můžeme chápat i jako prostředí, ve kterém se jedinec nachází (Nathan, 2008). Jako vnější faktor lze použít směr a rychlost větru, topografii včetně topografického sklonu, sních a vegetaci. Data o prostředí jdou získat z různých zdrojů, mezi které mohou například patřit meteorologické stanice nebo satelitní snímky. Pro spojení environmentálních údajů s údaji o pohybu se používá „anotace trajektorie“ (Demšar, 2015).

Jedním ze způsobů, jak analyzovat pohyb s údaji o životním prostředí, je systém EnV – DATA (The environmental-data automated track annotation). Systém umožňuje automatickou „anotaci trajektorie“ pomocí pozorování okolní atmosféry podkladových informací o krajině, a díky tomu umožňuje zkoumat vztahy mezi pohybem určitého jedince a jeho environmentálním prostředím. Velkým problémem „anotace trajektorie“ je sběr dat, který většinou nepochází ze stejné doby. Data o pohybu byla pořízena v jinou dobu než data o prostředí (Dodge, 2013).

3.3.4 Propojení údajů o pohybu s módy chování

Chování a pohyb zvířat je provázán. Často konkrétní chování odpovídá určitému typu pohybu a naopak. Při propojování vzorců pohybu s chováním se častou používají analýzy trajektorií za pomoci statistického modelování, anebo speciálními senzory, které zprostředkovávají jak informace o pohybu zvířete, tak i informace jiné. Většina

moderních GPS obojků mají zabudovaný teploměr, zaznamenávají venkovní teplotu či teplotu zvířete, na kterém je umístěn. Poslední dobou se využívá i kombinace akcelerometrů a GPS zařízení zaznamenávající i údaje zrychlení, které se potom využívají k segmentaci trajektorií u ptáků do několika typů chování: létání, shánění potravy, péče o tělo a sezení (Shamoun-Baranes, 2012; Demšar, 2015).


Při použití více senzorů záznam umožňuje podrobnější sledování chování jednotlivců. S akcelerometrem se může kombinovat gyroskop (zařízení používající se k učení „polohy“ a orientace jedince). Tato kombinace pomohla například v analýze vysokofrekvenčních pohybových situací u psa domácího (*Canis lupus familiaris*) (Gerencsér, 2013).

Převedení zaznamenaných dat a následné přiřazení k určitému typu chování může proběhnout třemi způsoby:

- 1) Neautomatickou interpretací údajů ze senzoru odborníkem, a to jak s terénním pozorováním, tak i bez něj – nejčastější metoda přiřazení určitého pohybu k druhu chování.
- 2) Automatizovaná segmentace nebo shlukování údajů ze senzoru bez terénního pozorování – někdy se používá odborník k identifikaci chování v určitém segmentu trajektorie.
- 3) Automatizovaná klasifikace údajů ze senzorů spolu s terénním pozorováním zvířete a jeho chování (Shamoun-Baranes, 2012).

K statistické analýze pohybu a chování se používají modely stochastického charakteru (tzv. state-space modely), dále jen SMM (Demšar, 2015). SMM jsou modely časové řady, které předpovídají budoucí a předchozí stavy a jejich pravděpodobnosti (obr. č. 10). U pohybové SMM lze chápat stav jako umístění, režim (typ) chování, energetický nebo fyziologický proces. Režim chování je zvláštní typ chování, který souvisí s chováním předchozím. Příkladem jsou třeba pasoucí se tur domácí (*Bos taurus*), který se na pastvě pohybuje pomalu, hodně se otáčí a hledá potravu. SMM v podstatě předpovídají budoucí stav zvířete k jeho vztahu současnému a umožňuje odhad pravděpodobnosti stavů (prostorové umístění, typ pohybu) i parametrů modelu (průměrná rychlost, rychlost otáčení, rozptyl chyb u pozorování). Kovariátou, která ovlivňuje pohyb, mohou být například environmentální informace či vzdálenost potravy od jedince. Velkou výhodou SMM je složení analýzy z tří částí: oprava chyb,

výpočet metrik a statistická analýza. Jedním z těchto modelů jsou skryté Markovovy modely, které budou detailněji probrány v následující části (Patterson, 2008).




Obrázek č. 10 – Grafické znázornění struktury SMM. Y označuje pozorování, x nepozorované stavy a vodorovné šipky znázorňují posun modelu v čase.

(Patterson, 2008)

Skryté Markovovy modely (HMM) a jejich použití v ekologii

Skryté Markovovy modely (HMM) jsou modely pro jednorozměrné a vícerozměrné časové řady včetně kategoričtých řad. Zjednodušeně by sedalo říct, že se skládají z dvou složek: z pozorované proměnné a skrytého stavu (nepozorované stavové sekvence). Pozorovanou proměnnou může být pohyb, který považujeme jako dvourozměrnou proměnnou zahrnující délku kroku a úhel otočení, popřípadě směr pohybu. Nepozorované stavy mohou představovat například diskrétní mody chování zvířete, jako je pastva, setrvání na jednom místě, přesun na nové místo apod. Nepozorované stavy jsou modelovány jako Markovský řetězec, což je posloupnost náhodných veličin (stavů), u kterých pravděpodobnostní rozdělení dané veličiny závisí pouze na předchozích hodnotách (stavech) veličin v rámci posloupnosti (Zucchini, 2009; Langrock, 2012).

Nejjednodušší verzí HMM je jednosměrný řetězec, který je založen na tzv. homogenním Markovském řetězci, což je řetězec, který nevykazuje trendy ani sezonní variace. Jak uvedeno výše, pravděpodobnost přesunu z jednoho stavu do jiného závisí pouze na stavech předchozích, přitom pravděpodobnostní rozdělení pozorované veličiny naopak závisí na tomto stavu (obr. č. 11) (Patterson, 2008; Zucchini, 2009).



Obrázek č. 11 – Obrázek znázorňuje HMM. X představuje skryté stavy modelu, Y možné pozorování, a pravděpodobnosti přechodu mezi stavy, b pravděpodobnost pozorovaných hodnot.

(Toledo, 2009)

Důležitou součástí vytvoření modelu je odhad jeho parametrů na základě známých hodnot pozorované veličiny. Odhad se provádí metodou maximální věrohodnosti, což je odhad, při kterém mají pozorovaná data největší pravděpodobnost.

HMM se používají nejméně tři desetiletí, a to především v aplikaci pro rozpoznání signálů, nejčastěji například u automatického rozpoznávání řeči. Avšak poslední dobou se tyto modely začínají používat i v jiných odvětvích, jako je rozpoznávání rukopisu, podpisu, obličeje, v bioinformatice (biologická sekvenční analýza), meteorologii, seismologii, biofyzice, a ekologii (Zucchini, 2009).

4 Metodika

4.1 Příprava dat

Vstupní data pro hlavní model byla získána z online databáze pro pohybová data Movebank (Power, 2020). Data byla pořízena v národním parku Pilanesberg, Jižní Africe, pro výzkum reintrodukce geparda štíhlého do volné přírody. Sledovaným jedincem byla samice geparda, která byla původně 3 měsíce v rezervaci Madikwe Game Reserve. Sledování probíhalo v roce 2014–2015 (Power, 2019).

Původní data byla stažena ve formátu .csv. Obsahovala velké množství dat, která byla pro model zbytečná, tudíž se odstranila. V datech zůstaly jenom sloupce s komentářem, o jakou fázi zvířete se jedná, s vnější teplotou, nadmořskou výškou a souřadnicemi ve formátu zeměpisné šířky a délky. Pro porovnání stavů geparda byl původní soubor rozdělen podle komentáře na 3 dílčí části, a to na soubor obsahující data pro samici geparda před březostí, březího geparda a geparda po porodu se 3 mláďaty.

Další úprava proběhla po nahrání dat do programu RStudio. Zeměpisná šířka a délka se převedla do souřadnicového systému UTM pomocí balíčku „sf“ kvůli lepšímu zobrazení polohy v modelu, a to následujícím způsobem. Nejdříve se transformovala data do objektu sf funkcí „st_as_sf“, poté se převedl souřadnicový systém do systému UTM pomocí příkazu „st_transform“, a výsledný soubor se připojil k původnímu (pro výběr souřadnic byla použita funkce „st_coordinates“). Pro převod souřadnic na kilometry stačilo souřadnice vydělit 1 000.

Posledním krokem v přípravě dat bylo doplnění chybějících měření tak, aby bylo po 6 hodinách a to pomocí funkcí „seq.POSIXt“ a „merge“. Výsledná data mají po úpravě rozestup 6 hodin a všechny důležité údaje k vytvoření modelu: teplotu, nadmořskou výšku, čas a souřadnice x a y (obr. č. 12).

	ID	TEMP	Height	time	X	Y	geometry
1	Cheetah_1	13.5	1161	2014-04-12 04:00:33	509.7917	-2792.354	c(509791.710791452, -2792353.74895874)
2	Cheetah_1	25.5	1164	2014-04-12 22:00:33	507.7540	-2793.037	c(507754.021394555, -2793036.75387737)
3	Cheetah_1	22.5	1167	2014-04-13 04:00:33	507.7540	-2793.037	c(507754.021394555, -2793036.75387737)
4	Cheetah_1	30.5	1167	2014-04-13 10:00:33	507.9374	-2792.934	c(507937.35877535, -2792933.87904357)

Obrázek č. 12 – Náhled data-setu po konečné úpravě

(Vlastní zdroj)

4.2 Analýza a vyhlazení trajektorie pomocí balíčku trajr


trajr je balíček pro R studio, který se zaměřuje na jednoduchou analýzu a vizualizaci dvourozměrných dat (McLean, 2018).

Prvním krokem je instalace balíčku a transformace původních dat do „trajectory object“ pomocí "TrajFromCoords", kde je potřeba použít následující argumenty:

- track: používaný dataframe
- xCol: název sloupce v původním souboru obsahující souřadnice x
- yCol: název sloupce v původním souboru obsahující souřadnice y
- timeCol: název sloupce, ve kterém je uveden čas

4.2.1 Vizualizace trajektorie

S nově vytvořeným objekt lze vizualizovat trajektorii pomocí jednoduché funkce „plot“ (obr. č. 13).

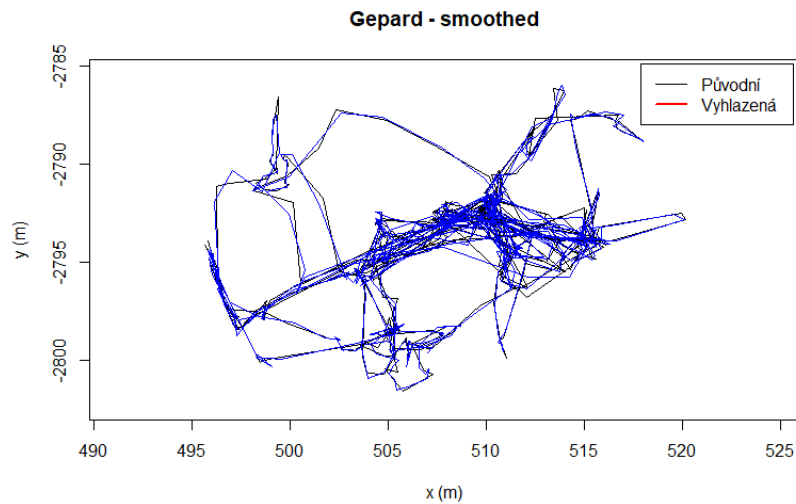


Obrázek č. 13 – Vizualizace trajektorie
(Vlastní zdroj)

Na obrázku č. 13 je vidět určitá trajektorie jedince, ale většina zvířat se nepohybuje v ostrých úhlech. Proto je dalším krokem vyhlazení trajektorie pomocí "TrajSmoothSG". Funkce "trajSmoothSG" se používá ke snížení vysokofrekvenčního šumu a zároveň zachovává původní trajektorii s použitím vyhlazovacího Savitzkyho-Golayova filtru (obr. č. 14). Parametry funkce jsou následující:

- trj: vstupní trajektorie
- p: pořadí filtrování

- n : délka filtru, její vypočet je následující: $p + 3 - p \% 2$ („ $\% 2$ “ je tzv. operace modulo – zbytek po celočíselném dělení)

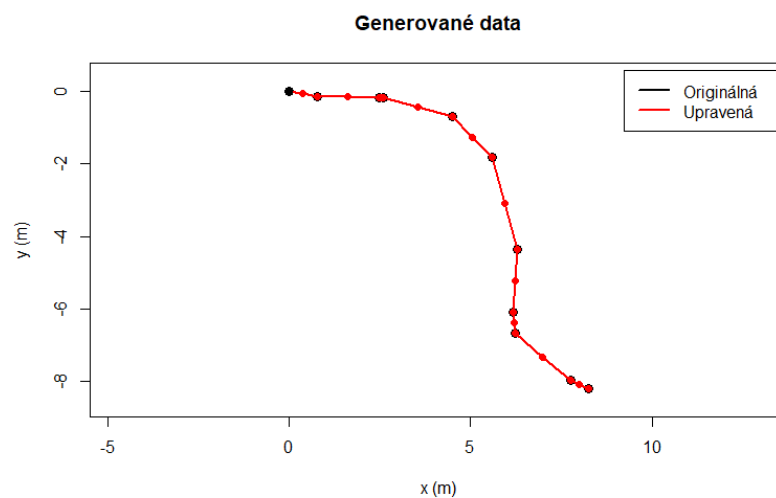


Obrázek č. 14 – Porovnání původní a vyhlazené trajektorie
(Vlastní zdroj)

Další zajímavou funkcí je "trajResampleTime", který upraví trajektorii a vytvoří novou s pevnými časovými intervaly kroku. Využívá dva argumenty:

- `trj`: vstupní trajektorie
- `steptime`: časový interval

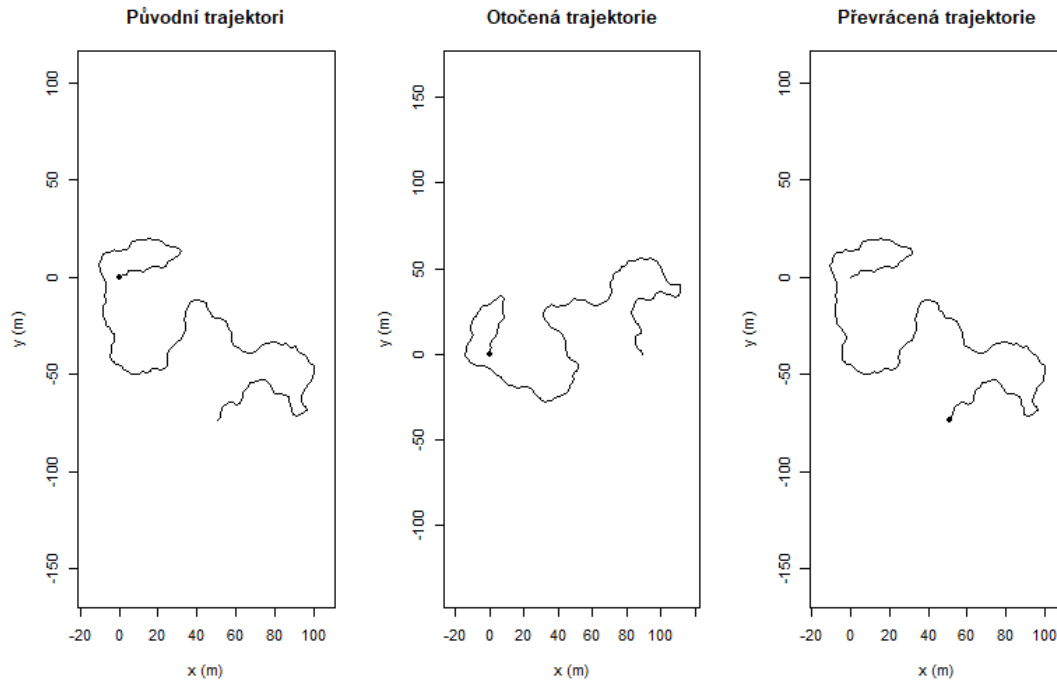
Pro lepší přehlednost se pro další funkce použila trajektorie vygenerovaná balíčkem (obr. č. 15). Náhodné generování je přiblíženo v kapitole 6.2.3.



Obrázek č. 15 – Porovnání původní trajektorie s trajektorií, která má upravené intervaly kroku

(Vlastní zdroj)

Balíček trajr má zabudované funkce i pro otáčení a převrácení trajektorie tak, aby počáteční bod byl posledním a naopak, a to „trj_rotate“ a „trj_reverse“ (obr. č. 16).




Obrázek č. 16 – Porovnání původní trajektorie, otočené a převrácené

(Vlastní zdroj)

4.2.2 Analýza trajektorie

Prvním krokem k analýze trajektorie je vytvoření, popřípadě i upravení trajektorie. Důležitou součástí balíčku je analýza rychlosti/zrychlení, která obsahuje hned několik funkcí zabývajících se analýzou rychlosti a zrychlení. Nejdůležitější funkce je „TrajDerivatives“, který vyžaduje vyhlazení trajektorie pomocí „TrajSmoothSG“ a převedení času na numerický formát pomocí „as.numeric“. Funkce umožňuje odhadnout rychlost jako vektor v každém bodě trajektorie pomocí první derivace (graf č. 1). Velkým nedostatkem je, že nedokáže zpracovat čas ve formátu: rok: měsíc: den: hodiny: minuty. Je potřeba ho mít ve vstupních datech v číselném formátu, např. v milisekundách.



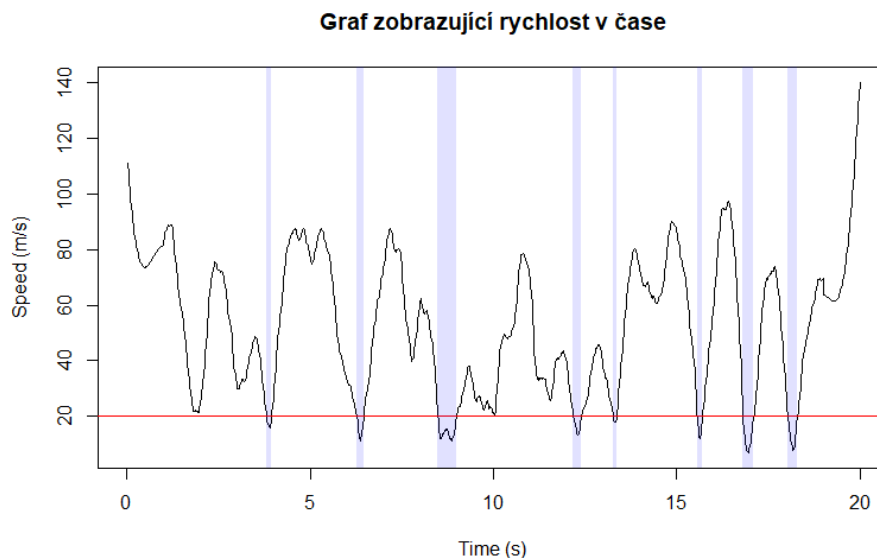
Graf č. 1 – Graf zobrazující změnu zrychlení a rychlosti. Modrá křivka zobrazuje závislost rychlosti na zrychlení.
(Vlastní zdroj)

Jakmile se analyzuje rychlost, tak pomocí „summary“ můžeme vytvořit přehlednou tabulku, kde jdou vyčíst všechny důležité hodnoty. Pro zobrazení hodnot samostatně stačí zadat jednoduché příkazy, jako jsou:

- Střední hodnota (`mean(derivs$speed)`)
- Maximální hodnota rychlosti (`max(derivs$speed)`)
- Minimální hodnota rychlosti (`min(derivs$speed)`)
- Souhrn všech informací (`summary(derivs$speed)`)

Odhad zrychlení jako vektoru v každém bodě trajektorie pomocí konečných druhých derivací lze pomocí "TrajAcceleration".

Funkce "TrajSpeedIntervals" umožňuje určit časové intervaly v rámci trajektorie. Lze pomocí ní najít intervaly, kdy je rychlost nižší nebo vyšší než námi určená hodnota. Argument „fasterThan“ zobrazí interval, kdy byla rychlost rychlejší než zadaná hodnota. Argumentem „slowerThan“ najdeme interval opačný, tedy kdy je rychlost nižší (graf č. 2).



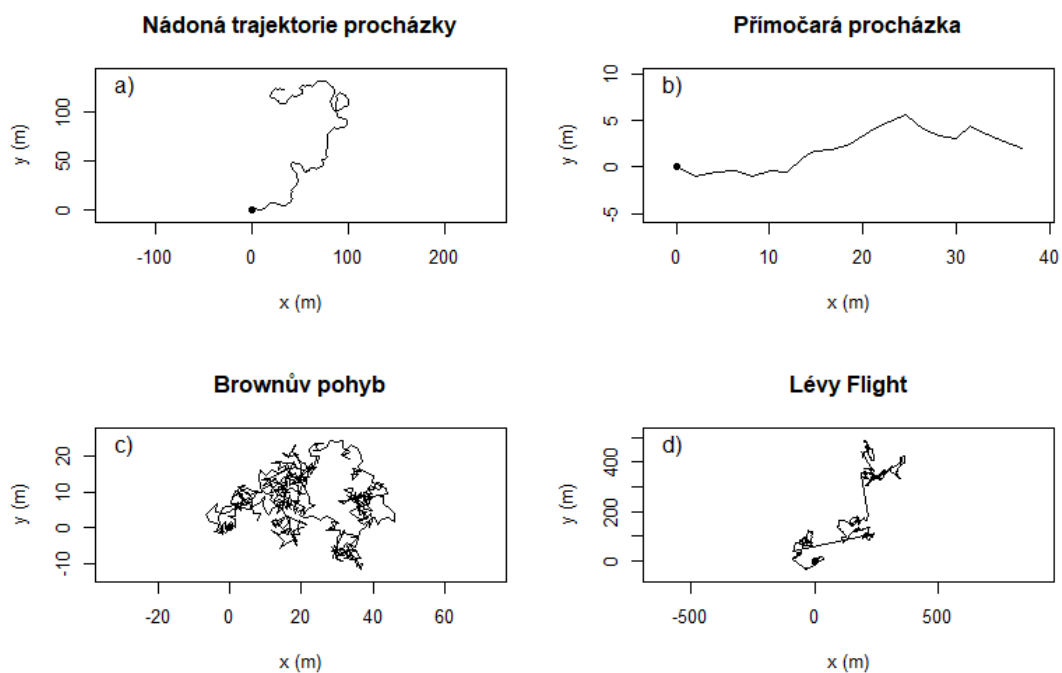
Graf č. 2 – Graf zobrazující rychlost v čase. Červená přímka je prahová hodnota 20 m/s. Zvýrazněná plocha znázorňuje intervaly, kdy byla rychlost nižší než tato prahová hodnota.
(Vlastní zdroj)

4.2.3 Náhodné generování trajektorie

trajr obsahuje i funkci "TrajGenerate", která umožňuje jednoduché vygenerování náhodné trajektorie. Funkce byla navržena pro použití v simulačních studiích a k experimentování s analýzou trajektorie (McLean, 2018).

Při zadání správných argumentů dokáže balíček vytvořit čtyři druhy náhodných trajektorií (obr. č. 17): náhodnou procházku, „přímočarou“ trajektorii, Brownův pohyb a Levyho procházku s Cauchyho rozdělením.

- 1) Náhodná procházka – argumentem pro náhodnou procházku je pouze „n“ udávající počet kroků v trajektorii. Popřípadě se může přidat argument „step“, který udává průměrnou délku kroku.
- 2) „Přímočará“ trajektorie – rozdílem oproti předešlé trajektorie je přidání argumentu „random = FALSE“.
- 3) Brownův pohyb – ačkoliv je Brownův pohyb ve světě zvířat spíše teoretickou záležitostí, lze zde vytvořit přidáním argumentu „angularErrorDist = function(n) stats::runif(n, -pi, pi)“.
- 4) Levyho procházka – Levyho procházka neboli Levy flight představuje trajektorii, kdy jedinec má oproti náhodné procházce větší pravděpodobnost dlouhých kroků.. Vytvoří se argumentem „linearErrorDist = stats::rcauchy“.



Obrázek č. 17 – Příklady náhodně generovaných trajektorií: a) Náhodná trajektorie, b) „Přimočará trajektorie“, c) Brownův pohyb, d) Lévyho procházka (Levy flight)
(Vlastní zdroj)

4.3 Analýza stavů/modů chování pomocí moveHMM

Balíček moveHMM byl navržen, jak už napovídá název, pro analýzu stavů a modů chování za použití skrytého Markovového modelu. K modelování používá dvourozměrné časové řady, délku kroku a úhel otočení v určitém čase (Michelot, 2016).

Stejně jako u předešlého balíčku je prvním krokem jeho instalace a následné nahrání. Před použitím moveHMM a jeho funkcí je potřeba mít správně naformátovaná data. Vstupní data musí obsahovat sloupce se souřadnicemi zeměpisné šířky a délky, anebo souřadnice v některém mapovém souřadnicovém systému. Volitelnými údaji je ID, které označuje jedince (pokud sloupec ID chybí, tak balíček předpokládá, že v datasetu existuje jenom jeden jedinec), a popřípadě i kovariáta, kterou můžeme použít při tvorbě modelu.

Před vytvořením cílového modelu je potřeba použít funkci „prebData“, která vypočítá délky kroků a jejich úhel otočení (obr. č. 18). Před jejím je potřeba vyřešit chybějící měření (balíček předpokládá konstantní časový krok mezi pozorováními). Chybějící

měření se v případě této práce vyřešila pomocí vlastní funkce (viz. příloha č. 1).
Potřebnými argumenty pro správné fungování funkce jsou:

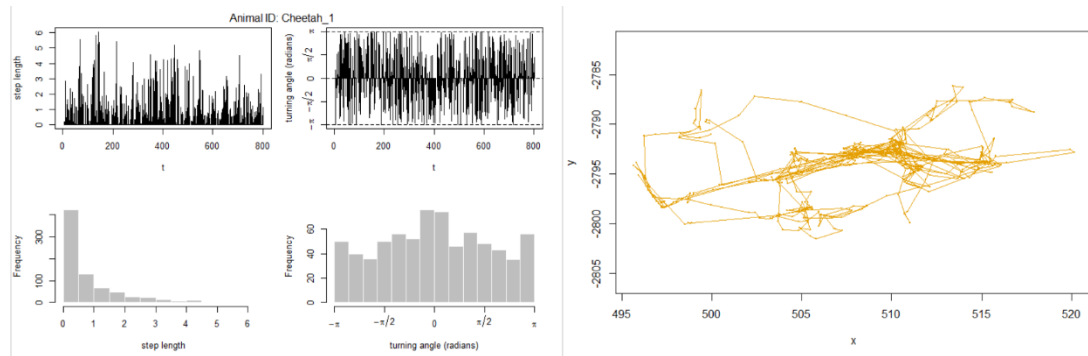
- type: Určuje, zdali jsou v mapovém souřadnicovém systému (type="UTM"), anebo v zeměpisné šířce/délce (type="LL")
- coordNames: Používá se v případě jiného pojmenování sloupců se souřadnicemi než „x“ a „y“

Výsledná data jdou graficky znázornit pomocí „plot = (data, compact = T)“ (obr. č. 19).

ID	step	angle	x	y	time	TEMP	Height
<chr>	<dbl>	<dbl>	<dbl>	<dbl>	<SI_posixct>	<dbl>	<dbl>
1	NA	NA	509.7917	-2792.354	2014-04-12 04:00:33	13.5	1161
2	NA	NA	NA	NA	2014-04-12 10:00:33	13.5	1161
3	NA	NA	NA	NA	2014-04-12 16:00:33	13.5	1161
4	0.0000000	NA	507.7540	-2793.037	2014-04-12 22:00:33	25.5	1164
5	0.2102280	NA	507.7540	-2793.037	2014-04-13 04:00:33	22.5	1167
6	0.2130708	-3.137161	507.9374	-2792.934	2014-04-13 10:00:33	30.5	1167

Obrázek č. 18 – Ukázka z dat vytvořených funkcí „prebData“

(Vlastní zdroj)



Obrázek č. 19 – Vizualizace „prebData“. Na levém ve vrchní části grafu lze vidět časové řady kroků jedince a úhel otočení; ve spodní části jsou graficky znázorněny histogramy pro délku kroků a jejich úhly. Pravý graf vizualizuje trajektorii.

(Vlastní zdroj)

Po použití „prebData“ na vstupní data lze začít s tvorbou data,. Než se přistoupí k tvorbě samotného modelu, je potřeba standardizovat hodnoty kovariát a zadat vstupní parametry, ke kterým můžou pomoci histogramy vytvořené funkcí „prebData“:

- mu0: průměrná délka kroku
- sigma0: odchylka kroku
- whichzero: podíl nulových hodnot délky kroku
- stepPar0: vektor kombinace m0, zeromass0 a whichzero
- angleMean0: průměrná velikost úhlu
- kappa0: odchylka pro velikost úhlu

- anglePar0: vektor kombinace angleMean0, kappa
- stepDist: rozdělení pro délku kroku (gamma, Weibullovo, exponenciální, lognormální)
- angleDist: rozdělení pro úhly (von Misesovo, Cauchyovo)

Pro vytvoření modelu se používá funkce „fitHMM“, která obsahuje velké množství argumentů:

- data: moveData připravená pomocí „prebData“
- nbStates: počet stavů v HMM
- beta0: koeficient, většinou se zadává „NULL“
- stepPar0: vektor kombinace m0, zeromass0 a whichzero
- anglePar0: vektor kombinace angleMean0, kappa
- formula: kovariáta, pro model bez kovariáty se používá hodnota ~1
- stepDist
- angleDist: parametr lze zadat i ve formě „angleDist = „none““ a vytvořit tím pouze jednorozměrný model
- angleMean

Ve vytvořeném modelu lze najít průměrné hodnoty délky kroků, velikosti úhlů pro daný stav a regresní koeficienty závislosti pravděpodobnosti přechodu z jednoho stavu do druhého na kovariátě (obr. 20).

```

Step length parameters:
-----
                state 1    state 2
mean          0.31415220  1.76045768
sd            0.50432602  1.29899567
zero-mass     0.01419297  0.04005698

Turning angle parameters:
-----
                state 1    state 2
mean          -2.92956218  0.004325341
concentration  0.09265775  0.776972965

Regression coeffs for the transition probabilities:
-----
                1 -> 2    2 -> 1
intercept     0.7821853  -1.13322631
TEMP          -0.1107295  0.01595603

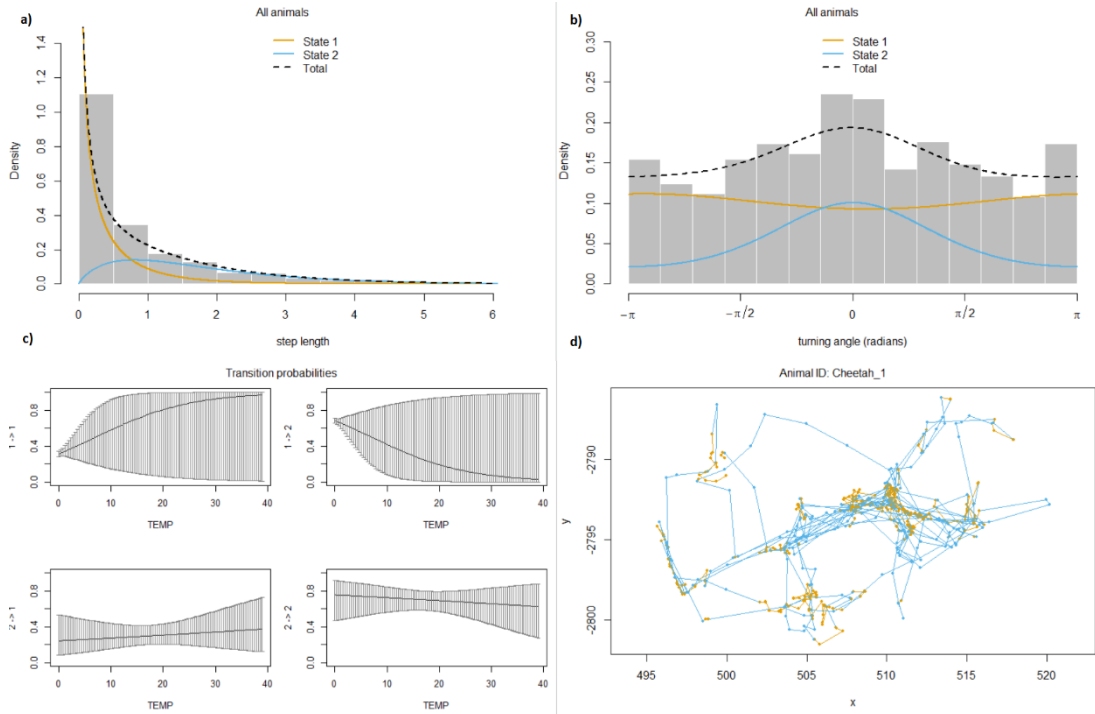
```

Obrázek č. 20 – Výpis z modelu, který jako kovariátu používá teplotu.

(Vlastní zdroj)

Nejvhodnější model lze například vybrat pomocí metody AIC (Akaike information criterion) a to funkci „AIC“.


Vytvoření modelu umožňuje výpočet konfidenčních intervalů pomocí „CI“, pravděpodobnosti stavu „stateProbs“ a vizualizaci modelu pomocí „plot“ a vyplnění argumentu „plotCI = T“ (obr. č. 21).



Obrázek č. 21 – Vizualizace modelu: a) Histogram zobrazující délku kroků k/ke hustotě kroků, b) Histogram zobrazující velikost úhlu kroků k/ke hustotě velikosti úhlů kroků, c) Graf pravděpodobnosti uvažované kovariáty, d) Vizualizace trajektorie s vyznačenými stavy (žlutá barva představuje stav 1, modrá představuje stav 2)

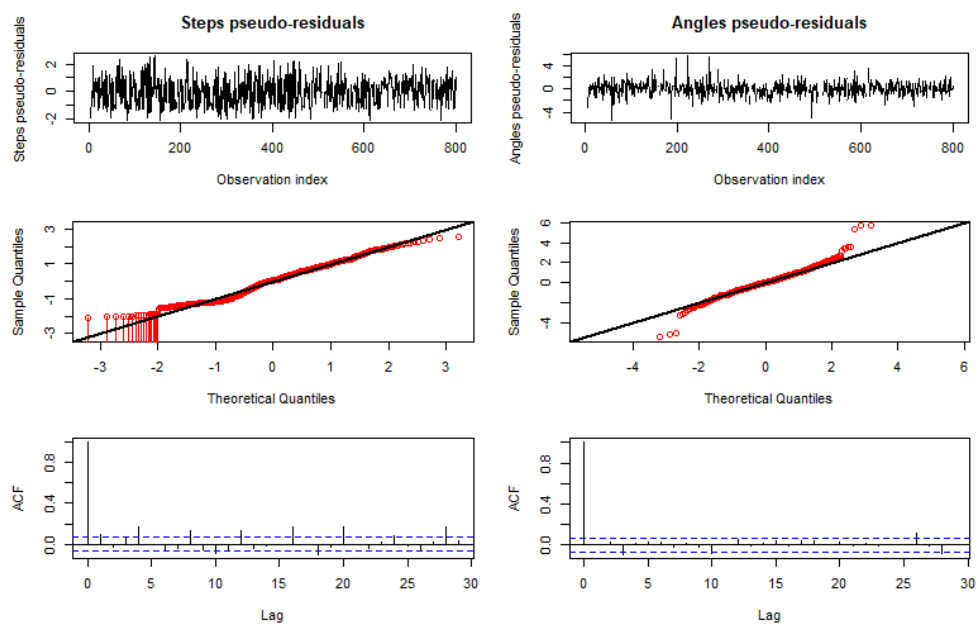
(Vlastní zdroj)

Jak bylo už výše zmíněno, tak pravděpodobnosti stavů jdou vypočítat pomocí funkce „stateProbs“. Její vizualizace probíhá přes „plotStates“, u kterého lze u více pozorovaných jedinců použít argument „animal“ a tím vizualizovat pravděpodobnost stavů jen pro zadaného jedince (graf č. 3).



Graf č. 3 – Vizualizace pravděpodobností stavů pro model používající jako kovorytu teplotu (Vlastní zdroj)

Po vytvoření modelu je potřeba model zkontrolovat, jestli splňuje všechna důležitá kritéria. K této činnosti balíček MoveHMM používá funkci „plotPR“. K jeho použití je potřeba nejdříve vypočítat pseudo-rezidua pomocí „pseudoRes“. Funkce „plotPR“ zobrazí časové řady pseudo-reziduí, Q-Q plot sloužící k porovnání rozdělení s předpokládaným normálním rozdělením a autokorelační funkci (obr. č. 22). Dalším možným testem je test normality reziduí, například Jarqueův a Berryho test normality („jarque.bera.test“) a nebo Shapiro-Wilkův test normality (shapiro.test).



Obrázek č. 22 – Grafické zobrazení „PlotPR. Horní grafy zobrazují časové řady pseudo-reziduí; prostřední grafy Q-Q plot pseudo-reziduí; spodní grafy autokorelační funkci „acf“.

(Vlastní zdroj)

5 Výsledky

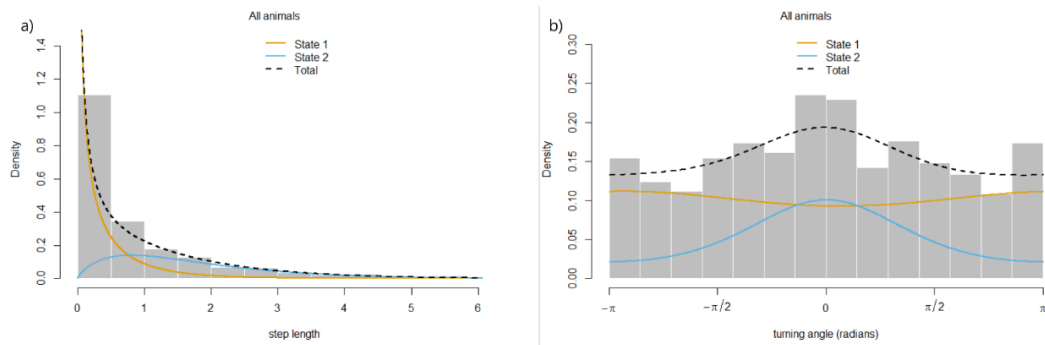
Hlavní praktická část se zabývala použitím skrytých Markovových modelů na porovnání trajektorií samice geparda štíhlého v různých reprodukčních obdobích v prostředí R, za použití balíčku MoveHMM (Michelot, 2016), za kterým stojí statističtí ekologové Théo Michelot, Roland Langrock a Brett T. McClintock. Hlavní otázkou bylo, jestli skryté Markovovy modely, dokážou odhalit různá reprodukční období.

Celkově bylo vytvořeno několik modelů s rozdělením podle Von Misesse pro úhly otočení a Gamma rozdělením pro délky kroků. Pro každé reprodukční období z nich byl vybrán vždy nejvhodnější model daného období s nejnižší hodnotou AIC. Funkce AIC porovnávala modely jednostavové, dvoustavové a trojstavové, jak bez kovariát, tak i s různými kovariátami a jejich kombinacemi. Jako kovariáta byla použita nadmořská výška a teplota.

5.1 Model pro samici geparda štíhlého před březostí

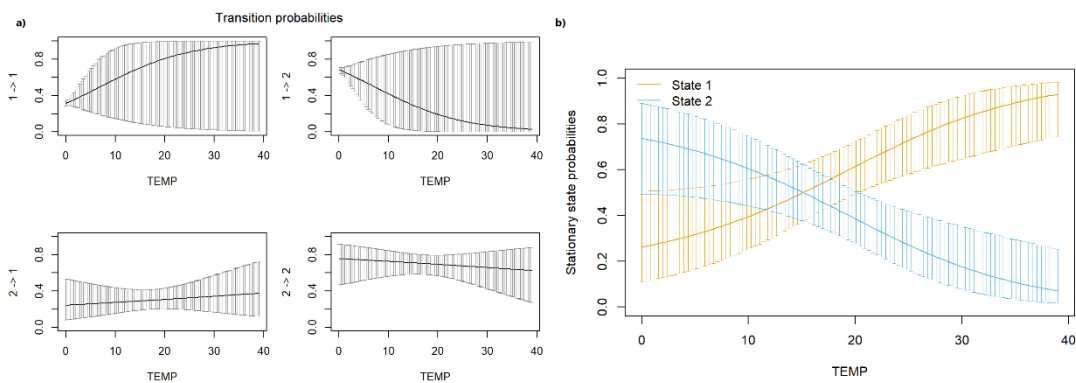
Nejvhodnějším modelem pro období, kdy samice nebyla březí a ani neměla mláďata, byl dvoustavový model s teplotou jako kovariátou. Samice se tedy pohybovala ve dvou stavech (modech), u kterých byl přechod ovlivňován teplotou. První stav byl charakterizován kratší vzdáleností kroků a více častým otáčením, v druhém stavu byli častější delší kroky a méně časté otáčení (obr. č. 23). Je zajímavé, že samice se v prvním stavu otáčela častěji ve směru hodinových ručiček, průměrný úhel otočení byl $-2,930$ s 95% konfidenčním intervalem $[-5,361; -0,801]$. V druhém stavu se skoro vůbec neodchylovala od přímočarého pohybu, průměrný úhel otočení byl $0,004$ s 95% konfidenčním intervalem $[-0,271; 0,297]$.

Podle (obr. č. 24a) lze soudit, že samice s vyšší teplotou prostředí má tendenci zůstat ve stavu jedna, naopak s nižší teplotou má větší pravděpodobnost přejít ze stavu jedna do stavu druhého a tam i zůstat při rostoucí teplotě. Stacionární stav je nepravděpodobnější kolem teploty 15 °C (obr. č. 24b). Z toho jde usoudit, že s největší pravděpodobností u samice převažoval přímočařejší pohyb, který je typický u druhého stavu. Ten to úsudek potvrdil i (obr. č. 25), na kterém převažuje modrá barva značící druhý stav.




Obrázek č. 23 – a) Histogram závislosti délky kroků k jejich hustotě, b) Histogram závislosti velikosti úhlů otočení k jejich hustotě.

(Vlastní data)



Obrázek č. 24 – Obrázek zobrazuje 2 grafy, ze kterých lze vyčíst pravděpodobnost přechodu ze stavu 1 do stavu 2 v závislosti na teplotě. Obrázek b) navíc ukazuje i pravděpodobnost stacionárního stavu.


(Vlastní zdroj)



Obrázek č. 25 – Obrázek vizualizuje trajektorii samice před březostí a změny stavu. Žlutá barva představuje stav 1 a modrá stav 2.

(Vlastní zdroj)

V modelu je možné pozorovat periodicky opakující se autokorelaci délky kroků. (graf č. 4). Diagnostika modelu pomocí pseudo-reziduí nevykazovala až na autokorelaci žádný problém, a dalo by se říct, že rozdělení pseudo-reziduí odpovídá normálnímu rozdělení.



Graf č. 4 – Graf autokorelační funkce délky kroků u samice před březostí

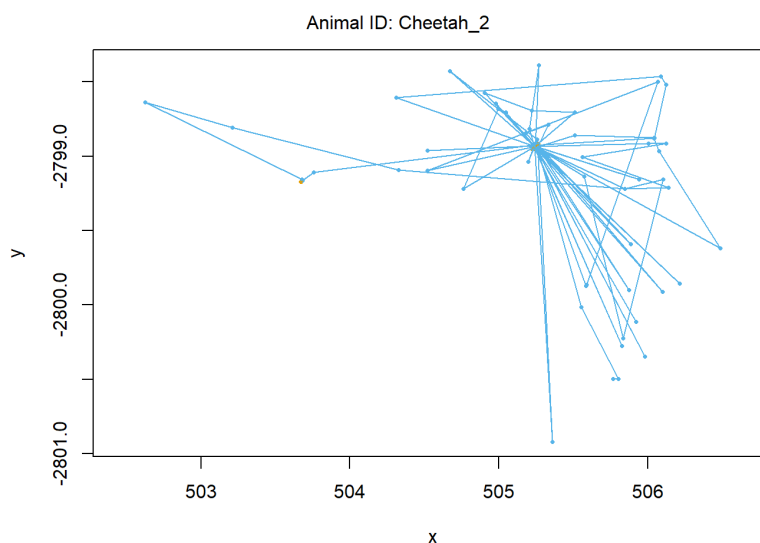
(Vlastní zdroj)

5.2 Model pro březí samici


Podle kritéria AIC byl silně upřednostněn model o dvou stavech bez žádné kovariáty. První stav je popisován krátkými kroky o průměrné délce 0,0039 m s hodně úzkým 95% konfidenčním intervalem [0,0034; 0,0044] a otočením proti směru hodinových ručiček s průměrným úhlem 2,769 a úzkým 95% konfidenčním intervalem [2,158; 3,364]. Naopak u druhého stavu se samice otáčela nejčastěji po směru hodin o průměrném úhlu otočení -2,963 s širším 95 % konfidenčním intervalem [-3,995; -1,994] a průměrnou délkou kroku $5,685e^{-1}$ m s 95% konfidenčním intervalem [$4,330e^{-1}$; $7,463e^{-1}$]. Samice měla opět v prvním stavu kratší kroky, ale úhel otočení se velikostí od stavu dva razantně neliší. Rozdílem mezi stavy je otáčení prvního stavu proti směru a druhého po směru.

Březí samice má pravděpodobnost, že přejde z prvního stavu do druhého 0,158, kdežto s pravděpodobností 0,842 zůstane ve stavu 1. Naopak pravděpodobnost, že zůstane ve stavu druhém, je 0,788 a naopak s pravděpodobností 0,212 se vrátí na zpět do stavu 1.

Vizualizace stavů v trajektorii březí samice (obr. č. 26) není zřetelná a na první pohled převládá ve velké míře stav druhý a první je skoro potlačen, ale v grafickém zobrazení pravděpodobnosti stavu pomocí funkce „plotStates“ převládá v prvních 60–70 pozorováních stav druhý, a posléze více dominuje první stav až přibližně do 180 pozorování, kdy se vyskytují oba stavy v podobném množství (graf č. 5). Na vizualizaci trajektorie je možné vidět, jak se samice vrací skoro pořád do stejného bodu.



Obrázek č. 26 – Vizualizace trajektorie o dvou stavech pro březí samici. Žlutá barva odpovídá stavu 1 a modrá stavu 2
(Vlastní zdroj)

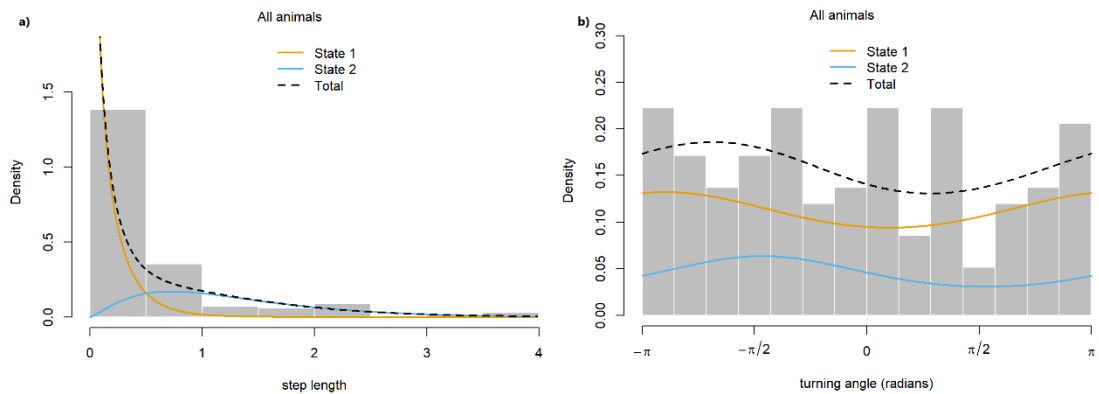


Graf č. 5 – Graf funkce „plotStates“ zobrazující v jakém pozorování měla samice stav 1,2.
(Vlastní zdroj)

Model pro březí samici opět vykazoval podobnou autokorelaci, jak předešlý model pro samici před březostí. Diagnostika modelu byla podobná jako u modelu s březí samicí, jediným rozdílem je odchýlení pseudo-reziduí u úhlů od normálního rozdělení.

5.3 Model pro samici s mlád'aty

Jako nejúspěšnější model pro samici s mlád'aty byl dvoustavových model, kde jako kovariáta vystupuje teplota. Tudiž přechod mezi stavy je ovlivněn změnou teploty. První stav modelu má průměrnou délku kroku 0,130m s 95% konfidenčním intervalem [0,087; 0,192] a průměrný úhel otočení -2,824 s konfidenčním intervalem [-5,410; -0,697]. Průměrná délka kroku pro druhý stav je 1,279m s konfidenčním intervalem [1,004; 1,629] a průměrným úhlem otočení -1,460 s konfidenčním úhlem [-2,756; 2,107] Samice v prvním stavu měla lehce delší kroky a větší úhel otočení, naopak druhý stav byl více přímočařejší. Zajímavé, že samice se v obou stavech otáčela častěji po směru hodinových ručiček (obr. č. 27).



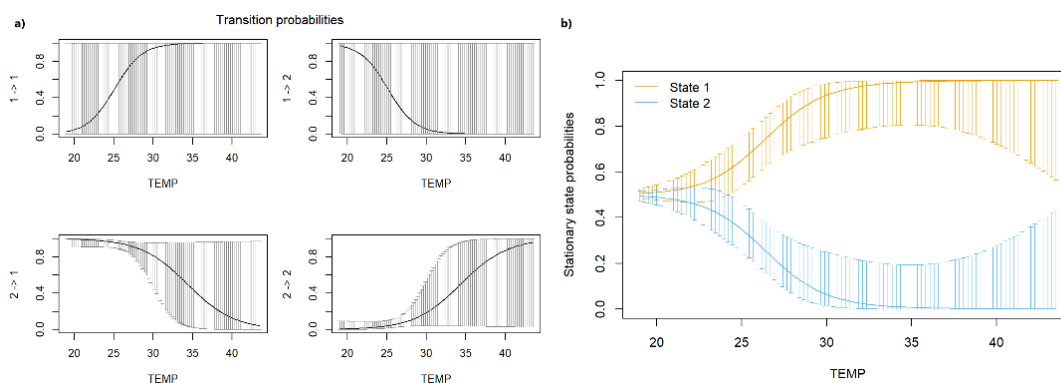
Obrázek č. 27 – a) Histogram závislosti délky kroků k jejich hustotě, b) Histogram závislosti velikosti úhlů otočení k jejich hustotě.

(Vlastní data)

Podle (obr. č. 28a) je nejspíš pravděpodobnost přechod ze stavu jedna do stavu dva se zvyšující teplotou nižší a tendence zůstat v prvním stavu roste s teplotou. Jak přechod ze stavu jedna do stavu dva, tak pravděpodobnost setrvání v prvním stavu má velké intervaly a interpretace nemusí být správná. Pravděpodobnost přechodu ze stavu dva do stavu jedna se zvyšující teplotou snižuje a pravděpodobnost setrvání v druhém stavu se zvyšuje s teplotou. Stacionární stav je nejpravděpodobnější v teplotě kolem 20 °C (obr. 28b).

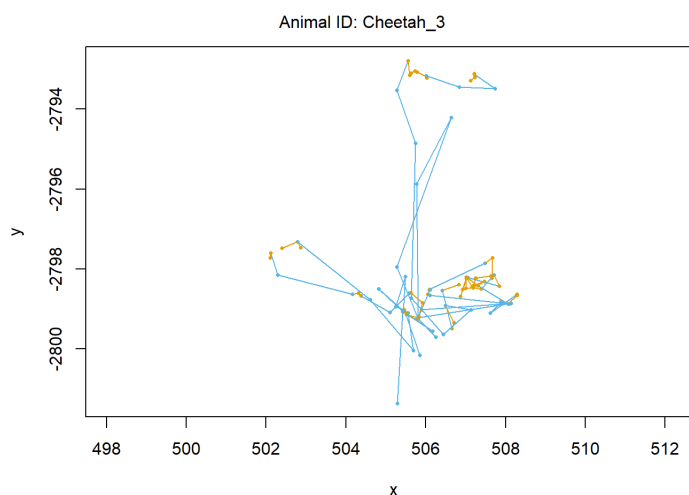
Vykreslení trajektorie s vyznačenými stavy má vyšší rozsah do výšky než do šířky a převládá v ní druhý stav s delšími kroky a menšími úhly (obr. 29).

Diagnostika modelu objevila znovu přítomnou periodickou autokorelaci a odchýlení pseudo-reziduů úhlů od normálního rozdělení.



Obrázek č. 28 – Obrázek zobrazuje 2 grafy, ze kterých lze vyčíst pravděpodobnost přechodu ze stavu 1 do stavu 2 v závislosti na teplotě. Obrázek b) navíc ukazuje i pravděpodobnost stacionárního stavu.

(Vlastní zdroj)




Obrázek č. 29 – Vizualizace trajektorie o dvou stavech pro samici s mládřaty. Žlutá barva odpovídá stavu 1 a modrá stavu 2.

(Vlastní zdroj)

5.4 Srovnání modelů

U různých modelů (reprodukčních období) se lišil tvar u vizualizované trajektorie a poměr stavů (obr. č. 30), které byly pokaždé dva, ale u březí samice je neovlivňovala teplota. U samice před březostí byla trajektorie různorodější a obsahovala největší poměr prvního stavu k druhému. Březí samice se podle trajektorie vracela na jedno místo a vizuálně je skoro první stav potlačen. Trajektorie samice s mládřaty obsahuje

už vyšší poměr prvního stavu k druhému, ale pořád se nemůže rovnat modelu samice před březostí a tvar trajektorie je rozdílný od zbylých reprodukčních období.



Obrázek č. 30 – Zobrazení rozdílnosti v trajektoriích, žlutá barva představuje první stav, modrá stav druhý; a) Samice před březostí; b) Březí samice; c) Samice s mláďaty. Každá trajektorie je v jiném měřítku

(Vlastní zdroj)

Po srovnání údajů z (tabulky č. 2) lze říct, že každé reprodukční období je rozdílné, ale v některých ohledech má podobné vlastnosti, jako ostatní. Ve všech období má samice větší kroky v druhém stavu než v prvním, ale samice před březostí dosahuje v obou stavech největší délky. Naopak březí samice má délku kroků znatelně menší. K největší změně úhlu došlo v modelu pro březí samici. V prvním stavu průměrný úhel byl 2,769 a ve druhém stavu -2,963 a jako v jediném modelu samice viditelně přešla z otáčení poměru hodinových ručiček do protisměru. Oproti tomu směr otáčení v modelu pro samici s mláďaty byl v obou stavech převážně v protisměru hodinových ručiček. Nejprimočařejší pohyb vykonávala samice před březostí, a to v druhém stavu.

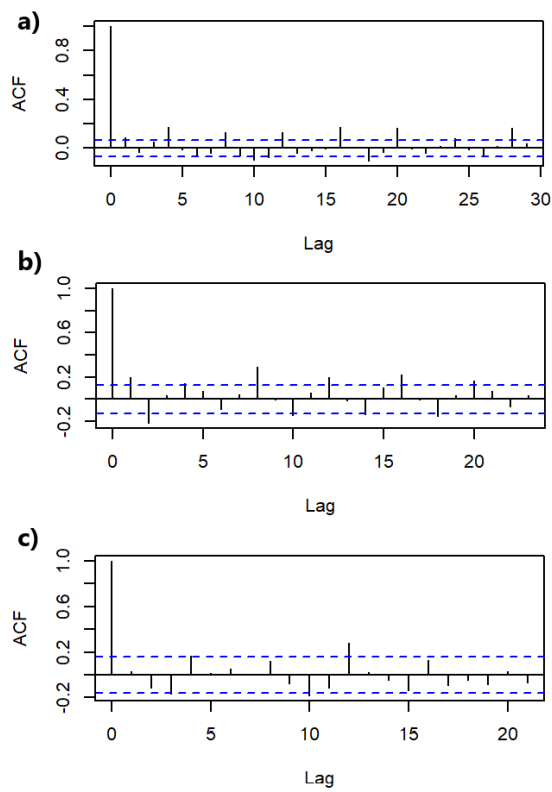
	První stav			
Model	průměrná délka	konfidenční interval	průměrný úhel	konfidenční interval
Samice před březostí	0,314m	[0,223; 0,442]	-2,930	[-5,361; -0,801]
Březí samice	0,0039m	[0,0034; 0,0044]	2,769	[2,158; 3,364]
Samice s mláďaty	0,130m	[0,087; 0,192]	-2,824	[-5,410; -0,697]
	Druhý stav			
Model	průměrná délka	konfidenční interval	průměrný úhel	konfidenční interval
Samice před březostí	1,760m	[1,518; 2,041]	0,004	[-0,271; 0,297]
Březí samice	0,5685e ⁻¹ m	[4,330e-1; 7,463e-1]	-2,963	[-3,995; -1,994]
Samice s mláďaty	1,279m	[1,004; 1,629]	-1,460	[-2,756; 2,107]

Tabulka č. 2 – Tabulka zobrazuje průměrné hodnoty pro délku kroku, velikost otočení a jejich konfidenční intervaly pro každý stav.

(Vlastní zdroj)

Po důkladném srovnání trajektorie pro každý model lze vidět určitý rozdíl jak v průměrných hodnotách, poměru stavů, tak i ve tvaru trajektorie. Zajímavým

spojením je přítomná periodická autokorelace u všech kroků, opakující se každých 24 hodin. (obr. č. 31).



Obrázek č. 31 – Zobrazení periodické autokorelace délky kroků u modelů. a) samice před březostí, b) březí samice, c) samice s mláďaty
(Vlastní zdroj)

6 Diskuze

6.1 Zhodnocení balíčků trajr a moveHMM

Na funkce balíčku Ttrajr nebyl kladený tak velký důraz jako u balíčku MoveHMM. Avšak jeho velkou výhodou je snadná vizualizace trajektorie a její úprava. Zajímavou funkcí balíčku je generování různých typů trajektorií, které by mohly být využity jako zkušební data pro jiné balíčky zabývající se analýzou telemetrických dat. U generovaných trajektorií je možné nastavit i délku kroku. Velkou nevýhodou balíčku je jeho neschopnost použít časové údaje, které nemají numerický formát a je potřeba je převést. Trajektorii jako samotnou lze ještě vytvořit a upravit, ale analytické funkce balíčku mají problém s jiným formátem času. Další nevýhodou je nemožnost vygenerovat trajektorii s nenumerickým formátem času.

moveHMM má velkou výhodu ve své jednoduchosti. Většina funkcí je lehce pochopitelná a neobsahuje spoustu argumentů. Výjimkou je hlavní funkce k vytvoření modelu „fitHMM“, do které se zadávají parametry, které je potřeba chvíli zkusit a pochopit. Balíček dokáže vytvořit vizualizaci trajektorie, histogramy a obsahuje i funkce na zhodnocení modelu. Dokáže vytvořit jak jednoduchý jednostavový model, tak i vícestavové modely, jednorozměrných, tak dvourozměrných dat. Modely jdou vytvořit jak bez kovariát, tak i s jejími kombinacemi. Navíc obsahuje i zkušební data s názvem „elk_data“. Balíček sice umí pracovat se souřadnicovým systémem UTM, tak i se zeměpisnými souřadnicemi, bohužel ale už neobsahuje možnost je převést. Navíc moveHMM předpokládá konstantní časové rozdíly mezi měřeními a po doplnění chybějících pozorování hodnotou „NA“ v datech nedovolí vytvořit objekt pomocí funkce „prebData“. Nevýhodou je i vizualizace stavu v trajektorii, která úplně neodpovídá poměru stavů, které jdou vyčíst z „plotStates“.

Zajímavou alternativou k trajr by mohl být adehabitatLT, který je součástí souboru balíčků adehabitat, který obsahuje adehabitatHR, adehabitatHS, adehabitatMA. Mohlo by se jednat přímo o adehabitat LT, který slouží k analýze pohybu a trajektorie zvířat. S použitím toho balíčku by se daly využít i ostatní součásti adehabitat, které umí analyzovat domovské okrsky, analyzovat výběr stanoviště a environmentálních jevů.

V poslední době vychází spousta nových balíčků a jejich aktualizace. Na začátku tohoto roku byl vydán balíček s názvem mometumHMM, který slouží k analýze telemetrických dat pomocí skrytých Markovových modelů. Ten je velmi podobný

moveHMM. momentumHMM je jednodušší verze, která řeší problémy a chyby v moveHMM a rozšiřuje i funkce pro přípravu dat, výpočet parametrů, a také i pro celkovou analýzu po vytvoření modelu (McClintock, 2018).

6.2 Relevance výsledků z hlediska ekologie sledovaných druhů

Samice geparda štíhlého se vyznačující velkým domovským okrskem, který patří mezi jedny z největších v říši zvířat. Některé samice dokonce ani domovské okrsky nevytváří a pohybují se na velké vzdálenosti. Během reprodukčních cyklů výrazně mění svůj způsob života (Durant, 2017).

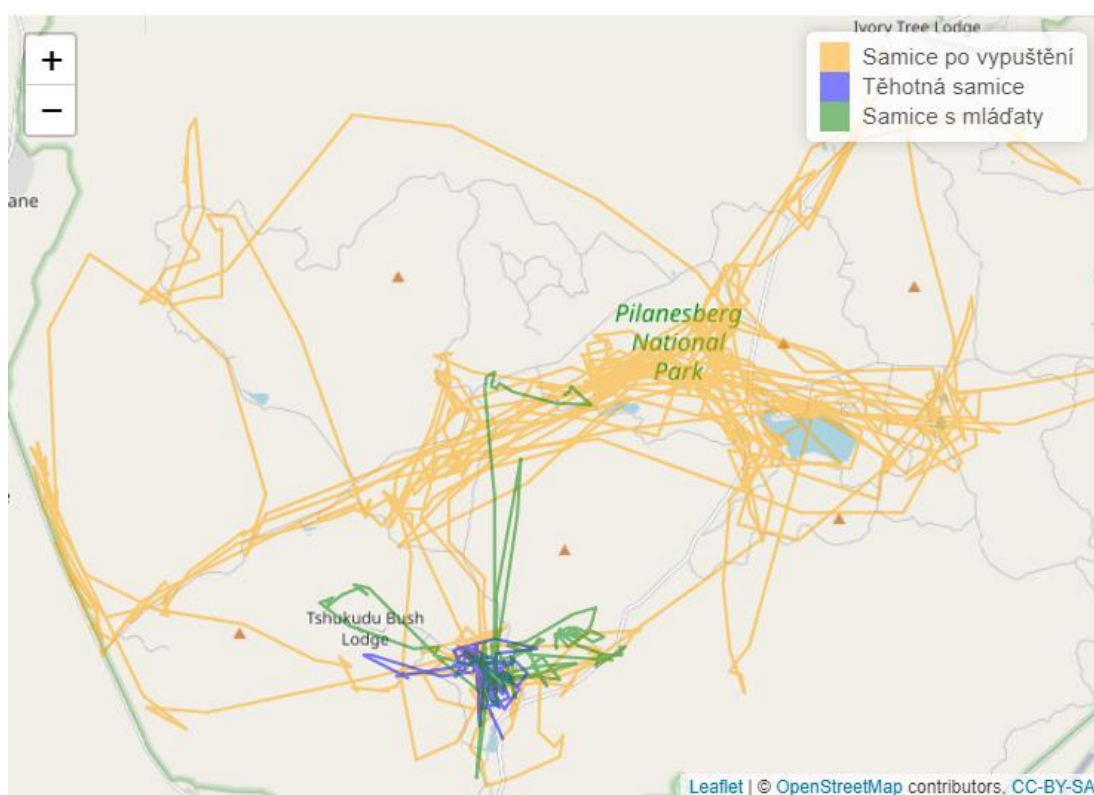
Samice, které nejsou březí a ani nemají mláďata, se pohybují na velké vzdálenosti a často volí přímočarou cestu. Po otěhotnění většinou nedochází k tak drastické změně pohybu, jako poté po porodu. Většinu doby se pohybují stejně, jako kdyby ani nebyly březí. Větší změna nastane před porodem, kdy samice začne hledat vhodné místo pro úkryt mláďat. Jakmile ho najde, tak se k němu často vrací. Po porodu se samici razantně změní jak život, tak i její pohyb. Z dlouhého pohybu přejde na krátký a pohybuje se zhruba 1 km od úkrytu, kde má svá mláďata. Velkou část času tráví s mláďaty a na lov vychází nejčastěji za den, aby v noci ochránila mláďata před predátory. Po dvou měsících začnou mláďata vycházet z úkrytu a následují svou matku. V tuto chvíli se pohyb matky znovu vrací trochu k normálu (Klein, 2021).

Trajektorie z prvního modelu odpovídá správně pohybovému chování samice bez mláďat, ale při vizualizaci trajektorie do mapy pomocí balíčku „leaflet“ (obr. č. 32) je patrné, že chybí některá měření. Pro lepší analýzu by byl lepší model s daty, která by měla menší časový rozdíl. Podle mapového výstupu samice geparda několikrát přeplavala jezero Mankwe Dam, které je široké přes jeden kilometr.

V modelu pro březí samici se samice často vrací na jedno místo, o kterém by se dalo říct, že je budoucí úkryt pro mláďata, avšak zase oproti první modelu změnila své chování víc, než v případě stádia, kdy porodila a měla mláďata (obr. č. 32). Proto ten to model úplně neodpovídá teoretickým informacím o pohybu březích gepardů. Jedním z možných příčin může být i chyba v měření, ale také i vnější faktor, který donutil samici zmenšit pohyb, například nedostatek potravy, který by vysvětloval časté otáčení.

Po porodu byla samice měřena pouze 2 měsíce, tedy do fáze, kdy ještě mláďata samici nedoprovázela a zůstávala stále v úkrytu. Samice se zase vracela zpátky do určitého místa, ale z mapy se zdá, že úkryt přesunula, anebo dokonce mláďata přesouvala častěji (obr. č. 32). Model sice ukazuje pohyb od úkrytů ve větším rozsahu než 1 km, ale pořád zde můžou mít roli vnější faktory. Samici se narodila 4 mláďata, a po krátké době byla sledována jen 3.

Ve všech třech modelech se vyskytovala periodická autokorelace, která se vyskytovala každých 24 hodin., což by mohlo odpovídat cirkadiánnímu rytmu. Gepard periodicky po 24 hodinách zvětšil na chvíli kroky.



Obrázek č. 32 – Mapa vytvořená pomocí balíčku „leaflet“, znázorňující trajektorie všech tří modelů.

(Vlastní zdroj)

7 Závěr

Cílem práce bylo představit prostorovou ekologii, způsoby monitoringu a především možnosti analýzy telemetrických dat, které byly v praktické části demonstrovány částečně na balíčku trajr, ale především také na balíčku moveHMM.

První část popisuje prostorovou ekologie, její principy, typy pohybu a její vazbu s behaviorální ekologií. Následně popisuje také metody monitoringu a metody sloužící k analýze telemetrických dat. V této části byla použita převážně zahraniční literatura zaměřená na prostorovou ekologii, animal behaviour a na analýzu telemetrických dat.

Druhá část se zabývala analýzou telemetrických dat v prostředí programu R, která se začíná stávat nedílnou součástí prostorové ekologie. V práci byly představeny dva balíčky. Okrajově byl použit také balíček trajr, který slouží k vizualizaci a k analýze trajektorie. Nejlepší vlastností je generování určitých typů trajektorie. Významnější část si zasloužil balíček moveHMM, který pracuje se skrytými Markovovy modely, které spadají pod tzv. state-space modely, jež se začínají v biologii čím dál víc využívat a skrývají velký potenciál (Langrock, 2012). Hlavní otázkou praktické části bylo, jestli dokáže model rozeznat reprodukční stádia geparda štíhlého, který byl sledován pomocí GPS telemetrie v Jižní Africe.

První model odpovídal teoretickým informacím. U zbylých dvou stádiích nebylo tak jednoznačné. Avšak velkou roli hrají i vnější efekty, které nebyly do modelu zahrnuty. Každé stadium bylo charakteristické určitým druhem pohybu, ale všechny tři měly jednu věc společnou, a to periodicky opakovanou korelaci délky kroku, která by v budoucnu stála za větší pozornost.

V budoucnu by bylo vhodné použít model na více samicích a klidně analyzovat pohyb samice po porodu až do dalšího oplodnění. Dále by se dal vytvořit jeden model, který by obsahoval všechny stadia zároveň a vyzkoušet zda-li balíček odhalí určité stadia. Zajímavé by bylo použít i jinou kovariátu než nadmořskou výšku a teplotu. Rovněž by bylo dobré vyzkoušet model se vzdáleností jedince od vody, nebo od potravy. Navíc by bylo vhodné provést i detailnější výzkum, který by obsahoval pozorování predátorů v dané lokaci a vnější vlivy, které by mohly ovlivnit chování jedince. Šlo by také zahrnout i použití jiných metod pro analýzu GPS telemetrických dat, ale také i jiných balíčků. Velkou pozornost by si zasloužil určitě balíček mometumHMM.

8 Přehled literatury a použitých zdrojů

ÅKESSON S., BIANCO G., 2016. Assessing vector navigation in long-distance migrating birds. *Behavioral Ecology* **27**: 865-875.

ALEXANDER J. S., ZHANG CH., SHI K., RIORDAN P., 2016. A granular view of a snow leopard population using camera traps in Central China. *Biological Conservation* **197**: 27-31.

ANIMALIA, © 2020. Sedentary animals (online) [cit. 2021-03-10]. Dostupné z: <<http://animalia.bio/sedentary-animals>>

BALL J. P., NORDENGREN C., WALLIN K., 2001. Partial migration by large ungulates: characteristics of seasonal moose *Alces alces* ranges in northern Sweden. *Wildlife Biology* **7**: 39-47.

BASTILLE-ROUSSEAU G., POTTS J. R., YACKULIC CH. B., FRAIR J. L., ELLINGTON E.H., BLAKE S., 2016. Flexible characterization of animal movement pattern using net squared displacement and a latent state model. *Movement Ecology* **4**: 1-12.

BASTILLE-ROUSSEAU G., GIBBS J. P., CHARLES B. YACKULIC CH. B., 2017. Animal movement in the absence of predation: environmental drivers of movement strategies in a partial migration system. *Oikos* **126**: 1004-1019.

BENHAMOU S., RIOTTE-LAMBERT L., 2012. Beyond the Utilization Distribution: Identifying home range areas that are intensively exploited or repeatedly visited. *Ecological Modelling* **227**: 112-116.

BERDAHL A., VAN LEEUWEN A., LEVIN S. A., TORNEY C. J., 2016. Collective behavior as a driver of critical transitions in migratory populations. *Movement Ecology* **4**.

BUNNEFELD N., BÖRGER L., MOORTER B. V., ROLANDSEN CH. M., DETTKI H., SOLBERG E. J., ERICSSON G., 2011. A model-driven approach to quantify migration patterns: individual, regional and yearly differences. *Journal of Animal Ecology* **80**: 466-476.

BURT W. H., 1943. Territoriality and Home Range Concepts as Applied to Mammals. *Journal of Mammalogy* **24**: 346-352.

- CALENGE, Clément, 2006. The package “adehabitat” for the R software: A tool for the analysis of space and habitat use by animals. *Ecological Modelling* 197: 516-519.
- CALSBECK R., 2009. Sex-specific adult dispersal and its selective consequences in the brown anole, *Anolis sagrei*. *Journal of Animal Ecology* **78**: 617-624.
- CARO T. M., COLLINS D. A., 1987. Male Cheetah Social Organization and Territoriality. *Ethology* **74**: 52-64.
- CLOBERT J., J.F. GALLIARD, COTE J., MEYLAN S., MASSOT M., 2009. Informed dispersal, heterogeneity in animal dispersal syndromes and the dynamics of spatially structured populations. *Ecology Letters* **12**: 197-209.
- ROCÍO J., BOONE M. E., SUMNER M., BASILLE M., 2021. CRAN Task View: Processing and Analysis of Tracking Data (online) [cit. 27.3.2021]. Dostupné z: < <https://cran.r-project.org/web/views/Tracking.html> >
- DAVIES N., KREBS J., 2012. *Introduction to Behavioural Ecology*. 4th., John Wiley & Sons, Hoboken, 506 p. ISBN 9781405114165.
- DEMŠAR U., BUCHIN K., CAGNACCI F., SAFI K., SPECKMANN B., N. VAN DE WEGHE, WEISKOPF D., WEIBEL R., 2015. Analysis and visualisation of movement: an interdisciplinary review. *Movement Ecology* **3**.
- DINGLE H., DRAKE V. A., 2007. What Is Migration?. *BioScience* **57**: 113-121.
- DINGLE H., 2014. *Migration: The Biology of Life on the Move*. 2nd., Oxford University Press, Oxford, 336 p. ISBN 9780199640386.
- DODGE S., BOHRER G., WEINZIERL R., 2013. The environmental-data automated track annotation (Env-DATA) system: linking animal tracks with environmental data. *Movement Ecology* **1**.
- DURANT M. S., MITCHELL N., GROOM R., 2017. The global decline of cheetah *Acinonyx jubatus* and what it means for conservation. *Proceedings of the National Academy of Sciences* **114**: 528-533.
- DUTCHER J., DUTCHER J., MANFULL J., 2019. *Skrytý život vlků*. Přeložila Vendula DAVIDOVÁ 1. vydání, Élyision, České Budějovice, 216 s. ISBN 978-80-8775-717-8.

- FLEETISTIC, 2016. How GPS Started (online) [cit. 2021-03-09]. Dostupné z: <<https://www.fleetistics.com/resources/gps-history-benefits/>>
- FLEMING, C. H., FAGAN W. F., MUELLER T., OLSON K. A., LEIMGRUBER P., CALABRESE J.M, 2015. Rigorous home range estimation with movement data: a new autocorrelated kernel density estimator. *Ecology* (5): 1182-1188
- FORAN D. R., 1997. Species Identification from Scat: An Unambiguous Genetic Method. *Wildlife Society Bulletin*. 4: 835–839.
- FOX J. L., CHUNDAWAT R. S., 2016. What is a Snow Leopard? Behavior and Ecology. In: NYHUS P. (eds.): *Snow Leopards*. Elsevier Books, Oxford, p. 13-21. ISBN 9780128022139.
- GAMO S., LINDZEY F, RUMBLE M. A., STEFANICH M., 1999. GPS radio collar 3D performance as influenced by forest structure and topography. *Biotelemetry* 15: 9-14.
- GENT T., GIBSON S., 2012. *Herpetofauna Workers' Manual*. 2nd., Pelagic Publishing, London, 152 p. ISBN 978-1907807237.
- GERENCSÉR L., VÁSÁRHELYI G., NAGY M., VICSEK T., MIKLÓSI A., POLAVIEJA G. G. (ed.), 2013. Identification of Behaviour in Freely Moving Dogs (*Canis familiaris*) Using Inertial Sensors. *PLoS ONE* 8.
- GESE E., 2001. Monitoring of terrestrial carnivore populations. In: FUNK S. M., *Carnivore Conservation*. University Press & The Zoological Society of London, Cambridge, p. 372–396. ISBN 978052166537.
- GETZ M. W., FORTMANN-ROE S., CROSS C. P., LYONS J. A., RYAN S. J., WILMERS C. CH., COULSON T., 2007. LoCoH: Nonparametric Kernel Methods for Constructing Home Ranges and Utilization Distributions. *PLoS ONE* 2.
- GURARIE E., BRACIS CH., DELGADO M., MECKLEY D. T., KOJOLA I., WAGNER C. M., BÖRGER L., 2016. What is the animal doing? Tools for exploring behavioural structure in animal movements. *Journal of Animal Ecology* 85: 69-84.
- HEINEMEYER K.S., ULIZIO T. J., HARRISON R.L., 2008. Natural sign: Tracks and scat. ROBERT L. A. (eds.), *Noninvasive Survey Methods for Carnivores*. 1nd., Island Press, Washington D.C, p. 45-74. ISBN 978-1597261203.

HORNE J. S., GARTON E. O., KRONE S. M., LEWIS J. S., 2007. Analyzing animal movements using brownian bridges. *Ecology* **88**: 2354-2363.

IVB, 2021. Vědci potvrdili výskyt kočky divoké na Dobříšsku, pomohla informace od veřejnosti (online) [cit. 2021-03-08]. Dostupné z: <<https://www.ivb.cz/aktuality/vedci-potvrdili-vyskyt-kocky-divoke-na-dobrissku-pomohla-informace-od-verejnosti/>>

JELTSCH F., BONTE D., PE'ER G. et al., 2013a. Integrating movement ecology with biodiversity research - exploring new avenues to address spatiotemporal biodiversity dynamics. *Movement Ecology* **1**.

KAMATH A., WESNER A. B., 2020. Animal territoriality, property and access: a collaborative exchange between animal behaviour and the social sciences. *Animal Behaviour* **164**: 233-239.

KRAUSMAN P. R., MORALES S. M., 2005. *Acinonyx jubatus*. *Mammalian Species* **771**: 1-6.

KUNDT R., 2017. Evoluční studium náboženství a terorismus (online) [cit. 2021-03-10]. Dostupné z: <https://is.muni.cz/el/phil/podzim2017/RLB405/um/Evolucni_studium_nabozenstvi_a_terorismus_2017_Podzim.pdf>

KUTAL M., BOJDA M., 2018. Základy terénního monitoringu pobytových znaků velkých šelem (online) [cit. 2021-03-08]. Dostupné z: <<https://www.selmy.cz/vlcihlidky/data/files/zaklady-terenniho-monitoringu-2018.pdf>>

LANGROCK R., KING R., MATTHIOPOULOS J., THOMAS L., FORTIN D., MORALES J. M., 2012. Flexible and practical modeling of animal telemetry data: hidden Markov models and extensions. *Ecology* **93**: 2336-2342.

LONG J. A., NELSON T. A., 2013. Measuring Dynamic Interaction in Movement Data. *Transactions in GIS* **17**: 62-77.

MCLEAN D. J., SKOWRON VOLPONI M. A., TREGENZA T., 2018. Trajr: An R package for characterisation of animal trajectories. *Ethology* **124**: 440-448.

- MICHELOT T., LANGROCK R., PATTERSON T. A., MCINERNY G., 2016. MoveHMM: an R package for the statistical modelling of animal movement data using hidden Markov models. *Methods in Ecology and Evolution* **7**: 1308-1315.
- MUELLER T., FAGAN W. F., 2008. Search and navigation in dynamic environments - from individual behaviors to population distributions. *Oikos* **117**: 654-664.
- MUELLER T., OLSON K. A., DRESSLER G., 2011. How landscape dynamics link individual- to population-level movement patterns: a multispecies comparison of ungulate relocation data. *Global Ecology and Biogeography* **20**: 683-694.
- MŽP, 2009. Metody monitoringu (online) [cit. 2021-03-05]. Dostupné z: <<http://www.velkeselmy.cz/metody-monitoringu>>
- NATHAN R., GETZ W. M., REVILLA E., HOLYOAK M., KADMON R., SALTZ D. a SMOUSE P. E., 2008. A movement ecology paradigm for unifying organismal movement research. *Proceedings of the National Academy of Sciences* **105**: 19052-19059.
- NESSE R. M., 2013. Tinbergen's four questions, organized: a response to Bateson and Laland. *Trends in Ecology & Evolution* **28**: 681-682.
- O'CONNELL A. F., NICHOLS J. D., KARANTH K. U. (ed.), 2011. *Camera Traps in Animal Ecology*. 1nd., Springer Japan, Tokyo. ISBN 978-4-431-99494-7.
- PATTERSON T., THOMAS L., WILCOX C., OVASKAINEN O., MATTHIOPOULOS J., 2008. State-space models of individual animal movement. *Trends in Ecology & Evolution* **23**: 87-94.
- PIMM S. L., SMITH R. L., 1999. Ecology (online) [cit. 2021-3-10]. Dostupné z: <<https://www.britannica.com/science/ecology>>
- PIÑEIRO A., BARJA I., 2012. The plant physical features selected by wildcats as signal posts: an economic approach to fecal marking. *Naturwissenschaften* [online]. **99**: 801-809.
- POWELL R. A., MITCHELL M. S., 2012. What is a home range?. *Journal of Mammalogy* **93**: 948-958.

POWER R. J., VAN DER MERWE V., PAGE-NICHOLSON S., BOTHA M. V., DELL S., NEL P., 2019. A Note on the Reestablishment of the Cheetah Population in the Pilanesberg National Park, South Africa. *African Journal of Wildlife Research* **49**: 12-15.

PNAS, 1997. The global positioning system: The Role of Atomic Clocks. In: *Beyond Discovery™: The Path from Research to Human Benefit* (online) [cit. 2021-03-09]. Dostupné z: <<http://www.nasonline.org/publications/beyond-discovery/the-global-positioning-system.pdf>>

ROGERS C., CRAIG A. D., HENSEL H., 1999. Thermoreception (online) [cit. 2021-3-10]. Dostupné z: <<https://www.britannica.com/science/thermoreception>>

RŮŽIČKOVÁ J., VESELÝ M., 2016. Využití radiotelemetrie v entomologii (online) [cit. 2021-03-09]. Dostupné z: <<https://ziva.avcr.cz/files/ziva/pdf/vyuziti-radiotelemetrie-v-entomologii.pdf>>

SHAMOUN-BARANES J., BOM R., VAN LOON E. E., ENS B. J., OOSTERBEEK K., BOUTEN W., POLAVIEJA G. G., 2012. From Sensor Data to Animal Behaviour: An Oystercatcher Example. *PLoS ONE* **7**.

SMITHSONIAN'S NATIONAL ZOO, 2018. Tracking devices (online) [cit. 2021-03-09]. Dostupné z: <<https://nationalzoo.si.edu/migratory-birds/what-radio-telemetry>>

TEITELBAUM C. S., MUELLER T., 2019. Beyond Migration: Causes and Consequences of Nomadic Animal Movements. *Trends in Ecology & Evolution* **34**: 569-581.

TKADLEC E., 2013. *Populační ekologie*, 2. vydání, Univerzita Palackého v Olomouci, Olomouc, 412 s. ISBN 9788024421490.

TUCKER A. D., LIMPUS C. J., MCCALLUM H. I., MCDONALD K. R., 1997. Movements and Home Ranges of *Crocodylus johnstoni* in the Lynd River, Queensland. *Wildlife Research* **24**: 10.

VESELOVSKÝ Z., 2005. *Etologie: biologie chování zvířat*. 1. vydání, Academia, Praha, 408 s. ISBN 80-200-1331-8.

- VLAŠÍN M., MIKÁTOVÁ B., 2005. Terénní výzkum plazů dostává ustálenou podobu (online) [cit. 2021-03-09]. Dostupné z: <https://www.zoobrno.cz/download/CZ%20ZOO%20PROFI%20brezen_15%20K04.pdf>
- WHEAT R. E., LEWIS S. B., WANG Y., LEVI T., WILMERS CH. C., 2017. To migrate, stay put, or wander? Varied movement strategies in bald eagles (*Haliaeetus leucocephalus*). *Movement Ecology* **5**.
- WHITWORTH, Darrell, 2007. Radio telemetry and bird movements (online) [cit. 2021-03-09]. Dostupné z: <<http://www.fao.org/3/a1521e/a1521e07.pdf>>
- WORTON, B. J., 1989. Kernel Methods for Estimating the Utilization Distribution in Home-Range Studies. *Ecology* **70**: 164-168.
- ZUCCHINI W., MACDONALD I., 2009. *Hidden Markov Models for Time Series: An Introduction Using R, Second Edition*. 2nd., Chapman & Hall/CRC, London. ISBN 9781482253832.
- ZWEIFEL-SCHIELLY B., SUTER W., 2007. Performance of Gps Telemetry Collars for Red Deer *Cervus Elaphus* in Rugged Alpine Terrain Under Controlled and Free-living Conditions. *Wildlife Biology* **13**: 299-312.

9 Seznam obrázků

Obrázek č. 1.,

NATHAN R., GETZ W. M., REVILLA E., HOLYOAK M., KADMON R., SALTZ D. a SMOUSE P. E., 2008. A movement ecology paradigm for unifying organismal movement research. *Proceedings of the National Academy of Sciences* **105**: 19052-19059.

Obrázek č. 2.,

BUNNEFELD N., BÖRGER L., MOORTER B. V., ROLANDSEN CH. M., DETTKI H., SOLBERG E. J., ERICSSON G., 2011. A model-driven approach to quantify migration patterns: individual, regional and yearly differences. *Journal of Animal Ecology* **80**: 466-476.

Obrázek č. 3.,

TEITELBAUM C. S., MUELLER T., 2019. Beyond Migration: Causes and Consequences of Nomadic Animal Movements. *Trends in Ecology & Evolution* **34**: 569-581.

Obrázek č. 4.,

JELTSCH F., BONTE D., PE'ER G. et al., 2013a. Integrating movement ecology with biodiversity research - exploring new avenues to address spatiotemporal biodiversity dynamics. *Movement Ecology* **1**.

Obrázek č. 5.,

MUELLER T., FAGAN W. F., 2008. Search and navigation in dynamic environments - from individual behaviors to population distributions. *Oikos* **117**: 654-664.

Obrázek č. 6.,

BURT W. H., 1943. Territoriality and Home Range Concepts as Applied to Mammals. *Journal of Mammalogy* **24**: 346-352.

Obrázek č. 7.,

KUTAL M., BOJDA M., 2018. Základy terénního monitoringu pobytových znaků velkých šelem (online) [cit. 2021-03-08]. Dostupné z:

<<https://www.selmy.cz/vlcihlidky/data/files/zaklady-terenniho-monitoringu-2018.pdf>>

Obrázek č. 8.,

RŮŽIČKOVÁ J., VESELÝ M., 2016. Využití radiotelemetrie v entomologii (online) [cit. 2021-03-09]. Dostupné z: <<https://ziva.avcr.cz/files/ziva/pdf/vyuziti-radiotelemetrie-v-entomologii.pdf>>

Obrázek č. 9.,

PNAS, 1997. The global positioning system: The Role of Atomic Clocks. In: Beyond Discovery™: The Path from Research to Human Benefit (online) [cit. 2021-03-09]. Dostupné z: <<http://www.nasonline.org/publications/beyond-discovery/the-global-positioning-system.pdf>>

Obrázek č. 10.,

PATTERSON T., THOMAS L., WILCOX C., OVASKAINEN O., MATTHIOPOULOS J., 2008. State–space models of individual animal movement. *Trends in Ecology & Evolution* **23**: 87-94.

Obrázek č. 11.,

TOLEDO T., KATZ R., 2009. State Dependence in Lane-Changing Models. *Transportation Research Record: Journal of the Transportation Research Board* **2124**: 81-88.

10 Přílohy

Příloha č. 1 – Použití HMM na samici geparda štíhlého

Data jsou stažena z <https://www.movebank.org/>. Data pochází ze GPS sledování samice reintrodukovaného geparda žijícího v Jižní Africe v národním parku Pilanesberg. Data se začali sbírat v roce 2014, kdy samice neměla žádné mláďata a ani nebyla březí (v datech jako cheetah_1). V listopadu toho stejného roku zabřezla (Cheetah_2) a v roce 2015 porodila 4 mláďata samce a jedno za chvíli umřelo (Cheetah_3).

Instalce balíčku, načtení dat a jejich úprava

```
library(moveHMM)
```

Vstupní data musí mít správný formát, aby bylo možné data zpracovat a poté je analyzovat. Data-frame musí obsahovat 2 sloupce:

- sloupec s názvem “x”: Easting nebo zeměpisná délka (longitude)
- sloupec s názvem “y”: Northing nebo zeměpisná šířka (latitude)

Důležitým sloupec je “ID”. Pokud není ve vstupních datech žádný sloupec s názvem “ID”, tak balíček bude předpokládat, že daná data jsou pouze pro jednoho jedince.

Načtení dat:

```
gepard <- read.table("Gepard_1.csv", header = T, sep = ";", dec=",")
gepard$time = as.POSIXct(gepard$time)

gepard_D <- read.table("Gepard_2.csv", header = T, sep = ";",
dec=",")
gepard_D$time = as.POSIXct(gepard_D$time)

gepard_PD <- read.table("Gepard_3.csv", header = T, sep = ";",
dec=",")
gepard_PD$time = as.POSIXct(gepard_PD$time)
```

Převod do souřadnicového systému UTM:

```
library(sf)
floor((180+gepard$long[1])/6) + 1
gepard_sf <- st_as_sf(gepard, coords = c("long", "lat"), crs = 4326)
```



```

gepard_utm <- st_transform(gepard_sf, crs = 32635)
gepard <- cbind(gepard_utm, st_coordinates(gepard_utm))

gepard_D_sf <- st_as_sf(gepard_D, coords = c("long", "lat"), crs =
4326)
gepard_D_utm <- st_transform(gepard_D_sf, crs = 32635)
gepard_D <- cbind(gepard_D_utm, st_coordinates(gepard_D_utm))

gepard_PD_sf <- st_as_sf(gepard_PD, coords = c("long", "lat"), crs =
4326)
gepard_PD_utm <- st_transform(gepard_PD_sf, crs = 32635)
gepard_PD <- cbind(gepard_PD_utm, st_coordinates(gepard_PD_utm))

```

Náhled na vstupní data:

```

## Simple feature collection with 6 features and 6 fields
## geometry type:  POINT
## dimension:      XY
## bbox:           xmin: 507733.9 ymin: -2793073 xmax: 509791.7
ymax: -2792354
## projected CRS:  WGS 84 / UTM zone 35N
##           ID TEMP Height           time           X           Y
## 1 Cheetah_1 13.5   1161 2014-04-12 04:00:33 509791.7 -2792354
## 2 Cheetah_1 25.5   1164 2014-04-12 22:00:33 507754.0 -2793037
## 3 Cheetah_1 22.5   1167 2014-04-13 04:00:33 507754.0 -2793037
## 4 Cheetah_1 30.5   1167 2014-04-13 10:00:33 507937.4 -2792934
## 5 Cheetah_1 28.0   1161 2014-04-13 16:00:33 507752.0 -2793039
## 6 Cheetah_1 22.0   1164 2014-04-13 22:00:33 507733.9 -2793073
##
##           geometry
## 1 POINT (509791.7 -2792354)
## 2 POINT (507754 -2793037)
## 3 POINT (507754 -2793037)
## 4 POINT (507937.4 -2792934)
## 5 POINT (507752 -2793039)
## 6 POINT (507733.9 -2793073)

```

Data obsahují jak sloupce se souřadnicemi, tak i sloupce s možnými kovariátami:

- TEMP = venkovní teplota (°C)
- Height = nadmořská výška (m n. m.)

Navíc je tady i sloupec ID (označení “jedince”) a čas sběru dat (time).

V datech lze vidět, že některá měření chybí a je potřeba je doplnit, tak aby bylo každé měření po 6 hodinách.

```
gepard_1a=data.frame(time=seq.POSIXt(from = min(gepard$time), by= "6
hour",length.out = 788))

gepard_1b=data.frame(time=seq.POSIXt(from =
gepard$time[788],to=max(gepard$time), by= "6 hour"))

geparad_data1=rbind(gepard_1a,gepard_1b)
gepard = merge(geparad_data1,gepard,by="time",all.x = TRUE)
#gepard_D (březí)
gepard_2a=data.frame(time=seq.POSIXt(from = min(gepard_D$time), to
=max(gepard_D$time), by= "6 hour"))

gepard_D = merge(gepard_2a,gepard_D,by="time",all.x = TRUE)

#gepard_PD (s mláďaty)
gepard_3a=data.frame(time=seq.POSIXt(from = min(gepard_PD$time), to
=max(gepard_PD$time), by= "6 hour"))

gepard_PD = merge(gepard_3a,gepard_PD,by="time",all.x = TRUE
```

Hodnoty “x” a “y” jsou v datech vyjádřeny v metrech, proto je potřeba data přetransformovat, aby byla délka v kilometrech.

```
gepard$X <- gepard$X/1000
gepard$Y <- gepard$Y/1000

gepard_D$X <- gepard_D$X/1000
gepard_D$Y <- gepard_D$Y/1000

gepard_PD$X <- gepard_PD$X/1000
gepard_PD$Y <- gepard_PD$Y/1000
```

Model pro geparda po vypuštění

Před použití následující funkce „PrebData“ je potřeba pro správné fungování balíčku spustit následující funkci:

```
get_closest_id <- function(i, ids=gepard$ID){
  id <- ids[i]
  ii <- i
  while (is.na(id) & ii > 1){
    ii <- ii - 1
    id <- ids[ii]
  }
  ii <- i
  while (is.na(id) & ii < length(ids)){
    ii <- ii + 1
    id <- ids[ii]
  }
  return(id)
}

for (i in which(is.na(gepard$ID))) {
  gepard$ID[i] <- get_closest_id(i)
}
```

Funkce “PrebData” umožňuje vymodelovat délky kroků a jejich úhel otočení a je vstupním objektem pro tvorbu modelu. Důležité je zvolit správné argumenty funkce:

- type: určuje, zda-li jsou souřadnice v easting/northing (type=“UTM”), a nebo v zeměpisné šířce/délce (type=“LL”)
- coordNames: používá se v případě, pokud sloupce se souřadnicemi nejsou pojmenované jako “x” a “y”.

Funkce „PrebData“:

```
data <- prepData(gepard, type="UTM", coordNames=c("X", "Y"))
## Warning in prepData(gepard, type = "UTM", coordNames = c("X",
## "Y")): There are
## 36 missing covariate values. Each will be replaced by the closest
## available
## value.
```

Varování upozorňuje na data bez kovariáty a říká, že nahradí nejbližší hodnotou.

```
##           ID      step  angle      x      y
time TEMP
## 1 Cheetah_1      NA      NA 509.7917 -2792.354 2014-04-12
04:00:33 13.5
## 2 Cheetah_1      NA      NA      NA      NA 2014-04-12
10:00:33 13.5
## 3 Cheetah_1      NA      NA      NA      NA 2014-04-12
16:00:33 13.5
## 4 Cheetah_1 0.0000000      NA 507.7540 -2793.037 2014-04-12
22:00:33 25.5
## 5 Cheetah_1 0.2102280      NA 507.7540 -2793.037 2014-04-13
04:00:33 22.5
## 6 Cheetah_1 0.2130708 -3.137161 507.9374 -2792.934 2014-04-13
10:00:33 30.5

##      Height      geometry
## 1    1161 POINT (509791.7 -2792354)
## 2    1161      POINT EMPTY
## 3    1161      POINT EMPTY
## 4    1164 POINT (507754 -2793037)
## 5    1167 POINT (507754 -2793037)
## 6    1167 POINT (507937.4 -2792934)
```

Po použití funkce `summary` lze vidět v hlavičce, kolik je sledování pro daného jedince a ve spodní části je zobrazeno minimum, medián, průměr kovariát

```
library(dplyr)
data %>% select(-c(geometry)) %>%
  summary()

## Movement data for 1 animal:
## Cheetah_1 -- 802 observations
##
## Covariate(s):
## time
##           Min.           25%
## "2014-04-12 04:00:33 CEST" "2014-06-01 05:30:33 CEST"
##           Median           Mean
## "2014-07-21 07:00:33 CEST" "2014-07-21 07:51:52 CEST"
##           75%           Max.
## "2014-09-09 08:30:33 CEST" "2014-10-31 10:00:33 CET"
```


```
##
## TEMP
##   Min.      25%   Median     Mean      75%     Max.
## 0.00000 17.50000 23.50000 23.23192 29.37500 39.00000
##
## Height
##   Min.      25%   Median     Mean      75%     Max.
## 1088.000 1132.000 1161.000 1177.014 1201.000 1455.000
```

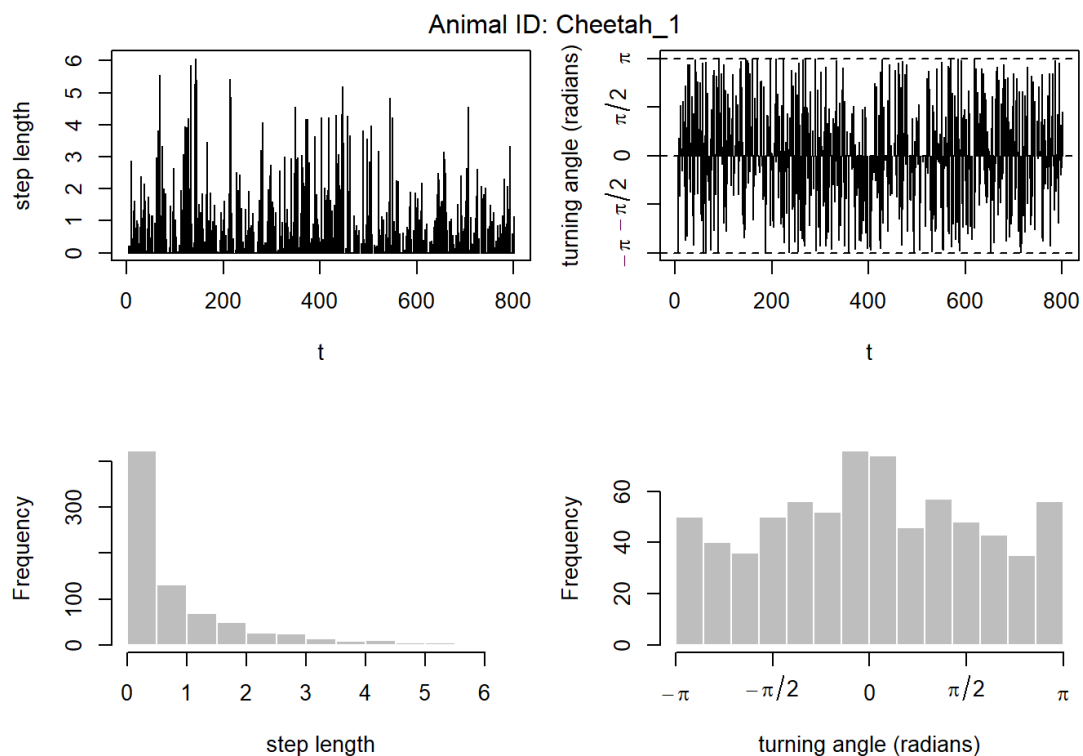
Vizualizace “prebData”

“plot(“prebData)” zobrazí:

- mapu trajektorie jedinců
- časové řady kroků a úhlů
- histogramy kroků a úhlů

```
plot(data, compact = T)
```





Model fitHMM

Fit HMM je funkce, která vytvoří model pro skryté Markovovy modely, používající numericko-logaritmickou funkci.

Základní argumenty pro model:

- data: moveData
- nbStates: počet stavů HMM
- stepPar0: počáteční vektor délky
- anglePar0: počáteční vektor úhlů
- formula: regresní formula pro kovariáty (výchozí: 1)
- stepDist: název rozdělení pro délku kroků (výchozí: gama)
- angleDist: název rozdělení pro úhel (výchozí: vm)
- angleMean: vektor úhlů (výchozí: NULL)
- stationary: argument FALSE použije se pokud existují kovariáty (výchozí: FALSE)

Parametry pro délku kroků:

- m0 = průměrná délka kroku
- sigma0 = odchylka kroku

- zeromass0
- StepPa0 = c(mu,sigma0,zeromass0)

```
mu0 <- c(0.5,2)
sigma0 <- c(0.5,1)

#kontrola jestli je potřeba zero-mass
whichzero <- which(data$step == 0)
length(whichzero)/nrow(data)
## [1] 0.02244389

#vyšlo číslo 0.02244389, které říká jaký je poměr 0 hodnot v
datech
zeromass0 <- c(0.1,0.05)
stepPar0 <- c(mu0,sigma0,zeromass0)
```

Parametry pro velikost úhlů:

- angleMean0 = průměrná velikost úhlů
- kappa0 = odchylka pro velikost úhlu
- anglePar0 = c(angleMean0, kappa0)

```
• angleMean0 <- c(pi,0)
• kappa0 <- c(0.7,1.5)
• anglePar0 <- c(angleMean0, kappa0)
```

Zvolené rozdělení:

- stepDist = rozdělení pro délku kroku (“gamma” = gamma rozdělení)
- angleDist = rozdělení pro úhly otáčení (“vm” = von Misesovo rozdělení)

```
stepDist <- "gamma"
angleDist <- "vm"
```

Dvoustavový model

```
m1 <- fitHMM(data=data, nbStates = 2, stepPar0 = stepPar0, anglePar0
= anglePar0,
             formula = ~1, stepDist=stepDist,
             angleDist =angleDist)#žádná kovariata
m2 <- fitHMM(data=data, nbStates = 2, stepPar0 = stepPar0, anglePar0
= anglePar0,
             formula = ~TEMP, stepDist=stepDist,
```

```

        angleDist =angleDist)#kovariata -> teplota
m3 <- fitHMM(data=data, nbStates = 2, stepPar0 = stepPar0, anglePar0
= anglePar0,
        formula = ~Height, stepDist=stepDist,
        angleDist =angleDist)#"kovariata -> nadmořská výška
m4 <- fitHMM(data=data, nbStates = 2, stepPar0 = stepPar0, anglePar0
= anglePar0,
        formula = ~TEMP+Height, stepDist=stepDist,
        angleDist =angleDist)# kovarita TEMP + Heigh

```

Tří stavový model:

```

mu0 <- c(0.5,2,4)
sigma0 <- c(0.5,1,1.5)

whichzero <- which(data$step == 0)
length(whichzero)/nrow(data)
## [1] 0.02244389
zeromass0 <- c(0.1,0.05,0.01)
stepPar0 <- c(mu0,sigma0,zeromass0)

angleMean0 <- c(pi,pi/2,0)
kappa0 <- c(0.7,1.5,2)
anglePar0 <- c(angleMean0, kappa0)

m1_3 <- fitHMM(data=data, nbStates = 3, stepPar0 = stepPar0,
anglePar0 = anglePar0,
        formula = ~1, stepDist=stepDist,
        angleDist =angleDist)# žádná kovariata
m3_3 <- fitHMM(data=data, nbStates = 3, stepPar0 = stepPar0,
anglePar0 = anglePar0,
        formula = ~Height, stepDist=stepDist,
        angleDist =angleDist)# kovariata -> nadmořská výška
m4_3 <- fitHMM(data=data, nbStates = 3, stepPar0 = stepPar0,
anglePar0 = anglePar0,
        formula = ~TEMP+Height, stepDist=stepDist,
        angleDist =angleDist)# kovarita TEMP + Height

```


Model s jedním stavem:

```
mu0 <- c(2)
sigma0 <- c(1)

whichzero <- which(data$step == 0)
length(whichzero)/nrow(data)
## [1] 0.02244389

zeromass0 <- c(0.05)
stepPar0 <- c(mu0, sigma0, zeromass0)

angleMean0 <- c(pi/2)
kappa0 <- c(1.5)
anglePar0 <- c(angleMean0, kappa0)

m0 <- fitHMM(data=data, nbStates = 1, stepPar0 = stepPar0, anglePar0 =
  anglePar0,
             formula = ~1, stepDist=stepDist,
             angleDist =angleDist)
```

Test AIC

```
print(AIC(m1,m2,m3,m4,m1_3,m3_3,m4_3,m0))
##   Model      AIC
## 1    m2 3348.546
## 2   m1_3 3354.094
## 3    m4 3357.687
## 4    m1 3360.814
## 5    m3 3366.062
## 6   m3_3 3368.870
## 7   m4_3 3416.735
## 8    m0 3453.976
```

Jako nejlepší model byl vybrán nakonec m2, protože má ze všech modelů nejnižší hodnotu AIC

```
m2
## Value of the maximum log-likelihood: -1659.273
##
```

```

## Step length parameters:
## -----
##           state 1    state 2
## mean      0.31415220 1.76045768
## sd        0.50432602 1.29899567
## zero-mass 0.01419297 0.04005698
##
## Turning angle parameters:
## -----
##           state 1    state 2
## mean      -2.92956218 0.004325341
## concentration 0.09265775 0.776972965
##
## Regression coeffs for the transition probabilities:
## -----
##           1 -> 2    2 -> 1
## intercept  0.7821853 -1.13322631
## TEMP      -0.1107295  0.01595603
##
## Initial distribution:
## -----
## [1] 1.327189e-06 9.999987e-01

```

Konfidenční intervaly

```

CI (m2)
## $stepPar
## $stepPar$lower
##           state 1    state 2
## mean      0.223120888 1.51845178
## sd        0.358965707 1.12890130
## zero-mass 0.003069412 0.01454566
##
## $stepPar$upper
##           state 1    state 2
## mean      0.44232346 2.041034
## sd        0.70854885 1.494719
## zero-mass 0.06307772 0.105521

```

```

##
##
## $anglePar
## $anglePar$lower
##           state 1    state 2
## mean          -5.35663666 -0.2702292
## concentration  0.02383586  0.5101674
##
## $anglePar$upper
##           state 1    state 2
## mean          -0.8077633  0.2978452
## concentration  0.2612038  1.0607607
##
##
## $beta
## $beta$lower
##           1 -> 2      2 -> 1
## intercept -0.4872198 -2.59643054
## TEMP      -0.1760870 -0.04219851
##
## $beta$upper
##           1 -> 2      2 -> 1
## intercept  2.05159036  0.32997791
## TEMP      -0.04537194  0.07411056

```


V tabulce CI ze vidět:

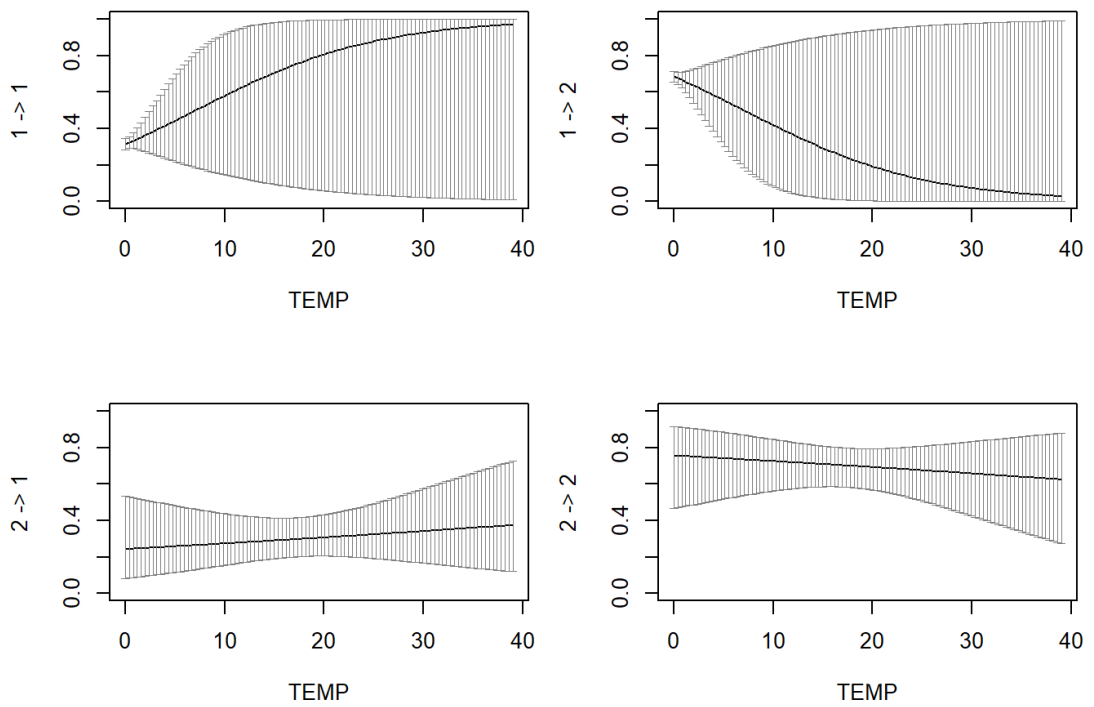

- interval po střední délku kroku:
 - pro stav 1 = (0.223207117-0.359104588) m
 - pro stav 2 = (1.51905094-2.041851) m
- Interval pro variabilní délku kroku:
 - pro stav 1 = 0.359104588 m
 - pro stav 2 = 1.12934926 m
- střední velikost úhlu -> pro stav 1 = (-5.35580872 do -0.8082987)
 - > pro stav 2 = (-0.2698473 -0.2968336)
- koncentrace úhlů -> pro stav 1 = 0.1948008
 - > pro stav 2 = 0.61492293
- pravděpodobnost přechodu z jednoho stavu do druhého a na zpět

Vizualizace modelu


```
plot(m2, plotCI = T)
```

```
## Decoding states sequence... DONE
```





Animal ID: Cheetah_1



Pravděpodobnosti stavu

```
sp <- stateProbs(m2)
```

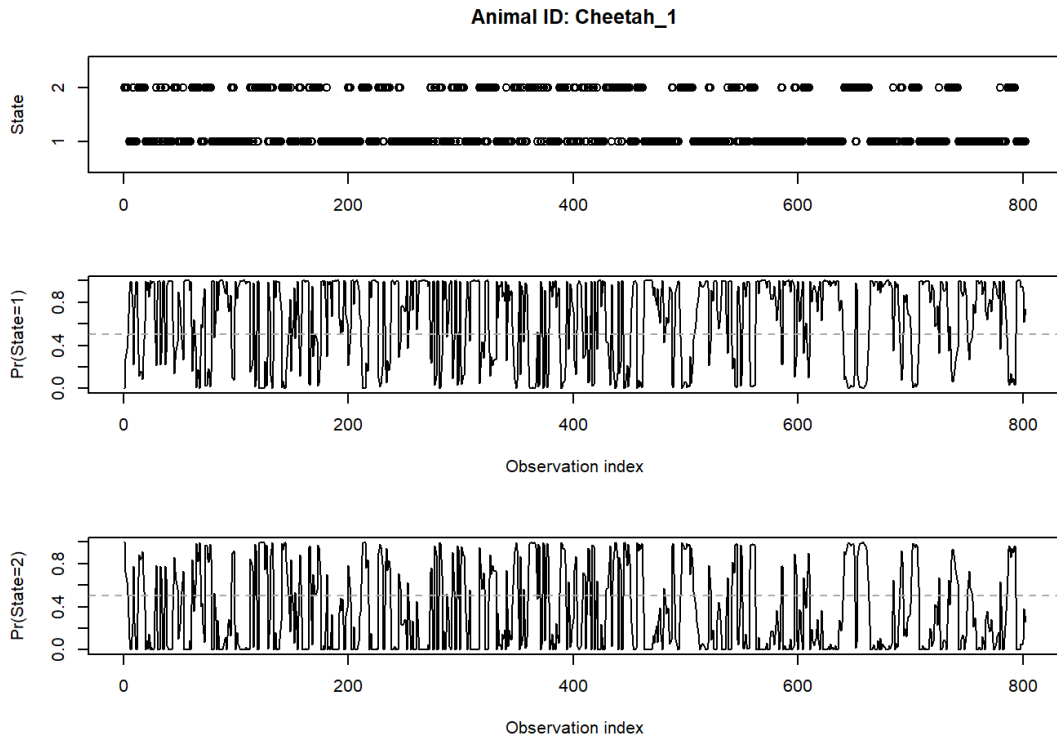
```
head(sp)
```

```
##           [,1]      [,2]  
## [1,] 1.301543e-06 0.999998698  
## [2,] 2.751819e-01 0.724818136  
## [3,] 3.643776e-01 0.635622361  
## [4,] 4.894820e-01 0.510517997  
## [5,] 8.992283e-01 0.100771676  
## [6,] 9.905691e-01 0.009430944
```

```
plotStates(m2)
```


```
## Decoding states sequence... DONE
```

```
## Computing states probabilities... DONE
```



Pravděpodobnost stacionárního stavu

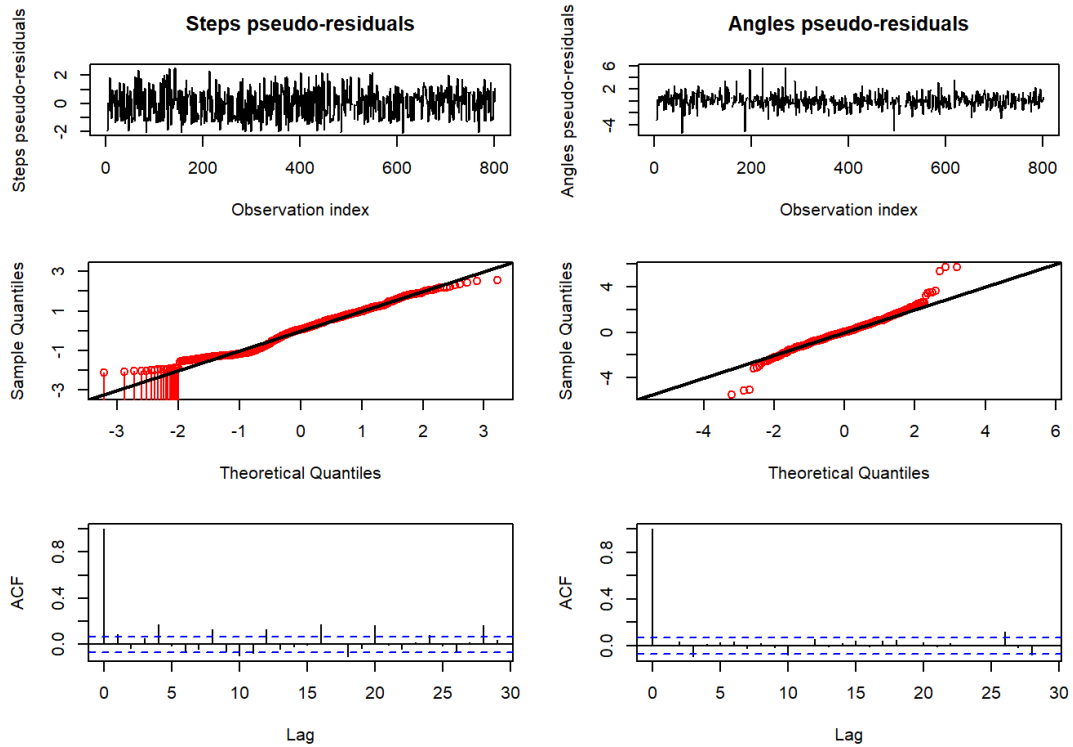
```
plotStationary(m2, plotCI=TRUE)
```



Stacionární stav bude nejpravděpodobnější mezi 15-20°C.

Kontrola modelu

```
res <- pseudoRes(m2)
plotPR(m2)
## Computing pseudo-residuals... DONE
```



Test normality:

```
library(tseries)
## Warning: package 'tseries' was built under R version 4.0.3
#test normality kroků
## Jarqueův a Berryho test normality
###H0: model má normální rozdělení
### p < 0.05 -> H0 nezamítám, model má normální rozdělení
print(jarque.bera.test(res$step[which(!is.na(res$step))]))
##
## Jarque Bera Test
##
## data: res$step[which(!is.na(res$step))]
## X-squared = 18.171, df = 2, p-value = 0.0001133
## Shapiro-Wilkův test normality
shapiro.test(res$stepRes)
```



```

##
## Shapiro-Wilk normality test
##
## data:  res$stepRes
## W = 0.97946, p-value = 6.616e-09
### p<0.05 -> model má normální rozdělení

#test normality pro úhly
print(jarque.bera.test(res$angle[which(!is.na(res$angle))]))
##
## Jarque Bera Test
##
## data:  res$angle[which(!is.na(res$angle))]
## X-squared = 357.67, df = 2, p-value < 2.2e-16
### p < 0.05 -> model má normální rozdělení
shapiro.test(res$angleRes)
##
## Shapiro-Wilk normality test
##
## data:  res$angleRes
## W = 0.9639, p-value = 2.777e-12
### p < 0.05 -> model má normální rozdělení

```


Test korelace:

```


par(mfrow=c(1,2))
acf(na.omit((data$step)))
acf(na.omit((data$angle)))

```

Series na.omit((data\$step))



Series na.omit((data\$angle))



Příloha č. 2 – Trajr: charakterizace trajektorií zvířat

Co je Trajr a k čemu slouží?

Trajr je balíček pro R studio, který se zaměřuje na jednoduchou analýzu a vizualizaci dvoudimenzionálních dat.

Instalace balíčku

```
library(trajr)
```

Balíček nabízí možnost vygenerování vlastní náhodné trajektorie pomocí příkazu “TrajGenerate” Základní argumenty “TrajGenerate”:

- n: počet kroků v trajektorii
- random: pro náhodné hodnoty zadáme “TRUE”
- stepLength: délka kroků v trajektorii
- angularErrorSd: směrodatná odchylka v radiánech

```
data_g <- TrajGenerate(200, random = TRUE, angularErrorSd = .25)
```

Data-frame bude tedy vypadat:

```
head(data_g)
```

	x <dbl>	y <dbl>	time <dbl>	displacementTime <dbl>	polar <cpl>	displacement <cpl>
1	0.000000	0.000000	0.00	0.00	0.000000+0.000000i	0.000000+0.000000i
2	1.872980	-0.5431895	0.02	0.02	1.872980-0.543190i	1.872980-0.543190i
3	4.092068	-0.6879887	0.04	0.04	4.092068-0.687989i	2.219088-0.144799i
4	5.790030	-0.2622837	0.06	0.06	5.790030-0.262284i	1.697962+0.425705i
5	7.614543	0.6980185	0.08	0.08	7.614543+0.698019i	1.824513+0.960302i
6	9.553829	1.2367750	0.10	0.10	9.553829+1.236775i	1.939286+0.538756i

Vytvoření trajektorie

Načtení vlastních dat:

```
library(trajr)
```

```
gepard <- read.table("Gepard_1.csv", header = T, sep = ";", dec=",")  
gepard$time = as.POSIXct(gepard$time)  
gepard$Height = as.numeric(gepard$Height)
```

```

library(sf)
## Warning: package 'sf' was built under R version 4.0.4
## Linking to GEOS 3.8.0, GDAL 3.0.4, PROJ 6.3.1
floor((180+gepard$long[1])/6) + 1
## [1] 35
gepard_sf <- st_as_sf(gepard, coords = c("long", "lat"), crs = 4326)
gepard_utm <- st_transform(gepard_sf, crs = 32635)
gepard <- cbind(gepard_utm, st_coordinates(gepard_utm))

gepard$X <- gepard$X/1000
gepard$Y <- gepard$Y/1000

```

Níže v tabulce lze vidět výpis s načtených dat. Sloupec:

- ID: ID jedince
- X: souřadnice x
- Y: souřadnice y
- time: čas v hodinách, ve kterém se jedinec nacházel na určitém místě

```
head(gepard)
```

	ID <chr>	TEMP <dbl>	Height <dbl>		time <dtm>	X <dbl>	Y <dbl>	geometry <sf_POINT>
1	Cheetah_1	13.5	1161	2014-04-12	04:00:33	509.7917	-2792.354	<sf_POINT>
2	Cheetah_1	25.5	1164	2014-04-12	22:00:33	507.7540	-2793.037	<sf_POINT>
3	Cheetah_1	22.5	1167	2014-04-13	04:00:33	507.7540	-2793.037	<sf_POINT>
4	Cheetah_1	30.5	1167	2014-04-13	10:00:33	507.9374	-2792.934	<sf_POINT>
5	Cheetah_1	28.0	1161	2014-04-13	16:00:33	507.7520	-2793.039	<sf_POINT>
6	Cheetah_1	22.0	1164	2014-04-13	22:00:33	507.7339	-2793.073	<sf_POINT>

Důležitým krokem pro tvorbu trajektorie je si vždy vytvořit “trajektorii jako objekt”, pomocí “TrajFromCoords”, kde je potřeba použít následující argumenty:

- xCol: název sloupce v našem souboru obsahující souřadnice x
- yCol: název sloupce v našem souboru obsahující souřadnice y
- timeCol: název sloupce, ve kterém máme uvedený čas

```


trj <- TrajFromCoords(gepard, xCol = "X", yCol = "Y", timeCol = "time")
trj_2 <- TrajFromCoords(data_g)

```


Vizualizace trajektorie

Pro vizualizaci trajektorie se ze začátku použije jednoduchá funkce a to “plot”

```
plot(trj, main= "Vizualizace trajektorie geparda", col="black")
```




```
plot(trj_2, main = "Generované data")
```



Pro vyhlazení, snížení vysokofrekvenčního šumu a zároveň zachování původní trajektorie použitím vyhlazovacího filtru Savitzky-Golay se používá funkce "trajSmoothSG".


```
# načtená data
p=9
n=p + 3 - p%%2
smoothed <- TrajSmoothSG(trj, p, n)

plot(trj, main= "Vizualizace trajektorie geparda", col="black")
```



```
plot(smoothed, lwd=1, lty=1, main = "Gepard - smoothed")
lines(smoothed, col="blue", lwd=0.5)

legend("topright", c("Původní", "Vyhlazená"), lwd = c(1, 2), lty =
c(1, 1), col = c("black", "blue"), inset = 0.01)
```




```
# vygenerovaná data
plot(trj_2, lwd=1, lty=1, main = "Generované data")

smoothed <- TrajSmoothSG(trj_2, p=3, n =31)

lines(smoothed, col="red", lwd=2)

legend("topright", c("Původní", "Vyhlazená"), lwd = c(1, 2), lty =
c(1, 1), col = c("black", "red"), inset = 0.01)
```



Převzorkování trajektorie

Funkce “TrajRediscretize” se upraví délku kroku na pevnou vzdálenost.

Argumenty:

- trj: vstupní trajektorie
- R: délka kroku (v našem případě m)

Pro výběr délky kroku neexistují žádná jasná pravidla. Pokud se použije malá délka kroku, tak operace vede k převzorkování, která způsobí vysokou autokorelaci mezi kroky a vysokou variabilitu. V případě použití větší délky dojde k pod vzorkování a díky tomu ke ztrátě informací.

Od této části se začíná pro zjednodušení pracovat pouze jen s generovaný daty.

```
trj3 <- TrajGenerate(10, stepLength = 2)


plot(trj3, lwd = 1.5, main = "Generované data")
points(trj3, draw.start.pt = F, pch=16, col="black", cex=1)

resampled <- TrajRediscretize(trj3, 2)

lines(resampled, col="red", lwd=1)
points(resampled, col="red", type = 'p', pch = 16)

legend("topright", c("Původní", "Upravená"), lwd = c(1, 2), lty = c(1,
1), col = c("black", "red"), inset = c(0.01, 0.02))
```


Generované data




Funkce “TrajResampleTime” upraví trajektorii a vytvoří novou s pevnými časovými intervaly kroku.

Argumenty:

- trj: vstupní trajektorie
- steptime: časový interval

```
trj3 <- TrajGenerate(10, stepLength = 1, fps = .5, timeUnits = "hours",  
linearErrorSd = .8)  
  
plot(trj3, lwd = 1.5, main="Generované data")  
  
points(trj3, draw.start.pt = FALSE, pch = 16, col = "black", cex =  
1.2)  
  
resampled <- TrajResampleTime(trj3, 1)  
  
lines(resampled, col = "red", lwd = 2)  
  
points(resampled, type = 'p', col = "red", pch = 16)  
  
legend("topright", c("Originálná", "Upravená"), col = c("black",  
"red"),  
lwd = 2, inset = c(0.01, 0.02))
```

Generované data




Další operace s trajektroí

Otočení trajektorie:

K otočení trajektorie se používá funkce "TrajRotate".

```
trj_rotate <- TrajRotate(trj_2)  
  
plot(trj_rotate, main = "Otočená trajektorie")
```


Otočená trajektorie



Obrácení trajektorie

Funkce “TrajReverse” trajektorii jednoduše obrátí – změni počátek a konec trajektorie.

```
trj_Reverse <- TrajReverse(trj_2)
plot(trj_Reverse, main="Obrácený trajektore")
```



Analýza trajektorie

K analýze trajektorie lze postoupit až ve chvíli kdy už je trajektorie správně upravená.

Analýza rychlosti/trajektroie :

V balíčku existuje několik funkce zabývající se analýzou rychlosti.

- TrajAcceleration: odhad zrychlení jako vektoru v každém bodě trajektorie pomocí konečných rozdílů druhého řádu
- TrajDerivatives: odhad rychlosti jako vektoru v každém bodě trajektorie pomocí rozdílu prvního řádu


```
derivs <- TrajDerivatives(smoothed)

plot(derivs$acceleration ~ derivs$accelerationTimes, type = 'l', col = 'red',
      yaxt = 'n',
      xlab = 'Time (s)',
      ylab = expression(paste('Change in speed (', m/s^2, ')')))
```

```

axis(side = 2, col = "red")
lines(derivs$speed ~ derivs$speedTimes, col = 'blue')
axis(side = 4, col = "blue")
mtext('Speed (m/s)', side = 4)
abline(h = 0, col = 'lightGrey')

```



Když je získaná rychlost trajektorie, tak lze jednoduše vypočítat hodnoty jako jsou:

- střední hodnota (`mean(derivsspeed)`)
- maximální hodnota rychlosti(`max(derivsspeed)`)
- maximální hodnota rychlosti(`max(derivsspeed)`)
- minimální hodnota rychlosti (`min(derivs$speed)`)

```

summary(derivs$speed)
##      Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
##  75.44   91.29   95.40   94.56   98.70  107.22

```


Funkce “TrajSpeedIntervals” umožňuje určit časové intervaly v rámci trajektorie. Díky ní lze najít intervaly, kdy je rychlost nižší/vyšší než rychlost určená, nebo jejich kombinace.

Argumetny:

- `trj`: trajektorie

- fasterThan: rychlejší než námi zadaná hodnota
- slowerThan: pomalejší než námi zadaná hodnota

```
intervals <- TrajSpeedIntervals(smoothed, slowerThan = 20)
print(intervals)
## [1] startFrame startTime stopFrame stopTime duration
## <0 rows> (or 0-length row.names)
plot(intervals)
```




Náhodné generování trajektorie

Generování náhodné procházky:

```
random <- TrajGenerate(n = 200)  
  
plot(random, main = "Nádoná trajektorie procházky")
```


Nádoná trajektorie procházky



Generování "Přimočaré" trajektorie:

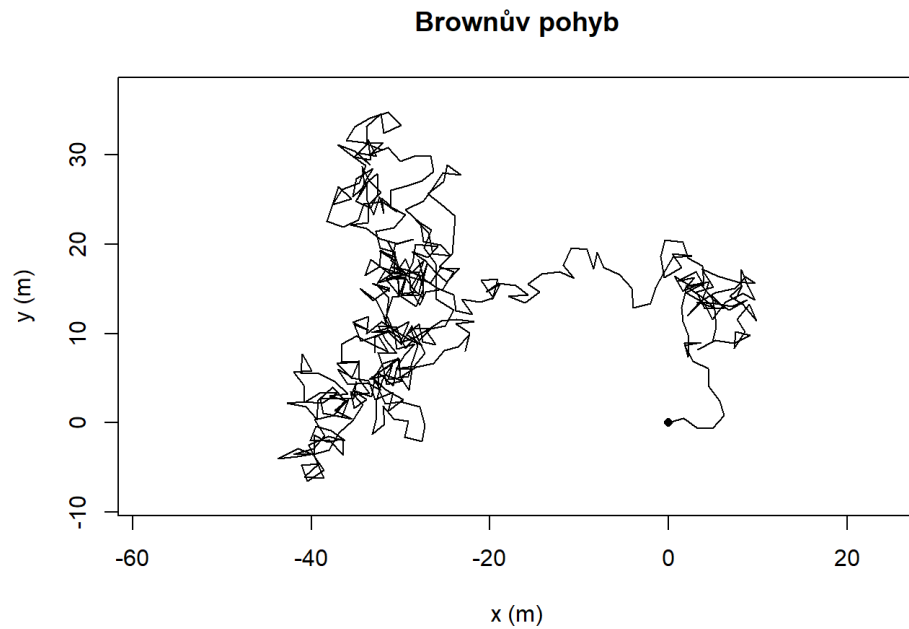
```
direct <- TrajGenerate(n = 20, random = FALSE)  
  
plot(direct, main="Přimočará procházka")
```

Přimočará procházka



Brownův pohyb:

```
brown <- TrajGenerate(n = 500, angularErrorDist = function(n)
stats::runif(n, -pi, pi))
plot(brown, main = "Brownův pohyb")
```



Lévy flight s Cauchyho rozdělením

```
levy <- TrajGenerate(linearErrorDist = stats::rcauchy)
plot(levy, main="Lévy Flight")
```

