

TRNAVSKÁ UNIVERZITA V TRNAVE
FAKULTA ZDRAVOTNÍCTVA A SOCIÁLNEJ PRÁCE
MATEMATICKÝ ÚSTAV SAV, v. v. i.



VÝSKUMNÁ SPRÁVA PROJEKTU

DIGITÁLNE RIEŠENIA NA PODPORU DUŠEVNÉHO ZDRAVIA
PACIENTOV S CHRONICKÝM ZLYHANÍM SRDCA

(DIGIMENT)

Projekt č.: 09I05-03-V02-00084

Grantová schéma: POO

Trvanie projektu: 04/2024 – 06/2026

TU FZaSP v Trnave – doc. PhDr. Silvia Puteková, PhD, MPH

MÚ SAV - doc. RNDr. Karol Nemoga, CSc.

Kolektív autorov zodpovedných za WP 1

WP1 (KPB1 - Doménové analýzy)

Výstupy 1. 3. Správa o riešeníach digitálnych technológií týkajúcich sa aspektov bezpečnosti a ochrany súkromia.

Úloha 1.13. Identifikácia a analýza relevantných technológií – údajov potrebných z elektronických zdravotných záznamov pre modely predikcie

Úloha 1.14. Identifikácia a analýza relevantných prístupov pri vytváraní modelov predikcie a systémov podpory klinických rozhodnutí

Úloha 1.15. Analýza existujúcich prístupov a ich aplikovateľnosť v oblastiach bezpečnosti údajov a ochrany súkromia pacientov

OBSAH

1	ÚVOD	9
1.1	DEFINÍCIA CHRONICKÉHO SRDCOVÉHO ZLYHANIA (CHF)	9
1.2	KLASIFIKÁCIA CHF	10
1.3	ZHORŠOVANIE CHF (WCHF)	11
2	ANALÝZA PARAMETROV	13
2.1	ZDROJOVÉ PARAMETRE PRE PREDIKCIU ZHORŠENIA CHF	13
2.1.1	<i>Klinické a demografické parametre</i>	13
2.1.2	<i>Anamnéza a klinická história</i>	13
2.1.3	<i>Biomarkery (krvný obraz)</i>	14
2.1.4	<i>Životné funkcie a fyziologické parametre</i>	15
2.1.5	<i>Príznaky a pacientom hlásené výsledky</i>	16
2.1.6	<i>Fyzická schopnosť a funkčný stav</i>	16
2.1.7	<i>Pokročilé zdroje dát a parametre strojového učenia</i>	16
2.2	CIELÉNÉ PARAMETRE PREDIKCIE WCHF	17
2.2.1	<i>Klinické udalosti a hospitalizácie</i>	18
2.2.2	<i>Kvalita života zo zdravotného hľadiska (HRQoL)</i>	18
2.2.3	<i>Predikcie biomarkerov</i>	18
2.2.4	<i>Funkčný stav a fyzická výkonnosť</i>	19
2.2.5	<i>Viacfaktorové modely a prístupy strojového učenia</i>	19
2.2.6	<i>Zhrnutie</i>	19
2.3	PROBLÉMY SO ZÍSKAVANÍM PARAMETROV ZDROJA	19
2.3.1	<i>Nekonzistentné a subjektívne údaje</i>	20
2.3.2	<i>Komplexnosť komorbidít</i>	20
2.3.3	<i>Obmedzenia v údajoch o hospitalizáciách</i>	20
2.3.4	<i>Technologické bariéry</i>	21
2.3.5	<i>Psychologické a behaviorálne faktory</i>	21
2.3.6	<i>Zhrnutie</i>	21
3	PRÍSTUPY NA PREDIKCIU WCHF	22
3.1	KLASIFIKÁCIA PODĽA ČASOVÉHO HORIZONTU PREDIKCIE	22
3.1.1	<i>Krátkodobé predikcie</i>	22
3.1.2	<i>Strednodobé predikcie</i>	22
3.1.3	<i>Dlhodobé predikcie</i>	22
3.2	KLASIFIKÁCIA PODĽA STUPŇA PERSONALIZOVANIA	23
3.2.1	<i>Vysoko personalizované modely</i>	23
3.2.2	<i>Polopersonalizované modely</i>	23
3.2.3	<i>Modely založené na populácii</i>	23
3.2.4	<i>Zhrnutie</i>	24
3.3	COXOV PROPORČNÝ MODEL RIZÍK	24
3.4	PRÍSTUP POMOCOU URČOVANIA SKÓRE	25
3.4.1	<i>Seattle Heart Failure Model (SHFM)</i>	25
3.4.2	<i>Stupnica MAGGIC (Meta-Analysis Global Group in Chronic Heart Failure)</i>	25
3.4.3	<i>Skóre prežitia pri srdcovom zlyhaní (HFSS)</i>	25

3.4.4	<i>Pokročilé modely využívajúce strojové učenie.....</i>	26
3.4.5	<i>Integrácia biomarkerov</i>	26
3.4.6	<i>Zhrnutie</i>	26
3.5	PRÍSTUP EXTRAPOLÁCIE ČASOVÝCH RADOV	26
3.5.1	<i>Klasické metódy extrapolácie časových radov</i>	27
3.5.2	<i>Metódy extrapolácie časových radov založené na strojovom učení</i>	28
3.5.3	<i>Zhrnutie</i>	29
3.6	DETEKCIA A ROZPOZNÁVANIE VZOROV	29
3.6.1	<i>Vzory na základe jednoduchých pravidiel.....</i>	30
3.6.2	<i>Vzory fyziologického monitorovania</i>	31
3.6.3	<i>Biomarkery a laboratórne vzory.....</i>	32
3.6.4	<i>Prístupy založené na údajoch a strojovom učení.....</i>	33
3.6.5	<i>Zhrnutie</i>	33
4	PREDIKCIA ZHORŠENIA PSYCHICKÉHO STAVU PACIENTOV S CHF	35
4.1	<i>VZŤAH MEDZI FYZIOLÓGIU PACIENTA A PSYCHICKÝM STAVOM</i>	35
4.2	<i>MERANIE PSYCHICKÉHO STAVU</i>	36
4.2.1	<i>Štandardizované dotazníky a hodnotenia</i>	36
4.2.2	<i>Hodnotenia kvality života súvisiacej so zdravím</i>	37
4.2.3	<i>Hodnotenia kognitívnych funkcií a mechanizmov zvládania.....</i>	37
4.2.4	<i>Zhrnutie</i>	38
4.3	<i>VHODNÉ PRÍSTUPOVÉ METÓDY</i>	38
4.3.1	<i>Štandardizované psychologické hodnotenia</i>	38
4.3.2	<i>Hodnotenia kvality života súvisiacej so zdravím</i>	39
4.3.3	<i>Kontinuálne monitorovanie a hodnotenie správania</i>	39
4.3.4	<i>Biomarkery súvisiace s psychickým stavom.....</i>	39
4.3.5	<i>Hodnotenia kognitívnej funkcie.....</i>	40
4.3.6	<i>Modely predikcie rizika.....</i>	40
4.3.7	<i>Zhrnutie</i>	40
5	BEZPEČNOSŤ INTEGRÁCIE A SPRACOVANIA ÚDAJOV TELEMEDICÍNY	41
5.1	<i>AUTENTIFIKÁCIA A KONTROLA PRÍSTUPU</i>	41
5.2	<i>ŠIFROVANIE ÚDAJOV.....</i>	42
5.3	<i>ANONYMIZÁCIA ÚDAJOV A DODRŽIAVANIE GDPR</i>	42
5.4	<i>SYSTÉMY DETEKcie NARUŠENÍ (IDS)</i>	42
5.5	<i>SPOĽAHLIVOSŤ A ODOLNOSŤ SYSTÉMOV</i>	43
5.6	<i>PRAVIDELNÉ BEZPEČNOSTNÉ AUDITY A ZHODA</i>	43
5.7	<i>VZDELÁVANIE A ŠKOLENIE POUŽÍVATEĽOV</i>	43
5.8	<i>ZÁLOHY ÚDAJOV A POSTUPY OBNOVY.....</i>	44
5.9	<i>ZHRNUTIE</i>	44
6	LITERATÚRA.....	45

OBRÁZKY

Obrázok 1: Progresia chronického srdcového zlyhania	11
Obrázok 2: Nositeľné technológie	177
Obrázok 3: Zmena hmotnosti pred hospitalizáciou pre srdcové zlyhanie	30
Obrázok 4: Variabilita srdcovej frekvencie	
Error! Bookmark not defined.2	
Obrázok 5: Pickerove princípy starostlivosti orientovanej na pacienta	36
Obrázok 6: Hybridný koncept pre zmenu paradigmy v liečbe chronického srdcového zlyhania	41

ZOZNAM SKRATIEK A SYMBOLOV

ACC	American College of Cardiology
AES-256	encryption protocol
AHA	American Heart Association
AI	artificial intelligence
ARIMA	autoregressive integrated moving average
BDI	Beck depression inventory
BNP	B-type natriuretic peptide
CHF	chronic heart failure
CISS	inventory for stressful situations
CKD	chronic kidney disease
COPD	chronic obstructive pulmonary disease
CRP	C-reactive protein
EDA	exploratory data analysis
eGFR	estimated glomerular filtration rate
ER	emergency room
GDPR	General Data Protection Regulation
GBM	gradient boosting machines
HADS	hospital anxiety and depression scale
HF	heart failure
HFmrEF	heart failure with mildly reduced ejection fraction
HFpEF	heart failure with preserved ejection fraction
HFrfEF	heart failure with reduced ejection fraction
HFSS	heart failure survival score
HIPAA	Health Insurance Portability and Accountability Act
hs-CRP	high-sensitivity C-reactive protein
HRQoL	health-related quality of life
HRV	heart rate variability
hs-CRP	high-sensitivity C-reactive protein
IDS	intrusion detection systems
KCCQ	Kansas City cardiomyopathy questionnaire
KIM-1	kidney injury molecule-1

LVEF	left ventricular ejection fraction
LSTM	long short-term memory
MAGGIC	meta-analysis global group in chronic heart failure
MFA	multi-factor authentication
MLHFQ	Minnesota living with heart failure questionnaire
MoCA	Montreal cognitive assessment
NAG	N-acetyl- β -D-glucosaminidase
NYHA	New York Heart Association
NT-proBNP	N-terminal pro-B-type Natriuretic Peptide
PHQ-9	patient health questionnaire
RNNs	recurrent neural networks
SHFM	Seattle heart failure model
sST2	soluble ST2
SVM	support vector machines
WCHF	worsening CHF
XGBoost	extreme gradient boosting
6MWT	six-minute walk test

1 Úvod

1.1 Definícia chronického srdcového zlyhania (CHF)

Chronické srdcové zlyhanie (CHF), známe aj ako kongestívne srdcové zlyhanie, je komplexný klinický syndróm charakterizovaný neschopnosťou srdca efektívne pumpovať krv, čo vedie k nedostatočnej perfúzii životne dôležitých orgánov a kongestívnym stavom spôsobeným zvýšeným tlakom v kardiovaskulárnom systéme. Predstavuje významný problém verejného zdravia, najmä v starnúcej populácii, pretože sa odhaduje, že prevalencia medzi jednotlivcami staršími ako 65 rokov v Spojených štátoch presahuje 10 %, pričom čísla stúpajú nad 20 % v starších kohortách na celom svete (Toh et al., 2010). Patofyziológia CHF je multifaktoriálna, často vyplývajúca z osobitných etiológií, ako je ischemická choroba srdca, hypertenzia a cukrovka (Chanyukov et al., 2023). Tieto stavy vyúsťujú do funkčných narušení postihujúcich srdcový sval a do štrukturálnych zmien vyskytujúcich sa v priebehu času, čo prispieva k zložitosti manažovania tejto choroby (Chakravarti & Busovsky-McNeal, 2016).

Pacienti s CHF často vykazujú príznaky ako dyspnoe, únavu a periférny edém, ktoré môžu výrazne ovplyvniť kvalitu ich života (Verhestraeten et al., 2020). Je pozoruhodné, že symptomatológia je reflexiou základných hemodynamických porúch a môže predisponovať jednotlivcov k opakovaným hospitalizáciám, čo ďalej komplikuje klinický priebeh ochorenia (Volz et al., 2010). Okrem toho, kvalita života súvisiaca so zdravím (HRQoL) sa významne znižuje, ak sa zhoršuje závažnosť chronického srdcového zlyhania; táto degradácia je spojená nielen s priamymi fyziologickými dopadmi, ale aj s psychologickými stresormi, vrátane úzkosti a depresie, ktoré sú u pacientov s CHF častejšie (Comín-Colet et al., 2013).

Taktiež interakcia medzi CHF a komorbiditami, ako je renálna dysfunkcia, ešte viac komplikuje výsledky liečby a celkovú prognózu. Znížená funkcia obličiek môže byť prediktorom nepriaznivých klinických výsledkov u pacientov s CHF, často zhoršujúcich kardio-vaskulárny stav kvôli zdieľaným patofyziologickým mechanizmom (Ruocco et al., 2019). Ako CHF postupuje, zvyšuje sa zaťaženie pacientov, čo vedie k zvýšenej miere úmrtnosti – až 50 % do piatich rokov od diagnózy – a k významným problémom pri zvládaní celkového zdravotného zaťaženia, ktoré tento syndróm kladie na jednotlivcov a zdravotnícke systémy (Erceg et al., 2013).


Chronické srdcové zlyhanie je kritickou zdravotnou otázkou, ktorá zahŕňa závažnú chronickosť, čo si vyžaduje komplexné stratégie medicínskeho manažmentu. Pochopenie jeho klinických charakteristík, základných mechanizmov a súvisiacich komorbidít je zásadné pre zlepšenie starostlivosti o pacientov a výsledkov v tejto rastúcej populácii.

1.2 Klasifikácia CHF

Chronické srdcové zlyhanie môže byť klasifikované na základe rôznych kritérií, pričom najbežnejšou metódou je zameranie sa na ejekčnú frakciu ľavej komory (LVEF). Usmernenia Americkej kardiologickej spoločnosti (ACC) a Americkej asociácie srdca (AHA) rozdeľujú CHF do troch hlavných kategórií: srdcové zlyhanie so zníženou ejekčnou frakciou (HFrEF), definované ako LVEF menej ako 40 %; srdcové zlyhanie s mierne zníženou ejekčnou frakciou (HFmrEF), definované ako LVEF medzi 40 % a 50 %; a srdcové zlyhanie so zachovanou ejekčnou frakciou (HFpEF), kde je LVEF väčší ako 50 % (Lainščak et al., 2017).

HFrEF je často spojené s históriou ischemickej choroby srdca, čo vedie k výraznej dysfunkcii ľavej komory. Táto podmnožina pacientov často vyžaduje intenzívnejší medicínsky manažment a má zvyčajne horšiu prognózu v porovnaní s tými, ktorí majú zachovanú ejekčnú frakciu (Lainščak et al., 2017). Na druhej strane, HFpEF je čoraz viac rozpoznávané, predovšetkým u starších dospelých, kde je často sprevádzané komorbiditami, ako sú hypertenzia a predsieňová fibrilácia (Pliquett, 2022). Pacienti v tejto kategórii zvyčajne vykazujú príznaky srdcového zlyhania, aj keď majú zachovanú ejekčnú frakciu, čo komplikuje prístupy k manažmentu (Pliquett, 2022).

Okrem toho sa klasifikácia môže rozšíriť nad rámec metrík ejekčnej frakcie, vrátane funkčných klasifikačných systémov, ako je klasifikácia New York Heart Association (NYHA), ktorá kategorizuje pacientov na základe závažnosti príznakov, ktoré zažívajú počas fyzickej aktivity (Yao et al., 2024). Keďže chronické srdcové zlyhanie často prekrýva funkciu obličiek, klasifikácia kardiorenálneho syndrómu ponúka ďalší rozmer, kategorizujúci pacientov na základe podstaty ich kardiálnych a renálnych porúch (Pliquett, 2022). Tu chronický kardiorenálny syndróm (typ II) odkazuje špecificky na chronické srdcové zlyhanie, ktoré vedie k pretrvávajúcej renálnej dysfunkcii. To zdôrazňuje komplexnú interakciu medzi týmito dvoma orgánmi, ktorá si vyžaduje starostlivé riadenie na zlepšenie výsledkov pacientov (Pliquett, 2022).



Obrázok 1: Progresia chronického srdcového zlyhania
https://link.springer.com/chapter/10.1007/978-4-431-56065-4_1

1.3 Zhoršovanie CHF (WCHF)

Zhoršovanie (exacerbácia) CHF (skrátene WCHF) je definované ako zhoršovanie príznakov a známk CHF u pacientov s existujúcim CHF, vyžadujúcim zintenzívnenie liečby, najčastejšie diuretickej terapie (Metra et al., 2023). Vyžaduje predchádzajúcu diagnózu CHF, pričom vylučuje epizódy nového srdcového zlyhania. Prípady, kde je príčinou zhoršovania symptómov skôr nedodržiavanie liečby než dekompenzácia predchádzajúceho CHF. Potreba zintenzívnenia terapie CHF je základnou súčasťou našej definície WCHF. Zhoršovanie CHF musí byť jasne oddelené od akútneho srdcového zlyhania, ktoré je omnoho širším pojmom, vrátane nových epizód HF, ako aj rôznych klinických prezentácií, ako sú akútne pľúcne edémy, zlyhanie pravej komory a kardiogénny šok. Keď sa používa termín WCHF, zameriavame sa namiesto toho na klinický priebeh pacienta s chronickým, existujúcim srdcovým zlyhaním.

Predikcia WCHF je kľúčová kvôli jej významným dôsledkom pre manažment pacientov, náklady na zdravotnú starostlivosť a výsledky pacientov. Zhoršovanie CHF často vedie k hospitalizáciám, ktoré sú spojené s horšími výsledkami, vrátane zvýšenej mortality a miery readmisie (Cooper et al., 2015). Raná identifikácia pacientov s rizikom zhoršovania srdcovej funkcie umožňuje včasný zásah, ktorý potenciálne zabráňuje týmto nepriaznivým výsledkom (Lavallo et al., 2023). Prediktívne modely, ktoré integrujú rôzne rizikové faktory – ako

komorbidné stavy a klinické parametre – zlepšujú stratifikáciu pacientov, u ktorých je viac pravdepodobné, že zažijú exacerbáciu, čo umožňuje prispôsobené manažérske stratégie (Groccia et al., 2018).

Telemedicina dáva príslub zlepšiť výsledky pacientov vďaka tomu, že umožňuje neustále sledovanie kľúčových fyziologických parametrov, čím pomáha identifikovať znaky exacerbácie skôr než sa príznaky stanú závažnými (Brons et al., 2018). Okrem toho je predikcia zhoršujúcich udalostí kľúčová nielen pre optimalizáciu starostlivosti o pacientov, ale aj na rozdelenie zdrojov a minimalizáciu ekonomického zaťaženia spojeného s hospitalizáciami v dôsledku dekompenzovaného srdcového zlyhania (Cooper et al., 2015). Po viacerých pokusoch sa ukázalo, že určiť účinok telemonitoringu nie je tak zjavné a často si vyžaduje klinické štúdie s dĺžkou pozorovania pacientov nad 1 rok (Umeh et al., 2022).

Záverom, presná predikcia rizika zhoršovania CHF je zásadná pre zlepšenie starostlivosti o pacientov, zvyšovanie kvality ich života a znižovanie nákladov na zdravotnú starostlivosť prostredníctvom proaktívneho manažmentu tohto progresívneho stavu.

2 Analýza parametrov

2.1 Zdrojové parametre pre predikciu zhoršenia CHF

Pri predikcii zhoršovania CHF môžeme využiť rôzne parametre, ktoré klasifikujeme na základe typu zdrojových dát, klinickej relevancie a povahy hodnotenia. Nižšie je uvedený zoznam týchto parametrov, usporiadaný do niekoľkých kategórií:

2.1.1 Klinické a demografické parametre

- **Vek:** Starší vek je významným prediktorom zhoršených výsledkov u pacientov s chronickým srdcovým zlyhaním v dôsledku akumulácie komorbidít a zmien vo fyziologických rezervách (Yang et al., 2023).
- **Pohlavie:** Niektoré štúdie naznačujú rozdiely medzi pohlaviami v prezentácii a výsledkoch chronického srdcového zlyhania, čo ovplyvňuje celkovú predikciu (Bielecka et al., 2024), (Chanyukov et al., 2023).

2.1.2 Anamnéza a klinická história

- **Nástup a trvanie príznakov:** Informácie o trvaní a povahe symptómov hlásených pacientom, ako sú dyspnoe, únava a edém, pomáhajú pri identifikácii klinickej degradácie (Wang & Zhang 2022).
- **História predchádzajúcich hospitalizácií a readmisií:** Počet minulých hospitalizácií z dôvodu exacerbácií srdcového zlyhania je silným prediktorom budúcich hospitalizácií, pričom zvyrazňuje pacientov s vyšším rizikom (Gyllensten et al., 2017).
- **Návštevy pohotovosti:** Časté návštevy pohotovosti kvôli zhoršujúcim sa symptómom môžu naznačovať zhoršenie stavu pacienta, signalizujúc potrebu bližšieho sledovania a zásahu (Gyllensten et al., 2017).
- **Dodržiavanie liečby:** História dodržiavania predpísaných liekov na srdcové zlyhanie môže naznačovať potenciálne zhoršovanie stavu, pretože nedodržiavanie je často spojené s exacerbáciami (Lin et al., 2020).
- **Profil komorbidít:** Je známe, že chronické stavy, ako je diabetes mellitus, chronická obštrukčná choroba pľúc (COPD), chronické ochorenie obličiek (CKD) a hypertenzia komplikujú výsledky srdcového zlyhania a sú rozhodujúce pre stratifikáciu rizika (Conrad et al., 2018; Alem, 2019).

- **Psychologické stavy:** Dokumentovanie úzkostí alebo depresíí je dôležité, pretože tieto faktory môžu nepriaznivo ovplyvniť dodržiavanie liečby pacientami a celkové zdravotné výsledky (Comín-Colet et al., 2013).

2.1.3 Biomarkery (krvný obraz)

- **N-terminálny pro-B-typ natriuretického peptidu (NT-proBNP):** Zvýšené hladiny NT-proBNP slúžia ako kritický biomarker pre predikciu akútnej dekompenzácie a celkovej prognózy u pacientov s CHF (Sheikhvatan et al., 2018).
- **Vysoko citlivý C-reaktívny proteín (hs-CRP):** Tento zápalový marker je spojený s kardiovaskulárnym rizikom a môže poskytnúť prognostické informácie týkajúce sa progresie CHF (Yu et al., 2023).
- **Thrombospondin-2:** Zvýšené hladiny cirkulujúceho thrombospondinu-2 boli spojené so zvýšenou celkovou mortalitou a nepriaznivými kardiovaskulárnymi výsledkami u pacientov s CHF (Berezin et al., 2016).
- **Rozpustný ST2 (sST2):** Tento biomarker je spojený s myokardiálnym stresom a remodelingom, pričom zvýšené hladiny naznačujú zlé výsledky u pacientov so srdcovým zlyhaním (Davison et al., 2021), (Vegter et al., 2016).
- **Galektín-3:** Zvýšené hladiny galektínu-3 sú ukazovateľom srdcovej fibrózy a môžu predpovedať zhoršenie srdcového zlyhania a mortalitu (Velde et al., 2013), (Felker et al., 2012)
- **Hladina kyseliny močovej:** Zvýšené hladiny kyseliny močovej slúžia ako významný biomarker pre predikciu zhoršovania chronického srdcového zlyhania, pretože štúdie ukázali, že hyperurikémia je spojená so zvýšeným rizikom nepriaznivých výsledkov, vrátane hospitalizácie a mortality. Konkrétne, pri každom 1 mg/dL zvýšení hladiny sérovej kyseliny močovej sa pravdepodobnosť vzniku srdcového zlyhania zvyšuje o 19 % (HR: 1,19; 95 % CI: 1,17-1,21) (Qin et al., 2023).
- **Molekula poškodenia obličiek-1 (KIM-1):** Tento biomarker indikuje akútne poškodenie obličiek a preukázal svoju užitočnosť pri predikcii výsledkov u pacientov so srdcovým zlyhaním v súvislosti s kardiorenálnym syndrómom (Jungbauer et al., 2016; Jungbauer et al., 2011).
- **N-acetyl-β-D-glukozaminidáza (NAG):** Zvýšenie NAG odráža poškodenie renálnych tubulov a môže byť prospešné pri hodnotení prognostického rizika progresie srdcového zlyhania (Jungbauer et al., 2016; Jungbauer et al., 2011).

- **Dlhé nekódujúce RNA (napr. Urothelial Carcinoma Associated 1):** Tieto nové biomarkery sa skúmajú pre ich prediktívnu hodnotu týkajúcu sa zlých prognóz a náhlych srdcových udalostí v populáciách s CHF (Yu et al., 2017).
- **Cirkulujúce mikroRNA:** Špecifické mikroRNA sa ukazujú ako sľubné biomarkery pre progresiu srdcového zlyhania, odrážajúc patofyziologické zmeny spojené s touto chorobou (Vegter et al., 2016).
- **Mitochondriálna DNA:** Zvýšené hladiny cirkulujúcej mitochondriálnej DNA môžu slúžiť ako marker pre zápal a myokardiálne poškodenie, naznačujúc zhoršujúci sa stav srdcového zlyhania (Krychtiuk et al., 2020).

2.1.4 Životné funkcie a fyziologické parametre

- **Saturácia kyslíka:** Meria percento miest na viazanie hemoglobínu v krvnom obeh, ktoré sú obsadené kyslíkom. Nízke hladiny nasýtenia kyslíkom môžu naznačovať respiračnú núdzu alebo slabý srdcový výdaj, čo slúži ako skorý varovný signál pre potenciálne zhoršenie srdcového zlyhania (Samchuk, 2023), (Jia et al., 2023).
- **Telesná hmotnosť:** Pravidelné sledovanie telesnej hmotnosti pomáha hodnotiť zadržanie tekutín, čo je bežný problém pacientov so srdcovým zlyhaním. Náhle zvýšenie telesnej hmotnosti (typicky viac ako 1–1,5 kg za niekoľko dní) môže naznačovať preťaženie tekutinami a zhoršenie srdcového zlyhania (Okada et al., 2023), (Brons et al., 2018).
- **Telesná teplota:** Sledovanie telesnej teploty môže poskytnúť prehľad o celkovom zdravotnom stave pacienta. Zvýšená telesná teplota môže naznačovať systémovú infekciu alebo zápal, ktoré môžu zhoršiť stavy srdcového zlyhania. Na druhej strane výskum naznačuje, že nepriaznivé výsledky u pacientov s CHF kladne korelujú skôr s nízkou telesnou teplotou. Toto pozorovanie môže byť vysvetlené nedostatočnou perfúziou alebo systémovou tiesňou (Samchuk, 2023).
- **Krvný tlak:** Pravidelné hodnotenie systolického a diastolického krvného tlaku je nevyhnutné pre manažovanie CHF. Zmeny krvného tlaku môžu odrážať zhoršenú funkciu srdca; hypotenzia môže naznačovať zlé prekrvenie, zatiaľ čo pretrvávajúca hypertenzia môže zaťažovať srdce (Verhestraeten et al., 2020).
- **Variabilita srdcovej frekvencie (HRV):** HRV meria variáciu v časových intervaloch medzi údermi srdca, čo odráža aktivitu autonómneho nervového systému. Znížená HRV je spojená so zvýšenou mortalitou a nepriaznivými výsledkami u pacientov so

srdcovým zlyhaním. Naznačuje zníženú autonómnú flexibilitu, ktorá môže predpovedať zhoršenie stavu (Piskorski & Guzik, 2011), (Morimoto et al., 2020).

- **Renálna funkcia:** Parametre ako sérový kreatinín a eGFR sú kľúčové pri hodnotení stavu tekutín a výsledkov pri srdcovom zlyhaní, čo naznačuje progresiu poškodenia obličiek (Hippisley-Cox & Coupland, 2015).

2.1.5 Príznaky a pacientom hlásené výsledky

- **Zhľuky príznakov:** Zhľuky príznakov, ako sú únava, dyspnoe a edém, sú kľúčové pre pochopenie skúseností pacientov so zhoršujúcimi sa podmienkami. Memorial Symptom Assessment Scale for Heart Failure hodnotí tieto stresujúce symptómy (DeVon et al., 2016).
- **Psychologický stres:** Prítomnosť úzkosti a depresie významne ovplyvňuje kvalitu života a výsledky u pacientov s CHF (Wang et al., 2023). Ako príklad môžu byť použité nástroje ako Patient Health Questionnaire (PHQ-9) na hodnotenie týchto aspektov.

2.1.6 Fyzická schopnosť a funkčný stav

- **Klasifikácia New York Heart Association (NYHA):** Táto klasifikácia kategorizuje pacientov na základe funkčných schopností a závažnosti symptómov, čím poskytuje pohľad na prognózu a usmerňuje stratégie manažovania (Yao et al., 2024), (Sheikhvatan et al., 2018).
- **Test šesťminútovej chôdze (6MWT):** Vzdialenosť prekonaná v tomto teste koreluje s funkčnou kapacitou a predpovedá riziko hospitalizácie a mortality u pacientov s chronickým srdcovým zlyhaním (Grundtvig et al., 2020).

2.1.7 Pokročilé zdroje dát a parametre strojového učenia

- **Dáta z nositeľných zariadení:** Neustále sledovanie srdcovej frekvencie, úrovne aktivity a krvného tlaku prostredníctvom nositeľných technológií umožňuje dynamické sledovanie zdravotného stavu a včasné identifikovanie zhoršujúcich sa stavov.
- **Algoritmy strojového učenia:** Tieto algoritmy môžu analyzovať komplexné interakcie medzi rôznymi parametrami a predpovedať výsledky na základe veľkých

údajových súborov získaných z elektronických zdravotných záznamov (Tian et al., 2022).



Obrázok 2: Nositeľné technológie (vľavo: čelenka, hrudný pás, fitness prsteň, inteligentné ponožky; vpravo: inteligentné okuliare, inteligentné tričko, inteligentné hodinky, inteligentná obuv)
(<https://link.springer.com/article/10.1007/s10389-023-01893-6>)

Predikcia zhoršovania chronického srdcového zlyhania sa opiera o multifaktoriálny prístup, ktorý zahŕňa klinické, fyziologické a psychologické parametre. Každý parameter prispieva unikátnym pohľadom, ktorý umožňuje komplexnú stratifikáciu rizika a informované manažérske rozhodnutia, čím sa nakoniec zlepšujú výsledky pacientov v tejto zložitej chronickej chorobe.

2.2 Cílené parametre predikcie WCHF

Rozličné štúdie a rizikové faktory identifikovali špecifické prvky, ktoré je možné predpovedať v kontexte zhoršenia CHF. Tieto predikcie sa môžu predovšetkým zameriavať na klinické udalosti, funkčný stav, kvalitu života zo zdravotného hľadiska (HRQoL) a biomarkery.

2.2.1 Klinické udalosti a hospitalizácie

Jedným z hlavných zameraní na predikciu WCHF je pochopenie rizika klinických udalostí, ako sú hospitalizácie a readmisie. Predikčné modely ukázali, že faktory ako vek, ejekčná frakcia ľavej komory (LVEF) menej ako 40 % a zvýšené hladiny kyseliny močovej sú konzistentne spojené so zvýšeným rizikom readmisie (Takimura et al., 2018). Pretol score identifikuje viacero nezávislých rizikových faktorov pre readmisie vrátane histórie hospitalizácií pre srdcové zlyhanie, renálnej funkcie tak, ako je indikované odhadovanou glomerulárnou filtráciou (eGFR), a požiadaviek na diuretiká (Takimura et al., 2018). Štúdia naznačila, že zhoršovanie udalostí srdcového zlyhania sa charakterizuje rôznymi výsledkami v závislosti od toho, či sa vyskytujú v skorých (prvých 24 hodín) alebo neskorších fázach hospitalizácie, pričom sa zdôraznil dopad načasovania na zotavenie (Cooper et al., 2015).

2.2.2 Kvalita života zo zdravotného hľadiska (HRQoL)

Predikcie súvisiace s HRQoL sú významné, pretože priamo ovplyvňujú skúsenosť pacienta a jeho schopnosť zúčastniť sa na denných aktivitách. Zistilo sa, že hospitalizácie a epizódy WCHF sú negatívne korelované s HRQoL, čo naznačuje, že nefatálne kardiovaskulárne udalosti významne prispievajú k poklesu výsledkov hlásených pacientmi (Almeida et al., 2020). Dlhodobé hodnotenie HRQoL u pacientov s CHF môže pomôcť kvantifikovať zaťaženie ich stavu a zdôrazniť potrebu intervencií, ktorých cieľom je udržiavať ich pohodu (Almeida et al., 2020).

2.2.3 Predikcie biomarkerov

Dôkazy naznačujú, že integrácia biomarkerov do predikčných modelov môže zvýšiť presnosť identifikácie pacientov, ktorí môžu zažiť zhoršenie srdcového zlyhania. Faktory, ako sú zvýšené hladiny B-typ natriuretického peptidu (BNP) (Sheikhvatan et al., 2018). a zápalové markery (napr. vysoko citlivý C-reaktívny proteín), sa ukázali ako prediktívne vo vzťahu k zlým výsledkom u pacientov s CHF (Pagano et al., 2024), (Lawson et al., 2018). Tieto biomarkery môžu byť použité spolu s tradičnými klinickými hodnoteniami na stratifikáciu pacientov podľa rizika dekompenzácie (Lawson et al., 2018), (Creber et al., 2015).

2.2.4 Funkčný stav a fyzická výkonnosť

Ďalšie predikcie sa týkajú hodnotenia funkčného stavu, ktorý naznačuje schopnosť pacienta zapájať sa do fyzickej aktivity bez zhoršenia príznakov. Štúdie ukázali, že funkčná kapacita dolných končatín je často korelovaná s nutričným stavom a rôznymi farmakologickými terapiami (Morimoto et al., 2020). Presnejšie povedané, krehkosť je uznávaná ako kritický prediktor nepriaznivých výsledkov v CHF, čo komplikuje klinický profil pacientov, predovšetkým pri stretnutí s mnohými komorbiditami.

2.2.5 Viacfaktorové modely a prístupy strojového učenia

Pokroky v metodológii strojového učenia umožnili preskúmanie komplexných interakcií medzi rizikovými faktormi spojenými so zhoršením CHF. Modely využívajúce široké spektrum dát o pacientoch, vrátane demografických informácií, klinickej histórie a výsledkov vyšetrení, môžu zvýšiť presnosť predikcií týkajúcich sa udalostí zhoršenia srdcového zlyhania (Sun et al., 2024). Využitím viacfaktorových prístupov poskytujú tieto predikčné modely komplexné hodnotenie rizika – identifikujú pacientov, u ktorých je pravdepodobnejšie, že sa im zhorší stav (Sun et al., 2024; Groccia et al., 2018).

2.2.6 Zhrnutie

Predikcia zhoršovania chronického srdcového zlyhania zahŕňa široké spektrum faktorov, vrátane klinických udalostí (hospitalizácie), kvality života zo zdravotného hľadiska, biomarkerov, funkčného stavu a inovatívnych monitorovacích technológií. Tieto predikčné prístupy môžu ponúknuť ciele intervencie, vytvoriť personalizované plány manažmentu a zlepšiť celkovú starostlivosť o pacientov v populácii s vysokým rizikom nepriaznivých udalostí. Takéto poznatky o progresii CHF sú neoceniteľné nielen pri zlepšovaní výsledkov pacientov, ale aj pri optimalizácii využívania zdrojov v zdravotníctve.

2.3 Problémy so získavaním parametrov zdroja

V ďalšom texte uvedené niektoré kľúčové problémy a obmedzenia spojené so získaním parametrov na predikciu zhoršeného chronického srdcového zlyhania na základe faktorov získaných z anamnézy, klinickej histórie, komorbidít a hospitalizácií/readmisií:

2.3.1 Nekonzistentné a subjektívne údaje

- **Variabilita v hlásení pacientov:** Symptómy hlásené pacientmi môžu výrazne ovplyvniť presnosť a spoľahlivosť, čo často vedie k nekonzistentným dátam, ktoré by mohli ohroziť predikčné modely. Faktory, ako je vnímanie symptómov pacientmi a dodržiavanie pokynov pre hlásenie symptómov, môžu ovplyvniť výsledky (Taniguchi et al., 2021).
- **Chýbajúce štandardizované protokoly:** Chýba štandardizovaný protokol na zber klinickej histórie, čo môže viesť k variabilite v tom, ako sú symptómy a komorbidity dokumentované v rôznych zdravotníckych zariadeniach. Táto nekonzistentnosť môže sťažovať vývoj robustných predikčných modelov (Brons et al., 2018).

2.3.2 Komplexnosť komorbidít

- **Dopad viacerých komorbidít:** Pacienti s CHF často trpia viacerými súbežne existujúcimi stavmi (napr. diabetes, COPD), ktoré komplikuje klinické vyhodnotenie. Prítomnosť každej dodatočnej komorbidity môže brzdiť manažment CHF a prinášať mäťuce premenné, čo sťažuje stanovenie jasných vzťahov príčina–dôsledok v predikčných modeloch (Hippisley-Cox & Coupland, 2015), (Ruocco et al., 2019), (Chen et al., 2019).
- **Výzvy pri identifikácii relevantných komorbidít:** Prahové hodnoty identifikátorov pre komorbidity – ako je hypertenzia alebo renálna dysfunkcia – nemusia byť vždy jasne definované, čo komplikuje hodnotenie rizika (Deichl et al. 2022).

2.3.3 Obmedzenia v údajoch o hospitalizáciách

- **Nekompletnosť dát:** Údaje o hospitalizáciách a readmisiách môžu byť neúplné alebo zavádzajúce, pretože niektorí pacienti sa nemusia dostať do nemocnice, napriek tomu, že majú zhoršujúce sa symptómy. Môže existovať aj variabilita v kódovaní prepúšťacích diagnóz, čo môže ovplyvniť miery readmisie hlásené v štúdiách.
- **Zameranie na krátkodobé výsledky:** Mnohé predikčné modely sa spoliehajú na údaje o krátkodobých hospitalizáciách, čo nemusí zohľadňovať dlhodobé trendy v zdravotných trajektóriách pacientov. Toto obmedzenie môže viesť k prehliadnutým predikciám u pacientov, ktorí zažívajú pozvolné zhoršenia (Hao & Chen, 2019).

2.3.4 Technologické bariéry

- **Závislosť od angažovanosti pacientov:** Efektívne telemonitorovanie a zber dát môžu zlyhať kvôli nekonzistentnému zapojeniu pacientov do aktivít sebamonitorovania. Mnohým pacientom môžu chýbať vedomosti alebo motivácia na efektívne využívanie telemonitorovacích nástrojov, čo ovplyvňuje spoľahlivosť údajov pre účely predikcie (Ekola et al., 2024).
- **Problémy s interoperabilitou:** Rôzne metódy a formáty zberu dát v rámci zdravotníckych systémov môžu vytvárať problémy s interoperabilitou, ktoré komplikujú agregáciu a analýzu relevantných pacientových údajov pre predikčné modelovanie.

2.3.5 Psychologické a behaviorálne faktory

- **Vplyv duševného zdravia:** Psychologický stres, ako sú depresia a úzkosť, často koexistuje s CHF a môže ovplyvniť dodržiavanie monitorovania a hlásení zo strany pacientov, čo skresľuje dáta. Toto psychologické zaťaženie môže brániť účinnosti predikčných modelov (Ekola et al., 2024), (Comín-Colet et al., 2013).
- **Variabilita špecifická pre pacienta:** Individuálne rozdiely v mechanizmoch zvládania a správania súvisiacim s vyhľadávaním zdravotnej pomoci môžu ovplyvniť reakcie na zhoršujúce sa symptómy a komplikovať predikciu akútnej dekompenzácie (D'Onofrio et al., 2021).

2.3.6 Zhrnutie

Predikcia zhoršenia chronického srdcového zlyhania je sprevádzaná problémami vyplývajúcimi zo subjektívnych údajov pacientov, zložitosti spôsobenej komorbiditami, obmedzeniami v údajoch o hospitalizáciách, technologickými prekážkami a psychologickými faktormi. Riešenie týchto výziev si vyžaduje koordinované úsilie v štandardizácii zbierania dát, posilnení angažovanosti pacientov a zlepšení prístupu k technológiám telemonitorovania na vypracovanie spoľahlivejších predikčných modelov.

3 Prístupy na predikciu WCHF

Na klasifikáciu prístupov na predikciu WCHF na základe časového horizontu predikcie a stupňa personalizácie môžeme tieto prístupy rozdeliť do niekoľkých odlišných kategórií.

3.1 Klasifikácia podľa časového horizontu predikcie

3.1.1 Krátkodobé predikcie

- **Real-time telemonitorovanie:** Prístupy využívajú nepretržité monitorovanie údajov na včasné identifikovanie akútnej dekompenzácie, pričom zachytávajú dôležité parametre, ako sú srdcová frekvencia, respiračná frekvencia a zmeny hmotnosti. Tieto metódy môžu varovať zdravotníckych pracovníkov o bezprostrednom riziku (Kerexeta et al., 2023).
- **Modely okamžitého hodnotenia rizika:** Štúdie, ako je tá od Ezera et al., zdôrazňujú použitie významných markerov, ako sú zmeny vitálnych funkcií počas hospitalizácie, na predpovedanie zhoršujúcich sa stavov v krátkom časovom intervale (napr. 24 hodín) (Ezer et al., 2022).

3.1.2 Strednodobé predikcie

- **Analýza časových trendov:** D'Onofrio et al. zdôraznili metódy, ktoré kombinujú stratifikáciu základného rizika s časovými trendmi v parametroch, ako je krvný tlak alebo úroveň aktivity, na predpokladanie hospitalizácií v strednodobom horizonte (napr. týždne až niekoľko mesiacov) (D'Onofrio et al., 2021).
- **Multivariatné modely:** Tieto modely integrujú niekoľko parametrov v strednodobých sledovaniach (napr. 1-3 mesiace). Napríklad Seattle Heart Failure Model sa používa na odhadovanie rizík na základe stanovených klinických profilov (Borisenko et al., 2018).

3.1.3 Dlhodobé predikcie

- **Komplexné modely rizika:** Techniky, ktoré hodnotia dlhodobé riziká integrovaním historických údajov. Voors et al. sa zameriavajú na multivariable modely, ktoré predpovedajú výsledky na základe širšieho spektra klinických a demografických údajov počas dlhých období (napr. roky) (Voors et al., 2017), (Sartipy et al., 2013), (Tohyama et al., 2021).

- **Hodnotenie charakteristík pacientov:** Prístupy analyzujúce základné charakteristiky na predpovedanie dlhodobých výsledkov (napr. 5 rokov), ako vidíme v modeloch postavených na observačných štúdiách o populáciách so srdcovým zlyhaním (Mentz et al., 2015).

3.2 Klasifikácia podľa stupňa personalizovania

3.2.1 Vysoko personalizované modely

- **Algoritmy strojového učenia:** Techniky prediskutované u Tohyama et al. využívajú špecifické údaje pacientov z elektronických zdravotných záznamov na vytváranie individualizovaných predikcií, prispôbených na základe unikátnej zdravotnej histórie pacienta a hladín biomarkerov (Tohyama et al., 2021).
- **Adaptívne techniky učenia:** Tieto modely neustále aktualizujú historické dáta, čo im umožňuje zapracovať vyvíjajúce sa metriky zdravia pacientov, čím sa dynamicky personalizujú prístupy k monitorovaniu.

3.2.2 Polopersonalizované modely

- **Modely stratifikácie rizika:** Modely ako MAGGIC score poskytujú odhady rizika založené na údajoch na úrovni populácie, pričom umožňujú určité individuálne úpravy na základe charakteristík pacientov, čím ponúkajú mierny stupeň personalizácie (Sartipy et al., 2013), (Shin et al., 2020).
- **Analýza kompozitných biomarkerov:** Prístupy, ktoré zbierajú rôzne biomarkery od pacientov a hodnotia individuálne riziko na základe agregovaných údajov, pričom vyvažujú medzi trendmi vo všeobecnej populácii a špecifickými pohľadmi na jednotlivých pacientov (Ky et al., 2012).

3.2.3 Modely založené na populácii

- **Generalizované modely rizika:** V štúdii Cooper et al. sa viac zameriavajú na dynamiku populácie a širšie aplikácie zavedených modelov, ktoré zhŕňajú priemerné reakcie a trendy v kohortách viac ako predikcie prispôbené jednotlivcom (Cooper et al., 2015).
- **Statické klinické usmernenia:** Tieto prístupy závisia od široko platných klinických usmernení a kritérií na predpovedanie zhoršenia CHF bez významnej prispôbivosti potrebám jednotlivých pacientov.

3.2.4 Zhrnutie

Klasifikácia predikčných prístupov pre zhoršenie chronického srdcového zlyhania na základe typu zdrojových dát, časového horizontu predikcie a stupňa personalizácie ponúka štruktúrovaný spôsob, ako pochopiť tieto metodológie. Každá predikčná stratégia môže efektívne cieľiť na manažment CHF, ponúkajúc rôzne stupne špecifickosti a rozsahu relevantné pre každodennú klinickú prax.

3.3 Coxov proporčný model rizík

Coxov proporčný model rizík predstavuje základný nástroj v analýze prežitia, ktorý sa široko využíva na predikciu zhoršených výsledkov u pacientov s chronickým srdcovým zlyhaním. Jednou z jeho významných výhod je schopnosť zvládať cenzurované údaje – inherentný charakteristický rys v štúdiách prežitia, kde môžu pacienti opustiť štúdiu pred tým, ako zažijú udalosť záujmu, ako je hospitalizácia alebo mortalita (Xue et al., 2020). Tento model súčasne zohľadňuje viacero rizikových faktorov súčasne, čo umožňuje lekárom zhodnotiť vplyv rôznych kovariátov na čas do výskytu nepriaznivých udalostí. Tento aspekt je obzvlášť prospešný v oblasti výskumu srdcového zlyhania, kde množstvo demografických, klinických a biomarkerových premenných môže ovplyvniť výsledky pacientov (Sartipy et al., 2013). Okrem toho flexibilita Coxovho modelu pri úprave pre časovo premenlivé kovariáty pridáva robustnosť, ktorá pomáha zohľadniť zmeny v zdravotnom stave pacienta v priebehu času a tým zachytiť zložitosti progresie chronického srdcového zlyhania (Giolo et al., 2012).

Avšak Coxov proporčný model rizík má aj významné obmedzenia. Jedným z kritických nedostatkov je predpoklad proporcionálnych rizík – že pomery rizík medzi skupinami zostávajú v čase konštantné (Denardo et al., 2016). Zlyhanie tohto predpokladu môže viesť k nepresným predikciám a nesprávnym interpretáciám účinkov kovariátov na výsledky prežitia. Okrem toho, hoci Coxov model poskytuje cenné poznatky o relatívnych rizikách, nedáva priame odhady pravdepodobností prežitia, čo môže obmedziť jeho praktickú aplikovateľnosť v klinických podmienkach, kde sú potrebné priame odhady prežitia na rozhodovanie (Yang et al., 2021). Ďalej môže model vykazovať zníženú výkonnosť v populáciách s rozličnými klinickými charakteristikami alebo v prítomnosti silne korelovaných prediktorov, čo by mohlo skomplikovať interpretáciu nálezov (Sartipy et al., 2013). Z tohto dôvodu sa výskumníci často snažia doplniť Coxov model inými metodológiami alebo ho upraviť, aby lepšie vyhovoval jedinečným zložitostiam, s ktorými sa stretávajú populácie s chronickým srdcovým zlyhaním.

3.4 Prístup pomocou určovania skóre

Predikcia zhoršenia chronického srdcového zlyhania bola vylepšená rôznymi prístupmi pomocou stupníc, ktoré poskytujú klinickým lekárom cenné nástroje na hodnotenie rizika pacienta a zlepšenie manažérskych stratégií. Vzniklo niekoľko osvedčených ohodnotení rizika, z ktorých každé má svoje špecifické silné a slabé stránky.

3.4.1 Seattle Heart Failure Model (SHFM)

Model Seattle Heart Failure je jedným z najpoužívanějších systémov bodovania na predikciu prežitia u pacientov s CHF. Zahŕňa rad demografických, klinických a laboratórnych premenných na odhadovanie 1-, 2- a 3-ročných mier prežitia (Sartipy et al., 2013). Hoci ponúka významnú prediktívnu užitočnosť, obmedzenia zahŕňajú jeho závislosť od určitých parametrov, ako je počet lymfocytov a kapacita cvičenia, ktoré nemusia byť ľahko hodnotené vo všetkých klinických podmienkach (Sartipy et al., 2013). Model preukázal nedostatočnú prediktívnu presnosť, najmä u pacientov s pokročilým srdcovým zlyhaním, kde štúdie naznačujú, že môže podceňovať riziko (O'Connor et al., 2012).

3.4.2 Stupnica MAGGIC (Meta-Analysis Global Group in Chronic Heart Failure)

MAGGIC je ďalší významný nástroj navrhnutý na predikciu dlhodobého prežitia u pacientov so srdcovým zlyhaním. Využíva klinické medzníky známe opatrovateľom, čo ho robí relatívne dostupným pre klinické použitie. Avšak citlivosť a špecifickosť tohto nástroja sa môžu líšiť v závislosti od populácie a kontextu, čo vedie výskumníkov k zisteniu, že skórové systémy ako MAGGIC by mohli byť vylepšené integráciou ďalších klinických údajov (Vazquez-Montes et al., 2020). Štúdie naznačujú, že hoci je MAGGIC užitočný, jeho výkon nemusí byť rovnomerný naprieč rôznymi patientskymi populáciami alebo klinickými podmienkami (Allen et al., 2017).

3.4.3 Skóre prežitia pri srdcovom zlyhaní (HFSS)

Ohodnotenie prežitia pri srdcovom zlyhaní je prognostický model zdôrazňujúci klinické parametre, vrátane maximálnej spotreby kyslíka počas cvičenia. Hoci efektívne predikuje výsledky pacientov, jeho závislosť od testovania cvičenia obmedzuje jeho aplikáciu, najmä u pacientov s pokročilým funkčným poškodením, ktorí nemusia byť schopní sa na takýchto posúdeniach zúčastniť (Sartipy et al., 2013).

3.4.4 Pokročilé modely využívajúce strojové učenie

S príchodom umelej inteligencie pribudli novšie sľubné modely využívajúce techniky strojového učenia pri zlepšovaní prediktívnej presnosti. Štúdie naznačujú, že modely strojového učenia, ktoré využívajú širšiu škálu údajov o pacientoch, môžu významne zlepšiť stratifikáciu rizika, pričom prekonávajú tradičné modely v predikcii hospitalizácie a miery mortality medzi pacientmi s CHF (Wang et al., 2021). Metódy strojového učenia, ako sú XGBoost a náhodné lesy (Random Forests), boli ocenené pre svoje schopnosti analyzovať komplexné interakcie v údajoch o pacientoch (Wang et al., 2021).

3.4.5 Integrácia biomarkerov

Zvyšujúce sa uznanie dôležitosti biomarkerov viedlo k integrácii biochemických markerov do rizikových modelov. Napríklad integrácia hladín B-typ natriuretického peptidu (BNP) do existujúcich modelov preukázala zlepšenie ich prediktívnych schopností týkajúcich sa hospitalizácií a mortality u pacientov so srdcovým zlyhaním (Pocock et al., 2021). Predikčné modely, ktoré kombinujú klinické a biomarkerové údaje, získavajú na popularite a ukazujú lepšie výsledky z hľadiska presnosti a spoľahlivosti.

3.4.6 Zhrnutie

Prehľad prístupov hodnotení pomocou skóre pri predikcii zhoršenia chronického srdcového zlyhania podčiarkuje vyvíjajúcu sa oblasť, kde tradičné modely ako SHFM a skóre MAGGIC majú veľký význam, ale musia sa vyvíjať, aby zahrnuli ďalšie faktory špecifické pre pacientov, vrátane biomarkerov a pokročilých analytických technológií. Pochopenie silných a slabých stránok týchto modelov môže pomôcť klinickým lekárom pri výbere najvhodnejších nástrojov na stratifikáciu rizika, čím sa nakoniec zlepšia výsledky pacientov a využívanie zdrojov pri manažmente srdcového zlyhania.

3.5 Prístup extrapolácie časových radov

Modely extrapolácie časových radov predstavujú inovatívny prístup na predikciu zhoršenia chronického srdcového zlyhania analýzou časových trendov a vzorov v údajoch o pacientoch. Tieto modely používajú historické údaje, vrátane vitálnych funkcií, výsledkov laboratórnych testov a hlásených výsledkov pacientmi, na predpovedanie budúcich zdravotných stavov a pravdepodobnosti akútnej dekompenzácie. Jednou z pozoruhodných výhod modelov časových

radov je ich schopnosť zohľadniť časovú dynamiku, ktorá je kľúčová v chronických stavoch, ako je srdcové zlyhanie, kde sa stav pacienta môže výrazne meniť v priebehu času (Essay et al., 2020). Táto od času závislá analýza umožňuje včasné identifikovanie pacientov s rizikom exacerbácie, čo umožňuje včasný zásah, ktorý môže potenciálne zlepšiť výsledky a znížiť hospitalizácie. Okrem toho, tieto modely môžu byť neustále aktualizované novými údajmi, čím sa prispôbujú meniacim sa podmienkam pacientov a poskytujú aktuálne poznatky (Truong et al., 2023).

Avšak aplikácia modelov extrapolácie časových radov čelí niektorým výzvam a obmedzeniam. Jedným z významných problémov je potenciál pre nadmerné prispôbenie (overfitting), najmä keď sú modely zostavené na obmedzených údajových súboroch alebo keď je zahrnutých príliš veľa parametrov. To môže viesť k modelu, ktorý sa zdá byť efektívny počas tréningu, ale nie je schopný generalizovať na nové alebo neznáme údaje o pacientoch. Navyše presnosť predikcií závisí vo veľkej miere od kvality a detailnosti zhromaždených údajov; neúplné alebo skreslené údaje môžu výrazne oslabiť prediktívnu silu (Paramita & Pratiwi, 2022). Zložitosti spojené s vývojom a validáciou takýchto modelov môžu vyžadovať značné výpočtové zdroje a odborné znalosti, čo môže vytvárať prekážky pre ich rozšírené klinické prijatie (Kerexeta et al., 2023). Navyše, hoci extrapolácia poskytuje pohľad do budúcnosti, jej inherentná závislosť od minulých údajov môže byť obmedzením v rýchlo sa meniacich klinických kontextoch, kde môžu byť náhle zmeny v zdravotnom stave pacienta zachytené až po ich manifestácii. Preto, aj keď sú sľubné, modely časových radov na predikciu zhoršenia chronického srdcového zlyhania vyžadujú starostlivé zváženie a dôkladnú validáciu pred ich úplným začlenením do bežnej klinickej praxe. Metódy extrapolácie časových radov, klasické aj založené na strojovom učení, zohrávajú čoraz dôležitejšiu úlohu pri predikcii zhoršovania chronického srdcového zlyhania analýzou vzorov v časových údajoch o fyziológii pacientov. Nižšie sú uvedené príklady rôznych prístupov a ich aplikácií v tejto oblasti.

3.5.1 Klasické metódy extrapolácie časových radov

1. **Modely autoregresívneho integrovaného kľzavého priemeru (ARIMA):** Modely ARIMA sú používané na zachytenie lineárnych závislostí v údajoch časových radov kombinovaním autoregresie, diferenciálnych a kľzavých priemerov. Napríklad, ARIMA bola použitá na analýzu vitálnych funkcií (napr. srdcová frekvencia a krvný tlak) v priebehu času na predikciu budúcich udalostí srdcového zlyhania na základe historických trendov (Tak et al., 2021).

2. **Exponenciálne vyhladzovanie:** Táto klasická metóda kladie dôraz na nedávne pozorovania pri súčasnom postupnom znižovaní váhy starších údajov. Môže sa využiť na vyhladenie meraní variability srdcovej frekvencie (HRV) s cieľom predpovedať epizódy zhoršenia srdcového zlyhania, pričom vychádza z dôležitosti nedávnych fyziologických zmien (Rocha et al., 2016).
3. **Modely stavového priestoru:** Tieto modely odhadujú skryté stavy z pozorovaných údajov, čo ich robí vhodnými pre nestacionárne časové rady, ktoré sú prevalentné pri CHF. Môžu modelovať dynamiku progresie CHF, čo umožňuje klinickým lekárom predpovedať budúce stavy na základe aktuálnej trajektórie (Hooda & Verma, 2019).
4. **Fourierova transformácia a sezónna dekompozícia:** Pomocou Fourierovej analýzy môžu výskumníci identifikovať periodické výkyvy v srdcovej frekvencii alebo variabilite v priebehu času. Takéto analýzy pomohli pri pochopení opakujúcich sa vzorov exacerbácií CHF a sezónnych trendov ovplyvňujúcich miery hospitalizácie (Mao et al., 2015).
5. **Kalmanove filtre:** Kalmanove filtre poskytujú rekurzívne riešenie na odhad stavu dynamického systému z reťazca neúplných a zašumených meraní, čo je vhodné pri monitorovaní pacientov s trvalým CHF tým, že zlepšujú predikcie s prichádzajúcimi novými údajmi (Mao et al., 2015), (Petrenko & Boloban, 2025), (Foussier et al., 2014).

3.5.2 Metódy extrapolácie časových radov založené na strojovom učení

1. **Rekurentné neurónové siete (RNN):**
RNN efektívne zachycujú časové závislosti v sekvenčných údajoch. Sú sľubné pri predpovedaní exacerbácií CHF analyzovaním sekvencií historických lekárskeho záznamov pacientov a fyziologických markerov. Ako podtyp RNN sú LSTMs siete navrhnuté na učenie z dlhodobých závislostí a boli použité na predpovedanie udalostí akútnej dekompenzácie pri CHF na základe údajov časových radov z nositeľných zdravotných senzorov (Wang et al., 2024), (Emir & Aydın, 2025).
2. **Gradient Boosting Machine (GBM):**
Tieto modely agregujú slabšie prediktory učenia tak, aby vytvorili robustný prediktor. Pri CHF boli GBM aplikované na časové údaje pacientov a priniesli zlepšenu klasifikáciu pri identifikácii pacientov s vysokým rizikom readmisie (Emir & Aydın, 2025).

3. **Support Vector Machines (SVM) s časovými komponentami:**

SVM dokážu riešiť klasifikačné problémy a boli prispôsobené na zahrnutie komponentov časových radov. Slúžia na hodnotenie úrovni rizika pre udalosti srdcového zlyhania identifikovaním vzorov v údajoch pacientov počas konkrétnych časových okien (Sinaga et al., 2023).

4. **Náhodné lesy pre sekvenčné údaje:**

Náhodné lesy boli efektívne použité na analýzu vlastností extrahovaných z údajov časových radov, ako sú variabilita srdcovej frekvencie a biochemické markery, generujúc predikcie zhoršenia stavu pacientov s CHF. Ich využitie súborového učenia zlepšuje robustnosť predikcií (Emir & Aydın, 2025).

5. **Transformátory v analýze časových radov:**

Transformátory boli aplikované na predpovedanie časových radov v oblasti zdravotnej starostlivosti vďaka svojej nadmernej výkonnosti pri spracovaní vzťahov sekvenčných údajov. Implementácia architektúr transformátorov umožňuje sofistikované modelovanie interakcií medzi viacerými klinickými časovými radmi súvisiacimi s manažmentom srdcového zlyhania (Ahmed et al., 2022).

3.5.3 Zhrnutie

Klasické aj moderné metódy strojového učenia pre extrapoláciu časových radov poskytujú cenné informácie o predikcii zhoršených stavov v chronickom srdcovom zlyhaní. Každá metóda má svoje silné a slabé stránky a výber techniky často závisí od konkrétneho klinického kontextu a dostupných údajov.


3.6 Detekcia a rozpoznávanie vzorov

Metódy detekcie vzorov, vrátane jednoduchých pravidiel a iných techník, zohrávajú významnú úlohu pri predikcii zhoršovania chronického srdcového zlyhania. Tieto metódy využívajú fyziologické údaje, klinické pozorovania a dokonca aj hlásené výsledky pacientov na rozpoznávanie trendov, ktoré môžu naznačovať zhoršenie funkcie srdca. Nižšie je uvedené podrobné preskúmanie rôznych prístupov detekcie vzorov aplikovaných v kontexte predikcie zhoršovania CHF.

3.6.1 Vzory na základe jednoduchých pravidiel

- **Sledovanie hmotnosti:**

Bežne používané jednoduché pravidlo pri manažmente CHF zahŕňa starostlivé sledovanie telesnej hmotnosti. Pacienti sú zvyčajne vyzývaní, aby hlásili akékoľvek náhle zvýšenia (napr. viac ako 1–1,5 kg za niekoľko dní), čo môže signalizovať zadržiavanie tekutín a hroziacu exacerbáciu srdcového zlyhania. Väčšina klinických usmernení odporúča pravidelné kontroly hmotnosti pre jednotlivcov, aby sa včas zachytili prvé známky preťaženia tekutinami, čo je dôležité pre včasné terapeutické zmeny (Okada et al., 2023), (Li et al., 2021), (Brons et al., 2018).



Obrázok 3: Zmena hmotnosti pred hospitalizáciou pre srdcové zlyhanie: prípady vs. kontrolné skupiny. $n=268$. „Days“ na osi x označuje dni pred prijatím do nemocnice u pacientov s prípadmi. Rozdiel v denných zmenách hmotnosti medzi pacientmi s prípadmi (Cases) a kontrolnými skupinami (Controls) v priebehu 30 dní pred (prípade) hospitalizáciou bol štatisticky významný ($P<0,001$) na základe generalizovaného lineárneho modelu s dennou zmenou hmotnosti ako závislej premennej.

(<https://doi.org/10.1161/CIRCULATIONAHA.107.690768>)

- **Znaky preťaženia tekutinami:**

Poskytovatelia starostlivosti často používajú jednoduché pravidlá na hodnotenie ukazovateľov preťaženia tekutinami, ako je zvýšený opuch končatín, distenzia krčných žíl a dýchavičnosť. Rozpoznať tieto klinické znaky umožňuje rýchlu intervenciu pred zhoršením stavu pacienta, čo je osobitne kritické, pretože u pacientov

sa môžu vyvinúť symptómy súvisiace s preťažením tekutinami medzi návštevami lekára (Pellicori et al., 2020), (Houston et al., 2015).

- **Denné kontrolné zoznamy symptómov:**

Pacienti sú povzbudzovaní, aby si udržiavali denné záznamy symptomatológie (napr. únava, dyspnoe, edém). Jednoduché samohodnotiace kontrolné zoznamy môžu fungovať ako nástroj na detekciu vzorov, pomáhajúc pacientom a poskytovateľom rýchlo identifikovať zhoršujúce sa podmienky na základe subjektívneho hlásenia symptómov (Aamodt et al., 2020).


3.6.2 Vzory fyziologického monitorovania

- **Ultrazvuk dolnej dutej žily (IVC):**

Používanie neinvazívneho ultrazvuku na meranie priemeru a indexu kolapsu dolnej dutej žily poskytuje klinikom rýchly prehľad o objemovom stave. Vzory zmien veľkosti IVC môžu efektívne pomôcť hodnotiť objemový stav a naznačiť úspech alebo neúspech manažmentu pri liečbe srdcového zlyhania (Türkarslan et al., 2023).

- **Analýza variability srdcovej frekvencie (HRV):**

Zmeny vo vzoroch HRV, predovšetkým kolísania srdcovej frekvencie (RR) počas rôznych aktivít, môžu naznačovať autonómnu dysfunkciu a hroziace zhoršenie srdcového zlyhania. Nízka HRV bola spojená so zvýšenou mortalitou a rizikom, čo umožňuje poskytovateľom odhaliť znepokojujúce trendy, ktoré naznačujú zhoršujúce sa podmienky (Piskorski & Guzik, 2011), (Coviello et al., 2013), (Kurtoğlu et al., 2013), (Schaarup et al., 2024), (Gyawali et al., 2025).



P vlna:

Predstavuje depolarizáciu predsiení, čo je elektrická aktivácia predsiení vedúca k ich kontrakcii. Dĺžka P vlny môže poskytnúť prehľad o zdraví a funkcii predsiení.

QRS komplex:

Skladá sa z troch odlišných vĺn (Q, R a S) a predstavuje depolarizáciu komôr. Tvar a dĺžka QRS komplexu môžu naznačovať abnormality vo vedení a funkcii komôr.

T vlna:

Predstavuje repolarizáciu komôr, čo je fáza obnovy po kontrakcii komôr. Zmeny v T vlne môžu naznačovať problémy, ako sú elektrolytové poruchy alebo ischémie.

PR interval:

Čas medzi začiatkom P vlny a začiatkom QRS komplexu, ktorý odráža trvanie depolarizácie predsiení a vedenia cez atrioventrikulárny (AV) uzol. Predĺžený PR interval môže naznačovať blokádu prvého stupňa AV, zatiaľ čo skrátený PR interval by mohol naznačovať iné poruchy vedenia.

QT interval:

Čas od začiatku Q vlny po koniec T vlny, ktorý predstavuje celkový čas potrebný na depolarizáciu a repolarizáciu komôr. Predĺženie QT intervalu môže viesť k život ohrozujúcim arytmiám, zatiaľ čo krátky QT interval môže tiež naznačovať potenciálne riziká.

RR interval:

Čas medzi po sebe idúcimi R vlnami v rámci QRS komplexu, ktorý slúži ako merač srdcovej frekvencie a ako podstatná súčasť pri výpočte HRV. Variabilita RR intervalu odráža vplyv autonómnej regulácie na srdcovú frekvenciu.

3.6.3 Biomarkery a laboratórne vzory

- **Analýza viacerých biomarkerov:**

Kombinácia viacerých biomarkerov (napr. B-typ natriuretického peptidu (BNP), C-reaktívny proteín (CRP)) zlepšuje stratifikáciu rizika u pacientov s CHF. Vzory

hladín biomarkerov môžu naznačovať zhoršujúci sa stav a efektívnejšie usmerňovať úpravy liečby ako jednotlivé merania (Creber et al., 2015).

- **Fluktuácia hladín troponínu:**

Monitorovanie hladín troponínu, najmä s vysoko citlivými testami, umožňuje zdravotníckym profesionálom identifikovať vzory myokardiálneho poškodenia, ktoré môžu naznačovať zhoršenie srdcového zlyhania. Zvýšené hladiny môžu poskytnúť náhľad na riziko akútnej exacerbácie a trajektória týchto hladín môže signalizovať potrebu zásahu (Lemos et al., 2011).

3.6.4 Prístupy založené na údajoch a strojovom učení

- **Strojové učenie pre klinické údaje:**

Techniky exploratívnej analýzy údajov (EDA) aplikované na rôzne klinické údaje pomáhajú detekovať vzory súvisiace so zhoršením srdcového zlyhania identifikovaním korelácií medzi rizikovými faktormi a výsledkami. EDA zlepšuje rozpoznávanie vzorov prostredníctvom grafických zobrazení distribúcií údajov a vzťahov (Sinaga et al., 2023).

- **Rozpoznávanie vzorov prostredníctvom nositeľných technológií:**

Pokroky v nositeľných zariadeniach umožňujúcich nepretržité monitorovanie vitálnych funkcií viedli k metodológiám detekcie vzorov založených na údajoch v reálnom čase. Srdcová frekvencia, krvný tlak a úrovne aktivity sledované týmito zariadeniami môžu poskytovať poznatky o potenciálnych exacerbáciách pred ich klinickou manifestáciou.

- **Podporné vektorové stroje (SVM) pre analýzu časových radov:**

SVM boli použité na klasifikáciu údajov časových radov zo srdcovej frekvencie a iných fyziologických meraní na predpovedanie epizód srdcového zlyhania. Detegovaním nelineárnych vzťahov a dôležitých charakteristík z historických údajov môže SVM pomôcť predpovedať trendy zdravotného stavu, ktoré naznačujú zhoršenie (Sinaga et al., 2023).

3.6.5 Zhrnutie

Metodológie detekcie vzorov – od jednoduchých klinických pravidiel až po pokročilé techniky strojového učenia – majú potenciál v predikcii zhoršenia chronického srdcového zlyhania. Pravidelným sledovaním telesnej hmotnosti pacientov, fyziologických ukazovateľov a údajov


založených na analýzach môžu zdravotnícki pracovníci zlepšiť svoje schopnosti efektívne riadiť CHF. Tieto prístupy, umožnené technologickými pokrokmi a klinickými pozorovaniami, môžu nakoniec zlepšiť výsledky pacientov prostredníctvom proaktívnych intervenčných stratégií.

4 Predikcia zhoršenia psychického stavu pacientov s CHF

4.1 Vzťah medzi fyziológiou pacienta a psychickým stavom

Vzťah medzi zhoršovaním chronického srdcového zlyhania a kvalitou života súvisiacou so zdravím (HRQoL) je významný a má dôležité dôsledky pre celkovú pohodu pacientov. Ako CHF postupuje, pacienti zažívajú zhoršenie symptómov, ako sú únava, dyspnoe a edém, čo môže narušiť ich fyzickú funkciu a schopnosť zapájať sa do každodenných aktivít (Wang et al., 2023). Výskum naznačuje, že symptómy srdcového zlyhania významne ovplyvňujú HRQoL rôznymi cestami, vrátane fyzických a psychologických aspektov (Wang et al., 2023). Napríklad emocionálny stres spojený s chronickým srdcovým zlyhaním, ako je úzkosť a depresia, zhoršuje fyzické zaťaženie, pričom psychosomatické mechanizmy zohrávajú kľúčovú úlohu pri utváraní skúseností pacientov (Patron et al., 2017). Dôsledkom toho pacienti často hlásia zníženú spokojnosť so životom, nižšie úrovne motivácie a zvýšenú závislosť od zdravotníckych služieb, čo vedie k zníženej kvalite života (Bobčíková & Bužgová, 2023).

Okrem toho psychické zdravie zohráva zásadnú a navzájom prepojenú úlohu v celkovej skúsenosti jednotlivcov žijúcich s CHF. Štúdie zistili, že symptómy depresie sú obzvlášť rozšírené medzi pacientmi so srdcovým zlyhaním a významne korelujú so zníženou HRQoL (Dinku et al., 2024). Táto asociácia naznačuje, že ako sa symptómy srdcového zlyhania zhoršujú, pravdepodobnosť psychologických komorbidít stúpa, čo ešte zhoršuje výzvy, ktorým pacienti čelia (Audi et al., 2017). Intervencie zamerané na psychické zdravie a fyzickú rehabilitáciu, ako napríklad rehabilitácia srdca založená na cvičení, sa ukázali sľubné pri zlepšovaní kvality života v tejto demografii (Bobčíková & Bužgová, 2023). Okrem toho, efektívne riadenie psychologických aspektov prostredníctvom podpory a psychoterapeutických prístupov môže významne zlepšiť HRQoL u pacientov s CHF, čo naznačuje, že holistický prístup, ktorý zdôrazňuje vzájomnú závislosť fyzického a psychického zdravia, je nevyhnutný pre optimálne výsledky pacientov (Patidar et al., 2021). Takže súčasné riešenie fyzických prejavov srdcového zlyhania a sprievodného psychického stresu je nevyhnutné na zlepšenie kvality života tých, ktorých sa táto chronická choroba týka.



Obrázok 5: Pickerove princípy starostlivosti orientovanej na pacienta, ktoré zdôrazňujú najdôležitejšie prvky s cieľom dosiahnuť kvalitnú zdravotnú starostlivosť a vysokú spokojnosť pacientov. Tieto princípy sú dôležité na integráciu do plánovanej zmeny paradigmy.

(Položky zhora nadol: rešpektovanie preferencií pacienta; koordinácia a integrácia starostlivosti; informácie a vzdelávanie; fyzický komfort; emocionálna podpora; zapojenie rodiny a priateľov; pokračovanie a zmena stavu; prístup k starostlivosti.)
<https://doi.org/10.1007/s13167-019-00188-9>

4.2 Meranie psychického stavu

Meranie psychického stavu pacientov s chronickým srdcovým zlyhaním je kľúčové pre pochopenie ich celkovej pohody a usmernenie liečebných prístupov. Rôzne nástroje a hodnotenia sa využívajú na hodnotenie psychologického stresu, úzkosti a depresie takejto populácie, čím sa poskytujú poznatky o tom, ako tieto faktory ovplyvňujú nielen kvalitu života, ale aj dodržiavanie liečby a klinické výsledky.

4.2.1 Štandardizované dotazníky a hodnotenia

Štandardizované psychologické hodnotiace nástroje sa bežne používajú na systematické hodnotenie stavu duševného zdravia pacientov s CHF. Medzi nimi sa často používa **Hospital Anxiety and Depression Scale** (HADS), pretože obsahuje dve podstupnice pre úzkosť a depresiu, špeciálne navrhnuté pre pacientov v lekárskech podmienkach (Michalski et al., 2024). Ďalším široko používaným nástrojom je **Beckova inventúra depresie** (BDI), ktorá pomáha klinickým lekárom kvantifikovať závažnosť depresívnych symptómov (Wang &

Gorenstein, 2013). Tým pomáha identifikovať pacientov, ktorí by mohli mať prospech z psychologických intervenčných prístupov. Okrem toho, dotazník o zdravotnom stave pacienta (PHQ-9) navyše slúži na posúdenie závažnosti depresie na základe symptómov, ktoré sami nahlásili, a poskytuje rýchly nástroj na skríning možných úzkostných porúch u pacientov so srdcovým zlyhaním (Sumaqa et al., 2023). Tieto nástroje dokážu posúdiť, ako emocionálny stres ovplyvňuje dodržiavanie liečby a sebaobslužné správanie, ktoré sú životne dôležité pre efektívne zvládanie chronického srdcového zlyhania (Wang et al., 2023).

4.2.2 Hodnotenia kvality života súvisiacej so zdravím

Ďalším dôležitým aspektom merania psychického stavu pacientov s CHF je **hodnotenie kvality života súvisiacej so zdravím** (HRQoL) (Almeida et al., 2020). Dotazník **Minnesota Living with Heart Failure Questionnaire** (MLHFQ) hodnotí vplyv symptómov srdcového zlyhania na každodenný život pacientov a psychickú pohodu, čo umožňuje poskytovateľom zdravotnej starostlivosti získať prehľad o širších dôsledkoch ich stavu (Rector et al., 2012). **Kansas City Cardiomyopathy Questionnaire** (KCCQ) tiež meria vnímanie pacientov o ich srdcovom zlyhaní a o jeho vplyve na kvalitu života, pričom do svojho hodnotenia zapracováva psychologické rozmery (Goates et al., 2019). Používaním týchto škál HRQoL spolu s psychologickými hodnoteniami môžu odborníci celostne vyhodnotiť, ako CHF ovplyvňuje duševné zdravie a celkovú kvalitu života, potenciálne identifikujúc tých, ktorí sú v riziku zlých výsledkov kvôli neliečeným psychologickým problémom (Wang et al., 2023).

4.2.3 Hodnotenia kognitívnych funkcií a mechanizmov zvládania

Hodnotenie kognitívnej funkcie a stratégií zvládania je rovnako dôležité pre pochopenie psychického stavu pacientov s CHF. Nástroje ako **Montreal Cognitive Assessment** (MoCA) hodnotia kognitívne poškodenia, ktoré môžu priamo ovplyvniť sebaovládanie pri CHF a emocionálne zdravie pacienta (Niu et al., 2022). Okrem toho meranie mechanizmov zvládania, ako je **Coping Inventory for Stressful Situations** (CISS), môže odhaliť, ako pacienti zvládajú stres súvisiaci so svojím stavom a jeho progresiou. Konkrétny referenčný podklad pre CISS v CHF však nebol nájdený a mal by sa používať s opatrnosťou. Pochopenie týchto stratégií zvládania môže pomôcť prispôsobiť psychologické intervencie na efektívnejšiu podporu pacientov s CHF (Ankomah et al., 2022), (Kristinawati et al., 2024).

4.2.4 Zhrnutie

Meranie psychického stavu pacientov s chronickým srdcovým zlyhaním zahŕňa multifaktoriálny prístup, ktorý zahŕňa štandardizované dotazníky hodnotenia kvality života súvisiacej so zdravím a hodnotenia kognitívnych funkcií a mechanizmov zvládania. Využívanie týchto nástrojov umožňuje klinickým lekárom získať komplexné porozumenie psychickej pohody pacientov, čo uľahčuje podporné intervencie, ktoré môžu viesť k zlepšeniu zdravotných výsledkov a zlepšenej kvalite života pre jednotlivcov žijúcich s CHF.

4.3 Vhodné prístupové metódy

Na predikciu zhoršovania psychického stavu pacientov s chronickým srdcovým zlyhaním sa dá použiť množstvo rozmanitých metód, ktoré využívajú klinické hodnotenia a kvantitatívne mierky. Nasledujúce body podrobne opisujú kľúčové prístupy vyplývajúce z uvedených referencií.

4.3.1 Štandardizované psychologické hodnotenia

- **Stupnica úzkosti a depresie v nemocnici (HADS):** Bežne používaný nástroj na hodnotenie úrovne úzkosti a depresie u pacientov v lekárskom kontexte. Stupnica obsahuje 14 položiek a poskytuje rýchly prehľad o emocionálnom stave pacienta, čo môže pomôcť identifikovať tých, ktorí potrebujú psychologickú podporu (Michalski et al., 2024).
- **Beckova inventúra depresie (BDI):** Toto hodnotenie pomáha zhodnotiť závažnosť depresívnych symptómov. Využitie tohto nástroja môže poskytnúť prehľad o psychickom zdraví pacientov s CHF a informovať o plánovaní liečby (Wang & Gorenstein, 2013)
- **Dotazník pre pacientov o duševnom zdraví (PHQ-9):** Tento dotazník s deviatimi položkami hodnotí závažnosť depresie a môže účinne identifikovať pacientov s vysokým rizikom zhoršenia psychického zdravia, čo umožňuje včasné intervencie (Mahoney-Davies et al., 2017).

4.3.2 Hodnotenia kvality života súvisiacej so zdravím

- **Dotazník Minnesota Living with Heart Failure (MLHFQ):** Tento nástroj meria vplyv srdcového zlyhania na každodenný život pacientov, vrátane fyzickej a emocionálnej pohody. Dotazník môže ponúknuť významné informácie o psychickom stave spojenom so závažnosťou srdcového zlyhania (Rector et al., 2012).
- **Dotazník Kansas City Cardiomyopathy (KCCQ):** Ďalší dôležitý nástroj, ktorý zahŕňa aspekty kvality života súvisiace so zdravím, ktoré odrážajú psychologické blaho, čím umožňuje identifikáciu pacientov s rizikom zlých duševných výsledkov (Goates et al., 2019).

4.3.3 Kontinuálne monitorovanie a hodnotenie správania

- **Údaje z nositeľných zariadení:** Technológie, ako sú inteligentné hodinky a fitness náramky, môžu poskytovať nepretržité monitorovanie fyziologických parametrov (ako je variabilita srdcovej frekvencie), ktoré korelujú s psychickou pohodou. Pokles úrovne aktivity alebo významné kolísanie srdcovej frekvencie môžu naznačovať zhoršujúce sa psychické zdravie (Odeh, 2024).
- **Kontrolné zoznamy symptómov:** Denné samohodnotiace kontrolné zoznamy symptómov môžu pomôcť pacientom a poskytovateľom sledovať emocionálne a fyzické symptómy súvisiace s CHF. Sledovanie symptómov, ako sú únava, beznádejnosť alebo úzkosť, poskytuje zásadné informácie o zmenách v psychickom zdraví (Aamodt et al., 2020), (Kristinawati et al., 2024).

4.3.4 Biomarkery súvisiace s psychickým stavom

- **B-typ natriuretického peptidu (BNP):** Zvýšené hladiny BNP boli spojené so zhoršovaním klinických výsledkov pri srdcovom zlyhaní a môžu tiež korelovať s psychologickým stresom (Wang et al., 2012). Monitorovanie zmien v BNP môže poskytnúť prehľad o celkovom zdraví pacientov s CHF (Sheikhvatan et al., 2018).
- **Vysoko citlivé C-reaktívne proteíny (hs-CRP):** Tento zápalový marker môže naznačovať úrovne psychologického stresu, ktoré korelujú so stavom fyzického zdravia. Môže tak slúžiť ako nepriamy ukazovateľ emocionálnej pohody (Yu et al., 2023).

4.3.5 Hodnotenia kognitívnej funkcie

- **Montreal Cognitive Assessment (MoCA):** Tento nástroj na skrining kognitívneho stavu hodnotí pamäť, pozornosť a jazykové schopnosti. Pacienti s CHF sú vystavení zvýšenému riziku kognitívneho poklesu, ktorý môže ovplyvniť ich stratégie zvládania a emocionálne zdravie (Niu et al., 2022).
- **Hodnotenie kognitívnych mechanizmov zvládania:** Hodnotenie stratégií zvládania môže poskytnúť prehľad o tom, ako pacienti s CHF zvládajú stres, čo prispieva k ich psychickému stavu. Hodnotenie týchto mechanizmov môže pomôcť prispôbiť podporu a intervencie (Sumaqa & Hayajneh, 2022), (Kristinawati et al., 2024).

4.3.6 Modely predikcie rizika


- **Prístupy strojového učenia:** Nové modely strojového učenia môžu analyzovať veľké dátové súbory klinických a psychologických údajov, aby predpovedali zmeny v psychickom zdraví pacientov v reakcii na progresiu srdcového zlyhania. Využitie rôznych hlásených výsledkov pacientov poskytuje sofistikovaný prístup k identifikácii jednotlivcov s rizikom (Sun et al., 2024).
- **Analýza variability srdcovej frekvencie (HRV):** HRV môže poskytnúť prehľad o funkcii autonómneho nervového systému, ktorý je spojený s emocionálnym zdravím. Sledovanie zmien v HRV môže pomôcť predpovedať potenciálne zhoršenia psychických stavov medzi pacientmi s CHF (Morimoto et al., 2020), (Kurtoğlu et al., 2013).

4.3.7 Zhrnutie

Multifaktoriálny prístup, ktorý zahŕňa štandardizované psychologické hodnotenia, hodnotenia kvality života súvisiacej so zdravím, nepretržité monitorovanie, biomarkery, kognitívne hodnotenia a predikčné modely, môže efektívne hodnotiť a predpovedať zhoršujúci sa psychický stav pacientov s chronickým srdcovým zlyhaním. Každá metóda prispieva ku komplexnému pochopeniu toho, ako psychické zdravie ovplyvňuje celkové výsledky pri CHF, pričom zdôrazňuje potrebu cielených intervencií na podporu duševnej aj fyzickej pohody pacienta.

5 Bezpečnosť integrácie a spracovania údajov telemedicíny

Integrácia telemedicíny do zdravotníckych systémov zvýšila potrebu robustných bezpečnostných opatrení na ochranu informácií o pacientoch. Vzhľadom na citlivú povahu zdravotných údajov je nevyhnutné riešiť otázky autentifikácie, anonymizácie, dodržiavania **Všeobecného nariadenia o ochrane údajov** (GDPR), detekcie narušení a spoľahlivosti systémov. Tieto elementy sú kľúčové nielen na udržanie súkromia pacientov, ale aj na zvýšenie dôvery pacientov a poskytovateľov zdravotnej starostlivosti v systémy telemedicíny.



Obrázok 6: Hybridný koncept pre zmenu paradigmy v liečbe chronického srdcového zlyhania, vrátane umelej inteligencie (AI) podporovanej sebaobsluhy a cieleného zapojenia zdravotníckych pracovníkov, vyžadujúci adekvátne viacúrovňové diagnostiky na strane pacienta a komplexné individuálne datasety. V závislosti od zložitosti sú rozhodnutia o liečbe pacienta robené priamo AI alebo zdravotníckymi profesionálmi (opatrovateľmi). (<https://doi.org/10.1007/s13167-019-00188-9>)

5.1 Autentifikácia a kontrola prístupu

Efektívne autentifikačné mechanizmy sú kľúčové v telemedicíne, aby sa zabezpečilo, že k citlivým informáciám o pacientoch môžu mať prístup iba oprávnení pracovníci. Techniky ako viacfaktorová autentifikácia (MFA) zlepšujú bezpečnosť tým, že vyžadujú viac ako len heslo, čím sa znižuje riziko neoprávneného prístupu (Zanke & Sontakke, 2024). Napríklad

biometrické metódy autentifikácie môžu poskytnúť vysokú úroveň istoty, že osoba prístupujúca k záznamom pacientov je skutočne oprávnená, čo je kľúčové v službách telemedicíny, ktoré spĺňajú normy HIPAA (Tabaeian et al., 2022). Okrem toho pravidelné audity prístupových záznamov môžu pomôcť identifikovať potenciálne porušenia a posilniť zodpovednosť medzi poskytovateľmi zdravotnej starostlivosti (Muyunda & Mpundu, 2024).

5.2 Šifrovanie údajov

Šifrovanie end-to-end: Implementujú sa šifrovacie protokoly napr. AES-256 (Salunkhe et al., 2024), aby sa zabezpečilo, že údaje pacientov prenášané medzi monitorovacími zariadeniami a poskytovateľmi zdravotnej starostlivosti budú chránené počas prepravy. To zabraňuje neoprávnenému prístupu alebo odchyту (Gyawali & Karyakarte, 2023), (Kotb et al., 2015).

Šifrovanie zabezpečených údajov: Požiadavka, aby boli uložené údaje – vrátane zdravotných záznamov pacientov a telemetrických údajov – zašifrované, aby sa chránili pred neoprávneným prístupom, najmä v situáciách, kde môžu byť zariadenia fyzicky kompromitované (Kotb et al., 2015).

5.3 Anonymizácia údajov a dodržiavanie GDPR

Anonymizácia údajov pacientov je nevyhnutná na ochranu individuálnych identít v telemedicíne. Tento proces zahŕňa odstránenie alebo zmenu osobných identifikátorov z informácií o pacientoch, čím sa znemožní sledovanie údajov späť ku konkrétnej osobe (Cui et al., 2020). Okrem toho GDPR stanovuje prísne predpisy na zaobchádzanie s osobnými údajmi, čím zdôrazňuje potrebu súhlasu pacientov a zabezpečuje, že spracovanie údajov je zákonné, transparentné a bezpečné (Nobili et al., 2025). Poskytovatelia telemedicíny musia nielen implementovať dôsledné rámce správy údajov, ktoré vyhovujú GDPR, ale aj pravidelne hodnotiť svoje politiky ochrany údajov. Tento súlad posilňuje dôveru medzi pacientmi a poskytovateľmi zdravotnej starostlivosti, čo podporuje väčšie akceptovanie služieb telemedicíny.

5.4 Systémy detekcie narušení (IDS)

Systémy detekcie narušení (IDS) zohrávajú kľúčovú úlohu pri monitorovaní a analýze sieťovej prevádzky pri pokusoch o neoprávnený prístup (Pant et al., 2023). To je obzvlášť dôležité v kontexte telemedicíny, kde porušenia údajov môžu mať závažné následky. Implementácia

riešení IDS umožňuje zdravotníckym organizáciám detegovať škodlivé aktivity v reálnom čase, čím sa rýchlo reaguje na potenciálne hrozby pre ochranu súkromia údajov pacientov (Moghbeli et al., 2017). Navyše, integrácia pokročilých algoritmov strojového učenia do IDS môže zlepšiť schopnosti detekcie tým, že sa rýchlo prispôbia sa vyvíjajúcim sa kybernetickým hrozbám. Tým sa zabezpečí, že systém zostane ostražitý voči novým technikám narušenia (Ghafari et al., 2019).

5.5 Spôľahlivosť a odolnosť systémov

Spôľahlivosť telemedicínskych systémov je kľúčová pre zaručenie kontinuálnej starostlivosti o pacientov a udržanie prevádzkovej integrity poskytovateľov zdravotnej starostlivosti. (Utami, 2025) Zlyhania systémov môžu viesť k významným narušeniam v manažmente pacientov, čo ohrozuje celkovú kvalitu starostlivosti. Vytváranie spoľahlivých telemedicínskych systémov vyžaduje implementáciu robustných zálohových riešení a stratégie pre zlyhania systému (failover), aby sa udržali operácie počas výpadkov. Okrem toho sú pravidelné aktualizácie softvéru a protokoly kybernetickej bezpečnosti nevyhnutné na zmiernenie zraniteľností a na posilnenie odolnosti systému voči kybernetickým hrozbám, čím sa chránia informácie o pacientoch a zabezpečuje sa plynulé poskytovanie zdravotnej starostlivosti (Ahmad et al., 2021).

5.6 Pravidelné bezpečnostné audity a zhoda

Je potrebné vykonávať periodické audity celého systému telemonitorovania na identifikáciu zraniteľností a zabezpečenie súladu s etablovanými lekáorskými a ochranárskymi predpismi (Inglis et al., 2015). Zabezpečiť, aby architektúra telemonitoringu bola v súlade s normami stanovenými GDPR a HIPAA na ochranu citlivých zdravotných údajov, vrátane implementácie politik ochrany súkromia a rámcov práv pacientov (Hasselgren et al., 2020), (Abirami & Anbarasi, 2024).

5.7 Vzdelávanie a školenie používateľov

Je potrebné pravidelné vzdelávanie poskytovateľov zdravotnej starostlivosti a pacientov o osvedčených praktikách v oblasti bezpečnosti údajov, vrátane rozpoznávania pokusov o phishing a udržiavania bezpečných hesiel (Abirami & Anbarasi, 2024) a tiež zriadenie a zdieľanie komplexných plánov reakcie na incidenty, ktoré vytyčujú kroky, ktoré sa majú podniknúť v prípade porušenia údajov alebo iného bezpečnostného incidentu (Wittkop, 2016).

5.8 Zálohy údajov a postupy obnovy

Nevyhnutná je implementácia automatizovaných a pravidelných záloh údajov pacientov, aby sa zmiernili straty údajov v dôsledku zlyhania systémov alebo kybernetických útokov. Zálohované údaje by mali byť taktiež šifrované, aby sa udržala ich dôvernosť. Treba vyvinúť jasné stratégie na obnovu po katastrofách, aby sa zabezpečila pokračujúca činnosť v prípade významného porušenia údajov alebo zlyhania infraštruktúry telemonitorovania (Wittkop, 2016).

5.9 Zhrnutie

Zabezpečenie údajov pacientov v telemedicíne si vyžaduje multifaktoriálny prístup, ktorý zahŕňa efektívne procesy autentifikácie, techniky anonymizácie údajov, prísne dodržiavanie regulačných rámcov ako GDPR a zriadenie systémov detekcie narušení, pričom sa zabezpečuje celková spoľahlivosť systémov. Prioritizovaním týchto elementov môžu poskytovatelia zdravotnej starostlivosti vytvoriť bezpečné prostredie pre poskytovanie služieb telemedicíny, zvyšujúc dôveru medzi pacientmi a nakoniec prispievať k efektívnosti a účinnosti poskytovania zdravotnej starostlivosti.

6 Literatúra

- Aamodt, I. T., Lycholip, E., Čelutkienė, J., von Lueder, T. G., Atar, D., Falk, R. S., . . . Lie, I. (2020). Self-Care Monitoring of Heart Failure Symptoms and Lung Impedance at Home Following Hospital Discharge: Longitudinal Study. *Journal of Medical Internet Research*. doi:10.2196/15445
- Abirami, N., & Anbarasi, M. S. (2024). An Efficient Multilayer Approach for Securing E-Healthcare Data in Cloud Using Crypto – Stego Technique. *Engineering World*. doi:10.37394/232025.2024.6.13
- Adedoyin, R. A. (2010). Assessment of Exercise Capacity in African Patients With Chronic Heart Failure Using Six Minutes Walk Test. *International Journal of General Medicine*. doi:10.2147/ijgm.s5533
- Aeschbacher, S., Blum, M. R., Kastner, P., Baguley, F., Aeschbacher, S., Auberson, C., . . . Schmid, R. (2021). Insulin-Like Growth Factor-Binding Protein 7 and Risk of Congestive Heart Failure Hospitalization in Patients With Atrial Fibrillation. *Heart Rhythm*. doi:10.1016/j.hrthm.2020.11.028
- Ahmad, R. W., Salah, K., Jayaraman, R., Yaqoob, I., Ellahham, S., & Omar, M. (2021). The Role of Blockchain Technology in Telehealth and Telemedicine. *International Journal of Medical Informatics*. doi:10.1016/j.ijmedinf.2021.104399
- Ahmad, T., Lund, L. H., Rao, P., Ghosh, R., Warier, P., Vaccaro, B. J., . . . Desai, N. R. (2018). Machine Learning Methods Improve Prognostication, Identify Clinically Distinct Phenotypes, and Detect Heterogeneity in Response to Therapy in a Large Cohort of Heart Failure Patients. *Journal of the American Heart Association*. doi:10.1161/jaha.117.008081
- Ahmed, S., Nielsen, I. E., Tripathi, A., Siddiqui, S. A., Rasool, G., & Ramachandran, R. P. (2022). Transformers in Time-Series Analysis: A Tutorial. doi:10.48550/arxiv.2205.01138
- Alem, M. M. (2019). Endothelial Dysfunction in Chronic Heart Failure: Assessment, Findings, Significance, and Potential Therapeutic Targets. *International Journal of Molecular Sciences*. doi:10.3390/ijms20133198
- Allen, L. A., Matlock, D. D., Shetterly, S., Xu, S., Levy, W. C., Portalupi, L. B., . . . Magid, D. J. (2017). Use of Risk Models to Predict Death in the Next Year Among Individual Ambulatory Patients With Heart Failure. *Jama Cardiology*. doi:10.1001/jamacardio.2016.5036
- Alsubai, S., Alqahtani, A., Binbusayyis, A., Sha, M., Gumaei, A., & Wang, S. (2023). Heart Failure Detection Using Instance Quantum Circuit Approach and Traditional Predictive Analysis. *Mathematics*. doi:10.3390/math11061467
- Ankomah, F., Quansah, F., Agormedah, E. K., Hagan, J. E., Srem-Sai, M., Sambah, F., . . . Schack, T. (2022). Validity and Reliability of Cultural Mix Coping Inventory for Stressful Situations Among Healthcare Professionals in Ghana Amidst COVID-19. *International Journal of Environmental Research and Public Health*. doi:10.3390/ijerph191710651
- Apriza, R., Hasan, H., Mukhtar, Z., R, A. H., Akbar, N. Z., & Lubis, A. C. (2021). Six Minute Walking Test as Predictor for Mortality and Rehospitalization Within 3 Months in Post Coronary Bypass Surgery Patients. *Acta (Acta Cardiologia Indonesiana)*. doi:10.22146/jaci.v7i1.1118

- Audi, G., Korologou, A., Koutelekos, I., Vasilopoulos, G., Karakostas, K. X., Makrygianaki, K., & Polikandrioti, M. (2017). Factors Affecting Health Related Quality of Life in Hospitalized Patients With Heart Failure. *Cardiology Research and Practice*. doi:10.1155/2017/4690458
- Berezin, A. E., Kremzer, A. A., & Samura, T. (2016). Circulating Thrombospondin-2 in Patients With Moderate-to-Severe Chronic Heart Failure Due to Coronary Artery Disease. *Journal of Biomedical Research*. doi:10.7555/jbr.29.20140025
- Bielecka-Dąbrowa, A., Trzmielak, D., Sakowicz, A., Janikowski, K., & Banach, M. (2024). Gender Differences in Efficiency of the Telemedicine Care of Heart Failure Patients. The Results From the TeleEduCare-HF Study. *Archives of Medical Science*. doi:10.5114/aoms/183523
- Bobčiková, K., & Bužgová, R. (2023). An Assessment of the Quality of Life in Chronic Heart Failure Patients. *Pielęgniarstwo Xxi Wieku / Nursing in the 21st Century*. doi:10.2478/pielxxiw-2023-0039
- Borisenko, O., Müller-Ehmsen, J., Lindenfeld, J., Rafflenbeul, E., & Hamm, C. W. (2018). An Early Analysis of Cost-Utility of Baroreflex Activation Therapy in Advanced Chronic Heart Failure in Germany. *BMC Cardiovascular Disorders*. doi:10.1186/s12872-018-0898-x
- Bradley, E. H., Curry, L., Horwitz, L. I., Sipsma, H., Wang, Y., Walsh, M. N., . . . Krumholz, H. M. (2013). Hospital Strategies Associated With 30-Day Readmission Rates for Patients With Heart Failure. *Circulation Cardiovascular Quality and Outcomes*. doi:10.1161/circoutcomes.111.000101
- Brons, M., Koudstaal, S., & Asselbergs, F. W. (2018). Algorithms Used in Telemonitoring Programmes for Patients With Chronic Heart Failure: A Systematic Review. *European Journal of Cardiovascular Nursing*. doi:10.1177/1474515118786838
- Comín-Colet, J., Enjuanes, C., González, G., Torrens, A., Cladellas, M., Meroño, O., . . . Bruguera, J. (2013). Iron Deficiency Is a Key Determinant of Health-related Quality of Life in Patients With Chronic Heart Failure Regardless of Anaemia Status. *European Journal of Heart Failure*. doi:10.1093/eurjhf/hft083
- Conrad, N., Judge, A., Tran, J., Mohseni, H., Hedgecott, D., Crespillo, A. P., . . . Rahimi, K. (2018). Temporal Trends and Patterns in Heart Failure Incidence: A Population-Based Study of 4 Million Individuals. *The Lancet*. doi:10.1016/s0140-6736(17)32520-5
- Cooper, L. B., DeVore, A. D., & Felker, G. M. (2015). The Impact of Worsening Heart Failure in the United States. *Heart Failure Clinics*. doi:10.1016/j.hfc.2015.07.004
- Cooper, L. B., Hammill, B. G., Sharma, P. P., DeVore, A. D., Mentz, R. J., Fonarow, G. C., . . . Hernandez, A. F. (2015). Differences in Health Care Use and Outcomes by the Timing of in-Hospital Worsening Heart Failure. *American Heart Journal*. doi:10.1016/j.ahj.2015.09.001
- Coviello, I., Pinnacchio, G., Laurito, M., Stazi, A., Battipaglia, I., Barone, L., . . . Crea, F. (2013). Prognostic Role of Heart Rate Variability in Patients With ST-Segment Elevation Acute Myocardial Infarction Treated by Primary Angioplasty. *Cardiology*. doi:10.1159/000345779
- Creber, R. M., Lee, C. S., Margulies, K. B., & Riegel, B. (2015). Identifying Biomarker Patterns and Predictors of Inflammation and Myocardial Stress. *Journal of Cardiac Failure*. doi:10.1016/j.cardfail.2015.02.006
- Cui, F., Ma, Q., He, X., Zhai, Y., Zhao, J., Chen, B., . . . Wang, Z. (2020). Implementation and Application of Telemedicine in China: Cross-Sectional Study. *Jmir Mhealth and Uhealth*. doi:10.2196/18426

- D'Onofrio, A., Solimene, F., Calò, L., Calvi, V., Viscusi, M., Melissano, D., . . . Padeletti, L. (2021). Combining Home Monitoring temporal Trends From Implanted Defibrillators and Baseline Patient Risk Profile to Predict Heart Failure Hospitalizations: Results From the SELENE HF Study. *Ep Europace*. doi:10.1093/europace/euab170
- Damman, K., van Veldhuisen, D. J., Navis, G. J., Vaidya, V. S., Smilde, T. D., Westenbrink, B. D., . . . Hillege, H. L. (2010). Tubular Damage in Chronic Systolic Heart Failure Is Associated With Reduced Survival Independent of Glomerular Filtration Rate. *Heart*. doi:10.1136/hrt.2010.194878
- Daniels, L. B., Clopton, P., Laughlin, G. A., Maisel, A. S., & Barrett-Connor, E. (2014). Galectin-3 Is Independently Associated With Cardiovascular Mortality in Community-Dwelling Older Adults Without Known Cardiovascular Disease: The Rancho Bernardo Study. *American Heart Journal*. doi:10.1016/j.ahj.2013.12.031
- Davison, B. A., Senger, S., Sama, I. E., Koch, G. G., Mebazaa, A., Dickstein, K., . . . Cotter, G. (2021). Is Acute Heart Failure a Distinctive Disorder? An Analysis From <sc>BIOSTAT-CHF</Scp>. *European Journal of Heart Failure*. doi:10.1002/ejhf.2077
- de Almeida, F. A., Al, M., Koymans, R., Riistama, J., Pauws, S., & Severens, J. L. (2020). Impact of Hospitalisation on Health-Related Quality of Life in Patients With Chronic Heart Failure. *Health and Quality of Life Outcomes*. doi:10.1186/s12955-020-01508-8
- de Boer, R. A., Lok, D. J., Jaarsma, T., der Meer, P. v., Voors, A. A., Hillege, H. L., & van Veldhuisen, D. J. (2010). Predictive Value of Plasma Galectin-3 Levels in Heart Failure With Reduced and Preserved Ejection Fraction. *Annals of Medicine*. doi:10.3109/07853890.2010.538080
- de Lemos, J. A., Morrow, D. A., & deFilippi, C. R. (2011). Highly Sensitive Troponin Assays and the Cardiology Community: A Love/Hate Relationship? *Clinical Chemistry*. doi:10.1373/clinchem.2011.163758
- Deichl, A. S., Wachter, R., & Edelmann, F. (2022). Comorbidities in Heart Failure With Preserved Ejection Fraction. *Herz*. doi:10.1007/s00059-022-05123-9
- Denardo, S. J., Vock, D. M., Schmalfuss, C., Young, G. D., Tchong, J. E., & O'Connor, C. M. (2016). Baseline Hemodynamics and Response to Contrast Media During Diagnostic Cardiac Catheterization Predict Adverse Events in Heart Failure Patients. *Circulation Heart Failure*. doi:10.1161/circheartfailure.115.002529
- DeVon, H. A., Vuckovic, K. M., Ryan, C., Barnason, S., Zerwic, J. J., Pozehl, B., . . . Zimmerman, L. (2016). Systematic Review of Symptom Clusters in Cardiovascular Disease. *European Journal of Cardiovascular Nursing*. doi:10.1177/1474515116642594
- DeVore, A. D., Hammill, B. G., Sharma, P. P., Qualls, L. G., Mentz, R. J., Johnson, K. W., . . . Hernandez, A. F. (2014). In-Hospital Worsening Heart Failure and Associations With Mortality, Readmission, and Healthcare Utilization. *Journal of the American Heart Association*. doi:10.1161/jaha.114.001088
- Dinku, K., Chala, D., Regea, F., & Lema, M. (2024). Health-Related Quality of Life and Associated Factors Among Individuals With Heart Failure Attending Public Hospitals in Nekemte Town, Western Oromia, Ethiopia: A Cross-Sectional Study. doi:10.21203/rs.3.rs-5287393/v1
- Ekola, T., Virtanen, V., & Koskela, T. (2024). Feasibility of a Noninvasive Heart Failure Telemonitoring System: A Mixed Methods Study. *Digital Health*. doi:10.1177/20552076241272633

- Emir, İ., & Aydın, Y. (2025). Comparison of the Effects of Features and Classifiers on Performance in the Cardiovascular Disease Detection System. *Journal of Scientific Reports-A*. doi:10.59313/jsr-a.1579269
- Erceg, P., Despotovic, N., Milošević, D., Soldatović, I., Zdravkovic, S., Tomic, S., . . . Davidović, M. (2013). Health-Related Quality of Life in Elderly Patients Hospitalized With Chronic Heart Failure. *Clinical Interventions in Aging*. doi:10.2147/cia.s53305
- Essay, P., Balkan, B., & Subbian, V. (2020). Decompensation in Critical Care: Early Prediction of Acute Heart Failure Onset. *Jmir Medical Informatics*. doi:10.2196/19892
- Ezer, P., Gergics, M., Szokodi, I., & Kónyi, A. (2022). Impact of Remote Monitoring in Heart Failure Patients With Cardiac Implantable Electronic Devices During COVID-19 Pandemic: A Single Center Experience. *Journal of Cardiothoracic Surgery*. doi:10.1186/s13019-022-01963-y
- Falck, L., Zoller, M., Rosemann, T., Martínez-González, N. A., & Chmiel, C. (2019). Toward Standardized Monitoring of Patients With Chronic Diseases in Primary Care Using Electronic Medical Records: Systematic Review. *Jmir Medical Informatics*. doi:10.2196/10879
- Felker, G. M., Fiuzat, M., Shaw, L. K., Clare, R. M., Whellan, D. J., Bettari, L., . . . O'Connor, C. M. (2012). Galectin-3 in Ambulatory Patients With Heart Failure. *Circulation Heart Failure*. doi:10.1161/circheartfailure.111.963637
- Fernández Sánchez, M. J., Scagliusi, S. F., Giménez, L., Pérez, P., Medrano, F. J., & Olmo, A. (2024). Design of Wearable Textile Electrodes for the Monitorization of Patients With Heart Failure. *Sensors*. doi:10.3390/s24113637
- Ferreira, J. P., Metra, M., Mordi, I., Gregson, J., ter Maaten, J. M., Tromp, J., . . . Zannad, F. (2018). Heart Failure in the Outpatient Versus Inpatient Setting: Findings From the BIOSSTAT-CHF Study. *European Journal of Heart Failure*. doi:10.1002/ejhf.1323
- Foussier, J., Teichmann, D., Jia, J., Misgeld, B. J., & Leonhardt, S. (2014). An Adaptive Kalman Filter Approach for Cardiorespiratory Signal Extraction and Fusion of Non-Contacting Sensors. *BMC Medical Informatics and Decision Making*. doi:10.1186/1472-6947-14-37
- Fu, M. R., Li, Y., Conway, C., Masone, A., Fang, J., & Lee, C. (2022). The Effects of Exercise-Based Interventions on Fluid Overload Symptoms in Patients With Heart Failure: A Systematic Review and Meta-Analysis. *Biomedicines*. doi:10.3390/biomedicines10051111
- Gensini, G. F., Alderighi, C., Rasoini, R., Mazzanti, M., & Casolo, G. (2017). Value of Telemonitoring and Telemedicine in Heart Failure Management. *Cardiac Failure Review*. doi:10.15420/cfr.2017:6:2
- Ghafari, S. F., Mahdizadeh, J., Valinejadi, A., Mehraeen, E., Mohammadpour, A., Bouraghi, H., & Kahouei, M. (2019). Iranian Physicians' Expectations of Telemedicine Development and Implementation Infrastructures in Teaching Hospitals. *Aims Public Health*. doi:10.3934/publichealth.2019.4.514
- Giolo, S. R., Krieger, J. E., Mansur, A. J., & Pereira, A. C. (2012). Survival Analysis of Patients With Heart Failure: Implications of Time-Varying Regression Effects in Modeling Mortality. *Plos One*. doi:10.1371/journal.pone.0037392
- Gjoreski, M., Gradišek, A., Budna, B., Gams, M., & Poglajen, G. (2020). Machine Learning and End-to-End Deep Learning for the Detection of Chronic Heart Failure From Heart Sounds. *Ieee Access*. doi:10.1109/access.2020.2968900

- Goates, S., Baron, S. J., Arnold, S., Prillinger, J. B., Cohen, D. J., & Spertus, J. A. (2019). Pcv30 Estimating Health-State Utility in Patients With Heart Failure: Mapping the Kansas City Cardiomyopathy Questionnaire to Sf-6d Utility Scores. *Value in Health*. doi:10.1016/j.jval.2019.04.466
- Groccia, M. C., Lofaro, D., Guido, R., Conforti, D., & Sciacqua, A. (2018). Predictive Models for Risk Assessment of Worsening Events in Chronic Heart Failure Patients. doi:10.22489/cinc.2018.249
- Grundtvig, M., Eriksen-Volnes, T., Ørn, S., Slind, E. K., & Gullestad, L. (2020). 6 min Walk Test Is a Strong Independent Predictor of Death in Outpatients With Heart Failure. *Esc Heart Failure*. doi:10.1002/ehf2.12900
- Gustian, C. I., Nursalam, N., & Qur'aniati, N. (2023). Systematic Review: Telehealth in the Patients Management With Heart Failure. *Medical Technology and Public Health Journal*. doi:10.33086/mtphj.v7i2.4712
- Gyawali, B., Roto, D., Lachant, M., White, R. J., & Lachant, D. (2025). Heart Rate Variability in Pulmonary Arterial Hypertension. *Pulmonary Circulation*. doi:10.1002/pul2.70048
- Gyawali, Y. P., & Karyakarte, M. (2023). A Modular Encryption Framework in Cloud and Mobile Environments for Cybersecurity Solutions in Health Information. *Rjcse*. doi:10.52710/rjcse.64
- Gyllensten, I. C., Crundall-Goode, A., Aarts, R. M., & Goode, K. (2017). Simulated Case Management of Home Telemonitoring to Assess the Impact of Different Alert Algorithms on Work-Load and Clinical Decisions. *BMC Medical Informatics and Decision Making*. doi:10.1186/s12911-016-0398-9
- Hao, Y., & Chen, Y. (2019). Vitamin D Levels and Vitamin D Receptor Variants Are Associated With Chronic Heart Failure in Chinese Patients. *Journal of Clinical Laboratory Analysis*. doi:10.1002/jcla.22847
- Hasselgren, A., Wan, P. K., Horn, M., Kravetska, K., & Gligoroski, D. (2020). GDPR Compliance for Blockchain Applications in Healthcare. doi:10.5121/csit.2020.101303
- Henriques, T., Mariani, S., Burykin, A., Rodrigues, F., da Silva, T. F., & Goldberger, A. L. (2015). Multiscale Poincaré Plots for Visualizing the Structure of Heartbeat Time Series. *BMC Medical Informatics and Decision Making*. doi:10.1186/s12911-016-0252-0
- Hidayaturrohmah, Q. A., & Hanada, E. (2024). Predictive Analytics in Heart Failure Prediction: A Systematic Review. doi:10.20944/preprints202401.1671.v1
- Hippisley-Cox, J., & Coupland, C. (2015). Development and Validation of Risk Prediction Equations to Estimate Future Risk of Heart Failure in Patients With Diabetes: A Prospective Cohort Study. *BMJ Open*. doi:10.1136/bmjopen-2015-008503
- Hooda, E., & Verma, U. (2019). Unobserved Components Model for Forecasting Sugarcane Yield in Haryana. *Journal of Applied and Natural Science*. doi:10.31018/jans.v11i3.2144
- Hossain, C. A., Mohamed, M. A., Rahman Zishan, M. S., Ahasan, R., & Sharun, S. M. (2022). Enhancing the Security of E-Health Services in Bangladesh Using Blockchain Technology. *International Journal of Information Technology*. doi:10.1007/s41870-021-00821-9
- Houston, B. A., Kalathiya, R., Kim, D. A., & Zakaria, S. (2015). Volume Overload in Heart Failure. *Mayo Clinic Proceedings*. doi:10.1016/j.mayocp.2015.05.002

- Chakravarti, S., & Busovsky-McNeal, M. (2016). Use of Tolvaptan in a Patient With Palliated Congenital Heart Disease. *World Journal for Pediatric and Congenital Heart Surgery*. doi:10.1177/2150135116664319
- Chen, S., Hu, W., Yang, Y., Cai, J., Luo, Y., Gong, L., . . . Chen, F. (2023). Predicting Six-Month Re-Admission Risk in Heart Failure Patients Using Multiple Machine Learning Methods: A Study Based on the Chinese Heart Failure Population Database. *Journal of Clinical Medicine*. doi:10.3390/jcm12030870
- Chen, Y., Feng, F., Li, M., Chang, X., Wei, B.-H., & Dong, C. (2019). Development of a Risk Stratification-Based Model for Prediction of Acute Kidney Injury in Critically Ill Patients. *Medicine*. doi:10.1097/md.00000000000016867
- Iacoviello, M., Diomedede, D., Terazzi, E., Diomedede, N., Alcidi, G., Pugliese, R., . . . Brunetti, N. D. (2023). Relationship Between the Strain Measures of Left Atrial Function and Heart Failure Worsening. doi:10.22541/au.168128144.43190347/v1
- Imamura, T., & Kinugawa, K. (2022). Successful Conversion From Conventional Potassium Binder to Sodium Zirconium Cyclosilicate in a Patient With Refractory Constipation. *Medicina*. doi:10.3390/medicina58050635
- Inglis, S. C., Clark, R., Dierckx, R., Prieto-Merino, D., & Cleland, J. G. (2015). Structured Telephone Support or Non-Invasive Telemonitoring for Patients With Heart Failure. *Cochrane Database of Systematic Reviews*. doi:10.1002/14651858.cd007228.pub3
- Izraiq, M., Albalbissi, K., Alawaisheh, R., Toubasi, A. A., Ahmed, Y. B., Mahmoud, M., . . . Abu-Hantash, H. (2024). Comparative Analysis of Heart Failure With Preserved vs Reduced Ejection Fraction: Patient Characteristics, Outcomes, Mortality Prediction, and Machine Learning Model Development in the JoHFR. *International Journal of General Medicine*. doi:10.2147/ijgm.s465388
- Jia, J.-f., Wang, L.-f., & Gao, X.-l. (2023). A Study on the Rapid Diagnosis of Chronic Heart Failure by Measuring the Difference in Pulse Oxygen Saturation Before and After Arm Compression. *Annals of Noninvasive Electrocardiology*. doi:10.1111/anec.13049
- Jungbauer, C., Birner, C., Jung, B., Büchner, S., Lubnow, M., Bary, C. v., . . . Luchner, A. (2011). Kidney Injury Molecule-1 and N-acetyl- β -D-glucosaminidase in Chronic Heart Failure: Possible Biomarkers of Cardiorenal Syndrome. *European Journal of Heart Failure*. doi:10.1093/eurjhf/hfr102
- Jungbauer, C., Uecer, E., Stadler, S., Birner, C., Büchner, S., Maier, L. S., & Luchner, A. (2016). N-acetyl- β -D-glucosaminidase and Kidney Injury Molecule-1: New Predictors for Long-term Progression of Chronic Kidney Disease in Patients With Heart Failure. *Nephrology*. doi:10.1111/nep.12632
- Kerexeta, J., Larburu, N., Escolar, V., Bahamonde, A. L., Macía, I., Beristain, A., & Graña, M. (2023). Prediction and Analysis of Heart Failure Decompensation Events Based on Telemonitored Data and Artificial Intelligence Methods. *Journal of Cardiovascular Development and Disease*. doi:10.3390/jcdd10020048
- Klein, H. (2010). Cardiac Resynchronization Therapy in Asymptomatic or Mildly Symptomatic Heart Failure Patients. *Current Treatment Options in Cardiovascular Medicine*. doi:10.1007/s11936-010-0089-2

- Kotb, A., Cameron, C., Hsieh, S.-C., & Wells, G. A. (2015). Comparative Effectiveness of Different Forms of Telemedicine for Individuals With Heart Failure (HF): A Systematic Review and Network Meta-Analysis. *Plos One*. doi:10.1371/journal.pone.0118681
- Kristinawati, B., Fikriyyah, M. J., Mardana, N. W., & Nur Latiifah, I. R. (2024). An Exploratory Study of Psychological Changes in Families of Heart Failure Patients. doi:10.2991/978-94-6463-467-9_{1}{1}
- Krychtiuk, K. A., Wurm, R., Ruhittel, S., Lenz, M., Huber, K., Wojta, J., . . . Speidl, W. S. (2020). Release of Mitochondrial DNA Is Associated With Mortality in Severe Acute Heart Failure. *European Heart Journal Acute Cardiovascular Care*. doi:10.1177/2048872618823405
- Kumar, A., Sinha, S., Jameel, J., & Kumar, S. (2022). Telemedicine Trends in Orthopaedics and Trauma During the COVID-19 Pandemic: A Bibliometric Analysis and Review. *Journal of Taibah University Medical Sciences*. doi:10.1016/j.jtumed.2021.09.003
- Kurtoğlu, E., Aktürk, E., Korkmaz, H., Ataş, H., Çuğlan, B., & Pekdemir, H. (2013). Impaired Heart Rate Variability in Patients With Mitral Annular Calcification: An Observational Study. *The Anatolian Journal of Cardiology*. doi:10.5152/akd.2013.189
- Ky, B., French, B., Levy, W. C., Sweitzer, N. K., Fang, J. C., Wu, A. H., . . . Cappola, T. P. (2012). Multiple Biomarkers for Risk Prediction in Chronic Heart Failure. *Circulation Heart Failure*. doi:10.1161/circheartfailure.111.965020
- Lainščak, M., Spoletini, I., & Coats, A. J. (2017). Definition and Classification of Heart Failure. *International Cardiovascular Forum Journal*. doi:10.17987/icfj.v10i0.419
- Lala, R. I., Dărbăntiu, D., Pilat, L., & Puşchiță, M. (2015). Galectin-3: A Link Between Myocardial and Arterial Stiffening in Patients With Acute Decompensated Heart Failure? *Arquivos Brasileiros De Cardiologia*. doi:10.5935/abc.20150149
- Larburu, N., Artetxe, A., Escolar, V., Bahamonde, A. L., & Kerexeta, J. (2018). Artificial Intelligence to Prevent Mobile Heart Failure Patients Decompensation in Real Time: Monitoring-Based Predictive Model. *Mobile Information Systems*. doi:10.1155/2018/1546210
- Lavalle, C., Lullo, L. D., Jabbour, J. P., Palombi, M., Trivigno, S., Mariani, M. V., . . . Vizza, C. D. (2023). New Challenges in Heart Failure With Reduced Ejection Fraction: Managing Worsening Events. *Journal of Clinical Medicine*. doi:10.3390/jcm12226956
- Lawson, C., Solis-Trapala, I., Dahlström, U., Mamas, M. A., Jaarsma, T., Kadam, U., & Strömberg, A. (2018). Comorbidity Health Pathways in Heart Failure Patients: A Sequences-of-Regressions Analysis Using Cross-Sectional Data From 10,575 Patients in the Swedish Heart Failure Registry. *Plos Medicine*. doi:10.1371/journal.pmed.1002540
- Leonard, C., Liu, W., Holstein, A., Alliance, S., Nunnery, M., Rohs, C. M., . . . Winchester, D. E. (2023). Informing Use of Telehealth for Managing Chronic Conditions: Mixed-Methods Evaluation of Telehealth Use to Manage Heart Failure During COVID-19. *Journal of the American Heart Association*. doi:10.1161/jaha.122.027362
- Li, J. (2022). Analysis of PETCT Imaging Diagnosis of Heart Failure Improved by Intelligent Sensor in Exercise. *Wireless Communications and Mobile Computing*. doi:10.1155/2022/5343872
- Li, Y., Yu, Y., Wu, Y., Liang, W., Dong, B., Xue, R., . . . Huang, P. (2021). Association of Body-Weight Fluctuation With Outcomes in Heart Failure With Preserved Ejection Fraction. *Frontiers in Cardiovascular Medicine*. doi:10.3389/fcvm.2021.689591

- Lin, J., Ma, H., Gao, L., Wang, Y., Wang, J., Zhu, Z., . . . Wu, W. (2020). Left Atrial Reservoir Strain Combined With E/E' as a Better Single Measure to Predict Elevated LV Filling Pressures in Patients With Coronary Artery Disease. *Cardiovascular Ultrasound*. doi:10.1186/s12947-020-00192-4
- Lok, D. J., der Meer, P. v., Bruggink-André Porte, P. W., Lipšic, E., Wijngaarden, J. v., Hillege, H. L., & van Veldhuisen, D. J. (2010). Prognostic Value of Galectin-3, a Novel Marker of Fibrosis, in Patients With Chronic Heart Failure: Data From the DEAL-HF Study. *Clinical Research in Cardiology*. doi:10.1007/s00392-010-0125-y
- Louvaris, Z., Spetsioti, S., Andrianopoulos, V., Chynkiamis, N., Habazettl, H., Wagner, H., . . . Vogiatzis, I. (2019). Cardiac Output Measurement During Exercise in COPD: A Comparison of Dye Dilution and Impedance Cardiography. *The Clinical Respiratory Journal*. doi:10.1111/crj.13002
- Mahoney-Davies, G., Davis, C., Glen, C., Clifton, C., & Šalkovskis, P. M. (2017). Examining the Emotional and Psychological Experiences of People With Heart Failure. *British Journal of Cardiac Nursing*. doi:10.12968/bjca.2017.12.4.192
- Mao, D., Wang, Y., & Wu, Q. (2015). A New Approach for Physiological Time Series. *Advances in Adaptive Data Analysis*. doi:10.1142/s1793536915500016
- Meijers, W. C., de Boer, R. A., van Veldhuisen, D. J., Jaarsma, T., Hillege, H. L., Maisel, A. S., . . . Peacock, W. F. (2015). Biomarkers and Low Risk in Heart Failure. Data From <scp>COACH</Scp> and <scp>TRIUMPH</Scp>. *European Journal of Heart Failure*. doi:10.1002/ejhf.407
- Mentz, R. J., Metra, M., Cotter, G., Milo, O., McKendry, C., Chiswell, K., . . . O'Connor, C. M. (2015). Early vs. Late Worsening Heart Failure During Acute Heart Failure Hospitalization: Insights From the PROTECT Trial. *European Journal of Heart Failure*. doi:10.1002/ejhf.308
- Metra, M., Tomasoni, D., Adamo, M., Bayés-Genís, A., Filippatos, G., Abdelhamid, M., . . . Rosano, G. (2023). Worsening of Chronic Heart Failure: Definition, Epidemiology, Management and Prevention. A Clinical Consensus Statement by the Heart Failure Association of the European Society of Cardiology. *European Journal of Heart Failure*. doi:10.1002/ejhf.2874
- Michalski, P., Kosobucka, A., Pietrzykowski, Ł., Kasprzak, M., Grzelakowska, K., Rzepka-Cholasińska, A., & Kubica, J. (2024). Functioning in an Illness and Quality of Life Versus the Prevalence of Depression and Anxiety Disorders in Patients With High Cardiovascular Risk. *Nursing Reports*. doi:10.3390/nursrep14030191
- Moghbeli, F., Langarizadeh, M., & Aliabadi, A. (2017). Application of Ethics for Providing Telemedicine Services and Information Technology. *Medical Archives*. doi:10.5455/medarh.2017.71.351-355
- Morgan, J. M., Kitt, S., Gill, J., McComb, J. M., Ng, G. A., Raftery, J., . . . Cowie, M. (2017). Remote Management of Heart Failure Using Implantable Electronic Devices. *European Heart Journal*. doi:10.1093/eurheartj/ehx227
- Morimoto, A., Kadoya, M., Kakutani-Hatayama, M., Kosaka-Hamamoto, K., Miyoshi, A., Shoji, T., . . . Koyama, H. (2020). Subclinical Decrease in Cardiac Autonomic and Diastolic Function in Patients With Metabolic Disorders: HSCAA Study. *Metabolism Open*. doi:10.1016/j.metop.2020.100025
- Morimoto, Y., Kawano, H., Miyanaga, K., Yano, Y., Fukushima, T., Kozu, R., . . . Maemura, K. (2020). Association of Lower Extremity Function With Nutritional Status and Number of

- Drugs in Patients With Chronic Heart Failure. *Journal of International Medical Research*. doi:10.1177/0300060520964374
- Mortazavi, B. J., Downing, N. S., Bucholz, E. M., Dharmarajan, K., Manhapra, A., Li, S.-X., . . . Krumholz, H. M. (2016). Analysis of Machine Learning Techniques for Heart Failure Readmissions. *Circulation Cardiovascular Quality and Outcomes*. doi:10.1161/circoutcomes.116.003039
- Murphy, M. M. (2018). Telehealth Factors for Predicting Hospital Length of Stay. *Journal of Gerontological Nursing*. doi:10.3928/00989134-20180305-01
- Murtagh, G., Dawkins, I., O'Connell, P. R., Badabhagn, M., Patel, A. S., Tallon, E., . . . McDonald, K. (2012). Screening to Prevent Heart Failure (STOP-HF): Expanding the Focus Beyond Asymptomatic Left Ventricular Systolic Dysfunction. *European Journal of Heart Failure*. doi:10.1093/eurjhf/hfs030
- Muyunda, L., & Mpundu, M. (2024). Mapping the Regulatory Framework for Telemedicine in Zambia: A Content Analysis. *International Journal of Membrane Science and Technology*. doi:10.15379/ijmst.v10i3.3382
- Nishat, M. M., Faisal, F., Ratul, I. J., Al-Monsur, A., Ar-Rafi, A. M., Nasrullah, S. M., . . . H. Khan, M. R. (2022). A Comprehensive Investigation of the Performances of Different Machine Learning Classifiers With SMOTE-ENN Oversampling Technique and Hyperparameter Optimization for Imbalanced Heart Failure Dataset. *Scientific Programming*. doi:10.1155/2022/3649406
- Niu, Q., Liu, W., Wang, F., Tian, L., & Dong, Y. (2022). The Utility of Cognitive Screening in Asian Patients With Heart Failure: A Systematic Review. *Frontiers in Psychiatry*. doi:10.3389/fpsy.2022.930121
- Nobili, M., Raguseo, D., & Setola, R. (2025). Cybersecurity Analysis of a Telemedicine Platform. *Healthcare*. doi:10.3390/healthcare13020184
- Nurhayati, N., Andari, F. N., & Fredrika, L. (2021). Reducing Anxiety Among Heart Failure Patients by Doing the Six-Minute Walk. *International Journal of Nursing Education*. doi:10.37506/ijone.v13i1.13325
- O'Connor, C. M., Whellan, D. J., Wojdyla, D., Leifer, E., Clare, R. M., Ellis, S. J., . . . Lee, K. L. (2012). Factors Related to Morbidity and Mortality in Patients With Chronic Heart Failure With Systolic Dysfunction. *Circulation Heart Failure*. doi:10.1161/circheartfailure.111.963462
- Odeh, V. A. (2024). Wearable Devices for Monitoring and Management of Heart Failure (Preprint). doi:10.2196/preprints.60105
- Okada, M., Tanaka, N., Iwakura, K., Seo, M., Hayashi, T., Yano, M., . . . Sakata, Y. (2023). Abstract 13242: Annual Body Weight Change and Subsequent Prognosis in Heart Failure With Preserved Ejection Fraction: Insights From the PURSUIT-HFpEF Registry. *Circulation*. doi:10.1161/circ.148.suppl_1.3242
- Pagano, M. C., Corallo, F., D'Aleo, P., Duca, A., Bramanti, P., Bramanti, A., & Cappadona, I. (2024). A Set of Possible Markers for Monitoring Heart Failure and Cognitive Impairment Associated: A Review of Literature From the Past 5 Years. *Biomolecules*. doi:10.3390/biom14020185

- Pant, J., Sharma, R. K., Pant, H., Singh, D. R., & Pant, D. (2023). A Machine Learning-Based Framework for Intrusion Detection Systems in Healthcare Systems. doi:10.4018/978-1-6684-6646-9.ch006
- Paramita, W. K., & Pratiwi, Y. M. (2022). Meta-Analysis Effects of Diabetes Mellitus on Mortality in Patients With Chronic Heart Failure. *Journal of Epidemiology and Public Health*. doi:10.26911/jepublichealth.2022.07.01.08
- Patidar, A. B., Kaur, H., & Kumar, R. (2021). Self Care of Heart Failure and Health Related Quality of Life Among Congestive Heart Failure Patients in Punjab, India. *International Journal of Health Sciences and Research*. doi:10.52403/ijhsr.20210409
- Patron, E., Benvenuti, S. M., Lopriore, V., Aratari, J., & Palomba, D. (2017). Somatic-Affective, but Not Cognitive-Depressive Symptoms Are Associated With Reduced Health-Related Quality of Life in Patients With Congestive Heart Failure. *Psychosomatics*. doi:10.1016/j.psych.2017.01.001
- Pellicori, P., Platz, E., Dauw, J., ter Maaten, J. M., Martens, P., Pivetta, E., . . . Girerd, N. (2020). Ultrasound Imaging of Congestion in Heart Failure: Examinations Beyond the Heart. *European Journal of Heart Failure*. doi:10.1002/ehf.2032
- Petrenko, A., & Boloban, O. (2025). Study of the Efficiency of Biomedical Signal Filtering Algorithms in Real Time. doi:10.20944/preprints202503.0033.v1
- Piskorski, J., & Guzik, P. (2011). Asymmetric Properties of Long-Term and Total Heart Rate Variability. *Medical & Biological Engineering & Computing*. doi:10.1007/s11517-011-0834-z
- Pliquett, R. U. (2022). Cardiorenal Syndrome: An Updated Classification Based on Clinical Hallmarks. *Journal of Clinical Medicine*. doi:10.3390/jcm11102896
- Pocock, S. J., Ferreira, J. P., Gregson, J., Anker, S. D., Butler, J., Filippatos, G., . . . Packer, M. (2021). Novel Biomarker-Driven Prognostic Models to Predict Morbidity and Mortality in Chronic Heart Failure: The EMPEROR-Reduced Trial. *European Heart Journal*. doi:10.1093/eurheartj/ehab579
- Qadri, A. M., Alam Hashmi, M. S., Raza, A., Jafar Zaidi, S. A., & Rehman, A. U. (2024). Heart Failure Survival Prediction Using Novel Transfer Learning Based Probabilistic Features. *PeerJ Computer Science*. doi:10.7717/peerj-cs.1894
- Qadri, A. M., Raza, A., Munir, K., & Almutairi, M. (2023). Effective Feature Engineering Technique for Heart Disease Prediction With Machine Learning. *Ieee Access*. doi:10.1109/access.2023.3281484
- Qin, S., Xiang, M., Gao, L., Cheng, X., & Zhang, D. (2023). Uric Acid Is a Biomarker for Heart Failure, but Not Therapeutic Target: Result From a Comprehensive Meta-analysis. *Esc Heart Failure*. doi:10.1002/ehf2.14535
- Ranjbar, A., & Ravn, J. (2023). Data Quality in Healthcare for the Purpose of Artificial Intelligence: A Case Study on ECG Digitalization. doi:10.3233/shti230534
- Rector, T. S., Carson, P. E., Anand, I. S., McMurray, J. J., Zile, M. R., McKelvie, R. S., . . . Massie, B. M. (2012). Assessment of Long-Term Effects of Irbesartan on Heart Failure With Preserved Ejection Fraction as Measured by the Minnesota Living With Heart Failure Questionnaire in the Irbesartan in Heart Failure With Preserved Systolic Function (I-Preserve) Trial. *Circulation Heart Failure*. doi:10.1161/circheartfailure.111.964221

- Research Progress on the Prevention and Treatment of Chronic Heart Failure With Integrated Traditional Chinese and Western Medicine. (2024). *Meds Chinese Medicine*. doi:10.23977/medcm.2024.060302
- Rocha, A. P., Leite, A., & Silva, M. E. (2016). Volatility Leveraging in Heart Rate: Health vs Disease. doi:10.22489/cinc.2016.008-287
- Ruocco, G., Palazzuoli, A., & ter Maaten, J. M. (2019). The Role of the Kidney in Acute and Chronic Heart Failure. *Heart Failure Reviews*. doi:10.1007/s10741-019-09870-6
- Sabouri, M., Bitarafan-Rajabi, A., Hajianfar, G., Mohebi, M., Avval, A. H., Naderi, N., & Shiri, I. (2023). Machine Learning Based Readmission and Mortality Prediction in Heart Failure Patients. *Scientific Reports*. doi:10.1038/s41598-023-45925-3
- Salunkhe, V., Tangudu, A., Mokkapati, C., Goel, P. P., & Aggarwal, A. (2024). Advanced Encryption Techniques in Healthcare IoT: Securing Patient Data in Connected Medical Devices. *MDMP*. doi:10.36676/mdmp.v1.i2.22
- Samchuk, O. O. (2023). Risk Factors for Unfavorable Prognosis and Progression of Chronic Heart Failure in Covid-19 Pneumonia. *Proceedings of the Shevchenko Scientific Society Medical Sciences*. doi:10.25040/ntsh2023.01.12
- Samorodskaya, I. V., Ларина, В. Н., Chernyavskaya, T. K., & Какорина, Е. П. (2022). Comparison of Classifications and Justification of the Need for Transdisciplinary Consensus to Take Into Account the Prevalence and Mortality Associated With Chronic Heart Failure. *Complex Issues of Cardiovascular Diseases*. doi:10.17802/2306-1278-2022-11-1-6-16
- Santini, L., Adamo, F. M., Mahfouz, K., Colaiaco, C., Finamora, I., Lucia, C. D., . . . Ammirati, F. (2024). Remote Management of Heart Failure in Patients With Implantable Devices. *Diagnostics*. doi:10.3390/diagnostics14222554
- Sartipy, U., Dahlström, U., Edner, M., & Lund, L. H. (2013). Predicting Survival in Heart Failure: Validation of the <sc>MAGGIC</Sc> Heart Failure Risk Score in 51 043 Patients From the <sc>Swedish</Sc> Heart Failure Registry. *European Journal of Heart Failure*. doi:10.1111/ehf.32
- Serrano, K. M., de Mendes, G. H., Lizarelli, F. L., & Devós Ganga, G. M. (2020). Assessing the Telemedicine Acceptance for Adults in Brazil. *International Journal of Health Care Quality Assurance*. doi:10.1108/ijhcqa-06-2020-0098
- Shah, R., Chen-Tournoux, A., Picard, M. H., van Kimmenade, R. R., & Januzzi, J. L. (2010). Galectin-3, Cardiac Structure and Function, and Long-term Mortality in Patients With Acutely Decompensated Heart Failure. *European Journal of Heart Failure*. doi:10.1093/eurjhf/hfq091
- Sheikhvatan, M., Ataei, Z., Heydari, A., & Zahergivar, A. (2018). The Value of N-Terminal Pro-B-Type Natriuretic Peptide (NT Pro-Bnp) to Predict Sudden Cardiac Death in Chronic Heart Failure Patients With Normal Renal Function; A Systematic Review and Meta-Analysis. *Journal of Nephro pharmacology*. doi:10.15171/npj.2018.32
- Shin, S., Austin, P. C., Ross, H. J., Abdel-Qadir, H., Freitas, C., Tomlinson, G., . . . Lee, D. S. (2020). Machine Learning vs. Conventional Statistical Models for Predicting Heart Failure Readmission and Mortality. *Esc Heart Failure*. doi:10.1002/ehf2.13073
- Schaarup, J. R., Bjerg, L., Hansen, C. S., Grove, E. L., Andersen, S. T., Vistisen, D., . . . Witte, D. R. (2024). Cardiovascular Autonomic Dysfunction Precedes Cardiovascular Disease and All-

- Cause Mortality: 11-Year Follow-Up of the ADDITION-PRO Study. doi:10.1101/2024.12.18.24319131
- Sinaga, P. t., Purba, S. S., Wiranto, D., Maharja, O. J., & Indra, E. (2023). Exploratory Data Analysis of Clinical Heart Failure Using a Support Vector Machine. *Jurnal Sistem Informasi Dan Ilmu Komputer Prima(jusikom Prima)*. doi:10.34012/jurnalsisteminformasidanilmukomputer.v7i1.4100
- Srinivas, K., & Prashanthi, V. (2024). Comparative Analysis of Heart Failure Prediction Using Machine Learning Models. *International Journal of Informatics and Communication Technology (Ij-Ict)*. doi:10.11591/ijict.v13i2.pp297-305
- Srivatsan, V., George, M., & Shanmugam, E. (2014). Utility of Galectin-3 as a Prognostic Biomarker in Heart Failure: Where Do We Stand? *European Journal of Preventive Cardiology*. doi:10.1177/2047487314552797
- Srividya, A., & Chaudhry, A. P. (2023). Dentists Role in Psychological Screening and Management of Head-and-Neck Cancer Patients Undergoing Radiotherapy – Narrative Review. *Indian Journal of Palliative Care*. doi:10.25259/ijpc_{4}_{7}_{2}_{0}_{2}_{3}
- Sumaqa, Y. A., & Hayajneh, F. (2022). Depression and Anxiety in Patients With Heart Failure: Contributing Factors, Consequences and Coping Mechanisms: A Review of the Literature. *Working With Older People*. doi:10.1108/wwop-12-2021-0061
- Sumaqa, Y. A., Hayajneh, F., Alhamory, S., Rayan, A., Alnaeem, M. M., Al Tarawneh, T. R., . . . Ayasreh, I. (2023). Consequences of Psychological Aspects: From Jordanian Heart Failure Patients' Beliefs. *Sage Open Nursing*. doi:10.1177/23779608231189128
- Sun, Z., Dong, W., Shi, H., Ma, H., Cheng, L., & Huang, Z. (2022). Comparing Machine Learning Models and Statistical Models for Predicting Heart Failure Events: A Systematic Review and Meta-Analysis. *Frontiers in Cardiovascular Medicine*. doi:10.3389/fcvm.2022.812276
- Sun, Z., Wang, Z., Yun, Z., Sun, X., Lin, J., Zhang, X., . . . Yao, K. (2024). Machine Learning-based Model for Worsening Heart Failure Risk in Chinese Chronic Heart Failure Patients. *Esc Heart Failure*. doi:10.1002/ehf2.15066
- Tabaeeian, R. A., Hajrahimi, B., & Khoshfetrat, A. (2022). A Systematic Review of Telemedicine Systems Use Barriers: Primary Health Care Providers' Perspective. *Journal of Science and Technology Policy Management*. doi:10.1108/jstpm-07-2021-0106
- Tak, A., Dia, S., Dia, M., & Wehner, T. C. (2021). Indian COVID-19 Dynamics: Prediction Using Autoregressive Integrated Moving Average Modelling. *Scripta Medica*. doi:10.5937/scriptamed52-29893
- Tak, A., Parihar, P. M., Mathur, S., Das, B., & Sawal, D. (2022). Survival Prediction in Heart Failure Using Machine Learning Algorithms. doi:10.21203/rs.3.rs-1960150/v1
- Takimura, H., Hada, T., Kawano, M., Yabe, T., Takimura, Y., Nishio, S., . . . Muramatsu, T. (2018). A Novel Validated Method for Predicting the Risk of Re-Hospitalization for Worsening Heart Failure and the Effectiveness of the Diuretic Upgrading Therapy With Tolvaptan. *Plos One*. doi:10.1371/journal.pone.0207481
- Taniguchi, C., Seto, N., & Shimizu, Y. (2021). Outpatient Nursing Support for Self-Monitoring in Patients With Chronic Heart Failure. *Plos One*. doi:10.1371/journal.pone.0254019

- Taylor, J., Coates, E., Wessels, B., Mountain, G., & Hawley, M. (2015). Implementing Solutions to Improve and Expand Telehealth Adoption: Participatory Action Research in Four Community Healthcare Settings. *BMC Health Services Research*. doi:10.1186/s12913-015-1195-3
- Thammana, R. V., & Goodlin, S. J. (2022). Telecommunication for Advance Care Planning in Heart Failure. *Cardiac Failure Review*. doi:10.15420/cfr.2021.23
- Tian, J., Yan, J., Han, G., Du, Y., Hu, X., He, Z., . . . Zhang, Y. (2022). Machine Learning Prognosis Model Based on Patient-Reported Outcomes for Chronic Heart Failure Patients After Discharge. doi:10.21203/rs.3.rs-2125084/v1
- Toh, C. T., Jackson, B., Gascard, D., Manning, A., & Tuck, E. J. (2010). Barriers to Medication Adherence in Chronic Heart Failure Patients During Home Visits. *Journal of Pharmacy Practice and Research*. doi:10.1002/j.2055-2335.2010.tb00721.x
- Tohyama, T., Ide, T., Ikeda, M., Kaku, H., Enzan, N., Matsushima, S., . . . Tsutsui, H. (2021). Machine Learning-based Model for Predicting 1 year Mortality of Hospitalized Patients With Heart Failure. *Esc Heart Failure*. doi:10.1002/ehf2.13556
- Tripoliti, E. E., Papadopoulos, T., Karanasiou, G. S., Naka, K. K., & Fotiadis, D. I. (2017). Heart Failure: Diagnosis, Severity Estimation and Prediction of Adverse Events Through Machine Learning Techniques. *Computational and Structural Biotechnology Journal*. doi:10.1016/j.csbj.2016.11.001
- Truong, M. C., Tran, K. H., & Chau, N. H. (2023). Differences in Clinical Characteristics and Mortality of De Novo Acute Heart Failure and Acutely Decompensated Chronic Heart Failure: A Prospective Cohort Study. *Tap Chí Tim Mạch Học Việt Nam*. doi:10.58354/jvc.107e.2023.718
- Türkarslan, M., Emektar, E., & Çevik, Y. (2023). Utility of Inferior Vena Cava and Internal Jugular Vein Ultrasonography for Evaluation of Treatment Efficiency in Patients With Acute Heart Failure. *International Target Medicine Journal*. doi:10.29228/targetmedj.68207
- Umeh, C., Torbela, A., Saigal, S., Kaur, H., Kazourra, S., Gupta, R., & Shah, S. (2022). Telemonitoring in Heart Failure Patients: Systematic Review and Meta-Analysis of Randomized Controlled Trials. *World Journal of Cardiology*. doi:10.4330/wjc.v14.i12.640
- Utami, A. (2025). Evaluating Telemedicine for Chronic Disease Management in Low- And Middle-Income Countries During Corona Virus Disease 2019 (COVID-19). *Hospitals*. doi:10.3390/hospitals2020009
- van Velde, A. R., Gullestad, L., Ueland, T., Aukrust, P., Guo, Y., Adourian, A., . . . de Boer, R. A. (2013). Prognostic Value of Changes in Galectin-3 Levels Over Time in Patients With Heart Failure. *Circulation Heart Failure*. doi:10.1161/circheartfailure.112.000129
- van Veldhuisen, D. J., Braunschweig, F., Conraads, V. M., Ford, I., Cowie, M., Jondeau, G., . . . Borggrefe, M. (2011). Intrathoracic Impedance Monitoring, Audible Patient Alerts, and Outcome in Patients With Heart Failure. *Circulation*. doi:10.1161/circulationaha.111.043042
- Vazquez-Montes, M., A. Debray, T. P., Taylor, K., Speich, B., Jones, N., Collins, G. S., . . . Trivella, M. (2020). UMBRELLA Protocol: Systematic Reviews of Multivariable Biomarker Prognostic Models Developed to Predict Clinical Outcomes in Patients With Heart Failure. *Diagnostic and Prognostic Research*. doi:10.1186/s41512-020-00081-4
- Vegter, E. L., Schmitter, D., Hagemeijer, Y., Ovchinnikova, E. S., der Harst, P. v., Teerlink, J. R., . . . Khan, M. A. (2016). Use of Biomarkers to Establish Potential Role and Function of

- Circulating microRNAs in Acute Heart Failure. *International Journal of Cardiology*. doi:10.1016/j.ijcard.2016.09.010
- Verhestraeten, C., Weijers, G., Debleu, D., Ciarka, A., Goethals, M., Droogmans, S., & Maris, M. B. (2020). Diagnosis, Treatment, and Follow-Up of Heart Failure Patients by General Practitioners: A Delphi Consensus Statement. *Plos One*. doi:10.1371/journal.pone.0244485
- Volz, A., Schmid, J.-P., Zwahlen, M., Kohls, S., Saner, H., & Barth, J. (2010). Predictors of Readmission and Health Related Quality of Life in Patients With Chronic Heart Failure: A Comparison of Different Psychosocial Aspects. *Journal of Behavioral Medicine*. doi:10.1007/s10865-010-9282-8
- Voors, A. A., Angermann, C. E., Teerlink, J. R., Collins, S. P., Kosiborod, M., Biegus, J., . . . Ponikowski, P. (2022). The SGLT2 Inhibitor Empagliflozin in Patients Hospitalized for Acute Heart Failure: A Multinational Randomized Trial. *Nature Medicine*. doi:10.1038/s41591-021-01659-1
- Voors, A. A., Ouwerkerk, W., Zannad, F., van Veldhuisen, D. J., Samani, N. J., Ponikowski, P., . . . Zwinderman, A. H. (2017). Development and Validation of Multivariable Models to Predict Mortality and Hospitalization in Patients With Heart Failure. *European Journal of Heart Failure*. doi:10.1002/ehf.785
- Wan, Y., Zhang, S., & Zhao, Y. (2024). Withdraw. *Applied and Computational Engineering*. doi:10.54254/2755-2721/97/2024melb0068
- Wang, H., Littleton, T., Wilson, S. J., Ros, F. M., Robinson, R. D., & Delaney, K. (2012). The Role of B-Type Natriuretic Peptide in the Evaluation of Congestive Heart Failure Patients in Emergency Department. *Open Journal of Clinical Diagnostics*. doi:10.4236/ojcd.2012.22003
- Wang, J. (2021). Heart Failure Prediction With Machine Learning: A Comparative Study. *Journal of Physics Conference Series*. doi:10.1088/1742-6596/2031/1/012068
- Wang, L., Jiang, Z., Song, L., Yu, X., Yuan, S., & Zhang, B. (2024). A Groundwater Level Spatiotemporal Prediction Model Based on Graph Convolutional Networks With a Long Short-Term Memory. *Journal of Hydroinformatics*. doi:10.2166/hydro.2024.226
- Wang, Q., Li, B., Chen, K., Yu, F., Su, H., Hu, K., . . . Su, G. (2021). Machine Learning-based Risk Prediction of Malignant Arrhythmia in Hospitalized Patients With Heart Failure. *Esc Heart Failure*. doi:10.1002/ehf2.13627
- Wang, X., & Zhang, C. (2022). Chinese Expert Consensus on the Diagnosis and Treatment of Chronic Heart Failure in Elderly Patients (2021). *Aging Medicine*. doi:10.1002/agm2.12215
- Wang, Y., Yang, Q., Liu, Y.-C., Zheng, G., Fan, F., Tian, H., & Zhang, X. (2023). Psychosomatic Mechanisms of Heart Failure Symptoms on Quality of Life in Patients With Chronic Heart Failure: A Multi-centre Cross-sectional Study. *Journal of Clinical Nursing*. doi:10.1111/jocn.16955
- Wang, Y.-P., & Gorenstein, C. (2013). Assessment of Depression in Medical Patients: A Systematic Review of the Utility of the Beck Depression Inventory-II. *Clinics*. doi:10.6061/clinics/2013(09)15
- Winger, T., Ozdemir, C., Narasimhan, S. L., & Srivastava, J. (2025). Time-Adaptive Machine Learning Models for Predicting the Severity of Heart Failure With Reduced Ejection Fraction. *Diagnostics*. doi:10.3390/diagnostics15060715
- Wittkop, J. (2016). Incident Response Planning. doi:10.1007/978-1-4842-2053-5_5

- Xu, C., Li, H., Yang, J., Peng, Y., Cai, H., Zhou, J., . . . Chen, L. (2023). Interpretable Prediction of 3-Year All-Cause Mortality in Patients With Chronic Heart Failure Based on Machine Learning. *BMC Medical Informatics and Decision Making*. doi:10.1186/s12911-023-02371-5
- Xu, Q., Cai, X., Yu, R., Zheng, Y., Chen, G., Sun, H., . . . Sun, J. (2024). Machine Learning–Based Risk Factor Analysis and Prediction Model Construction for the Occurrence of Chronic Heart Failure: Health Ecologic Study (Preprint). doi:10.2196/preprints.64972
- Xue, Y., Jiang, W., Ma, Q., Wang, X., Jia, P., Li, Q., . . . Ma, A. (2020). U-Shaped Association Between Plasma Sphingosine-1-Phosphate Levels and Mortality in Patients With Chronic Systolic Heart Failure: A Prospective Cohort Study. *Lipids in Health and Disease*. doi:10.1186/s12944-020-01262-2
- Yan, W., Liu, C., Li, R., Mu, Y., Jia, Q., & He, K. (2016). Usefulness of the Neutrophil-to-Lymphocyte Ratio in Predicting Adverse Events in Elderly Patients With Chronic Heart Failure. *International Heart Journal*. doi:10.1536/ihj.16-049
- Yang, H., Tian, J., Meng, B., Wang, K., Zheng, C., Liu, Y., . . . Zhang, Y. (2021). Application of Extreme Learning Machine in the Survival Analysis of Chronic Heart Failure Patients With High Percentage of Censored Survival Time. *Frontiers in Cardiovascular Medicine*. doi:10.3389/fcvm.2021.726516
- Yang, Z., Jia, H.-h., & Wang, A. (2023). Predictors of Home-Based Cardiac Rehabilitation Exercise Adherence Among Patients With Chronic Heart Failure: A Theory-Driven Cross-Sectional Study. *BMC Nursing*. doi:10.1186/s12912-023-01566-5
- Yao, Z., Wang, P., Fu, Q., Song, Q., Ai, L., Li, H., . . . Zhang, P. (2024). Efficacy and Safety of Sacubitril/Valsartan in Hemodialysis Patients With Chronic Heart Failure: A Retrospective Study at a Single Center. *Medical Science Monitor*. doi:10.12659/msm.943529
- Yin, T., Shi, S., Zhu, X., Cheang, I., Lu, X., Gao, R., . . . Li, X. (2022). A Survival Prediction for Acute Heart Failure Patients via Web-Based Dynamic Nomogram With Internal Validation: A Prospective Cohort Study. *Journal of Inflammation Research*. doi:10.2147/jir.s348139
- Yu, Q., Zhao, L., Chen, Y., & Zhao, Q. (2023). Value of N-Terminal Pro B-Type Natriuretic Peptide, High-Sensitivity C-Reactive Protein, and Homocysteine Levels in Predicting Cardiovascular Events in Chronic Heart Failure Patients After Discharge. *Proceedings of Anticancer Research*. doi:10.26689/par.v7i2.4788
- Yu, X., Zou, T., Zou, L., Jin, J., Xiao, F., & Yang, J. (2017). Plasma Long Noncoding RNA Urothelial Carcinoma Associated 1 Predicts Poor Prognosis in Chronic Heart Failure Patients. *Medical Science Monitor*. doi:10.12659/msm.904113
- Zanke, P., & Sontakke, D. (2024). Safeguarding Patient Confidentiality in Telemedicine: A Systematic Review of Privacy and Security Risks, and Best Practices for Data Protection. *International Journal of Current Science Research and Review*. doi:10.47191/ijcsrr/v7-i6-42
- Zhou, Z. (2023). Application Analysis of Machine Learning and Data Visualization in Heart Failure Prediction. *Applied and Computational Engineering*. doi:10.54254/2755-2721/20/20231095
- Chanyukov, O. O., Pesotskaya, L. A., Sapozhnychenko, L. V., & Dziuba, S. (2023). Comorbidities and Sex Differences in Chronic Heart Failure of Ischemic Etiology. doi:10.21203/rs.3.rs-2770634/v1