

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



**Cirkadiánní aktivita prekociálních  
mlád'at bahňáků**  
Diplomová práce

Vedoucí práce: Mgr. Martin Sládeček, Ph.D.

Diplomant: Bc. Veronika Firlová

2020

# ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE

Fakulta životního prostředí

## ZADÁNÍ DIPLOMOVÉ PRÁCE

Bc. Veronika Firlová

Inženýrská ekologie  
Ochrana přírody

Název práce

Cirkadiánní aktivita prekociálních mláďat bahňáků

Název anglicky

Circadian activity of precocial shorebird chicks

---

Cíle práce

- 1.) Shromáždit dostupné literární zdroje týkající se aktivity prekociálních mláďat a využití akcelerometrů.
- 2.) S využitím multisenzorických dataloggerů vyvinutých týmem behaviorální ekologie sesbírat dostatečné množství dat u kuřat dvou modelových druhů na lokalitě Al Marmoom v Dubaji (UAE).
- 3.) Popsat rytmicitu a diverzitu základních typů chování v průběhu dne a vzhledem ke stáří kuřete.

Metodika

- 1.) Terénní sběr dat s využitím miniaturních multisenzorických dataloggerů, které budou připevňovány na záda kuřat po dobu 24 – 48 hodin.
- 2.) Dataloggery jsou schopny kontinuálně zaznamenávat údaje o akceleraci, vlhkosti, teplotě, světelnosti a magnetometrii.
- 3.) Bude pořízen video záznam s chováním kuřat, který bude vyhodnocen v programu BORIS.
- 4.) Data z akcelerometrů budou zpracovávána v programu R, s využitím skrytých Markovových modelů. Videonahrávky budou použity pro řízený trénink příslušných algoritmů.

**Doporučený rozsah práce**

25-30 s.

**Klíčová slova**

Vanellus indicus, Himantopus himantopus, ACM, HMM,

---

**Doporučené zdroje informací**

Leos-Barajas, Vianey, et al. "Analysis of animal accelerometer data using hidden Markov models." *Methods in Ecology and Evolution* 8.2 (2017): 161-173.

Williams, Hannah J., et al. "Identification of animal movement patterns using tri-axial magnetometry." *Movement ecology* 5.1 (2017): 6.

---

**Předběžný termín obhajoby**

2019/20 LS – FŽP

**Vedoucí práce**

Mgr. Martin Sládeček, Ph.D.

**Garantující pracoviště**

Katedra ekologie

V Praze dne 11. 02. 2020

## **Prohlášení**

Prohlašuji, že jsem diplomovou práci na téma: Cirkadiánní aktivita prekociálních mláďat bahňáků vypracovala samostatně a citovala jsem všechny informační zdroje, které jsem v práci použila a které jsem rovněž uvedla na konci práce v seznamu použitých informačních zdrojů. Jsem si vědoma, že na moji diplomovou 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 tohoto díla. Jsem si vědoma, že odevzdáním diplomové souhlasím s jejím zveřejněním podle zákona č. 111/1998 Sb., o vysokých školách a o změně a doplnění dalších zákonů, ve znění pozdějších předpisů, a to i bez ohledu na výsledek její obhajoby. Svým podpisem rovněž prohlašuji, že elektronická verze práce je totožná s verzí tištěnou a že s údaji uvedenými v práci bylo nakládáno v souvislosti s GDPR

V Praze 30.6.2020

.....

## **Poděkování**

Na tomto místě bych chtěla poděkovat Mgr. Martinovi Sládečkovi, Ph.D. za cenné rady a připomínky ke zpracování této práce. Velké díky patří mé rodině a přáteli za podporu během studia.

## Abstrakt

Chování je základní součástí biologie zvířat a jeho studium je důležité k celkovému poznání druhů. Nicméně studium chování a denních aktivit jedinců v přirozeném prostředí je velice náročné. V posledních letech došlo k rozmachu monitorování zvířat a identifikaci jejich chování pomocí měření akcelerace.

Tato práce se zabývá měřením aktivity u dvou modelových druhů – čejky černoprsé (*Vanellus indicus*) a pisily čáponohé (*Himantopus himantopus*). Terénní práce probíhaly v chráněné rezervaci Al Marmoom v Dubaji, UAE. Kuřata modelových druhů byla chycena a vybavena multisenzorickým dataloggerem vyvinutým týmem behaviorální ekologie. Na základě dat z těchto dataloggerů a s využitím strojového učení a skrytého Markovova modelu byla aktivita klasifikována do pěti typů chování – ležení, stání, chůze, běh a plavání. Rozložení těchto aktivit, stejně jako jejich celkové procentuální zastoupení se mezi studovanými druhy lišilo, přičemž kuřata pisily čáponohé byla aktivnější. Při porovnání procentuálního rozložení aktivit u jednotlivých kuřat nebyly pozorovány žádné významné rozdíly mezi mladšími a staršími jedinci.

**Klíčová slova:** *Vanellus indicus*, *Himantopus himantopus*, multisenzorický datalogger, ACM, HMM

## **Abstract**

Understanding behavior is one of the keystones for comprehensive understanding of animal biology. However, studying behavior and circadian activity is very difficult in the field. There was a great advance on the field of animal monitoring and behavior identification using acceleration measuring.

This work is about activity measuring in two model species – Red-wattled lapwing (*Vanellus indicus*) and Black-winged stilt (*Himantopus himantopus*). Fieldwork was done in Al Marmoom Conservation Reserve, Dubai, UAE. Chicks of the model species were captured and equipped with multisensory datalogger developed by the Behavioral Ecology Research Group. Activity was classified into five types of behavior based on data from these dataloggers – lying, standing, walking, running and swimming. Distribution of activities during the day, same as total percentage, was different for each species. Chicks of Black-winged stilt were more active. Comparing activity percentage in individual chicks did not show any significant differences between younger and older individuals.

**Key-words:** *Vanellus indicus*, *Himantopus himantopus*, multisensory datalogger, ACM, HMM

# Obsah

1. Úvod.....	1
1.1 Prekociální mláďata a jejich růst.....	1
1.2 Aktivita prekociálních mláďat .....	2
1.2 Metody výzkumu aktivity.....	4
1.3 Možnosti využití akcelerometrů .....	6
1.4 Zpracování dat z akcelerometrů.....	7
1.4.1 Metriky pro hodnocení chování .....	8
1.4.2 Klasifikace chování na základě akcelerometrických dat .....	11
1.4.3 Skrytý Markovův model .....	12
1.3 Modelové druhy .....	13
1.3.1 Čejka černoprsá .....	13
1.3.2 Pisila čáponhá.....	14
2. Cíle práce.....	16
3. Metodika.....	17
3.1 Lokalita.....	17
3.2 Sběr dat v terénu .....	17
3.2 Analýza videí .....	19
3.3 Zpracování dat z akcelerometrů.....	19
4. Výsledky.....	23
4.1 Zhodnocení použitého modelu.....	23
4.2 Denní patrnosti v chování.....	24
4.3 Patrnosti v zastoupení jednotlivých typů chování.....	26
5. Diskuze.....	31
5.1 Hodnocení použitého modelu .....	31
5.2 Denní patrnosti v chování.....	32



6. Závěr .....	35
7. Literatura .....	36
7. Přílohy .....	47

# 1. Úvod

## 1.1 Prekociální mláďata a jejich růst

Dle strategie v rodičovské péči lze ptáky rozdělit na dvě základní skupiny: altriciální a prekociální druhy. Mláďata altriciálních druhů se líhnou neopeřená, slepá a s nevyvinutou schopností termoregulace. Zůstávají v hnízdě až do vzletnosti a jsou plně odkázána na rodičovskou péči. Příkladem altriciálních druhů jsou například pěvci (Passeriformes), papoušci (Psittaciformes), holubi (Columbidae), sovy (Strigiformes) a další. Naproti tomu mláďata prekociálních druhů se líhnou vyvinutá, krytá prachovým peřím a krátce po vyklubání opouštějí hnízdo (Nice 1962). Musí být schopna alespoň částečné termoregulace, sama se nakrmit a vyhnout se predátorům (Colwell et al. 2007). Typickými zástupci prekociálních ptáků jsou kachny (Anatidae), hrabaví (Galliformes) či bahňáci (Charadrii).

Rodičovská strategie a délka péče se liší napříč jednotlivými řády i druhy. Délka péče často souvisí s rychlostí vývoje mláďat. Ta je u prekociálních druhů poměrně variabilní, přičemž nejvyšší rychlosti růstu dosahují arktické druhy. V chladných oblastech, kde je nepříznivé počasí jedním z nejvíce ohrožujících faktorů, jsou rychlý růst a velké přírůstky jednou z variant, jak zamezit populačním ztrátám (Beintema & Visser 1989a). A to především z důvodu zkrácení období, ve kterém jsou zranitelná vůči predátorům a nepříznivým environmentálním faktorům. U migrujících druhů je také zásadní schopnost mláďat opustit hnízdiště ještě před nástupem zimy (Ricklefs et al. 1986). Rychlý růst má však vysoké nároky na spotřebu energie (Beintema & Visser 1989a; 1989b) a dostatek potravy se tak pro řadu druhů stává limitujícím faktorem (Picozzi et al. 1999; Wegge & Kastdalen 2007). Mezi ptačí druhy hnízdící v boreálních a arktických klimatických zónách patří i mnoho bahňáků, zejména pak z čeledi slukovití (Scolopacidae) (del Hoyo 1996). Jedním takovým příkladem může být jespák rezavý (*Calidris canutus*). Jeho mláďata dosahují vysokých přírůstků a jsou vzletná již mezi 17. a 20. dnem života (Schekkerman et al. 2003). Obdobně rychlý růst má i jespák křivozobý (*Calidris ferruginea*), jehož kuřata mohou dosáhnout vzletnosti již po patnácti dnech (Schekkerman et al. 1998).

V kontrastu s tím subtropické a tropické druhy vykazují míru růstu nižší. Přestože ve srovnání s arktickými druhy je studií na tropické a subtropické druhy prekociálních ptáků podstatně méně, byly u nich kromě pomalejšího růstu zjištěny

i menší denní energetické výdaje a nižší rychlost metabolismu (Wiersma et al. 2007; Tjørve et al. 2008). Pomalejší růst i metabolismus může vést k menším nárokům na množství potravy, minimalizaci ztrát vody a také snížení produkce vnitřního tepla. Tato kombinace tak představuje dokonalé přizpůsobení teplému semiaridnímu prostředí s chudší potravní nabídkou (Schekkerman et al. 2003; Tjørve et al. 2008).

## 1.2 Aktivita prekociálních mlád'at

Ve srovnání s altriciálními druhy podobné velikosti, prekociální mlád'ata vyžadují více potravy. Proto je krmení jejich nejdůležitější a také časově nejnáročnější aktivitou, kterou vykazují (Schekkerman & Visser 2001). V prvních dvou týdnech, v důsledku ještě plně nevyvinuté termoregulace, jsou kuřata závislá na péči rodičů (Pienkowski 1984). Ti je v pravidelných intervalech mezi hledáním potravy a krmením zahřívají. Jak budou tyto intervaly dlouhé (jinými slovy, kolik času kuřata stráví hledáním potravy a kolik zahříváním), záleží z velké části také na počasí (Beintema & Visser 1989a; 1989b; Schekkerman et al. 1998; Krijgsveld et al. 2003). Během chladných a deštivých dnů jsou mladší kuřata odkázána na péči a teplo rodičů a hledáním potravy tráví jen minimum času. V důsledku toho se snižuje i jejich rychlost růstu a tím se prodlužuje i doba do vzletnosti (Beintema & Visser 1989b). Navíc nutnost častěji zahřívání mlád'at při nízkých teplotách zvyšuje i míru predace, jelikož nápadnější peří dospělých jedinců přitahuje více pozornosti predátorů než nenápadné zbarvení kuřat. Mimo to mladší kuřata jsou méně mobilní, drží se pospolu v blízkosti rodičů a při hrozícím nebezpečí setrvávají nehybně na místě a spoléhají na své kryptické zbarvení (Colwell et al. 2007). Spolu s přibývajícím věkem klesá celková závislost na rodičích. Díky stále lepší termoregulaci se snižuje potřeba zahřívání a tím se prodlužuje doba, kterou mohou strávit hledáním potravy (Schekkerman & Boele 2009). Také vzdálenosti od rodičů a sourozenců vzrůstají a v případě ohrožení již před nebezpečím aktivně utíkají (Colwell et al. 2007).

Jen málo autorů se zaměřilo na celkovou aktivitu prekociálních mlád'at a rozdělení daných aktivit během dne. V tropických a subtropických oblastech, kde denní teploty přesahují i 50 °C je velice důležitá blízkost vodního zdroje. Dospělci u něj nacházejí potravu a během inkubace představuje také místo k jejich ochlazení a díky namáčení břicha i způsob, jak v hnízdě udržovat ideální teplotu a vlhkost. Po vylíhnutí jsou mlád'ata z hnízda odváděna během ranních nebo pozdně odpoledních

hodin. Následně většinu horkých dní tráví u vody, kde nacházejí dostatek potravy. I přestože ještě nemají plně vyvinutou termoregulaci díky brodění dokáží dobře zvládat tepelný stres (Grant 1982). Vědecké práce na celkovou aktivitu, aktivitu během noci či rozložení jednotlivých aktivit během dne však u těchto druhů chybí. O něco lépe jsou zdokumentovány arktické druhy a druhy temperátní zóny. Schekkerman a Boele (2009) pozorovali potravní chování mláďat břehouše černoocasého (*Limosa limosa*), který má rozšíření především v temperátní zóně. Čas strávený hledáním potravy u kuřat starších jednoho týdne byl odhadnut na 70-90 % dne. Přičemž nejvyšší aktivita byla zaznamenána v ranních hodinách, a naopak nejnižší v hodinách odpoledních, obzvláště během teplejších dnů. Naproti tomu mladší kuřata, která byla nucena prokládat hledání potravy se zahříváním u rodičů, trávila krměním okolo 55-65 % dne. Potřeba zahřívání byla nejvyšší během ranních a také večerních hodin. Odpočinek zabíral jen malé procento z celkové denní aktivity. Nicméně zatímco u mladších kuřat byl odpočinek pozorován spíše okolo poledne, starší kuřata odpočívala rovnoměrně během celého dne (Schekkerman & Boele 2009). Ve srovnání s tím u kulíka hnědokřídleho (*Pluvialis dominica*), hnízdícího v arktické tundře, byla potravní aktivita značně závislá na věku a aktuální teplotě. Při průměrné teplotě okolo 12 °C trávila kuřata starší jednoho týdne krměním v průměru 70-80 % dne, zatímco mladší jedinci v průměru jen 40 % dne. Nicméně pokud teplota poklesla pod 10 °C, doba strávená hledáním potravy byla omezena v průměru pouze na 30 % dne a u kuřat mladších tří dnů ještě méně (Krijgsveld et al. 2003). Během chladných a větrných dnů tak mláďata stráví více času zahříváním než hledáním potravy, což může být pro jejich přežití kritické, neboť Beintema a Visser (1989b) uvádějí, že pro efektivní nabírání na váze a růst musí kuřata strávit krměním více než 30 % dne.

Z těchto prací se dá usuzovat, že pokud jsou environmentální podmínky příznivé, prekociální kuřata jsou po většinu dne aktivní (vyjma krátkých přestávek na odpočinek a v případě ohrožení). Avšak rozdělení aktivit v rámci dne se v závislosti na věku mění. Nicméně je tady značný prostor k dalšímu bádání. Stejně jako u aktivit během noci, o nichž je dokladů minimálně. Whittingham et al. (1999) za pomoci vysílaček zaznamenali u kulíka zlatého (*Pluvialis apricaria*) aktivitu v průběhu noci pouze (až na jednu výjimku) u jedinců starších jednoho týdne. Naproti tomu mladší kuřata byla neaktivní a s největší pravděpodobností po celou noc zahřívána rodiči. Kuřata jsou v období růstu až po vzletnost velmi zranitelná vůči predátorům a podle

Whittinghama et al. (1999) je možné, že starší mláďata s již lepší termoregulací využívají k hledání potravy i noc, aby urychlila růst a zkrátila kritické období na minimum.

V kontrastu s tím u dospělých jedinců bylo pravidelné krmení v průběhu noci mnohokrát pozorováno. Obzvláště během zimování, a to v mírném i tropickém pásu (Robert et al. 1989; Burger & Gochfeld 1991; Mouritsen 1994; Hötker 1999). U dospělců se mimo hnízdní sezónu převážná část aktivit skládá z hledání potravy, krmení, odpočinku, čištění a péče o peří (Nol et al. 2014; Morrier & McNeil 2015). Přičemž čas, který věnují krmení, závisí především na druhu a také na enviromentálních podmínkách (Fasola & Biddau 1997; Nol et al. 2014; Morrier & McNeil 2015). Naproti tomu během období rozmnožování tráví většinu svého času námluvami, stavěním hnízd, pářením, inkubací, obranou hnízda a následnou péčí o mláďata (Hötker 1999; Cuervo 2003). Před migrací se opět více zaměřují na shánění potravy, aby si vytvořili dostatečné tukové zásoby potřebné pro zdolání dlouhé a náročné cesty na zimoviště (O'Reilly & Wingfield 1995).

## 1.2 Metody výzkumu aktivity

Chování zvířat je základní součástí jejich biologie, avšak ne vždy je snadné nebo možné jednotlivé prvky chování zaznamenat přímým pozorováním. Obzvláště u zvířat, která přirozeně žijí skrytě (Marion et al. 1981) nebo mimo dosah pozorování člověkem, jako jsou například mořští živočichové (Tsuda et al. 2006) nebo ptáci (Weimerskirch et al. 2005; Halsey et al. 2009). Nicméně i v případech, kdy je přímé pozorování určitého druhu možné, bývá náročné na čas a pracovní sílu, a i přesto mohou být výsledky zkresleny. Jak z důvodu, že mnoho zvířat vnímá člověka jako potenciálního predátora, tak také v závislosti na jeho přítomnosti mohou měnit své behaviorální interakce s jinými druhy (Isbell & Young 1993; Yasué 2005). V důsledku toho vznikla potřeba vyvinout metody, které by eliminovaly nežádoucí efekt přítomnosti pozorovatele a zároveň splňovaly vysoké nároky na úroveň podrobností v záznamu dat. Na poli biotelemetrie, tedy sledování zvířat na dálku, tak došlo k výraznému pokroku, díky kterému bylo možné lokalizovat a zaznamenávat pohyb a návyky kryptických zvířat, vysoce mobilních jedinců nebo zvířat pohybujících se na širém moři či v noci (Kooyman 2004; Hart & Hyrenbach 2009; Cagnacci et al. 2010). Biotelemetrie se vyvíjela od manuálního sledování rádiových

nebo akustických signálů z drobných vysílačů připevněných k jedincům až po automatické zaznamenávání polohy zvířete za pomoci satelitních polohových systémů - GPS (Cagnacci et al. 2010; Tomkiewicz et al. 2010). Tento technologický pokrok vedl k porozumění v mnohých ekologických otázkách. Přesto všechno je však díky telemetrii získána jen lokalizace jedince a záznam, jak dlouhou dobu tam setrval. Nicméně behaviorální kontext chybí. Z tohoto důvodu bylo potřeba vyvinout technologii, která by umožňovala měřit a zaznamenávat nejen pohyb v prostoru, ale i chování zvířat. A to tak, aby se snížily nebo vyloučily potenciální účinky z přítomnosti pozorovatele a zároveň bylo dosaženo takové úrovně detailů v záznamu dat, jenž by byly srovnatelné s přímým pozorováním (Brown et al. 2013).

V posledních letech, mimo jiné zásluhou miniaturizace elektroniky, došlo k rozmachu monitorování zvířat a identifikaci jejich chování pomocí měření akcelerace (Shepard et al. 2008; Nathan et al. 2012). Akcelerometry se již několik desetiletí využívají pro měření třesu a motorické aktivity u neurologických pacientů (Frost 1978; LeMoyné et al. 2013) nebo ke studiu chůze a dalších pohybů u člověka (Foerster et al. 1999; Mathie et al. 2004). Pro hodnocení aktivity a chování u zvířat se začaly využívat ke konci 90. let (Sellers et al. 1998; Scheibe et al. 1998) a v posledních letech jsou na značném vzestupu, což je dáno především tím, že většina vzorců chování je definována pohyby nebo posturálními vzory, které lze pomocí akcelerometrů kvantifikovat (Laich et al. 2008; Nathan et al. 2012).

Akcelerometr je přístroj pro měření zrychlení ( $m/s^2$ ). Pro akcelerometry se nejčastěji využívají piezoelektrické materiály. Piezoelektrický krystal je schopen při deformaci (jak gravitačním zrychlením, tak i setrvačným zrychlením v důsledku pohybu) generovat elektrický náboj, jenž je úměrný síle, která na něho působí (Brown et al. 2013). V praxi se běžně využívají akcelerometry zaznamenávající pohyb (zrychlení) ve dvou osách (např. Watanuki et al. 2006; Sato et al. 2007) a v posledních letech také ve třech osách. U těchto takzvaných triaxiálních akcelerometrů jsou senzory uspořádány kolmo na sebe a záznam z tohoto simultánního měření, může realisticky představovat trojrozměrný pohyb (např. Laich et al. 2008; Shepard et al. 2008). Jednotlivé senzory mohou být uživatelsky naprogramovány tak, aby vzorkovaly při frekvencích 0,5 až 10 000 Hz. Obecně platí, že pro přesnou charakterizaci pohybů pomocí akcelerometrů je důležité nastavit vzorkovací frekvenci

tak, aby byla minimálně dvakrát větší než nejvyšší očekávaná frekvence pohybu (Han 2010).

Akcelerometr lze vybranému jedinci připevnit pomocí krčního límce (Kappeler & Erkert 2003), různých druhů bandáží (de Passillé et al. 2010), speciálních postrojů (Halsey & White 2010), lepících pásek (Brischoux et al. 2010) nebo pomocí různých druhů rychle schnoucích lepidel (Suzuki et al. 2009). Správné umístění a uchycení dataloggeru je velice důležité. Jednak z důvodu co nejmenšího ovlivnění svého nositele, tak také z hlediska kvality sbíraných dat. Zejména, aby nedošlo ke špatné interpretaci dat, jelikož senzory akcelerometru jsou velice citlivé k jakýmkoliv posunům vzhledem k poloze těla zvířete (Brown et al. 2013).

### **1.3 Možnosti využití akcelerometrů**

Akcelerometry se běžně využívají v každodenním životě a lze je nalézt v mobilních telefonech (Kwapisz et al. 2011) nebo chytrých hodinkách (Bieber et al. 2013), kde slouží především k vyhodnocení denních aktivit nositele. V lékařství mohou sloužit k monitorování pacientů (Van de Vel et al. 2013) i diagnostice nemocí jako je například Parkinsonova choroba (Okuno et al. 2007). U zvířat lze za pomoci akcelerometrů monitorovat pohyb jednotlivých částí těla. Při kombinaci dvou akcelerometrů (jeden umístěný na hlavě a druhý na čelisti) je možné detekovat potravní aktivitu, tedy čas a dobu strávenou krmením (Suzuki et al. 2009; Viviant et al. 2010). Je možné sledovat chování i celkovou aktivitu zvířat (Laich et al. 2008; Wang et al. 2015). Jelikož je metabolismus většinou úzce korelován s mechanickou prací, lze na základě aktivity také stanovit celkový energetický výdej jedince (Wilson et al. 2006; Elliott et al. 2013).

Akcelerometry mohou být využity i společně s jinými senzory. Díky tomu je možné popsat aktivitu i v širším ekologickém kontextu. Ve spojení s magnetometrem je lze využít k určení směru pohybu a kvantifikaci široké škály, především rotačních pohybů (Williams et al. 2017). Akcelerometry v kombinaci se senzory snímajícími intenzitu osvětlení, teplotu vzduchu či vlhkost umožňují sledovat aktivitu v závislosti na okolních podmínkách. Příkladem může být dlouhodobý výzkum denních i sezónních rytmů Madagaskarských lemurů (Kappeler & Erkert 2003; Erkert & Kappeler 2004). Při spojení akcelerometrů a lokátorů polohy,

jako je GPS nebo hloubkoměr, lze podrobně zkoumat aktivitu a rozmístění jedinců v prostoru. To může výrazně pomoci k porozumění chování a prostorové ekologie například mořských živočichů (O'Toole et al. 2010) nebo velkých kočkovitých šelem, které přirozeně žijí skrytě (Wang et al. 2015). Za pomoci akcelerometrů a GPS se při zkoumání potravního chování a disperze tukana hnědohřbetého (*Ramphastos swainsonii*) a tukana krátkozobého (*Ramphastos sulfuratus*) objasnily i základní poznatky o disperzi semen. Díky kombinaci dat z akcelerometrů, GPS a znalosti doby, za kterou projdou semena trávícím traktem tukanů, je možné odhadnout rozptyl semen od matečního stromu. Mimo to plody, na nichž tukani hodovali dozrávají v ranních hodinách, což odpovídá i nejvyšší zjištěné potravní aktivitě tukanů. Tyto poznatky mohou prohloubit znalosti o dynamice tropického lesa a koevoluci rostlin a jejich přenašečů semen (Kays et al. 2011).

V současnosti díky pokroku v technologii a také neustálé miniaturizaci mechanických součástek došlo k vývoji dataloggerů, které umožňují monitoring více proměnných v intervalu mnohokrát za sekundu a mohou vážit pouze okolo 1 g (Brown et al. 2013). Díky tomu lze zaznamenávat komplexní kvantitativní měření zvířat, která se chovají ve svém prostředí zcela přirozeně (Ropert-Coudert & Wilson 2005). Je tak možné poskytnout širokou škálu podrobných informací o environmentálním kontextu chování zvířat a fyziologii, které mohou překročit popisné schopnosti lidského pozorovatele a prohloubit naše znalosti i pro známé druhy (Brown et al. 2013).

#### 1.4 Zpracování dat z akcelerometrů

Interpretace dat z akcelerometrů, především u volně žijících zvířat, může být obtížná, protože naměřené zrychlení je výsledkem **dynamické složky** (zrychlení ve směru pohybu objektu), **statické složky** (gravitačního zrychlení Země) a **náhodného šumu**, který je nutné odstranit. Mimo tento náhodný šum může v datech vznikat i šum způsobený například prouděním vody okolo dataloggeru upevněném na těle vodního živočicha nebo při připevnění na ne zcela stabilní podklad, kupříkladu ptačí peří (Williams et al. 2017). Mimo to mohou mít zvířata velký repertoár pohybových vzorců, které se liší jednak složitostí a také délkou trvání (Shepard et al. 2008).



### 1.4.1 Metriky pro hodnocení chování

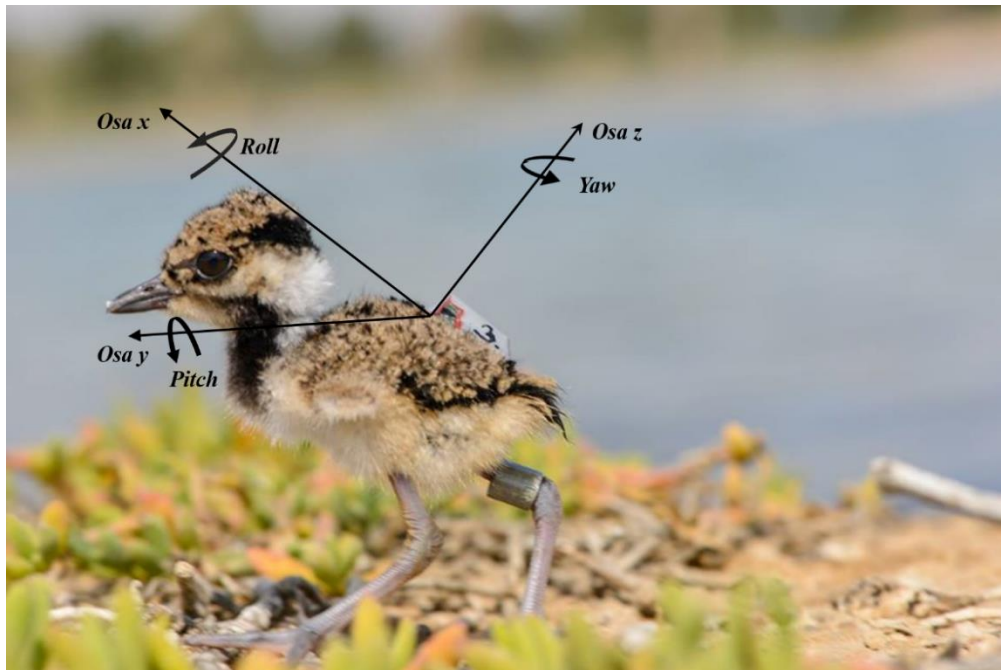
Pro hodnocení jednotlivých prvků chování lze využít širokou škálu odvozených metrik. Triaxiální akcelerometry měří ve třech osách, přičemž jednotlivé senzory jsou postaveny kolmo na sebe. *Osa x* měří zrychlení podélně k tělu zvířete, respektive je zarovnána s osou těla dataloggeru. *Osa z* směřuje dolů, kolmo na *osu x* a měří zrychlení v dorzoventrálním směru. *Osa y* pak protíná osu *x* a *z* v pravém úhlu. Tyto tři osy tedy vytvářejí pravoúhlý souřadnicový systém (Shepard et al. 2008; Mark 2013).

Přestože jsou akcelerometry silným nástrojem v monitorování zvířat, nezávládnou vysvětlit všechny druhy chování a pohybů. Samy o sobě především nedokážou určit směr pohybu jedince. Pro tento účel lze však využít magnetometr. Mimo záznam směru magnetometr měří velikost magnetické indukce nebo magnetického momentu a zároveň není citlivý na dynamické ani gravitační zrychlení. Z tohoto důvodu je lze použít ve spojení s akcelerometry a získat tak kvalitnější metriky pro kvantifikaci chování zvířat. V praxi se využívají jednoosé až tříosé magnetometry, přičemž jednoosý magnetometr produkuje maximální hodnotu ve chvíli, kdy směřuje k magnetickému severu a má svou měřicí osu přesně rovnoběžnou s čarami magnetického pole. Minimální hodnotu pak nabývá, jestliže míří na magnetický jih (Williams et al. 2017). V současnosti nejčastěji využívané tříosé magnetometry jsou schopné definovat orientaci jedince vůči magnetickému poli Země. Magnetometry jsou citlivé na rotační pohyby, což může být obzvláště cenné u organismů pohybujících se ve vzduchu či ve vodě, kde se rotační úhly kolem *osy x* a *y* často vychylují od vodorovné polohy. V kombinaci s akcelerometry tedy představují nástroj pro přesnou kvantifikaci široké škály pohybů u různých terestrických i vodních druhů (Williams et al. 2017).

Akcelerometry ve všech osách zaznamenávají jak dynamické zrychlení, které je zapříčiněno pohybem zvířat, tak statické zrychlení, které je způsobeno silou gravitačního pole Země. V případě, že je měřený jedinec v klidu celkové dynamické zrychlení je rovno nule a celkové statické zrychlení je rovno gravitačnímu zrychlení, tedy  $9,8 \text{ ms}^{-2}$ . Pro práci s dynamickou složkou je nutné statické zrychlení odstranit, nicméně samo o sobě ukazuje míru sklonu akcelerometru vzhledem k zemskému gravitačnímu poli a lze jej využít k určení orientace jedince v prostoru

(Shepard et al. 2008). Změny v této orientaci jsou popsány pomocí úhlů rotací okolo zmíněných os (Obr. 1). Tyto úhly se nazývají Eulerovy úhly (Příkryl 2008):

- $\varphi$  úhel rotace kolem osy x
- $\theta$  úhel rotace kolem osy y
- $\psi$  úhel rotace kolem osy z



Obr. 1: Kuře čejky černoprsé. Orientace jednotlivých akcelerometrických os a úhlů rotací.  
Foto: Tom Jůnek

Při určení relativní orientace objektu v prostoru se využívá specifická sekvence těchto úhlů. Pro **natočení** („Roll“), jenž je definováno jako rotace okolo osy x (Obr. 1), lze vypočítat pomocí funkce arcus tangens a vzorce:

$$\text{atan}\left(\frac{\text{osa } y}{\sqrt{\text{osa } x^2 + \text{osa } z^2}}\right) * \frac{180}{\pi}$$

Obdobně lze stanovit i **naklonění** („Pitch“), které je definováno jako rotace okolo osy y (Obr. 1):

$$\text{atan}\left(\frac{\text{osa } x}{\sqrt{\text{osa } y^2 + \text{osa } z^2}}\right) * \frac{180}{\pi}$$

Avšak ke stanovení rotace okolo poslední osy  $z$  – **vybočení** („*Yaw*“) (Obr. 1), je nutné využít informací z magnetometru:

$$\text{atan}\left(\frac{-\text{mag } y}{\text{mag } x}\right) * \frac{180}{\pi}$$

V souvislosti s triaxiálními akcelerometrovými daty se velice často používá ODBA („overall dynamic body acceleration“). Jedná se o důležitou souhrnnou metriku, která vyjadřuje celkovou dynamickou akceleraci těla. Představuje míru agregovaného zrychlení daného subjektu a pro její vypočet je nutné odečíst statickou složku zrychlení od jednotlivých os a následně sečíst absolutní hodnoty všech výsledných dynamických složek zrychlení (Wilson et al. 2006).

$$ODBA = |A_x| + |A_y| + |A_z|$$

Velmi podobná souhrnná metrika je VeDBA - vektorová dynamická tělesná akcelerace („vectorial dynamic body acceleration“), tedy vektorový součet dynamických složek zrychlení (Qasem et al. 2012).

$$VeDBA = \sqrt{A_x^2 + A_y^2 + A_z^2}$$

Obě tyto metriky se nejčastěji využívají v souvislosti s vyjádřením energetického výdeje zkoumaného jedince, především z důvodu zjištěné korelace mezi těmito metrikami a spotřebou kyslíku (jako vyjádření rychlosti metabolismu) u široké škály druhů (např. Fahlman et al. 2008; Halsey et al. 2009; Enstipp et al. 2011).

Měření z akcelerometrů lze využít i k odvození rychlosti sledovaného jedince a spolu s informacemi z magnetometru, hloubkoměru nebo výškoměru je možné odhadnout polohu, respektive trasu zvířete (Brown et al. 2013). Navigace výpočtem („Dead-reckoning“) je relativně jednoduchá metoda založená na odhadnutí aktuální pozice v prostoru na základě rychlosti, směru pohybu (určené pomocí magnetometru), změn na svislé ose (výška/hloubka) a času uplynulého od poslední známé pozice (často místo vypouštění jedince) (Wilson et al. 2007). Pokud datalogger není vybaven snímačem rychlosti, je možné potřebnou rychlost vypočítat integrací zrychlení ve známém časovém intervalu nebo pomocí známé délky kroku a frekvence kroku změřené akcelerometrem. Takto definovaná rychlost však podléhá značným chybám, především díky změnám ve sklonu terénu i podkladu, po kterém se jedinec pohybuje. Tyto chyby se následně akumulují a s tím se zhoršují i odhady aktuální polohy (Brown et al. 2013).

### 1.4.2 Klasifikace chování na základě akcelerometrických dat

Předností akcelerometrů je shromažďování velkého množství dat o pohybech a aktivitách zvířat bez vlivu pozorovatele. Abychom však pochopili, jak se data z akcelerometrů a dalších senzorů vztahují k jednotlivým typům chování, je nutné najít metodu přiřazení těchto dat ke konkrétním druhům chování nebo kategoriím chování s vysokou mírou přesnosti. Pro tento úkol je nutná předchozí znalost chování daného druhu. Tyto informace lze získat z výzkumu na příbuzných druzích domácích zvířat, jedincích odchovávaných v zajetí nebo krátkých pozorování jedinců v přírodě, popřípadě prostřednictvím videozáznamu. Pečlivá synchronizace jednotlivých pozorování se záznamy z dataloggerů nám prozradí, jaké chování odpovídá výsledným křivkám z měření. Toto manuální zkoumání je v prvotních fázích velice důležité, ovšem vzhledem k velkému množství dat je nezbytný automatický systém kategorizace dat z dataloggerů a jejich automatické přiřazování k jednotlivým typům aktivit (Brown et al. 2013). V posledních letech se tak vyvíjí možnost automatické detekce jednotlivých prvků chování s využitím strojového učení (např. Nathan et al. 2012; Brewster et al. 2018).

Strojové učení je založeno na práci s algoritmy a je velice úzce propojeno se statistikou. Při strojovém učení se předpokládá co nejméně informací o povaze distribuce dat a umožnění tak danému algoritmu určit který model nejlépe aproximuje proces generování dat (Shalev-Shwartz & Ben-David 2014). Tento proces strojového učení prostupuje různá odvětví lidské činnosti a nalézá uplatnění v nejrůznějších disciplínách od bankovního a finančního sektoru přes dopravu až po zdravotnictví. Na poli biologie je často spojováno s bioinformatikou (např. He et al. 2019; Liu 2019), klinickou medicínou (např. Weng et al. 2017) a v neposlední řadě také s vyhodnocováním akcelerometrových dat jak u lidí (např. Mannini & Sabatini 2011), tak v posledních letech také u zvířat (např. Halsey et al. 2009; Nathan et al. 2012).

Ve strojovém učení je možné využít dvou přístupů. V prvním přístupu, takzvaném učení bez učitele, není ke vstupním datům předem daný výstup. Využívá se statistických algoritmů, které seskupí data podobných charakteristik a ke každé skupině přiřadí obecný typ chování (např. Sakamoto et al. 2009). Druhý přístup, který je využíván častěji, je takzvané učení s učitelem. Jedná se o metodu, kdy k tréninku algoritmu je použita cvičná sada dat z pozorovaného chování. Jedná se tedy o data,

pro které jsou známé výstupy. Na zbývající data se pak použijí tyto „vytrénované“ algoritmy, které jim přiřadí konkrétní kategorii chování (Brown et al. 2013).

### 1.4.3 Skrytý Markovův model

Skrytý Markovův model (angl. hidden Markov Model, zkr. HMM) je pravděpodobnostní model, který nemá, na rozdíl od jiných metod strojového učení, jako základní předpoklad absenci časové autokorelace analyzovaných dat, nýbrž jí předpokládá a explicitně s ní pracuje. Tento model je využíván ve strojovém učení často ve spojitosti s rozeznáváním a syntézou řeči (např. Schuller et al. 2003; Tokuda et al. 2013) nebo psaného textu (např. Kessentini et al. 2010). Nicméně ho lze využít i pro analýzu akcelerometrových dat a detekci jednotlivých prvků chování zvířat (Leos-Barajas et al. 2017).

**HMM** je stochastický model časových řad, který je definován dvěma základními vlastnostmi. V první řadě předpokládá, že pozorování v čase  $t$  bylo generováno procesem, jehož stav  $S_t$  je před pozorovatelem „skrytý“. V druhé řadě pak, že stav tohoto „skrytého“ procesu splňuje takzvanou Markovovskou vlastnost. To znamená, že vzhledem k hodnotě  $S_{t-1}$  je současný stav  $S_t$  nezávislý na všech stavech před  $t-1$ . Jinými slovy stav v čase  $t$  je závislý pouze na stavu v čase  $t-1$  (Ghahramani 2001). Pro predikci těchto skrytých stavů v HMM modelu lze využít oba výše zmíněné přístupy, tedy učení s učitelem i bez učitele. V obou případech je však cílem identifikace odlišných pohybových vzorců jedince, přičemž výsledné odhadované stavy HMM závisí na vlastnostech vybraných pro interpretaci (Leos-Barajas et al. 2017). Odhadované parametry u jednorozměrného HMM modelu jsou průměry a rozptyly vysvětlující proměnné pro daný stav, pravděpodobnosti jednotlivých stavů pro čas  $t_1$  a pravděpodobnosti jednotlivých přechodů.

Pro trénink modelu je možné využít např. **Baum-Welchův algoritmus**, jenž je zvláštním případem algoritmu očekávané maximalizace („EM algorithm“). Tento algoritmus využívá trénink bez učitele, který probíhá v několika iteracích s cílem maximalizovat věrohodnost (angl. maximum likelihood) odhadnutých parametrů. Druhým typem algoritmu je **křížová validace** („Leave-one-out training“). V prvním kroku tento algoritmus rozdělí data do podmnožin (například jednotlivých

videonahrávek), poté postupně vždy jednu podmnožinu vynechá a na ostatních odhadne parametry modelu. Následně vznikne rozdělení parametrů, ze kterého je možné vybrat kupříkladu průměr (Ko et al. 2009).

Pro stanovení maximálně věrohodné posloupnosti stavů pro konkrétní dataset lze využít **Viterbiho algoritmus**. Jedná se o algoritmus dynamického programování, jehož účelem je vyvodit závěr na základě tréninkového modelu. Jinými slovy určuje nejpravděpodobnější volbu stavu vzhledem k datům a trénovacímu modelu (Leos-Barajas et al. 2017).

## 1.3 Modelové druhy

### 1.3.1 Čejka černoprsá

Čejku černoprsou (*Vanellus indicus*, Boddaert 1783) řadíme do řádu dlouhokřídlí (Charadriiformes) a čeledi kulíkovití (Charadriidae). Tento středně velký druh bahňáka je rozšířen od západní Asie (Irák, jižní Írán, Perský záliv), přes jižní Asii (Pákistán, Afghánistán, celý Indický subkontinent) až po Thajsko, Kambodžu a Vietnam (Rasmussen & Anderton 2005; BirdLife International 2016).

Tato čejka má zřetelné červené laloky v oblasti očí, červený kořen zobáku a žluté nohy. Hřbet a křídla má světle hnědá, letky jsou černé, stejně jako hlava, hrdlo a prsa. Naopak krk po stranách, břicho a spodní strana křídel jsou bílé (Obr. 2). Jedná se o silně teritoriální druh s výrazným hlasovým projevem, kterým varuje před predátory. Běžně je lze vidět v párech nebo rodinných uskupeních, mimo hnízdní sezónu i ve vícečetných skupinkách (Message & Taylor 2005).

Vyskytuje se v teplých oblastech subtropického a tropického pásma. Hnízdí v otevřené krajině, často i na zemědělsky využívané půdě v blízkosti mokřadů, řek, rybníků či tůní (del Hoyo et al. 1996; Message & Taylor 2005). Tam nachází dostatek potravy, která se skládá především z hmyzu a vodních bezobratlých (del Hoyo et al. 1996).

Jako většina bahňáků hnízdo staví na zemi a na jeho budování se podílejí obě pohlaví, stejně jako na inkubaci a následné péči o mláďata. Snůšku tvoří 3 – 4 krypticky zbarvená vejce, ze kterých se po 25-28 dnech líhnou kuřata (Khalil et al. 2019; Sethi et al. 2011). Již krátce po vylíhnutí kuřata opouštějí hnízdo a sama

si shánějí potravu. Díky horkému podnebí, ve kterém hnízdí, rodiče zahřívají mláďata především v noci, naopak přes den je chrání před horkými slunečními paprsky. Ochraňují je také před predátory, a to až do jejich vzletnosti (Saxena & Saxena 2013), které kuřata dosahují okolo 38. dne života (Kalsi & Khera 1990; Dhandhukia & Patel 2015).



Obr. 2: Čejka černoprská (*Venellus indicus*) dospělec  
Foto: Tým behaviorální ekologie.



Obr. 3: Kuřata čejky černoprské.  
Foto: Tým behaviorální ekologie.

### 1.3.2 Pisila čáponohá

Pisila čáponohá (*Himantopus himantopus*, Linnaeus 1758) patří do řádu dlouhokřídlí (Charadriiformes) a čeledi tenkozobcovití (Recurvirostridae). Tento nezaměnitelný druh se vyznačuje neobyčejně dlouhýma červenýma nohama, úzkým rovným zobákem a kontrastním černobílým zbarvením (Message & Taylor 2005).

K hnízdění vyhledává bahnitě či písčité okraje mělkých sladkovodních, ale i brakických vod. Tento mokřadní druh je schopen obývat i relativně nestálé prostředí často značně vzdálené jeho trvalým hnízdním oblastem. Hnízdí tak například i v oázách v poušti, které jim mohou poskytnout více či méně stabilní hnízdní lokalitu (Adamou et al. 2009). Obecně se vyhýbají chladnému a deštivému podnebí, naproti tomu dokážou tolerovat silný vítr a odolávat extrémně vysokým teplotám a přímému slunci bez potřeby vyhledávání stínu (del Hoyo et al. 1996).

Během rozmnožování obvykle vytvářejí volné kolonie (běžně okolo 10-40 párů), běžně i smíšené s jinými druhy bahňáků (del Hoyo et al. 1996; Cuervo 2004). Do hnízda, které představuje důlek v zemi vystlaný stébly trávy a úlomky dalších

rostlin, samice snáší nejčastěji 4 krypticky zbarvená vejce (Adamou et al. 2009; Ashoori 2011).

Na inkubaci i péči o mláďata se podílejí obě pohlaví. Během hnízdění bývají teritoriální a agresivní a mláďata brání až do jejich vzletnosti (Cuervo 2003; Ashoori 2011). Kuřata se líhnou po 25 až 26 dnech a již po několika hodinách je rodiče odvádějí z hnízda (Ashoori 2011). Mláďata jsou nekrmivá a stejně jako dospělí jedinci potravu nacházejí v okolí vody, kde se živí především drobnými vodními bezobratlými, hmyzem a jejich larvami (Dostine & Morton 1989; Ueng et al. 2009).

Pisila představuje kosmopolitní druh, který se vyskytuje v Euroasii, Africe, Austrálii, Severní i Jižní Americe (BirdLife International 2016). V Evropě je rozšířena ostrůvkovitě a v České republice nepravidelně hnízí v jižních Čechách a na jižní Moravě (Kloubec et al. 2015).



Obr. 4: *Pisila čáponohá* dospělec.  
Foto: Tým behaviorální ekologie.



Obr. 5: Hnízdo *pisily čáponohé*.  
Foto: Tým behaviorální ekologie.



## 2. Cíle práce

Cílem předkládané práce je shromáždit informace o aktivitě prekociálních mláďat, využití a možností vyhodnocení dat z akcelerometrů a prozkoumat možnosti využití akcelerometrů a skrytého Markovova modelu pro monitoring aktivity na příkladu prekociálních mláďat bahňáků. Konkrétní cíle zahrnovaly:

- 1.) S využitím multisenzorických dataloggerů vyvinutých týmem behaviorální ekologie sesbírat dostatečné množství dat u kuřat dvou modelových druhů (čejka černoprsá a pisila čáponohá) na lokalitě Al Marmoom v Dubaji (UAE).
- 2.) Na základě pořízených videozáznamů a dat z loggerů ověřit možnosti použití HMM a navrhnout postupy pro další využití.
- 3.) Popsat rytmicitu a diverzitu základních typů jejich chování v průběhu dne a vzhledem k věku kuřete.

## 3. Metodika

### 3.1 Lokalita

Al Marmoom, Dubaj, UAE. Rezervace se nachází asi 30 km od města Dubaj (obr. 6). Jedná se o chráněnou pouštní lokalitu se soustavou uměle vytvořených jezer Al Qudra Lakes. Tato člověkem vytvořená oáza je zásobena odsolenou vodou z moře. Přestože se jedná o uměle vytvořený biotop, je zde možné vidět až několik desítek ptačích druhů, včetně silné hnízdní populace obou modelových druhů. (Ilustrační foto viz kapitola 7. Přílohy, obr. 12, 13, 14).



Obr. 6: Lokalizace Al Marmoom Conservation Reserve v Dubaji. Zdroj: maps.google.com

### 3.2 Sběr dat v terénu

Terénní sběr dat probíhal v hnízdní sezóně (březen-červen) 2019 a v březnu 2020. Během práce v terénu byla dohledávána a chytána kuřata obou modelových druhů (čejka černoprsá a pisila čáponohá). Pomocí posuvného měřítka s přesností na 0,1 mm byla měřena délka zobáku od špičky po proximální okraj nozdry („BNprox“ dle Eck et al. 2011), délka hlavy („HL“ dle Eck et al. 2011) a tarsus („Tar1“ dle Eck et al. 2011). Všichni jedinci byli zváženi pomocí pružinové váhy značky Pesola s přesností na gramy, fotograficky zdokumentováni a označeni hliníkovým kroužkem s unikátní číselnou kombinací. Vždy 1-2 kuřata ze snůšky (minimální váha kuřat, která mohla dostat datalogger, byla stanovena na 14 g) byla vybavena multisenzorickým

dataloggerem, který byl pomocí vteřinového lepidla upevněn na prachové peři v dolní třetině zad, a to s co možná největší přesností tak, aby jeho poloha byla podobná pro všechny jedince (obr. 7). Celkem bylo dataloggerem vybaveno 82 kuřat čejky černoprsé a 13 kuřat pisily čáponohé. Po získání všech biometrických údajů, fotek a označení, byla kuřata vypuštěna v místě odchyty. Vybraná kuřata s dataloggery ( $n = 34$ ) byla několik minut nahrávána na kameru pro následnou analýzu jednotlivých prvků chování. Celkem bylo pořízeno 80 minut záznamu.

Použitý multisenzorický datalogger byl vyvinut týmem behaviorální ekologie. Má rozměry 20,1 x 19,1 mm a spolu s lepidlem váží 1,1 g. Zaznamenává údaje o vlhkosti, teplotě, intenzitě světla, magnetometrii a akceleraci (obojí ve 3 osách). Teplota, vlhkost a světlo jsou měřeny s frekvencí 1 Hz, magnetometrie 10 Hz a akcelerometr měří s frekvencí 10 až 100 Hz po dobu až 72 hodin (při 100 Hz). Pro tuto práci byla vyhodnocena data z akcelerometru a magnetometru, přičemž zvolená frekvence záznamu byla převážně 100 Hz. Dále byly využity údaje o teplotě.

Po 24–48 hodinách byla kuřátka dohledána a znovu odchycena. Po sejmutí akcelerometrů byla všechna kuřata převážena a vypuštěna.



*Obr. 7: Kuřata čejky černoprsé vybavena multisenzorickým dataloggerem.  
Foto: Tým behaviorální ekologie.*

## 3.2 Analýza videí

Veškerá pořízená videa (n=34) byla zpracována v programu BORIS („Behavioral Observation Research Interactive Software“, Friard & Gamba 2016). V tomto programu byly analyzovány jednotlivé druhy chování, a to ve dvou kategoriích: činnosti bodové (*krok, čištění, krmení*) a činnosti trvající určitý čas (*běh, plavání, ležení a zahřívání rodiči*). Videa byla analyzována s přesností na desetinu sekundy. Mimo to byl zaznamenáván i pohyb jedince na slunci, ve stínu či polostínu a jeho vzdálenost od vody ve 3 kategoriích: ve vodě, na břehu a z dosahu vodní plochy. Data z analýzy těchto videí posloužila jako sada tréninkových dat pro následné strojové učení s učitelem („supervised“).

## 3.3 Zpracování dat z akcelerometrů

Všechna data byla zpracována v programu R (R Core Team 2016). V prvním kroku bylo nezbytné připravit soubor tréninkových dat, tedy takových, které mají jasné dané výstupy. K tomu bylo potřeba upravit výsledky z analyzovaných videí a spojit je s výstupy z akcelerometrů.

V první řadě, tak bylo nutné upravit výstupy z dataloggerů a provést autokalibraci akcelerometrových dat pro lokální podmínky (gravitační zrychlení, teplota). K autokalibraci byly využity úseky, kde nebyla vyvíjena žádná aktivita (sd  $VeDBA < 0,013$  g) a  $VeDBA$  by tak měla být rovna 1. Za pomoci iterativního algoritmu a vážené regrese se data upraví, aby tomu tak skutečně bylo a  $VeDBA$  se v úsecích klidu blížila 1 (viz van Hees et al. 2014).

Pro výpočet  $VeDBA$  byl použit vzorec:

$$VeDBA = \sqrt{(A_x^2 + A_y^2 + A_z^2)}$$

Dalším krokem v úpravě dat bylo zhlazování. Byly pro něj použity „mediánové filtry“, jejichž použití je vhodné v případě vysokého šumu v datech (Chen et al. 2015). Ještě před zhlazením byl stanoven průměrný úhel natočení („*mean roll*“):

$$mean\ roll = mean \left( \left( atan \frac{\sqrt{osa\ x^2 + osa\ z^2}}{osa\ y} * \frac{180}{\pi} \right) \right)$$

a průměrný úhel naklonění („*mean pitch*“):

$$mean\ pitch = mean\left(atan\left(\frac{\sqrt{osa\ y^2 + osa\ z^2}}{osa\ x} * \frac{180}{\pi}\right)\right)$$

Následně byl stanoven úhel naklonění („*pitch*“) a natočení („*roll*“) tak, že byl vypočítán „*pitch*“ a „*roll*“ s vyhlazenými akcelerometrickými daty pomocí klouzavého mediánu s velikostí okna 201 a od této hodnoty byl odečten „*mean pitch*“, respektive „*mean roll*“. Takto získaný „*pitch*“ a „*roll*“ je zbaven šumu, který vzniká lehce rozdílným umístěním dataloggeru na jednotlivá kuřata.

Pomocí údajů z magnetometru byl dopočítán i poslední rotační úhel, tedy vybočení („*yaw*“):

$$mag\ x = MAG\ X * cos(pitch) + MAG\ Y * sin(roll) * sin(pitch) + MAG\ Z * cos(roll) * sin(pitch)$$

$$mag\ y = MAG\ Y * cos(roll) - MAG\ Z * sin(roll)$$

$$yaw = atan\left(\frac{-mag\ y}{mag\ x}\right) * \frac{180}{\pi}$$

Dále byl na akcelerometrická data použit „low-pass“ filtr, který nepropouští vyšší frekvence. Data z jednotlivých os byla zhlazena pomocí klouzavého mediánu s velikostí okna 501 a takto zhlazená data byla odečtena od těch původních. Tím byla odstraněna statická složka zrychlení. Pro odstranění šumu byla data znovu zhlazena opět pomocí klouzavého mediánu a velikostí okna 51.

Byla vypočítána ODBA za použití vzorce:

$$ODBA = |A_x| + |A_y| + |A_z|$$

Odhad okamžité rychlosti byl získán integrací hodnot dynamické složky zrychlení a korigován s pomocí již známých úseků nulového pohybu (viz autokalibrace). Dále byly následující metriky spolu s teplotou sumarizovány po vteřinách, aby následně mohly být spojeny s výsledky z analyzovaných videí: „ODBA“, „mean VeDBA“, „sd VeDBA“, „sd roll“, „sd pitch“, „sd yaw“, „mean roll“, „mean pitch“, „mean yaw“.

„min pitch“, rychlost na jednotlivých osách: „velocity x“, „velocity y“, „velocity z“ a akcelerometrická data z jednotlivých os: „suma x“, „suma y“, „sum z“.

V druhém kroku, bylo tedy nutné upravit i výsledky z analyzovaných videí. Pomocí programu BORIS bylo rozeznáno celkem 7 typů chování (*jednotlivé kroky, běh, krmení, čištění, plavání, ležení a zahřívání mlád'at rodiči.*). Každá sekunda, ve které nebylo zaznamenáno žádné z těchto druhů chování byla klasifikována jako *stání*. *Jednotlivé kroky* byly následně rozděleny do dvou kategorií chování: 6 a méně kroků za sekundu představovalo *chůzi* a více než 6 kroků za sekundu bylo již klasifikováno jako *běh*. Na základě akcelerometrových dat bylo velmi těžké odlišit *krmení* od *chůze* a *čištění* od *stání* stejně jako *zahřívání rodiči* od *stání*, jelikož byly následným modelem vnímány totožně. Z tohoto důvodu bylo *krmení* přiřazeno k *chůzi* a *čištění* a *zahřívání rodiči* ke *stání*.

Vzhledem k tomu, že videa jsou ve formátu 12 snímků za sekundu a akcelerometr snímá ve frekvenci 100 Hz (tzn. 100 záznamů za sekundu), bylo nutné tyto frekvence sjednotit. Jako optimální časový úsek byla zvolena 1 sekunda a chování, které převažovalo v dané sekundě, bylo zvoleno jako určující.

Pro všechny kombinace prediktorů (maximálně 5 v jednom modelu) byly odhadnuty skryté Markovovy modely na základě křížové validace („*Leave-one-out training*“). Tyto modely byly následně porovnány na základě správně rozpoznávaných stavů jakož i na procentuální úspěšnosti jejich přiřazení. Jako vítězný model byl zvolen procentuálně druhý nejlepší, a to z toho důvodu že měl vyrovnanější pravděpodobnost odhadu jednotlivých stavů (viz kapitola 4.1 Zhodnocení použitého modelu). Parametry odhadnuty tímto modelem vstupovaly do Viterbiho algoritmu pro stanovení maximálně věrohodné posloupnosti stavů pro kompletní záznamy.

V závěru bylo ještě nutné odstranit úseky, kde jeden typ chování trval déle než 30 minut, jelikož se ve většině případů jednalo o úseky, kdy byl datalogger nalezen spadlý na zemi. Úseky, které představovaly *plavání* o délce kratší než 3 sekundy byly upraveny na *chůzi*. Jednak z důvodu, že je nepravděpodobné, aby kuřata plavala v takto krátkých intervalech a také, protože výsledný model *plavání* nejčastěji zaměňoval právě za *chůzi*. Následně již data byla pouze sumarizována po hodinách.

Pro vyhodnocení analýzy signifikantních vlivů na jednotlivé typy chování byly použity lineární smíšené modely počítané funkcí „lmer“ z knihovny lme4 (Bates et al.

2015). Pro všechny odhady parametrů je velikost efektu stanovena jako medián a Bayesovský 95% interval věrohodnosti (95% CrI), založený na posteriorní distribuci 5000 hodnot simulovaných funkcí „sim“ z R knihovny „arm“ (Gelman et al. 2016). Pro všechny modely byla stanovena sada stejných prediktorů – druh, váha jedince (která představuje velikost, resp. stáří kuřete), teplota okolí (měřena rovněž multisenzorickým dataloggerem) a denní doba (čas), přičemž čas bylo nutné převést na radiány formulí:

$$(2 * \text{čas} * \pi) / 24$$

Ve všech modelech byla také zahrnuta interakce mezi druhem a denní dobou, váhou kuřete a denní dobou, okolní teplotou a denní dobou. Jako náhodný efekt (intercept) byl v tomto modelu použit jedinec. Vysvětlovaná proměnná vždy představovala daný typ chování (*ležení, stání, chůze, běh, plavání*).

## 4. Výsledky

Celkově byla data získána z 95 dataloggerů, zaznamenávajících chování 82 jedinců kuřat čejky černoprsé a 13 jedinců kuřat pisily čáponohé. Délka záznamu z dataloggerů byla u čejek v průměru 40,4 hodin (sd = 20,9, range = 0,28 – 103,6) a u pisil v průměru 24,84 hodin (sd = 12,98, range = 0,7 – 45,96). Pro analýzu videí bylo pořízeno celkem 34 nahrávek, o celkové délce 80 minut.

### 4.1 Zhodnocení použitého modelu

Jako vítězný model byl zvolen procentuálně druhý nejlepší, a to z důvodu vyrovnanějších pravděpodobnostních odhadů jednotlivých stavů. Avšak nejlepší model celkově správně přiřadil jen o 0,41 % více chování. Ve výsledném modelu byla zahrnuty tyto metriky:

$$\text{chování} \sim \text{roll } sd + \text{sum } y + \text{mean } VeDBA + sd \text{ } VeDBA$$

Celkově bylo tímto modelem vysvětleno (správně přiřazeno) **67,23 %** veškerého chování v rámci tréninkového datasetu. Přitom *ležení* bylo správně určeno v **88,44 %** případů, *stání* v **51,22 %** případů, *chůze* byla správně určena v **69,57 %** případů, *běh* v **86,04 %** případů a *plavání* v **81,25 %** případů. Dalším důležitým prvkem v hodnocení modelu je v kolika procentech případů typ chování přiřazený modelem skutečně odpovídalo danému typu chování. **87,36 %** modelem predikovaného *ležení* bylo skutečně *ležení*, **56,77 %** predikovaného *stání* bylo skutečně *stání*, **72,44 %** predikované *chůze* byla skutečně *chůze*, **86,04 %** predikovaného *běhu* bylo skutečně *běh* a modelem predikované *plavání* bylo skutečně *plaváním* v **69,07 %**. Přitom *plavání* bylo nejčastěji zaměňováno za *chůzi*, stejně tak jako *běh*. *Ležení* bylo nejčastěji zaměňováno za *stání*. Mezi těmito chybami lze nalézt i jistou reciprocitu. Například u *stání*, které bylo nejčastěji zaměňováno za *chůzi* přibližně v tolika případech jako byla *chůze* zaměněna za *stání* (Tab. 1).

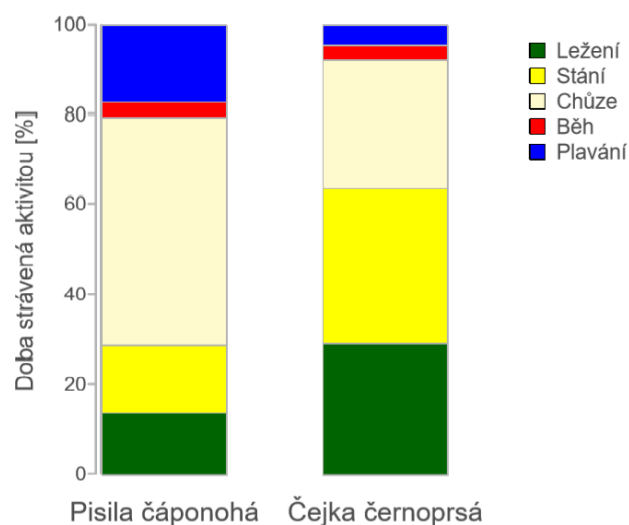


	Ležení	Běh	Stání	Plavání	Chůze
Ležení	<b>1.75</b>	0.00	0.14	0.00	0.12
Běh	0.02	<b>6.12</b>	0.9	0.09	3.00
Stání	0.21	0.05	<b>14.04</b>	0.39	10.05
Plavání	0.02	0.00	0.76	<b>8.41</b>	2.98
Chůze	0.07	0.95	11.57	1.45	<b>36.91</b>

Tab. 1: Relativní konfusní matice výsledného modelu. Sloupce představují reálné stavy, zatímco řádky jsou stavy fitované modelem a tučně zvýrazněné prvky na diagonále jsou správně detekované stavy. Součet celé matice dává dohromady 1 (100 %).


## 4.2 Denní patrnosti v chování

S využitím skrytého Markovova modelu bylo na základě akcelerometrických dat rozpoznáváno 5 typů chování: *ležení, stání, chůze, běh a plavání*. Rozložení aktivit během dne, stejně jako jejich procentuální zastoupení, se mezi studovanými druhy prokazatelně lišilo (Tab. 2). Kuřata pisily čáponohé v porovnání s kuřaty čejky černoprsé byla celkově aktivnější. Daleko méně času trávila stáním (až o 18 %) a ležením (až o 15 %). Naproti tomu v průměru o 11,6 % více času strávila plaváním a také chůzí trávila o 22 % více času. Doba, kterou v průměru strávila kuřata během byla srovnatelná pro oba druhy, tedy okolo 3,5 % (Obr. 8).



Obr. 8: Celkové rozdělení aktivit v závislosti na druhu

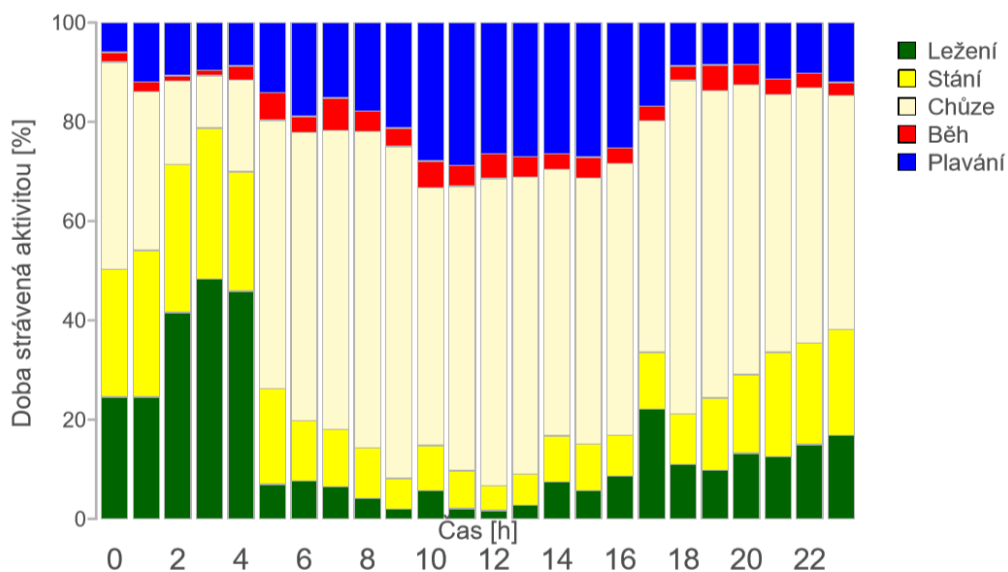
Rovněž rozložení aktivity během dne se u obou druhů značně lišilo (Obr. 9 – 10). U čejky černoprse nastává výrazný zlom v aktivitě okolo 7. hodiny ranní, což přibližně odpovídá východu slunce. V tuto hodinu klesla doba strávená *ležením* na pouhých 10 % a naproti tomu čas strávený *chůzí* se téměř zdvojnásobil, až na 40 % z celkové hodiny. Vzrostl i čas, který kuřata strávila *plaváním*, přibližně na 10 %. Během dne jsou kuřata relativně aktivní a většinu času tráví *chůzí* nebo *stáním*. Druhý výraznější zlom v aktivitě pak nastává mezi 19. – 20. hodinou, tedy přibližně po západu slunce. Po 20. hodině se aktivita opět snižovala a čas trávený *ležením* vzrostl až na 50 % z celkové hodiny (Obr. 9).



Obr. 9: Rozložení aktivity během dne u kuřat čejky černoprse (*Vanellus indicus*)

U kuřat pisily čáponohé je výrazný zlom v aktivitě již mezi 4. a 5. hodinou ranní. Již od 5. hodiny ranní byla kuřata velmi aktivní, přičemž nejčastější aktivitou byla *chůze*, kterou trávila v průměru až 60 % času. Přes poledne věnovala *ležení* jen minimum času (přibližně 2 %), zato vzrostla doba strávená *plaváním* téměř na 30 %. Výraznější zlom v aktivitě ve večerní hodinách u pisil nenastává, až kolem půlnoci vzrostla doba strávená *ležením* (v průměru na 25 %) (Obr. 10).

Při porovnání procentuálního rozložení aktivit u jednotlivých kuřat nebyly pozorovány žádné významné rozdíly mezi mladšími a staršími jedinci (viz kapitola 7. Přílohy, Obr. 15 a 16).



Obr. 10: Rozložení aktivity během dne u kuřat pisily čáponohé (*Himantopus himantopus*)

### 4.3 Patrnosti v zastoupení jednotlivých typů chování

#### *Ležení*

Kuřata pisily čáponohé trávila ležením v průměru pouze 14 % celkového času, zatímco kuřata čejky černoprsé v průměru 29 %, tedy v průměru až o 15 % času více (Obr. 8). Proporce času věnovaného ležení byla signifikantně ovlivněna časem, druhem a teplotou. Přičemž teplota proporcí tohoto času zvyšuje (Estimate = 0.042, 95 % CrI 0.014 – 0.071) (Tab. 2).

#### *Stání*

V průměru čejčí kuřata strávila stáním 34 %, ve srovnání s pisilami celkově o 18 % více (Obr. 8). Proporce času, kterou kuřata věnovala stání byla signifikantně ovlivněna denní dobou a druhem (Tab. 2), přičemž čejky stály více během dne, naproti tomu pisily trávily čas stáním spíše v noci (Obr. 11).

#### *Chůze*

Chůze tvořila převážnou většinu (51 %) z celkové aktivity kuřat pisily, zatímco kuřata čejky trávila chůzi jen 29 % celkového času (Obr. 8). Proporce času věnovaného chůzi byla signifikantně ovlivněna pouze druhem a denní dobou (Tab. 2). Přičemž nejaktivnější byla kuřata okolo 13. hodiny (Obr. 11).

## Běh

Čas, který kuřata v průměru strávila běháním byl pro oba druhy téměř stejný (čejka 3,2 %, pisily 3,6 %). Zabírá tak jen malé procento celkové aktivity. Proporce času věnovaná běhu byla signifikantně ovlivněna denní dobou a teplotou, přičemž teplota proporce tohoto času snižuje, jinými slovy s rostoucí teplotou kuřata běhala méně (Estimate = -0,018, 95 % CrI -0.023 – -0.014) (Tab. 2).

## Plavání

Kuřata čejek v průměru strávila plaváním 4,5 % celkového času, naproti tomu kuřata pisily trávila plaváním až 17 % celkového času, tedy o 12,5 % více (Obr. 8). Proporce času věnovaného plavání byla signifikantně ovlivněna druhem, denní dobou a teplotou (Tab. 2), přičemž oba druhy byly v plavání nejaktivnější okolo 12. hodiny (Obr. 11).

<b>a) Proporce času věnovaná ležení</b>					
Vysvětlovaná proměnná	Typ efektu	Efekt	95% CrI		
			Estimate	Lower	Upper
Ležení	Pevný	<b>Intercept</b>	<b>0.110</b>	<b>0.048</b>	<b>0.175</b>
		<b>Druh (hh)</b>	<b>0.150</b>	<b>0.081</b>	<b>0.216</b>
		Sin (24 hodin)	0.022	-0.042	0.085
		<b>Cos (24 hodin)</b>	<b>0.209</b>	<b>0.140</b>	<b>0.282</b>
		Váha	-0.015	-0.037	0.007
		<b>Teplota</b>	<b>0.042</b>	<b>0.014</b>	<b>0.071</b>
		Druh : sin (24 hodin)	0.054	-0.016	0.124
		<b>Druh : cos (24 hodin)</b>	<b>0.091</b>	<b>0.023</b>	<b>0.161</b>
		Sin (24 hodin) : Váha	-0.003	-0.025	0.019
		<b>Cos (24 hodin) : Váha</b>	<b>-0.025</b>	<b>-0.048</b>	<b>-0.004</b>
		<b>Sin (24 hodin) : Teplota</b>	<b>-0.049</b>	<b>-0.067</b>	<b>-0.030</b>
		<b>Cos (24 hodin) : Teplota</b>	<b>-0.04</b>	<b>-0.065</b>	<b>-0.014</b>
		Náhodný	Kuře (Intercept)	13 %	
	Sin (24 hodin)		10 %		
Cos (24 hodin)	9 %				
Residual	67%				

<b>b) Proporce času věnovaná stání</b>					
Vysvětlovaná	Typ efektu	Efekt	95% CrI		
			Estimate	Lower	Upper
Stání	Pevný	<b>Intercept</b>	<b>0.137</b>	<b>0.08</b>	<b>0.195</b>
		<b>Druh (hh)</b>	<b>0.21</b>	<b>0.147</b>	<b>0.270</b>
		<b>Sin (24 hodin)</b>	<b>0.047</b>	<b>0.007</b>	<b>0.087</b>
		<b>Cos (24 hodin)</b>	<b>0.085</b>	<b>0.015</b>	<b>0.156</b>

	Váha	0.021	-0.001	0.041
	Teplota	-0.01	-0.031	0.011
	<b>Druh : sin (24 hodin)</b>	<b>-0.076</b>	<b>-0.119</b>	<b>-0.034</b>
	<b>Druh : cos (24 hodin)</b>	<b>-0.122</b>	<b>-0.195</b>	<b>-0.05</b>
	<b>Sin (24 hodin) : Váha</b>	<b>-0.03</b>	<b>-0.044</b>	<b>-0.016</b>
	Cos (24 hodin) : Váha	0.009	-0.014	0.034
	Sin (24 hodin) : Teplota	0.004	-0.01	0.017
	Cos (24 hodin) : Teplota	-0.009	-0.029	0.010
Náhodný	Kuře (Intercept)	19%		
	Sin (24 hodin)	4%		
	Cos (24 hodin)	23%		
	Residual	54%		

**c) Proporce času věnovaná chůzi**


Vysvětlovaná proměnná	Typ efektu	Efekt	95% CrI			
			Estimate	Lower	Upper	
Chůze	Pevný	<b>Intercept</b>	<b>0.527</b>	<b>0.463</b>	<b>0.589</b>	
		<b>Druh (hh)</b>	<b>-0.216</b>	<b>-0.286</b>	<b>-0.144</b>	
		<b>Sin (24 hodin)</b>	<b>-0.069</b>	<b>-0.118</b>	<b>-0.018</b>	
		<b>Cos (24 hodin)</b>	<b>-0.145</b>	<b>-0.204</b>	<b>-0.083</b>	
		Váha	0.004	-0.019	0.027	
		Teplota	0.002	-0.017	0.022	
		Druh : sin (24 hodin)	0.033	-0.021	0.088	
		Druh : cos (24 hodin)	-0.056	-0.116	0.004	
		<b>Sin (24 hodin) : Váha</b>	<b>0.028</b>	<b>0.01</b>	<b>0.045</b>	
		Cos (24 hodin) : Váha	0.014	-0.006	0.033	
		<b>Sin (24 hodin) : Teplota</b>	<b>0.049</b>	<b>0.036</b>	<b>0.063</b>	
		<b>Cos (24 hodin) : Teplota</b>	<b>0.042</b>	<b>0.025</b>	<b>0.058</b>	
		Náhodný	Kuře (Intercept)	25%		
			Sin (24 hodin)	9%		
			Cos (24 hodin)	15%		
Residual	51%					

**d) Proporce času věnovaná běhu**

Vysvětlovaná proměnná	Typ efektu	Efekt	95% CrI			
			Estimate	Lower	Upper	
Běh	Pevný	<b>Intercept</b>	<b>0.047</b>	<b>0.037</b>	<b>0.058</b>	
		Druh (hh)	-0.008	-0.019	0.003	
		Sin (24 hodin)	0.003	-0.01	0.014	
		<b>Cos (24 hodin)</b>	<b>-0.047</b>	<b>-0.059</b>	<b>-0.035</b>	
		Váha	-0.002	-0.006	0.002	
		<b>Teplota</b>	<b>-0.018</b>	<b>-0.023</b>	<b>-0.014</b>	
		Druh : sin (24 hodin)	-0.008	-0.021	0.006	
		Druh : cos (24 hodin)	0.011	0	0.023	
		Sin (24 hodin) : Váha	0.003	-0.001	0.007	
		<b>Cos (24 hodin) : Váha</b>	<b>0.007</b>	<b>0.003</b>	<b>0.011</b>	
		<b>Sin (24 hodin) : Teplota</b>	<b>0.005</b>	<b>0.001</b>	<b>0.009</b>	
		<b>Cos (24 hodin) : Teplota</b>	<b>0.01</b>	<b>0.006</b>	<b>0.014</b>	
		Náhodný	Kuře (Intercept)	10%		
			Sin (24 hodin)	9%		
			Cos (24 hodin)	7%		

			Residual	74%			
<b>e) Proporce času věnovaná plavání</b>							
			95% CrI				
Vysvětlovaná proměnná	Typ efektu	Efekt	Estimate	Lower	Upper		
Plavání	Pevný	<b>Intercept</b>	<b>0.174</b>	<b>0.144</b>	<b>0.204</b>		
		<b>Druh (hh)</b>	<b>-0.126</b>	<b>-0.159</b>	<b>-</b>		
		Sin (24 hodin)	-0.005	-0.024	0.016		
		<b>Cos (24 hodin)</b>	<b>-0.115</b>	<b>-0.142</b>	<b>-0.087</b>		
		Váha	-0.003	-0.014	0.008		
		<b>Teplota</b>	<b>-0.023</b>	<b>-0.031</b>	<b>-0.016</b>		
		Druh : sin (24 hodin)	-0.003	-0.025	0.019		
		<b>Druh : cos (24 hodin)</b>	<b>0.077</b>	<b>0.049</b>	<b>0.105</b>		
		Sin (24 hodin) : Váha	0.004	-0.003	0.01		
		Cos (24 hodin) : Váha	-0.003	-0.012	0.007		
		<b>Sin (24 hodin) : Teplota</b>	<b>-0.007</b>	<b>-0.012</b>	<b>-0.001</b>		
		Cos (24 hodin) : Teplota	0.004	-0.002	0.011		
		Náhodný	Kuře (Intercept)	31%			
			Sin (24 hodin)	7%			
Cos (24 hodin)	19%						
Residual	44%						

Tab. 2: Posteriorní odhady (mediány) velikosti efektu s 95% Bayesovskými intervaly věrohodnosti (95% CrI) z posteriorní distribuce 5000 simulovaných hodnot funkcí „sin“ v R (Gelman et al. 2016). Byly využity lineární smíšené modely (funkce „lmer“) (Bates et al. 2015). Čas představoval „hodinu ze dne“ a byl převeden na radiány a upraven jako sinus a cosinus radiánů. Odhady, jejichž 95% CI neobsahují 0 jsou tučně zvýrazněny. Jako vysvětlované proměnné byly zvoleny: a) proporce času věnovaná ležení b) proporce času věnovaná stání c) proporce času věnovaná chůzi d) proporce času věnovaná běhu e) proporce času věnována plavání.



Obr. 11: Graf zobrazující časové rozložení jednotlivých aktivit během dne v závislosti na druhu. Křivky se stínovanými oblastmi představují predikce modelu (Tab. 2) s 95 % intervaly věrohodnosti založené na posteriorním rozdělení 5 000 simulovaných hodnot generovaných funkcí „sim“ v R (Gelman et al. 2016). a) Proporce času věnovaná ležení b) proporce času věnovaná stání c) proporce času věnovaná chůzi d) proporce času věnovaná běhu e) proporce času věnovaná plavání

## 5. Diskuze

Na základě dat získaných z 95 multisenzorických dataloggerů, zaznamenávajících chování 82 jedinců kuřat čejky černoprsé a 13 jedinců kuřat pisily čáponohé byly popsány základní patrnosti v jejich aktivitách. Byly zjištěny významné rozdíly mezi studovanými druhy, a to jak v rozložení daných aktivit během dne, tak také v jejich souhrnném procentuálním zastoupení. Čejčí kuřata byla celkově méně aktivní a neaktivitou (ležením a stáním) strávila až o 26 % celkového času více v porovnání s kuřaty pisil. Přičemž výrazný nárůst aktivity byl u mláďat čejek zaznamenán okolo 7. hodiny ránní, zatímco u mláďat pisil již o dvě hodiny dříve.

### 5.1 Hodnocení použitého modelu

Použitý HMM je výpočetně komplexní model, jehož využití při klasifikaci chování u zvířat v posledních letech narůstá (Norris 2019; Wang 2019) a pro vyhodnocení akcelerometrických dat a klasifikaci chování byl využit i v této práci.

Při hodnocení výsledného modelu je důležité posouzení nejen procenta veškeré vysvětlené aktivity, ale také vyrovnanost pravděpodobnostních odhadů (Norris 2019). Model s vysokým procentem vysvětlené veškeré aktivity může mít správně přiřazený pouze jeden typ chování a v ostatních naprosto chybovat, zatímco model s nižším procentem vysvětlené veškeré aktivity může mít nadpoloviční úspěšnost přiřazení u všech typů chování, takovýto model je vždy hodnocen jako lepší. Z tohoto důvodu byl jako vítězný model v této práci zvolen procentuálně až druhý nejlepší, jehož pravděpodobnostní odhady jednotlivých stavů byly mnohem vyrovnanější. Pro hodnocení těchto modelů však bude potřeba do budoucna stanovit jasná pravidla.

Výsledný model vysvětlil 67,23 % veškeré aktivity, tedy ji přiřadil ke správnému typu chování. Obdobného výsledku (70 %) dosáhli například i při vyhodnocování typů letu u supy bělohlavého (*Gyps fulvus*) na základě telemetrických dat (Khosravifard et al. 2018). Avšak modely u prací na klasifikaci typů chování či rozpoznávání řeči u lidí dosahují 77,8 % – 86 % (Schuller et al. 2003; Mannini & Sabatini 2011). To souvisí s faktem, že lidé mohou být pro potřeby získání tréninkových dat, na rozdíl od divoce žijících zvířat, snadno monitorováni, a to jak v prostředí laboratoře, tak také v reálnějších situacích jako je například chůze doma



či venku (Leenders et al. 2000). Jednou z věcí, jak do budoucna zlepšit výsledný model je tedy poskytnutí obsáhlejšího trénovacího datasetu.

Zvolený model ve 32,77 % nesprávně přiřadil typ chování, avšak při jejich záměně docházelo k jisté reciprocitě, kdy bylo například stání zaměňováno za chůzi, a naopak chůze za stání. To by mohlo být způsobeno tím, že pořízená videa byla analyzována na desetinu sekundy přesně, ale výsledky z těchto videí byly poté sumarizovány po sekundách, přičemž chování převažující v dané sekundě bylo zvoleno jako určující. Takže v sekundě, ve které byl zaznamenán přechod například mezi stáním a chůzí bylo nutné vybrat vždy jen jeden typ chování, a to ten převládající. Nicméně bezpochyby je i řada chování modelem určena špatně. A to nejspíše ty typy chování, které se v krátkém časovém úseku rychle střídají nebo mají snadno zaměnitelné výstupy z akcelerometrů, což potvrzují i práce jiných autorů (Khosravifard et al. 2018).

Původní plán zahrnoval analýzu dalších behaviorálních projevů: krmení, čištění a zahřívání rodiči. Avšak trénované modely těžko odlišovaly krmení od chůze a čištění a zahřívání rodiči od stání. Díky tomu byly tyto pro finální model snadno zaměnitelné typy chování sloučeny. Nicméně zahřívání rodiči bude pravděpodobně možné odlišit zvláštním modelem s kombinací akcelerace a intenzity světla ve dne či teploty během noci. Obdobně, ale s využitím VeDBA a ekvivalentních metrik získaných z magnetometru (například úhlová rychlost koule „*m-sphere*“), jenž je citlivý na jakékoliv rotační pohyby, by mohlo být rozeznatelné i jednotlivé zobání kuřat (Williams et al. 2017).

## 5.2 Denní patrnosti v chování

Celkově bylo dataloggery úspěšně vybaveno 95 kuřat, přičemž většinu jedinců ( $n = 83$ ) představovala mláďata čejky černoprsé a pouze třináct jedinců zastupovalo pisilu čáponohou. Nicméně i přes to, že vzorek pro srovnání těchto druhů je nevyrovnaný, lze vidět rozdíly v čase věnovaném jednotlivým typům chování, tak i jejich rozložení během dne.

Obecně byla kuřata pisily čáponohé aktivnější a chůzí a plaváním trávila prokazatelně více času než kuřata čejky černoprsé. Zajímavý je také fakt, že začala být hodně aktivní již okolo 5. hodiny ráno, tedy ještě před východem slunce.

Avšak opětovný výrazný pokles aktivity již tolik patrný není. Naproti tomu u kuřat čejky černoprse přišel viditelný nárůst aktivity až okolo 7. hodiny ranní, přičemž okolo 20. hodiny večer aktivita opět výrazně klesala. Časový interval s vysokou mírou aktivity, tak zabíral pouze 13 hodin (7. hod. – 20. hod). Jednou z možností, jak na uvedené rozdíly nahlížet je přes původ druhů. Čejka černoprse představuje subtropický druh, u nichž byl zjištěn pomalejší růst, nižší míra aktivity během dne a také pomalejší metabolismus ve srovnání s druhy temperátní zóny (Tjørve et al. 2008; Wiersma et al. 2007), což by mohlo vysvětlit kratší časový úsek aktivity během dne. Menší denní energetický výdej a nižší bazální metabolismus může vést k minimalizaci ztrát vody a snížení produkce vnitřního tepla (Tjørve et al. 2008). Tato kombinace představuje přizpůsobení na subtropické klima (Schekkerman et al. 2003; Tjørve et al. 2008), které by mohlo vysvětlovat korespondující aktivitu s teplotou. Nicméně je pak zarážející fakt, že u kuřat pisily, jakožto představitele kosmopolitního druhu, nedocházelo ani během nejvyšších teplot k poklesu aktivity, který by byl předpokládán. Obecně je však pisila čáponohá považována za odolný druh, který dokáže bez problému odolávat vysokým teplotám a přímému slunci (del Hoyo et al. 1996) a je schopný zahnídit i v extrémním a relativně nestálém prostředí (Adamou et al. 2009).

Během dne tráví mláďata také čas u vody, kde hledají potravu a využívají brodění ke zvládnutí teplotního stresu (Grant 1982). Čas strávený plaváním byl však mezi druhy rozdílný. Obecně kuřata pisily plavala o 11 % více, což jistě souvisí i s prostorovou distribucí modelových druhů. Pisily se po většinu dne pohybují v blízkosti vody, zatímco čejky se vzdalují a odvádí i mláďata od vody relativně daleko. Nejvyšší míra plavání byla u pisil zaznamenána mezi 10. – 11. hodinou. Naproti tomu u čejek byl čas věnovaný plavání během dne relativně vyrovnaný, přičemž nárůst doby strávené plaváním koreluje s nárůstem aktivity, což může souviset s převáděním mláďat z ostrovů na pevninu.

Čejčí kuřata ve srovnání s pisilami také trávila během dne více času ležením, jenž může představovat odpočinek, ale rovněž antipredační chování, při kterém především mladší kuřata setrvávají v leže na místě a spoléhají na kryptické zbarvení (Colwell et al. 2007). Obecně interpretace zaznamenaných typů chování nemusí být jednoznačná. Mimo ležení může být příkladem i potravní chování, které se bude skládat ze sekvence krátkých úseků stání a chůze. Právě chůze tvořila převážnou

většinu (až 51 %) z celkové aktivity kuřat pisil. To by opět mohlo souviset s původem druhů. Kuřata kosmopolitní pisily, mají rychlejší růst a s tím i větší nároky na potravu. Většinu času tak nejspíše budou muset strávit krmením a hledáním potravy. Zajímavým rozdílem mezi studovanými druhy byl také průkazný vliv denní doby na stání. Čejčí kuřata stála více během dne, zatímco kuřata pisil trávila stáním spíše noc. Dá se tedy předpokládat, že kuřata čejek odpočívají více ležením, zatímco pisily spíše stojí.

Všechna kuřata byla před nasazením dataloggeru zvážena. Jednak byla stanovena minimální hmotnost kuřete, které mohlo nést datalogger na 14 g, ale také váha jednotlivých jedinců reprezentovala jejich věk. S přibývajícím věkem klesá celková závislost na rodičích. Zlepšuje se termoregulace a tím se snižuje i potřeba zahřívání, případně stínění rodiči (Schekkerman & Boele 2009). S věkem se mění i antipredační chování a v případě nebezpečí již mláďata aktivně utíkají (Colwell et al. 2007). Z těchto poznatků by se dalo předpokládat, že se s věkem bude měnit i procentuální rozložení aktivit, nicméně v této práci signifikantní vliv věku kuřete prokázán nebyl. Jedním z vysvětlení by mohl být fakt, že kuřata nejsou tolik omezena nízkou teplotou jako severnější druhy (Beintema & Visser 1989b, Schekkerman et al. 1998), takže se po celou dobu vývoje mohou v dostatečné míře věnovat hledáním potravy i ostatním aktivitám. Významný vliv věku kuřete na změnu v procentuálním zastoupení jednotlivých aktivit sice prokázán nebyl, nicméně u některých typů chování byla prokázána interakce s denní dobou. Z toho by se dalo usuzovat, že starší kuřata se v průměru chovají stejně, ale mají aktivitu během dne rovnoměrněji rozloženou.

Do budoucna by se měla práce soustředit na zlepšení modelu a jeho schopnosti vysvětlit procentuálně větší část veškeré aktivity a také se zaměřit na rozlišení více typů chování (například zahřívání rodiči, krmení apod.) s využitím dalších metrik, které multisenzorický datalogger nabízí (magnetometr, intenzita světla, vlhkost). HMM je relativně jednoduchý model pro učení sekvenčních dat, nicméně se složitějším rozsahem činností se stává méně efektivním. V souvislosti s tím by bylo vhodné se v budoucnu zaměřit i na rozšířené skryté Markovovy modely. Těmi by mohly být: skrytý semiMarkovův model (HSMM), případně hierarchický skrytý Markovův model (HHMM) (Duong et al. 2005).

## 6. Závěr

Za posledních několik let se, také díky miniaturizaci elektroniky, dálkový monitoring zvířat a identifikace jejich chování pomocí měření akcelerace posunula ohromným krokem kupředu. Přestože se akcelerometry již několik desítek let využívají v biomonitoringu a měření aktivit u lidí, k vyhodnocování aktivity a klasifikování chování zvířat nachází uplatnění až od konce 90. let.

Tato práce přináší první výsledky ze studia kuřat subtropické čejky černoprásé a kosmopolitně rozšířené pisily čáponohé pomocí multisenzorických dataloggerů z chráněné pouštní rezervace Al Marmoom v Dubaji. S použitím multisenzorických dataloggerů vyvinutých týmem behaviorální ekologie bylo získáno dostatek dat pro hodnocení jejich aktivity v průběhu dne. Na základě těchto dat a pořízených video záznamů bylo rozpoznáváno 5 základních typů chování. Hlavní část výsledků se věnuje popisu rytmicity a diverzity těchto typů chování v průběhu dne a jejich srovnání mezi oběma druhy.

Výsledky této práce přinesly nové poznatky o kuřatech modelových druhů a ověření možnosti využití strojového učení a skrytého Markovova modelu při zpracování a vyhodnocování dat z akcelerometrů. Studium prekociálních mláďat s využitím multisenzorických dataloggerů je však na začátku a přináší obrovský potenciál ve výzkumu aktivity a chování u široké škály druhů.

## 7. Literatura

- Adamou A. E., Kouidri M., Chabi Y., Skwarska J., Bańbura J., 2009. Egg size variation and breeding characteristics of the Black-winged stilt *Himantopus Himantopus* in a Saharan Oasis. *Acta Ornithologica* 44(1): 1–7.
- Ashoori A., 2011. Breeding ecology of the Black-winged stilt *Himantopus Himantopus* in Boujagh National Park, Gilan Province, Northern Iran. *Podoces* 6(1): 87–91.
- Bates D., Mächler M., Bolker B. M., Walker S. C., 2015. Fitting linear mixed-effects models using Lme4. *Journal of Statistical Software* 67(1): 1–48.
- Beintema A. J. & Visser G. H., 1989a. Growth parameters in chicks of Charadriiform birds. *Ardea* 77(2): 169–80.
- Beintema A. J. & Visser G. H., 1989b. The effect of weather on time budgets and development of chicks of meadow birds. *ARDEA* 77(2): 181–92.
- Bieber G., Haescher M., Vahl M., 2013. Sensor requirements for activity recognition on smart watches. IN *Proceedings of the 6th International Conference on Pervasive Technologies Related to Assistive Environments*.
- BirdLife International 2016. *Himantopus himantopus*. The IUCN Red List of Threatened Species 2016: (online) [cit. 4.2.2020] Dostupné na: <https://dx.doi.org/10.2305/IUCN.UK.2016-3.RLTS.T22727969A86541570.en>.
- BirdLife International 2016. *Vanellus indicus*. The IUCN Red List of Threatened Species 2016: (online) [cit. 25.1.2018] Dostupné na: <https://dx.doi.org/10.2305/IUCN.UK.2016-3.RLTS.T22694013A89569039.en>
- Brewster L. R., Dale J. J., Guttridge T. L., Gruber S. H., Hansell A. C., Elliott M., Cowx I. G., Whitney N. M., Gleiss A. C., 2018. Development and application of a machine learning algorithm for classification of elasmobranch behaviour from accelerometry data. *Marine Biology* 165(4): 62.
- Brischoux F., Kato A., Ropert-Coudert Y., Shine R., 2010. Swimming speed variation in amphibious seasnakes (Laticaudinae): A search for underlying mechanisms. *Journal of Experimental Marine Biology and Ecology* 394: 116–22.

- Brown D. D., Kays R., Wikelski M., Wilson R., Klimley A. P., 2013. Observing the unwatchable through acceleration logging of animal behavior. *Animal Biotelemetry* 1(20): 1–16.
- Burger J. & Gochfeld M., 1991. Human activity influence and diurnal and nocturnal foraging of sanderlings (*Calidris Alba*). *The Condor* 93(2): 259–65.
- Cagnacci F., Boitani L., Powell R. A., Boyce M. S., 2010. Animal ecology meets GPS-based radiotelemetry: A perfect storm of opportunities and challenges. *Philosophical Transactions of the Royal Society B* 365: 2157–62.
- Chen K. H., Chen P. C., Liu K. C., Chan C. T., 2015. Wearable sensor-based rehabilitation exercise assessment for knee osteoarthritis. *Sensors* 15: 4193–4211.
- Colwell M. A., Hurley S. J., Hall J. N., Dinsmore S. J., 2007. Age-related survival and behavior of Snowy plover chicks. *The Condor* 109: 638–47.
- Cuervo J. J., 2003. Parental roles and mating system in the Black-winged stilt. *Canadian Journal of Zoology* 81: 947–53.
- Cuervo J. J., 2004. Nest-site selection and characteristics in a mixed-species colony of Avocets *Recurvirostra Avosetta* and Black-winged stilts *Himantopus Himantopus*. *Bird Study* 51: 20–24.
- del Hoyo J., Elliott A., Sargatal J., 1996. Handbook of the Birds of the World, vol. 3: Hoatzin to Auks. Lynx Edicions, Barcelona, Spain
- Dhandhukia S. N. & Patel K. B., 2015. Growth of various morphometric parameters of Red-wattled lapwing (*Vanellus indicus*) at Junagadh City, Gujarat. *Zoology* 4(10): 131–32.
- Dostine P. L. & Morton S. R., 1989. Food of the Black-winged stilt *Himantopus Himantopus* in the Alligator Rivers region, Northern Territory. *Emu* 89: 250–53.
- Duong T. V., Bui H. H., Phung D. Q., Venkatesh S., 2005. Activity recognition and abnormality detection with the switching hidden semi-Markov model. IN *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*. IEEE 1:838-845.

- Elliott K. H., Le Vaillant M., Kato A., Speakman J. R., Ropert-Coudert Y., 2013. Accelerometry predicts daily energy expenditure in a bird with high activity levels. *Biology Letters* 9: 1–4.
- Enstipp M. R., Ciccione S., Gineste B., Milbergue M., Ballorain K., Ropert-Coudert Y., Kato A., Plot V., Georges J. Y., 2011. Energy expenditure of freely swimming adult Green turtles (*Chelonia Mydas*) and its link with body acceleration. *The Journal of Experimental Biology* 214: 4010–20.
- Erkert H. G. & Kappeler P. M., 2004. Arrived in the light: Diel and seasonal activity patterns in wild Verreaux's sifakas (*Propithecus v. Verreauxi*; primates: Indriidae). *Behavioral Ecology and Sociobiology* 57: 174–86.
- Fahlman A., Wilson R., Svärd C., Rosen D. A. S., Trites A. W., 2008. Activity and diving metabolism correlate in Steller sea lion *Eumetopias jubatus*. *Aquatic Biology* 2: 75–84.
- Fasola M. & Biddau L., 1997. An assemblage of wintering waders in Coastal Kenya: Activity budget and habitat use. *African Journal of Ecology* 35: 339–50.
- Foerster F., Smeja M., Fahrenberg J., 1999. Detection of posture and motion by accelerometry: A validation study in ambulatory monitoring. *Computers in Human Behavior* 15: 571–83.
- Friard O. & Gamba M., 2016: BORIS: a free, versatile open-source event-logging software for video/audio coding and live observations. *Methods in Ecology and Evolution*. 7 11. 1325–1330.
- Frost J. D., 1978. Triaxial vector accelerometry: A method for quantifying tremor and ataxia. *IEEE Transactions on Biomedical Engineering* 25(1).
- Gelman A., Su Y. S., Yajima M., Hill J., Pittau M. G., Kerman J., Zheng T., Dorie V., 2016. Data analysis using regression and multilevel/hierarchical models. *CRAN Repository*.
- Ghahramani Z., 2001. An introduction to hidden Markov models and Bayesian networks. *International Journal of Pattern Recognition and Artificial Intelligence* 15(1): 9–42.
- Grant G. S., 1982. Avian incubation: Egg temperature, nest humidity and behavioral thermoregulation in hot environment. *Ornithological Monographs* 30.

- Halsey L. G., Portugal S. J., Smith J. A., Murn C. P., Wilson R. P., 2009. Recording raptor behavior on the wing via accelerometry. *Journal of Field Ornithology* 80(2): 171–77.
- Halsey L. G. & White C. R., 2010. Measuring energetics and behaviour using accelerometry in Cane toads *Bufo Marinus*. *PLoS ONE* 5(4): e10170.
- Halsey L. G., Shepard E. L. C., Quintana F., Laich A. G., Green J. A., Wilson R. P., 2009. The relationship between oxygen consumption and body acceleration in a range of species. *Comparative Biochemistry and Physiology, Part A* 152: 197–202.
- Han S., 2010. Measuring displacement signal with an accelerometer. *Journal of Mechanical Science and Technology* 24(6): 1329–35.
- Hart K. M. & Hyrenbach K. D., 2009. Satellite telemetry of marine megavertebrates: The coming of age of an experimental science. *Endangered Species Research* 10: 9–20.
- He W., Jia C., Zou Q., 2019. 4mCPred: Machine learning methods for DNA N4-methylcytosine sites prediction. *Bioinformatics* 35(4): 593–601.
- van Hees V., Fang Z., Langford J., Assah F., Mohammad A., da Silva I. C. M., Trenell M. I., White T., Wareham N. J., Brage S., 2014. Autocalibration of accelerometer data for free-living physical activity assessment using local gravity and temperature: An evaluation on four continents. *Journal of Applied Physiology* 117: 738–44.
- Hötker H., 1999. What determines the time-activity budgets of Avocets (*Recurvirostra Avosetta*)? *Journal of Ornithology* 140: 57–71.
- Isbell L. A. & Young T. P., 1993. Human presence reduces predation in a free-ranging Vervet monkey population in Kenya. *Animal Behaviour* 45: 1233–35.
- Kalsi R. S. & Khera S., 1990. Growth and development of the Red-wattled lapwing *Vanellus indicus*. *The Stilt* 17: 57–64.
- Kappeler P. M. & Erkert H. G., 2003. On the move around the clock: Correlates and determinants of cathemeral activity in wild Redfronted lemurs (*Eulemur Fulvus Rufu*). *Behavioral Ecology and Sociobiology* 54: 359–69.



- Kays R., Jansen P. A., Knecht E. M. H., Vohwinkel R., Wikelski M., 2011. The effect of feeding time on dispersal of *Virola* seeds by toucans determined from GPS tracking and accelerometers. *Acta Oecologica* 37: 625–31.
- Kessentini Y., Paquet T., Benhamadou A., 2010. Off-line handwritten word recognition using multi-stream hidden Markov models. *Pattern Recognition Letters, Elsevier* 31(1): 60–70.
- Khalil S., Hussain T., Anwar M., Rafay M., Abdullah M., Khalid M., Tariq M., Sarwar S., Tabish R., Ashraf I., 2019. Breeding biology of Red-wattled lapwing (*Vanellus indicus*) from Southern Punjab, Pakistan. *International Journal of Biodiversity and Conservation* 11(2): 78–84.
- Khosravifard. S., Venus V., Skidmore A. K., Bouten W., Mun A. R., 2018. Identification of Griffon vulture's flight types using high-resolution tracking data. *International Journal of Environmental Research* 12(3): 313–25.
- Kloubec B., Hora J. & Šťastný K. (eds.), 2015. Ptáci jižních Čech. Jihočeský kraj, České budějovice.
- Ko A. H. R., Cavalin P. R., Sabourin R., Britto A. S., 2009. Leave-one-out training and Leave-one-out testing hidden Markov models for a handwritten numeral recognizer: The implications of a single classifier and multiple classifications. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 31(12): 2168–78.
- Kooyman G. L., 2004. Genesis and evolution of bio-logging devices: 1963 – 2002. *Memoirs of National Institute of Polar Research. Special Issue* 58: 15–22.
- Krijgsveld K., Reneerkens J. W. H., McNett G. D., Ricklefs R. E., 2003. Time budgets and body temperatures of American Golden-plover chicks in relation to ambient temperature. *The Condor* 105: 268–78.
- Kwapisz J. R., Weiss G. M., Moore S. A., 2011. Activity recognition using cell phone accelerometers. *ACM SigKDD Explorations Newsletter* 12(2): 74–82.
- Laich A. G., Wilson R. P., Quintana F., Shepard E. L. C., 2008. Identification of Imperial Cormorant *Phalacrocorax Atriceps* behaviour using accelerometers. *Endangered Species Research* 10: 29–37.

- Leenders N. Y. J. M., Sherman W. M., Nagaraja H. N., 2000. Comparisons of four methods of estimating physical activity in adult women. *Medicine & Science in Sports & Exercise* 32(7): 1320–1326.
- LeMoyne R., Mastroianni T., Grundfest W., 2013. Wireless accelerometer configuration for monitoring Parkinson's disease hand tremor. *Advances in Parkinson's Disease* 2(2): 62–67.
- Leos-Barajas V., Photopoulou T., Langrock R., Patterson T. A., Watanabe Y. Y., Murgatroyd M., Papastamatiou Y. P., 2017. Analysis of animal accelerometer data using hidden Markov models. *Methods in Ecology and Evolution* 8: 161–73.
- Liu B., 2019. BioSeq-Analysis: A platform for DNA, RNA and protein sequence analysis based on machine learning approaches. *Briefings in Bioinformatics* 20(4): 1280–94.
- Mannini A. & Sabatini A. M., 2011. Accelerometry-based classification of human activities using Markov modeling. *Computational Intelligence and Neuroscience* 2011.
- Marion W. R., O'Meara T. E., Maehr D. S., 1981. Use of playback recordings in sampling elusive or secretive birds. *Studies in Avian Biology* 6(6): 81–85.
- Mark P., 2013. Tilt sensing using a three-axis accelerometer. *Freescale Semiconductor Application Note* 1: 2012–13.
- Mathie M. J., Celler B. G., Lovell N. H., Coster A. C. F., 2004. Classification of the basic daily movements using a triaxial accelerometer. *Medical and Biological Engineering and Computing* 42: 679–87.
- Message S. & Taylor D., 2005: Waders of Europe, Asia & North America. Bloomsbury Publishing PLC, London, UK.
- Morrier A. & McNeil R., 2015. Time-activity budget of Wilson's and Semipalmated plovers in a tropical environment. *The Wilson Bulletin* 103(4): 598–620.
- Mouritsen K. N., 1994. Day and night feeding in Dunlins *Calidris alpina*: Choice of habitat, foraging technique and prey. *Journal of Avian Biology* 25(1): 55–62.

- Nathan R., Spiegel O., Fortmann-Roe S., Harel R., Wikelski M., Getz W. M., 2012. Using tri-axial acceleration data to identify behavioral modes of free-ranging animals: General concepts and tools illustrated for Griffon vultures. *The Journal of Experimental Biology* 215: 986–96.
- Nice M. M., 1962. *Development of Behavior in Precocial Birds*. New York.
- Nol E., MacCulloch K., Pollock L., McKinnon L., 2014. Foraging ecology and time budgets of non-breeding shorebirds in Coastal Cuba. *Journal of Tropical Ecology* 30: 347–57.
- Norris C. E., 2019. Testing the efficacy of unsupervised machine learning techniques to Infer shark behaviour from accelerometry data. PhD Thesis, Murdoch University.
- O'Reilly K. M. & Wingfield J. C., 1995. Spring and autumn migration in Arctic shorebirds: Same distance, different strategies. *American Zoologist* 35: 222–33.
- O'Toole A. C., Murchie K. J., Pullen C., Hanson K. C., Suski C. D., Danylchuk A. J., Cooke S. J., 2010. Locomotory activity and depth distribution of adult Great barracuda (*Sphyraena Barracuda*) in Bahamian Coastal habitats determined using acceleration and pressure biotelemetry transmitters. *Marine and Freshwater Research* 61: 1446–56.
- Okuno R., Yokoe M., Fukawa K., Sakoda S., Akazawa K., 2007. Measurement system of finger-tapping contact force for quantitative diagnosis of Parkinson's disease. IN *Proceedings of the 29th Annual International Conference of the IEEE EMBS*.
- de Passillé A. M., Jensen M. B., Chapinal N., Rushen J., 2010. Technical note: Use of accelerometers to describe gait patterns in dairy calves. *Journal of Dairy Science* 93: 3287–93.
- Picozzi N., Moss R., Kortland K., 1999. Diet and survival of Capercaillie *Tetrao Urogallus* chicks in Scotland. *Wildlife Biology* 5(1): 11–23.
- Přikryl K., 2008. Kinematika. 5. vydání. Akademické nakladatelství CERM, Brno. ČR.

- Qasem L., Cardew A., Wilson A., Griffiths I., Halsey L. G., Shepard E. L. C., Gleiss A. C., Wilson R., 2012. Tri-axial dynamic acceleration as a proxy for animal energy expenditure; should we be summing values or calculating the vector? *PLoS ONE* 7 (2): e31187.
- Rasmussen C. P. & Anderton J. C., 2005. *Birds of South Asia: The Ripley Guide*. Smithsonian Institution & Lynx Edicions, Washington, D.C., US.
- R Core Team, 2016. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria
- Ricklefs R. E., Bruning D. F., Archibald G. W., 1986. Growth rates of Cranes reared in captivity. *The Auk* 103(1): 125–34.
- Robert M., McNeil R., Leduc A., 1989. Conditions and significance of night feeding in shorebirds and other water birds in a tropical lagoon. *The Auk* 106(1): 94–101.
- Ropert-Coudert Y. & Wilson R. P., 2005. Trends and perspectives in animal-attached remote sensing. *Frontiers in Ecology and the Environment* 3(8): 437–44.
- Sakamoto K. Q., Sato K., Ishizuka M., Watanuki Y., Takahashi A., Daunt F., Wanless S., 2009. Can ethograms be automatically generated using body acceleration data from free-ranging birds? *PLoS ONE* 4(4): e5379.
- Sato K., Watanuki Y., Miller P. J. O., Tanaka H., Kawabe R., Ponganis P. J., Handrich Y., Akamatsu T., Watanabe Y., Mitani Y., Costa D. P., Bost C. A., Aoki K., Amano M., Trathan P., Shapiro A., Naito Y., 2007. Stroke frequency, but not swimming speed, is related to body size in free-ranging seabirds, Pinnipeds and Cetaceans. *Proceedings of the Royal Society* 274: 471–77.
- Saxena V. L. & Saxena A. K., 2013. The study of nidification behavior in Red-wattled lapwings, *Vanellus indicus*. *Asian Journal of Experimental Sciences* 27(2): 17–21.
- Scheibe K. M., Schleusner T., Berger A., Eichhorn K., Lamgbein J., Zotto D. L., Streich W. J., 1998. ETHOSYS (R) - New system for recording and analysis of behaviour of free-ranging domestic animals and wildlife. *Applied Animal Behaviour Science* 55: 195–211.

- Schekkerman H., Roomen M. W. J. V. A. N., Underhill L. G., 1998. Growth, behaviour of broods and weather-related variation in breeding productivity of Curlew sandpipers *Calidris Ferruginea*. *Ardea* 86(2): 153–68.
- Schekkerman H. & Visser G. H., 2001. Prefledging energy requirements in shorebirds: Energetic implications of self-feeding precocial development. *The Auk* 118(4): 944–57.
- Schekkerman H., Tulp I., Piersma T., Visser G. H., 2003. Mechanisms promoting higher growth rate in arctic than in temperate shorebirds. *Oecologia* 134: 332–42.
- Schekkerman H. & Boele A., 2009. Foraging in precocial chicks of the Black-tailed godwit *Limosa Limosa*: Vulnerability to weather and prey size. *Journal of Avian Biology* 40: 369–79.
- Schuller B., Rigoll G., Lang M., 2003. Hidden Markov model-based speech emotion recognition. IN *International Conference on Acoustics, Speech, and Signal Processing 2*.
- Sellers W. I., Varley J. S., Waters S. S., 1998. Remote monitoring of locomotion using accelerometers: A pilot study. *Folia Primatologia* 69(1): 82–85.
- Sethi V. K., Bhatt D., Kumar A., Naithani A. B., 2011. The hatching success of ground- and roof-nesting Red-wattled lapwing *Vanellus indicus* in Haridwar, India. *Forktail* 27: 7–10.
- Shalev-Shwartz S. & Ben-David S., 2014. *Understanding Machine Learning: From Theory to Algorithms*. Cambridge University Press, Cambridge, UK.
- Shepard E. L. C., Wilson R. P., Quintana F., Laich A. G., Liebsch N., Albareda D. A., Halsey L. G., Gleiss A., Morgan D. T., Myers A. E., Newman C., MacDonald D. W., 2008. Identification of animal movement patterns using tri-axial accelerometry. *Endangered Species Research* 10: 47–60.
- Suzuki I., Yasuhiko N., Folkow L., Miyazaki N., Blix A. S., 2009. Validation of a device for accurate timing of feeding events in marine animals. *Polar Biology* 32: 667–71.

- Tjørve K., Calf M., Underhill L. G., Visser G. H., 2008. The energetic implications of precocial development for three shorebird species breeding in a warm environment. *Ibis* 150: 125–38.
- Tokuda K., Nankaku Y., Toda T., Zen H., Yamagishi J., Oura K., 2013. Speech synthesis based on hidden Markov models. IN *Proceedings of the IEEE 101*.
- Tomkiewicz S. M., Fuller M. R., Kie J. G., Bates K. K., 2010. Global positioning system and associated technologies in animal behaviour and ecological research. *Philosophical Transactions of the Royal Society B* 365: 2163–76.
- Tsuda Y., Kawabe R., Tanaka H., Mitsunaga Y., Hiraishi T., Yamamoto K., Nashimoto K., 2006. Monitoring the spawning behaviour of Chum Salmon with an acceleration data logger. *Ecology of Frechfater Fish* 15: 264–74.
- Ueng Y. T., Wang J. P., Hou P. C. L., Perng J. J., 2009. Diet of Black-winged stilt chicks in coastal wetlands of southwestern Taiwan. *Waterbirds* 32(4): 514–22.
- Van de Vel A., Cuppens K., Bonroy B., Milosevic M., Van Huffel S., Vanrumste B., Lagae L., Ceulemans B., 2013. Long-term home monitoring of hypermotor seizures by patient-worn accelerometers. *Epilepsy & Behavior* 26: 118–25.
- Viviant M., Trites A. W., Rosen D. A. S., Monestiez P., Guinet C., 2010. Prey capture attempts can be detected in Steller sea lions and other marine predators using accelerometers. *Polar Biology* 33: 713–19.
- Wang G., 2019. Ecological informatics machine learning for inferring animal behavior from location and movement data. *Ecological Informatics* 49: 69–76.
- Wang Y., Nickel B., Rutishauser M., Bryce C. M., Williams T. M., Elkaim G., Wilmers C. C., 2015. Movement, resting, and attack behaviors of wild pumas are revealed by tri-axial accelerometer measurements. *Movement Ecology* 3(2): 1–12.
- Watanuki Y., Wanless S., Harris M., Lovvorn J. R., Miyazaki M., Tanaka H., Sato K., 2006. Swim speeds and stroke patterns in wing-propelled divers: A comparison among alcids and a penguin. *The Journal of Experimental Biology* 209: 1217–30.
- Wegge P. & Kastdalen L., 2007. Pattern and causes of natural mortality of Capercaillie, *Tetrao urogallus*, chicks in a fragmented boreal forest. 44: 141–51.

- Weimerskirch H., Le Corre M., Ropert-Coudert Y., Kato A., Marsac F., 2005. The three-dimensional flight of Red-footed boobies: Adaptations to foraging in a Tropical Environment? *Proceedings of the Royal Society* 272: 53–61.
- Weng S. F., Reps J., Kai J., Garibaldi J. M., Qureshi N., 2017. Can machine-learning improve cardiovascular risk prediction using routine clinical data? *PLoS ONE* 12(4): e0174944.
- Whittingham M. J., Percival S. M., Brown A. F., 1999. Notes on night-time activity of Golden plover *Pluvialis Apricaria* chicks in the North Pennines. *Bulletin-Wader Study Group* 90: 56–58.
- Wiersma P., Muñoz-Garcia A., Walker A., Williams J. B., 2007. Tropical birds have a slow pace of life. IN *Proceedings of the National Academy of Sciences*, 104.
- Williams H. J., Holton M. D., Shepard E. L. C., Largey N., Norman B., Ryan P. G., Duriez O., Scantlebury M., Quintana F., Magowan E. A., Marks N. J., Alagaili A. N., Bennett N. C., Wilson R. P., 2017. Identification of animal movement patterns using tri-axial magnetometry. *Movement Ecology* 5: 1–14.
- Wilson R. P., Liebsch N., Davies I. M., Quintana F., Weimerskirch H., Storch S., Lucke K., Siebert U., Zankl S., Müller G., Zimmer I., Scolaro A., Campagna C., Plötz J., Bornemann H., Teilmann J., McMahon C. R., 2007. All at sea with animal tracks; Methodological and analytical solutions for the resolution of movement. *Deep-Sea Research II* 54: 193–210.
- Wilson R. P., White C. R., Quintana F., Halsey L. G., Liebsch N., Martin G. R., Butler P. J., 2006. Moving towards acceleration for estimates of activity-specific metabolic rate in free-living animals: The case of the Cormorant. *Journal of Animal Ecology* 75: 1081–90.
- Yasué M., 2005. The effects of human presence, flock size and prey density on shorebird foraging rates. *Journal of Ethology* 23(2): 199–204.

## 7. Přílohy



Obr. 12: Rezervace Al Marmoom, letecký pohled na Al Qudra Lakes, Dubaj. Zdroj: <http://www.dronestagr.am/>

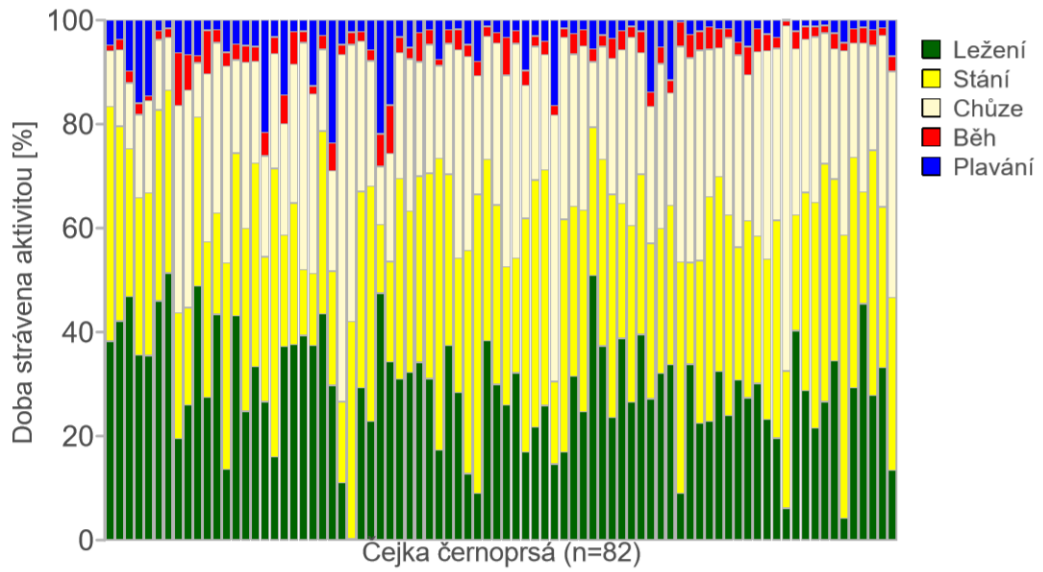


Obr. 13: Rezervace Al Marmoom, Dubaj.  
Foto: Tým behaviorální ekologie




Obr. 14: Rezervace Al Marmoom, Dubaj.  
Foto: Tým behaviorální ekologie





Obr. 15: Celková aktivita jednotlivých jedinců kuřat čejky černoprsé ( $n=82$ ). Sloupce reprezentují jednotlivá kuřata a procentuální zastoupení aktivit po dobu, co měla dataloggery. Kuřata jsou seřazena vzestupně podle váhy, která reprezentuje věk.



Obr. 16: Celková aktivita jednotlivých jedinců kuřat pisily čáponohé ( $n=13$ ). Sloupce reprezentují jednotlivá kuřata a procentuální zastoupení aktivit po dobu, co měla dataloggery. Kuřata jsou seřazena vzestupně podle váhy, která reprezentuje věk.