



ČESKÉ VYSOKÉ UČENÍ TECHNICKÉ V PRAZE

FAKULTA BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

Katedra biomedicínské techniky

Automatické rozpoznávání číselných hodnot z monitoru životních funkcí

Automatic recognition of numeric values from the monitor of vital signs

Diplomová práce

Studijní program: Biomedicínská a klinická technika
Studijní obor: Biomedicínský inženýr

Vedoucí práce: Ing. Petr Kudrna, Ph.D.

Bc. Michaela Soukopová

Kladno 2020



ZADÁNÍ DIPLOMOVÉ PRÁCE

I. OSOBNÍ A STUDIJNÍ ÚDAJE

Příjmení: **Soukopová** Jméno: **Michaela** Osobní číslo: **434136**
Fakulta: **Fakulta biomedicínského inženýrství**
Garantující katedra: **Katedra biomedicínské techniky**
Studijní program: **Biomedicínská a klinická technika**
Studijní obor: **Biomedicínský inženýr**

II. ÚDAJE K DIPLOMOVÉ PRÁCI

Název diplomové práce:

Automatické rozpoznávání číselných hodnot z monitoru životních funkcí

Název diplomové práce anglicky:

Automatic recognition of numerical values from the monitor of vital signs

Pokyny pro vypracování:

Navrhněte a realizujte SW řešení pro automatické rozpoznávání číselných hodnot z monitoru životních funkcí snímaného videokamerou. Realizované řešení musí umožnit nastavení frekvence odečtu hodnot HR a SpO2 z obrazu, ukládání získaných hodnot do obecně čitelného formátu datového souboru a exportovat protokol získaného záznamu. Navržené řešení ověřte za pomoci simulátoru životních funkcí. Vytvořenou aplikaci pak analyzujte min. 3 záznamy stabilizace novorozence na porodním sále.

Seznam doporučené literatury:

- [1] Gonzalez R. C., Woods R., Eddins S., Digital Image Processing Using MATLAB, ed. 2, Gatesmark Publishing, ISBN 9780982085400
- [2] Tricia L. Gomella, Neonatology: management, procedures, on-call problems, diseases and drugs, ed. Sixth Edition, McGraw Hill Professional, 2009, ISBN 78-0-07-154431-3

Jméno a příjmení vedoucí(ho) diplomové práce:

Ing. Petr Kudrna, Ph.D.

Jméno a příjmení konzultanta(ky) diplomové práce:

Datum zadání diplomové práce: **10.02.2020**

Platnost zadání diplomové práce: **19.09.2021**

prof. Ing. Peter Kneppo, DrSc., dr.h.c.
podpis vedoucí(ho) katedry

prof. MUDr. Ivan Dylevský, DrSc.
podpis děkana(ky)

PROHLÁŠENÍ

Prohlašuji, že jsem diplomovou práci s názvem „Automatické rozpoznávání číselných hodnot z monitoru životních funkcí“ vypracovala samostatně a použila k tomu úplný výčet citací použitých pramenů, které uvádím v seznamu přiloženém k diplomové práci.

Nemám závažný důvod proti užití tohoto školního díla ve smyslu § 60 Zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů.

V Kladně dne 21.5.2020

.....

Bc. Michaela Soukopová

PODĚKOVÁNÍ

Ráda bych na tomto místě využila možnosti poděkovat vedoucímu této práce, Ing. Petru Kudrnovi, Ph.D., za ochotu, věcné připomínky a veškerý čas, který mi věnoval. Dále bych chtěla poděkovat mé rodině za veškerou podporu, které se mi dostávalo po celou dobu mého studia.

Práce byla podpořena grantem Studentské grantové soutěže ČVUT v Praze, číslo SGS19/202/OHK4/3T/17 – Zpracování a interpretace dat pro potřeby neonatologie a projektem „Péče o nezralé novorozence“, reg. č. CZ.2.16/3.1.00/21564, spolufinancovaným v rámci Operačního programu Praha – Konkurenceschopnost z Evropského fondu pro regionální rozvoj.



EVROPSKÝ FOND PRO REGIONÁLNÍ ROZVOJ
PRAHA & EU: INVESTUJEME DO VAŠÍ
BUDOUCNOSTI



ABSTRAKT

Automatické rozpoznávání číselných hodnot z monitoru životních funkcí:

Stabilizace a resuscitace novorozenců je odborně i psychicky extrémně náročný proces. Pro úspěšnost stabilizace je klíčové rychle a správně vyhodnotit stav novorozence a tomu přizpůsobit použití příslušných intervencí. Protokoly pro postup vycházejí z mezinárodních protokolů vydávaných Evropskou radou pro resuscitaci (ERC, European Resuscitation Council) a jsou aktualizované každých 5 let. Doporučované postupy jsou však propracovány především pro donošené a lehce nezralé novorozence a v klinické praxi zcela chybí jednotné doporučení pro stabilizaci a resuscitaci extrémně nezralých novorozenců.

Gynekologicko-porodnická klinika Všeobecné fakultní nemocnice v Praze patří mezi zařízení, která poskytují zdravotní péči i pro novorozence s těžkou poporodní adaptací. Jeden z jejich výzkumů se orientuje právě na problematiku stabilizace a resuscitace extrémně nezralých novorozenců na porodním sále. V pravidelných intervalech hodnotí efektivitu současných postupů sestavených především na datech gestačně starších novorozenců a snaží se celý postup optimalizovat pro extrémně nezralé novorozence.

Současný proces získávání dat pro tento výzkum spočívá v procházení video záznamů stabilizace a resuscitace extrémně nezralých novorozenců a ručním vypisování jednotlivých hodnot životních funkcí novorozence v daný čas. Pro lékaře se jedná o zdlouhavý a neefektivní proces, který je ovšem nezbytný pro analýzu postupu a následné využití dat.

V rámci práce byla vytvořena webová aplikace, která umožňuje automatické rozpoznávání číselných hodnot srdeční frekvence HR a saturace krve kyslíkem SpO₂ pomocí konvoluční neuronové sítě z monitoru životních funkcí s možností změny frekvence odečítání těchto číselných hodnot. Aplikace vykresluje hodnoty HR a SpO₂ do grafu v závislosti na čase od porodu. Data je možné stáhnout v obecně čitelném datovém formátu CSV.

Klíčová slova

Monitor životních funkcí, konvoluční neuronová síť, rozpoznání čísel

ABSTRACT

Automatic recognition of numeric values from the monitor of vital signs:

Stabilization and resuscitation of newborns is an extremely professionally and mentally demanding process. It is crucial for its success to quickly and correctly evaluate the condition of the newborn and adapt the use of appropriate interventions. The protocols for the procedure are based on international protocols issued by the European Resuscitation Council (ERC) and are updated every 5 years. However, the recommended procedures are elaborated especially for full term and moderate to late preterm newborns, and in clinical practice there is a complete lack of recommendations for stabilization and resuscitation of extremely immature newborns.

The Department of Obstetrics and Gynecology at the General University Hospital in Prague is one of the facilities that provide health care for newborns with severe postpartum adaptation. One of its research lines focuses on the issue of stabilization and resuscitation of extremely immature newborns in the delivery room. It evaluates the effectiveness of current procedures compiled mainly on the data of older newborns and optimizes the whole procedure for extremely immature newborns.

The current process of collecting data for this research is a long and inefficient. It is based on procedure, which consists of watching video recordings of stabilization and resuscitation of extremely immature newborns and manual writing down values of the newborn's vital functions at a given time. Due to this, a web application was created, which enables automatic recognition of numerical values of heart rate and blood oxygen saturation from the vital signs monitor using a convolutional neural network. The application plots HR and SpO₂ values against the time of delivery. The data can be downloaded in a generally used CSV data format.

Keywords

Vital signs monitor, convolution neural network, number recognition

Obsah

Seznam symbolů a zkratk	9
1 Úvod	10
2 Přehled současného stavu	12
2.1 Neonatologie	12
2.2 Podpora poporodní adaptace a resuscitace novorozence	13
2.2.1 Personální a materiální podmínky resuscitace	14
2.3 Současný postup při stabilizaci a resuscitaci novorozenců	15
2.3.1 Monitorování novorozence po porodu a v průběhu stabilizace.....	17
2.3.2 Skóre podle Apgarové	18
2.3.3 Postup při stabilizaci a resuscitaci extrémně nezralých novorozenců.....	19
2.3.4 Současná doporučení pro stabilizaci a resuscitaci extrémně nezralých novorozenců	20
2.4 Umělé neuronové sítě	20
2.4.1 Rozdělení umělých neuronových sítí	22
2.4.2 Konvoluční neuronové sítě.....	23
2.4.3 Trénování sítě	23
2.4.4 Využití AI v biomedicíně	24
3 Cíle práce	26
4 Metody	27
4.1 Rozbor vstupních dat.....	27
4.2 Analýza požadavků na software.....	28
4.3 Návrh architektury softwaru.....	28
4.4 Vytvoření modelu pro rozpoznávání číslic	29
4.4.1 Implementace a struktura neuronové sítě	30
4.4.2 Předzpracování trénovacích dat.....	31
4.4.3 Trénování sítě	33
4.5 Implementace webové aplikace	36
5 Výsledky	38
5.1 Webová aplikace	38
5.1.1... Ověření funkce aplikace	40

5.2	Vyhodnocení záznamů stabilizace tří novorozenců	43
5.2.1	Záznam 1 (1. novorozenec)	44
5.2.2	Záznam 2 (2. novorozenec)	48
5.2.3	Záznam 3 (3. novorozenec)	52
5.3	Přesnost rozpoznání číselných hodnot	56
6	Diskuse	57
7	Závěr	61
	Seznam použité literatury	62
	Příloha A: Obsah přiloženého CD.....	70

Seznam symbolů a zkratek

Zkratka	Význam
AI	Umělá inteligence (Artificial Intelligence)
ANN	Umělé neuronové sítě (Artificial Neural Networks)
bpm	Údery/minuta (Beats per minute)
CNN	Konvoluční neuronové sítě (Convolution Neural Networks)
CPAP	podpora dechu kontinuálním přetlakem (Continuous Positive Airway Pressure)
CSV	Hodnoty oddělené čárkami (Comma-separated values)
EKG	Elektrokardiografie
ERC	Evropská rada pro resuscitaci (European Resuscitation Council)
FC	Plně propojené vrstvy (Full-connected)
FDA	Úřad pro kontrolu potravin a léčiv (Food and Drug Administration)
GDPR	Obecné nařízení o ochraně osobních údajů (General Data Protection Regulation)
GPK	Gynekologicko porodnická klinika
HR	Srdeční frekvence (Heart Rate)
KNN	Algoritmus k-nejbližších sousedů
KPR	Kardiopulmonární resuscitace
OCR	Optické rozpoznávání znaků
PPV	Ventilace pozitivním tlakem
SpO ₂	Saturace krve kyslíkem
SVM	Metoda podpůrných vektorů
VFN	Všeobecná fakultní nemocnice v Praze
VGG	Visual Geometry Group

1 Úvod

Počet předčasně narozených dětí s nízkou porodní hmotností meziročně stoupá, obzvláště pak počet extrémně nezralých novorozenců s porodní hmotností pod 499 g. V minulosti tyto novorozence nebylo možné zachránit, ale moderní medicína přináší těmto novorozencům šanci na život. U nezralých a extrémně nezralých novorozenců lze očekávat zdravotní komplikace zejména pak problémy s respirací, termoregulací a srdečními vadami. V některých případech dokonce musí dojít k stabilizaci a resuscitaci novorozence. Je to odborně i psychicky extrémně náročný proces, kde je každá sekunda rozhodující. Pro úspěšnost stabilizace je klíčové rychle a správně vyhodnotit stav novorozence a tomu přizpůsobit použití příslušných intervencí. [1, 2, 3]

Pro zefektivnění tohoto procesu byl Evropskou radou pro resuscitaci sestaven protokol doporučených intervencí. Jeho dodržování vede k zvýšení pravděpodobnosti úspěšnosti stabilizace. Doporučované postupy jsou však propracovány především pro donošené a lehce nezralé novorozence a v klinické praxi zcela chybí jednotné doporučení pro stabilizaci a resuscitaci extrémně nezralých novorozenců. Lékaři jsou tedy nuceni získávat zkušenosti a znalosti i z jiných zdrojů a jako široce využívaný učební materiál pro lékaře slouží videozáznamy z již provedených stabilizací. Ty zároveň slouží i jako nástroj pro retrospektivní hodnocení úspěšnosti a účinnosti provedených intervencí, na jejichž základě jsou optimalizovány standardy pro stabilizaci a resuscitaci novorozenců, zpětnou vazbu a výzkum. Tak je tomu i na Gynekologicko-porodnické klinice Všeobecné fakultní nemocnice (GPK VFN) v Praze, kde celý proces stabilizace a resuscitace probíhá na resuscitačním lůžku snímaném dvěma kamerami. První kamera nahrává plochu lůžka a prováděné intervence. Druhá kamera snímá přístroje na panelu resuscitačního lůžka a umožňuje tak odečítat hodnoty životních funkcí novorozence. [3-7]

GPK VFN v Praze patří mezi perinatologická centra intenzivní péče, tedy zařízení, která poskytují zdravotní péči i pro novorozence s těžkou poporodní adaptací. Zdejší lékaři se kromě klinické praxe zabývají i výzkumnou prací. Jeden z výzkumů podporovaný GPK se orientuje na problematiku stabilizace a resuscitace extrémně nezralých novorozenců na porodním sále. V pravidelných intervalech hodnotí efektivitu současných postupů sestavených především na datech gestačně starších novorozenců a snaží se celý postup optimalizovat pro extrémně nezralé novorozence.

Současný proces získávání dat pro tento výzkum spočívá v procházení video záznamů stabilizace a resuscitace extrémně nezralých novorozenců a ručním vypisování jednotlivých hodnot životních funkcí novorozence v daný čas. Pro lékaře se jedná o zdoluhavý a neefektivní proces, který je ovšem nezbytný pro analýzu postupu a následné využití dat. [3] Z tohoto důvodu vznikl na GPK VFN v Praze podnět

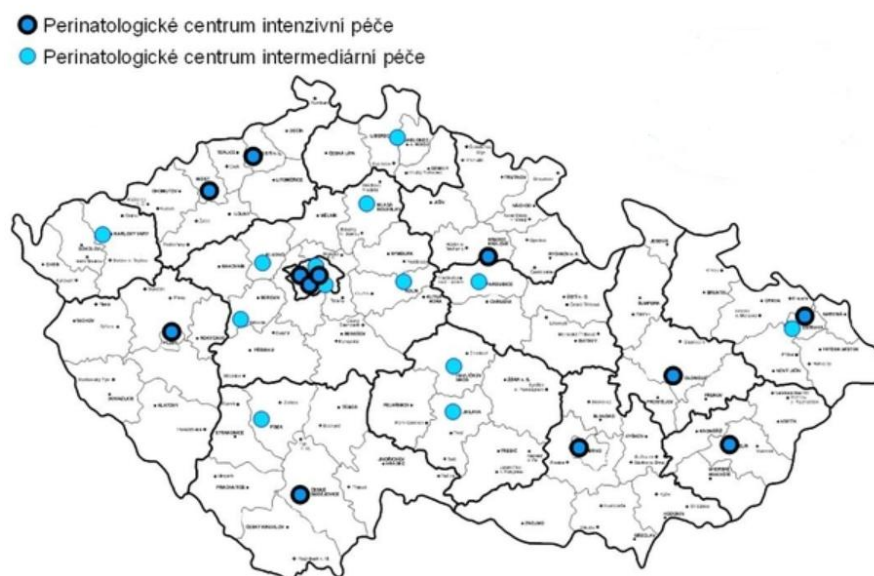
k optimalizaci a vytvoření nástroje, který by tuto činnost usnadnil a data z již hotových videozáznamů automaticky rozpoznal a převedl do přehlednější podoby pro další vyhodnocení. Tedy aby vznikl grafický výstup jednotlivých parametrů životních funkcí v závislosti na čase, ze kterého by lékaři mohli proces stabilizace analyzovat.

2 Přehled současného stavu

2.1 Neonatologie

Neonatologie je obor zabývající se péčí o fyziologické i patologické novorozence. Je součástí perinatologické péče, která zajišťuje návaznost péče pro těhotné ženy, plod a novorozence. [2]

V současné době je v České republice neonatologická a perinatologická péče členěná do tří stupňů podle zdravotního stavu novorozenců. Fyziologicky se vyvíjející plod a poporodní stav bez komplikací spadá do prvního stupně. Druhý stupeň zajišťují perinatologická centra intermediální péče, kam spadá péče o novorozence se středně těžkou adaptací a o středně nezralé novorozence (od 32. gestačního týdne), kteří nevyžadují intenzivní péči. Novorozence s těžkou adaptací pak ošetřují samostatná specializovaná neonatologická pracoviště, označovaná jako perinatologická centra intenzivní péče, kterých je v České republice 12 (viz obrázek 2.1). Mezi ně patří i Gynekologicko-porodnická klinika v Praze. [8, 9]



Obrázek 2.1: Perinatologická centra intenzivní péče a perinatologická centra intermediální péče v České republice [9]

Pojmem fyziologický novorozenec je označován novorozenec o výšce přibližně 50 cm, váhy 2500-4800 g s růžovou kůží krytou mázkem, jemnými vlasy, nehty překrývajícími konce prstů, rýhovanými ploškami nohou, vyvinutými ušními boltci a zralým genitálem. [10]

Podle doby narození můžeme novorozence rozdělovat na: [11]

- nedonošené (narozené před 36. týdnem),
- donošené (narozené mezi 37. – 41. týdnem),
- přenášené (narozené po 42. týdnu).

Nedonošené novorozence pak můžeme rozdělit podle zralosti na: [11]

- extrémně nezralé (pod 28. týden těhotenství),
- těžce nezralé (28. – 31. týden těhotenství),
- středně nezralé (32. – 35. týden těhotenství),
- lehce nezralé (36. – 37. týden těhotenství).

Důležitým faktorem pro klasifikaci novorozenců je i porodní váha. Dle ní rozdělujeme novorozence: [12]

- s velkou porodní hmotností (nad 4500 g),
- s normální porodní hmotností (2500 – 4500 g),
- s nízkou porodní hmotností (1500 – 2500 g),
- s velmi nízkou porodní hmotností (1000 – 1500 g),
- s extrémně nízkou porodní hmotností (pod 1000 g).

Porodní hmotnost, zralost plodu a doba narození hrají důležitou roli při přípravě lékařů na porod a volbě postupů. Příčiny předčasného porodu mohou být různé, mezi nejčastější patří záněty placenty. Vliv na předčasný porod může mít také vyšší věk matky, vícečetné těhotenství, asistovaná reprodukce, nebo kouření [3, 13, 14].

U nezralých a extrémně nezralých novorozenců s nízkou porodní váhou lze očekávat komplikace při adaptaci na extrauterinní podmínky. V extrémních případech pak musí dojít k stabilizaci a resuscitaci novorozence. [3]

2.2 Podpora poporodní adaptace a resuscitace novorozence

Porucha poporodní adaptace novorozence se vyskytuje přibližně u 5–10 % novorozenců, zejména u novorozenců s porodní hmotností nižší než 2500 g. Ve většině případů se jedná pouze o nutnost dechové podpory a jen velmi zřídka je vyžadována i nepřímá srdeční masáž. U novorozenců s porodní váhou nad 2500 g je resuscitace nutná pouze v 1 % případů. Na rozdíl od dospělých je u novorozenců úspěšnost KPR (kardiopulmonální resuscitace) více než 90 %. [3, 10, 15]

Stabilizace a resuscitace novorozenců probíhá dle protokolů příslušného zdravotnického zařízení. Ty vycházejí z mezinárodních protokolů vydávaných Evropskou radou pro resuscitaci (ERC, European Resuscitation Council) a jsou aktualizované každých 5 let. Jejich cílem je zajistit základní životní funkce novorozence při přechodu z intrauterinního prostředí do extrauterinního. Protokoly jsou vypracovány zejména pro novorozence, u kterých se předpokládá zralost dýchacích cest. Úspěšnost

stabilizace a resuscitace je podmíněna schopností a organizovaností týmu rychle a správně posoudit stav novorozence a přizpůsobit mu veškeré použité intervence a jejich míru. [3, 6]

2.2.1 Personální a materiální podmínky resuscitace

Pro každý porod je nutné zajistit vhodné personální i materiální podmínky. Požadavky se odvíjí od předpokládaného průběhu porodu, nicméně i tak by u každého porodu měla být přítomna osoba, která je schopna zahájit resuscitaci novorozence. Pokud existuje riziko poruchy poporodní adaptace, pak by porodu vždy měla být přítomná alespoň jedna osoba kompletně proškolená v resuscitaci novorozence. V klinické praxi to na porodních sálech většinou probíhá tak, že je k porodu, který porodní asistentka nebo lékař gynekolog vyhodnotí jako rizikový, přivolán i lékař pediatr či neonatolog, který má s resuscitací novorozenců zkušenost. U porodu těžce kompromitovaných novorozenců s předpokládaným těžkým průběhem adaptace a možnou nutností resuscitace se doporučuje přítomnost tří kompletně proškolených osob. První osoba zajišťuje intubaci, druhá monitoring, popřípadě nepřímou srdeční masáž, a třetí osoba farmakoterapii. U vícečetných porodů je nutná přítomnost oddělených týmů pro zajištění péče pro každého novorozence. [3, 6, 15]

Materiální požadavky vychází z vyhlášky č. 92/2012 Sb., o požadavcích na minimální technické a věcné vybavení zdravotnických zařízení a kontaktních pracovišť domácí péče. Ta ovšem blíže nespecifikuje přesné vybavení pro stabilizaci novorozence na porodním sále. Při té je zejména důležité vyhřívané resuscitační lůžko (viz obrázek 2.2), které by mělo být doplněno potřebnou zdravotnickou technikou pro monitoring srdeční činnosti a SpO_2 , resuscitačním přístrojem, zvlhčovačem a ohřivačem plynů a odsávačkou. Součástí vybavení resuscitačního lůžka jsou i Apgar stopky, které jsou spuštěny po porodu a slouží pro lepší orientaci personálu v čase a pro pravidelné hodnocení stavu novorozence. K dispozici musí být i lékárna a spotřební materiál jako jsou katetry, obličejové masky, endotracheální kanyly, laryngální masky, hrudní drény, termo-folie, svorky atd. [3, 6, 10, 15]



Obrázek 2.2: Resuscitační lůžko LN 91 (Alfamedic, Česká republika) používané ve VFN

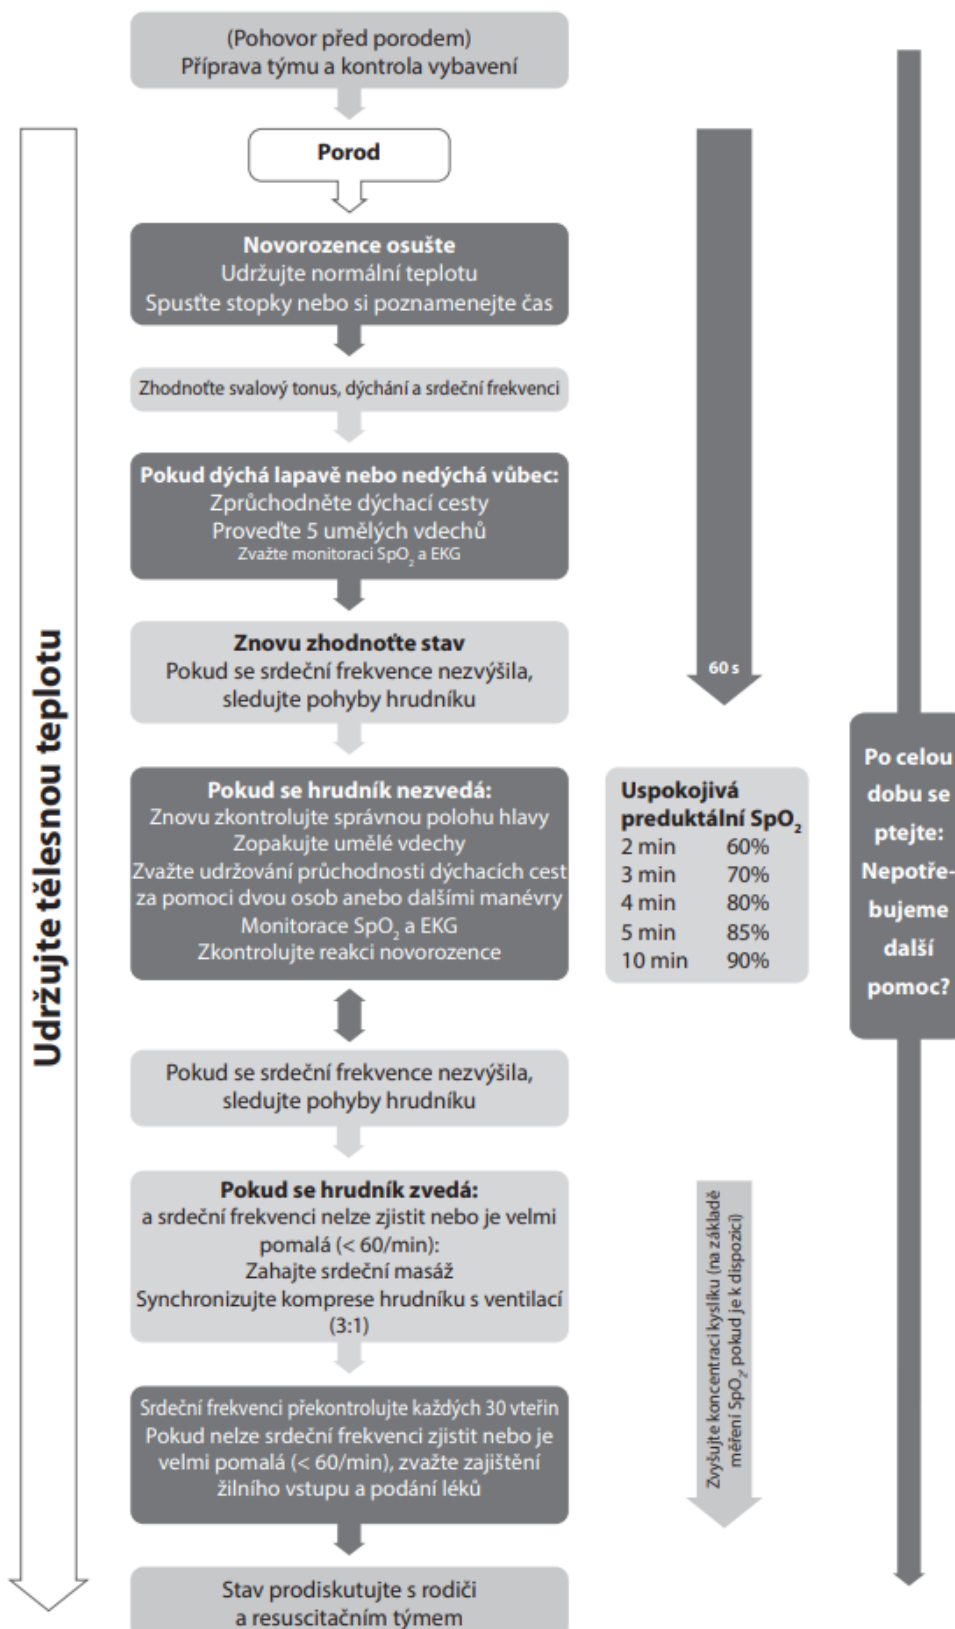
Stabilizace má být prováděna v dostatečně teplé místnosti, kde by teplota prostředí neměla klesnout pod 26 °C. K dispozici musí být zdroj medicínálních plynů a místnost musí být vhodně uspořádána pro možnost pohybu celého resuscitačního týmu. [3, 6, 15]

2.3 Současný postup při stabilizaci a resuscitaci novorozenců

V roce 2015 vydala Evropská resuscitační rada doporučený postup pro resuscitaci novorozenců, viz obrázek 2.3. Tento postup je pouze doporučen. Konkrétní úkony se na různých pracovištích drobně liší podle místních zvyklostí. [6]

Lékař se při hodnocení stavu dítěte řídí zejména podle srdeční frekvence, dechové aktivity a svalového tonu dítěte. Adekvátně ventilující novorozenec pláče, pravidelně zvedá hrudník a mění barvu z modré na světle růžovou. Srdeční frekvenci lékař nejčastěji hodnotí pomocí fonendoskopu, pulzního oxymetru nebo elektrokardiografie (EKG). Použití jednotlivých přístrojů se liší podle zvyklostí konkrétního pracoviště. Zkušený lékař i sestra jsou schopni rozpoznat patologického novorozence během několika málo sekund. [3, 6, 10, 15]

Pokud novorozenec vyžaduje jakoukoliv podporu, je přemístěn od matky na vyhřívané lůžko pod zdroj tepla a osušen rouškou, čímž je i taktilně stimulován. To může příznivě ovlivnit nástup dýchání. Mezitím lékař vyhodnocuje stav dítěte a zahajuje potřebné úkony ke stabilizaci stavu novorozence. Pokud taktilní stimulace během krátké chvíle nevede k nástupu dostatečného dýchání, zahájí lékař ventilační podporu a dále zpravidla postupuje dle algoritmu vydaného Evropskou radou pro resuscitaci, viz obrázek 2.3. [16]



Obrázek 2.3: Schéma doporučeného postupu při stabilizaci a resuscitaci novorozence (SpO₂ – saturace krve kyslíkem, EKG – elektrokardiografie, PPV – ventilace pozitivním tlakem) [16]

2.3.1 Monitorování novorozence po porodu a v průběhu stabilizace

Pro objektivní monitorování novorozence při stabilizaci a během KPR se podle platných doporučení využívá pulzní oxymetr. Pulzní oxymetrie je neinvazivní metoda, která poskytuje informaci o transportu kyslíku do tkání. Při stabilizaci a resuscitaci novorozenců se využívá hlavně ke zjištění srdeční frekvence (HR, Heart rate) a monitorování saturace krve kyslíkem (SpO₂). [18, 19]

Srdeční frekvence poskytuje informaci o šíření krve tělem a je základním pilířem pro volbu postupu při stabilizaci a resuscitaci novorozence. Odborné publikace uvádí fyziologické hodnoty novorozenců v rozmezí 120-140 bpm (úderů/minutu). O fyziologických hodnotách srdeční frekvence novorozence v prvních minutách po porodu existuje omezené množství informací. Na toto téma proběhla studie, která zahrnovala 465 novorozenců a monitorovala jejich pulz v prvních 10 minutách po porodu. Výsledky této studie jsou v tabulce 2.1. Studie také prokázala, že u předčasně narozených dětí stoupal pulz pomaleji než u novorozenců narozených v termínu. [3, 6, 20, 21, 22]


Tabulka 2.1: Hodnoty BPM novorozenců v prvních 10 minutách po porodu [22]

Čas po porodu (min)	HR (bpm)
1	96 (65–127)
1,5	123 (91–153)
2	139 (110–166)
3	157 (136–176)
4	162 (145–178)
5	163 (146–178)
6	162 (146–175)
7	162 (146–174)
8	159 (145–172)
9	157 (144–170)
10	157 (144–170)

V případě tepové frekvence pod 60 bpm zahájí lékař nepřímou srdeční masáž v doporučeném poměru dechů a stlačování hrudníku. Pokud je tepová frekvence pod 100 tepů/minutu, bývá ventilační podpora dostatečná k tomu, aby sama pomohla postupně zvýšit tep dítěte nad 100 bpm. [16]

Sekundárně monitorovaným parametrem je SpO₂. Hodnotu kyslíkové saturace je možné získat jako procentuální poměr koncentrace oxyhemoglobinu vůči celkové sumě koncentrací redukovaného hemoglobinu, oxyhemoglobinu, karboxyhemoglobinu a methemoglobinu. [23]

Cílové hodnoty saturace krve kyslíkem po porodu jsou uvedeny na obrázku 2.4.



Obrázek 2.4: 3., 10., 25., 50., 75., 90. a 97. Percentil SpO₂ novorozenců po porodu [23]

Předpokládaná odezva pulzního oxymetru je 30 sekund po umístění čidla, ale některé publikované studie upozorňují, že to může být i skoro minutu a hodnoty naměřené zejména v prvních minutách života bývají nepřesné. Mohou mít tedy negativní dopad na průběh a úspěšnost stabilizace. Tyto studie zároveň doporučují využití EKG, který poskytuje hodnoty srdeční frekvence rychleji a přesněji než pulzní oxymetr. [24–27]

2.3.2 Skóre podle Apgarové

Hodnocení dle Apgarové spočívá v zhodnocení vzhledu a barvy novorozence, dýchání, srdeční akce, reakce na podráždění a svalového tonu v 1., 5., a 10. minutě po narození. Dle hodnotících kritérií uvedených v tabulce 2.2 se v příslušných časech ohodnotí stav novorozence odpovídajícím počtem bodů a ty jsou sečteny. Jako celkový výsledek se pak uvádí hodnoty ve všech časech (např. 3–5–10). Tato tři čísla potom odráží stav novorozence po porodu a jeho přizpůsobení se extrauterinním podmínkám. [3, 15, 17]

Tabulka 2.2: Hodnocení adaptace novorozence podle Apgarové [15]

Kritéria hodnocení	0	1	2
Dechová aktivita	žádná	nízká	vydatná
Akce srdeční	nepřítomná	<100/min	>100/min
Barva	generalizovaná cyanóza	akrocyanóza	růžová, včetně končetin
Reakce na podráždění	žádná	pomalá	okamžitá
Tonus	atonie	hypotonie	normotonie

Pro rozpoznání situace, kdy je nutno zahájit KPR nebo jiný úkon k podpoře životní funkce, se skóre dle Apgarové v klinické praxi nehodí a lékaři se přímo podle něj neřídí. Jeho přínos spočívá hlavně v možnosti si velmi rychle zpětně udělat představu o tom, jak probíhala adaptace konkrétního jedince. Jak je patrné z obrázku 2.1 se v praxi doporučuje řídit podle svalového tonu, dýchání a srdeční frekvence novorozence. Výhodou skóre dle Apgarové je jeho jednoduchost a rychlost, někdy mu ale bývá vyčítána vysoká subjektivita při posuzování novorozence. [3, 15, 17]

2.3.3 Postup při stabilizaci a resuscitaci extrémně nezralých novorozenců

U extrémně nezralých novorozenců je postup mírně odlišný. Porodu by měl být přítomen neonatolog, který bezprostředně po narození dítěte stanoví, jaký bude další postup. Dle stupně nezralosti lze orientačně hodnotit, zda bude novorozenec sám schopen dýchat, nebo bude nutné zajistit ventilační podporu. U extrémně nezralých novorozenců, kdy není ještě zcela vyvinut dýchací systém, se záhy po porodu projevuje těžká dechová nedostatečnost. Proto je nutné dopředu počítat s nutností intubace, aplikace surfaktantu a umělou plicní ventilací.

Nezralí novorozenci se neosuší, ale jsou zabaleni do průsvitné polyetylenové folie, nebo do dvouvrstvého polyetylenového sáčku. Od roku 2011 se u všech nezralých novorozenců v GPK provádí placentární transfuze expresí pupečnicku, tzv. milking. Ten má stejný účinek jako oddálený podvaz pupečnicku, tedy má za cíl zvýšit krevní tlak novorozence. Během toho je zároveň možné novorozence taktálně stimulovat k dýchání. Poté je novorozenec přenesen na vyhřívané lůžko, kde je napojen na monitoraci pulzním oxymetrem. Čidlo pulzního oxymetru bývá zpravidla umístěno na zápěstí horní končetiny. [3, 4, 10]

Jak již bylo zmíněno hodnoty získané pulzním oxymetrem nelze okamžitě po umístění čidla považovat za validní. To má samozřejmě negativní dopad na plynulost průběhu stabilizace a zpomaluje to rozhodovací proces. Proto je v prvních minutách stabilizace získávána kontrolní hodnota srdeční frekvence auskultačně nebo pomocí EKG. Pokud je nutné novorozence ventilovat, používá se standardně nejdříve podpora dechu kontinuálním přetlakem (CPAP, Continuous Positive Airway Pressure). V případě apnoe nebo nedostatečné spontánní dechové aktivity, je zahájena intubace novorozence. Pokud by nebyla zajištěna adekvátní ventilace, nebylo by možné novorozence stabilizovat a jeho tep by klesal, až by nastala asystolie. Po provedení iničiálních vdechů aplikuje lékař surfaktant a dále ventiluje pacienta. Tato opatření by měla vést k růstu tepové frekvence nad 100 bpm. Při těžké bradykardii (HR < 60 bpm) je pak zahájena nepřímá srdeční masáž a aplikována farmaka k podpoře oběhu. [3, 4, 10]

Stabilizovaní novorozenci jsou pak převezeni na jednotku intenzivní péče. U novorozenců bez spontánní dechové frekvence je nutné pokračovat ve ventilaci. [3]

2.3.4 Současná doporučení pro stabilizaci a resuscitaci extrémně nezralých novorozenců

Stávající doporučení z roku 2015 jsou dobře propracována pro dospělé pacienty, donošené a lehce nezralé novorozence. Postup při stabilizaci a resuscitaci extrémně nedonošených novorozenců je v literatuře zmiňován jen velmi zřídka nebo je formulován nejasně. Obecně je zejména zdůrazňována důležitost centralizace a poskytování péče ve specializovaných perinatologických centrech s odpovídajícími zkušenostmi, vybavením a kvalitním resuscitačním týmem. [4, 28, 29]

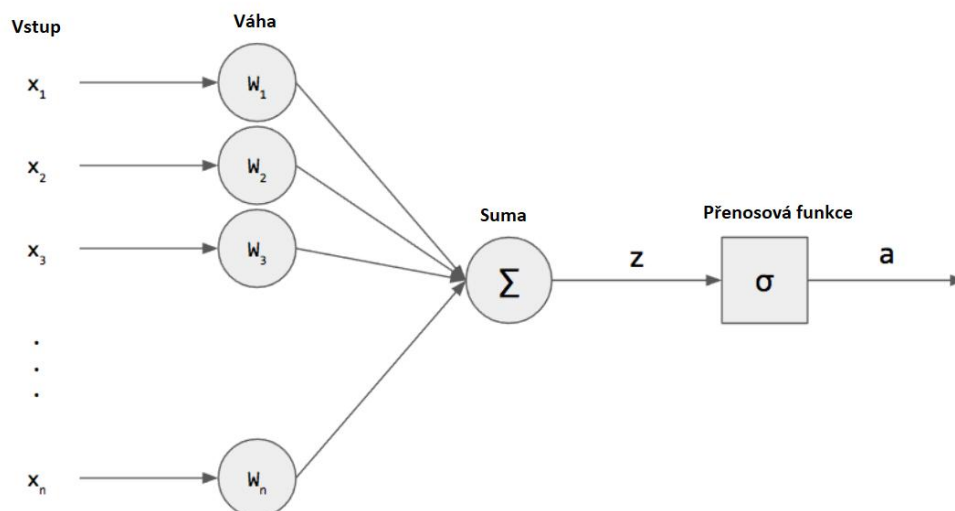
Efektivita současných doporučení je závislá na stáří novorozence a s nižším gestačním týdnem klesá. Pro některé extrémně nezralé novorozence, kteří mají omezenou schopnost provzdušnění plic, může mít použití doporučených postupů dokonce negativní efekt. Podklady pro použití a účinnost konkrétních intervencí při stabilizaci a resuscitaci extrémně nezralých novorozenců jsou založeny na odborném konsensu, datech z animálních studií a na datech ze studií gestačně starších nezralých novorozenců. [3]

Nedílnou součástí zlepšování péče a prognózy extrémně nezralých novorozenců je hledání a studium nových postupů. Touto tematikou se zabývá i výzkum probíhající na GPK VFN v Praze. Na jeho základě byla doložena velká různorodost reakcí extrémně nezralých novorozenců na prováděné intervence. Z toho vyplynula potřeba individuálního přístupu pro jednotlivé podskupiny extrémně nezralých novorozenců rozdělených podle gestačního stáří. Tento výzkum probíhá observační metodou, kdy jsou data získávána procházením videozáznamů a odečítáním hodnot vitálních funkcí.

2.4 Umělé neuronové sítě

Umělé neuronové sítě (ANN, Artificial Neural Network) jsou jedním z nástrojů umělé inteligence (AI, Artificial Intelligence). Na základě inspirace neurofyzilogickými poznatky o struktuře a činnosti neuronů a nervových systémů živých organismů byly vytvořeny výpočetní modely, které umožňují řešit i úlohy, které nelze, nebo jen velmi obtížně, přesně popsat matematickými vztahy. [30, 31, 32]

Stejně jako biologické neuronové sítě jsou umělé neuronové sítě tvořeny funkčními a stavebními jednotkami. V případě umělých neuronových sítí se nazývají funkční neurony, nebo perceptrony. Ty mají podobně jako biologické neurony za úkol předávat, zpracovávat a uchovávat informace. Jejich stavba je na obrázku 2.4. [30, 31]



Obrázek 2.4: Stavba perceptronu [33]

Do perceptronu vede jeden až n vstupů x . Vstupy bývají převážně ve formě reálných čísel. V závislosti na konkrétní poloze perceptronu v neuronové síti je možné rozdělit vstupy do dvou skupin. Na perceptrony, které zpracovávají výstupy z jiných, předcházejících (presynaptických) neuronů, a na vstupy s přímými podněty z vnějšího okolí. Každý vstup neuronu má přidělenou synaptickou váhu w_n . Ta je obvykle vyjádřena reálným číslem, jehož hodnota vypovídá o průchodnosti a o důležitosti daného spojení. Optimalizace hodnot jednotlivých vah je součástí procesu učících algoritmů neuronové sítě. Cílem je získání optimálních hodnot vah, které umožní dosáhnout shody mezi reálnými výstupy zkoumaného procesu a výstupy predikovanými neuronovou sítí. [32, 33]

Celkový potenciál neuronu je pak udáván právě váženým součtem vstupů. Ten je porovnán s prahovou hodnotou perceptronu a při jejím překročení perceptron indikuje signál na svém jediném výstupu. Prahová hodnota tedy rozhoduje o aktivitě daného perceptronu. Jako aktivační funkce neuronu je nejčastěji využíván jednotkový skok, signum nebo lineární funkce.


Výstup perceptronu lze popsat funkcí:

$$Y = S \left(\sum_{n=1}^n (x_n w_n) + \theta \right) \quad (2.1)$$

Kde x_n je vstup, w_n jeho váha, θ je prahová hodnota, S přenosová funkce a y výstup neuronu. [34, 35]

2.4.1 Rozdělení umělých neuronových sítí

Propojením jednotlivých perceptronů vznikají umělé neuronové sítě. V současné době se nejvíce používají sítě s dopředným šířením signálu (feedforward), kde výstupy z jedné vrstvy jsou vedeny na vstup následující vrstvy a výstup z poslední vrstvy je výstupem celé sítě. První vrstva je nazývána vstupní a poslední výstupní. Mezi nimi mohou být vrstvy tzv. skryté (viz obrázek 2.2). Při dopředném šíření signálu jsou nejprve excitovány neurony vstupní vrstvy. Tato excitace je vazbami vedena na následující vrstvu a zároveň je hodnota excitace snížena, zvýšena, nebo zachována pomocí odpovídající synaptické váhy. Každý neuron následující vrstvy nejprve provede sumaci signálů obdržných z předchozí vrstvy a je opět excitován. Takto se signál šíří neuronovou sítí až k výstupní vrstvě. [36, 37]



Obrázek 2.5: Struktura vícevrstvé neuronové sítě [38]

Neuronové sítě se podle způsobu učení, tedy procesu, kdy jsou vstřebávány a ukládány informace do synaptických vah, dělí na sítě s učitelem a bez učitele.

V případě ANN s učitelem je adaptačnímu algoritmu poskytována správná informace o výstupu. Neuronové sítě jsou předložena vstupní data a odpovídající korektní výstupní data. Na základě aktuálního nastavení vah je vypočítána odezva, která je porovnána se správným výstupem a je stanovena chyba sítě. K tomu se využívá tzv. chybové funkce. Dalším krokem je úprava synaptických vah tak, aby došlo k minimalizaci výsledné chyby.


Naopak v případě ANN bez učitele systém nezískává žádné kritérium o správném výstupu, ale odvozuje si ho od svého výstupu pomocí zpětné vazby. Síť tedy pracuje na principu shlukování a samostatně vyhledává společné vlastnosti vstupních dat, na jejichž základě data klasifikuje. Počet hledaných skupin může, ale nemusí být na začátku určen. Synaptické váhy se v tomto případě nastavují tak, aby síť poskytovala podobnou odpověď na vstupy s podobnými příznaky. [39]

2.4.2 Konvoluční neuronové sítě

Konvoluční neuronové sítě (CNN, Convolution Neural Networks) patří mezi vícevrstvé dopředné neuronové sítě. Topologie těchto sítí je inspirována vizuálním kortexem. Konvoluční sítě obsahují několik druhů vrstev, z nichž každá má svou specifickou funkci. Každá konvoluční vrstva sítě má za cíl vytvořit tzv. příznakovou mapu. Obsahuje sadu filtrů, většinou o velikosti 3×3 nebo 5×5 pixelů se třemi barevnými kanály. Tyto filtry jsou aplikovány na každý obrazový bod, čímž dochází k extrakci příznaků z obrázku. Příznakem mohou být oblasti specifické barvy nebo hrany. Použitím více konvolučních vrstev získávají příznaky jasnější charakter. Každá konvoluční vrstva je charakterizovaná dvěma parametry. Prvním parametrem je hloubka, ta udává počet filtrů konvoluční vrstvy. Druhým je krok konvoluce, který specifikuje, o kolik bodů se konvoluční filtr posune. Vliv na výsledek má i tzv. „Zero padding“, kdy se vstupní obrázek rozšiřuje o nulové prvky tak, aby bylo možné aplikovat filtr i na okrajové body obrázku. [30, 40, 41, 42]

Dalšími typy vrstev jsou jednak tzv. pooling vrstvy, které slouží k redukci dimenze, snížení počtu parametrů sítě a výpočetní náročnosti, a dále plně propojené vrstvy (FC, full-connected), ve kterých jsou propojeny všechny neurony vrstvy se všemi neurony vrstvy následující. [40, 42]

Využitím optimálního počtu a kombinace vrstev je pak možné rozpoznat i objekty po deformaci, změně polohy a velikosti. [40, 42]



Obrázek 2.6: Schéma konvoluční neuronové sítě [42]

2.4.3 Trénování sítě

Proces trénování sítě je závislý na dostupnosti vstupních dat. Je tedy nutné, aby byla k dispozici data, která pokud možno rovnoměrně reprezentují požadované výstupy sítě. Pokud je signifikantně více vstupních dat pro jednu určitou kategorii, je možné, že výsledky vyhodnocení takto trénovanou sítí pak budou vykazovat vyšší chybovost. V takovém případě je nutné přidělit váhu jednotlivých kategoriím, aby žádná nebyla zvýhodněna. Kategorie s nejnižším počtem trénovacích dat bude mít tedy nejvyšší

přidělenou váhu a naopak kategorie s nejvyšším počtem dat bude mít váhu přiměřeně nižší. [39, 43]

Dostupná data je v prvním kroku nutné rozdělit do dvou kategorií, a to na data trénovací a testovací. Poměr počtu prvků v trénovací a testovací množině není pevně dán, je závislý na konkrétní úloze, nicméně obecně lze říci, že trénovací množina obvykle představuje 70-80 % dat a testovací množina tedy 20-30 %. V některých případech je nutné oddělit ze vstupních dat ještě třetí kategorii, a to data validační. Na rozdíl od testovací množiny se validační množina používá pouze při ukončení procesu učení. [39, 43, 44]

Vlastní proces trénování spočívá v předkládání dat z trénovací množiny síti a zjišťování její odezvy. Podle odchylky reálného výstupu od požadovaného výstupu je provedena korekce synaptických vah. Trénování sítě probíhá v tzv. epochách, kdy jedna epocha představuje jeden cyklus, ve kterém jsou síti předloženy všechny vzory z trénovací množiny. V procesu učení většinou musí proběhnout desítky až tisíce epoch. [45]

Proces trénování je možné ukončit několika způsoby, a to dosažením požadované chybovosti sítě, nebo její neměnnosti, nebo dosažením maximálního počtu epoch stanoveného na začátku procesu. Naučená síť je poté otestována pomocí testovací množiny a je vyhodnocena její výkonnost, a to většinou pomocí výpočtu chybové funkce, kterou nejčastěji bývá střední čtvercová chyba. [39, 43, 44]

Při volbě modelu je zároveň nutné zohlednit jeho velikost a náročnost dat. Pokud je počet neuronů příliš velký, je možné, že dojde k tzv. přeučení. To znamená, že se síť velmi přesně naučí data z tréninkové množiny, ale zároveň začne ztrácet schopnost generalizace. [45]

Naprostá většina NN je dnes učena metodou backpropagation. Tato metoda dovoluje počítat změnu chyby ve vnitřních vrstvách sítě pomocí derivace součinu (chain rule), tedy umožňuje spočítat parciální derivaci chyby na jeden konkrétní parametr sítě. Celý proces probíhá ve směru největšího gradientu, tedy směrem, který přináší největší snížení chyby a snaží se konvergovat k optimu. [36]

2.4.4 Využití AI v biomedicíně

V biomedicíně představuje využití algoritmů umělé inteligence veliký potenciál, ať už se jedná o analýzu dat nebo aplikaci počítačového vidění. Díky aplikacím poháněným umělou inteligencí, které vznikly na základě učení se z reálných případů, je možné diagnostikovat i vzácná onemocnění, se kterými se lékař běžně nesetkává a jejich diagnostika je v běžné klinické praxi velmi obtížná. [46]

Mezi architekturami ANN vyvinutých přímo pro medicínu převládají hlavně konvoluční neuronové sítě. Nejčastějším využitím těchto konvolučních sítí je

segmentace obrazu, tedy detekce jednotlivých struktur, nebo částí obrazu s podobnými vlastnostmi. Ta je v současnosti využívána už v mnoha oborech jako je např. radiologie, kde tyto aplikace pomáhají lékařům při detekci a klasifikaci zlomenin kostí, nádorů a stavů měkkých tkání, nebo v kardiologii, kde se algoritmů umělé inteligence využívá například k vizualizaci koronární tepny a průtoku krve, nebo automatické detekci patologie v srdci analýzou strukturálních a funkčních aspektů srdce. Pomocí umělé inteligence je možné také simulovat vzdělávací prostředí pro intervenční kardiology prostřednictvím virtuální reality. Dále se využívají v embryologii nebo v dermatologii, kde napomáhají prevenci kožních chorob a včasnému odhalení kožních onemocnění. [47-49]

Aktuálnost a široké využití ANN v biomedicíně dokazují studie z posledních let, které se zabývají například aplikací ANN pro diagnostiku hypoglykemických epizod, glaukomů, rakoviny prsu, nebo i viru hepatitidy. Kromě nástroje pro analýzu dat je možné ANN využít i pro jejich zisk k výzkumným účelům. [50-53]

Přestože technologie umělé inteligence v lékařském výzkumu přitahují značnou pozornost, je mnohdy jejich implementace do běžné praxe komplikovaná. Velkou překážkou je v tomto případě i legislativa, kdy stávající předpisy postrádají standardy pro hodnocení bezpečnosti a účinnosti systémů AI. Aby tyto systémy fungovaly dobře, musí být trénovány daty z klinických studií, nebo lékařské praxe. A aby byla udržována jejich aktuálnost a možné průběžné zdokonalování je klíčové, aby měly k těmto datům přístup, což může být problematické vzhledem k citlivosti klinických dat, kdy je nutné vyloučit jejich zneužití. [54]

Jedna z mála již fungujících platforem, která byla schválena Úřadem pro kontrolu potravin a léčiv (FDA, Food and Drug Administration), je platforma vyvinutá univerzitou Stanford Arterys, která slouží k diagnostice srdečních chorob. [54, 55]

3 Cíle práce

Doporučované postupy pro stabilizaci a resuscitaci extrémně nezralých novorozenců jsou propracovány především pro donošené a lehce nezralé novorozence. V klinické praxi tak zcela chybí jednotné doporučení pro stabilizaci a resuscitaci extrémně nezralých novorozenců na porodním sále. Jeden z výzkumů na Gynekologicko-porodnické klinice Všeobecné fakultní nemocnice v Praze se orientuje právě na tuto problematiku. Nicméně současný proces získávání dat pro tento výzkum je zdlouhavý a neefektivní. Spočívá v procházení video záznamů stabilizace a resuscitace extrémně nezralých novorozenců a ručním vypisování jednotlivých hodnot životních funkcí novorozence v daný čas.

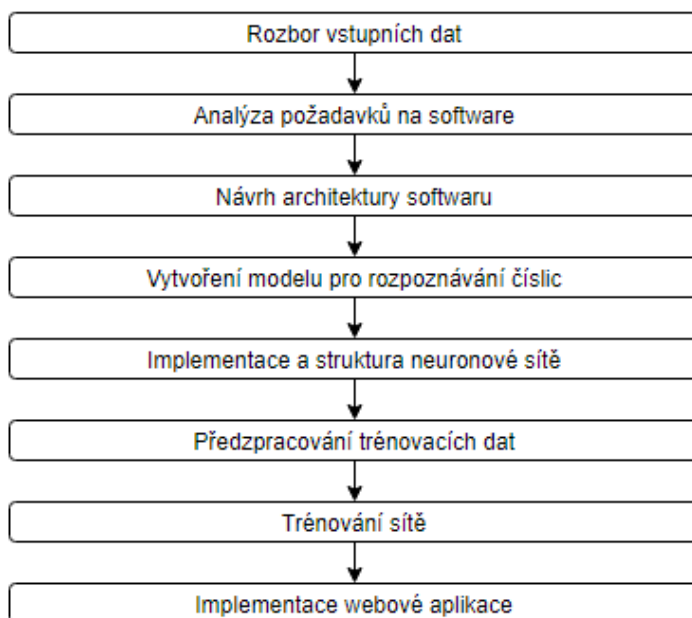
Cílem práce je zefektivnit proces získávání patientských dat z videozáznamu procesu stabilizace a resuscitace novorozence na porodním sále a tato data vhodně zpracovat pro následné využití.

Dílčí cíle:

1. Vytvořit softwarový nástroj, který umožní automatické rozpoznávání číselných hodnot HR a SpO₂ z monitoru životních funkcí, který je při procesu stabilizace novorozence snímán videokamerou.
2. Vhodně zpracovat získaná data pro jejich následnou analýzu lékaři.
3. Ověřit funkci navrženého řešení za pomoci simulátoru životních funkcí.
4. Vyhodnotit tři záznamy stabilizace novorozence na porodním sále.

4 Metody

V této kapitole budou popsány metody a postupy použité při řešení této práce. Při řešení bylo postupováno podle schématu na obrázku 4.1.



Obrázek 4.1: Schéma postupu řešení práce

4.1 Rozbor vstupních dat

Videozáznamy ze stabilizací a resuscitací novorozenců byly v anonymní podobě poskytnuty GPK VFN v Praze. Další data potřebná pro tvorbu softwaru a následné ověření jeho funkce byla získána připojením simulátoru životních funkcí ProSim-8 (Fluke, USA) k monitoru vitálních funkcí, který je součástí resuscitačního lůžka.

Na základě následujícího protokolu byl vytvořen videozáznam simulace:

Protokol pro získávání dat pro trénování neuronové sítě

Vybavení: Resuscitační lůžko vybavené monitorem životních funkcí, stopkami a kamerovým systémem (1. kamera snímá plochu pro manipulaci s novorozencem, 2. kamera přístrojovou techniku), simulátor ProSim-8 (Fluke, USA).


Postup:

Před začátkem měření je nutné ověřit, zda poloha stopek a monitoru životních funkcí je fixní a shodná na všech resuscitačních lůžkách na oddělení.

1. Připojení simulátoru (HR, SpO₂) k monitoru životních funkcí.
2. Zapnutí nahrávání kamerovým systémem.

3. Spuštění stopek, které jsou součástí resuscitačního lůžka.
4. Postupné nastavení hodnot simulátoru na hodnoty HR a SpO₂ v rozsahu:
 - 1-9 (pro každou hodnotu vytvořit záznam alespoň 15 s),
 - minimálně 40 hodnot HR (tak, aby se prostřídaly všechny číslice na první a druhé pozici a alespoň 15 trojčíferných hodnot, pro každou hodnotu záznam alespoň 20 s),
 - minimálně 30 hodnot SpO₂ (tak, aby se prostřídaly všechny číslice na první a druhé pozici, pro každou hodnotu záznam alespoň 20 s),
 - nechat běžet čas na stopkách alespoň 2x 20 minut.
5. V průběhu záznamu je nutné měnit světelné podmínky.

Získaný videozáznam ze dvou kamer má podobu viz obrázek 4.2. V poli 1 běží čas, který je spuštěn hned po porodu dítěte, v poli 2 je hodnota HR a v poli 3 SpO₂.



Obrázek 4.2: Snímek z videozáznamu resuscitace (1 – čas, 2 – HR, 3 – SpO₂)

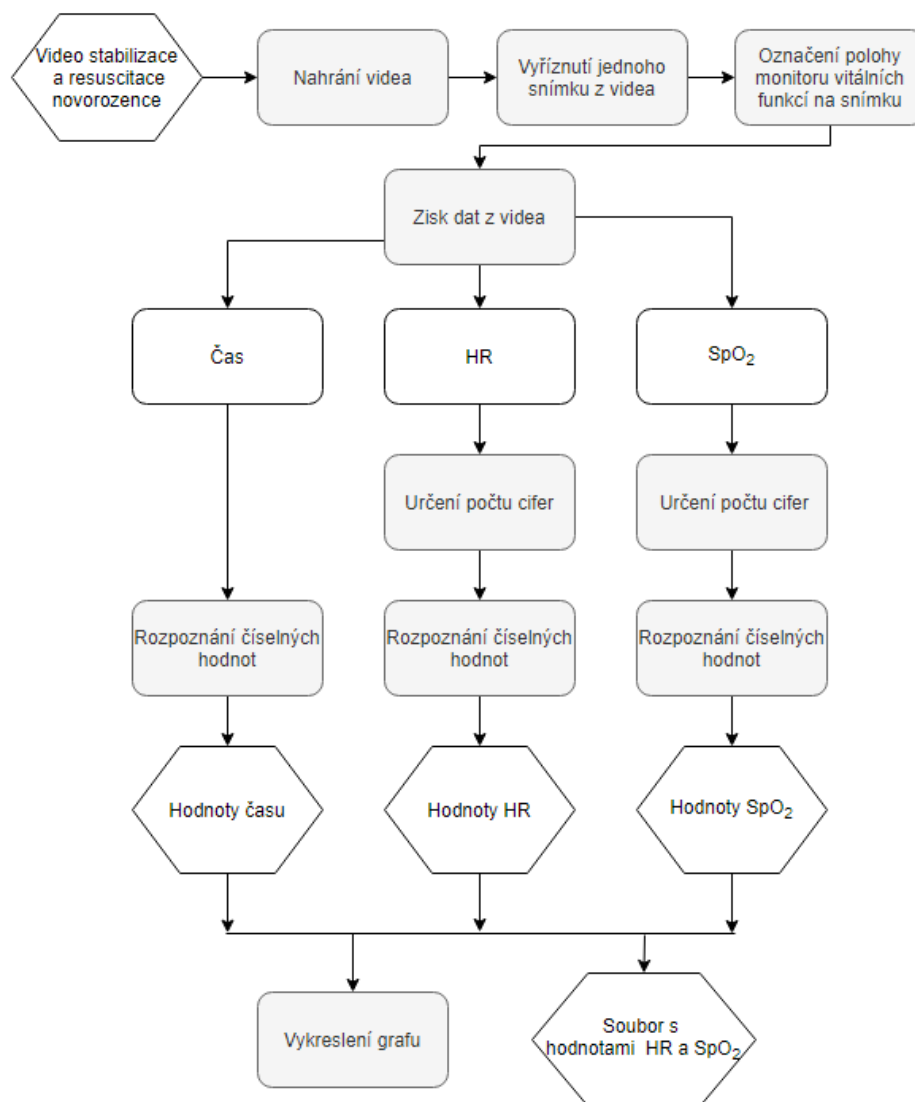
4.2 Analýza požadavků na software

Na základě konzultace s lékaři z GPK VNF, kteří budou výsledný nástroj používat, byly stanoveny následující požadavky na software:

- uživatelská přívětivost,
- dostupnost nezávislá na speciálním softwarovém a hardwarovém vybavení,
- možnost nastavení frekvence odečtu hodnot HR a SpO₂,
- přehledný výstup dat,
- možnost exportu dat pro další zpracování ve vhodném formátu.

4.3 Návrh architektury softwaru

Softwarové řešení pro automatickou detekci číselných hodnot z monitoru životních funkcí bylo koncipováno podle vývojového diagramu na obrázku 4.3.



Obrázek 4.3: Vývojový diagram

4.4 Vytvoření modelu pro rozpoznávání číslic

V práci byl využit jeden model pro získání číselných dat z monitoru vitálních funkcí. Jako model byla zvolena konvoluční neuronová síť. Byla použita pro tři různé účely: pro odečítání číselných hodnot času, pro rozlišení počtu cifer hodnot HR a SpO₂ a pro rozpoznání jednotlivých hodnot HR a SpO₂.

V prvním případě byla využita pro odečítání číselných hodnot času. Stopky jsou spuštěny bezprostředně po porodu novorozence a velmi často dříve než videokamera, která je snímá. Je tedy nutné rozpoznávat i počáteční hodnotu času při spuštění videozáznamu, aby hodnoty HR a SpO₂ byly přiřazeny ke správnému času od porodu.

Aby mohl být obraz následně segmentován na pole s jednotlivými číslicemi, byla neuronová síť využita i pro rozlišení počtu cifer (1–3) hodnot HR a SpO₂. Víceciferná čísla není nutné uvažovat, protože SpO₂ mohou nabývat pouze hodnot 0-100 a stejně

tak srdeční frekvence nepřesahuje trojciferné hodnoty. Tento krok je klíčový pro následné určení pozice jednotlivých číslic na monitoru životních funkcí, neboť při změně počtu cifer dochází k centrování, tedy posunu pozice jednotlivých číslic.

Nakonec byla aplikována na rozpoznání jednotlivých hodnot HR a SpO₂. K jejich rozpoznání lze použít stejně natrénovanou ANN, neboť mají totožný font písma.

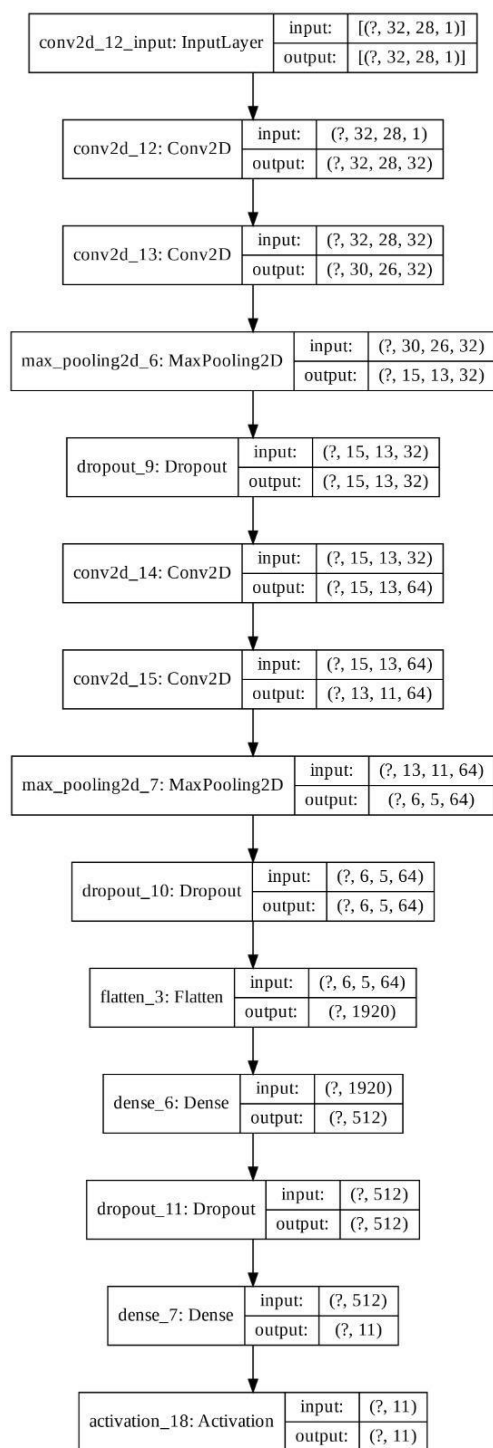
4.4.1 Implementace a struktura neuronové sítě

Zdrojové kódy byly napsány v programovacím jazyce Python, verzi Python 3.7. Python je vysokoúrovňový open-source programovací jazyk s velkým počtem nástrojů a knihoven určenými právě pro práci s umělými neuronovými sítěmi. V práci byly využity následující knihovny:

- Keras - knihovna pro modelování neuronových sítí,
- TensorFlow 2 - výpočetní knihovna vyvinutá pod záštitou Googlu,
- Matplotlib - knihovna pro vykreslování grafů,
- NumPy – knihovna pro matematické výpočty v multidimenzionálních polích,
- SciPy – knihovna pro matematické výpočty (např. integrace, FFT).

Struktura použitého modelu je inspirována obecně využívanou neuronovou sítí VGG (Visual Geometry Group) pro rozpoznávání obrazu. Model byl implementován za použití frameworku Tensorflow 2. Pro učení modelu bylo použito prostředí Google Colaboratory, které umožňuje psát a spouštět kódy v Pythonu přímo v prohlížeči a využít zdarma výkon grafické karty.

Vybraný model neuronové sítě použitý pro všechny výše zmíněné detekce má celkem 1 054 187 parametrů a skládá se ze čtyř konvolučních a dvou pooling vrstev (schéma celé neuronové sítě viz obrázek 4.4). Oproti VGG-16 má méně vrstev a je proto jednodušší. Pro řešení tohoto problému však dostačuje a má nižší výpočetní náročnost.




Obrázek 4.4: Vrstvy použité konvoluční neuronové sítě

4.4.2 Předzpracování trénovacích dat


Ze záznamu vyhotoveného podle protokolu v kapitole 4.1 byly v prostředí MATLAB z každého 25. snímku (podle vzorkovací frekvence použité videokamery 25 snímků/s) vyříznuty číselné hodnoty SpO₂, HR a času. Ty byly dále ručně rozříděny podle fontu číslice na obrázku a dále na třídy dle hodnoty čísla na obrázku. Jelikož videozáznamy ze stabilizace a resuscitace obsahují i pasáže, kdy hodnoty SpO₂ a HR

měřeny nejsou, ať už z důvodu vypadnutí senzoru, nebo srdeční zástavy, je nutné kromě tříd pro čísla 0–9 vytvořit 10. třídu pro obrázky bez číselných hodnot. Takto vyřezané a rozříděné obrázky byly zformovány do datasetů pro trénování neuronové sítě. Vytvořené dva datasety vždy obsahují obrázky a příslušnou třídu, která udává správnou hodnotu čísla na obrázku. Zároveň byl vytvořen i dataset, který obsahuje 3 třídy obrázků v závislosti na počtu cifer (1–3).

Výsledkem předpracování dat jsou tedy tři datasety, kdy první obsahuje číslice času rozříděné do tříd 0–9 (viz obrázek 4.5), druhý číslice pro SpO₂ a HR (viz obrázek 4.6) a poslední třídy s rozdílným počtem cifer (viz obrázek 4.7).



Obrázek 4.5: Ukázka datasetu pro rozpoznání času (každý řádek reprezentuje jednu třídu)



Obrázek 4.6: Ukázka datasetu pro rozpoznání HR a SpO₂ (každý řádek reprezentuje jednu třídu)




Obrázek 4.7: Ukázka datasetu pro rozpoznání počtu cifer (každý řádek reprezentuje jednu třídu)

4.4.3 Trénování sítě


Neuronová síť byla trénovaná pro každý dataset zvlášť. Pro každý byl upraven rozměr vstupu a výstupu sítě. V síti je použita metoda “dropout”, která snižuje pravděpodobnost přeučení modelu. Jako prevence proti přeučení byla také využita metoda augmentace. Tato metoda generuje mírně deformované obrázky z trénovacích vzorků a model se tedy učí na nově vygenerovaných obrázcích, čímž se i kompenzuje nižší počet trénovacích dat a naučený model je robustnější.

Z důvodu rozdílného počtu jednotlivých čísel v datasetech, bylo nutné jednotlivé číselné skupiny vyvážit tak, aby u nejpočetněji zastoupených číslic nedocházelo k jejich preferenci při následném rozpoznávání. Pro učení byl tedy použit generátor vyvážených trénovacích dávek.


Každý dataset byl před samotným učením rozdělený na trénovací a testovací množinu v poměru 85:15. Trénování modelu probíhalo v maximálně 200 epochách, po 16 vzorcích v jedné dávce. Úspěšnost modelu byla vyhodnocována na testovací množině. Pokud model nedosáhl v posledních deseti epochách zlepšení, byl proces trénování zastaven. Výsledky učení modelu pro jednotlivá data jsou v grafech vývoje přesnosti a ztrátové funkce na obrázcích 4.8 a 4.9 pro určení hodnoty času, na obrázcích 4.10 a 4.11 pro hodnoty SpO₂ a HR a na obrázcích 4.12 a 4.13 pro určení počtu cifer.




Obrázek 4.8: Graf vývoje přesnosti v závislosti na epoše pro rozeznání hodnot času




Obrázek 4.9: Graf ztrátové funkce v závislosti na epoše pro rozeznání hodnot času



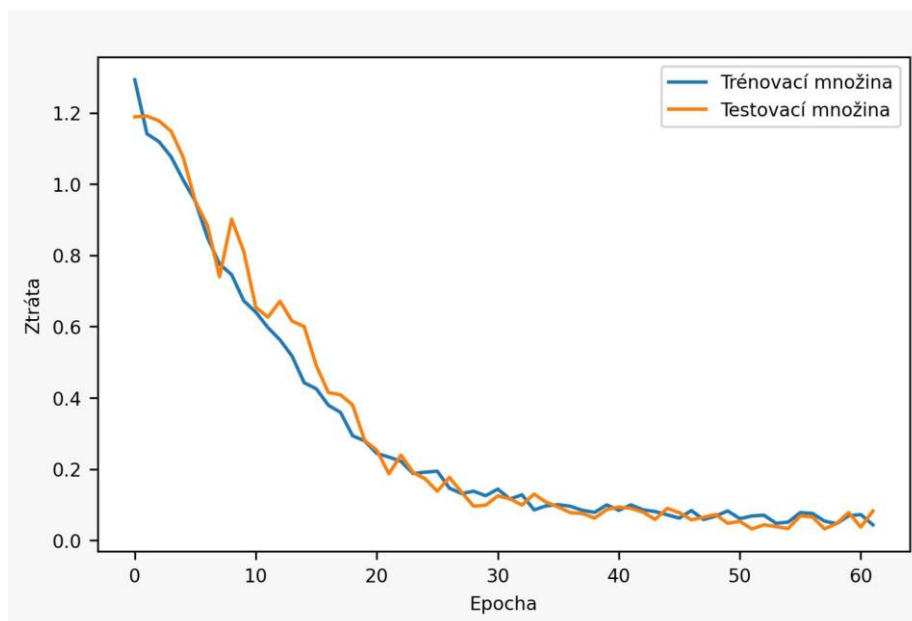
Obrázek 4.10: Graf vývoje přesnosti v závislosti na epoše pro rozeznání hodnot SpO₂ a HR



Obrázek 4.11: Graf ztrátové funkce v závislosti na epoše pro rozeznání hodnot SpO₂ a HR



Obrázek 4.12: Graf vývoje přesnosti v závislosti na epoše pro určení počtu cifer



Obrázek 4.13: Graf ztrátové funkce v závislosti na epoše pro určení počtu cifer

4.5 Implementace webové aplikace

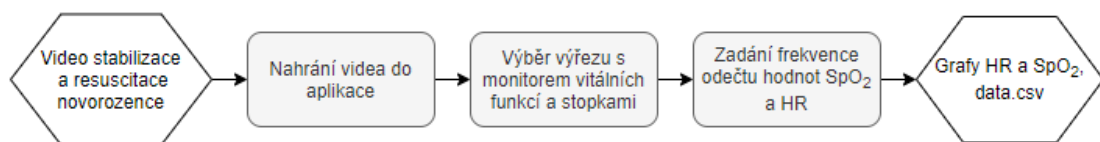
Hodnoty synaptických vah z natrénovaných konvolučních neuronových sítí byly přeneseny do aplikace, která je využívá ke spuštění predikce modelu po zadání vstupů uživatelem.

S ohledem na požadavky provozu aplikace bylo zvoleno řešení pomocí webového serveru. Uživatelé budou moci k aplikaci přistupovat pomocí libovolného webového prohlížeče. Nebude tedy nutné konfigurovat, nebo instalovat nový software.

Webová aplikace byla rovněž implementována v jazyce Python. Pro vývoj byl použit jednoduchý webový framework Flask napsaný v Pythonu, který nevyžaduje žádné zvláštní nástroje nebo knihovny a nemá žádnou databázovou abstrakční vrstvu, ověření formuláře ani žádné další komponenty, kde jsou běžné funkce poskytovány knihovnami třetích stran.

Vývoj webové aplikace probíhal v programu Pycharm, používaném v počítačovém programování, konkrétně pro jazyk Python, který je vyvíjen českou společností JetBrains. Poskytuje analýzu kódu, grafický debugger, integrovaný tester jednotek, integraci se systémy pro správu verzí a podporuje právě i vývoj webových aplikací. [6]

Z hlediska uživatele pak bude výsledná aplikace fungovat podle schématu na obrázku 4.14. Vstup uživatele je tedy nutný pouze pro nahrání dat, označení pozice monitoru vitálních funkcí a stopek a zadání požadované frekvence odečtu hodnot HR a SpO₂.



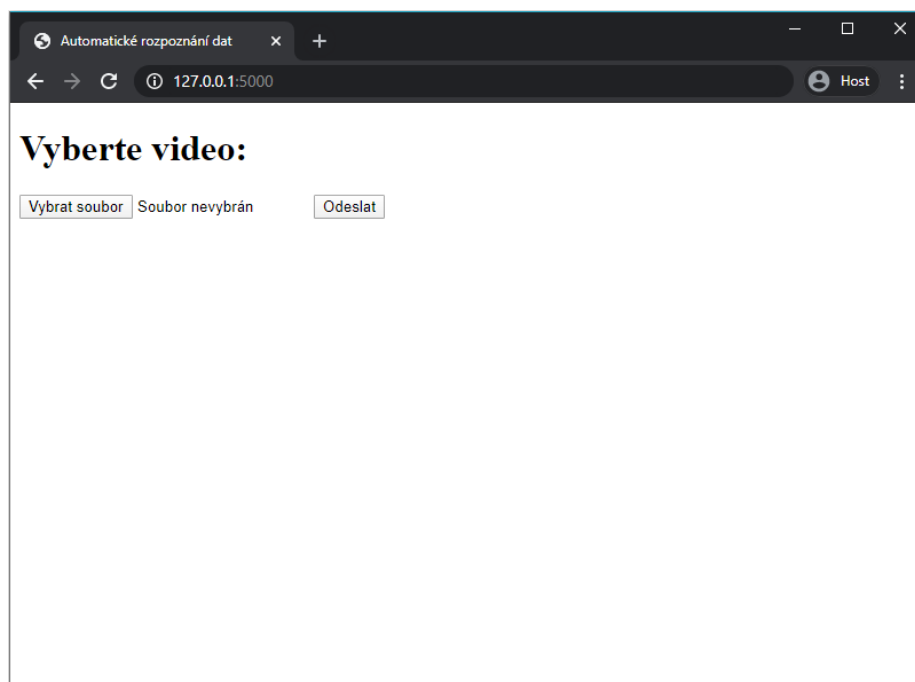
Obrázek 4.14: Aplikace pro získání číselných dat z monitoru vitálních funkcí z pohledu uživatele

5 Výsledky

Výsledkem práce je webová aplikace umožňující rozpoznávat číselné hodnoty srdeční frekvence a saturace krve kyslíkem z videozáznamů stabilizací a resuscitací extrémně nezralých novorozenců. Rozpoznané hodnoty HR a SpO₂ jsou vykresleny do grafu v závislosti na čase od porodu a uloženy do souboru ve formátu CSV, který je k dispozici ke stažení. Aplikace umožňuje změnit frekvenci odečítání těchto číselných hodnot.

5.1 Webová aplikace


Na obrázku 5.1 je vstupní obrazovka webové aplikace, kde je uživatel vyzván k nahrání videozáznamu ve formátu MP4, nebo AVI. Záznam je nutné nahrát s pojmenováním, které splňuje podmínky Obecného nařízení o ochraně osobních údajů (GDPR, General Data Protection Regulation).




Obrázek 5.1: Úvodní obrazovka webové aplikace

V dalším kroku je nutné zkontrolovat označené výřezy videozáznamu se stopkami a s polem s hodnotami HR a SpO₂ na monitoru životních funkcí (viz obrázek 5.2 a 5.3). Ty musí odpovídat zobrazeným vzorům. Ve webové aplikaci je defaultně nastavena předpokládaná poloha výřezu, ale v případě posunu polí s hodnotami lze vybraný výřez manuálně upravit. V tomto kroku lze také upravit frekvenci odečtu hodnot (defaultně je nastavena frekvence odečtu na 1s).


Vyberte pole se stopkami:




Vzor:



Vyberte pole s hodnotami HR a SpO2:



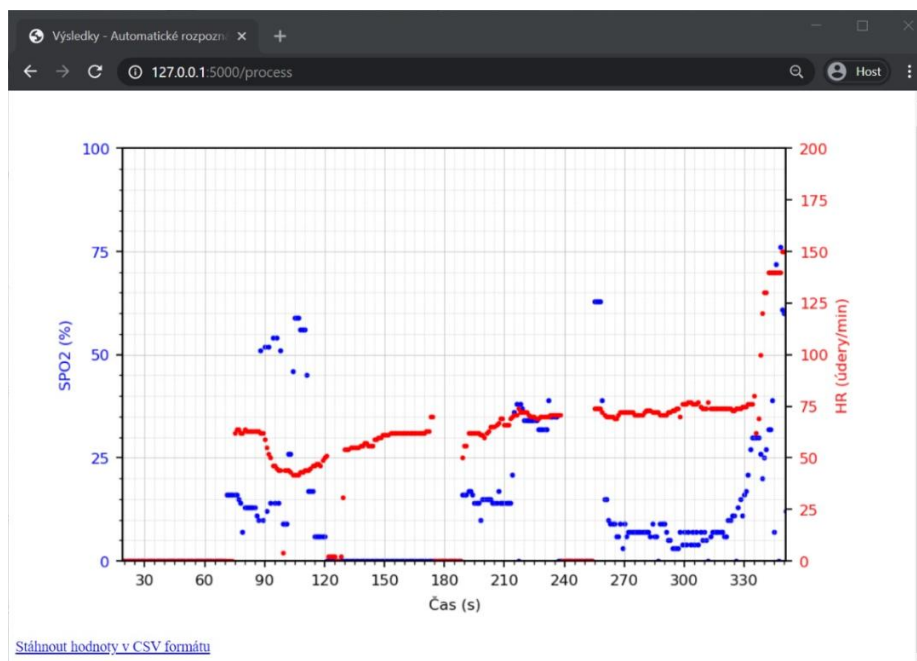
Vzor:



Frekvence odečtu (s):

Obrázek 5.2: Manuální výběr pole s Apgar stopkami a pole s hodnotami HR a SpO₂


Následně je již zobrazen protokol záznamu, tedy graf hodnot SpO₂ a HR v závislosti na čase od porodu. Soubor s těmito daty je možné vyexportovat ve formátu CSV (viz obrázek 5.4).



Obrázek 5.3: Závěrečná stránka webové aplikace s grafem HR a SpO₂ v závislosti na čase a možností stáhnout dokument CSV


5.1.1 Ověření funkce aplikace

Ověření aplikace bylo provedeno na základě videozáznamu, kdy byl k monitoru životních funkcí připojen simulátor ProSim-8 (Fluke, USA). Graf na obrázku 5.5 zobrazuje rozpoznané hodnoty SpO₂ a HR.



Obrázek 5.4: Graf hodnot HR a SpO₂ rozeznávaných konvoluční neuronovou sítí v závislosti na čase

Dále byly tyto hodnoty porovnány s reálnými hodnotami. Ty byly získány sledováním záznamu a manuálním vypisováním hodnot HR a SpO₂ v intervalu jedné sekundy. Porovnání rozpoznávaných hodnot s reálnými hodnotami HR je znázorněno v grafu na obrázku 5.5 a v grafu na obrázku 5.7 pro hodnoty SpO₂.




Obrázek 5.5: Porovnání reálných hodnot HR s hodnotami rozpoznávanými konvoluční neuronovou sítí

K chybnému rozpoznání hodnot HR došlo pouze v jednom případě, a to v 394. sekundě z důvodu částečného zakrytí monitoru životních funkcí rukou (viz obrázek 5.6).



Obrázek 5.6: Zakrytí monitoru



Obrázek 5.7: Porovnání reálných hodnot SpO_2 s hodnotami rozpoznány konvoluční neuronovou sítí

Z důvodu vyšší chybovosti rozpoznání hodnot SpO_2 byla provedena analýza těchto chyb s cílem identifikovat jejich příčinu (viz tabulka 5.1).

Tabulka 5.1: Příčiny jednotlivých chyb (chyba = chybné rozpoznání hodnoty CNN)

Čas (s)	Reálná hodnota SpO_2 (%)	Rozpoznaná hodnota SpO_2 (%)	Příčina	Čas (s)	Reálná hodnota SpO_2 (%)	Rozpoznaná hodnota SpO_2 (%)	Příčina		
1	308	65	55	chyba	24	544	41	71	blikání
2	320	65	55	chyba	25	550	41	71	blikání
3	324	44	74	blikání	26	553	41	1	blikání
4	326	44	45	blikání	27	556	41	1	blikání
5	329	34	39	blikání	28	557	41	1	blikání
6	332	29	26	chyba	29	559	41	1	blikání
7	336	29	26	chyba	30	561	41	1	blikání
8	338	29	26	chyba	31	563	41	1	blikání
9	342	29	26	chyba	32	565	41	1	blikání
10	344	29	26	chyba	33	567	41	1	blikání
11	348	34	0	blikání	34	579	65	0	blikání
12	349	33	0	blikání	35	581	65	0	blikání
13	363	33	30	blikání	36	590	65	55	chyba
14	394	37	0	překážka	37	594	65	55	chyba
15	422	37	0	překážka	38	604	66	65	chyba
16	530	40	0	překážka	39	613	77	0	blikání
17	532	40	0	překážka	40	626	77	70	chyba
18	533	40	70	chyba	41	636	77	0	blikání
19	534	40	0	blikání	42	637	88	66	chyba
20	536	40	0	blikání	43	638	88	80	chyba
21	537	40	0	blikání	44	644	88	68	chyba
22	542	41	1	chyba	45	647	90	60	chyba
23	543	41	71	blikání	46	650	90	0	blikání

Vyšší chybovost rozpoznání hodnot SpO_2 je způsobena zejména blikáním pole zobrazujícím její hodnoty (viz obrázek 5.8). Neuronová síť v tomto případě rozezná pouze jednu číslici, nebo žádnou. Pokud je jako příčina v tabulce 5.1 uvedeno „chyba“ znamená to, že vizuálně bylo možné číslo přečíst, ale konvoluční neuronová síť vyhodnotila hodnotu nesprávně. Další příčina chybného rozpoznání může být překážka v zorném úhlu kamery, která částečně, nebo úplně zakryla pole s hodnotou a znemožnila tak její přečtení. V klinické praxi se může jednat zejména o zakrytí monitoru obsluhujícím personálem při nastavování přístrojové techniky na panelu resuscitačního lůžka, nebo hadičkami ventilace vedoucí přes monitor.




Obrázek 5.8: Blikání hodnot SpO_2

5.2 Vyhodnocení záznamů stabilizace tří novorozenců

Součástí práce je vyhodnocení videozáznamů stabilizace tří novorozenců na porodním sále. Všechny záznamy byly poskytnuty GPK VFN v Praze. Videozáznamy byly nejdříve vyhodnoceny vytvořenou webovou aplikací. Následně byla provedena analýza použitých intervencí, například intubace nebo podání surfaktantu. U každého záznamu byly opět porovnány hodnoty rozpoznané konvoluční neuronovou sítí s reálnými hodnotami HR a SpO_2 získanými manuálním vypisováním.

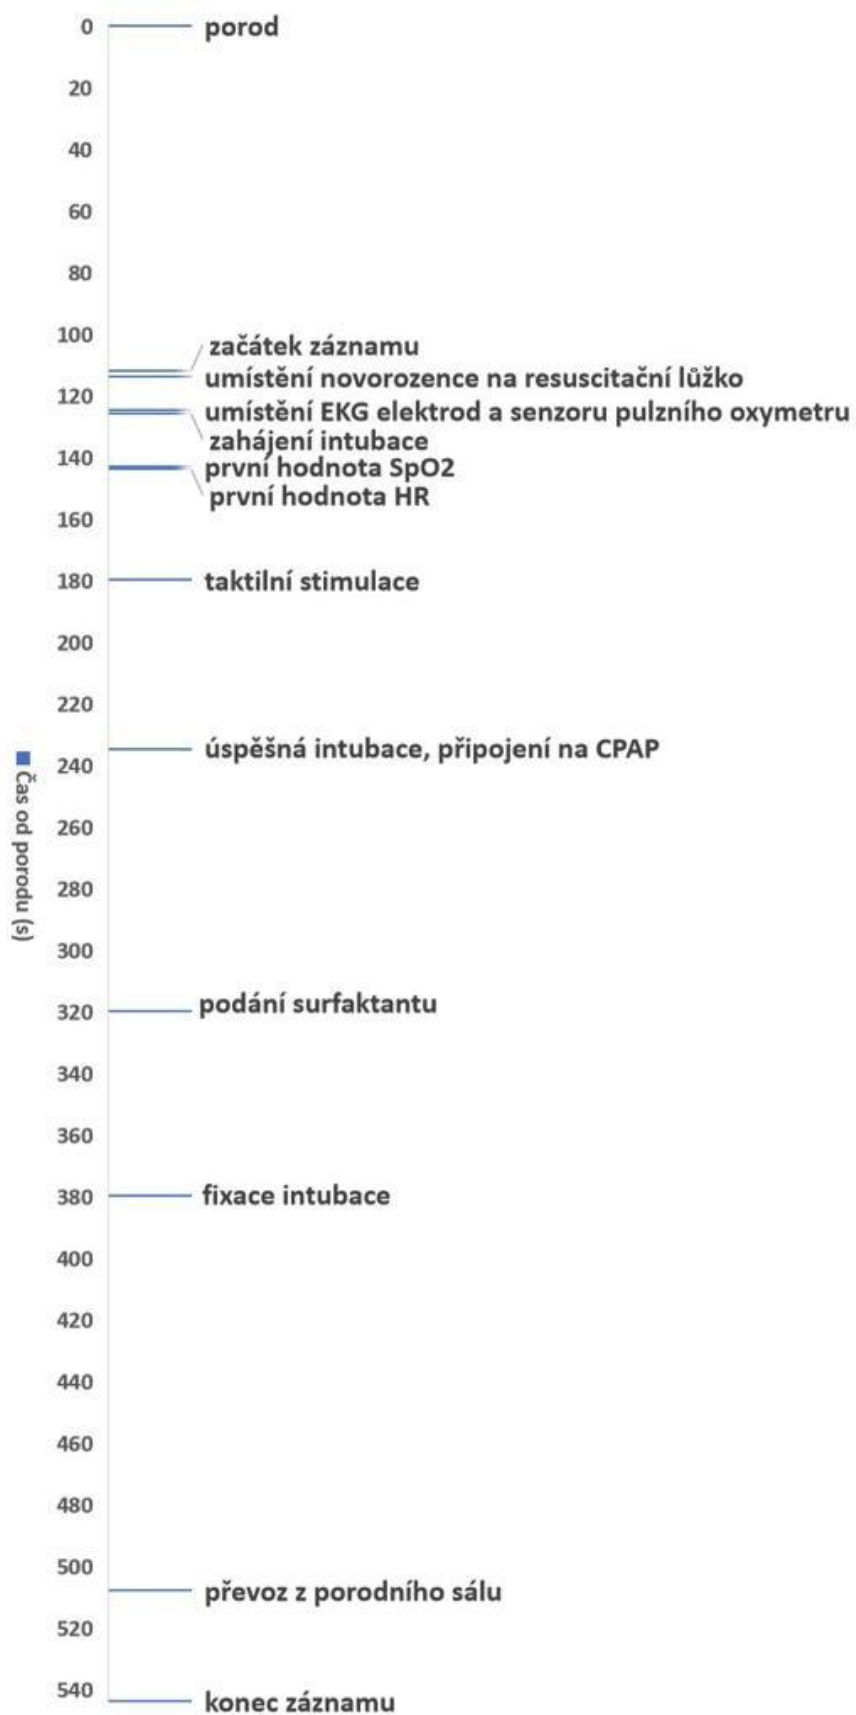
5.2.1 Záznam 1 (1. novorozenec)



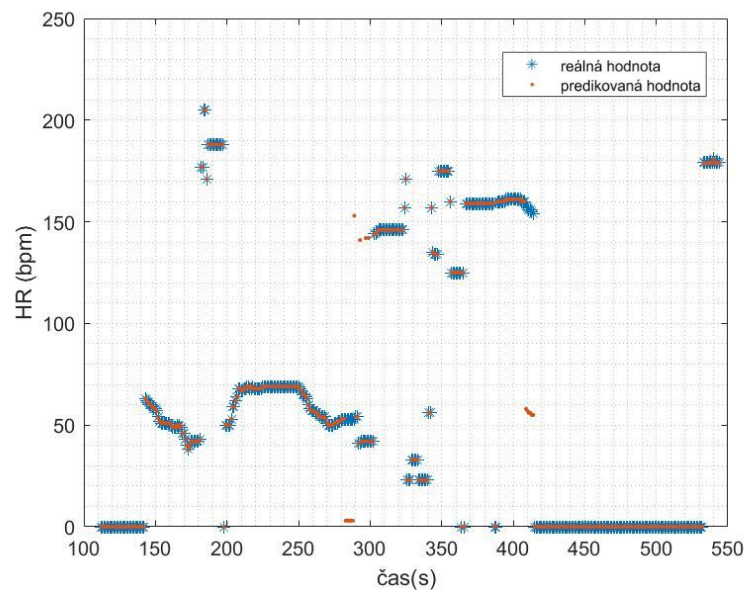
Obrázek 5.9: Graf hodnot HR a SpO₂ rozpoznávaných konvoluční neuronovou sítí ze záznamu stabilizace 1. novorozence v závislosti na čase

Tabulka 5.2: Použité intervence u 1. novorozence

Čas (s)	Intervence
0	porod
112	začátek záznamu
114	umístění novorozence na resuscitační lůžko
125	umístění EKG elektrod a senzoru pulzního oxymetru
126	zahájení intubace
144	první hodnota SpO ₂
143	první hodnota HR
180	taktilní stimulace
235	úspěšná intubace, připojení na CPAP
320	podání surfaktantu
380	fixace intubace
508	převoz z porodního sálu
544	konec záznamu



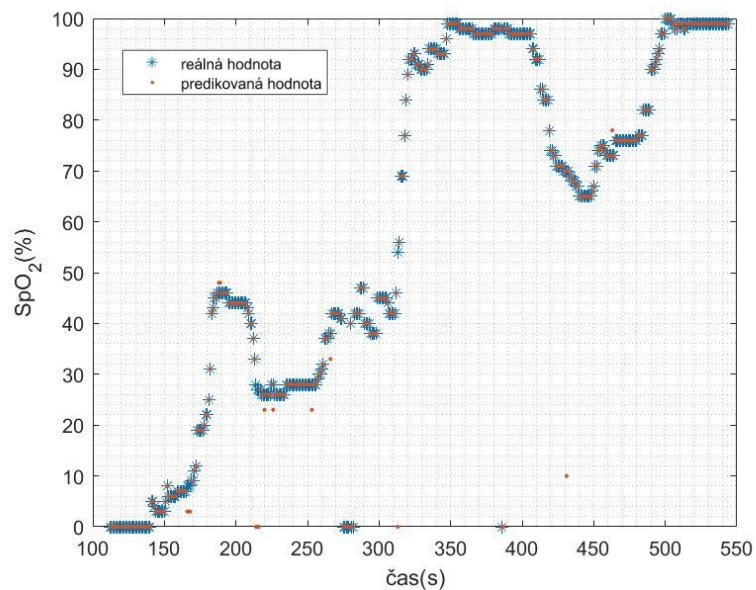
Obrázek 5.10: Časová osa stabilizace 1. novorozence



Obrázek 5.11: Porovnání reálných hodnot HR s rozpoznávanými konvoluční neuronovou sítí

Tabulka 5.3: Příčiny jednotlivých chyb při rozpoznávání číselných hodnot

Čas (s)	Reálná hodnota HR (bpm)	Rozpoznaná hodnota HR (bpm)	Příčina
283	53	3	překážka přes 1. číslici
284	53	3	překážka přes 1. číslici
285	53	3	překážka přes 1. číslici
286	53	3	překážka přes 1. číslici
287	53	3	překážka přes 1. číslici
288	53	3	překážka přes 1. číslici
289	53	153	překážka přes 1. číslici
293	41	141	překážka přes 1. číslici
297	42	142	špatná čitelnost
299	42	142	špatná čitelnost
409	158	58	překážka přes 1. číslici
410	157	57	překážka přes 1. číslici
411	156	56	překážka přes 1. číslici
412	156	56	překážka přes 1. číslici
413	155	55	překážka přes 1. číslici
414	154	54	překážka přes 1. číslici




Obrázek 5.12: Porovnání reálných hodnot SpO_2 s rozpoznávanými konvoluční neuronovou sítí

Tabulka 5.4: Příčiny jednotlivých chyb při rozpoznávání číselných hodnot

Čas (s)	Reálná hodnota SpO_2 (%)	Rozpoznaná hodnota SpO_2 (%)	Příčina
166	8	3	chyba
167	8	3	chyba
168	8	3	chyba
188	46	48	blikání
189	46	48	blikání
214	27	0	špatná čitelnost
215	28	0	špatná čitelnost
216	28	0	špatná čitelnost
220	26	23	chyba
226	26	23	chyba
253	28	23	chyba
266	38	33	chyba
313	54	0	blikání
387	98	0	chyba
431	70	10	chyba
463	73	78	chyba

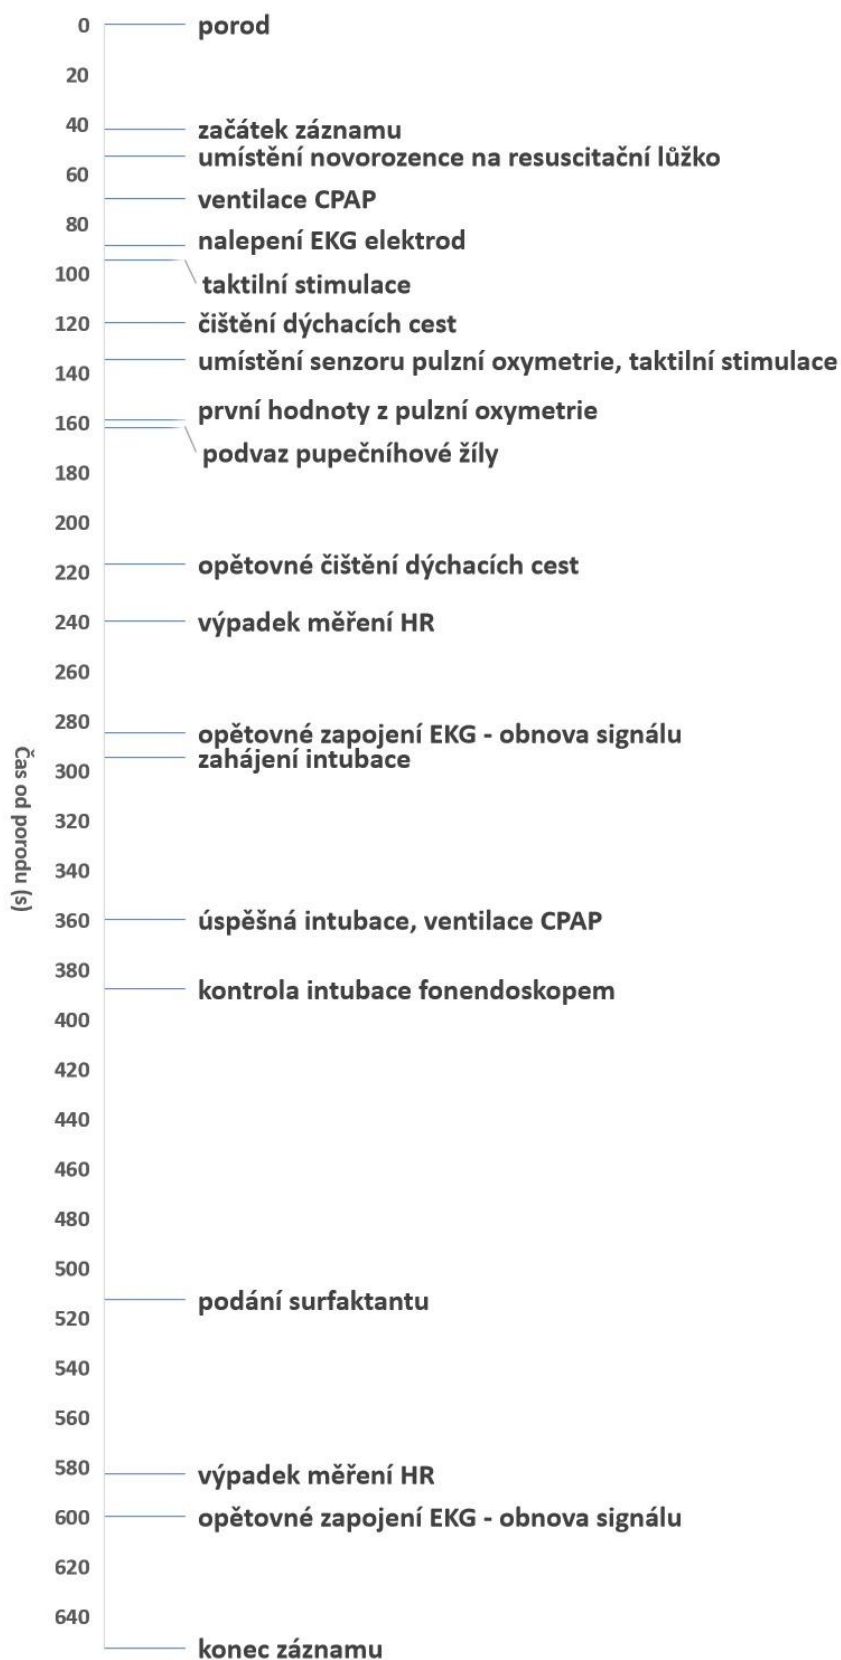
5.2.2 Záznam 2 (2. novorozenec)




Obrázek 5.13: Graf hodnot HR a SpO₂ rozpoznávaných konvoluční neuronovou sítí ze záznamu stabilizace 2. novorozenec v závislosti na čase

Tabulka 5.5: Použité intervence u 2. novorozenec

Čas (s)	Intervence
0	porod
42	začátek záznamu
53	umístění novorozenec na resuscitační lůžko
70	ventilace CPAP
89	nalepení EKG elektrod
95	taktilní stimulace
120	čištění dýchacích cest
135	umístění senzoru pulzní oxymetrie, taktilní stimulace
159	první hodnoty z pulzní oxymetrie
162	podvaz pupečníkové žíly
217	opětovné čištění dýchacích cest
240	výpadek měření HR
285	opětovné zapojení EKG - obnova signálu
295	zahájení intubace
360	úspěšná intubace, ventilace CPAP
388	kontrola intubace fonendoskopem
513	podání surfaktantu
583	výpadek měření HR
600	opětovné zapojení EKG - obnova signálu
653	konec záznamu




Obrázek 5.14: Časová osa stabilizace 2. novorozence



Obrázek 5.15: Porovnání reálných hodnot HR s rozpoznávanými konvoluční neuronovou sítí

Tabulka 5.6: Příčiny jednotlivých chyb při rozpoznávání číselných hodnot

Čas (s)	Reálná hodnota HR (bpm)	Rozpoznaná hodnota HR (bpm)	Příčina
173	122	22	překážka přes 1. číslici
175	120	20	překážka přes 1. číslici
186	124	24	překážka přes 1. číslici
206	116	16	překážka přes 1. číslici
228	115	15	překážka přes 1. číslici
308	131	31	překážka přes 1. číslici
360	91	0	překážka
469	130	30	překážka přes 1. číslici
561	111	11	překážka přes 1. číslici
646	133	88	překážka přes 1. číslici




Obrázek 5.16: Porovnání reálných hodnot SpO_2 s rozpoznávanými konvoluční neuronovou sítí

Tabulka 5.7|: Příčiny jednotlivých chyb při rozpoznávání číselných hodnot

Čas (s)	Reálná hodnota SpO_2 (%)	Rozpoznaná hodnota SpO_2 (%)	Příčina
200	34	84	chyba
201	34	84	chyba
205	34	84	chyba
221	48	43	chyba
241	49	0	překážka
318	51	0	překážka
360	50	0	překážka
363	50	0	překážka
366	50	0	překážka
386	48	40	překážka přes 2. číslici
387	48	40	překážka přes 2. číslici
388	48	40	překážka přes 2. číslici
447	50	0	překážka
506	33	38	chyba
564	39	89	chyba
593	35	0	překážka
635	53	0	překážka


5.2.3 Záznam 3 (3. novorozenec)



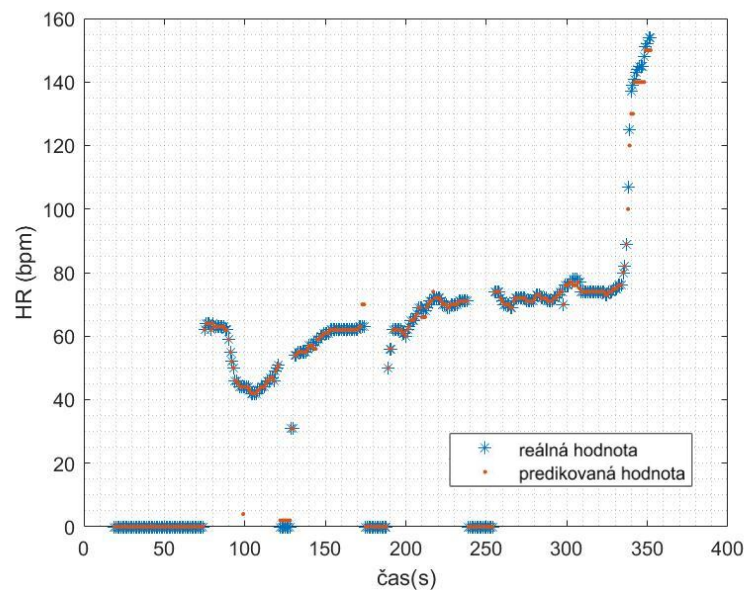
Obrázek 5.17: Graf hodnot HR a SpO₂ rozpoznávaných konvoluční neuronovou sítí ze záznamu stabilizace 3. novorozenec v závislosti na čase

Tabulka 5.8: Použité intervence u 3. novorozenec

Čas (s)	Intervence
0	porod
19	začátek záznamu
30	umístění novorozenec na resuscitační lůžko
35	čištění dýchacích cest
43	umístění senzoru pulzní oxymetrie
45	kanylace pupečnickové žíly
56	počátek intubace
71	první hodnota SpO ₂
75	první hodnota HR
97	intubace, připojení CPAP
100	opětovná intubace
173	úspěšná intubace
201	kontrola fonendoskopem
243	podání surfaktantu
240	výpadek signálu pulzního oxymetru
255	obnovení signálu z pulzního oxymetru



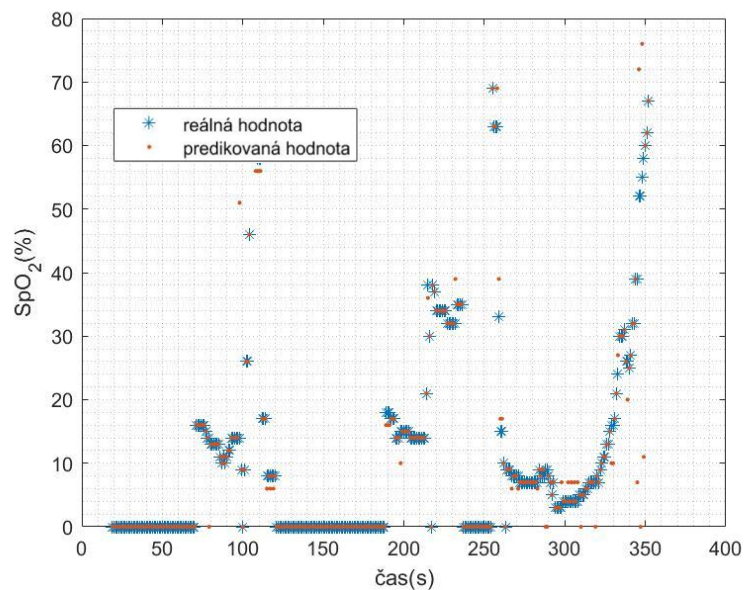
Obrázek 5.18: Časová osa stabilizace 3. novorozence



Obrázek 5.19: Porovnání reálných hodnot HR s rozpoznávanými konvoluční neuronovou sítí

Tabulka 5.9: Příčiny jednotlivých chyb při rozpoznávání číselných hodnot

Čas (s)	Reálná hodnota HR (bpm)	Rozpoznaná hodnota HR (bpm)	Příčina
99	44	4	překážka přes 2. číslici
122	0	2	chyba
128	0	2	chyba
143	58	56	překážka přes 2. číslici
144	58	56	překážka přes 2. číslici
173	63	70	přeexponovaný obraz
174	63	70	přeexponovaný obraz
210	69	66	překážka přes 2. číslici
211	68	66	překážka přes 2. číslici
212	68	66	překážka přes 2. číslici
217	72	74	překážka přes 2. číslici
304	78	76	překážka přes 2. číslici
305	78	76	překážka přes 2. číslici
306	78	76	překážka přes 2. číslici
338	107	100	překážka přes 3. číslici
339	125	120	překážka přes 3. číslici
340	137	130	překážka přes 3. číslici
341	139	130	překážka přes 3. číslici
342	141	140	překážka přes 3. číslici
343	143	140	překážka přes 3. číslici
344	144	140	překážka přes 3. číslici
345	145	140	překážka přes 3. číslici
346	145	140	překážka přes 3. číslici
347	145	140	překážka přes 3. číslici
348	148	140	překážka přes 3. číslici
349	151	150	překážka přes 3. číslici
350	152	150	překážka přes 3. číslici
351	154	150	překážka přes 3. číslici
352	154	150	překážka přes 3. číslici



Obrázek 5.20: Porovnání reálných hodnot SpO_2 s rozpoznávanými konvoluční neuronovou sítí

Tabulka 5.10: Příčiny jednotlivých chyb při rozpoznávání číselných hodnot

Čas (s)	Reálná hodnota SpO_2 (%)	Rozpoznaná hodnota SpO_2 (%)	Příčina
79	14	0	přeexponovaný obraz
100	14	51	překážka
108	59	56	blikání
109	58	56	blikání
111	58	56	blikání
115	8	6	blikání
117	8	6	blikání
119	8	6	blikání
189	18	16	blikání
190	18	16	chyba
191	18	16	chyba
198	15	10	překážka
215	38	36	překážka
232	32	39	blikání
258	63	69	chyba
259	33	39	chyba
260	15	17	chyba
261	15	17	chyba
267	8	6	chyba
286	8	9	blikání
287	8	9	blikání
288	9	0	špatná čitelnost
289	9	0	špatná čitelnost
298	3	7	blikání
302	4	7	blikání
304	4	7	blikání
306	4	7	blikání
308	4	7	blikání
310	5	0	blikání
319	5	0	blikání
329	16	10	překážka
330	16	10	překážka
333	24	27	chyba
339	26	20	chyba

5.3 Přesnost rozpoznání číselných hodnot

Přesnost rozpoznání byla posuzována podle dvou kritérií. Nejprve byla určena na základě počtu všech špatně vyhodnocených čísel (viz tabulka 5.11). Tedy například pokud reálná hodnota čísla byla 43 a rozpoznána 45, bylo rozpoznání považováno jako chybné.

V druhém případě pak byla přesnost hodnocena na základě rozpoznání jednotlivých číslic (viz tabulka 5.12). Ve stejném příkladu by byla chybně rozpoznána pouze druhá číslice (5).

Tabulka 5.11: Přesnost rozpoznání celých čísel

	HR	SpO₂
Simulátor	99,76 %	89,02 %
Záznam 1	96,30 %	96,30 %
Záznam 2	98,47 %	97,40 %
Záznam 3	91,29 %	89,79 %
Průměr	96,45 %	93,13 %

Tabulka 5.12: Přesnost rozpoznání jednotlivých číslic

	HR	SpO₂
Simulátor	99,76 %	93,57 %
Záznam 1	98,07 %	97,39 %
Záznam 2	99,11 %	98,10 %
Záznam 3	94,75 %	93,57 %
Průměr	97,92 %	95,66 %

6 Diskuse

V rámci práce byla vytvořena webová aplikace, která umožňuje automatické rozpoznání hodnot HR a SpO₂, jejich následné vykreslení do grafu a stažení výsledných dat ve formátu CSV. V aplikaci lze měnit frekvenci odečtu hodnot. Kromě hodnot HR a SpO₂ je detekován i čas na Apgar stopkách. Cílem práce je zjednodušit a zkrátit proces získávání patientských dat z videozáznamů procesu stabilizace a resuscitace novorozenců na porodním sále a tato data vhodně zpracovat pro následné využití. Řešení je koncipováno přesně na míru záznamů z GPK VFN v Praze. Pro jejich přesné vyhodnocení je nutné, aby videozáznam byl dostatečně kvalitní a číselné hodnoty byly po celou dobu záznamu zcela viditelné.

Pro samotné rozeznávání číselných hodnot bylo uvažováno několik možných metod, jako jsou KNN (algoritmus k-nejbližších sousedů), SVM (metoda podpůrných vektorů), ANN (umělé neuronové sítě), OCR (optické rozpoznávání znaků), CNN (konvoluční neuronová síť) a algoritmus založený na kombinaci volby prahové hodnoty, mediánového filtru a metody projekce. Jednotlivé metody se liší přesností, výpočetní náročností i rozsahem objemu vstupních dat. [56-58]

Jako model pro rozeznávání číslic byla vybrána konvoluční neuronová síť. Toto řešení je u rozeznávání číselných hodnot poměrně obvyklé a existuje mnoho publikací zabývajících se touto tematikou. V praxi se CNN využívá například pro rozeznávání poznávacích značek aut, nebo obličejů. Patří sice mezi výpočetně náročnější metody, nicméně její velkou výhodou je přesnost rozpoznání. CNN dokáže po dostatečném trénování rozpoznat hodnoty i v záběrech, kde se často mění světelné podmínky a čitelnost hodnot, jako je tomu právě ve videozáznamech poskytnutých GPK. Pro zajištění dostatečného množství trénovacích dat byl vytvořen záznam, kdy byl k monitoru životních funkcí připojen simulátor Pro-sim8 (Fluke, USA). Pro zvýšení přesnosti rozpoznání byla ještě data doplněna metodou augmentace. [56, 59]

Podmínkou zadanou GPK VFN v Praze byla dostupnost řešení nezávisle na speciálním softwarovém a hardwarovém vybavení. Nebylo tedy možné použít programy s licenci (např. Matlab) a byly zvoleny open-source prostředky. Dalším požadavkem na výsledný software byla uživatelská přívětivost. Proto byl výsledný natrénovaný model konvoluční neuronové sítě implementován do prostředí webové aplikace, kterou lze spustit v libovolném webovém prohlížeči. Aplikace byla navržena tak, aby vyžadovala co nejmenší kooperaci uživatele, a to pouze nahrání videa, následné upřesnění výřezu s Apgar stopkami a hodnotami HR a SpO₂. Apgar stopky jsou spuštěny ihned po porodu, ještě než je novorozenec umístěn na resuscitační lůžko, a tedy před začátkem nahrávání samotného videozáznamu. Vzhledem k tomu, že fotografický záznam je z hlediska GDPR řazen mezi osobní údaje, je nutné soubor se záznamem stabilizace

nahrát s anonymním pojmenováním pro zabránění identifikace novorozence na videu. [60]

V aplikaci je možné měnit frekvenci odečtu hodnot (předpokládá se snímková frekvence 25 snímků/sekundu, jako tomu je u všech videozáznamů poskytnutých GPK VFN v Praze). Rozpoznané hodnoty jsou zobrazeny v grafu v závislosti na čase od porodu a je možné je vyexportovat i ve formátu CSV. Ten byl zvolen pro svou univerzálnost s možností následného využití a zpracování dat programy jako např. Microsoft Excel nebo Matlab.

Webová aplikace bude využívána k retrospektivní analýze videozáznamů stabilizace v GPK VFN v Praze. Řešení tedy bylo koncipováno přesně na míru těchto záznamů a je uzpůsobeno pro vybavení resuscitačních lůžek v GPK. Ale volbou polohy monitoru životních funkcí a stopek je možné webovou aplikaci použít i pro vyhodnocení záznamů z jinak uspořádaných resuscitačních lůžek za předpokladu, že využívají stejný monitor životních funkcí a stopky. Při případné aplikaci na záznamy s monitorem vitálních funkcí s jiným fontem číslic a by bylo nutné aplikaci dodatečně upravit. Tomuto problému by šlo sice předejít využitím funkce OCR v prostředí Matlab, nicméně při testování jejího použití byla její přesnost z důvodu špatné čitelnosti a změnám jasů ve videozáznamu velmi nízká. Možné vylepšení webové aplikace je automatická detekce číselných hodnot bez upřesnění polohy přístrojů.

Funkčnost navrženého řešení byla ověřena pomocí simulátoru životních funkcí. Pomocí webové aplikace byly dále vyhodnoceny tři záznamy stabilizace novorozence na porodním sále. Hodnoty HR jsou rozhodující pro volbu postupu a volbu míry použitých intervencí při stabilizaci novorozenců. Hodnoty SpO₂ jsou při procesu stabilizace až druhotně sledovaným parametrem. Pro retrospektivní analýzu je důležitý vývoj hodnot životních funkcí v čase od porodu, tedy trend dat. Z něj si lékaři mohou už na první pohled udělat představu o průběhu stabilizace. Trend dat je v případě rozložení jednotlivých chybně rozpoznávaných hodnot do celé délky záznamu snadno rozpoznatelný. [15]


Záznamy byly analyzovány i z hlediska prováděných intervencí. V několika případech došlo ke ztrátě signálu vlivem odlepení elektrody, nebo vypadnutím konektoru při manipulaci s novorozencem. Pokud by lékaři vycházeli pouze z grafického výstupu, mohlo by dojít k záměně takovéto situace za srdeční zástavu. Kontrola záznamu by se tak měla zaměřit především na výrazné poklesy, nebo vzestupy hodnot. [15]

Rozpoznané hodnoty byly porovnávány s hodnotami získanými manuálním vypisováním v intervalu jedné sekundy. Časová náročnost získání hodnot HR a SpO₂ u desetiminutového záznamu byla cca jednu hodinu. Oproti tomu vyhodnocení webovou aplikací trvalo cca 2 minuty (doba závisí na výpočetním výkonu použitého počítače). Přesnost rozpoznání byla hodnocena podle dvou kritérií (viz tabulka 5.11

a tabulka 5.12). V případě, že byla hodnocena na přesnost celých čísel, byla průměrná přesnost rozpoznání HR 96,45 % a SpO₂ 93,13 %. Pokud bylo hodnoceno rozpoznání jednotlivých číslic, byla přesnost konvoluční sítě vyšší, HR 97,92 % a SpO₂ 95,66 %. Nižší přesnost u rozpoznání hodnot SpO₂ je způsobena zejména problikáváním hodnot na negativní zobrazení. To je závislé na konkrétním nastavení alarmů na daném monitoru životních funkcí. To, že přesnost CNN je výrazně nižší u negativních obrázků potvrzuje i [61]. Pro zvýšení přesnosti rozpoznání byly zařazeny negativní obrázky i do datasetu pro trénování CNN. V některých případech nejsou bohužel hodnoty SpO₂ vlivem blikání čitelné vůbec (viz obrázek 5.9). Nicméně celkově je přesnost vyhodnocení závislá především na konkrétním videozáznamu. [61, 62]

Možným řešením pro redukci této chyby by bylo nastavení rozpoznávání číselných hodnot ze dvou po sobě jdoucích snímků a jejich porovnání. Při odečítání hodnot každou sekundu je hodnocen každý 25. snímek videozáznamu (videozáznam má standardně 25 snímků/s). Touto úpravou by byl hodnocen 25. i 26. snímek a výsledky porovnány a vyhodnoceny. Tím by však došlo k prudkému nárůstu výpočetní náročnosti. Při porovnání s touto skutečností se jeví současná míra přesnosti jako dostatečná.

Poměrně častou komplikací pro správné rozpoznání hodnot představují překážky v obraze, které číslo úplně, nebo částečně překrývají. Jedná se zejména o okruhy CPAP pro ventilační podporu novorozence nebo pohyb personálu před monitorem. V takovém případě dochází k chybám rozpoznání, kdy jsou buď odečteny nesprávné hodnoty, nebo CNN nerozezná žádnou číselnou hodnotu a vyhodnotí výsledek jako 0. V případě částečného zakrytí pak závisí na velikosti zakryté plochy. Rozpoznávání čísel neuronovou sítí je založeno na matematických algoritmech a i přes možnost učení není možné vyhodnotit některá data, která člověk vyhodnotit dokáže. Lidské vnímání, a to i díky principu amodálního doplnění, vychází kromě vizuálního podmětu z informací získaných zkušeností a znalostí širších souvislostí. Umí např. vyhodnotit číslo na obrázku 6.1, nebo na obrázku 6.2, kde je zakryta celá první číslice, nicméně na základě zkušenosti je evidentní, že došlo k posunutí pozic číslic a číslo na obrázku bude tedy trojciferné. Na základě znalostí o hodnotách HR lze pak předpokládat, že první číslice bude 1. [63]



Obrázek 6.1: Ukázka překážky ve videozáznamu



Obrázek 6.2: Ukázka překážky ve videozáznamu

Pro automatické rozpoznávání je klíčové, na které z pozic je číslice zakrytá. Pokud se jedná o částečné zakrytí jako např. v záznamu 3 (viz tabulka 5.9), kde je zakrytá pouze poslední číslice trojčíferného čísla, lze stále identifikovat první dvě číslice. Model rozpoznal, že se jedná o trojčíferné číslo a nahradil tak poslední nečitelnou číslici hodnotou 0 (např. místo hodnoty HR 141 bylo rozpoznáno 140). Takto vzniklá chyba (maximální velikost chyby je 9 bpm) nemá při procesu stabilizace dopad na volbu použité intervence a při následné interpretaci záznamu není podstatná. Naopak zásadní chyba může nastat při překrytí první číslice, kdy např. v záznamu 2 je místo hodnoty HR 122 bpm detekováno pouze 22 bpm. V takovém případě záleží i na době překrytí číslice. Pokud se jedná o krátký časový úsek, po který jsou hodnoty rozpoznávány chybně, může lékař předpokládat chybnou detekci, nebo výpadek signálu. Při delším trvání by ale tyto chyby mohly vést k nesprávným závěrům o průběhu stabilizace a videozáznam je nutné zkontrolovat v těchto časových úsecích vizuálně. Hodnoty životních funkcí jako HR a SpO₂ není možné predikovat, není tedy ani možné předvídat, jakým způsobem se trend hodnot bude vyvíjet. [15]

Možné vylepšení webové aplikace pro snížení výskytu náhodných chyb by bylo použití filtru, který by porovnával několik po sobě jdoucích hodnot a při rozdílu vyšším než je stanovený práh by hodnotu považoval za chybnou a nahradil by jí průměrem těchto okolních hodnot. Tato úprava by ale nevyřešila situaci, kdy je jedna číslice zakrytá delší dobu (např. jako u záznamu 1 u hodnot HR).

Automatická detekce hodnot HR a SpO₂ ze záznamů stabilizace redukuje jednotvárnou a rutinní práci při sběru dat a umožňuje lékařům se zaměřit na odborné vyhodnocení průběhu stabilizace a resuscitace extrémně nezralých novorozenců na porodním sále.

7 Závěr

Výsledkem práce je zefektivnění procesu získávání patientských dat z videozáznamů procesu stabilizace a resuscitace extrémně nezralých novorozenců na porodním sále. Současný proces získávání dat spočívá v procházení těchto videozáznamů a ručním vypisování jednotlivých hodnot životních funkcí novorozence v daný čas. Jedná se o pro lékaře zdlouhavý a neefektivní proces, který je ovšem nezbytný pro analýzu postupu a následné využití dat ve výzkumu a stanovení efektivních postupů při stabilizaci extrémně nezralých novorozenců.

Byla vytvořena webová aplikace, která umožňuje automatické rozpoznávání číselných hodnot srdeční frekvence HR a saturace krve kyslíkem SpO₂ pomocí konvoluční neuronové sítě z monitoru životních funkcí s možností změny frekvence odečítání těchto číselných hodnot. Aplikace vykresluje hodnoty HR a SpO₂ do grafu v závislosti na čase od porodu. Data je možné stáhnout v obecně čitelném datovém formátu CSV. Řešení bylo koncipováno přesně pro potřeby GPK VNF v Praze a je primárně zaměřené na retrospektivní vyhodnocování videozáznamů z resuscitačních lůžek v GPK, u kterých jsou neměnné parametry jako snímkovací frekvence, kvalita a kompozice.

Funkčnost webové aplikace byla ověřena za pomoci simulátoru životních funkcí připojenému k monitoru životních funkcí. Součástí práce je vyhodnocení tří záznamů stabilizace novorozenců na porodním sále. Průměrná přesnost rozeznávání hodnot byla při frekvenci snímání po 1 sekundě pro hodnoty HR 96,45 % a pro SpO₂ 93,13 %. Celkově je přesnost ovlivněna především čitelností hodnot HR a SpO₂ po celou dobu záznamu. Nižší přesnost hodnot SpO₂ je způsobena především blikáním pole s touto hodnotou. Možnosti úprav webové aplikace pro zvýšení přesnosti jsou konkretizovány v diskuzi.

Další možnou budoucí úpravou aplikace je její rozšíření o automatickou detekci polohy polí s hodnotami životních funkcí a automatický výpočet snímkovací frekvence. To by umožňovalo využít aplikaci i pro videozáznamy z dalších zdravotnických zařízeních.

Seznam použité literatury

- [1] ŠANDA, Robert, 2019. Pohyb obyvatelstva - rok 2018. Český statistický úřad [online]. 21.3.2019 [cit. 2019-11-24]. Dostupné z: <https://www.czso.cz/csu/czso/cris/pohyb-obyvatelstva-rok-2018>
- [2] ŠTEMBERA, Zdeněk. Historie české perinatologie. Praha: Maxdorf, 2004. ISBN 9788073450212
- [3] Resuscitace a stabilizace extrémně nezralých novorozenců., 2018. Praha. Dostupné také z: <https://dspace.cuni.cz/bitstream/handle/20.500.11956/105483/140072306.pdf?sequence=1&isAllowed=y>. Disertační práce. Univerzita Karlova. Vedoucí práce Prof. MUDr. Richard Plavka, CSc.
- [4] WYLLIE, Jonathan, Jos BRUINENBERG, Charles Christoph ROEHR, Mario RÜDIGER, Daniele TREVISANUTO a Berndt URLESBERGER, 2015. European Resuscitation Council Guidelines for Resuscitation 2015. Resuscitation [online]. 95, 249-263 [cit. 2020-04-09]. DOI: 10.1016/j.resuscitation.2015.07.029. ISSN 03009572. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S030095721500341X>
- [5] KNOBEL, Robin a Diane HOLDITCH-DAVIS, 2007. Thermoregulation and Heat Loss Prevention After Birth and During Neonatal Intensive-Care Unit Stabilization of Extremely Low-Birthweight Infants. Journal of Obstetric, Gynecologic & Neonatal Nursing [online]. 36(3), 280-287 [cit. 2020-04-09]. DOI: 10.1111/j.1552-6909.2007.00149.x. ISSN 08842175. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S088421751530040X>
- [6] Finn D, Boylan GB, Ryan CA, Dempsey EM. Enhanced monitoring of the preterm infant during stabilization in the delivery room. Front Pediatr. 2016; 4:30
- [7] Carbine DN, Finer NN, Knodel E, Rich W. Video recording as a means of evaluating neonatal resuscitation performance. Pediatrics. 2000; 106(4): 654–8.
- [8] PLAVKA, R., Česká neonatologie "na špičce." A co dál?: Malý průvodce vývojem některých ukazatelů kvality péče o novorozence v uplynulých 15 letech v České republice [online]. Gynekologicko porodnická klinika VFN a 1.LF UK Praha, 1-7 [cit. 2019-11-24]. Dostupné z: <http://www.neonatology.cz/upload/neonatalogie.web360.cz/ceskaneonatalogie.pdf>

- [9] Seznam perinatologických center intenzivní a intermediární péče a kontakt na jejich Neonatologická pracoviště., 2011. Česká neonatologická společnost [online]. [cit. 2019-11-24]. Dostupné z: <http://www.neonatology.cz/neonatologicka-centra>
- [10] HADAŠ, Libor, Kristína KIČOVÁ a Anton VIK, 2016. Skripta neonatologie [online]. Praha [cit. 2020-04-08]. Dostupné z: <http://avikspace.xf.cz/web/medicine.html>. Univerzita Karlova v Praze.
- [11] DORT, Jiří, Eva DORTOVÁ a Petr JEHLIČKA. Neonatologie. 2., upr. vyd. Praha: Karolinum, 2013. ISBN 978-802-4622-538.
- [12] ROZTOČIL, Aleš. Moderní porodnictví. 2., přepracované a doplněné vydání. Praha: Grada Publishing, 2017. ISBN 978-802-4757-537.
- [13] V Česku vzrostl počet předčasných porodů. Může za to asistovaná reprodukce i životní styl rodiček. Česká televize [online]. 6.3.2019 [cit. 2018-06-28]. Dostupné z: <https://ct24.ceskatelevize.cz/domaci/2410438-v-cesku-prudce-roste-pocet-predcasnych-porodu-jeza-tim-hlavne-asistovana-reprodukce>
- [14] GOLDENBERG, Robert L, Jennifer F CULHANE, Jay D IAMS a Roberto ROMERO. Epidemiology and causes of preterm birth. The Lancet [online]. 2008, 371(9606), 75-84 [cit. 2018-06-28]. DOI: 10.1016/S0140-6736(08)60074-4. ISSN 01406736. Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S0140673608600744>
- [15] STRAŇÁK, Zbyněk, 2015. <https://www.ipvz.cz/seznam-souboru/2359-resuscitace-a-post-resuscitacni-pece-o-novorozence-pro-lekare-i-nelekarske-profese.pdf>: Resuscitační a post-resuscitační péče o novorozence [online]. Praha [cit. 2020-04-21]. Dostupné z: <https://www.ipvz.cz/seznam-souboru/2359-resuscitace-a-post-resuscitacni-pece-o-novorozence-pro-lekare-i-nelekarske-profese.pdf>
- [16] Urgentní medicína: Časopis pro neodkladnou lékařskou péči [online], 2015. Mimořádné vydání 2015. MEDIPRAX CB [cit. 2020-04-20]. ISSN 1212-1924. Dostupné z: https://cprguidelines.eu/sites/573c777f5e61585a053d7ba5/content_entry573c77e35e61585a053d7baf/57e192854c84860895c389dd/files/DOPORUC_ENE__POSTUP_Y_PRO_RESUSCITACI-ERC2015_Souhrn_doporuc_eni__CZE.pdf 6
- [17] KANESHIRO, Neil, Apgar score. Medline Plus [online]. 11.2018 [cit. 2020-04-21]. Dostupné z: KANESHIRO, Neil, Apgar score. Medline Plus [online]. 11.2018 [cit. 2020-04-21]. Dostupné z: <https://medlineplus.gov/ency/article/003402.htm> KANESHIRO, Neil, Apgar score. Medline Plus [online]. 11.2018 [cit. 2020-04-21]. Dostupné z: <https://medlineplus.gov/ency/article/003402.htm>

- [18] SINEX, James E, 1999. Pulse oximetry: Principles and limitations. *The American Journal of Emergency Medicine* [online]. 17(1), 59-66 [cit. 2020-04-09]. DOI: 10.1016/S0735-6757(99)90019-0. ISSN 07356757. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S0735675799900190>
- [19] JUBRAN, Amal, 2004. Pulse oximetry. *Intensive Care Medicine* [online]. 30(11), 2017-2020 [cit. 2020-04-21]. DOI: 10.1007/s00134-004-2399-x. ISSN 0342-4642. Dostupné z: <http://link.springer.com/10.1007/s00134-004-2399-x>
- [20] Assessments for Newborn Babies, Stanford Children's Health [online]. [cit. 2020-04-21]. Dostupné z: <https://www.stanfordchildrens.org/en/topic/default?id=assessments-for-newborn-babies-90-P02336>
- [21] KOZAR, Marek, Ingrid TONHAJZEROVA, Michal MESTANIK, Katarina MATASOVA, Mirko ZIBOLEN, Andrea CALKOVSKA a Kamil JAVORKA, 2018. Heart rate variability in healthy term newborns is related to delivery mode: a prospective observational study. *BMC Pregnancy and Childbirth* [online]. 18(1) [cit. 2020-04-09]. DOI: 10.1186/s12884-018-1900-4. ISSN 1471-2393. Dostupné z: <https://bmcpregnancychildbirth.biomedcentral.com/articles/10.1186/s12884-018-1900-4>
- [22] DAWSON, J., C. KAMLIN, C. WONG, et al., 2010. Changes in heart rate in the first minutes after birth. *Archives of Disease in Childhood - Fetal and Neonatal Edition* [online]. 95(3), F177-F181 [cit. 2020-04-09]. DOI: 10.1136/adc.2009.169102. ISSN 1359-2998. Dostupné z: <http://fn.bmj.com/cgi/doi/10.1136/adc.2009.169102>
- [23] DAWSON, J. A., C. O. F. KAMLIN, M. VENTO, C. WONG, T. J. COLE, S. M. DONATH, P. G. DAVIS a C. J. MORLEY, 2010. Defining the Reference Range for Oxygen Saturation for Infants After Birth. *PEDIATRICS* [online]. 125(6), e1340-e1347 [cit. 2020-04-09]. DOI: 10.1542/peds.2009-1510. ISSN 0031-4005. Dostupné z: <http://pediatrics.aappublications.org/cgi/doi/10.1542/peds.2009-1510>
- [24] Katheria A, Rich W, Finer N. Electrocardiogram provides a continuous heart rate faster than oximetry during neonatal resuscitation. *Pediatrics*. 2012; 130(5): e1177–81.
- [25] Kamlin CO, O'Donnell CP, Everest NJ, Davis PG, Morley CJ. Accuracy of clinical assessment of infant heart rate in the delivery room. *Resuscitation*. 2006; 71(3): 319–21
- [26] Wyllie J, Perlman JM, Kattwinkel J, Wyckoff MH, Aziz K, Guinsburg R, et al. Part 7: Neonatal resuscitation: 2015 International Consensus on Cardiopulmonary Resuscitation and Emergency Cardiovascular Care Science with Treatment Recommendations. *Resuscitation*. 2015; 95: e169–201.

- [27] Wyckoff MH, Aziz K, Escobedo MB, Kapadia VS, Kattwinkel J, Perlman JM, et al. Part 13: Neonatal Resuscitation: 2015 American Heart Association Guidelines Update for Cardiopulmonary Resuscitation and Emergency Cardiovascular Care. *Circulation*. 2015; 132(18 Suppl 2): S543–60
- [28] Wyckoff MH, Aziz K, Escobedo MB, Kapadia VS, Kattwinkel J, Perlman JM, et al. Part 13: Neonatal Resuscitation: 2015 American Heart Association Guidelines Update for Cardiopulmonary Resuscitation and Emergency Cardiovascular Care. *Circulation*. 2015; 132(18 Suppl 2): S543–60.
- [29] Phibbs CS, Baker LC, Caughey AB, Danielsen B, Schmitt SK, Phibbs RH. Level and volume of neonatal intensive care and mortality in very–low–birth–weight infants. *N Engl J Med*. 2007; 356(21): 2165–75.
- [30] VOLNÁ, Eva. *Neuronové sítě 1. Druhé*. Ostrava: Ostravská univerzita v Ostravě, 2008.
- [31] MAŘÍK, Vladimír, Olga ŠTĚPÁNKOVÁ a Jiří LAŽANSKÝ. *Umělá inteligence*. Praha: Academia, 1993. ISBN 80-200-0496-3.
- [32] NICHOLSON, Chris, *A Beginner's Guide to Neural Networks and Deep Learning*. Pathmind [online]. [cit. 2020-04-15]. Dostupné z: <https://pathmind.com/wiki/neural-network>
- [33] DESHPANDE, Mohit, *Perceptrons: The First Neural Networks* [online]. 12/09/2017 [cit. 2020-04-15]. Dostupné z: <https://pythonmachinelearning.pro/perceptrons-the-first-neural-networks/>
- [34] *Neuronové sítě* [online], [cit. 2020-04-15]. Dostupné z: https://is.mendelu.cz/eknihovna/opory/zobraz_cast.pl?cast=21471
- [35] KVASNIČKA, V. a kol. *Úvod do teórie neurónových sietí*. Bratislava: IRIS, 1997. 285 s. ISBN 80- 88778-30-1
- [36] KRAJČA, Vladimír a Václava PIORECKÁ. *Neuronové sítě a Backpropagation: Algoritmy umělé inteligence* [online]. 2019 [cit. 2020-05-01]. Dostupné z: https://predmety.fbmi.cvut.cz/sites/default/files/predmet/1746/prednasky/17PMBA_UI_20190415_152527_eb2529d2e5a028691196b3a1a648354f.pdf
- [37] YIU, Tony, *Understanding Neural Networks: We Explore How Neural Networks Function in Order to Build an Intuitive Understanding of Deep Learning* [online]. 2.6.2019 [cit. 2020-04-15]. Dostupné z: <https://towardsdatascience.com/understanding-neural-networks-19020b758230>

- [38] Institut biostatistiky a analýz Lékařské fakulty Masarykovy univerzity, Koncept umělé neuronové sítě [online]. [cit. 2020-04-15]. Dostupné z: <https://portal.matematickabiologie.cz/index.php?pg=analyza-a-hodnoceni-biologickych-dat--umela-intelligence--neuronove-site-jednotlivy-neuron--uvod-do-neuronovych-siti--koncept-umele-neuronove-site>
- [39] Institut biostatistiky a analýz Lékařské fakulty Masarykovy univerzity, Principy učení neuronu obecně [online]. [cit. 2020-04-15]. Dostupné z: <https://portal.matematickabiologie.cz/index.php?pg=analyza-a-hodnoceni-biologickych-dat--umela-intelligence--neuronove-site-jednotlivy-neuron--adaptacni-dynamika-neuronu--principy-uceni-neuronu-obecne>
- [40] CAMACHO, Cezanne, Convolutional Neural Networks [online]. 3.6.2018 [cit. 2020-04-15]. Dostupné z: https://cezannec.github.io/Convolutional_Neural_Networks/
- [41] ŠTANGLOVÁ, Tereza. Detekce specifických objektů v digitálním snímku pro potřeby určení druhu obsahu scény. Plzeň, 2017. Diplomová práce. Západočeská univerzita v Plzni. ,<https://ujjwalkarn.me/2016/08/11/>
- [42] RATH, Sovit, Convolutional Neural Network Architectures and Variants [online]. 23.6.2019 [cit. 2020-04-15]. Dostupné z: <https://debuggercafe.com/convolutional-neural-network-architectures-and-variants/>
- [43] Institut biostatistiky a analýz Lékařské fakulty Masarykovy univerzity, Učení s učitelem [online]. [cit. 2020-04-15]. Dostupné z: <https://portal.matematickabiologie.cz/index.php?pg=analyza-a-hodnoceni-biologickych-dat--umela-intelligence--neuronove-site-jednotlivy-neuron--adaptacni-dynamika-neuronu--uceni-s-ucitelem>
- [44] Institut biostatistiky a analýz Lékařské fakulty Masarykovy univerzity, Učení bez učitele [online]. [cit. 2020-04-15]. Dostupné z: <https://portal.matematickabiologie.cz/index.php?pg=analyza-a-hodnoceni-biologickych-dat--umela-intelligence--neuronove-site-jednotlivy-neuron--adaptacni-dynamika-neuronu--uceni-bez-ucitele>
- [45] VOLNÁ, Eva. Neuronová sítě I [online]. Ostrava: Ostravská univerzita v ostravě, 2008 [cit. 2020-05-01]. Dostupné z: https://www1.osu.cz/~volna/Neuronove_site_skripta.pdf
- [46] GOLKARIEN, Hadi, Applications of Computer Vision in Healthcare [online]. 7.2.2019 [cit. 2020-04-20]. Dostupné z: <https://medium.com/optima-ai/applications-of-computer-vision-in-healthcare-5651208b3539>

- [47] SUZUKI, Kenji, 2011. Artificial neural networks - Methodological advances and Biomedical Applications [online]. Rijeka: InTech [cit. 2020-04-20]. Dostupné z: https://books.google.cz/books?hl=cs&lr=&id=JuaODwAAQBAJ&oi=fnd&pg=PR11&dq=neural+networks+in+biomedical+applications&ots=XUnNUQbTYf&sig=-bSc7V0JV4VXe1b546J_Dgt2WVQ&redir_esc=y#v=onepage&q=neural%20networks%20in%20biomedical%20applications&f=false
- [48] RONNEBERGER, Olaf, Philipp FISCHER a Thomas BROX, 2015. U-Net: Convolutional Networks for Biomedical Image Segmentation.
- [49] NAVAB, Nassir, Joachim HORNEGGER, William M. WELLS a Alejandro F. FRANGI, ed. Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015 [online]. Cham: Springer International Publishing, 2015-11-18 [cit. 2020-04-20]. Lecture Notes in Computer Science. DOI: 10.1007/978-3-319-24574-4_28. ISBN 978-3-319-24573-7. Dostupné z: http://link.springer.com/10.1007/978-3-319-24574-4_28
- [50] CHAN, K.Y., S.H. LING, T.S. DILLON a H.T. NGUYEN, 2011. Diagnosis of hypoglycemic episodes using a neural network based rule discovery system. Expert Systems with Applications [online]. 38(8), 9799-9808 [cit. 2020-04-20]. DOI: 10.1016/j.eswa.2011.02.020. ISSN 09574174. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S0957417411002260>
- [51] RAGHAVENDRA, U, Hamido FUJITA, Sulatha V BHANDARY, Anjan GUDIGAR, Jen Hong TAN a U Rajendra ACHARYA, 2018. Deep convolution neural network for accurate diagnosis of glaucoma using digital fundus images. Information Sciences [online]. 441, 41-49 [cit. 2020-04-20]. DOI: 10.1016/j.ins.2018.01.051. ISSN 00200255. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S0020025518300744>
- [52] SUN, Wenqing, Tzu-Liang (Bill) TSENG, Jianying ZHANG a Wei QIAN, 2017. Enhancing deep convolutional neural network scheme for breast cancer diagnosis with unlabeled data. Computerized Medical Imaging and Graphics [online]. 57, 4-9 [cit. 2020-04-20]. DOI: 10.1016/j.compmedimag.2016.07.004. ISSN 08956111. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S0895611116300696>
- [53] METWALLY, Najla' Fathi, Eman Khaled ABUSHAREKH a Sami ABU-NASER, Diagnosis of Hepatitis Virus Using Artificial Neural Network [online]. 2018 [cit. 2020-04-20]. Dostupné z: <http://dstore.alazhar.edu.ps/xmlui/handle/123456789/361>
- [54] JIANG, Fei, Yong JIANG, Hui ZHI, et al., 2017. Artificial intelligence in healthcare: past, present and future. Stroke and Vascular Neurology [online]. 2(4), 230-243 [cit. 2020-04-20]. DOI: 10.1136/svn-2017-000101. ISSN 2059-8688. Dostupné z: <http://svn.bmj.com/cgi/doi/10.1136/svn-2017-000101>

- [55] Arterys: About us [online], 2019 [cit. 2020-04-20]. Dostupné z: <https://www.arterys.com/about-us>
- [56] BENIWAL, Himanshu. Handwritten Digit Recognition using Machine Learning [online]. 2018 [cit. 2020-05-01]. Dostupné z: <https://medium.com/@himanshubeniwal/handwritten-digit-recognition-using-machine-learning-ad30562a9b64>
- [57] SHAMIM, S M, Mohammad Badrul Alam MIAH, Angona SARKER, Masud RANA a Abdullah Al JOBAIR, 2018. Handwritten Digit Recognition Using Machine Learning Algorithms. Indonesian Journal of Science and Technology [online]. 3(1), 29-39 [cit. 2020-05-03]. DOI: 10.17509/ijost.v3i1.10795. ISSN 2527-8045. Dostupné z: <http://ejournal.upi.edu/index.php/ijost/article/view/10795>
- [58] HAMED, Fathi a Amna ELNJAR. An algorithm to Recognize Number in Image: Based on Statistical Image Analysis. Proceedings Engineering & Technology [online]. 2013, (2), 50-55 [cit. 2020-05-01]. Dostupné z: http://ipco-co.com/PET_Journal/presented%20papers/125.pdf
- [59] FRID-ADAR, Maayan, Eyal KLANG, Michal AMITAI, Jacob GOLDBERGER a Hayit GREENSPAN. Synthetic data augmentation using GAN for improved liver lesion classification. In: 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018) [online]. IEEE, 2018, 2018, s. 289-293 [cit. 2020-05-01]. DOI: 10.1109/ISBI.2018.8363576. ISBN 978-1-5386-3636-7. Dostupné z: <https://ieeexplore.ieee.org/document/8363576/>
- [60] EVA, Škorničková, Co považuje GDPR za osobní údaje. GDPR [online]. [cit. 2020-05-01]. Dostupné z: <https://www.gdpr.cz/gdpr/osobni-udaje/>
- [61] HOSSEINI, Hossein, Baicen XIAO, Mayoore JAISWAL a Radha POOVENDRAN. On the Limitation of Convolutional Neural Networks in Recognizing Negative Images. In: 2017 16th IEEE International Conference on Machine Learning and Applications (ICMLA) [online]. IEEE, 2017, 2017, s. 352-358 [cit. 2020-05-01]. DOI: 10.1109/ICMLA.2017.0-136. ISBN 978-1-5386-1418-1. Dostupné z: <http://ieeexplore.ieee.org/document/8260656/>
- [62] SHAMIM, S M, Mohammad Badrul Alam MIAH, Angona SARKER, Masud RANA a Abdullah Al JOBAIR. Handwritten Digit Recognition Using Machine Learning Algorithms. Indonesian Journal of Science and Technology [online]. 2018, 3(1), 29-39 [cit. 2020-05-01]. DOI: 10.17509/ijost.v3i1.10795. ISSN 2527-8045. Dostupné z: <http://ejournal.upi.edu/index.php/ijost/article/view/10795>

[63] MICHOTTE, Albert. *Michottes experimental phenomenology of perception* [online]. 13. New York: Routledge, 2014 [cit. 2020-05-01]. ISBN 978-1-315-88997-9. Dostupné z:
https://books.google.cz/books?hl=cs&lr=&id=nbREAQAAQBAJ&oi=fnd&pg=PA140&dq=Amodal+completion&ots=0vTnK5yFtO&sig=Ree8XLsSNvxsTk3wxRQYeKZ9t14&redir_esc=y#v=onepage&q=Amodal%20completion&f=false

Příloha A: Obsah příloženého CD

- Klíčová slova v českém jazyce
- Klíčová slova v anglickém jazyce
- Abstrakt v českém jazyce
- Abstrakt v anglickém jazyce
- Zadání diplomové práce
- Diplomová práce
- Zdrojový kód
- Ukázkové video