



Fakulta zemědělská
a technologická
Faculty of Agriculture
and Technology

Jihočeská univerzita
v Českých Budějovicích
University of South Bohemia
in České Budějovice

JIHOČESKÁ UNIVERZITA V ČESKÝCH BUDĚJOVICÍCH

FAKULTA ZEMĚDĚLSKÁ A TECHNOLOGICKÁ

Katedra techniky a kybernetiky

Autoreferát dizertační práce

Využití moderních výpočetních metod k diagnostice
onemocnění paznehtů dojnic

Autor práce: Ing. Mgr. Radim Stehlík

Školitel: doc. RNDr. Petr Bartoš, Ph.D.

Školitel specialista: Ing. Mgr. Roman Bumbálek, Ph.D.

České Budějovice
2024

Prohlášení

Prohlašuji, že jsem autorem této kvalifikační práce a že jsem ji vypracoval pouze s použitím pramenů a literatury uvedených v seznamu použitých zdrojů.

V Českých Budějovicích dne

.....

Ing. Mgr. Radim Stehlík

Abstrakt

Dizertační práce je zaměřena na problematiku onemocnění paznehtů u mléčného skotu, která má významný dopad na zdraví zvířat a ekonomiku chovu. Práce začíná literární rešerší, která pojednává o příčinách, důsledcích a profylaxi onemocnění paznehtů, stejně jako diagnostických metodách, které byly aplikovány v rámci detekce onemocnění paznehtů u dojného skotu. Dále se věnuje moderním metodám strojového vidění a infračervené termografii, které nacházejí uplatnění v živočišné výrobě.

Cílem práce bylo vyvinout efektivní systém pro detekci zdravotních obtíží u paznehtů, přičemž využívá pokročilé metody strojového učení a segmentaci obrazových dat. Práce popisuje metodiku sběru dat, tvorby trénovacího datasetu a anotaci obrázků. Důležitou částí je aplikace segmentačního modelu s architekturou CNN, konkrétně YOLOv8, k dosažení vysoké přesnosti v identifikaci a klasifikaci zdravých a nemocných paznehtů.

Výsledky prezentují účinnost aplikovaného modelu při identifikaci a klasifikaci nemocných paznehtů, přičemž analýza dosažených metrik poskytuje podrobné poznatky o schopnosti modelu správně segmentovat a klasifikovat paznehty. V práci se diskutují výsledky aplikace klasifikačních modelů CNN ve srovnání s klasifikační sítí MobileNetV3, což přispívá k dalšímu rozvoji v oblasti diagnostických metod ve veterinární medicíně.

Klíčová slova: Infračervená termografie, onemocnění paznehtů, strojové vidění, mléčný skot.

Abstract

The thesis focuses on the issue of hoof disease in dairy cattle, which has a significant impact on animal health and the economics of breeding. The thesis begins with a literature review that discusses the causes, consequences and prophylaxis of hoof disease, as well as diagnostic methods that have been applied in the detection of hoof disease in dairy cattle. It also discusses modern methods of machine vision and infrared thermography which are both used in livestock production.

The aim of the work was to develop an effective system for the detection of hoof health problems, using advanced machine learning methods and image data segmentation. The thesis describes the methodology for data collection, training dataset creation and image annotation. An important part is the application of the segmentation model with CNN architecture, specifically YOLOv8, to achieve high accuracy in the identification and classification of healthy and diseased claws.

The results are presenting the effectiveness of the applied model in identifying and classifying diseased hooves, while the analysis of the achieved metrics provides detailed insights into the model's ability to correctly segment and classify hooves. The results of the application of the CNN classification model and the MobileNetV3 classification network are discussed, contributing to further developments in the field of diagnostic methods in veterinary medicine.

Keywords: Infrared thermography, hoof diseases, machine vision, dairy cattle.

Obsah

Úvod	6
1 Literární rešerše	8
1.1 Onemocnění paznehtu mléčného skotu	8
1.1.1 Příčiny onemocnění paznehtů	8
1.1.2 Důsledky onemocnění paznehtů	10
1.1.3 Diagnostické metody	12
1.2 Moderní metody strojového vidění a jejich aplikace	14
1.3 Infračervená termografie a její využití v živočišné výrobě	16
2 Cíle práce	18
3 Metodika	19
3.1 Sběr dat	19
3.1.1 Použité přístroje	19
3.1.2 Metodika měření	20
3.2 Tvorba datasetu	22
3.3 Segmentace oblasti paznehtů z obrazu	23
3.4 Systém pro detekci zdravotních obtíží u paznehtů	23
4 Vybrané výsledky a diskuse	26
4.1 Dílčí výsledky navrženého systému	26
4.1.1 Vlastnosti trénovacího datasetu	26
4.1.2 Výsledky trénování CNN architektury YOLOv8	31
4.1.3 Vybrané výsledky klasifikační sítě MobileNetV3	33
4.2 Aplikace modelu CNN pro přímou detekci onemocnění paznehtů	35
Závěr	39
Seznam zkratk	40
Seznam použitých zdrojů	41

Úvod

Celosvětová produkce mléka z mléčného skotu se za poslední tři desetiletí zvýšila o více než 77 %, v roce 2022 byla odhadována na 938 milionů tun (FAO et al., 2023). Vzhledem k demografickému a ekonomickému vývoji ve světě se očekává, že poptávka po mléce a mléčných výrobcích bude v blízké budoucnosti dále růst. Očekává se, že celosvětová spotřeba potravin v průběhu příštího desetiletí poroste o 1,3 % ročně (OECD/FAO, 2022).

V tomto ohledu bude stále více kladen důraz na intenzifikaci chovů, což může mít za následek vyšší výskyt zdravotních problémů. Zdravotní problémy se stávají akutnějšími s rostoucím počtem zvířat na jednotku plochy, kdy je obtížnější udržovat optimální podmínky pro jejich zdraví. Záněty paznehtů, které lze považovat za jeden z nejčastějších a ekonomicky nejnáročnějších nemocí u dojníc, se mohou rychle rozšířit a způsobit vážné ztráty (Hogeveen et al., 2019). Jedná se o závažný a komplexní problém, který se přímo podílí na pohodě zvířat. V důsledku toho dochází k výraznému nárůstu nákladů na léčbu, která často zahrnuje podávání antibiotik, aplikaci různých lokálních terapií a v krajních případech k předčasnému vyřazení zvířete z produkčního cyklu. Kromě přímých nákladů na léčbu je třeba zohlednit i ekonomické ztráty spojené se snížením produkce mléka, ztrátou hmotnosti zvířete a nutností jejich náhrady, což dále zvyšuje finanční zátěž chovatelů.

Rozšíření automatizovaného monitoringu do mléčných farem může představovat významnou výzvu 21. století. Tradiční metoda, vizuální inspekce, je časově náročná, subjektivní a může vést k opožděné identifikaci problému, mezi které patří například interdigitální dermatitida (dermatitis interdigitalis, ID), digitální dermatitida (dermatitis digitalis, DD) nebo laminitidy (laminitis, LAM). Uvedená onemocnění mohou vést k intenzivní bolesti a snížené pohyblivosti, což zvyšuje riziko rozvoje závažných zdravotních problémů a následně k poklesu produkce mléka. Udržet vysokou úroveň pozornosti při pravidelném sledování každého zvířete je obtížné a následkem nepřesnosti při pozorování může dojít k přehlédnutí počátečních příznaků a komplikaci spojené s déletrvající léčbou.

Kombinace moderních technologií, jako je infračervená termografie (Infrared thermography, IRT) a umělá inteligence (Artificial intelligence, AI), však mohou představovat nové možnosti, jak zefektivnit diagnostiku a prevenci onemocnění paznehtů dojného skotu, což by se mohlo posléze promítnout významnou měrou v rámci zlepšení welfare mléčného skotu.

IRT je neinvazivní metoda, kterou lze využít pro měření povrchové teploty těla zvířete. V kontextu chovu dojného skotu se tato technologie může jevit jako velmi slibná pro identifikaci zánětů paznehtů, které jsou obvykle doprovázeny zvýšením místní teploty v postižené oblasti. Zvýšenou teplotu lze pomocí termografických snímků snadno detekovat. Včasná detekce zvýšené teploty na paznehtech může umožnit rychlé zahájení léčby – zamezení rozvoje závažných klinických příznaků a dlouhodobých zdravotních problémů. Navíc, díky neinvazivnímu charakteru této metody, nedochází k žádnému fy-

zickému diskomfortu zvířat, a to je v souladu se současnými požadavky na zlepšování welfare hospodářských zvířat. V kontextu s rostoucím zájmem o etický chov a udržitelné praktiky, kde je kladen důraz na minimalizaci stresu a bolesti zvířat během jejich životního cyklu, se jedná o velice důležitý atribut.

Využití AI se zaměřením na zpracování obrazu může představovat velký milník v oblasti diagnostiky onemocnění paznehtů. Integrace AI do procesu analýzy termografických snímků přináší několik významných výhod, například možnost analyzovat obrovské množství dat v reálném čase, identifikovat anomálie a vzory, které by mohly uniknout lidskému oku, a upozornit chovatele na případný zdravotní problém v chovu. Díky schopnosti AI rychle a efektivně zpracovávat data lze detekovat i mírné odchylky teploty, které mohou signalizovat počáteční fáze zánětlivých procesů. To by vedlo k reakci chovatelů na daný problém dříve, než se problém dostane do závažnějšího stádia, čímž by došlo ke zlepšení šance na úspěšnou léčbu a minimalizaci nutnosti používání antibiotik. Nespornou výhodou je tedy potenciál rychlejšího zotavení a celkového zlepšení kvality života zvířat s pozitivním dopadem na produkci mléka.

Tím, že tyto technologie umožní včasnou detekci a prevenci zánětů paznehtů, přispějí k celkové udržitelnosti chovu a podpoře konkurenceschopnosti v odvětví mlékárenského průmyslu. V budoucnosti se dá očekávat, že tyto technologie budou hrát stále větší roli v řízení chovů, a to nejen v případě automatizované detekce onemocnění paznehtů, ale i v dalších oblastech s ohledem na pestrou škálu napříč spektrem chovů všech hospodářských zvířat. Jedná se tedy o nástroj, který pozitivně ovlivní produkční schopnosti a celkovou pohodu hospodářských zvířat.

Dizertační práce je zaměřena na posouzení současného stavu využití zpracování obrazu v technologii chovu skotu se zaměřením na včasnou diagnostiku onemocnění paznehtů. Práce je orientována především na využití IRT, přičemž proces sběru a předzpracování dat byl realizován v rámci projektu TAČR Delta 2 TM02000027. Hlavním výstupem je návrh systému pro detekci zdravotních obtíží u paznehtů dojníc obsahující soubor algoritmů určených pro práci s IR obrazem a vybrané metody počítačového vidění.

1 Literární rešerše

1.1 Onemocnění paznehtu mléčného skotu

Poruchy a onemocnění paznehtů jsou častou příčinou kulhání, a to až v 90 %. Jedná se o abnormální chůzi nebo odlehčování nemocí postižené končetiny u skotu. Pojem kulhání neoznačuje nemoc jako takovou. Jedná se o příznak, který může poukazovat na zdravotní problém vyskytující se například v oblasti paznehtu. Jednotlivá onemocnění u paznehtů skotu vyvolávají kulhání v odlišných mírách a liší se rovněž i pro různé fáze (Zavadilová et al., 2020).

Většina chovů skotu využívá stájový typ ustájení, kde dojnice tráví většinu času v prostředí s vysokou vlhkostí a značnou mírou infekčnosti. V kombinaci s tvrdým povrchem, na kterém zvířata stojí, a jejich vysokou hmotností, se vytvářejí podmínky vhodné pro vznik onemocnění paznehtů, jejichž typickým projevem je zánět (O'Driscoll et al., 2008).

Cockburn (2020) a Juarez et al. (2003) označují kulhání za jedno z největších zdravotních problémů v případě chovu dojníc, který představuje jeden ze tří hlavních důvodů vedoucích k předčasnému odstranění z chovu. Nejčastěji jsou tímto onemocněním postiženy zadní končetiny. Urban-Chmiel et al. (2024) odůvodňují tento předpoklad s ohledem na větší tělesné zatížení těchto končetin.

Podle Bran et al. (2018) a Browne et al. (2022) je etiopatogeneze vedoucí ke vzniku a rozvoji onemocnění paznehtů u mléčného skotu multifaktoriální povahy. Predispoziční faktory dle autorů mohou být odlišné v závislosti pro jednotlivé země, regiony, ale především i samotné farmy.

1.1.1 Příčiny onemocnění paznehtů

Intenzifikace chovů hospodářských zvířat je globálně aktuálním tématem díky rostoucímu tlaku na zajištění dostatečné produkce potravin pro rychle se zvyšující populaci a stále vyššího poptávce po levných, na bílkoviny bohatých potravinách (OECD/FAO, 2022). Tento proces, zaměřený na maximalizaci výnosů prostřednictvím moderních technologií a efektivizace systému chovu, je často vnímán jako klíčové řešení zejména v rozvojových zemích, kde jsou problémy s potravinovou bezpečností a podvýživou stále aktuální. Nicméně s intenzifikací přicházejí i závažné ekologické a zdravotní výzvy (Singh et al., 2023).

Nejčastěji uváděné faktory ovlivňující vznik problémů, mezi které patří infekční a neinfekční onemocnění končetin, souvisejí s kontrolou a řízením stáda. Zahrnují nevhodné velikosti budov, nadměrné množství zvířat na omezeném prostoru, nevyhovující povrchy pro pohyb, jako jsou roštové a jiné kluzké podlahy. Dalším rizikem jsou prudké změny směru v pohybu zvířat při přechodech z budov a jednotlivých prostor, či nedostatečně velké plochy pro odpočinek (Bran et al., 2018; Browne et al., 2022).

Neinfekčních predispozičních faktorů, které vedou k rozvoji zdravotních komplikací v oblasti končetin způsobující kulhání, je celá řada. V případě zemědělských objektů se může jednat o špatnou hygienu v chovném prostředí a různé předměty s potenciálem způsobit poranění končetin mléčného skotu. Mezi další faktory patří nedostatečné frekvence kontrol a špatné ošetřování paznehtů. V neposlední řadě může dojít k ovlivnění zdravotního stavu sezónními podmínkami v roce (Antanaitis et al., 2021; Moreira et al., 2019). Hernandez-Mendo et al. (2007) například uvádějí, že betonové, mokré povrchy jsou hlavním rizikovým faktorem výskytu lézí.

Stálý kontakt s vlhkými povrchy změkčuje a narušuje nejen pazneht, ale i kůži v jeho okolí, což oslabuje přirozenou ochrannou bariéru a zvyšuje riziko bakteriální infekce. Vlhké prostředí je proto zvláště problematické na jaře a v létě. Problém se týká především podmínek v chovu skotu ve venkovním prostředí (Buch et al., 2011).

Kromě proměnných v prostředí patří mezi další důležité faktory management chovu, který je třeba vzít v úvahu s ohledem na onemocnění paznehtů (Brujinis et al., 2012; Endres, 2017). Roche et al. (2024) zmiňují rizika, která mohou ovlivnit stav paznehtů v podobě typu ustájení (vazné nebo volné), možnosti přístupu na pastvu, typu podestýlky, velikosti stáda a další. Dle Roche et al. (2024) aspekty jako jsou vlhká stání nebo více znečištěná fekáliemi, méně časté preventivní prohlídky prováděné osobami pečujícími o paznehty, delší doby strávené mimo kotec během dojení a vyšší koncentrace zvířat na omezeném prostoru, v chovech dojeného skotu spojovány s vyšší měrou výskytu kulhání.

Složení krmné dávky patří mezi další faktor, který může ovlivnit zdraví končetin u skotu. Jedná se o vysokoenergetické krmivo, nadměrné množství bílkovin, nedostatek vlákniny, vitamínů nebo minerálů ve stravě, a nebo náhlé změny stravování, zejména v poporodním období (Antanaitis et al., 2021; Moreira et al., 2019; Thorup et al., 2016).

Někteří autoři zmiňují genetické vlivy jako možnou příčinu onemocnění paznehtů (Laursen et al., 2009; Ugglä et al., 2008; Van der Linde et al., 2010; Van der Waaij et al., 2005). Jde například o stavbu paznehtu a plemenné predispozice, zejména u holštýnsko-fríského skotu (Antanaitis et al., 2021; Moreira et al., 2019; Thorup et al., 2016). Oberbauer et al. (2013) uvádí vliv dědičnosti na zvýšené riziko digitální dermatitidy. Rozsáhlý výzkum v této oblasti prokázal, že výskyt infekčních onemocnění závisí na individuální odolnosti zvířat ve stádě. U některého kusu skotu v rámci jednoho chovu je častější výskyt infekčních onemocnění, zatímco jiné ze stejného stáda a jejich potomci nevykazují žádné příznaky onemocnění (Palmer a O'Connell, 2015; Somers et al., 2005). Thorup et al. (2016) uvádí jako možnou příčinou samotnou tělesnou konstituci a věk skotu.

Přehled od Sadiq et al. (2019) zabývající se tím, jak chovatelé dojníc vnímají kulhání a jaká opatření proti němu přijímají, poukazuje na několik klíčových překážek. Chovatelé považují nedostatek času a pracovních sil za hlavní problémy v boji proti kulhání. Cutler et al. (2017) uvádí, že právě čas a kvalifikovaná pracovní síla jsou zásadními faktory, které omezují aktivity zaměřené na kontrolu kulhání. Finanční omezení také hraje velkou roli. Leach et al. (2010) zjistil, že ve 30 % případů ve Spojeném království farmáři nejednají podle doporučení právě kvůli nedostatku financí, což potvrzují i podobná zjištění z Kanady. Sadiq et al. (2019) ve své práci uvádí, že farmáři mají jen omezené povědomí o dopadech kulhání ve vztahu k jejich zemědělské činnosti. Navíc chovatelé mléčného skotu často podceňují skutečnou míru kulhání ve svých stádech. Jedním z důvodů je zejména nedostatečná schopnost rozeznat případy, kdy je kulhání v mírné fázi (Roche et al., 2024).

1.1.2 Důsledky onemocnění paznehtů

V důsledku intenzifikace produkce mléka se zvýšilo související riziko kulhání (Huxley, 2012). Prevalence kulhání u intenzivně obhospodařovaných mléčných stád se pohybuje kolem 20 % (Cook, 2003; Espejo et al., 2006). Kulhání je jedno z nejčastěji pozorovaných zdravotních problémů skotu a je hlavní příčinou zdravotních a ekonomických ztrát v chovu mléčného skotu (Urban-Chmiel et al., 2024).

Na mléčných farmách se detekce onemocnění paznehtů u dojeného skotu provádí jen zřídka rutinně, a i když k ní dojde, často se podceňuje skutečná míra výskytu kulhání. Podcenění kulhání výrazně omezuje možnosti včasné diagnostiky a následné léčby (Sheng et al., 2023). Bolest spojená s kulháním výrazně ovlivňuje pohodu dojeného skotu (Whay et al., 2003) a tyto bolestivé stavy mohou přetrvávat týdny až měsíce (Green et al., 2002).

Zdravotní problémy spojené s končetinami představují významnou překážku pro welfare a produktivitu zvířat. Bolesti v těchto oblastech často vedou k poruchám pohybového aparátu a nesprávnému držení těla. Typickými projevy jsou omezená pohyblivost nebo nestandardní postoj, jedná se o přirozenou reakci zvířete ve snaze minimalizovat bolest v postižené části těla (Gardenier et al., 2018; Qiao et al., 2019).

Faktory prostředí, jako jsou vysoké teploty a vlhkost, mohou negativně ovlivňovat zdraví paznehtů, přispívat k tvorbě vředů, podpoře mikrobiální replikace a zvýšení závažnosti onemocnění. Tyto predispoziční faktory kulhání u skotu se mohou lišit v závislosti na způsobu chovu na farmě (Orman a Endres, 2016).

Mezi infekční faktory, které zahrnují široké spektrum bakterií a jejich doprovodným znakem může být kulhání, patří artritida (Dudek et al., 2020), hniloba rohoviny patek, kožní a multiorgánové infekce (Refaai et al., 2013), paronychie (akutní/chronická infekce paznehtů), digitální dermatitida (Refaai et al., 2013; Van Metre, 2017), interdigitální dermatitida (Berry, 2009; Van Amstel a Shearer, 2006), komplex respiračních onemocnění (Hazelton et al., 2020; Nuss, 2011) nebo interdigitální flegmóna (Refaai et al., 2013).

V případech neinfekčních onemocnění paznehtů se může jednat o vředy (Volkman et al., 2019), onemocnění bílé čáry (Best et al., 2021), hnisavou dutou stěnu (Berger, 1988) nebo například praskliny rohoviny paznehtů (Goonewardene a Hand, 1995).

Blowey (2015) ve své knize uvádí, že nevyvážená strava může způsobit poruchy tvorby stěny rohoviny u paznehtu a zvyšuje tím náchylnost ke vzniku infekčních onemocnění. Krmení dojníc snadno stravitelnými a vysokoenergetickými krmivy s nízkým obsahem vlákniny může vést k metabolickým poruchám, včetně bachorové acidózy. Při poklesu pH bachoru pod hodnotu 5 dochází ke zvýšené produkci kyseliny mléčné, což narušuje procesy fermentace. Endotoxiny, které vznikají v důsledku těchto změn, stimulují produkci a uvolňování histaminu, jenž způsobuje zúžení cév v oblasti paznehtů, což vede k jejich poškození. Patologickým důsledkem těchto procesů je rozvoj LAM.

Green et al. (2002) a Amory et al. (2008) popisují souvislost mezi onemocněním paznehtů, jako jsou vředy na chodidle, onemocnění bílé čáry a digitální dermatitidy s jejich negativním vlivem na snížení mléčné užitkovosti.

Podle Palmer a O'Connell (2015) je Mortellaroova choroba (též označení pro digitální dermatitidu) spojována s nadměrnou hustotou ustájení, špatnou hygienou paznehtů a nevyváženou krmnou dávkou. Toto multifaktoriální onemocnění může vést k trvalému poškození končetiny. Postižená zvířata vykazují výrazné kulhání a většinu času tráví vleže. Léze se obvykle nacházejí v interdigitálním prostoru nebo na kůži patek a to zejména na pánevních končetinách. Zánět je zpočátku povrchový, ale může se vyvinout v ulcerózní

granulomatózní zánět, který postihuje kůži mezi paznehty. Jedná se o onemocnění, které je rozšířené po celém světě.

Statistická analýza provedená Browne et al. (2022), která zkoumala vliv faktorů spojených s řízením stáda na výskyt kulhání poukázala na fakt, kdy přítomnost kulhání ve stádě zvyšuje pravděpodobnost jeho opětovného výskytu v následujícím produkčním cyklu až o 47 %.

Snížení mléčné užitkovosti a předčasné vyřazení dojeného skotu v důsledku onemocnění paznehtů je úzce spjato s průběžnými ekonomickými ztrátami farem (Penev a Stankov, 2015; Willshire a Bell, 2009), které mohou podstatně ovlivnit jejich celkovou ziskovost (Bennett et al., 1999; Radinović et al., 2020). Bruijnjs et al. (2010) vypočítal celkové náklady v důsledku poruch paznehtů na jedné z farem s 65 kusy dojníc na 4 899 USD ročně (75 USD na kus). Z tohoto vyplývá, že náklady způsobené onemocněním paznehtu jsou podstatnější, než by si zemědělci mohli myslet. Subklinické poruchy paznehtů způsobily 32 % celkových nákladů. Booth et al. (2004) se zabývali vlivem kulhání na vyřazování dojnic z chovu a došli k závěru, že kulhání nemusí být vždy rizikovým faktorem ovlivňujícím vyřazení dojnice v průběhu laktace ve srovnání s nekulhavými kusy. Jejich výsledky poukazují na riziko vyřazení, které je úzce spojováno s konkrétní diagnózou kulhání a dobou, kdy byla tato diagnóza stanovena.

Edwardes et al. (2022) ve své studii zjistili, že celková roční ekonomická ztráta způsobená onemocněním paznehtů na typické holandské mléčné farmě se 125 dojnicemi činila 15 342 EUR. Tato ztráta byla tvořena přímými a nepřímými náklady. Celkové přímé ztráty dosáhly 9 061 EUR, přičemž 47 % připadalo na dojnice s mírnými formami onemocnění paznehtů. Studie také přinesla nové poznatky o nepřímých ztrátách, které představovaly 41 % celkových ročních ekonomických ztrát spojených s těmito onemocněními. Nepřímé ztráty byly převážně způsobeny poklesem očekávané produkce mléka a vyššími náklady na vyřazení produkčních dojnic z chovů. Tyto výsledky, včetně přímých ztrát naznačují, že celkové ekonomické dopady onemocnění paznehtů jsou opravdu výraznější, než si farmáři často uvědomují.

S ohledem na výše zmíněné je možno konstatovat, že onemocnění paznehtů má za následek značné meziroční ztráty na úrovni farem (Dolecheck a Bewley, 2018). Navzdory tomu farmáři a veterináři podceňují prevalenci kulhání skotu (Cutler et al., 2017; Denis-Robichaud et al., 2020). Leach et al. (2010) ve své publikaci poukazuje na fakt, že kulhání je často považováno za méně prioritní než jiné zdravotní problémy.

Je nezbytné, aby si zemědělci uvědomili dopad kulhání na produkci mléka. Uvědomění je klíčové pro zvýšení jejich pozornosti k tomuto problému, proto je potřeba důkazů, které ukazují ztráty v produkci způsobené onemocněním paznehtů skotu. Takovéto důkazy mohou pomoci zdůraznit význam včasného řešení kulhání pro zemědělce (Prasomsri, 2022).

Odborných publikací reflektujících ekonomické dopady snížené produkce mléka spojené s onemocněním paznehtů dojnic je celá řada (Alvergnas et al., 2019; Bruijnjs et al., 2010; Dolecheck et al., 2019; Edwardes et al., 2022; Losinger, 2006; Ryan a Conneely, 2024; Willshire a Bell, 2009). Výsledky uvedených studií mohou zvýšit povědomí chovatelů o ekonomické významnosti těchto onemocnění, zejména u mírných forem. Včasné zásahy při léčbě paznehtů by mohly snížit ekonomické ztráty a zároveň zlepšit zdraví a pohodu skotu, pokud budou zavedeny vhodné metody intervence. Avšak tradiční metody detekce kulhání a identifikace abnormalit jsou časově náročné a pracné, což farmám způsobuje značné obtíže (Qiao et al., 2021a).

Zlepšení zdraví mléčného skotu přináší výhody nejen z ekonomického hlediska, ale také z pohledu dobrých životních podmínek zvířat, ochrany životního prostředí a možného dopadu na veřejné zdraví. V současné době spotřebitelé a společnosti vyjadřují obavy týkající se environmentální udržitelnosti mléčné produkce (Rombach et al., 2023), používání antimikrobiálních látek (Wemette et al., 2021) a v neposlední řadě welfare dojníc (Ortega a Wolf, 2018).

Onemocnění paznehtu je zřídka kdy diagnostikováno v raných stádiích (Severiano et al., 2021), pravděpodobně kvůli nedostatku citlivých a nákladově efektivních diagnostických metod, což vede k tomu, že včasná léčba a prevence jsou jen zřídka implementovány (Sadiq et al., 2019). Navzdory rozsáhlému výzkumu etiologie, diagnostiky a léčby kulhání za posledních 20 let bylo celosvětově dosaženo jen malého pokroku ve snížení prevalence kulhání u chovů dojníc, což je pravděpodobně částečně způsobeno omezeními v detekci kulhání (Cook, 2020).

1.1.3 Diagnostické metody

Zcela zabránit vzniku zánětu v agresivním prostředí stáje není možné ani při dodržování přísných zootechnických opatření. Nicméně je možné alespoň eliminovat negativní dopady spojené s onemocněním dolních končetin, a to včasnou diagnostikou a zahájením odpovídající léčby (Randall et al., 2016).

Včasná detekce kulhání je hlavním pilířem pro poskytnutí účinné a levné léčby v návaznosti na prevenci budoucích onemocnění (Zhao et al., 2018).

Vizuální hodnocení, spolu s moderními technologiemi, jako jsou například automatizované monitorovací systémy a analýzy pohybu, mohou posloužit k rychlejší a přesnější detekci kulhání. Při zavedení těchto efektivních metod může dojít nejen ke zlepšení zdraví zvířete, ale i k optimalizaci produkčních výsledků a snížení ekonomických ztrát (García et al., 2020).

Výše zmíněná metoda vizuálního hodnocení je založena na principu sledování změn chování zvířat, které se mohou vyznačovat například snížením rychlosti pohybu, vyklenuutím v oblasti páteře a poklesem hlavy během chůze (Alsaad et al., 2019). Schlageter-Tello et al. (2015) se ve svém výzkumu zabývali hodnocením lokomoce za pomoci pětiúrovňové ordinální škály po vzoru Flower a Weary (2006), kdy hodnotícími znaky bylo sledování asymetrie chůze, pohupování hlavou, neochota nést svou váhu, prohnutí v oblasti páteře a stopování, které definovali jako vzdálenost mezi polohou přední nohy a zadní nohy na stejné straně těla na podlaze v následujícím kroku. Velikou nevýhodou tohoto systému vizuální detekce je aspekt subjektivního hodnocení, které je do značné míry ovlivněno zkušenostmi a rozpoznávacími schopnostmi pozorovatele (Gardenier et al., 2021). Tento zmíněný tradiční přístup detekce kulhání a rozpoznávání chování je však časově náročný a pracný, což je v případě pravidelných kontrol ve velkých farmách značným problémem (Qiao et al., 2021b).

Z pohledu automatického přístupu detekce kulhání Schlageter-Tello et al. (2014), Flower a Weary (2009) a Alsaad et al. (2019) rozdělují tento typ do tří kategorií:

- kinetické,
- kinematické,
- techniky nepřímého měření.

V případě kinetických přístupů pro hodnocení skóre lokomoce je využíváno například měření sil při došlápnutí paznehtu za pomoci systému GaitWise obsahujícího tlakové senzory (Van Nuffel et al., 2015), nebo rozložení hmotnosti skotu při chůzi či stání (Pastell et al., 2010).

Chapinal et al. (2010) a Chapinal a Tucker (2012) hodnotí princip detekování kulhání založený na měření rozložení hmotnosti prostřednictvím vážící plošiny jako slibný v kombinaci s měřením aktivity a rychlosti chůze za pomoci kamerového záznamu. Dalšími autory, zabývajících se využitím různých druhů systémů na bázi kinetiky k detekci onemocnění zdravotního stavu jsou Dunthorn et al. (2015), Liu et al. (2011) a Zillner et al. (2018).

Na rozdíl od kinetických přístupů, které jsou založeny na principu detekce reakční síly ve vztahu pazneht a zem, se kinematické přístupy zaměřují na časoprostorové proměnné při pohybu skotu (Gardenier et al., 2018). Zmíněná metoda, jak již samotný název napovídá, využívá k detekci materiál pořízený z kamer. Poursaberi et al. (2010) se zaměřili na analýzu polohy zad výpočtem zakřivení zad během stoje a chůze. Pluk et al. (2012) se zabývali zpracováním a analýzou videozáznamu, kdy záznam byl transformován do sekvencí obrázků a následně došlo k extrakci kinematiky. Reflexní značky na kloubních spojeních a dalších částech těla sloužily pro výpočet kinematických parametrů chůze.

Zvláštním případem záznamu pohybu je výzkum Volkmann et al. (2019), který se zaměřil na použití detekce kročejového zvuku dojníc pro odhalení paznehtních lézí.

Poslední kategorie v podobě nepřímých technik měření zahrnuje pro detekci onemocnění paznehtů skotu parametry, které nepřímo souvisejí s pohybem a kulháním. Například Norring et al. (2014) analyzoval chování při krmení se zaměřením na množství příjmu krmiva. Jako další parametry ve své práci zařadili dojivost a tělesnou hmotnost. Samotné sledování bylo zprostředkováno za pomoci elektronických krmných žlabů spolu s automatizovaným systémem dojení. De Mol et al. (2013) využili jako vstupní data pro model výstupní data ze senzorů aktivity a výsledků mléčné užitkovosti při robotizovaném dojení spolu s podavačem koncentráту. Kamphuis et al. (2013) se zabýval detekcí kulhání za pomoci dat pořízených senzory z váhy pro určení živé hmotnosti v kombinaci s určováním denní aktivity za pomoci pedometrů. Dalšími ukazateli pro vyhodnocení byly informace týkající se parametrů spojených s mléčnou užitkovostí (množství nadojeného mléka a délka dojení).

Další technologií, která se kromě tradičních 2D a 3D kamer dostala do popředí v rámci zjišťování zdravotních problémů paznehtů, jsou IR kamery (Rodríguez et al., 2016).

V současné době se lze setkat se snahou využít různých druhů senzorů v kombinaci s AI v rámci problematiky kulhání dojného skotu. Různé druhy v podobě silových platforem (Liu et al., 2011), akcelerometrů na končetinách (Thorup et al., 2015), nebo například dvojrozměrných a trojrozměrných kamer (Viazzì et al., 2014) jsou k tomuto způsobu detekování využity. Tyto nástroje mohou být v budoucnu velmi žádoucí pro své vlastnosti, především díky možnostem automatické detekce onemocnění paznehtů. Velkým přínosem by mohla být dovednost rychleji a přesněji detekovat problém týkající se zánětů (Gardenier et al., 2021).

Borghart et al. (2021) se snažili vyvinout predikční model kulhání u mléčného skotu pomocí kombinace technologie vzdálených senzorů a dalších záznamů zvířat. Výsledkem je transformace širokého spektra dat do snadno interpretovatelné klasifikované informace o lokomoci, kterou by obdržela odpovědná osoba v daném podniku.

1.2 Moderní metody strojového vidění a jejich aplikace

V této dizertační práci se chceme zaměřit na využití moderních metod strojového vidění k detekci onemocnění končetin skotu. Proto je v této kapitole shrnut aktuální stav problematiky pro danou oblast.

Rozvoj moderních výpočetních technologií umožňuje využívání nových metod pro zpracování dat. Mezi nejvýznamnější z nich patří zpracování obrazu, které může nalézt své uplatnění v širokém spektru oblastí, například v dopravě Kuo et al. (2019) použili tento nástroj pro detekci a kontrolu jízdního pruhu, Ali et al. (2023) rozvinuli tuto oblast navíc o detekci překážek, Carratù et al. (2022) využili tuto technologii pro měření rychlosti, Farahani (2017) se zabýval detekci a lokalizaci vozidel, Jiang et al. (2018) se zaměřili na využití rozpoznávání obrazu pro technologii určenou k navádění.

Pro oblast geografie má AI zásadní význam při analýze a klasifikaci hyperspektrálních a multispektrálních snímků z dálkového průzkumu, jak uvádí Bansal et al. (2024). Tato technologie se využívá zejména při analýze využití půdy, v meteorologii, při detekci změn a v dalších aplikacích. Autoři Silván-Cárdenas et al. (2014) se zaměřili na identifikace budov pomocí dálkového snímání s vysokým rozlišením a Mohamed (2019) aplikovali tento nástroj ke zpracování satelitního obrazu pro mapování městských oblastí náchylných k bleskovým povodním v Qena (Egypt).

Počítačové vidění nachází v astronomii uplatnění například při analýze různých druhů snímků (Karypidou et al., 2021) nebo při zpracování a studiu planetárních obrazů (Zubarev et al., 2016).

Využití počítačového vidění je nezbytnou součástí ve strojírenství a v průmyslu. Zejména v rámci konceptu Průmyslu 4.0 se zabývá Arora (2023) pokročilou kontrolou kvality pomocí moderních metod zpracování obrazu pro automatizovanou detekci defektů. Jasińska (2019) se zaměřila na algoritmy pro zpracování a analýzu obrazu při hodnocení opotřebení textilií. Zhang et al. (2020) pak popisují využití této technologie pro rychlou a přesnou detekci při robotickém úchopu.

Své uplatnění našlo počítačové vidění i ve zdravotnictví, například v případě stomatologie se lze setkat se systémy AI k detekci a segmentaci orálních a maxilofaciálních struktur pomocí snímků z počítačové tomografie (Abesi et al., 2023), AI má také velký potenciál zefektivnit péči o ústní a zubní zdraví (Gokdeniz a Kamburoğlu, 2022). Velmi populární pro své výsledky je tato technologie zejména pro včasnou diagnostiku neurologických a kardiovaskulárních chorob či poruch (Bernasconi a Bernasconi, 2011; Dahi et al., 2019; De Bresser et al., 2013; Velagapudi et al., 2017), stejně jako pro detekci nádorových onemocnění a rakoviny (Sadoughi et al., 2018; Saraswat et al., 2023).

V zemědělství lze tuto metodu rovněž efektivně využít. V rostlinné výrobě nachází své uplatnění při určování životaschopnosti semen zemědělských plodin (Pereira et al., 2022; Pinheiro et al., 2020), stav jejich růstu, identifikaci plodů, jejich metrických vlastností a počtu (Beyaz a Öztürk, 2016; Koirala et al., 2019; Matsuo et al., 2023; Sun et al., 2019). Vyhodnocování obrazových dat získaných bezpilotními letouny nebo drony (Unmanned Aerial Vehicle, UAV) lze uplatnit například za účelem zjišťování vlastností vegetačního pokryvu (Deng et al., 2020; Retallack et al., 2022).

V případě živočišné výroby je možné se s využitím AI pro analýzu obrazu setkat s celou řadou hospodářských zvířat, například u drůbeže, kdy Fadchar a Dela Cruz (2020) vytvořili prediktivní model pro včasnou detekci stavu plodnosti slepičích vajec, Li et al. (2020) se zaměřili na analýzu chování při krmení a pití u skupinově chovaných brojlerů,

Zhuang a Zhang (2019) se v případě brojlerů věnovali detekci nemocných kusů. U prasat byla například aplikována tato metoda v rámci klasifikace držení těla (Jeon et al., 2024), rozpoznání agresivního chování (Lee et al., 2016), sledování zdravotního stavu (Ni et al., 2020), odhadu živé hmotnosti (Bhoj et al., 2022; Kollis et al., 2007; Kongsro, 2014), sledování lokomoce prasat (Kashiha et al., 2014), nebo rozpoznání chování kojících prasníc (Lao et al., 2016).

Dalším hospodářským zvířetem v rámci využití moderních metod zpracování obrazu je skot (De Vries et al., 2023). V případě skotu byla tato technologie využita například v systému vizuální identifikace dojnic při měření individuálního příjmu krmiva (Bloch et al., 2021). Další možností využít systémy počítačového vidění je pro včasnou diagnostiku onemocnění, například zdravotních problémů, jako je zánět paznehtů u dojnic (Krpalkova et al., 2019). Van Hertem et al. (2014) se ve své studii zaměřili na optimalizaci klasifikačního algoritmu založeném na počítačovém vidění pro skórování kulhání. Viazzi et al. (2013) se zabývali individuální klasifikací kulhání s ohledem na měření držení zad mléčného skotu.

Guo et al. (2020) vyvinuli model strojového vidění pro rozpoznání chování telat. Ve své práci se zaměřili na rozlišování chování telat v kotcích, kde zohledňovali chování při krmení a pití, vstup do kotce, opuštění kotce, stání nebo ležení ve statické poloze a otočení. Ve své studii poukazují na fakt, že aplikace této metody do volného ustájení dojnic by byla náročná z hlediska instalace a kombinovaného vyhodnocování více kamer.

Shen et al. (2020) ve své práci popisuje návrh automatického algoritmu pro identifikaci skotu pomocí obrázků které detekují jednotlivé kusy z bočního pohledu. K detekce objektů využili model YOLO. Pro identifikaci jednotlivých kusů skotu použili model AlexNet. Vytvořili tak soubor obrazových dat 105 různých dojnic. Experimentální výsledky ukázaly, že metodu lze použít k vývoji automatického identifikačního systému dojnic na farmách. Samotná metoda identifikace založená na hlubokém učení má dobrý potenciál pro uplatnění a může poskytnout přesné detekování jednotlivých kusů v rámci precizního chovu dojného skotu.

Na zpracování obrazu je možné aplikovat značné množství metod, dle Wang et al. (2019) a Sadoughi et al. (2018) lze tyto metody rozdělit do následujících kategorií s ohledem na pořadí jejich aplikace následovně:

- zachycení obrazu,
- předzpracování obrazu,
- segmentace,
- extrakce příznaků,
- klasifikace.

Jinou kategorizaci uvádí například Jindal a Singh (2019), kteří rozdělují metody na kompresi, kódování, vylepšení obrazu a odstranění šumu, segmentaci, hranovou detekci, sloučení více obrazů, rozpoznání obrazu.

Výše zmíněné techniky lze využít samostatně, avšak nejčastěji je možné se setkat s jejich kombinací. K nejvyspělejšími metodám se řadí klasifikace a rozpoznání obrazu pomocí hlubokého učení, tedy aplikací konvolučních neuronových sítí, jejichž základ tvoří konvoluční, subsamplingové a klasifikační vrstvy (Liu et al., 2018). Konvoluční vrstvy

slouží k nalezení požadovaných příznaků, například rovných hran. Každá z nich se skládá z několika příznakových map, jejichž počet je odvozen od počtu stanovených variant hledaného příznaku. Subsamplingová vrstva, označovaná také jako pooling vrstva, následuje za každou konvoluční vrstvou a slouží k redukci její velikosti a zabránění přeučení sítě. Subsamplingová vrstva se skládá ze stejného počtu příznakových map jako předchozí konvoluční vrstva, jejichž neurony jsou propojeny s nepřekrývajícími se neurony odpovídajících příznakových map konvoluční vrstvy. Klasifikační vrstvy rozpoznávají jednotlivé příznaky, jejich kombinaci a vytváří výsledný výstup neuronové sítě. Důležitým kritériem pro správné fungování neuronové sítě je také její trénování na vhodném souboru dat (Gao et al., 2020; Ma et al., 2020).

1.3 Infračervená termografie a její využití v živočišné výrobě

IRT je neinvazivní a bezpečná metoda zobrazování teplotních map objektů. Tato technologie je proto výborným nástrojem, který přispívá ke snížení finančních ztrát farem a fyzického stresu zvířat. Jako neinvazivní metodu detekce lze IRT použít k indikaci změn tepelně biologických charakteristik v metabolismu zvířat. Jedná se tak o potenciál učinit z této technologie užitečný nástroj k detekci problémů spojených se zdravím a pohodou zvířat (Wang et al., 2023).

Udržování tepelné pohody zvířat je jednou z hlavních priorit uvnitř potravinářských provozů (Prasad et al., 2015). Vysoké teploty okolí způsobují tepelný stres, spouštějí termoregulační změny, které zahrnují fyziologické a behaviorální reakce, jako je zakrývání se v bahně nebo používání stínu ke snížení tělesné teploty (Unger et al., 2020).

Arfuso et al. (2022) se ve svém přehledu publikací snažili analyzovat neurobiologickou odezvu spojenou s tepelným stresem využitím IRT. Tepelný stres je stav, který může ovlivnit zdraví, výkonnost a pohodu hospodářských zvířat. Vnímání tepelného stresu vede k aktivaci autonomního nervového systému ke spuštění řady fyziologických a behaviorálních mechanismů k obnovení termostability. Reakce zvířat ve stresových podmínkách zahrnují především aktivaci sympatického systému a osy hypothalamus-hypofýza-nadledviny prostřednictvím uvolňování efektorových hormonů, jako jsou katecholaminy, respektive produkce glukokortikoidů. Jedním z důsledků této aktivace je stresem indukovaná hypertermie, která spočívá ve zvýšené tělesné teplotě.

Whittaker et al. (2023) se zabývali ve svém přehledu hodnocení bolesti a zánětu u zvířat pomocí IRT. Hodnocení bolesti u zvířat nabylo v posledních letech na důležitosti díky uznání fyziologických, behaviorálních a endokrinních důsledků akutní bolesti na jejich produkci a welfare. Současné přístupy k identifikaci akutní bolesti se spoléhají hlavně na škály založené na chování, kvantifikaci biomarkerů souvisejících s bolestí a použití zařízení monitorujících aktivitu sympatiku. IRT je alternativou, kterou lze použít ke korelaci změn povrchové teploty s jinými nástroji, a tak být dalším nebo alternativním markerem hodnocení akutní bolesti.

Zajímavý přehled od Casas-Alvarado et al. (2024) je zaměřen na analýzu aplikace IRT při monitorování fyzioterapie zvířat s využitím teplotních změn, které jsou přítomny u zvířat trpících problémy s chůzí nebo kulháním (např. zánět, bolest, zvýšená lokální teplota) jako neurobiologický základ. Rehabilitační techniky, jako je akupunktura, fyzikální terapie, termoterapie, fotobiomodulace a elektrostimulace, mají údajně protizánětlivý účinek,

který snižuje množství lokální produkce tepla, což je teplo, které lze zaznamenat pomocí IRT.

Riaz et al. (2024) pojednává o potenciálu IRT pro včasnou diagnostiku březosti u buvolů Nili-Ravi. Tato studie odhalila, že maximální teplota v oblasti tlamy byla významně vyšší u nebřezích ve srovnání s březími buvoly. Výsledky ukázaly, že různé oblasti těla mají tendenci vykazovat rozdíly v povrchové teplotě po zjištění těhotenství a že IRT by mohla sloužit jako doplňkový nástroj k měření takových tepelných změn spojených s těhotenstvím.

Rodríguez et al. (2016) se zaměřil v případě skotu na hodnocení teploty paznehtů u dojnic s různým skóre mobility. Jejich výsledky poukázali na možnost využití v případě prokázání vyšší teploty u dojnic se skórem mobility 3, který v rámci své kategorie ukazuje na těžce narušenou pohyblivost.

V tradičním výzkumu založeném na IRT jsou metody zpracování tepelných informací obsažených v termosnímku těžkopádné. Většina z nich je získávána a zpracovávána ručně z teplotních matic pomocí specifického softwaru např. FLIR Tools, což výrazně omezuje použití technologie IRT ve výrobě. Vývoj nových technologií reprezentovaných technologií strojového učení (ML) poskytuje příležitost dosáhnout bezkontaktního, vysoce přesného a automatizovaného hodnocení zdraví. Vývoj technologie ML poskytuje řešení tohoto problému. Od 80. let došlo v případě ML k rychle se rozvíjejícímu nezávislému oboru (Wang et al., 2023).

Další informace týkající se aplikace technologie strojového vidění a IRT k detekci onemocnění paznehtů u dojného skotu jsou uvedeny v článku „*Application of the Machine Vision Technology and Infrared Thermography to the Detection of Hoof Diseases in Dairy Cows: A Review.*“ publikovaném v časopise Applied Sciences, na kterém se autor aktivně podílel.

Kříž, P.; Horčíčková, M.; Bumbálek, R.; Bartoš, P.; Smutný, L.; **Stehlík, R.**; Zoubek, T.; Černý, P.; Vochozka, V.; Kuneš, R. Application of the Machine Vision Technology and Infrared Thermography to the Detection of Hoof Diseases in Dairy Cows: A Review. *Appl. Sci.* 2021, 11, 11045. <https://doi.org/10.3390/app112211045>

2 Cíle práce

Cílem dizertační práce je rozpracovat problematiku využití moderních výpočetních metod k diagnostice onemocnění paznehtů dojnic a navrhnout algoritmus pro včasnou detekci onemocnění paznehtů na základě obrazového vstupu.

Za účelem dosažení stanoveného cíle byly pracovní aktivity rozděleny do několika dílčích celků, které na sebe vzájemně navazovaly:

1. posouzení současného stavu problematiky:
 - výběr vhodné metody sběru dat,
 - výběr vhodné metody zpracování dat,
2. příprava trénovacích datasetů:
 - pořízení dat z provozů,
 - převod dat do vhodné formy,
 - segmentace zájmové oblasti z obrazu,
3. návrh vhodného algoritmu pro detekci zánětu paznehtů.

První dílčí cíl je zaměřen na posouzení současného stavu dané problematiky na jehož základě budou vybrány vhodné metody pro získání experimentálních dat a také jejich následné zpracování. Procesem pořízení dat z provozů, jejich následnými úpravami zahrnujícími předzpracování teplotních matic, převod na RGB obraz a další činnosti spojené s tvorbou anotací v podobě segmentace zájmových oblastí z obrazu a vygenerováním výsledných datasetů, se zabývá druhý dílčí cíl. Cílem poslední etapy je navrhnout a vytvořit vhodný systém pro detekci nemocných paznehtů implementující metody počítačového vidění natrénované na připravených datasetech i konvenční algoritmy pro zpracování obrazu.

3 Metodika

Pořizování obrazových dat je zásadním krokem pro vytvoření kvalitního datasetu nezbytného k efektivnímu trénování konvoluční neuronové sítě (CNN). Kvalita a rozmanitost těchto dat přímo ovlivňují schopnost sítě rozpoznávat vzory a správně generalizovat na nové, dosud neznámé vstupy. Z tohoto důvodu je klíčové pečlivě vybírat kamery, nastavit optimální rozlišení a další technické parametry, aby bylo možné získat co nejpřesnější a nejrelevantnější obrazové informace. Tyto faktory výrazně přispívají k vyšší výkonnosti modelu při úlohách, jako je detekce objektů, klasifikace nebo segmentace.

Kromě technických aspektů, jako jsou rozlišení kamery, kvalita optiky nebo rozsah teplot, je také důležitý samotný proces pořizování dat. Pro zajištění vysoké variability snímků je nutné zachytit zájmové objekty (paznehty) z různých úhlů, v různých prostředích a případně při pohybu.

3.1 Sběr dat

Pro sběr dat byly stanoveny tři základní pohledy na paznehty. Tyto pohledy se soustředily na pozici pozorovatele s IR kamerou ve vztahu k pozorovanému paznehtu, jednalo se o přední, boční a zadní část paznehtu. První dvě kategorie byly vytvořeny s ohledem na možné budoucí rozšíření výzkumu, zatímco třetí kategorie, zachycující zadní část paznehtu, byla využita v této práci k natrénování sítě pro rozpoznávání potenciálních zdravotních problémů paznehtů.

3.1.1 Použité přístroje

Sběr obrazového materiálu pro všechny kategorie, stejně jako pro vytvoření trénovací a testovací sady, probíhal od listopadu roku 2019 do května roku 2024. Vzhledem k technologickému pokroku a dostupnosti měřicí techniky byly snímky pořízeny v průběhu pěti let čtyřmi různými kamerami. Jednalo se o tři ruční IR kamery a jednu stacionární. Ruční kamery Testo 875-2i (A), FLIR E6 (B) a FLIR E 96 (C) umožnily flexibilní přístup a detailní záběry z různých úhlů, zatímco stacionární kamera WIC 640 (D) zajišťovala konzistentní a reprodukovatelné snímání. Tento mnohostranný přístup byl klíčový pro zajištění kvality dat, která byla nezbytná pro následné trénování konvoluční neuronové sítě.

Při sběru dat na jednotlivých farmách bylo nutné před měřením zdánlivých teplot paznehtů nejprve nastavit základní parametry kamer. Vzhledem ke struktuře povrchu měřeného objektu byla emisivita nastavena na hodnotu 0,98. Vzdálenost objektů od kamery se měnila v závislosti na aktuálních podmínkách, přičemž nejčastěji se jednalo o rozmezí 0,4 m až 1,5 m mezi IR kamerou a paznehtem. K určení dalších parametrů, jako je atmosférická teplota a relativní vlhkost, byl použit přístroj Testo 605i. Jedná se o kompaktní přístroj,

který lze ovládat a monitorovat přes mobilní aplikaci na chytrých telefonech či tabletech prostřednictvím bezdrátové komunikace využívající k přenosu dat technologii Bluetooth. Čas potřebný k ustálení hodnot přístroje byl stanoven na 30 minut před začátkem měření. V závislosti na atmosférických podmínkách různých prostředí byly hodnoty na přístroji kontrolovány a v případě potřeby upravovány v intervalech 5 až 30 minut. V případě stacionární kamery byla možnost dodatečné úpravy dat prostřednictvím softwaru od výrobce výhodou.

3.1.2 Metodika měření

Pro dosažení větší rozmanitosti a spolehlivosti dat získaných z termografických měření byly záměrně vybrány tři různé farmy. Na každé z těchto farem probíhal sběr dat ve specifických prostorech (kruhová dojírna, přehaněcí ulička, nebo oblast dojícího robota). Tato volba měla za cíl vytvořit heterogenitu v podmínkách měření, což umožnilo pokrýt širší spektrum situací a podmínek, které se na farmách vyskytují. Získaná data díky tomu mohou poskytovat komplexnější obraz a tvořit tím rozsáhlejší a reprezentativnější dataset, který může přispět k vyšší přesnosti a robustnosti následných analýz.

Na Farmě 1 byl sběr dat realizován v prostoru kruhové dojírny. Snímky byly pořizovány jak z vnitřní, tak z vnější strany oblasti kruhové dojírny, aby bylo zajištěno zachycení paznehtů z různých úhlů a pozic. Pro dokumentaci byly použity dvě kamery, označené jako kamera A a kamera B. V této farmě byly pořizovány záznamy paznehtů ze předního zadního i bočního pohledu.

Na Farmě 2 bylo poprvé otestováno použití stacionární kamery pro sběr dat. Tato kamera byla umístěna v oblasti přehaněcí uličky. Kromě stacionární kamery byla data pořizována také pomocí ručních kamer B a C, a to vždy těsně před kontrolou osob provádějících paznehtářskou činnost. Zpočátku byla zvažována dlouhodobá instalace stacionární kamery na tomto místě, avšak ukázalo se, že vzhledem k tomu, že se nachází venku pod širým nebem, nejedná se o optimální řešení. Kamera by byla vystavena nepříznivým povětrnostním podmínkám a také riziku odcizení, jelikož zabezpečení v takovémto případě je značně komplikované.

Farma 3 se ukázala jako nejvhodnější místo pro sběr dat stacionární kamerou, a proto byl sběr dat pro vytvoření trénovací a testovací sady pro detekci onemocnění paznehtů omezen výhradně na tuto farmu. Veškeré následující informace se tak vztahují pouze k této farmě.

Na farmě je chováno celkem 160 kusů mléčného skotu holštýnského plemene. Přibližně 80 dojnic je aktuálně dojeno, zatímco zbytek tvoří dojnice v období zaprahlosti, před otelením nebo mladá zvířata s telaty. Pro automatizaci dojení je na farmě nainstalován dojící robot Lely Astronaut A4, který zajišťuje efektivní a šetrné dojení skotu. Dojnice mají volný přístup k napájecím žlabům, které neustále zajišťují dostatek vody.

Typ ustájení je volný boxový, což umožňuje skotu volný pohyb ve stáji. Prosvětlená stáj je vybavena jedním krmným stolem a třemi hnojnými chodbami. Podlahy i boxová lože jsou vyrobeny z betonu, přičemž pro komfort zvířat je používán stelivový systém se slámou. Exkrementy jsou z hnojných chodeb pravidelně odstraňovány jednou denně pomocí manipulátoru, který zároveň doplňuje čistou podestýlku. Ventilace ve stáji je zajišťována manuálně ovládanými bočními plachtami, které regulují proudění vzduchu a poskytují stínění, čímž přispívají k udržení vhodného mikroklimatu ve stáji.

Na Farmě 3 probíhal sběr veškerých dat v prostoru, kde se nachází dojící robot. Pro pořizování snímků byla využívána ruční kamera typu C, která umožňovala flexibilní pohyb a zaznamenávání různých úhlů pohledu. Kromě toho byla v této oblasti nainstalována také stacionární kamera typu D. Její umístění bylo pečlivě zvoleno s cílem zajistit co nejvyšší kvalitu snímků pro následné analýzy. Stacionární kamera byla strategicky umístěna u vstupní branky dojícího robota, odkud zachycovala detailní záběry zadní části paznehtů zvířat během jejich vstupu a výstupu z dojícího procesu. Toto umístění umožnilo efektivní monitorování a zaznamenávání důležitých dat pro další zpracování.

Obrázek 3.1 znázorňuje zjištění optimálního nastavení umístění kamery, které je klíčové pro zajištění kvalitního záznamu, jenž byl využit v následujících fázích řešení vybrané problematiky. K dosažení tohoto cíle byl použit laboratorní stojan se svorkami a lepicí páska, které umožnily stabilní a přesné upevnění kamery. Tento proces zahrnoval důkladnou analýzu pozice kamery a pečlivé plánování sběru dat, aby bylo zajištěno, že snímky budou zachyceny z nejvhodnějšího úhlu. Pečlivé nastavení a testování kamery tak hraje zásadní roli v celém výzkumném procesu k získání vysoce kvalitních snímků pro potřeby trénování modelů neuronových sítí.



Obrázek 3.1: *Pohled na instalovanou IR kameru*

Po výběru vhodného místa pro instalaci kamery bylo nezbytné provést několik opatření k ochraně zařízení před vnějšími vlivy. Kamera byla dodána s ochranným krytem od výrobce, který splňuje standard ochrany IP65, což zaručuje její odolnost proti prachu a vodě. Tento kryt je klíčový pro zajištění dlouhé životnosti kamery v náročném prostředí farmy.

Další ochranná opatření se zaměřila na prevenci mechanického poškození, které by mohlo nastat v důsledku ořesů a vibrací způsobených skotem pohybujícím se v blízkosti zařízení. K tomuto účelu byl navržen speciální ochranný kryt, jehož konstrukce byla plánována tak, aby mohla být pevně přikotvena ke stěně. Pro ukotvení krytu bylo využito sedm natloukacích šroubů se zápusťnou hlavou 10×180 mm. Šrouby byly použity v kombinaci s podložkami DIN 125 -2 A. Tím se zvýšila stabilita a odolnost celé instalace, což minimalizovalo riziko poškození kamery a zajistilo její spolehlivý provoz. Tato kombinace opatření poskytuje kamerovému systému robustní ochranu a umožňuje efektivní sběr dat bez obav z narušení funkčnosti zařízení.

3.2 Tvorba datasetu

Po úspěšném pořízení základních dat, která zahrnovala zachycení různých snímků paznehtů, bylo přistoupeno k dalšímu kroku v podobě importu jednotlivých snímků do počítače. Tento proces byl nezbytný pro předzpracování snímků do požadovaného formátu, což umožnilo vytvoření komplexní vstupní databáze, která by sloužila jako základ pro další analýzu. Pro efektivní uspořádání obrazových vstupů ve formě termogramů, jež obsahují matice reprezentující zdánlivé teploty, byl u kamer A, B, a D využit specializovaný software poskytovaný výrobcem. Tento software byl navržen tak, aby maximálně zjednodušil práci s termografickými daty a zajistil jejich přesné zpracování.

V případě použití ruční kamery C byl realizován převod IR videa na jednotlivé teplotní matice za pomoci algoritmu napsaného v programovacím jazyce Python. Tento jazyk byl zvolen díky své flexibilitě a široké škále dostupných knihoven, které usnadňují manipulaci s daty. Veškeré teplotní matice jsou poté aplikací vlastních vytvořených funkcí převedeny na RGB obraz.

Pro anotace obrázků byl využit open-source nástroj Computer Vision Annotation Tool (CVAT), který se stal nezbytným nástrojem pro efektivní a přesné označování dat. Tento proces anotace je klíčovým krokem v oblasti vývoje a trénování počítačového vidění, algoritmů a modelů strojového učení. Anotace obrázků pomáhají algoritmům porozumět obsahu vizuálních dat, což je zásadní pro jejich schopnost správně rozpoznávat a interpretovat objekty v různých scénářích.

CVAT disponuje širokým spektrem funkcí, které usnadňují proces označování objektů, segmentaci, kategorizaci a další úkoly spojené s anotací. Mezi jeho hlavní vlastnosti patří intuitivní uživatelské rozhraní, které umožňuje uživatelům snadno interagovat s nástrojem a efektivně provádět anotace. Tento nástroj byl obzvláště užitečný pro tvorbu datasetu, který byl následně použit pro trénování a testování algoritmů a modelů zaměřených na rozpoznávání paznehtů dojnic.

Základní uživatelské prostředí nástroje CVAT je vyobrazeno na obrázku 3.2. Tento obrázek ukazuje, jak intuitivní a uživatelsky přívětivé je rozhraní, což usnadňuje práci i méně zkušeným uživatelům, kteří se s tímto nástrojem teprve seznamují.



Obrázek 3.2: Základní uživatelské prostředí nástroje CVAT

V rámci anotací byly vytvořeny kategorie zaměřené jednak na druh paznehtů, v případě hrudních se jednalo o přední a u pánevních o zadní paznehty. Další rozdělení bylo na pazneht s pohledu jeho celistvosti v obraze s ohledem na různé překryvy (celý nebo necelý) a jako poslední byl stanoven jeho zdravotní stav (zdravý a nemocný).

Důkladná anotace a kategorizace obrazových dat tímto způsobem přispívají k robustnosti a přesnosti modelů strojového učení, což zajišťuje, že výsledné algoritmy budou schopny správně identifikovat a hodnotit paznehty dojnic v různých podmínkách a scénářích.

3.3 Segmentace oblastí paznehtů z obrazu

Pro precizní segmentaci paznehtů na obraze je nezbytné trénovat model CNN na pečlivě připraveném vstupním datasetu s přesnými anotacemi. Tento proces je klíčový, protože kvalitní anotace přímo ovlivňují schopnost modelu správně identifikovat a lokalizovat paznehty na různých typech obrazových dat. Pro získání rozsáhlého datasetu byla nejprve využita neuronová síť MaskDino, která se vyznačuje vysokou přesností a spolehlivostí svých predikcí. Tato síť je speciálně navržena pro úkoly segmentace a dokáže efektivně rozlišovat mezi různými objekty na základě jejich tvaru a kontur.

Avšak je důležité poznamenat, že kvůli velkému množství parametrů, které MaskDino používá, je tato síť náročná na hardwarové prostředky. To znamená, že pro její trénink a provoz je zapotřebí výkonný hardware, což může být v některých případech omezením, zejména pro menší výzkumné týmy nebo instituce s omezenými zdroji.

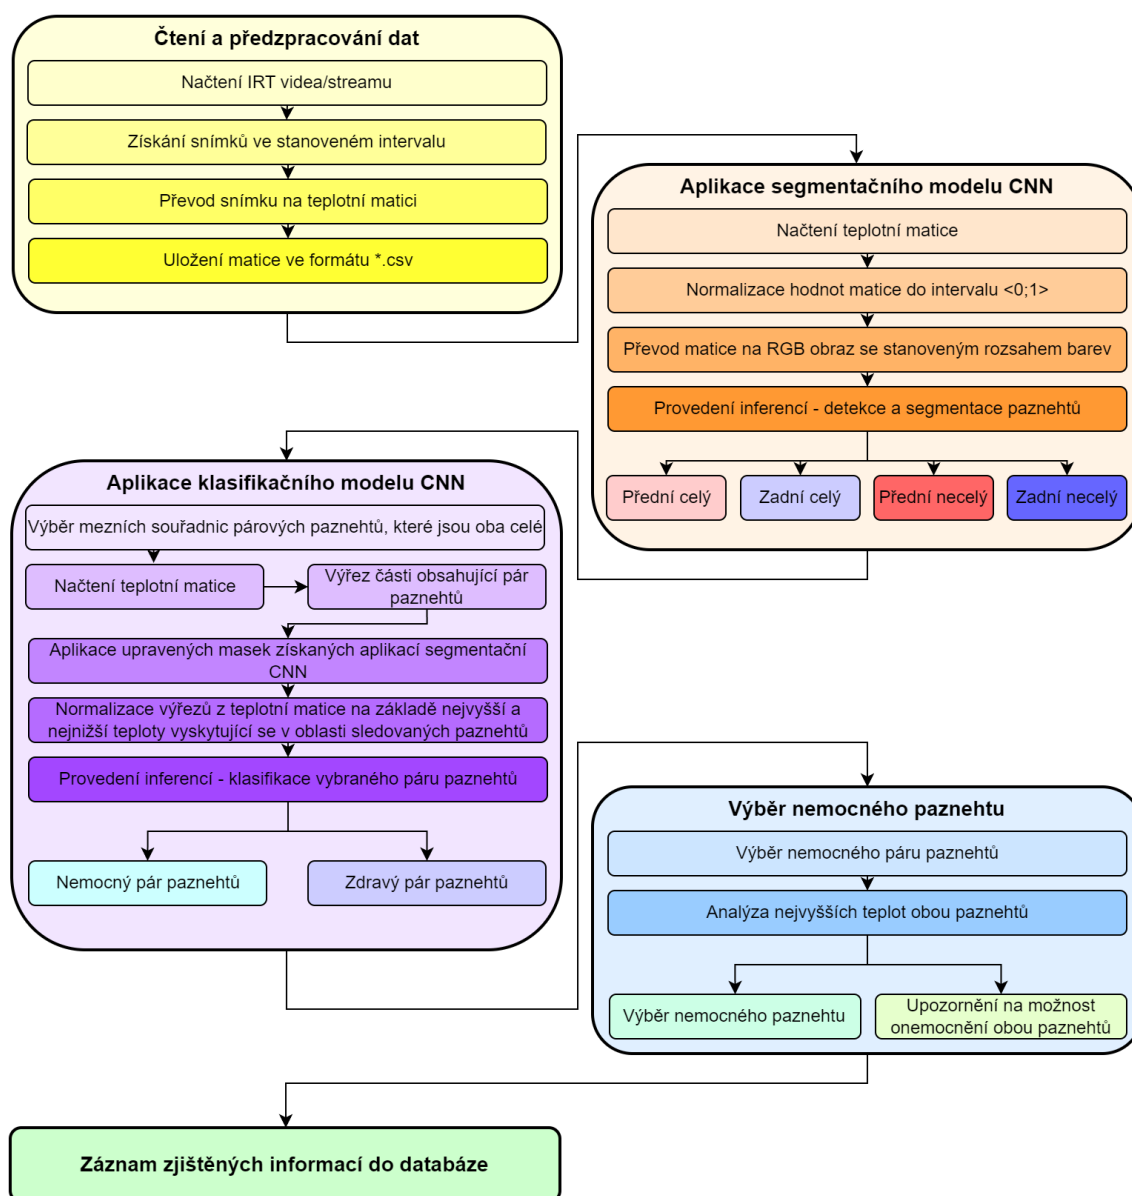
Po tréninku na menším datasetu, který obsahoval 10 000 snímků s augmentací, byla tato síť následně využita k automatizovanému anotování většího datasetu. Takto rozšířený dataset, který byl generován díky schopnostem MaskDino, sloužil jako vstup pro trénování sítě architektury YOLO (You Only Look Once). YOLO se stala populární volbou pro úkoly detekce objektů díky své vysoké přesnosti a rychlosti zpracování.

Architektura YOLO je implementována do hlavní části softwaru pro segmentaci obrazu a je ceněna pro svou schopnost dosáhnout vysoké přesnosti s relativně nízkými požadavky na výpočetní výkon. Tímto způsobem se zefektivňuje celý proces segmentace, což umožňuje rychlejší a efektivnější analýzu obrazových dat.

3.4 Systém pro detekci zdravotních obtíží u paznehtů

Vyvinutý systém pro automatizovanou detekci onemocnění paznehtů pomocí IR záznamu představuje pokročilou aplikaci metod hlubokého učení, konkrétně CNN, pro přesnou analýzu teplotních dat. Systém schematicky znázorněný na 3.3 se skládá z několika na sebe navazujících částí zaměřených na získání a předzpracování IR dat, detekci a zároveň segmentaci jednotlivých paznehtů, přičemž jsou kategorizovány do stanovených tříd, výběr párových paznehtů a klasifikaci zdravého či nemocného páru, výběr nemocného paznehtu a záznam všech získaných informací do databáze.

Nejprve dochází k načtení IR kamerového záznamu nebo streamu z termokamery, která monitoruje teplotu povrchu paznehtů u hospodářských zvířat. Ve stanovených časových intervalech jsou z těchto dat extrahovány jednotlivé snímky, jež jsou následně převedeny na teplotní matice, kde každý prvek reprezentuje specifickou teplotu povrchu paznehtů. Ma-



Obrázek 3.3: Schéma systému pro automatickou detekci zdravotních obtíží u paznehtů

tice jsou ukládány ve formátu *.csv pro další zpracování. V následujícím kroku je aplikován segmentační model CNN architektury YOLO. Během načítání dat do modelu proběhne normalizace teplotních hodnot matice do intervalu $<0;1>$, což je nezbytné pro správnou funkci neuronové sítě. Dále dochází k převodu teplotní matice na RGB obraz. Různé teploty jsou vizualizovány ve specifickém barevném rozsahu (barevné mapě), což usnadňuje následnou segmentaci. Segmentační model provádí inferenci, tj. detekci a rozdělení paznehtů na jednotlivé kategorie, kterými jsou přední a zadní paznehty, přičemž každý z nich může být klasifikován jako celý (kompletně zobrazený), nebo necelý (zobrazený částečně). Tento krok je velice důležitý pro přesnou lokalizaci paznehtů pro další analýzu.

Po segmentaci následuje aplikace klasifikačního modelu CNN, který se zaměřuje na vyhodnocení zdraví jednotlivých paznehtů. Nejprve dochází k výběru mezních souřadnic detekovaných celých párových paznehtů. Z teplotní matice se provede výřez části obsahující celý pár paznehtů. Následně jsou aplikovány upravené binární masky získané během segmentačního procesu. Ty umožňují přesné odlišení oblastí reprezentujících paznehty od pozadí. Teplotní data, nacházející se pouze v oblastech, kde masky nabývají hodnotu 1, jsou dále normalizována na základě nejvyšších a nejnižších teplot zaznamenaných v oblasti paznehtů. Je tomu tak, aby došlo k eliminaci případných odchylek způsobených vnějšími faktory. Prvkům, jejichž poloha odpovídá pozadí, je přiřazena hodnota 0. Klasifikační model MobileNetV3 poté provádí inferenci, v rámci které je určeno, zda je analyzovaný pár paznehtů zdravý, nebo vykazuje známky onemocnění. Pokud systém identifikuje nemocný pár paznehtů, přechází se k detailnější analýze, která zahrnuje výběr konkrétního nemocného paznehtu na základě analýzy teplotního rozložení. K tomu slouží porovnání nejvyšších teplot obou paznehtů, přičemž vyšší teplota často indikuje zánětlivý proces nebo jiný zdravotní problém. Pokud je rozdíl mezi teplotními maximy obou paznehtů nízký, tak systém upozornění na možné onemocnění obou paznehtů.

Veškeré zjištěné informace, včetně teplotních dat, detekovaných oblastí a výsledků klasifikace, jsou automaticky zaznamenávány do databáze. Tento záznam umožňuje sledovat vývoj zdraví jednotlivých zvířat v čase a provádět dlouhodobou analýzu stavu paznehtů. To může přispívat k efektivnímu managementu zdraví ve velkochovech. Mezi zaznamenávaná data náleží také časový údaj o pořízení záznamu, na jehož základě mohou být informace spárovány s údaji systému dojícího robota. Tím může následně dojít k získání ID čísla náležícího konkrétnímu kusu skotu.

4 Vybrané výsledky a diskuse

Problematika práce je řešena dvěma rozdílnými způsoby. První způsob je zaměřený na aplikaci komplexního systému sestávajícího se ze dvou CNN – jedna síť je segmentační a druhá klasifikační. Systém je určen pro detekci nemocných paznehtů na základě srovnání párových končetin. Druhý způsob řešení se zabývá přímou detekcí párových paznehtů, ale zároveň i stanovením jejich zdravotního stavu v rámci jednoho modelu CNN.

4.1 Dílčí výsledky navrženého systému

4.1.1 Vlastnosti trénovacího datasetu


Pro účely trénování CNN zaměřené na rozpoznávání paznehtů byl vytvořen trénovací dataset čítající po augmentaci 14 322 snímků obsahující 48 427 jednotlivých polygonálních anotací rozdělených do čtyř tříd dle párovosti a podílu vyskytujícího se v obraze na „Přední pazneht – celý“, „Zadní pazneht – celý“, „Přední pazneht – necelý“ a „Zadní pazneht – necelý“, přičemž hodnoty vybraných parametrů anotací jsou uvedeny v tabulce 4.1.

Tabulka 4.1: Vybrané parametry anotací v trénovacím datasetu pro velikost obrazu 1 080×720

	vše	pazneht celý		pazneht necelý	
		přední	zadní	přední	zadní
Počet anotací	48 427	15 582	22 358	7 896	2 590
Min. šířka (px)	6	10	14	6	31
Max. šířka (px)	340	236	246	220	340
Prům. šířka (px)	72,89	57,14	89,79	34,44	139,10
Min. výška (px)	9	11	21	15	9
Max. výška (px)	280	211	278	248	280
Prům. výška (px)	91,71	71,17	113,33	59,33	127,31
Min. plocha vůči snímku (%)	0,01	0,01	0,03	0,01	0,08
Max. plocha vůči snímku (%)	7,68	3,77	5,76	3,70	7,68
Prům. plocha vůči snímku (%)	0,78	0,46	1,08	0,22	1,82
Min. počet obvodových bodů	8	46	32	18	8
Max. počet obvodových bodů	3876	2604	3330	2518	3876
Prům. počet obvodových bodů	963,20	778,55	1 243,18	461,45	1 186,87

Velikost i členitost jednotlivých instancí je velice různorodá, kdy výška i šířka bounding boxu obklopujícího polygonální masku nabývají hodnot od 6 do 340 pixelů, respektive od 9 do 280 pixelů, z čehož vyplývá, že největší paznehty v záběru mohou dosahovat až 31,5 % šířky či 38,9 % výšky celého obrazu. Průměrná šířka a výška anotací v celém datasetu je 72,89 pixelu a 91,71 pixelu.

Z vizualizace rozměrů anotací obsažených v trénovacím datasetu na obrázku 4.1 vyplývá, že většina anotací v datasetu má podobné rozměry, přičemž šířky paznehtů se nejčastěji pohybují mezi 50 px až 75 px a výšky mezi 75 px až 125 px. Hustotní konturová mapa ukazuje, že nejvyšší koncentrace anotací se nachází v této oblasti. Významně větší nebo menší rozměry jsou méně časté, což potvrzují i histogramy šířky a výšky, kde hodnoty nad 150 px pro šířku a nad 200 px pro výšku jsou vzácné. To naznačuje, že dataset je relativně homogenní, s menším zastoupením extrémně velkých nebo malých paznehtů.




Obrázek 4.1: Vizualizace rozměrů anotací obsažených v trénovacím datasetu

Při bližším pohledu na jednotlivé kategorie anotací nabývají větších velikostí paznehty na zadních končetinách. Větší plocha na obrazu je zapříčiněna perspektivou obrazu. Paznehty na zadních končetinách jsou výrazně blíže k záznamovému zařízení než paznehty přední, jak je znázorněno na obrázku 4.2.




Obrázek 4.2: *Znárodnění vlivu perspektivy na velikost sledovaných paznehtů*

I anotace předních paznehtů mohou dosahovat značných rozměrů, nicméně jejich výskyt je v datasetu značně menší, přičemž jsou získány ze snímků, kde dojnice vstupuje do obrazu a přední paznehty se vyskytují v blízkosti kamery, v takovýchto případech v obrazu zadní paznehty zcela chybí, viz obrázek 4.3.




Obrázek 4.3: *Ukázka situace, kdy nabývající přední paznehty v obrazu větších rozměrů*

Na obrázku 4.4 je znázornění rozměrů anotací dílčích kategorií, ze kterého je patrné, že objekty znázorňující přední celé paznehty mají největší koncentraci rozměrů v rozmezí šířky 50 px až 100 px a výšky 50 px až 150 px, což naznačuje relativně konzistentní velikost v této kategorii. Zadní celé paznehty jsou v datasetu obecně větší, s hlavní koncentrací v oblasti šířky 75 px až 150 px a výšky 100 px až 200 px, a několik extrémních případů dosahuje šířky až 250 px. Kategorii předních necelých paznehtů charakterizují menší rozměry, kde je většina anotací soustředěna mezi šířkou 25 px až 75 px a výškou 25 px až 100 px, což naznačuje kompaktnější charakter těchto instancí. Naproti tomu zadní necelé paznehty vykazují výrazně vyšší rozptyl rozměrů, s šířkou rozprostírající se od 50 px do 350 px a výškou až do 250 px, což poukazuje na vysokou variabilitu této kategorie.



Obrázek 4.4: Vizualizace rozměrů anotací dílčích kategorií obsažených v trénovacím datasetu

Z pohledu vztahu mezi velikostí anotace vůči snímku a počtem obvodových bodů anotace většina anotací zabírá relativně malou část snímku, zpravidla do 2 % plochy, přičemž počet obvodových bodů u těchto anotací se pohybuje mezi 500 a 1 500 body. Významně vyšší velikosti anotací nad 3 % plochy jsou méně časté, ale pokud se vyskytují, jsou obvykle doprovázeny výrazně vyšším počtem obvodových bodů, až do 4 000, viz obrázek 4.5. Histogramy uvedené v této vizualizaci ukazují, že rozložení dat je silně koncentrované v nižších hodnotách pro obě proměnné, což naznačuje, že většina anotací v datasetu je relativně malá a nemá příliš členitou geometrii, anotace s vyšším počtem obvodových bodů se nevyskytují v datasetu příliš často, přičemž náleží větším objektům. Také se v datasetu vyskytuje zajímavý jev, kdy část objektů obsahuje do 200 obvodových bodů napříč různými velikostmi, který je zapříčiněn paznehty, jejichž část vystupuje mimo záběr, kdy mezní část polygonu kopírující okraj obrazu je tvořena linií s minimálním počtem bodů.



Obrázek 4.5: Vizualizace souvislosti mezi plochou polygonálních anotací a počtem jejich obvodových bodů

4.1.2 Výsledky trénování CNN architektury YOLOv8

Na základě podrobné rešerše byla pro segmentaci paznehtů a určení jejich zdravotního stavu vybrána konvoluční neuronová síť architektury YOLOv8 v modelech „n“, „s“, „m“, „l“ a „x“, jejichž vybrané charakteristiky jsou představeny v tabulce 4.2 (Ultralytics Inc., 2024), přičemž největší model „x“ obsahuje 71,8 mil. parametrů a má velikost 137,2 MB a nejmenší model „n“ se skládá pouze z 3,4 mil. parametrů a jeho velikost činí 6,5 MB. Při procesu učení, který proběhl na GPU serveru osazeném grafickými kartami NVIDIA A100, byly použity hyperparametry learning rate 0,01, batch size 1024 a optimizér SGD. U každého trénovaného modelu byl zkoumán vliv velikosti strany vstupních obrazových dat na výsledky trénování, konkrétní velikosti byly 240, 320, 480 a 720 bodů. Hodnocení bylo založeno na pozorování standartních metrik Precision (rovnice 4.1), Recall (rovnice 4.2) a mean Average Precision (rovnice 4.3).

Tabulka 4.2: Srovnání modelů YOLOv8 podle počtu parametrů, FLOPs a velikosti modelu

Model	Počet parametrů (mil.)	FLOPs (B)	Velikost modelu (MB)
YOLOv8-n	3,4	12,6	6,5
YOLOv8-s	11,8	42,6	22,8
YOLOv8-m	27,3	110,2	52,3
YOLOv8-l	46,0	220,5	88,0
YOLOv8-x	71,8	344,1	137,2

$$P = \frac{1}{n} \sum_{i=1}^n \frac{TP_i}{FP_i + TP_i}, \quad (4.1)$$


$$R = \frac{1}{n} \sum_{i=1}^n \frac{TP_i}{FN_i + TP_i}, \quad (4.2)$$

$$mAP = \frac{1}{n} \sum_{i=1}^n \int_0^1 P_i(R_i) dR_i, \quad (4.3)$$

kde TP je True Positive, neboli správně označené objekty, FP je False Positive, což jsou objekty, které byly označeny nesprávně, a FN je False Negative, neboli objekty, které byly nedetekovány. Precision tedy značí podíl správně detekovaných objektů ku všem detekovaným objektům. Recall udává podíl všech správně detekovaných objektů ku všem objektům dané třídy nacházejících se v datasetu. Plocha pod křivkou v grafu, kde svislá osa představuje Precision a vodorovná Recall, se nazývá Average Precision. Sřední hodnota této průměrné přesnosti napříč všemi kategoriemi je označována jako mean Average Precision.


Na obrázku 4.6 jsou uvedeny grafy metrik sledovaných v průběhu trénování modelu YOLOv8-s při vstupním obrazu o velikosti strany 240 bodů a modelu YOLOv8-x s velikostí strany vstupního obrazu 720. Při porovnání průběhu trénování obou sítí na základě grafů popisujících jeho průběh je patrné, že velká robustnější síť typu YOLOv8-x již v prvních

etapách trénování dosahují velmi slušných výsledků, kdežto u malé sítě typu YOLOv8-n začínají první etapy prakticky od nuly, poté dochází k prudkému zlepšování až do rozmezí 10–20 etapy s následným poklesem zlepšení až k finální oscilaci kolem nejlepších dosažených výsledků.



Obrázek 4.6: Porovnání vybraných metrik dokumentujících průběh trénovacího procesu CNN: a) YOLOv8-n s velikostí strany vstupního obrazu 240, b) YOLOv8-x s velikostí strany vstupního obrazu 720

Všechny natrénované modely absolvovaly benchmark na stolním počítači s herní GPU NVIDIA RTX 3090, z něhož byly získány nejenom údaje o přesnosti a spolehlivosti, ale také o rychlosti inferencí v milisekundách a následně přepočítány do počtu zpracovaných snímků za sekundu (FPS). Pro názornější srovnání byly sledované metriky zkombinovány do jednoho výsledného čísla, které odráží kvalitu jejich detekčních schopností při zvoleném případě užití. Z grafu na obrázku 4.7 je patrné, že nejlepších hodnot dosáhly modely při využití obrazu s nejvyšším rozlišení, avšak je velice zajímavé, že výborné hodnoty nevykazují pouze velké modely, které jsou pomalejší, ale také nejmenší YOLOv8-n, jenž i při velkém vstupním obrazu byl schopen dosáhnout více než 70 FPS. Křivka v grafu také ukazuje rostoucí trend FPS při snižování rozlišení vstupního obrazu, který je však více patrný u velkých modelů.




Obrázek 4.7: Srovnání natrénovaných modelů na základě kombinace metrik a počtu zpracovaných snímků za sekundu


4.1.3 Vybrané výsledky klasifikační sítě MobileNetV3

Pro identifikaci zdravotního stavu paznehtů, segmentovaných pomocí sítě architektury YOLOv8, byla využita klasifikační síť MobileNetV3. Ta z vyříznutých bounding boxů detekovaných párů paznehtů určovala již pouze dvě třídy objektů, a to zdravý pár paznehtů či nemocný pár paznehtů. Zdravé páry paznehtů byly v trénovacím datasetu zastoupeny 6 306 snímky a nemocné páry byly zachyceny na 1 483 snímcích. Termín nemocný pár

v tomto případě označuje stavy, kdy je nemocný jeden či oba paznehty v dané dvojici. Ukázky zdravých a nemocných párů z trénovacího datasetu jsou ilustrovány obrázkem 4.8. Kvalita trénovacího procesu byla hodnocena na základě pozorování přesnosti predikce trénovaného modelu na trénovacích a testovacích datech. Průběhy těchto pozorovaných metrik jsou zachyceny na grafu zobrazeném na obrázku 4.9. Již od prvotních etap vykazoval trénovaný model vysokou přesnost detekce. V druhé etapě již dosáhla přesnost na testovacích datech 96 % a od desáté etapy se pohybovala nad 98 %.



Obrázek 4.8: Ukázka snímků zdravých párů (a), (b) a nemocných párů (c) a (d) z datasetu použitého pro trénování detekční sítě MobileNetV3




Obrázek 4.9: Graf křivky PR vytrénovaného modelu YOLOv8-x s batch size 256 a learning rate 0,01

4.2 Aplikace modelu CNN pro přímou detekci onemocnění paznehtů

K vytrénování segmentačního modelu identifikujícího zdravé a nemocné paznehty na předních a zadních končetinách skotu byla využita konvoluční neuronová síť architektury YOLOv8-x. Proces trénování probíhal po dobu 100 epoch při nastavení hyperparametrů batch size 256, learning rate 0,01 a za použití optimizéru SGD, přičemž velikost obrazových dat, na nichž byl model vytrénován, byla 720×720 pixelů. Vyhodnocení vytrénovaného modelu proběhlo na základě sledování průběhu metrik Precision (P), Recall (R) a mean Average Precision (mAP_0.5), které jsou podrobně představeny v (Padilla et al., 2020), během trénovacího procesu. V tabulce 4.3 jsou zaznamenány výsledné hodnoty vybraných metrik, pomocí nichž lze interpretovat schopnost vytrénovaného modelu detekovat požadované objekty a zařadit je do definovaných tříd. Průběžné hodnoty těchto metrik během trénovacího procesu jsou zachyceny na obrázku 4.10, kde je u většiny pozorovaných metrik znatelný trend zlepšování výsledků během trénování. Během prvních epoch dochází k největšímu zlepšení výsledků, přičemž postupně míra zlepšení klesá až dochází k oscilaci okolo nejvyšší dosažené hodnoty. Výjimku tvoří metrika val/seg_loss, u níž došlo k poklesu mezi epochami 91 a 92 o 0,17. Po tomto propadu opět docházelo ke zlepšování získaných výsledků. Z hlediska této metriky by bylo optimální navýšit počet epoch alespoň o dalších 50.


Tabulka 4.3: Výsledky vybraných metrik vytrénovaného modelu YOLOv8-x s batch size 256 a learning rate 0,01 při době trénování 100 epoch

Validation Box_loss	Validation Seg_loss	Validation Classifi- cation_loss	Precision	Recall	mAP_0.5
0,51872	0,69397	0,34096	0,93533	0,83827	0,88873



Obrázek 4.10: Grafy dokumentující průběh trénování modelu YOLOv8-x s batch size 256 a learning rate 0.01

Vytrénovaný model je schopen segmentovat a identifikovat zdravý pazneht na přední končetině, zdravý pazneht na zadní končetině, nemocný pazneht na přední končetině, nemocný pazneht na zadní končetině, neúplný pazneht na přední končetině a neúplný pazneht na zadní končetině. Zastoupení jednotlivých klasifikovaných tříd je zachyceno na obrázku 4.11.




Obrázek 4.11: Vizualizace vlastností pozorovaných objektů ve vstupním datasetu. Levý horní roh – počet instancí jednotlivých tříd, pravý horní roh – zobrazení velikostí jednotlivých bounding boxů, levý dolní roh – vizualizace výskytu pozorovaných objektů (v použitém balíku je bod o souřadnicích [0;0] v levém horním rohu, proto je tato vizualizace oproti skutečnému stavu horizontálně překlopena), pravý dolní roh – znázornění relativních velikostí bounding boxů vůči obrazu

Počet paznehtů předních a zadních končetin je v datasetu téměř identický. Při rozdělení na zdravé, nezdravé a neúplné paznehty hrála svou roli fyziologie skotu a také umístění kamery pořizující obrazová data. Přední končetiny skotu jsou méně náchylné k onemocnění, neboť při chůzi a stání jsou zadní končetiny více zatěžovány, to zvyšuje riziko přetížení a následně i poškození paznehtů (Urban-Chmiel et al., 2024), což se odráží i na zastoupení

třídy nemocný pazneht na přední končetině v datasetu, kdy je minimální. Zároveň jsou paznehty předních končetin na obrázcích často v zákrytu, jak je vidět na obrázku 4.11, proto je zastoupení předních neúplných paznehtů zhruba třikrát větší než těch zadních.

Na obrázku 4.11, lze dále pozorovat, v jeho pravé horní části, tvar jednotlivých bounding boxů, kde mají všechny bounding boxy podobnou velikost a žádná klasifikovaná třída z hlediska velikosti nevybočuje. Všechny detekované objekty se na snímcích pohybují ve středu a v dolní části, jak je patrné z levé dolní části obrázku 4.11. V pravém dolním rohu je vizualizována velikost jednotlivých bounding boxů vzhledem k výšce a šířce snímků. Z vyobrazení vyplývá, že jednotlivé objekty zabíraly na obrázcích, ve většině případů, méně než 10 % výšky a 6 % šířky celého snímku. Pouze ve výjimečných případech překročila velikost bounding boxu 30 % výšky a 20 % šířky obrazu.

Matice záměn, zobrazená na obrázku 4.12, ve vertikálním směru ukazuje schopnost klasifikace jednotlivých tříd vytrénovaným modelem YOLOv8-x s Batch size 256 a Learning rate 0,01.



Obrázek 4.12: Matice záměn při predikci jednotlivých tříd vytrénovaným modelem architektury YOLOv8-x s Batch size 256 a Learning rate 0,01

Schopnost identifikace zadních zdravých paznehtů je velmi dobrá, správně byla určena v 3 835 případech, což činí úspěšnost 95,18 %. Naopak chybně byla určena ve 194 případech, přičemž nejčastěji byla zaměněna, osmdesát jedenkrát, s nemocnými paznehty zadních končetin. Celkem čtyřicet pětkrát byla tato třída zaměněna za neúplné paznehty a třicet devětkrát nebyla vůbec detekována. Identifikace zdravých paznehtů předních končetin byla prakticky stejně úspěšná jako klasifikace zadních zdravých paznehtů. Správně

byla tato kategorie určena u 3 415 případů, což činí 95,23 %. Avšak daleko častěji docházelo k jejich záměně s jednou ze tříd neúplných paznehtů, celkem k tomu došlo devadesát třikrát. K identifikaci těchto paznehtů nedošlo ve 48 případech. Třída nemocných paznehtů předních končetin byla v datasetu zastoupena pouze čtrnáctkrát, jak bylo výše zdůvodněno. Všechny 14 případů bylo určeno správně a nedošlo k jejich záměně s jinou třídou. U detekce nemocných paznehtů zadních končetin bylo dosaženo nejlepších výsledků predikce a to 95,85 %. Pouze sedmkrát došlo k záměně se zdravými paznehty na téže končetině a v 29 případech nebyly detekovány. Horší výsledky byly získány při detekci neúplných paznehtů, a to jak na předních tak i zadních končetinách. Na předních končetinách byla úspěšnost identifikace neúplných paznehtů 89,22 % a na zadních končetinách pouze 88,88 %. U zadních končetin docházelo, vyjma předních nemocných paznehtů, k záměně se všemi ostatními třídami. U předních končetin došlo k záměně jen se dvěma třídami, a to s předními zdravými paznehty a s pozadím. Pro funkčnost vytrénovaného modelu v reálných podmínkách by však horší výsledky při detekci neúplných paznehtů nebyla zásadním problémem. U neúplných paznehtů není možné zcela kvalifikovaně posoudit jejich zdravotní stav, proto jejich záměna s pozadím či zdravými paznehty nemá za následek zhoršení schopnosti odhalit nemocné paznehty. Vliv na tuto predikci by ovšem již měla záměna neúplných paznehtů za nemocné. K tomu došlo u 24 neúplných zadních paznehtů, které byly určeny jako zadní paznehty se zdravotními komplikacemi.

Závěr

Dizertační práce se zabývá využitím moderních výpočetních metod v kombinaci s infračervenou termografií pro detekci onemocnění paznehtů dojníc. Jedná se o aktuální a významné téma ve veterinární medicíně a chovu skotu. Zdraví paznehtů bylo řešeno v experimentální části, která se zaměřila na aplikaci pokročilých technologií, jako jsou IR kamery a algoritmy strojového učení. Tyto metody představují slibnou cestu k automatizaci diagnostických procesů. To může významně přispět k včasné detekci a léčbě onemocnění paznehtů.

Analýza výsledků ukázala, že spojení moderních technologií v podobě konvolučních neuronových sítí a termografie, může v budoucnu přispět k rychlejší a efektivnější detekci zdravotních problémů. Důraz na využití technologického pokroku pro detekci představuje důležitý krok k vytvoření komplexního a holistického přístupu, který zohledňuje všechny aspekty zdraví zvířat.

Navržený systém pro detekci onemocnění, ačkoliv se jeví jako složitější, je robustnější vůči nerovnoměrnosti datasetu. Natrénovaná síť dokáže s vysokou přesností segmentovat a zároveň stanovit jestli se jedná o pazneht přední, nebo zadní. Další vlastností je rozlišení s ohledem na vyobrazení celého paznehtu, nebo pouze jen jeho části. Následně klasifikační síť pracuje již s paznehty na základě jejich párovosti a rozděluje páry s ohledem na jejich zdravotní stav. Určení konkrétního paznehtu posléze probíhá již na základě konvenčních metod.

Aplikace modelu CNN pro přímou detekci onemocnění konkrétních paznehtů se nejeví jako optimální, jelikož nedosahuje tak přesných výsledků v porovnání s komplexním systémem. Jedním z problémů mohl být nízký počet snímků u předních nemocných paznehtů v trénovacím datasetu vyplývající z výrazně nižšího procenta onemocnění předních končetin skotu (Urban-Chmiel et al., 2024).

Vzhledem k finanční náročnosti prostředků pro získávání dat by bylo vhodné problematiku dále rozpracovat obzvláště v případě rozšíření trénovacích datasetů na větším množství chovů. V kombinaci s dalšími technologiemi se tato metoda jeví jako zajímavé řešení, nicméně bude vhodné systém více otestovat v praxi.

Seznam zkratek

AI	Artificial Intelligence	Umělá inteligence
CNN	Convolutional Neural Network	Konvoluční neuronová síť
CVAT	Computer Vision Annotation Tool	
DD	Dermatitis Digitalis	Digitální dermatitida
FPS	Frames Per Second	Snímky za sekundu
GPU	Graphics Processing Unit	Grafický procesor
ID	Dermatitis Interdigitalis	Interdigitální dermatitida
IP	Ingress Protection	Stupeň krytí
IR	Infrared	Infračervená
IoT	Internet of Things	Internet věcí
IRT	Infrared Thermography	Infračervená termografie
JSON	(JavaScript Object Notation)	
LAM	Laminitis	Laminitidy
MB	Megabyte	Megabajt
ML	Machine Learning	Strojové učení
px	Pixel	Bod obrazu
SGD	Stochastic Gradient Descent	Stochastický gradientní sestup
YOLO	You Only Look Once	
rF	Relative Humidity	Relativní vlhkost
UAV	Unmanned Aerial Vehicle	Bezpilotní letoun

Seznam použitých zdrojů

- Abesi, F., Jamali, A. S., a Zamani, M. (2023). Accuracy of artificial intelligence in the detection and segmentation of oral and maxillofacial structures using cone-beam computed tomography images: a systematic review and meta-analysis. *Polish Journal of Radiology*, 88:256–263. DOI: 10.5114/pjr.2023.127624.
- Ali, A., Kaur, K., Ain, N. U., a Kumar Shukla, A. (2023). Design and Implementation of an IoT-based AI Surveillance Car with Obstacle Detection, Line Following, and Live Streaming. In *2023 Third International Conference on Secure Cyber Computing and Communication (ICSCCC)*, pp. 161–166. DOI: 10.1109/ICSCCC58608.2023.10176395.
- Alsaad, M., Fadul, M., a Steiner, A. (2019). Automatic lameness detection in cattle. *Veterinary Journal*, 246:35–44. DOI: 10.1016/j.tvjl.2019.01.005.
- Alvergnas, M., Strabel, T., Rzewuska, K., a Sell-Kubiak, E. (2019). Claw disorders in dairy cattle: Effects on production, welfare and farm economics with possible prevention methods. *Livestock Science*, 222:54–64. DOI: 10.1016/j.livsci.2019.02.011.
- Amory, J. R., Barker, Z. E., Wright, J. L., Mason, S. A., Blowey, R. W., a Green, L. E. (2008). Associations between sole ulcer, white line disease and digital dermatitis and the milk yield of 1824 dairy cows on 30 dairy cow farms in England and Wales from February 2003–November 2004. *Preventive Veterinary Medicine*, 83(3–4):381–391. DOI: 10.1016/j.prevetmed.2007.09.007.
- Antanaitis, R., Juozaitienė, V., Urbonavičius, G., Malašauskienė, D., Televičius, M., Urbutis, M., Džermeikaitė, K., a Baumgartner, W. (2021). Identification of risk factors for lameness detection with help of biosensors. *Agriculture*, 11(7):610. DOI: 10.3390/agriculture11070610.
- Arfuso, F., Acri, G., Piccione, G., Sansotta, C., Fazio, F., Giudice, E., a Giannetto, C. (2022). Eye surface infrared thermography usefulness as a noninvasive method of measuring stress response in sheep during shearing: Correlations with serum cortisol and rectal temperature values. *Physiology & Behavior*, 250:113781. DOI: 10.1016/j.physbeh.2022.113781.
- Arora, M. (2023). AI-Driven Industry 4.0: Advancing Quality Control through Cutting-Edge Image Processing for Automated Defect Detection. *International Journal of Computer Science and Mobile Computing*, 12(8):16–32. DOI: 10.47760/ij-csmc.2023.v12i08.003.

- Bansal, P., Palade, V., a Piuri, V. (2024). Editorial: Foreword to the Special Issue on Artificial Intelligence for Hyper- and Multispectral Remote Sensing Image Processing. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17:7212–7215. DOI: 10.1109/JSTARS.2024.3379013.
- Bennett, R. M., Christiansen, K., a Clifton-Hadley, R. S. (1999). Estimating the costs associated with endemic diseases of dairy cattle. *Journal of Dairy Research*, 66(3):455–459. DOI: 10.1017/S0022029999003684.
- Berger, G. (1988). *Type and distribution of foot diseases among the individual claws of cows in strawless loose housing*.
- Bernasconi, A. a Bernasconi, N. (2011). Unveiling epileptogenic lesions: The contribution of image processing. *Epilepsia*, 52(s4):20–24. DOI: 10.1111/j.1528-1167.2011.03146.x.
- Berry, S. (2009). Update on infectious claw diseases of cattle. In *CanWest Veterinary Conf., Oct, Banff, Alberta*.
- Best, C. M., Roden, J., Phillips, K., Pyatt, A. Z., a Behnke, M. C. (2021). Prevalence and Temporal Dynamics of White Line Disease in Sheep: An Exploratory Investigation into Disease Distribution and Associated Risk Factors. *Veterinary Sciences*, 8(6). DOI: 10.3390/vetsci8060116.
- Beyaz, A. a Öztürk, R. (2016). Identification of olive cultivars using image processing techniques. *Turkish Journal of Agriculture and Forestry*, 40(5):671–683. DOI: 10.3906/tar-1504-95.
- Bhoj, S., Tarafdar, A., Chauhan, A., Singh, M., a Gaur, G. K. (2022). Image processing strategies for pig liveweight measurement: Updates and challenges. *Computers and Electronics in Agriculture*, 193:106693. DOI: 10.1016/j.compag.2022.106693.
- Bloch, V., Levit, H., a Halachmi, I. (2021). Design a system for measuring individual cow feed intake in commercial dairies. *Animal*, 15(7):100277. DOI: 10.1016/j.animal.2021.100277.
- Blowey, R. (2015). *Cattle Lameness and Hoof Care*. 3. 5M Publishing Ltd., Sheffield, UK. ISBN: 978-1-910455-02-9.
- Booth, C., Warnick, L., Gröhn, Y., Maizon, D., Guard, C., a Janssen, D. (2004). Effect of lameness on culling in dairy cows. *Journal of Dairy Science*, 87(12):4115–4122. DOI: 10.3168/jds.S0022-0302(04)73554-7.
- Borghart, G. M., O’Grady, L. E., a Somers, J. R. (2021). Prediction of lameness using automatically recorded activity, behavior and production data in post-parturient Irish dairy cows. *Irish Veterinary Journal*, 74(4). DOI: 10.1186/s13620-021-00182-6.
- Bran, J. A., Daros, R. R., von Keyserlingk, M. A., LeBlanc, S. J., a Hötzel, M. J. (2018). Cow- and herd-level factors associated with lameness in small-scale grazing dairy herds in Brazil. *Preventive veterinary medicine*, 151:79–86. DOI: 10.1016/j.prevetmed.2018.01.006.

- Browne, N., Hudson, C., Crossley, R., Sugrue, K., Kennedy, E., Huxley, J., a Conneely, M. (2022). Cow- and herd-level risk factors for lameness in partly housed pasture-based dairy cows. *Journal of Dairy Science*, 105(2):1418–1431. DOI: 10.3168/jds.2021-20767.
- Brujinis, M., Beerda, B., Hogeveen, H., a Stassen, E. (2012). Assessing the welfare impact of foot disorders in dairy cattle by a modeling approach. *Animal*, 6(6):962–970. DOI: 10.1017/S1751731111002606.
- Brujinis, M. R. N., Hogeveen, H., a Stassen, E. N. (2010). Assessing economic consequences of foot disorders in dairy cattle using a dynamic stochastic simulation model. *Journal of Dairy Science*, 93(6):2419–2432. DOI: 10.3168/jds.2009-2721.
- Buch, L. H., Sørensen, A. C., Lassen, J., Berg, P., Eriksson, J.-Å., Jakobsen, J., a Sørensen, M. K. (2011). Hygiene-related and feed-related hoof diseases show different patterns of genetic correlations to clinical mastitis and female fertility. *Journal of Dairy Science*, 94(3):1540–1551. DOI: 10.3168/jds.2010-3137.
- Carratù, M., Gallo, V., Liguori, C., a Paciello, V. (2022). Development of a new speed measurement technique based on deep learning. In *2022 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*, pp. 1–6. DOI: 10.1109/I2MTC48687.2022.9806625.
- Casas-Alvarado, A., Ogi, A., Villanueva-García, D., Martínez-Burnes, J., Hernández-Avalos, I., Olmos-Hernández, A., Mora-Medina, P., Domínguez-Oliva, A., a Mota-Rojas, D. (2024). Application of Infrared Thermography in the Rehabilitation of Patients in Veterinary Medicine. *Animals*, 14(5). DOI: 10.3390/ani14050696.
- Chapinal, N., de Passillé, A., Rushen, J., a Wagner, S. (2010). Automated methods for detecting lameness and measuring analgesia in dairy cattle. *Journal of Dairy Science*, 93(5):2007–2013. DOI: 10.3168/jds.2009-2803.
- Chapinal, N. a Tucker, C. (2012). Validation of an automated method to count steps while cows stand on a weighing platform and its application as a measure to detect lameness. *Journal of Dairy Science*, 95(11):6523–6528. DOI: 10.3168/jds.2012-5742.
- Cockburn, M. (2020). Review: Application and Prospective Discussion of Machine Learning for the Management of Dairy Farms. *Animals*, 10(9). DOI: 10.3390/ani10091690.
- Cook, N. B. (2003). Prevalence of lameness among dairy cattle in Wisconsin as a function of housing type and stall surface. *Journal of the American Veterinary Medical Association*, 223(9):1324–1328. DOI: 10.2460/javma.2003.223.1324.
- Cook, N. B. (2020). Symposium review: The impact of management and facilities on cow culling rates. *Journal of Dairy Science*, 103(4):3846–3855. DOI: 10.3168/jds.2019-17140.
- Cutler, J. H., Rushen, J., De Passillé, A., Gibbons, J., Orsel, K., Pajor, E., Barkema, H., Solano, L., Pellerin, D., Haley, D., et al. (2017). Producer estimates of prevalence and perceived importance of lameness in dairy herds with tiestalls, freestalls, and automated milking systems. *Journal of Dairy Science*, 100(12):9871–9880. DOI: 10.3168/jds.2017-13008.

- Dahi, F., Parsons, M., Orlowski, H., Salter, A., Dahiya, S., a Sharma, A. (2019). Image Processing to Improve Detection of Mesial Temporal Sclerosis in Adults. *American Journal of Neuroradiology*, 40(5):798–801. DOI: 10.3174/ajnr.A6022.
- De Bresser, J., Brundel, M., Conijn, M., Van Dillen, J., Geerlings, M., Viergever, M., Luijten, P., a Biessels, G. (2013). Visual cerebral microbleed detection on 7T MR imaging: reliability and effects of image processing. *American Journal of Neuroradiology*, 34(6):E61–E64. DOI: 10.317/ajnr.A2960.
- De Mol, R. M., André, G., Bleumer, E. J. B., van der Werf, J. T. N., de Haas, Y., a van Reenen, C. G. (2013). Applicability of day-to-day variation in behavior for the automated detection of lameness in dairy cows. *Journal of Dairy Science*, 96(6):3703–3712. DOI: 10.3168/jds.2012-6305.
- De Vries, A., Bliznyuk, N., a Pinedo, P. (2023). Invited Review: Examples and opportunities for artificial intelligence (AI) in dairy farms*. *Applied Animal Science*, 39(1):14–22. DOI: 10.15232/aas.2022-02345.
- Deng, X., Tong, Z., Lan, Y., a Huang, Z. (2020). Detection and Location of Dead Trees with Pine Wilt Disease Based on Deep Learning and UAV Remote Sensing. *AgriEngineering*, 2(2):294–307. DOI: 10.3390/agriengineering2020019.
- Denis-Robichaud, J., Kelton, D., Fauteux, V., Villettaz-Robichaud, M., a Dubuc, J. (2020). Accuracy of estimation of lameness, injury, and cleanliness prevalence by dairy farmers and veterinarians. *Journal of Dairy Science*, 103(11):10696–10702. DOI: 10.3168/jds.2020-18651.
- Dolecheck, K. a Bewley, J. (2018). Animal board invited review: Dairy cow lameness expenditures, losses and total cost. *Animal*, 12(7):1462–1474. DOI: 10.1017/S1751731118000575.
- Dolecheck, K. A., Overton, M. W., Mark, T. B., a Bewley, J. M. (2019). Use of a stochastic simulation model to estimate the cost per case of digital dermatitis, sole ulcer, and white line disease by parity group and incidence timing. *Journal of Dairy Science*, 102(1):715–730. DOI: 10.3168/jds.2018-14901.
- Dudek, K., Nicholas, R. A., Szacawa, E., a Bednarek, D. (2020). Mycoplasma bovis infections-occurrence, diagnosis and control. *Pathogens*, 9(8):640. DOI: 10.3390/pathogens9080640.
- Dunthorn, J., Dyer, R. M., Neerchal, N. K., McHenry, J. S., Rajkondawar, P. G., Steingraber, G., a Tasch, U. (2015). Predictive models of lameness in dairy cows achieve high sensitivity and specificity with force measurements in three dimensions. *Journal of Dairy Research*, 82(4):391–399. DOI: 10.1017/S002202991500028X.
- Edwardes, F., van der Voort, M., Halasa, T., Holzhauer, M., a Hogeveen, H. (2022). Simulating the mechanics behind sub-optimal mobility and the associated economic losses in dairy production. *Preventive Veterinary Medicine*, 199:105551. DOI: 10.1016/j.prevetmed.2021.105551.

- Endres, M. I. (2017). The relationship of cow comfort and flooring to lameness disorders in dairy cattle. *The Veterinary clinics of North America. Food animal practice*, 33(2):227–233. DOI: 10.1016/j.cvfa.2017.02.007.
- Espejo, L. A., Endres, M. I., a Salfer, J. A. (2006). Prevalence of lameness in high-producing Holstein cows housed in freestall barns in Minnesota. *Journal of Dairy Science*, 89(8):3052–3058. DOI: 10.3168/jds.S0022-0302(06)72579-6.
- Fadchar, N. A. a Dela Cruz, J. C. (2020). Prediction Model for Chicken Egg Fertility Using Artificial Neural Network. In *2020 IEEE 7th International Conference on Industrial Engineering and Applications (ICIEA)*, pp. 916–920. DOI: 10.1109/ICIEA49774.2020.9101966.
- FAO, IFAD, UNICEF, WFP, a WHO (2023). *The State of Food Security and Nutrition in the World 2023: Urbanization, agrifood systems transformation and healthy diets across the rural–urban continuum*. FAO, Rome. DOI: 10.4060/cc3017en.
- Farahani, G. (2017). Dynamic and robust method for detection and locating vehicles in the video images sequences with use of image processing algorithm. *EURASIP Journal on Image and Video Processing*, 87. DOI: 10.1186/s13640-017-0230-1.
- Flower, F. C. a Weary, D. M. (2006). Effect of Hoof Pathologies on Subjective Assessments of Dairy Cow Gait. *Journal of Dairy Science*, 89(1):139–146. DOI: 10.3168/jds.S0022-0302(06)72077-X.
- Flower, F. C. a Weary, D. M. (2009). Gait assessment in dairy cattle. *Animal*, 3(1):87–95. DOI: 10.1017/S1751731108003194.
- Gao, Y., Gao, L., Li, X., a Yan, X. (2020). A semi-supervised convolutional neural network-based method for steel surface defect recognition. *Robotics and Computer-Integrated Manufacturing*, 61:101825. DOI: 10.1016/j.rcim.2019.101825.
- García, R., Aguilar, J., Toro, M., Pinto, A., a Rodríguez, P. (2020). A systematic literature review on the use of machine learning in precision livestock farming. *Computers and Electronics in Agriculture*, 179:105826. DOI: 10.1016/j.compag.2020.105826.
- Gardenier, J., Underwood, J., a Clark, C. (2018). Object detection for cattle gait tracking. In *2018 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 2206–2213. IEEE. DOI: 10.1109/ICRA.2018.8460523.
- Gardenier, J., Underwood, J., Weary, D. M., a Clark, C. E. F. (2021). Pairwise comparison locomotion scoring for dairy cattle. *Journal of Dairy Science*, 104(5):6185–6193. DOI: 10.3168/jds.2020-19356.
- Gokdeniz, S. a Kamburoğlu, K. (2022). Artificial intelligence in dentomaxillofacial radiology. *World Journal of Radiology*, 14(3):55–59. DOI: 10.4329/wjr.v14.i3.55.
- Goonewardene, L. A. a Hand, R. K. (1995). A study of hoof cracks in grazing cattle — association of age, weight and fatness. *Canadian Journal of Animal Science*, 75(1):25–29. DOI: 10.4141/cjas95-003.

- Green, L. E., Hedges, V. J., Schukken, Y. H., Blowey, R. W., a Packington, A. J. (2002). The impact of clinical lameness on the milk yield of dairy cows. *Journal of dairy science*, 85(9):2250–2256. DOI: 10.3168/jds.S0022-0302(02)74304-X.
- Guo, Y., He, D., a Chai, L. (2020). A machine vision-based method for monitoring scene-interactive behaviors of dairy calf. *Animals*, 10(2):190. DOI: 10.3390/ani10020190.
- Hazelton, M., Morton, J., Parker, A., Bosward, K., Sheehy, P., Dwyer, C., Niven, P., a House, J. (2020). Mycoplasma bovis and other Mollicutes in replacement dairy heifers from Mycoplasma bovis-infected and uninfected herds: A 2-year longitudinal study. *Journal of dairy science*, 103(12):11844–11856. DOI: 10.3168/jds.2020-18921.
- Hernandez-Mendo, O., Von Keyserlingk, M., Veira, D., a Weary, D. (2007). Effects of pasture on lameness in dairy cows. *Journal of Dairy Science*, 90(3):1209–1214. DOI: 10.3168/jds.S0022-0302(07)71608-9.
- Hogeveen, H., Steeneveld, W., a Wolf, C. A. (2019). Production diseases reduce the efficiency of dairy production: A review of the results, methods, and approaches regarding the economics of mastitis. *Annual review of resource economics*, 11(1):289–312. DOI: 10.1146/annurev-resource-100518-093954.
- Huxley, J. N. (2012). Lameness in cattle: an ongoing concern. *Veterinary Journal (London, England: 1997)*, 193(3):610–611. DOI: 10.1016/j.tvjl.2012.06.039.
- Jasińska, I. (2019). The Algorithms of Image Processing and Analysis in the Textile Fabrics Abrasion Assessment. *Applied Sciences*, 9(18):3791. DOI: 10.3390/app9183791.
- Jeon, C., Kim, H., a Kim, D. (2024). A Deep-Learning-Based System for Pig Posture Classification: Enhancing Sustainable Smart Pigsty Management. *Sustainability*, 16(7). DOI: 10.3390/su16072888.
- Jiang, L., Fan, Y., Sheng, Q., Feng, X., a Wang, W. (2018). Research on path guidance of logistics transport vehicle based on image recognition and image processing in port area. *EURASIP Journal on Image and Video Processing*, 141(2018). "DOI: 10.1186/s13640-018-0384-5".
- Jindal, N. a Singh, K. (2019). Applicability of fractional transforms in image processing – review, technical challenges and future trends. *Multimedia Tools and Applications*, 78:10673–10700. DOI: 10.1007/s11042-018-6594-0.
- Juarez, S., Robinson, P., DePeters, E., a Price, E. (2003). Impact of lameness on behavior and productivity of lactating Holstein cows. *Applied Animal Behaviour Science*, 83(1):1–14. DOI: 10.1016/S0168-1591(03)00107-2.
- Kamphuis, C., Frank, E., Burke, J. K., Verkerk, G. A., a Jago, J. G. (2013). Applying additive logistic regression to data derived from sensors monitoring behavioral and physiological characteristics of dairy cows to detect lameness. *Journal of Dairy Science*, 96(11):7043–7053. DOI: 10.3168/jds.2013-6993.
- Karypidou, S., Georgousis, I., a Papakostas, G. A. (2021). Computer Vision for Astronomical Image Analysis. In *2021 IEEE International Conference on Progress in Informatics and Computing (PIC)*, pp. 94–101. DOI: 10.1109/PIC53636.2021.9687023.

- Kashiha, M. A., Bahr, C., Ott, S., Moons, C. P., Niewold, T. A., Tuytens, F., a Berckmans, D. (2014). Automatic monitoring of pig locomotion using image analysis. *Livestock Science*, 159:141–148. DOI: 10.1016/j.livsci.2013.11.007.
- Koirala, A., Walsh, K., Wang, Z., a McCarthy, C. (2019). Deep learning for real-time fruit detection and orchard fruit load estimation: benchmarking of ‘MangoYOLO’. *Precision Agriculture*, 20:1107–1135. DOI: 10.1007/s11119-019-09642-0.
- Kollis, K., Phang, C. S., Banhazi, T. M., a Searle, S. J. (2007). Weight estimation using image analysis and statistical modelling: A preliminary study. *Applied engineering in agriculture*, 23(1):91–96. DOI: 10.13031/2013.22332.
- Kongsro, J. (2014). Estimation of pig weight using a Microsoft Kinect prototype imaging system. *Computers and Electronics in Agriculture*, 109:32–35. DOI: 10.1016/j.compag.2014.08.008.
- Krpalkova, L., Cabrera, E. V., Zavadilova, L., a Stipkova, M. (2019). The importance of hoof health in dairy production. *Czech Journal of Animal Science*, 64(3):107–117. DOI: 10.17221/27/2018-CJAS.
- Kuo, C., Lu, Y., a Yang, S. (2019). On the Image Sensor Processing for Lane Detection and Control in Vehicle Lane Keeping Systems. *Sensors (Basel, Switzerland)*, 19(7). DOI: 10.3390/s19071665.
- Lao, F., Brown-Brandl, T., Stinn, J., Liu, K., Teng, G., a Xin, H. (2016). Automatic recognition of lactating sow behaviors through depth image processing. *Computers and Electronics in Agriculture*, 125:56–62. DOI: 10.1016/j.compag.2016.04.026.
- Laursen, M., Boelling, D., a Mark, T. (2009). Genetic parameters for claw and leg health, foot and leg conformation, and locomotion in Danish Holsteins. *Journal of Dairy Science*, 92(4):1770–1777. DOI: 10.3168/jds.2008-1388.
- Leach, K., Whay, H., Maggs, C., Barker, Z., Paul, E., Bell, A., a Main, D. (2010). Working towards a reduction in cattle lameness: 1. Understanding barriers to lameness control on dairy farms. *Research in Veterinary Science*, 89(2):311–317. DOI: 10.1016/j.rvsc.2010.02.014.
- Lee, J., Jin, L., Park, D., a Chung, Y. (2016). Automatic Recognition of Aggressive Behavior in Pigs Using a Kinect Depth Sensor. *Sensors*, 16(5):631. DOI: 10.3390/s16050631.
- Li, G., Zhao, Y., Purswell, J. L., Du, Q., Chesser, G. D., a Lowe, J. W. (2020). Analysis of feeding and drinking behaviors of group-reared broilers via image processing. *Computers and Electronics in Agriculture*, 175:105596. DOI: 10.1016/j.compag.2020.105596.
- Liu, J., Dyer, R. M., Neerchal, N. K., Tasch, U., a Rajkondawar, P. G. (2011). Diversity in the magnitude of hind limb unloading occurs with similar forms of lameness in dairy cows. *Journal of Dairy Research*, 78(2):168–177. DOI: 10.1017/S0022029911000057.
- Liu, N., Wan, L., Zhang, Y., Zhou, T., Huo, H., a Fang, T. (2018). Exploiting Convolutional Neural Networks With Deeply Local Description for Remote Sensing Image Classification. *IEEE Access*, 6:11215–11228. DOI: 10.1109/ACCESS.2018.2798799.

- Losinger, W. C. (2006). Economic impacts of reduced milk production associated with papillomatous digital dermatitis in dairy cows in the USA. *Journal of Dairy Research*, 73(2):244–256. DOI: 10.1017/S0022029906001798.
- Ma, L., Xie, W., a Huang, H. (2020). Convolutional neural network based obstacle detection for unmanned surface vehicle. *Mathematical Biosciences and Engineering*, 17(1):845–861. DOI: 10.3934/mbe.2020045.
- Matsuo, S., Takahashi, Y., Tokoro, C., a Isozaki, M. (2023). Construction of flower bud diagnosis system using AI image analysis in strawberry cultivation. *Acta Horticulturae*, 1360:229–236. DOI: 0.17660/ActaHortic.2023.1360.29.
- Mohamed, S. A. (2019). Application of satellite image processing and GIS-Spatial modeling for mapping urban areas prone to flash floods in Qena governorate, Egypt. *Journal of African Earth Sciences*, 158:103507. DOI: 10.1016/j.jafrearsci.2019.05.015.
- Moreira, T. F., Nicolino, R. R., Meneses, R. M., Fonseca, G. V., Rodrigues, L. M., Farcy Filho, E. J., a Carvalho, A. U. (2019). Risk factors associated with lameness and hoof lesions in pasture-based dairy cattle systems in southeast Brazil. *Journal of dairy science*, 102(11):10369–10378. DOI: 10.3168/jds.2018-16215.
- Ni, C.-T., Ng, K.-S., Chen, Y.-R., Chang, S.-C., Hsu, C.-B., Chen, P.-Y., a Liao, S.-C. (2020). A System for Analyzing Pig's Behavior with AI. In *2020 IEEE International Conference on Consumer Electronics – Taiwan (ICCE-Taiwan)*, pp. 1–2. DOI: 10.1109/ICCE-Taiwan49838.2020.9258228.
- Norring, M., Häggman, J., Simojoki, H., Tamminen, P., Winckler, C., a Pastell, M. (2014). Short communication: Lameness impairs feeding behavior of dairy cows. *Journal of Dairy Science*, 97(7):4317–4321. DOI: 10.3168/jds.2013-7512.
- Nuss, K. (2011). Synovial structures-cure or no cure? *Large Animal Review*, 18(18):39–40. DOI: 10.5167/uzh-74090.
- Oberbauer, A., Berry, S., Belanger, J., McGoldrick, R., Pinos-Rodriguez, J., a Famula, T. (2013). Determining the heritable component of dairy cattle foot lesions. *Journal of Dairy Science*, 96(1):605–613. DOI: 10.3168/jds.2012-5485.
- OECD/FAO (2022). *OECD-FAO Agricultural Outlook 2022–2031*. OECD Publishing, Paris. DOI: 10.1787/f1b0b29c-en.
- Orman, A. a Endres, M. (2016). Use of thermal imaging for identification of foot lesions in dairy cattle. *Acta Agriculturae Scandinavica, Section A—Animal Science*, 66(1):1–7. DOI: 10.1080/09064702.2016.1179785.
- Ortega, D. L. a Wolf, C. A. (2018). Demand for farm animal welfare and producer implications: Results from a field experiment in Michigan. *Food Policy*, 74:74–81. DOI: 10.1016/j.foodpol.2017.11.006.
- O'Driscoll, K., Boyle, L., French, P., a Hanlon, A. (2008). The effect of out-wintering pad design on hoof health and locomotion score of dairy cows. *Journal of Dairy Science*, 91(2):544–553. DOI: 10.3168/jds.2007-0667.

- Padilla, R., Netto, S. L., a da Silva, E. A. B. (2020). A Survey on Performance Metrics for Object-Detection Algorithms. In *2020 International Conference on Systems, Signals and Image Processing (IWSSIP)*, pp. 237–242. DOI: 10.1109/IWSSIP48289.2020.9145130.
- Palmer, M. A. a O’Connell, N. E. (2015). Digital dermatitis in dairy cows: A review of risk factors and potential sources of between-animal variation in susceptibility. *Animals (Basel)*, 5(3):512–535. DOI: 10.3390/ani5030369.
- Pastell, M., Hänninen, L., de Passille, A. M., a Rushen, J. (2010). Measures of weight distribution of dairy cows to detect lameness and the presence of hoof lesions. *Journal of dairy science*, 93(3):954–960. DOI: 10.3168/jds.2009-2385.
- Penev, T. a Stankov, K. (2015). Effect of lameness on milk production traits in holstein-friesian dairy cows. *Veterinarija ir Zootechnika*, 70(92):53–59.
- Pereira, F., Jeromini, T., Silva, G., Barros Torres, S., a Martins, C. (2022). Evaluation of the physiological potential of *Panicum maximum* seeds by multivariate analysis. *Bioscience Journal*, 38:e38017. DOI: 10.14393/BJ-v38n0a2022-53754.
- Pinheiro, D. T., Medeiros, A. D., Zavala-León, M. J., Dias, D. C. F. S., a da Silva, L. J. (2020). Physical and physiological quality of *Jatropha curcas* L. seeds at different maturity stages using image analysis. *Spanish Journal of Agricultural Research*, 18(3):e0206. DOI: 10.5424/sjar/2020183-16028.
- Pluk, A., Bahr, C., Poursaberi, A., Maertens, W., Van Nuffel, A., a Berckmans, D. (2012). Automatic measurement of touch and release angles of the fetlock joint for lameness detection in dairy cattle using vision techniques. *Journal of dairy Science*, 95(4):1738–1748. DOI: 10.3168/jds.2011-4547.
- Poursaberi, A., Bahr, C., Pluk, A., Van Nuffel, A., a Berckmans, D. (2010). Real-time automatic lameness detection based on back posture extraction in dairy cattle: Shape analysis of cow with image processing techniques. *Computers and electronics in agriculture*, 74(1):110–119. DOI: 10.1016/j.compag.2010.07.004.
- Prasad, R., Sourie, S., Cherukuri, V., Fita, L., a Merera, C. (2015). Global warming: Genesis, facts and impacts on livestock farming and mitigation strategies. *Int. J. Agric. Innov. Res*, 3:2319–1473.
- Prasomsri, P. (2022). Effect of lameness on daily milk yield in dairy cow. *The Thai Journal of Veterinary Medicine*, 52(4):679–687. DOI: 10.56808/2985-1130.3263.
- Qiao, Y., Kong, H., Clark, C., Lomax, S., Su, D., Eiffert, S., a Sukkarieh, S. (2021a). Intelligent Perception-Based Cattle Lameness Detection and Behaviour Recognition: A Review. *Animals*, 11(11). DOI: 10.3390/ani11113033.
- Qiao, Y., Kong, H., Clark, C., Lomax, S., Su, D., Eiffert, S., a Sukkarieh, S. (2021b). Intelligent perception for cattle monitoring: A review for cattle identification, body condition score evaluation, and weight estimation. *Computers and Electronics in Agriculture*, 185:106143. DOI: 10.1016/j.compag.2021.106143.

- Qiao, Y., Truman, M., a Sukkarieh, S. (2019). Cattle segmentation and contour extraction based on Mask R-CNN for precision livestock farming. *Computers and Electronics in Agriculture*, 165:104958. DOI: 10.1016/j.compag.2019.104958.
- Radinović, M., Stanojević, J., Cincović, M., a Belić, B. (2020). The Effect of aseptic pododermatitis on milk production. *Veterinary Journal of the Republic Serbia*, 20(1–2). DOI: 10.7251/VETJEN2001133S.
- Randall, L., Green, M., Chagunda, M., Mason, C., Green, L., a Huxley, J. (2016). Lameness in dairy heifers; impacts of hoof lesions present around first calving on future lameness, milk yield and culling risk. *Preventive Veterinary Medicine*, 133:52–63. DOI: 10.1016/j.prevetmed.2016.09.006.
- Refaai, W., Van Aert, M., Abd El-Aal, A., Behery, A., a Opsomer, G. (2013). Infectious diseases causing lameness in cattle with a main emphasis on digital dermatitis (Mortellaro disease). *Livestock Science*, 156(1–3):53–63. DOI: 10.1016/j.livsci.2013.06.004.
- Retallack, A., Finlayson, G., Ostendorf, B., a Lewis, M. (2022). Using deep learning to detect an indicator arid shrub in ultra-high-resolution UAV imagery. *Ecological Indicators*, 145:109698. DOI: 10.1016/j.ecolind.2022.109698.
- Riaz, U., Idris, M., Ahmed, M., Ali, F., Farooq, U., a Yang, L. (2024). The Potential of Infrared Thermography for Early Pregnancy Diagnosis in Nili-Ravi Buffaloes. *Animals*, 14(13). DOI: 10.3390/ani14131966.
- Roche, S., Renaud, D., Saraceni, J., Kelton, D., a DeVries, T. (2024). Invited review: Prevalence, risk factors, treatment, and barriers to best practice adoption for lameness and injuries in dairy cattle – A narrative review. *Journal of Dairy Science*, 107(6):3347–3366. DOI: 10.3168/jds.2023-23870.
- Rodríguez, A., Olivares, F., Descouvieres, P., Werner, M., Tadich, N., a Bustamante, H. (2016). Thermographic assessment of hoof temperature in dairy cows with different mobility scores. *Livestock Science*, 184:92–96. DOI: 10.1016/j.livsci.2015.12.006.
- Rombach, M., Dean, D. L., a Bitsch, V. (2023). “Got Milk Alternatives?” Understanding Key Factors Determining U.S. Consumers’ Willingness to Pay for Plant-Based Milk Alternatives. *Foods*, 12(6). DOI: 10.3390/foods12061277.
- Ryan, E. a Conneely, M. (2024). The cost of lameness in Irish dairy herds. *Veterinary Ireland Journal*, 14(4):217–222.
- Sadiq, M. B., Ramanoon, S. Z., Shaik Mossadeq, W. M., Mansor, R., a Syed Hussain, S. S. (2019). Dairy farmers’ perceptions of and actions in relation to lameness management. *Animals*, 9(5):270. DOI: 10.3390/ani9050270.
- Sadoughi, F., Kazemy, Z., Hamedan, F., Owji, L., Rahmanikatigari, M., a Azadboni, T. T. (2018). Artificial intelligence methods for the diagnosis of breast cancer by image processing: a review. *Breast Cancer: Targets and Therapy*, 10:219–230. DOI: 10.2147/BCTT.S175311.

- Saraswat, S., Keswani, B., Sharma, V., Saraswat, V., a Lamba, M. (2023). Mammograms-Based Breast Cancer Detection Using Ai Image Processing Techniques. *Journal of Coastal Life Medicine*, 11(1):1980–1986. DOI: 10.52783/jclm.v11i1.617.
- Schlageter-Tello, A., Bokkers, E., Groot Koerkamp, P., Van Hertem, T., Viazzi, S., Romanini, C. and Halachmi, I., Bahr, C., Berckmans, D., a Lokhorst, K. (2015). Comparison of locomotion scoring for dairy cows by experienced and inexperienced raters using live or video observation methods. *Animal Welfare*, 24(1):69–79. DOI: 10.7120/09627286.24.1.069.
- Schlageter-Tello, A., Bokkers, E. A. M., Koerkamp, P. W. G. G., Van Hertem, T., Viazzi, S., Romanini, C. E. B., Halachmi, I., Bahr, C., Berckmans, D., a Lokhorst, K. (2014). Manual and automatic locomotion scoring systems in dairy cows: A review. *Preventive Veterinary Medicine*, 116(1):12–25. DOI: 10.1016/j.prevetmed.2014.06.006.
- Severiano, R. S., Araújo, J. P., Cristina, G., Flávio, S., Mariana, A., a Cerqueira, J. L. (2021). Precision technologies to address dairy cattle welfare: focus on lameness, mastitis and body condition. *Animals*, 11(8):2253. DOI: 10.3390/ani11082253.
- Shen, W., Hu, H., Dai, B., Wei, X., Sun, J., Jiang, L., a Sun, Y. (2020). Individual identification of dairy cows based on convolutional neural networks. *Multimedia Tools and Applications*, 79:14711–14724. DOI: 10.1007/s11042-019-7344-7.
- Sheng, K., Foris, B., von Keyserlingk, M. A. G., Gardenier, J., Clark, C., a Weary, D. M. (2023). Crowd sourcing remote comparative lameness assessments for dairy cattle. *Journal of Dairy Science*, 106(8):5715–5722. DOI: 10.3168/jds.2022-22737.
- Silván-Cárdenas, J. L., Almazán-González, J. A., a Couturier, S. A. (2014). Remote Identification of Housing Buildings with High-Resolution Remote Sensing. In Martínez-Trinidad, J. F., Carrasco-Ochoa, J. A., Olvera-Lopez, J. A., Salas-Rodríguez, J., a Suen, C. Y., eds., *Pattern Recognition*, pp. 380–390, Cham. Springer International Publishing. ISBN: 978-3-319-07491-7.
- Singh, R., Maiti, S., Garai, S., a Singh, R. (2023). Sustainable intensification – reaching towards climate resilience livestock production system – A Review. *Annals of Animal Science*, 23:1037–1047. DOI: 10.2478/aoas-2023-0027.
- Somers, J., Frankena, K., Noordhuizen-Stassen, E., a Metz, J. (2005). Risk factors for digital dermatitis in dairy cows kept in cubicle houses in The Netherlands. *Preventive Veterinary Medicine*, 71(1–2):11–21. DOI: 10.1016/j.prevetmed.2005.05.002.
- Sun, S., Li, C., Paterson, A. H., Chee, P. W., a Robertson, J. S. (2019). Image processing algorithms for infield single cotton boll counting and yield prediction. *Computers and Electronics in Agriculture*, 166:104976. DOI: 10.1016/j.compag.2019.104976.
- Thorup, V. M., Munksgaard, L., Robert, P.-E., Erhard, H. W., Thomsen, P. T., a Friggens, N. C. (2015). Lameness detection via leg-mounted accelerometers on dairy cows on four commercial farms. *Animal*, 9(10):1704–1712. DOI: 10.1017/S1751731115000890.

- Thorup, V. M., Nielsen, B. L., Robert, P.-E., Giger-Reverdin, S., Konka, J., Michie, C., a Friggens, N. C. (2016). Lameness affects cow feeding but not rumination behavior as characterized from sensor data. *Frontiers in veterinary science*, 3:37. DOI: 10.3389/fvets.2016.00037.
- Uggla, E., Jakobsen, J., Bergsten, C., Eriksson, J.-Å., a Strandberg, E. (2008). Genetic correlations between claw health and feet and leg conformation traits in Swedish dairy cows. In *Proceedings of the 2008 Interbull meeting*, volume 38, pp. 91–95.
- Ultralytics Inc. (2024). YOLOv8. [online]. [cit. 2024-08-25], Dostupné z: <https://docs.ultralytics.com/models/yolov8/#supported-tasks-and-modes>.
- Unger, S. D., Rollins, M. A., a Thompson, C. M. (2020). Hot- or cold-blooded? A laboratory activity that uses accessible technology to investigate thermoregulation in animals. *The American Biology Teacher*, 82(4):227–233. DOI: 10.1525/abt.2020.82.4.227.
- Urban-Chmiel, R., Mudron, P., Abramowicz, B., Kurek, L., a Stachura, R. (2024). Lameness in Cattle-Etiopathogenesis, Prevention and Treatment. *Animals*, 14(12):1836. DOI: 10.3390/ani14121836.
- Van Amstel, S. a Shearer, J. (2006). *Manual for treatment and control of lameness in cattle*. John Wiley & Sons. ISBN: 9780813814186.
- Van der Linde, C., De Jong, G., Koenen, E., a Eding, H. (2010). Claw health index for Dutch dairy cattle based on claw trimming and conformation data. *Journal of Dairy Science*, 93(10):4883–4891. DOI: 10.3168/jds.2010-3183.
- Van der Waaij, E., Holzhauer, M., Ellen, E., Kamphuis, C., a De Jong, G. (2005). Genetic parameters for claw disorders in Dutch dairy cattle and correlations with conformation traits. *Journal of Dairy Science*, 88(10):3672–3678. DOI: 10.3168/jds.S0022-0302(05)73053-8.
- Van Hertem, T., Viazzi, S., Steensels, M., Maltz, E., Antler, A., Alchanatis, V., Schlageter-Tello, A. A., Lokhorst, K., Romanini, E. C., Bahr, C., Berckmans, D., a Halachmi, I. (2014). Automatic lameness detection based on consecutive 3D-video recordings. *Biosystems Engineering*, 119:108–116. DOI: 10.1016/j.biosystemseng.2014.01.009.
- Van Metre, D. C. (2017). Pathogenesis and treatment of bovine foot rot. *The Veterinary clinics of North America. Food animal practice*, 33(2):183–194. DOI: 10.1016/j.cvfa.2017.02.003.
- Van Nuffel, A., Saeys, W., Sonck, B., Vangeyte, J., Mertens, K. C., De Ketelaere, B., a Van Weyenberg, S. (2015). Variables of gait inconsistency outperform basic gait variables in detecting mildly lame cows. *Livestock Science*, 177:125–131. DOI: 10.1016/j.livsci.2015.04.008.
- Velagapudi, V., O'Horo, J. C., Vellanki, A., Baker, S. P., Pidikiti, R., Stoff, J. S., a Tighe, D. A. (2017). Computer-assisted image processing 12 lead ECG model to diagnose hyperkalemia. *Journal of electrocardiology*, 50(1):131–138. DOI: 10.1016/j.jelectrocard.2016.09.001.

- Viazzi, S., Bahr, C., Schlageter-Tello, A., Van Hertem, T., Romanini, C., Pluk, A., Halachmi, I., Lokhorst, C., a Berckmans, D. (2013). Analysis of individual classification of lameness using automatic measurement of back posture in dairy cattle. *Journal of Dairy Science*, 96(1):257–266. DOI: 10.3168/jds.2012-5806.
- Viazzi, S., Bahr, C., Van Hertem, T., Schlageter-Tello, A., Romanini, C., Halachmi, I., Lokhorst, C., a Berckmans, D. (2014). Comparison of a three-dimensional and two-dimensional camera system for automated measurement of back posture in dairy cows. *Computers and Electronics in Agriculture*, 100:139–147. DOI: 10.1016/j.compag.2013.11.005.
- Volkman, N., Kulig, B., a Kemper, N. (2019). Using the Footfall Sound of Dairy Cows for Detecting Claw Lesions. *Animals*, 9(3). DOI: 10.3390/ani9030078.
- Wang, A., Zhang, W., a Wei, X. (2019). A review on weed detection using ground-based machine vision and image processing techniques. *Computers and Electronics in Agriculture*, 158:226–240. DOI: 10.1016/j.compag.2019.02.005.
- Wang, Y., Li, Q., Chu, M., Kang, X., a Liu, G. (2023). Application of infrared thermography and machine learning techniques in cattle health assessments: A-review. *Biosystems Engineering*, 230:361–387. DOI: 10.1016/j.biosystemseng.2023.05.002.
- Wemette, M., Greiner Safi, A., Wolverton, A., Beauvais, W., Shapiro, M., Moroni, P., Welcome, F., a Ivanek, R. (2021). Public perceptions of antibiotic use on dairy farms in the United States. *Journal of Dairy Science*, 104(3):2807–2821. DOI: 10.3168/jds.2019-17673.
- Whay, H. R., Main, D. C. J., Green, L. E., a Webster, A. J. F. (2003). Assessment of the welfare of dairy cattle using animal-based measurements: direct observations and investigation of farm records. *Veterinary Record*, 153(7):197–202. DOI: 10.1136/vr.153.7.197.
- Whittaker, A. L., Muns, R., Wang, D., Martínez-Burnes, J., Hernández-Ávalos, I., Casas-Alvarado, A., Domínguez-Oliva, A., a Mota-Rojas, D. (2023). Assessment of Pain and Inflammation in Domestic Animals Using Infrared Thermography: A Narrative Review. *Animals*, 13(13). DOI: 10.3390/ani13132065.
- Willshire, J. A. a Bell, N. J. (2009). An economic review of cattle lameness. *Cattle Practice*, 17(2):136–141.
- Zavdilová, L., Kašná, E., a Krupová, Z. (2020). *Definice kombinovaných znaků nemocí a poruch paznehtů pro odhad plemenných hodnot u holštýnského skotu*. Výzkumný ústav živočišné výroby, v.v.i., Praha, 1 edition. ISBN: 978-80-7403-234-9.
- Zhang, J., Li, M., Feng, Y., a Yang, C. (2020). Robotic grasp detection based on image processing and random forest. *Multimedia Tools and Applications*, 79:2427–2446. DOI: 10.1007/s11042-019-08302-9.
- Zhao, K., Bewley, J., He, D., a Jin, X. (2018). Automatic lameness detection in dairy cattle based on leg swing analysis with an image processing technique. *Computers and Electronics in Agriculture*, 148:226–236. DOI: 10.1016/j.compag.2018.03.014.

- Zhuang, X. a Zhang, T. (2019). Detection of sick broilers by digital image processing and deep learning. *Biosystems Engineering*, 179:106–116. DOI: 10.1016/j.biosystemseng.2019.01.003.
- Zillner, J. C., Tücking, N., Plattes, S., Heggemann, T., a Büscher, W. (2018). Using walking speed for lameness detection in lactating dairy cows. *Livestock Science*, 218:119–123. DOI: 10.1016/j.livsci.2018.10.005.
- Zubarev, A., Nadezhdina, I., Kozlova, N., Brusnikin, E., a Karachevtseva, I. (2016). SPECIAL SOFTWARE FOR PLANETARY IMAGE PROCESSING AND RESEARCH. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLI-B4:529–536. DOI: 10.5194/isprs-archives-XLI-B4-529-2016.



Jméno a příjmení: Ing. Mgr. Radim Stehlík

Narození: 2. července 1993, Příbram

Bydliště: Pražská tř. 839/40, České Budějovice 3, 370 04

Kontakt: stehlr@fzt.jcu.cz

Rodinný stav: ženatý

ODBORNÉ ZAMĚŘENÍ

Vývoj a testování technologií pro živočišnou produkci.
Aplikace metod počítačového vidění v chovech skotu.
Modelování a 3D tisk.

VZDĚLÁNÍ

od 2019	Jihočeská univerzita v Českých Budějovicích – Zemědělská fakulta DSP Zootechnika, Obecná zootechnika
2019-2022	Jihočeská univerzita v Českých Budějovicích – Zemědělská fakulta Zemědělské inženýrství, Zemědělská a dopravní technika, titul Ing.
2017-2019	Jihočeská univerzita v Českých Budějovicích – Pedagogická fakulta obor Učitelství technické výchovy pro 2. stupeň ZŠ a tělesné výchovy pro střední školy, titul Mgr.
2013-2017	Jihočeská univerzita v Českých Budějovicích – Pedagogická fakulta obor Technická výchova, tělesná výchova a sport se zaměřením na vzdělání, titul Bc.
2009-2013	Střední průmyslová škola a Vyšší odborná škola Příbram obor Slaboproudá elektrotechnika, zaměření Výpočetní technika

PRACOVNÍ ZKUŠENOSTI

od 2020	Jihočeská univerzita v Českých Budějovicích, Zemědělská fakulta od 10/2020 – odborný asistent od 01/2022 – vedoucí mezinárodního vzdělávacího a výzkumného centra společnosti DeLaval
2019-2020	ZŠ a MŠ J. Š. Baara Učitel druhého stupně základní školy
2019	Jihočeská univerzita v Českých Budějovicích, Zemědělská fakulta IT specialista

Pracovní úvazky formou DPP či DPČ u společností **Jihočeská univerzita v Českých Budějovicích**, **C+C servis s.r.o.**, **PBTisk a.s.** a další.

VĚDECKO-VÝZKUMNÁ ČINNOST

Spoluúčast na grantových projektech:

NAZV QK1910174 Zvyšování kvality mléka a jeho ekonomických ukazatelů využitím automatizovaného systému sledování vybraných parametrů v reálném čase (2019-2023 – *aktivní spoluúčast na řešení*)

TAČR TREND FW01010391

Vývoj systému pro nepřetržitou identifikaci a etologické sledování zvířat v chovech skotu s využitím metod umělé inteligence (2020-2023 – *aktivní spoluúčast na řešení*)

TAČR DELTA 2 TM02000027

Výzkum a vývoj chytrých technologií pro chovy skotu a prasat založených na pokročilých výpočetních postupech (2020-2023 – *aktivní spoluúčast na řešení*)

Realizace zakázek aplikovaného výzkumu:

MPO TRIO FV30234

Výzkum a vývoj procesu laserového potisku skleněných ploch malého až velkého formátu pro potřeby současného stavebnictví (2018-2020 – *aktivní spoluúčast na řešení*)

OP PIK CZ.01.1.02/0.0/0.0/20_321/0024484

Výzkum a vývoj inteligentního čajovaru pro přípravu čaje s přidanými složkami (2021-2023 – *člen řešitelského týmu*)

JIHOČESKÝ PODNIKATELSKÝ VOUCHER Kvalitní analýza mléka (2020-2021 – *člen řešitelského týmu*)

PUBLIKAČNÍ ČINNOST

Přehled

Články v impaktovaném časopise:	7	Patenty:	1
Další publikační činnost:	6	Užitné vzory:	5
Knihy a brožury:	1		

Články v impaktovaném časopise

- KŘÍŽ, P., KUNEŠ, R., SMUTNÝ, L., ČERNÝ, P., HAVELKA, Z., OLŠAN, P., XIAO, M., **STEHLÍK, R.**, DOLAN, A., BARTOŠ, P. Methodology for Measurement of Ammonia Emissions from Intensive Pig Farming. Agriculture, 2021, roč. 11, č. 11, s. 1073. ISSN 2077-0472.
- KŘÍŽ, P., HORČIČKOVÁ, M., BUMBÁLEK, R., BARTOŠ, P., SMUTNÝ, L., **STEHLÍK, R.**, ZOUBEK, T., ČERNÝ, P., VOCHOZKA, V., KUNEŠ, R. Application of the Machine Vision Technology and Infrared Thermography to the Detection of Hoof Diseases in Dairy Cows: A Review. Applied Sciences-Basel, 2021, roč. 11, č. 22, s. 11045. ISSN 2076-3417.
- HAVELKA, Z., KUNEŠ, R., KONONETS, Y., STOKES, JE., SMUTNÝ, L., OLŠAN, P., KRESAN, J., **STEHLÍK, R.**, BARTOŠ, P., XIAO, M., KŘÍŽ, P., FINDURA, P., ROZTOČIL, D. Technology of Microclimate Regulation in Organic and Energy-Sustainable Livestock Production. Agriculture, 2022, roč. 12, č. September, s. 1–24. ISSN 2077-0472.
- KUNEŠ, R., HAVELKA, Z., OLŠAN, P., SMUTNÝ, L., FILIP, M., ZOUBEK, T., BUMBÁLEK, R., PETROVIĆ, B., **STEHLÍK, R.**, BARTOŠ, P. A Review: Comparison of approaches to the approval process and methodology for estimation of ammonia emissions from livestock farms under IPPC. Atmosphere, 2022, roč. 13, č. November, s. 1–22. ISSN 2073-4433.
- KUNEŠ, R., HAVELKA, Z., OLŠAN, P., DOLAN, A., **STEHLÍK, R.**, PETROVIĆ, B., SMUTNÝ, L., BARTOŠ, P., XIAO, M., KŘÍŽ, P., ČERNÝ, P. Comparison of the Three Approaches for Determining Ammonia Emissions in the Intensive Breeding of Fattening Pigs with Respect to the Integrated Pollution Prevention and Control: Case Study for the Czech Republic. Atmosphere, 2022, roč. 13, č. 12, s. 1–12. ISSN 2073-4433.
- UFITIKIREZI, JdDM., FILIP, M., GHORBANI, M., ZOUBEK, T., OLŠAN, P., BUMBÁLEK, R., STROB, M., BARTOŠ, P., UMURUNGI, SN., MURINDANGABO, YT., HEŘMÁNEK, A., TUPÝ, O., HAVELKA, Z., **STEHLÍK, R.**, ČERNÝ, P., SMUTNÝ, L. Agricultural Waste Valorization: Exploring Environmentally Friendly Approaches to Bioenergy Conversion. Sustainability. 2024; 16(9):3617.
- VOCHOZKA, V., ČERNÝ, P., ŠRAMHAUSER, K., ŠPALEK, F., KŘÍŽ, P., ČECH, J., ZOUBEK, T., BARTOŠ, P., KRESAN, J., **STEHLÍK, R.** Fused Filament Fabrication Parametry 3D tisku ovlivňující průsvitnost částí kyseliny polymléčné. Polymery 2024 , 16 , 2862.

Další publikační činnost

- BUMBÁLEK, R., HAVELKA, Z., **STEHLÍK, R.**, SMUTNÝ, L., OLŠAN, P. Stručný přehled umělé inteligence a její aplikace. Malá, , Novák, , Holíková, Aktuální otázky bioklimatologie zvířat 2021. Praha : Výzkumný ústav živočišné výroby, 2021, s. 10–13. ISBN 978-80-7403-263-9.
- SMUTNÝ, L., SMUTNÁ, Š., BUMBÁLEK, R., HAVELKA, Z., **STEHLÍK, R.**, SMUTNÝ, D., OLŠAN, P. Využití hmotnostní křivky ke sledování zdravotního stavu dojnic. Malá, , Novák, , Holíková, Aktuální otázky bioklimatologie zvířat 2021. Praha : Výzkumný ústav živočišné výroby, 2021, s. 104–105. ISBN 978-80-7403-263-9.
- SMUTNÝ, L., BUMBÁLEK, R., KOŽÍŠKOVÁ, M., **STEHLÍK, R.**, SMUTNÝ, D. (2022). Využití robotické ruky jako náhrada ruční práce dojičů. In: Aktuální otázky bioklimatologie zvířat 2022. Výzkumný ústav živočišné výroby, Praha. ISBN 978-80-7403-277-6.
- HÁLOVÁ, K., SAMKOVÁ, E., SMUTNÝ, L., SMUTNÝ, D., **STEHLÍK, R.**, CLIMOVÁ, N., HONESOVÁ, S., SMETANA, P., JANOUŠKOVÁ, K., BARTOŠ, P.: Experimentální porovnání nepřímých metod pro stanovení vybraných kvalitativních ukazatelů mléka (Experimental comparison of indirect methods for determination of selected qualitative milk parameters). In Sborník XLIX. konference o jakosti potravin a potravinových surovin „Ingrový dny 2023“. Brno: Mendelova univerzita 2023, s. 236–248. ISBN 978-80-7509-917-4. <https://doi.org/10.11118/978-80-7509-917-4>.

Naposledy aktualizováno: 14.10.2024

BUMBÁLEK, R., ZOUBEK, T., OTÁHAL, M., **STEHLÍK, R.**, SMUTNÝ, L. (2022). Aplikace strojového vidění ve velkochovu hospodářských zvířat. *Náš chov*, (8)2022, 39-62.

BUMBÁLEK, R., ZOUBEK, T., ŠTINDLOVÁ, L., HAVELKA Z., OLŠAN, P., BARTOŠ, P., KUNEŠ, R., **STEHLÍK, R.**, DOLAN, A. (2023). Comparison of the Performance of Convolutional Neural Networks YOLOV5 and YOLOV8 for Appliacation in Agricultural Technologies. In: *TECHNOFORUM 2023 „New Trends in Machines and Technologies for Biosystems*. SUA, Nitra. ISBN 978-80-552- 2603-3.

Knihy a Brožury

HAVELKA, Z., OLŠAN, P., KUNEŠ, R., **STEHLÍK, R.**, BUMBÁLEK, R., ZOUBEK, T., FILIP, M., ŠÍSTKOVÁ, M., a BARTOŠ, P. (2021). Referenční dokument o nejlepších dostupných technologiích pro intenzivní chovy drůbeže a prasat. České Budějovice: Jihočeská univerzita v Českých Budějovicích, Zemědělská fakulta. ISBN: 978-80-7394-889-4.

Patenty

JIHOČESKÁ UNIVERZITA V ČESKÝCH BUDĚJOVICÍCH; AGROSOFT TÁBOR, S.R.O.. Zařízení pro automatizaci dojení s manuální obsluhou dojících robotů. P. BARTOŠ, R. BUMBÁLEK, M. FILIP, Z. HAVELKA, R. KUNEŠ, A. LANG, P. OLŠAN, L. SMUTNÝ, D. SMUTNÝ, **R. STEHLÍK**, F. ŠPALEK, T. ZOUBEK. Úřad průmyslového vlastnictví, 309824. 27.09.2023.

Užitné vzory

AGROSOFT TÁBOR, S.R.O., TÁBOR, ČESKÁ REPUBLIKA JIHOČESKÁ UNIVERZITA V ČESKÝCH BUDĚJOVICÍCH, ČESKÉ BUDĚJOVICE, ČESKÉ BUDĚJOVICE 2, ČESKÁ REPUBLIKA. Zařízení pro automatizaci dojení s manuální obsluhou dojících strojů. P. BARTOŠ, R. BUMBÁLEK, M. FILIP, Z. HAVELKA, R. KUNEŠ, A. LANG, P. OLŠAN, L. SMUTNÝ, D. SMUTNÝ, **R. STEHLÍK**, F. ŠPALEK, T. ZOUBEK. Úřad patentového vlastnictví, <https://isdv.upv.cz/webapp/!resdb.pta.frm>, 36572. 15.11.2022.

AGROSOFT TÁBOR, S.R.O.; JIHOČESKÁ UNIVERZITA V ČESKÝCH BUDĚJOVICÍCH. Systém pro využití rozboru obrazového záznamu k řízení chovu skotu. P. BARTOŠ, R. BUMBÁLEK, M. FILIP, Z. HAVELKA, R. KUNEŠ, A. LANG, P. OLŠAN, L. SMUTNÝ, D. SMUTNÝ, **R. STEHLÍK**, F. ŠPALEK, T. ZOUBEK. Úřad patentového vlastnictví, 36612. 29.11.2022.

Jihočeská univerzita v Českých Budějovicích. Multifunkční identifikační mikročip. Původci: BARTOŠ P., BUMBÁLEK R., FILIP M., HAVELKA Z., KUNEŠ R., OLŠAN P., **STEHLÍK R.**, SMUTNÝ L., ŠPALEK F., ZOUBEK T. Česká republika. Užitný vzor č. 37059 ze dne 23. 5. 2023.

Jihočeská univerzita v Českých Budějovicích. Systém pro monitorování zdravotního stavu paznehtů dojníc. Původci: BARTOŠ P., BUMBÁLEK R., FILIP M., HAVELKA Z., KUNEŠ R., OLŠAN P., **STEHLÍK R.**, SMUTNÝ L., ŠPALEK F., ZOUBEK T. Česká republika. Užitný vzor č. 37058 ze dne 23. 5. 2023.

Jihočeská univerzita v Českých Budějovicích. Systém pro monitorování zdravotního stavu vemene dojníc. Původci: BARTOŠ P., BUMBÁLEK R., FILIP M., HAVELKA Z., KUNEŠ R., OLŠAN P., **STEHLÍK R.**, SMUTNÝ L., ŠPALEK F., ZOUBEK T. Česká republika. Užitný vzor č. 37057 ze dne 23. 5. 2023.