

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

DIPLOMOVÁ PRÁCE

Brno, 2022

Bc. Hana Šandová



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

ALGORITMY PRO ZLEPŠENÍ DETEKCE VYBRANÝCH ARYTMIÍ V EKG

ALGORITHMS FOR IMPROVING THE DETECTION OF SELECTED CARDIAC ARRHYTHMIAS

DIPLOMOVÁ PRÁCE

MASTER'S THESIS

AUTOR PRÁCE

AUTHOR

Bc. Hana Šandová

VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Petra Novotná

BRNO 2022

Diplomová práce

magisterský navazující studijní program **Biomedicínské inženýrství a bioinformatika**

Ústav biomedicínského inženýrství

Studentka: Bc. Hana Šandová

ID: 203204

Ročník: 2

Akademický rok: 2021/22

NÁZEV TÉMATU:

Algoritmy pro zlepšení detekce vybraných arytmií v EKG

POKYNY PRO VYPRACOVÁNÍ:

1) Proved'te literární rešerši v oblasti detekce arytmií v EKG se zaměřením na metody automatické detekce s využitím hlubokých neuronových sítí. Seznamte se s metodikami obohacování databází určených pro učení hlubokých neuronových sítí. 2) Seznamte se s databází EKG signálů dostupnou na ÚBMI. Signály předzpracujte pro použití při učení neuronových sítí a proved'te výběr vhodných augmentačních metod. 3) Navrhněte alespoň 2 algoritmy s různými přístupy pro zlepšení detekce arytmií v závislosti na jejím typu. Algoritmy realizujte v jazyce Python nebo jiném programovém prostředí. 4) Realizované algoritmy optimalizujte z pohledu klasifikačního zadání (1 arytmie, více arytmií, atp.). 5) Dosažené výsledky interpretujte z pohledu využití neuronových sítí i fyziologického. Diskutujte výhody a nevýhody navržených postupů. 6) Dosažené výsledky porovnejte s publikovanými výsledky z předešlých studií.

DOPORUČENÁ LITERATURA:

- [1] Y.-Y. JO, J.-M. KWON, K.-H. JEON, et al. Detection and classification of arrhythmia using an explainable deep learning model. Journal of Electrocardiology, 2021, vol. 67, pp. 124-132.
- [2] Pan, Qing & Li, Xinyi & Fang, Luping. (2020). Data Augmentation for Deep Learning-Based ECG Analysis. 10.1007/978-981-15-3824-7_6.

Termín zadání: 7.2.2022

Termín odevzdání: 20.5.2022

Vedoucí práce: Ing. Petra Novotná

prof. Ing. Ivo Provazník, Ph.D.
předseda rady studijního programu

UPOZORNĚNÍ:

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

ABSTRAKT

Práce se zabývá navyšováním datových sad arytmií v EKG, které bývají v databázích méně často zastoupené. Teoretická část je věnována literární rešerši odborných prací, které se zabývají klasifikátory srdečních arytmií s využitím hlubokého učení a augmentací EKG signálů. V praktické části byly realizovány generátory šumu, které by po přičtení do reálně změřených signálů mohly obohatit datovou sadu. Také byla realizována metoda pro augmentaci flutteru síní. Byly vytvořeny funkce, které uměle vytvářejí signály napodobující atrioventikulární blokády II. a III. stupně. Nakonec byla snaha generovat atrioventikulární blokády II. stupně pomocí generativních kompetitivních sítí (GAN). Úspěšnost augmentace byla hodnocena přidáním různě kombinovaných syntetických dat do trénovacích množin pro EKG klasifikátor v podobě hluboké neuronové sítě.

KLÍČOVÁ SLOVA

Augmentace dat, EKG, srdeční arytmie, hluboké učení, GAN

ABSTRACT

The work deals with the generation of ECG arrhythmias that are underrepresented in databases. The theoretical part of the thesis is devoted to a literature search of academic publications that deal with the classification of arrhythmia by using deep learning and data augmentation methods for ECG. The practical part of the thesis deals with noise generator, because adding noise to signals could make the dataset richer. Functions for augmentation of atrial flutter and 3rd and 2nd atrioventricular block were created. It has been tried generation of 2nd atrioventricular block using generative adversarial networks (GAN). Deep learning-based ECG classifiers were used for evaluating the efficiency of the proposed technique in generating synthetic ECG data.

KEYWORDS

Data augmentation, ECG, heart arrhythmia, deep learning, GAN

ŠANDOVÁ, Hana. *Algoritmy pro zlepšení detekce vybraných arytmií v EKG*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství, 2022, 76 s. Diplomová práce. Vedoucí práce: Ing. Petra Novotná

Prohlášení autora o původnosti díla

Jméno a příjmení autora: Bc. Hana Šandová
VUT ID autora: 203204
Typ práce: Diplomová práce
Akademický rok: 2021/22
Téma závěrečné práce: Algoritmy pro zlepšení detekce vybraných arytmií v EKG

Prohlašuji, že svou závěrečnou práci jsem vypracovala samostatně pod vedením vedoucí/ho závěrečné práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autorka uvedené závěrečné práce dále prohlašuji, že v souvislosti s vytvořením této závěrečné práce jsem neporušila autorská práva třetích osob, zejména jsem nezasáhla nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědoma následků porušení ustanovení § 11 a následujících autorského 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, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Brno
.....
podpis autorky*

*Autor podepisuje pouze v tištěné verzi.

PODĚKOVÁNÍ

Ráda bych poděkovala vedoucí diplomové práce paní Ing. Petře Novotné za odborné vedení, konzultace, trpělivost a podnětné návrhy k práci.

Obsah

Úvod	13
1 Hluboké neuronové sítě	14
1.1 Konvoluční neuronové sítě	14
1.2 Rekurentní neuronové sítě	15
1.3 Reziduální sítě	16
1.4 Interpretovatelný model hlubokého učení	17
1.5 Shrnutí	17
2 Generativní kompetitivní sítě	18
2.1 Triky pro trénování GAN	19
3 Augmentace dat	21
3.1 Augmentace obrazových dat	21
3.2 Augmentace 1D signálů	22
3.3 Augmentace pomocí GAN	23
3.4 Shrnutí	29
4 Data	30
4.1 Popis arytmií, na které bude zaměřena augmentace	30
4.1.1 Atrioventrikulární blokáda II. stupně	30
4.1.2 Atrioventrikulární blokáda III. stupně	32
4.1.3 Flutter síní	33
4.2 Filtrace dat	34
5 Augmentace dat přidáním šumu	39
5.1 Síťové rušení	39
5.2 Kolísání nulové izolinie	39
5.3 Elektromyografické rušení	40
5.4 Aplikace šumů na signál	40
6 Augmentace flutteru síní	42
7 Augmentace atrioventrikulární blokády II. stupně	44
7.1 Augmentace AV blokády typu Mobitz I	44
7.2 Augmentace AV blokády typu Mobitz II	46
8 Augmentace atrioventrikulární blokády III. stupně	49

9	Augmentace AV blokády II. stupně pomocí GAN	51
10	Vyhodnocení úspěšnosti augmentace	57
10.1	Vyhodnocení úspěšnosti augmentace flutteru síní z pohledu neuronových sítí	57
10.2	Vyhodnocení úspěšnosti augmentace atrioventrikulárních blokády z pohledu neuronových sítí	61
10.3	Úspěšnost augmentace z fyziologického pohledu	66
10.4	Výhody a nevýhody navržených postupů augmentace	66
10.5	Srovnání úspěšnosti augmentace s dostupnou literaturou	67
	Závěr	69
	Literatura	71
	Seznam symbolů a zkratk	76

Seznam obrázků

3.1	Architektury GAN sítí z článku [29]	25
3.2	Schéma možných výsledků po aplikování vrstvy fázového míchání pro 4 příznakové mapy a $n=1$	26
3.3	Ukázka generovaného EKG sítí Pulse2Pulse	26
3.4	Ukázka generovaného EKG sítí z článku [30]	27
3.5	Ukázka generovaného EKG sítí z článku [31]	28
3.6	Ukázka generované fibrilace síní sítí z článku [32]	29
4.1	Absolutní a procentuální zastoupení EKG záznamů s různými pato- logickými projevy v databázi	31
4.2	Atrioventrikulární blokáda II. stupně typu Mobitz I	32
4.3	Atrioventrikulární blokáda II. stupně typu Mobitz II	33
4.4	Atrioventrikulární blokáda III. stupně	33
4.5	Flutter síní	34
4.6	Amplitudová a fázová frekvenční charakteristika Butterworthova fil- tru, který byl použit pro filtraci driftu v EKG	35
4.7	Porovnání zkreslení tvaru signálu vlivem nelineární fázové charakte- ristiky	35
4.8	Výsledek filtrace kolísání nulové izolinie	36
4.9	Třístupňová dyadická vlnková dekompozice s decimací	37
4.10	Princip Wienerovské vlnkové filtrace metodou pilotního odhadu uži- tečného signálu	37
4.11	Výsledek filtrace elektromyografického rušení	38
5.1	Aplikace vygenerovaných šumů na vyfiltrovaný signál	41
6.1	Výsledek augmentace flutteru síní permutací úseků signálu	43
7.1	EKG křivka s vyznačenými významnými body	45
7.2	EKG křivka s vyznačenými významnými body určenými pomocí funkcí <i>ecg_peaks</i> a <i>ecg_delineate</i> z knihovny <i>neurokit2</i>	46
7.3	Augmentovaná AV blokáda II. stupně typu Mobitz I a původní sinu- sový rytmus	46
7.4	Augmentovaná AV blokáda II. stupně typu Mobitz II a původní si- nusový rytmus	48
8.1	Augmentovaná AV blokáda III. stupně a původní sinusový rytmus	50
9.1	Blokové schéma sítí diskriminátoru a generátoru	53
9.2	Ukázka výstupů z generátoru po učení po dobu 50, 70 a 120 epoch při použití Wassersteinovy vzdálenosti s ořezáváním vah	54
9.3	Ukázka výstupů z generátoru po učení po dobu 50, 100, 130, 140 a 335 epoch při použití kritériální funkce v podobě binární křížové entropie	55

9.4	Ukázka 3 výstupů z generátoru po 80. epoše učení pro 3 různé náhodné vstupní šumy	56
10.1	Matice záměn pro více nehomogenní datasety: K, M1 a M2	61
10.2	Matice záměn pro AVB datasety obsahující pouze generované AVB2 a AVB3	66

Seznam tabulek

1.1	Rozdělení život neohrožujících arytmii do 5 skupin podle americké organizace <i>Association for the Advancement of Medical Instrumentation</i> (AMMI)	16
10.1	Počty EKG záznamů v klasifikovaných skupinách v jednotlivých množinách pro klasifikátor FL	57
10.2	Výsledná F1 skóre všech kategorií a jejich průměr pro testovací množinu při učení různými trénovacími datasety pro klasifikátor FL . . .	59
10.3	Počty EKG záznamů v klasifikovaných skupinách v jednotlivých množinách pro zmenšenou databázi	59
10.4	Výsledná F1 skóre všech kategorií a jejich průměr pro testovací množinu při učení různými trénovacími datasety pro více nehomogenní databázi pro klasifikátor FL	60
10.5	Počty EKG záznamů v klasifikovaných skupinách v jednotlivých množinách pro klasifikaci AVB	62
10.6	Počty a typy augmentací EKG záznamů kategorií AVB3 a AVB2 v rozdílných trénovacích množinách	63
10.7	Výsledná F1 skóre všech kategorií a jejich průměr pro testovací množinu při učení různými trénovacími datasety pro klasifikátor AVB . .	64
10.8	Rozdíly F1 skóre kategorií AVB2 a AVB3 augmentovaných datasetů oproti nehomogenní a nakopírované množině	65

Úvod

Světová zdravotnická organizace (WHO) uvádí, že více než polovina úmrtí v Evropě je způsobena kardiovaskulárními onemocněními, převážně srdečním infarktem a mrtvicí. Jako prevence se doporučuje zdravá strava, fyzická aktivita a vyhýbat se kouření. Neméně důležité jsou však také lékařské prohlídky.

Nejčastějším vyšetřením srdce je měření jeho elektrické aktivity, tzv. elektrokardiogramu (EKG). Pacienti mohou trpět arytmií, tedy poruchou srdečního rytmu, která není trvalého rázu. V tomto případě není moc pravděpodobné, že by byla zachycena na krátkodobě měřeném EKG u lékaře v ambulanci.

Proto je nutné pacienta měřit dlouhodoběji s využitím tzv. EKG holterů, které pacient může nosit při běžné činnosti. Tak je možné zaznamenávat srdeční aktivitu pacienta 24 hodin denně po dobu několika dnů až týdnů. Tímto však vzniká velké množství dat, jejichž hodnocení pouze lidským operátorem je velmi časově náročné.

Pokud máme velké množství dat ke zpracování, tak se nabízí představa využití počítačové techniky. Metody strojového učení toto automatické zpracování umožňují. Tzv. hluboké učení dokonce dovoluje umělým neuronovým sítím učit se z předem nezpracovaných surových dat a samy si vyhledávají důležité struktury v datech. Na základě nalezených souvislostí jsou následně například schopny data klasifikovat do různých skupin.

Aby však modely za pomoci hlubokého učení byly schopny například klasifikovat různé typy arytmií v signálu EKG, je nutné modely učit na poměrně velkém datovém souboru. Také je vhodné, aby v datech byly přibližně stejně zastoupeny všechny typy arytmií, které chceme klasifikovat. U některých arytmií, které se u pacientů nevyskytují tak často, ale nemusí být snadné získat dostatečné množství naměřených dat. K umělému navýšení datové sady slouží augmentace dat.

Cílem této práce je augmentace signálu EKG s arytmiemi, které se v rámci populace objevují spíše ojediněle. Při umělém navyšování medicínských dat je důležité, aby syntetická data vnášela při učení do modelu novou informaci, ale při tom si zachovala fyziologickou podobu. V rámci této práce bude vyzkoušena augmentace pomocí přidání šumu do naměřených dat a umělá transformace dat založená na empirické znalosti augmentovaných arytmií. Také bude vyzkoušeno generování dat pomocí neuronových sítí. Vytvořené algoritmy budou implementovány v jazyce Python (verze 3.9) s využitím vývojového prostředí Spyder 5.

1 Hluboké neuronové sítě

Strojové učení se stalo nedílnou součástí technologií moderní společnosti, je používáno ve webových vyhledávačích, v některých překladačích, v programech pro zpracování obrazů, videí i lidské řeči a v mnoha dalších aspektech. Strojové učení se také využívá pro klasifikaci, kdy se vstupní data po průchodu předem naučeného systému přiřadí do jedné z definovaných výstupních tříd. [1]

Často používaným typem klasifikátorů jsou umělé neuronové sítě. Aby byl model schopný klasifikovat, je nutné ho předem naučit souvislosti a rozdíly mezi jednotlivými třídami. Velkou výhodou strojového učení je, že model si tyto souvislosti dokáže určit sám, pokud mu poskytneme dostatečné množství dat, na kterých se může učit. Konvenční metody strojového učení však nezvládají zpracování tzv. surových dat, tedy například pokud na vstup sítě pošleme každý pixel klasifikovaného obrázku, nebo všechny vzorky naměřeného signálu. Pro tyto metody je nutné data nejprve předzpracovat. Nejčastěji dochází k ručnímu výběru vektoru příznaků, které představují vhodnou a dostatečnou reprezentaci dat. Avšak určení těchto příznaků nemusí být snadné. Byla ale vyvinuta metoda, tzv. hlubokého učení, kdy je možné na vstup systému dát surová nepředzpracovaná data a model je schopný odhadovat strukturu v souboru dat a sám si vyhledat důležité parametry. U hlubokých neuronových sítí je tento typ učení umožněn větším počtem skrytých výpočetních vrstev neuronů. První vrstvy sítě pak fungují jako extraktory příznaků, ty postupují dále do posledních vrstev sítě, které představují samotný klasifikátor. [1]

Hluboké neuronové sítě se používají i pro klasifikaci medicínských dat. Měření a analýza elektrokardiogramu (EKG) je díky jednoduchosti a ceně měření stále jednou z nejpoužívanějších metod vyšetření funkčnosti srdce. Pomocí EKG je možné detekovat abnormální srdeční rytmus neboli arytmií. Každý den se naměří velké množství dat, ať už v nemocnicích nebo v domácích podmínkách, a kontrola všech dat lidským operátorem se stává nesnadná. Pro usnadnění této práce se nabízí možnost automatické detekce a klasifikace srdečních arytmií za použití hlubokých neuronových sítí. Vysoké přesnosti zaznamenávají klasifikační sítě například pro síňovou fibrilaci nebo komorovou i síňovou extrasystolii. Architektury hlubokých sítí, které se skládají z více skrytých vrstev, jsou různé a poměrně rozmanité. V následujícím textu se pokusím shrnout a krátce popsat nejpoužívanější typy neuronových sítí používaných pro klasifikaci srdečních arytmií. [2]

1.1 Konvoluční neuronové sítě

Konvoluční neuronové sítě (CNN z angl. Convolutional Neural Network) jsou jednou z nejpoužívanějších architektur hlubokých neuronových sítí. Obecně se konvoluční

sítě skládají ze tří základních vrstev, konvoluční, poolingové a plně propojené vrstvy.

V konvoluční vrstvě si lze neuron představit jako filtr vah. Tento filtr má stejnou dimenzi jako data, která do dané vrstvy vstupují. Pokud je tedy například vstupem barevný RGB obraz o rozměrech $21 \times 21 \times 3$, tak filtr bude také třírozměrný. Třetí rozměr, označovaný jako hloubka, musí mít stejnou velikost jako je třetí rozměr vstupu. Naopak první dvě dimenze, které určují prostorový rozsah filtru, bývají vždy menší. Tento filtr je pak v obou směrech posouván po krocích (anglicky označovaných jako „stride“) o zadané velikosti. Pro každé posunutí je vypočítána lineární kombinace vah filtru se vstupem na odpovídajících pozicích daných posunutím filtru. Jakmile se provede kompletní konvoluce, tedy po projetí všech pozic filtru, dostaneme tzv. aktivační mapu. V jedné konvoluční vrstvě může být více typů neuronů s různými váhami, proto z jedné vrstvy můžeme získat více aktivačních map. Výstup vrstvy se vytvoří naskládáním všech aktivačních map na sebe. Hloubka výstupu pak bude odpovídat počtu použitých unikátních neuronů. Každý bod aktivačních map je pak transformován aktivační funkcí. Výstupem je mapa příznaků o stejné velikosti jako byly naskládány aktivační mapy. [3]

Poolingová vrstva slouží k podvzorkování. Nejčastěji se používá „max pool“, kdy je do další vrstvy přenesen nejsilnější prvek vybraného okolí vstupu. Stejně jako v konvoluční vrstvě se volí velikost okolí, ze kterého se bude maximální hodnota vybírat, a velikost kroku („stride“), který určuje o kolik pozic se filtr bude v každém kroku posouvat. [3]

Konvolučních i poolingových vrstev bývá obvykle více a mají za úkol extrahovat příznaky. Plně propojené vrstvy pak slouží k samotné klasifikaci. [4]

Příkladem studie, kde byla použita konvoluční síť pro zařazení úseků EKG, které odpovídají jednotlivým srdečním cyklům, do jedné z 5 skupin (podrobnější popis tříd je v tabulce 1.1), je [5]. V tomto článku autoři použili 9 vrstvou neuronovou síť, která byla složena ze 3 konvolučních, 3 poolingových a 3 plně propojených vrstev. Použili databázi arytmií MIT-BIH a dosáhli přesnosti 0,935 pro data bez filtrace a přesnosti 0,940 pro data, která byla předem upravená filtrací.

1.2 Rekurentní neuronové sítě

Rekurentní neuronové sítě (RNN z angl. Recurrent Neural Network) jsou výhodné pro svoji dynamiku. V paměti se uchovává informace o datech, která už sítě prošla, a ovlivňují nové vstupy. Rekurentní sítě mohou mít specifické architektury, vzniklé sítě se pak nazývají Long Short-Term Memory (LSTM) a Gated Recurrent Unit (GRU). LSTM pracuje s paměťovými bloky a je schopna uchovávat informaci o všech prošlých datech na jejichž základě ovlivňuje momentální vstup. GRU je

Tab. 1.1: Rozdělení život neohrožujících arytmíí do 5 skupin podle americké organizace Association for the Advancement of Medical Instrumentation (AMMI), převzato z [5]

zkratka skupiny	popis skupiny
N	neektopické rytmy
S	supraventrikulární ektopie
V	komorové ektopie
F	fúze komorových a normálních rytmů
Q	neklasifikovatelné rytmy

pak vyvozená z LSTM ale je zjednodušená, čímž umožňuje zachovávání dlouhodobé paměti, ale zároveň není tak výpočetně náročná a umožňuje rychlejší učení. [4], [6]

Autoři článku [6] porovnávali všechny 3 zmíněné architektury rekurentních sítí. Také byla použita databáze arytmíí MIT-BIH, ale oproti výše zmíněnému článku, kde autoři klasifikovali do 5 skupin, zde sítě měly pouze binárně určovat, jestli vstupní EKG signál představuje sinusový rytmus nebo arytmii. V tomto článku nejvyšší přesnosti dosáhla LSTM 0,881, následovala klasická architektura RNN s přesností 0,854. Nejnižší přesnost (0,825) v tomto případě byla zaznamenána u GRU.

1.3 Reziduální síť

Navyšování počtů vrstev neuronových sítí vede ke zlepšování klasifikačních schopností sítě, ale existuje prahová hodnota, nad kterou když navyšujeme hloubku sítě, začne docházet ke snižování výkonu sítě.

Jedním důvodem je, že může docházet k mizení nebo naopak k extrémnímu nárůstu gradientu, což ztěžuje trénování modelu. Tento problém řeší reziduální síť (ResNet z angl. Residual Network), které jsou vylepšením konvolučních sítí. Problém s gradientem řeší zkratkovým spojením, které přeskakuje více vrstev sítě. Reziduální síť tedy umožňuje vytváření hlubších modelů než klasické konvoluční síť. [7]

Ve článku [7] autoři porovnávali klasickou 9 a 11 vrstvou konvoluční síť s reziduálními sítěmi s 19, 25 a 31 vrstvami. Opět byla použita databáze arytmíí MIT-BIH a jednotlivé srdeční cykly byly klasifikovaly do 5 skupin (podrobnější popis tříd je v tabulce 1.1). Klasické konvoluční síť s 9 a 11 vrstvami dosáhly přesnosti 0,960 a 0,969. Pro reziduálními sítě s 19, 25 a 31 vrstvami pak vyšla přesnost 0,990, 0,989 a 0,991.

1.4 Interpretovatelný model hlubokého učení

Přestože hluboké neuronové sítě dosahují poměrně vysokých přesností při klasifikaci srdečních arytmií, jsou kritizovány pro svoji povahu „černých skříněk“. Pro člověka není snadné pochopit, proč a na základě čeho bylo při průchodu dat sítí rozhodnuto, že budou zařazena do dané skupiny. Tato neschopnost vysvětlit důvody rozhodnutí může budít nedůvěru v model. Autoři článku [8] vytvořili interpretovatelný model hlubokého učení (XDM z angl. explainable deep learning model). Bylo vytvořeno 6 hlubokých sítí každá pro posouzení jednoho z příznaků, které jsou důležité pro klasifikaci arytmií (pravidelné vzory v RR intervalech¹, přítomnost P vlny, pravidelné PR intervaly², aktivace síní a komor nezávisle na sobě (síňokomorová disociace), shoda 1:1 P a R vlny a přítomnost stimulačního impulzu). Každý z těchto 6 modelů byl tvořen 5 reziduálními bloky a 2 plně propojenými vrstvami. Výstupy ze všech 6 sítí jsou přivedeny na vícevrstvý plně propojený perceptron, který provádí samotnou klasifikaci do 9 různých skupin arytmií. Aby bylo možné modelu porozumět, byly vytvořeny mapy citlivosti pro všech 6 příznakových sítí. Použité mapy citlivosti byly počítány na základě gradientů výstupu a aktivačních map, výsledek se poté namapuje na vstup (v tomto případě EKG signál) a zvýrazní části vstupu, které byly pro výslednou klasifikaci důležité. Mapy pro každý model pak ukazují na jakou část EKG a na které příznaky se XDM při klasifikaci zaměřil. Na použitém datasetu Sejong byla dosažena přesnost 0,936.

1.5 Shrnutí

Jelikož každá architektura sítě vnáší do řešení klasifikačního problému jiné vylepšení, málokdy se jako kompletní klasifikátor používá samostatně jenom jeden z výše zmíněných typů sítí. Reálně používané klasifikátory tedy vznikají různou kombinací těchto sítí.

¹RR interval - vzdálenost dvou sousedních R kmitů.

²PR interval - úsek srdečního cyklu od začátku vlny P po začátek QRS komplexu.

2 Generativní kompetitivní sítě

Generativní kompetitivní sítě (GAN z angl. Generative Adversarial Networks) byly poprvé představeny v roce 2014 ve článku [9]. Slouží ke generování syntetických dat, které se podobají datům z trénovací množiny. GAN se skládá ze 2 modelů neuronových sítí nazývaných generátor a diskriminátor. Často se jejich funkce připodobňuje k padělateli bankovek a policii. Generátor, který představuje padělatele, se snaží co nejvěrněji napodobit bankovky. Diskriminátor jakožto policie má za úkol rozeznat, které bankovky jsou pravé a které falešné. V počátku učení generátor vytváří velmi nekvalitní napodobeniny, které diskriminátor snadno rozpozná, ale jako šikovný padělatel je schopný se na svých chybách velmi rychle učit a jeho padělky jsou po každém kroku učení kvalitnější. Učí se však i diskriminátor, kterého je naopak těžší a těžší oklamat padělky. Obě sítě jsou tedy navzájem v souboji.

Diskriminátor je síť fungující jako klasifikátor. Na jeho vstup přichází reálná data z trénovací množiny a syntetická data generovaná generátorem. Výstupem sítě je binární rozhodnutí, zda jsou vstupní data pravá či nikoliv. Pokud diskriminátor označíme jako funkci D , kam vstupují data x , pak $D(x)$ určuje pravděpodobnost, že data x jsou reálné vzorky. Při trénování D se tedy snažíme maximalizovat pravděpodobnost správného označení reálných a generovaných dat. Pro optimalizaci se používá kritériální funkce V (rovnice 2.1).

$$\max_D V(D) = E_{x \sim \text{data}(x)}[\log(D(x))] + E_{z \sim p_z(z)}[\log(1 - D(G(z)))], \quad (2.1)$$

kde E_x odpovídá očekávané hodnotě reálných dat z trénovací množiny (označených hodnotou 1) a E_z odpovídá očekávané hodnotě dat generovaných generátorem G z náhodné množiny z (označených hodnotou 0).

Generátor mívá složitější strukturu než diskriminátor. Na jeho vstup přichází náhodný šum z , jehož dimenze je nastavitelný parametr. Úkolem generátoru je přetransformovat tento vektor náhodných čísel na výstup, který se podobá učební množině. Pro učení generátoru je také použita klasifikační chyba diskriminátoru. Zajímá nás, jak diskriminátor reaguje na data generovaná generátorem ($D(G(z))$) a v tomto případě je naopak snaha minimalizovat pravděpodobnost, že diskriminátor označí generované vzorky za falešné (rovnice 2.2).

$$\min_G V(G) = E_{z \sim p_z(z)}[\log(1 - D(G(z)))], \quad (2.2)$$

V praxi bývá vzorec 2.2 ještě upravován. V počátcích učení generátor generuje data, která jsou velmi rozdílná od dat reálných, takže je od sebe diskriminátor velmi snadno rozezná. V tomto případě vzorec $\log(1 - D(G(z)))$ velmi rychle konverguje k nule a nedostáváme dostatečný gradient pro úpravy vah generátoru. Proto se častěji

pro učení používá maximalizace výrazu $\log(D(G(z)))$, kdy tato funkce poskytuje větší gradient i v prvotních fázích učení. [9]

2.1 Triky pro trénování GAN

Trénování GAN sítí je obecně velmi složité kvůli nestabilitě. Změna vah diskriminátoru snižuje kritériální funkci diskriminátoru, ale zároveň může zvyšovat kritériální funkci generátoru a naopak. Proto je složité nalézt optimum, GAN se přestává učit a kolabuje. [10] Mezi další problémy patří mizející gradient a ztráta unikátnosti výstupů. [11] Byla publikována řada článků, které se zaměřují na způsoby stabilizace GAN sítí (např. [10], [11], [12]). Některé z doporučených triků budou popsány dále.

- Váhy diskriminátoru je vhodné upravovat častěji než váhy generátoru. Na jeden krok optimalizace generátoru se provede k kroků optimalizace diskriminátoru, kde k je nastavitelný hyperparametr a doporučená hodnota se pohybuje mezi 3 až 10. Tento přístup učení by měl udržovat diskriminátor v blízkosti optimálního řešení, pokud změny v generátoru budou probíhat dostatečně pomalu. [9]
- Normalizace vstupních dat do intervalu $<-1; 1>$ a tedy i doporučení použití hyperbolického tangens pro aktivační funkci výstupní vrstvy generátoru. [13]
- Trénovat diskriminátor zvlášť na reálných a zvlášť na falešných vzorcích. [14]
- Pro podvzorkování v konvolučních vrstvách diskriminátoru nepoužívat poolingové vrstvy ale přímo nastavení kroku („stride“) v konvoluční vrstvě. [13]
- V [14] se všeobecně doporučuje místo ReLU používat LeakyReLU aktivační funkci. V [13] navrhuje použití ReLU pro generátor a LeakyReLU jenom pro diskriminátor s nastaveným sklonem 0,2.
- Inicializovat všechny váhy malou hodnotou z normálního rozložení se směrodatnou odchylkou 0,02. [14]
- Upravit hodnoty klasifikačních tříd. „Tvrdé“ označení 0 - falešné a 1 - reálné mírně transformovat do „hladší“ podoby. V [14] doporučují reálné vzorky ohodnotit náhodnými čísly např. z intervalu $<0,7; 1,2>$ a pro falešné použít hodnoty např. z intervalu $<0,0; 0,3>$. Naopak v [10] doporučují změnu označení pouze u reálných vzorků (např. na hodnotu 0,9) a falešné vzorky ponechat s označením 0.
- Pro diskriminátor použít optimalizační algoritmus SGD a pro generátor ADAM. [14]
- Poměrně velké spory napříč články a diskuzemi se vedou o batch normalizaci. V [13] doporučují použít batch normalizaci ve všech vrstvách mimo výstupní vrstvu generátoru a vstupní vrstvu diskriminátoru. Články [15] a [16] uvádí, že klasická batch normalizace způsobuje nestabilitu a zhoršuje proces trénování,

zvlášť pokud je použita u diskriminátoru. Článek [15] představuje jako lepší řešení váhovanou normalizaci. Další alternativa v podobě spektrální normalizace je popsána v [16].

- Posledním zde zmíněným doporučením je modifikace kritériální funkce. Je možné použít Wassersteinovovu vzdálenost, která způsobuje, že vypočítané gradienty, sloužící k učení sítě, nedosahují takových extrémů a zároveň nedochází k mizení gradientu jako při použití binární vzájemné entropie. [17] Při použití této kritériální funkce je nutné zajistit, aby používaná funkce diskriminátoru splňovala podmínku 1-Lipschitz. V původní článku [17] je tato podmínka splňována ořezáváním vah. Ve článku [18] však zmiňují, že ořezávání vah k vynucení Lipschitzova omezení může vést k nežádoucímu chování, jako generování špatných vzorků nebo selhání při konvergenci. Proto navrhnou alternativu v podobě penalizování normy gradientu diskriminátoru s ohledem na vstup.

3 Augmentace dat

V dnešní době jsou nejúspěšnější hluboké neuronové sítě poměrně rozsáhlé, mohou mít až milióny parametrů. Aby se tyto parametry nastavily při učení správně, je nutné velké množství trénovacích dat. Dostatečný dataset umožňuje, aby síť dosáhla určité generalizace a nedošlo k tzv. přeučení sítě, kdy je minimalizovaná chybová funkce pro učební set dat, ale pro testovací množinu dat vykazuje síť velkou chybu. Důležité je i rovnoměrné zastoupení klasifikovaných tříd v datech, aby nedocházelo k neobjektivním výsledkům klasifikace. [19] Není vždy možné nebo jednoduché naměřit dostačující množství variabilních reálných dat. Například pro klasifikaci různých srdečních arytmií je potřeba mít přibližně rovnoměrné zastoupení záznamů všech těchto srdečních abnormalit, přestože se v populaci objevují v různé míře. Proto může být výhodné uchýlit se k augmentaci a syntetickému vytvoření nových dat. [20] Dále v textu budou popsány různé přístupy augmentace dat pro klasifikaci srdečních arytmií vyhledané v odborné literatuře.

3.1 Augmentace obrazových dat

Jak již bylo zmíněno v kapitole 1.1, asi nejpoužívanějšími sítěmi se staly konvoluční neuronové sítě, které byly velmi úspěšné ve zpracování obrazů. I proto je většina primárních augmentačních metod zaměřena především na obrazová data. Nejpopulárnější jsou afinní transformace, kdy jsou nové obrazy vytvářeny pomocí rotace, přibližování nebo oddalování, posunem, aplikací zkreslení nebo barevnými změnami. [19] Možná i toto je jeden z důvodů, proč je v některých publikovaných studiích snaha EKG signál zpracovávat jako obraz.

Ve článku [21] byly jako vstupní data do sítě použity obrazy 12 svodového papírového záznamu EKG. Autoři klasifikují poměrně neobvyklé kategorie: EKG pacienta s onemocněním COVID-19, EKG s probíhajícím infarktem, EKG pacienta s dříve prodělaným infarktem, normální rytmus a abnormální rytmus. Pro rozšíření datové sady zde byly využity jednoduché a hojně používané metody pro augmentaci obrazových dat. Konkrétně bylo vyzkoušeno horizontální a vertikální převrácení obrazu, náhodný ořez, perspektivní zkreslení a změna kontrastu v obraze. Avšak ani jeden typ těchto augmentací nebo jejich kombinace nenavýšila přesnost použité sítě, ale naopak průměrná přesnost i F1 skóre přes všechny klasifikované kategorie poklesly.

Autoři článku [22] využili krátkodobou Furierovu transformaci pro převod 1D signálu EKG na 2D spektrogram. Jednotlivé srdeční cykly byly klasifikovány do 8 tříd: normální cyklus, komorová extrasystola, stimulovaný cyklus, blokáda pravého Tawarova raménka, blokáda levého Tawarova raménka, supraventrikulární extrasystola, flutter síní a uniklý komorový stah. Ve článku zmiňují, že není jednoduché provést

augmentaci EKG v časové oblasti, aby zůstal zachován význam dat. Méně zastoupené arytmie byly augmentovány pomocí jednoduchého ořezu spektra. Bylo použito devět různých operací oříznutí (vlevo nahoře, uprostřed nahoře, vpravo nahoře, vlevo uprostřed, uprostřed, vpravo uprostřed, vlevo dole, uprostřed dole, vpravo dole). Tímto způsobem byl z jednoho původního spektra o velikosti 256x256 pixelů obohacen dataset o 9 dalších rozdílných spekter o velikostech 200x200, jejichž velikost byla pomocí lineární interpolace zvětšena zpět na velikost 256x256 pixelů. Pro použitou konvoluční síť narostla při použití augmentovaných dat průměrná přesnost pro všechny kategorie z 0,989 na 0,991, průměrné F1 skóre zůstalo v obou případech zachováno na hodnotě 0,98.

3.2 Augmentace 1D signálů

I pro jednorozměrné časové řady byly vyvinuty nejrozličnější typy augmentací. Jednou z používaných metod je rozkouskování celého signálu na více částí, kdy každá část bude klasifikována jako původní celý signál (windows slicing). [20] Další způsob augmentace je v rámci signálu vybrat jeho náhodnou část a tento úsek buď rozšířit nebo zúžit (windows wrapping). Další možností je rozkouskovat signál na několik segmentů a ty pak permutovat a pospojovat v náhodném pořadí. Ani jedna z těchto používaných metod se však pro augmentaci EKG signálu příliš nehodí. Nově generované vzorky by mohly být nefyziologické a při učení by v některých případech mohly spíše zanášet chyby. Dalšími používanými metodami pro augmentaci 1D signálů, které se jeví jako vhodnější pro použití pro navýšení data setu EKG, jsou zanesení šumu do vzorků a převzorkování. Protože jednotlivé srdeční arytmie vykazují různé morfologické vlastnosti, tak je pravděpodobné, že pokud některé augmentační metody budou vytvářet fyziologicky vypadající signál s jednou arytmií, tak tato stejná metoda může být pro jinou arytmiu zcela nevhodná. [20], [23]

Ve článku [20] se autoři zaměřili na detekci síňové fibrilace. Vycházeli ze značně nevyvážené datové sady, která byla rozdělena do 3 skupin: sinusový rytmus (5 154 záznamů), síňová fibrilace (771 záznamů) a ostatní abnormální rytmy (2 557 záznamů). Jejich způsob augmentace spočíval v tom, že si nejprve vyhledali počátky všech QRS komplexů, poté vzali úsek signálu mezi prvním a posledním vyhledaným komplexem, tento úsek nakopírovali a za originální úsek zřetězili nakopírovaný. Následně pomocí posuvného okna vybírali z tohoto dvojnásobně dlouhého signálu kratší signály, které představovaly nové vzorky. Posun okna volili podle požadovaného počtu nových vzorků. Pro klasifikaci použili dvouvrstvnou LSTM síť. Bez augmentace vyšlo F1 skóre kategorie fibrilace síní pouhých 0,308 a průměrné F1 skóre 0,356. Po navýšení všech datových sad navrženou augmentační metodou do počtu 15 000 se zvýšilo F1 skóre fibrilace na 0,798 a průměrné F1 na 0,810. V tomto článku navíc

zkoušeli porovnávat i augmentaci pomocí permutací a náhodného rozkouskování signálu (windows wrapping) popsaných výše taktéž do počtu 15 000. Permutace navýšila F1 skóre fibrilace na 0,699 a průměrné F1 na 0,740. Při augmentaci rozkouskováním signálu bylo pro fibrilaci síní dosaženo F1 skóre ve výši 0,691 a průměrné F1 bylo 0,729.

Ve článku [24] autoři klasifikovali soubor dat do 5 tříd (podrobnější popis skupin je v tabulce 1.1). Vzorky jsou pouze krátké úseky signálu odpovídající jednomu srdečnímu cyklu. Pro augmentaci byly použity 4 bezztrátové transformace, převzorkování podél časové osy zkrácením a prodloužením vzdáleností mezi sousedními body a zvětšení a zmenšení úrovně signálu v nastaveném rozsahu. Pro použitý konvoluční model se navýšila hodnota průměrného F1 skóre pro všechny klasifikované třídy při použití augmentovaných dat pro trénování z 0,900 na 0,980.

Autoři článku [23] vytvořili program pro automatické generování úseků signálů EKG. Nejprve si vytvořili knihovnu úseků QRS komplexů a T vln ze signálů, u kterých byly významné body ručně vyznačeny expertem. Program následně náhodně kombinuje QRS komplexy a T vlny, tyto úseky různým způsobem transformuje. V programu je možnost nastavení různých parametrů jako šířka QRS, délka ST úseku, amplitudový rozsah signálu a další. Při vhodném nastavení těchto parametrů by se na výstupu měly objevovat signály, které se velice podobají reálně změřenému EKG. V tomto článku augmentovali data pro učení neuronové sítě, která měla správně vyhledávat právě důležité body v EKG křivkách. Nicméně tím, že je v programu možné nastavit i například požadované délky RR intervalů, by se možná dal tento program využít i pro navýšení datových sad některých arytmií jako je například síniová fibrilace.

3.3 Augmentace pomocí GAN

V kapitole 2 byly popsány generativní kompetitivní sítě, které slouží ke generování syntetických dat. Přestože většina literatury o GAN se zabývá obrazovými daty, bylo publikováno i několik článků, které GAN využívají pro augmentaci EKG.


Ve článcích [25] a [26] opět využili krátkodobou Furierovu transformaci pro převod 1D signálu EKG na 2D spektrogram. V [25] klasifikovali fibrilaci síní a normální sinusový rytmus. GAN pro generování fibrilace byla učena na množině, která byla testovací pro dva použité klasifikátory. Autoři zmiňují, že zkoušeli generovat i 1D EKG signál, ale tento pokus nebyl tak úspěšný jako generování spekter. Pro vyhodnocení výsledků byl použit klasifikátor. Při trénování na nehomogenní databázi dosáhl klasifikátor přesnosti pro fibrilaci síní 0,756 a průměrného F1 pro obě třídy 0,845. Když byly záznamy fibrilace nakopírovány, aby byla odstraněna nehomogenita, byla přesnost pro fibrilaci navýšena na 0,793 a průměrné F1 na 0,859. Při

použití augmentovaných dat se výrazně zvýšila přesnost pro fibrilaci na 0,863 a průměrné F1 se zvýšilo na 0,868. Článek [26] se zaměřil na klasifikaci 6 tříd s nerovnoměrným zastoupením vzorků: normální sinusový rytmus (2 000 záznamů), fibrilace síní (1 269 záznamů), flutter síní (104 záznamů), komorové extrasystoly v bigeminní vazbě (272 záznamů), komorové extrasystoly v trigeminní vazbě (137 záznamů) a stimulovaný rytmus (137 záznamů). Všechny signály byly převedeny na spektra a pro každý rytmus byla zvlášť natrénovaná GAN. Pro klasifikaci spekter byly využity sítě LeNet, AlexNet, ZFNet a VGG13. U všech klasifikátorů se po augmentaci dat generováním všech rytmů do stejného počtu navýšilo průměrné F1 skóre o necelé 1 %.

Některé články (např. [27], [28]) používají GAN ke generování jednotlivých srdečních cyklů. Kvůli typům arytmií, na jejichž augmentaci se tato práce zaměřuje (flutter síní a atrioventrikulární blokády II. a III. stupně, viz kapitola 4), jsou podstatnější články, ve kterých se autoři zaměřují na augmentaci delších úseků EKG signálů jako [29], [30], [31] a [32], které budou popsány dále.


Autoři článku [29] porovnávají 2 typy GAN pro generování 10 sekundového 12 svodového EKG s normálním sinusovým rytmem, respektive se generuje 8 svodů a zbylé 4 jsou dopočítávány. První vyzkoušený typ sítě používá jako generátor upravenou WaveGAN, která byla představena ve článku [33] a původně sloužila pro generování audio signálů. Vstupem do sítě je vektor šumu z normálního rozdělení o velikosti 100×1 , ten dále prochází 6 dekonvolučními bloky a transformuje signál do požadované podoby 8×5000 (8 svodů po 5 000 vzorcích). Blokové schéma sítě je na obrázku 3.1(a). Součástí druhého typu GAN autory nazvaného Pulse2Pulse je generátor inspirovaný architekturou U-Net, která bývá používána pro segmentaci obrazů. Na vstup je přivedena matice šumu o velikosti 8×5000 , ten prochází 6 bloky s podvzorkováním a následně 6 bloky, které signál zpátky nadvzorkovávají do velikosti 8×5000 . Blokové schéma architektury je na obrázku 3.1(b). Černé šípky na obrázku 3.1(b) představují konkatenaci příznakových map nadvzorkovacích bloků s příznakovými mapami podzorkovacích bloků. Pro oba typy generátorů byla použita stejná architektura diskriminátoru (obrázek 3.1(c)), která byla opět inspirovaná diskriminátorem použitým pro WaveGAN z [33]. Skládá se ze 7 konvolučních bloků. Za každým konvolučním blokem následuje Leaky ReLU aktivační funkce a speciální vrstva fázového míchání. Fázové míchání v každé vrstvě náhodně ořeze příznakové mapy o $-n$ až n vzorků, kde n je nastavitelný hyperparametr. Chybějící vzorky se doplní zrcadlením. Schéma možných výsledků pro 4 příznakové mapy a $n=1$ je na obrázku 3.2. V původním článku [33], kde byla tato vrstva představena, je používána pro odstranění artefaktů, které vznikají při nadvzorkování pomocí transponované konvoluce používané v generátoru. Pro trénování všech sítí byla použita optimalizace ADAM ($krok\ u\ čení = 0,0001$, $\beta 1 = 0,5$, $\beta 2 = 0,9$). Jako kritériální funkce byla pou-

žita Wassersteinova vzdálenost s penalizováním normy gradientu. Diskriminátor byl učen pětikrát častěji než generátor. Učení probíhalo po dobu maximálně 3 000 epoch. Pro posouzení kvality výstupů byl použitý komerční program pro interpretaci EKG MUSE 12SL. Oběma naučenými modely bylo vygenerováno 150 000 EKG záznamů, které byly hodnoceny MUSE 12SL. Jako normální sinusový rytmus bylo vyhodnoceno 72,5 % EKG generovaných WaveGAN a 81,6 % EKG generovaných Pulse2Pulse sítí. Žádné EKG nebylo vyhodnoceno jako nevalidní. Největší chyba byla způsobena příliš nízkou nebo vysokou tepovou frekvencí, kdy bylo EKG hodnoceno jako bradykardie nebo tachykardie. Ukázka generovaného EKG sítí Pulse2Pulse je na obrázku 3.3.




Obr. 3.1: Architektury GAN sítí z článku [29].

Ve článku [30] autoři generují úseky EKG. Generátor se skládá ze 2 BiLSTM vrstev, kde obě obsahují 100 neuronů, dropout vrstvy a plně propojené vrstvy. Jako diskriminátor byly vyzkoušeny 4 typy sítí, konvoluční, plně propojená síť, LSTM a GRU. Výstupy z generátoru jsou na obrázku 3.4. Autoři nepoužívají pro posouzení výstupu z generátoru klasifikátor, ale v závěru zmiňují, že generovaný signál má




Obr. 3.2: Schéma možných výsledků po aplikování vrstvy fázového míchání pro 4 příznakové mapy a $n=1$. Převzato z [33].



Obr. 3.3: Ukázka generovaného EKG sítí Pulse2Pulse. Převzato z [29].


statistické vlastnosti EKG a je mu i morfologicky podobný, s čímž na základě obrázku 3.4 moc nesouhlasím.



Obr. 3.4: Ukázka generovaného EKG sítí z článku [30]. V GAN byl použitý stejný generátor - BiLSTM a 4 rozdílné diskriminátory: (a) konvoluční síť (CNN), (b) GRU, (c) plně propojená síť (MLP) a (d) LSTM.


Autoři článku [31] nepoužili ke generování EKG klasickou GAN, ale její pozměněnou verzi GFMN (z angl. Generative Feature Matching Networks). V GFMN jsou diskriminátor a generátor trénovány zvlášť, čímž je možné se při jejich trénování vyhnout vzájemnému souboji, který může vést k nestabilitě. Nejprve je diskriminátor na reálných datech naučen vyextrahovat v každé vrstvě důležité příznaky dat. Generátor se pak při učení snaží generovat takové vzorky, aby se střední hodnoty a rozptyly jejich příznaků co nejvíce podobaly příznakům reálných dat. Pro diskriminátor využili síť ResNet, která pro každý signál vytvářela 2 473 984 příznaků, které se používaly k učení generátoru. Do modelu generátoru vstupuje šum o velikosti 128x1 následně prochází vrstvou transponované konvoluce, 8 residuálními bloky a konečnou konvoluční vrstvou s aktivací funkcí v podobě hyperbolického tangens. Výstupem je 64 sekundový signál EKG. Autoři článku generovali normální sinusový rytmus a fibrilaci síní. Pro ověření nebyla použita žádná klasifikační síť, ale na základě zobrazených výstupů z generátoru (obrázek 3.5), lze říct, že se generované signály morfologicky velmi podobají reálným EKG.

Autoři článku [32] použili pro generování fibrilace síní spojení dvou GAN. První GAN generuje vzor nepravidelné srdeční frekvence, která je pro fibrilaci síní typická. Výstupem z generátoru a tedy i vstupem do diskriminátoru je vektor 50 čísel, které



Obr. 3.5: Ukázka generovaného EKG sítí z článku [31].

představují vzdálenost sousedních R vln. Generátor této GAN se skládá ze dvou plně propojených vrstev o 40 a 50 neuronech. Diskriminátor představují dvě LSTM vrstvy s 64 jednotkami. Druhá GAN má za úkol generovat morfologický tvar mezi dvěma sousedními vlnami R. Generují se úseky dlouhé 200 vzorků, které odpovídají při vzorkovací frekvenci 300 Hz tepové frekvenci 90 tepů za minutu. Generátor se skládá z plně propojené vrstvy o 6 400 neuronech, dvou dekonvolučních vrstev se 128 a 64 filtry a výstupní konvoluční vrstvy. Diskriminátor představují dvě konvoluční vrstvy s 64 a 128 filtry a výstupní plně propojená vrstva s binárním výstupem. Do klasické kritériální funkce pro učení generátoru (popsané v kapitole 2) autoři navíc přidávají penalizaci v podobě váhované střední kvadratické odchylky mezi generovanými a skutečnými daty. Byla použita optimalizace ADAM (*krok učení* = 0,0002), učení probíhalo po dobu 500 epoch. Byly upraveny hodnoty klasifikačních tříd do „hladší“ podoby, reálné vzorky byly označeny hodnotou o trochu menší než 1 a falešné vzorky o trochu větší hodnotou než 0. Výsledné EKG bylo vytvářeno převzorkováním 200 vzorků dlouhého úseku kubickým splajnem podle generovaného vektoru vzdálenosti RR intervalů. Ukázka výsledných generovaných signálů je na obrázku 3.6. Pro ověření byly použity dvě klasifikační sítě. Jako metrika nebylo uvedeno F1 skóre ale senzitivita a specificita, které se sice po augmentaci dat pomocí GAN navýšily, ale pro porovnání s úspěšností GAN z ostatních článků nejsou vhodné.



Obr. 3.6: Ukázka generované fibrilace síní z článku [32].

3.4 Shrnutí

Srovnání výše zmíněných augmentačních metod není snadné. Nejen, že metody byly použity na různých datových sadách a byly jimi učeny různé neuronové sítě, ale především i napříč články autoři klasifikovali rozdílné třídy. Každopádně ve většině případů umělé navýšení počtu trénovacích dat zvyšovalo přesnost i F1 skóre použitých sítí.

Dále v praktické části této práce budou vyzkoušeny různé augmentační metody pro navýšení trénovací sady dat méně častých arytmií.

V žádném výše zmíněném článku nebyla vyzkoušena augmentace za pomoci přidání šumu do dat, přestože se jedná o poměrně jednoduchou metodu. Pro augmentaci EEG (elektroencefalogramu) použili přidání šumu například ve článku [34], díky čemuž dosáhla jejich použitá neuronová síť vyšší přesnosti. Jelikož i měření EKG je zatíženo šumem, bude tento typ augmentace v praktické části práce vyzkoušen.

Další typy augmentací budou specifické pro jednotlivé arytmie. Pro sínový flutter bude vyzkoušena permutace rozkouskovaného signálu na specifických místech. U EKG s atrioventrikulární bloádou bude snaha vytvořit úpravou sinusového rytmu analytickým způsobem na základě empirických znalostí o arytmiích. V poslední řadě bude také vyzkoušeno použití neuronových sítí pro generování atrioventrikulární bloády.

4 Data

Data použitá v této práci pochází z databáze Ústavu biomedicínského inženýrství, FEKT, VUT Brno. Data byla poskytnuta firmou MDT s.r.o., která nabízí služby krátkodobé i dlouhodobé monitorace srdečního rytmu.

Nahrávky EKG byly získány od reálných pacientů jak s normálním sinusovým rytmem, tak se srdečními arytmiemi. Databáze obsahuje celkem 60 579 EKG záznamů. EKG záznamy jsou 3 svodové (svod I, svod II a aVF) a mají délku 10 sekund až několik minut. Aby byly záznamy jednotné, byly všechny převzorkovány s frekvencí 250 Hz a kvantovány na 1 $\mu\text{V}/\text{LSB}$. Každý tří svodový záznam EKG je uložen v .csv souboru. Zároveň jsou pro každý záznam k dispozici informace uložené v datovém formátu JSON. Najdeme zde například údaje o morfologii EKG křivky, popis přítomného srdečního rytmu nebo pozice detekovaných QRS komplexů. Rovněž zde můžeme dohledat informace o způsobu měření a jeho technické specifikace. Také je k dispozici informace o pohlaví a věku pacienta.


Na obrázku 4.1 je zobrazeno absolutní a procentuální zastoupení všech změn srdečního rytmu a morfologií EKG křivek z databáze. Jak je z grafu patrné, tak v jednom EKG záznamu se může nacházet více typů arytmií, a proto procentuální zastoupení není rovno 100 %.

Červenou barvou jsou v grafu zvýrazněny arytmie, které jsou jak v této, tak i obecně v databázích obvykle málo zastoupené. Často při klasifikacích pak bývají spojovány do kombinovaných kategorií. Například flutter síní bývá spojován s fibrilací síní a u atrioventrikulárních bloků se neodlišuje stupeň blokády. [35] Právě pro tyto arytmie je vhodná augmentace dat, protože malé množství záznamů nemusí být dostatečné pro kvalitní naučení klasifikačního modelu. Následující práce se tedy zaměří především na augmentaci atrioventrikulární blokády II. a III. stupně a flutteru síní.

4.1 Popis arytmií, na které bude zaměřena augmentace

4.1.1 Atrioventrikulární blokáda II. stupně

Při atrioventrikulární (AV) blokádě II. stupně dochází k občasnému nepřivedení síňového vzruchu na komory, což se na EKG projeví osamocenou P vlnou, po které nenásleduje QRS komplex. [36] Typicky se převod vzruchu s každou excitací síní zhoršuje, až je jeden vzruch kompletně zablokovaný a neprojde na komory. Při této pauze se převod přes postižené místo obvykle opět zlepší a celý cyklus se opakuje. Často se tedy udává poměr všech vzruchů v cyklu k nepřivedeným vzruchům (např. 3:2).




Obr. 4.1: Absolutní a procentuální zastoupení EKG záznamů s různými patologickými projevy v databázi. Některé EKG záznamy jsou zařazeny do více kategorií, proto procentuální zastoupení je v součtu větší než 100 %. Červeně zvýrazněné arytmie budou předmětem zájmu prováděné augmentace.

AV blokády II. stupně se dělí na 2 typy Mobitz I (nebo také Wenckebachův typ) a Mobitz II. [37]

Atrioventrikulární blokáda Mobitz I

U AV blokády II. stupně typu Mobitz I dochází k postupnému prodlužování vedení až dojde k tomu, že vzruch ze síní je úplně zablokovaný a nepřevede se na komory. Prodlužování vedení je nerovnoměrné, interval, o který se vedení prodlužuje se postupně zmenšuje. [37] Na EKG záznamu se tento typ arytmie projevuje postupným prodlužováním PQ intervalu až se objeví vlna P, za kterou nenásleduje QRS komplex. K excitaci síní dochází pravidelně, takže vzdálenost mezi jednotlivými P vlnami se výrazně nemění. Naopak kvůli prodlužování převodů na komory dochází k postupnému zkracování intervalů mezi sousedními QRS komplexy. [36] Tento typ blokády je charakteristický pro sinoatriální a atrioventrikulární uzly, tedy místa s pomalým vedením. [37] Ukázka signálu je na obrázku 4.2.




Obr. 4.2: Atrioventrikulární blokáda II. stupně typu Mobitz I (Wenckebachův typ) s vyznačením prodlužujících se PQ intervalů.

Atrioventrikulární blokáda Mobitz II

U částečné blokády Mobitz II nedochází na EKG záznamu k prodlužování PQ intervalu, vždy pouze po určitém počtu převedených vzruchů se jedna excitace zablokuje. Tento typ blokády se nachází ve tkáních, kde dochází k rychlému převodu, tedy například na Hisově svazku nebo Tawarově raménku. [37] Pokud jsou postižena raménka, mohou být QRS komplexy široké. [36]. Ukázka signálu je na obrázku 4.3.


4.1.2 Atrioventrikulární blokáda III. stupně

AV blokáda III. stupně je kompletní blokádou, kdy je vedení síňových vzruchů na komory úplně přerušeno. Aktivita síní je dále řízena sinusovým uzlem a má vyšší



Obr. 4.3: Atrioventrikulární blokáda II. stupně typu Mobitz II.


frekvenci než komorový rytmus.[36] Klidový sinusový rytmus se u člověka v průměru pohybuje okolo 72/minutu. [38] Náhradní rytmus pro komory může vycházet z distální části AV junkce (pokud došlo k blokádě AV uzlu) nebo z některého z Tawarových ramének (pokud došlo k blokádě pod AV uzlem). Tento rytmus je pomalejší (přibližně 40-60/minutu [38]) než sínový, na kterém je navíc naprosto nezávislý. Pokud je rytmus generován raménkem, QRS komplex bývá širší. [36] Ukázka signálu je na obrázku 4.4.



Obr. 4.4: Atrioventrikulární blokáda III. stupně.

4.1.3 Flutter síní

Flutter síní je arytmie způsobená opakovaným kroužením vzruchu kolem pravé síně (reentry okruh). Elektrická aktivita síní se pohybuje okolo frekvence 300/min. Na EKG se projevuje pravidelnými vlnami f, které jsou často popisovány jako tvar „zubů pily“, tyto vlny jsou nejlépe viditelné ve svodech II, III a aVF. Na komory jsou pak běžně f vlny převáděny v poměru 2:1, takže frekvence komorové aktivity je okolo 150/min. Flutter síní může být paroxysmální nebo setrvalý. [36]. Ukázka signálu je na obrázku 4.5.



Obr. 4.5: Flutter síní.


4.2 Filtrace dat

Některé záznamy EKG jsou značně zarušené, což by mohlo znesnadnit další manipulaci s daty při augmentaci, proto budou data filtrována.


Kolísání nulové izolinie je nízkofrekvenční rušení, které většinou dosahuje menší frekvence než 1 Hz. Tento šum bude filtrován za pomoci horní propusti. Použitý Butterworthův filtr 4. řádu byl vytvořen pomocí funkce *signal.butter* z knihovny *scipy*. Teto typ filtru byl vybrán, protože má poměrně strmý přechod charakteristiky mezi propustným a nepropustným pásmem a zároveň má rovnoměrnou amplitudovou frekvenční charakteristiku v propustném pásmu s přenosem 1. Frekvenční charakteristiky filtru jsou zobrazeny na obrázku 4.6. Mezní frekvence byla zvolena na 0,7 Hz. Jelikož Butterworthův filtr je typu IIR (s nekonečnou impulzní odezvou) a jeho fázová charakteristika je nelineární (obrázek 4.6), bude pro filtraci využita funkce *signal.sosfiltfilt*, která aplikuje filtr na signál dvakrát. Dopředná a zpětná filtrace způsobí, že fáze bude nulová a nedojde k nežádoucímu tvarovému zkreslení signálu. Porovnání zkreslení tvaru signálu při jednoduché a dvojité aplikaci filtru je na obrázku 4.7. Výsledek filtrace je zobrazen na obrázku 4.8

Elektromyografické (EMG) rušení je širokopásmový šum, který svým frekvenčním rozsahem překrývá frekvenční spektrum EKG. Z tohoto důvodu není vhodné jeho filtraci provádět lineárními filtry. Proto byla použita Wienerovská vlnková filtrace metodou pilotního odhadu užitečného signálu založená na článku [39]. Diskrétní dyadická vlnková transformace byla realizována pomocí funkce *wavedec* z knihovny *pywt* a odpovídá rozkladu signálu bankou filtrů zobrazené na obrázku 4.9, kde $H_{HP}(z)$ představuje rozkladovou horní propust a $H_{LP}(z)$ rozkladovou dolní propust. Na rozdíl od [39] byl použit vlnkový rozklad s podvzorkováním, které je znázorněno koncovými bloky na obrázku 4.9 s vepsaným faktorem podvzorkování. Princip Wienerovské filtrace s pilotním odhadem je ukázán na obrázku 4.10. Vstupní signál, který je aditivní směsí užitečného signálu $s(n)$ (EKG) a rušení $w(n)$ (EMG),


Butterworthův filtr 4. řádu, horní propust s mezní frekvencí 0,7



Obr. 4.6: Amplitudová a fázová frekvenční charakteristika Butterworthova filtru, který byl použit pro filtraci driftu v EKG. Parametry filtru: 4. řád, horní propust s mezní frekvencí 0,7 Hz.



Obr. 4.7: Porovnání zkreslení tvaru signálu vlivem nelineární fázové charakteristiky.




Obr. 4.8: Výsledek filtrace kolísání nulové izoliny.

vstupuje do horní větve schématu sloužící pro pilotní odhad užitečného signálu. Je rozložen dyadickou vlnkovou transformací s decimací (WT1). Stupeň rozkladu byl zvolen 4 a jako rozkladová vlnka byla použita bior2.2. Blok H představuje prahování, tedy filtrování jednotlivých pásem. Práh byl určen pro každé pásmo zvlášť jako trojnásobek směrodatné odchylky pásma. Pro úpravu hodnot bylo použito prahování garrotte (někdy také označováno jako hybridní). Filtrovaná pásma byla rekonstruována zpětnou vlnkovou transformací (IWT1) funkcí *waverec*. Výstupem je pilotní odhad signálu $^ps(n)$. Tento pilotní odhad stejně jako původní vstupní signál jsou opět podrobeny vlnkové dekompozici (WT2). Stupeň rozkladu byl zvolen 3 a rozkladová vlnka bior2.2. Jelikož EMG má nejvýraznější složky mezi 20 až 100 Hz [40], tak nízkofrekvenční pásmo, obsahující nižší frekvence (v našem případě 0 až 15,625 Hz), nebylo filtrováno. Úprava koeficientů byla provedena jejich násobením korekčním členem vypočítaným z rozloženého pilotního odhadu a směrodatné odchylky pásma. Vzorec pro výpočet korekčního členu:


$$g_m(n) = \frac{^pu_m^2(n)}{^pu_m^2(n) + \sigma_m^2}, \quad (4.1)$$

kde $g_m(n)$ jsou hodnoty korekčního členu pro m -té rozkladové pásmo, $^pu_m(n)$ jsou hodnoty pilotního odhadu po dekompozici a σ_m je směrodatná odchylka m -tého rozkladového pásma. Rovnice 4.1 byla převzata z článku [39].


Výsledný vyfiltrovaný signál vznikl zpětnou vlnkovou transformací (IWT2). Výsledek filtrace je zobrazen na obrázku 4.11.



Obr. 4.9: Třístupňová dyadická vlnková dekompozice s decimací. Převzato z [39].



Obr. 4.10: Princip Wienerovské vlnkové filtrace metodou pilotního odhadu užitečného signálu. Převzato z [39].



Obr. 4.11: Výsledek filtrace elektromyografického rušení.

5 Augmentace dat přidáním šumu

Naměřené EKG je běžně zatíženo různými typy šumu. Jelikož jsou známy jejich přibližné parametry, je možné vytvořit generátory, které budou různé typy šumů napodobovat. Vygenerované šумы budou následně přičteny k reálně naměřeným datům, čímž bude dataset obohacen. Přestože jsou často signály před tím, než jsou poslány do sítě, filtrovány, filtrace nebývá úplně dokonalá, takže i po filtraci by signál s přičteným šumem měl vykazovat alespoň lokální změny.

Pro realizaci generátorů bude využit programovací jazyk Python.

5.1 Síťové rušení

Rušení ze sítě (označované také jako síťový brum) je jedním z nejběžnějších rušení v měřeném EKG. Jedná se o harmonické rušení s frekvencí 50 Hz (nebo v některých zemích 60 Hz) s přesností $\pm 0,2$ Hz a vyšších harmonických složek. Amplituda této harmonické funkce nedosahuje obvykle více než 50 % maximálního rozsahu měřeného signálu. [40]

Generování síťového rušení bylo realizováno pomocí knihovny *numpy* a funkce *sin*, které generuje sinusovou křivku. Jako vstup je nutné zadat signál, který chceme zašumět, jeho vzorkovací frekvenci a případně i požadovanou amplitudu šumu. Pokud není amplituda šumu zadána, tak je náhodně generována v rozmezí 5 až 15 % maximální hodnoty v signálu po odfiltrování kolísavé nulové izoliny. Náhodně je také generován fázový posun. Pro generování náhodných čísel je využita knihovna *random*.

5.2 Kolísání nulové izoliny

Kolísání nulové izoliny (někdy označované jako drift) je nízkofrekvenční rušení, které většinou dosahuje menší frekvence než 1 Hz (obvykle 0,15 - 0,30 Hz). Je způsobeno především pohyby pacienta, dýcháním, kašláním nebo také špatným kontaktem elektrod na kůži a impedancí mezi elektrodami a kůží. Délka trvání šumu a jeho amplituda závisí na vlastnostech elektrod, impedanci kůže a pohybech těla. Maximální amplituda šumu se pohybuje okolo 15 % maximální hodnoty v měřeném EKG. [40]

Pro generování kolísání nulové izoliny byl využit bílý gausovský šum, který má rovnoměrně zastoupené všechny frekvenční složky. Generován byl funkcí *random.normal* z knihovny *numpy* s nulovou střední hodnotou a směrodatnou odchylkou rovnou 1. Tento bílý šum byl následně filtrován dolní propustí s mezní frekvencí 1 Hz. Parametry filtru byly vytvořeny funkcí *signal.butter* z knihovny *scipy*, řád

Butterworthova filtru byl nastaven na 4. Pomocí stejné knihovny byl bílý šum i vyfiltrován. Amplitudu šumu může opět uživatel zadat, nebo je náhodně generovaná z rozmezí 5 až 10 % maximální hodnoty v signálu po odfiltrování původního driftu.

5.3 Elektromyografické rušení

Elektromyografické (EMG) rušení je způsobenou elektrickou aktivitou ve svalech. Jedná se o širokopásmový signál a zasahuje až do frekvence 10 kHz. Protože svým frekvenčním spektrem překrývá frekvenční rozsah EKG (0,01 - 100 Hz) dochází jeho vlivem ke značnému zkreslení signálu a jeho filtrace není snadná. Amplituda myopotenciálového šumu dosahuje přibližně 10 % maximální hodnoty v měřeném EKG. [40]

EMG představuje nestacionární stochastický proces. Jedna z jednoduchých možností, jak tento typ signálu generovat je jako základ využít bílý gausovský šum, který se bude filtrovat na základě spektra EMG. [41] Tvar výkonového spektra je určený podle rovnice 5.1, převzaté z [41]


$$P(f) = \frac{f_h^4 f^2}{(f^2 + f_l^2)(f^2 + f_h^2)^2}, \quad (5.1)$$

kde $P(f)$ jsou hodnoty normalizovaného výkonového spektra pro jednotlivé frekvence f a f_l a f_h jsou parametry které upravují šířku frekvenčního pásma.

Vypočtené výkonové spektrum bude použito jako frekvenční charakteristika filtru, kterým bude filtrován bílý šum. Stejně jako ve článku [41] budou i v rámci tohoto generátoru použity čtyři tvary výkonových spekter daných parametry f_l a f_h (v kombinaci $f_{l1}=30$ Hz a $f_{h1}=60$ Hz, $f_{l2}=40$ Hz a $f_{h2}=100$ Hz, $f_{l3}=60$ Hz a $f_{h3}=120$ Hz, $f_{l4}=50$ Hz a $f_{h4}=150$ Hz). Celý signál se rozdělí na úseky odpovídající přibližně 0,5 s. Pro každý úsek pak bude náhodně vybrán tvar spektra EMG a také bude náhodně generována hodnota amplitudy v rozmezí 0 až 10 % maximální hodnoty v měřeném EKG.

5.4 Aplikace šumů na signál

Všechny tři výše zmíněné typy šumů jsou šumy aditivní, stačí tedy vygenerované šumové hodnoty přičíst do původního signálu. Pro všechny tři šumy jsou realizovány funkce zvlášť, ale pro jednoduchost byly zároveň i spojeny do jedné funkce, kde může uživatel zadat, který šum chce do signálu přidat a jejich parametry. Výsledné šumy aplikované na vyfiltrováný signál jsou na obrázku 5.1.



Obr. 5.1: Aplikace vygenerovaných šumů na vyfiltrovaný signál.

6 Augmentace flutteru síní

Flutter síní bude augmentován ze záznamů EKG, ve kterých se tato arytmie už vyskytuje. Reálně naměřený signál EKG bude rozsekán na náhodný počet úseků o náhodných délkách a jejich pořadí bude náhodně promícháno.


Rozkouskováním a následným spojením signálu mohou vznikat nefyziologické signály, nebo se tímto postupem mohou do signálu vnášet vlastnosti jiných arytmií, jako například nepravidelnost RR intervalů, což je typické například pro fibrilaci síní. Nejlogičtější postupem, aby se tomuto zabránilo, se zdá rozsekat signál tak, aby úseky obsahovaly vždy celé srdeční cykly. To by znamenalo, že by se signál měl vždy rozseknout na začátcích vlny P, kde se u fyziologického signálu nachází počátek srdečního cyklu. Flutter síní je však patologický proces, na jehož EKG záznamu klasické P vlny nejsou a místo nich se tam nachází opakující se f vlny, takže se počátek srdečního cyklu nedá s určitostí označit.

Proto se v tomto případě jako místa rozkouskování signálu brala jako vrcholy QRS komplexů. Jedná se asi o nejjednodušeji lokalizovatelný významný bod v EKG, pro jehož vyhledání byla vyvinuta řada algoritmů. V tomto případě je navíc výhodou, že není nutné vyhledat všechny vrcholy v záznamu. Pokud nějaký nebude označen, tak se pouze v tomto místě signál nikdy nerozdělí. V používané databázi jsou pozice vrcholů QRS komplexů k dispozici. Pokud nebudou do realizované funkce pro augmentaci pozice QRS komplexů zadány, budou vyhledány pomocí funkce *ecg_peaks* z knihovny *neurokit2*. Dosažená pozitivní předpovědní hodnota detekovaných R vln pro 1 047 flutterů z databáze byla 96,65 %. Tato funkce nemusí být vždy při hledání R kmitů úspěšná (z 1 053 dostupných flutterů v databázi funkce nevyhledala pozice R kmitů u 6 signálů). Pokud nejsou touto funkcí R kmitů nalezeny, určí se prahová hodnota a jako pozice R kmitů jsou označeny maxima nad tímto prahem. Na základě vzorkovací frekvence a počtu vzorků vstupního signálu je určeno kolik QRS komplexů by se v signále mohlo nacházet při tepové frekvenci 40 tepů za minutu. Podle této hodnoty je v signále nalezeno odpovídající množství maxim, z nich je vybrán medián a vynásoben hodnotou 0.9 pro určení prahu. Pokud se při této hodnotě prahu nenalezne víc než 4 QRS komplexy, práh se postupně snižuje a hledá se znovu. Dosažená pozitivní předpovědní hodnota detekovaných R vln tímto způsobem pro 1 053 flutterů z databáze byla 88,26 %. Další výhodou rozdělení signálu v tomto místě je, že při následném zpětném spojování úseků signálu není nutné řešit přechodové jevy. V místech, kde na sebe budou úseky navazovat, by se neměly objevit velké skokové změny, pokud bude u signálu předem vyfitrované kolísání nulové izolinie.

Do vytvořené funkce pro augmentaci vstupuje originální signál a nadetekované pozice QRS komplexů, pokud jsou k dispozici. Je také možno zadat požadovanou

délku výstupního signálu a kolik úseků z původního signálu si přeje uživatel vytvořit. Pokud je zadán počet úseků, tak se z vektoru QRS komplexů náhodně vybere odpovídající počet míst, kde bude signál rozkouskovaný, přičemž první úsek vždy bude začínat prvním nadetekovaným vrcholem a posledním úsek bude končit posledním vrcholem. Pokud není počet úseků zadán, tak jako první pozice rozseknutí signálu je opět uložen první nadetekovaný QRS komplex signálu. Následující pozice je vždy náhodně vybrána z komplexů, které jsou v signálu situovány dál než předchozí vybraný, dokud se tímto postupem nedostaneme k poslednímu QRS komplexu v signále. Náhodné hodnoty z vektoru pozic QRS komplexů jsou vybírány funkcí *choice* z knihovny *random*.

Vytvořené úseky jsou poté pomocí funkce *random.permutation* z knihovny *numpy* proházeny bez opakování a poskládány za sebe v tomto náhodně vygenerovaném pořadí. Výsledek je zobrazen na obrázku 6.1. Pokud je zadána i požadovaná délka výstupního signálu, jsou do signálu dál přidávány úseky mezi náhodně vybranými QRS komplexy z původního signálu, dokud není délka vytvářeného signálu dostatečná.



Obr. 6.1: Výsledek augmentace flutteru síní permutací úseků signálu.

Také byla vytvořena modifikace této funkce, kam vstupují 2 svody stejného EKG. Výstupem jsou shodně proházené signály z původních 2 svodů. Důvodem vytvoření této modifikace je, že některé hluboké neuronové sítě pro klasifikaci využívají právě 2 svody EKG.

7 Augmentace atrioventrikulární blokády II. stupně

7.1 Augmentace AV blokády typu Mobitz I


Augmentace AV blokády II. stupně Mobitz I bude vycházet z filtrovaného sinusového rytmu. Vstupem do vytvořené funkce pro augmentaci je filtrovaný sinusový signál, jeho vzorkovací frekvence a parametr n , kterým se nastavuje poměr převedených vzruchů, každý n -tý vzruch se tedy nepřeveďe na komory. Také je možné na vstup dát nefiltrovaný signál a nastavit parametr vstupu *filtrace* = *True*, pak se provede filtrace filtry popsanými v kapitole 4.2. Uživatel taky může zadat požadovanou délku výstupního signálu.

U tohoto typu AV blokády dochází k prodlužování PQ intervalů, proto je nutné pozice těchto bodů v sinusovém rytmu nadetekovat. Budou k tomu využity funkce *ecg_peaks* a *ecg_delineate* z knihovny *neurokit2*. Tyto funkce umí vyhledat pozice všech významných bodů v EKG. Významné body a jejich umístění v jednom srdečním cyklu je zobrazeno na obrázku 7.1. Ukázka vyhledaných pozic bodů pomocí funkcí na sinusovém signále z databáze je na obrázku 7.2.

Podle parametru n jsou určeny cykly, které budou pozměněny tak, aby představovaly nepřeveďený vzruch ze síní na komory. Následně se upravují všechny $n-1$ cykly. U prvního cyklu, který následuje ihned po výpadku, nedochází k prodlužování PQ intervalu. V tomto cyklu je pouze změřeno, jak je dlouhý PQ interval. Poté se náhodně vybere procento zvětšení druhého cyklu z intervalu 40 až 60 % pomocí funkce *randint* z knihovny *random*. Jak bylo zmíněno v kapitole 4.1.1, tak u prvního zpomaleného vedení, bývá prodloužení PQ intervalu největší a postupně se zmenšuje. Proto se počet vzorků, o které bude každý další cyklus prodloužen zvětší náhodně jen o 5 až 10 % oproti předchozímu.

Jelikož by měla být zachována frekvence buzení síní, je nutné zajistit, aby se vzdálenost jednotlivých P vln nezvětšovala navzdory prodlužujícím se PQ interválům. Proto je nutné vždy zmenšit vzdálenost mezi koncem vlny T a začátkem vlny P následujícího cyklu o stejný počet vzorků, o které se prodloužil odpovídající PQ interval. Pokud by se úsek měl zmenšit o více vzorků než je jeho délka, dojde k přičtení následující vlny P k vlně T, k čemuž dochází i v reálných případech.

PQ interval i úsek od konce vlny T po začátek vlny P by měly odpovídat izolínii. [37] V těchto úsecích signálu, které jsou v rámci augmentace převzorkovávány, by tedy pro jednotlivé vzorky mělo zůstat přibližně konstantní napětí. Proto je při podvzorkování jednoduše odebráno z původního úseku požadovaný počet vzorků z náhodných míst. A při nadvzorkování jsou na náhodných místech vkládány nové




Obr. 7.1: EKG křivka s vyznačenými významnými body. Převzato a upraveno z [4].

vzorky, jejichž hodnota je daná průměrem sousedních hodnot.


U n -tých srdečních cyklů, kde je simulováno nepřevedení vzruchu ze síní na komory, je potřeba se signálu odstranit QRS komplex a vlnu T, které odpovídají aktivitě komor. Proto jsou úseky od konce vlny P po konec vlny T nahrazeny lineárně rozloženým vektorem, který je generovaný funkcí *linspace* z knihovny *numpy*. Tento vektor má stejnou délku, jako je nahrazovaný úsek, a jde o lineární rozložení mezi hodnotami, kterých nabývají body označené jako konec vlny P a konec vlny T. Výsledek augmentace je na obrázku 7.3.

V některých případech nemusí funkce *ecg_peaks* a *ecg_delineate* najít ve vstupním signálu dostatečné množství významných bodů pro provedení augmentace. Proto na výstupu funkce je mimo augmentovaného signálu i logická proměnná, která určuje, zda byla augmentace provedena, nebo nikoliv.

Pokud uživatel zadá délku požadovaného signálu, je signál, který vznikl výše popsaným způsobem, nakopírovaný za sebe a z něj je vyříznut úsek o zadané délce.



Obr. 7.2: EKG křivka s vyznačenými významnými body určenými pomocí funkcí *ecg_peaks* a *ecg_delineate* z knihovny *neurokit2*.



Obr. 7.3: Augmentovaná AV blokáda II. stupně typu Mobitz I a původní sinusový rytmus.

7.2 Augmentace AV blokády typu Mobitz II

Obdobně jako Mobitz I bude i tato blokáda augmentována změnou filtrovaného sinusového rytmu. Do funkce pro augmentaci vstupuje sinusový signál, jeho vzorkovací frekvence, popřípadě parametr *filter* = *True* pro filtraci vstupního signálu. Také je možné nastavit, jestli má v rámci celého signálu dojít pouze k jednomu nepřeve-


dení vzruchu ze síní na komory, nebo jestli se nepřeveďte každý n -tý vzruch, přičemž velikost n jde nastavit.

Opět jsou pomocí funkcí *ecg_peaks* a *ecg_delineate* z knihovny *neurokit2* vyhledány významné body v EKG. Následně je podle zvoleného n určeno, u kterých cyklů nedojde k převodu vzruchu na komory. Pokud je vybrána možnost nepřevedení jenom jedné P vlny, je tento cyklus vybrán pomocí funkce *randint* z knihovny *random*. Pokud je zadáno konkrétní n , tak je vygenerován vektor indexů cyklů, u kterých má dojít k přerušení vedení, pomocí funkce *arange* z knihovny *numpy*. První vypadnutý komplex nemusí být na n -té pozici, protože i u reálně zaznamenaného EKG málokdy úsek začíná přesně prvním převedeným cyklem a jsou na něm vidět všechny $n-1$ převedené vzruchy před prvním výpadkem. Toto posunutí je opět generováno náhodně.

U srdečních cyklů, kde je simulováno nepřevedení vzruchu ze síní na komory, jsou úseky od konce vlny P po konec vlny T nahrazeny lineárně rozloženým vektorem o stejné velikosti jako je nahrazovaný úsek. Lineární rozložení je mezi hodnotami, kterých nabývají body označené jako konec vlny P a konec vlny T. Vektor je vygenerován funkcí *linspace* z knihovny *numpy*.

Aby se kompenzovaly nově vložené lineární úseky, je k signálu přičten drift generovaný funkcí popsanou v kapitole 5.2. Výsledný augmentovaný signál je na obrázku 7.4.

Opět v některých případech nemusí funkce *ecg_peaks* a *ecg_delineate* najít ve vstupním signálu významné body potřebné pro provedení augmentace. Proto na výstupu funkce je mimo augmentovaného signálu i logická proměnná, která určuje, zda byla augmentace provedena, nebo nikoliv.



Obr. 7.4: Augmentovaná AV blokáda II. stupně typu Mobitz II a původní sinusový rytmus.

8 Augmentace atrioventrikulární blokády III. stupně

Augmentace atrioventrikulární blokády III. stupně bude vycházet ze sinusového rytmu. Pomocí funkcí *ecg_peaks* a *ecg_delineate* z knihovny *neurokit2* se vyhledají všechny významné body v EKG. V tomto případě nás konkrétně budou zajímat počátky a konce vln P, Q kmitů a konce vln T. Pozice těchto bodů budou využity pro extrakci částí EKG signálů, které odpovídají aktivitě síní a částí odpovídající aktivitě komor. Také budou použity pozice kmitů S a počátky vln T.

Do funkce vstupuje sinusový signál a jeho vzorkovací frekvence. Také je možné nastavit parametr, který ovlivní délku výstupního signálu napodobujícího AV blokádu. Pokud tento parametr uživatel nevyplní, tak se každý detekovaný cyklus použije pouze jednou. Pokud je zadána požadovaná délka výstupního signálu, tak se ze všech detekovaných částí náhodně vybírá, které budou použity, takže například některé P vlny se mohou ve výsledném signálu objevit vícekrát a některé vůbec.

Vstupní sinusový signál je vyfiltrovaný horní propustní zmíněnou v kapitole 4.2 s mezní frekvencí 0.7 Hz, aby bylo odstraněno kolísání nulové linie v signálu. Pokud uživatel zadá parametr *filtrace = True*, jsou ze signálu navíc vyfiltrovány myopotenciály. Pomocí výše zmíněných funkcí jsou nadetekovány potřebné pozice kmitů a vln. Pokud nejsou nalezeny body alespoň 4 P vln a 3 QRS komplexy, ukončí se augmentace a kontrolní logická proměnná, určující úspěšnost augmentace, se nastaví na hodnotu *False*. Poté jsou náhodně vybrány frekvence síní a komor (funkce *randint* z knihovny *random*). Jak již bylo zmíněno v kapitole 4.1.2, frekvence síní bývá vyšší než frekvence komor, proto se pro síně vybírá frekvence z intervalu od 60 do 120 za minutu a pro komory od 40 do 60 za minutu.


Základ pro nový signál bude tvořit nulová linie, která je generována funkcí *zeros* z knihovny *numpy*. Délka je nastavena buď podle požadované délky uživatele nebo podle počtu nadetekovaných P vln a vygenerované frekvence.

K nulové linii jsou na místech odpovídajících vygenerované frekvenci síní přičítány vyextrahované P vlny z původního sinusového signálu. Přestože byl signál filtrován horní propustí, tak v některých částech P vlny se mohou objevovat záporné hodnoty, proto je ke každému vzorku P vlny přičtena absolutní hodnota průměru záporných prvků P vlny. Nabízí se možnost, aby byla přičtena absolutní hodnota minimální záporné hodnoty P vlny, ale jelikož detektor počátku a konců P vlny není úplně přesný, tak v některých případech je jako konec P vlny označena záporná část signálu, která odpovídá už spíše kmitu Q. P vlna je poté ještě oříznuta tak, aby obsahovala pouze nezáporné hodnoty.

Dál jsou k nulovému signálu s P vlnami přičteny části sinusového signálu, které

odpovídají aktivitě komor, tyto úseky jsou brány od bodu Q po konec vlny T. Tyto úseky mohou mít opět nevhodnou úroveň, tedy mohou být vlivem nedokonalé filtrovaného driftu posunuty do vyšších nebo nižších hodnot. Úsek ST by měl odpovídat izoelektrické linii, proto se od každého prvku signálu odečte mediánová hodnota tohoto úseku, aby se úsek posunul přibližně na nulovou izoelektrickou linii.

Výsledný vygenerovaný signál je následně filtrován mediánovým filtrem s oknem o velikosti 5, který byl vytvořen funkcí *signal.medfilt* z knihovny *scipy*. Nakonec je k signálu přidán drift generovaný funkcí popsanou v kapitole 5.2, aby byla kompenzována izolinie v podobě nulového signálu. Příklad výsledného augmentovaného signálu je na obrázku 8.1.



Obr. 8.1: Augmentovaná AV blokáda III. stupně a původní sinusový rytmus.

9 Augmentace AV blokády II. stupně pomocí GAN

Přestože je trénování GAN náročné, byly publikovány články, ve kterých bylo učení GAN pro generování EKG celkem úspěšné (některé jsou popsány v kapitole 3.3). Proto i v rámci této práce byla snaha naučit GAN generovat AVB II. stupně.

Architektura sítě byla inspirována úspěšnou GAN popsanou v [29], kde generátor vycházel z architektury U-Net a diskriminátor v podobě CNN z [33]. V rámci optimalizace byly různě měněny počty konvolučních vrstev. Také byl zkoušen vliv vrstev fázového míchání, které byly použity v diskriminátoru v [33]. Přítomnost těchto vrstev pouze zpomalovala průběh učení a na výstupy z generátoru po vizuální stránce neměly vliv, proto ve výsledné síti nebyly použity. Výsledná použitá architektura je na obrázku 9.1.

Do diskriminátoru vstupují buď reálné nebo generované signály, které prochází 6 konvolučními vrstvami (použité velikosti jader a podvzorkování je zobrazeno na schématu 9.1). Jako aktivační funkce je zde použita LeakyReLU s nastaveným prahem na 0,2. Nakonec signál prochází plně propojenou vrstvou se sigmoidální aktivační funkcí s binárním výstupem.

Vstupem generátoru je náhodný šum o velikosti požadovaného výstupního signálu 2500×1 , poté prochází 5 konvolučními bloky pro podvzorkování a následně 5 bloky, které signál zpětně nadvzorkovávají. U prvních 5 bloků je použita LeakyReLU aktivační funkce, u následujících 4 bloků je použita ReLU, pro aktivační funkci výstupní vrstvy generátoru byl použit hyperbolický tangens. Byla použita batch normalizace. Červené šipky na obrázku 9.1 ukazují, u kterých bloků proběhla konkaténace.

Jako učební množina dat byly použity signály generované funkcemi pro augmentaci AVB II. stupně popsané výše. AV blokády byly generované ze sinusových rytmů z databáze popsané v kapitole 4. Celkem bylo vygenerováno 3 840 signálů o 2 500 vzorcích, které byly normalizovány do intervalu $\langle -1; 1 \rangle$.

Dalším nastavovaným parametrem byla **kriteriální funkce**. Přestože je ve většině článků jako nejstabilnější kriteriální funkce uváděna Wassersteinova vzdálenost s penalizováním normy gradientu, nebyla nalezena kombinace nastavitelných hyperparametrů, architektury sítě a normalizace, která by při použití této kriteriální funkce udržela stabilitu při učení po více než 5 epoch. Gradient vždy po pár epochách buď vymizel nebo extrémně narostl, takže učení nemohlo pokračovat. Při použití Wassersteinovy vzdálenosti s ořezáváním vah byla stabilita různě nastavených sítí udržena většinou po více než 100 epoch, ale výstupy z generátoru (obrázek 9.2) se nepodobají EKG. Jako neúspěšnější se v tomto případě jevila kriteriální funkce


v podobě binární křížové entropie, která byla představena v původním článku [9]. Byl využit trik popsáný v kapitole 2.1, kdy se „tvrdé“ označení 0 pro falešné a 1 pro reálné vzorky mírně transformují do „hladší“ podoby. Nejprve byla vyzkoušena pouze úprava označení třídy u reálných vzorků na hodnotu 0,9, následně i změna ohodnocení obou tříd, kdy reálné vzorky byly ohodnoceny náhodnými čísly z intervalu $<0,7; 1,2>$ a falešné náhodnými hodnotami z intervalu $<0,0; 0,3>$. Rozdíl mezi těmito dvěma nastaveními nebyl patrný a nakonec byla použita první zmíněná varianta.

Dále byl zkoušen vliv **normalize**. Pro generátor a diskriminátor byly vyzkoušeny různé kombinace batch, spektrální a váhované normalizace a také bez normalizace. Po vizuální stránce výstupu z generátoru dopadlo nejlépe použití batch normalizace pro generátor a bez normalizace pro diskriminátor.


Váhy diskriminátoru byly upravovány třikrát častěji než váhy generátoru. Diskriminátor byl zvlášť trénován na reálných a zvlášť na falešných vzorcích. Všechny váhy byly inicializovány malou hodnotou z normálního rozložení se směrodatnou odchylkou 0,02. Pro diskriminátor i generátor byl použit optimalizační algoritmus ADAM (*krok učení* = 0.0002). Velikost batche byla nastavena na 256 vzorků.

Kvůli časové náročnosti byla každá varianta nastavení GAN učená maximálně po 200 epoch. U konečné použité verze bylo vyzkoušeno učení po dobu 400 epoch.


Výstupy z generátoru nebyly hodnoceny žádným sofistikovanějším způsobem jako například klasifikátorem AVB, protože se nepovedlo vytvořit reálně vypadající signály. Proto byly hodnoceny pouze na základě alespoň částečné vizuální podobnosti s reálnými AV blokádami. Na obrázku 9.3 je vidět, že generátor vytváří signál, kde se opakují části velmi podobné EKG srdečním cyklům, opakování těchto cyklů je však naprosto nepravidelné. Občas jsou patrné i delší výpadky cyklů, jako je typické pro AVB. Celkově je síť velmi nestabilní a výstup silně závisí na náhodném vstupním vektoru, což je vidět např. na obrázku 9.4, kde jsou vyobrazeny 3 výstupy z generátoru při různém vstupu ve stejné epoše učení. Ani po delším učení po dobu 400 epoch generátor neměl na výstupu reálněji vypadající vzorky. Velmi často docházelo k tomu, že generátor po dobu například 10 epoch měl na výstupu vzorky, co alespoň vzdáleně připomínaly EKG signál, a následně po dobu například dalších 50 epoch byl na výstupu opět šum. Proto nepovažuji generátor za dostatečně naučený a je tedy zřejmě nevhodný pro augmentaci dat a nebude při závěrečném porovnání implementovaných augmentací brán v potaz.




Obr. 9.1: Blokové schéma sítí diskriminátoru a generátoru.



Obr. 9.2: Ukázka výstupů z generátoru po učení po dobu 50, 70 a 120 epoch při použití Wassersteinovy vzdálenosti s ořezáváním vah.



Obr. 9.3: Ukázka výstupů z generátoru po učení po dobu 50, 100, 130, 140 a 335 epoch při použití kritériální funkce v podobě binární křížové entropie.



Obr. 9.4: Ukázka 3 výstupů z generátoru po 80. epoše učení pro 3 různé náhodné vstupní šumy.

10 Vyhodnocení úspěšnosti augmentace

10.1 Vyhodnocení úspěšnosti augmentace flutteru síní z pohledu neuronových sítí

Pro vyhodnocení úspěšnosti augmentace flutteru síní byl použit klasifikátor v podobě hluboké neuronové sítě navržený a popsáný v [42].

Sít klasifikuje 4 skupiny: sinusový rytmus (SR), fibrilaci síní (FIB), flutter síní (FL) a ostatní arytmie (Ostatní). Převážná část použitých dat pochází z databáze popsané v kapitole 4. Autorka [42] zmíněnou databázi obohatila o málo zastoupenou třídu flutteru síní z internetové databáze PhysioNet Challenge 2021. Každý EKG záznam v databázi může být ohodnocen více typy arytmií, například jeden signál může být označen jako fibrilace a zároveň jako flutter síní. Jelikož síť zařazuje každý vstupní signál pouze do jedné z výše zmíněných kategorií, je jako výsledná arytmie brána vždy ta závažnější. Pokud je tedy v databázi signál označen jako flutter i fibrilace síní, síť ho bude pokládat za fibrilaci síní. Do sítě vstupují signály o délce 5 000 vzorků, pokud je vstupní signál delší, je na požadovanou délku oříznut, pokud je kratší, je doplněn nulami. Databáze byla rozdělena na trénovací, validační a testovací množiny. Počty záznamů v klasifikovaných skupinách jsou uvedeny v tabulce 10.1. Podrobnější informace jsou v [42].

Tab. 10.1: Počty EKG záznamů v klasifikovaných skupinách v jednotlivých množinách pro klasifikátor FL. **SR** - sinusový rytmus, **FIB** - fibrilace síní, **FL** - flutter síní, **Ostatní** - ostatní arytmie.

	Trénovací	Trénovací augmentovaná	Validační	Testovací
SR	5000	5000	800	1000
FIB	5023	5023	809	1006
FL	2761	5000	595	589
Ostatní	5546	5546	1241	1000

V tabulce 10.1 jsou naznačeny i počty signálů pro trénovací množinu po augmentaci dat. V tomto případě byla navyšována pouze klasifikační skupina flutteru síní do počtu 5 000 záznamů, aby množství přibližně odpovídalo zastoupení ostatních klasifikovaných skupin. Z původních 2 761 záznamů flutterů na začátku bylo náhodně vybráno 2 239 signálů do počtu 5 000 a při augmentaci bylo manipulováno již pouze s touto vybranou podmnožinou.

Nejprve byla síť trénována na původním nevyváženém setu (**P**), následně bylo v trénovací množině nakopírováno 2 239 flutteru síní (**K**). Poté byly vyzkoušeny augmentace navržené v této práci. Dvě trénovací množiny byly doplněny fluttery generovaných funkcí, která provádí permutaci nakouskovaného signálu (popis funkce v kapitole 6). V prvním případě byla nastavena délka výstupního permutovaného signálu na stejný počet vzorků, jako měl vstupní signál (**M1**). Pro druhý set byly generovány signály o délce 5 000 vzorků (**M2**), protože do sítě vstupují signály o této velikosti. Další 4 rozdílné trénovací množiny byly připraveny za použití náhodně generovaného šumu (použitý generátor pro šumy je popsán v kapitole 5). Nejprve byly vytvořeny množiny, kde byl k nakopírovaným flutterům přičten vždy jenom jeden typ šumu, vznikla tedy zvlášť množina augmentovaná přičtením brumu (**M3**), driftu (**M4**) a myopotenciálů (**M5**). V poslední množině byla ke každému z nakopírovaných flutterů přičítaná náhodná kombinace šumů (**M6**). Amplitudy všech šumů byly generovány náhodně.

Každá z těchto 8 množin byla použita zvlášť ke trénování klasifikační sítě. Učení probíhalo vždy po dobu 40 epoch a jako výsledek trénování byla brána epocha, kdy klasifikátor dosáhl nejlepšího průměrného F1 skóre přes všechny 4 kategorie pro validační množinu. Výsledná F1 skóre všech kategorií a jejich průměr pro testovací množinu jsou v tabulce 10.2.

Z tabulky 10.2 je patrné, že navyšování počtu flutterů v databázi výrazně neměnilo F1 skóre testovací množiny. Některé z vyzkoušených augmentací nepatrně navýšila F1 skóre pro flutter síní, ale vždy méně než o 1 %. Jelikož však neklesla úspěšnost sítě ani při učení nevyváženým datasetem, ve kterém bylo téměř o polovinu méně záznamů flutteru síní než ostatních kategorií, je možná v tomto konkrétním případě další umělé navyšování méně zastoupené kategorie zbytečné. Jedním z důvodů může být, že nepoměr dat není tak vysoký, aby při učení byla kategorie s nižším zastoupením viditelně znevýhodněna. Dalším důvodem mohou být záznamy přidávané z externí internetové databáze. Tyto signály flutteru síní byly ručně vybírány autorkou [42] a představují tedy ukázkové signály s typickou morfologií pro flutter síní. Je proto možné, že síti stačí méně těchto vzorových signálů pro vyhledání důležitých příznaků popisujících klasifikační třídu flutter síní.

Jelikož ve výše zmíněném příkladu bylo použití augmentace neprůkazné, byla znovu augmentace vyzkoušena na více nevyvážené databázi. Z původních množin dat byly odstraněny záznamy, které byly přidány z internetové databáze PhysioNet Challenge 2021. Všechna data, která byla použita v tomto případě pochází z databáze popsané v kapitole 4. Počty záznamů v klasifikovaných skupinách pro tuto zmenšenou databázi jsou uvedeny v tabulce 10.3.

Pro tento zmenšený více nehomogenní dataset byly provedeny stejné augmentace jako v předchozím případě. Každý z dostupných 713 flutterů byl funkcemi k aug-

Tab. 10.2: Výsledné F1 skóre všech kategorií a jejich průměru pro testovací množinu při učení různými trénovacími datasy. Trénovací datasy: **P** - data bez úpravy počtů, **K** - nakopírování FL do počtu 5 000, **M1** - augmentace FL permutací úseků při zachování délky signálu, **M2** - augmentace FL permutací úseků a prodloužení signálu na délku 5 000 vzorků, **M3** - přičtení brumu k nakopírovaným FL, **M4** - přičtení driftu k nakopírovaným FL, **M5** - přičtení myopotenciálů k nakopírovaným FL, **M6** - přičtení náhodných šumů k nakopírovaným FL. Kategorie: **SR** - sinusový rytmus, **FIB** - fibrilace síní, **Ostatní** - ostatní arytmie, **FL** - flutter síní.

	SR	FIB	Ostatní	FL	Rozdíl FL oproti FL množiny P	Průměr
P	0,820	0,750	0,736	0,679	-	0,747
K	0,810	0,762	0,728	0,674	-0,005	0,744
M1	0,825	0,761	0,738	0,675	-0,005	0,749
M2	0,814	0,767	0,745	0,684	0,005	0,753
M3	0,808	0,763	0,728	0,684	0,005	0,746
M4	0,808	0,773	0,727	0,685	0,006	0,748
M5	0,811	0,724	0,720	0,681	0,002	0,734
M6	0,801	0,750	0,732	0,672	-0,007	0,739

Tab. 10.3: Počty EKG záznamů v klasifikovaných skupinách v jednotlivých množinách pro zmenšenou databázi. **SR** - sinusový rytmus, **FIB** - fibrilace síní, **FL** - flutter síní, **Ostatní** - ostatní arytmie.

	Trénovací	Trénovací augmentovaná	Validační	Testovací
SR	5000	5000	800	1000
FIB	5000	5000	805	998
Ostatní	5412	5412	1208	1000
FL	713	3565	168	172

mentaci změněn čtyřikrát. Takže i s přidáním 713 nezměněných signálů bylo v trénovací množině 3 565 záznamů. Výsledná F1 skóre všech kategorií a jejich průměr pro testovací množinu jsou v tabulce 10.4.

Z tabulky 10.4 jde vidět, že v této zmenšené a mnohem nehomogenněji rozložené


Tab. 10.4: Výsledné F1 skóre všech kategorií a jejich průměru pro testovací množinu při učení různými trénovacími dataseťmi pro více nehomogenní databázi pro klasifikátor FL. Trénovací dataseť: **P** - data bez úpravy počtů, **K** - nakopírování FL do počtu 5 000, **M1** - augmentace FL permutací úseků při zachování délky signálu, **M2** - augmentace FL permutací úseků a prodloužení signálu na délku 5 000 vzorků, **M3** - přičtení brumu k nakopírovaným FL, **M4** - přičtení driftu k nakopírovaným FL, **M5** - přičtení myopotenciálů k nakopírovaným FL, **M6** - přičtení náhodných šumů k nakopírovaným FL. Kategorie: **SR** - sinusový rytmus, **FIB** - fibrilace síní, **Ostatní** - ostatní arytmie, **FL** - flutter síní.

	SR	FIB	Ostatní	FL	Rozdíl FL oproti FL množiny P	Průměr
P	0,777	0,880	0,728	0,486	-	0,718
K	0,822	0,878	0,738	0,523	0,037	0,740
M1	0,800	0,879	0,734	0,536	0,050	0,737
M2	0,816	0,888	0,738	0,511	0,025	0,738
M3	0,806	0,878	0,732	0,509	0,023	0,731
M4	0,817	0,863	0,714	0,503	0,017	0,724
M5	0,826	0,879	0,740	0,495	0,009	0,735
M6	0,809	0,888	0,734	0,505	0,018	0,734

databázi už má rozkopírování dat vliv na úspěšnost učení. F1 skóre pro flutter síní po trénování na nehomogenní databázi (**P**) bylo 0,486 a při rozkopírování flutteru v trénovací množině (**K**) se zvýšilo na 0,523. V tabulce 10.4 je také zaznamenán rozdíl F1 skóre flutteru mezi původními daty a použitými augmentacemi.

Pouze augmentace v podobě permutace signálu při zachování délky vstupního signálu (**M1**) dosáhlo lepšího F1 skóre pro flutter síní, konkrétně o 1,3 % oproti pouhému nakopírování dat a o 5 % oproti nehomogennímu datasetu. Zároveň však ale kleslo průměrné F1 skóre přes všechny kategorie, protože pokleslo F1 skóre u sinusového rytmu o 2,2 % oproti trénování množinou **K**. Na obrázku 10.1 jsou zobrazeny výsledné matice záměn, ze kterých je vidět, že při použití augmentovaných dat bylo více sinusových rytmů označeno jako kategorie Ostatní. Tento celkový pokles úspěšnosti sítě mohl být způsoben tedy spíš počáteční inicializací sítě a náhodným rozdělením signálů do batchů než přidáním augmentovaných dat.

Zajímavý je také výsledek pro augmentaci permutace signálu do délky 5 000 vzorků (**M2**). Při tomto typu augmentace sice pokleslo F1 skóre jak u flutteru síní, tak i to



Obr. 10.1: Matice záměn pro více nehomogenní datasety: K, M1 a M2.

průměrné, ale z matice záměn (obrázek 10.1) jde vidět, že se částečně zlepšilo rozlišování sítě mezi flutterem a fibrilací sítí. V tomto případě byl největší problém, že síť více signálu z kategorie Ostatní označila za flutter.

U všech 4 datasetů (**M3-6**), kde byla augmentace provedena přidáním šumu, se snížilo nejen průměrné F1 skóre ale povětšinou i F1 skóre všech kategorií oproti množině, kde byly záznamy flutterů pouze rozkopírovány (**K**), proto se tento typ augmentace zdá jako nevhodný.

Nakonec bylo vyzkoušeno ještě další možné využití generovaného šumu, kdy byl s nízkou amplitudou přičítán ke všem signálům z databáze. Byl předpoklad, že by se tím mohla vnést variabilita do celého datasetu. V každé epoše byla přičítána náhodná kombinace nově generovaných šumů. Žádná data nebyla při vstupu do sítě filtrována. Avšak ani tato snaha, jak vnést nové informace do datasetu, nebyla úspěšná. Výsledná F1 skóre všech kategorií se významně nezměnila.

10.2 Vyhodnocení úspěšnosti augmentace atrioventrikulárních bloků z pohledu neuronových sítí

Pro vyhodnocení úspěšnosti augmentace AV bloků byl také použit klasifikátor v podobě hluboké neuronové sítě navržený a popsáný v [42].

Síť klasifikuje 5 skupin: sinusový rytmus (SR), atrioventrikulární blokády I., II. a III. stupně (AVB1, AVB2 a AVB3) a ostatní arytmie (Ostatní). Opět převážná část použitých dat pochází z databáze popsané v kapitole 4. Autorka [42] zmíněnou databázi obohatila o málo zastoupené třídy AVB2 a AVB3 z internetové databáze PhysioNet Challenge 2021 a o další záznamy poskytnuté firmou MDT s.r.o., ze které

pocházejí data popsané v této práci. EKG záznamy v databázi mohou být ohodnoceny více typy arytmií. Pokud je signál označen více typy AVB, klasifikátor bere v potaz pouze nejvyšší stupeň blokády, kterou je signál označen. Do sítě vstupují signály o délce 10 000 vzorků, pokud je vstupní signál delší, je na požadovanou délku oříznut, pokud je kratší, je doplněn nulami. Databáze byla rozdělena na trénovací, validační a testovací množiny. Počty záznamů v klasifikovaných skupinách jsou uvedeny v tabulce 10.5. Podrobnější informace jsou v [42].

Tab. 10.5: Počty EKG záznamů v klasifikovaných skupinách v jednotlivých množinách pro klasifikaci AVB. **AVB1** - atrioventrikulární blokáda I. stupně, **AVB2** - atrioventrikulární blokáda II. stupně, **AVB3** - atrioventrikulární blokáda III. stupně, **Ostatní** - ostatní arytmie.

	Trénovací	Trénovací augmentovaná	Validační	Testovací
AVB1	1853	1853	398	397
AVB2	771	1 850	243	234
AVB3	309	1 854	82	88
Ostatní	2000	2000	700	700
SR	2000	2000	700	700

Množina *Trénovací augmentovaná* v tabulce 10.5 představuje počty, do kterých budou záznamy AVB2 a AVB3 rozkopírovány a nebo augmentovány. Počty a typy augmentací EKG záznamů kategorií AVB2 a AVB3 v rozdílných trénovacích množinách jsou shrnuty v tabulce 10.6 a budou i popsány dále.

První způsob, jak bude odstraněna nehomogenita v datech je rozkopírování dostupných dat (**K**). U AVB2 budou všechny záznamy rozkopírovány méně než třikrát, aby bylo dosaženo počtu 1 850. Všechny záznamy AVB3 budou v trénovací množině šestkrát. Další typ augmentace (**M1** a **M2**) bude představovat doplnění signálů AVB2 a AVB3 záznamy generovanými funkcemi, které upravují sinusový rytmus do podoby AVB (funkce jsou popsány v kapitolách 7 a 8). Všechny AVB byly generovány ze sinusových rytmů, které jsou součástí trénovací množiny. Pro AVB2 bylo generováno 1 079 záznamů, kdy přibližná polovina signálu byla generována funkcí pro Mobitz I a druhá polovina funkcí pro Mobitz II. Parametr n určující, které cykly při blokádě vypadnou, byl generován náhodně. Pro AVB3 bylo funkcí vytvořeno 1 545 záznamů. Pro první trénovací množinu (**M1**) byly generovány signály o délce původního sinusového rytmu. Pro druhou takto vytvořenou množinu (**M2**) byly generovány signály o délce 10 000 vzorků, mimo záznamy generované funkcí

Tab. 10.6: Počty a typy augmentací EKG záznamů **AVB3** a **AVB2** v rozdílných trénovacích množinách **P**, **K**, **M1-7**. **Původní** - reálné záznamy z databáze, **generované** - signály generované ze SR funkcemi z kapitol 7 a 8 - červeně označené signály byly generovány o délce 10 000 vzorků, **šumové** - reálné signály zašuměné náhodnou kombinací šumů z generátoru popsaným v kapitole 5.

	AVB3			AVB2		
	původní	generované	šumové	původní	generované	šumové
P	309	-	-	771	-	-
K	1854	-	-	1850	-	-
M1	309	1545	-	771	1079	-
M2	309	1545	-	771	1079	-
M3	927	927	-	1310	540	-
M4	618	-	1236	771	-	1079
M5	618	618	618	771	539	540
M6	-	1854	-	-	1850	-
M7	-	1854	-	-	1850	-

pro Mobitz II, kde není nastavení délky možné. V další trénovací množině (**M3**) bylo přidáno méně generovaných dat funkcemi a zároveň byly i nakopírovány původní signály. Konkrétně pro AVB2 bylo v množině reálných 1 310 signálů (771 původních a 539 z nich nakopírovaných) a 540 záznamů generovaných funkcemi opět o délce vstupních SR. A pro AVB3 bylo 927 reálných signálů (třikrát rozkopírovaných 309 záznamů) a 927 signálů generovaných funkcí o délce vstupních sinusových rytmů. Přestože u klasifikátoru pro flutter síní neměla augmentace v podobě přidání šumu dobré výsledky, byl stejný způsob vyzkoušen částečně i zde. K signálům AVB2 a AVB3 byla přičítaná náhodná kombinace šumů o náhodných amplitudách. Další trénovací množinu (**M4**) tedy v případě AVB2 tvořilo 771 původních záznamů a 1 079 zašuměných. Pro AVB3 v této množině bylo 618 záznamů AVB3 z databáze (dvakrát nakopírovaných 309) a 1236 zašuměných signálů AVB3. V další množině (**M5**) byla vyzkoušena kombinace původních, generovaných i zašuměných dat. Pro AVB2 bylo v množině 771 původních dat, 539 generovaných a 540 zašuměných. Pro AVB3 bylo použito 618 původních signálů, 618 generovaných a 618 zašuměných.

Navíc bylo ještě vyzkoušeno, jak se síť zachová, pokud budou v trénovací množině všechny AVB2 a AVB3 pouze generované signály. Opět byly vyzkoušeny 2 varianty s 2 různými délkami generovaných signálů, tedy o délkách původních vstupních SR (**M6**) a o délce 10 000 (**M7**).

Každá z těchto 9 množin byla použita zvlášť ke trénování klasifikační sítě. Učení probíhalo vždy po dobu 45 epoch a jako výsledek trénování byla brána epocha, kdy klasifikátor dosáhl nejlepšího průměrného F1 skóre přes všech 5 kategorií pro validační množinu. Výsledná F1 skóre všech kategorií a jejich průměr pro testovací množinu jsou v tabulce 10.7. V tabulce 10.8 jsou zapsány rozdíly mezi F1 skóre AVB3 a AVB2 augmentovaných množin (**M1-7**) a nehomogenní (**P**) a nakopírovanou (**K**) množinou.

Tab. 10.7: Výsledné F1 skóre všech kategorií a jejich průměru pro testovací množinu při učení různými trénovacími datasety pro klasifikátor AVB. Složení trénovacích množin je popsáno v tabulce 10.6. Kategorie: **AVB3** - atrioventrikulární blokáda III. stupně, **AVB2** - atrioventrikulární blokáda II. stupně, **AVB1** - atrioventrikulární blokáda I. stupně, **SR** - sinusový rytmus, **Ostatní** - ostatní arytmie.

	SR	AVB3	AVB2	AVB1	Ostatní	Průměr
P	0,784	0,715	0,885	0,809	0,734	0,785
K	0,806	0,735	0,897	0,829	0,739	0,801
M1	0,797	0,735	0,886	0,830	0,733	0,796
M2	0,809	0,715	0,885	0,826	0,734	0,794
M3	0,795	0,763	0,908	0,825	0,736	0,805
M4	0,798	0,740	0,878	0,817	0,737	0,794
M5	0,791	0,748	0,885	0,811	0,717	0,791
M6	0,791	0,363	0,572	0,765	0,690	0,636
M7	0,778	0,277	0,513	0,776	0,673	0,604

Pro všechny trénovací množiny, kam byly přidány augmentované signály (mimo množiny M6 a M7, kde byly v trénovací množině čistě jenom augmentované záznamy), bylo dosaženo většího F1 skóre pro AVB3 než pro trénování sítě na nehomogenním datasetu. Avšak vyššího F1 skóre pro AVB3 oproti trénovací množině, kde byla nehomogenita datasetu odstraněna rozkopírováním signálů (**K**), dosáhlo málo množin s augmentovanými daty. Nejúspěšnější byl dataset **M3**, kde byly záznamy částečně rozkopírovávány a částečně byly přidány generované signály. V tomto případě bylo výsledné F1 skóre pro AVB3 o 2,8 % vyšší než při nakopírování dat. O 1,3 % se také zvedlo F1 skóre AVB3 pro učební množinu **M5**, ve které byla kombinace rozkopírovaných, generovaných a zašuměných dat. Naopak o 2 % pokleslo F1 skóre AVB3 datasetu **M2** oproti nakopírované množině. V tomto datasetu byly augmentovány signály o délce 10 000 vzorků.


Úspěšnost při augmentaci AVB2 byla menší. Pouze množina **M3** navýšila F1 skóre

Tab. 10.8: Rozdíly F1 skóre kategorií AVB2 a AVB3 augmentovaných datasetů (**M1-7**) oproti nehomogenní (**P**) a nakopírované (**K**) množině. Složení trénovacích množin je popsáno v tabulce 10.6. Kategorie: **AVB3** - atrioventrikulární blokáda III. stupně, **AVB2** - atrioventrikulární blokáda II. stupně.

	AVB3	Rozdíl oproti AVB3 množiny P	Rozdíl oproti AVB3 množiny K	AVB2	Rozdíl oproti AVB2 množiny P	Rozdíl oproti AVB2 množiny K
P	0,715	-	-	0,885	-	-
K	0,735	0,020	-	0,897	0,013	-
M1	0,735	0,020	0,001	0,886	0,002	-0,011
M2	0,715	0,000	-0,020	0,885	0,000	-0,013
M3	0,763	0,048	0,028	0,908	0,023	0,010
M4	0,740	0,025	0,005	0,878	-0,007	-0,020
M5	0,748	0,033	0,013	0,885	0,000	-0,013
M6	0,363	-0,353	-0,372	0,572	-0,313	-0,325
M7	0,277	-0,438	-0,458	0,513	-0,372	-0,384

kategorie AVB2 oproti nakopírovanému datasetu, a to konkrétně o 1 %. Proto se celkově dataset **M3** dá označit za nejúspěšnější.

Celková věrohodnost generovaných signálů AVB2 a AVB3 jde také posoudit z výsledků pro trénovací množiny **M6** a **M7**. V těchto trénovacích datasetech byly pouze generované AVB2 a AVB3. F1 skóre pro AVB3 se pohybovalo pouze okolo 30 % a F1 pro AVB2 okolo 50 %, přičemž výsledky pro kratší generované signály byly vyšší. Na obrázku 10.2 jsou výsledné matice záměn pro testovací dataset. Po trénování množinou **M6**, kde byly generovány signály o délkách vstupních SR, bylo 32 z 88 signálů AVB3 označeno jako kategorie Ostatní a pouze 33 jich bylo klasifikováno správně. Značná část AVB2 (55 z 233) bylo také klasifikováno jako Ostatní, navíc i dalších 52 bylo označeno jako AVB3. Pro množinu **M7**, kde byly generovány signály o délce 10 000 vzorků, dopadla klasifikace ještě hůř. Opět vysoké množství AVB2 i AVB3 bylo zařazeno do kategorie Ostatní a navíc jich bylo i větší množství klasifikováno jako AVB1. Na základě časté záměny AVB2 a AVB3 za kategorii Ostatní, je možné soudit, že generované signály nejsou dostatečně charakteristické pro svoji kategorii.



Obr. 10.2: Matice záměn pro AVB datasey M6 a M7, obsahující pouze generované AVB2 a AVB3.

10.3 Úspěšnost augmentace z fyziologického pohledu

Z fyziologického hlediska se dle mého názoru jeví augmentované fluttery s níž věrohodně. Permutace úseků (obrázek 6.1) ani přičtení generovaného šumu nezasahují nijak výrazně do morfologie signálu, takže jeho fyziologická podoba zůstává zachována.

Generované atrioventrikulární blokády (obrázky 7.3, 7.4 a 8.1) mají sice základní morfologické znaky typické pro tyto arytmie, ale v generovaném signálu se mohou objevit části, které působí trochu nepřírodně. Jedná se hlavně o ostré přechody v oblasti P vln a o vyhlazené úseky například v místě, kde je simulován výpadek QRS komplexu.

10.4 Výhody a nevýhody navržených postupů augmentace

Metody augmentace, které jsou v této práci představeny, pokládám za jednoznačné a dobře interpretovatelné postupy.

Asi nejpřirozenější způsob zde navržených augmentačních metod je přičtení generovaných šumů, které se v EKG běžně vyskytují. Generované šumy se při učení sítě dají využít různými způsoby. V první vyzkoušené variantě se šum přičítá pouze k rozkopírovaným signálům kategorie, kterých je v trénovací databázi nedostatek.

Signály jsou navíc před vstupem do sítě filtrovány, ale původním předpokladem bylo, že filtrace není vždy stoprocentně účinná a zbylý šum způsobí alespoň částečnou variabilitu mezi nakopírovanými signály. Na základě výše zmíněných výsledků z klasifikátorů však tento předpoklad splněn úplně nebyl. Většina trénovacích množin, kde byl k nakopírovaným signálům přičten šum, nevykazovaly lepší výsledky než pouhé nakopírování. Další způsob, jak byl generovaný šum využit, bylo jeho přičtení s nízkou amplitudou ke všem signálům z databáze, čímž by se mohla vnést variabilita do celého datasetu. Signály v tomto případě nebyly filtrovány. Ani tato varianta nepřinesla lepší klasifikační výsledky. Nevýhodou této varianty navíc bylo zvýšení časové náročnosti při učení.

Při augmentaci permutací nakouskovaného flutteru síní je v signále nutné vyhledat pozice R kmitů. Tyto body jsou však asi nejsnadněji lokalizovatelné body v EKG a velkou výhodou zde je, že není nutné, aby se v signálu vyhledaly všechny R kmity. Pokud nějaký nebude označen, tak se pouze v tomto místě signál nikdy nerozdělí. Nevýhodou této metody je, že do množiny nevnášíme žádné zcela nové informace, ale pouze upravujeme signály, které v množině již jsou.

Výhodou augmentačních technik pro AVB II. a III. stupně je, že pro jejich vytvoření je třeba sinusový signál, kterých bývá v databázích dostatek. Nevýhodou u této metody je naopak nutnost vyhledání význačných bodů ve vstupním sinusovém signálu. Tyto body se nemusí podařit vždy detekovat, a proto není každý sinusový signál pro augmentaci vhodný. Přestože generované signály vykazují vzhledově základní morfologické znaky charakteristické pro dané arytmie, celkový vzhled signálů, jak již bylo výše zmíněno, působí trochu uměle.

Žádná z navržených augmentačních metod není výpočetně náročná. Generování a uložení 5 000 signálů AVB3 na běžném kancelářském notebooku s procesorem 11th Gen Intel(R) Core(TM) i7-1165G7 trvalo několik jednotek minut.

10.5 Srovnání úspěšnosti augmentace s dostupnou literaturou

Porovnání dosažených výsledků s publikovanými výsledky z předešlých studií je v tomto případě velice obtížné. Nepovedlo se nalézt žádnou studii, kde by se autoři zabývali augmentací přímo atrioventrikulárních blokád a pouze 2 studie, ve kterých se autoři zabývají augmentací flutterů síní.

Ve článku [26] klasifikovali 6 tříd s nerovnoměrným zastoupením vzorků: normální sinusový rytmus (2 000 záznamů), fibrilace síní (1 269 záznamů), flutter síní (104 záznamů), komorové extrasystoly v bigeminní vazbě (272 záznamů), komorové extrasystoly v trigeminní vazbě (137 záznamů) a stimulovaný rytmus (137 záznamů).

Signály byly klasifikovány na základě spekter a pro augmentaci byly použity natrénované GAN pro každou kategorii. V práci je zmíněno, že augmentací obohatili původní dataset spekter tak, aby byly všechny klasifikační třídy zastoupeny stejně, ale nezmiňují výsledný počet. Pro klasifikaci byly využity sítě LeNet, AlexNet, ZFNet a VGG13, ale úspěšnosti pro jednotlivé kategorie byly publikovány jen pro nejúspěšnější síť VGG13. Pro tuto síť se po augmentaci F1 skóre flutteru síní zvýšilo ze 73,2 % na 82,2 %. U všech ostatních arytmií došlo ke zlepšení F1 skóre vždy o méně než 1 %.

Dalším článkem, kde autoři také klasifikovali flutter síní a použili augmentaci je [22]. Pracovali se spektry jednotlivých srdečních cyklů, které klasifikovali do 8 tříd: normální rytmus, komorová extrasystola, stimulovaný cyklus, blokáda pravého Tawarova raménka, blokáda levého Tawarova raménka, supraventrikulární extrasystola, flutter síní a uniklý komorový stah. Všechny arytmie mimo normální cyklus byly augmentovány pomocí jednoduchého ořezu spektra. Ve článku se nezmiňují o počtech v jednotlivých kategoriích ani před ani po augmentaci. Nebyly publikovány ani výsledky pro jednotlivé kategorie, autoři pouze uvádí, že pro použitou konvoluční síť narostla při použití augmentovaných dat průměrná přesnost pro všechny kategorie z 98,9 % na 99,1 %, průměrné F1 skóre zůstalo v obou případech zachováno na hodnotě 98 %.

Jediné možné srovnání je tedy s článkem [26], ve kterém augmentací dosáhli navýšení F1 skóre flutteru síní o 9 % oproti nehomogennímu datasetu. Nejlepší dosažené výsledky augmentace flutteru síní v této práci bylo navýšení F1 skóre flutteru o 5 % v porovnání s nehomogenní trénovací množinou.

Závěr

V první části práce byla provedena literární rešerše v oblasti automatické detekce arytmií EKG s využitím hlubokých neuronových sítí a metodik obohacování databází, které slouží k učení těchto hlubokých neuronových sítí.

Pro poskytnutou databázi EKG signálů byly v jazyce Python vytvořeny filtry pro odstranění šumu. Na základě malého zastoupení flutteru síní a atrioventrikulární blokády II. a III. stupně v databázi bylo rozhodnuto, že praktická část této práce se zaměří na augmentaci právě těchto arytmií.

První realizovaný přístup augmentace dat byl založen na přidání různých typů uměle generovaných šumů do reálně změřených EKG signálů. Tento typ augmentace tedy není určen pro konkrétní arytmiu. Byly vytvořeny generátory tří nejčastěji se vyskytujících rušení v EKG, konkrétně síťové rušení, kolísání nulové izolinie a elektromyografické rušení.

Další augmentační metoda byla zaměřená konkrétně na flutter síní. Reálně změřený signál byl rozkouskovan na náhodný počet úseků v náhodných vrcholech R kmitů. Tyto úseky pak byly v náhodném pořadí spojeny zpět za sebe.

Třetí realizovaný typ augmentace byl zaměřený na atrioventrikulární blokády. Generované signály byly vytvořeny pozměněním sinusového rytmu na základě empirických znalostí morfologie jednotlivých typů AV blokády.

Pro poslední realizovaný augmentační postup byla použita hluboká neuronová síť. Byla snaha naučit generativní kompetitivní síť generovat atrioventrikulární blokády II. stupně. Dosažené výstupy z této sítě však nebyly dostatečně kvalitní, aby mohly být použity pro trénování klasifikační sítě.

Úspěšnost augmentace byla vyhodnocována na konvolučních klasifikátorech. Při doplnění záznamů flutteru síní v trénovací množině augmentovanými daty, bylo dosaženo o 1,3 % lepšího F1 skóre pro flutter síní pro testovací množinu oproti pouhému nakopírování dat a o 5 % oproti nehomogennímu datasetu. Pro klasifikátor atrioventrikulárních blokády bylo dosaženo nejvyššího průměrného F1 skóre (80,5 %) na testovací množině při trénování datasetem, ve kterém byly méně zastoupené kategorie atrioventrikulární blokády II. a III. stupně částečně nakopírovány a částečně doplněny daty generovanými navrženými augmentačními metodami. F1 skóre atrioventrikulární blokády II. stupně se zvýšilo o 1 % oproti rozkopírovaným datům a o 2,3 % oproti nehomogennímu datasetu. U atrioventrikulární blokády III. stupně bylo při použití augmentovaných dat v trénovací množině dosaženo o 2,8 % vyššího F1 skóre oproti nakopírovaným datům a o 4,8 % oproti nehomogennímu datasetu. Přičítání šumu k datům vnášelo do učení sítě spíše chyby.

Přestože zde navržené augmentační techniky v tomto konkrétním případě většinou alespoň částečně navýšily F1 skóre augmentovaných kategorií, nedá se obecně

tvrdit, že tyto typy augmentací pomohou navýšit přesnost klasifikace vždy. Jak bylo částečně v práci ukázáno, při použití jiné a méně nehomogenní trénovací množiny neměla augmentace ani nakopírování dat na výslednou úspěšnost klasifikace skoro žádný vliv. Aby bylo možné potvrdit význam navržených augmentačních metod, bylo by vhodné vyzkoušet augmentaci pro různé databáze dat s odlišnou mírou nehomogenity a i různé klasifikátory, což vzhledem k časové náročnosti nebylo v této práci realizováno.

Literatura

- [1] LECUN, Yann, Yoshua BENGIO, Geoffrey HINTON. Deep learning. *Nature* [online]. 2015, 521(7553), 436-444. ISSN 0028-0836.
- [2] PARVANEH, Saman, Jonathan RUBIN, Saeed BABAEIZADEH, Minnan XU-WILSON. Cardiac arrhythmia detection using deep learning: A review. *Journal of Electrocardiology* [online]. 2019, 57, S70-S74. ISSN 00220736.
- [3] AGGARWAL, Charu C. *Neural Networks and Deep Learning* [online]. Cham: Springer International Publishing, 2018. ISBN 978-3-319-94462-3.
- [4] EBRAHIMI, Zahra, Mohammad LONI, Masoud DANESHTALAB a Arash GHAREHBAGHI. A review on deep learning methods for ECG arrhythmia classification. *Expert Systems with Applications: X* [online]. 2020, 7. ISSN 25901885.
- [5] ACHARYA, U. Rajendra, Shu Lih OH, Yuki HAGIWARA, Jen Hong TAN, Muhammad ADAM, Arkadiusz GERTYCH a Ru San TAN. A deep convolutional neural network model to classify heartbeats. *Computers in Biology and Medicine* [online]. 2017, 89, 389-396. ISSN 00104825.
- [6] SINGH, Shraddha, Saroj Kumar PANDEY, Urja PAWAR a Rekh Ram JANGHEL. Classification of ECG Arrhythmia using Recurrent Neural Networks. *Procedia Computer Science* [online]. 2018, 132, 1290-1297. ISSN 18770509.
- [7] LI, Zhi, Dengshi ZHOU, Li WAN, Jian LI a Wenfeng MOU. Heartbeat classification using deep residual convolutional neural network from 2-lead electrocardiogram. *Journal of Electrocardiology* [online]. 2020, 58, 105-112. ISSN 00220736.
- [8] JO, Yong-Yeon, Joon-myung KWON, Ki-Hyun JEON, et al. Detection and classification of arrhythmia using an explainable deep learning model. *Journal of Electrocardiology* [online]. 2021, 67, 124-132 [cit. 2021-11-09]. ISSN 00220736.
- [9] GOODFELLOW, Ian J., et al. Generative Adversarial Nets. *Conference on Neural Information Processing Systems (NIPS 2014)* [online].
- [10] SALIMANS, Tim, et al. Improved techniques for training gans. In *Advances in Neural Information Processing Systems*, pages 2226–2234. *30th Conference on Neural Information Processing Systems (NIPS 2016)* [online]. 2016.

- [11] GOODFELLOW, Ian J. NIPS 2016 Tutorial: Generative Adversarial Networks. *30th Conference on Neural Information Processing Systems (NIPS 2016)* [online].
- [12] ARJOVSKY, Martin a Léon Bottou. Towards Principled Methods for Training Generative Adversarial Networks. *International Conference on Learning Representations (ICLR 2017)* [online]. 2017.
- [13] RADFORD, Alec, Luke METZ, Soumith CHINTALA. Unsupervised representation learning with deep convolutional generative adversarial networks. *International Conference on Learning*, 2016.
- [14] CHINTALA, Soumith, Emily DENTON, Martin Arjovsky, Michael MATHIEU. How to Train a GAN? Tips and tricks to make GANs work. *Github.com* [online]. 2020. Dostupné z: <<https://github.com/soumith/ganhacks>>
- [15] XIANG , Sitao, Hao LI. On the Effects of Batch and Weight Normalization in Generative Adversarial Networks, 2016
- [16] MIYATO, Takeru, Toshiki KATAOKA, Masanori KOYAMA, Yuichi YOSHIDA. Spectral normalization for generative adversarial networks. *International Conference on Learning Representations (ICLR 2018)* [online]. 2018.
- [17] ARJOVSKY, Martin, Soumith CHINTALA, Léon BOTTOU. Wasserstein GAN. *International Conference on Learning Representations (ICLR 2017)* [online]. 2017.
- [18] GULRAJANI, Ishaan, Faruk AHMED, Martin ARJOVSKY, Vincent DUMOU-LIN, Aaron COURVILLE. Improved Training of Wasserstein GANs. In *Advances in Neural Information Processing Systems*, pages 5768 - 5778. *31th Conference on Neural Information Processing Systems (NIPS 2017)* [online]. 2017
- [19] MIKOLAJCZYK, Agnieszka a Michal GROCHOWSKI. Data augmentation for improving deep learning in image classification problem. In: 2018 *International Interdisciplinary PhD Workshop (IIPhDW)* [online]. IEEE, 2018, 2018, s. 117-122. ISBN 978-1-5386-6143-7.
- [20] CAO, Ping, Xinyi LI, Kedong MAO, Fei LU, Gangmin NING, Luping FANG a Qing PAN. A novel data augmentation method to enhance deep neural networks for detection of atrial fibrillation. *Biomedical Signal Processing and Control* [online]. 2020, 56. ISSN 17468094.

- [21] ANWAR, Talha a Seemab ZAKIR. Effect of Image Augmentation on ECG Image Classification using Deep Learning. In: 2021 *International Conference on Artificial Intelligence (ICAI)* [online]. IEEE, 2021, 2021-4-5, s. 182-186. ISBN 978-1-6654-3293-1.
- [22] ULLAH, Amin, Syed Muhammad ANWAR, Muhammad BILAL a Raja Majid MEHMOOD. Classification of Arrhythmia by Using Deep Learning with 2-D ECG Spectral Image Representation. *Remote Sensing* [online]. 2020, 12(10). ISSN 2072-4292.
- [23] STABENAU, Hans Friedrich, Christopher P. BRIDGE a Jonathan W. WAKS. ECGAug: A novel method of generating augmented annotated electrocardiogram QRS complexes and rhythm strips. *Computers in Biology and Medicine* [online]. 2021, 134. ISSN 00104825.
- [24] KANANI, Pratik a Mamta PADOLE. ECG Heartbeat Arrhythmia Classification Using Time-Series Augmented Signals and Deep Learning Approach. *Procedia Computer Science* [online]. 2020, 171, 524-531. ISSN 18770509.
- [25] HATAMIAN, Faezeh Nejati, Nishant RAVIKUMAR, Sulaiman VESAL, Felix P. KEMETH, Matthias STRUCK a Andreas MAIER. The Effect of Data Augmentation on Classification of Atrial Fibrillation in Short Single-Lead ECG Signals Using Deep Neural Networks. In: *ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* [online]. IEEE, 2020, 2020, s. 1264-1268. ISBN 978-1-5090-6631-5.
- [26] LAN, Tianjie, Qihan HU, Xin LIU, Kaiyue HE a Cuiwei YANG. Arrhythmias Classification Using Short-Time Fourier Transform and GAN Based Data Augmentation. In: 2020 *42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)* [online]. IEEE, 2020, 2020, s. 308-311. ISBN 978-1-7281-1990-8.
- [27] WANG, Pu, Borui HOU, Siyu SHAO a Ruqiang YAN. ECG Arrhythmias Detection Using Auxiliary Classifier Generative Adversarial Network and Residual Network. *IEEE Access* [online]. 2019, 7, 100910-100922. ISSN 2169-3536.
- [28] WANG, Haiyan, Yanjie ZHOU, Bing ZHOU, Xiangdong NIU, Hua ZHANG a Zongmin WANG. Interactive ECG annotation: An artificial intelligence method for smart ECG manipulation. *Information Sciences* [online]. 2021, 581, 42-59 [cit. 2022-04-08]. ISSN 00200255.
- [29] THAMBAWITA, Vajira, Jonas L. ISAKSEN, Steven A. HICKS, et al. DeepFake electrocardiograms using generative adversarial networks are the beginning of

- the end for privacy issues in medicine. *Scientific Reports* [online]. 2021, 11(1). ISSN 2045-2322.
- [30] ZHU, Fei, Fei YE, Yuchen FU, Quan LIU a Bairong SHEN. Electrocardiogram generation with a bidirectional LSTM-CNN generative adversarial network. *Scientific Reports* [online]. 2019, 9(1). ISSN 2045-2322.
 - [31] CAO, Fan, Aamani BUDHOTA, Hao CHEN a Kuldeep Singh RAJPUT. Feature matching based ECG generative network for arrhythmia event augmentation. In: *2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)* [online]. IEEE, 2020, 2020, s. 296-299. ISBN 978-1-7281-1990-8.
 - [32] BANERJEE, Rohan a Avik GHOSE. Synthesis of Realistic ECG Waveforms Using a Composite Generative Adversarial Network for Classification of Atrial Fibrillation. In: *2021 29th European Signal Processing Conference (EUSIPCO)* [online]. IEEE, 2021, 2021-8-23, s. 1145-1149 [cit. 2022-04-10]. ISBN 978-9-0827-9706-0.
 - [33] DONAHUE , Chris, Julian MCAULEY, Miller PUCKETTE. Adversarial audio synthesis. in *International Conference on Learning Representations* (2019).
 - [34] WANG, Fang, Sheng-hua ZHONG, Jianfeng PENG, Jianmin JIANG a Yan LIU. Data Augmentation for EEG-Based Emotion Recognition with Deep Convolutional Neural Networks. SCHOEFFMANN, Klaus, Thanarat H. CHALIDABHONGSE, Chong Wah NGO, Supavadee ARAMVITH, Noel E. O'CONNOR, Yo-Sung HO, Moncef GABBOUJ a Ahmed ELGAMMAL, ed. *MultiMedia Modeling* [online]. Cham: Springer International Publishing, 2018, 2018-01-13, s. 82-93. Lecture Notes in Computer Science. ISBN 978-3-319-73599-3.
 - [35] HANNUN, Awni Y., Pranav RAJPURKAR, Masoumeh HAGHPANAHI, Geoffrey H. TISON, Codie BOURN, Mintu P. TURAKHIA a Andrew Y. NG. Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network. *Nature Medicine* [online]. 2019, 25(1), 65-69. ISSN 1078-8956.
 - [36] BENNETT, David H. *Srdeční arytmie: praktické poznámky k interpretaci a léčbě*. Praha: Grada, 2014. ISBN 978-80-247-5134-4.
 - [37] ŠTEJFA, Miloš, Josef ŠUMBERA a Pavel BRAVENÝ. *Základy elektrokardiografie*. 2., přeprac. vyd. Brno: Masarykova univerzita, 1991. ISBN 80-210-0265-4.

- [38] WILHELM, Zdeněk. *Stručný přehled fyziologie člověka pro bakalářské studijní programy*. 3. přeprac. vyd. Brno: Masarykova univerzita, 2002. ISBN 80-210-2837-8.
- [39] CHMELKA, L. a J. KOZUMPLIK. Wavelet-based wiener filter for electrocardiogram signal denoising. In: *Computers in Cardiology, 2005* [online]. IEEE, 2005, 2005, s. 771-774. ISBN 0-7803-9337-6.
- [40] CHATTERJEE, Shubhojeet, Rini Smita THAKUR, Ram Narayan YADAV, Lalita GUPTA a Deepak Kumar RAGHUVANSHI. Review of noise removal techniques in ECG signals. *IET Signal Processing* [online]. 2020, 14(9), 569-590. ISSN 1751-9675.
- [41] FARINA, Dario a Roberto MERLETTI. Comparison of algorithms for estimation of EMG variables during voluntary isometric contractions. *Journal of Electromyography and Kinesiology* [online]. 2000, 10(5), 337-349. ISSN 10506411.
- [42] NĚMEČKOVÁ, Karolína. *Detekce vybraných typů srdečních arytmíí v EKG*. Brno, 2022. Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce Marina Ronzhina.

Seznam symbolů a zkratek

ADAM	Adaptive Moment Estimation
AMMI	Association for the Advancement of Medical Instrumentation
AV	atrioventrikulární
CNN	konvoluční neuronová síť (z angl. Convolutional Neural Network)
EEG	elektroencefalogram
EKG	elektrokardiogram
EMG	elektromyogram
FIB	fibrilace síní
FL	flutter síní
GAN	generativní kompetitivní síť (GAN z angl. Generative Adversarial Networks)
GFMN	Generative Feature Matching Networks
GRU	Gated Recurrent Unit
IIR	nekonečná impulsní odezva (z angl. infinite impulse response)
LSB	nejméně významný bit (z angl. Least Significant Bit)
LSTM	Long Short-Term Memory
ReLU	Rectified Linear Unit
ResNet	residuální neuronová síť (z angl. Residual Network)
RNN	rekurentní neuronová síť (z angl. Recurrent Neural Network)
SGD	Stochastic Gradient Descent
SR	sinusový rytmus
XDM	interpretovatelný model hlubokého učení (z angl. explainable deep learning model)