

Česká zemědělská univerzita v Praze

Fakulta agrobiologie, potravinových a přírodních zdrojů

Katedra chovu hospodářských zvířat



**Fakulta agrobiologie,
potravinových a přírodních zdrojů**

Aplikace strojového učení v chovu hospodářských zvířat

Bakalářská práce

Eliška Blahová

Chov hospodářských zvířat

doc. Ing. Jaroslav Čítek, Ph.D.

© 2022 ČZU v Praze

Čestné prohlášení

Prohlašuji, že svou bakalářskou práci "Aplikace strojového učení v chovu hospodářských zvířat jsem vypracovala samostatně pod vedením vedoucího bakalářské práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou citovány v práci a uvedeny v seznamu literatury na konci práce. Jako autorka uvedené bakalářské práce dále prohlašuji, že jsem v souvislosti s jejím vytvořením neporušil autorská práva třetích osob.

V Praze dne 22.4.2022

Poděkování

Ráda bych touto cestou poděkovala rodině a vedoucímu mé bakalářské práce doc. Ing. Jaroslavovi Čítkovi, Ph.D. za trpělivost, vstřícný přístup, odborné vedení a všestrannou pomoc při psaní bakalářské práce.

Aplikace strojového učení v chovu hospodářských zvířat

Souhrn

Cílem bakalářské práce bylo vytvoření literární rešerše popisující technologie strojového učení a jejích možných aplikací v chovu hospodářských zvířat. Z přehledu literatury je patrné, že rozvíjející se výzkum a aplikace technologického pokroku zahajují rozvoj precizního chovu hospodářských zvířat prostřednictvím senzorů. Mezi nejznámější senzory patří kamery, termokamery a fotoaparáty, které slouží k zachycení informací jako je obraz, zvuk, teplota, ale také třeba i chování. Získané informace ze senzorů se kombinují s algoritmy pro neinvazivní sledování zvířat s cílem zjistit jejich welfare. Zpracovaná data se ukládají lokálně, v místě měření, nebo jsou odesílána přímo do zpracovatelského uzlu, kde jsou vyhodnocena pomocí algoritmů. Výsledkem je ukazatel konkrétního stavu například procentuální podíl tuku v jatečně upraveném těle. Dálkové monitorování hospodářských zvířat může poskytnout kvantitu informací, a proto včasné upozornění na neobvyklé situace v chovu, které vyžadují pozornost chovatele. Práce zahrnuje popis terminologie, strojového učení, ale také výzkum. Práce se zabývá komerčními aplikacemi v oblasti dálkového rozpoznávání a monitorování zvířat. Práce popisuje, jak mohou nástroje precizního chovu zlepšit samotný chov zvířat. Mezi hlavní aplikace strojového učení patří zobrazování a analýza obrazu, počítačové vidění, 3D zobrazování a infračervená termografie. Z přehledu literatury vyplývá, že využití umělé inteligence v chovu zdokonaluje a usnadňuje řízení stáda. Bohužel jeho rozsáhlejší využití zpomalují vysoké vstupní náklady a nedostatek kvalifikovaných pracovníků.

Klíčová slova: prase, technologie, strojové učení

Application of machine learning in livestock breeding

Summary

The aim of the bachelor thesis was to create a literature search describing machine learning technologies and their possible applications in livestock breeding. A review of the literature shows that evolving research and the application of technological progress are initiating the development of precision livestock farming through sensors. The most well-known sensors include cameras, thermal imagers and cameras, which are, used to capture information such as image, sound temperature, but also behavior. The information obtained from the sensors is combined with algorithms for non-invasive animal tracking to determine their welfare. The processed data are stored locally, at the measurement site, or are sent directly to the processing node, where they are evaluated using algorithms. The result is an indicator of a specific condition, such as the percentage of fat in the carcass. Remote monitoring of livestock can provide a quantity of information and therefore early warning of unusual farming situations that require the attention of the breeder. The work includes a description of terminology, machine learning, but also research. The work deals with commercial applications in the field of remote animal recognition and monitoring. The work describes how precision breeding tools can improve the breeding of animals. The main applications of machine learning include image imaging and analysis, computer vision, 3D imaging and infrared thermography. A review of the literature shows that the use of artificial intelligence in breeding improves and facilitates herd management. Unfortunately, its wider use is slowed by high input costs and a shortage of skilled workers.

Keywords: pig, technology, machine learning

Obsah

1 Úvod	1
2 Cíl práce.....	2
3 Literární rešerše	3
3.1 Precizní zemědělství	3
3.2 Digitální zpracování a analýza obrazu.....	3
3.3 Tvorba obrazu	4
3.4 Zpracování obrazu a extrakce rysů.....	5
3.5 Počítačové vidění.....	5
3.6 Aplikace systémů počítačového vidění.....	5
3.7 Infračervené záření.....	6
3.8 Aplikace infračervené termografie	6
3.9 3D zobrazování	7
3.10 Hodnocení zvířat pomocí 3D kamer	7
3.11 Jatečné vlastnosti	9
3.12 Hodnocení masa a jatečně upravených těl u živých zvířat	10
3.13 Analýza chování pomocí CCD nebo CMOS kamer	11
3.14 Předpovídání hmotnosti a denního přírůstu během fáze růstu	13
3.15 Zánětlivé procesy a detekce onemocnění	14
3.16 Detekce mastitidy	14
3.17 Detekce ektoparazitů.....	15
3.18 Metabolismus a výživa	16
3.19 Hodnocení adaptability na teplo.....	16
3.20 Rozpoznání prasklých vajec na základě strojového vidění	16
3.21 Welfare	17
4 Závěr	19

5 Literatura.....	20
6 Seznam použitých zkratek a symbolů	29

1 Úvod

Předpokládá se, že do roku 2050 bude celosvětová lidská populace činit více než 9 miliard lidí, kteří budou konzumovat o 50–60 % více potravin (Organizace pro výživu a zemědělství 2009) ve srovnání se současnými způsoby spotřeby. Navzdory nerovnostem se celosvětově populace stává bohatší a bude mít tendenci vybírat si produkty živočišné výroby, upřednostňovat maso, mléko a vejce před základními hlízami a obilím (Godfray a kol. 2014). Bez úpravy našich současných spotřebitelských praktik dojde k výraznému nárůstu potravinové nejistoty na celém světě. Godfray a Garnett uvádějí, že jedním z řešení tohoto bezpečnostního problému je udržitelná intenzifikace s následujícím rámcem: (1) potřeba zvýšené produkce potravin, (2) že potraviny musí pocházet ze stávající zemědělské půdy a (3) široká škála nástrojů a výrobní metody, které je třeba vzít v úvahu (Godfray a kol. 2014). V tomto rámci intenzifikace dobytka zvýší hustotu zvířat a sníží poměr chovaných zvířat na zvíře (Scholten a kol. 2013). Dobré životní podmínky zvířat jako takové mohou být jedním z potenciálních kompromisů ve prospěch udržitelné intenzifikace. Broom a kol (2010) napsal, že lidé mají za to, že mají závazky ke zvířatům, která používají, ať už pro společnost, přepravu nebo produkci potravin a očekávají péči o jednotlivá zvířata. Ekonomové usuzují, že produkce masa poroste, ale společnost očekává, že se zvířaty používanými na maso se bude zacházet humánně a individuálně.

2 Cíl práce

Cílem bakalářské práce bylo vytvoření literární rešerše popisující technologie strojového učení a jejích možných aplikací v chovu hospodářských zvířat. Byly popsány technologie pro využití na inteligentní farmě zahrnující možnosti automatického sledování welfare, monitoringu užítkovosti a zdravotního stavu. Byly popsány systémy již na trhu dostupné.

3 Literární rešerše

3.1 Precizní zemědělství

Během posledních čtyř desetiletí se vývoj a aplikace technologií precizního zemědělství otevřely novým obzorům pro podporu hospodaření se zemědělskými plodinami a hospodářskými zvířaty. Některé z moderních technologií se vyvinuly do standardních aplikací jako je GPS podporující mapování výnosu obilovin. Precizní zemědělství vyvinulo nová odvětví, která poskytují technická řešení umožňující reagovat na variabilitu oboru a zdokumentovat tuto odpověď jako digitální mapy (Cox 2002). Současný výzkum precizního zemědělství se zaměřuje také na vývoj senzoru, pomocí kterého lze na dálku detekovat vlastnosti plodin a půdy v reálném čase, včetně digitální analýzy obrazu. Dosud se precizní zemědělství soustředilo především na řízení site-specific managementu (SSM) plodin. Whelan a McBratley (2000) definují SSM jako párování aplikací zdrojů a agronomické postupy s půdou a plodinami. Většina autorů se však shoduje, že precizní zemědělství je více než jen management (Staford, 2000). Plant (2001) uvádí, že lepším vysvětlením precizního zemědělství by bylo použití informačních technologií v celém zemědělství. V souladu se širší definicí precizního zemědělství by měla zahrnovat každou zemědělskou činnost, která implementuje moderní informační technologie spolu s rostlinnou výrobou, živočišnou produkcí, welfare, hospodaření s přírodními zdroji (např. úrodnost půdy, kvalita vody), management zemědělské krajiny a také posklizňové zpracování surovin. Precizní zemědělství není samoúčelný, ale inovativní, integrovaný a mezinárodně standardizovaný přístup k udržitelnému zemědělství s cílem zvýšit účinnost zdrojů (Zhang a kol. 2002) a snížit riziko a nejistotu manažerského rozhodování. Zároveň je to strategie, která odpovídá potřebám bezpečnosti životních podmínek lidí a zvířat (Cox 2002). Nicméně většina současného výzkumu a technického rozvoje v precizním zemědělství se spíše soustředí na plodiny na orné půdě než na pastviny. To může být způsobeno především ekonomickou převahou komerčních plodiny pěstované převážně v oblíbených klimatických podmínkách. Kromě aplikace informačních technologií zaměřených na reakce na změny jakéhokoliv druhu. Precizní zemědělství také umožňuje sledovat a dokumentovat výrobní procesy ve vztahu k prostoru a času v různých měřících bez přímé reakce. Snímání a měření vlastností půd a plodin poskytuje velké množství dat z farmy, která pokud jsou správně shromážděna, uložena a interpretována, mohou poskytnout vynikající prostředky pro zlepšení znalostí o faktorech určujících proces produkce.

3.2 Digitální zpracování a analýza obrazu

Digitální zpracování obrazu se zabývá zachycováním a překladem vizuálního signálu do digitálního obrazu. Jedná se o oblast, která studuje proces získávání vizuálního signálu světa a jeho přeměnou. Zahrnuje studium tvorby obrazu, jako výsledek získávání světelných signálů speciálně navrženými senzory. Digitální zpracování obrazu tedy zahrnuje koncepcce, design, vývoj a vylepšení digitálního zobrazování algoritmů a programů (Burger a Burge 2005). Jako taková je to disciplína silně založená na fyzice a matematice. Termín může být také používán k přímému adresování aplikací nebo techniky používané pro digitální manipulace s obrazem, od redukce šumu, tvarování a filtrování obrazu a další používané postupy přípravy snímků pro následné kroky v analytickém potrubí nebo pro estetické vylepšení obrázků (Ravoor a Sudarshan 2020). Skupina technik velkého významu v digitálním zpracování obrazu má hrana, kontura a detekce. Ačkoliv existuje několik metod pro detekci hran, všechny spoléhají na skutečnost, že hrany jsou oblasti v obrázku, kde dochází k drastické změně barvy/intenzity

spolu s konkrétní orientací (Atherton & Kerbyson 1999) Tyto techniky jsou obecně užitečné v mnoho aplikací, jako je korekce obrazu a doostření (tj. zvýraznění hran). Analýza obrazu je identifikace složitých struktur a porovnání objektů v obraze se specifickými šablonami (Fernandes a kol. 2020).

Digitální analýza obrazu nebo jen digitální zobrazování odpovídá procesu extrahování smysluplných informací z obrázku (Burger a Burge 2005). Informace mohou být popisovány statisticky. Informace extrahované z analýzy obrazu pak mohou být použity jako vstup pro techniky zpracování obrazu, jako je zaostření obrazu (Kheradmand a Milanfar 2015), vyhlazení a vylepšení hran a kontur (Polesel a kol. 2000). Na druhou stranu technika zpracování obrazu může být také použita před technikami analýzy obrazu. Příkladem je použití technik detekce hran v procesu identifikace struktur, jako jsou čáry a kruhy v obraze (Atherton a Kerbyson 1999). Segmentace obrazu je rozdělení obrazu do různých oblastí, což může být jednoduchá binarizace obrazu (rozdělení obrazu na dvě oblasti, jako je pozadí a popředí) nebo více oblastí, jako jsou různé objekty přítomné na obrázku. Existuje několik metod segmentace obrazu, ale v zásadě je lze rozdělit na metody, které provádějí globální shlukování obrazových pixelů podle určitých kritérií nezávislých na prostorové informaci a metodě, která zohledňuje více informací, jako je prostor, textura, barva, okraje a tvar (Nakagomi a kol. 2013).

3.3 Tvorba obrazu

Důležitým aspektem digitálního zobrazování je způsob získávání samotného obrazu. Než dojde ke zpracování a analýze obrazu bylo potřeba vyvinout senzory schopné rozpoznat, měřit a digitalizovat světelné signály. Bylo to v 70. letech 20. století s příchodem snímačů charge-coupled devices (Boyle a Smith 1973). Bylo vyvinuto digitální zobrazování a vzrostl zájem o CVS. V zásadě platí, že při vytváření digitálního obrazu jsou světelné signály zachycovány senzorem, kódovány a ukládány do polí dat, která lze interpretovat a manipulovat s nimi ve výpočetních algoritmech. (Szelisk 2011). Obrázek není nic jiného než číselné hodnoty ve strukturovaném poli dat, které kódují světlo a barvy pro každý bod na obrázku. Toto pole může být jednoduchá matice, kde hodnoty uvnitř matice odpovídají černé nebo bílé tzv. binární obraz nebo různým odstínům šedé tehdy se jedná o obraz ve stupních šedé. Také to může být pole tří matic v případě barevných obrázků tj. intenzity červené, zelené a modré v barevném prostoru nebo dokonce více matic pro hyperspektrální obrázky (Qiao a kol. 2019). Matematická manipulace a statistika obrazu patřily mezi první studie vyvinuté v oblasti digitální analýzy a zpracování obrazu. Dalším zlomem v historii počítačového vidění byl nástup osobních digitálních fotoaparátů v 90. letech 20. století, které snížily náklady a popularizovaly proces pořizování a analýzy digitálních snímků (Lister 1995; van Dijck 2008). Popularizace digitálních fotoaparátů přímo souvisí s rostoucím objemem dat (fotografií a videí) generovaných v posledních několika letech. Tento zvýšený zájem o počítačové vidění a související oblasti lze ilustrovat rostoucím počtem publikací v posledním desetiletí. Některé oblasti počítačové vidění jsou snímky objektů, mapování, rozpoznávání, sledování pohybu, navigace, segmentace obrazu a interpretace scény (Szelisk 2011). Mnoho úspěšných CVS je tedy výsledkem multidisciplinárních přístupů přizpůsobených konkrétním případům, například interaktivní segmentace (Tang a kol. 2013), detekce obličeje na základě obrazových funkcí (Viola a Jones 2004) a metody strojového učení pro detekci a rozpoznávání objektů, jako je optické

rozpoznávání (LeCun a kol. 1998) a klasifikaci snímků, jako je klasifikace oblastí a buněk histopatologických snímků (Litjens a kol. 2016).

3.4 Zpracování obrazu a extrakce rysů

Z každého videozáznamu byly extrahovány obrázky prasat spolu s jejich příslušnými rysy. Tento proces byl zcela automatizován s videonahrávkami na virtuální kameře Kinect prostřednictvím sady Kinect for Windows SDK v2.0 (Microsoft, 2014) a CVS pro zpracování videa inicializovaného v nezávislé rutině MATLAB. Spojení mezi oběma instancemi bylo provedeno pomocí vlastního zapouzdření sady Kinect for Windows SDK na MATLAB MEX podle pokynů v sadě nástrojů Kin2 (Terven a Córdova-Esparza, 2016). CVS používá pro zpracování a extrakci videí vhodné obrázky a jejich příslušné vlastnosti odpovídají vlastním kódům vyvinutých autory v MATLABu (The MathWorks 2017). Tento CVS je kombinací kroků zpracování obrazu a segmentace pro výběr snímků s dobře umístěným prasetem a následné odstranění jeho hlavy a ocasu a také šumu. Algoritmus poté uloží původní vybrané obrázky spolu se segmentovanými a příslušnými extrahovanými prvky (Mazur-Milecka a Ruminski 2020). Doba, po kterou každé prase zůstalo pod 3D kamerou, nebyla stejná a snímky byly vybírány automaticky. Pro každé zvíře vybráno více snímků, což vedlo k vícenásobnému měření snímků, přičemž bylo získáno pouze jedno přímé měření pro každé zvíře.

3.5 Počítačové vidění

Počítačové vidění lze definovat jako obor, jehož cílem je popsat svět prostřednictvím obrázků, interpretací, rekonstrukcí a extrakcí vlastností z obrázků, jako jsou tvary, textury, hustota a vzdálenost (Szelisk 2010). CVS je také známé jako systém strojového vidění, vizuální obrazový systém nebo jen obrazový systém. Spolu s analýzou a zpracováním obrazu jsou s počítačovým viděním úzce propojeny i další oblasti, jako je Machine Learning a Pattern Recognition. Rozpoznávání vzorů je obor, který studuje nejen obrazy, ale také další signály, jako jsou zvuky a texty. Jak název napovídá, jedná se o oblast věnovanou studiu vzorců, které se mohou objevit v jakémkoliv daném signálu. V kontextu zobrazování je rozpoznávání vzorů, obecný vývoj matematických metod pro identifikaci jednoduchých geometrických struktur, jako jsou čáry a kruhy (Atherton a Kerbyson 1999) nebo prvky klíčových bodů, které lze společně použít k identifikaci složitějších objektů nebo vzorů. Strojové učení je také širší obor, který se zabývá vývojem a aplikací algoritmů pro extrakci informací z nejrůznějších datových sad (Murphy, 2012) a několik algoritmů strojového učení bylo vyvinuto nebo přizpůsobeno speciálně pro řešení problémů s počítačovým viděním. (Fernandes a kol. 2020)

3.6 Aplikace systémů počítačového vidění

Před příchodem CVS vyžadovalo mnoho aplikací pro vizuální klasifikaci znaků u živých zvířat, jako je chování zvířat, skóre tělesné kondice, ukládání tuku v jatečně upraveném těle, mramorování masa nebo klasifikace kvality vaječných skořápek (Cevik 2020). Existují také metody, které využívají pomoc mikroskopů pro hodnocení morfologie buněk v krevním nátěru nebo pohyblivosti spermií a jejich defektů. Počítačové vidění široce používá tyto signály: ultrazvuk, infračervené záření a rentgenové záření. Většina takových měřicích procesů je také

časově náročná, stresující pro zvířata a nákladná pro farmáře. Pro takové úkoly CVS obecně používá algoritmy a principy rozpoznávání vzorů, analýzy obrazu a zpracování, aby se vypořádal s nejrozmanitějšími problémy. Vývoj automatizovaného CVS může umožnit vysoce výkonné sledování u hospodářských zvířat a data generovaná takovými systémy pak lze použít pro mnoho různých aplikací, od vývoje nástrojů pro inteligentní řízení farmy až po pokrokové šlechtitelské programy. (Fernandes a kol. 2020)

3.7 Infračervené záření

Infračervené záření má vlnovou délku delší než viditelné světlo a podle Mezinárodní organizace pro standardizaci (ISO) jej lze rozdělit na blízké infračervené záření (NIR), střední infračervené záření (MIR) a vzdálené infračervené záření (FIR). Toto rozdělení bylo založeno na specifických prahových hodnotách vlnových délek 0,78–3, 3–50 a 50–1 000 μm pro NIR, MIR a FIR, v daném pořadí. Existuje mnoho různých aplikací IR v zobrazování a pro účely tohoto přehledu jsou nejvýznamnější z nich ve 3D zobrazování, spektroskopii, v nočním vidění a termálním zobrazování. Pro všechny tyto aplikace existují různé specifické senzory pro zachycení záření v rozsahu NIR, MIR nebo FIR. Ve většině kamer pro noční vidění se senzory spoléhají na vysílač, který vysílá IR na vlnové délce NIR, aby aktivně osvětloval scénu. Na druhou stranu termovize využívá principu produkce tepla, takže není potřeba žádný zářič, protože senzory jsou schopny zachytit tepelný signál v MIR nebo FIR (Ring a kol. 2015).

Senzory pro termovizi lze rozdělit do dvou skupin, chlazené nebo nechlazené pole ohniskové roviny. Hlavním rozdílem je, že chlazené senzory obecně produkují lepší snímky a méně variabilní měření, za cenu toho, že jsou těžší, méně přenosné a drahé. Termokamery se používají většinou pro sledování zvířat (hospodářských zvířat nebo volně žijících zvířat) v noci nebo v situacích se slabým světlem, a to buď samostatně, nebo ve spojení se standardními digitálními obrazovými senzory (Lavers a kol. 2005). Termokamery však mají také využití v diagnostickém zobrazování pro detekci malých změn povrchové teploty těla (McManus a kol. 2016), což může být způsobeno stresem, horečkou či zánět. Správné použití termovizního zobrazování pro diagnostické účely však stále vyžaduje správnou kalibraci zařízení, odpovídající umístění a správné umístění zvířete a kamery (Ring a kol. 2015; McManus a kol. 2016).

3.8 Aplikace infračervené termografie

Tato metoda se řadí mezi neinvazivní metody, které se používají k indikaci tepelných biometrických změn v metabolismu zvířat vyplývajících ze zvýšené teploty a změn průtoku krve v reakci na okolní. Tato technologie může být nástrojem a obecným indikátorem stresu, zánětlivého procesu, bolesti nebo i onemocnění. Proto si tato studie klade za cíl zhodnotit použití této technologie v živočišné výrobě. V současné době se běžně používají k hodnocení odběru krve, rektální měření teploty a měření dýchání a srdeční frekvence (Stewart a kol. 2008). Takové invazivní metody mohou poskytovat nespolehlivé výsledky kvůli reakcím, které vyplývají ze samotného postupu, takže samotné výsledky je těžké interpretovat (Soerensen a Pedersen 2015). Tělesa s teplotou nad absolutní nulou vyzařují záření, tvořící elektromagnetické spektrum, které může být absorbováno jiným tělem (Roberto a kol. 2014).

S využitím digitální termografie (termografická kamera) je tedy možné detekovat tento druh záření detekcí i minimálních teplotních změn (Knížková a kol. 2007). Když se zvíře dostane do stresu, aktivuje se adrenokortikální osa a vzniká teplo v důsledku zvýšené koncentrace katecholaminů a kortizolu. (Schaefer a kol. 2002). Každá oblast zvířete vyzařuje různé množství infračerveného záření. Takové teplotní změny mohou být interpretovány různými počítačem vygenerovanými barevnými odstíny. Získané snímky umožňují přímé pozorování rozložení teploty na povrchu (Knížková a kol. 2007). Tyto informace pomáhají porozumět termoregulaci v důsledku změn povrchové teploty a dopadu podmínek prostředí na dobré životní podmínky zvířat (Kotrba a kol. 2007). Následné teploty jsou digitalizované a zpracované počítačem a zobrazeny ve formě tepelné mapy. Infračervená termografie má četné aplikace nejen v průmyslu, ale také v humánní a veterinární medicíně (Schaefer a kol. 2012; Martins a kol. 2013). Výhodou této metody je, že není potřeba fyzický kontakt se sledovaným zvířetem a umožňuje tak dálkový odečet rozložení teplot (Speakmen a Ward 1998).

3.9 3D zobrazování

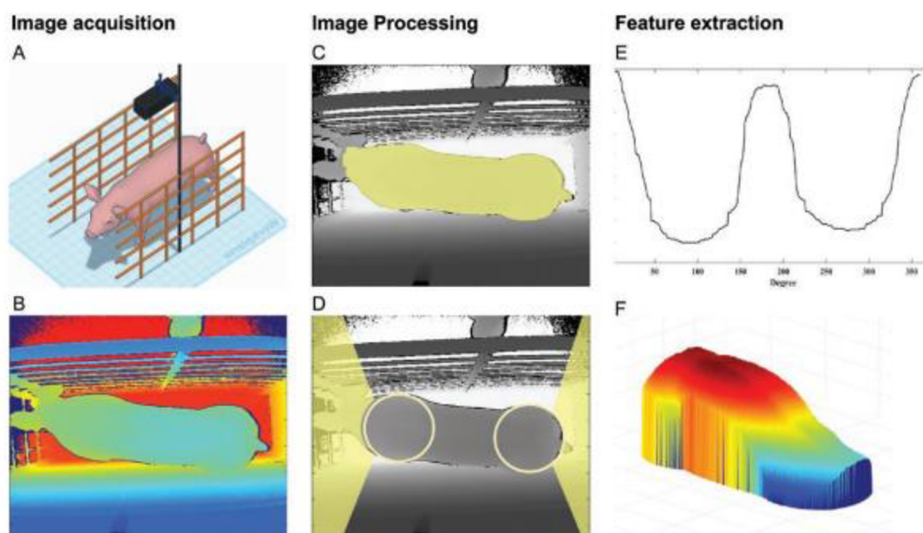
Pro měření vzdálenosti objektů od kamery, získávání a vytváření 3D snímků se používá mnoho různých senzorů a technik. U hospodářských zvířat lze tyto senzory použít mimo jiné například pro měření objemu, povrchu a chůze zvířete. Z několika technologií vyvinutých pro 3D zobrazování se zaměříme na optické aplikace (tj. aplikace využívající záření ve viditelném a blízkém světle) používané ve 3D kamerách, známých také jako hloubkové senzory. Tyto techniky lze dále rozdělit na pasivní, jako je zobrazování a struktura pohybu, nebo aktivní, jako je strukturované světlo a doba letu (Zanuttigh a kol. 2016).

3.10 Hodnocení zvířat pomocí 3D kamer

Zájem o použití 3D kamer je způsoben schopností měřit vlastnosti v třírozměrném prostoru, jako je zvíře, poloha těla, chůze a objem. U některých aplikací je také zlepšeno zpracování obrazu, protože v rámci 3D obrazů je méně šumu kvůli světlu a podmínkám pozadí a je snazší použít vzdálenost ke kameře jako práh. Pokud jde o použití hloubkových senzorů existuje mnoho příkladů úspěšných aplikací včetně sledování ryb v nádrži (Saberioo a Cisar 2016), identifikace orientačních bodů na těle zvířete s postupným modelováním chůze (Salua a kol. 2017; Stavrakakis a kol. 2015), skóre tělesného stavu (Spoliansky a kol. 2016), detekce nemoci (Okinda a kol. 2019) a odhad mnoha dalších tělesných měření, která budou diskutována níže. Studie analýzy chůze obvykle vyžadovala intenzivní ruční označování video snímků lidským pozorovatelem anebo nákladný systém deskových značek, které měly být umístěny na těle zvířete. (Stavrakakis a kol. 2014). Se zavedenou technologií a dostupnějších 3D kamer byl CVS s jedním nebo dvěma senzory schopny efektivně odhadnout kinematiku chůze u prasat v nákladově efektivním rámci s přesností předpovědi srovnatelnou se současným stavem kinematiky (Stavrakakis a kol. 2015). Spoliansky a kol. (2016) vyvinuli automatizovaný CVS založený na 3D kamerách pro hodnocení tělesného skóre dojníc (BCS). V této studii byly shromážděny obrázky z pohledu shora od krav v okamžiku, kdy opouštěly dojírnu. Tyto snímky byly poté automaticky zpracovány s odstraněním pozadí, rotací a centralizací krávy, vyplněním děr a normalizací. Ze zpracovaných snímků bylo extrahováno několik obrazových prvků a byly

použity pro vývoj více lineárních regresních modelů prostřednictvím postupné regrese. I když extrahované proměnné nepředstavovaly vysokou korelaci s BCS, vyvinutý model dosáhl lepšího průměru což je srovnatelné nebo lepší než předchozí studie založené na ručním zpracování snímků pomocí buď standardních digitálních snímků (Bewley a kol. 2008; Bercovich a kol. 2013) nebo termokamery (Halachm a kol. 2013). U kuřat byly také použity 3D senzory k identifikaci malých úprav na povrchu zvířete, které souvisí s hlavou a polohování ocasu (Okinda a kol. 2019). V této studii, ve které byla zvířata vystavena drůbežímu Pseudomoru, bylo možné identifikovat změny ve tvaru a chování zvířete 6 dní po inokulaci. Další aplikace, ve kterých hloubkové senzory vykazují slibné výsledky, jsou pro odhad tělesných rozměrů zvířat (příklady výšky, šířky, plochy a objemu) a tělesné hmotnosti (Gomes a kol. 2016; Kongsro 2014; Pezzuolo a kol. 2018). V jedné studii mohl CVS založený na hloubkovém zobrazení extrahovat další informace o objemu zvířete (Kongsro 2014) za experimentálních podmínek. V jiné studii byly hodnoceny (Pezzuolo a kol. 2018) tělesné rozměry prasat v podmínkách farmy ručním měřením. Nicméně tyto předchozí studie používaly určitou úroveň ruční manipulace s obrázky a nehodnotily výkonnost modelu pomocí nezávislého souboru zvířat nebo přístupu křížové validace. To ztěžuje hodnocení toho, jak zobecnitelné jsou predikční modely, tedy jak by tyto CVS založené na 3D kamerách fungovaly v praxi.

Další nevýhodou těchto předchozích studií je chybějící automatizace pro aplikaci v podmínkách farmy, kde by bylo extrémně obtížné ručně zpracovat snímky. (Fernandes a kol. 2020). V současné studii byly z obrázků extrahovány tyto znaky: 1) tělesné rozměry prasat, včetně sesbíraného zdánlivého objemu (V), plochy povrchu (A), délky (L), výšek (H) a šířky (W) v ekvidistantních bodech podél hřbetu zvířete a excentricita (E); 2) 360 ekvidistantních měření od obrysu polárního tvaru obrázku shora; a 3) odpovídajících 360 znaků ze stejného obrysu polárního tvaru. Byly extrahovány tělesné míry z 3D snímků (což je mapa vzdálenosti pixelů od kamery) a byly převedeny na hodnoty metrické stupnici pomocí vnitřní ohniskové vzdálenosti (f) z použité hloubkové kamery Kinect. F bylo použito pro odhad faktoru zvětšení obrazu (m) v každém pixelu jako $m = f/d$, kde d je vzdálenost v mm od bodu k rovině kamery. Z m byla plocha pixelu (ap) v mm vypočtena jako $ap = a$ celková plocha prasete byla vypočtena jako součet ap . Podobně objem pixelu je potom $vp = ap \times hp$, kde hp je výška prasete v pixelu p na zadní straně prasete. Objem prasete byl vypočítán jako součet objemů pixelů. Excentricita prasete byla odhadnuta jako poměr mezi ohnisky a hlavní osou elipsy, která má stejnou hlavní a vedlejší osu jako oblast prasete. Deskriptory polárního tvaru (PSD) byly měřeny jako vzdálenost od těžiště (x_c, y_c) prasete k bodům na jeho hraničním obrysu jako $PSD_t = \llcorner (x_t, y_t)$ bod (x_t, y_t) je souřadnice prasečí hranice ve stupni t . Polární Fourierovy deskriptory (PFD) byly skutečné hodnoty z Fourierovy transformace PSD kontury prasete (Oster meier et al. 2001; Zhang a Lu 2002).



Obrázek 1 | Reprezentativní fluxogram potrubí pro získávání a zpracování obrazu: (A) nastavení 3D kamery; (B) nezpracovaný hloubkový obraz; (C) snímek prahové hloubky, vybraná oblast prasete zvýrazněná; (D) identifikace plece a zadku prasete a odstranění hlavy a ocasu; (E) PSD obrysu prasete; a (F) zpracované tělo prasete pro měření extrakce. Převzato od Fernandes a kol. 2020.

3.11 Jatečné vlastnosti

Pravděpodobně jedna z prvních aplikací CVS byla ve vědách o mase, přičemž nejstarší studie byly nalezeny v 80. letech 20. století (Lin 1978). Tento systém se skládá z kamer, světelného zdroje a počítačové jednotky. CVS potřebuje operátora, který umístí kusy hovězího masa na povrch ve známé vzdálenosti a úhlu od kamery a spustí systém na pořizování snímků. Všechny kusy masa byly umístěny stejným způsobem s konstantním pozadím a osvětlením. V té době byl zájmem předpovídat snížený obsah libového masa a tuku. (Fernandes a kol. 2020)



Obrázek 2 | Příklad strukturovaného světelného systému založeném na lineárním vzoru stínu. (A) Schéma s přirozeným osvětlením a schéma B je pod strukturovaným světlem promítaným emitorem. Převzato od Fernandes a kol. 2020

Složení jatečně upraveného těla prasat je pro farmáře velmi důležité, protože balírny mají tendenci je odměňovat podle procenta svalové hmoty (Engel a kol. 2012). Kromě toho mohou farmáři využít informace o individuálním růstu prasat a ukládání svalové hmoty a tuku ke zlepšení krmných strategií, protože náklady na krmivo představují přibližně 60% až 70% celkové produkce prasat. Kromě toho existují rostoucí obavy z emisí fosforu a dusíku ve výkrmu prasat (Cadéro a kol. 2018) a dobře vyvážené krmivo může tyto náklady a emise snížit. Neustálé sledování růstu a tělesného složení prasat může být proto nanejvýš důležité při přesném krmení prasat, zlepšení stejnorodosti skupiny, snížení nákladů a také emisí skleníkových plynů, fosforu a příjmu a vylučování bílkovin (Pomar a Remus. 2019).

3.12 Hodnocení masa a jatečně upravených těl u živých zvířat

V sekci jatečně upravené tělo a vlastnosti masa jsme viděli, že CVS bylo úspěšně použito pro predikci vlastností, jako je libové maso a obsah tuku z jatečně upravených těl a kusů masa. Nicméně stejná prediktivní výkonnost nebyla zpočátku pozorována pro hodnocení vlastností masa a jatečně upravených těl u živých zvířat. Počáteční pokusy o predikci složení jatečně upraveného těla u prasat provedl Doeschl-Wilson a kol. (2005) kde CVS dosáhlo prediktivních hodnot. V nedávných studiích využívajících lékařská zobrazovací zařízení vykazovala ultrazvuková měření pozitivní střední korelaci 0,6 a 0,56 s měřením jatečně upraveného těla, libového masa a hloubky tuku, zatímco CT vykazovalo nízkou až střední korelaci 0,48–0,67 pro tuk a vysoká korelace 0,91–0,94 pro libové maso (Font-i-Furnols a kol. 2015; Lucas a kol. 2017).

Technologie mají několik nevýhod, pokud jde o manipulaci se zvířaty a náklady, jak bylo vysvětleno dříve. Aby bylo možné tyto problémy řešit některé nedávné práce vyvinuly CVS založené na 3D kamerách pro bezkontaktní automatizovaný odhad svalového skóre (Alsahaf a kol. 2019), obsahu tuku a svalové hmoty (Fernandes a kol. 2020) na živých prasatech. Alsahaf a kol. (2019) vyvinul systém, který extrahoval morfometrické rysy z obrázků pohybujících se prasat pro predikci svalové hmoty. S klasifikátorem se zesíleným gradientem dosahovali přesnosti klasifikace mezi 0,3 a 0,58. Mezitím Fernandes a kol. (2020) hodnotil nejen rysy extrahované z obrázků, ale také hloubkové metody učení, které nevyžadují zpracování obrazu, s přístupy hloubkového učení dosáhl lepších výsledků. Zobrazovací techniky, jako je vizuální analýza obrazu, ultrazvuk a počítačová tomografie, se tradičně používají při hodnocení složení jatečně upravených těl prasat v podmínkách výzkumu, přičemž počítačová tomografie představuje celkově vyšší přesnost než jiné techniky (Carabús a kol. 2016). Předchozí studie hodnotící ultrazvuk a počítačovou tomografii ukázaly, že ultrazvukové měření má korelace 0,6 a 0,56 s měřeními jatečně upraveného těla, zatímco počítačová tomografie má korelace 0,48 až 0,67 pro tuk a 0,91 až 0,94 pro libové maso (Font-i-Furnols a kol. 2015; Lucas a kol. 2017).

V těchto studiích bylo několik lineárních regresí přizpůsobených proměnným extrahovaným z CVS a byly porovnány s modely, které zahrnovaly manuální měření. I když systém nebyl plně automatizovaný, předpovědní rovnice vyvinuté s proměnnými měřeními systémy vykazovaly o něco lepší výsledky než predikční rovnice vyvinuté s proměnnými měřeními školenými srovnávací. Nejlepší lineární model pro predikci hmotnosti libového masa vyvinutý s proměnnými by mohly být statistické modely, jako je lineární a částečná regrese nejmenších čtverců k metodám strojového učení. (Fernandes a kol. 2020)

Od těchto dřívějších studií vzrůstá zájem o využití počítačového vidění k predikci nejrozmanitějších znaků kvality masa a to nejen u hovězího, ale také u ryb, drůbeže a vepřového. Existuje aplikace zaměřená na zobrazovací technologie pro stanovení nejen obsahu hrubých bílkovin a tuku v mase, ale i jemnějších chemických vlastností, jako je profil mastných kyselin, čerstvost, (Khoshnoudi-Nia a kol. 2019; Wang a kol. 2013), kvalita masa, chutnost, křehkost a dalších vlastností, které běžně hodnotí skupina vyškolených odborníků (Nunes a kol. 2015; Jackman a kol. 2010; Zapotoczny a kol. 2016). Automatické třídění a vážení odřezků a vnitřností, které se běžně provádí ručně (Paluchowski a kol. 2016; Adamczak a kol. 2018). Opět byla použita různá zařízení a zobrazovací technologie. Nicméně, nezávisle na použitém zobrazovacím zařízení, takové aplikační potrubí obecně zahrnuje několik kroků, jako je: (1) Příprava vzorku se standardizací použitého masa, pozadí a světelné podmínky; (2) Kalibrace zařízení (v případě potřeby), sběr a zpracování snímků; (3) Přímé měření sledovaných atributů pomocí chemické analýzy a (4) Přizpůsobení modelu, které odpovídá predikci chemické analýzy pomocí obrazových prvků jako prediktorů. Je zajímavé podotknout, že zpracování obrazu v kroku 2 může zahrnovat několik dílčích kroků, jako je vyrovnaní histogramu, odstranění pozadí a vyhlazení obrazu. Také v případě hyperspektrálního obrazu, zpracování zahrnuje výběr volných dálek anebo redukce rozměrů pomocí technik, jako je Fourier transformace (Ostermeier a kol. 2001) a hlavní komponenty pro hloubkový přehled aplikací hyperspektrálního zobrazování (Xiong a kol. 2014). Za zmínku také stojí, že pro krok 4 neexistuje žádný standardní model výběru, protože v literatuře bylo hodnoceno několik prediktivních přístupů. Tyto prediktivní přístupy by mohli být statistické modely, jako jsou lineární a částečně nejmenší čtverce regrese k metodám strojového učení, jako je podpurný vektor stroje (Fernandes a kol. 2020).

3.13 Analýza chování pomocí CCD nebo CMOS kamer

Kamery pro standardní digitální zobrazování pracují se signály v rozsahu viditelného světla a obecně mají CCD nebo komplementární metal-oxide-semiconductor (CMOS) senzor. Oba senzory mají podobnou funkci, kterou je zachycení světla a jeho převod na digitální obraz, nicméně mají některé důležité rozdíly. Na jedné straně jsou CCD snímače nabíjeny pasivně světelným zdrojem a informace jsou zachyceny v každém pixelu a jsou zpracovávány postupně. Na druhé straně snímače CMOS mají aktivní pixely s tranzistorem pro každý pixel, takže informace z každého pixelu jsou převedeny do obrázku nezávisle a synchronně k digitálnímu obrázku. Tyto rozdíly v architektuře senzorů vedou k rozdílu v cenách a možnostech senzorů. I když je průmysl v neustálém vývoji, CCD snímače mají obecně vyšší dynamický rozsah a produkují jednotnější snímky, zatímco snímače CMOS jsou levnější, energeticky úspornější a citlivější. (Fernandes a kol. 2020)

Některé z nejžádanějších aplikací CVS pro živá zvířata odpovídají identifikaci a sledování zvířat, slouží k identifikaci změn v jejich každodenním chování. Mezitím sledování zahrnuje průběžnou identifikaci zvířete přes snímky ve videu nebo přes obrázky z různých míst. Pokud jde o chování, zvířata mají tendenci synchronizovat své chování ve skupině a mohou se objevit nápadné odchylky, které mohou být způsobeny stresem, prostředím popřípadě onemocněním, ačkoliv individuální rozdíly v chování musíme vzít v úvahu, proto je neustálá snaha porozumět změnám chování a jejich vztahu k ostatním zájmům jako je zdravotní stav a růst zvířat. Bližší

hodnocení chování a zdraví zvířat jsou běžně prováděné vyškolenými hodnotiteli v konkrétních časových bodech, jako je například doba přesunu zvířat z jednoho místa na druhé nebo očkování. Je to, protože manažeři a pracovníci mají omezený čas, který může strávit při pozorování skupiny zvířat. Také při současném trendu s rostoucí velikostí chovů hospodářských zvířat, dochází také k nárůstu poměru zvíře/manažer. Tedy základní využití CVS pro hodnocení chování zvířat může být získávání a ukládání obrázků a videí, která mohou farmáři posoudit později na dálku. To zlepšuje hospodaření se zvířaty, protože není potřeba, aby byl hodnotitel fyzicky přítomen. Od té doby však tento druh systému není optimální, hodnotitel by ještě musel zkontrolovat všechny obrázky. Proto v literatuře jsou snahy vyvinout CVS, které dokáže automaticky klasifikovat chování zvířat a upozornit farmáře v reálném čase o důležitých změnách. Počáteční práce s prasaty prokázaly použitelnost CVS dokázaly identifikovat polohu zvířete a sledovat jeho pohyb (Tillett a kol. 1997; Lind a kol. 2005). Tyto práce ukázaly, že algoritmy zpracování obrazu v této době by mohl segmentovat jedno prase ze zázemí za specifických podmínek. Podmínky byly: kamera umístěná tak, aby zvíře viděla shora a kamera umístěná na tmavé pozadí pro bílá prasata. Tillettem a kol (1997), který odhadl bodové rozložení orientačních bodů na prasečí obrys pro sekvenci snímků (13-30 snímků) a byl schopen modelovat malé změny v držení těla zvířete. Nicméně bylo hodnoceno pouze sedm sekvencí. Na druhou stranu Lind a kol (2005) používá robustnější sedimentační přístup založený na generování matice pozadí pro odečtení obrazu a následné segmentace zvířat. I když tato metoda nemůže identifikovat držení těla, byla efektivní pro použití v reálném čase a efektivně sledovat rozdíly v aktivitě zvířat. Jejich vyvinutý CVS byl schopen sledovat vzdálenost a chování při chůzi a identifikovat rozdíly mezi prasaty, který dostali apomorfín nebo ne. Podobné přístupy založené na tradičním zobrazování snímku pro identifikaci byly použité také ve srovnání s brojlery a jejich chování v hejně (Kashiha a kol. 2013) na různých krmítkách (Neves a kol. 2015).

K překonání tohoto problému bylo úspěšným přístupem u prasat identifikace zvířat podle elipsy na ploše zvířete a rozpoznání vzorů vytištěných na jejich hřbetech (Kashina a kol. 2013). Pomocí tohoto jednoduchého přístupu byli vědci schopni sledovat a identifikovat více zvířat s přesností 88,7 %, což umožnilo charakterizovat a vyhodnotit stav jednoduché aktivity jako aktivní nebo neaktivní s vysokou korelací (průměr 0,9) s hodnoceními provedenými lidským pozorovatelem (Kashina a kol. 2013; Ott a kol. 2014). Tento přístup identifikace a sledování však nelze použít u zvířat s tmavší kůží nebo v komerčních farmách, které mají zvířata s různou barvou kůže, protože metoda byla vyvinuta pro bílá prasata na tmavém pozadí (podlahy). Další výzvou při použití vzorů vytištěných na kůži zvířete pro identifikaci v komerčním prostředí je vyšší hustota osazení a velikost kotce. Matthews a kol (2017) vyvinuli přístup využívající více 3D kamer ke sledování více prasat v kotci a zaznamenávání jejich chování, přičemž dosáhli celkové přesnosti sledování 0,89. V novější studii byl testován přístup hlubokého učení pro identifikaci a sledování více prasat pomocí standardních digitálních fotoaparátů, přičemž bylo dosaženo přesnosti 0,91 (Psota a kol. 2019). I když se jedná o slibné výsledky, tyto systémy jsou náchylné ke ztrátě sledování zvířat v průběhu času, stále tedy existuje potřeba spolehlivého Základním konceptem je identifikovat nejen zvířata, ale také předměty, jako je zdroj vody a krmítka a sledovat, jak zvířata s těmito předměty fungují. Pomocí techniky spojené s modelem přenosové funkce s jedním vstupem a jedním výstupem. Kashiha a kol (2013) byli schopni identifikovat chování prasat při pití. Prasata byli rozděleny do 4 kotců po 40 kusů. Techniky

strojového učení se ukázaly jako účinné pro identifikaci držení těla, jako je stání, ležení nebo sezení (Barnard a kol. 2016; Lao a kol. 2016). Ve stejné studii Barnard a kol (2016) dosáhli průměrné přesnosti 0,91 při použití strukturálního podpůrného vektorového stroje pro klasifikaci psích pozic z hloubkových snímků. V jiné studii Lao a kol (2016) definovali klasifikační strom pro identifikaci několika typů chování prasnic pomocí videí ze 3D kamer s vysokou přesností na 99% pro chování vleže a vsedě, pro klečení s přesností na 78% a přesouvání s přesností na 64%. Techniky strojového učení se také ukázaly jako účinné pro identifikaci sociálních interakcí mezi zvířaty, jako je například agresivní chování (Viazzi a kol. 2014; Chen a kol. 2020). Viazzi a kol (2014) dosáhli průměrné přesnosti 0,88 při použití lineární diskriminační analýzy pro klasifikaci agresivního chování u prasat. Zatím co Chen a kol (2020) dosáhli přesnosti 0,97 na ověřovací sadě pomocí konvoluční neuronové sítě a přístupu dlouhodobé paměti. I když ve druhé studii došlo ke zlepšení přesnosti, tato studie nezahrnovala automatizovanou strategii pro identifikaci jednotlivých zvířat. Současné metody lze tedy použít k identifikaci změn v chování na úrovni skupiny, nikoli však na úrovni jedlivce.

Další aspekt je, že je třeba zdůraznit, že výše diskutované metody jsou přístupy učení pod dohledem a jako takové potřebují datovou sadu označených obrázků. K vytvoření těchto trénovacích datových sad je zapotřebí manuální klasifikace obrázků lidským pozorovatelem, takže model bude nanejvýš tak dobrý jako lidský pozorovatel, který obrázky nejprve vyhodnotil. Další přístup, který lze také použít, je crowdsourcing vývoje datové sady. Pomocí crowdsourcingu může manuální klasifikaci obrázků provádět několik hodnotitelů a pomocí většinového hlasování, čímž se snižuje dopad subjektivity jednotlivých hodnotitelů (Arganda-Carreras a kol. 2015). Jedním z nezákladnějších sestav by bylo použití průměrné předpokládané hodnoty z více modelů (Burnham a Anderson 2004). Kombinace crowdsourcingu vývoje datové sady s použitím více modelových klasifikátorů umožnila zvýšení přesnosti aplikací v lékařské analýze obrazu, přičemž systém umělé inteligence překonal kvalifikované hodnotitele (McKinney a kol. 2020).

3.14 Předpovídání hmotnosti a denního přírůstu během fáze růstu

Tělesná hmotnost je jednou z nejdůležitějších vlastností v produkci masného skotu. Lze jej použít ke sledování růstu zvířat a napomáhat tak rozhodování o nejlepších strategiích řízení. K měření tělesné hmotnosti u masného skotu se tradičně používají váhy. Tato praxe je však pro zvířata stresující a je také nákladná a pracná (Schofield a kol. 1999). Alternativně bylo navrženo použití systému počítačového vidění jako nástroje k extrakci biometrických měření zvířat (Gomes a kol. 2016; Kashiha a kol. 2014; Wang a kol. 2008) z trojrozměrných obrázků. Zvířecí biometrie se pak používá jako proměnné odezvy ve statistických modelech k předpovědi tělesné hmotnosti (Gomes a kol. 2016; Li a kol. 2014; Ozkaya a kol. 2016). Použití CVS tedy může být alternativou k monitorování růstu zvířat v reálném čase s minimálním stresem zvířat a mnohem nižšími náklady a prací. Jsou také neinvazivní, automatizované, vzdálené a složité algoritmy, které mohou být „založené na cloudu“, což vede k okamžitému nasazení výsledků v terénu. (Fernandes a kol. 2019; Gomes a kol. 2016).

3.15 Zánětlivé procesy a detekce onemocnění

Infračervená termografie je účinná metoda, která ukazuje fyziologické změny, takže je užitečná pro diagnostiku a hodnocení bolesti (Nahm 2013). Zánětlivé procesy bez výrazného otoku mohou vést k detekovatelnému zvýšení povrchové teploty (Hovinen a Pyörälä 2011). Zanícené tkáně vykazují změněnou cirkulaci a jedním z příznaků zánětu je vysoká teplota místa kde se zánět nachází. Průtok krve však může být snížen v důsledku lokální bolesti, edému nebo vaskulární trombózy, což ukazuje na oblast s klesající teplotou, kterou charakterizuje zvýšené tepelné emise v termogramu, pravděpodobně v důsledku vytvoření zkratu (Crivellaro a Júnior 2007).

Termografie byla také užitečná pro časnou diagnostiku laminitidy. Alsaad a kol (2014) zjistili, že se jedná o slibný diagnostický nástroj pro detekci laminitidy u dojníc, měřením teplotního rozdílu mezi zdravými a postiženými končetinami. Nikkhah a kol (2005) také provedli infračervená měření v paznehtech dojníc a spojili teploty s vizuálními abnormalitami laminitidy, přičemž dospěli k závěru, že teplota měřená touto technikou na začátku laktace může být užitečná při sledování paznehtů.

Kromě toho lze termografii použít k odhalení nezákonných postupů u koní, jako je aplikace dráždivých látek v perineální oblasti nebo v análním svěrači, aby se vynutilo zvednutí ocasu a odhalení nezákonně zvýšené výkonnosti u koní (Van Hoogmoed a Snyder 2002).

Pro sportovní medicínu u koní se termografie používá v klinické diagnostice a je užitečná při prevenci, diagnostiky a prognóze onemocnění nohou. Stejně jako při léčbě klaudikací (Eddy a kol. 2001; Holmes a kol. 2003; Levet a kol. 2009) a k detekci lokálních injekcí (Van Hoogmoed a Snyder, 2002).

3.16 Detekce mastitidy

Většina prezentovaných aplikací počítačového vidění dosud používala standardní nebo CMOS kamery. Jak již bylo uvedeno, existují také další zajímavé senzory, jako jsou termální a hloubkové kamery. Termovizní kamery se běžně používají ve veterinárních vědách jako nástroj při klinickém vyšetření. Snímky lze použít k identifikaci rozdílů ve vnější teplotě/teplotě kůže, které mohou souviset se zánětlivým procesem, infekcí, nekrózou, stresem a celkovým zdravím. Ve výzkumu byla infračervená termografie (IRT) použita k identifikaci mastitidy u mléčného skotu a ovcí (Hovinen a kol. 2008; Martins a kol. 2013) a pro digitální dermatitidu u ovcí (Byrne a kol. 2019), což ukazuje na schopnost klasifikovat zdravá a klinicky nemocná zvířata. Navíc v kontrolované studii Metzner a kol. (2015) pozorovali, že IRT byla schopna detekovat zvýšení teploty vemene ~ 10 h po inokulaci E. Coli. Nicméně se jednalo o klinické studie s omezeným počtem zvířat, takže stále existuje potřeba vyhodnotit IRT za obecnějších podmínek farmy. Zaninelli a kol. (2018) hodnotili využití IRT pro zdraví vemene pomocí dat od více než 300 krav ze tří farem. V jejich studii, i když byly snímky sbírány ručně, bylo zpracování zobrazení automatizováno pomocí klasického prahu obrazu. V tomto počátečním kroku směrem k automatizaci hodnocení zdraví vemene byl vyvinut prahový model pro klasifikaci zdraví vemene do dvou kategorií, dosahující oblasti pod křivkou (AUC) kolem 0,8. V jiné studii bylo 149 krav z osmi farem klinicky hodnoceno na digitální dermatitidu a IRT byla hodnocena jako neinvazivní terénní diagnostický nástroj pro dojný skot (Alsaad a kol. 2014). V jejich studii

byla pozorována AUC kolem 0,84. Pro klasifikaci na teplotní rozdíl od předních a zadních nohou, což ukazuje sliby IRT jako nástroje na farmě. Autoři však poukázali na to, že snímky byly sbírány ručně a že u 11 % krav musela být data odstraněna kvůli nadměrnému znečištění. Také stále existuje mnoho komplikací souvisejících s variací a opakovatelností měření IRT. V některých studiích bylo pozorováno, že teplota kůže/povrchu zvířat se může lišit podle vnějších faktorů, jako je teplota prostředí, rychlost větru nebo jiné faktory, jako je umístění operátora a kamery a hodnocená oblast těla (Byrne a kol. 2017; Yang a kol. 2018; Scoley a kol. 2019). Proto byly aplikace IRT náročné a stále jsou obecně založeny na poloautomatickém CVS, takže by mělo být vynaloženo další úsilí na vývoj metod pro automatizaci a zlepšení měření pro podmínky na farmě.

Kunc a spol. (2007) uvedl, že vemeno s mastitidou má vysokou teplotu ještě předtím, než se objeví klinické příznaky. Navíc Pezeshki a kol. (2011) zaznamenali zvýšení povrchové teploty vemene o 2-3 °C u laktujících krav po inokulaci *Escherichia coli* v různých částech vemene. Berry a kol. (2003) pozorovali, že teplota vemene měřená pomocí termografie může být užitečným diagnostickým nástrojem pro detekci mastitidy u mléčného skotu. Martins a kol. (2013) použili termografické snímky jako nástroj k detekci mastitidy u ovcí, zejména subklinické mastitidy. Screening subklinické mastitidy, měřením povrchové teploty vemene, má vysokou prediktivní diagnostickou schopnost podobnou Kalifornskému testu mastitidy (CMT). Analýza spolehlivosti povrchové teploty pomocí termografie mezi krávami s různými tělesnými a fyziologickými vlastnostmi žijícími v různých podmínkách prostředí však musí být stanovena v každém případě (Polat a kol. 2010).

Automatický monitorovací systém mastitidy u dojnic byl vyvinut komerčně pomocí termografických kamer detekujících mastitidu 2 až 3 dny před nástupem klinických příznaků. Tento systém má také varovný systém, který signalizuje zvýšenou teplotu vemene. Infračervená technika byla použita jako metoda časně detekce k identifikaci zvířat infikovaných virem bovinního virového průjmu (BVDV) a slintavkou a kulhavkou (FMD). Schaefer a kol. (2004) dospěli k závěru, že došlo k významným změnám teploty oka o několik dní až týden před nástupem dalších klinických příznaků infekce BVDV, což naznačuje, že tato techniku se dá použít při vývoji časně predikce indexu onemocnění. Teplota paznehtů krav infikovaných virem slintavky a kulhavky byla zkoumána pomocí Rainwater-Lovett a kol. (2009). Termografické snímky ukázaly výrazné zvýšení teploty paznehtů zvířat trpících tímto onemocněním ještě před objevením se klinických příznaků. Termografii lze také použít při studiích s jinými patologickými stavy, jako jsou muskuloskeletální afekce, měření orbitální teploty pro včasné odhalení onemocnění telat.

3.17 Detekce ektoparazitů

Tato technika byla také použita pro detekci ektoparazitů, kteří jsou považováni za limitující faktory pro produkci mléčného skotu. Vzhledem k tomu, že teplota ektoparazita je regulována prostředím, pokud jsou na povrchu zvířete, jeho tepelný obraz vystupuje z teplejšího těla hostitele. Proto lze infračervenou termografii použít jako nástroj k počítání těchto parazitů bez ohledu na barvu srsti zvířete. Termografické snímky v kombinaci s automatickým počítacím softwarem byly použity k přesnému určení stupně zamoření rohatými mouchami u skotu (Dall'Cortivo a kol. 2014).

3.18 Metabolismus a výživa

Bylo navrženo několik technik na měření produkce emisí metanu u přežvýkavců, avšak tato hodnocení vyžadují omezení zvířat a použití invazivních technik s drahým vybavením a vysokými provozními náklady. Infračervená termografie byla tedy použita jako neinvazivní nástroj pro predikci produkce emisí metanu, protože je jednodušší než konvenční metody (Baowei a kol. 2007; Montanholi a kol. 2008). Další studií vyhodnotili, že nejlepší čas je během cirkadiánního cyklu a odpovídá počtem termogramů v čase, tito autoři potvrdili možnost zvýšení předvídatelnosti krmné účinnosti s využitím infračervené termografie, což může směřovat v aplikaci této technologie směrem k selekci výkonnějšího masného skotu. Toto nepřímé hodnocení účinnosti krmiva bylo levnější a s nižším prediktivním limitem ve srovnání s konvenčním měřením příjmu krmiva.

Studie energetického metabolismu ukázaly, že produkce hovězího masa je efektivnější s nižšími tepelnými ztrátami (Castro Bulle a kol. 2007) a produkci metanu (Hegarty a kol. 2007), proto mají výkonnější zvířata nižší povrchovou teplotu těla ve srovnání s méně výkonnými zvířaty.

Také při produkci kuřat byla termografie použita k identifikaci metabolické aktivity a příjmu krmiva měřením povrchové teploty ptáků (Ferreira a kol. 2011; Nascimento a kol. 2014). Malheiros a kol. (2020) pozorovali, že snížením okolní teploty z 35 na 20°C došlo ke snížení kloakální a povrchové teploty u 7denních kuřat.


3.19 Hodnocení adaptability na teplo

Hodnocení adaptability a tolerance vůči teplu je dáno především měřením fyziologických parametrů, jako je tělesná teplota a dechová frekvence (Costa a kol. 2015). K vyhodnocení těchto parametrů je však často nutné zvíře znehybnit, což může způsobit velký stres kvůli manipulaci (Mazieiro a kol. 2012). Termografie tak vzniká jako neinvazivní a vzdálený nástroj pro odběr vzorků, který může pomoci při identifikaci stresu zvířat. Termografické snímky mohou naznačovat změny v průtoku krve vyplývající ze zvýšené tělesné teploty související se stresovými podmínkami prostředí. Teplota specifických oblastí zvířete, jako jsou oči, krk, tlama, žebra, záď, slabina, břicho, stehno, holeň, vemeno a chodidlo byly získané pomocí infračervené termografie a vedly k predikci fyziologických parametrů a stresu u hospodářských zvířat (Montanholi a kol. 2008; Luzi a kol. 2013; Soerensen a kol. 2014; Weschenfelder a kol. 2014). Infračervené termografické měření tělesné teploty z oční oblasti prasat před porážkou se ukázalo jako slibná technika k předpovědi změn důležitých znaků kvality masa (Weschenfelder a kol. 2013). Paim a kol. (2012) pozorovali, že teploty získané infračerveným termografem z tlamy, krku a záďě byly dobrými ukazateli podmínek prostředí a tepelné pohody jehňat; tyto body zvířecího těla jsou považovány za preferované pro měření tepelné situace zvířete.

3.20 Rozpoznání prasklých vajec na základě strojového vidění

Vzhledem k tomu, že praskliny na skořápce jsou obtížně rozpoznatelné kvůli okolním zvýrazněným tmavým skvrnám na povrchu vejce pod osvětlením, byla navržena nová metoda

identifikace prasklin na základě strojového vidění. Po analýze charakteristik prasklin na obrázku vejce pod osvětlením zezadu byl použit negativní Laplacianův Gaussův operátor k efektivnímu zvýraznění prasklin. Poté byl přijat algoritmus prahování hystereze k získání správných prahových hodnot, které eliminovaly irelevantní tmavé skvrny v binárním obrazu vajec a zajistily kontinuitu trhlin. Nakonec byl použit vylepšený index LFI (Local Fitting Image) k odlišení oblasti trhliny od oblasti s nesprávným označením (Guanjun a kol. 2019). Aby se zvýraznily praskliny na povrchu vajec, výzkum založený na strojovém vidění obecně používá podsvícení. Vzhledem k tomu, že vejce by byla před vstupem do zpracovatelské linky vyčištěna, povrch vajec by se během detekce trhlin nezbarvil. Podsvícení však také zvýrazňuje tmavé skvrny na skořápce, což ztěžuje detekci prasklin. Tento článek použil komerčně dostupná slepičí vejce jako studijní objekty, jejichž snímky byly pořízeny při podsvícení. Negativní LOG (Laplacian of Gaussian) operátor byl použit ke zvýraznění existujících trhlin na povrch vajec. Poté byl získán binární obraz metodou hystereze prahování. Nakonec byla oblast trhliny identifikována pomocí parametru tvarového znaku vylepšeného indexu LFI (Local Fitting Image). Navržená metoda byla ověřena experimentem s mírou identifikace rozbitých vajec 92,5% (Guanjun a kol. 2019).



Obrázek 3 | Vajíčka z pohledu kamery a segmentace s pevnou velikostí. Převzato od Guanjun a kol 2019.

3.21 Welfare

Precizní chov hospodářských zvířat využívá vývoj informačních technologií pro chov hospodářských zvířat ke zvýšení a zajištění produktivity, zdraví a dobrých životních podmínek. Takové IT jsou určeny k automatickému a kontinuálnímu sledování parametrů založených na zvířatech nebo prostředí v reálném čase pro jednotlivá zvířata (Berckmans 2017) Vytváření „digitálních reprezentací“ zvířat, která má zlepšit sledování zvířat tím, že zemědělcům poskytne důležité informace o jednotlivých zvířatech (Norton a kol. 2019) Řešením pro automatizaci hodnotících opatření by tedy mohla být IT vyvinutá v oblasti výzkumu precizního chovu zvířat. Ačkoli se může zdát nepravděpodobné, že farmy napříč regiony a zeměmi budou mít nainstalované dostatečně podobné systémy, aby mohly používat vzdálené hodnocení pro účely certifikace. Precizní chov vyžaduje vysokou úroveň spolupráce mezi výzkumnými obory a specialisty včetně biosystémových inženýrů, datových vědců, vědců zabývajících se zvířaty a

etologů (Norton a kol. 2019). Proto je důležité porozumět obecné terminologii v oboru. Obecné pojmy zahrnují cílovou proměnnou, zlatý standard, proměnnou vlastností, terénní data a označení (Norton a kol. 2019; Berckmans 2013). Pro monitorování welfare je cílová proměnná přímo spojena se studovanou problematikou welfare a může být měřena validovaným zlatým standardem. Zlatý standard je však omezený, protože jej nelze měřit nepřetržitě a v reálném čase. Pro nepřímé měření cílové proměnné, např. výkonu, je tedy zapotřebí proměnná funkce agresivního chování. Proměnná funkce je extrahována z terénních dat shromážděných prostřednictvím senzorů, jako jsou kamery, mikrofony nebo senzory připojené ke zvířeti. Jsou vyvinuty dva algoritmy; jeden pro extrakci funkce proměnné z dat pole, což vyžaduje podrobné označení dat pole, a jeden pro přiřazení proměnné funkce k cílové proměnné, která vyžaduje měření zlatého standardu. Vývoj systému precizního chovu pro konkrétní problematiku welfare tedy může být v různých fázích vývoje v závislosti na tom, zda je studována proměnná funkce nebo cílová proměnná (nebo obojí) a zda je systém vyvíjen, ověřován nebo implementován.

4 Závěr

Precizní zemědělství přináší celou řadu nástrojů využitelných k optimalizaci řízení stáda, tedy ke zlepšení zdravotního stavu, produkci, reprodukci a welfare chovaných zvířat. Na trhu se nachází velké množství monitorovacích senzorů pomocí, kterých může chovatel přesněji detekovat mastitidy, dermatitidy, může sledovat fenotypizaci u živých zvířat, problémy s končetinami, metabolické poruchy, ektoparazity, rozpoznání prasklých vajec nebo může detekovat samotné projevy chování (projevy agresivního chování). Pro využití těchto informací se předpokládá nutnost zájmu o práci s daty, což v počátku vede ke zvýšení pracovního zatížení. Tyto technologie nahrazují lidskou práci, ale je třeba zmínit, že ani nejlepší technologie plně nenahradí člověka. Vždy je vhodnější, aby si chovatel svá zvířata kontroloval individuálně a tyto technologie bral pouze jako doplněk. Ačkoliv se jedná o poměrně novou technologii, využití umělé inteligence představuje budoucnost v chovu hospodářských zvířat. Zpracované téma je aktuálním tématem živočišné výroby. Pro jeho zdokonalení a snažší implementaci do velkochovu je zapotřebí další výzkum.

5 Literatura

- Adamczak L, Chmiel M, Florowski T, Pietrzak D, Witkowski M, Barczak T. 2018. The use of 3D scanning to determine the weight of the chicken breast. *Comput Electron Agric* **155**:394-399.
- Alsaad M, Syring C, Dietrich J, Doherr MG, Gujan T, Steiner A. 2014. A field trial of infrared thermography as a non-invasive diagnostic tool for early detection of digital dermatitis in dairy cows. *Vet Journal* **199**:281-285.
- Alsaahaf A, Azzopardi G, Ducro B, Hanenberg E, Veerkamp RF, Petkov N. 2019. Estimation of muscle scores of live pigs using a Kinect camera. *7*:52238-52245.
- Arganda-Carreras I, Turaga SC, Berger DR, Cire san D, Giusti A, Gambardella LM. 2015. Crowdsourcing the creation of image segmentation algorithms for connectomics. *Front Neuroanat* **9**:142.
- Atherton TJ, Kerbyson DJ. 1999. Size invariant circle detection. *Image Vis Comput* **17**:795-803.
- Baowei W, Encui Y, Genhui X, Jinku H. 2007. Theoretical study of reaction paths and transition states on conversion methane into C2 hydrocarbons through plasma **15**:44-50.
- Barnard S, Calderara S, Pistocchi S, Cucchiara R, Podaliri-Vulpiani M, Messori S, Ferri N. 2016. Quick, accurate, smart: 3d computer vision technology helps assessing confined animals' behaviour. *Plos One Journal*
- Berckmans D. 2017. General introduction to precision livestock farming. *Animal Frontiers* **7**:6-11.
- Bercovich A, Edan Y, Alchanatis V, Moallem U, Parmet Y, Honig H, Maltz E, Antler A, Halachmi I. 2013. Development of an automatic cow body condition scoring using body shape signature and Fourier descriptors. *Journal of Dairy Science* **96**:8047-8059.
- Berry RJ, Kennedy AD, Scott SL, Kyle BL, Schaefer AL. 2003. Daily variation in the udder surface temperature of dairy cows measured by infrared thermography: potential for mastitis detection. *Canadian Journal of Animal Science* **83**:687-693.
- Bewley JM, Peacock AM, Lewis O, Boyce RE, Roberts DJ, Coffey MP. 2008. Potential for estimation of body condition scores in dairy cattle from digital images. *Journal of Dairy Science* **91**:3439-3453.
- Boyle WS, Smith GE. Buried channel charge coupled devices. **9**. **1973**. Available online at: <https://patents.google.com/patent/US3792322> (accessed May 17, 2019).
- Burger W, Burge MJ. 2015. *Digital image processing: An Algorithmic Introduction Using Java*. 2nd ed. London: Springer London 811.
- Burnham KP, Anderson DR (editors). 2004. *Model Selection and Multimodel Inference – A Practical Information – Theoretic Approach*. Springer New York 149-203.
- Byrne DT, Berry DP, Esmonde H, McGovern F, Creighton P, McHugh N. 2019. Infrared thermography as a tool to detect hoof lesions in sheep. *Transl Anim Science* **3**:577-88.
- Byrne DT, Berry DP, Esmonde H, McHugh N. 2017. Temporal, spatial, inter-, and intra-cow repeatability of thermal imaging. *Journal Animal Science* **95**:970-979.
- Cadéro A, Aubry A, Brossard L, Dourmad JY, Salaün Y, Garcia-Launay F. 2018. Modelling interactions between farmer practices and fattening pig performances with an individual-based model. *Animal* **12**:1277-1286.

- Carabús A, Gispert M, Font-i-Furnols M. 2016. Imaging technologies to study the composition of live pigs: a review. *Spanish Journal of agricultural research* **14**:1-16.
- Castro Bulle FCP, Paulino PV, Sanches AC, Sainz RD. 2007. Growth, carcass quality, and protein and energy metabolism in beef cattle with different growth potentials and residual feed intakes. *Journal of Animal Science* **85** (4):928–936.
- Cevik KK. 2020. Deep Learning Based Real-Time Body Condition Score Classification System. *IEEE ACCESS* **8**:213950-213957
- Cook NJ, Chabot B, Lui T, Bench CJ, Schaefer AL. 2015. Infrared thermography detects febrile and behavioural response to vaccination of weaned pigs. *Animal* **9** (2):339–346.
- Costa ANL, Feitosa JV, Montezuma Jr PA, Souza PT, Araújo AA. 2015. Rectal temperatures, respiratory rates, production, and reproduction performances of crossbred Girolando cows under heat estresse in northeastern Brazil. *International Journal of Biometeorology* **59** (11):1647–1653.
- Cox S. 2002. Information technology: the global key to precision agriculture and sustainability. *Computers Electronics in Agriculture* **36**:93–111.
- Crivellaro RS, Júnior WT. 2007. Infravermelho na ciência forense. Instituto Geral de Perícias, Departamento de Criminalística.
- Dall’Cortivo P, Dias E, Silva ICM, Brettas AA, Pereira G, McManus C. 2014. Automatic determination of horn fly (*Haematobia irritans*) infestation in livestock using infrared images. In: Annual Meeting of the Brazilian Society of Animal Science. Brazilian Society of Animal Science **51**.
- Doeschl-Wilson AB, Green DM, Fisher AV, Carroll SM, Schofield CP, Whittemore CT. 2005. The relationship between body dimensions of living pigs and their carcass composition. *Meat Science* **70**:229–240.
- Eddy AL, Van Hoogmoed LM, Snyder JR. 2001. The role of thermography in the management of equine lameness. *Veterinary Journal* **162** (3):172–181.
- Engel B, Lambooij E, Buist WG, Vereijken P. 2012. Lean meat prediction with HGP, CGM and CSB-Image-Meater, with prediction accuracy evaluated for different proportions of gilts, boars and castrated boars in the pig population. *Meat Science* **90**:338–344.
- Fernandes AFA, Dórea JRR, Fitzgerald R, Herring W, Rosa GJM. 2019. A novel automated system to acquire biometric and morphological measurements and predict body weight of pigs via 3D computer vision. *Journal of Animal Science* **97**:496–508.
- Fernandes AFA, Turra EM, de Alvarenga ÉR, Passafaro TL, Lopes FB, Alves GFO, Singh V, Rosa GJM. 2020. Deep learning image segmentation for extraction of fish body measurements and prediction of body weight and carcass traits in Nile tilapia. *Computers and Electronics in Agriculture* **170**:105-274.
- Fernandes AFA, Dórea JRR, Fitzgerald R, Herring W, Rosa CJM. 2019. A novel automated system to acquire biometric and morphological measurements and predict body weight of pigs via 3D computer vision. *Journal of Animal Science* **97**:496–508.
- Ferreira VMOS, Francisco NS, Belloni M, Aguirre GMZ, Caldara FR, Nääs IA, Garcia RG, Almeida Paz ICL, Polycarpo GV. 2011. Infrared thermography applied to the evaluation of metabolic heat loss of chicks fed with different energy densities. *Brazil Journal of Poultry Science* **13** (2):113–118.

- Font-i-Furnols M, Carabús A, Pomar C, Gispert M. 2015. Estimation of carcass composition and cut composition from computed tomography images of live growing pigs of different genotypes. *Animal*. **9**:166–178.
- Gomes RA, Monteiro GR, Assis GJF, Busato KC, Ladeira MM, Chizzotti ML. 2016. Technical note: estimating body weight and body composition of beef cattle through digital image analysis. *Journal of Animal Science* **94**:5414–5422.
- Halachmi I, Klopčič M, Polak P, Roberts DJ, Bewley JM. 2013. Automatic assessment of dairy cattle body condition score using thermal imaging. *Computers and Electronics in agricultural science* **99**:35–40.
- Hegarty RS, Goopy JP, Herd RM, McCorkell B. 2007. Cattle selected for lower residual feed intake have reduced daily methane production. *Journal of Animal Science* **85** (6):1479–1487.
- Holmes LC, Gaughan EM, Gorondy DA, Hogge S, Spire MF. 2003. The effect of perineural anesthesia on infrared thermographic images of the forelimb digits of normal horses. *Canadian Veterinary Journal* **44** (5):392–396.
- Hovinen M, Pyörälä S. 2011. Invited review: udder health of dairy cows in automatic milking. *Journal of Dairy Science* **94** (2):547–562.
- Hovinen M, Siivonen J, Taponen S, Hänninen L, Pastell M, Aisla AM. 2008. Detection of clinical mastitis with the help of a thermal camera. *Journal of Dairy Science* **91**:4592–4598.
- Chen C, Zhu W, Steibel J, Siegford J, Wurtz K, Han J. 2020. Recognition of aggressive episodes of pigs based on convolutional neural network and long short-term memory. *Computers and Electronics in agricultural science* **169**:105–166.
- Jackman P, Sun DW, Allen P, Brandon K, White AM. 2010. Correlation of consumer assessment of longissimus dorsi beef palatability with image colour, marbling and surface texture features. *Meat Science* **84**:564–568.
- Kashiha MA, Bahr C, Haredasht SA, Ott S, Moons CPH, Niewold TA. 2013. The automatic monitoring of pigs water use by cameras. *Computers and Electronics in agricultural science* **90**:164–169.
- Kashiha MA, Bahr C, Ott S, Moons CPH, Niewold TA, Ödberg FO. 2013. Automatic identification of marked pigs in a pen using image pattern recognition. *Computers and Electronics in agricultural science* **93**:111–120.
- Kheradmand A, Milanfar P. 2015. Non-linear structure-aware image sharpening with difference of smoothing operators. *Front ICT* **2**:22.
- Khoshnoudi-Nia S, Moosavi-Nasab M. 2019. Prediction of various freshness indicators in fish fillets by one multispectral imaging system. *Science of Reproduction* **9**:14704.
- Knížková I, Kunc P, Gürdíl GAK, Pinar Y, Selvi KÇ. 2007. Applications of infrared thermography in animal production. *Anadolu Journal of Agricultural Science* **22** (3):329–336.
- Kongsro J. 2014. Estimation of pig weight using a Microsoft Kinect prototype imaging system. *Computers and Electronics in Agricultural* **109**:32–35.
- Kotrba R, Knížková I, Kunc P, Bartoš L. 2007. Comparison between the coat temperature of the eland and dairy cattle by infrared thermography. *Journal of Thermal Biology* **32** (6):355–359.

- Kunc P, Knížková I, Příklad M, Maloun J. 2007. Infrared thermography as a tool to study the milking process: a review. *Agricultura Tropica et Subtropica* **40** (1):29–32
- Lao F, Brown-Brandl T, Stinn JP, Liu K, Teng G, Xin H. 2016. Automatic recognition of lactating sow behaviors through depth image processing. *Computers and Electronics in Agricultural* **125**:56–62.
- Lavers C, Franks K, Floyd M, Plowman A. 2005. Application of remote thermal imaging and night vision technology to improve endangered wildlife resource management with minimal animal distress and hazard to humans. *Journal of Physics: Conference Series* **15**:207–212.
- LeCun Y, Bottou L, Bengio Y, Haffner P. 1998. Gradient-based learning applied to document recognition. *Proceedings of IEEE* **86**:2278–2324.
- Levet T, Martens A, Devisscher L, Duchateau L, Bogaert L, Vlaminck L. 2009. Distal limb cast sores in horses: risk factors and early detection using thermography. *Equine Veterinary Journal* **41** (1):18–23.
- Li N, Ren Z, Li D, Zeng L. 2019. Review: automated techniques for monitoring the behaviour and welfare of broilers and laying hens: towards the goal of precision livestock farming. *Animal* **14**:617–25.
- Lin SSP. Automated Pattern Recognition of Beef. **1978**. Available online at: <http://krex.k-state.edu/dspace/bitstream/handle/2097/13198/LD2668R41978L54.pdf?sequence=1> (accessed August 29, 2022).
- Lind NM, Vinther M, Hemmingsen RP, Hansen AK. 2005. Validation of a digital video tracking system for recording pig locomotor behaviour. *Journal of Neuroscience Methods* **143**:123–32.
- Lister M. 1995. *The photographic image in digital culture*. Routledge
- Litjens G, Sánchez CI, Timofeeva N, Hermsen M, Nagtegaal I, Kovacs I. 2016. Deep learning as a tool for increased accuracy and efficiency of histopathological diagnosis. *Science of Reproduction* **6**:262-286.
- Lucas D, Brun A, Gispert M, Carabús A, Soler J, Tibau J, Font-i-Furnols M. 2017. Relationship between pig carcass characteristics measured in live pigs or carcasses with Piglog, Fat-o-Meat'er and computed tomography. *Livestock Science* **197**:88– 95.
- Luzi F, Mitchell M, Nanni Costa L, Redaelli V. 2013. *Thermography: Current Status and Advances in Livestock Animals and in Veterinary Medicine*. Brescia Foundation.
- Malheiro RD, Moraes VMB, Bruno LDG. 2000. Environmental temperature and cloacal and surface temperatures of broilers chicks in first week post hatch. *Journal of Applied Poultry Research* **9** (1):111–117.
- Martin I, Mattos MCC, Ferreira JCP. 2012. Plasma concentration of progesterone and cortisol in Nelore cows (*Bos taurus indicus*) submitted to daily or weekly handling. *Veterinária e Zootecnia* **19** (3):366–372.
- Martins RFS, do Prado Paim T, de Abreu Cardoso C, Stéfano Lima Dallago B, de Melo CB, Louvandini H. 2013. Mastitis detection in sheep by infrared thermography. *Research of Veterinary Science* **94**:722–4.
- Martins RFS, Paim TP, Cardoso CA, Dallago BSL, Melo CB, Louvandini H, Mcmanus C. 2013. Mastitis detection in sheep by infrared thermography. *Research of Veterinary Science* **94** (3):722–724.

- Matthews SG, Miller AL, Plötz T, Kyriazakis I. 2017. Automated tracking to measure behavioural changes in pigs for health and welfare monitoring. *Science of Reproduction* **7**:175-182.
- Mazur-Milecka M, Ruminski J. 2020. Deep learning based thermal image segmentation for laboratory animals tracking. *THERMOGRAPHY JOURNAL* **18**:159-176.
- McKinney SM, Sieniek M, Godbole V, Godwin J, Antropova N, Ashrafian H. 2020. International evaluation of an AI system for breast cancer screening. *Nature* **577**:89–94.
- McManus C, Tanure CB, Peripolli V, Seixas L, Fischer V, Gabbi AM. 2016. Infrared thermography in animal production: an overview. *Computers and Electronics in Agriculture* **123**:10–6.
- Metzner M, Sauter-Louis C, Seemueller A, Petzl W, Zerbe H. 2015. Infrared thermography of the udder after experimentally induced *Escherichia coli* mastitis in cows. *Veterinary Journal* **204**:360–362.
- Microsoft. 2014. Kinect SDK for Windows. Available from <https://developer.microsoft.com/en-us/windows/kinect/> [accessed August 12, 2020].
- Montanholi YR, Nicholas EO, Kendall CS, Schenkel FS, McBride BW, Miller SP. 2008. Application of infrared thermography as an indicator of heat and methane production and its use in the study of skin temperature in response to physiological events in dairy cattle (*Bos taurus*). *Journal of Thermal Biology* **33** (8):468–475.
- Murphy KP. 2012. *Machine Learning: A Probabilistic Perspective*. Cambridge, Massachusetts: MIT Press. Available at: <http://mitpress.mit.edu> (accessed June 18, 2019).
- Nahm FS. 2013. Infrared thermography in pain medicine. *Korean Journal Pain* **26** (3):219–222.
- Nakagomi K, Shimizu A, Kobatake H, Yakami M, Fujimoto K, Togashi K. 2013. Multi-shape graph cuts with neighbor prior constraints and its application to lung segmentation from a chest CT volume. *Medical Image Analysis* **17**:62–77.
- Nascimento GR, Nääs IA, Baracho MS, Pereira DF, Neves DN. 2014. Infrared thermography in the estimation of thermal comfort of broilers. *Revista Brasileira de Engenharia Agrícola e Ambiental* **18** (6), 658–663.
- Nasirahmadi A, Edwards SA, Sturm B. 2017. Implementation of machine vision for detecting behaviour of cattle and pigs. *Livestock Science* **202**:25–38.
- Neves DP, Mehdizadeh SA, Tschärke M, Nääs I de A, Banhazi TM. 2015. Detection of flock movement and behaviour of broiler chickens at different feeders using image analysis. *Information Process in Agricultural* **2**:177–182.
- Nikkhah A, Plaizier JC, Einarson MS, Berry RJ, Scott SL, Kennedy AD. 2005. Infrared thermography and visual examination of hooves of dairy cows in two stages of lactation. *Journal of Dairy Science* **88** (8):749–2753.
- Norton T, Chen C, Larsen MLV, Berckmans D. 2019. Precision livestock farming: Building ‘digital representations’ to bring the animals closer to the farmer. *Animal* **13**:309–317.
- Okinda C, Lu M, Liu L, Nyalala I, Muneri C, Wang J. 2019. A machine vision system for early detection and prediction of sick birds: a broiler chicken model. *Biosystem Engineering* **188**:229–42.

- Ostermeier GC, Sargeant GA, Yandell BS, Parrish JJ. 2001. Measurement of bovine sperm nuclear shape using fourier harmonic amplitudes. *Journal of Andrology* **22**:584–94.
- Ott S, Moons CPH, Kashiha MA, Bahr C, Tuytens FAM, Berckmans D. 2014. Automated video analysis of pig activity at pen level highly correlates to human observations of behavioural activities. *Livestock Science* **160**:132–137.
- Ozkaya S, Neja W, Krezel-Czopek S, Oler A. 2016. Estimation of body weight from body measurements and determination of body measurements on Limousin cattle using digital image analysis. *Animal Production Science* **56**:2060–2063.
- Paim TP, Borges BO, Lima PMT. 2012. Relation between thermographic temperatures of lambs and thermal comfort indices. *International Journal of Application Animal Science* **1** (4):108–115.
- Paluchowski LA, Misimi E, Grimsno L, Randeberg LL. 2016. Towards automated sorting of Atlantic cod (*Gadus morhua*) roe, milt, and liver – Spectral characterization and classification using visible and near-infrared hyperspectral imaging. *Food Control* **62**:337–345.
- Pezeshki A, Stordeur P, Wallemacq H, Schynts F, Stevens M, Boutet P, Peelman LJ, De Spiegeleer B, Duchateau L, Bureau F, Burvenich C. 2011. Variation of inflammatory dynamics and mediators in primiparous cows after intramammary challenge with *Escherichia coli*. *Veterinary Research* **42** (15):1–10.
- Pezzuolo A, Guarino M, Sartori L, González LA, Marinello F. 2018. Onbarn pig weight estimation based on body measurements by a Kinect v1 depth camera. *Computers and Electronics in Agricultural* **148**:29–36.
- Plant RE. 2001. Site-specific management: the application of information technology to crop production. *Computers and Electronics in Agriculture* **30**:9–29.
- Polat B, Colak B, Cengiz M, Yanmaz LE, Bastan A, Kaya S, Hayirl A. 2010. Sensitivity and specificity of infrared thermography in detection of subclinical mastitis in dairy cows. *Journal of Dairy Science* **93** (8):3525–3532.
- Polesel A, Ramponi G, Mathews VJ. 2000. Image enhancement via adaptive unsharp masking. *IEEE Trans Image Process* **9**:505–510.
- Pomar C, Remus A. 2019. Precision pig feeding: a breakthrough toward sustainability. *Animal Front* **9**:52–59.
- Psota ET, Mittek M, Pérez LC, Schmidt T, Mote B. 2019. Multi-pig part detection and association with a fully-convolutional network. *Sensors* **19**:852.
- Qiao YL, Su D, Kong H. 2019. Individual Cattle Identification Using a Deep Learning Based Framework. *IFAC PAPERSONLINE* **52**:318-323.
- Ravoor PC, Sudarshan TSB. 2020. Deep Learning Methods for Multi-Species Animal Re-identification and Tracking - a Survey. *COMPUTER SCIENCE REVIEW* **38**:1-10.
- Ring F, Jung A, Zuber J. 2015. *Infrared Imaging A Casebook in Clinical Medicine*. Bristol-UK: IOP Publishing.
- Roberto JVB, Souza BB, Delfino LJB, Marques BB. 2014. Thermal gradients and physiological responses of goats in the Brazilian semi-arid using thermography infrared. *Journal of Animal Behavior* **2** (1):11–19.

- Saberioon M, Gholizadeh A, Cisar P, Pautsina A, Urban J. 2017. Application of machine vision systems in aquaculture with emphasis on fish: state-of-the-art and key issues. *Review of Aquacultural* **9**:369–387.
- Saberioon MM, Cisar P. 2016. Automated multiple fish tracking in threeDimension using a Structured Light Sensor. *Computers and Electronics in Agricultural* **121**:215–21.
- Salau J, Haas JH, Junge W, Thaller G. 2017. Automated calculation of udder depth and rear leg angle in Holstein-Friesian cows using a multi-Kinect cow scanning system. *Biosystem Engeering* **160**:154–169.
- Sassi N, Averós X, Estevez I. 2016. Technology and poultry welfare. *Animals* **6**:62–83.
- Scoley GE, Gordon AW, Morrison SJ. 2019. Use of thermal imaging in dairy calves: exploring the repeatability and accuracy of measures taken from different anatomical regions. *Animal Science* **3**:564–576.
- Schaefer AL, Cook NJ, Bench C, Chabot JB, Colyn J, Liu T, Okine EK, Stewart M, Webster JR. 2012. The non-invasive and automated detection of bovine respiratory disease onset in receiver calves using infrared thermography. *Research in Veterinary Science* **93** (2):928–935.
- Schaefer AL, Cook NJ, Church JS, Basarab J, Perry B, Miller C, Tong AKW. 2007. The use of infrared thermography as an early indicator of bovine respiratory disease complex in calves. *Research in Veterinary Science* **83** (3):376–384.
- Schaefer AL, Cook NJ, Tessaro SV, Deregt D, Desroaches G, Dubeski P, Tong AKM, Godson DL. 2004. Early detection and prediction of infection using infrared thermography. *Canadian Journal of Animal Science* **84**:73–80.
- Schaefer AL, Matthews LR, Cook NJ, Webster J, Scott SL. 2002. Novel noninvasive measures of animal welfare. In: *Animal Welfare and Behaviour: From Science Solution, Joint NAWAC/ISAE Conference*. 27–28 June 2002. Hamilton, New Zeland.
- Schofield CP, Marchant JA, White RP, Brandl N, Wilson M. 1999. Monitoring pig growth using a prototype imaging system. *Journal of Agricultural Engeering Research* **72**:205–210.
- Soerensen DD, Clausen S, Mercer JB, Pedersen LJ. 2014. Determining the emissivity of pig skin for accurate infrared thermography. *Computers and Electronics in Agricultural* **109**:52–58.
- Soerensen DD, Pedersen LJ. 2015. Infrared skin temperature measurements for monitoring health in pigs: a review. *Acta Veterinaria Scandinavia* **57** (1):1–11.
- Speakmen JR, Ward S. 1998. Infrared thermography: principle and applications. *Zool. Anal. Complex Syst.* **101**:224–232.
- Spoliansky R, Edan Y, Parmet Y, Halachmi I. 2016. Development of automatic body condition scoring using a low-cost 3-dimensional Kinect camera. *Journal of Dairy Science* **99**:7714–7725.
- Stafford JV. 2000. Implementing precision agriculture in the 21st century. *Journal of Agricultural Engineering Research* **76**:267–275.
- Stavarakakis S, Guy JH, Warlow OME, Johnson GR, Edwards SA. 2014. Walking kinematics of growing pigs associated with differences in musculoskeletal conformation, subjective gait score and osteochondrosis. *Livestock Science* **165**:104–113.

- Stavarakakis S, Li W, Guy JH, Morgan G, Ushaw G, Johnson GR. 2015. Validity of the Microsoft Kinect sensor for assessment of normal walking patterns in pigs. *Computers and Electronics in Agricultural* **117**:1–7.
- Stewart M, Stafford K, Dowling S, Schaefer A, Webster J. 2008. Eye temperature and heart rate variability of calves disbudded with or without local anaesthetic. *Physiology&Behavior* **93** (4):789–797.
- Szelisk R. 2011. Computer vision: algorithms applications. In: Gries D, Schneider FB. London: Springer-Verlag.
- Terven JR, Córdova-Esparza DM. 2016. Kin2. A Kinect 2 toolbox for MATLAB. *Science in Computers Program*. **130**:97–106.
- The MathWorks. 2017. MATLAB Release 2017. Available from https://www.mathworks.com/products/new_products/release2017b.html
- Tillett RD, Onyango CM, Marchant JA. 1997. Using model-based image processing to track animal movements. *Computers and Electronics in Agricultural* **17**:249–261.
- Van Dijck J. 2008. Digital photography: communication, identity, memory. *Vis Commun*. **7**:57–76.
- Van Hoogmoed LM, Snyder JR. 2002. Use of infrared thermography to detect injections and palmar digital neurectomy in horses. *Veterinary Journal* **164** (2):129–141.
- Viazzi S, Ismayilova G, Oczak M, Sonoda LT, Fels M, Guarino M. 2014. Image feature extraction for classification of aggressive interactions among pigs. *Computers and Electronics in Agricultural* **104**:57–62.
- Viola P, Jones MJ. 2004. Robust Real-Time Face Detection. *International Journal of Computer Vis*. **57**:137–54.
- Wang Y, Yang W, Winter P, Walker L. 2008. Walk-through weighing of pigs using machine vision and an artificial neural network. *Biosystems Engineering* **100**:117–125.
- Weschenfelder AV, Maldague X, Rocha LM, Schaefer AL, Saucier L, Faucitano L. 2014. The use of infra-red thermography for pork quality prediction. *Meat Science* **96** (1):120–125.
- Weschenfelder AV, Saucier L, Maldague X, Rocha LM, Schaefer AL, Faucitano L. 2013. Use of infrared ocular thermography to assess physiological conditions of pigs prior to slaughter and predict pork quality variation. *Meat Science* **95**:616–620.
- Whelan BM, McBratley AB. 2000. The null hypothesis of precision agriculture management. *Precision Agriculture* **2**:265–279.
- Xiong Z, Sun D-W, Zeng X-A, Xie A. 2014. Recent developments of hyperspectral imaging systems and their applications in detecting quality attributes of red meats: a review. *Journal of Food Engineering* **132**:1–13.
- Yang C, Li G, Zhang X, Gu X. 2018. Udder skin surface temperature variation preand post-milking in dairy cows as determined by infrared thermography. *Journal of Dairy Research* **85**:201–213.
- Zaninelli M, Redaelli V, Luzi F, Bronzo V, Mitchell M, Dell’Orto V. 2018. First evaluation of infrared thermography as a tool for the monitoring of udder health status in farms of dairy cows. *Sensors* **18**:862.

- Zanuttigh P, Mutto CD, Minto L, Marin G, Dominio F, Cortelazzo GM. 2016. Time-of-Flight and Structured Light Depth Cameras: Technology and Applications. Cham: Springer International Publishing. p. 355.
- Zapotoczny P, Szczypinski PM, Daszkiewicz T. 2016. Evaluation of the quality of cold meats by computer-assisted image analysis. *LWT - Food Science Technology* **67**:37–49.
- Zhang D, Lu G. 2002. Shape-based image retrieval using generic Fourier descriptor. *Signal Process. Image Communication* **17**:825-848.
- Zhang N, Wang M, Wang N. 2002. Precision agriculture—a worldwide overview. *Computers and Electronics in Agriculture* **36**:113–132.

6 Seznam použitých zkratek a symbolů

AUC - Area Under Curve
BCS - Hodnocení tělesného skóre
BVDV - Bovine viral diarrhoea virus (Virus bovinního virového průjmu)
CCD - Charge-coupled device
CMOS - Complementary Metal-Oxide Semiconductor
CMT - Kalifornskému testu mastitidy
CVS - Concurrent Version System
DXA - DualEnergy X-Ray Absorptiometry
FIR - Vzdálené infračervené záření
FMD - Foot and mouth disease (Slintavka a kulhavka)
IR - Infračervené záření
IRT - Infračervená termografie
ISO - Mezinárodní organizace pro standardizaci
IT - Infračervená technologie
LFI - Local Fitting Image
LOG - Laplacian of Gaussian
MIR - Střední infračervené záření
NIR - Blízké infračervené záření
PFD - Polární Fourierovy deskriptory
PFD - Polární Fourierovy deskriptory
PSD - Deskriptory polárního tvaru
PSD - Deskriptory polárního tvaru
ROC - Receiver Operating Characteristic
SDK - Software Development Kit
SSM - Site-Specific management