

ХИБРИДНИ ПОДХОДИ ЗА ИЗГРАЖДАНЕ НА ДИГИТАЛЕН БЛИЗНАК НА ВАРИАБИЛНОСТТА НА СЪРДЕЧНАТА ЧЕСТОТА

доц. д-р инж. Галя Николова Георгиева-Цанева

АВТОРЕФЕРАТ

на дисертационен труд
за придобиване на научна степен
“Доктор на науките”

Научна област: Технически науки

Професионално направление:

5.2 Електротехника, електроника и автоматика

Научна специалност:

02.21.02 Елементи и устройства

на автоматиката и изчислителната техника

**София
2026**

Дисертационният труд е в обем от 246 стр, фигури, таблици, 235 цитирани източника и съдържа увод, пет глави, заключение, приноси.

Дисертационният труд е базиран на 25 научни публикации, за които са известни над 70 независими цитирания.

В автореферата е запазена номерацията на отделните глави и раздели. Номерацията на фигурите, таблиците и формулите не се различава от тази в дисертационният труд.

Дисертационният труд е обсъден и насрочен за защита от еднократно разширено научно звено на семинар на секция „Медицинска роботика“ при Институт по роботика, БАН, проведено на 25.03.2026 и заповед на Директора на Институт по роботика, БАН №37/18.03.2026г.

Защитата на дисертацията ще се състои на.....2026 г. от часа в зала на Институт по роботика, ул. „Акад. Г. Бончев“, бл. 2.

Материалите за защитата са на разположение на интересуващите се в канцеларията на ИР-БАН, ул. „Акад. Г. Бончев“, бл. 2.

Научно жури:

Вътрешни членове:

Външни членове:

Резервни членове:

Автор: доц. д-р Галя Николова Георгиева-Цанева

Заглавие: Хибридни подходи за изграждане на дигитален близък на вариационността на сърдечната честота

Тираж: 10бр.

Издателство:

ОБЩА ХАРАКТЕРИСТИКА НА ДИСЕРТАЦИОННИЯ ТРУД

Актуалност на проблема

Актуалността на проблема произтича от нарастващите изисквания към съвременните здравни, спортни и IoT системи за непрекъснат и прогностичен мониторинг на физиологични състояния в реално време. Развитието на преносими сензори, телемедицина и дигитални близнаци изисква интегрирани подходи, които осигуряват точност, устойчивост към шум и възможност за интерпретируем анализ и прогнозиране.

HRV сигналите се характеризират с нелинейност, нестационарност и чувствителност към артефакти, което налага използването на усъвършенствани методи за обработка, нелинеен и фрактален анализ, както и адекватни математически модели за описване на автономната регулация.

Допълнително предизвикателство е защитата на биомедицинските данни, изискваща сигурни архитектури и криптографски механизми без компромис с диагностичната стойност.

В този контекст дисертационният труд предлага подход за изграждане на дигитален близнак на HRV, обединяващ анализ, моделиране и сигурна обработка на данни, с приложение в интелигентния мониторинг и персонализираната медицина.

Цел и задачи на дисертационния труд

Основната цел на дисертационния труд е разработването и изследването на интегрирана хибридна методологична рамка за обработка, анализ, моделиране и защита на кардиологични сигнали, базирана на съчетаване на класически математически и съвременни AI-базирани подходи, подпомагаща изграждането на дигитален близнак на вариабилността на сърдечната честота в IoT среди.

За изпълнение на поставената цел се дефинират следните основни **задачи**:

1. Разработване и изследване на методи за ефективно намаляване на шумовете в кардиологични сигнали чрез комбиниране на класически и AI-базирани подходи.
2. Разработване на устойчиви хибридни методи и алгоритми за детекция на характерни върхове в ECG и PPG сигнали, приложими в реални и шумови условия.
3. Създаване и анализ на нови модели за симулация на ECG, PPG и HRV, базирани на гаусови модели, хаотични системи и невронни мрежи, с повишена физиологична достоверност, контролируемост и възпроизводимост на реални кардиологични процеси.
4. Изследване и разработване на методи за защита на кардиологични данни чрез интеграция на криптографски и водно-знакови подходи, осигуряващи поверителност, цялостност и автентичност на данните без компромис с диагностичната им стойност.
5. Разработване на методологична рамка за разграничаване на физиологичните състояния покой, умора и стрес при спортисти чрез комплексен анализ на HRV показатели, с фокус върху приложения в спортната кардиомедицина.
6. Изследване и развитие на подходи за изграждане на дигитален близнак на вариабилността на сърдечната честота, интегриращ реални измервания, симулационни модели и интелигентен анализ, с приложение в IoT и носими системи за непрекъснат мониторинг.
7. Създаване на нови интегрални индекси за оценка и прогнозиране на функционалното състояние на организма, базирани на HRV показатели, предназначени за използване в рамките на HRV-базиран дигитален близнак.

Апробация на резултатите от дисертационния труд

Дисертационният труд е апробиран в основните си части на следните научни форуми:

International Conference on Computer Science (ICOCS-25), 20th – 21st September 2025, Bucharest, Romania

International Conference Automatics and Informatics (ICAI), 2025, Varna, Bulgaria;
CompSysTech '24: International Conference on Computer Systems and Technologies 2024, Ruse, Bulgaria;
23rd International Conference on Computer Systems and Technologies, CompSysTech, 2022, Ruse, Bulgaria;
CompSysTech '21: 22st International Conference on Computer Systems and Technologies 2021, Ruse, Bulgaria;
16th International Technology, Education and Development Conference in INTED2022, Valencia, Spain, March 7–9, 2022.
Seventh International Scientific Conference "Innovative STEM Education", 05 – 10 October 2025, Veliko Tarnovo, Bulgaria;
International Conference "ROBOTICS & MEHATRONICS" 5 – 6 November, 2025, Sofia, Bulgaria.
International Conference "ROBOTICS & MEHATRONICS" 29 – 30 October, 2024, Sofia, Bulgaria.

Научни публикации

Основните резултати от дисертационния труд са публикувани в **25 научни публикации**, от **14 които в издания с IF или SJR** (6 с Q1, 2 с Q2, 4 с Q3 и 2 с Q4); 10 са представени на международни и национални научни конференции и 1 глава от монография. Осем от публикациите са самостоятелни, а останалите са в авторски колектив. Списък на публикациите е даден в края на автореферата.

Забелязани цитирания

До момента са забелязани общо **70 цитирания** на публикациите по настоящия дисертационен труд, 51 от които в SCOPUS и 19 в други издания.

Получени отличия

Грамота за най-добър доклад на Международна конференция „COMPSYSTECH“, 2022 г.

КРАТКО СЪДЪРЖАНИЕ НА ДИСЕРТАЦИОННИЯ ТРУД

ГЛАВА ПЪРВА: ОБЗОР НА МЕТОДИТЕ ЗА ОБРАБОТКА НА КАРДИОЛОГИЧНИ ДАННИ

В глава първа е описана е актуалността на проблема, анализирани са научните публикации в изследваната област. Поставена целта на дисертационния труд и са формулирани задачите за нейното изпълнение.

Аналитичният преглед и обзорът на научната литература в проблемната област показва следното:

1. В областта на обработката, анализа и моделирането на кардиологични сигнали се наблюдава напредък в развитието на методи за филтрация, детекция, симулация и оценка на физиологични състояния. Изследванията обхващат широк спектър от подходи – от класически линейни, нелинейни и адаптивни методи, през уейвлет и модално-разложителни техники, до съвременни дълбоки невронни архитектури. Въпреки това, липсва универсален методологичен подход, който едновременно да осигурява висока устойчивост на шум, морфологична достоверност на сигнала и надеждна приложимост в реални условия, характерни за IoT-базирани системи.
2. Артефактите от движение, оптичните смущения, базовият дрейф и нестационарните компоненти оказват съществено влияние върху точността на детекцията на характерните върхове, което води до натрупване на грешки в последващия HRV анализ и компрометира надеждността на извлечените физиологични показатели.
3. Класическите алгоритми за детекция на върхове в PPG, базирани на производни, адаптивни прагове и евристични правила, запазват своята приложимост при сигнали с добро качество, но имат ограничена устойчивост при силно шумови и динамични условия. Дълбоките невронни модели постигат значително по-висока точност и адаптивност, но се характеризират с повишена изчислителна сложност, което ограничава директното им внедряване в edge и IoT среди.
4. Анализът на съществуващите симулационни модели за ECG, PPG и HRV подчертава тяхната съществена роля като инструмент за разработване, тестване и валидиране на алгоритми.

Класическите параметрични модели, фракталните процеси и генеративните AI подходи адресират отделни аспекти на кардиосигналите, но не предоставят цялостна рамка, която едновременно да интегрира морфологията на сигнала, вариабилността на ритъма, шумовите компоненти и динамичната физиологична адаптация.

5. Обзорът в областта на защитата на кардиологични данни показва, че традиционните криптографски методи, използвани самостоятелно, не са достатъчни за гарантиране на целостта, автентичността и устойчивостта срещу манипулации на физиологичните сигнали. Комбинирането на криптографски техники с методи за цифров воден знак се очертава като ефективна стратегия за повишаване на сигурността на чувствителните кардиоданни в спортни и телемедицински приложения, особено в контекста на IoT и IoMT системи.
6. Разграничаването на физиологичните състояния покой, умора и стрес, особено при спортисти и физически активни индивиди, изисква висока надеждност на входните кардиоданни и устойчивост на HRV анализа към шум и грешки в детекцията. Многообразието от HRV показатели и тяхната чувствителност към качеството на сигнала правят анализа обемен и ограничават възможностите за автономна оценка, интерпретация и прогнозиране на функционалното състояние.
7. Съществува научен дефицит, свързан с липсата на интегрирана, хибридна методологична рамка за обработка, анализ, симулация и защита на кардиологични сигнали. Това мотивира разработването на нови мултимодални подходи и интегрални индекси, които да подпомагат изграждането на надеждни дигитални близнаци на вариабилността на сърдечната честота в условията на реални IoT и носими системи.

ГЛАВА ВТОРА: РАЗРАБОТВАНЕ НА МЕТОДИ ЗА НАМАЛЯВАНЕ НА ШУМА И ДЕТЕКЦИЯ В БИОМЕДИЦИНСКИ ДАННИ

Многофакторен уейвлет-базиран метод за адаптивно намаляване на шум в PPG сигнали

Представен е нов многофакторен уейвлет-базиран метод за адаптивно намаляване на шум в PPG сигнали [D2-1], извършващ дискретна уейвлет трансформация (DWT) с различни базиси, нива на разлагане и прагови правила, който рекурсивно търси оптималната комбинация за всеки конкретен изследван входен сигнал. Прагът за обработка на детайлните коефициенти се определя чрез модифицирана формула, предложена от автора, която повишава ефективността при отделяне на шумовите компоненти. След обратна WT методът осигурява висок SNR, минимални RMSE и PRD стойности, което го прави подходящ за реално приложение и за дигитални близнаци на HRV.

Многофакторният характер на предложената уейвлет-базирана процедура може да бъде формализиран като дискретна оптимизационна задача за избор на параметри:

$$\theta^* = \arg \min_{\theta \in \Omega} J(\theta), \quad (2.3)$$

където:

$$\theta = \{\psi, L, T, f\};$$

ψ – уейвлет базис (Db2, Db4, Db6, Db8, Db12);

L – ниво на декомпозиция ($L \in \{1, \dots, Lmax\}$);

T – прагово правило (Wave Shrink, VisuShrink, SURE, Minimax);

f – вид прагово филтриране: твърдо/меко/адаптивно;

Ω е множеството от допустими комбинации от тези параметри, дефинирано от предварително избраните базиси и нива на разлагане; валидните прагови правила и функции;

ограниченията за реализация;

J е скаларен функционал, чрез който се минимизират RMSE и PRD и едновременно се максимизира SNR.

Оптимизационна процедура

Описаната последователност се изпълнява за всички допустими комбинации $\theta \in \Omega$. В резултат се получава множество от оценки $J(\theta)$, което позволява извеждане на една или няколко оптимални

конфигурации Θ ; анализ на зависимостите между уейвлет базиса, нивото на декомпозиция и праговото правило; оценка на робустността на оптималните решения спрямо различни шумови нива.


Възможността за наличие на повече от една оптимална конфигурация е концептуално важна, тъй като отразява физиологичната вариабилност и различните типове шум в реални PPG записи.

Адаптивна прагова стратегия

Праговата обработка на детайлните уейвлет коефициенти се реализира чрез модифицирана формула, базирана на класическия подход на Donoho [184], разширена с мащабно-нормализиращ фактор:

$$thr_j = \sigma \sqrt{\frac{2 \log(n)}{n}} \cdot 1/\mu_j, \quad (2.4)$$

където $\mu_j = \max(|d_j|)$ е мащабно-зависим нормализиращ параметър, въведен от автора и обоснован първоначално при ECG сигнали [185]. Настоящото изследване показва, че тази формулировка е ефективна и при PPG сигнали (фигура 2.9), тъй като адаптира прага към локалната енергия на сигнала и предотвратява прекомерно потискане на физиологично значими детайли.




Фигура 2.9 Разлика между PPG сигнал с шум и PPG чист сигнал след процедура за намаляване на шума (модифицирана формула за прагова обработка на коефициентите, Db8, 4 нива) [D2-1]

Влияние на уейвлет базиса и нивото на декомпозиция

Анализът на зависимостите между входното и изходното SNR при различни уейвлет базиси (фигура 2.10) показва, че базисите с голям брой коефициенти (Db8–Db12) осигуряват по-добра адаптация към морфологията на PPG сигналите. Това може да се обясни с по-доброто съвпадение между формата на уейвлет функцията и характерните особености на пулсовата вълна.

Зависимостта между RMSE и SNR (фигура 2.11), както и между PRD и SNR (фигура 2.12), потвърждава, че оптималните резултати се постигат при уейвлет базис Db8 и Db12 и средни нива на декомпозиция. По-високите нива на разлагане не водят до допълнително подобрене и в някои случаи въвеждат излишна загуба на локални детайли, което подчертава необходимостта от адаптивен избор на параметрите.



Фигура 2.10 Зависимост на SNR_{out} от SNR_{in}. **Фигура 2.11** Зависимост на RMSE от SNR. **Фигура 2.12** Зависимост между PRD и SNR.

Алгоритъм за намаляване на шума в PPG в реално време за вграждане в преносими устройства

Алгоритмичната структура на предложения реалновремени метод (фигура 2.13) е изградена като каскада от прости допълващи се филтрационни етапи, всеки от които адресира различен клас шумови смущения в PPG сигналите:

1. Усредняващ филтър (Moving Average Filter) — потискане на краткотрайни шумове. Реализирано е линейно филтриране чрез подвижен прозорец, при което всяка стойност се заменя със средната стойност от съседните проби. Филтърът елиминира високочестотен шум, електронни смущения внесени в сигнала от сензора, кратки импулсни пикове, които не са физиологични.
2. Премахване на DC компонента (DC Removal/High-pass component). PPG сигналът съдържа стабилна DC компонента, породена от оптичните свойства на тъканта, сензорния offset, околна светлина. DC компонентата не носи информация за пулсовата динамика.
3. Медианен филтър (Median Filter) — Нелинеен филтър, който заменя всяка точка със средната по големина стойност в прозореца. Филтърът елиминира артефакти от движения (Motion Artifacts); остри скокове, причинени от движение на ръката, промяна на силата на натиск, резки пикове от околната светлина, като запазва формата на вълната.
4. Нискочестотен филтър (Low-Pass Filter, напр. 10 Hz) — премахване на остатъчни високочестотни шумове. Стандартен low-pass дигитален филтър, напр. IIR Butterworth 2-ри или 4-ти ред; FIR филтър.

Уейвлет базиран метод за детекция на максималните отклонения (P-върхове) в PPG сигнали **Алгоритмична концепция и описание на метода за детекция**

Предложеният уейвлет-базиран метод за детекция на P-върхове [D2-3] комбинира спектрална декомпозиция, прагова селекция и морфологично уточняване на кандидат-събитията:

1. Дискретна уейвлет трансформация. Входният PPG сигнал се разлага на апроксимиращи и детайлни уейвлет коефициенти, използвайки различни базиси на Добеши (Db2, Db4, Db6, Db8, Db10, Db12 и Db20). Детайлните уейвлет коефициенти подчертават бързите амплитудни отклонения в сигнала, които корелират с появата на систоличните върхове.
2. Прагова обработка на детайлните коефициенти. Прилага се прагова обработка за потискане на шумовите компоненти. Редуцира нискоенергийни шумови колебания и формира първоначален набор от кандидат-върхове.
3. Анализ на кандидат-върхове и финална детекция. Полученият набор се подлага на допълнителен анализ чрез процедури за филтриране на фалшиви събития – проверка на локалната амплитуда, оценка на морфологичната консистентност и налагане на минимални физиологично допустими интервали между последователни върхове.
4. Обратна уейвлет трансформация (Inverse WT).

Експерименталната валидация на предложени уейвлет-базиран метод е извършена върху шест PPG записа, като резултатите от детекцията са обобщени в таблица 2.2. Получените стойности на чувствителността (95.0%–98.2%), положителната предсказуемост (93.0%–96.9%) и честотата на грешки в детекцията (1.43%–1.62%) показват висока и стабилна ефективност на метода.

Таблица 2.2 Детекция на върхове с предложени метод [D2-3]

№	Общ брой удари	Se (%)	PP (%)	DER (%)
1	1849	97.14	93.04	1.62
2	1723	97.26	96.84	1.43
3	2011	98.23	94.07	1.58
4	1945	96.05	93.22	1.61
5	1602	95.44	94.36	1.59
6	1883	95.01	96.91	1.48

Хибриден DWT метод за локализация на P(S)-пикове и екстракция на времеви интервали

Локализацията на P върхове в PPG сигналите и екстракцията на времевите интервали между тях представляват фундаментален етап при изграждането на HRV последователности. В контекста на реалновремени системи и дигитален HRV близък задачата трябва да бъде решена при наличие на шум, артефакти от движение и строги ограничения върху изчислителните ресурси. Проблемът може да бъде формализиран като задача за надеждна локализация на времеви събития $\{t_k\}_{k=1}^N$,


съответстващи на физиологични пикове, и последващо извличане на интервална серия $PP_k = t_{k+1} - t_k$, която коректно отразява динамиката на сърдечната регулация в условия на нестационарност.

Предложеният хибриден метод [D2-4] е разработен с цел директно вграждане в преносими и IoT-базирани устройства, като комбинира класически филтрационни техники, диференциален анализ и дискретна уейвлет трансформация:


1. Сегментиране на входна последователност на блокове от 4096 отчета с припокриване от 128 отчета при подаване на данните за обработка (така се елиминира възможността за пропускане на пик).
2. Прилагане на процедура за намаляване на шума: премахване на DC компонента; пълзяща средна (за намаляване на случайната стойност на шума); прилагане на медианен филтър (чрез осредняване на стойностите на сигнала, което премахва големи отклонения резултат от външен шум) и нискочестотен филтър с гранична честота 4 Hz за премахване на високочестотните компоненти.
3. Определяне на първата производна на входната серия и определяне на локални максимуми и минимуми чрез метод на пресичане с нула; съставяне на набор от възможни кандидати за пикове.
4. Извършване на DWT на входните данни и получаване на детайлни и апроксимиращи коефициенти (уейвлет бази си: Daubechies, Symlet, Coiflet с различни коефициенти и биортогонални вълни).
5. Прагова обработка на детайлните коефициенти чрез положителен/отрицателен праг [6]. Прилагането на тези прагове ограничава възможността непотиснатите стойности на пиковия шум да бъдат идентифицирани като пикове на изследвания сигнал. Съставяне на набора от кандидат-пикове според извършеното DWT и определяне на прага.
6. Анализ на компилираните набори от кандидат-пикове, съпоставяне и окончателно определяне на P(S) пикове. Запазване на зададените стойности в буферната памет.
7. Реконструкция на сигнала чрез обратна уейвлет трансформация.
8. Формиране на последователността на променливост на пулсовата честота чрез определяне на времевите стойности на интервалите между определените P пикове.
9. Записване на получената HRV интервална серия в буфер или за последващ математически анализ.
10. Проверка за нови входни данни и преминаване към стъпка 1, ако има такива.

Експериментални резултати и сравнителен анализ

Фигура 2.15 показва суровия входен PPG сигнал, след неговата регистрация и аналогово-цифрово преобразуване. Фигура 2.16 илюстрира обработения PPG сигнал, с премахнати шумови компоненти и открити P(S) пикове, маркирани със зелени кръгове.



Фигура 2.15 Суров PPG сигнал с шум [D2-4]



Фигура 2.16 PPG след отстраняване на шумовите компоненти и детекция на върховете [D2-4]

Изследвано е влиянието върху точността на определяне на P(S) пиковите на следните уейвлет базиси: Db2, Db4, Db8, Db12, Db20, Симплет и Койфлет (коэффициенти 4,8,12,20) и обратен биортогонален базис. Количествените резултати от анализа на 12 реални PPG записа (общо 24 548 върха) са обобщени в таблица 2.3. При използване на уейвлет базис Db4 са постигнати средни стойности Se = 99.84%, PPV = 99.86% и DER = 0.29%.

Таблица 2.3 Резултати за детекция на върхове в PPG сигнали (с базис Db4 [D2-4])

№	Total	TP	FN	FP	Se (%)	PP (%)	DER(%)
1	2175	2169	6	4	99.72	99.82	0.45
2	2252	2249	3	2	99.87	99.91	0.22
3	2704	2701	3	1	99.89	99.96	0.15
4	2076	2072	4	3	99.81	99.86	0.33
5	2066	2064	2	4	99.9	99.81	0.29
6	1534	1532	2	3	99.87	99.80	0.32
7	2162	2159	3	2	99.86	99.91	0.23
8	1686	1684	2	2	99.88	99.88	0.24
9	1870	1865	5	4	99.73	99.79	0.48
10	2501	2497	4	5	99.84	99.8	0.36
11	1720	1717	3	2	99.83	99.88	0.29
12	1802	1800	2	2	99.89	99.89	0.22
Сумарно	24548				99.84	99.86	0.29

Допълнителен анализ на влиянието на нивото на разлагане (таблица 2.4) показва, че четвъртото ниво при Db4 базис осигурява оптимален компромис между чувствителност и устойчивост спрямо шум. Експериментално е установено, че уейвлет базис Db4, 4-тото ниво на разлагане е най-ефективен при откриване на върхове в реална 30-минутна серия от PPG сигнали, записани в положение на покой. Оптималните характеристики за оценка са получени при прилагане на Db4 базис, 4-то ниво на разлагане: Se=99.84%; PPV=99.86%; DER=0.29%.

Таблица 2.4 Сравнение според нивата на разлагане в оптималния базис Db4 [D2-4]

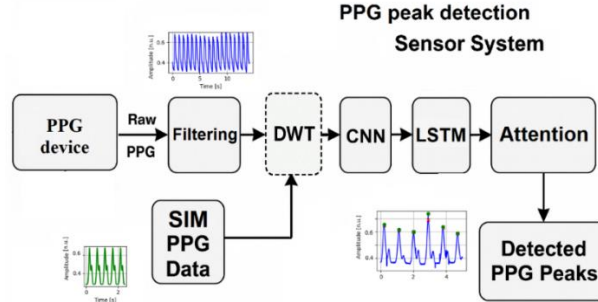
Ниво на декомпозиция	Se (%)	PPV (%)	DER(%)
2	99.82	99.83	0.33
4	99.84	99.86	0.29
6	99.82	99.84	0.31
8	99.79	99.72	0.44
12	99.75	99.78	0.48
20	99.7	99.71	0.57

Подобрена детекция на върховете на PPG, с използване на хибридна архитектура DWT-CNN-LSTM с времево внимание

Предложеният подход [D2-5] представлява еволюционна надстройка на класическите методи от Глава 2 (фигура 2.17), като интегрира:

- мултирезолюционен уейвлет анализ (DWT) за многомащабно декомпозиране на сигнала;
- дълбоки конволюционни невронни мрежи (CNN) за извличане на морфологични характеристики;
- рекурентни мрежи с дълга краткосрочна памет (LSTM) за улавяне на времеви зависимости;
- механизъм за времево внимание (Temporal Attention).

Така се преминава от детекция, базирана на фиксирани правила, към обучаем, контекстно-зависима детекция, което е ключово за концепцията за дигитален HRV близнак.



Фигура 2.17 Архитектура на предложения DWT-CNN-LSTM-Attention метод [D2-5]

Описание на предложения метод [D2-5]:

1. Предварителна обработка на суровите данни: Бътъруърт филтри, включително високочестотен филтър с гранична честота 0.5 Hz за елиминиране на дрейфа на базовата линия, лентов филтър с честотен диапазон 0.5–10 Hz за изолиране на основния честотен спектър на PPG. Тези филтри редуцират артефакти от мускулна активност и отстраняват електрически смущения от електрозахранването (50/60 Hz). Филтрацията има за цел да предотврати некоректни анотации на пиковите.

2. Ръчна корекция на автоматично откритите анотации на P-пикове. За тренировъчния набор се извършва ръчна проверка и корекция на автоматично откритите P-пикове.

3. Добавяне на шум (Noise Augmentation). С цел повишаване на устойчивостта на модела към реални условия, към входните данни се добавят шумови компоненти като baseline wander, мускулни артефакти и електрически шум от захранващата мрежа (50/60 Hz).

4. Прилагане на DWT за разлагане и извличане на характеристики. Използван е Db4 уейвлет базис. Детайлните коефициенти се мащабират до дължината на оригиналния PPG сегмент чрез линейна интерполация, за да се осигури времева съвместимост между каналите. При моделите, които използват DWT, тези коефициенти формират втори входен канал и предоставят допълнителна времево-честотна информация за морфологията на P-пика. В моделите без DWT се използва само суровият PPG сигнал.

5. Обработка на сигнала чрез CNN

5.1. Разделяне на сигнала на прозорци. Входният сигнал (PPG или PPG + DWT детайлни коефициенти) се разделя на времеви прозорци с продължителност 2 секунди и 50% припокриване.

5.2. Приложение на 1D конволюционни слоеве (Conv1D). Conv1D слоевете извличат локални характеристики от DWT коефициентите.

5.3. MaxPooling слой. Приложен е слой за максимално пулсиране (Pool Size = 2), който намалява размерността и запазва най-значимите характеристики. Конволюционният слой използва ReLU активация ($x = \max(0, x)$). Изходният сигнал е:

$$y_1(t) = \text{ReLU}\left(\sum_{i=0}^{K-1} x_{dwt}(t+i) \cdot w_1(i) + b_1\right), \quad (2.8)$$

$x_{dwt}(t)$ – входен сигнал към CNN слоя, който идва от детайлните DWT коефициенти; $w_1(i)$ – конволюционен слой филтър (с размер K); b_1 – отклонение за слоя.

След CNN е добавен Dropout слой (0.25) за предотвратяване на overfitting.

5.4. Значение на времевите прозорци

Прозорците с припокриване се държат като времеви „patches“ – подобно на обработката в съвременни модели тип Transformer.

6. Интеграция на LSTM слоеве. LSTM обработва времевите последователности от характеристики, като разпознава повтарящи се патерни в морфологията на PPG сигнала.

Формули за LSTM компонентите:

- Forget Gate: $f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f)$, (2.9)

W_f – Входна тегловна матрица; x_t – Входен вектор за текущия момент t ; U_f – тегловна матрица за предишното скрито състояние; h_{t-1} – Скритото състояние от предишния момент; b_f – Вектор на

отклонение (добавен за компенсиране на стойностите); σ - Сигмоидна функция, която ограничава изхода между 0 и 1.

- Input Gate: $i_t = \sigma(W_i x_t + U_f h_{t-1} + b_i)$, (2.10)

Candidate актуализация: $\tilde{c}_t = \sigma(W_c x_t + U_f h_{t-1} + b_c)$, (2.11)

- Memory актуализация: $c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t$, (2.12)

- Output Gate: $o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o)$, (2.13)

- Final output: $h_t = o_t \odot \tanh(c_t)$, (2.14)

При бинарна класификация се използва сигмоидна активация:

$$y = \sigma(W_{\text{dense}} h + b_{\text{dense}}), \quad \sigma(x) = \frac{1}{1+e^{-x}} \quad (2.15)$$

Приложената функция на загуби е Binary Cross-Entropy (BCE):

$$L = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)], \quad (2.16)$$

където: N – брой параметри; y_i - истинска (анотирана) стойност; \hat{y}_i – прогнозна стойност, получена от сигмоидната функция.

Добавя се втори Dropout слой (0.3) за редуциране на свръхнапасването.

7. Времени Attention слой

- Скаларни оценки: $e_t = v^T \tanh(W_h h_t + b_h)$ (2.17)

- Softmax нормализация: $\alpha_t = \frac{\exp(e_t)}{\sum_{i=1}^T \exp(e_i)}$ (2.18)

- Контекст вектор: $c = \sum_{i=1}^T \alpha_t \cdot h_t$ (2.19)

Attention насочва модела към временните области с най-висока вероятност за наличие на P-пикове.

8. Изходен слой и пост-обработка

8.1. Dense слой със сигмоидна активация. Определя вероятността дадена проба да е пик.

8.2. Прагова детекция. Определя се оптимален адаптивен праг за бинарна класификация.

8.3. Филтрация на резултите: премахват се фалшиви пикове, които не съвпадат с локален максимум.

9. Обучение на модела. Данните се разделят в съотношение: 70% обучение/15% валидация/15% тест.

Използват се Adam оптимизатор и двоична кръстосана ентропия (BCE) загуба.

Мрежата е обучена с помощта на метода на загубата с BCE, който е подходящ за задачи за двоична класификация, каквато е откриването на пикове. BCE се дефинира като:

$$L_{BCE} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)], \quad (2.20)$$

където N е броят на обучителните извадки, y_i етикетът на истинската стойност, и \hat{y}_i е прогнозираната вероятност от сигмоидния изход.

За да се подобри времевата локализация на пиковете, допълнително се предлага **нов член PeakDistanceLoss**, за минимизиране на разстоянието между истинските и прогнозираните пикове:

$$L_{DIST} = \frac{1}{N} \sum_{i=1}^N \min_j |p_i - \hat{p}_j|, \quad (2.21)$$

p_i са позициите на истинските пикове, а \hat{p}_j са прогнозираните позиции на пиковете.

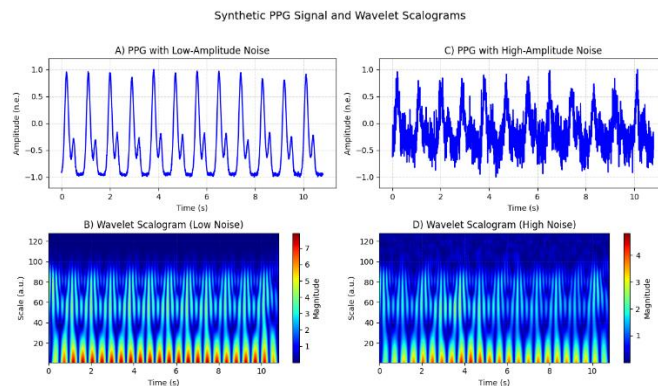
Общата загуба математически комбинира двата члена:

$$L_{TOTAL} = \alpha_1 \cdot L_{BCE} + \alpha_2 \cdot L_{DIST}, \quad (2.22)$$

с тегловни коефициенти α_1 и α_2 .


Експериментални резултати и интерпретация

Проведена е оценка на 30 варианта на предложения модел, като са изследвани различни комбинации от входни типове, нива на декомпозиция и активиращи функции. На фигура 2.18 [D2-5] са представени примери на PPG и съответните уейвлет-скалограми при ниски и високи амплитуди на шум. Тези визуализации илюстрират как при повишено ниво на шум енергията на сигнала се разпределя в по-широк честотен диапазон, което затруднява класическите методи, базирани на фиксирани прагове или локални амплитудни критерии.



Фигура 2.18 PPG и уейвлет Scalogram при ниски и високи амплитуди на шума [D2-6].

Архитектурата с темпорално внимание (фигура 2.19Б) коректно потиска фалшивия пик и локализира истинските Р-пикове. Механизмът за внимание функционира като адаптивен селектор на физиологично релевантни времеви сегменти, който интегрира информация от по-широк времеви контекст. По този начин моделът е способен да дискриминира между истински сърдечни събития и шумово-индуцирани отклонения.



Фигура 2.19 Сравнение на метод, базиран на DWT (А), и метод с повишено внимание (Б) при наличие на амплитудна вариабилност и артефакти от движението [D2-5].

Количественото потвърждение на тази концептуална разлика е представено в таблица 2.7, която показва поведението на двата най-добре представящи се модела – Type29 и Type30 – при различни стойности на съотношението сигнал/шум (20 dB, 10 dB и 5 dB).

Моделът Type30, който комбинира DWT, CNN, LSTM и механизъм за внимание, демонстрира най-висока устойчивост, като запазва F1-оценка 0.895 при 10 dB и 0.861 дори при 5 dB. Това поведение показва, че допълнителната дълбочина и адаптивност на архитектурата не водят до свръхнапасване, а напротив – подпомагат по-добро фокусиране върху съществените морфологични и времеви характеристики на сигнала при високи нива на шум.

Таблица 2.7. Устойчивост на шум на най-добре представящите се модели (Тип 29 и Тип 30) [D2-5]

Model	SNR (dB)	Precision	Recall	F1-Score
Type29	20	0.923	0.952	0.914
Type29	10	0.893	0.936	0.891
Type29	5	0.860	0.914	0.853
Type30	20	0.930	0.955	0.920
Type30	10	0.902	0.943	0.895
Type30	5	0.867	0.920	0.861

ГЛАВА ТРЕТА: СИМУЛАЦИОННО МОДЕЛИРАНЕ НА КАРДИОЛОГИЧНИ СИГНАЛИ

Тази глава е посветена на математическото моделиране на HRV, PPG и ECG, като описва, надгражда и анализира модели за компютърна симулация на краткосрочни и дългосрочни записи,

използвайки ГРФ, WT и невронни мрежи. Получените симулирани времеви серии се сравняват по редица показатели с реалните времеви кардио серии. Основната цел е създаване на гъвкава симулационна среда, подходяща за изграждане на цифрови HRV близнаци, които могат да бъдат използвани в телемедицината, IoT системите и спортната физиология.

Изследван е Gaussian-базиран модел за генериране на HRV, базиран на сума от ограничен брой Гаусови функции, като фокусът е поставен върху влиянието на броя на компонентите (три и четири) върху спектралното разпределение и статистическите свойства на генерираните RR интервали. Чрез моделиране на основните честотни компоненти на HRV (ULF, VLF, LF и HF) като сума от Гаусови разпределения се постига генериране на реалистични краткосрочни и дългосрочни HRV серии, съответстващи на физиологичните характеристики на индивиди с нормален синусов ритъм (NSR) и с отклонения от него (non-NSR) [D3-1, D3-2].

В следващ етап математическият модел се разширява чрез въвеждане на фракталност в симулираните HRV серии, базирана на модифициран алгоритъм на Hosking, при който експонентата на Хърст се задава като променлива във времето. Чрез въвеждане на локално моментно съвпадение по ключови показатели (SDNN и RMSSD), моделът осигурява сегментно пресъздаване на състояния като покой, натоварване и възстановяване, като запазва плавните преходи [D3-3].

Проучен е научният проблем за симулиране на морфологията и динамиката на PPG сигнали, чрез комбиниране на параметрични Гаусови модели за описание на формата на пулсовата вълна със статистическо времево моделиране чрез ARIMA, предназначено да възпроизведе дългосрочната нестационарност и циркадната динамика на реалните записи [D3-4].

Математическият модел за симулиране на PPG е надграден чрез въвеждане на дълбоки генеративни модели, способни да възпроизведат сложни нелинейни зависимости и високоизмерни особености на реалните сигнали. Представеният модел Deep-SimPPG комбинира параметрично Гаусово моделиране и ARIMA-базирана времева динамика с генеративно-състезателни мрежи (GAN) [D3-5].

Разработен е нелинеен симулационен модел на ECG, базиран на Gaussian Mesa Functions (GMF) за морфологично описание на P, QRS и T вълните и хаотичен атрактор на Рьослер за моделиране на HRV [D3-6]. Този хибриден GMF-Rössler модел позволява едновременно контролируемо формиране на морфологията на сърдечния цикъл и физиологично достоверно възпроизвеждане на нестационарната и фрактална динамика на сърдечния ритъм, включително преходи между покой, стрес и възстановяване.

Гаусово-базирано моделиране на варибилността на сърдечната честота

Динамиката на HRV може да бъде апроксимирана чрез стационарен стохастичен процес с нормално (гаусово) разпределение, при който спектралните характеристики на сигнала са предварително дефинирани. Това позволява директен контрол върху честотното съдържание на симулираните RR интервали и съответствието им с физиологично значимите компоненти на автономната регулация – нискочестотната (LF) и високочестотната (HF) област. Гаусово-базираните модели са особено подходящи като начална точка в изграждането на цифрови близнаци, тъй като осигуряват добре формализирана връзка между параметрите на модела и класическите HRV метрики; висока възпроизводимост на резултатите; ниска изчислителна сложност, подходяща за мащабни симулации и обучение на алгоритми.

В предложения модел [D3-1] маргиналното HRV разпределение се апроксимира чрез сума от гаусови функции [200]:

$$p(x_t | \mu_k, \sigma_k) = N(x_t | \mu_k, \sigma_k) = \frac{1}{\sqrt{2\pi} \sigma_k} \exp\left(-\frac{(x_t - \mu_k)^2}{2\sigma_k^2}\right), \quad (3.4)$$

където: x_t – последователността от данни; μ_k - централната честота на k-тия спектрален компонент; σ_k – неговата ширина (дисперсия); f – честотната променлива; k – индексът на съответния гаусов компонент; N – обозначава гаусовото (нормално) разпределение.

Чрез използване на три или четири гаусови функции в уравнение (3.8) се реализира параметрично вграждане на основните физиологични честотни диапазони – ULF, VLF, LF и HF. Всеки компонент отразява доминиращ регулаторен механизъм.

За осигуряване на гъвкав контрол върху относителния принос на отделните спектрални компоненти, в модела се въвежда тегловен коефициент π_k за всеки гаусов компонент. Оптимизацията на теглата се извършва чрез максимизиране на логаритмичната вероятност [202]:

$$\sum_{t=1}^T \log \sum_{k=1}^K \pi_k N(x_t | \mu_k, \sigma_k) \quad (3.5)$$

Реализацията може да бъде формализирана чрез следните основни стъпки [D3-1]:

1. Създаване на еднокомпонентен гаусов модел ($k=1$), който описва доминиращата честотна компонента на HRV и задава началната статистическа структура на симулираната серия.

2. Итеративно разширяване на спектралното представяне. На всяка следваща итерация се добавя нов гаусов компонент: $(x_t | \mu_{k+1}, \sigma_{k+1})$, асоцииран с физиологично значим честотен диапазон. Тегловният коефициент π_{k+1} контролира относителния принос на новия компонент към общото разпределение, като целта е оптимално приближаване на реалната спектрална структура на HRV. Логаритмичната правдоподобност на смесения модел се максимизира съгласно:

$$\sum_{t=1}^T \log [\pi_{k+1} \cdot N(x_t | \mu_{k+1}, \sigma_{k+1}) + (1 - \pi_{k+1}) \sum_{k=1}^K \pi_k \cdot N(x_t | \mu_k, \sigma_k)] \quad (3.6)$$

което осигурява адаптивно балансиране между отделните спектрални компоненти.

3. Формиране на смесеното вероятностно разпределение. След всяка итерация се конструира ново маргинално разпределение на HRV като претеглена сума от всички налични гаусови компоненти:

$$(x_t | \mu_k, \sigma_k) = \pi_{k+1} \cdot N(x_t | \mu_{k+1}, \sigma_{k+1}) + (1 - \pi_{k+1}) \sum_{k=1}^K \pi_k \cdot N(x_t | \mu_k, \sigma_k), \quad (3.7)$$

което позволява мултимодално описание на RR интервалите и отразява комбинираното влияние на различни регулаторни механизми.

4. Критерии за завършване на симулационния слой. Итеративното разширяване на модела се прекратява при изпълнение на предварително зададен критерий, като достигане на фиксиран брой гаусови компоненти (три или четири); минимална промяна в спектралните HRV показатели.

5. Генериране на времева HRV серия. След определяне на крайното спектрално разпределение се генерира комплексна честотна последователност $\{z_1, z_2, \dots, z_K\}$, при която амплитудите се задават от получената спектрална плътност, а фазите се избират случайно в интервала $(0, 2\pi)$. Чрез обратна трансформация във времевата област се получава HRV времева серия $\{t_1, t_2, t_3, \dots, t_K\}$.

В това изследване [D3-1]) е използвана и анализирана сума от три и четири функции на разпределение на Гаус, чрез които се смесват елементарните спектрални компоненти (с въвеждане на тегловни коефициенти) в следните честотни диапазони: ULF, VLF, LF и HF.

Симулация на патологични състояния

Чрез задаване на $\gamma = LF/HF = 0.5$ са генерирани 16 дългосрочни HRV серии, характеризиращи се с понижена вариабилност. Анализът във времевата (таблица 3.4) и честотната област (таблица 3.5) показва стойности извън референтните граници за здрави индивиди [67], което съответства на състояния на стрес или сърдечно-съдови заболявания.

Таблица 3.4 Времеви параметри на HRV на генерираната серия [D3-2]

Параметър	Стойност (ср. ст.±ст.откл.)	Референтни стойности (ср. ст.±ст.откл.)	Мерна единица
HRmin	34.3±8.42	>50	bpm
HRmax	119.27±14.81	<120	bpm
MeanHR	98.26±18.93	>50, <120	bpm
MeanRR	609.51±184.05	-	ms
SDNN	68.08±10.07	141±39 (102-180)	ms
SDANN	52.32±9.13	127± 35 (92-162)	ms
RMSSD	14.26±4.29	27±12 (15-39)	ms

SDDS	89.03±18.44	-	ms
SDNN Index	37.56±22.97	-	ms
NN50	32.4±1.6	-	-
pNN50	10.9±2.59	-	ms
HRV Triangular Index	141.62±26.03	37±15 (22-52)	-
TINN	552.08±132.11	-	ms

Таблица 3.5 Честотни параметри на HRV на генерираната серия [D3-2]

Параметър	Стойност (ср. ст.±ст.откл.)	Референтни стойности (ср. ст.±ст.откл.)	Мерна единица
TP	2327±403	3466±1018	ms ²
ULF	662±28.53	-	ms ²
VLF	832±24.08	-	ms ²
LF	311±79	1170±416	ms ²
HF	622±169	975±203	ms ²
LFnu	33±8.08	54±4	nu
HFnu	66±5.04	29±3	nu
LF/HF	0.5±0.00002	1.5-2.0	-

Метод за генериране на HRV с променлива експонента на Хърст и моментно съответствие на HRV метриците

Плавно преминаване между сегментите (cross-fade механизъм). Директното конкатениране на сегменти с различни стойности на H би довело до изкуствени скокове и артефакти в HRV сигнала. За да се гарантира непрекъснатост и физиологична правдоподобност, между всеки два съседни сегмента се въвежда зона на смесване с дължина C , разположена около границата t_s . В тази зона сигналите от два съседни сегмента се комбинират чрез линейно претегляне в края на сегмент s и началото на $s+1$:

$$\tilde{X}_t = \alpha_t X_t^{(s)} + (1 - \alpha_t) X_t^{(s+1)}, \alpha_t = \frac{t_s - t + 1}{C}, t \in [t_s - C + 1, t_s]. \quad (3.11-3.13)$$

Нормализация на моментите в зоната на преход. Преди извършване на смесването се прилага моментна нормализация на сегментите за уеднаквяване на първите два момента и избягване на изкуствени промени в средната стойност и дисперсията: $X^{(\cdot)} \leftarrow \mu^* + \frac{\sigma^*}{\hat{\sigma}^{(\cdot)}} (X^{(\cdot)} - \hat{\mu}^{(\cdot)})$, (3.14)

където $(\hat{\mu}, \hat{\sigma})$ са емпирични моменти в прозореца, а (μ^*, σ^*) – целевите моменти, определящи желаното локално ниво на HRV.

Формулировка на мащабиращия механизъм. Нека R_t е RR последователност в плъзгащ прозорец с дължина W , с желана средна стойност μ_{RR} . Коригираната серия се получава чрез линейно мащабиране около локалната средна стойност:

$$R_t = \bar{R} + s(R_i - \bar{R}), \quad i \in [t - W + 1, t], \quad (3.15 \text{ и } 3.16)$$

където \bar{R} – средна стойност в текущия прозорец. Мащабният коефициент s се дефинира като комбинация на два независими множителя, чрез които се променят SDNN и RMSSD:

$$s_{SD} = \frac{SDNN^{target}}{SDNN}, s_{RM} = \frac{RMSSD^{target}}{RMSSD}, \quad (3.17)$$


$$s = \alpha \cdot s_{SD} + (1 - \alpha) s_{RM}, \alpha \in [0, 1]. \quad (3.18)$$

Оценките на моментните стойности на метриците се изчисляват по стандартните дефиниции:


$$\widehat{SDNN} = \sqrt{\frac{1}{W-1} \sum_{i=2}^W (R_i - \bar{R})^2}, \quad \widehat{RMSSD} = \sqrt{\frac{1}{W-1} \sum_{i=2}^W (R_i - R_{i-1})^2}. \quad (3.19, 3.20)$$

Разширена демонстрация с множество сегменти и променлива експонента на Хърст

Фигури 3.17–3.19 представят разширен експеримент с девет последователни сегмента, всеки с различна стойност на експонентата на Хърст ($H \in [0.6, 0.83]$). Резултатите показват, че промените в H водят до систематични изменения в SDNN и RMSSD; по-високите стойности на H са асоциирани с по-устойчива, дългосрочно корелирана динамика; по-ниските стойности на H водят до по-хаотични и краткосрочно доминирани вариации.



Фигура 3.17 Синтетична RR-последователност, сегментен Hosking-модел (9 сегмента).




Фигура 3.18 Плъзгащ се SDNN прозорец. Фигура 3.19 Плъзгащ се RMSSD прозорец.

Анализ на динамичната структура чрез Recurrence Plot

Допълнителна валидация на динамичните различия между режимите е извършена чрез Recurrence Plot анализ (фигура 3.20). Получените диаграми показват различима фазова организация:

- при покой (фигура 3.20 сегмент 1) матрицата е по-плътна, с ясно изразени диагонални структури, което показва висока детерминираност и стабилност;
- при натоварване (сегмент 2) рекурентността намалява, диагоналите се скъсяват, а структурата става по-разредена, отразявайки по-ниска корелация и по-висока нестабилност;
- при възстановяване (сегмент 3) се наблюдава постепенно възвръщане на структурираността, но без пълно достигане на нивата от покой.

Тези различия в RP (при фиксиран ϵ) съгласувано отразяват сегментните промени на μ_{RR} и H : по-голяма детерминираност и рекурентност в покой, редукция при натоварване и плавно възстановяване на корелационните структури.



A)

Б)

В)

Фигура 3.20 Recurrence Plot: А) Сегмент1; Б) Сегмент 2; В) Сегмент В).

Хибриден гаусов алгоритъм за симулиране на фотоплетизмографски сигнали с отчитане на циркадни вариации

Математически модел на морфологията на PPG сигнала

В представения модел [D3-4] морфологията на единичната PPG вълна се описва чрез суперпозиция от две ГРФ [209], което представлява модифицирано и разширено формулиране на подхода, предложен в [207], с цел по-добро описание на реалните физиологични вариации и последващо вграждане на дългосрочна динамика. Математически моделът се задава с израза:

$$ppg(t) = a_1 \exp\left(-\frac{(f-\mu_1)^2}{2\sigma_1^2}\right) + a_2 \exp\left(-\frac{(f-\mu_2)^2}{2\sigma_2^2}\right), \quad (3.21)$$

Чрез модифициране на амплитудния параметър a_2 , става възможно да се синтезират PPG вълнови форми за различни възрастови групи, тъй като по-ниските стойности на a_2 съответстват на намаление на отразената диастолична вълна на артериалното налягане), типично за повишена артериална твърдост при по-възрастни хора.

За реализирането на представения модел е създаден алгоритъм [D3-4]:

1. Инициализиране на входните параметри $(a_1, a_2, \mu_1, \mu_2, \sigma_1, \sigma_2, b_0, b_1), N$;
2. Синтезиране на комплексна числова серия $\{c_1, c_2, \dots, c_N\}$. Амплитудите на сериите се изчисляват с формулата $|c_i| = \sqrt{S(f_k)}$. Комплексните серии имат фази, разпределени произволно в интервала $(0, 2\pi)$.
3. Реализация на математическия модел, базиран на две ГРФ (формула 3.21);
4. Реализиране на променливостта на дължината на времевите серии чрез добавяне/изваждане към базовата дължина на величина със случайно разпределение.
5. Добавяне на линеен локален тренд (формула 3.22) и базов дрейф.
6. Въвеждане на шум в симулираните серии: $\delta(t) = m \sin(2\pi f_n t)$, m – амплитуда на шума; f_n – честота на шумовата компонента (напр. $m=0.1$ и $f_n = 60\text{Hz}$ за високочестотен шум); стойностите се генерират със случайно разпределение в интервал $m \in [0.01; 0.5]$ и $f \in [0.1; 100]$.
7. При синтезиране на дългосрочни PPG се добавя прогностичен елемент чрез ARIMA(2,2,2).

Сравнителният анализ между реални и симулирани PPG серии (таблица 3.7) показва, че основните времеви HRV параметри – MeanPP, SDNN, SDANN, RMSSD, pNN50, SDNN Index, HRVTi и TINN – попадат в сходни диапазони.

Таблица 3.7 Получени резултати за времева област (2 часа) [D3-4]

Параметри	HRV реална N=48 mean± sd	HRV симулирана N=48 mean± sd	Нормални стойности mean± sd
MeanPP (ms)	889.22±128.06	885.25±90.17	-
SDNN (ms)	132.55±64.91	130.22±25.28	141±39 (102-180)
SDANN (ms)	128.51±21.47	124.14±18.33	127± 35 (92-162)
RMSSD (ms)	16.42±6.42	14.52±5.35	27±12 (15-39)
pNN50 (%)	28.72±6.95	26.39±7.99	-
SDNN Index (ms)	68.07±11.93	64.36±10.22	-
HRVTi (-)	31.17±3.1	27.42±2.42	37±15 (22-52)
TINN (ms)	508.42±212.61	490.05±145.34	-

Честотен анализ и циркадна динамика

Резултатите от честотния анализ на двучасови и 24-часови симулирани серии (таблицы 3.8 и 3.9) показват, че спектралната мощност в LF и HF диапазоните е съпоставима с тази на реалните PPG записи. Това потвърждава, че ARIMA-базираният слой успешно въвежда бавни модуляции в сигнала, които се проявяват като реалистично разпределение на спектралната енергия.

При дългосрочните записи моделът възпроизвежда ясно изразени ULF и VLF компоненти, което е ключово за анализ на циркадни ефекти и автономен баланс. Получените стойности на LF/HF

коэффициента при симулираните серии съответстват на нормалните референтни граници, което показва, че моделът позволява контрол върху съотношението между ниско- и високочестотните компоненти на вариабилността.

Таблица 3.8 Получени резултати за честотната област (2 часа) [D3-4]

Параметри	HRV реална [ms ²] N=48 mean± sd	HRV симулирана [ms ²] N=48 mean± sd	Нормални стойности mean± sd
TP	2401±302	2240±120	3466±1018
LF (0.04-0.15 Hz)	1528±241	1420±160	1170±416
HF (0.15-0.4 Hz)	873±183	820±130	975±203
LFnu	64±6.24	63±4.12	54±4
HFnu	36±4.06	37±3.22	29±3
LF/HF	1.75±0.02	1.73±0.01	1.5-2.0

Таблица 3.9 Получени резултати за честотната област [D3-4]

Параметри	HRV реална [ms ²] N=48 mean± sd	HRV симулирана [ms ²] N=48 mean± sd	Нормални стойности mean± sd
ULF (0-0.003 Hz)	12305±530	10230±350	-
VLF (0.003-0.04 Hz)	4504±282	3960±180	-
LF (0.04-0.15 Hz)	1533±204	1477±110	1170±416
HF (0.15-0.4 Hz)	875±131	853±90	975±203
LFnu	64±9.45	63±5.5	54±4
HFnu	36±7.28	37±3.6	29±3
LF/HF	1.75±0.002	1.73	1.5-2.0

Deer-SimPPG: Хибридна GAN-базирана рамка за реалистичен синтез на фотоплетизмографски сигнали

Параметричен генератор на базова PPG форма

В основата на Deer-SimPPG се намира аналитичен модул, който генерира синтетична PPG форма на вълната, използвайки сума от две Гаусови функции, представляващи систоличните и диастоличните пикове:

$$PPG(t) = A_1 \exp\left(-\frac{(t-\mu_1)^2}{2\sigma_1^2}\right) + A_2 \exp\left(-\frac{(t-\mu_2)^2}{2\sigma_2^2}\right) + \beta_0 + \beta_1 t, \quad (3.23)$$

където A_1 , A_2 са амплитудите на систоличния и диастоличния пик, μ_1 , μ_2 определят позициите времевите им позиции, σ_1 , σ_2 задават ширините на вълновата форма, а параметрите на линейния тренд β_0 , β_1 моделират базовия дрейф. Тази параметрична формулировка позволява лесен контрол върху морфологията и деформацията на вълновата форма, зависима от възрастта.

ARIMA(p,d,q) моделиране се прилага за вграждане на дългосрочна вариабилност и циркадна динамика, симулирайки 24-часови записи с реалистични спектрални характеристики.

GAN-базиран модул за морфологично и шумово дообогатяване


За да се преодолеят ограниченията на традиционно създадените вълнови форми и да се вградят нелинейни характеристики във вълновите форми и естествени шумови модели, в модела се интегрира GAN-базиран модул. Генераторът $G(z|\theta)$ приема като вход базовата Гаусова вълнова форма, конкатенирана с шумов вектор $z \sim \mathcal{N}(0, I)$, и извежда рафиниран PPG сегмент:

$$PPG_{GAN} = G(z|\theta). \quad (3.24)$$

Дискриминаторът $D(x)$ се обучава да различава реални PPG сигнали от генерирани. Целевата функция комбинира състезателни загуби L_{GAN} , заедно със загуби от реконструкция на формата на вълната, дефинирани като:
$$\min_{\phi} (L_{GAN} + \lambda L_1). \quad (3.25)$$


Този GAN модул се учи да трансформира реалистично базовия сигнал, като добавя физиологични артефакти, променливост на формата на импулса и шумови характеристики, ръководейки се от реални PPG записи и състезателно обучение.

На фигура 3.28 са показани симулирани PPG сигнали с различна степен на интервална вариабилност – ниска, умерена и висока. Тези примери демонстрират как промените в HRV влияят върху времевата структура и морфологията на сигнала и позволяват симулиране на широк спектър от физиологични състояния.



Фигура 3.28 Симулирани PPG сигнали с шум и дрейф и интервална вариабилност [D3-5]

CWT спектрограмите на реалния и симулирания сигнал (фигура 3.32) показват сходни времево-честотни разпределения на енергията. Количествената оценка чрез времеви, честотни и нелинейни HRV показатели (таблицы 3.12 и 3.13) показва, че за по-голямата част от метриците не се установяват статистически значими разлики между реалните и симулираните сигнали ($p > 0.05$). Наблюдаваните разлики при MeanRR, HRVti и LF/HF са в рамките на очакваните физиологични вариации и не нарушават общата правдоподобност на симулацията.



Фигура 3.32 CWT спектрограми: А) симулирана PPG; Б) реална PPG [D3-5].

Таблица 3.12 HRV времева и честотна област [D3-5]

Параметър	Реален Mean ± SD	Симулиран Mean ± SD	Нормални ст-ти Mean ± SD	t-test p-value
MeanRR (ms)	896.30 ± 129.23	857.70 ± 87.36	-	0.045
SDNN (ms)	133.44 ± 66.64	126.31 ± 24.52	141 ± 39 (102–180)	0.158 NS*
SDANN (ms)	134.93 ± 22.54	120.40 ± 17.79	127 ± 35 (92–162)	0.079 NS ^a
RMSSD (ms)	16.94 ± 6.62	14.07 ± 5.19	27 ± 12 (15–39)	NS
pNN50 (%)	29.55 ± 7.18	25.58 ± 7.74	-	NS
SDNN Index (ms)	68.62 ± 11.28	62.45 ± 9.91	-	NS ^a
HRVTi	31.67 ± 3.22	26.59 ± 2.35	37 ± 15 (22–52)	0.012
TINN (ms)	519.12 ± 210.96	475.29 ± 140.99	-	NS
LFnu	64±11	62±8	54±4	NS
HFnu	35±9	38±7	29±3	ONS
LF/HF	1.82±0.4	1.63±0.1	1.5-2.0	0.023

*Not Significant (няма статистическа значимост)

Таблица 3.13 Нелинейни и фрактални характеристики [D3-5]

Параметър	Реален (Mean ± SD)	Симулиран (Mean ± SD)	Нормални ст-ти (Mean ± SD)
DFA α_1	0.95 ± 0.31	0.89 ± 0.28	NS
DFA α_2	0.80 ± 0.34	0.74 ± 0.3	NS
Hurst	0.74 ± 0.28	0.81 ± 0.43	NS
SampEn	1.56 ± 0.68	1.39 ± 0.52	NS
ApEn	1.24± 0.61	0.88± 0.38	NS
Shannon Entropy	5.22± 2.14	4.07± 1.98	NS

Ентропийният анализ (таблица 3.14) показва прогресивно увеличаване на SampEn, ApEn и Shannon entropy при преминаване от чисто Гаусова симулация към пълния модел, включващ шум, ARIMA и GAN компоненти.

Таблица 3.14 Ентропийни характеристики [D3-5]

Параметър	Реален (Mean ± SD)	Симулиран (Mean ± SD) Gaussian	Симулиран (Mean ± SD) Gaussian, шум и ARIMA	Симулиран (Mean ± SD) Gaussian, шум, ARIMA и GAN
SampEn	1.56 ± 0.68	0.93 ± 0.38	1.18 ± 0.46	1.39 ± 0.52
ApEn	1.24± 0.61	0.67 ± 0.22	0.74±0.43	0.88± 0.38
Shannon Entropy	5.22± 2.14	2.81 ± 0.96	3.34±1.68	4.07± 1.98

Хибриден модел GMF–Rössler за симулация на ECG сигнали

В представения хибриден модел GMF–Rössler [D3-6] морфологията на ECG сигнала и динамиката на сърдечния ритъм се моделират като два концептуално различни, но съгласувани слоя. Този подход позволява независимо управление на формата на отделния сърдечен цикъл и на времевата вариабилност между последователните удари.

Представянето на този пълен нов хибриден динамичен модел [D3-6], който комбинира хаотичната подсистема на Ръослер, дискретната динамика на RR-интервалите и ECG морфологията, базирана на GMF, е следното:

$$\left\{ \begin{array}{l} \frac{dx}{dt} = -y - z, \\ \frac{dy}{dt} = x + ay, \\ \frac{dz}{dt} = b + z(x - c), \\ RR_k = \overline{RR} \exp(\alpha u(\tilde{t}_k)) + \varepsilon_k, \varepsilon_k \sim N(0, \sigma_{sto}^2) \\ t_{k+1} = t_k + RR_k, t_0 = 0, \\ y(t) = \sum_k \sum_{i \in \{P, Q, R, S, T\}} G_{mesa, i}(t - t_k - \mu_i; A_i, \sigma_{1i}, \sigma_{2i}, \sigma_{Li}), \end{array} \right. \quad (3.38)$$

където $u(\tilde{t}) = \frac{x(\tilde{t}) - \mu_x}{\sigma_x}$, $\tilde{t} = k_t$, t е безразмерното, нормализирано състояние на атрактора, $A_i, \mu_i, \sigma_{1i}, \sigma_{2i}, \sigma_{Li}$ са параметрите на Гаусовата меза функция за ECG вълните $i \in \{P, Q, R, S, T\}$, а $y(t)$ е крайния синтезиран ECG сигнал.

Постъпковото описание на алгоритъма за ECG синтез с помощта на Гаусови меза функции и Ръослер атрактор [D3-6] включва:

1. Инициализиране на входните параметри:

Морфологични (GMF) параметри за всяка вълна $i \in \{P, Q, R, S, T\}$:

$A_i, \mu_i, \sigma_{1i}, \sigma_{2i}, \sigma_{Li}$, където A_i е амплитудата, μ_i е времето отместване, σ_{1i}, σ_{2i} контролират асиметричното покачване/затихване, а σ_{Li} е продължителността на платото.

Параметри на Ръослеровия атрактор:

$a, b, c, x_0, y_0, z_0, k_t$, където a, b, c са системни параметри,

(x_0, y_0, z_0) са начални условия, k_t е коефициентът на времево мащабиране, а α контролира силата на HRV модулацията.

Параметри на сърдечната честота и семплирането:

среден RR интервал \overline{RR} , брой сърдечни удари N и честота на семплиране f_s .

Параметри на базов дрейф и шум:

m_{drift}, f_{drift} за дрейф,

$m_{HF}, f_{HF}, m_{LF}, f_{LF}$ за високочестотни и нискочестотни компоненти и дисперсията на адитивния Гаусов шум.

(По избор) Параметри на модулация на дихателната амплитуда: $\lambda_{resp}, f_{resp}, \varphi_{resp}$.

2. Интегриране на атрактора на Ръослер.

Решаване числено на системата на Ръослер, чрез схема на Рунге-Кута с времева стъпка Δt , генерирайки траекторията $x(t)$ в симулацията.

3. Премащабиране във времето и нормализиране на хаотичното състояние.

4. Генериране на последователността на RR-интервала от хаотичния драйвер.

5. Синтезиране на основната ECG вълнова форма, използвайки GMF модела.

6. (По избор) Въвеждане на физиологична амплитудна модулация (респираторно влияние).

За да се емулира бавна, нехаотична амплитудна вариабилност, дължаща се на дишането, се модулират амплитудите на GMF чрез нискочестотен синусоида:

$$A_i(t) = A_i^{base} \cdot (1 + \lambda_{resp} \sin(2\pi f_{resp} t + \varphi_{resp})), \quad (3.39)$$

с $\lambda_{resp} \in [0.02, 0.1]$ и $f_{resp} \in [0.15, 0.33]$ Hz.

Зависимите от времето амплитуди $A_i(t)$ заместват константата A_i в стъпка 5.

7. Добавяне на базов дрейф и локални тенденции чрез:

$$d(t) = m_{drift} \sin(2\pi f_{drift} t + \phi_{drift}) + b_{rw}(t),$$

$$b_{rw}(t_k) = b_{rw}(t_{k-1}) + \eta_k, \eta_k \sim N(0, \sigma_{rw}^2), \quad (3.40)$$

където $\phi_{drift} \sim U(0, 2\pi)$ е произволна фаза, η_k е Гаусова стъпка, а σ_{rw}^2 контролира силата на нестабилния дрейф.

Избира се $m_{drift} \in [0.01, 0.3]$ mV и $f_{drift} \in [0.01, 0.1]$ Hz. Добавя се линейна локална тенденция, ако се симулират дългосрочни ECG сигнали.

8. Въвеждане на шум:

- Високочестотен шум (електрическа интерференция, ЕМГ артефакти) се добавя с:

$$n_{HF}(t) = HPF_{20Hz}\{\theta(t)\}, \quad (3.41)$$

където $\theta(t) \sim N(0, \sigma_{HF}^2)$ е бял Гаусов шум, преминал през HPF (високочестотен филтър) (гранична стойност: 20–30 Hz), за да се имитират широколентови ЕМГ флукуации.

- Нискочестотен шум (респираторни влияния, отклонение на базовата линия):

$$n_{LF}(t) = LPF_{0.5Hz}\{\theta(t)\}, \quad (3.42)$$

където $\theta(t) \sim N(0, \sigma_{HF}^2)$ е бял Гаусов шум, преминал през LPF (нискочестотен филтър), за да отрази бавни, нерегулярни дихателни трептения.

Адитивен стохастичен шум $\varepsilon(t) \sim N(0, \sigma_{\varepsilon}^2)$, обикновено Гаусов с нулева средна стойност.

Общият член на шума е както следва:

$$n(t) = n_{HF}(t) + n_{LF}(t) + \varepsilon(t).$$

9. Сглобяване на крайния ECG сигнал:


$$ECG_{final}(t) = ECG_{base}(t) + d(t) + n(t). \quad (3.43)$$

Нормализиране и мащабиране на сигнала, за да пасне стандартните ECG диапазони (–1.5 до 2.5 mV).

10. Валидирана на синтезираната ECG чрез HRV анализ: Изчисляване на показатели във времевата и честотната област; спектрален анализ: STFT и CWT, за да се потвърдят реалистичните честотни компоненти.

11. Запазване и експортиране на синтезираната ECG за по-нататъшен анализ.

Регулирането на параметрите на атрактора (фигура 3.35) позволява контролирано увеличаване на вариабилността на RR интервалите, включително симулация на неравномерен пулс и аритмоподобни режими. Това потвърждава, че моделът отделя ясно времевата динамика от морфологията — ключово изискване за физиологично коректна HRV симулация.



Фигура 3.35. По-висока вариабилност във времевата между съседни R пикове [D3-6].

Таблица 3.16. Статистическо сравнение (p-стойности и корелация на Пийрсън) между реални и симулирани сигнали - параметри на HRV при състояния на покой, умора и стрес [D3-6].

Параметър	p-Value Real vs. Sim (Rest)	p-Value Real vs. Sim (Fatigue)	p-Value Real vs. Sim (Stress)	Pearson Correlation Real vs. Sim (Rest)	Pearson Correlation Real vs. Sim (Fatigue)	Pearson Correlation Real vs. Sim (Stress)	Effect Size Real vs. Sim (Rest)	Effect Size Real vs. Sim (Fatigue)	Effect Size Real vs. Sim (Stress)
Mean RR [ms]	0.894	0.598	0.086	0.82	0.89	0.76	0.416	0.300	-0.432
SDNN [ms]	0.7603	0.4888	0.369	0.84	0.78	0.73	0.113	0.031	-0.224
RMSSD [ms]	0.7504	0.5237	0.289	0.78	0.75	0.81	0.350	0.027	-0.266
TP (ms ²)	0.684	0.552	0.433	0.83	0.81	0.78	0.142	0.118	-0.165
nLF [nu]	0.5769	0.8211	0.601	0.76	0.76	0.82	0.305	0.324	-0.137

nHF [nu]	0.4985	0.3956	0.289	0.79	0.74	0.81	0.656	0.035	-0.254
LF/HF [-]	0.5721	0.0476	0.588	0.81	0.89	0.87	0.414	0.613	-0.150
Hurst [-]	0.6297	0.6310	0.646	0.79	0.81	0.75	0.392	0.062	-0.133
SampEn [-]	0.6110	0.7305	0.654	0.76	0.80	0.72	0.270	0.197	-0.117

Таблица 3.17. Поанкаре параметрите за реални и симулирани сигнали при условия на покой, умора и стрес [D3-6].

Параметър	Real—Rest (Pre-Training)	Real—Rest (Pre-Training) 95% CI	Simulated—Rest	Simulated—Rest 95% CI	Real—Fatigue (Post-training)	Real—Fatigue (Post-training) 95% CI	Simulated—Fatigue	Simulated—Fatigue 95% CI	Real—Stress (After a Competition)	Real—Stress (After a Competition) 95% CI	Simulated—Stress	Simulated—Stress 95% CI
SD1 [ms]	28.24 ± 7.35	[25.80, 30.68]	30.73 ± 5.91	[28.80, 32.66]	17.81 ± 1.97	[17.17, 18.45]	17.91 ± 4.01	[16.58, 19.24]	13.06 ± 6.28	[11.03, 15.09]	12.34 ± 6.21	[10.35, 14.33]
SD2 [ms]	67.36 ± 28.19	[58.15, 76.57]	72.98 ± 13.55	[68.55, 77.41]	56.83 ± 9.64	[53.68, 59.98]	58.13 ± 10.33	[54.75, 61.51]	50.01 ± 26.34	[41.37, 58.65]	43.87 ± 27.92	[34.55, 53.19]
SD2/SD1 [-]	2.14 ± 0.38	[2.12, 2.28]	2.37 ± 0.38	[2.25, 2.49]	2.99 ± 0.25	[2.91, 3.07]	3.24 ± 0.35	[3.18, 3.30]	3.89 ± 0.45	[3.74, 4.04]	3.55 ± 0.41	[3.41, 3.69]

Таблица 3.18. Статистическо сравнение между реални и симулирани сигнали — Поанкаре параметри в различни физиологични състояния (покой, умора и стрес) [D3-6].

Параметър	p-Value Real vs. Sim (Rest)	p-Value Real vs. Sim (Fatigue)	p-Value Real vs. Sim (Stress)	Pearson Correlation Real vs. Sim (Rest)	Pearson Correlation Real vs. Sim (Fatigue)	Pearson Correlation Real vs. Sim (Stress)	Effect Size Real vs. Sim (Rest)	Effect Size Real vs. Sim (Fatigue)	Effect Size Real vs. Sim (Stress)
SD1 [ms]	0.7573	0.4035	0.37	0.84	0.72	0.84	0.373	0.033	-0.116
SD2 [ms]	0.6874	0.6815	0.646	0.86	0.79	0.82	0.254	0.134	-0.236
SD2/SD1 [-]	0.9208	0.0971	0.37	0.84	0.85	0.78	0.605	0.788	-0.79,

Таблица 3.19. Recurrence plot параметри за реални и симулирани сигнали (покой, умора и стрес) [D3-6].

Параметър	Real—Rest (Pre-training)	Real—Rest (Pre-training) 95% CI	Simulated—Rest	Simulated—Rest 95% CI	Real—Fatigue (Post-Training)	Real—Fatigue (Post-Training) 95% CI	Simulated—Fatigue	Simulated—Fatigue 95% CI	Real—Stress (After a Competition)	Real—Stress (After a Competition) 95% CI	Simulated—Stress	Simulated—Stress 95% CI
REC [%]	3.82 ± 0.54	[3.64, 4.00]	3.88 ± 0.49	[3.71, 4.05]	4.76 ± 0.60	[4.56, 4.96]	4.69 ± 0.57	[4.50, 4.88]	5.93 ± 0.68	[5.70, 6.16]	5.88 ± 0.64	[5.67, 6.09]
DET [%]	91.6 ± 2.3	[90.9, 92.3]	90.9 ± 2.5	[90.1, 91.7]	86.2 ± 2.8	[85.3, 87.1]	85.4 ± 2.4	[84.6, 86.2]	79.1 ± 3.1	[78.1, 80.1]	78.3 ± 2.9	[77.4, 79.2]
LAM [%]	71.9 ± 3.5	[70.8, 73.0]	70.8 ± 3.2	[69.8, 71.8]	65.4 ± 3.1	[64.4, 66.4]	64.7 ± 2.9	[63.8, 65.6]	59.8 ± 2.8	[58.9, 60.7]	58.7 ± 2.6	[57.9, 59.5]
Lmax	186 ± 24	[179, 193]	181 ± 22	[175, 187]	159 ± 21	[153, 165]	154 ± 19	[149, 159]	131 ± 18	[126, 136]	128 ± 17	[123, 133]
TT (Trapping Time)	21.6 ± 2.7	[20.8, 22.4]	20.9 ± 2.5	[20.2, 21.6]	17.4 ± 2.2	[16.8, 18.0]	16.9 ± 2.0	[16.4, 17.4]	14.1 ± 1.9	[13.6, 14.6]	13.7 ± 1.8	[13.2, 14.2]
ENTR	2.89 ± 0.40	[2.76, 3.02]	2.82 ± 0.38	[2.70, 2.94]	2.43 ± 0.34	[2.32, 2.54]	2.37 ± 0.32	[2.27, 2.47]	2.05 ± 0.29	[1.96, 2.14]	2.02 ± 0.27	[1.94, 2.10]

Таблица 3.20. Статистическо сравнение между реални и симулирани сигнали – индекси на графика на повторение в различните физиологични състояния.

Параметър	<i>p</i> -Value Real vs. Sim (Rest)	<i>p</i> -Value Real vs. Sim (Fatigue)	<i>p</i> -Value Real vs. Sim (Stress)	Pearson Correlation Real vs. Sim (Rest)	Pearson Correlation Real vs. Sim (Fatigue)	Pearson Correlation Real vs. Sim (Stress)	Effect Size Real vs. Sim (Rest)	Effect Size Real vs. Sim (Fatigue)	Effect Size Real vs. Sim (Stress)
RQA: REC [%]	0.521	0.487	0.441	0.77	0.80	0.79	0.115	0.122	0.081
RQA: DET [%]	0.338	0.410	0.367	0.81	0.79	0.78	0.144	0.098	0.121
RQA: LAM [%]	0.276	0.352	0.295	0.80	0.78	0.77	0.182	0.097	0.105
RQA: Lmax	0.446	0.391	0.418	0.78	0.76	0.75	0.210	0.243	0.173
RQA: TT (Trapping Time)	0.389	0.421	0.338	0.81	0.80	0.79	0.177	0.159	0.120
RQA: ENTR	0.277	0.312	0.268	0.82	0.83	0.81	0.173	0.185	0.143

Таблица 3.21. Триизмерни показатели за атрактор на фазово пространство за реални и симулирани HRV сигнали при условия на покой, умора и стрес [D3-6].

Параметър	Real—Rest (Pre-training)	Real— Rest (Pre- training) 95% CI	Simulat- ed— Rest	Simulated —Rest 95% CI	Real— Fatigue (Post- Trainin g) 95% CI		Simulat- ed— Fatigue	Simulated —Fatigue 95% CI	Real— Stress (After a Competiti on)	Real—Stress (After a Competition 95% CI	Simulated —Stress	Simulated —Stress 95% CI
					Fatigue (Post- Training)	Fatigue (Post- Training)						
Lyapunov λ_1 [bits/s]	0.102 ± 0.018	[0.095, 0.108]	0.099 ± 0.020	[0.092, 0.106]	0.138 ± 0.024	[0.129, 0.147]	0.132 ± 0.022	[0.124, 0.140]	0.168 ± 0.028	[0.157, 0.179]	0.162 ± 0.025	[0.152, 0.172]
Correlation Dimension D ₂ [-]	2.41 ± 0.32	[2.30, 2.52]	2.38 ± 0.29	[2.28, 2.48]	2.12 ± 0.27	[2.03, 2.21]	2.09 ± 0.25	[2.00, 2.18]	1.86 ± 0.22	[1.78, 1.94]	1.82 ± 0.20	[1.75, 1.89]
Permutation Entropy	0.84 ± 0.06	[0.82, 0.86]	0.81 ± 0.07	[0.79, 0.83]	0.72 ± 0.05	[0.70, 0.74]	0.69 ± 0.06	[0.67, 0.71]	0.61 ± 0.05	[0.59, 0.63]	0.58 ± 0.05	[0.56, 0.60]

Таблица 3.22. Статистическо сравнение на реални и симулирани сигнали: нелинейни HRV показатели за 3D фазово-пространствен атрактор в различни физиологични състояния (покой, умора и стрес) [D3-6].

Параметър	<i>p</i> -Value Real vs. Sim (Rest)	<i>p</i> -Value Real vs. Sim (Fatigue)	<i>p</i> -Value Real vs. Sim (Stress)	Pearson Correlation Real vs. Sim (Rest)	Pearson Correlation Real vs. Sim (Fatigue)	Pearson Correlation Real vs. Sim (Stress)	Effect Size Real vs. Sim (Rest)	Effect Size Real vs. Sim (Fatigue)	Effect Size Real vs. Sim (Stress)
Lyapunov λ_1 [bits/s]	0.284	0.311	0.267	0.82	0.84	0.81	0.156	0.250	0.223
Correlation Dimension D ₂ [-]	0.402	0.365	0.298	0.79	0.82	0.83	0.095	0.113	0.188
Permutation Entropy	0.315	0.337	0.289	0.80	0.83	0.82	0.120	0.145	0.210

Ограничения: Механизмът за вариабилност, базиран на атрактор, улавя основни модели на HRV в различни физиологични състояния, но той остава детерминистичен модул и може да не емулира напълно стохастичността, наблюдавана в динамиката на HRV, например при патологични състояния. Настоящата оценка е ограничена до три физиологични състояния (покой, умора и стрес).

Подходът за валидиране, базиран на коефициенти на корелация и визуален атракторен анализ, би могъл да се възползва от по-нататъшно разширение с помощта на класификатори, базирани на машинно обучение, и външни набори от данни за сравнение.

Бъдещата работа ще се фокусира върху интегрирането на предложената рамка за ЕКГ симулация в носими устройства за генериране и тестване на сигнали в реално време. Тази интеграция би позволила валидиране на алгоритми за откриване на умора, стрес и възстановяване на устройството.

ГЛАВА ЧЕТВЪРТА: МЕТОДИ И АРХИТЕКТУРИ ЗА ЗАЩИТА НА КАРДИОЛОГИЧНИ ДАННИ В БИОМЕДИЦИНСКИ СИСТЕМИ

В тази глава се формулира и валидира нов научен принцип за защита на биомедицински времеви серии, наречен регионално-осъзната защита (Region-Aware Security). Принципът се

основава на тезата, че защитата на физиологичните сигнали следва да бъде адаптивна спрямо диагностичната значимост, енергията и локалната сложност на различните физиологични региони, а не еднородна по цялата времева серия. За разлика от традиционните инженерни решения, предложената концепция разглежда защитата като част от самия модел на сигнала, а не като външна процедура, което я прави съвместима с концепцията за дигитален близък и с изискванията за проследимост, автентичност и клинична интерпретируемост.

Унифициран метод за защита на кардиологични данни чрез трансформационно представяне, цифрово водно маркиране и хибридно криптиране

Моделът се реализира чрез следните концептуални етапи:

1. **Трансформационно представяне чрез DWT.** Всеки сигнал се представя в уейвлет домейна, което осигурява многорезолюционно описание, подходящо за нестационарната природа на кардиологичните сигнали. Използването на уейвлет базис Db4 и четири нива на разлагане осигурява оптимален баланс между локализация и реконструкционна точност за ECG, PPG и Холтерни записи.
2. **Енергийно-ориентирана редукция (EPE).** В уейвлет домейна се прилага редукция на коефициентите, базирана на тяхната енергийна значимост. Чрез Energy Packaging Efficiency (EPE) се елиминират компоненти с минимален принос към диагностичната информация.
3. **Цифрово водно маркиране.** В редуцираните уейвлет коефициенти се вгражда воден знак, носещ информация за идентичността и целостта на сигнала. Вграждането се извършва в най-нискочестотната подлента, което осигурява устойчивост спрямо компресия, шум и филтрация, като същевременно минимизира въздействието върху морфологията на сигнала.
4. **Хибридна криптографска защита.** Получената последователност се криптира чрез симетричен алгоритъм (AES), а симетричният ключ се защитава чрез асиметрично криптиране (RSA). По този начин се постига висока производителност при обработка на големи обеми данни и сигурен обмен на ключове.
5. **Обратна реконструкция и оценка.** След декриптиране и обратна уейвлет трансформация се възстановява сигналът, който подлежи на количествена оценка чрез стандартни показатели за качество и диагностична съвместимост.

Основните метрики за оценка включват PRD, SNR и RMSE, които служат за проверка на запазването на диагностичната морфология на сигналите след защитната обработка.

Експерименталната валидация на предложения унифициран метод за защита на кардиологични данни е извършена върху реални ECG, PPG и Холтер записи с цел да се оцени неговата ефективност, стабилност и съвместимост с диагностичните изисквания. Анализът обхваща основните компоненти на модела – компресия, водно маркиране и криптографска защита – както поотделно, така и в тяхната последователна интеграция.

Валидиране на компресионния компонент

Резултатите, представени в Таблицы 4.2–4.4, демонстрират поведението на EPE-базирания метод за редукция на уейвлет коефициентите при различни типове кардиологични сигнали и различни дължини на блоковете. За всички изследвани записи е постигнат стабилен компромис между коефициента на компресия и параметъра PRD, като стойностите на CR варират в диапазона от 3.87 (PPG) до 5.07 (Холтер), при PRD под 3%.

Наблюдава се закономерно увеличение на PRD с повишаване на степента на компресия, което е очакван ефект при всяка загубна редукция. Въпреки това, получените стойности остават в граници, които не водят до клинично значими изкривявания на основните морфологични компоненти на сигналите. Анализът на различните размери на блоковете показва, че увеличаването на дължината на блока позволява постигане на по-висок коефициент на компресия при минимално влошаване на сходството с оригиналния сигнал.

Таблица 4.2 Стойности на CR и PRD за ECG записи (N = 24) [D4-2].

Показател						Стойност
Апроксимиращи коефициенти с EPE 99%						99%
Детайлни коефициенти		99%	95%	90%	80%	75%
Дължина на блока: 1024 проби	CR [mean ± std]	3.92 ± 0.84	3.98 ± 0.81	4.14 ± 0.91	4.49 ± 0.93	4.73 ± 0.97
	PRD (%)	1.26 ± 0.12	1.88 ± 0.13	2.32 ± 0.15	2.47 ± 0.16	2.51 ± 0.18
Дължина на блока: 2048 проби	CR [mean ± std]	3.94 ± 0.86	4.08 ± 0.81	4.17 ± 0.93	4.53 ± 0.94	4.81 ± 0.99
	PRD (%)	1.32 ± 0.13	1.98 ± 0.14	2.44 ± 0.17	2.49 ± 0.16	2.58 ± 0.19
Дължина на блока: 4096 проби	CR [mean ± std]	3.98 ± 0.11	4.14 ± 0.13	4.19 ± 0.9	4.38 ± 0.91	4.83 ± 0.98
	PRD (%)	1.34 ± 0.12	1.98 ± 0.17	2.48 ± 0.19	2.57 ± 0.18	2.62 ± 0.17

Таблица 4.3 Стойности на CR и PRD за Holter записи (N = 24) [D4-2].

Показател						Стойност
Апроксимиращи коефициенти с EPE 99%						99%
Детайлни коефициенти		99%	95%	90%	80%	75%
Дължина на блока: 1024 проби	CR [mean ± std]	4.06 ± 0.71	4.23 ± 0.8	4.29 ± 0.82	4.81 ± 0.79	4.98 ± 0.85
	PRD (%)	1.18 ± 0.11	2.02 ± 0.13	2.28 ± 0.09	2.37 ± 0.41	2.48 ± 0.32
Дължина на блока: 2048 проби	CR [mean ± std]	4.14 ± 0.69	4.28 ± 0.7	4.37 ± 0.83	4.84 ± 0.81	5.04 ± 0.88
	PRD (%)	1.22 ± 0.14	1.85 ± 0.11	2.32 ± 0.13	2.4 ± 0.39	2.54 ± 0.36
Дължина на блока: 4096 проби	CR [mean ± std]	4.17 ± 0.13	4.31 ± 0.22	4.42 ± 0.12	4.89 ± 0.14	5.07 ± 0.17
	PRD (%)	1.23 ± 0.12	2.03 ± 0.17	2.35 ± 0.14	2.59 ± 0.28	2.68 ± 0.39

Таблица 4.4 Стойности на CR и PRD за PPG записи (N = 24) [D4-2].

Показател						Стойност
Апроксимиращи коефициенти с EPE 99%						99%
Детайлни коефициенти		99%	95%	90%	80%	75%
Дължина на блока: 1024 проби	CR [mean ± std]	3.87 ± 0.98	3.98 ± 0.88	4.06 ± 0.63	4.36 ± 0.58	4.54 ± 0.8
	PRD (%)	1.24 ± 0.09	1.78 ± 0.11	2.25 ± 0.12	2.51 ± 0.16	2.64 ± 0.17
Дължина на блока: 2048 проби	CR [mean ± std]	3.92 ± 0.97	4.06 ± 0.77	4.11 ± 0.67	4.44 ± 0.78	4.58 ± 0.83
	PRD (%)	1.31 ± 0.11	1.88 ± 0.13	2.27 ± 0.14	2.6 ± 0.17	2.71 ± 0.21
Дължина на блока: 4096 проби	CR [mean ± std]	3.96 ± 1.03	4.06 ± 0.99	4.14 ± 0.65	4.55 ± 0.69	4.61 ± 0.91
	PRD (%)	1.33 ± 0.16	1.78 ± 0.25	2.29 ± 0.13	2.63 ± 0.18	2.77 ± 0.19

Влияние на водното маркиране върху диагностичното качество

Оценката на процедурата за вграждане на воден знак е извършена върху трансформирани и компресирани PPG сигнали. Резултатите от таблица 4.5 показват, че стойностите на PRD остават под 0.3%, а PSNR надвишава 44 dB за всички изследвани записи. Това потвърждава, че вграждането на водния знак в нискочестотната подлента не нарушава диагностично значимите характеристики на сигнала. Получените резултати показват, че предложената схема за водно маркиране осигурява висока устойчивост и проследимост на данните, без да компрометираща качеството на сигнала.

Таблица 4.5 Стойности на PRD и PSNR за PPG сигнали [D4-2].

№ на кардио запис	PRD [%]	PSNR [dB]
1	0.2014	53.11
2	0.1911	52.03
3	0.1805	46.38
4	0.2502	48.44
5	0.1611	51.08
6	0.1173	44.37
7	0.1239	48.55

8	0.1386	44.07
9	0.1604	49.75
10	0.2091	54.98
11	0.1035	44.09
12	0.1357	52.47

Анализ на компромиса между капацитет, качество и устойчивост

Резултатите от Таблицы 4.7 и 4.8 позволяват да се анализира компромисът между дължината на водния знак, качеството на реконструкцията и устойчивостта на защитата. Установено е, че увеличаването на капацитета на водния знак води до постепенно влошаване на показателите PRD, MSE и BER. Въпреки това, при умерени дължини на водния знак и използване на уейвлет базииси от семейство Добеши (Db4 и Db8) се постига най-балансирано съотношение между всички оценявани параметри.

Сравнението между различните уейвлет базииси показва, че използването на Haar (Db2) води до по-висок коефициент на компресия, но за сметка на значително влошено качество. От друга страна, базиисите с по-голям брой коефициенти (Db12 и Db16) предизвикват прекомерно изглаждане на сигнала и загуба на локални особености. Това мотивира избора на Db4 като оптимален компромис в рамките на предложената архитектура.

Таблица 4.7. Параметри за оценка за различни дължини на водния знак [D4-2].

Дължина на водния знак	32	64	128	256	512
PSNR [db]	45.33	44.44	43.62	42.33	41.51
MSE	0.043	0.047	0.051	0.058	0.063
PRD [%]	5.14	5.86	6.31	6.87	6.99
RMSE	0.2074	0.2168	0.2258	0.2408	0.251
MAPE [%]	0.0041 ± 0.001	0.0046 ± 0.002	0.013 ± 0.002	0.11 ± 0.003	0.21 ± 0.007
BER	0.005	0.08	0.11	0.18	0.22
KLD	0.002	0.006	0.014	0.06	0.08

Таблица 4.8 Параметри на оценка за различни уейвлет базииси [D4-2].

Уейвлет базис	Db2 (Haar)	Db4	Db8	Db12	Db16
PSNR [db]	14.81 ± 1.19	52.03 ± 0.81	51.16 ± 0.47	45.32 ± 0.31	44.65 ± 0.88
MSE	0.91 ± 0.08	0.022 ± 0.001	0.024 ± 0.002	0.043 ± 0.02	0.046 ± 0.001
PRD [%]	16.88 ± 3.74	5.91 ± 0.99	6.12 ± 1.02	6.82 ± 1.11	6.94 ± 1.03
RMSE	0.956 ± 0.11	0.1483 ± 0.03	0.1549 ± 0.04	0.2047 ± 0.07	0.2145 ± 0.07
MAPE [%]	0.33 ± 0.04	0.0047 ± 0.0008	0.0051 ± 0.001	0.0054 ± 0.01	0.062 ± 0.03
BER	0.41 ± 0.1	0.011 ± 0.03	0.014 ± 0.08	0.017 ± 0.09	0.024 ± 0.01
KLD	0.36 ± 0.01	0.006 ± 0.01	0.014 ± 0.002	0.011 ± 0.02	0.06 ± 0.003
CR	6.68 ± 0.84	4.18 ± 0.53	4.16 ± 0.72	3.99 ± 0.32	3.81 ± 0.41

Регионално-адаптивен метод за защита с SHA-256, λ-сегментация и хибридна криптография

В този раздел се въвежда нов фундаментален принцип за защита на кардиологични данни, основан на концепцията за регионално-осъзната сигурност. За разлика от съществуващите подходи, които третират биомедицинския сигнал като хомогенна последователност, предложеният метод разглежда кардиологичните сигнали като **структурирани обекти с нееднородна диагностична значимост**, изискващи адаптивна защитна стратегия.

При регионално-осъзнатата защита силата и типът на защитните механизми **се адаптират спрямо диагностичната и клинична важност на отделните сегменти на сигнала**, а не се прилагат равномерно върху цялата времева серия. Този принцип позволява едновременно повишаване на сигурността и запазване на клиничната използваемост, което не може да бъде постигнато чрез класически еднородни защитни схеми.

Формална постановка. Нека кардиологичният сигнал бъде представен като дискретна времева последователност $(t, t=1,2,\dots,N$. Сигналят се сегментира на K неприпокриващи се региона: $x(t) = \bigcup_{k=1}^K R_k$, където всеки регион R_k съответства на определен физиологичен или диагностичен сегмент (например QRS-комплекс, ST-сегмент, диастолна фаза, пулсова вълна при PPG). На всеки регион R_k се асоциира регионален коефициент на чувствителност $\lambda_k \in (0,1]$, който количествено описва неговата диагностична значимост. Високите стойности на λ_k се асоциират с региони, критични за клиничната интерпретация, докато по-ниските стойности се отнасят за второстепенни или структурно по-малко чувствителни области.

Регионално-адаптивна защита. Защитната трансформация (\cdot) върху сигнала се дефинира като композиция от регионално зависими операции $P(x) = \bigcup_{k=1}^K P_k(x|\lambda_k)$, където P_k представлява локална защитна процедура, включваща адаптивна компресия; регионално контролирано водно маркиране; криптографска защита с различна дълбочина.

Контрол на изкривяването. Въвежда се регионално ограничение върху допустимото изкривяване $D(R_k) \leq \varepsilon(\lambda_k)$, където $D(\cdot)$ е мярка за изкривяване (напр. PRD или MSE), а $\varepsilon(\lambda_k)$ е допустим праг, обратно пропорционален на диагностичната значимост. Това гарантира, че критичните региони се защитават консервативно, докато в по-малко чувствителните области може да се прилага по-агресивна защита.

Всяка входна времева серия (t) , се сегментира в физиологично и диагностично значими региони. За ECG сигнал това включва P-вълна, QRS комплекс, T-вълна, които носят различна диагностична информация. За PPG сигнал се идентифицират систолни пикове, възходящи и низходящи фази, както и базова линия. Регионалното сегментиране позволява адаптивно водно маркиране – силата на вграждане се настройва според важността и чувствителността на всеки сегмент.

Към оригиналния кардио сигнал $x(t)$ след сегментация се прилага многостепенна DWT. За да се даде възможност за **регионално адаптивно водно маркиране**, на всеки DWT коефициент c_i се присвоява тегловен коефициент, базиран на региона, към който принадлежи. Теглото λ_i модулира силата на вграждане и се изчислява като:

$$\lambda_i = f(H_i, E_i, S_i), \quad (4.14)$$

където:

H_i е локалната ентропия (сложност), в позиция i , представляваща непредсказуемост на сигнала;

$E_i = \sum_{j \in w_i} x_j^2$ е локалната енергия (физиологична активност), върху плъзгач се прозорец w_i ;

S_i кодира семантичния клас на региона (напр. QRS комплекс, T-вълна, базова линия), което позволява приоритетно вграждане в диагностично значими области (диагностично значение).


Функцията $f(\cdot)$ се определя от формулата:

$$\lambda_i = \alpha \cdot H_i + \beta \cdot E_i + \gamma \cdot S_i \quad (4.15)$$

с коефициенти $\alpha, \beta, \gamma \in [0,1]$, $\alpha + \beta + \gamma = 1$, което позволява балансиране на приноса на всяка характеристика.

При тази функционална форма λ_i варира адаптивно в диапазона $[0.5, 1.5]$, което позволява оптимално вграждане на воден знак в диагностично значими области (напр. QRS комплекс), умерено в почувствителни области (напр. T-вълна) и минимално или нулево в маловажни области.

Фигура 4.14 представя шумен ECG сигнал с приложено регионално зависимо тегло λ за вграждане на воден знак. Шумът имитира реални клинични условия, при които надеждната защита на данните остава предизвикателство. Използването на адаптивна λ позволява прецизен контрол върху интензитета на вграждане: в QRS комплекса (около 0.38–0.42 s и 0.58–0.62 s) се прилага най-високата стойност $\lambda = 1.5$, осигуряваща максимална устойчивост на водния знак в диагностично критичните сегменти. В областите на T- и P-вълните (0.18–0.22 s и 0.62–0.66 s) λ приема междинни стойности, докато в зоните с ниско информационно съдържание тя намалява до около 0.6, което минимизира изкривяването и запазва естествения морфологичен вид на сигнала. Този подход осигурява оптимален баланс между надеждност, невидимост и клинична използваемост.



Фигура 4.14 Регионално адаптирано λ -картиране върху ECG сигнал [D4-3].


Влияние на дължината на водния знак

Таблица 4.10 обобщава количествените показатели за ефективността на метода при различни дължини на водния знак (32–512 бита). С увеличаване на дължината на водния знак се наблюдава очаквано намаляване на PSNR и увеличение на останалите показатели за грешка. Въпреки това, за дължини до 128 бита методът поддържа високо качество на сигнала (PSNR > 44 dB) и ниски стойности на BER (< 0.1), което гарантира както диагностична използваемост, така и надеждна защита.

Таблица 4.10 Показатели за оценка на качеството при различни дължини на водния знак [D4-3]

Watermark (bits)	PSNR (dB)	MSE	PRD (%)	RMSE	MAPE (%)	BER
32	46.12	0.039	4.91	0.197	0.0037	0.003
64	45.31	0.042	5.45	0.205	0.0042	0.060
128	44.55	0.046	5.89	0.214	0.0098	0.090
256	43.21	0.052	6.38	0.229	0.0940	0.150
512	42.44	0.058	6.74	0.243	0.1810	0.200

Фигура 4.18 илюстрира шумна част от ECG сигнал, използвана за оценка устойчивостта на водния знак при тежки условия на измерване. Тази област съдържа значителни артефакти — вариации в базовата линия, високочестотен шум и случайни амплитудни смущения, които симулират реални предизвикателства при мобилно или дистанционно измерване. Въпреки това, методът успява да запази извличаемостта на водния знак, което демонстрира неговата устойчивост при ниско SNR.



Фигура 4.18 Значително зашумена част от ECG сигнал [D4-3].

ГЛАВА ПЕТА: МЕТОДОЛОГИЧНА РАМКА НА КОНЦЕПЦИЯТА ДИГИТАЛЕН БЛИЗНАК НА ВАРИАБИЛНОСТТА НА СЪРДЕЧНАТА ЧЕСТОТА

В пета глава е разработен и формализиран нов методологичен подход за неконтролирано разпознаване на физиологични състояния, базиран на интегриран анализ на вариабилността на сърдечната честота (HRV), фрактални характеристики и алгоритми на изкуствения интелект. Подходът преодолява ограниченията на класическите HRV-базирани системи, които разчитат на предварително дефинирани прагове или етикетирани данни, като въвежда концепция за извличане на физиологичните състояния като латентни структури в многомерно пространство на признаците.

Предложеният подход е формализиран като последователна трансформация на кардиологичен времеви ред $x(t)$ към структурирано пространство на състоянията $S \subset R^n$, в което физиологичните режими се проявяват като геометрично обособени области.

Аналитичната последователност включва:

1. Придобиване и предварителна обработка на кардио сигнали (детекция на R-пикове, конструиране на RR времеви ред, отстраняване на артефакти);
2. Извличане на линейни, нелинейни и фрактални HRV характеристики, формиращи многомерен вектор на признаците $f = (f_1, f_2, \dots, f_n)$;
3. Формиране на многомерно пространство на автономната динамика, в което всяко наблюдение представлява точка в R^n ;
4. Намаляване на размерността и елиминирание на корелации чрез линейна ортогонализация (PCA), с цел извеждане на доминиращите оси на вариация;
5. Неконтролирано клъстериране и откриване на аномалии, при което се изследва дали съществуват устойчиви плътности или центроидни структури;
6. Интерпретация на клъстерите като физиологични състояния, базирана на статистически и физиологичен анализ, а не на предварително зададени етикети.

Емпиричната валидация на подхода е проведена върху 10 минутни холтерни записи, регистрирани от 22 спортисти (на възраст 24–46 години) в три състояния: почивка, стрес и физическо натоварване.

От предварително обработените RR редове е конструирано многомерно пространство на автономната динамика, включващо линейни, спектрални и нелинейни показатели: Mean RR, SDNN, RMSSD, SampEn (Sample Entropy), експонента на Хърст, фрактална размерност D; спектър в LF, HF честотни ленти и отношението LF/HF.

Всеки 10-минутен прозорец се представя чрез вектор от признаци:

$$x_i = [MeanRR_i, SDNN_i, RMSSD_i, LF_i, HF_i, \frac{LF}{HF}, SampEn_i, H_i, D_i]^T \quad (5.1)$$

Всички наблюдения се обединяват в матрица $X \in R^{N \times p}$, която се стандартизира чрез z-нормализация (с цел предотвратяване изкриването на геометрията на пространството) преди последващия анализ.

С цел елиминирание на корелации и откриване на латентна структура в данните е приложен анализ на главните компоненти (PCA). PCA реализира ортогонална линейна трансформация на стандартизираните данни $Z = X_z W$, където W съдържа собствените вектори на ковариационната матрица.

За разкриване на естествени групировки в редуцираното пространство са приложени няколко алгоритъма за неконтролирано обучение:

- K-Means клъстериране (k=3), съответстващо на очакваните физиологични режими;
- йерархично клъстериране с Ward linkage, минимизиращо вътрешноклъстерната дисперсия;
- DBSCAN, позволяващ откриване на преходни състояния и аномалии чрез анализ на плътността.

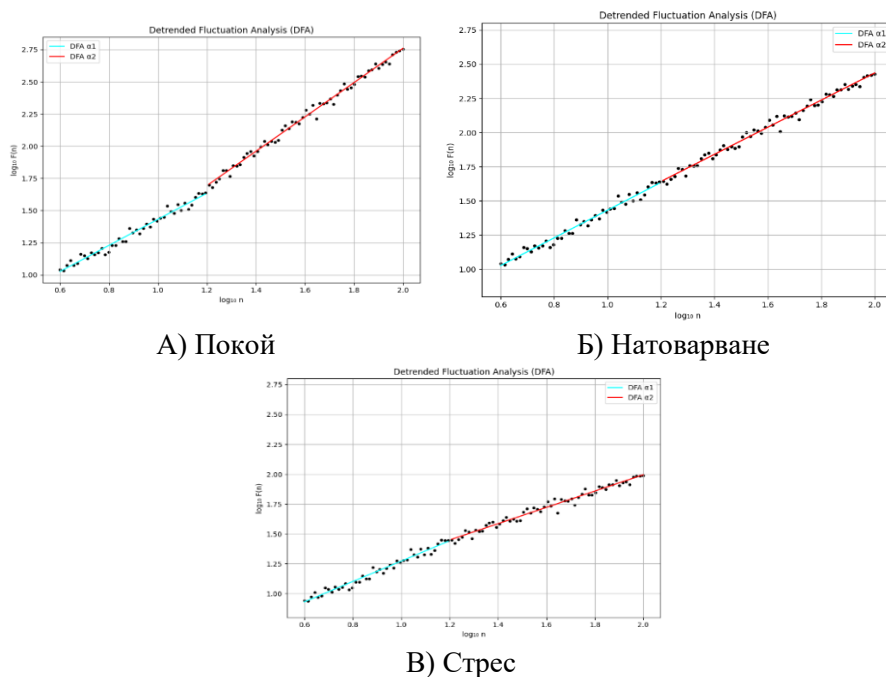
Таблица 5.4 представя описателна статистика за всички характеристики на HRV в трите физиологични състояния. Анализът разкрива много добро разграничение между покой, стрес и натоварване въз основа на времеви, спектрални и нелинейни параметри на HRV.

Таблица 5.4 HRV параметри за трите физиологични състояния [D5-1].

Параметър	Почивка N=22 [Mean ± sd]	Стрес N = 22 [Mean ± sd]	Натоварване/умора N = 22 [Mean ± sd]
Mean RR (ms)	842.16 ± 143.23	638.28 ± 126.17	689.42 ± 131.38
SDNN (ms)	161.43 ± 46.73	93.46 ± 45.68	118.27 ± 26.19
RMSSD (ms)	28.39 ± 7.24	9.86 ± 4.81	18.22 ± 5.93
SampEn	1.22 ± 0.12	1.72 ± 0.08	1.35 ± 0.18

Hurst Exponent (H)	0.72 ± 0.04	0.58 ± 0.05	0.63 ± 0.04
Fractal Dimension (FD)	1.18 ± 0.03	1.41 ± 0.04	1.36 ± 0.08
LF (nu)	37.21 ± 4.50	68.12 ± 6.42	54.00 ± 5.61
HF (nu)	63.42 ± 5.06	32.33 ± 4.22	46.00 ± 4.52
LF/HF	0.59 ± 0.11	2.12 ± 0.23	1.22 ± 0.14
DFA α_1	1.14 ± 0.06	0.88 ± 0.08	1.04 ± 0.07
DFA α_2	1.33 ± 0.05	0.86 ± 0.07	0.99 ± 0.06

Фигура 5.7 визуализира тези различия чрез логаритмичните зависимости $F(n)$ – n . В покой се наблюдава персистираща динамика ($\alpha > 1$), при натоварване – умерена редукция на дългосрочната скала, а при стрес – системна загуба на фрактална структура.



А) Покой

Б) Натоварване

В) Стрес

Фигура 5.7. DFA на HRV: А) покой, В) натоварване и С) стрес[D5-1].

Двустранен t-тест за независими извадки е приложен при сравнение на двойки физиологични състояния (покой–стрес, стрес–натоварване, покой–натоварване). Резултатите (Таблица 5.5) показват статистически значими различия ($p < 0.05$) в почти всички времеви, спектрални и нелинейни показатели. Най-изразени са различията между покой и стрес, където се наблюдава системна редукция на вариабилността (Mean RR, SDNN, RMSSD), промяна в автономния баланс (LF, HF, LF/HF) и съществено нарушение на фракталната организация (DFA α_1 , α_2 , H, FD).

Таблица 5.5 Резултати от T-тест анализ (p параметър) [D5-1].


Параметър	Покой срещу Стрес	Стрес срещу натоварване	Покой срещу натоварване
Mean RR (ms)	<0.0001	<0.05	<0.0001
SDNN (ms)	<0.001	<0.05	<0.001
RMSSD (ms)	<0.0001	<0.05	<0.05
SampEn	<0.0001	<0.05	<0.05
Hurst Exponent (H)	<0.05	<0.05	<0.01
Fractal Dimension (FD)	<0.0001	<0.05	<0.05
LF (nu)	<0.001	<0.01	<0.001
HF (nu)	<0.001	<0.05	<0.001

LF/HF	<0.001	<0.01	<0.001
DFA α_1	<0.0001	<0.05	<0.001
DFA α_2	<0.0001	<0.05	<0.05

За оценка на едновременния ефект на физиологичното състояние върху множеството показатели е проведен еднофакторен дисперсионен анализ (ANOVA), последван от Tukey HSD post hoc процедура. Анализът потвърждава наличието на статистически значими различия между отделните състояния в почти всички параметри. Изключения (се наблюдават единствено при SampEn (натоварване спрямо покой, $p = 0.26$) и Mean RR (натоварване спрямо стрес, $p = 0.79$), което показва частично припокриване между тези режими.

Триизмерният PCA биplot (Фигура 5.12) предоставя интегрална визуализация на тази структура, като едновременно представя групирането на наблюденията и приноса на отделните показатели към латентните оси (PC1–PC3).

За анализ на вътрешната геометрия на HRV-пространството е приложен DBSCAN метод върху PCA-редуцираното представяне на данните. Целта е проверка дали физиологичните състояния формират естествени плътности региони в многомерното пространство на линейните, нелинейните и фракталните показатели. Резултатите (Фигура 5.15) показват, че данните се организират в компактни области, разделени от по-слабо наситени преходни зони.



Фигура 5.12 Триизмерна PCA биplotна графика. **Фигура 5.15** DBSCAN клъстериране [D5-1].

Оценъчни характеристики на неконтролираното структуриране

Ефективността на предложената рамка е оценена чрез три стандартни външни индекса: Purity, Adjusted Rand Index (ARI) и Normalized Mutual Information (NMI), които измерват съответствието между емпирично формираните клъстери и физиологичните състояния, дефинирани от експерименталния протокол. Получените стойности (Purity = 0.933; ARI = 0.89; NMI = 0.92) показват висока степен на съгласуваност между неконтролираното клъстериране и реалните физиологични режими. Това означава, че над 93% от наблюденията са структурирани в групи, съответстващи на биологично валидни състояния, без използване на предварително зададени етикети.

Интегриран HRV–фрактален–RQA подход за оценка на автономната регулация и умората при спортисти

Представеният подход [D5-2] има за цел да оцени промените в автономната регулация непосредствено и два часа след тренировка при спортисти, използвайки интегрирана аналитична рамка (комбинираща времеви и честотни HRV индекси с нелинейни и рекурентно-количествени (RQA) показатели). Проследяването в продължение на четири месеца позволява анализ на кумулативните ефекти от тренировъчния процес и идентифициране на спортисти с повишен риск от автономен дисбаланс. Акцентът е върху ранното откриване на признаци на прекомерна умора, нарушена регулаторна адаптация и повишен сърдечно-съдов стрес. Подходът осигурява многомерна оценка на автономната динамика и създава предпоставки за прецизно мониториране на тренировъчното възстановяване.

Формализирано описание на интегрирания подход

Нека $\{RR_k\}_{k=1}^N$ е дискретна времева серия от последователни RR-интервали, извлечени от 5-минутен сегмент на холтерен запис. Серията се разглежда като реализация на стохастичен процес, описващ динамиката на автономната регулация.

Всеки запис i се представя чрез вектор от признаци:

$$x_i = [MeanRR_i, SDNN_i, RMSSD_i, LF_i, HF_i, \frac{LF}{HF}_i, \alpha_{1i}, \alpha_{2i}, SampEn_i, H_i, D_i]^T \in R^p, \quad (5.2)$$

където:

- MeanRR, SDNN, RMSSD – времеви HRV показатели;
- LF, HF и LF/HF – честотни показатели;
- α_1, α_2 – DFA скалиращи експоненти;
- SampEn – ентропията на пробата;
- H – експонентата на Хърст;
- RQA=[REC,DET,LAM,TT,ENTR] – вектор от рекурентни показатели.

Рекурентно количествен анализ

За анализ на геометричната структура във фазовото пространство се дефинира рекурентната матрица:

$$R_{i,j} = \Theta(\varepsilon - \|y_i - y_j\|), \quad (5.3)$$

където y_i са векторите на вложеното фазово пространство, ε е праг на близост, а $\Theta(\cdot)$ е стъпковата функция на Хевисайд.

От $R_{i,j}$ се извличат количествените показатели REC, DET, LAM, TT, EMTR, които са чувствителни към преходи, нестабилност и структурни промени в автономната динамика.

Анализ на данните и статистическа обработка

Дължина и избор на сегмент. HRV анализът е извършен върху фиксиран 5-минутен сегмент от всеки 10-минутен холтерен запис, обхващащ интервала между 3-тата и 8-мата минута. Този избор цели елиминиране на начални преходни процеси (адаптация, електродни артефакти), минимизиране на двигателни смущения и осигуряване на относителна стационарност на автономната регулация и дихателния ритъм. При записи с по-кратка продължителност 5-минутният прозорец е центриран спрямо времевата ос. Подходът е в съответствие с международните препоръки за краткосрочен HRV анализ и гарантира надеждно изчисляване както на линейни, така и на нелинейни показатели.

Определени са следните параметри: линейни (Mean RR, SDNN, RMSSD, LF, HF, LF/HF); нелинейни (DFA α_1, α_2); фрактални (SampEn, Hurst); RQA (REC, DET, LAM, TT, ENTR).

Статистически анализ. Нормалността на данните е оценена с теста на Shapiro-Wilk. Променливите са представени като средна стойност \pm стандартно отклонение (SD) и 95% доверителен интервал (CI). За оценка на ефектите от тренировката и възстановяването върху параметрите на HRV, е приложен еднофакторен ANOVA с повторни измервания, при който условието (преди тренировка, непосредствено след тренировка, 2 часа след тренировка) е вътресубектен фактор. Поради наличието на един повтарящ се фактор не са разглеждани взаимодействия. При откриване на значими ефекти, са извършени post hoc сравнения, използвайки t-тестове за сдвоени извадки между условията. За контрол на грешката от първи род при множествени сравнения е използвана процедурата на Holm–Bonferroni. Размерът на ефекта е оценен чрез η^2 . Статистическата значимост е приета при $p < 0.05$ след корекция, което осигурява устойчивост на резултатите спрямо множествени тестове и взаимосвързаността между HRV индексите.

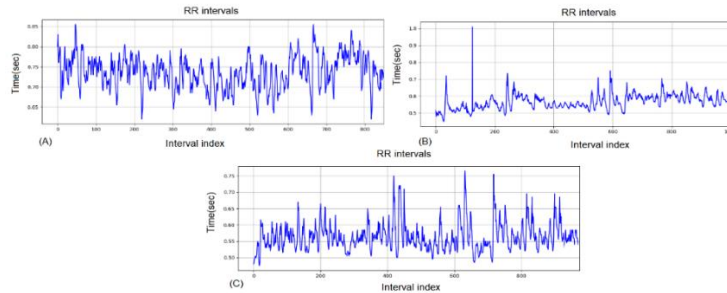
Резултати

Общо 960 записа са анализирани за всяко състояние: преди тренировка, след тренировка и след 2-часово възстановяване. Въз основа на числения HRV анализ и графичните представяния се обособяват три групи:

- Група 1– леки отклонения от референтните диапазони, съответстващи на лека до умерена умора (695 записа; 72.4%). Това е доминиращата група и отразява добро функционално състояние.
- Група 2– умерени отклонения, индикиращи изразена умора или претоварване (211 записа; 22%).

• Група 3 – значителни отклонения от нормата, предполагащи повишен кардиоваскуларен риск (54 записа; 5.6%) и изискващи внимателна интерпретация.

Фигура 5.17 представя динамиката на RR-интервалите при един спортист в трите състояния. В покой (А) се наблюдава относително стабилна вариабилност, характерна за балансирана автономна регулация. Непосредствено след тренировка (В) се регистрират изразени флукутации и понижаване на RR-интервалите, отразяващи симпатикова активация и потиснат вагусов контрол. Два часа след натоварването (С) се установява частично възстановяване на вариабилността, без пълна нормализация на автономния тонус.



Фигура 5.17 RR интервали за един и същ състезател от Група 1: (А) преди тренировка, (В) след тренировка (С) 2-часово възстановяване.

Резултати за Група 1

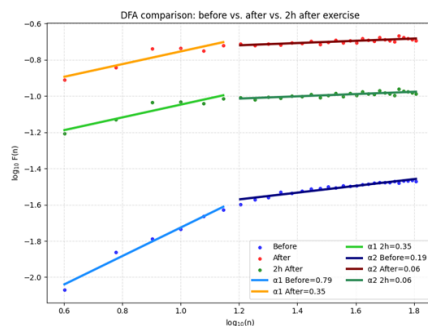
Получените резултати динамиката на HRV параметрите в трите състояния. Средният RR интервал намалява значимо след тренировка ($p < 0.001$), съответстващо на повишена сърдечна честота. Времевите индекси (SDNN, RMSSD) също се редуцират статистически значимо, отразявайки потиснатата парасимпатикова активност. В рамките на 2-часовото възстановяване се наблюдава частична нормализация. Спектралният анализ показва увеличение на nLF и редукция на nHF непосредствено след натоварване, което свидетелства за симпатиково доминиране.

Нелинейните показатели ($SD1$, $SD2$, $SD2/SD1$, Hurst, DFA α_1 , α_2 , SampEn) демонстрират понижена сложност и адаптивност веднага след тренировка, с частично възстановяване след два часа (всички $p < 0.05$).

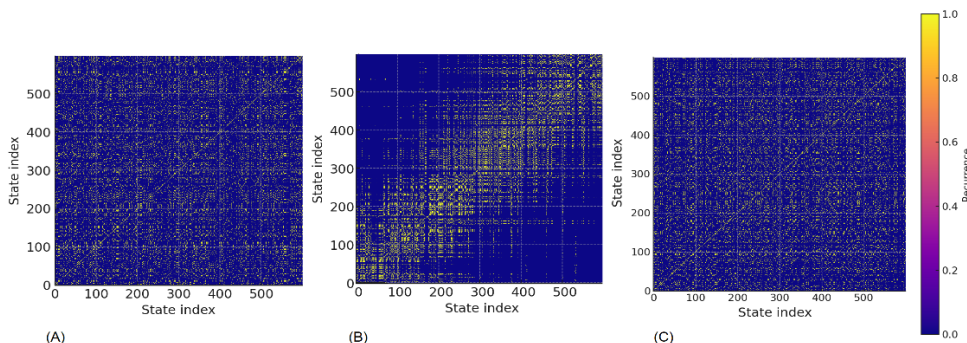
ANOVA с повторни измервания потвърждава значими различия между трите състояния за всички индекси ($p < 0.05$).

Фигура 5.18 илюстрира динамиката на DFA. Преди тренировка $\alpha_1 = 0.79$ и $\alpha_2 = 0.06$, което съответства на относително балансирана краткосрочна структура. Непосредствено след натоварване α_1 намалява до 0.06, докато α_2 се увеличава до 0.19, което отразява нарушена краткосрочна автокорелация и преход към по-детерминистична динамика. Два часа по-късно $\alpha_1 = 0.35$ и $\alpha_2 = 0.26$, което показва частично възстановяване, без пълна нормализация.

Recurrence Plot анализът (Фигура 5.19) потвърждава тези изменения. В покой се наблюдава разпръснатата и хетерогенна структура, характерна за сложна динамика. След тренировка се появяват по-концентрирани и организирани рекурентни области, свидетелстващи за повишена детерминираност и намалена вариабилност. След 2 часа структурата частично се възстановява, но остава редуцирана спрямо изходното състояние.



Фигура 5.18 DFA за трите изследвани състояния [D5-2].



Фигура 5.19 Recurrence Plot за един и същ състезател: (A) преди тренировка, (B) след тренировка, (C) 2-часово възстановяване (адаптивни спортисти) [D5-2].

Резултатите (Таблица 5.8) показват, че след тренировка индексите DET, LAM и TT се увеличават значително, което показва по-структурирана и предвидима динамика на физиологичните сигнали. Намалването на ентропията отразява намалена сложност и по-ниска вариабилност, вероятно поради повишен симпатиков контрол и умора. За спортистите това означава, че след интензивно натоварване има временно намаляване на адаптивността, което изисква адекватно възстановяване преди следващото усилие. В Група 1, големите размери на ефектите за DET, LAM и Entropy показват изразено увеличение на нормалността на сигнала след обучение с намалена сложност, частично нормализиращо се след 2 часа, докато REC не показва значима промяна.

Таблица 5.8 RQA показатели на 3-те физиологични състояния за Група 1 [D5-2].

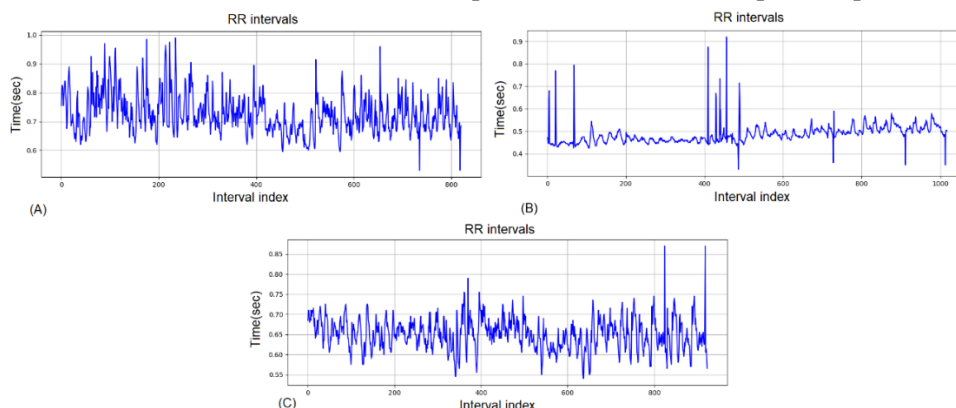
Параметър	Pre-Training		Post-Training		2-h		p Value Pre/Post/2-h (ANOVA)	BonferroEffect ni adj. p Size (η^2)	
	n = 695 [mean \pm std]	Pre 95% CI	n = 695 [mean \pm std]	Post 95%CI	n = 695 [mean \pm std]	2-h 95%CI			
REC (%)	15.98 \pm 6.64	[15.5–16.5]	16.2 \pm 3.09	[16.0–16.4]	16.1 \pm 5.21	[15.7–16.5]	NS ¹	NS	0.01
DET (%)	29.80 \pm 8.02	[29.2–30.4]	60.91 \pm 23.04	[59.2–62.6]	49.55 \pm 18.83	[48.1–51.0]	<0.01	0.0120	0.48
LAM (%)	36.37 \pm 11.06	[35.6–37.1]	74.26 \pm 21.35	[73.3–75.2]	58.23 \pm 12.97	[57.3–59.2]	<0.01	0.0080	0.52
TT	2.33 \pm 0.73	[2.28–2.38]	3.07 \pm 0.19	[3.06–3.08]	2.91 \pm 0.82	[2.90–2.92]	<0.05	0.0200	0.22
Entropy	4.62 \pm 0.32	[4.60–4.64]	3.81 \pm 0.24	[3.80–3.82]	4.35 \pm 0.29	[4.34–4.36]	<0.001	0.0025	0.5

¹NS – незначима стойност.

Резултати за Група 2 (умерена умора)

Фигура 5.20 илюстрира динамиката на RR-интервалите при уморен спортист в трите състояния. Още преди тренировка се наблюдава повишена вариабилност и по-ниска стабилност спрямо Група 1, което предполага натрупана умора. Непосредствено след натоварването RR-интервалите се скъсват значително и демонстрират неправилна вариабилност, съответстваща на

изразено симпатиково доминиране. Два часа по-късно се отчита частично възстановяване, но вариабилността остава потисната, което индикира непълна автономна реинтеграция.



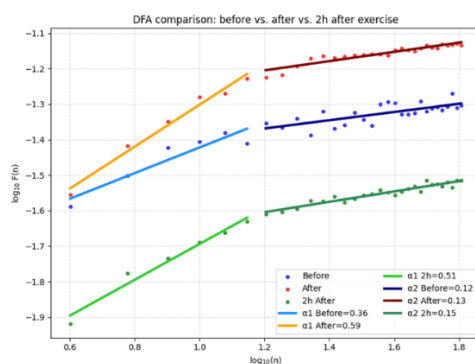
Фигура 5.20 RR интервали за един и същ състезател от Група 2: (А) преди тренировка, (В) след тренировка, (С) 2-часово възстановяване [D5-2].

Количественият анализ потвърждава задълбочен вегетативен дисбаланс. Mean RR и RMSSD намаляват значимо след тренировка ($p < 0.001$), с големи размери на ефекта ($\eta^2 \approx 0.5-0.6$). DFA $\alpha 1$ и SampEn показват редуциране, което отразява загуба на краткосрочна фрактална организация.

Спектралните индекси (nLF, nHF, LF/HF) демонстрират статистически значими, но по-малки ефекти ($\eta^2 < 0.12$), което подсказва по-висока чувствителност на нелинейните показатели към състояния на дезадаптация.

DFA анализът (Фигура 5.21) показва различен възстановителен профил спрямо Група 1. Предтренировъчните стойности на $\alpha 1$ са вече редуцирани, а след натоварване спадат допълнително, докато $\alpha 2$ демонстрира ограничена компенсаторна реакция. Частичното възстановяване на $\alpha 1$ след 2 часа остава под базовото ниво, което е индикатор за персистираща краткосрочна дезорганизация на автономната регулация.

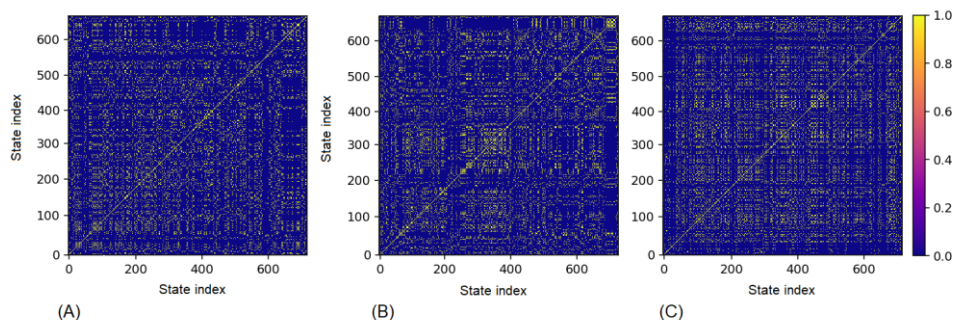
Recurrence Plot анализът (Фигура 5.22) потвърждава тези наблюдения. Преди тренировка се регистрират по-плътни и организирани структури, предполагащи намалена комплексност. След натоварване се формират удължени диагонални и вертикални линии, характерни за повишена детерминистичност и ламинарност.



Фигура 5.21 DFA за трите изследвани условия [D5-2].

RQA показателите (Таблица 5.10) демонстрират високи DET и LAM още преди натоварването, с допълнително увеличение след него ($\eta^2 \approx 0.46-0.50$) и намалена ентропия ($\eta^2 \approx 0.31$). Това отразява по-структурирана, но по-малко адаптивна динамика. Възстановяването е частично и остава под нивата, характерни за отпочиналите спортисти.

Обобщено, Група 2 се характеризира с изразена автономна дезадаптация, по-бавно възстановяване и по-висока чувствителност на нелинейните и рекурентни показатели спрямо класическите спектрални индекси.




Фигура 5.22 Recurrence Plot за един и същ състезател: (A) преди тренировка, (B) след тренировка (C) 2-часово възстановяване (уморени спортисти) [D5-2].

Таблица 5.10 RQA показатели на 3-те физиологични състояния за Група 2 [D5-2].

Параметър P	Pre-Training n = 211 [mean ± std]	Pre 95%CI	Post-Training n = 211 [mean ± std]	Post 95%CI	2-h Recovery n = 211 [mean ± std]	2-h 95%CI	p value Pre/Post/ 2-h (ANOVA)	Holm- Bonferroni adj. p	Effect Size (η^2)
REC (%)	15.20 ± 6.10	[14.4–16.0]	15.8 ± 3.05	[15.4–16.2]	15.6 ± 5.10	[14.9–16.3]	NS	NS	0.01
DET (%)	31.50 ± 8.30	[30.4–32.6]	58.40 ± 22.50	[55.3–61.5]	47.20 ± 18.10	[44.7–49.7]	<0.001	0.0210	0.46
LAM (%)	38.10 ± 10.90	[36.7–39.5]	72.10 ± 20.85	[70.3–73.9]	56.40 ± 12.80	[54.7–58.1]	<0.001	0.0160	0.5
TT	2.40 ± 0.70	[2.31–2.49]	3.00 ± 0.20	[2.94–3.06]	2.85 ± 0.80	[2.74–2.96]	<0.01	0.0084	0.24
Entropy	4.38 ± 0.30	[4.34–4.42]	3.85 ± 0.23	[3.82–3.88]	4.12 ± 0.28	[4.08–4.16]	<0.01	0.0200	0.31


Резултати за Група 3 (група на изключенията)

RR-сериите (Фигура 5.23) демонстрират потисната вариабилност още преди натоварването. Във фазата на 2-часово възстановяване се наблюдават епизоди на нестабилен ритъм (остри пикове и спадове), последвани от стеснена вариабилност – профил, съвместим с автономна дисрегулация и повишен функционален риск. Количествените данни потвърждават тежка вегетативна дезадаптация. Още преди тренировка RMSSD, SDNN и nHF са по-ниски, а LF/HF – по-високо спрямо останалите групи, което показва непълно възстановяване. След натоварване HR остава повишена, а вариабилността се редуцира значимо ($p < 0.001$). Най-големи размери на ефекта се наблюдават при нелинейните показатели – DFA $\alpha 1$ ($\eta^2 = 0.78$) и SampEn ($\eta^2 = 0.86$), което подчертава дълбоки изменения в комплексността на регулацията. Възстановяването след 2 часа е частично и статистически несъществено спрямо посттренировъчните стойности при повечето RQA показатели.




Фигура 5.23 RR интервали за един и същ спортист от Група 3: (A) преди тренировка, (B) след тренировка (C) 2-часово възстановяване [D5-2].

DFA анализът (Фигура 5.24) показва отчетливо намаление на $\alpha 1$ и $\alpha 2$ след натоварване, без пълна нормализация във фазата на възстановяване – индикация за персистиращ сърдечно-съдов стрес. Recurrence Plot (Фигура 5.25) разкрива атипични, фрагментирани и силно организирани структури още преди натоварване, които се засилват след тренировка и не се нормализират след 2 часа. Повишените DET, LAM и TT при намалена ентропия ($\eta^2 = 0.31\text{--}0.48$; Таблица 5.12) свидетелстват за патологично увеличена детерминистичност и автономна ригидност.



Фигура 5.24 DFA за умора и стрес [D5-2].



Фигура 5.25 Recurrence Plot за умора и стрес: (A) преди тренировка, (B) след тренировка (C) 2-часово възстановяване [D5-2].

Таблица 5.12 Показатели за RQA преди и след тренировка за състезатели от Група 3 [D5-2].

Параметър	Pre-Training n = 54		Post-Training n = 54		2-h Recovery n = 54		p Value Pre/Post (t Test)	Holm- Bonferro ni adj. p	p Value Post /2-h (t Test)	Effect Size (η^2)
	mean \pm std]	Pre 95%CI	mean \pm std]	Post 95%CI	mean \pm std]	2-h 95%CI				
REC (%)	18.50 \pm 5.90	[16.89–20.11]	19.10 \pm 3.20	[18.23–19.97]	19.00 \pm 3.15	[18.14–19.86]	NS	NS	NS	0.01
DET (%)	45.20 \pm 12.50	[41.79–48.61]	72.80 \pm 21.90	[66.89–78.71]	71.50 \pm 21.30	[65.72–77.28]	<0.01	0.016	NS	0.42
LAM (%)	55.10 \pm 14.30	[51.20–59.00]	85.40 \pm 15.80	[81.10–89.70]	84.20 \pm 15.60	[80.92–87.48]	<0.01	0.018	NS	0.48
TT	2.85 \pm 0.65	[2.67–3.03]	3.25 \pm 0.22	[3.15–3.35]	3.21 \pm 0.24	[3.15–3.27]	<0.01	0.010	NS	0.31
Entropy	3.95 \pm 0.28	[3.87–4.03]	3.60 \pm 0.20	[3.54–3.66]	3.62 \pm 0.21	[3.56–3.68]	<0.01	0.018	NS	0.36

Практически последици

Резултатите показват, че HRV мониторингът позволява ясно разграничаване между адаптивни, неадаптивни и потенциално рискови реакции към натоварване.

Група 1 възстановява HRV комплексността в рамките на 2 часа, което предполага, че стандартните възстановителни протоколи са достатъчни.

Група 2 демонстрира персистиращо потискане на нелинейните показатели, което изисква индивидуализирано намаляване на натоварването и удължено възстановяване.

Група 3 показва атипична HRV динамика и PVC, което налага медицинска оценка, а не само тренировъчни корекции.

Включването на нелинейни показатели (DFA $\alpha 1$, SampEn, RQA) в рутинния мониторинг предоставя чувствителни маркери за персонализиране на тренировките и ранно откриване на риск.

Въпреки ограниченията (малка извадка, липса на контролна група), проучването подчертава потенциала на интегрирания HRV анализ като инструмент за по-безопасно и ефективно управление на тренировъчния процес

5.4 Методологичен подход за сравнителен HRV анализ на автономната регулация при НИТ и обемна тренировка

Различните тренировъчни режими предизвикват специфични адаптивни реакции в автономната нервна система, които могат да бъдат количествено оценени чрез HRV. Високоинтензивните интервални тренировки (НИТ) обикновено са свързани с остър симпатиков стрес и забавено възстановяване, докато традиционните обемно-ориентирани тренировки обикновено водят до по-умерени, но по-постепенни автономни адаптации.

В този контекст настоящото изследване [D5-3] предлага **сравнителен аналитичен методологичен подход**, чрез който се изследват динамиката на автономната регулация и възстановяването след тренировка при два фундаментално различни тренировъчни режима (НИТ и обемна тренировка), чрез стандартизирани HRV показатели във времевата и честотната област.

Целта на подхода е **да се оцени както острият ефект от тренировката, така и краткосрочната фаза на възстановяване**, като се анализира взаимодействието между типа тренировъчно натоварване (НИТ срещу обемна тренировка); времевата динамика (преди тренировка, веднага след тренировка и два часа след натоварването).

5.4.1 Теоретична основа и формална постановка

Нека HRV параметрите на даден спортист се представят като вектор:

$$h_{i,g,t} = [RMSSD, SDNN, LF, HF, LF/HF]^T, \text{ където:}$$

$i = 1, \dots, N$ е индекс на участника;

$g \in \{HIIT, VOL\}$ обозначава тренировъчната група;

$t \in \{pre, post, rec\}$ - времевата точка (преди, веднага след и 2 часа след тренировка).

Сравнителният анализ има за цел да оцени главния ефект на времето върху HRV параметрите; главния ефект на тренировъчния режим; взаимодействието време \times режим, която отразява различията в автономната адаптация и възстановяване.

Формално това се моделира чрез **двухфакторен ANOVA с повторни измервания (2 \times 3 дизайн)**, като зависимите променливи са отделните HRV показатели.

Изследвана популация и дизайн


Експерименталното проучване [D5-3] е проведено върху 10 минутни холтерни записи на двадесет и четирима спортисти борци по свободен стил (мъже: 100%; възраст: 22.4 ± 2.3 години; телесна маса: 78.6 ± 6.8 кг; ръст: 176.5 ± 5.9 см).

И двете групи поддържат еднакво общо седмично тренировъчно време (~10 часа/седмица), но се различават по разпределението на интензивността. Изследването е рандомизирано контролирано проучване с две паралелни групи (високоинтензивна интервална тренировка и обемна (за постигане на издръжливост) тренировка), като участниците са рандомизирани чрез компютърно генериран списък. За да се сведе до минимум потенциалният дисбаланс между групите, е приложена стратифицирана рандомизация според състезателната категория (67, 72 и 77 кг) и годините състезателен опит (>8 години за всички участници). Във всяка стратификация борците са разпределени в НИТ или обемна група в съотношение 1:1, използвайки блокова рандомизация (размер на блока = 4). Тази процедура осигурява сравнимо разпределение на групите.

Експериментални резултати

Общо 720 записа са анализирани за всяко състояние (преди тренировка, след и 2-часа след тренировка).

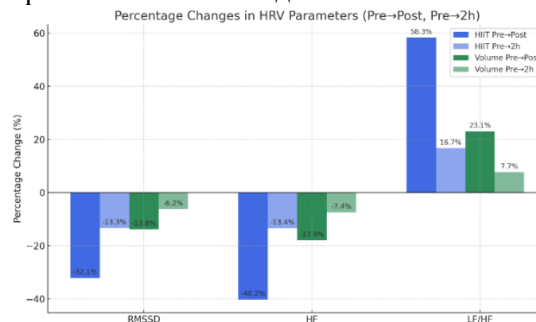
За илюстриране на индивидуалната автономна динамика, фигура 5.27 представя хистограми на RR интервала на един и същи борец. Разпределението се измества към по-къси интервали веднага след тренировка, последвано от частично възстановяване на 2-ия час, което отразява острата симпатикова активация и последващото парасимпатиково възстановяване.



Фигура 5.27 Хистограми на RR интервалите на един и същ спортист (А) преди, (В) след и (С) 2 часа след края на тренировката [D5-3].

Резултатите показват, че НИПТ тренировките предизвикват по-голям ефект върху параметрите на HRV, характеризиращ се със значително намаляване на парасимпатиковата активност, увеличаване на симпатиковото доминиране и само частично възстановяване в рамките на два часа. Размерите на ефекта (d на Cohen) допълнително подкрепят, че тези промени са по-изразени в НИПТ групата в сравнение с групата с обем.

За допълнително илюстриране на разликите между тренировъчните методи, процентните промени в ключовите параметри на HRV (RMSSD, HF, LF/HF) са изчислени и за двете групи (НИПТ и Volume) веднага след тренировката и 2 часа след началото на възстановяването (Фигура 5.28).



Фигура 5.28 Процентни промени (средно \pm SD) в RMSSD, HF и LF/HF в групите НИПТ и Volume, изчислени спрямо стойностите преди тренировка [D5-3].

Сравнението на процентните промени в HRV параметрите разкри добре различаващи се модели на автономен отговор между двете групи. В групата НИПТ RMSSD намалява с 32.0% непосредствено след тренировка и остава 13.3% под изходното ниво след 2 часа, докато в групата Volume спадът е по-умерен (13.8% и 6.2%). Аналогично, HF мощността намалява с 40.2% след НИПТ (възстановяване до 13.4% след 2 часа), спрямо 17.9% и 7.4% при Volume. Съотношението LF/HF се увеличава значително повече при НИПТ (58.3%) в сравнение с Volume (23.1%), с частична нормализация след 2 часа (16.7% срещу 7.7%). Тези данни потвърждават, че НИПТ индуцира по-изразено вагусово отдръпване и по-силен симпатовагален дисбаланс, като автономното възстановяване остава непълно в рамките на двучасовия прозорец. За разлика от това, обемната тренировка предизвиква по-умерени и по-бързо обратими промени.

5.5 Адаптивен многоиндексен метод за откриване и сигнализиране на физиологичен риск

5.5.1 Теоретична рамка и концептуален модел

Разработен е адаптивен многоиндексен метод за автоматично откриване и сигнализиране на физиологичен риск [D5-4], реализиран като хибридна система за поточен анализ и правило-базирано вземане на решения. Методът е проектиран за реалновременна работа и е приложим в носими устройства, edge-системи и HRV-базирани дигитални близнаци.

Предварителна обработка и поточен анализ. RR/PP интервалите се интерполират до 4 Hz и се подлагат на детрендиране и филтрация на нискочестотни и високочестотни шумови компоненти. За осигуряване на надеждност се въвежда индекс за качество на сигнала (SQI), дефиниран като отношение между броя на валидните интервали и общия брой интервали в прозореца. Прозорци със SQI < 0.7 при ECG и SQI < 0.8 при PPG се изключват от анализа. Това гарантира устойчивост на метода при реални условия и предотвратява натрупване на грешки в последващия HRV анализ.

Многоиндексна HRV характеристика и персонализирана нормализация

Във всеки прозорец се изчислява набор от времеви (mean RR, SDNN, RMSSD, pNN50), спектрални (LF, HF, LF/HF чрез Welch или AR модел), и нелинейни показатели (Poincaré SD1/SD2, DFA $\alpha1/\alpha2$, Hurst, Sample Entropy).

За елиминиране на междуиндивидуалните различия се прилага персонализирана z-нормализация:

$$Z_x = \frac{x - \mu_x}{\sigma_x}, \quad (5.4)$$

където μ_x и σ_x са средната стойност и стандартното отклонение на показателя в базовото физиологично състояние. Този подход позволява унифицирана интерпретация на риска.

Правило-базирана логика и обобщена оценка на риска

Дефинирани са четири флага (P1–P4), отразяващи характерни рискови модели:

Флаг P1 (потисната вариабилност), активира се при:

$$z_{SDNN} < -1.5 \text{ OR } z_{SDNN} < -1.5. \quad (5.5)$$

Флаг P2 (автономен дисбаланс), активира се при:

$$\frac{z_{LF}}{z_{HF}} > 1.5 \text{ OR } (LF/HF > 2.5 \text{ AND } z_{HF} < -1). \quad (5.6)$$

Флаг P3 (загуба на фрактална структура), задейства се при:

$$z_{\alpha1} > 1.0 \text{ OR } z_{SampleEn} < 1.0 \text{ (support } z_{RMSSD} < -1). \quad (5.7)$$

Флаг P4 (тахикардия в покой), сигнализира при:

$$z_{HR} > 15 \text{ for } \geq 30 \text{ s}. \quad (5.8)$$

Флаговете се комбинират в обобщена правило-базирана оценка, показваща общото ниво на физиологичен риск в даден прозорец:

$$R_{rule} = clip(0.35 \cdot 1\{P_1\} + 0.3 \cdot 1\{P_2\} + 0.25 \cdot 1\{P_3\} + 0.35 \cdot 1\{P_{41}\}), \quad (5.9)$$

чиято стойност е в интервала [0,1].

Алармата се активира при $R > 0.6$ в два последователни прозореца и се деактивира при $R < 0.4$ за ≥ 60 s, което намалява фалшивите сработвания и осигурява стабилност при динамични сигнали.

В таблица 5.14 е представена оценката на алармения модул при високорискови параметри [D5-4].

Таблица 5.14 Ефективност на алармения модул [D5-4]

Метрика	Стойност
Чувствителност (Sensitivity, Se)	91.8 %
Специфичност (Specificity, Sp)	89.6 %
Позитивна предиктивна стойност (PPV)	87.3 %
Негативна предиктивна стойност (NPV)	93.4 %
Средна латентност на аларма	120 ms
Средно CPU натоварване (edge)	28 %
RAM използване (edge)	7 MB

Резултатите в Таблица 5.14 показват, че аларменият модул постига висока чувствителност (91.8%) и специфичност (89.6%), което показва надеждно откриване на високорискови HRV състояния с нисък процент на фалшиво положителни резултати. Положителната прогностична

стойност (87.3%) и отрицателната прогностична стойност (93.4%) потвърждават стабилността на класификацията. Въпреки непрекъснатата си работа на периферен хардуер, модулът поддържа ниска средна латентност (120 ms), позволяваща реалновременна реакция и ниско изчислително натоварване (28% CPU; 7 MB RAM), подходящо за edge и преносими устройства.

5.6 Дигитален близък на варибилността на сърдечната честота: концепция, архитектура и интегрални индекси

5.6.1. Концепция за дигитален близък на HRV

В настоящото изследване се въвежда концепцията за **дигитален близък на варибилността на сърдечната честота (HRV Digital Twin)** [D5-5] като нов тип персонализиран физиологичен модел, фокусиран върху автономната регулация на сърдечния ритъм.

HRV Digital Twin се дефинира като персонализиран, динамично адаптиращ се виртуален модел, който в реално време отразява, интерпретира и прогнозира автономното състояние на конкретен индивид чрез непрекъснат анализ на HRV. Моделът използва непрекъснат поток от RR/PP интервали (ECG/PPG), времеви, спектрални и нелинейни HRV показатели (SDNN, RMSSD, LF/HF, DFA α_1/α_2 , ентропийни мерки), както и допълнителен контекст (физическа активност, сън, натоварване), получен от преносими устройства.

За разлика от класическите кардиологични цифрови близъци, които моделират анатомични, електрофизиологични или хемодинамични процеси, предложеният HRV Digital Twin поставя автономната регулация като централна състояние-променлива на модела. В този смисъл HRV не се третира като вторичен биомаркер, а като основен динамичен параметър, описващ адаптивността, регулаторния резерв и физиологичната устойчивост на организма.

Предложеният дигитален близък има три ключови функции:

- Описателна – текущо количествено представяне на автономното състояние;
- Диагностична – откриване на отклонения, умора и предрискови режими;
- Прогностична – оценка на кратко- и средносрочни траектории на възстановяване и адаптация.

По този начин HRV Digital Twin представлява интегрална рамка, обединяваща измерване, анализ, интерпретация и прогнозиране в единен персонализиран модел.

Архитектурна и IoT реализация на HRV Digital Twin

Архитектурната реализация на HRV Digital Twin е базирана на IoT многослойна структура, състояща се от сензорно, edge и облачно ниво. Всеки сензорен възел включва биомедицински сензор (ECG или PPG), аналогово-цифров преобразувател, микропроцесорен модул за предварителна обработка и комуникационен интерфейс (BLE/Wi-Fi). Възелът регистрира сигнала в реално време, извършва първична филтрация и детекция на върхове и генерира RR/PP интервални серии.

5.6.2 Архитектура на HRV Digital Twin

Предложеният HRV Digital Twin е реализиран като модулна и мащабируема архитектура, интегрираща сензорни данни, персонализирана базова линия и интелигентен прогностичен модул.

Основни архитектурни компоненти:

- Данни от носими устройства (ECG patches, смарт часовници, PPG сензори) – RR интервали, HRV показатели, амплитуда на пулсовия сигнал, активност, сън.
- Персонална базова линия – индивидуални стойности на HRV (SDNN, RMSSD, LF/HF, фрактални/ентропийни показатели), определени при покой и различни натоварвания.
- Модул за моделиране и прогнозиране – хибриден AI модел (wavelet + CNN-LSTM или друг интерпретируем модел), който учи динамиката на HRV и предсказва бъдещи състояния.

Интегрални индекси на дигиталния близък

В рамките на HRV Digital Twin са въведени три композитни индекса [D5-5], [D5-6]:

Индекс за състояние – Fatigue Digital Twin Index (FDTI) за оценка на умора/стрес в реално време и

Индекс за оценка на темпа на възстановяване – Recovery Digital Twin Index (RDTI).

Прогностичен индекс – Predictive Digital Twin Index (PDTI) за прогнозиране на бъдещо състояние.

За всеки индивид се изгражда персонален HRV профил, включващ стойности при покой и различни нива на натоварване. Тази базова линия служи като референтна рамка за интерпретация на всички бъдещи състояния и формира аналитичното ядро на дигиталния близък.

Функционални възможности

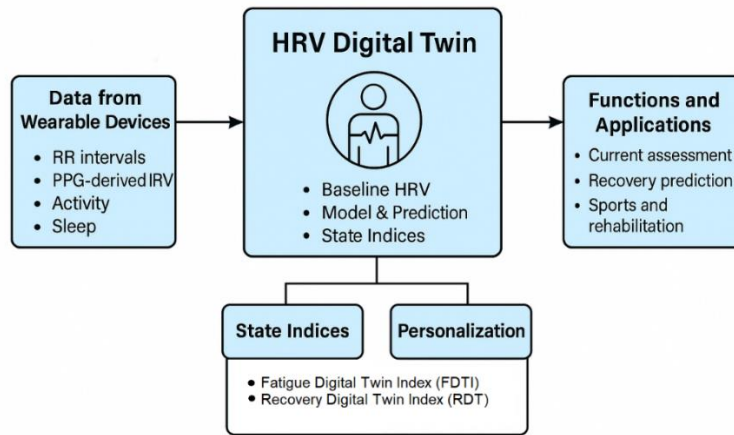
HRV Digital Twin осигурява:

- Моментна оценка на автономното състояние (чрез FDTI);
- Прогнозиране на възстановяване и адаптация (чрез RDTI);
- Симулации „какво ако“, позволяващи оценка на ефекта от натоварване, стрес или интервенция;
- Подкрепа за спортна периодизация, кардиорехабилитация и персонализиран мониторинг.

Концептуална значимост

За първи път HRV е дефинирана [D5-5] като централна основа на цифров близък, а не като периферен биомаркер. Предложената рамка интегрира измерване, персонализация, прогнозиране и интерпретируем анализ в единна кибер-физиологична система.

Фигура 5.35 представя потока на данни от носимите устройства към модула на дигиталния близък, персоналната базова линия и прогностичните индекси, както и визуализацията към потребителя или медицинския специалист.



Фигура 5.35 Архитектура на предложението HRV Digital Twin [D5-5]

Общото представяне на въведените индекси е обобщено в таблица 5.16 [D5-5].

Таблица 5.16 Основни характеристики на интегралните индекси

Индекс	Времева скала	Основни входове	Очаквана посока
FDTI (умора/стрес)	0–2 h след натоварване (прозорци 60–120 s)	↓SDNN, ↓RMSSD, ↑LF/HF, ↑DFA α_1 (или специфична промяна), ↓SampEn, ↑ΔHR, ↓PPG амплитуда, ↑вариабилност на PPG, ↓PTT	По-висок FDTI ⇒ по-висока остра умора
RDTI (възстановяване)	2–24 h (агрегати* на 5–30 min + траектории)	Тренд към базови: ↑SDNN, ↑RMSSD, LF/HF → rest зона, SampEn/MSE ↑, стабилизиране на PPG амплитуда, PTT → базово; нощен RMSSD ↑	По-висок RDTI ⇒ по-завършено възстановяване
PDTI (прогноза)	Дни–седмици (дългосрочна динамика; дневни/многодневни агрегати)	$SD2_t/SD2_{pre}$, H_t/H_{pre} , $SampEn_t/SampEn_{pre}$, $DFA \alpha_{2pre}/\alpha_{2t}$	По-висок PDTI ⇒ по-добра автономна адаптация; ниски стойности ⇒ риск от претрениране

* времево обобщени представяния на HRV показатели

Дефиниране на индекса **Fatigue Digital Twin Index**

За да се осигури количествена и персонализирана оценка на умората и стреса в реално време, в рамките на предложения HRV Digital Twin [D5-5] е разработен FDTI. Индексът интегрира времеви, спектрални, фрактални, ентропийни и пулсови характеристики, извлечени след хибридна уейвлет–невронна обработка.

Формална дефиниция. FDTI се дефинира като претеглена линейна комбинация от K стандартизирани характеристики $f_k(t)$:

$$FDTI(t) = \sum_{k=1}^K w_k \frac{f_k(t) - \mu_k}{\sigma_k}, \quad (5.10)$$

където $f_k(t)$ са времевите редове на избраните HRV характеристики (SDNN, RMSSD, LF/HF, DFA α , ентропийни показатели, енергии на уейвлет коефициенти и др.);

μ_k и σ_k са средната стойност и стандартното отклонение на характеристиката за съответния индивид в покой (персонална базова линия);

w_k са теглата, определени чрез обучение върху референтна кохорта и впоследствие адаптирани към конкретния индивид чрез on-device incremental learning.

Индивидуализирани тегла

Вместо универсални тегла, за всеки индивид могат да се изчисляват персонални коефициенти:

$$FDTI^i(t) = \sum_{k=1}^K w_k^i \cdot z_{k,s}^i \quad (5.21)$$

където w_k^i са персонални тегла на i -я индивид, а $z_{k,s}^i$ – нормализирани признаци на i -я индивид.

Дефиниране на индекса на възстановяване (RDTI) [D5-6]

RDTI е разработен като количествена мярка за оценка на краткосрочното автономно възстановяване (2 h след натоварване). По-високи стойности на индекса отразяват по-пълно възстановяване на симпатовагалия баланс и регулаторната сложност.

Предложената формула е [D5-6] :

$$RDTI = w_1 \frac{SDNN_{2h}}{SDNN_{pre}} + w_2 \frac{RMSSD_{2h}}{RMSSD_{pre}} + w_3 \frac{nHF_{2h}}{nHF_{pre}} + w_4 \frac{SD1_{2h}}{SD1_{pre}} + w_5 \frac{SampleN_{2h}}{SampleN_{pre}} + w_6 \frac{DFA\alpha_{2pre}}{DFA\alpha_{2h}} \quad (5.22)$$

където w_i – тегловни коефициенти, удовлетворяващи $\sum w_i = 1$.

Дефиниране на Прогностичен индекс (PDTI)

PDTI е разработен за оценка на средно- и дългосрочната автономна адаптация (дни–седмици).

Индексът интегрира структурната стабилност, сложността и фракталната динамика на HRV [D5-6]:

$$PDTI = w_{p1} \frac{SD2_t}{SD2_{pre}} + w_{p2} \frac{H_t}{H_{pre}} + w_{p3} \frac{SampleN_t}{SampleN_{pre}} + w_{p4} \frac{DFA\alpha_{2pre}}{DFA\alpha_{2t}} \quad (5.23)$$

Обосновка на използването на включените параметри:

$\frac{SD2_t}{SD2_{pre}}$ – улавя дългосрочната компонента на варибилността и общия резерв на автономната регулация, така че нарастването му във времето е маркер за системно възстановяване и устойчивост.

$\frac{H_t}{H_{pre}}$ – характеризира степента на дългосрочна зависимост/самоподобност; стабилизирани или покачващи се H показва по-устойчива и предвидима динамика на сърдечния ритъм в дни/седмици.

$\frac{SampleN_t}{SampleN_{pre}}$ – измерва ритмичната комплексност и адаптивност; възстановяването/увеличението на ентропията отразява по-гъвкава автономна система и по-добра способност за справяне с тренинг стрес.


$\frac{DFA\alpha_2_{pre}}{DFA\alpha_2_t}$ – индексира дългосрочните фрактални корелации; намалението на α_2 (което води до по-голямо отношение pre/t) показва редукция на фракталната ригидност (намалена способност на биологичната система да променя своята динамика, на адаптивност в самоподобие на сигнала) и преминаване към по-адаптивен контрол, което е прогностично благоприятно. Високи стойности на PDTI (>1.2) отразяват ефективна адаптация и подобрен автономен контрол, докато стойности под 0.6 сигнализират риск от натрупана умора или претрениране.

Интерпретация

Резултатите демонстрират, че FDTI:

- диференцира ясно степента на остра умора между отделните спортисти;
- улавя динамиката на възстановяване в рамките на 2 часа;
- позволява както индивидуален, така и групов анализ.

Наблюдаваната редукция на индекса във времето потвърждава чувствителността му към автономната реадaptация и валидира приложимостта му като компонент на HRV Digital Twin.



А) Непосредствено след тренировка Б) Два часа след тренировка

Фигура 5.36 Heatmap диаграма на относителните промени на параметрите [D5-5]

Таблица 5.23 показва, че повечето показатели демонстрират изключително силна положителна корелация с FDTI индекса ($r > 0.93$, $p < 0.01$), което потвърждава, че индексът успешно улавя физиологичните промени, свързани с умора, стрес и автономен дисбаланс. Корелациите остават високи както непосредствено след тренировка, така и 2 часа по-късно, което показва стабилност на зависимостта във времето и чувствителност на FDTI към динамиката на възстановяване. Най-силната връзка се наблюдава за 1/RMSSD и 1/SD1 ($r \approx 0.98$), което подчертава централната роля на краткосрочната парасимпатикова модуляция в индекса. Единствено 1/SampEn показва слаба и статистически незначима корелация, което предполага, че ентропийните характеристики допринасят по-слабо за моментната оценка на умора чрез FDTI.

Таблица 5.23 Pearson корелация между HRV параметрите и FDTI индекса [D5-5]


Параметър	r (Post-training), p	r (2 h Post-training), p
1/SDNN	$r = 0.802$, $p \approx 0.055$	$r = 0.765$, $p \approx 0.077$
1/RMSSD	$r = 0.980$, $p \approx 0.001$	$r = 0.960$, $p \approx 0.003$
LF/HF	$r = 0.967$, $p \approx 0.002$	$r = 0.950$, $p \approx 0.004$
1/SD1	$r = 0.980$, $p \approx 0.001$	$r = 0.960$, $p \approx 0.003$
SD2/SD1	$r = 0.946$, $p \approx 0.006$	$r = 0.934$, $p \approx 0.009$
DFA α_1	$r = 0.943$, $p \approx 0.006$	$r = 0.932$, $p \approx 0.010$
1/SampEn	$r = -0.395$, $p \approx 0.438$	$r = -0.360$, $p \approx 0.483$

Топлинната карта на фигура 5.40 визуализира относителните промени (2h/pre) на HRV параметрите и агрегиращия индекс RDTI. B1 и B2 – стойности над 0.8 при повечето параметри – добро, но непълно възстановяване. B3–B6 – стойности ≥ 1.0 при RMSSD, SD1 и nHF – ясно изразена

парасимпатикова реактивация. Най-изразени са подобренията при B4–B6, особено по RMSSD и SD1, което подчертава тяхната по-висока краткосрочна адаптивност.

RDTI следва същата тенденция като отделните линейни и нелинейни компоненти, което потвърждава, че индексът успешно синтезира мултидимензионалната информация в единен показател за възстановяване.

Фигура 5.41 потвърждава тенденцията към постепенна парасимпатикова реактивация, възстановяване на фракталната структура, повишаване на регулаторната сложност, достигане на оптимално автономно равновесие при повечето атлети след 5 седмици. Интерпретационни ориентири: $PDTI > 1.2$ сочи висока адаптация и устойчивост; $PDTI \approx 1.0$ показва стабилно автономно равновесие; $PDTI < 0.6–0.8$ сочи риск от натрупана умора или неадекватна адаптация.



Фигура 5.40 Топлинна карта на HRV и RDTI [D5-6]. **Фигура 5.41** Времева промяна на PDTI.

PDTI демонстрира способност да интегрира дългосрочни линейни и нелинейни характеристики на HRV; проследява индивидуалната адаптационна траектория; диференцира ефективната суперкомпенсация от стагнация; осигурява прогностична оценка в рамките на HRV Digital Twin.

Комбинираното използване на FDTI (остра умора), RDTI (краткосрочно възстановяване) и PDTI (дългосрочна адаптация) формира цялостна система за мониторинг и прогнозиране на автономната регулация, което представлява съществен принос към концепцията за интегрален HRV Digital Twin.

ЗАКЛЮЧЕНИЕ

Настоящият дисертационен труд разработва и формализира интегрална научна концепция за моделиране, анализ, симулация и защита на кардиологични сигнали, HRV в центъра на един системно обоснован изследователски подход.

HRV не се разглежда като набор от изолирани показатели, а е концептуализирана като динамична, нелинейна и фрактално организирана система, подлежаща на едновременно измерване, структурен анализ, прогнозиране и сигурна обработка.

Обхванат е пълен научен цикъл – от първичния биосигнал до адаптивния цифров модел. Разработени са методи за надеждна детекция и намаляване на смущенията на ECG и PPG сигнали, позволяващи устойчив HRV анализ в условия на шум и мобилна среда. Предложен е многоизмерен аналитичен подход, интегриращ времеви, спектрални, ентропийни, фрактални и рекурентни показатели в обща математическа рамка, която разкрива латентни физиологични режими и адаптивни процеси без предварително етикетиране.

Съществено научно постижение е формализирането на дигитален близък на варибилността на сърдечната честота – динамичен, персонализируем и развиващ се модел, който интегрира реални данни, аналитични индекси и прогностични механизми. Предложеният дигитален близък не е статично представяне, а адаптивна система, способна да отразява автономната регулация във времето и да подпомага вземането на решения в клиничен и спортен контекст.

Разработената хибридна симулационна концепция, съчетаваща параметрично, фрактално и генеративно моделиране, създава възможност за контролируемо възпроизвеждане на физиологична динамика и сценарии „какво ако“, което разширява границите на класическия експериментален анализ.

Особено значение има интеграцията на сигурността като вътрешно присъщ компонент на модела. Чрез регионално-осъзнат подход към защитата на кардиосигнали се постига баланс между поверителност, клинична валидност и аналитична използваемост – предпоставка за реална приложимост в телемедицина и IoT-базирани здравни системи.

В обобщение, дисертационният труд предлага концептуално завършена и интердисциплинарна научна рамка, която свързва математическо моделиране, изкуствен интелект, физиология и киберсигурност в единна платформа за анализ на кардиологични данни. Получените резултати разширяват теоретичните основи на HRV анализа и създават методологична база за развитие на интелигентни дигитални близнаци, персонализиран мониторинг и прогностични здравни технологии.

Бъдещото развитие на предложената концепция ще бъде насочено към разширяване на персонализираните модели, реализация в реално време, мултисензорна интеграция и клинична валидация в по-големи кохорти. Очаква се дигиталният близнак на HRV да се утвърди като ключов елемент в следващото поколение адаптивни, обясними и защитени интелигентни здравни системи.

Получените резултати, описани в дисертационния труд, са отразени в общо **25 научни публикации**, от **14 които в издания с IF или SJR** (6 с Q1, 2 с Q2, 4 с Q3 и 2 с Q4); 10 са представени на международни и национални научни конференции и 1 глава от монография. До момента са забелязани общо **70 цитирания** на публикациите по настоящия дисертационен труд, 51 от които в SCOPUS и 19 в други издания.

НАУЧНИ ПРИНОСИ

1. Разработен е оригинален хибриден AI метод за детекция на P-пикове в PPG сигнали, който интегрира уейвлет представяне, CNN–LSTM архитектура и механизъм за времево внимание. Въведена е нова комбинирана функция на загуба с времеви компонент за минимизиране на времево отклонение между реални и прогнозиранни върхове, което води до съществено повишаване на локализационната точност при шумови условия.
2. Предложен е нов хибриден симулационен модел GMF–Rössler, който за първи път интегрира Gaussian Mesa Functions за морфологията и хаотична динамика (Rössler атрактор) за варибилността на RR-интервалите, осигурявайки едновременно управление на формата и фракталната структура на кардиосигналите.
3. Разработен е хибриден параметрично-стохастичен модел за симулация на PPG сигнали, комбиниращ гаусово морфологично описание и ARIMA-базирана нестационарност, позволяващ контролируема генерация на физиологично правдоподобни краткосрочни и дългосрочни серии.
4. Въведена е интегрална концепция за HRV Digital Twin, при която варибилността на сърдечната честота се формализира като динамичен, персонализируем и адаптивен модел, обединяващ измерване, симулация, нелинеен анализ и прогностична оценка в единна рамка.

НАУЧНО-ПРИЛОЖНИ ПРИНОСИ

5. Разработен е интегриран метод за защита на кардиологични данни, комбиниращ уейвлет-домейн водно маркиране и хибридна AES–RSA криптография, осигуряващ поверителност, цялостност и диагностична съвместимост в IoT и телемедицински среди.
6. Предложена е методологична рамка за неконтролирано разпознаване на физиологични състояния чрез PCA, K-Means и DBSCAN, базирана на линейни, нелинейни и фрактални HRV показатели, позволяваща откриване на латентни групи и автономни аномалии без предварително етикетиране.

7. Създадени са три нови интегрални HRV индекса (FDTI, RDTI, PDTI), които обединяват времеви, спектрални, фрактални и ентропийни характеристики за оценка на умора, краткосрочно възстановяване и дългосрочна адаптация.
8. Разработен е многоиндексен, z-калибриран и правило-ориентиран алгоритъм за автоматично сигнализиране на предрискови и рискови физиологични състояния, валидиран при различни тренировъчни режими (HIIT и Volume) и приложим върху edge хардуер.

СПИСЪК НА ПУБЛИКАЦИИТЕ, В КОИТО СА ПРЕДСТАВЕНИ РЕЗУЛТАТИТЕ ПО ДИСЕРТАЦИОННИЯ ТРУД

- D1-1. **Georgieva-Tsaneva, G.**, Tsanev, Y.-A. Heart rate variability data PPG based analysis. *Complex Control Systems*, 7, IR-BAS, 2024, ISSN:2603-4697(online), 1-5
- D1-2. Gospodinova, E.; Lebamovski, P.; **Georgieva-Tsaneva, G.**; Negreva, M. Evaluation of the Methods for Nonlinear Analysis of Heart Rate Variability. *Fractal Fract.* 2023, 7, 388. **IF 5.4, Q1 (WoS)** <https://doi.org/10.3390/fractalfract7050388>
- D1-3 Tsanev, Y.-A., **Georgieva-Tsaneva, G.**, Miroslav Dechev. Study of Changes in the Fractality of Heart Rate Variability After Training in Athletes. *International Journal of Environmental Sciences*, 2025, vol. 11, No 25s, 376-383. <https://doi.org/10.64252/weyb7p84>. **SJR 0.166, Q3**
- D1-4 **Georgieva-Tsaneva, G.** Distinguishing States of Rest, Fatigue, and Stress in Athletes Using HRV Geometric and Entropic Measures. *Complex Control Systems*, 9, 2, IR-BAS, 2025, ISSN:2603-4697(online), 1-6
- D1-5 **Georgieva-Tsaneva, G.**; Cheshmedzhiev, K.; Tsanev, Y.-A.; Dechev, M.; Popovska, E. Healthcare Monitoring Using an Internet of Things-Based Cardio System. *IoT* **2025**, 6, 10. **SJR 0.628, Q1**, <https://doi.org/10.3390/iot6010010>
- D2-1 **Georgieva-Tsaneva, G.** A Novel Photoplethysmographic Noise Removal Method via Wavelet Transform to Effective preprocessing. *Proceedings of the 23rd International Conference on Computer Systems and Technologies, CompSysTech, 2022*, ISBN:978-1-4503-9644-8, DOI:10.1145/3546118.3546145, 113-118. **SJR (Scopus):0.209, Q4**
- D2-2 **Georgieva-Tsaneva, G.**, Gospodinova, E., Cheshmedzhiev, K. Cardiodiagnostics Based on Photoplethysmographic Signals. *Diagnostics*, 12, 2, Multidisciplinary Digital Publishing Institute (MDPI), 2022, ISSN:E-2075-4418, DOI:10.3390/diagnostics12020412, 1-21. **SJR (Scopus):0.66, JCR-IF (Web of Science):3.992, Q2**
- D2-3 **Georgieva-Tsaneva, G.**, Tsanev, Y.-A. Investigating the Application of Wavelet Basis for HRV Determining. *Complex Control Systems*, 7, IR-BAS, 2024, ISSN:2603-4697(online), 1-6
- D2-4 **Georgieva-Tsaneva, G.**, Cheshmedzhiev, K, Lebamovski, P. A Wavelet Based Hybrid Method for Time Interval Series Determining. *CompSysTech '24: Proceedings of the International Conference on Computer Systems and Technologies 2024, ACM International Conference Proceeding Series*, 2024, ISBN:978-3-031-42134-1, DOI:10.1145/3674912.3674913, 137-142. **SJR (Scopus):0.191, Q3**
- D2-5 **Georgieva-Tsaneva, G.** Improved PPG Peak Detection Using a Hybrid DWT-CNN-LSTM Architecture with a Temporal Attention Mechanism. *Computation* 2025, 13, 273. <https://doi.org/10.3390/computation13120273>, **SJR 0.437, Q1**
- D3-1 **Georgieva-Tsaneva, G.** Simulation of long-term Heart Rate Variability records with Gaussian distribution functions. *CompSysTech '21: Proceedings of the 22st International Conference on Computer Systems and Technologies '20, ACM International Conference Proceeding Series*, 2021, ISBN:978-1-4503-8982-2, DOI:10.1145/3472410.3472439, 156-160. **SJR (Scopus):0.232, Q4**
- D3-2 **Георгиева-Цанева, Г.** Моделиране на вариабилността на сърдечната честота. Глава VIII (стр. 213-238) от монографията: Господинов, М., Господинова, Е., Георгиева-Цанева, Г., Чешмеджиев, К., Лебамовски, П. Математически методи за обработка, анализ и моделиране

- на кардиологични сигнали и данни. Университетско издателство „Св.св. Кирил и Методий“, гр. Велико Търново, 2023, ISBN:978-619-208-356-4, 272
- D3-3 **Galya Georgieva-Tsaneva**. Adaptive Hosking Generator with Time-Varying Hurst for HRV Simulation in Support of Digital Twin Modeling. 2025 International Conference “ROBOTICS & MEHATRONICS”, 5 – 6 November, 2025, Sofia, Bulgaria
- D3-4 **Georgieva-Tsaneva, G.**, Cheshmedzhiev, K. A Gaussian-based hybrid method for simulating photoplethysmographic signals. CompSysTech '24: Proceedings of the International Conference on Computer Systems and Technologies 2024, ACM International Conference Proceeding Series, 2024, ISBN:979-8-4007-1684-3, DOI:10.1145/3674912.3674934, 143-148. **SJR (Scopus):0.191, Q3**
- D3-5 **Georgieva-Tsaneva, G.**, Tsanev, Y-A., Cheshmedzhiev, K. Deep-SimPPG: A GAN-Based Hybrid Framework for Realistic Photoplethysmographic Signal Synthesis. 2025 International Conference Automatics and Informatics (ICAI), Varna, Bulgaria, IEEE, 2026, DOI:<https://doi.org/10.1109/ICAI67591.2025.11324985>, 787-792
- D3-6 **Galya Georgieva-Tsaneva**. Mathematical modeling using Gaussian functions and Chaotic attractor: a hybrid approach for realistic representation of the intrinsic dynamics of heartbeats. 2025. AppliedMath 2025, 5, 172. <https://doi.org/10.3390/appliedmath5040172>, **SJR 0.218, Q3**
- D4-1 **Georgieva-Tsaneva, G.**, Gospodinova, E., Bogdanova, G. Model of Information Platform with Possibility for Introduction and Protection of Patient Information for the Purposes of Medical Training. 16th International Technology, Education and Development Conferencein, in INTED2022 Proceedings., International Academy of Technology, Education and Development (IATED), 2022, ISBN:978-84-09-37758-9, ISSN:2340-1079, DOI:10.21125/inted.2022.1865, 7393-7400
- D4-2 **Georgieva-Tsaneva, G.**, Bogdanova, G., Gospodinova, E. Mathematically Based Assessment of the Accuracy of Protection of Cardiac Data Realized with the Help of Cryptography and Steganography. Mathematics, 10, 3, Multidisciplinary Digital Publishing Institute (MDPI), 2022, ISSN:2227-7390, DOI:10.3390/math10030390, 1-18. SJR (Scopus):0.54, **JCR-IF (Web of Science):2.592, Q1**
- D4-3 **Georgieva-Tsaneva, G.**, Tsanev, Y-A., Cheshmedzhiev, K., Dechev, M.. A Privacy-Preserving Architecture for Biomedical Signal Acquisition and Transmission Using Hybrid Cryptography and Regulatory-Aware Protocols. 2025 International Conference Automatics and Informatics (ICAI), IEEE, 2026, DOI:<https://doi.org/10.1109/ICAI67591.2025.11325096>, 793-798
- D5-1 **Georgieva-Tsaneva, G.**; Cheshmedzhiev, K.; Tsanev, Y.-A.; Dechev, M. Physiological State Recognition via HRV and Fractal Analysis Using AI and Unsupervised Clustering. Information 2025, 16, 718. <https://doi.org/10.3390/info16090718>, **IF 2.9, Q2**
- D5-2 **Georgieva-Tsaneva, G.**; Lebamovski, P.; Tsanev, Y.-A. Impact of Prolonged High-Intensity Training on Autonomic Regulation and Fatigue in Track and Field Athletes Assessed via Heart Rate Variability. Appl. Sci. 2025, 15, 10547. <https://doi.org/10.3390/app151910547>, **SJR 0.521, Q1**
- D5-3 **Georgieva-Tsaneva, G.**; Tsanev, Y.-A.; Dechev, M.; Cheshmedzhiev, K. Impact on Competitive Performance and Assessment of Fatigue and Stress Based on Heart Rate Variability. Appl. Sci. 2025, 15, 10892. <https://doi.org/10.3390/app152010892>, **SJR 0.521, Q1**
- D5-4 **Georgieva-Tsaneva, G.**, Cheshmedzhiev, K. (2025). Modern Technologies for Registration, Processing and Analysis of Physiological Signals (ECG, PPG), and Decision-making in Sensory Information Systems, Science Series "Innovative STEM Education", vol. 07, ISSN: 2683-1333, Institute of Mathematics and Informatics – Bulgarian Academy of Sciences, pp. 201-211, DOI: <https://doi.org/10.55630/STEM.2025.0717>
- D5-5 **Georgieva-Tsaneva, G.**, Cheshmedzhiev, K. (2025). Artificial Intelligence for EGG/PPG Signal Processing on Mobile Platforms, Science Series "Innovative STEM Education", vol. 07, ISSN: 2683-1333, Institute of Mathematics and Informatics – Bulgarian Academy of Sciences, pp. 272-290, DOI: <https://doi.org/10.55630/STEM.2025.0725>

D5-6 **Georgieva-Tsaneva, G.** Development of Recovery and Prognostic Indices for HRV-Based Digital Twin Modeling in Athletes. *Complex Control Systems*, 9, 2, IR-BAS, 2025, ISSN:2603-4697, 1-7

ЗАБЕЛЯЗАНИ ЦИТИРАНИЯ НА ПУБЛИКАЦИИТЕ ПО ДИСЕРТАЦИОННИЯ ТРУД

D1-1. **Georgieva-Tsaneva, G.,** Tsanev, Y.-A. Heart rate variability data PPG based analysis. *Complex Control Systems*, 7, IR-BAS, 2024, ISSN:2603-4697(online), 1-5

1 в SCOPUS

D1-2. Gospodinova, E.; Lebamovski, P.; **Georgieva-Tsaneva, G.**; Negreva, M. Evaluation of the Methods for Nonlinear Analysis of Heart Rate Variability. *Fractal Fract.* 2023, 7, 388. <https://doi.org/10.3390/fractalfract7050388>

16 в SCOPUS, 4 в други бази

D1-5 **Georgieva-Tsaneva, G.**; Cheshmedzhiev, K.; Tsanev, Y.-A.; Dechev, M.; Popovska, E. Healthcare Monitoring Using an Internet of Things-Based Cardio System. *IoT* **2025**, 6, 10. <https://doi.org/10.3390/iot6010010>

11 в SCOPUS, 7 в други бази

D2-1 **Georgieva-Tsaneva, G.** A Novel Photoplethysmographic Noise Removal Method via Wavelet Transform to Effective preprocessing. *Proceedings of the 23rd International Conference on Computer Systems and Technologies, CompSysTech*, 2022, ISBN:978-1-4503-9644-8, DOI:10.1145/3546118.3546145, 113-118. SJR (Scopus):0.209

2 в SCOPUS, 2 в други бази

D2-2 **Georgieva-Tsaneva, G.,** Gospodinova, E., Cheshmedzhiev, K. Cardiodiagnostics Based on Photoplethysmographic Signals. *Diagnostics*, 12, 2, Multidisciplinary Digital Publishing Institute (MDPI), 2022, ISSN:E-2075-4418, DOI:10.3390/diagnostics12020412, 1-21. SJR (Scopus):0.66, JCR-IF (Web of Science):3.992, **Q2**

6 в SCOPUS, 2 в други бази

D3-1 **Georgieva-Tsaneva, G.** Simulation of long-term Heart Rate Variability records with Gaussian distribution functions. *CompSysTech '21: Proceedings of the 22st International Conference on Computer Systems and Technologies '20, ACM International Conference Proceeding Series*, 2021, ISBN:978-1-4503-8982-2, DOI:10.1145/3472410.3472439, 156-160. SJR (Scopus):0.232

3 в SCOPUS, 2 в други бази

D4-1 **Georgieva-Tsaneva, G.,** Bogdanova, G., Gospodinova, E. Mathematically Based Assessment of the Accuracy of Protection of Cardiac Data Realized with the Help of Cryptography and Steganography. *Mathematics*, 10, 3, Multidisciplinary Digital Publishing Institute (MDPI), 2022, ISSN:2227-7390, DOI:10.3390/math10030390, 1-18. SJR (Scopus):0.54, JCR-IF (Web of Science):2.592

10 в SCOPUS, 2 в други бази

D5-1 **Georgieva-Tsaneva, G.**; Cheshmedzhiev, K.; Tsanev, Y.-A.; Dechev, M. Physiological State Recognition via HRV and Fractal Analysis Using AI and Unsupervised Clustering. *Information* 2025, 16, 718. <https://doi.org/10.3390/info16090718>

2 в SCOPUS