

Қ.И.Сәтбаев атындағы Қазақ ұлттық техникалық зерттеу университеті

ӘОЖ: 615.47:616-072.7(43)

Қолжазба құқығында

АЛИМБАЕВА ЖАДЫРА НУРДАУЛЕТОВНА

**Миокард инфарктісін диагностикалауда электрокардиосигналдарды
нейрожелілік талдау**

6D071600 – Аспап жасау

Философия докторы (PhD) дәрежесін алу үшін
дайындалған диссертация

Ғылыми жетекшісі:
техника ғылымдарының кандидаты, профессор
Өжікенов Қасымбек Әділбекұлы

Шетелдік ғылыми жетекші:
техника ғылымдарының докторы, профессор
Бодин Олег Николаевич
(ПМУ, Пенза)

Республика Казахстан
Алматы, 2022

МАЗМҰНЫ

НОРМАТИВТІК СІЛТЕМЕЛЕР	4
КІРІСПЕ	6
1 МӘСЕЛЕНІҢ ЖАЙ-КҮЙІ ЖӘНЕ МӘСЕЛЕНІ БЕЛГІЛЕУ	8
1.1 Миокард инфарктісін диагностикалау әдістеріне шолу	8
1.2 Электрокардиосигналдың даму процесі.....	13
1.4 Миокард инфарктісінің ЭКС белгілері.....	16
1.4.1 ЭКС өңдеуге арналған машиналық оқыту әдістері.....	20
1.4.2 Машиналық оқыту үлгілерін зерттеу	25
1.5 Электрокардиосигналды нейрожелілік талдау	44
1.5.1 Жасанды нейрон және оның іске белсендіру функциялары	44
1.5.2 Нейрондық желілер мен оқыту алгоритмдерінің жіктелуі.....	45
1.6 Бірінші тараудың қорытындылары және мәселенің тұжырымы	50
2. КАРДИОЦИКЛ СЕГМЕНТТЕРІН НЕЙРОЖЕЛІЛІК ТАЛДАУ ЖӘНЕ НЕЙРОНДЫҚ ЖЕЛІЛЕРДІҢ СЕРИЯЛЫҚ-ПАРАЛЛЕЛЬ ҚОСЫЛУЫ НЕГІЗІНДЕ МИОКАРД ИНФАРКТИСІН ДИАГНОСТИКАЛАУ ӘДІСТЕМЕСІН ӨЗІРЛЕУ	52
2.1 Электрокардиографиялық ақпаратты нейрожелілік талдау әдістемесінің сипаттамасы	52
2.2 Электрокардиосигналдарды тіркеп, алдын ала өңдеу	55
2.3 МИ диагностикалау үшін электрокардиосигналдың нейрожелілік талдау әдісі.	69
2.3.1 Кардиоциклдің сегменттерін талдау үшін оқыту үлгісін қалыптастыру	72
2.3.2 Кардиоциклдің сегменттерін талдауға арналған НС оқыту ерекшеліктері	74
2.4 Диагностикалық қорытынды бойынша шешім қабылдау әдістемесі.....	76
2.5 Миокард инфарктісін диагностикалау үшін электрокардиосигналды нейрожелілік өңдеу әдісін іске асыру	80
2.5.1 Электрокардиосигналды нейрожелілік талдау әдісінің сезімталдығы мен ерекшелігін анықтау	93
2.6 Екінші тараудың қорытындысы	97
ҚОРЫТЫНДЫ.....	98
ПАЙДАЛАНЫЛҒАН ӘДЕБИЕТТЕР ТІЗІМІ	100
ҚОСЫМША А	109
ҚОСЫМША В	111

НОРМАТИВТІК СІЛТЕМЕЛЕР

Диссертациялық жұмыста келесі стендтер бойынша сілтемелер пайдаланылды:

МЕМСТ 20790-93 (МЕМСТ Р 50444-92) - Медициналық құрылғылар, аппараттар мен жабдықтар, жалпы техникалық шарттар.

ҚР СТ ГОСТ Р 51264-2010 - "Электрондық байланыс, информатика және сигнализация құрылғылары. Жалпы техникалық шарттар"

ГОСТ 30324.0-95 (ГОСТ Р 50267.0-92, МЭК 601-1-88) "Медициналық электр жабдықтары. 1 бөлім. Жалпы қауіпсіздік талаптары".

ГОСТ 6.38.90 - Сәйкестендірілген құжаттама жүйелері. Ұйымдық-өкімдік Құжаттама жүйесі. Құжаттарды ресімдеуге қойылатын талаптар.

ГОСТ 7.32.2001 - Ақпарат, кітапхана және баспа стандарттары жүйесі. Ғылыми-зерттеу жұмысы бойынша есеп. Дизайн құрылымы мен ережелері.

МЕМСТ 8.417-81 - Мемлекеттік өлшемдердің бірлігін қамтамасыз ету жүйесі. Физикалық шама бірліктері.

ҚР СТ МЕМСТ 15.011-2005 - Патенттік зерттеулер.

ҚАБЫЛДАНҒАН ҚЫСҚАРТУЛАР ТІЗІМІ

АВ – Атриовентрикулярлы
АУТ – Амплитудно-уақыттық талдау
ДБ – Деректер базасы
ВДЖ – Валидациялық деректер жиынтығы
МИ – Миокард инфарктісі
АҚЕ – Ақпараттық қамтамасыз ету
АП – Ақпараттық параметр
ЖНЖ – Жасанды нейрондық желілер
МАЖ – Медициналық ақпараттық жүйе
АХЖ – Аурулардың халықаралық жіктелуі
НЖ – Нейрондық желі
НЖТ – Нейрожелілік талдау
ЖМИ – Жедел миокард инфарктісі
ОМЖ – Оқыту мәліметтер жиынтығы
ДББЖ – Деректер базасын басқару жүйесі
ЖҚА – Жүрек қантамырлары аурулары
ЖУТ – Жиілік-уақыттық талдау
ЭКГ – Электрокардиограмма
ЭКС – Электрокардиосигнал
LVQ – Оқыту векторларын кванттау (Learning Vector Quantization)
ССLVQ3 – Дөңес комбинация әдісін (convex combination) қолдануға негізделген НЖ LVQ оқыту алгоритмі

КІРІСПЕ

Жұмыстың өзектілігі. Әлем бойынша жүрек ауруларынан болатын мүгедектік пен өлім-жітімнің жоғары деңгейіне байланысты жүрек-қан тамырлары ауруларымен күрес проблемасы барған сайын маңызды және өзекті мәнге ие болуда. Дүниежүзілік денсаулық сақтау ұйымының мәліметтері бойынша, жүрек-қан тамырлары ауруларынан (ЖҚА) болатын өлім әлемде бұрыннан жетекші орынға ие. Қазақстанда адамдар қан айналымы жүйесі ауруларынан, мысалы, Еуропа елдеріне қарағанда, екі есе жиі қайтыс болады. Жүрек аурулары ішінде, өмірге ең қауіптісі - миокард инфарктісі (МИ). Ауыр ағымға және жоғары өлім-жітімге байланысты (миокард инфарктісінің жедел, өткір және соңғы кезеңдердегі жалпы өлім-жітім шамамен 30% - ды құрайды) осы ауруды уақтылы диагностикалау қазіргі заманғы денсаулық сақтаудың өзекті мәселелерінің бірі болып табылады. Қазіргі уақытта кардиологиялық ақпаратты өңдеудің статистикалық, математикалық әдістері мен компьютерлік құралдарының алуан түрлілігіне қарамастан, осы зерттеу саласында диагностика үшін электрокардиосигналды (ЭКС) талдау әдістері мен құралдарының дәлдігін арттыру міндеті өзекті болып қала береді. Қолданыстағы классикалық әдістер мен диагностикалық құралдар диагностиканың дәлдігінің заманауи талаптарын қанағаттандырмайды. МИ диагностикалаудың жетілмеген құралдары мен жүйелерін, сондай-ақ адам факторын ескере отырып, дәрігерге көмектесе алатын МИ диагностикалаудың дәлдігін жоғарылату арқылы шешім қабылдауды қолдау әдісін жасау қажеттілігі айқын.

Миокард инфарктісін (МИ) диагностикалау үшін ЭКС талдауында жасанды нейрондық желілерді қолдану бөлек. Кардиологиялық ақпаратты нейрожелілік талдау (НЖТ) белсенді дамып келеді және бүкіл әлемнің зерттеушілерін қызықтыруда.

МИ мерзімінен бұрын диагностикалау үшін дәрігерге көмектесе алатын тәсілдің болмауы жаңа диагностикалық ақпаратты алу әдістерін жасауды қажет етеді.

Зерттеу пәні - миокард инфарктісін диагностикалау үшін кардиографиялық ақпаратты өңдеу әдістері, бастапқы деректерді дайындау әдістері, нейрондық желілердің құрылымы мен алгоритмдері.

Жұмыстың мақсаты - миокард инфарктісін диагностикалау үшін электрокардиосигналдарды нейрожелілік талдау негізінде кардиологиялық ақпаратты өңдеу құралдарының дәлдігін арттыру.

Зерттеудің міндеттері: қойылған мақсатқа жету үшін келесі міндеттер шешіледі:

1. Миокард инфарктісін диагностикалау үшін кардиографиялық ақпаратты өңдеудің қолданыстағы әдістері мен құралдарын сыни талдау, олардың кемшіліктерін анықтау және кардиологиялық ақпаратты өңдеудің жаңа әдістерін әзірлеуді негіздеу.

2. Машиналық оқыту алгоритмдерін қолдана отырып, миокард инфарктісін болжау әдісін зерттеу және таңдау.

3. Миокард инфарктісінің тікелей және кері белгілерін бірлесіп талдау негізінде миокард инфарктісін диагностикалауға арналған ЭКС НЖТ жаңа әдістерін әзірлеу.

4. Ұсынылған нейрожелілік талдау әдістемесі негізінде МИ болуы туралы диагностикалық қорытынды жасау үшін шығыс логикалық функцияларды құру.

5. ЭКС-ті нейрожелілік талдаудың жаңа әдістерін іске асыратын ЭКС-ды клиникаға дейін талдап, миокард инфарктісін диагностикалауға арналған НЖ әдістің құрылымын жасау.

Зерттеу әдістері. Қойылған міндеттерді шешу үшін жұмыста машиналық оқыту теориясы, сигналдарды сандық өңдеу теориясы, жүйелер мен жүйелік талдау теориялары, кардиология мен диагностиканың әдістері қолданылды.

Зерттеудің ғылыми жаңалығы:

Зерттеудің ғылыми жаңалығы келесідей:

1. МИ анықтауда ЭКС талдау функционалдылығын кеңейтетін алдымен МИ трансмуралдылығын, содан кейін МИ тікелей және өзара белгілерін жүйелі НЖ талдау жасап, МИ бар болуы туралы диагностикалық қорытынды жасауға мүмкіндік беретін әдісі ұсынылды.

2. Ұсынылған нейрондық желіні талдау әдісі негізінде миокард инфарктісінің орналасқан жері туралы шешім қабылдай отырып, миокард инфарктісінің бар туралы диагностикалық қорытынды жасау үшін логикалық функциялар синтезделді.

3. Ұсынылған әдістерді жүзеге асыратын, миокард инфарктісінің болуы туралы шешім қабылдай алатын кардиологиялық ақпаратты клиникалық зерттеу деңгейіне жақындатуға мүмкіндік беретін қолдау әдісінің құрылымы ұсынылып, негізделді.

Зерттеудің практикалық маңыздылығы:

1. Кардиографиялық ақпаратты өңдеудің ұсынылған әдістерін жаңа кардиодиагностика құралдарын құруда қолдануға болады.

2. Кардиоциклдің жеке сегменттерін алдын-ала оқшаулап, оларды нейрожелілік талдау негізінде кардиологиялық ақпаратты өңдеу және ЭКС нейрожелілік талдау әдісі кардиологиялық ақпаратты клиникаға дейінгі өңдеудің функционалдылығын кеңейтеді, миокард инфарктісі мен миокардтың зақымдану орнын дәл анықтауға мүмкіндік береді.

Нәтижелерді енгізу. Жұмыс автордың қатысуымен Қазақ ұлттық техникалық зерттеу университетінде "Жүрек инженериясы" пәнін оқытуда қолданылады.

Қорғауға шығарылады:

1. Кардиоциклдің жекелеген элементтерінің миокард инфарктісінің белгілерін нейрожелілік талдаудан тұратын, 99,7% - ға дейінгі ықтималдылықпен жаппай тексеру жағдайында миокард инфарктісінің түрін және орналасуын анықтауға мүмкіндік беретін электрокардиосигналдарды нейрожелілік талдау әдісі. (РФ патенті №2704913).

2. Нейрондық желілердің шығыс ақпараттарын талдау негізінде миокард инфарктісін локализациялау туралы диагностикалық қорытынды жасаудың шешуші ережелері.

3. Кардиографиялық ақпаратты өңдеудің дамыған тәсілін жүзеге асыруға мүмкіндік беретін және кардиодиагностиканың жаңа құралдарын құрудың негізі ретінде қолданылатын миокард инфарктісінің болуы туралы шешім қабылдауға мүмкіндік беретін әдістің құрылымы.

Автордың жеке үлесі. Қорғауға алынған негізгі нәтижелерді автордың өзі алды. Басқа авторлармен бірге жарияланған нәтижелер авторларға тең үлестермен тиесілі. Баяндау барысында пайдаланылған басқа авторлардың нәтижелері тиісті әдебиеттерге сілтемелерден тұрады.

Зерттеу нәтижелерін апробациялау. Жұмыстың негізгі нәтижелері 6 халықаралық және ғылыми-техникалық конференциялар мен форумдарда ұсынылды, оның ішінде "ақпараттық және коммуникациялық технологияларды қолдану жөніндегі 12-ші халықаралық конференцияда IEEE", АІСТ2018 (Алматы 2018); "Микро / нанотехнологиялар және Электрондық аспаптар жөніндегі жас мамандардың XX халықаралық конференциясы", EDM 2019, (Новосибирск 2019); "ШЛЯНДИНСКИЕ чтения – 2019" на XI Международной научно-технической конференции "(Пенза 2019); жыл сайынғы Ұлттық ғылыми-техникалық конференция" Ғылым апталығы СПбПУ-2019 " халықаралық қатысумен (Санкт-Петербург-2019); Апробация" Технологияларды коммерцияландыру білім беру мен бизнесті кіріктіру құралы ретінде" халықаралық форумында (Нұр-сұлтан-2019); "Сәтбаев оқулары-2018" халықаралық ғылыми-практикалық конференциясында (Алматы 2018) өтті.

Публикациялар. Жұмыстың негізгі қорытындылары 15 жарияланымда ұсынылған, соның ішінде Scopus дерекқорына кіретін журналда 2 мақала (перцентиль 48%, 43%), Scopus дерекқорына кіретін халықаралық конференцияларда 2 мақала, ҚР БҒСБК ұсынған басылымдарда 4 мақала, РФ пайдалы моделіне 1 патент, 1 патент Еуразиялық авторлық құқыққа, басқа басылымдарда 5 мақала.

Жұмыстың құрылымы мен көлемі. Жұмыс кіріспеден, екі тараудан, қорытындыдан, пайдаланылған дереккөздердің тізімінен тұрады. Жұмыстың жалпы көлемі 115 беттен тұрады, жұмыста 55 сурет, 15 кесте, 2 қосымша, 122 атаудан тұратын әдебиеттер тізімі бар.

1 МӘСЕЛЕНІҢ ЖАЙ-КҮЙІ ЖӘНЕ МӘСЕЛЕНІ БЕЛГІЛЕУ

1.1 Миокард инфарктісін диагностикалау әдістеріне шолу

Әдетте, миокард инфарктісіне келесі критерийлер арқылы диагноз қойылады: симптомдардың болуы, электрокардиограммада (ЭКГ) ST сегментінің уаытқуының болуы немесе болмауы, тропонин деңгейінің жоғарылауы, ангиография немесе компьютерлік томография арқылы қан ұйығанын анықтау.

Тропонин Т. Миокардтың зақымдану белгілерін анықтау үшін жүрек тропонинінің деңгейі өлшенеді-бұл ақуыз әдетте қанда болмайды және тек миокард некрозымен шығарылады және миокард инфарктісін зертханалық диагностикалаудың ең ерекше құралдарының бірі болып саналады [1-3]. Миокардтың зақымдану белгілерін анықтау үшін жүрек тропонинінің деңгейі өлшенеді-бұл ақуыз әдетте қанда болмайды және тек миокард некрозы болған жағдайда пайда болады және миокард инфарктісін зертханалық диагностикалаудың ең ерекше құралдарының бірі болып саналады [1-3]. Тропонин деңгейі 2-3 сағаттан кейін өсе бастайды және 24-28 сағаттан кейін шыңына жетеді. Дені сау адамдардың қанында, шамадан тыс физикалық күш салғаннан кейін де, тропонин т деңгейі 0,2 – 0,5 нг/мл-ден аспайды, сондықтан оның көрсетілген шектен асып кетуі жүрек бұлшықетінің зақымдануын көрсетеді.



Сурет 1.1.1. Тропонин деңгейін анықтауға арналған экспресс-тестер


Миокард инфарктісіндегі тропонин Т кинетикасы басқа ферменттердің кинетикасынан өзгеше. Тропонин Т жоғарылауының бірінші күні инфаркт аймағындағы қан ағымына байланысты. Миокард инфарктісінде тропонин Т қанда ауырсыну сезімі басталғаннан кейін 3-4 сағаттан кейін жоғарылайды, оның концентрациясының шыңы 3-4 күнге түседі, 5-7 күн ішінде үстірт байқалады, содан кейін тропонин Т деңгейі біртіндеп төмендейді, бірақ ол 10-20 күнге дейін жоғары болып тұрады. Тромболизис сәтті аяқталған жағдайда, екі шың анықталады: біріншісі – ол пайда болғаннан кейін 14 сағаттан кейін, оның мәні жедел миокард инфарктісінің 4-ші күніне сәйкес келетін екінші шың деңгейінен әлдеқайда жоғары. Сарысудағы тропонин Т жоғарылауының тез анықталуы фибринолизге байланысты окклюзияланған артерияның ерте рекализациясы бар науқастарда байқалады, яғни миокард инфарктісінің бірінші күні қандағы тропонин Т концентрациясы окклюзияның ұзақтығына байланысты болады; тамыр неғұрлым тезірек "ашылса", тропонин т жоғарылауы соғұрлым күшті болады. Тропонин Т концентрациясының жоғарылауы (екінші шың) контрактильді аппараттың прогрессивті протеолитикалық деградациясын және сәйкесінше қайтымсыз миокард некрозын көрсетеді. Ұзақ окклюзия кезінде 10 күн ішінде байқалатын қандағы тропонин Т-ның жоғары деңгейі оның инфаркт аймағынан ұзақ шығарылуымен түсіндіріледі (тропонин Т-ның жартылай шығарылу кезеңі 12 минутты құрайды) [4-5].

Миокард инфарктісі басталғаннан кейін тропонин Т концентрациясы креатинкиназа мен лактатдегидрогеназаға қарағанда едәуір артады. Табысты реканализациясы бар кейбір пациенттерде Т тропонинінің концентрациясы 300 еседен астамға артуы мүмкін. Қандағы тропонин т концентрациясы миокард инфарктісінің орнының мөлшеріне байланысты. Тромболизден кейін ірі ошақты немесе трансмуралды миокард инфарктісінде тропонин Т деңгейі 400 есе, ал Q тісі жоқ миокард инфарктісі бар науқастарда – тек 37 есе жоғарылауы мүмкін. Тропонин Т үшін" диагностикалық терезе " (патологиялық өзгерістер кезінде ферменттің немесе ақуыздың жоғарылауын анықтау уақыты) креатинкиназамен салыстырғанда 4 есе және лактатдегидрогеназамен салыстырғанда 2 есе артады. Тропонин Т үшін жедел миокард инфарктісіндегі абсолютті диагностикалық сезімталдық аралығы 125-129 сағатты құрайды. Креатинкиназа және лактатдегидрогеназа үшін-сәйкесінше 22 және 70 сағат.

Қандағы тропонин Т деңгейін миокард некрозының мөлшерін бағалау үшін қолдануға болады. Оның ең жоғары деңгейі қабырғаның қозғалғыштық индексіне, екі өлшемді эхокардиография мен контрастты вентрикулографиямен өлшенген сол жақ қарыншаның шығарылу фракциясына қатаң кері пропорционал [6].

Жүрек тропонині I немесе T (сTn) таңдаулы биомаркер болып табылады және жедел миокард инфарктісін ерте диагностикалау кезінде 12 қорғасындағы клиникалық бағалау мен ЭКГ-ны толықтырады деген кең консенсус бар, бірақ маңызды белгісіздіктер мен жоғары сезімтал сTn талдауларының мәніне, оның ішінде ең жақсы клиникалық қолдануға қатысты сұрақтар қалады.

Жүрек суреттерін алуға көмектесетін әдістер, алынған ақпараттар жиынтығын визуализациялап, диагностикалау үшін қолданылады. Ол инвазивті емес (кеуде қуысының рентгенографиясы, КТ немесе МРТ) [7-12] және инвазивті (ангиография) [13-14] болуы мүмкін. Рентгенография симптомдардың балама себептерін болдырмауға және миокард инфарктісінен кейін асқынулардың бар-жоғын тексеруге мүмкіндік береді. Эхокардиография (жүрек ультрадыбыстық зерттеуі) арқылы жүрек бұлшықетін көруге, жүрек клапандарының қан өткізгіштігін көруге, мүмкін болатын зақымдарды бағалауға болады [15-17]. 1.1.2-суретте миокард инфарктісі кезіндегі жүректің визуализациясы әртүрлі әдістермен көрсетілген.



Сурет 1.1.2. Миокард инфарктісі кезінде жүректі әртүрлі әдістермен визуализациялау
 а – КТ; б – МРТ; в – ангиография; г – эхокардиография

Коронарлық ангиография артерияның бітелуі немесе тарылуы бар-жоғын анықтауға көмектеседі. Бұл процедура кезінде дәрігер ағзаға жіңішке түтікті (катетерді) іштегі немесе қолдағы қан тамырлары арқылы енгізіп, сол арқылы бітелу немесе тарылу орнын анықтауға көмектесетін арнайы бояғыш (контрастты зат) енгізеді. Патологияны стент орнату арқылы дереу жоюға болады — процедура теріасты коронарлық араласу (ТКА) деп аталады.

Электрокардиограмма (ЭКГ)-бұл миокард инфарктісі үшін ең қолайлы диагностикалық құрал, оның танымалдылығы, инвазивті емес және бағасы қол жетімді [18-19]. Тәжірибелі кардиологтар ЭКГ талдауы арқылы миокард инфарктісінің локализациясын анықтай алады. Алайда, ЭКГ деректерін талдау және диагностикалау көп уақытты қажет етеді және дәрігерлер үшін қиын болып табылады. Автоматты ЭКГ диагностикалық жүйесі жылдам, объективті және сенімді талдауды ұсына отырып, қолмен скринингтік шектеулерден асып кетуі мүмкін. Сонымен қатар, үйде медициналық көмек көрсету жағдайындағы скрининг кезінде ЭКГ талдауда жасырын миокард инфарктісін диагностикалауға арналған автоматтандырылған әдісті қолдануға болады.

Диагностиканың бұл түрі үшін көптеген зерттеулер әдетте белгілерді бөліп көрсету мен жіктеуден тұратын машиналық оқытудың дәстүрлі тәсілдерін қолданды. Кейбір зерттеулерде белгілерді алу үшін клиникаларда дәрігерлер диагноз қою үшін қолданатын қолмен жасалған ЭКГ толқын

пішінінің сипаттамалары қолданылды. МИ белгілерін есептеу J нүктесі, эквипотенциалды сызық, QRS кешені және T тісі сияқты негізгі сипаттамалық нүктелер мен толқын пішіндеріне байланысты [20, 21]. Алайда, қисықтың бұл ерекшеліктері көбінесе сигнал сапасы төмен немесе аритмия болған кезде қателіктерге бейім ЭКГ сипаттамалық нүктелерін дәл анықтауға байланысты. Сонымен қатар, толқындық түрлендіру, Фурье түрлендіруі, полиномиялық жуықтау, энергия және меншікті кеңістік, доменді түрлендіруге негізделген әдістер ұсынылды [22, 23, 24]. Бұл әдістер сенімді үлкен сипаттамаларды ала алады, бірақ ЭКГ-да кейбір айқын немесе жасырын белгілерді жіберіп алуы мүмкін. МИ анықтаған кезде классификациялау үшін K-жақын көршілер (KNN) [22], кездейсоқ ормандар (RF) [25], шешімдер ағашы (DT) [24, 25], тірек векторлық машиналар (SVM) сияқты бірнеше жалпы жіктеуіштер қолданылды [23, 27]. Бұл әдістер жоғары тиімділікке қол жеткізгенімен, олардың кемшіліктері де бар. Мысалы, осы әдістерде белгілерді алу және ол белгілерді жіктеу оқшауланған модульдер болып табылады. Жіктеу модулімен кері байланыс болмағандықтан, келесі жіктеу үшін қандай функциялардың пайдалы екенін анықтау қиын. Атап айтқанда, белгілерді анықтау әдістері тек ЭКГ уақыт қатарындағы толқын пішінінің өзгеруі туралы ақпаратты ескереді және диагноз қою үшін әртүрлі тіркеуіштер арасындағы кеңістіктік корреляциясы туралы құнды ақпаратты елемейді.

Соңғы жылдары терең оқыту (DL) - қолайлы мүмкіндіктері мен функциялары арқасында, компьютерлік көру және уақыттық сериялардың сигналдарын талдау сияқты әртүрлі салаларда қолданылды [28, 29, 30]. Конвульсиялық нейрондық желі (CNN) - танымал терең оқыту архитектурасы. CNN белгілерді жақсы анықтау қабілеті биомедициналық сигналдарды талдау мәселелерін шешуге өте ыңғайлы. Мысалы, Эндрю Н. мен басқа ғалымдар CNN-ге негізделген бір тіркегіштен алынған ЭКГ сигналын қолдана отырып, аритмияны анықтайтын тәсілді ұсынды. Көрсеткіштер ақпараттарды жаңадан анықтау жылдамдығы мен дәлдігі бойынша орташа кардиологтың көрсеткіштерінен асып түсті [31]. Бірнеше зерттеулерде CNN МИ анықтау үшін де қолданылды. Мысалы, Лю және олардың командасы сәйкесінше бір және төрт тіркегішті ЭКГ ақпаратын қолдана отырып, МИ анықтау әдістерін ұсынды. Олар CNN-ге байланысты жақсы дәлдікке қол жеткізді. Алайда, бір немесе төрт тіркегішті ЭКГ жүректегі әр түрлі локализацияға байланысты МИ туралы барлық ақпаратты тіркей алмайды. Мұның ең үлкен кемшілігі, МИ алынған тіркеуіштер орналасқан аймақта болмаса, МИ бар екендігін анықтай алмауымыз мүмкін. Стандартты ЭКГ, әдетте, жүректің электрлік белсенділігін әр түрлі жағынан көрсететін 12 тіркеуіштен тұрады. ЭКГ-нің нақты тіркеуіштері локализация мен ауырлыққа сәйкес келетін толқын пішінінің өзгеруін білдіреді, бұл өз кезегінде коронарлық артерия (КА) окклюзиясының локализациясына байланысты. Керісінше, 12 тіркеуішті ЭКГ әртүрлі кеңістіктік бұрыштардан толығырақ барлық ақпаратты жаза алады [32]. Сондықтан МИ сенімді бақылау барлық 12 тіркеуіштегі ақпаратты бір уақытта зерттеуді қажет етеді. Сонымен қатар, МИ әсерінен болатын ЭКГ өзгерістері


әдетте әртүрлі жиілік диапазоңдарында болады және олардың сипаттамаларын бірнеше ажыратымдылықтағы талдау әдісімен жақсырақ алуға болады.

1.2 Электрокардиосигналдың даму процесі

XX ғасырдағы адамзаттың ең үлкен жетістіктерінің бірі-электрокардиография. Жыл сайын тек біздің елімізде миллиондаған электрокардиограмма (ЭКГ) тіркеледі. Көптеген ғалымдардың еңбектері электрокардиографияға арналған (М.и.Кечкер, а. б. де Луна, в. Н. Орлов, М. П. Роцевский, а. в. Струтынский, Ф. Зиммерман, М. Габриэль Хан және т. б.). Бұл жұмыстардың көпшілігі электрокардиографияның теориялық негіздері, ЭКГ талдау принциптері және жүрек-тамыр аурулары мен белгілердегі электрокардиографиялық өзгерістердің қалыптасу механизмдері егжей-тегжейлі сипатталған электрокардиографиядағы классикалық еңбектер [33-38] болып табылады. Сондықтан, осы зерттеудің бағытын анықтау үшін біз электрокардиографияның мүмкіндіктері мен даму ерекшеліктерін қысқаша сипаттаумен шектелеміз.


Бұл әдіс жүрек биотоктарының дене бетінде тұрақты таралуы бар және оларды тіркеуге (шығаруға), күшейтуге, содан кейін тән қисық – ЭКГ түрінде жазуға болатындығы туралы идеяға негізделген. Мұны алғаш рет В. Эйтховен (в. Эйтховен) 1903 жылы іске асыра алды. В. Эйтховен ЭКГ тістерін латын алфавитінің P, Q, R, S, T әріптерімен белгіледі. ЭКГ-бұл миокардта болатын электрофизиологиялық процестердің графикалық көрінісі.

Жүрек өзінің ырғақ драйвері шығаратын электр импульстарының әсерінен жұмыс істейді (қозғалады) [39]. Анатомиялық тұрғыдан алғанда, бұл жүрек ырғағының драйвері оң жақ атриумда, қуыс тамырлардың бірігу орнында, синус түйінінде орналасқан (1.2.1-суретті қараңыз), сол себепті одан шыққан қозу импульсі сәйкесінше синус импульсі деп аталады.



Сурет 1.2.1. Жүректің өткізгіш жүйесінің анатомиясы

Синус түйіні электр импульстарын шығарады, олар өткізгіш жүйе арқылы миокард жасушаларын қоздырады. Миокард жасушаларының электрлік белсенділігі нәтижесінде жүрек айналасында белгілі бір уақыт аралығында өзгертін электр өрісін жасайды. Теріге орналастырылған электродтар осы өрістің өзгеруін қабылдайды және оларды электрокардиографқа жібереді. Қалыпты ЭКГ тістері мен аралықтары 1.2.2 суретте көрсетілген [40].



Сурет 1.2.2. Қалыпты ЭКГ тістері мен аралықтары

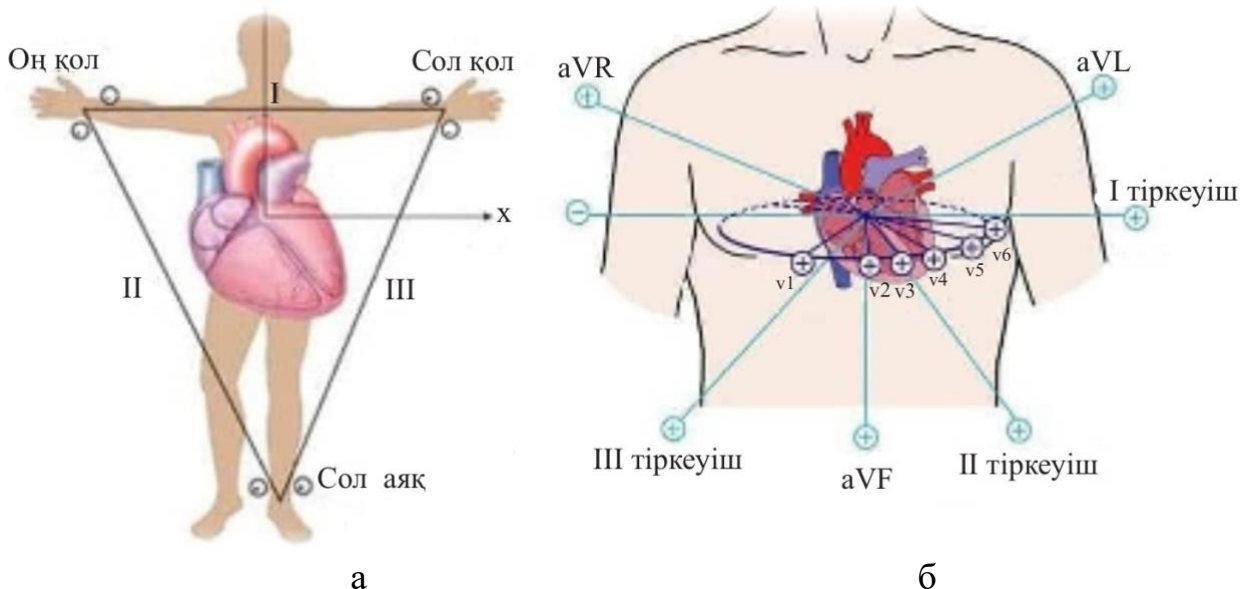
Тік тішшелерді тіркеуден басқа, ЭКГ-ға көлденеңінен импульс жүректің белгілі бір бөліктері бойынша өтетін уақыт жазылады. Кардиограммадағы уақыт бойынша (секундпен) өлшенген сегмент интервал деп аталады [41-43].

Электрлік қозу импульсі синус түйінінде пайда болады (ЭКГ-да тіркелмейді), атриа арқылы таралады (P тісі ЭКГ-да тіркеледі) және атриовентрикулярлық (AB) түйінінен өтеді (1.2.2-суретті қараңыз). AB түйінінде импульстің физиологиялық кідірісі жүреді (жүргізу жылдамдығының баяулауы), сондықтан ЭКГ-да P және Q тістері арасындағы бөлім (PQ сегменті) изоэлектрлік (изоляция) деп аталатын түзу сызықпен көрсетілген. Әрі қарай, электр импульсі Гис сәулелік жүйесі мен Пуркинье талшықтарымен ұсынылған қарыншалардың өткізгіш жолдарына жетіп (1.2.1-суретті қараңыз), қарыншалық миокардты қоздырады. Бұл процесс QRS қарыншалық кешенінің қалыптасуымен көрінеді (1.2.2-суретті қараңыз). Қарыншаны қоздырғаннан кейін электр қоздыру импульсі төмендеп, ST сегменті мен T тістері арқылы ЭКГ-да көрінетін реполяризация процестері жүреді.

Осылайша, ЭКГ генезисі миокард жасушаларында деполяризация (қозу) және реполяризация (релаксация немесе бастапқы күйді қалпына келтіру) процестерімен анықталады [44-48]. ЭКГ генезисінің процесін 1.2.3-суретте келтірілген шартты схемадан көруге болады. Жүрек бетінің барлық

элементтерінің (Si) трансмембраналық әсер ету потенциалының (ТМӨП) фазалық ығысқан қисықтары тиісті k_i коэффициенттеріне көбейтіліп, тиісті тіркеуіштен электрокардиосигнал түзеді (1.2.3-суретті қараңыз).

Электрокардиосигналды (ЭКС) тіркеу белгілі бір ережелерге қатаң сәйкестікте жүзеге асырылады. ЭКС-ті тіркеудің бірнеше жалпы қабылданған әдістері бар. Функционалды диагностика жасау үшін ЭКС-ды тіркеудің міндетті әдісі-ЭКГ-ны 12 стандартты тіркеуіштерге жазу керек.



Сурет 1.2.3. Электрокардиосигнал (а) генезісі және ЭКС 12 стандартты тіркеуіште (б)тіркеу кезінде электродтарды салу схемасы

Тіркеуіш пациент денесінің бетінде орналасқан екі электрод арасындағы потенциалдар айырмасы ретінде қалыптасады. ЭКС-ды стандартты жетектерге тіркеу үшін электродтар келесідей қолданылады: I – сол қол және оң қол, II – сол аяқ және оң қол, III – сол аяқ және сол қол. Күшейтілген тіркеуіштерге белсенді электрод aVR – оң қолға (R – right), aVL – сол қолға (L – left), aVF – сол аяққа (F – foot) бағыттау үшін орналастырылады. Кеуде қуысы үшін V1-V6 электродтардың бірі-кеуде бетіндегі нүкте, ал екіншісі – барлық аяқтардан біріктірілген электрод тіркеуіштері.

12 стандартты тіркеуіштің әрқайсысы жүректің белгілі бір бөлігінің электрлік белсенділігінің өзгеруін тіркеуге мүмкіндік береді. 1.2.1-кестеде жүрек бөлімдері және олардың күйін көрсететін стандартты тіркеуіштер туралы ақпарат берілген.

Кесте 1.2.1. Миокардтың орналасуы мен тіркеуіштердің сәйкес келуі

Тіркеуіш	Тіркеуіштерде көрсетілетін миокардтың орналасуы
I	Жүректің алдыңғы бөлігі
II	I және III жиынтық бөлу
III	Жүректің артқы бөлігі
aVR	Жүректің оң жақ қабырғасы
aVL	Жүректің сол жақ алдыңғы қабырғасы

aVF	Жүректің артқы-төменгі қабырғасы
V1 и V2	Оң жақ қарынша
V3	Қарыншааралық септум
V4	Жүректің жоғарғы жағы
V5	Сол жақ қарыншаның алдыңғы бүйір бөлігі
V6	Сол жақ қарыншаның бүйірі

1.2.2 кестеде қалыпты жағдайдағы ЭКС амплитуда-уақыттық параметрлерінің мәндері келтірілген.

Кесте 1.2.2 – Қалыпты жағдайдағы ЭКС амплитуда-уақыттық параметрлерінің мәндері

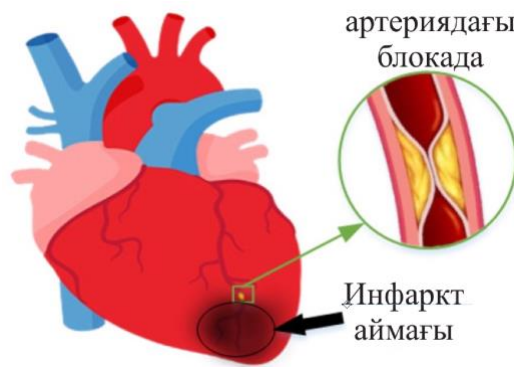
Элементтері	Ұзақтығы, с	Амплитуда, мм
Тісшелері		
<i>P</i>	0,06-0,1	0,05-2,5
<i>Q</i>	<0,03	<1/4 R
<i>R</i>	0,03-0,04	<8 (в I, II), <25 (в V1)
<i>S</i>	<0,03	до 20 (V5,6 до 26)
<i>T</i>	0,16	<1/2-1/3; R (II отв. до 1/4 R)
<i>U</i>	0,06-0,16	2-3
Интервалдар		
<i>PQ</i>	0,12-0,2	-
<i>QT</i>	0,35-0,42	-
<i>RR</i>	0,75-1,0	-
<i>RS</i>	0,03-0,05	-
Сегмент		
<i>ST</i>	0,03-0,12	-
Кешен		
<i>QRS</i>	0,06-0,09 (0,1)	-

ЭКС дәрігерлік интерпретация жүрек жиырылуының жиілігін және ырғақтылығын бағалаудан, тісшелердің амплитудасын және ұзақтығын өлшеуден, сегменттер мен интервалдардың ұзақтығын өлшеуден, сигнал элементтерінің морфологиясының өзгерістерін бағалаудан тұрады. Өлшеу нәтижелерінің негізінде сау жүректің күйі туралы қорытынды жасалынады.

1.4 Миокард инфарктісінің ЭКС белгілері

Жүрек ауруларының арасында өлімге жиі әкеліп соқтыратын ауру миокард инфарктісі (МИ) болып табылады. Ауыр ағымға және жоғары өлімге байланысты (өткір, жедел және аса өткір кезеңдердегі жалпы өлім-жітім шамамен 30% құрайды), бұл аурудың уақтылы диагнозы қазіргі кардиологияның өзекті мәселелерінің бірі болып табылады.

Миокард инфарктісі (ИМ) — бұл Коронарлық қан айналымының жеткіліксіздігі нәтижесінде дамиды жүрек бұлшықетінің ишемиялық некрозы.

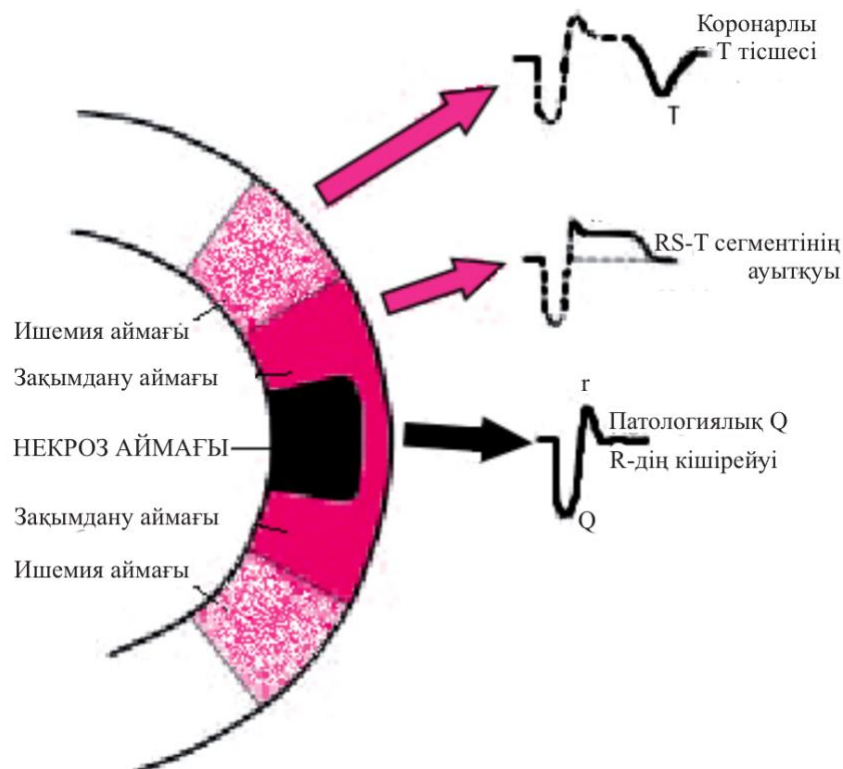


Сурет 1.3.1. Миокард инфарктісі

Миокард инфарктісінің заманауи жіктелуі оның келесідей бөлінуін қамтамасыз етеді:

- жүрек бұлшықетінің зақымдану көлемі мен тереңдігі бойынша;
- аурудың сипаты бойынша;
- МИ оқшаулау бойынша;
- ауру сатысы бойынша;

Bailey идеяларына сәйкес, Коронарлық қан айналымының бұзылуы патологиялық өзгерістердің келесідей үш аймағының пайда болуына әкеледі: некроз аймағында ишемиялық зақымдану және ишемия аймақтары орналасқан. 1.3.2-суретте миокардтың патологиялық өзгерістерінің үш аймағында ЭКС-тің пайда болуы көрсетілген.



Сурет 1.3.2. Миокардтың патологиялық өзгерістерінің үш аймағындағы электрокардиосигнал генезі

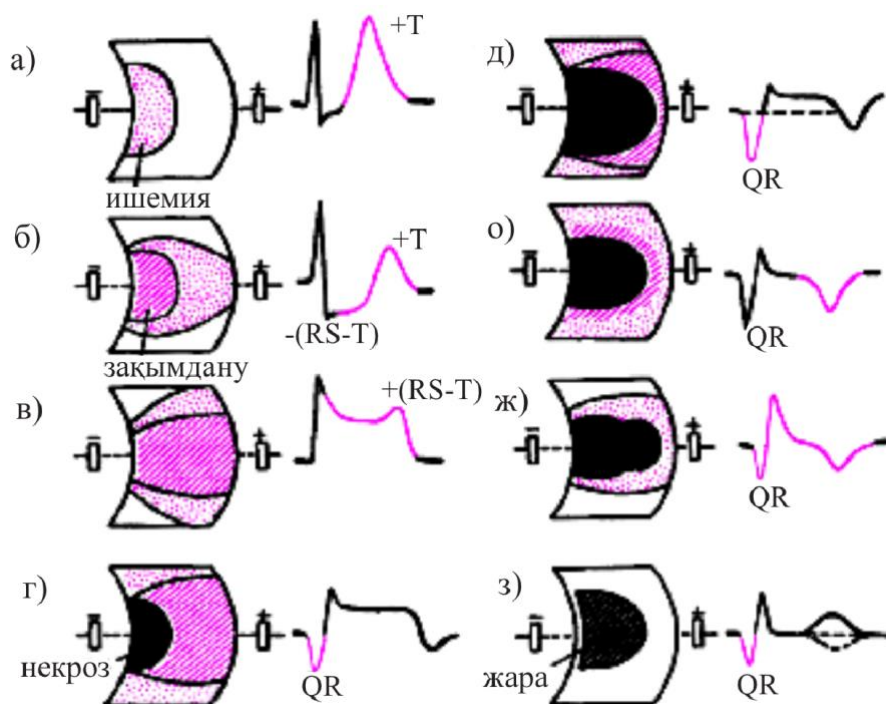
Белсенді электрод МИ аймағының үстінде орналасқан тіркеуіштердің әрқайсысы келесі ЭКГ өзгерістерін тіркей алады.

Некроз аймағы-бұл патологиялық тіс Q (ұзақтығы 30 мс-тан асады) және R тісшесінің немесе QS кешенінің амплитудасының күрт төмендеуі.

Ишемиялық зақымдану аймағы-RS-T сегментінің оқшаулаудан жоғары (трансмуральды ИМ кезінде) немесе төмен (жүрек бұлшықетінің субэндокардиальды зақымдануы кезінде) ығысуы.

Ишемия аймағы - "коронарлық" (тең жақты және үшкір) T тісшесі (субэндокардиалды МИ үшін жоғары оң және трансмуралды МИ үшін теріс).

Аурудың кезеңдерін қарастырайық. 1.3.4-суретте МИ кезеңдерінің дамуы көрсетілген. МИ ауыр, өткір және аса өткір сатыларын ажыратылып көрсетілген.



Сурет 1.3.4. МИ кезеңдерінің дамуы

Өткір кезең (МИ басталуына 2 сағатқа дейін). Коронарлық қан ағымы тоқтатылғаннан және жүрек бұлшықетінде ангинозды шабуыл пайда болғаннан кейін бірнеше минут ішінде субэндокардиалды ишемия аймағы анықталады, ол жоғары коронарлық T тісшелерінің пайда болуымен және изоэлектрлік сызықтан төмен RS-T сегментінің ығысуымен сипатталады (1.3.4, а, б суретті қараңыз). Ишемиялық зақымдану аймағы эпикардқа дейін таралған кезде, RS-T сегментінің оқшаулаудан жоғары жылжуы (трансмуралды ишемиялық зақым) ЭКГ-ға жазылады. Бұл жағдайда RS-T сегменті ТМӨП пішініне ұқсайтын монофазиялық қисық деп аталатын T оң тісшесімен біріктіріледі (1.3.4, в суретін қараңыз).

Жедел кезең 1-2 тәулік ішінде патологиялық Q тісшесінің немесе QS кешенінің қалыптасуымен және тістің R амплитудасының төмендеуімен сипатталады, бұл некроз аймағының пайда болуын және кеңеюін көрсетеді (1.3.4 г, д — суретті қараңыз). Сонымен қатар, RS-T сегментінің оқшаулаудан

жоғары ауытқуы бірнеше күн бойы сақталады және алдымен оң, содан кейін теріс Т тісімен жалғасады. Бірнеше күннен кейін RS–Т сегменті оқшаулауға жақындайды, ал 1-ші аптаның соңында немесе аурудың 2-ші аптасының басында изоэлектрлік болады, бұл ишемиялық зақымдану аймағының азаюын көрсетеді (1.3.4, е-суретті қараңыз). Теріс коронарлық Т-тісшесі күрт тереңдеп, симметриялы және үшкір болады (Т-тісшесінің қайта инверсиялануы).

Жітілеу кезеңде МИ патологиялық Q тісшесі немесе QS комплексті (некроз) және теріс коронарлық Т тісшесін (ишемия) тіркейді, оның амплитудасы МИ-нің 20-25 күнінен бастап біртіндеп төмендейді. RS–Т сегменті оқшаулауда орналасқан (1.3.4, ж суретін қараңыз).

Тыртықтану сатысы көптеген жылдар бойы патологиялық тістің Q немесе QS кешенінің сақталуымен және теріс, тегістелген немесе оң Т тісшелерінің болуымен сипатталады (1.3.4, з-суретті қараңыз).

МИ үшін жалпы қабылданған ЭКГ белгілері:

Инфаркт аймағында орналасқан тіркеуіштерде R тісшесінің болмауы.

Инфаркт аймағының үстінде орналасқан тіркеуіштерде патологиялық Q тісшесінің пайда болуы.

Инфаркт аймағының үстінде орналасқан тіркеуіштердің ST сегментінің оқшаулаудан жоғары көтерілуі.

Инфаркт аймағына қарама-қарсы тіркеуіштердегі ST сегментінің оқшаулаудан төмен ығысуы.

Инфаркт аймағының үстінде орналасқан тіркеуіштердегі теріс Т тісшесі.

МИ локализациясына байланысты ЭКГ белгілері әртүрлі ЭКГ тіркеуіштерінде кездеседі (1.3.1-кестені қараңыз).

Кесте 1.3.1. МИ белгілері анықталған локализациялар мен тіркеуіштердің сәйкестігі

МИ локализациясы	МИ белгілері анықталатын тіркеуіштер	
	Тікелей белгілер: патологиялық Q (QS); RS–Т элевациясы; теріс коронарлық Т	Өзара белгілер: RS–Т депрессиясы; Т тісшесі жоғары оң; R тісшесі жоғары (артқы жақ МИ)
Сол жақ қарыншаның алдыңғы жақ миокард инфарктісі		
Алдыңғы аралық	V1 — V3	
Алдыңғы жоғарғы жақ	V3, V4	
Алдыңғы шет жақ	I, aVL, V5, V6	
Алдыңғы базальды (жоғары алдыңғы)	V24 — V26 и/или V34 — V36	
Жалпы алдыңғы	I, aVL, V1 — V6	III, aVF, II
Сол жақ қарыншаның артқы жақ миокард инфарктісі		
Артқы диафрагмалық (төменгі)	III, aVF, II	
Артқы базальды		V1 — V3
Артқы жақ	V5, V6, III, aVF	
Жалпы артқы	III, aVF, II, V5, V6,	V1 — V3

ЭКГ әдісінің ерекшелігі мен сезімталдығы абсолютті емес екендігін айта кету керек. Электрокардиографиялық диагноз МИ тән емес екендігі белгілі, яғни электр процестерінің фокустық өзгерістері миокардтағы ишемиялық зақымданулар мен морфологиялық өзгерістерден ғана емес, сонымен бірге кардиомиопатия мен қарыншалық гипертрофиядан да туындауы мүмкін. Өкінішке орай, МИ электрокардиографиялық диагнозынында қателіктер болуы мүмкін. Диагноз қою кезінде МИ қарыншалық депполяризацияны (QRS кешені) көрсететін қарыншалық кешеннің бастапқы бөлігін талдаумен және қарыншалық кешеннің соңғы бөлігіндегі өзгерістерді – қарыншалық реполяризация элементтерін (ST аралығы және T тісшесі) түсіндіруде қиындықтар туындауы мүмкін. Әр түрлі авторлардың айтуынша, МИ 10-нан 42% - ға дейін диагноз қойылмайды. Жедел МИ (ЖМИ) кейбір ЭКГ-белгілерінің сезімталдығы: ST – тісшесі 54%, Q – аномальді тісшесі 31%.

1.4 Машиналық оқыту алгоритмдерін қолдана отырып, миокард инфарктісін болжау әдісін зерттеу және таңдау

1.4.1 ЭКС өндеуге арналған машиналық оқыту әдістері

Машиналық оқыту - бұл компьютерлер проблемаларды нақты бағдарламаламай шешуді үйренетін ғылыми әдіс [49-50]. Қазіргі уақытта терең оқыту алгоритмдер, есептеу қуаты және үлкен көлемдегі мәліметтерге негізделген ML жарысында көш бастап тұр. Дегенмен, классикалық ML алгоритмдері осы салада күшті позицияларға ие. Біз сызықтық регрессия, логистикалық регрессия, k жақын көршілер мен шешімдер ағашы, тірек векторлық машиналары, кездейсоқ орман және Наивті Байес сияқты машиналық оқытудың әртүрлі әдістеріне салыстырмалы зерттеу жүргіземіз. Біз олардың негізгі логикасын, артықшылықтарын, кемшіліктерін, болжамдарын, коллинеарлық және эмиссиялық әсерлерін, гиперпараметрлерді, өзара салыстыруды және т. б. қарастырамыз.

Сызықтық регрессия. Сызықтық регрессия-бұл регрессиялық модель, ол функцияларды қабылдайды және үздіксіз нәтижені болжайды, мысалы: акциялардың бағасы, жалақы және т.б. Сызықтық регрессия, аты айтып тұрғандай, әр мәселе үшін қисықтың сызықтық шешімін табады [51-53].

Логистикалық регрессия. Сызықтық регрессия сияқты, логистикалық регрессия - жіктеу алгоритмдерінен бастау үшін дұрыс алгоритм. "Регрессия" атауы пайда болғанына қарамастан, бұл регрессиялық модель емес, жіктеу моделі. Екілік Шығыс моделін құру үшін логистикалық функцияны қолданады. Логистикалық регрессияның нәтижесі ықтималдық болады ($0 \leq x \leq 1$) және оны 0 немесе 1 екілік мәндерін шығыс ретінде болжау үшін қолдануға болады (егер $x < 0.5$, $output = 0$, әйтпесе $output = 1$) [54-57].

K-жақын көршілер. K-жақын көршілер-бұл жіктеу және регрессия үшін қолданылатын параметрлік емес әдіс. Бұл ең қарапайым ML әдістерінің бірі. Бұл жергілікті жуықтаумен жалқау оқытудың моделі. KNN-дің негізгі қисыны-сіздің аймағыңызды зерттеп, point тест деректері ұқсас деп болжау

және нәтиже алу. KNN-де біз k көршілерін іздейміз және болжам аламыз [58-62].

Тірек векторларының машинасы. Тірек векторлық машинасы-бұл жіктеу үшін де, регрессия үшін де қолдануға болатын ML әдісінің бір түрі. Онда негізінен сызықтық және сызықтық емес тапсырмаларды қолдаудың екі нұсқасы бар. Сызықтық SVM ядросы жоқ және минималды маржамен мәселенің сызықтық шешімін табады. Ядросы бар SVM шешім сызықты бөлінбейтін кезде қолданылады. Тірек векторлық машина-бұл мәтіндерді жіктеуде, кескіндерді жіктеуде, биоинформатикада және т. б. салаларда кеңінен қолданылатын оқыту әдісі [63-66].

Наивный Байес. Наивтік байес-бұл жіктеу тапсырмалары үшін қолданылатын генеративті ықтималды модель. Бұл мәтіндік классификация үшін қолданылатын негізгі модель, онда функциялар жиынтығы өте үлкен. Ол көңіл-күй талдау, спам сүзу және т. б. үшін кеңінен пайдаланылады [67-69].

Шешімдер ағашы. Шешімдер ағашы - бұл регрессия және жіктеу мәселелерін шешу үшін қолданылатын ағаш тәрізді алгоритм. Төңкерілген ағаш құрылады ол біртекті тамыр түйінінен ықтималдылықты бөлу арқылы шығу үшін қатты әртүрлі соңғы түйіндерге дейін таралады. Регрессия ағаштары үздіксіз мәндері бар тәуелді айнымалы үшін қолданылады, ал жіктеу ағаштары дискретті мәндері бар тәуелді айнымалы үшін қолданылады [70-73].

Кездейсоқ орман. Кездейсоқ орман - бұл күшті модель алу үшін бірнеше шешім ағаштары біріктірілген ансамбль моделі. Туынды модель неғұрлым сенімді, дәл болады және күрделі модельдерге қарағанда артық жабдықтаумен күреседі. Кездейсоқ орманда жіктеу және регрессия нәтижелерін алу үшін "пакеттеу әдісімен" біріктірілген шешімдер жиынтығы бар. Жіктеу кезінде ол көпшілік дауыспен дауыс беру арқылы нәтижені есептейді, ал регрессия орташа мәнді есептейді [74-79].

Нейрондық желілер. Нейрондық желі дегеніміз-бұл математикалық теңдеулер желісі. Ол бір немесе бірнеше кіріс айнымалыларын қабылдайды және теңдеулер желісінен өтіп, бір немесе бірнеше шығыс айнымалыларына әкеледі. Сондай-ақ, нейрондық желі кіріс және қайтару мәндерінің векторын алады деп айта аламыз. Сондай-ақ, нейрондық желі кіріс векторын қабылдайды және шығыс векторын қайтарады деп айта аламыз [80-84].

1.4.1.1-кестеде біз ЭКС-ті өңдеуге жарамды сегіз Машиналық оқыту әдісін салыстырып [85-102], олардың кемшіліктері мен артықшылықтарын жаздық.

Кесте 1.4.1.1. Машиналық оқыту әдістерін салыстыру

Әдістер	Салыстыру
Сызықтық регрессия (Linear Regression)	Шешімдер ағашына қарсы: Шешім ағаштары сызықты емес шешімдерді қолдаса, мұнда LR тек сызықтық шешімдерді қолдайды. Деректер жиынтығы аз (шу деңгейі төмен) нысандар көп болған кезде, сызықтық регрессиялар шешімдер ағашынан / кездейсоқ ормандардан асып кетуі мүмкін. Екі жағдайда да шешімдер ағашы орташа дәлдікке ие болады.

	<p>Категориялық тәуелсіз айнымалылар үшін шешім ағаштары сызықтық регрессияға қарағанда жақсы.</p> <p>SVM-ге қарсы:</p> <p>SVM негізгі трюкті қолдана отырып, сызықтық және сызықтық емес шешімдерді қолдайды.</p> <p>SVM шығындыларды LR-ге қарағанда жақсы өндейді.</p> <p>Олардың екеуі де оқу мәліметтері аз болған кезде және функциялар көп болған кезде жақсы жұмыс істейді.</p> <p>KNN-ге қарсы:</p> <p>KNN-параметрлік емес модель, ал LR - параметрлік модель.</p> <p>KNN нақты уақыт режимінде баяу жұмыс істейді, өйткені ол барлық жаттығу деректерін қадағалап, көрші түйіндерді табуы керек, ал LR нәтижені θ реттелген коэффициенттерден оңай шығара алады.</p> <p>нейрондық желіге қарсы:</p> <p>Нейрондық желілер LR моделімен салыстырғанда үлкен оқыту деректерін қажет етеді, ал LR тіпті аз оқыту деректерімен де жақсы жұмыс істей алады.</p> <p>NN LR-мен салыстырғанда баяу болады.</p> <p>Нейрондық желілермен орташа дәлдік әрдайым жақсы болады.</p>
<p>Логистикалық регрессия (Logistic regression)</p>	<p>SVM қарсы:</p> <p>SVM сызықтық емес шешімдерді өндей алады, ал логистикалық регрессия тек сызықтық шешімдерді өндей алады.</p> <p>Сызықтық SVM шығарындыларды жақсырақ басқарады, өйткені ол шешімді максималды маржамен шығарады.</p> <p>SVM-де топсаның жоғалуы LR-де журнал шығынынан асып түседі.</p> <p>Шешімдер ағашына қарсы:</p> <p>Шешім қабылдау ағаштары белгілердің маңыздылығын анықтай алмайды, бірақ LR мұны жасай алады.</p> <p>Шешім ағаштары LR-ге қарағанда категориялық мәндерге жақсы сәйкес келеді.</p> <p>нейрондық желіге қарсы:</p> <p>NN LR мүмкін емес сызықтық емес шешімдерді қабылдай алады.</p> <p>LR дөңес жоғалту функциясына ие, сондықтан ол жергілікті минимумдарда қатып қалмайды, ал NN қатып қалуы мүмкін.</p> <p>LR оқыту деректері аз және функциялар көп болған кезде NN-ден асып түседі, ал NN-ге үлкен оқыту деректерін қажет етеді.</p> <p>Наивті Байеске қарсы:</p> <p>Байес-генеративті модель, ал LR - дискриминациялық модель.</p> <p>Байес кішігірім мәліметтер жиынтығымен жақсы жұмыс істейді, ал LR + реттелуі ұқсас өнімділікті қамтамасыз ете алады.</p> <p>LR сызықтық негізделген, Байеске қарағанда жақсы жұмыс істейді, өйткені Байес барлық мүмкіндіктер тәуелсіз болғанын күтеді.</p> <p>KNN-ге қарсы :</p> <p>KNN-параметрлік емес модель, мұнда LR - параметрлік модель.</p> <p>KNN логистикалық регрессияға қарағанда баяу жұмыс істейді.</p> <p>KNN сызықтық емес шешімдерді қолдайды, ал LR тек сызықтық шешімдерді қолдайды.</p> <p>LR сенімділік деңгейін анықтай алады (оның болжамына қатысты), ал KNN тек белгілерді көрсете алады.</p>
<p>К-жақын көршілер (KNN)</p>	<p>Наивті Байеске қарсы:</p> <p>Naive Bayes KNN-ге қарағанда тезірек, KNN нақты уақытта орындау арқылы ұзақ жұмыс атқарады.</p>

	<p>Аңғал байес параметрлік, ал KNN параметрлік емес. сызықтық регрессияға қарсы: Деректер жоғары SNR болған кезде KNN сызықтық регрессияға қарағанда жақсы. SVM қарсы: SVM шығарындылар туралы KNN-ге қарағанда жақсы ойлайды. Егер оқыту деректері жоқ болса, әлдеқайда көп. функциялардың ішінен ($m \gg n$) KNN SVM-ге қарағанда жақсы. SVM KNN-ден функциялар көп болған кезде және оқыту деректері аз болған кезде асып түседі. Нейрондық желілерге қарсы: Нейрондық желілер жеткілікті дәлдікке қол жеткізу үшін KNN-мен салыстырғанда үлкен оқыту деректерін қажет етеді. NN KNN-ге қарағанда гиперпараметрлердің үлкен қондырмасын қажет етеді.</p>
Тірек векторлық машинасы (Support Vector Machine)	<p>кездейсоқ орманға қарсы: Кездейсоқ орман көп классты жіктей алады, ал SVM бірнеше модельдерді қажет етеді. Кездейсоқ орман болжамнан асып кету ықтималдығын бере алады, ал SVM оны бере алмайды. Кездейсоқ орман категориялық деректерді SVM-ге қарағанда жақсы өңдейді. Наивті Байеске қарсы: Жаттығу деректерінің аз көлемімен және үлкен мүмкіндіктермен екі нұсқа да жақсы жұмыс істейді. Егер функциялар өзара тәуелді болса, SVM Naive Bayes-тен асып түседі. SVM - дискриминативті модель, ал NB - генеративті модель. нейрондық желілерге қарсы: SVM-де дөнес онтайландыру функциясы бар, ал NN жергілікті минимумдарда тоқтап қалуы мүмкін. Шектеулі оқу деректері мен көптеген мүмкіндіктерді ескере отырып, SVM NN қарағанда жақсырақ жұмыс істей алады. NN жеткілікті дәлдік үшін үлкен оқу деректерін қажет етеді. Көп классты жіктеу SVM үшін бірнеше модельді қажет етеді, ал NN оны бір модельмен жасай алады.</p>
Наивті Байес (Naive Bayes)	<p>логистикалық регрессияға қарсы: Naive Bayes - генеративті модель, ал LR - дискриминативті модель. Naive Bayes шағын деректер жиынында жақсы жұмыс істейді, ал LR+ реттеуі ұқсас өнімділікті қамтамасыз ете алады. LR қоллинеарлылыққа негізделген Naive Bayes-ке қарағанда жақсырақ жұмыс істейді, өйткені Naive Bayes барлық мүмкіндіктердің тәуелсіз болуын күтеді. Шешімдер ағашына қарсы: Шешімдер ағашы - дискриминативті модель, ал Naive Bayes - генеративті модель. Шешімдер ағашы икемдірек және қарапайым. Шешімдер ағашын кесу жаттығу деректеріндегі кейбір негізгі мәндерді елемей мүмкін, бұл лақтыру дәлдігінің төмендеуіне әкелуі мүмкін. кездейсоқ орманға қарсы: Random Forest - күрделі және үлкен модель, ал Naive Bayes салыстырмалы түрде кішірек модель.</p>

	<p>Naive Bayes кішігірім оқу деректерімен жақсырақ жұмыс істейді, ал RF үлкенірек оқу деректер жинағын қажет етеді.</p>
Шешімдер ағашы (Decision Tree)	<p>кездейсоқ орманға қарсы: Кездейсоқ орман - бұл шешімдер ағашының жиынтығы және болжамды нәтиже ретінде орманның орташа/көпшілік дауыстары таңдалады. Кездейсоқ орман моделі шешімдер ағашына қарағанда қайта оқытуға бейім емес болады және жалпыланған жауап береді. Кездейсоқ орман шешімдер ағашына қарағанда сенімді және дәл. KNN қарсы: Екі әдісте параметрлік емес болып табылады. Шешімдер ағашы KNN-ге қарағанда, автоматты түрде объектінің өзара әрекеттесуін қолдайды. Шешімдер ағашы KNN-нің нақты уақытта орындалуына байланысты жылдамырақ болады. Наив Бэйске қарсы: Шешімдер ағашы дискриминациялық модель, ал Naive Bayes генеративті модель. Шешім ағаштары икемдірек және қарапайым. Шешімдер ағашын алып тастаса, жаттығу деректеріндегі кейбір негізгі мәндерді елемеуі мүмкін, бұл лақтыру дәлдігінің төмендеуіне әкелуі мүмкін. нейрондық желіге қарсы: Екеуі де сызықтық емес шешімдерді табады және тәуелсіз айналыстар арасында өзара әрекеттеседі. Шешім ағаштары оқыту деректерінде категориялық мәндердің үлкен жиыны болғанда жақсырақ жұмыс істейді. Сценарий шешімді түсіндіруді талап еткен жағдайда, шешімдер ағашы NN-ге қарағанда жақсырақ болып табылады. Оқыту деректері жеткілікті берілген кезде NN шешімдер ағашынан асып түседі. SVM-ге қарсы: SVM сызықты емес есептерді шешу үшін ядро трюкін пайдаланады, ал шешім ағаштары мәселені шешу үшін кіріс кеңістігінде гипер-тіктөртбұрыштарды шығарады. Шешім ағаштары категориялық деректер үшін жақсырақ және олар SVM-ге қарағанда колинеарлықты жақсы өндейді.</p>
Кездейсоқ орман (random forest)	<p>Naive Bayes қарсы: Random Forest - күрделі және үлкен модель, ал Naive Bayes салыстырмалы түрде кішірек модель. Naive Bayes кішігірім оқу деректерімен жақсырақ жұмыс істейді, ал RF үлкенірек оқу деректер жинағын қажет етеді. нейрондық желілерге қарсы: Екеуі де өте күшті және өте дәл алгоритмдер. Екеуінің де ішкі функциялық өзара әрекеттесулері бар және түсініксіздеу болып келеді. Кездейсоқ орман объектілерді масштабтауды қажет етпейді, ал NN объектілерді масштабтауды қажет етеді. Екі модельдің ансамбльдік нұсқасы күшті болады.</p>

Нейрондық желілер (Neural networks)	<p>сызықтық регрессияға қарсы: Нейрондық желілер LR үлгісімен салыстырғанда үлкен оқу деректерін қажет етеді, ал LR аз оқу деректерімен де жақсы жұмыс істей алады. NN LR салыстырғанда баяу болады. Нейрондық желілерде орташа дәлдік әрқашан жақсырақ болады.</p> <p>логистикалық регрессияға қарсы: NN сызықты емес шешімдерді LR мүмкін емес жерде қолдай алады. LR дөңес жоғалту функциясына ие, сондықтан ол жергілікті минимумдарда тұрып қалмайды, ал NN тұрып қалуы мүмкін. Оқу деректері кішірек және функциялары үлкен болған кезде LR NN-ден асып түседі, ал NN үлкен оқу деректерін қажет етеді.</p> <p>SVM-ге қарсы: Шектеулі оқу деректері мен көптеген функцияларды ескере отырып, SVM NN қарағанда жақсырақ жұмыс істей алады. NN жеткілікті дәлдік үшін үлкен оқу деректерін қажет етеді. Көп класты жіктеу SVM үшін бірнеше модельді қажет етеді, ал NN оны бір модельмен жасай алады.</p> <p>кездейсоқ орманға қарсы: Екеуі де өте күшті және өте дәл алгоритмдер. Екеуінің де ішкі функциялық өзара әрекеттесулері бар және түсінікті емес. Кездейсоқ орман объектілерді масштабтауды қажет етпейді, ал NN объектілерді масштабтауды қажет етеді. Екі модельдің ансамбльдік нұсқасы күшті болады.</p>
-------------------------------------	--

1.4.1.1-кестеде нейрондық желілердің машиналық оқытудың басқа әдістерінен жоғары екенін көре аламыз.

1.4.2 Машиналық оқыту үлгілерін зерттеу

Бастапқы деректерді жүктеу және өңдеу атрибуттары

Біз бұл зерттеуді жүргізу үшін Венгрияның кардиология институтынан, Цюрих университетінің ауруханасынан, Базель университетінің ауруханасынан, Лонг-Бич медициналық орталығынан және Кливленд клиникасынан (<https://physionet.org/content> күрделі физиологиялық сигналдарға арналған зерттеу ресурсы) 303 пациент туралы бастапқы деректерді пайдаландық. Пациенттердің дерекқорында он төрт атрибут бар. Деректер жиынының атрибуттары туралы ақпарат 1.4.2.1 кестеде берілген. 1.4.2.2 кестедегі деректер құрылымын көрсету үшін, зерттеуде пайдаланылған деректер қорының бір бөлігі көрсетілген.

1.4.2.1-кесте. Деректер атрибуттарының сипаттамасы

Атрибуттың нөмірі	Атрибуттың атауы	Атрибуттың сипаттамасы
I	P тісшесінің ауытқуы	Сандық мән 80 мс дейін
II	Жүректің электрлік белсенділігінің	Electrical activity of the heart

	болуы немесе болмауы	(жүректің электрлік белсенділігі)
III	Миокардтың трансмембраналық потенциалы	1 - типтік стенокардия 2 - атипті стенокардия 3 - ангиальды емес ауырсыну 4 - симптомсыз
IV	Тыныштық жағдайында сегментінің ST депрессиясы (ST депрессиясы, d қалыпты жағдайда)	Сандық мән
V	T-тісшесі (0,16 секунд)	Сандық мән
VI	Интервал ST > 0,12 секунд	Сандық мән
VII	жоғарғы RR нүктелері арасындағы интервал	0-between 0,75-1,2 sec, 1- >1,2sec, 2- <0,75sec
VIII	Максималды жүрек соғу жиілігі (ЖСЖ)	Сандық мән
IX	Жаттығудан туындаған стенокардия	1 – бар 0 – жоқ
X	PQ интервалы	Сандық мән
XI	QRS комплексі (қалыпты жағдай от 0,06 дан 1-1,2с.)	1 – бар 0 – жоқ
XII	QT интервалы (0,42 с. аспауы керек)	Сандық мән
XIII	the slope of the peak exercise ST segment (жүктеме кезіндегі ең жоғары ST сегменті)	0 – қалыпты 1 – тұрақты ақау 2 – қайтымды ақау
XIV	the amount of increase in the ejection fraction (босату фракциялардың өсу мөлшері)	>3

1.4.2.2-кесте. Тестілеуге арналған деректер жиынтығының фрагменті (атрибуттың реттік нөмірлері бойынша)

I	II	III	IV	V	VI	VII	VIII	IX	X	XI	XII	XIII	XIV
0,06	1	0	0,11	0,15	0	1	75	1	0,8	1	0,35	0	0
0,1	1	0	0,16	0,10	0	1	125	0	0	0	0,30	0	1
0,05	1	0	0,18	0,18	0	1	101	0	0	1	0,40	1	0
0,04	1	0	0,11	0,16	0	0,80	65	0	0,2	1	0,42	2	1
0,01	1	0	0,14	0,16	0	0,75	69	1	0,4	0	0,38	2	0
0,07	1	0	0,12	0,15	0	0,78	92	1	0,8	1	0,35	2	1
0,02	1	0	0,11	0,16	0	1	93	0	0	0	0,42	0	0
0,03	0	1	0,12	0,15	0	1	96	1	0,2	0	0,48	0	0
0,07	1	3	0,13	0,16	0	1	62	1	0	0	0,45	0	1

Біз максималды жүрек соғу жиілігі, стенокардия және миокардтың трансмембраналық потенциалы сияқты категориялық айнымалылар алдын ала

калыпқа келтірілген тәуелсіз дискретті мәндер болғандықтан кодтауды қолдандық. Кейбір атрибуттар тұрақты болып саналды, мысалы, R толқыны және ST аралығы. Кейбір атрибуттар айнымалылар ретінде қарастырылды, мысалы, шығару фракцияларының өсу мөлшері.

Біздің зерттеу іс жүзінде 14 атрибут пен 297 деректер жолын пайдаланды. Негізгі мақсатымыз 14-ші - науқаста жүрек ауруының болуын болжау үшін алғашқы 13 ақпаратты пайдалану болып табылады.

Атрибуттардың әрбір жұбы арасындағы корреляциялық байланыс талданып, анықталды.

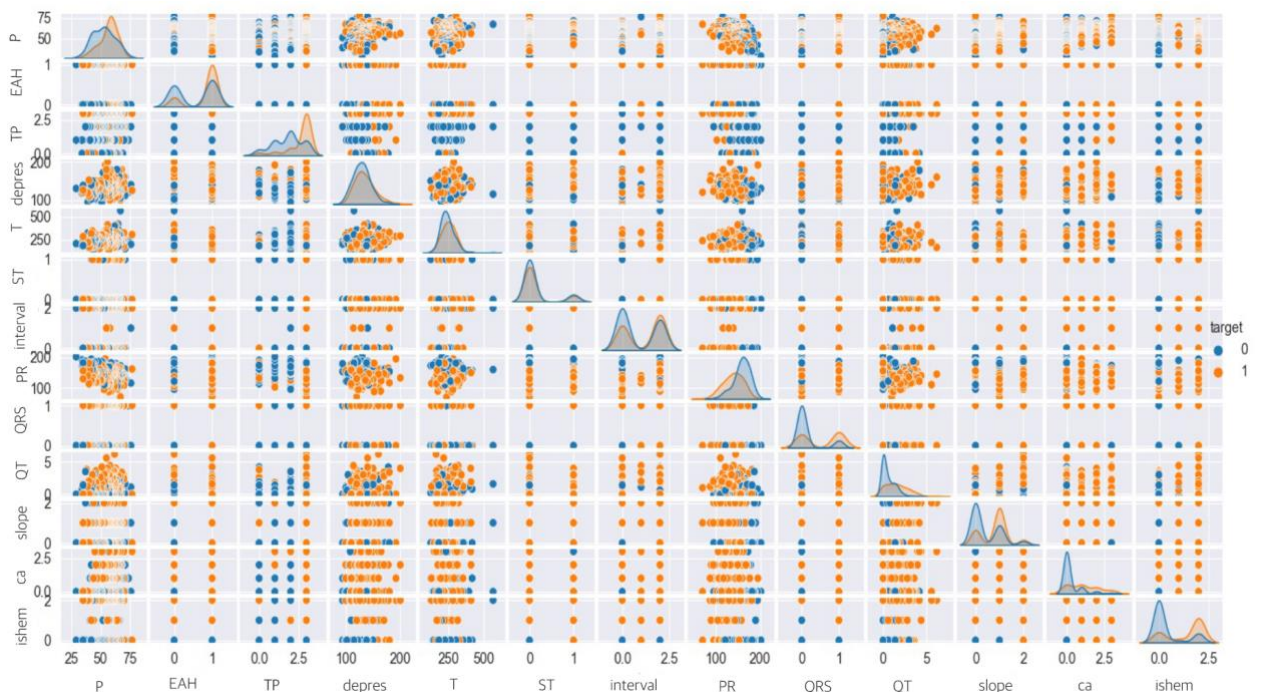
1.4.2.3-кесте. Атрибут мәліметтері

№	Атрибуттар	Мәндері	Сипаттамасы
1	P	0,06-0,1 sec	P тісшесі
2	EAH	1-true, 0-false	Electrical activity of the heart (жүректің электрлік белсенділігі)
3	TP	1-typical angina ; 2-atypical angina 3-non-anginal pain ; 4-asymptomatic	Transmembrane potential of the myocardium (Миокардтың трансмембраналық потенциалы)
4	depres	Numeric value	ST depression to rest (тыныштықта ST депрессиясы)
5	T	Numeric value	T-тісшесі(0,16 миллисекунд)
6	ST	1-true, 0-false	Интервал $0,03 < ST < 0,12$ секунд.
7	interval	0-between 0,75-1,0 sec, 1- $>1,0$ sec, 2- $<0,75$ sec	қарыншалардың жоғарғы RR нүктелері арасындағы интервал
8	PQ	0,12-0,2	PR арасындағы интервал
9	QRS	1-yes, 0-no	QRS комплексінің өзгерісі (қалыпты жағдайда 0,06 дан 1,0 с. дейін)
10	QT	Numeric value	QT арасындағы интервал (0,42с. дейін)
11	slope	1-upsloping, 2-flat, 3-downsloping	the slope of the peak exercise ST segment (жүктеме кезіндегі ең жоғары ST сегменті)
12	ca	>3	the amount of increase in the ejection fraction (босату фракциялардың өсу мөлшері)
13	Ishem	0-normal, 1-fixed defect, 2-reversable defect	Ishemiya

1.4.2.1-суреттегі негізгі диагональдағы графиктер классификация көрсеткішімен (жүрек ауруының болуы немесе болмауы) салыстырғанда әрбір атрибуттың гистограммасы болып табылады. Негізгі диагональда орналаспаған графиктер идентификаторларға сәйкес екі түрлі атрибут арасындағы корреляцияны көрсетеді:

- P тісшесі;
- Electrical activity of the heart (жүректің электрлік белсенділігі);

- Transmembrane potential of the myocardium (Миокардтың трансмембраналық потенциалы);
- ST depression to rest (d тыныштықта, ST депрессиясы);
- T-тіше (160 миллисекунд);
- $0,03 < ST > 120$ миллисекунд, интервалы;
- жоғарғы RR нүктелері арасындағы интервал (0,75-1,0сек);
- PQ аралығы;
- QRS кешенінің өзгеруі (қалыпты 0,06-дан 1,0 с. дейін);
- QT аралығы (норма 0,42 артық емес және 0,35 с кем емес);
- the slope of the peak exercise ST segment (жүктеме кезіндегі ең жоғары ST сегменті);
- the amount of increase in the ejection fraction (босату фракциялардың өсу мөлшері);
- ишемия.



1.4.2.1-сурет. Деректер атрибуттары арасындағы байланыс


Дерекқорға сәйкес келетін жұптастырылған картаны (1.4.2.1-суретті қараңыз) бақылай отырып, біз TP, QRS, QT, көлбеу, ca, ishem (1.4.2.3 кестесін қараңыз) сияқты атрибуттардың үлестірімі, трансмембраналық потенциалдың болуы немесе болмауына байланысты айтарлықтай ерекшеленетінін көреміз. Яғни, бұл атрибуттар пациенттің миокард инфарктісінің кезеңінің ықтималдығын болжауға көмектеседі.

Суреттегі корреляциялық диаграммадан. 1.4.2.1 жүрек ауруының болуы немесе болмауының жүрек ауруы (cp) сияқты атрибуттарды бөлуде QRS кешенінің өзгеруі; тыныштықпен салыстырғанда жаттығудан туындаған ST депрессиясы (oldpeak); жүктеме кезінде шыңы ST сегментінің еңісі (eeg);

ұлғайтылған шығару фракцияларының саны (ca) және миокард ишемиясы (ишем) елеулі айырмашылықтар бар екенін көрсетеді.

Осылайша, миокард инфарктісінің ықтималдығы туралы ақпарат бере алатын, ең статистикалық маңызды атрибуттар анықталды. Атрибуттар арасындағы корреляцияны көрсету үшін түс градациясы корреляция дәрежесіне сәйкес келетін түспен кодталған матрица салынды (1.4.2.2-сурет). Бұл матрицадан QT сегментінің ең жоғарғы шегі, қалыпты жағдайда туындаған ST сегментінің ауытқу көрсеткішімен оң корреляцияланғанын көруге болады. Тыныштық күйімен салыстырғанда корреляция коэффициенті 0,58. Бұл QT сегментінің көлбеуінің мәні жоғарыласа, онда ST депрессия шыңы да жоғарылайды және керісінше.

Миокард инфарктісінің болуының мақсатты мәні ишемия көрсеткішімен (0,52) ең жоғары оң корреляцияға, содан кейін босату фракцияның жоғарылауы, QRS кешенінің өзгеруі, ST депрессиясы және миокардтың трансмембраналық потенциалында жоғары корреляцияға ие болды.



1.4.2.2-сурет. Атрибуттар арасындағы корреляциялық көрініс.

Операциялық ортаны жобалау және деректерді алдын ала өңдеу. Ең алдымен модульдерді импорттап, оқу деректерін жүктейміз:

```
import numpy as np
import pandas as pd
import tensorflow as tf
```

```
from sklearn.model_selection import train_test_split
from sklearn.linear_model import LogisticRegression
from sklearn.neighbors import KNeighborsClassifier
from sklearn.svm import SVC
from sklearn.naive_bayes import GaussianNB
from sklearn.tree import DecisionTreeClassifier
from sklearn.ensemble import RandomForestClassifier
```

```

from sklearn.preprocessing import StandardScaler, MinMaxScaler, RobustScaler
from sklearn.neural_network import MLPClassifier

import seaborn as sns
sns.set_style('darkgrid')

tf.logging.set_verbosity(tf.logging.ERROR)
pd.options.mode.chained_assignment = None
np.random.seed(100)

```

Біріншіден, деректер өрістерінің атын сипаттау үшін өзгертіп аламыз.

```

myData = pd.read_csv("heart.csv")
myData.columns = ['P', 'EAH', 'TP', 'depres', 'T', 'ST', 'interval', 'PQ', 'QRS', 'QT', 'slope', 'ca',
'ischem', 'target']

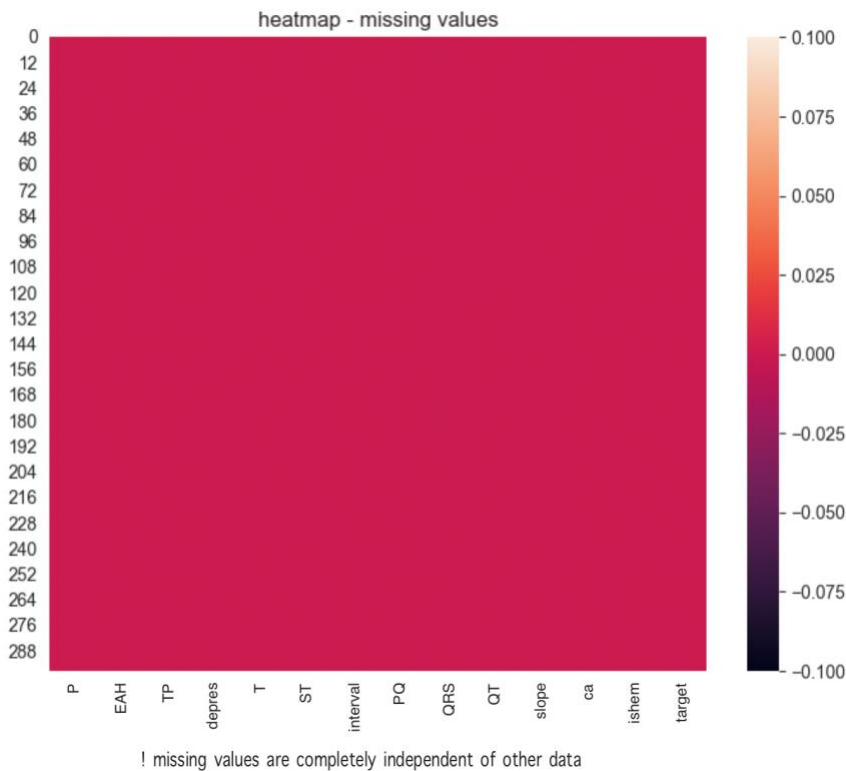
myData['EAH'][myData['EAH'] == 0] = 'no'
myData['EAH'][myData['EAH'] == 1] = 'yes'
myData['TP'][myData['TP'] == 1] = 'typical angina'
myData['TP'][myData['TP'] == 2] = 'atypical angina'
myData['TP'][myData['TP'] == 3] = 'non-anginal pain'
myData['TP'][myData['TP'] == 4] = 'asymptomatic'
myData['depres'][myData['depres'] == 0] = 'lower than 40ms'
myData['depres'][myData['depres'] == 1] = 'greater than 120ms'
myData['T'][myData['T'] == 0] = 'normal'
myData['T'][myData['T'] == 1] = 'ST-T wave abnormality'
myData['T'][myData['T'] == 2] = 'left ventricular hypertrophy'
myData['ST'][myData['ST'] == 0] = 'no'
myData['ST'][myData['ST'] == 1] = 'yes'
myData['st_slope'][myData['st_slope'] == 1] = 'upsloping'
myData['st_slope'][myData['st_slope'] == 2] = 'flat'
myData['st_slope'][myData['st_slope'] == 3] = 'downsloping'
myData['ischem'][myData['ischem'] == 1] = 'normal'
myData['ischem'][myData['ischem'] == 2] = 'fixed defect'
myData['ischem'][myData['ischem'] == 3] = 'reversible defect'

```

Содан кейін деректерді тазалаймыз.

1) жетіспейтін және шектен тыс мәндерді жою

Жетіспейтін мәндердің жылу картасы (1.4.2.3-суретті қараңыз)
деректер жиынында жетіспейтін мәндердің жоқтығын көрсетеді.



1.4.2.3-сурет. - жетіспейтін мәндердің жылу картасы

2) Стандарттау, мәліметтерді нормалау

Біз категориялық айнымалылар үшін бір реттік кодтауды қолданамыз. ST депрессиясының мөлшері, QRS кешенінің өзгеруі және т.б. барлығы one-hot секілді мәндер емес, тәуелсіз дискретті мәндер болып табылады, бұл деректерді $[0,1]$ немесе $[-1,1]$ секілді қалыпқа келтіру керек. Деректерді дайындаймыз: нейрондық желілер қалыпқа келтірілген деректер жиынында әлдеқайда жылдам жаттығады.

```
myData = pd.get_dummies(myData, drop_first=True)
myData = (myData - np.min(myData)) / (np.max(myData) - np.min(myData))
```

3) Деректерді бөлу

Дерекқордан белгілерді және қалған оқу деректерін шығарып аламыз және алдын ала өңделген деректерді сынақ жинағы мен жаттығу жиынына бөлеміз. Өкінішке орай, бұл деректер жинағы өте аз, сондықтан біз тексеруге жиынды арнай алмаймыз. Алдымен деректеріміздің 20%-ын сынақ жинағы ретінде сақтаймыз.

```
x_train, x_test, y_train, y_test = train_test_split(myData.drop('target', axis=1),
                                                    myData['target'], test_size=.2, random_state=2)
```

```
>>>
```

```
Feature set of train data : (252, 13)
```

```
Target set of train data : (252,)
```

```
Feature set of test data : (45, 13)
```

```
Target set of test data : (45,)
```

Scikit-Learn моделдері. Scikit-learn - деректер ғылымы мен машиналық оқытуға арналған ең көп қолданылатын Python пакеттерінің бірі болып табылады. Ол көптеген операцияларды орындауға мүмкіндік береді және көптеген алгоритмдерді ұсынады. Scikit-learn сонымен қатар оның класстары, әдістері және функциялары туралы тамаша құжаттаманы, сондай-ақ қолданылатын алгоритмдердің сипаттамасын ұсынады.

Scikit-Learn:

- мәліметтерді алдын ала өңдеу;
- өлшемді азайту;
- үлгі таңдау;
- регрессия;
- классификация;
- кластерлік талдау секілді мүмкіндіктерге ие.

Ол сондай-ақ модельдерді тексеру үшін пайдалануға болатын бірнеше деректер жиынын қамтамасыз етеді.

Scikit-learn машиналық оқытуға қатысты барлық нәрсені жүзеге асыра алмайды.

Scikit-learn NumPy және SciPy негізінде жасалған, сондықтан Scikit-learn тиімді пайдалану үшін кем дегенде осы екі кітапхананың негіздерін түсіну керек.

Scikit-learn - бұл ашық бастапқы код пакеті. Python экожүйесіндегі заттардың көпшілігі сияқты, коммерциялық пайдалану үшін ол тегін. Ол BSD лицензиясы бойынша лицензияланған.

Scikit-learn деректер жиынында модельдерді жылдам құруға және үйретуге мүмкіндік береді. Осы үлгілердің әрқайсысы `fit()`, сондай-ақ `predict()` және `score()` әдістеріне ие. Бұл дауыс беру ансамблі классификаторын оңай жасауға мүмкіндік береді..

```
lin_model = LogisticRegression(solver='lbfgs')
lin_model.fit(x_train, y_train)
print("Logistic Regression Model Accuracy: ", lin_model.score(x_test, y_test))
```

```
knn_model = KNeighborsClassifier()
knn_model.fit(x_train, y_train)
print("K Nearest Neighbor Model Accuracy: ", knn_model.score(x_test, y_test))
```

```
svm_model = SVC(gamma='auto')
svm_model.fit(x_train, y_train)
print("Support Vector Machine Model Accuracy: ", svm_model.score(x_test, y_test))
```

```
nb_model = GaussianNB()
nb_model.fit(x_train, y_train)
print("Naive Bayes Model Accuracy: ", nb_model.score(x_test, y_test))
```

```
tree_model = DecisionTreeClassifier()
tree_model.fit(x_train, y_train)
print("Decision Tree Model Accuracy: ", tree_model.score(x_test, y_test))
```

```

forest_model = RandomForestClassifier(n_estimators=100)
forest_model.fit(x_train, y_train)
print("Random Forest Model Accuracy: ", forest_model.score(x_test, y_test))

```

Нәтижелер кездейсоқ бастапқы мәндерге байланысты әр түрлі болады (іс жүзінде өте аз!). Бір айналым келесі нәтижені берді:

```

Logistic Regression Model Accuracy: 0.852
K Nearest Neighbor Model Accuracy: 0.836
Support Vector Machine Model Accuracy: 0.852
Naive Bayes Model Accuracy: 0.869
Decision Tree Model Accuracy: 0.754
Random Forest Model Accuracy: 0.836

```

Терең оқыту моделі

Болжамдарымызды жасау үшін нейрондық желі моделін қолдана отырып, нәтижені жақсартуға тырысайық.

neural networks part

#Preprocessing

```

def onehot_encode(df, column_dict):
    df = df.copy()
    for column, prefix in column_dict.items():
        dummies = pd.get_dummies(df[column], prefix=prefix)
        df = pd.concat([df, dummies], axis=1)
    df = df.drop(column, axis=1)
    return df

```

def preprocess_inputs(df, scaler):

```

    df = df.copy()

    # One-hot encode the nominal features
    nominal_features = ['cp', 'slope', 'thal']
    df = onehot_encode(df, dict(zip(nominal_features, ['CP', 'SL', 'TH'])))

```

Split df into X and y

```

y = df['target'].copy()
X = df.drop('target', axis=1).copy()

```

Scale X

```

X = pd.DataFrame(scaler.fit_transform(X), columns=X.columns)

```

return X, y

X, y = preprocess_inputs(myData, MinMaxScaler())

#Training

```

X_train, X_test, y_train, y_test = train_test_split(X, y, train_size=0.8, random_state=0)

```



```


#Neural Network
nn_model = MLPClassifier()
nn_model.fit(X_train, y_train)
print("Neural Network Accuracy: {:.2f}%".format(nn_model.score(X_test, y_test) * 100))

```


көріп отырғанымыздай, нәтижесі әлдеқайда жақсырақ:

Neural Network Accuracy: 90.16%

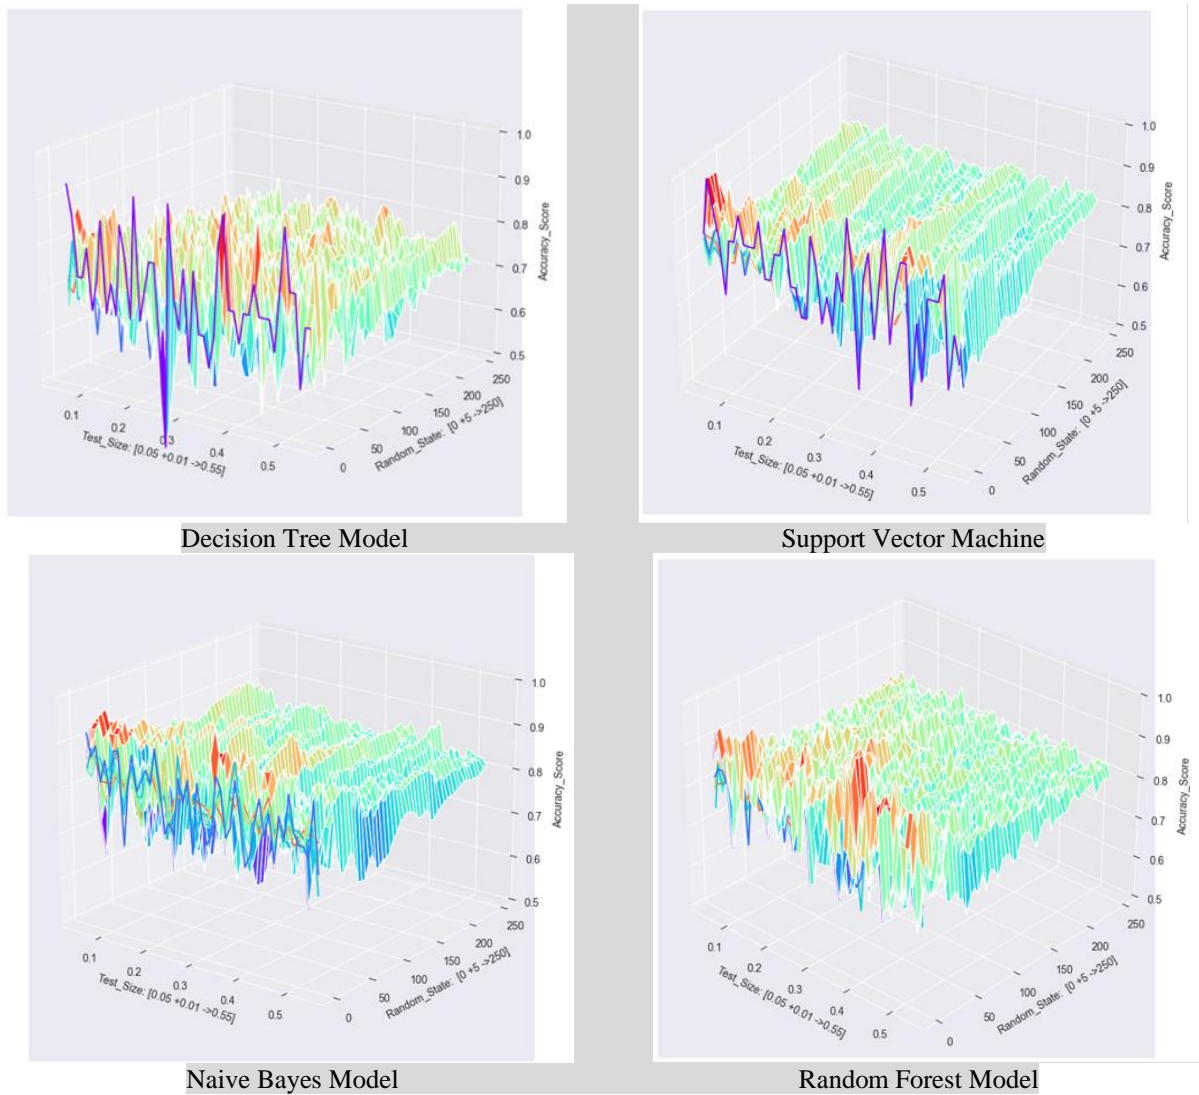
Оқытудан кейін кірістерге сәйкес келетін дәлдікті алуға болады және үш өлшемді дәлдік бетінің қисығы (1.4.2.4-суретті қараңыз) деректер нүктелерінен құрылуы мүмкін (z осі ретінде модель дәлдігін, X осі ретінде сынақ өлшемін, y осі ретінде кездейсоқ күйді қолдана отырып), ол көрсетілуі мүмкін негізгі заңдар мен өзгеретін тенденциялар арасында кейінгі жөндеу кезінде мәліметтер жиынтығын бөлудің әртүрлі және тұрақты әдісін алу үшін модель параметрлерін, яғни модельді болжау дәлдігін `test_size` және `random_state` тиісті мәндерін таңдау арқылы оңтайландыруға болады.



Logistic Regression



K-Nearest Neighbor



Сурет 1.4.2.4 - әр модельдің үш өлшемді қисық бетінің дәлдігі

1.4.2.4-суреттегі әрбір график дәлдік деректерінің 50×50 нүктесінен тұратын дәлдік бетінің қисығы болып табылады. Олардың ішінде жылы түс жоғары дәлдікті көрсетеді, ал сол жақтағы көк сынық сызық-random State = 0 мысалында ұсталған дәлдік қисығы.

Осы графиктерден test Size мәнінің x - өзгеруі бағытында әр модельдің өзінің ерекше тарату қасиеттері бар екенін көруге болады. Ал y бағытында - Random State мәнінің өзгеруі, дәлдік қисығы Random State мәнімен шамамен теріс байланысты, яғни Random State мәнінің жоғарылауымен төмендейді. Модель салыстырмалы түрде жоғары жаһандық дәлдікке (шыңға) жеткенде, Random State негізінен (5, 30) аралықта болады.

Содан кейін алдымен Random state = 20 аламыз (бұл жағдайда дәлдік мәні экстремалды мәндерді алуға оңай), test Size бен Accuracy Score/әр модельдің дәлдігі арасында нүктелік-сынған диаграммаларды сызамыз, нәтижелері 1.4.2.5 суретте көрсетілген. 1.4.2.4-суреттегі графиктермен бірге мынаны байқауға болады: x - Test Size бағытында $[0,08, 0,14]$ аралықтарында салыстырмалы түрде жоғары дәлдік бар, $[0,08, 0,14]$ аралықтарында Random state = 20 кезінде дәлдіктің өзгеруі салыстырмалы түрде тұрақты, ал Random

State = 0 кезінде дәлдіктің өзгеруі үлкен ауытқуды тудырады. мұның бәрі салыстырмалы түрде жоғары, бірақ тұрақты емес дәлдік көбінесе underfitting және overfitting-пен байланысты.

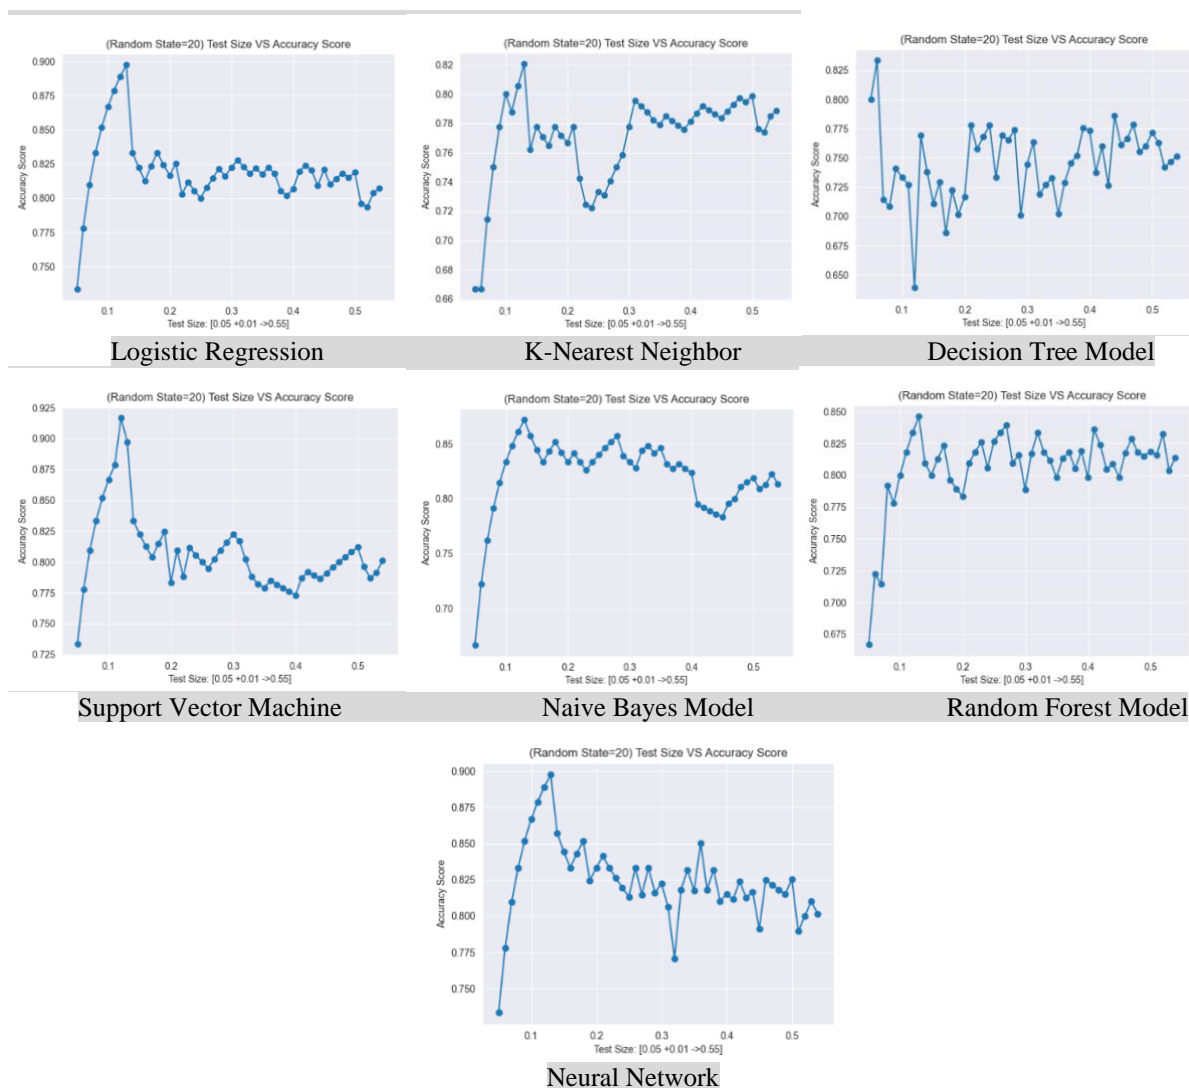


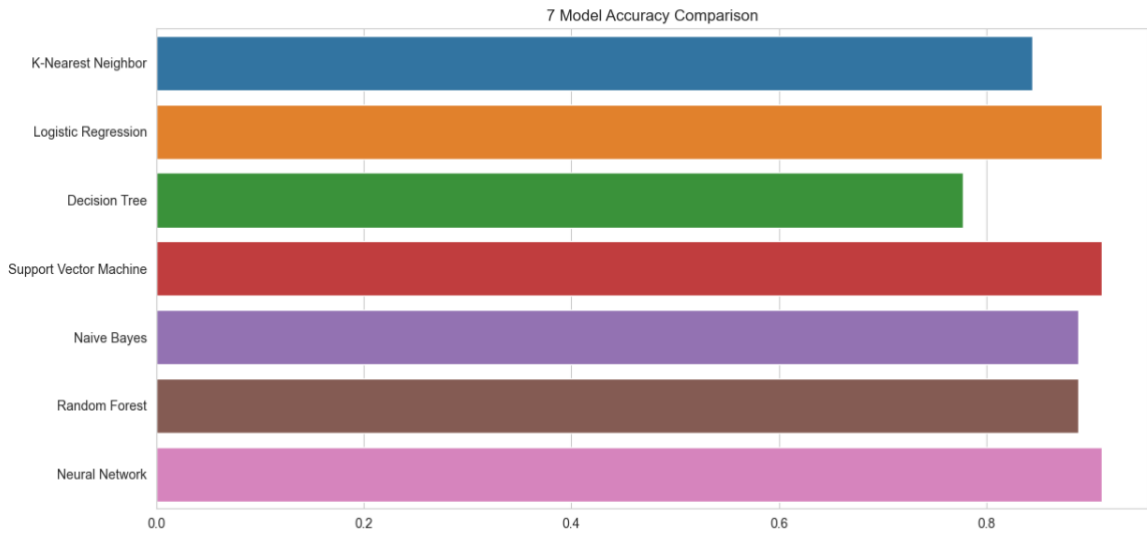
Рисунок 1.4.2.5 - Әр модельдің нүктелік дәлдік графигі (Random State = 20 кезінде)

Машиналық оқыту модельдерін салыстыру

Test_size = 0,15 және random_state = 50 кезінде дәлдік-әр модельден алынған екілік жіктеудің нәтижесі:

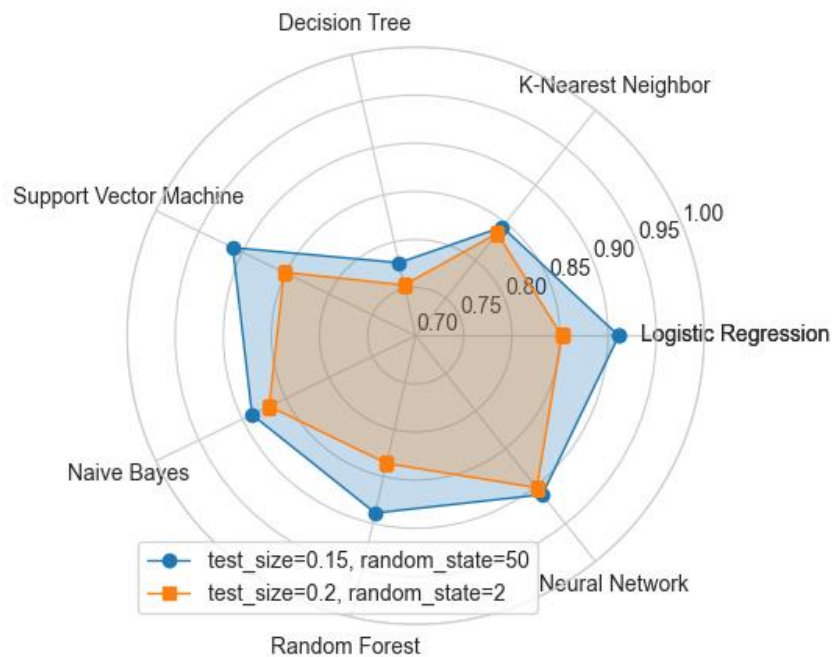
- Logistic Regression - 0.911
- K Nearest Neighbor - 0.844
- Decision Tree Model - 0.778
- Support Vector Machine - 0.911
- Naive Bayes Model - 0.889
- Random Forest Model - 0.889
- Neural Network Model - 0.911

Осы 7 модельді салыстырудың гистограммасы 1.4.2.6-суретте көрсетілген.



Сурет 1.4.2.6 - 7 модельдің дәлдігін салыстыру

Алынған нәтижелермен бірге интуитивті салыстыру үшін әртүрлі жағдайларда алынған екі модельдің радарлық дәлдік диаграммаларын саламыз.




Сурет 1.4.2.7. - Радиолакациялық диаграмма екі модельдің дәлдігін салыстыру

Айта кету керек, әр модельдің дәлдігі тұрақты емес, деректерді қалыпқа келтіру, мәліметтер жиынтығын бөлу және модельдерді құру кезінде модельдің дәлдігін параметрлерді реттеу арқылы жақсартуға болады.

Штатастыру матрицасы және модельдерді бағалау

Шатастыру матрицасы деректердегі нақты нәтижелермен (мақсатты мәнмен) салыстырғанда жіктеу моделі жасаған дұрыс және бұрыс болжамдардың санын көрсетеді. 1.4.2.8-суретте жеті модельдің әрқайсысы алған араластыру матрицасы негізінде жасалған жылу картасы көрсетілген.

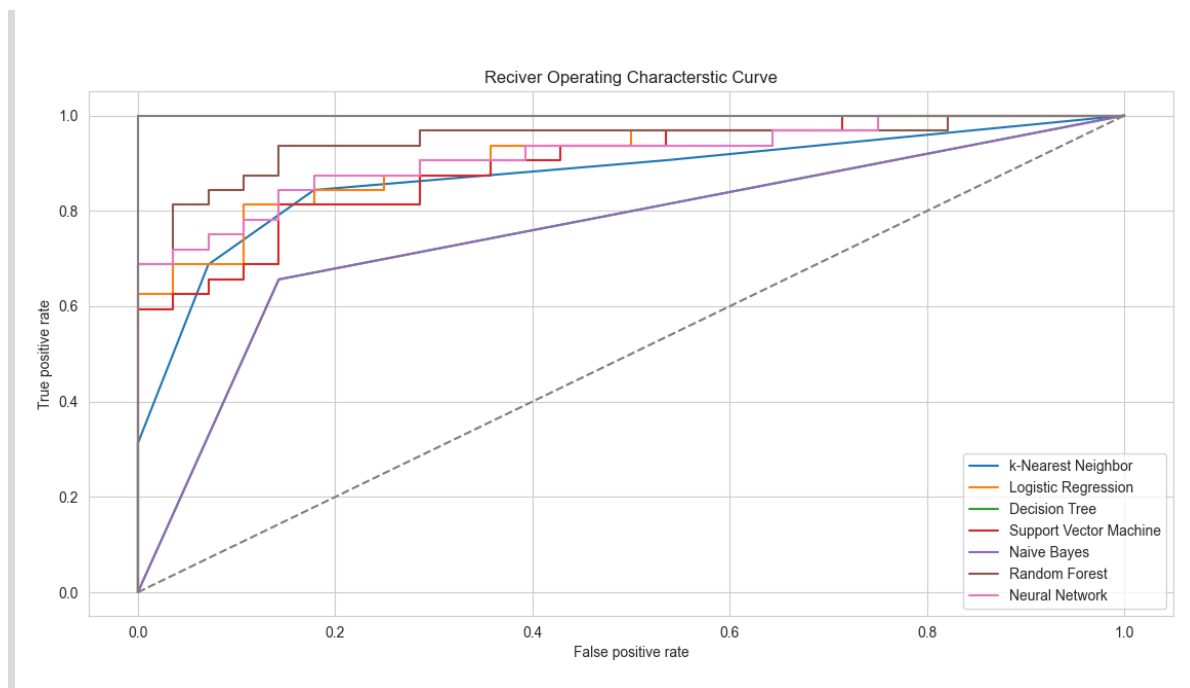


Сурет 1.4.2.8. - Әртүрлі модельдердегі шатастыру матрицалары

ROC қисық және әрбір моделі AUC мәні

ROC диаграммасы (receiver operating characteristic) жіктеу модельдері арасында салыстыру құралын ұсынады. ROC диаграммасында X осі бойынша жалған оң көрсеткіш (False Positive Rate, FPR ерекшелігі), мақсаты ықтималдығы = 1 тең болса, егерде оның шын мәні 0-ге тең болса, Y осі бойынша шынайы оң көрсеткіштермен (True Positive Rate, TPR - чувствительность, TPR сезімталдығы) салыстырғанда, мақсат ықтималдығы = 1 тең болса, егер оның шын мәні 1-ге тең болған жағдайда.

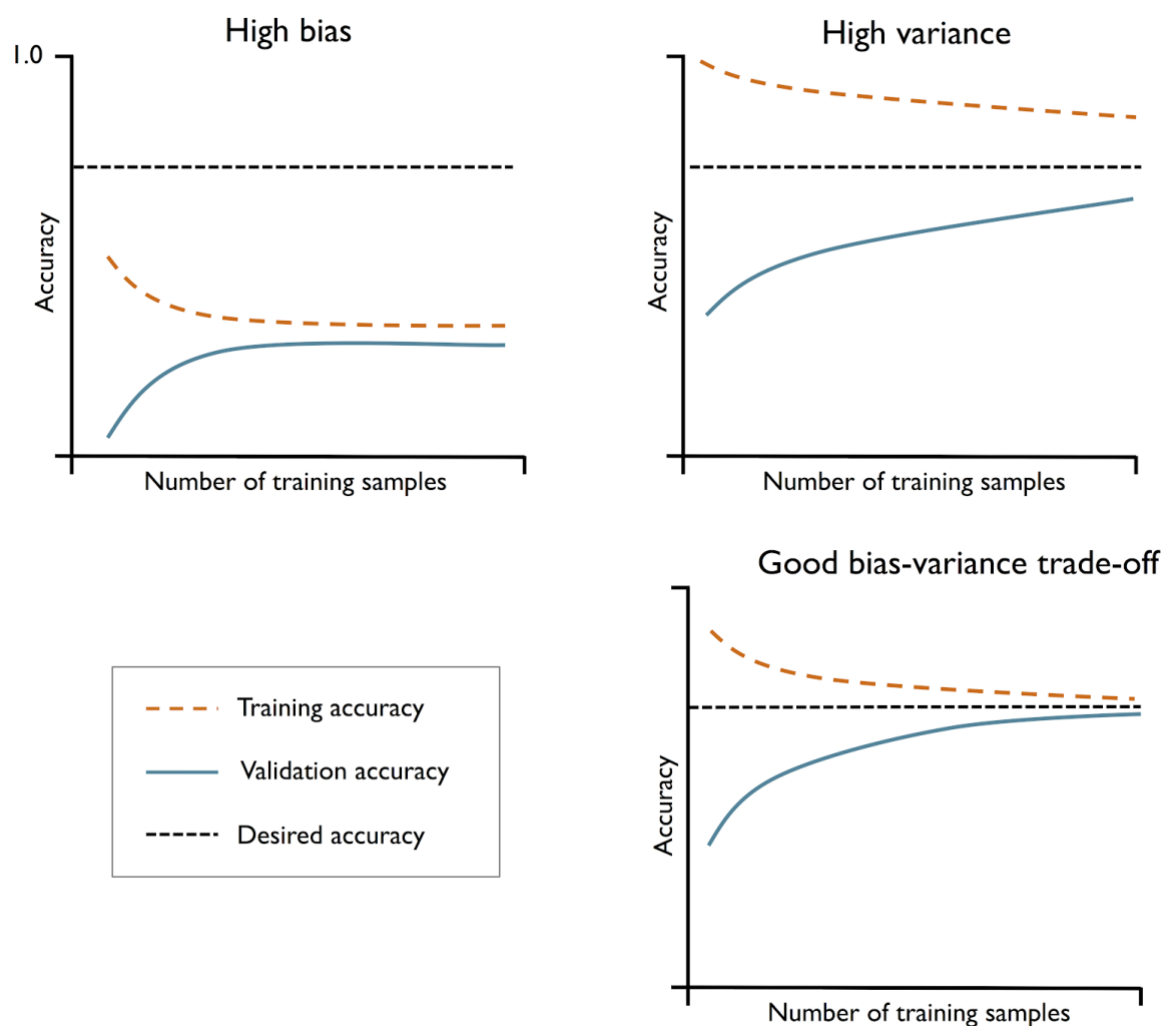
Ең дұрысы, ROC қисығы жасырын сол жақ шекараға тез көтерілу керек, яғни модель жағдайларды дұрыс болжады дегенді білдіреді. Диагональды сызық кездейсоқ модельге сәйкес келеді.



Сурет 1.4.2.9. - ROC curve

Модель жағдайын бағалау үшін оқыту қисығы (Learning curve)

Оқу қисығы-бұл жаттығу жиынындағы және әр түрлі мөлшердегі жаттығулар жиынтығындағы үлгіні бағалаудың өзгеру қисығы. Ол модельді оқыту жиынтығына сәйкестендірудің дәлдігін және модельді болжау дәлдігі абсцисса ретінде үлгіні қалай өзгертетінін және оқу және қиылысы — тексеру жиынтықтарындағы балдардың (мысалы, дәлдік) ордината екенін білдіреді. Оқыту қисығы модельдің қазіргі жағдайын анықтай алады: шамадан тыс жүктеме (*overfitting / high variance*) немесе толық емес оқыту (*underfitting / high bias*). Модельдің қайта оқытылуы мен толық емес оқытылуын ажырату үшін оқыту қисығының дискриминантты әдісі 1.4.2.10-суретте көрсетілген.



Сурет 1.4.2.10. - Оқыту қисығын жіктеу критерийі

Біздің деректер жиынымыздың өлшемі $297 * 13$ болғандықтан, оқу қисығын келесі процесс арқылы сызуға болады:

1 қадам. Деректер жиынтығын оқуға арналған мәліметтер жиынтығына және кросс-тексеруге арналған мәліметтер жиынтығына бөлеміз.

2 қадам. Оқу үлгісінің 20% - ын оқу үлгісі ретінде аламыз және модель параметрлерін үйретеміз.

3 қадам. Оқытылған модельдің дәлдігін есептеу үшін кросс-тексеру деректерін пайдаланамыз.

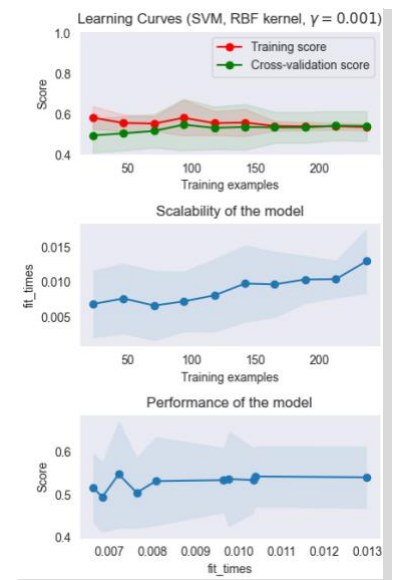
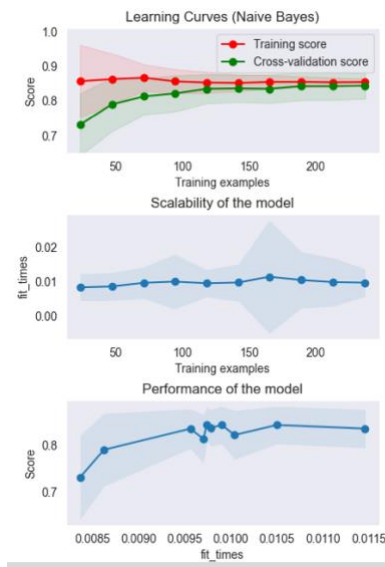
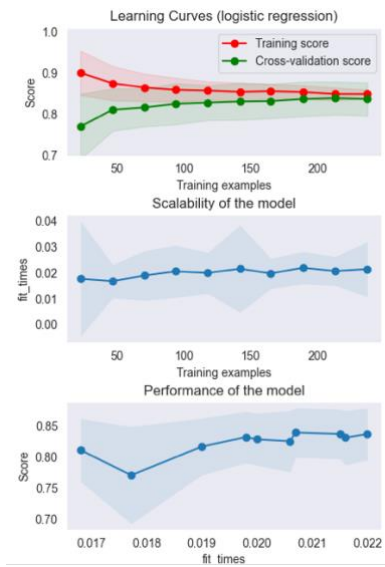
4 қадам. Оқу мәліметтері жиынтығының дәлдігін және ординат осі бойынша кросс-тексерудің дәлдігін және абсцисса осі бойынша оқыту мәліметтерінің жиынтығын қабылдап, алдыңғы қадамдарда есептелген модельдің дәлдігін координат осіне қолданамыз.

5 қадам. Оқу деректерінің жиынтығын 10% - ға көбейтіп, 3-қадамға өтеміз және оқу деректерінің жиынтығы 100% - ға жеткенше жалғастырамыз.

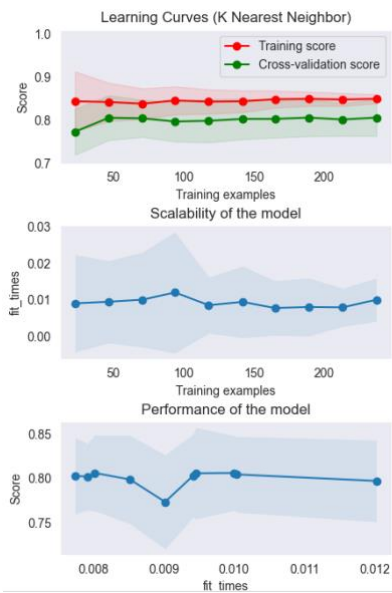
Logistic Regression

Naive Bayes Model

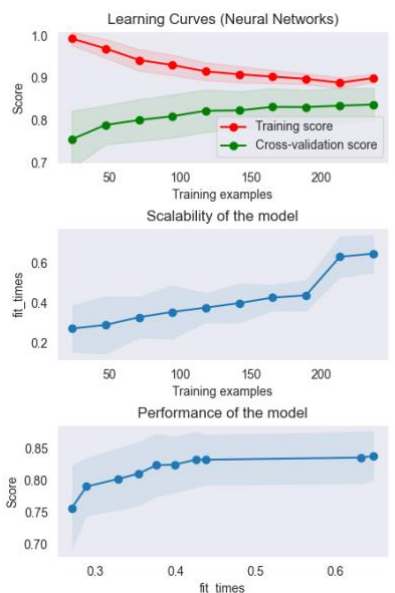
Support Vector Machine



K Nearest Neighbor

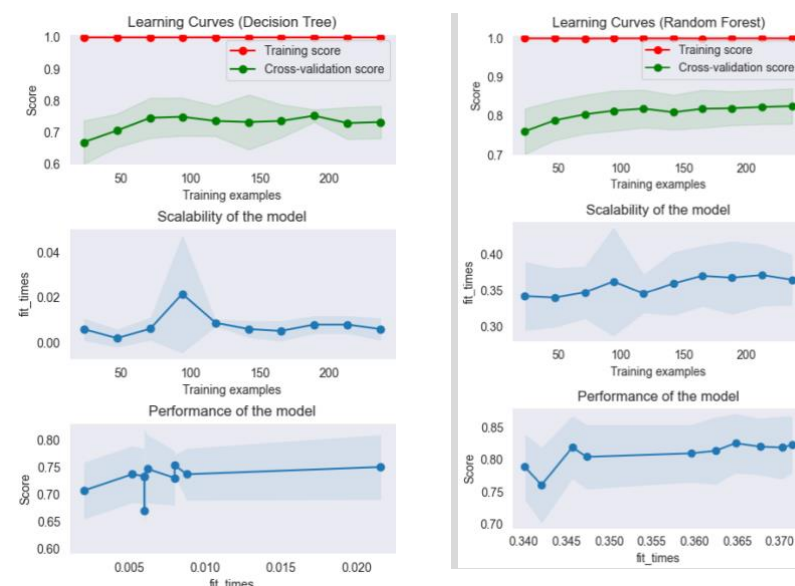


Neural Networks



Decision Tree Model

Random Forest Model



Сурет 1.4.2.10. - 7 түрлі модельдің оқу қисықтары ($n_splits=50$, $test_size=0,2$, $random_state=0$)

Олардың ішінде, бірінші жолдағы графиктер оқу жиынтығының әртүрлі өлшемдеріндегі модульдерді оқыту қисығын көрсетеді; екінші жолда модельдердің оқу жиынтығының әртүрлі өлшемдерімен оқуға кететін уақыты көрсетілген; үшінші жолда-әр жаттығу өлшемі үшін модельдерді оқытуға қанша уақыт кеткенін көрсетілген.

Қызыл сызық: оқытушының мәліметтер жиынтығы үшін есептелген балы, яғни модельді оқыту жиынтығына сәйкестендірудің дәлдігі.

Жасыл сызық: кросс-валидация туралы мәліметтер жиынтығы үшін есептелген балл, яғни модельді қиылыса тексеру туралы мәліметтер жиынтығына болжау дәлдігі.

Барлық мәліметтер: логистикалық регрессия, К-жақын көршілердің әдісі, шешімдер ағашы, тірек векторлық машина, Байес классификаторы, кездейсоқ орман және нейрондық желілер, жеті модельмен талданды. Машиналарды оқыту әдістерін бағалау үшін алдын-ала өңделген деректерді оқу және тест жиынтықтарына бірнеше рет кездейсоқ бөлу қолданылды. Нәтиже осы бөлудің кездейсоқ бастапқы мәндеріне байланысты өзгеруі мүмкін болғандықтан, сәйкесінше сынақ үлгісі ретінде деректердің 20% және 15% - ы бар екі эксперимент жүргізілді. Сынақ жиынтығы ретінде деректердің 20% және 15% - ын сақтай отырып, барлық модельдер бойынша эксперименттердің екі сериясының нәтижелері 1.4.2.4-кестеде келтірілген.

Кесте 1.4.2.4. Эксперименттердің екі сериясының нәтижелері

Машиналық оқыту моделі	20% сынама үлгісімен модельдердің дәлдігі	15% сынама үлгісімен модельдердің дәлдігі	Модельдердің сапа параметрінің мәні (AUC)
Логистикалық	0.852	0.911	0.95

регрессия			
К-жақын көршілер әдісі	0.836	0.867	0.94
Тірек векторлық машиналары	0.852	0.911	0.94
Байес классификаторы	0.869	0.889	0.95
Шешімдер ағашы	0.754	0.822	0.89
Кездейсоқ орман	0.836	0.933	0.94
Нейрондық желілер әдісі	0.902	0.911	0.95

Алынған нәтижелерді талдау мақсатында, модельдердің дәлдігін салыстыру үшін графиктер салынды (сурет. 1.4.2.10.). Машиналық оқытудың барлық зерттелген әдістерінің негізгі параметрлері 1.4.2.5-кестеде келтірілген.

Кесте 1.4.2.5. Бақыланатын машиналық оқыту әдістерінің параметрлері

Машиналық оқыту моделі	Әдістің негізгі параметрлері
Логистикалық регрессия	Реттеу түрі: L2 (модельдің төмен салмақтық коэффициенттерінің пайда болуына ықпал етеді). Оңтайландыру алгоритмі: шектеулі жады бар Бройден–Флетчер–Голдфарба–Шанно алгоритмі. Шешім конвергенциясы үшін итерациялардың максималды саны: 100.
К-жақын көршілер әдісі	Сұраулар үшін әдепкі бойынша пайдаланылатын көршілердің саны: 5 Болжау кезінде қолданылатын салмақ функциясы: әр көршінің салмағы тең. Метрика: Минковскийдің қашықтығы.
Тірек векторлық машиналары	Ядро: радиалды негіз функциясы. Көпмүшелік ядро функциясының дәрежесі: 3. Кэш өлшемі: 200 мб.
Байес классификаторы	Кластардың априорлық ықтималдығы: деректерге сәйкес түзетілмейді. Есептеулердің тұрақтылығын қамтамасыз ету үшін айнымалы тегістеу коэффициенті: 10^9 (дисперсияға қосылған барлық объектілердің ең үлкен дисперсиясының бөлігі).
Шешімдер ағашы	Бөлу сапасын өлшеу функциясы: Джини коэффициенті. Ағаштың ішкі түйінін бөлуге қажетті үлгілердің ең аз саны: 2. Соңғы түйінде болу үшін қажетті үлгілердің ең аз саны: 1
Кездейсоқ орман	Шешім ағаштарының саны: 100. Бөлу сапасын өлшеу функциясы: Джини коэффициенті (Gini Impurity). Ішкі түйінді бөлуге қажетті үлгілердің ең аз саны: 2.

	Соңғы түйінде болу үшін қажетті үлгілердің ең аз саны: 1.
Нейрондық желілер әдісі	<p>Жасырын қабаттардың саны: 100.</p> <p>Әрбір жасырын қабаттың активтендіру функциясы: кесілген сызықтық түрлендіру.</p> <p>Салмақты оңтайландыру алгоритмі: моменттерді адаптивті бағалау әдісі.</p> <p>Итерациялардың максималды саны: 200.</p> <p>Ерте тоқтату үшін тексеру жиынтығы ретінде кейінге қалдыру қажет оқыту деректерінің үлесі: 0.1.</p> <p>Адаптивті бағалау әдісінің сандық тұрақтылығының мәні: 10^{-8}</p>

1.4.2.5-кестеде біз машиналық оқытудың әр бақыланатын әдісінің негізгі параметрлерін сипаттадық.

1.5 Электрокардиосигналды нейрожелілік талдау

1.5.1 Жасанды нейрон және оның іске белсендіру функциялары

Жасанды нейрондық желілер (ЖНЖ) жасанды интеллект саласындағы зерттеулерден пайда болды, атап айтқанда биологиялық жүйке жүйелерінің мидың төмен деңгейлі құрылымын модельдеу арқылы үйрену және қателерді түзету қабілетін көбейтуге тырысу. 60-80 жылдардағы жасанды интеллект бойынша негізгі зерттеу саласы сараптамалық жүйелер болды. Мұндай жүйелер ойлау процесін жоғары деңгейлі модельдеуге негізделді (атап айтқанда, біздің ойлау процесіміз символдарды басқаруға негізделген деген идеяға негізделген). Көп ұзамай мұндай жүйелер кейбір салаларда пайда әкелуі мүмкін болғанымен, адам ақыл-ойының кейбір негізгі аспектілерін қамтымайтыны белгілі болды.


ЖНЖ шешетін тапсырмалардың кең ауқымы әмбебап, қуатты желілерді құруға мүмкіндік бермей, аппараттық немесе бағдарламалық жасақтамада әртүрлі алгоритмдер бойынша жұмыс істейтін мамандандырылған нейрондық желілерді дамытуға мәжбүр етеді. Сонымен қатар әрбір жасанды нейрондық желінің негізін салыстырмалы түрде қарапайым, көп жағдайда ми нейрондарының жұмысын еліктейтін бір типті элементтер (клеткалар) құрайды.

Әрбір нейрон қоздырылуы немесе тежелуі мүмкін ағымдағы күйімен сипатталады. Нейронның тармақталған ақпаратты енгізу құрылымы (дендриттер), ядросы және тармақталған шығысы (аксон) болады. Жасушаның аксондары синапс арқылы басқа жасушалардың дендриттерімен байланысады. Іске қосылған кезде нейрон өз аксонына сигнал жібереді. Синапстар арқылы бұл сигнал басқа нейрондарға жетіп, өз кезегінде оларды белсендендіруі мүмкін. Нейрон оның ядросына дендриттерден келген сигналдардың жалпы деңгейі белгілі бір деңгейден (белсенділік шегі) асқанда белсендіріледі. Әрбір

нейрон кіріс векторының өлшемімен (дендриттер саны) және белсендіру функциясымен сипатталады.

Әрбір синапс синоптикалық қосылымның мәнімен немесе оның салмағы w_i -мен сипатталады, ол физикалық түрде электр өткізгіштікке тең.

Структура нейрона и его возможные функции активации приведены на рисунке 1.5.1.1.



1.5.1.1-сурет – Нейронның құрылымы және оның белсендіру қызметтері:

- а) бір секіріс функциясы; б) сызықтық шек (гистерезис);
- в) сигмоид – гиперболалық тангенс; г) сигмоид – формула

Нейронның ағымдағы жағдайы оның кірістерінің өлшенген қосындысы ретінде анықталады:

$$s = \sum x_i * w \quad (1.1)$$

Нейронның шығуы-оның күйінің функциясы:

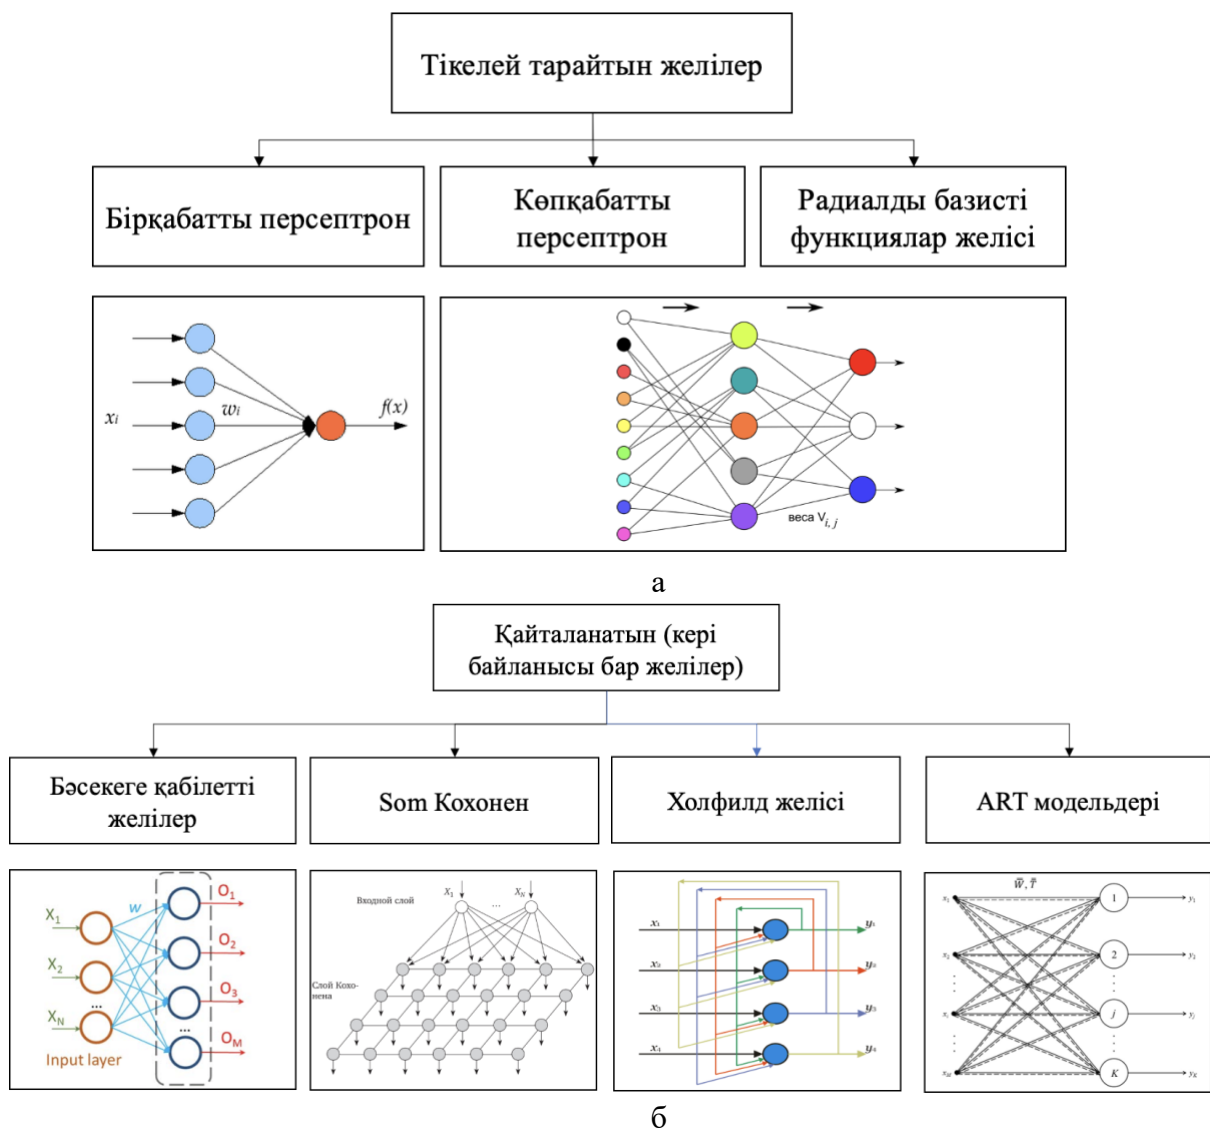
$$y = f(s) \quad (1.2)$$

f сызықты емес функциясы активация деп аталады және 1.5.1.1 суретте көрсетілгендей әр түрлі болуы мүмкін. Ең көп таралған функциялардың бірі-қанықтылығы бар сызықты емес функция, логистикалық функция немесе сигмоид деп аталады(яғни S-тәрізді функция):

$$f(x) = 1/(1+e^{-\alpha x}) \quad (1.5.1.1)$$

1.5.2 Нейрондық желілер мен оқыту алгоритмдерінің жіктелуі

Байланыс архитектурасы бойынша ЖНЖ екі сыныпқа топтастыруға болады (1.5.2.1-суретті қараңыз) [103]: бағандарда ілмектері жоқ тікелей тарату желілері (А) және қайталанатын желілер (б) немесе кері байланысы бар желілер.



Сурет 1.5.2.1 - Жасанды нейрондық желілердің байланыс архитектурасы

Нейрондық желілерді оқыту алгоритмдерін (НЖ) 3 негізгі топқа бөлуге болады: "мұғаліммен", "мұғалімсіз", "аралас".

ЭКС-ті талдау үшін мұғалімнің көмегімен оқытылатын желіні пайдалану керек, өйткені оқу үлгісін қалыптастыру кезінде біз әр берілген мән үшін шығысында алатын дұрыс мәнді білеміз.

Мұғаліммен бірге оқитын НЖ классын толығырақ қарастырайық, бұл ЭКС талдау мәселесін шешу үшін белгілі бір желілік топологияның пайдасына таңдау жасауға мүмкіндік береді.

а) Бір қабатты перцептрон

Бір қабатты перцептронды оқыту 1949 жылы ашылған Хэбб ережесі бойынша жүзеге асырылады [104]. Бұл НЖ мүмкіндіктері өте шектеулі екенін Минск М. Л. дәлелдеді [105]. Бір қабатты перцептронды сәтті оқыту үшін жиынтықтың сызықтық бөлінуі туралы мәселені шешу қажет екендігі белгілі болды, бұл көптеген айнималылар (ЖНЖ кірістері) үшін мүмкін болмады. Осылайша, ЭКС талдау үшін бір қабатты ЖНЖ қолайлы емес.

б) Көп қабатты перцептрон

Көп қабатты перцептронның бір қабаттан артықшылығы қабаттар арасындағы сызықты емес активтендіру функциясы бар болғанда ғана мүмкін екендігі атап өтілді. Колмогоров теоремасының белгілі болғандай, екі қабатты перцептрон кез-келген жуықтау және жіктеу мәселесін шешу үшін жеткілікті, барлық жасырын қабаттың салмағының санына ғана негізделген. Көп қабатты перцептронды пайдалану кезінде логистикалық немесе тангенциалды сигмоидты активтендіру функциясын қолдануға болады (олардың ең маңызды артықшылығы-туындыны есептеу қарапайымдылығына байланысты ЖНЖ-ны аппараттық деңгейде жүзеге асыруды айтарлықтай жеңілдетеді):

$$Y = \frac{1}{1 + e^{-x}} \quad (1.5.2.1)$$

$$Y = th(X) \quad (1.5.2.2)$$

Көп қабатты перцептрон қатені кері тарату алгоритмі арқылы оқытылады. Жақсы оқытылған көп қабатты желі өте жақсы нәтиже береді, бірақ оны оқыту барысында, әдетте, көптеген қиындықтарды жеңуге тура келеді. Оларға:

- жергілікті минимумның тұзағы (жаттығу кезінде жергілікті минимумға түскен кезде өте үлкен қате пайда болады, бірақ салмақты түзеткеннен кейін қате одан да көп болады, бұл салмақтың "сәтті" комбинациясының оралуына әкеледі). Бұл проблемадан құтылудың негізгі әдісі-оқытудың жоғары жылдамдығын анықтау және оқу барысында осы параметрді біртіндеп азайту. Бұл әдіс локалды минимумның тар аймақтарында ғана жақсы жұмыс істейді. Локалды минимумның кең аймақтары үшін, өкінішке орай, тұзақты айналып өтудің кепілдендірілген әдісі жоқ.

– желінің қатып қалуы. Желіні оқыту процесінде салмақтардың мәндері түзету нәтижесінде өте үлкен мәндерге айналуы мүмкін, бұл оқу процесінің қатып қалуына әкеледі. Теориялық тұрғыдан алғанда, бұл мәселе нашар түсініледі. Бұл әдетте оқу жылдамдығы параметрін азайту арқылы болдырмайды, бірақ бұл оқу уақытын арттырады.

Бұл екі мәселе қабаттасып кетуі мүмкін. Жергілікті ең аз тұзаққа жол бермеу үшін оқу жылдамдығын арттыру желіні оңай парализациялауы мүмкін және керісінше. Бар проблемаларға қарамастан, көп қабатты перцептрон әлі де ең танымал желі парадигмасы болып табылады..

в) Рекурентті желі

Қайталанатын желілер тура бағытталатын желілерден қабаттар арасындағы кері байланыстың болуымен ерекшеленеді. Қайталанатын желілер (ассоциативті желілер) кіріске бірнеше элементтерден тұратын вектор берілгенде желі минималды энергетикалық күйді алуға бейім болатындығымен ерекшеленеді, оның параметрлері шын мәнінде ЖНЖ

шығыстары болып табылады. Осы типтегі ЖНЖ енгізудің күрделілігі, олардың ЖНЖ жаппай қолданылуына кедергі болып табылады.

г) АРТ желісі

ART (Adaptive Resonance Theory) желісі векторлық классификатор болып табылады. Кіріс векторы бұрын сақталған кескіндер жиынының қайсысына ұқсайтынына байланысты жіктеледі. АРТ желісі өзінің жіктеу шешімін тану қабатының нейрондарының бірінің қозуы түрінде білдіреді. Енгізу векторы сақталған үлгілердің ешқайсысына сәйкес келмесе, жаңа кіріс векторымен бірдей үлгіні сақтау арқылы жаңа үлгі жасалады. Егер кіріс векторы белгілі бір ұқсастық критерийі бойынша бұрын сақталған векторлардың біріне ұқсас екені анықталса, онда сақталған вектор жаңа кіріс векторының әсерінен осы кіріс векторына көбірек ұқсас болуы үшін өзгертін (үйренетін) болады.

Ағымдағы кіріс векторы оған жеткілікті түрде ұқсас болмаса, сақталған үлгі өзгермейді. Осылайша, тұрақтылық-пластикалық дилемма шешілді. Жаңа кескін қосымша жіктеу санаттарын жасай алады, бірақ жаңа кіріс кескіні бар жадты өзгертуге мәжбүрлей алмайды. АРТ-тің математикалық сипаттамасы өте күрделі, бұл олардың осы типтегі ЖНЖ-ді жаппай пайдалануына кедергі болып табылады..

д) Оқыту векторларын кванттаумен бәсекеге қабілетті желі(LVQ)

Бұл желі өзін-өзі ұйымдастыратын Кохонен қабаты негізінде құрылады, мұғалімсіз оқиды және Кохонен қабатының шығуын нейрондық желінің шығысына дұрыс көрсете алатын тарату қабаты. Бәсекелес қабаттың жұмысы берілген кіріске жақын кластерді табуға негізделген. Кохонен қабатының өзі танымал желілік құрылым болып табылады. Кохонен қабатының маңызды артықшылықтарының бірі-жоғары оқу жылдамдығы болып табылады. Бұл құрылымда жасырын қабат "жеңімпаз бәрін алады"қағидаты бойынша әрекет етеді. Түсінікті тілмен айтқанда, вектор қабаттың кірісіне беріледі, оның параметрлері Кохонен қабатының барлық нейрондарының салмағымен салыстырылады. Салмағы кіріс векторына ұқсас болған нейрон жеңімпаз болып саналады және оның шығуы "1" мәніне, ал қалған (жеңілген) нейрондарға "0"мәні меншіктеледі. Кластерлеу орталығы мен кіріс векторы арасындағы жақындық коэффициентін есептеу үшін Евклид нормасы қолданылады (1.5.2.3 өрнегін қараңыз), дегенмен ара қашықтық өлшемін анықтаудың басқа әдістері де бар (бастапқыда кірістердің классикалық өлшенген қосындысы ара қашықтық өлшемі ретінде әрекет етті, бірақ электрлік сигналдарды өңдеу кезінде Евклид нормасын қолдану әлдеқайда ыңғайлы екені белгілі болды).

$$d = \sqrt{\sum_{i=1}^n (x_i - x_j)^2}$$

(1.5.2.3)

LVQ (оқыту векторын кванттау) желісі үйренуге қабілеттілік пен жалпыламалық сияқты қасиеттерді жақсартатын Кохонен желісінің

эволюциясы болып табылады. Бұл ретте Кохонен қабатына шығыс сызықты сигма тәрізді қабат қосылады, ондағы нейрондар саны ЖНЖ шығыстарының санына сәйкес келеді. LVQ желісін оқыту алгоритмінің ерекшеліктері шығыс қабатының салмақтары алдын ала белгілі болғандықтан, оны үйретуді қажет етпейді. Дегенмен, бұл қабат Кохонен қабатын оқыту процесінде қолданылады. Бұл желінің басты ерекшелігі, оны оқыту барысында өзін-өзі ұйымдастырушы деңгейдің кластерлері класстарға топтастырылады.. Мұндай топтастыру желіге оқыту жиынын кластерлерге нақтырақ бөлумен байланысты қосымша артықшылықтар береді.

Жоғарыда атап өтілгендей, оқыту алгоритмдерін мұғаліммен және мұғалімсіз оқыту алгоритмдері ретінде жіктеуге болады. Енді олардың ерекшеліктерін қарастырайық.

Бірінші жағдайда желінің кіріс суреттерін ұсынатын, алынған нәтижелерді қажеттімен салыстыратын, содан кейін айырмашылықтарды азайтатындай етіп желінің салмақтарын реттейтін мұғалім бар.

Перцептрон - бұл екі қабатты, қайталанбайтын желі болып табылады. Желіні оқыту әрбір нейронның салмақ коэффициенттерін реттеуден тұрады. Жаттығу үлгісі деп аталатын (x_α, y_α) , $\alpha = 1 \dots p$ жұп векторлар жиыны болсын. Егер әрбір x_α векторының желілік кірістеріне әр уақытта y_α тиісті векторы алынған болса, біз нейрондық желіні осы оқу үлгісінде оқытылған деп атаймыз.

Розенблат ұсынған оқыту әдісі салмақ матрицасын итеративті реттеуден тұрады, бұл шығыс векторларындағы қатені реттілікпен азайтады. Оқыту алгоритмі келесідей:

Барлық нейрондардың салмақтарының бастапқы мәндері W ($t=0$) кездейсоқ болуы керек.

Желі x_α кіріс векторын ұсынады, нәтижесінде $y_\alpha \neq y_\alpha$ шығыс векторы қалыптасады.

Шығу кезінде желі жасаған қателік векторы $\delta_\alpha = (y_\alpha - \hat{y}_\alpha)$ есептеледі. Одан әрі идея - кіші қателер аймағында салмақ векторының өзгеруі шығыс қатесіне пропорционалды және қате нөлге тең болса, нөлге тең болуы керек.

Салмақ векторы келесі формула бойынша өзгертіледі:

$$W(t+\Delta t) = W(t) + \eta x_\alpha * (\delta_\alpha)T \quad (1.5.2.4)$$

мұндағы $0 < \eta < 1$ – оқу жылдамдығы.

2-4 қадамдар барлық оқу векторлары үшін қайталанатын.

Бүкіл үлгіні дәйекті ұсынудың бір циклі дәуір деп аталады. Оқыту бірнеше кезеңнен кейін аяқталады:

а) итерациялар біріктірілген кезде, яғни салмақ векторы өзгеруі тоқтайды;

б) барлық векторлар бойынша толық жинақталған абсолютті қате кейбір кіші мәннен аз болады.

Оқытудың бұл әдісі Розенблатт "қате сигналын кері беру арқылы түзету әдісі" деп аталды. Кейінірек "δ-ереже" атауы кеңінен белгілі болды.

Розенблатт дәлелдеген δ -ереже бойынша оқытудың сәйкестігі туралы теорема перцептрон өзі елестете алатын кез-келген оқыту жиынтығын үйренуге қабілетті екенін айтады.

Екінші жағдайда, оқыту мұғалімсіз жүзеге асырылады, кіріс образдарын ұсынған кезде желі белгілі бір алгоритмге сәйкес өз салмағын орнату арқылы өзін-өзі ұйымдастырады. Оқу процесінде қажетті шығуды көрсетпеу салдарынан нақты нейрондар үшін қоздырғыш образдарды анықтау тұрғысынан нәтижелерді болжау мүмкін емес. Бұл ретте желі оқыту жиынтығының маңызды сипаттамаларын көрсететін түрде ұйымдастырылады. Мысалы, кіріс векторларын олардың ұқсастық дәрежесіне қарай жіктеуге болады, осылайша бір класстағы векторлар бірдей шығыс нейронын іске қосады.

1.6 Бірінші тараудың қорытындылары және мәселенің тұжырымы

Машиналық оқыту әдістерінің, бұлтты технологиялар мен нейрондық желілердің қарқынды дамуына, жүрек-қан тамырлары ауруларының жоғары әлеуметтік маңыздылығына байланысты бұл зерттеудің өзектілігі күмән тудырмайды. Сонымен қатар, денсаулық сақтау жүйесі медициналық шешімдерді қамтамасыз етудің жоғары дәл және сенімді әдістерін, үлкен деректерді жинау және біріктіру әдістерін, сондай-ақ болжамды әдістерді бағалау және растау әдістерін енгізуді талап етеді. Сонымен қатар, машиналық оқыту әдістері, оның ішінде жасанды нейрондық желілер, жүрек-қан тамырлары ауруларын диагностикалауда, әсіресе МИ-нің ерте сатысында уақтылы алдын алуға және адам өмірінің ұзақтығы мен сапасын арттыруға ықпал етіп, барған сайын маңызды рөл атқаруда.

Бірінші тарауда медициналық параметрлердің корреляциялық талдауы жүргізілді, МИ болжау үшін машиналық оқыту үлгілері қарастырылып, талданды. Зерттеулер нәтижесінде әрбір әдістің тиімділігінің бағалары алынды. Ұсынылған әдістер денсаулық сақтаудың практикалық мәселелерін шешуде өздерінің тиімділігін растады. Бірқатар есептеу эксперименттерінің нәтижесінде жүрек ауруын болжау үшін машиналық оқытудың бір немесе басқа әдісін таңдау ғана емес, сонымен қатар оның параметрлерін, соның ішінде тестілеу алгоритмдерінің хаотикалық сипаттамаларын таңдау маңызды екені анықталды.

Жүректің күйін диагностикалаудың сенімділігін арттыру үшін жүректің негізгі электрофизиологиялық сипаттамаларын есептеу және жүректің негізгі электрофизиологиялық сипаттамаларының есебін тексеру қажет. Бұл жүректің электрофизиологиялық сипаттамаларын анықтаудың жеткіліктілігін бағалауға мүмкіндік береді.

ЭКС нейрожелілік талдаудың заманауи тәсілдерін зерттеудің нәтижесінде, олардың үлкен мүмкіндіктеріне қарамастан, нейрондық желілерді пайдалана отырып, МИ-ді жоғары сапалы диагностикалауға мүмкіндік бермейтін бірқатар мәселелер бар екенін көрсетті. ЭКС

нейрожелілік талдауды жетілдіру миокард инфарктісінің нейрожелілік диагностикасының деңгейін сапалы арттыра алады.

Жүргізілген шолу мен талдау негізінде диссертациялық зерттеудің міндеттері нақтыланды. Оларды шешу үшін келесі міндеттерді орындау қажет:

1. Миокард инфарктісінің тікелей және өзара белгілерін бірге талдау негізінде, миокард инфарктісін диагностикалауға арналған ЭКС нейрожелілік талдаудың жаңа әдістерін әзірлеу.

2. Ұсынылған нейрожелілік талдау әдістері негізінде МИ болуы туралы диагностикалық қорытынды жасау үшін шығыс логикалық функцияларды құру

3. ЭКС нейрожелілік талдаудың жаңа әдістерін іске асыратын миокард инфарктісін диагностикалауды, оны алдын ала өңдеуді және ЭКС клиникаға дейінгі талдауға арналған диагностикалық қорытынды жасау мүмкіндігі бар тәсілін әзірлеу және енгізу.

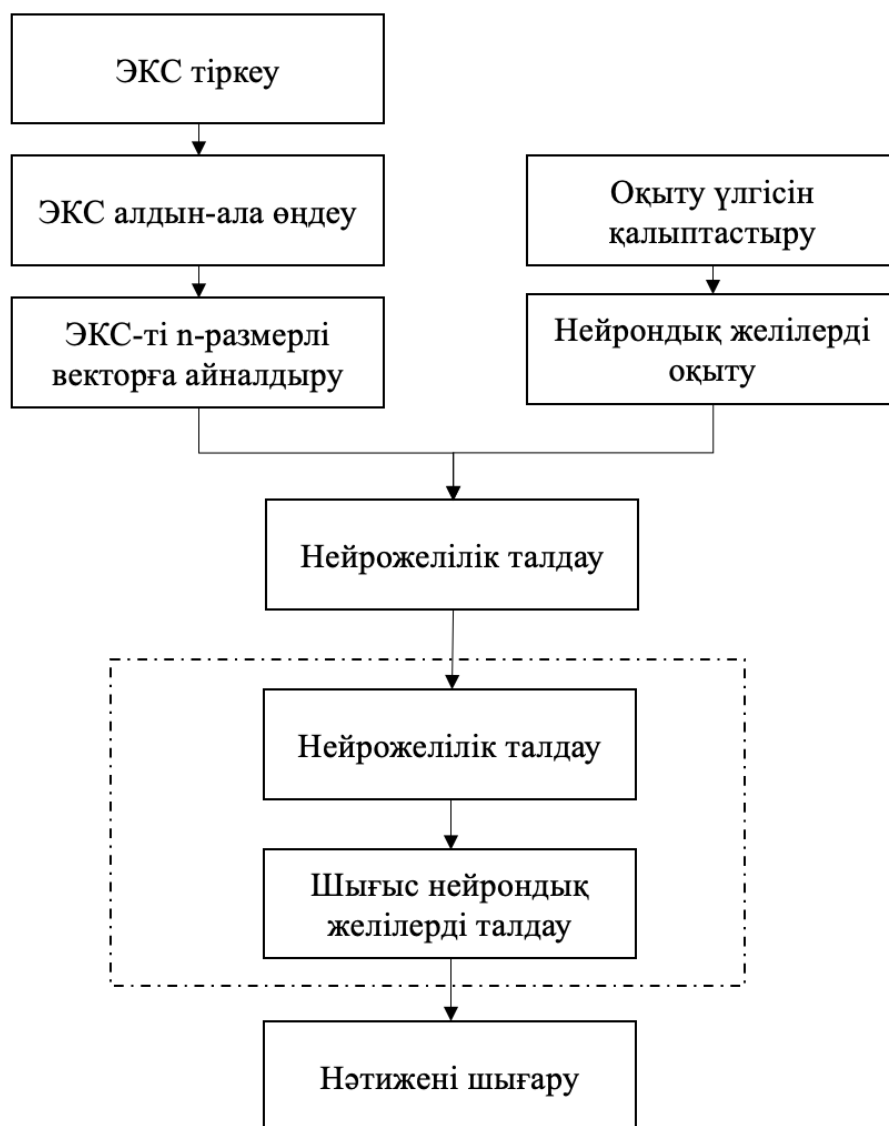
2. КАРДИОЦИКЛ СЕГМЕНТТЕРІН НЕЙРОЖЕЛІЛІК ТАЛДАУ ЖӘНЕ НЕЙРОНДЫҚ ЖЕЛІЛЕРДІҢ СЕРИЯЛЫҚ-ПАРАЛЛЕЛЬ ҚОСЫЛУЫ НЕГІЗІНДЕ МИОКАРД ИНФАРКТИСІН ДИАГНОСТИКАЛАУ ӘДІСТЕМЕСІН ӘЗІРЛЕУ

2.1 Электрокардиографиялық ақпаратты нейрожелілік талдау әдістемесінің сипаттамасы

Бірінші тарауда жүргізілген ЭКС нейрожелілік талдау тәсілдерін талдау ЭКС ақпаратты өңдеу сапасының жеткілікті дәрежеде жоғары емес екенін көрсетті. Сонымен бірге МИ түрі туралы шешім қабылдау принципі түсініксіз болып қалады. Кардиоциклдің сегменттерін талдаудан тұратын тәсіл назар аударуға тұрарлық, бірақ кардиоциклдің жеке сегменттерін таңдап, нақты диагноз қою мүмкіндігінің болмауы бұл әдісті жүрек ауруының клиникаға дейінгі диагноз қоюда қолдануға мүмкіндік бермейді.

МИ диагностикалау сенімділігін арттыру үшін ЭКС нерожелілік талдау мүмкіндіктерін кеңейтуі керек екені белгілі. Миокард инфарктісінің болуын сапалы анықтау, сондай-ақ оның түрін және локализациясын анықтау-бұл жалпы қабылданған белгілерге сәйкес кардиоциклдің ЭКС сегменттерін талдау. Бұл тәсіл клиникаға дейінгі зерттеуде диагностикалық жүйелерді қолдану мүмкіндіктерін сапалы жақсартуға қабілетті. Ұсынылған тәсілге сәйкес, шешілуі қажет ілеспе міндеттер "пайда болады". Мұндай міндеттер-кардиоциклдің қажетті сегменттерін автоматты түрде таңдап, МИ түрі мен орналасуы туралы шешім қабылдау ережелері.

Ресми диагноздарға байланудың орнына, белгілі бір тіркеуіштерден алынған сигналға сәйкес миокард инфарктісін диагностикалау мүмкіндіктерін кеңейту қажет. Жоғарыда айтылғандарды ескере отырып, 2.1.1-суретте көрсетілген диагноз қою үшін ЭКС (НСА ЭКС) нейрожелілік талдау тәсілі әзірледі.



2.1.1 - сурет. Миокард инфарктісін диагностикалау үшін ЭКС өңдеуге ұсынылатын тәсіл

ЭКС НЖТ-ға ұсынылатын тәсілдің негізгі кезеңдері:

ЭКС-ті тіркеу сертифицирталған бастапқы медициналық құралдардың (электрокардиографтар, кардиокүшейткіштер) [106-108] көмегімен орындалады, олар: ЭКС-ды пациенттің денесінен 12 стандартты тіркеуіштен (3 стандартты, 3 күшейтілген және 6 кеуде) алу функциясын жүзеге асырады;

Шуды жою және фильтрациялау мүмкіндіктері бойынша қазіргі заманғы цифрлық электрокардиограф [109] баяндалған талаптарды қанағаттандыруы тиіс, бұл ретте цифрлық ЭКС [110] алмасу үшін SCP-ECG стандартына сәйкес үлгілеу жиілігі пайдаланылуы тиіс, яғни 300 Гц кем емес. Сонымен қатар, деректерді беру үшін сымды (COM, LPT, USB, Ethernet және т.б.) және сымсыз (InfraRed, Bluetooth, WiFi және т. б.) байланыс арналарын пайдалануға болады. Деректерді өңдеу құрылғысы ретінде ерікті түрдегі компьютерлер (дербес компьютер, ноутбук, NetBook, қалта компьютері және т.б.) әрекет ете алады. Бұл кезеңде ЭКС-ті тіркеу құрылғысының көмегімен ЭКС-ті алу және тіркеу жүзеге асырылады. ЭКС тіркеу кезінде келесі мәселелер шешіледі:

- электродтар орналасқан жердегі электрод пен тері арасындағы электрлік өзара әрекеттесу;
- пациенттің электрлік қауіпсіздігі;
- аналогтық фильтрлау және ЭКС күшейту;
- ЭКС-ті іріктеу және цифрлау;
- ЭКС тіркеу құрылғысын компьютермен жұптастыру;

Тіркеу кезеңінен кейін цифрланған ЭКС компьютердің кірісіне түседі. **ЭКС-ті алдын-ала өңдеу** НЖ сапалы оқытуға және ЭКС-ті сенімді НЖТ арналған, компьютердің есептеу мүмкіндіктерін қолдана отырып жүзеге асырылады. ЭКС тіркеп, алдын ала өңдеп, ЭКГ тісшелерін анықтау сатысын портативті электрокардиоанализатордың көмегімен іске арырып көрдік.

Біз электрокардиограмма сигналдарын көп мақсатты зерттеу арқылы жүрек бұлшықетінің зақымдану мөлшерін анықтайтын боламыз. ЭКГ сигналының маңызды құрамдас бөлігі - QRS кешені, оның шыңы R-шыңдары ретінде белгіленеді. R-R үзілісі R қатарынан екі шыңның арасындағы уақыт аралығын білдіреді. Ол аритмия деп аталатын жүректің қалыпты жұмысындағы бұзылуларды анықтау үшін қолданылады. Диагноз инфаркт мөлшерін бағалауды және жедел асқынуларды анықтауды қамтиды. ЭКГ-ның электрокардиограмма сигналында Q және T толқындары маңызды рөл атқарады. Егер қандай да бір проблема P толқынында туындаса, бұл ешқандай асқынуларға әкелмейді. Сонымен, біз мақсатымызға жету үшін QRS кешенін анықтауымыз қажет. T тісшесінің өзгеруі үлкен аймақта жүреді және бұл ишемияны білдіреді, ал ST сегментінің өзгеруі аз тісшелер арқылы келеді және бұл сегмент миокардтың зақымдалуын көрсетеді, ал Q тісі қабаттасып келеді және миокард некрозының негізгі аймағын білдіреді.

ЭКС нейрожелілік талдау нейрондық желілерді сериялы-параллель қосу негізінде жүзеге асырылады. Бұл процедура белгілі ЭКС нейрожелілік талдаудың функционалдығын кеңейтеді және диагноздың тиімділігін арттыра алады. Осы процедура аясында келесілер ұсынылады:

– МИ-ның тереңдігін нейрожелілік талдау. Бұл жағдайда QRS кешенін R тісінің болуына талдау жасалады: R тісінің болмауы жүрек соғысының трансмуралдылығын көрсетеді.

МИ түрі туралы шешім қабылдау. Жеке мәселе - МИ болуы туралы шешім қабылдау принципі. Ұсынылған тәсілде МИ түрі туралы шешім қабылдаудың мақсаты ЭКС өңдеу кезінде алынған нәтижелерді талдау және диагностикалық қорытынды жасау операцияларын жүзеге асырады:

– талдау нәтижелерін өңдеу жүректің электрофизиологиялық сипаттамаларын ескере отырып, тиісті локализациядағы нейрондық желілердің шығуын салыстырудан тұрады;

– диагностикалық қорытындыны қалыптастыру сол немесе басқа диагнозды айқындайтын эзірленген логикалық функциялар негізінде жүзеге асырылады.

2.2 Электрокардиосигналдарды тіркеп, алдын ала өңдеу

Қарқынды техникалық прогрестің арқасында өзекті болған ЖҚА диагностикасының бір бағыты-еркін қозғалыс белсенділігі (ЖҚА) жағдайында жүректің жай-күйін бақылау. Заманауи технологиялар еркін қозғалыс белсенділігі жағдайында жұмыс істейтін адамның функционалдық параметрлерін тіркеуге арналған көлемі кіші, өзімен алып жүруге қолайлы құрылғыларды жасауға мүмкіндік берді. Мұндай құрылғыларды қолдану электрокардиосигналды (ЭКС) өңдеу құралдары мен алгоритмдерін тереңірек және егжей-тегжейлі зерттеуді қажет етті.

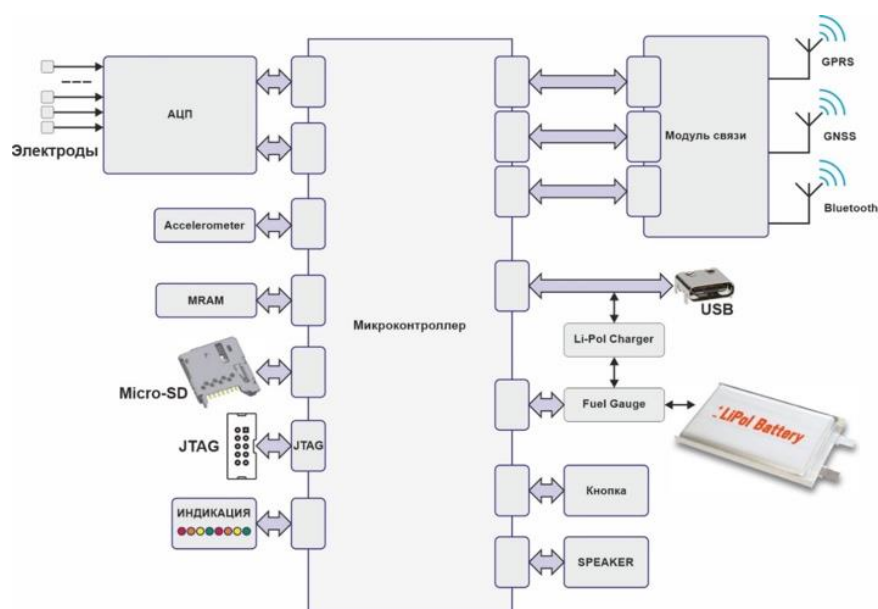
Бұл жұмыс біздің алдыңғы жұмысымыздың жалғасы болып табылады, онда авторлар біздің бірінші буын электрокардиоанализатордың портативті кардиоанализатордың алғашқы эксперименттік нәтижелерін ұсынды. Бірінші сынақ нұсқасының бастапқы орналасуында TQFP-100 және 8 каналды АЦТ корпусындағы микроконтроллер таңдалды. Алайда, мобильді кардиоанализатордың бірінші нұсқасын жасап, схеманы оңтайландырғаннан кейін, жүрек жағдайын бақылайтын құрылғы үшін TQFP-64 корпусындағы микроконтроллер мен төрт каналды АЦТ жеткілікті екендігі белгілі болды. Сондықтан кардиоанализатордың екінші буынын жасау кезінде TQFP-64 корпусындағы микроконтроллер нұсқасы мен 4 каналды АЦТ нұсқасы қолданылады.



2.2.1 – сурет. Портативті кардиоанализатордың суреті.

Портативті мобильді кардиоанализатордың функционалды схемасын жасау.

2.2.2-суретте әзірленген портативті мобильді кардиоанализатордың функционалды блок-схемасы толық ашылып көрсетілген.



2.2.2 – сурет. Кардиоанализатордың функционалды блок-схемасы

Портативті кардиоанализатордың негізгі элементі-микроконтроллер. ЭКС түсіру үшін АСТ сериялық деректер каналдары арқылы микроконтроллерге қосылады. АСТ микроконтроллерден және жүйенің қалған сандық компоненттерінен қуат желілері арқылы өтетін кедергілерді азайту үшін тәуелсіз қуатпен қамтамасыз етілуі керек.

Ағымдағы ЭКС бойынша жедел деректерді жазу үшін микроконтроллерге тұрақты емес MRAM жылдам жады блогы қосылған. ЭКС бойынша деректерді одан әрі жинақтау және ұзақ мерзімді сақтау үшін микроконтроллерге MicroSD Flash-жад есептеуіш түріндегі сыртқы диск қосылған, оған 32 Гб дейінгі тұрақты жады бар Flash-карта салына алады.

Науқастың құлауын немесе қозғалысыз күйін анықтау үшін портативті кардиоанализаторда соққыларды, құлауды және қозғалыссыз күйді тіркейтін MEMS акселерометрі бар. Портативті кардиоанализатордың қуаты, кіріктірілген аккумулятордың заряды сияқты, сыртқы қуат көзінен алынады.

Портативті дербес құрылғыларға қойылатын талаптарға сәйкес, портативті кардиоанализатор қуат көзін қолмен басқаруды қамтамасыз ететін қуат көзін қосу түймесінің контроллерімен жабдықталған. Жедел медициналық жәрдем қызметімен байланысу үшін, сондай-ақ экс деректерін медициналық ақпараттық жүйенің (МАЖ) серверіне жедел беру үшін портативті кардиоанализатор GPRS байланыс модулімен жабдықталған.

Сыртқы ұялы телефон арқылы ЭКС деректерін жіберген жағдайда, портативті жүрек анализаторы Bluetooth модулімен жабдықталған. Портативті мобильді кардиоанализатордың жұмысын визуалды бақылау жүйесі екі үш түсті және бір түсті үш жарықдиодты шамдарда жасалған. Бірінші жарық диоды зарядтағыштың жұмысының визуализациясын қамтамасыз етеді және "сыртқы қуаттың қосылуы", "батареяны зарядтау" және "батареяны зарядтаудың аяқталуы" режимдерін білдіреді. Екінші үш түсті жарық диоды микроконтроллерге тікелей қосылған және бағдарлама арқылы басқарылады.

Бір түсті жарық диоды GPS модуліне қосылған және интернетке қосылу және сервермен байланыс режимдерін білдіреді.

Портативті мобильді кардиоанализатордың электрлік схемасын жасау

Портативті мобильді кардиоанализаторды әзірлеу құрылғының блок-схемасын әзірлеуден басталады, кейін, оған сәйкес принципті электрлік схемасын әзірлеу жалғасады. Құрылғының блок-схемасы жеке блоктардың өзара әрекеттесу деңгейіне дейін пысықталды.

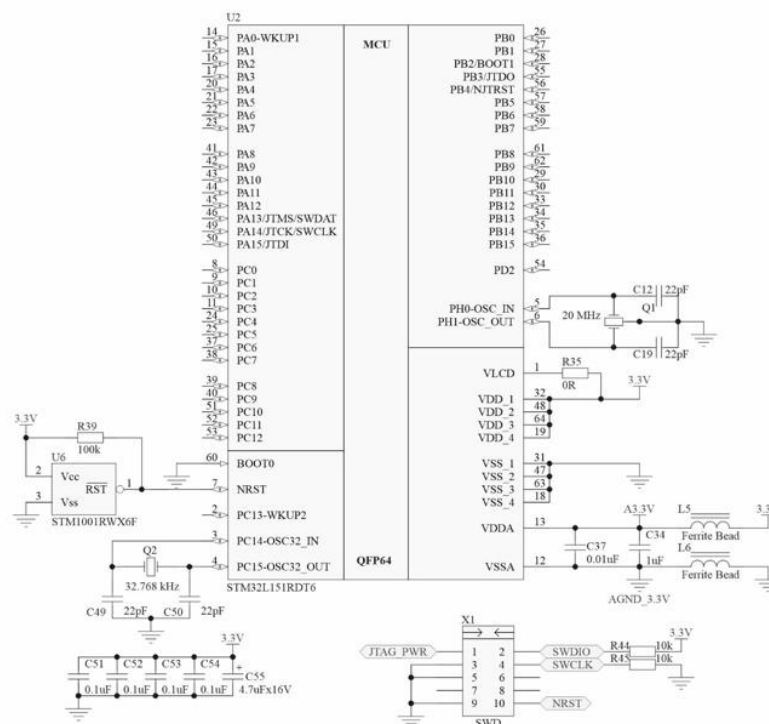
Жалпы принципті схеманы қалыптастыру үшін әрбір жеке блокты пысықтап, әр блок үшін принципті схеманы жасап, оларды жалпы схемада біріктіру қажет.

Процессор модулі

Процессор модулі қазіргі заманғы төмен тұтынылатын stm32l151xd микроконтроллерінде құрастырылған.

Микроконтроллердің қалыпты жұмысын қамтамасыз ету үшін 20 МГц сыртқы кварц резонаторы, бастапқы қуат беру кезінде RESET сигналын беру үшін қуат бақылаушысының чипі, 32.768 кГц сағаттық кварц, бағдарламалауға арналған SWD коннекторы және берілген микроконтроллердің техникалық құжаттамасына сәйкес барлық қуат желілеріне ажырату конденсаторларын қамтамасыз ету қажет.

Мобильді кардиоанализаторды әзірлеу кезінде TQFP-64 корпусындағы микроконтроллер қолданылды (2.2.3-сурет).



2.2.3 – сурет. Процессор модулінің принципті схемасы.

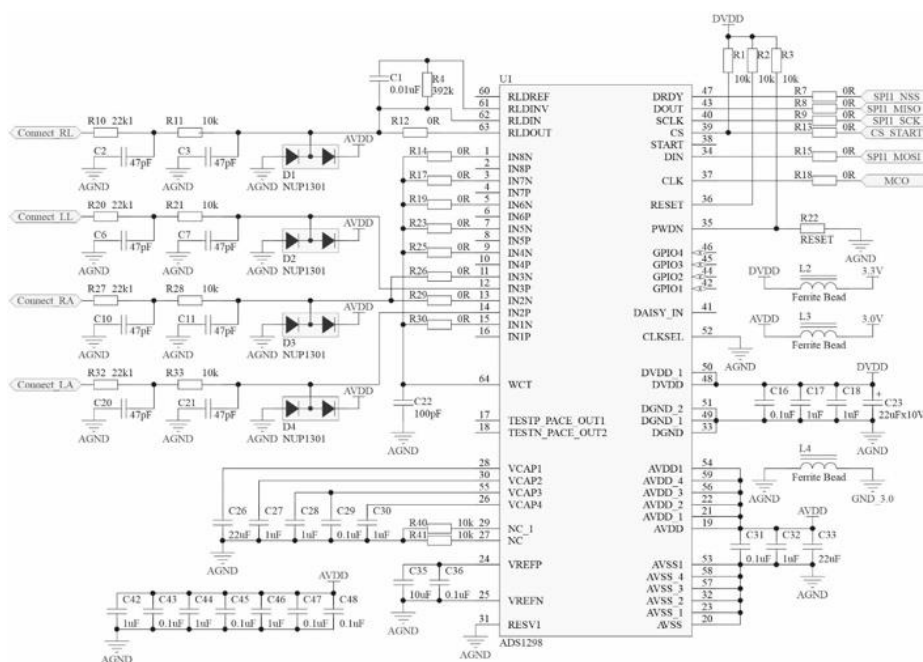
ACT модулі

ACT модулі ADS1298 (өндіруші-Texas Instruments) 4 каналды 24 биттік Front-End Модулінің (FEM) негізінде жасалған. Модуль функционалды түрде

аяқталған және сериялық синхронды интерфейс SPI арқылы процессор модулімен байланысқан.

АСТ-тің қалыпты жұмысын қамтамасыз ету үшін 2.048 МГц жиіліктегі сыртқы осциллятор қажет. Бұл жиілік микроконтроллермен қалыптасып, ADS1298 ке МСОКО желісі бойынша беріледі.

Әрбір АСТ (4 каналды) кіріс каналында екі төмен жиілікті RC-сүзгілері мен диодты құрастырудан тұратын қорғаныс желілері қалыптасқан. Қорғаныс желілері жоғары жиілікті сигналдарды сүзуге, кері полярлықты жоюға және кіріс кернеуін жоюға қызмет етеді. АСТ құрастырылуының нұсқасы 2.2.4-суретте көрсетілген.




2.2.4 – сурет. АСТ принциптік схемасы.

Жедел жад блогы

Жедел жад блогы энергияға тәуелді MRAM жады MR25H40 512Kx8тық жады жиынтығымен құрастырылған.

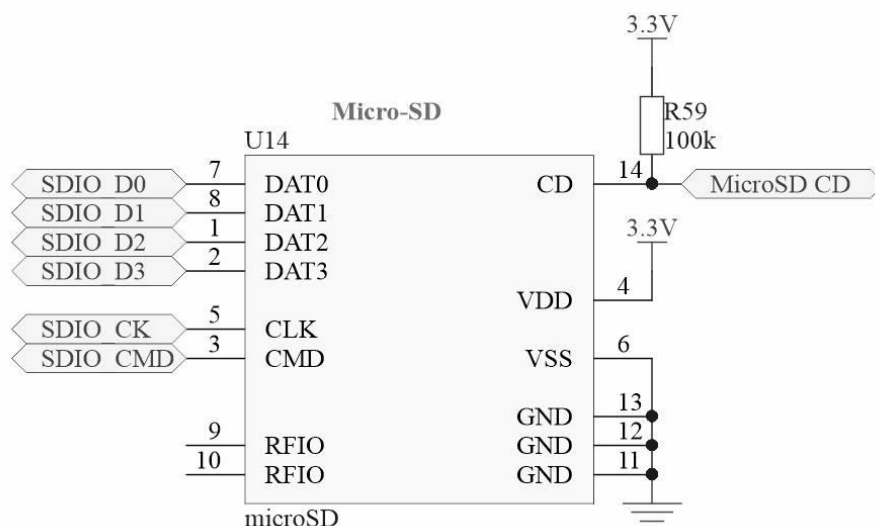
Тұрақты емес жадқа қол жеткізу сериялық синхронды SPI интерфейсі арқылы жүзеге асырылады. MRAM қосылым опциясы 2.2.5-суретте көрсетілген.



2.2.5 – сурет. Принципиальная схема блока оперативной памяти.

Тұрақты жад блогы

Үлкен көлемдегі деректердің тұрақсыз сақталуын қамтамасыз ету үшін 32 гигабайтқа дейінгі жады бар ауыстырылатын microSD форматындағы SSD бар. Портативті кардиоанализаторда сыртқы дискіні пайдалану үшін микроконтроллерге арнайы SDIO шинасы арқылы қосылған microSD карталары үшін кардхолдер қолданылады. MRAM қосылым опциясы 2.2.6-суретте көрсетілген.



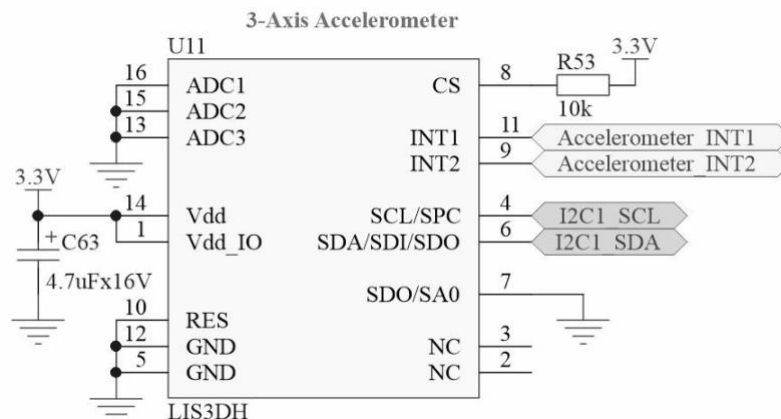
2.2.6 – сурет. Тұрақты жад блогының схемасы

Үдеуді анықтау блогы (акселерометр)

Үдеуді анықтау блогы соққыларды, құлауды және қозғалмайтын күйді тіркейтін MEMS акселерометріне салынған. Акселерометр ретінде ST Microelectronics компаниясының LGA-16 корпусында LIS3DH 3 координаталық MEMS акселерометрінің чипі пайдаланылды. MEMS акселерометрі микроконтроллерге I2C сериялық интерфейсі арқылы қосылады.

Сондай-ақ, акселерометрде INT1 және INT2 үзілістерінің 2 шығысы бар, олар арқылы микроконтроллерді соққылар мен құлау кезінде оятуға және «ұйқы режимінен» шығаруға болады.

Акселерометрді қосу опциясы 2.2.7-суретте көрсетілген.



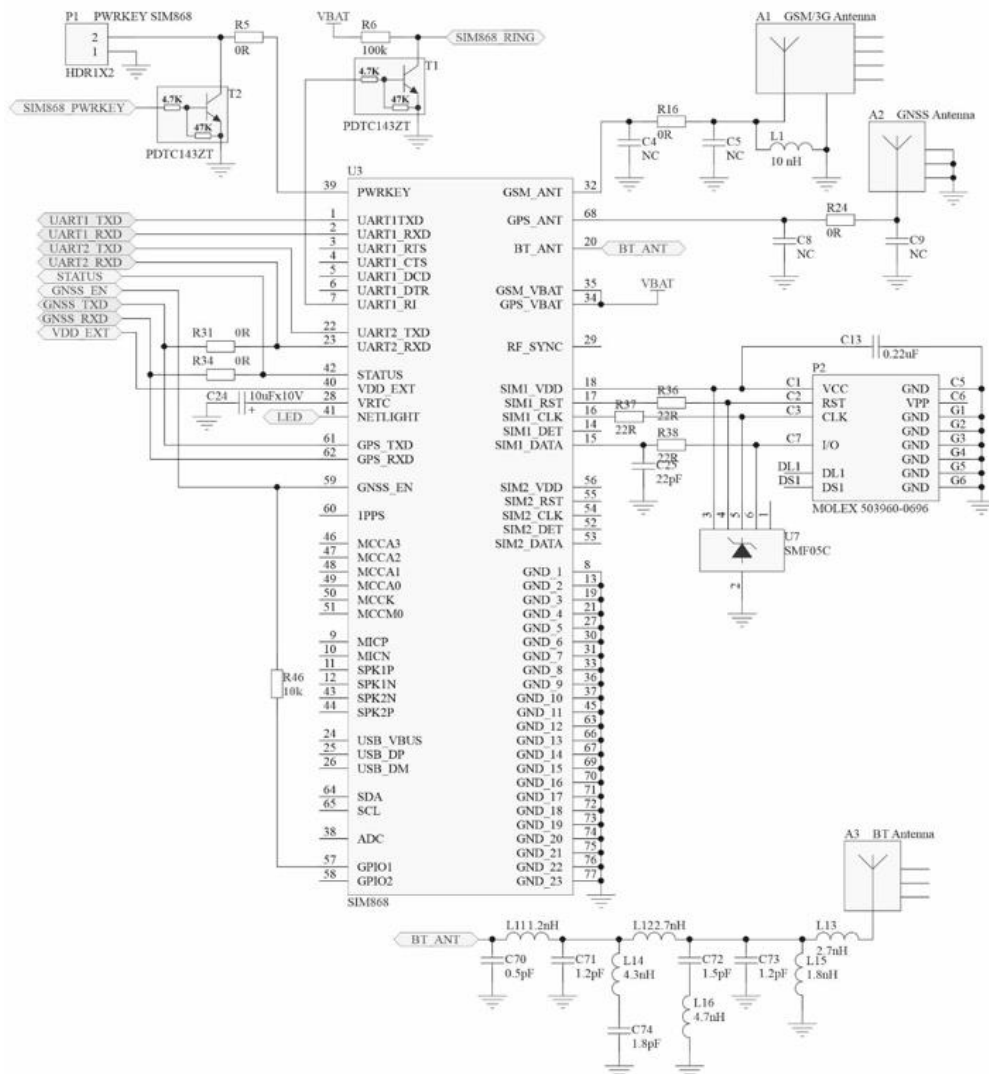
2.2.7 – сурет. Үдеуді анықтау блогының схемасы

Байланыс блогы

GSM/GPRS ұялы байланыс желілерінде деректер алмасуды, навигациялық жүйелер спутниктерінен (GNSS) орналасқан жер деректерін және нақты уақыт сигналдарын қабылдауды қолдайтын simcom компаниясының әмбебап sim868 комбо негізінде байланыс блогы жасалды. Sim868 микроконтроллерімен байланысу үшін Serial Port Interface (SPI) порты қолданылады. Simm 868 модулі мен микроконтроллердің кернеуі әртүрлі болғандықтан, үйлесімділікті қамтамасыз ету үшін Analog Devices компаниясының ADG3308 чіпіндегі сигнал деңгейінің түрлендіргіші қолданылды.

MicroSIM телефон картасының модуліне қосылу үшін Molex 503960-0696 моделінің кардхолдері пайдаланылды, ол SIM868 модуліне баратын желілерді SMF05C төрт супрессорымен статикалық электр тогынан қорғаумен қосымша қамтамасыз етілді.

SIM 868 модуліне 3 антенна қосылады: GPRS, GPS және Bluetooth. Бұл Антенналарды модульге қосымша сәйкестендіру RLC компоненттерінде жасалады, оны 2.2.8-суретте көрсеттік .



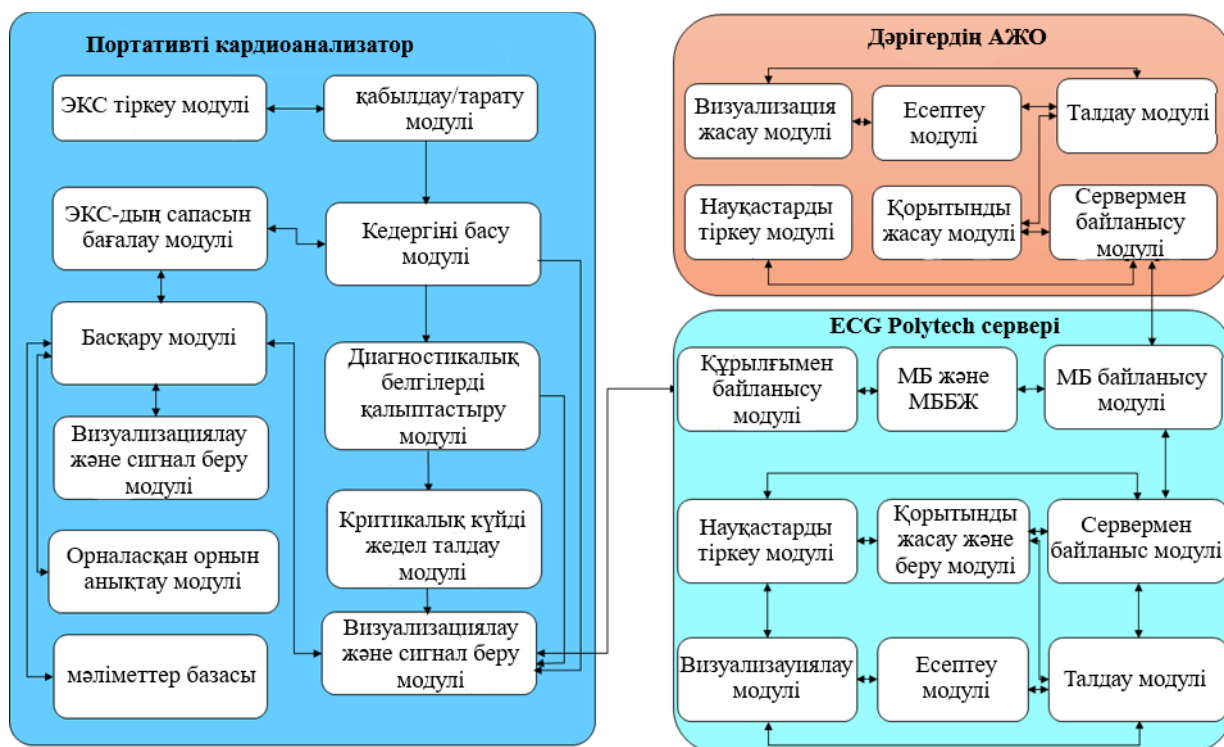
2.2.8-сурет. Байланыс блогының принципті схемасы.

I. ПКА бағдарламалық бөлігін әзірлеу

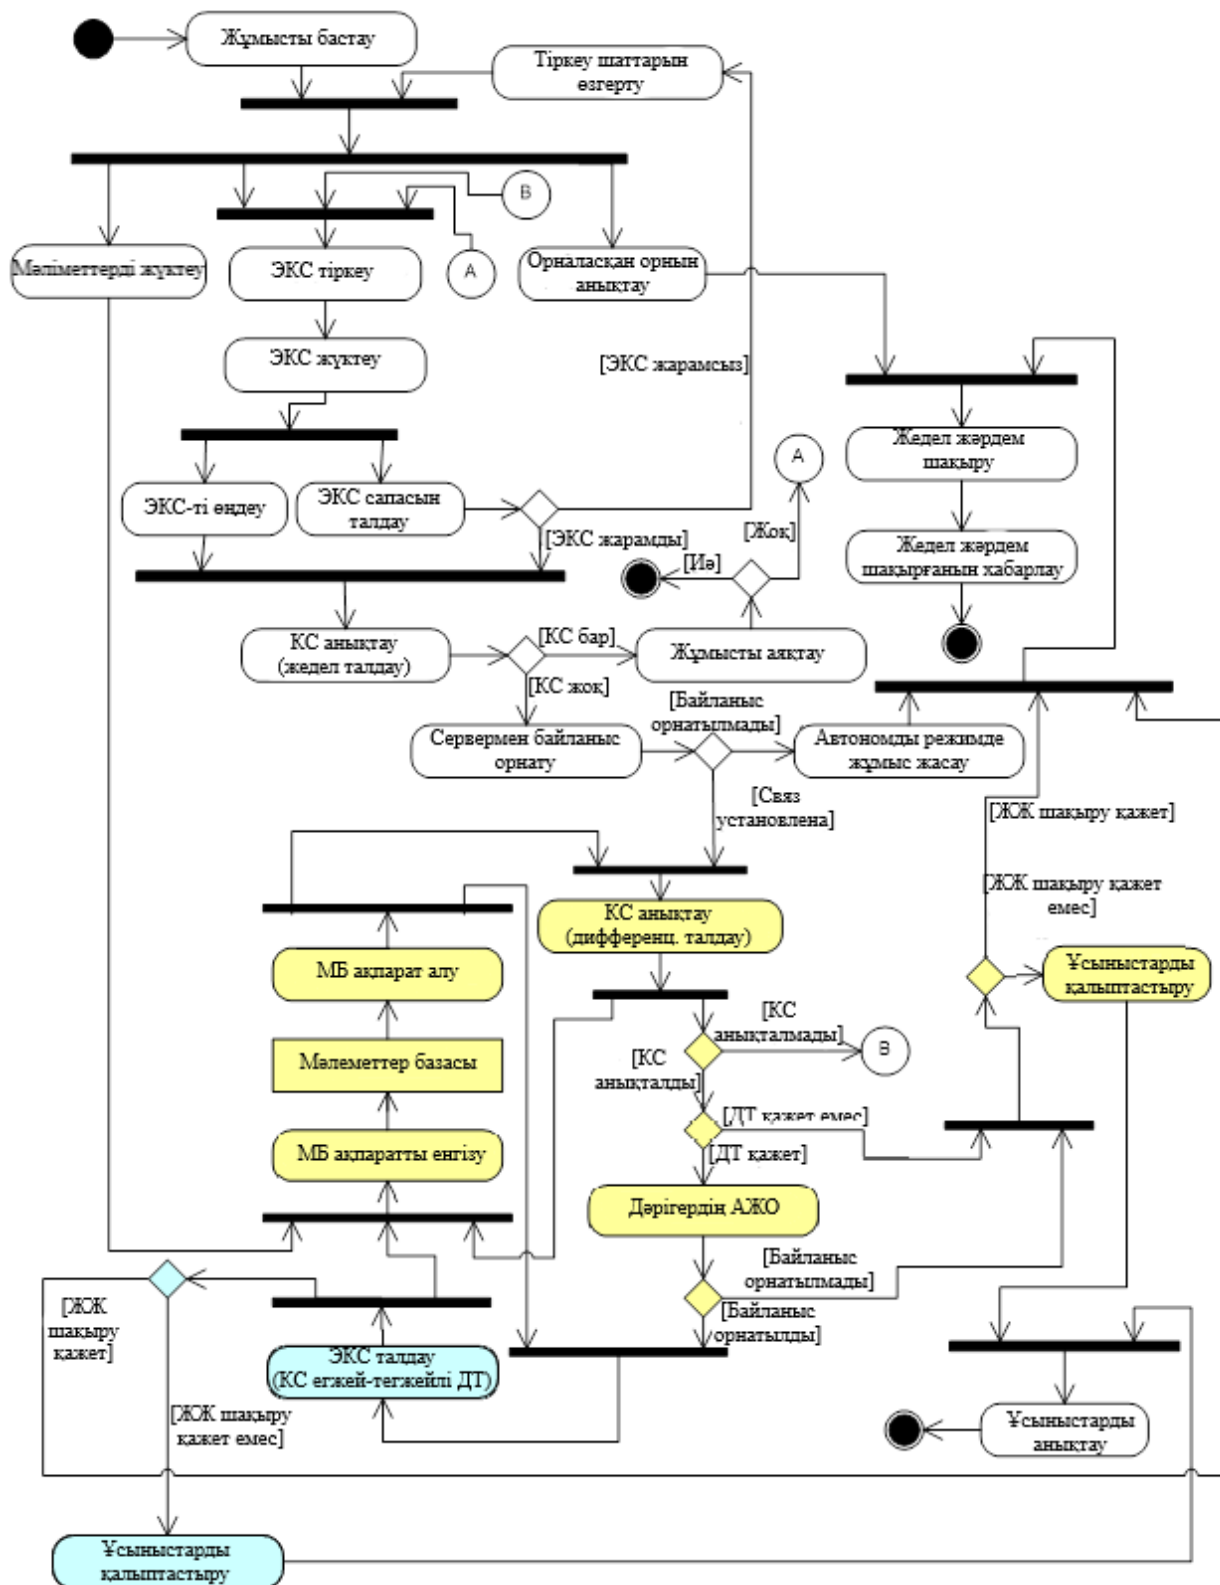
Қазіргі уақытта медициналық жүйелердің жекелеген құрылғылары арасындағы сымды қосылыстар ақпаратты берудің сымсыз технологияларымен ауыстырылады, бұл ретте бірқатар факторларды ескеру қажет: құрылғылар арасындағы қашықтық және оларды жылжыту мүмкіндігі, берілетін ақпараттың берілу жылдамдығы мен көлемі, энергия тұтыну, шифрлау мүмкіндігі, кедергі деңгейі және т. б. ИЭКДЖ құрамдас бөліктері арасындағы байланыс хаттамаларын қарастырамыз.

Портативті жүрек анализаторында GSM/GPRS ұялы байланыс желілерінде деректер алмасуды, навигациялық жүйелер спутниктерінен (GNSS) орналасқан жер деректерін және нақты уақыт сигналдарын қабылдауды қолдайтын simcom компаниясының әмбебап sim868 комбо-модуліне негізделген меншікті байланыс блогы бар. Sim868 микроконтроллерімен байланысу үшін Serial Port Interface (SPI) порты қолданылады. SIMM 868 модулі мен микроконтроллердің кернеуі әртүрлі болғандықтан, үйлесімділікті қамтамасыз ету үшін Analog Devices компаниясының ADG3308 чіпіндегі сигнал деңгейінің түрлендіргіші қолданылды.

Бүкіл жүйенің және оның жекелеген бөліктерінің функцияларына сәйкес инвазивті емес кардиодиагностика жүйесінің бағдарламалық жасақтамасының құрылымы жасалды (2.2.9-сурет).



2.2.9-сурет. ИЭКДЖ БҚЕ жүйесі



Сурет 2.2.10 – ИЭҚДЖ шешім қабылдау моделін көрсететін қызмет диаграммасы

Инвазивті емес кардио диагностикалық жүйенің БЖ портативті кардиоанализатор БЖ, сервер және дәрігердің АЖО тұрады. Сервер бөлігі (2.2.10-суретте көгілдір түспен көрсетілген) құрылғымен өзара әрекеттесу

модулін, мәліметтер базасын (ДББЖ) және мәліметтер базасын басқару жүйесін (ДББЖ), ДБ-мен өзара әрекеттесу модулін қамтиды.

Үш деңгейлі модельге сәйкес ИЭКДЖ жұмыс істеген кезде келесі жұмыс режимдері мүмкін: "автономды" - ЭКС өңдеу және талдау бойынша барлық тапсырмалар портативті кардиоанализаторда орындалады;" кардиоанализатор-сервер " – ЭКС өңдеу және талдау бойынша тапсырмалар кардиоанализатор мен сервер арасында бөлінеді; "кардиоанализатор-сервер-дәрігер" - барлық өңдеу тапсырмалары кардиографиялық ақпарат дәрігердің АЖО-ға жүктелген, ал сервер тек деректерді сақтау үшін қолданылады. Қабылданған шешімдер иерархиясының деңгейлері, оларға сәйкес жұмыс режимдері, талдау нұсқалары және әртүрлі деңгейлерде қабылданған шешімдер 1-кестеде келтірілген.

2.2.1-кесте- ИЭКДЖ -де қабылданатын шешімдер иерархиясының деңгейлері

Hierarchy levels	Operating modes	Analysis option	Decisions made
Lower	Autonomous	Automatic express analysis of ECG	Suitability of the ECG for analysis, the presence of a critical situation
Average	Cardioanalyze r-server	Automatic differentiated analysis of a critical situation	The need for a detailed medical analysis, the presence of a connection with the doctor's workstation.
Highest	Cardioanalyze r-server-doctor	Detailed medical analysis by a cardiologist	Calling an ambulance, making recommendations.

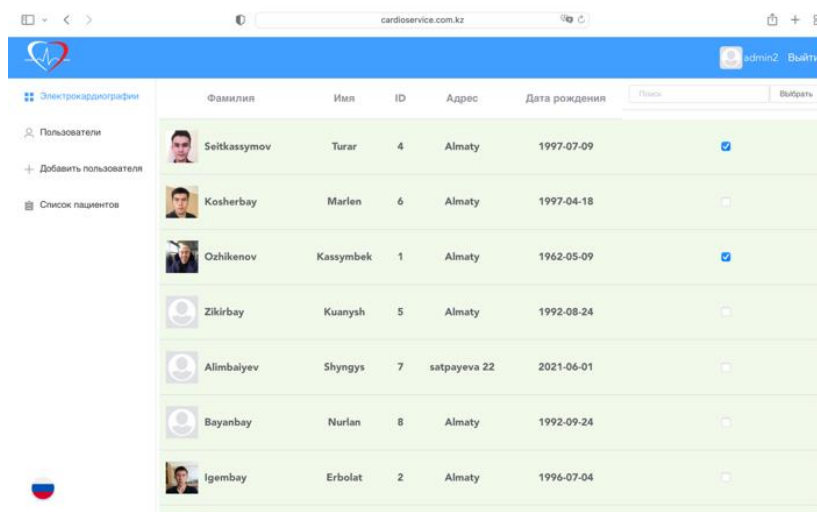
Түспен ерекшеленбеген әрекеттер мен шешімдерді портативті кардиоанализатор жүзеге асырады, сары түспен бөлектелген сервер жүзеге асырады, көк түспен бөлектелген – дәрігердің АЖО.

Осылайша, жүйенің дамыған құрылымы, бағдарламалық жасақтама құрылымы, шешім қабылдау моделі, сондай-ақ әдістер, алгоритмдер және құрылымдық шешімдер тұжырымдалған талаптарға сәйкес инвазивті емес кардиодиагностика жүйесін жүзеге асыруға мүмкіндік береді.

Пайдаланушы моделі, белгілі бір портативті кардиоанализатордың белгілі бір пайдаланушымен байланысы

Django әдепкі пайдаланушы үлгісімен бірге пайдаланушы аты, Құпия сөздер және электрондық пошта мекенжайы сияқты өрістермен бірге келеді, бірақ кейбір жағдайларда бұл өрістер пайдаланушы үлгісін кеңейту немесе Пайдаланушының жеке үлгісін жасау үшін жеткіліксіз болуы мүмкін. Бұл жағдайда біз пайдаланушы моделін кеңейтеміз, өйткені бізге пайдаланушыларды саралау әдісі қажет.

Құрылғыны анықтау үшін біз әр құрылғы үшін бірегей id жасадық және оны белгілі бір пайдаланушымен байланыстырдық, осылайша деректерді беру кезінде құрылғының id да береміз.



2.2.11-сурет. Пайдаланушыны жүйеге тіркеу

Сценарийде (17-суретті қараңыз) socket кітапханасын пайдаланып, құрылғыдан деректерді қабылдау үшін сокет құрамыз. Мұны істеу үшін сіз сервердің мекен-жайын және бір уақытта ашылуы мүмкін максималды дескрипторлардың санын көрсетуіңіз керек. Сонымен, Бұл код тестілеу үшін пайдаланылғандықтан, дескрипторлардың максималды саны-30 қылдық.

```
1 import socket
2 import select
3 import requests
4 import binascii
5
6 SERVER_ADDRESS = ('***.***.***.***', '***')
7
8 dd = ""
9 # Говорит о том, сколько дескрипторов одновременно могут быть открыты
10 MAX_CONNECTIONS = 30
11
12 # Откуда и куда записывать информацию
13 INPUTS = list()
14 OUTPUTS = list()
15
16 def get_non_blocking_server_socket():
17     # Создаем сокет, который работает без блокирования основного потока
18     server = socket.socket(socket.AF_INET, socket.SOCK_STREAM)
19     server.setblocking(0)
20
21     # Биндим сервер на нужный адрес и порт
22     server.bind(SERVER_ADDRESS)
23
24     # Установка максимального количество подключений
25     server.listen(MAX_CONNECTIONS)
26
27     return server
28
```

2.2.12-сурет. Құрылғыдан деректерді қабылдауға арналған сценарийлер

Әрі қарай, біз тыңдаушы мен сигналды өңдеуші функциясын немесе басқалай атауы – деректер пакетін жазуымыз керек (18-суретті қараңыз).

Тыңдаушы бірінші кезекте жіберілетін деректердің мекен-жайына қарайды, егер олар біздің IP-ге жіберілген болса, біз деректерді қабылдаймыз. Енді біз деректерді өңдеу үшін әрі қарай жіберуіміз керек және қажет болған жағдайда белгілі бір пайдаланушының астында дерекқорымызда сақтауымыз керек.

```

29
30 def handle_readables(readables, server):
31     #Обработка появления событий на входах
32     global dd
33     for resource in readables:
34         # Если событие исходит от серверного сокета, то мы получаем новое подключение
35         if resource is server:
36             connection, client_address = resource.accept()
37             connection.setblocking(0)
38             INPUTS.append(connection)
39             print("new connection from {address}".format(address=client_address))
40
41         # Если событие исходит не от серверного сокета, но сработало прерывание на наполнение входного буфера
42         else:
43             data = ""
44             try:
45                 data = resource.recv(1024)
46                 # Если сокет был закрыт на другой стороне
47                 except ConnectionResetError:
48                     pass
49
50             if data:
51                 data = binascii.hexlify(data).decode()
52                 # Вывод полученных данных на консоль
53                 print("Received data: {data}".format(data=str(data)))
54                 # Первоначальный фильтр для получения данных, исключая все микрозапросы
55                 if len(data) > 18:
56                     response = requests.post('https://back.cardioservice.com.kz/api/setByte/', data={'byte':str(data)})
57                     print(response)
58                 # Говорим о том, что мы будем еще и писать в данный сокет
59                 if resource not in OUTPUTS:
60                     OUTPUTS.append(resource)
61
62             # Если данных нет, но событие сработало, то ОС нам отправляет флаг о полном прочтении ресурса и его закрытии
63             else:
64                 # Очищаем данные о ресурсе и закрываем дескриптор
65                 clear_resource(resource)
66

```

2.2.13-сурет. Кіріс ақпараттардың пайда болуын өңдеу

Сокет сценарийін іске қосқанда, шығысында біз сервер консолінде сандарға түрлендірілген деректерді көреміз. Hexlify () функциясын қолдана отырып, біз байттарды алдымен hex-ке түрлендірдік, содан кейін decode() функциясын декодтау арқылы String түріне айналдырдық.

Деректерді алу, байт деректерін өңдеу және ондық сандарға түрлендіру.

```

PROBLEMS  OUTPUT  DEBUG CONSOLE  TERMINAL

RECEIVED DATA:
b'\x80\x00\x00\x80\x00\x00\x80\x00\x00\x80\x00\x00\x80\x00\x00\x7f\xff\xff'
b'\x7f\xff\xff\x80\x00\x00\x80\x00\x00\x80\x00\x00\x80\x00\x00'

```

2.2.14-сурет. Деректердің бастапқы түрі (байттар)

b'\x80\x00\x00\x80\x00\x00\x80\x00\x00\x80\x00\x00\x80\x00\x00\x7f\xff\xff\x7f\xff\xff\x80\x00\x00\x80\x00\x00\x80\x00\x00\x80\x00\x00' – мұнда біз құрылғының өзін анықтау үшін, сондай-ақ пайдаланушының идентификаторын, деректерді беру күні мен уақытын беру үшін алғашқы 8 байтты тағайындадық.


```
PROBLEMS OUTPUT DEBUG CONSOLE TERMINAL
RECEIVED DATA:
['16271475', '16272212', '16272212', '16278374', '16278374', '16268908', '16268908', '16269703', '16269703', '16271698', '16271698', '16272184',
'16272184', '16278229', '16278229', '16268990', '16268990', '16269994', '16269994', '16271870', '16271870', '16272026', '16272026', '16269964', '16
269964', '16268840', '16268840', '16278114', '16278114', '1627874', '1627874', '16271854', '16271854', '16268810', '16268810', '16268902', '16268902', '16278531', '16272163', '16272163', '16271528', '16271528', '16268420', '16268420', '16269039', '16269039', '16278748', '162787
48', '16271995', '16271995', '16271264', '16271264', '16269274', '16269274', '16269882', '16269882', '16271038', '16271038', '16272226', '16272226',
'16271146', '16271146', '16269056', '16269056', '16269180', '16269180', '16271247', '16271247', '16272154', '16272154', '16278855', '16278855',
'16269101', '16269101', '16269262', '16269262', '16271169', '16271169', '16271519', '16271519', '16269829', '16269829', '16268413', '16268413',
'16268989', '16268989', '16271552', '16271552', '16272260', '16272260', '16278684', '16278684', '16269138', '16269138', '16269917', '16269917', '16
272121', '16272121', '16272354', '16272354', '16278220', '16278220', '16269007', '16269007', '16278010', '16278010', '16271905', '16271905', '1627
1986', '16271986', '16269886', '16269886', '16268938', '16268938', '16278356', '16278356', '16272228', '16272228', '16271911', '16271911', '162697
82', '16269782', '16269889', '16269889', '16272896', '16272896', '16275256', '16275256', '16276154', '16276154', '16274915', '16274915', '16271313',
'16271313', '16267859', '16267859', '16262876', '16262876', '16255308', '16255308', '16252887', '16252887', '16254194', '16254194', '16258630',
'16258630', '16263457', '16263457', '16264139', '16264139', '16264249', '16264249', '16266435', '16266435', '16269777', '16269777', '16271524',
16271524', '16278414', '16278414', '16269345', '16269345', '16278042', '16278042', '16273487', '16273487', '16273143', '16273143', '16271368', '16
271368', '16278015', '16278015', '16278836', '16278836', '16272792', '16272792', '16273875', '16273875', '16271295', '16271295', '16269974', '16269
974', '16271185', '16271185', '16273282', '16273282', '16273263', '16273263', '16271250', '16271250', '16278481', '16278481', '16271643', '16271643',
'16273447', '16273447', '16273236', '16273236', '16271157', '16271157', '16278629', '16278629', '16272135', '16272135', '16273773', '16273773',
'16273419', '16273419', '16271155', '16271155', '16278804', '16278804', '16272694', '16272694', '16274085', '16274085', '16273340', '16273340',
16271524', '16271524', '16278414', '16278414', '16269345', '16269345', '16278042', '16278042', '16273487', '16273487', '16273143', '16273143', '16271368', '16
16271926', '16271926', '16273959', '16273959', '16274916', '16274916', '16273789', '16273789', '16273789', '16271975', '16271975', '16272219', '16272219', '16
274404', '16274404', '16275073', '16275073', '16273430', '16273430', '16271924', '16271924', '16272415', '16272415', '16274395', '16274395', '1627
4709', '16274709', '16272595', '16272595', '16278970', '16278970', '16271773', '16271773', '16273533', '16273533', '16273365', '16273365', '162712
33', '16271233', '16278083', '16278083', '16271062', '16271062', '16272776', '16272776', '16272570', '16272570', '16278477', '16278477', '16269487',
'16269487', '16278710', '16278710', '16272375', '16272375', '16272072', '16272072', '16269917', '16269917', '16269377', '16269377', '16271127',
'16271127', '16272532', '16272532', '16271860', '16271860', '16269887', '16269887', '16269389', '16269389', '16271404', '16271404', '16272540', '16272540',
'16272540', '16271556', '16271556', '16269727', '16269727', '16269479', '16269479', '16271695', '16271695', '16272710', '16272710', '16272104', '16272104', '1626
271304', '16269550', '16269550', '16269709', '16269709', '16271895', '16271895', '16272736', '16272736', '16278978', '16278978', '16269464', '16269464', '1626
9464', '16269881', '16269881', '16271970', '16271970', '16272482', '16272482', '16278910', '16278910', '16269524', '16269524', '16278225', '16278225', '162702
25', '16272213', '16272213', '16272427', '16272427', '16278597', '16278597', '16269344', '16269344', '16278399', '16278399', '16272260', '16272260',
'16272380', '16272380', '16278293', '16278293', '16269358', '16269358', '16278647', '16278647', '16272357', '16272357', '16272132', '16272132',
```

2.2.15-сурет. Түрлендіруден кейін (List<String> –типі)

Бірақ бұл деректерді пайдалануға болмайды, себебі деректерді беру немесе өңдеу кезінде көптеген өзгеріске ұшыраған, шулар мен қайталанатын деректер бар. Алынған деректерді өңдеу кезеңінде біз POST әдісін қолдандық. Бұл әдіс деректерді қауіпсіз беруді қамтамасыз етеді. Әрі қарай, сәйкестендіру үшін кесуді қолдана отырып, тасымалдау деректері мен идентификаторы жазылған деректер аймағын таңдаймыз. Келесі мақсат - пакеттің денесіндегі деректерді филтрлау. Мұнда шуды кесу принципі қолданылады, біз алынған деректердің жоғарғы және төменгі шегін анықтаймыз және онымен сәйкесінше деректерді кесеміз. Яғни, осы шектен асатын барлық шу алынып тасталады. Филтрдан кейін пайдаланушының идентификаторын анықтап, деректерді алынған күні мен уақыты бойынша сұрыптаймыз және серверге сақтауға жібереміз.

Біздің жобада деректермен алмасу үшін біз бағдарламалық интерфейс – сокетті қолданамыз, бұл бізге әрқашан адамның жағдайын дәл анықтауға мүмкіндік береді және дереу деректермен алмасуды қамтамасыз етеді. Vue-де.js сокеттері айтарлықтай дамыған және үнемі жетілдіріліп отырады. Сокеттерді пайдалану үшін WebSocket () веб-сокеттерін инициализациялау функциясына жүгіну жеткілікті. Бірінші атрибут-біздің серверге бағытталған мекен-жай. Біз деректерін көргіміз келетін пациенттің id-нің нақты көрсеткішіне назар аударған жөн.

Бұл сценарийді іске қосқан кезде біз "@action/lcjs" графиктерді визуализациялауға арналған кітапханаға бағытталған есептеулерді байқай аламыз. Графиктерді салу кезінде бұл кітапхана графикалық теорияны қолданады, бұл бізге алынған деректерді integer типті сандар түрінде тиімді орналастыруға мүмкіндік береді. Осының арқасында пайдаланушы ЭКС-ды нақты уақытта көре алады (2.2.15-сурет).



2.2.16-сурет. ЭКС-тің нақты уақыттағы визуализациясы

Біздің құрылғының 4 тіркеуішінен алынған ақпараттың МИ локализациясын анықтауға жеткіліксіз екендігіне көз жеткізгеннен кейін, бастапқы этап ретінде алынған ЭКС арқылы қауіпті жүрек аритмиясын анықтадық. Бұл бастапқы этап, екінші этап, біздің ЭКС НЖТ әдісін пайдалану арқылы төрт тіркеуіштен алынған ЭКС МИ бар болу қауіпін анықтап, ол ақпаратты ары қарай нақтылау үшін білікті кардиолог дәрігерге жіберетін әдісті іске асырамыз. Өз кезегінде дәрігер МИ диагнозын нақтылау үшін ары қарай талдау жасауға шешім шығарады.

Жүректің қауіпті аритмиясын анықтаудағы негізгі мән – жүректің соғу жиілігі. Жүректің соғу жиілігінің мәнін есептеу үшін біздің құрылғы 60 секунд ішінде ЭКС алса жеткілікті болады. Жүректің соғу жиілігін анықтау формуласын алдын ала біле отырып, біз формуланы төменде жазылған синтаксис сияқты функцияға қайта жаздық:

$$\text{ЧСС} = \frac{60}{R-R'}, \quad (2.2.1)$$

мұндағы 60-минуттағы секундтар саны, R - R-секундтармен көрсетілген интервалдың ұзақтығы.

```
if (self.seconds >= 60) {
    self.chss = parseInt(len / 360);
    self.rr = 60 / parseInt(len / 360);
}
```

2.2.17-сурет. JavaScript бағдарламалау тілінде жазылған жүректің соғу жылдамдығын есептеу формуласы

RR мәнін есептеу өте маңызды (сигналдың екі амплитудасы арасындағы қашықтық, яғни жүрек соғуы). Осы мәндерді алғаннан кейін біз екі өте қауіпті

диагнозды оңай анықтай аламыз: "синус брадикардиясы" және "синус тахикардиясы". Дәлірек айтсақ, өте сирек жүрек соғу жиілігінде, мәні 45 соққыдан/сек-тен аз болса, "синус брадикардиясы", ал егер 100 соққыдан/сек-тен көп болса, онда "синус тахикардиясы" анықталады.

```

30 <div>
31   <b>{{ $t("protocol") }}</b>
32 </div>
33 <div>{{ $t("hs") }}: {{ chss }} {{ $t("bl_min") }}</div>
34 <div class="mb10">{{ $t("interval") }} RR: {{ rr }} мс</div>
35 </div>
36 <div class="table-conclusion">
37   <div>{{ $t("danger") }}</div>
38   <div>{{ $t("device_check") }}</div>
39 </div>
40 <div class="table-conclusion">
41   <div>{{ $t("sinus_rhythm") }}</div>
42   <div>{{ $t("normal_ecg") }}</div>
43 </div>
44 <div class="table-conclusion">
45   <div>{{ $t("sinus_bradycardia") }} ({{ $t("hs") }} 45)</div>
46   <div v-if="chss > 45">{{ $t("not_found") }}</div>
47   <div v-else>{{ $t("found") }}</div>
48 </div>
49 <div class="table-conclusion">
50   <div>{{ $t("sinus_tachycardia") }} ({{ $t("hs") }} ≥ 100)</div>
51   <div v-if="chss < 100">{{ $t("not_found") }}</div>
52   <div v-else>{{ $t("found") }}</div>
53 </div>

```

2.2.18-сурет. Қорытындыны визуализациялауға арналған код

Қорытындыға қажетті мәндерді есептеп болғаннан кейін, пайдаланушы өзінің соңғы диагнозын көре алады (2.2.19-сурет).



2.2.19-сурет. Диагностика нәтижесін визуализациялау

ЭКС тіркеу құрылғысынан сигнал алуға, оны алдын ала өңдеуді орындауға, өмірге қауіп төндіретін жүрек аритмиясын диагностикалауға, пациентті диагностика нәтижелері туралы хабардар етуге және пациенттің

ақпаратын одан әрі сақтау үшін деректерді серверге беруге арналған мобильді қосымшаға арналған бағдарламалық қамтамасыз ету әзірленді.

Еркін белсенділік жағдайында жүрек мониторингінің портативті ақпараттық-өлшеу жүйесінің қолданыстағы макеті Алматы қаласының "Central Asia Medical Industries" қалалық клиникасында сынақтан өтуде.

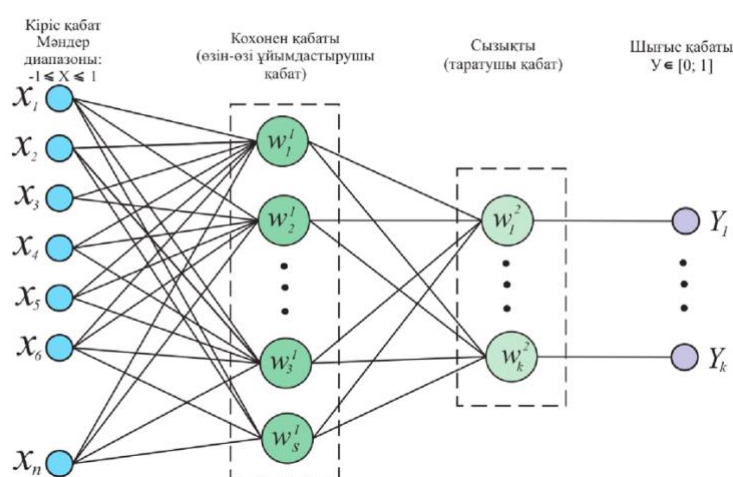
Жоғарыда айтып өткендей, МИ орналасқан орнын анықтау үшін, бізге 4 тіркеуіштен алынған ақпараттың жеткіліксіздігіне байланысты, ары қарайғы зерттеуге біз сандық ақпараттар базасынан алынған сигналдарды қолдандық.

2.3 МИ диагностикалау үшін электрокардиосигналдың нейрожелілік талдау әдісі.

Жоғарыда айтылғандай, МИ-на 6 негізгі белгі бойынша диагноз қойылады. Әрбір белгі белгілі бір сегментте көрінеді. Бұл тәсіл амплитудалық-уақыттық талдауда жүзеге асырылады.

ЭКС-дың ақпараттық параметрлерін анықтау ЭКС бойынша өсу, кему, тұрақтылық интервалдарын анықтаудан, тоқтау нүктелерін, осы нүктелердегі амплитудалық мәндерді бекітуден және анықталған интервалдардың ұзақтығын анықтаудан тұрады. Амплитудалық уақыттық ақпарат параметрлерін анықтау үшін олар амплитудалық уақыт аймағындағы МИ-нің ЭКС - белгілерімен салыстырылады. МИ белгілерін анықтау мақсатында ЭКС амплитудалық-уақыттық талдауының нәтижелері бойынша жүректің жағдайы бағаланады. Бұл кезде салыстыру нәтижелері көрсетіліп, жүрек жағдайына баға беріледі.

Бұл тәсілдің идеясы ұсынылған НЖТ әдісінің негізін құрады, яғни. 12 стандартты тіркеуіштің әрқайсысының МИ симптомы үшін белгілі бір тіркеуіштегі, белгілі бір симптомды анықтауға бағытталған нейрондық желі құрылады.



2.3.1 сурет – МИ диагностикасы үшін НЖ LVQ схемасы

ЭКС нейрожелілік талдаудың (NNA) әзірленген әдісі, LVQ нейрондық желілерін пайдаланып МИ диагностикалауына мүмкіндік береді. МИ

диагностикасы үшін қолданылатын LVQ НЖ схемасы 2.3.1 суретте көрсетілген.

LVQ НЖ шығысындағы сигналдың мәні келесі формула бойынша анықталады:

$$Y_k = F_{lin} \left(\sum_{j=1}^S w_{jk}^2 \cdot F_{compet} \left(\sqrt{\sum_{i=1}^N (x_i - w_{im}^1)^2} \right)_j \right), \quad (2.3.1)$$

мұндағы x_i – кіріс векторының i -ші элементі;

w_{im}^1 – бәсекелес қабаттың m -нейронының салмақтар векторының i -ші элементі;

w_{jk}^2 – сызықтық қабаттың k -нейронының салмақтар векторының j -ші элементі;

F_{compet} – жеңімпаз нейронды анықтайтын бәсекелес қабаттың тасымалдау функциясы;

F_{lin} – тарату қабатының нейрондарының сызықтық белсендіру функциясы;

N – НЖ кіріс векторының өлшемі;

S – бәсекелес қабаттағы нейрондардың саны;

Y_k – НЖ k -ші шығыс мәні.

Ұсынылған тәсілді негіздеу үшін ЭКС НЖТ функционалды сенімділігін есептеп, ерекшелігі мен сезімталдығын анықтау қажет. Ерекшелік – дені сау науқастардың жалпы санының арасында қолданылатын диагностикалық әдіспен сау науқастарды дұрыс анықтау ықтималдығы, ал сезімталдық – науқастардың жалпы санының арасында қолданылатын диагностикалық әдіспен ауру науқастарды дұрыс анықтау ықтималдығы.

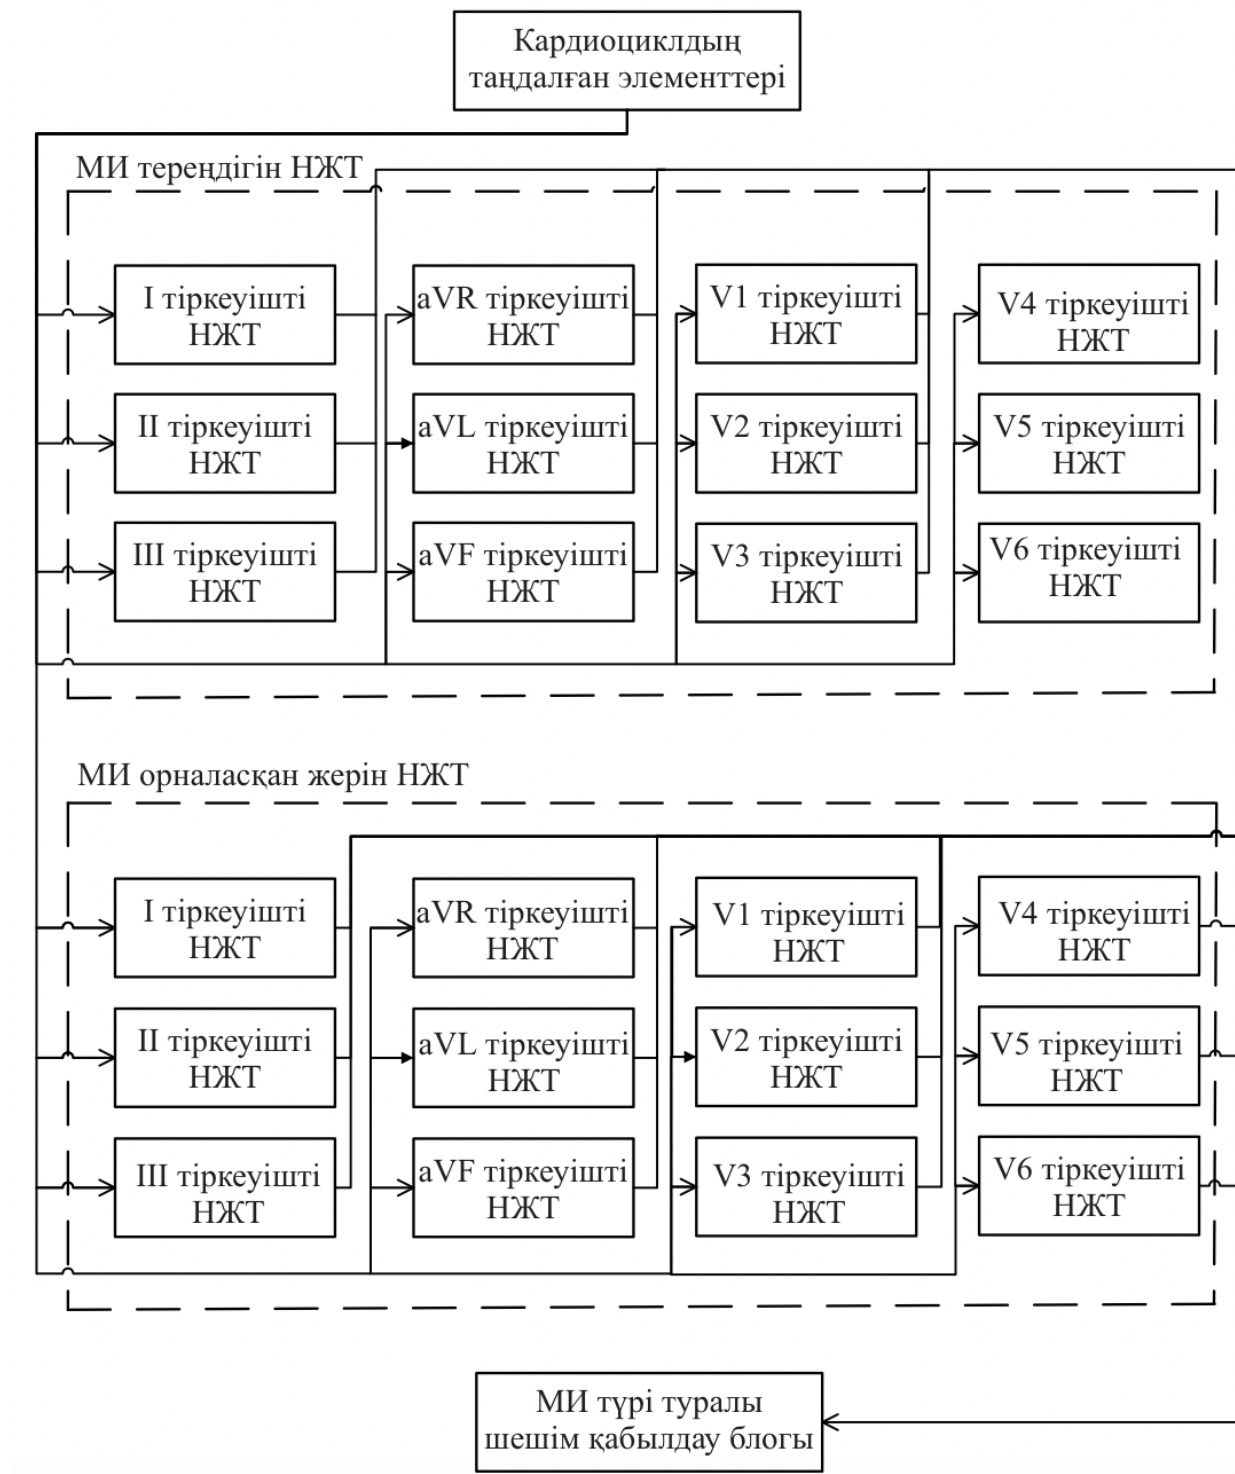
Жобалау кезеңінде мұндай сенімділікті есептеу күтілетін сенімділікті болжау және ЭКС НЖТ құрылымының оңтайлы нұсқасын таңдау үшін жүзеге асырылады. ЭКС НЖТ – да сенімділік теориясы тұрғысынан [114] ауру адамда аурудың болу ықтималдығын арттыру-сезімталдық функционалды қайталану, яғни олардың әртүрлі диагностикалық белгілерін бір уақытта талдау болып табылады. Кардиоциклдің жекелеген элементтеріндегі тікелей және өзара белгілерді талдау нәтижелері бойынша шешім қабылданады және жүректің жай-күйі туралы қорытынды беріледі. Диагноз қою үшін ЭКС-ті НЖТ ұсынылған тәсілін жүзеге асыратын құрылымдық схема 2.3.2-суретте көрсетілген.

2.1.1-суреттегі схеманы талдау кезінде МИ локализациясын НЖТ блогындағы "НЖТ i -ші тіркеуіш" -тің әрқайсысы осы немесе басқа белгілерге сәйкес келетін кардиоцикл элементін НЖТ-ға арналған алты НЖ LVQ параллель қосылысы екенін есте ұстаған жөн.

2.3.2-суреттен МИ диагнозын қою үшін ЭКС НЖТ ұсынылған тәсілдің құрылымдық схемасы параллель-кезекті құрылым екенін көре аламыз, онда кардиоцикл элементтерін НЖТ параллель қосылады, олардың бірлескен істен шығуы ЭКС НЖТ толық істен шығуына әкеліп соғады. Кардиоциклді және

кардиоцикл элементтерін таңдауға арналған блоктар, кардиоциклді НЖТ элементтері, сондай-ақ шешім қабылдау сериялық тізбекте қосылған, олардың кез келгенінің істен шығуы ЭКС НЖТ істен шығуына әкеледі.

ЭКС НЖТ жұмыс істеу сенімділігінің құрылымдық схемасының негізгі элементі кардиоциклді НЖТ элементтері болғандықтан, сенімділік теориясы тұрғысынан НЖТ-да МИ әртүрлі белгілерімен қатар қолдану науқаста аурудың болу ықтималдығын арттыратыны анық.



Сурет 2.3.2-ЭКС НЖТ ұсынған тәсілдің құрылымдық схемасы

n параллель қосылған элементтерден тұратын құрылғының ақаусыз күйінің ықтималдығы бірлескен кездейсоқ оқиғалардың ықтималдылығын қосу теоремасы бойынша анықталады [115]:

$$P = (p_1 + p_2 + \dots + p_n) - (p_1, p_2 + p_1, p_3 + \dots) - (p_1, p_2, p_3 + p_1, p_2, p_n + \dots) - \dots \pm (p_1, p_2, p_1, p_n) \quad (2.3.2)$$

Сенімділік теориясынан белгілі НЖТ МИ әртүрлі белгілерін қатар қолдану науқас адамда аурудың болуын анықтау ықтималдығын арттырады. Тәуелсіз (жиынтықта) оқиғалардың ықтималдығын көбейту ережесіне сәйкес n элементтен тұратын құрылғының сенімділігі мына формуламен есептеледі:

$$P = 1 - \prod_{i=1}^n (1 - p_i) \quad (2.3.3)$$

яғни тәуелсіз (сенімділік бойынша) элементтер параллель қосылғанда, олардың сенімсіздігі ($1 - p_i = q_i$) көбейтіледі.

Барлық элементтердің сенімділігі бірдей болған нақты жағдайда (2.3.3) формула келесідей түрленеді:

$$P = 1 - (1 - p)^n \quad (2.3.4)$$

Біздің жағдайда әрбір нейрондық желі бойынша дұрыс диагноз қою (сезімталдық) ықтималдығының өзіндік мәні бар. Осылайша, кардиоциклдің элементтерін НЖТ біріктіріп қолдану жағдайында дұрыс диагнозды анықтау ықтималдығы: $P = 0,997$ болады.

Осылайша, ұсынылған тұжырымдамаға сәйкес келесі мәселелерді шешу қажет:

1. Оқыту үлгісін қалыптастыру
2. Нейрондық желілер архитектурасын дамыту
3. Нейрондық желілерді оқыту
4. НЖТ шығыс деректерін өңдеу алгоритмін құру

Ұсынылған ЭКС НЖТ әдісінде 84 LVQ НЖ пайдаланылады. 12 тіркеуіштің әрқайсысының локализациясын талдау үшін 6 НЖ жасалады (патологиялық Q-тісше, патологиялық R тісше, ST сегментінің элевациясы, теріс T тісшесі, ST сегментінің депрессиясы, T үшкір тісшесі) және олардың тереңдігін талдау үшін 12 НЖ, яғни QRS кешеніндегі R тісшесінің болмауын талдау үшін әр тіркеуіш үшін бір нейрондық желі.

2.3.1 Кардиоциклдің сегменттерін талдау үшін оқыту үлгісін қалыптастыру

Бұл кезең шешуші мәнге ие, өйткені оқыту деректер жиынтығында (ОДЖ) сапасыз ақпарат болған жағдайда НЖ ақпаратты не оқи алмайды, не оқытудан кейін НЖТ сапасы қанағаттанарлықсыз болады. НЖ оқыту мақсатында ОДЖ қалыптастыру үшін "ЭКС-ті алдын ала өңдеу" блогы

ұсынған және жоғарыда сипатталған барлық іс-әрекеттерді орындау, сондай-ақ келесі іс-әрекеттерді орындау қажет:

1) **ОДЖ векторларының құрамдас бөліктерінің НЖ кіріс санына сәйкестігін қамтамасыз ету.** x - Таңдалған ЭКС кардиоциклінің компоненттерінің векторы; nx – x векторындағы компоненттер саны; k – x векторының құраушыларының координаталар векторы; n – НЖ кірістер саны болсын. Нейрондық желіні жаттықтыру үшін n және nx сәйкес келуі керек. n параметрі НЖ құрылымын сипаттайды, оның белгілі бір мәні бар, мысалы 150. n_x параметрі кардиоциклді таңдау нәтижесінде анықталған мән болып табылады және әрбір кардиоцикл үшін әр түрлі болады. Таңдалған кардиоциклдің x' ұзындығы n құрамдас бөліктерінің модификацияланған векторын алу қажет. Айтылған мәселе интерполяция міндеттеріне жатады, яғни белгілі "түйін" мәндеріне сәйкес аралық компоненттерді қалпына келтіруге дейін азаяды. Белгілі түйіндік мәндер бірдей болғандықтан, Ньютон көпмүшелі интерполяцияны қолданған жөн. Ең жақсы өнімділікті қамтамасыз ету үшін үш түйіндік интерполяция қолданылады, онда аралық мәндер x_j^i формулаға сәйкес есептеледі:

$$x_j^i = x_i + (x_{i+1} - x_i) \cdot e + \frac{x_{i+2} - 2 \cdot x_{i+1} + x_i}{2} \cdot 2 \cdot e \cdot (e - 1), \quad e = \frac{j - k_i}{k_{i+1} - k_i} \quad (2.3.1.1)$$

Осылайша, НЖ векторларының құрамдас бөліктерінің ОДЖ кіріс санына сәйкестігі қамтамасыз етіледі.

2) **ОДЖ векторларының компоненттерін масштабтау.** LVQ НЖ сапалы оқыту үшін ОДЖ векторларының компоненттерін масштабтау қажет. Ұсынылатын масштабтау ауқымы: $[-1; 1]$. x -таңдалған кардиоцикл ЭКС компоненттерінің векторы; x_{\max} - x векторының ең үлкен (оң немесе теріс) компонентінің абсолютті мәні болсын. Содан кейін x векторының компоненттерін масштабтау формула бойынша жүзеге асырылады:

$$x_i = \frac{x_i}{x_{\max}}. \quad (2.3.1.2)$$

3) **ОДЖ векторларының шуы мен уақыт ығысуын қоса алғанда, ОДЖ резервтеуді енгізу.** Жаттығу сигналдарының шектеулі саны жағдайында ОДЖ-на резервтеуді енгізу пайдалы. Бұл жағдайда ОДЖ-ның әрбір x^h векторы R есе қайталанатын, мұндағы R артықтық коэффициенті. Қайталану нәтижесінде ОДЖ векторларының саны R есе артады. Әрі қарай, векторлар жаңа ОДЖ шуылданады. Артық ОНД векторларының шуылы - "өлі" мәселесін шешудің тиімді әдістерінің бірі. Шуыл операциясы вектордың әрбір компонентінің мәнін формула бойынша есептелетін Rnd кездейсоқ шамасына қосу арқылы бұрмалаудан тұрады.:

$$Rnd = Sign \cdot Random \cdot \frac{F}{100}, \quad Sign = (-1)^{Random(2)}, \quad (2.3.1.3)$$

мұндағы F – пайызбен берілген шудың дәрежесі;

$Sign$ – есептелген шаманың Rnd белгісін анықтайтын шама.

ОДЖ векторларының белгілі бір шуылымен қатар, – ОДЖ векторларының компоненттерінің уақыт осіне қатысты кездейсоқ шамаға солға немесе оңға "уақыт ауысуы" қосымша әрекетті енгізу ұсынылады.. Енгізілген әрекет "өлі" және оқытылмаған нейрондардың санын азайтады, сондықтан НЖ жалпы қабілетін арттырады деп болжанады.

4) **ОДЖ векторларын ондыққа араластыру.** Алдыңғы әрекеттерді орындау нәтижесінде ОДЖ құрамында оқу векторларының реттелген жиынтығы бар, яғни белгілі бір класстың барлық оқу векторлары бірінен кейін бірі қатар жүреді. Мұндай тәртіп бірінші оқу дәуірінде бірінші класқа жататын векторлар нейрондардың көп бөлігіне әсер етеді, нәтижесінде НЖ басқа класстарға жататын векторларда нашар оқытылады. Оқу векторларын араластыру алгоритмі қарапайым. р-ОДЖ-дағы векторлардың саны болсын. Алгоритмді жүзеге асыру үшін ОДЖ векторларының жаңа индекстері бар вектор дайындалады. Әр индекс 1-ден р-ге дейінгі кездейсоқ сан ретінде анықталады, және индекстер қайталанбайды. Әрі қарай, алынған индекстерге сәйкес ОДЖ векторларын араластыру жүзеге асырылады.

ОДЖ дайындауға бағытталған іс-әрекеттер аяқталғаннан кейін LVQ НЖ оқыту жүзеге асырылады.

2.3.2 Кардиоциклдің сегменттерін талдауға арналған НС оқыту ерекшеліктері

LVQ НЖ МИ диагностикалауға үйрету үшін автор ұсынған CCLVQ3 оқыту алгоритмі қолданылады. Жаттығу векторының x компоненттері мен w^l_m бәсекелес қабатының нейрондарының салмақтарының арасындағы жақындық дәрежесін анықтау үшін (2.3.2.3) формуламен өрнектелетін евклидтік өлшем қолданылады. Оқытудың аяқталу критеріі циклдегі барлық дәуірлердің өтуі болып табылады, олардың саны оқытудың басында T көрсетіледі.

CCLVQ3 оқыту алгоритмінің схемасы 2.3.2.1 суретте көрсетілген.



2.3.2.1-сурет – CCLVQ3 оқыту алгоритмінің схемасы

CCLVQ3 оқыту алгоритмі келесідей жұмыс істейді:

1) Бәсекелес қабаттың барлық салмақтарына формула бойынша бірдей бастапқы мән беріледі:

$$w_{im}^1 = \frac{1}{\sqrt{n}}, \quad (2.3.2.1)$$

мұндағы n – нейрондық желі кірістерінің саны;

2) Келесі x^h векторы жаттығу үлгісінен таңдалады;

3) x^h векторының құраушылары формулаға сәйкес өзгертіледі:

$$x' = \beta(t) \cdot x^h + \frac{1 - \beta(t)}{\sqrt{n}}, \quad (2.3.2.2)$$

мұндағы t – жаттығу дәуірінің саны,

$\beta(t)$ – монотонды түрде өсетін функция, ол оқудың алға жылжуына қарай 0-ден 1-ге дейін өзгереді. Ол нөлге тең болғанда x^h векторының құраушылары (2.3.2.1) формулаға сәйкес өзгереді..

4) x' векторы мен бәсекелес қабаттың әрбір нейроны арасындағы евклидтік қашықтық формуламен анықталады:

$$d_m = \sqrt{\sum_{i=1}^N (x'_i - w_{im}^1)^2}, \quad (2.3.2.3)$$

мұндағы x' - модификацияланған жаттығу векторы;

w_{im}^1 - m -ші нейронның салмақ векторы;

5) x' векторына ең жақын екі нейрон анықталады, табылған нейрондар мен x' векторының арасындағы d_1, d_2 евклидтік қашықтықтары есептеледі;

б) Келесі шарт тексеріледі:

$$\min \left(\frac{d_1}{d_2}, \frac{d_2}{d_1} \right) > \frac{1 - \varepsilon}{1 + \varepsilon}, \quad (2.3.2.4)$$

мұндағы d_1 – x^h -тан бірінші жеңген нейронға дейінгі қашықтық;

d_2 - x^h -тен екінші жеңіске жеткен нейронға дейінгі қашықтық;

ε - оқыту векторы x^h түсуі керек терезенің ені. ε мәні $0,2 \div 0,3$ диапазонынан таңдалады.

7) Табылған нейрондардың салмақтары өзгереді. x' векторы дұрыс жіктелген жағдайда, ары қарай формула бойынша оң түзету орындалады:

$$w_m^1(t) = w_m^1(t-1) + \eta \cdot \delta \cdot (x' - w_m^1(t-1)), \quad (2.3.2.5)$$

мұндағы m – жеңген нейронның саны;

δ - салмақты түзету дәрежесіне әсер ететін параметр. Тәжірибе көрсеткендей, нейронның салмақтарын теріс түзету кезінде δ оңтайлы мәні 0,1-ден 0,3-ке дейінгі аралықта болады;

η - бәсекелес қабаттағы нейрондардың салмақтарын реттеу жылдамдығына әсер ететін параметр. Стандартты оқыту алгоритмдерінде (мысалы, LVQ1) бұл мән тұрақты (мысалы, 0,01) қабылданады немесе монотонды түрде төмендейді. CCLVQ3 алгоритмінде η мәні оқу процесі кезінде міндетті түрде

1-ден 0-ге дейін өзгереді. Жаттығудың басында η 1-ге тең болып қабылданады. Келесі жаттығу дәуірінің соңында η мына формула бойынша түзетіледі:

$$\eta = \eta - \frac{1 - 0,2}{T}, \quad (2.3.2.)$$

мұндағы T – оқыту дәуірлерінің жалпы саны. Алғашқы дәуірлерде салмақты түзету өте маңызды болып табылады, ал оқыту алгоритмі «өлі» нейрондардың санын барынша азайту үшін нейрондардың максималды санын алуға тырысады. Соңғы дәуірлерде салмақты түзету азырақ жүзеге асырылып, алдыңғы дәуірлерде оқытылған нейрондардың салмағы нақтыланады. Егер табылған екі нейронның біріншісі түзетілсе, онда δ параметрі 1-ге тең қабылданады. Егер екінші табылған нейрон түзетілсе, онда δ параметрінің мәні бірінші нейронға қандай операция орындалғанына байланысты қабылданады: егер түзету орындалса, онда 0,1 мәні, кері итеру болса, онда 1 мәні қолданылады.

x' векторы жалған классификацияланған кезде теріс түзету орындалады, яғни, формула бойынша нейрондық салмақтардың кері қайтарылуы (итерілуі):

$$w_m^l(t) = w_m^l(t-1) - \eta \cdot \delta \cdot (x' + w_m^l(t-1)), \quad (2.3.2.7)$$

мұндағы δ – 0,2 мәнін қабылдайтын параметр.

Айта кету керек, бірінші жаттығу дәуірі үшін кері қайтару жүргізілмейді.

8) Егер бұл оқыту дәуірі соңғы болмаса, онда 2-қадамға көшу жүзеге асырылады, яғни келесі дәуірге өтеді.

2.4 Диагностикалық қорытынды бойынша шешім қабылдау әдістемесі

Жоғарыда айтылғандай, әрбір электрокардиографиялық тіркеуіш жүректің белгілі бір бөлігінің электрлік белсенділігін көрсетеді. Осылайша, кез келген қорғасында МИ белгісінің көрінісімен біз оның локализациясын анықтай аламыз.

Диагностикалық қорытынды локализацияны көрсететін МИ белгілеріне байланысты «біріктірілген». Мысалы, бүйір жақтағы МИ локализациясын анықтау келесі өрнекке сәйкес жүзеге асырылады:

$$L_6 = Q_{V5} \cup R_{V5} \cup (ST \uparrow_{V5}) \cup (T \downarrow_{V5}) \cup Q_{V6} \cup R_{V6} \cup (ST \uparrow_{V6}) \cup (T \downarrow_{V6}) \quad (2.4.1)$$

мұндағы L_k - бөлінген локализациялар және олардың келесідей анықталған түрі:

$$L_k = \begin{cases} 1, & \text{егер МИ – ның кем дегенде бір сәйкес белгісі көрінсе} \\ 0, & \text{симптомдардың ешқайсысы пайда болмаса} \\ Q_g, R_g, (ST \uparrow_g), (T \downarrow_g) & \text{сәйкес } g \text{ тіркеуіштегі МИ белгісінің көрінісі.} \end{cases}$$

МИ локализациясының әзірленген кестесінің негізінде белгіге байланысты МИ түрі мен локализациясы бойынша келесі логикалық шешім қабылдау функциясы алынды.

$$Z = \bigcup_{k=1}^m L_k \quad (2.4.2)$$

мұндағы Z – МИ түрі туралы диагностикалық қорытынды;

m – талданатын белгілердің саны;

Шешім қабылдау принципі МИ-нің көрінетін белгісін оны анықтайтын локализациясымен корреляциялаудан тұрады. Ол үшін МИ локализациясының кестесі құрастырылды. (2.1.1 кестені қараңыз)

Нейрондық желілердің нәтижелерін талдау үшін шешім қабылдау ережелерін құру МИ локализацияларының әрқайсысындағы ауытқулар барлық тіркеуіштерде пайда болмайтындығына негізделген. МИ-ге қатысты (к-1) жүрек жағдайының біреуін таңдау бойынша шешім қабылдау ережелерін құру үшін сегіз түрлі локализация үшін ЭКС тіркеуіштерінде МИ тікелей және реципрокты белгілерінің болуы мен болмауының комбинациясы қолданылды.

МИ сегіз диагнозы үшін логикалық блоктарды құрудың шешуші ережелері:

1) алдыңғы және алдыңғыбөлімінің МИ

$$F_1 = \bar{I} \& \bar{II} \& III \& \overline{aVR} \& \overline{aVF} \& \overline{aVL} \& V1 \& V2 \& V3 \& V4 \& \bar{V5} \& \bar{V6}, \quad (2.4.3)$$

2) алдыңғы базальды МИ

$$F_2 = \bar{I} \& \bar{II} \& III \& \overline{aVR} \& \overline{aVF} \& \overline{aVL} \& V1 \& V2 \& \bar{V3} \& \bar{V4} \& \bar{V5} \& \bar{V6}, \quad (2.4.4)$$

3) алдыңғы кең таралған МИ

$$F_3 = I \& II \& III \& \overline{aVR} \& \overline{aVF} \& \overline{aVL} \& V1 \& V2 \& V3 \& V4 \& V5 \& V6 \quad (2.4.5)$$

4) бүйірлік МИ

$$F_4 = I \& II \& \bar{III} \& \overline{aVR} \& \overline{aVF} \& \overline{aVL} \& V1 \& V2 \& \bar{V3} \& \bar{V4} \& V5 \& V6, \quad (2.4.6)$$

5) бүйірлік базальды МИ

$$F_5 = \bar{I} \& \bar{II} \& III \& \overline{aVR} \& \overline{aVF} \& \overline{aVL} \& V1 \& V2 \& \bar{V3} \& \bar{V4} \& \bar{V5} \& \bar{V6}, \quad (2.4.7)$$

6) Артқы жақ (төменгі)МИ

$$F_6 = I \& II \& III \& \overline{aVR} \& \overline{aVF} \& \overline{aVL} \& \bar{V1} \& V2 \& V3 \& V4 \& V5 \& \bar{V6}, \quad (2.4.8)$$

7) Циркулярлы МИ

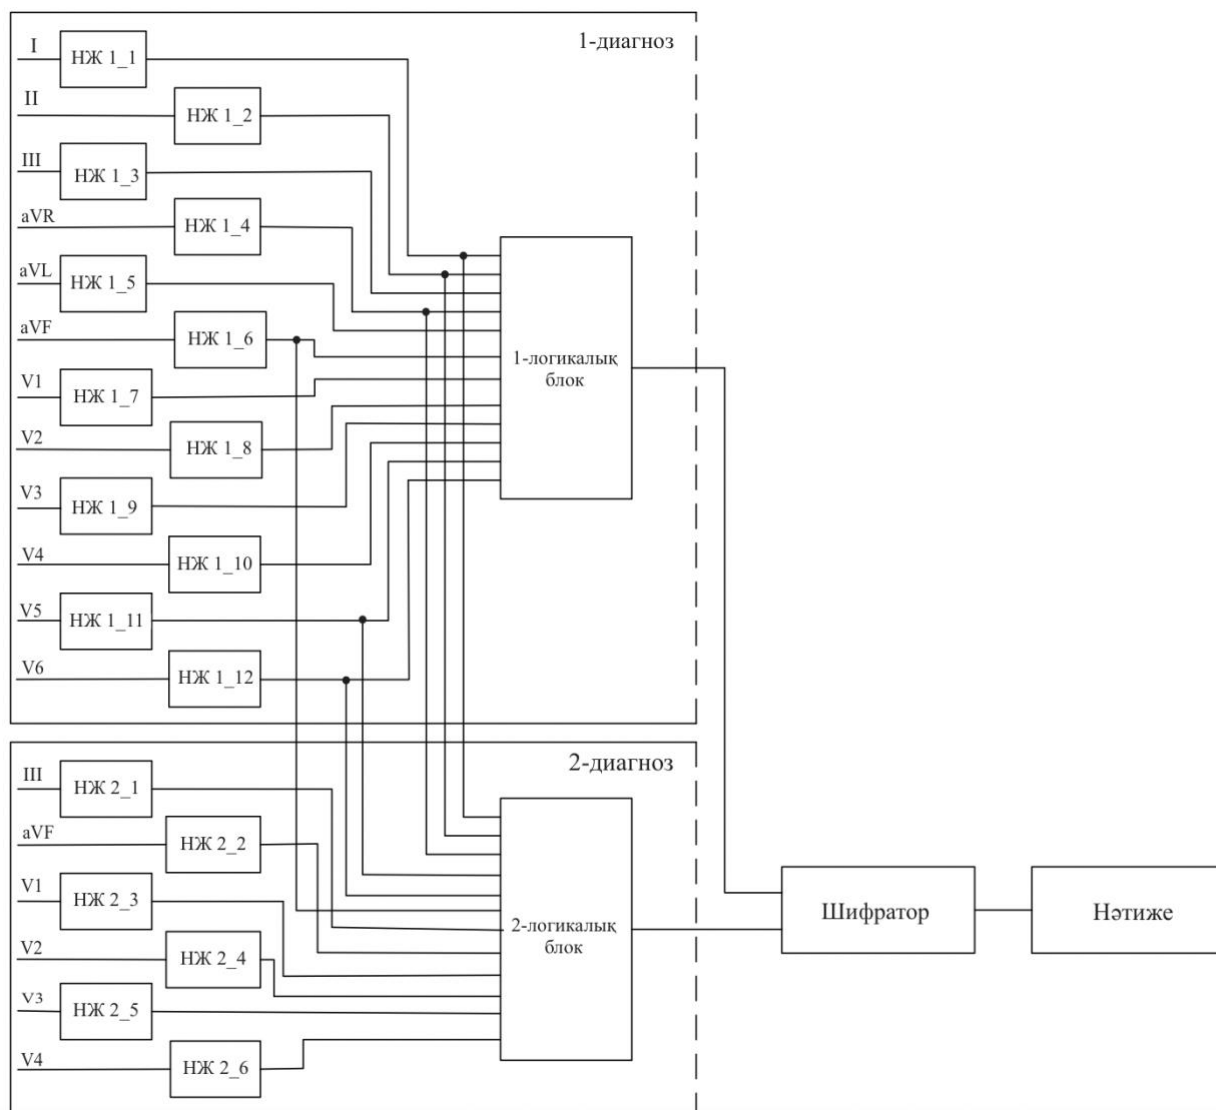
$$F_7 = \bar{I} \& II \& III \& \overline{aVR} \& \overline{aVF} \& \overline{aVL} \& V1 \& V2 \& V3 \& V4 \& V5 \& V6, \quad (2.4.9)$$

8) артқы базальды МИ

$$F_8 = \bar{I} \& \bar{II} \& \bar{III} \& \overline{aVR} \& \overline{aVF} \& \overline{aVL} \& V1 \& V2 \& V3 \& \bar{V4} \& \bar{V5} \& \bar{V6}, \quad (2.4.10)$$

мұнда \bar{I} , \bar{II} , \bar{aVR} , \bar{aVF} , \bar{aVL} , $\bar{V1}$, $\bar{V2}$, $\bar{V3}$, $\bar{V4}$, $\bar{V5}$, $\bar{V6}$ – сау ЭКС-ті анықтайтын нейрондық желілердің шығу деректері.

Нейрондық желілердің шығуын талдау (1...k). Бұл кезеңде шешуші ережелер негізінде (1÷8) науқастың жүрек жағдайы туралы шешім қабылданады. Төменде 2.5-суретте Mathlab ортасында жүзеге асырылған жүректің бес жағдайына арналған ЭКС нейрожелілік талдау схемасы көрсетілген. 2.4.1-суретте жүректің екі жағдайының біріне жататын пациенттің жүрек жағдайы туралы диагностикалық қорытындыны қалыптастыру схемасы келтірілген: сау және миокард инфарктісі, алдыңғы және алдыңғыбөлік МИ локализациясы.



2.4.1-сурет-пациенттің жүрегінің жай-күйі туралы диагностикалық қорытындыны қалыптастыру схемасы

2.4.1-Кесте - көрсетілген белгілерге сәйкес оларды оқшаулау

Тіркелігі	МИ ЭКС белгілері	Локализациясы	Тіркелігі	МИ ЭКС белгілері	Локализациясы
I	Патологиялық Q	Передний ИМ	V1	Патологиялық Q	Передний ИМ
	Патологиялық R	Передний ИМ		Патологиялық R	Передний ИМ
	ST элевациясы	Передний ИМ		ST элевациясы	Передний ИМ
	Теріс T	Передний ИМ		Теріс T	Передний ИМ
	ST депрессиясы	Задний ИМ		ST депрессиясы	Задний ИМ
	Жоғары T	Задний ИМ		Жоғары T	Задний ИМ
II	Патологиялық Q	Передний ИМ	V2	Патологиялық Q	Передний ИМ
	Патологиялық R	Передний ИМ		Патологиялық R	Передний ИМ
	ST элевациясы	Нижний ИМ		ST элевациясы	Передний ИМ
	Теріс T	Нижний ИМ		Теріс T	Передний ИМ

	<i>ST</i> депрессиясы	Задний ИМ		<i>ST</i> депрессиясы	Задний ИМ
	Жоғары <i>T</i>	Задний ИМ		Жоғары <i>T</i>	Задний ИМ
III	Патологиялық <i>Q</i>	Задний ИМ	V3	Патологиялық <i>Q</i>	Передний ИМ
	Патологиялық <i>R</i>	Задний ИМ		Патологиялық <i>R</i>	Передний ИМ
	<i>ST</i> элевациясы	Нижний ИМ		<i>ST</i> элевациясы	Перегородочный ИМ
	Теріс <i>T</i>	Нижний ИМ		Теріс <i>T</i>	Перегородочный ИМ
	<i>ST</i> депрессиясы	Передний ИМ		<i>ST</i> депрессиясы	Перегородочный ИМ
	Жоғары <i>T</i>	Передний ИМ		Жоғары <i>T</i>	Задний ИМ
aVL	Патологиялық <i>Q</i>	Передний ИМ	V4	Патологиялық <i>Q</i>	Верхушечный ИМ
	Патологиялық <i>R</i>	Передний ИМ		Патологиялық <i>R</i>	Верхушечный ИМ
	<i>ST</i> элевациясы	Передний ИМ		<i>ST</i> элевациясы	Верхушечный ИМ
	Теріс <i>T</i>	Передний ИМ		Теріс <i>T</i>	Верхушечный ИМ
	<i>ST</i> депрессиясы	Задний ИМ		<i>ST</i> депрессиясы	Верхушечный ИМ
	Жоғары <i>T</i>	Задний ИМ		Жоғары <i>T</i>	Верхушечный ИМ
aVR	Патологиялық <i>Q</i>	Боковой ИМ	V5	Патологиялық <i>Q</i>	Боковой ИМ
	Патологиялық <i>R</i>	Боковой ИМ		Патологиялық <i>R</i>	Боковой ИМ
	<i>ST</i> элевациясы	Боковой ИМ		<i>ST</i> элевациясы	Боковой ИМ
	Теріс <i>T</i>	Боковой ИМ		Теріс <i>T</i>	Боковой ИМ
	<i>ST</i> депрессиясы	Боковой ИМ		<i>ST</i> депрессиясы	Задний ИМ
	Жоғары <i>T</i>	Боковой ИМ		Жоғары <i>T</i>	Задний ИМ
aVF	Патологиялық <i>Q</i>	Задний ИМ	V6	Патологиялық <i>Q</i>	Боковой ИМ
	Патологиялық <i>R</i>	Задний ИМ		Патологиялық <i>R</i>	Боковой ИМ
	<i>ST</i> элевациясы	Нижний ИМ		<i>ST</i> элевациясы	Боковой ИМ
	Теріс <i>T</i>	Нижний ИМ		Теріс <i>T</i>	Боковой ИМ
	<i>ST</i> депрессиясы	Передний ИМ		<i>ST</i> депрессиясы	Задний ИМ
	Жоғары <i>T</i>	Передний ИМ		Жоғары <i>T</i>	Задний ИМ

ЭКС НЖТ ұсынылатын тәсілдің ерекшелігі - НЖ сериялы-параллель қосылысы қолданылады. Локализацияны анықтаумен қатар МИ трансмуральдылығын немесе «тереңдігін» талдау (QRS кешенінде R-толқынының болмауы) жүргізіледі. Кез-келген тіркеуіштен келген ақпаратта, R - тісшесі болмаған жағдайда QRS кешенінің бейнесінің ерекшеліктеріне байланысты осы тіркеуіштегі патологиялық Q және R-тістерін талдау жүргізілмейтіндігін айта кету керек. Осы шартты пайдалана отырып, нейрондық желі арқылы осы мүмкіндіктерді талдаудағы қате жойылады.

Жүректің жай-күйі туралы болжам жасау үшін шешім қабылдау ережелері:

– егер НЖТ нәтижесінде барлық тіркеуіштен кардиоциклдің барлық сегменттері "сау" ЭКС класына жатқызылса, науқас сау деп шешім шығарылады;

– егер сегменттердің кем дегенде біреуі патологиялық болып шықса, нормадан ауытқу деген сөз. Бұл жағдайда басқа кардиоциклде пайда болған белгіні қайта талдау жүргізіледі. Ол ақпарат расталған жағдайда субъектіге клиникалық тексеруден өтуге, атап айтқанда тропонинге тест тапсыруға немесе ЭхоКГ жасауға нұсқама беріледі.

– бірнеше сегментте ауытқу белгілерінің бар болуы айқын патология бар екенін білдіреді, бұл жағдайда пайда болған белгілерді шығарумен диагностикалық шешім қабылданады.

2.5 Миокард инфарктісін диагностикалау үшін электрокардиосигналды нейрожелілік өндеу әдісін іске асыру

Әзірленген алдын-ала өңделген ЭКС-ды талдау әдістемесі 2 кезеңнен тұрады:

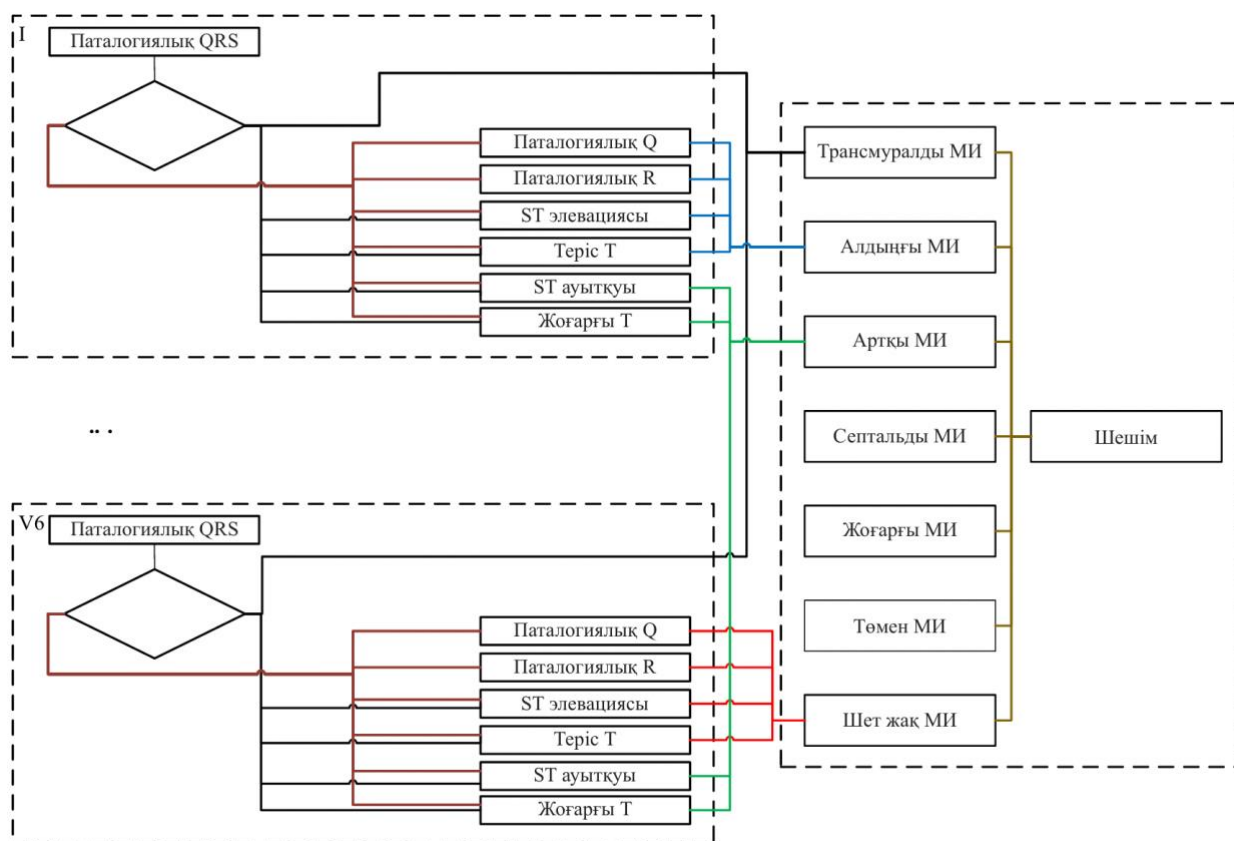
1) Кейбір анықтамалық геометриямен ЭКС сегменттерін аналитикалық (геометриялық) салыстыру.

2) Логикалық түрлендірулер арқылы барлық нейрондық желілерден алынған мәліметтер негізінде диагноз қою.

Әрі қарай, әр кезеңнің толық сипаттамасы берілген.

1) Әрбір тіркеуіштегі кардиоцикл сегментін жеке-жеке талдау үшін MATLAB ортасында жасалған және оқытылған LVQ типті нейрондық желілер қолданылады, олар үшін мәліметтер жиынтығы патологиялары бар типтік артық сигналдар емес, патологиялардың формасы, басқаша айтқанда, сигналдың белгілі бір сегменттегі әрекеті (амплитудасының өзгеруі және т. б.) болып табылады, бұл нейрондық желілердің жұмысын/позитивтің дәлдігін едәуір арттыруға мүмкіндік береді (эксперименталды түрде 98% дейін дәлелденген). Мұндай нейрондық желілердің шығыс ақпараты логикалық модульге берілетін Boolean (жалған/шындық) мәндерінің тізбегі болып табылады.

2) Нейрожелілік талдау блогынан алынған деректер жекелеген белгілер бойынша сұрыпталып, алдын ала дайындалған бағдарлама бойынша кіріс деректерінің шынайы мәндері болған кезде миокард инфарктісін одан әрі оқшаулай отырып, трансмуралдылыққа тексеруге мүмкіндік беретін логикалық құрылғыға беріледі. Логикалық модульден мәліметтер базасының негізінде миокард инфарктісі диагнозының негізгі кестесінен диагноз таңдалады (2.4.1 кестені қараңыз).



2.5.1-сурет – Диагностикалық шешім қабылдау принципі

Талдау аяқталғаннан кейін, жүйенің шығысында МИ анықталған жағдайда:

- 1) МИ трансмуралдығы туралы қорытынды;
- 2) Жүректің проблемалық аймақтарын локализациялау;
- 3) 2.4.1 кесте негізінде қойылған диагноз.

2.5.1-суретте Matlab ортасында жүзеге асырылған жүректің бес жағдайына арналған ЭКС нейрожелілік талдау схемасы көрсетілген. Приоритеттік шифратордың көмегімен k нейрондық желі арқылы ЭКС талдауы нәтижесінде алынған нақты шешімдердің бірі таңдалады. Приоритетті шифратордың шығуында оң кіріс сигналы келетін кіріс желісі нөмірінің коды қалыптастырылады (ЭКС-талдауға қатысатын k нейрондық желілерінің бірінің шығысының логикалық бірлік сигналы). Бір уақытта бірнеше кіріс сигналдары түскен кезде, ең үлкен нөмірі бар кіріске сәйкес келетін шығыс коды жасалады. Сондықтан шифратор приоритетті болып табылады. Осы кезеңнің жұмысының нәтижесі талданған ЭКС тағайындалған пациенттің жүрегінің жай-күйі туралы диагностикалық қорытындының нөмірі болып табылады. Содан кейін алынған нөмірге пациенттің жүрегінің жай-күйі туралы диагностикалық қорытындының ауызша сипаттамасы беріліп, пайдаланушыға хабарланады.

ЭКС НЖТ әдісін іске асыру үшін біз MATLAB бағдарламалық жасақтамасын қолдандық. Ол үшін QRS кешендерін және электрокардиограмма (ЭКГ) сигналдарының R шындарын белгілеу үшін

Signal Labeler-де автоматты таңбалаудың арнайы функциялары қолданылды. Бір пайдаланушы функциясы QRS кешендерін анықтау және орналастыру үшін алдын-ала дайындалған рекурентті LVQ терең оқыту желісі пайдаланылады. Другая пользовательская функция использует поиск пиков для определения местоположения R пиков. Бұл тапсырмада желі - желіні оқыту және тестілеу процесіне толығымен тәуелсіз екі сигналдың QRS кешендерін белгілейді.

Біздің тапсырмамыздағы терең оқыту желісі сигнал сегментациясына терең оқытуды пайдалана отырып енгізілді, онда ол жалпы QT дерекқорынан алынған ЭКГ сигналдары арқылы оқытылды. Деректер 250 Гц жиілікте таңдалған 303 пациенттің шамамен 15 минуттық ЭКГ жазбаларынан тұрады. Мәліметтер базасы автоматтандырылған сараптамалық жүйемен жасалған сигнал аймақтарының белгілерін береді [116]. Қосылған белгілер терең оқыту желісін оқыту үшін деректерді пайдалануға мүмкіндік береді.

Біздің зерттеуде белгіленген сигналдар жоғарыда айтылған цифрланған электрокардиосигналдар жиынтығына сақталатын мәліметтер базасынан алынған [117]. Дерекқордағы әрбір сигнал кездейсоқ 250 Гц орташа жиілікте іріктеліп алынды және нәтижелерді Пенза қаласының білікті кардиологына тексіртіп, аннотация жасалынды.

200 және 203 жазбаларына сәйкес екі сигналды жүктейік. QT дерекқорының деректерін іріктеудің номиналды жиілігіне сәйкес келетін 1/250 секунд уақытымен сигналдарды біртекті сеткаға қайта іріктеу.

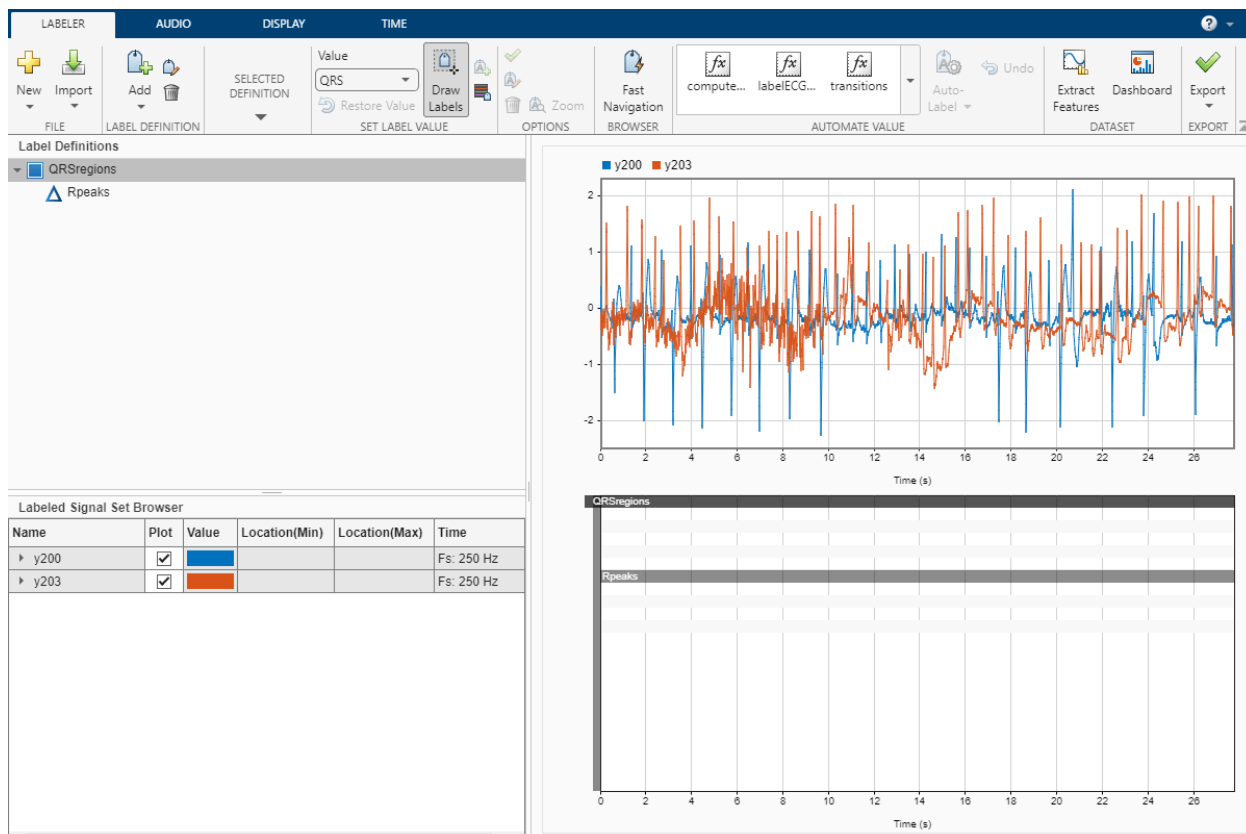
```
load pots200
y200 = resample(ecgsig,tm,250);

load pots203
y203 = resample(ecgsig,tm,250);
```

Signal Labeler-ді ашамыз. Labeler қойындысынан Import түймесін басып, Members тізіміндегі жұмыс аймағынан таңдаймыз. Диалогтік терезеден y200 және y203 сигналдарын таңдап аламыз. Уақыт туралы ақпаратты қосуымыз керек: ашылатын тізімнен уақытты таңдап, 250 Гц іріктеу жиілігін көрсетеміз. Import түймесін басып, сигналдарымызды жүктеп алғаннан кейін, Close батырмасын басып, жабамыз. Сигналдар Labeled Signal Set Browser аймағында көрсетіледі. Диаграммаға сигналдарды олардың атауларының жанына құсбелгі қою арқылы енгіземіз.

Сигналдарға бекіту үшін белгілерді анықтаймыз. QRS кешендеріне арналған қызығушылық аймағының (ROI) категориялық торын анықтаймыз. Labeler қойындысындағы анықтаманы алу үшін Add Definition түймесін басамыз. Таңбаның атын QRS аймағы ретінде көрсетіп, ROI таңбасының түрін таңдап, деректер түрін категориялық ретінде енгізіп, әрқайсысы бөлек жолда екі санатты, QR және n/a қосамыз.

QRS аймақтарын R шыңдары үшін сандық нүкте белгісі ретінде анықтаймыз. Оны таңдау үшін белгі анықтамалары браузеріндегі QR аймақтарын таңдаймыз. Анықтама қосу түймесін басып, кірістірілген белгі анықтамасын қосамыз. Белгілердің атауын R шыңдары ретінде көрсетіп, нүкте белгілерінің түрін таңдаймыз және деректер түрін сандық деп енгіземіз.



Сурет 2.5.1 Белгіні анықтау

Жеке автомаркерлеу функцияларын жасау

QRS кешендерін табатын функция үшін Name өрісіне findQRS енгізіп, Label Type ретінде ROI таңдаймыз. Description өрісін бос қалдырып немесе өз сипаттамамызды енгізуімізге болады.

R шыңдарын табатын функция үшін атау өрісіне шыңдарды іздеуді енгізіп, Label Type ретінде нүктені таңдаймыз. Бұл жерде де, Description өрісін бос қалдырып немесе өз сипаттамамызды енгізуімізге болады. Біз екі жеке маркерлеу функциясын жасап аламыз, олардың біреуі QRS кешендерінің орналасуы мен таңбалануы үшін, ал екіншісі әр QRS кешенінде орналасқан R шыңын анықтап, оларды белгілеу үшін (finders және findRpeaksfunctions функциялары үшін қолданылған кодтар туралы төменде толығырақ жазамыз). Әрбір функцияны құру үшін Labeler қойындысында автоматтандырылған мәндер галереясын кеңейтіп, жеке функцияны қосуды таңдаңыз. Функция белгісінің атауын, сипаттамасын және түрін сұрайтын тілқатысу терезесін Signal Labeler көрсетеді

Егер сізде бұрыннан жазылған функциялар болса және функциялар ағымдағы папкада немесе MATLAB тізбегінде болса, Signal Labeler галереяға

функцияларды қосады. Біз ешқандай функцияларды жазбағандықтан, Labeler кодты енгізу немесе қою үшін редакторда бос үлгілерді ашады. Файлдарды сақтаймыз. Файлдарды сақтағаннан кейін функциялар галереяда пайда болады

QRS кешендерін және R шыңдарын белгілеу

Кіріс сигналдарының QRS кешендерін тауып, белгілейміз.

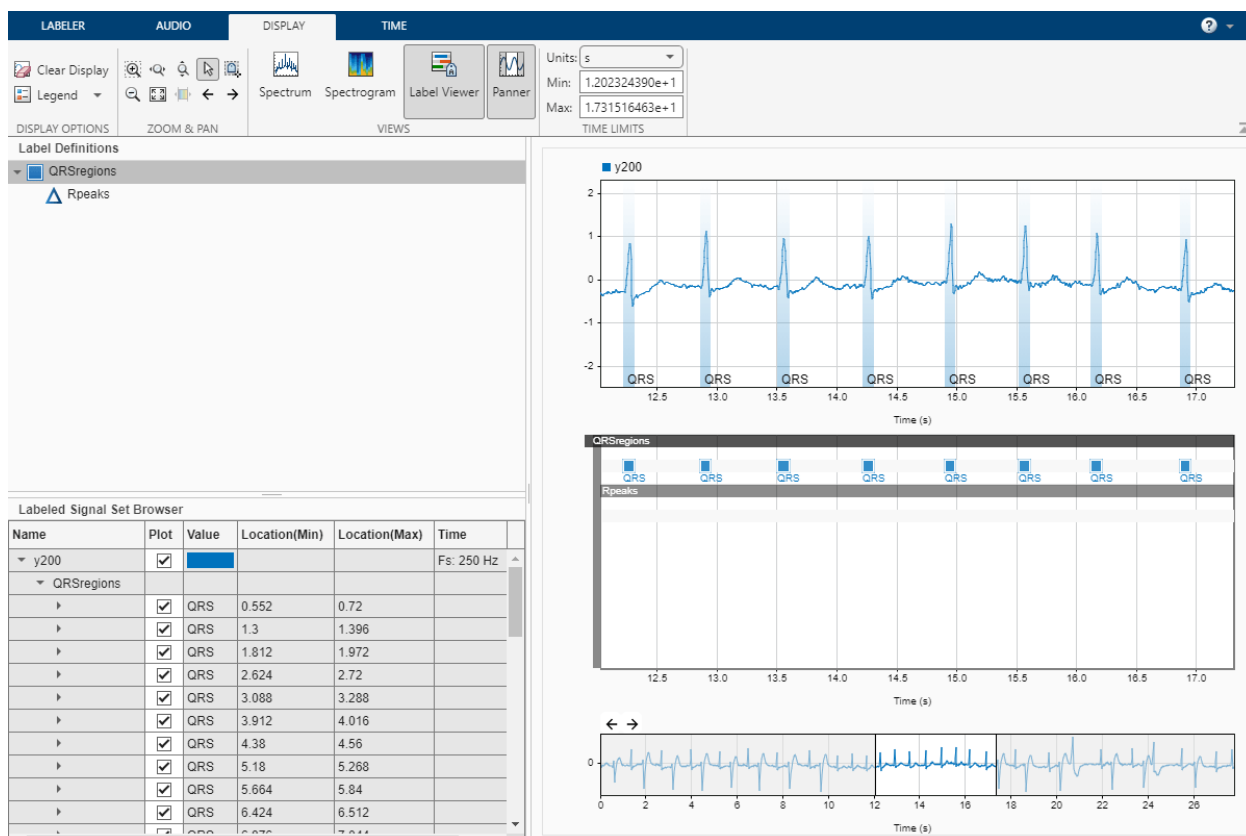
Орнатылған Sets of labeled signals y200 жанындағы құсбелгіні қоямыз.

Label Definitions браузеріндегі QRS аймақтарын таңдаймыз.

Automate Value галереясында findQRS таңдаймыз.

"Автоматты таңбалау" түймесін басып, "Auto-Label All Signals" таңдаймыз. Пайда болған тілқатысу терезесінде Аргументтер өрісіне 250 іріктеу жиілігін енгізіп, ОК түймесін басамыз.

Signal Labeler барлық сигналдарға арналған QR кешендерін тауып, таңбалайды, бірақ жалаушалары орнатылған сигналдарға арналған белгілерді ғана көрсетеді. QRS кешендері диаграммада және белгілерді қарау осьтерінде күңгірттелген аймақтар түрінде көрсетіледі. Display қойындысындағы Panner түймесін басу арқылы панельді белсендіреміз және белгіленген сигналдың аумағын үлкейтіп аламыз.



2.5.2 сурет QRS кешенін оқшаулау

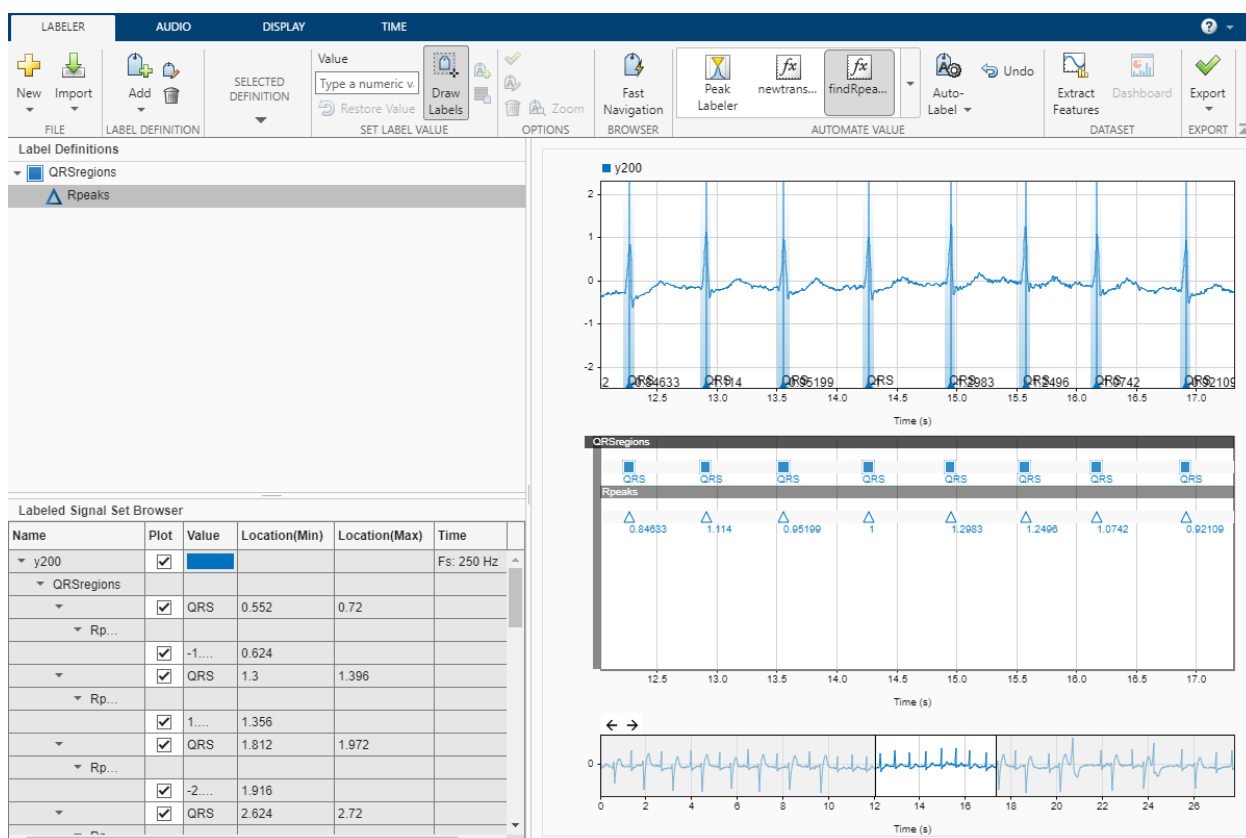
QRS комплекстеріне сәйкес R шыңдарын тауып, белгілейміз.

Label Definitions browser-ден шығдарды таңдаймыз.

"Label" қойындысына оралып, Automate Value галереясынан findpeaks таңдап аламыз.

"Автоматты таңбалау" түймесін басып, "Auto-Label All Signals" таңдаймыз. Пайда болған диалогтік терезесінде ОК түймесін басыңыз.

Белгілер мен олардың сандық мәндері графикте және белгілерді қарау осьтерінде көрсетіледі.



Сурет 2.5.3. R шыңын таңдау

Белгіленген сигналдарды экспорттау және жүрек атрасының өзгергіштігін есептеу

Әр пациент үшін жүрек соғу жиілігінің өзгермелілігін салыстыру үшін белгіленген сигналдарды экспорттау. Белгіленген қойындыда Export түймесін басып, «Signal Setlist» деп белгіленген тізімнен файлды таңдап аламыз. Пайда болған диалогтық терезеде көрсетілген сигналдар жинағына HeartRates.mat атауын беріп, қосымша қысқаша сипаттаманы қосып алғаннан кейін, Export түймесін басыңыз.

MATLAB пәрмен терезесіне оралып, белгіленген сигналдар жинағын жүктейміз. Жиынтықтағы әрбір сигнал үшін жүрек соғу жиілігінің өзгермелілігін дәйекті импульстар арасындағы уақыт айырмашылығының стандартты ауытқуы ретінде есептейміз. Айырмашылықтардың гистограммасын сызып, жүрек соғу жиілігінің өзгергіштігін көрсетеміз.

```
load HeartRates
```

```
nms = getMemberNames(heartrates);
```

```

for k = 1:heartrates.NumMembers


    v = getLabelValues(heartrates,k,["QRSregions" "Rpeaks"]);

    hr = diff(cellfun(@(x) x.Location,v));

    subplot(2,1,k)
    histogram(hr,0.5:0.025:1.5)
    legend("hrv = " + std(hr))
    ylabel(nms(k))
    ylim([0 6])

end

```



2.5.4-сурет. Жүрек соғу жиілігінің өзгергіштігі

Әрі қарай, біз әдісімізді жүзеге асыру үшін қолданылатын функциялар мен командалар туралы толығырақ сипаттаймыз.

QRS іздеу функциясы: QRS кешенін іздеу
findQRS функциясы кіріс сигналдарының QRS кешендерін тауып, белгілейді.

Функция кіріс формасын өзгерту және Фурье түрлендіруін синхрондап есептеу үшін computers көмекші функциясын қолданады. Біз компьютерлерді бір каталогтағы бөлек файлға сақтай аламыз немесе оны findQRS-ке салып, оны соңғы end операторының алдына қоя аламыз.

findQRS QRS аймақтарын анықтау үшін classify (Deep Learning Toolbox) функциясын және deep learning Network желісін қолданады. Терең оқыту желілері әр кіріс нүктесін R-шыңы, QRS кешеніне тиесілі, және де, T аймағы олардың ешқайсысына тиесілі емес деп белгілейтін категориялық массивті шығарады. Бұл функция QRS кешеніне сәйкес келетін нүкте белгілерін signalMask көмегімен QRS бізге керек аймағының белгілеріне түрлендіреді және қалғандарын тастайды. df параметрі қызығушылық аймағы ретінде тек ұзақтығы 20 санақтан асатын QRS кешендерін таңдайды. Егер біз іріктеу жиілігін көрсетпесек, функция әдепкі 250 Гц мәнін қолданатын болады.

```
function [labelVals,labelLocs] = findQRS(x,t,parentLabelVal,parentLabelLoc,varargin)

labelVals = cell(2,1);
labelLocs = cell(2,1);

if nargin<5
    Fs = 250;
else
    Fs = varargin{1};
end

df = 20;

load("trainedQTSegmentationNetwork","net")

for kj = 1:size(x,2)

    sig = x(:,kj);

    % Кіріс формасының өзгеруі және синхронды Фурье түрлендірулерін есептеу

    potsLVQ = computeLVQ(sig,Fs);

    % Біз QRS аймақтарына қандай нүктелер жататынын болжау үшін оқытылған желіні қолданамыз

    netPreds = classify(net,potsLVQ,MiniBatchSize=50);
```

```

% QRS аймақтары үшін сигнал маскасын жасап, тізбектің ең аз ұзындығын көрсетеміз

QRS = categorical([netPreds{1} netPreds{2}],'QRS');
msk = signalMask(QRS,MinLength=df,SampleRate=Fs);
r = roimask(msk);

% Біз QRS кешендерін бізге керек аймақтар ретінде белгілейміз

labelVals{kj} = r.Value;
labelLocs{kj} = r.ROIlimits;


end

labelVals = vertcat(labelVals{:});
labelLocs = cell2mat(labelLocs);

% QRS-ті тауып, computeLVQ-ті салу үшін осында қоямыз.

end

```



2.5.5-сурет. Кардиоциклдің басын таңдау

ComputeLVQ функциясы: кіріс формасын өзгерту және синхронды Фурье түрлендірулерін есептеу.

Бұл функция оқыту векторларын кванттау (LVQ) арқылы Фурье түрлендіруін есептеу үшін fast функциясын қолданады. Deep Learning көмегімен толқын пішінін сегменттеу бөлімінде талқыланғандай, кіріс әрбір

оқыту немесе сынақ сигналының уақыт-жиілік картасы болған кезде желі жақсы жұмыс істейді. FAST нәтижесі рекурентті желілер үшін әсіресе пайдалы функциялар жинағын береді, себебі түрлендіру бастапқы кіріс ақпаратпен бірдей уақыт ажыратылымдылығына ие.

Функция енгізуді кездейсоқ сандармен толтырады және оны желі күткендей 2-ден 5000-ға дейінгі ұяшық массивіне түрлендіреді.

Тиісті жиілік ажыратылымдылығын қамтамасыз ету үшін ұзындығы 128 болатын Kaiser терезесін және $\beta=0,5$ әдепкі пішін факторын көрсетеді.

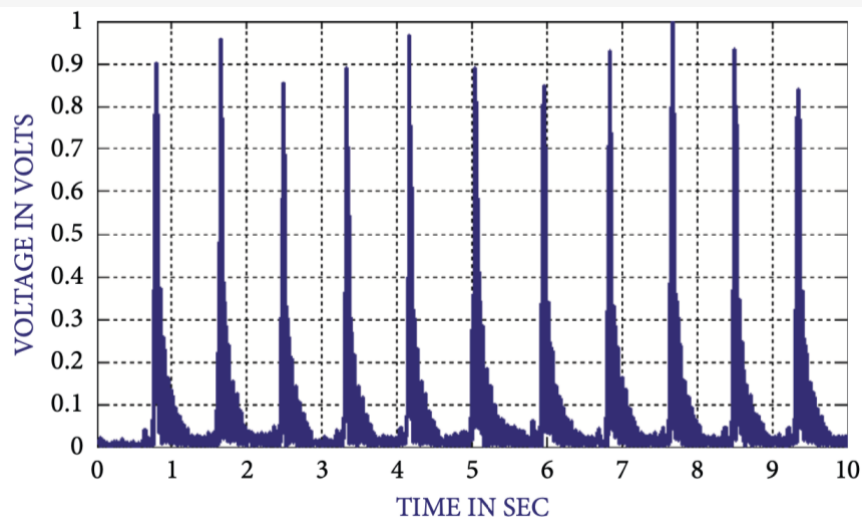
0,5Гц-тен 40Гц-ке дейінгі жиілік диапазонындағы деректерді шығарады. POST-тың нақты және елестетілген бөліктерін жеке объектілер ретінде қарастырады. Орташа мәнді алып тастау және стандартты ауытқуға бөлу арқылы деректерді қалыпқа келтіреді.

```
function signalslvq = computeLVQ(xd,Fs)

xd = reshape([xd;randn(10000-length(xd),1)/100],5000,2);
signalsLVQ = cell(1,2);

for k = 1:2
    [ss,ff] = lvq(xd(:,k),Fs,kaiser(128));
    sp = ss(ff>0.5 & ff<40,:);
    signalsLvq{k} = normalize([real(sp);imag(sp)],2);
end

end
```



2.5.6-сурет. ЭКС кіріс сигналы

findpeaks функциясы: R шыңдарын табу

Бұл функция findQRS арқылы табылған QRS қызығушылық аймақтарының ең көрнекті шыңын анықтайды. Функция MATLAB islocalmax функциясын findQRS көмегімен орналасқан сигналдың абсолютті мәніне қолданады.

```
function [labelVals,labelLocs] = findRpeaks(x,t,parentLabelVal,parentLabelLoc,varargin)
```



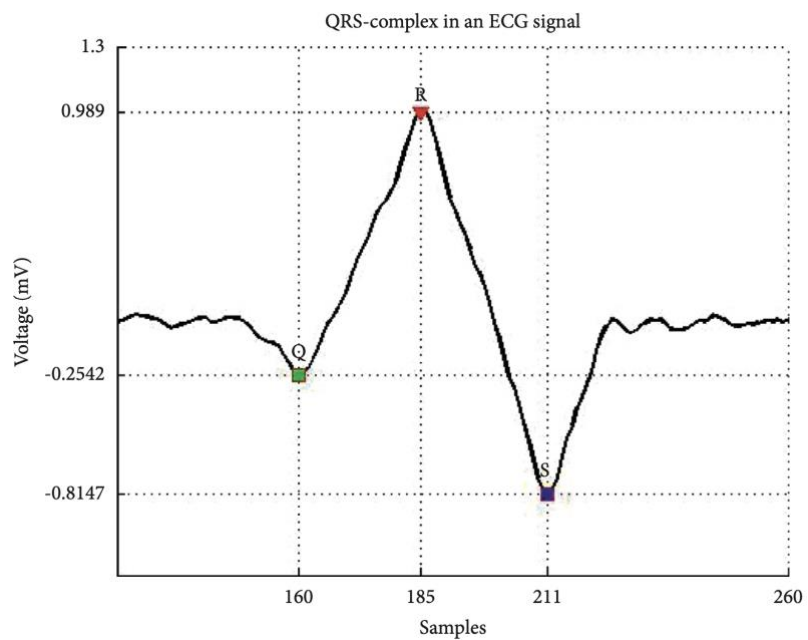
```

labelVals = zeros(size(parentLabelLoc,1),1);
labelLocs = zeros(size(parentLabelLoc,1),1);

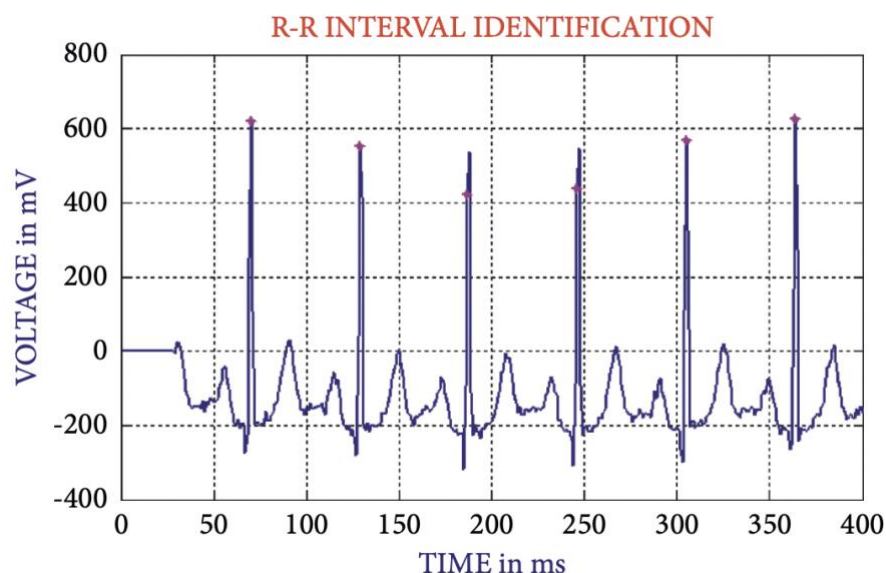
for kj = 1:size(parentLabelLoc,1)
    tvals = t>=parentLabelLoc(kj,1) & t<=parentLabelLoc(kj,2);
    ti = t(tvals);
    xi = x(tvals);
    lc = islocalmax(abs(xi),MaxNumExtrema=1);
    labelVals(kj) = xi(lc);
    labelLocs(kj) = ti(lc);
end

end
end

```



2.5.7-сурет. R-шыңының мәнін есептеу

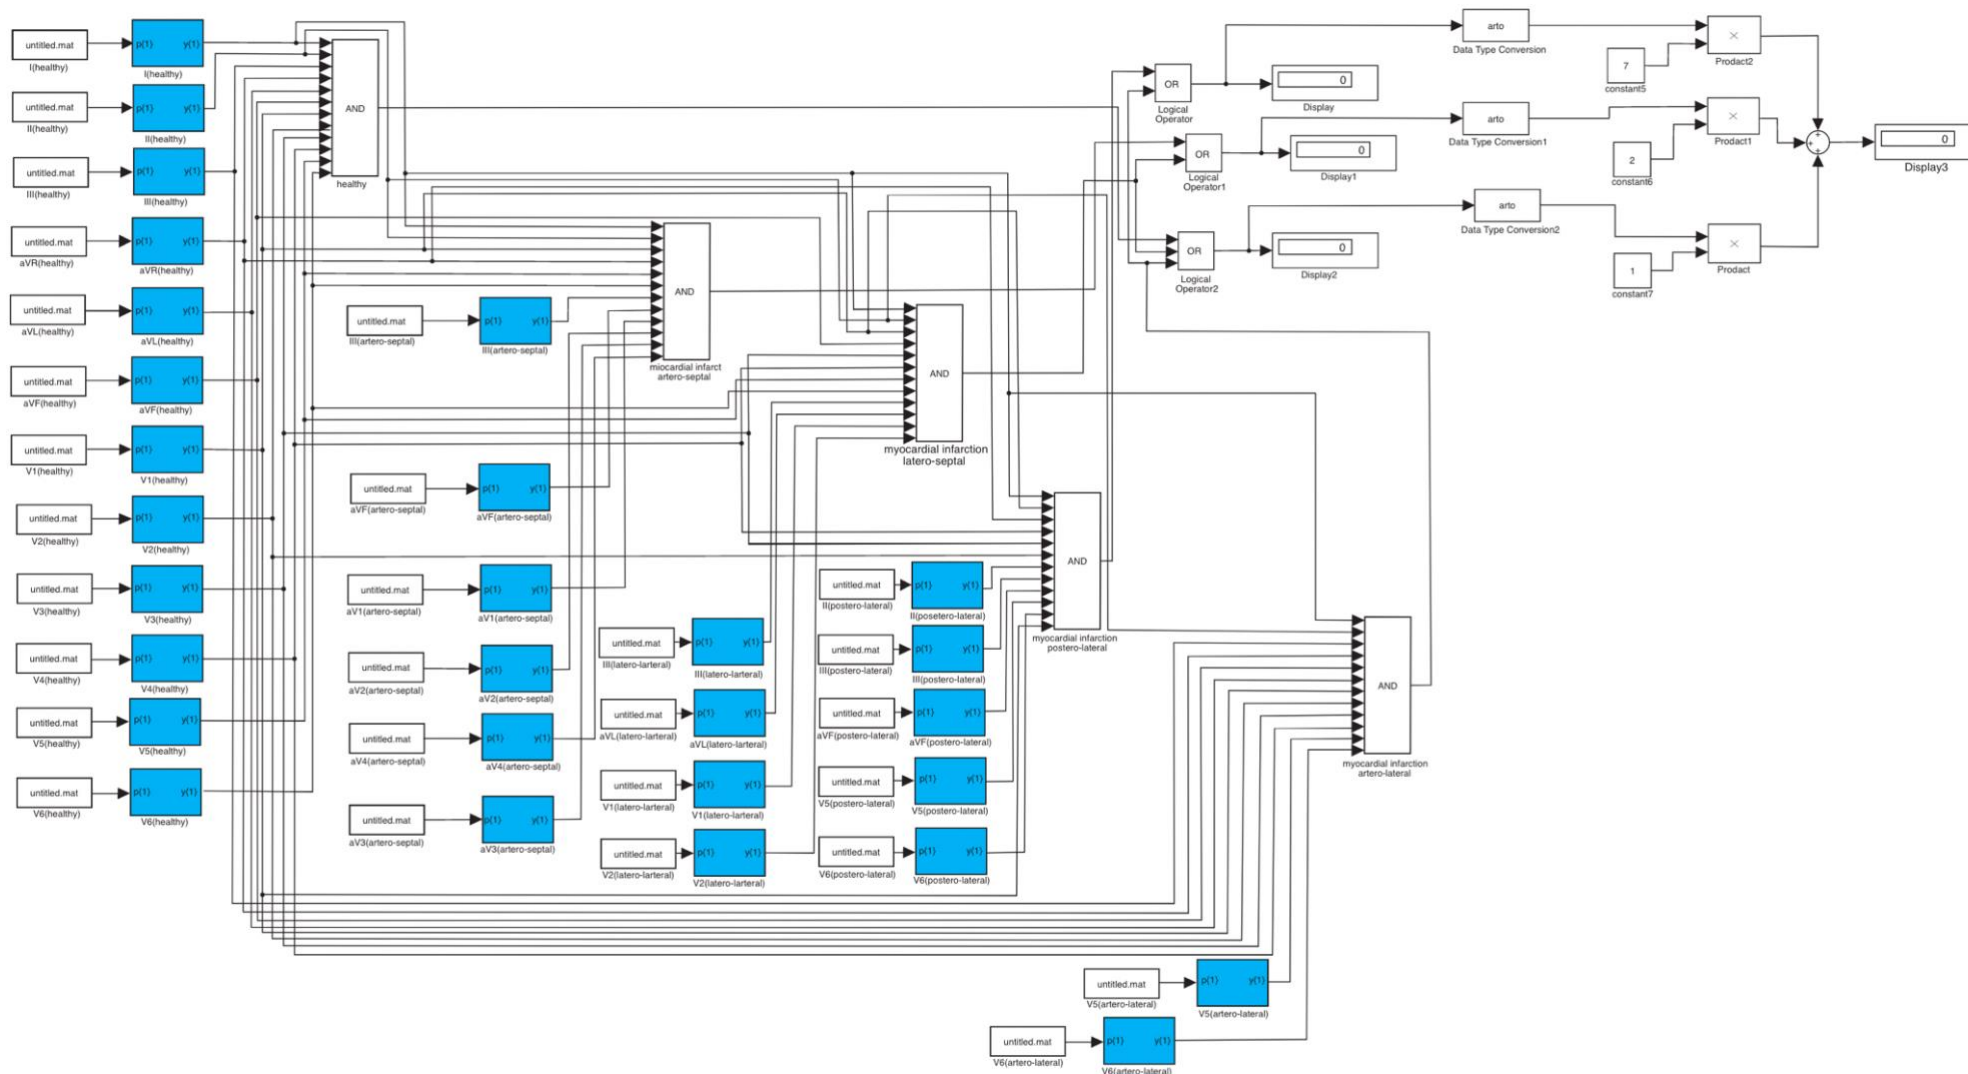


2.5.8-сурет. R-R интервалын есептеу

Шешім қабылдау принципі МИ-нің көрінетін белгісін оның анықтаушы локализациясымен корреляциялаудан тұрады. Ол үшін локализация кестесі жасалды. (2.1.1-кестені қараңыз). Нейрондық желілердің шығыс ақпараттарын талдау үшін шешуші ережелерді құру әр локализациядағы ауытқулар барлық тіркеуіштерде көрінбейтіндігіне негізделген. Миокард инфарктісіне жататын жүрек жағдайының біреуін ($k-1$) таңдаудың шешуші ережелерін құру үшін сегіз түрлі локализация үшін ЭКС-қорғасын кезінде тікелей және рецепкалық белгілердің болуы мен болмауының үйлесімі қолданылды.

Сегіз диагноз үшін логикалық блоктарды құрудың шешуші ережелері 2.4.3 – 2.4.10 формулаларында келтірілген.

Төменде 2.5-суретте Matlab ортасында Simulink графикалық редакторының көмегімен жасалған миокард инфарктісін диагностикалаудың әзірленген әдісінің схемасы келтірілген. Бұл жерде Matlab ортасында жүзеге асырылған жүректің бес жағдайына арналған ЭКС нейрожелілік талдау схемасы көрсетілген. Приоритетті шифратордың көмегімен ЭКС k нейрожелілік талдау нәтижесінде алынған нақты бес шешімдердің бірін таңдау жүзеге асырылады. Приоритетті шифратордың шығысында оң кіріс сигналы келетін кіріс нейрондық желі нөмірінің коды жасалады (ЭКС талдауына қатысатын k нейрондық желілерінің бірінің шығуының логикалық бірлік сигналы). Бір уақытта бірнеше кіріс сигналдары түскен кезде ең үлкен нөмірі бар кіріске сәйкес келетін шығыс коды жасалады, яғни үлкен кіріс сигналдары кіші кіріс сигналдарына қарағанда басым болады. Сондықтан шифратор приоритетті болып табылады.



Сурет 2.5-MathLab ортасында жүзеге асырылған жүректің бес жағдайына арналған ЭКС нейрожелілік талдау схемасы.

Бұл модельдеудің нәтижесі-талданатын ЭКС тағайындалған науқастың жүрек жағдайы туралы диагностикалық қорытындының нөмірі болып табылады.

2.5.1 Электрокардиосигналды нейрожелілік талдау әдісінің сезімталдығы мен ерекшелігін анықтау

НЖ оқыту сапасының көрсеткіштерін анықтау үшін, әр түрлі параметрлер бойынша НЖ-ны бірнеше рет оқытуды жүзеге асыратын зерттеулер жүргізді. Әрбір оқу процедурасынан кейін келесі параметрлер есептелді: ерекшелік, сезімталдық, оқу дәлдігі, оқу уақыты. Оқыту нәтижелері кестеге енгізіліп отырылды. НЖ оқыту нәтижелерінің мысалдары 2.5.1.1, 2.5.1.2 және 2.5.1.3 кестелерде келтірілген:

2.5.1.1-кесте - II тіркеуіштегі патологиялық Q-толқынын талдау үшін нейрондық желіні оқыту нәтижелері

НЕЙРОНДАР САНЫ	ЕРЕКШЕ ЛІГІ	СЕЗІМТАЛДЫ Қ	ЖАЛПЫЛАУ ҚАТЕСІ	ОҚУ УАҚЫТЫ	ОҚУ ҚАТЕЛІГІ
10		0,98	0	0,15	0
16	0,93	0,97	0	0,17	0
20	0,96	0,96	0	0,17	0
24	0,97	0,98	0	0,2	0
28	0,95	0,99	0	0,21	0
34	0,95	0,98	0	0,23	0
38	0,95	0,99	0	0,26	0
44	0,95	0,97	0	0,3	0
48	0,95	0,98	0	0,35	0
52	0,95	0,98	0	0,4	0
56	0,95	0,97	0	0,45	0

2.5.1.2-кесте – aVL тіркеуішіндегі теріс T-толқынды талдау үшін нейрондық желіні оқыту нәтижелері

НЕЙРОНДАР САНЫ	ЕРЕКШЕЛІГІ	СЕЗІМТАЛ ДЫҚ	ЖАЛПЫЛА У ҚАТЕСІ	ОҚУ УАҚЫТ Ы	ОҚУ ҚАТЕЛІГІ
10	0,99	0,99	0	0,10	0
16	0,99	0,99	0	0,12	0
20	0,99	0,99	0	0,12	0
24	0,99	0,99	0	0,12	0
28	0,99	0,99	0	0,12	0
34	0,99	0,99	0	0,13	0
38	0,99	0,99	0	0,13	0
44	0,99	0,99	0	0,13	0
48	0,99	0,99	0	0,13	0


52	0,99	0,99	0	0,14	0
56	0,99	0,99	0	0,14	0

2.5.1.3-кесте – V1 тіркеуішіндегі R толқынының жоқтығын талдау үшін нейрондық желіні оқыту нәтижелері

НЕЙРОНДА P САНЫ	ЕРЕКШЕЛІ ПІ	СЕЗІМТАЛДЫ Қ	ЖАЛПЫЛАУ ҚАТЕСІ	ОҚУ УАҚЫТЫ	ОҚУ ҚАТЕЛІ ПІ
10	0,99	0,99	0	0,09	0
16	0,99	0,99	0	0,11	0
20	0,99	0,99	0	0,11	0
24	0,99	0,99	0	0,11	0
28	0,99	0,99	0	0,11	0
34	0,99	0,99	0	0,11	0
38	0,99	0,99	0	0,12	0
44	0,99	0,99	0	0,12	0
48	0,99	0,99	0	0,12	0
52	0,99	0,99	0	0,12	0
56	0,99	0,99	0	0,12	0


Жоғарыда келтірілген кестелерді талдау сезімталдық пен ерекшеліктің орташа мәндерін сәйкесінше 97% және 98% деңгейінде көрсетеді. Бұл көрсеткіштер ЭКС-ды НЖТ белгілі әдісінен тиісінше 10 және 15% - ға асып түседі.

Ұсынылған әдістің өнімділігі CNN және FFNN сияқты дәстүрлі әдістермен салыстырылды. Максималды дәлдік әртүрлі сынақтар үшін 98,5% құрайды. Ұсынылған әдістің сенімділігі кепілді, өйткені оның тиімділігі үнемі жоғары дәрежеде. 2.5.1.1-суретте алгоритмдердің дәлділігі салыстырылған.



2.5.1.1-сурет – Дәлдікті салыстыру.

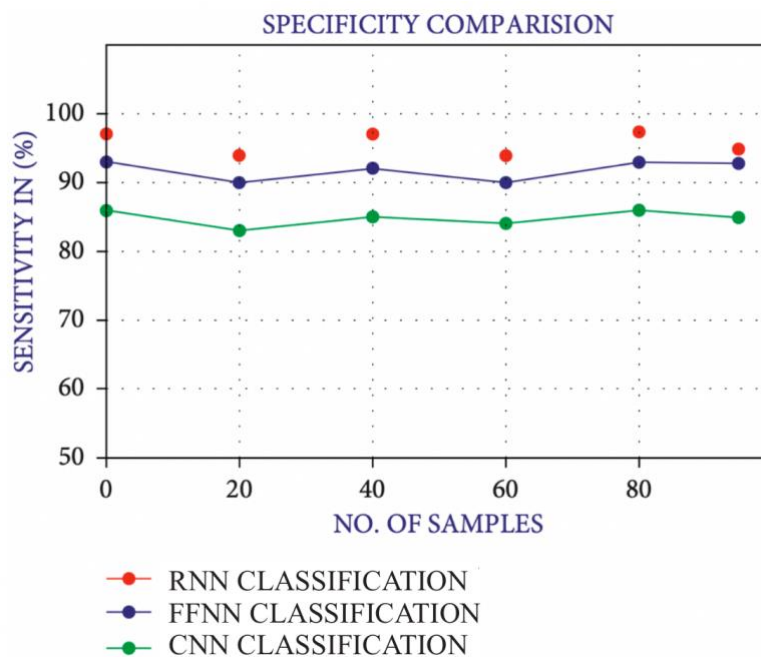
Сезімталдық классификацияның шынайы оң мәнін көрсетеді. Ол дұрыс жіктелген оң нәтижелердің пайызы ретінде есептеледі [118]. 98,3% максималды сезімталдықпен ол ағымдағы жүйеден асып түседі, ал CNN және SVM сәйкесінше 92% және 86% максималды сезімталдыққа ие. 2.5.1.2-сурет сезімталдық қатынасын көрсетеді. 2.5.1.2-суретте сезімталдықты салыстыру көрсетілген.



2.5.1.2-сурет – Сезімталдықты салыстыру.

Ұсынылатын әдіс ерекшелігінің мәндері үлгілер санының ұлғаюына қарай зигзаг түрінде өзгереді [119], ұсынылатын әдіс үшін максималды ерекшелігі 99% және CNN және FFNN жіктеуіштері үшін сәйкесінше 93% және 95,6% [120].

2.5.1.3-сурет ерекшелікті салыстыруды білдіреді. ЭКГ сигналында [121] сынып, синус ырғағы, артефакт, қарыншалық тахикардия, атриальды фибрилляция, бигеминия және т.б. R, P, S, сондай-ақ F1 тұрғысынан есептеледі. Салыстырмалы кестеден ұсынылған RNN бойынша бағалау [122] дәстүрлі әдістерге қарағанда көп екенін көруге болады.



Сурет 2.5.1.3 - Ерекшелікті салыстыру.

2.5.1.4 – кестеде желілердің дәлдігінің салыстырмалы нәтижесі көрсетілген. Ұсынылған әдісті оқытудың, тексерудің және тестілеудің тиімділігі дәстүрлі әдістермен салыстырылды.

Кесте 2.5.1.4-Желілердің дәлдігінің салыстырмалы кестесі.

Модель	Дайындық (%)	Тексеру (%)	Тест (%)
LSTM базалық деңгей	66,8	66,3	65,6
CNN	68,6	72,2	68,8
Жинақтаумен бір бағытты-LSTM	80,5	78,1	79,2
Екі бағытты жинақтаумен - LSTM	82,2	79,5	80,2
Терең қалдықты - CNN	84,7	75,3	79,3
Аралас бір бағытты LSTM-CNN	83,4	77,7	79,6
Аралас екі бағытты LSTM-CNN	93,2	74,8	76,8
Ұсынылған LVQ	99	84,4	98,5

2.5.1.5-кестеде жіктеу көрсеткіштері көрсетілген.

Кесте 2.5.1.5 - Жіктеу көрсеткіштерін салыстыру.

Rhythm Class	BDLSTM								LSTM-CNN				Proposed LVQ			
	R	P	S	ST	R	P	S	ST	R	P	S	ST	R	P	S	ST
ST depres	0,8 2	0,8 3	0,9 4	0,8 4	0,6 4	0,8 8	0,8 6	0,7 6	0,7 9	0,8 0	0,9 5	0,7 9	0,8 5	0,8 7	0,9 6	0,8 9
potologi cal Q	0,8 8	0,8 2	0,9 4	0,8 3	0,8 9	0,9 7	0,9 4	0,8 2	0,8 1	0,8 3	0,9 4	0,8 1	0,8 9	0,8 5	0,9 2	0,8 4
hihgt T	0,1 6	0,5 1	0,9 5	0,2 6	0,4 8	0,9 2	0,9 6	0,0 8	0,5 6	0,5 7	0,9 7	0,4 3	0,5 5	0,3 4	0,9 4	0,6 7

negative T	0,8 1	0,8 3	0,9 4	0,8 2	0,7 8	0,9 3	0,9 2	0,7 6	0,7 3	0,6 9	0,8 9	0,8 4	0,8 8	0,8 1	0,9 7	0,8 1
Potological R	0,7 2	0,6 5	0,8 2	0,6 7	0,8 9	0,9 8	0,9 8	0,1 6	- ,67	0,6 7	0,9 6	0,5 5	0,8 4	0,8 3	0,9 1	0,8 0
Elevation ST	0,7 8	0,7 6	0,8 8	0,7 6	0,7 8	0,9 3	0,9 3	0,8 3	0,7 9	0,7 7	0,9 2	0,7 2	0,8 1	0,8 2	0,9 5	0,8 9

ЭКС нерожелілік талдаудың ұсынылған әдісі (2.3пп) 98,5% жоғары сезімталдық пен дәлдікті қамтамасыз етеді (2.5.1.4 кесте). Салыстырмалы кестеден (2.5.1.5-кесте) ұсынылған әдіс бойынша бағалау дәстүрлі әдістерге қарағанда жоғары екенін көруге болады. Біздің әдістің оқу тиімділігі басқа әдістерге қарағанда әлдеқайда жоғары.

2.6 Екінші тараудың қорытындысы

1. МИ диагностикалау үшін ЭКС-ті өңдеуде НЖТ әдісін жетілдіруге келесі негізгі кезеңдерді қамтитын тәсіл ұсынылады: сигналды тіркеу, ЭКС-ды алдын-ала өңдеу, нейрондық желіні талдау, МИ болуы туралы шешім қабылдау.

2. МИ диагноз қою үшін электрокардиосигналды нейрожелілік талдау әдістемесі жасалды, ол ЭКС-тің ақпараттық параметрлерінің амплитудалық-уақыттық талдауына негізделген, ол ЭКС-интервалдарда өсу, кему немесе тұрақтылықты анықтауға, сыну нүктелерін, осы нүктелердегі амплитудалық мәндерді белгілеуге және анықталған аралықтардың ұзақтығын анықтауға негізделген. Бұл әдіс LVQ нейрондық желілерін қолдана отырып диагноз қоюға мүмкіндік береді.

3. ЭКС НЖТ тәсілі ұсынылды, оның айрықша ерекшелігі кардиоцикл сегменттерін талдауға арналған оқу кешенін қалыптастыруда НЖ сериялы-параллельді қосылуын пайдалану болып табылады. Бұл ретте локализацияны анықтаумен қатар МИ трансмуральдылығын немесе «тереңдігін» талдау (QRS кешенінде R-толқынының болмауы) жүргізіледі.

4. Миокард инфарктісін локализациялау белгілерін кестеге сәйкес бағалауға және шешім қабылдау нәтижесінің логикалық функциясын қолдана отырып есептеуге негізделген жүректің жағдайы туралы болжам жасау кезінде шешуші ережелер тұжырымдалды.

5. Барлық әзірленген әдістер Matlab ортасында Simulink графикалық редакторында жүзеге асырылды.

6. Ұсынылған нейрондық желіні талдау әдісі 98,5% - дан жоғары сезімталдық пен дәлдікті қамтамасыз етеді. Салыстырмалы кестеден ұсынылған әдіс бойынша бағалау дәстүрлі әдістерге қарағанда үлкен екенін көруге болады. Біздің әдісті оқытудың тиімділігі басқа әдістерге қарағанда әлдеқайда жоғары.

ҚОРЫТЫНДЫ

1. Медициналық параметрлерге корреляциялық талдау жүргізілді, оларды болжау үшін машиналық оқыту модельдері қарастырылып, талданды. Жүргізілген зерттеулер нәтижесінде әрбір әдістің тиімділігіне бағалау алынды. Ұсынылған әдістер денсаулық сақтаудың практикалық міндеттерін шешуде өзінің тиімді екенін көрсетті. Бірқатар есептеу эксперименттерінің нәтижесінде жүрек ауруларын болжау үшін машинаны оқытудың белгілі бір әдісін таңдау ғана емес, сонымен қатар оның параметрлерін, соның ішінде тестілеу алгоритмдерінің хаотикалық сипаттамаларын таңдау маңызды екендігі анықталды. Миокард инфарктісін диагностикалау үшін ЭКС-ті өңдеуде НЖТ әдісін жетілдіруге келесі негізгі кезеңдерді қамтитын тәсіл ұсынылады: сигналды тіркеу, ЭКС алдын-ала өңдеу, нейрожелілік талдау, МИ болуы туралы шешім қабылдау.

2. Электрокардиосигнал элементтерін (QRS-кешені және R-тісі) таңдау әдісі әзірленіп, ұсынылды. Ұсынылған әдіс кардиоциклдің сегменттерін талдауға негізделген, сәйкесінше, кардиоциклдің өзін оқшаулау басты міндет болып табылады. Кардиоциклді таңдау - бұл бір-бірінен кейінгі екі кардиоциклдің басталуына сәйкес келетін жұп есептерді анықтау.

7. МИ диагноз қою үшін электрокардиосигналды нейрожелілік талдау әдісі жасалды, ол ЭКС-тің ақпараттық параметрлерінің амплитудалық-уақыттық талдауына негізделген, ол ЭКС-интервалдарда өсу, кему немесе тұрақтылықты анықтауға, сыну нүктелерін, осы нүктелердегі амплитудалық мәндерді белгілеуге және анықталған аралықтардың ұзақтығын анықтауға негізделген. Бұл әдіс LVQ нейрондық желілерін қолдана отырып диагноз қоюға мүмкіндік береді.

8. ЭКС НЖТ тәсілі ұсынылды, оның айрықша ерекшелігі кардиоцикл сегменттерін талдауға арналған оқу кешенін қалыптастыруда НЖ сериялы-параллельді қосылуын пайдалану болып табылады. Бұл ретте локализацияны анықтаумен қатар МИ трансмуральдылығын немесе «тереңдігін» талдау (QRS кешенінде R-толқынының болмауы) жүргізіледі.

5. Миокард инфарктісін локализациялау белгілерін кестеге сәйкес бағалауға және шешім қабылдау нәтижесінің логикалық функциясын қолдана отырып есептеуге негізделген жүректің жағдайы туралы болжам жасау кезінде шешуші ережелер тұжырымдалды.

6. Matlab ортасында Simulink графикалық редакторында миокард инфарктісін диагностикалау үшін экс нейрондық желіні талдау әдісінің моделі жасалды.

Ұсынылған нейрожелілік талдау әдісі 98,5% - дан жоғары сезімталдық пен дәлдікті қамтамасыз етеді. Салыстырмалы кестеден ұсынылған әдіс бойынша бағалау дәстүрлі әдістерге қарағанда көп екенін көруге болады.

Біздің әдісті оқытудың тиімділігі басқа әдістерге қарағанда әлдеқайда жоғары.

ЭКС-ті талдаудың ұсынылған әдістерін кардиодиагностиканың жаңа құралдарын құрудың негізі ретінде пайдалануға болады. Миокард инфарктісін диагностикалауға арналған ЭКС нейрожелілік талдау әдістемесі жүрек жағдайының болжамды маңызды параметрлерін анықтауға және терапияны оңтайландыруға, яғни миокард зақымданған кезде оның дамуын тежеу немесе баяулату және науқастың өмір сүру сапасын сақтау мақсатында дәрілік көмектің қандай да бір әдістерін таңдау қажет болған кезде туындайтын күрделі терапиялық міндеттерді шешуге ықпал етеді. Жұмыс ережелерін іске асыру және сынау нәтижелері олардың дұрыстығын және функционалды диагностика саласындағы мәселелерді шешу үшін пайдалану мүмкіндігін растайды.

ПАЙДАЛАНЫЛҒАН ӘДЕБИЕТТЕР ТІЗІМІ

1. Use of high-sensitivity troponin for the diagnosis of acute myocardial infarction, Mueller C., Coronary artery disease, DOI 10.1097/MCA.0000000000000049, 2013
2. Main analytical characteristics of laboratory methods for the determination of cardiac troponins: a review from the historical and modern points of view, Chaulin A. M., ORVOSI HETILAP, DOI 10.1556/650.2021.32296, 2022
3. Biology of Cardiac Troponins: Emphasis on Metabolism, Chaulin A. M., BIOLOGY BASEL, DOI 10.3390/biology11030429, 2022
4. Чаулин А.М., Свечков Н.А., Волкова С.Л., Григорьева Ю.В. Диагностическая ценность сердечных тропонинов у пожилых пациентов, не страдающих инфарктом миокарда // Современные проблемы науки и образования. 2020. № 6. [Электронный ресурс]. URL: <https://science-education.ru/article/view?id=30302> (дата обращения: 18.12.2020).
5. Ярохно, Н. Н. Особенности различных кардиомаркеров в диагностике острого коронарного синдрома / Н. Н. Ярохно // Атеросклероз. – 2014. – Т. 10. – № 4. – С. 57–61.
6. Чаулин А.М. // О роле тропонинов в лабораторной диагностике инфаркта миокарда // The Scientific Heritage. 2021. №58-2.
7. Correlation of Standard ECG with 2D-Echo and Serum Troponin I in Locating the Site of Myocardial Infarction and its Extent-An Observational Study, Pandiyan T. R., Rao S., Journal of clinical and diagnostic research, DOI 10.7860/JCDR/2022/53075.16071, 2022
8. Coronary Artery and Cardiac Disease in Patients With Type 2 Myocardial Infarction: A Prospective Cohort Study, Bularga A., Hung J., Daghem M., Stewart S., CIRCULATION, DOI 10.1161/CIRCULATIONAHA.121.058542, 2022
9. CT or Invasive Coronary Angiography in Stable Chest Pain, Maurovich-Horvat P., Bossert M., Kofoed K. F., Rieckmann N., Benedek T., Donnelly P., NEW ENGLAND JOURNAL OF MEDICINE, DOI 10.1056/NEJMoa2200963, 2022
10. Positron Emission Tomography (PET) with F-18-FGA for Diagnosis of Myocardial Infarction in a Coronary Artery Ligation Model, Awasthi V., Gali H., Hedrick A. F., Molecular imaging, DOI 10.1155/2022/9147379, 2022
11. The Value of Iterative Reconstruction of Algorithm-Based Coronary Artery Computed Tomography Imaging in the Diagnosis of Old Myocardial Infarction, Guo L., Ren L., and etc., Journal of healthcare engineering, DOI 10.1155/2021/4383963, 2021
12. Radiogenomics and Artificial Intelligence Approaches Applied to Cardiac Computed Tomography Angiography and Cardiac Magnetic Resonance for Precision Medicine in Coronary Heart Disease: A Systematic Review, Infante T., Cavaliere C., Punzo B., Grimaldi V., and etc., Circulation-cardiovascular imaging, DOI 10.1161/CIRCIMAGING.121.013025, 2021

13. Echocardiography with tissue harmonic imaging in the detection of ST segment elevation myocardial infarction: Comparison with coronary angiography, Yang, L., Wu W., Wang J. F., Zhang H. Z., Zhang X. L., *Echocardiography-a journal of cardiovascular ultrasound and allied techniques*, DOI 10.1111/j.1540-8175.2006.00244.x, 2006
14. Detection of Left Ventricular Thrombus by Coronary Computed Tomography Angiography, Tehrani F., Eshaghian S., *American journal of the medical sciences*, DOI 10.1097/MAJ.0b013e3181a3dbfb, 2009
15. Acute myocardial infarction complication diagnosed by three-dimensional echocardiography, Marques J. S., Jorge C., Martins S. R., Feijao A., Diogo A. N., *European journal of echocardiography*, DOI 10.1093/ejechocard/jer002, 2011
16. Role of echocardiography in complications associated with partial or complete rupture of the myocardium in acute myocardial infarction, Bhatia A., Khalid M. A., Gal R., *Echocardiography-a journal of cardiovascular ultrasound and allied techniques*, DOI 10.1111/j.1540-8175.1999.tb00819.x, 1999
17. Contrast echocardiography for the diagnosis of left ventricular thrombus in anterior myocardial infarction, Wada H., Yasu T. and etc., *Heart and Vessels*, DOI 10.1007/s00380-013-0363-9, 2014
18. L. Sun, Y. Lu, K. Yang, et al., “ECG analysis using multiple instance learning for myocardial infarction detection”, *IEEE Transactions on Biomedical Engineering*, Vol. 59, No. 12, pp. 3348–3356, 2012.
19. Ruda MJa, Averkov OV, Golicyn SP, et al. Diagnostics and treatment of acute myocardial infarction with ST-segment elevation electrocardiogram. Clinical guidelines. Moscow; 2013. Russian (Руда М. Я., Аверков О. В., Голицын С. П., и др. Диагностика и лечение больных острым инфарктом миокарда с подъемом сегмента ST электрокардиограммы. Клинические рекомендации. Москва; 2013).
20. Ansari, N. Farzaneh, M. Duda, et al., “A review of automated methods for detection of myocardial ischemia and infarction using electrocardiogram and electronic health records”, *IEEE Reviews in Biomedical Engineering*, Vol. 10, pp. 264–298, 2017.
21. U. R. Acharya, H. Fujita, V.K. Sudarshan, et al., “Automated detection and localization of myocardial infarction using electrocardiogram: A comparative study of different leads”, *Knowledge-Based Systems*, Vol. 99, No. 9, pp. 146–156, 2016.
22. B. Liu, J. Liu, G. Wang, et al., “A novel electrocardiogram parameterization algorithm and its application in myocardial infarction detection”, *Computers in Biology and Medicine*, Vol. 61, pp. 178–184, 2015.
23. L. Sharma, R. Tripathy, S. Dandapat, et al., “Multiscale energy and eigenspace approach to detection and localization of myocardial infarction”, *IEEE Transactions on Biomedical Engineering*, Vol. 62, No. 7, pp. 1827–1837, 2015.
24. M. Hadjem, F. Naït-Abdesselam and A. Khokhar, “ST-segment and T-wave anomalies prediction in an ECG data using RUSBoost”, 2016 IEEE 18th International Conference on e-Health Networking, IEEE, pp. 1–6, 2016.

25. N. A. Bhaskar, “Performance analysis of support vector machine and neural networks in detection of myocardial infarction”, *Procedia Computer Science*, Vol. 46, pp. 20–30, 2015.
26. T. N. Sainath, A.-R. Mohamed, B. Kingsbury, et al., “Deep convolutional neural networks for LVCSR”, 2013 IEEE International Conference on Acoustics, Speech and Signal Processing, pp. 8614–8618, 2013.
27. S. Padhy and S. Dandapat, “Third-order tensor-based analysis of multilead ECG for classification of myocardial infarction”, *Biomedical Signal Processing and Control*, Vol. 31, No. 3, pp. 71–78, 2017.
28. H. Li, D. Pan, and C. P. Chen, “Intelligent prognostics for battery health monitoring using the mean entropy and relevance vector machine”, *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, Vol. 44, No. 7, pp. 851–862, 2014.
29. F. Gao, M. Wang, J. Wang, et al., “A novel separability objective function in CNN for feature extraction of SAR images”, *Chinese Journal of Electronics*, Vol. 28, No. 2, pp. 423–429, 2019.
30. A. Y. Hannun, P. Rajpurkar, M. Haghpanahi, et al., “Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network”, *Nature medicine*, Vol. 25, No. 1, pp. 65–69, 2019.
31. U. R. Acharya, H. Fujita, S. L. Oh, et al., “Application of deep convolutional neural network for automated detection of myocardial infarction using ECG signals”, *Information Sciences*, Vol. 415, pp. 190–198, 2017.
32. He Liu Y. Tan, “A novel adaptive wavelet thresholding with identical correlation shrinkage function for ECG noise removal”, *Chinese Journal of Electronics*, Vol. 27, No. 3, pp. 507–513, 2018.
33. Gabbay FH, Krantz DS, Kop WJ, et al. Triggers of myocardial ischemia during daily life in patients with coronary artery disease: Physical and mental activities, anger and smoking. *J Am Coll Cardiol*. 1996;27:585–592. [PubMed] [Google Scholar]
34. El electrocardiograma en las miocardiopatías: las innovaciones no deben hacernos prescindir del conocimiento previo, *CardiCore* 52, DOI:10.1016/j.carcor.2017.04.003, May 2017
35. Электрокардиографическое заключение и краткое описание изменений ЭКГ, М.И. Кечкер, 1993 г. - медицинская литература, книга по медицине, учебник
36. Руководство по электрокардиографии, В.Н. Орлов, 2017
37. Руководство по клинической ЭКГ, А. Б. де Луна, 1993
38. Rapid ECG Interpretation, M. Gabriel Khan, DOI:https://doi.org/10.1007/978-1-59745-408-7, 2008
39. <https://my.clevelandclinic.org/health/body/21648-heart-conduction-system#:~:text=The%20heart%20conduction%20system%20is,heart%20to%20expand%20and%20contract>.
40. Клиническая интерпретация ЭКГ. Введение в электрокардиографию, Со Кук-Суп, 2015

41. Ялымов А.А. Причины и клиническое значение ЭКГ-феномена депрессии сегмента ST / А. А. Ялымов, Г. Г. Шехян, А. М. Щикота // Consilium Medicum.- 2013.- № 5.- Режим доступа http://con-med.ru/magazines/consilium_medicum/consilium_medicum-05_2013/prichiny_i_klinicheskoe_znachenie_ekg_fenomena_depressii_segmenta_st/

42. Kukla P. Use of ischemic ECG patterns for risk stratification in intermediate-risk patients with acute PE / P. Kukla, W. F. McIntyre, K. Fijorek [et al.] // Am. J. Emerg. Med.- 2014.- Vol. 32, N 10.- P. 1248-1252.

43. Симон В. А. Метод регистрации электрокардиограмм посредством емкостной связи электродов с телом пациента / В. А. Симон, А. А. Ухов // Биотехнические, медицинские и экологические системы и комплексы. Биомедсистемы-2015. Материалы конференции. – Рязань. – 2015. – С. 314-318

44. Пат. 2383295 Российская Федерация. Способ обработки электрокардиосигнала для диагностики инфаркта миокарда / О.Н. Бодин, Д.С. Логинов, О.А. Зайцева, А.Е. Моисеев. – № 2008135937/14 ; заявл. 08.09.2008 ; опубл. 10.03.2010, Бюл. № 7.

45. Пат. 2410023 Российская Федерация. Способ выделения QRS-комплекса электрокардиосигнала / О.Н. Бодин, Л.Ю. Кривоногов, Ф.К. Рахматуллоев, Д.С. Логинов, О.А. Зайцева. – № 2009116480/14 ; заявл. 29.04.2009 ; опубл. 27.01.2011, Бюл. № 3.

46. Пат. №2195164 Российская Федерация. Способ выделения начала кардиоцикла и устройство для его реализации / А.А. Михеев. – №2001109189/14 ; заявл. 05.04.2001; опубл. 27.12.2002.

47. Пат. 2217045 Российская Федерация. Способ обработки электрокардиосигнала в динамике для диагноза инфаркта миокарда / О.М. Белоцерковский [и др.]. – №2001128049/14 ; заявл. 17.10.2001 ; опубл. 27.11.2003, Бюл. № 11.

48. Пат. 2257838 Российская Федерация. Способ диагностики состояния сердечнососудистой системы / О.Н. Бодин [и др.]. – № 2004107011/14 ; заявл. 09.03.2004 ; опубл. 10.08.2005, Бюл. № 22.

49. Introducing Machine Learning, Lawryniewicz, A and Tresp, V, 2014, PERSPECTIVES ON ONTOLOGY LEARNING 18 , pp.35-50

50. On the Integration of Machine Learning and Array Databases, Villarroya, S and Baumann, P., IEEE 36th International Conference on Data Engineering (ICDE) 2020, 2020 IEEE 36TH INTERNATIONAL CONFERENCE ON DATA ENGINEERING (ICDE 2020) , pp.1794-1797

51. Robust ECG Artifact Removal From EEG Using Continuous Wavelet Transformation and Linear Regression, Dora, C and Biswal, PK, 11th International Conference on Signal Processing and Communications (SPCOM)

52. Real-Time Baseline Wander Removal in ECG Signal Based on Weighted Local Linear Regression Smoothing, Tan, X; Chen, XX; (...); Xia, SH, IEEE International Conference on Information and Automation (ICIA)

53. Segmentation of the ECG Signal by Means of a Linear Regression Algorithm, Aspuru, J; Ochoa-Brust, A; (...); Martinez-Pelaez, R, Feb 2 2019 |SENSORS 19 (4)

54. A generalized Hosmer-Lemeshow goodness-of-fit test for multinomial logistic regression models, Fagerland, MW and Hosmer, DW, 2012, STATA JOURNAL 12 (3) , pp.447-453
55. Logistic regression when binary predictor variables are highly correlated, Barker, L and Brown, C, May 15 2001, 20 (9-10) , pp.1431-1442
56. Conditional logistic regression in cluster-specific 1: m matched treatment-control designs, He, ZL, 2018, COMMUNICATIONS IN STATISTICS-THEORY AND METHODS 47 (9) , pp.2134-2145
57. On almost unbiased ridge logistic estimator for the logistic regression model, Wu, JB and Asar, Y, Jun 2016, HACETTEPE JOURNAL OF MATHEMATICS AND STATISTICS 45 (3) , pp.989-998
58. Fast Approximate Complete-data k-nearest-neighbor Estimation, Murua, A and Wicker, N, Feb 2020, AUSTRIAN JOURNAL OF STATISTICS 49 (2) , pp.18-30
59. Quantum Algorithm for K-Nearest Neighbors Classification Based on the Categorical Tensor Network States, Ma, YZ; Song, HF and Zhang, J, Mar 2021 | Mar 2021 (Ранний доступ), 60 (3) , pp.1164-1174
60. Face Recognition Using String Grammar Fuzzy K-Nearest Neighbor, Kasemsumran, P; Auephanwiriyaikul, S and Theera-Umpon, N, 8th International Conference on Knowledge and Smart Technology (KST 206)
61. Multiple Real-valued K Nearest Neighbor Classifiers System by Feature Grouping, Hua, Q; Ji, AB and He, Q, IEEE International Conference on Systems, Man and Cybernetics
62. Fast k-Nearest Neighbor Searching in Static Objects, Lee, JM, Mar 2017, WIRELESS PERSONAL COMMUNICATIONS 93 (1) , pp.147-160
63. Computer Based Diagnosis of Some Chronic Diseases: A Medical Journey of the Last Two Decades, Malakar, S; Roy, SD; (...); Sarkar, R, Jun 2022, ARCHIVES OF COMPUTATIONAL METHODS IN ENGINEERING
64. An Improved Auto Categorical PSO with ML for Heart Disease Prediction, Dubey, AK; Sinhal, AK and Sharma, R, Jun 2022, ENGINEERING TECHNOLOGY & APPLIED SCIENCE RESEARCH 12 (3) , pp.8567-8573
65. The severity prediction of the binary and multi-class cardiovascular disease-A machine learning-based fusion approach, Kibria, HB and Matin, A, Jun 2022, COMPUTATIONAL BIOLOGY AND CHEMISTRY 98
66. Implementation of a Heart Disease Risk Prediction Model Using Machine Learning, Karthick, K; Aruna, SK; (...); Thelkar, AR, May 2 2022, COMPUTATIONAL AND MATHEMATICAL METHODS IN MEDICINE 2022
67. Machine Learning Technology-Based Heart Disease Detection Models, Nagavelli, U; Samanta, D and Chakraborty, P, Feb 27 2022, JOURNAL OF HEALTHCARE ENGINEERING 2022
68. An Effective Analytics and Performance Measurement of Different Machine Learning Algorithms for Predicting Heart Disease, Iqbal, SMHS; Jahan,

N; (...); Khatun, M, Feb 2022, INTERNATIONAL JOURNAL OF ADVANCED COMPUTER SCIENCE AND APPLICATIONS 13 (2) , pp.429-433

69. Application of ensemble machine learning algorithms on lifestyle factors and wearables for cardiovascular risk prediction Huang, WT; Ying, TW; (...); Kiong, NS, Jan 20 2022, SCIENTIFIC REPORTS 12 (1)

70. Predictive Classifier for Cardiovascular Disease Based on Stacking Model Fusion, Liu, JM; Dong, XY; (...); Tian, YH, Apr 2022, PROCESSES 10 (4)

71. Assessment of the risk factors of type II diabetes using ACO with self-regulative update function and decision trees by evaluation from Fisher's Z-transformation, Abdullah, AS, May 2022 | Mar 2022, MEDICAL & BIOLOGICAL ENGINEERING & COMPUTING 60 (5) , pp.1391-1415

72. Risk assessment of coronary heart disease based on cloud-random forest, Wang, J; Rao, CJ; (...); Xiao, XP, Mar 2022 (Ранний доступ), ARTIFICIAL INTELLIGENCE REVIEW

73. Analyzing the Performance of Machine Learning Techniques in Disease Prediction Phasinam, K; Mondal, T; (...); Shabaz, M, Mar 3 2022, JOURNAL OF FOOD QUALITY 2022

74. Development and assessment of machine learning based heart disease detection using imbalanced heart sound signal, Rath, A; Mishra, D; (...); Pal, M, Jul 2022, BIOMEDICAL SIGNAL PROCESSING AND CONTROL 76

75. Prediction and Risk Stratification of Cardiovascular Disease in Diabetic Kidney Disease Patients, Ren, JJ; Liu, DW; (...); Liu, ZS, Jun 24 2022, FRONTIERS IN CARDIOVASCULAR MEDICINE 9

76. Deciphering potential pharmacological mechanisms of Danhong injection to treat chronic stable angina based on drug response-related modules and genes, Chen, YY; Nan, JY; (...); Wang, J, Jun 12 2022, JOURNAL OF ETHNOPHARMACOLOGY 291

77. Integrated Bioinformatics Identifies FREM1 as a Diagnostic Gene Signature for Heart Failure, Jiang, CY and Jiang, WD, Jun 11 2022, APPLIED BIONICS AND BIOMECHANICS 2022

78. An Outlier Detection and Feature Ranking based Ensemble Learning for ECG Analysis Ardeti, VA; Kolluru, VR; (...); Patjoshi, RK, Jun 2022, INTERNATIONAL JOURNAL OF ADVANCED COMPUTER SCIENCE AND APPLICATIONS 13 (6) , pp.727-737

79. The Efficacy of Machine-Learning-Supported Smart System for Heart Disease Prediction, Absar, N; Das, EK; (...); Pathan, RK, Jun 2022, HEALTHCARE 10 (6)

80. An Accurate Heart Disease Prognosis Using Machine Intelligence and IoMT, Pirgazi, J; Sorkhi, AG and Mobarkeh, MI, Jul 1 2022, WIRELESS COMMUNICATIONS & MOBILE COMPUTING 2022

81. ECG Classification Using Orthogonal Matching Pursuit and Machine Learning, Smigiel, S, Jul 2022, SENSORS 22 (13)

82. Hybrid Hypercube Optimization Search Algorithm and Multilayer Perceptron Neural Network for Medical Data Classification, Tunay, M; Pashaei,

E and Pashaei, E, Mar 25 2022, COMPUTATIONAL INTELLIGENCE AND NEUROSCIENCE 2022

83. Risk Prediction of Coronary Artery Stenosis in Patients with Coronary Heart Disease Based on Logistic Regression and Artificial Neural Network, Cheng, XB; Han, WX; (...); Chen, D, Mar 19 2022, COMPUTATIONAL AND MATHEMATICAL METHODS IN MEDICINE 2022

84. Detection and classification of arrhythmia type using hybrid model of LSTM with convolutional neural network, Anbarasi, A and Ravi, T, Mar 2022, APPLIED NANOSCIENCE

85. The Comparison of Machine-Learning Methods XGBoost and LightGBM to Predict Energy Development, Nemeth, M; Borkin, D and Michalconok, G, 3rd Conference on Computational Methods in Systems and Software (CoMeSySo)

86. Comparison of Machine Learning Algorithms on Different Datasets, Uysal, E and Ozturk, A, 26th IEEE Signal Processing and Communications Applications Conference (SIU)

87. Machine learning for application in distribution grids for power quality applications Turovic, R; Stanisavljevic, A; (...); Katic, V, 20th International Symposium on Power Electronics (Ee), 2019

88. Vulnerability Assessment for Machine Learning Based Network Anomaly Detection System, Ogawa, Y; Kimura, T and Cheng, J, 7th IEEE International Conference on Consumer Electronics - Taiwan (ICCE-Taiwan)

89. Development and comparison of deep learning toolkit with other machine learning methods, Mitrofanov, A; Korotcov, A; (...); Ekins, S, 254th National Meeting and Exposition of the American-Chemical-Society (ACS) on Chemistry's Impact on the Global Economy

90. Intersections of machine learning and epidemiological methods for health services research, Rose, S, Dec 2020, INTERNATIONAL JOURNAL OF EPIDEMIOLOGY 49 (6) , pp.1763-1770

91. Comparison of Coronary Heart Disease Prediction models using various Machine Learning Algorithms, Tiwari, SK and Garg, SK, Oct 2021, JOURNAL OF ENGINEERING RESEARCH 9 , pp.32-47

92. A Comparison Study of Machine Learning Enabled Filtering Methods for Battery Management, Kohtz, S and Wang, PF, IEEE International Conference on Prognostics and Health Management (ICPHM)

93. A Comparison Study Between Deep Learning and Conventional Machine Learning on White Blood Cells Classification, Wibawa, MS, International Conference on Orange Technologies (ICOT)

94. Comparison of Preprocessors for Machine Learning in the Predictive Maintenance Domain, Kollmann, S; Estaji, A; (...); Sauter, T, IEEE 29th International Symposium on Industrial Electronics (ISIE)

95. Battery Health Prediction Using Fusion-Based Feature Selection and Machine Learning, Hu, XS; Che, YH; (...); Onori, S, Jun 2021, IEEE TRANSACTIONS ON TRANSPORTATION ELECTRIFICATION 7 (2) , pp.382-398

96. Physical Activity Change in an RCT: Comparison of Measurement Methods, Nelson, SH; Natarajan, L; (...); Kerr, J, May 2019, AMERICAN JOURNAL OF HEALTH BEHAVIOR 43 (3) , pp.543-555
97. Application of Machine Learning Methods in Mental Health Detection: A Systematic Review, Abd Rahman, R; Omar, K; (...); Al-Garadi, MA, 2020, IEEE ACCESS 8 , pp.183952-183964
98. Comparison of machine learning methods to predict udder health status based on somatic cell counts in dairy cows, Bobbo, T; Biffani, S; (...); Cassandro, M, Jul 1 2021, SCIENTIFIC REPORTS 11 (1)
99. Machine learning methods applied to triage in emergency services: A systematic review, Sanchez-Salmeron, R; Gomez-Urquiza, JL; (...); Suleiman-Martos, N, Jan 2022 | Dec 2021, INTERNATIONAL EMERGENCY NURSING 60
100. Comparing different supervised machine learning algorithms for disease prediction Uddin, S; Khan, A; (...); Moni, MA, Dec 21 2019, BMC MEDICAL INFORMATICS AND DECISION MAKING 19 (1)
101. Machine-learning Classifiers for Security in Connected Medical Devices, Gao, SD and Thamilarasu, G, 26th International Conference on Computer Communication and Networks (ICCCN)
102. A comparison of Machine Learning Methods to predict Hospital Readmission of Diabetic Patient, Cuong, LDP and Wang, D, 2021, ESTUDIOS DE ECONOMIA APLICADA 39 (4)
103. Осовский С. Нейронные сети для обработки информации / пер. с польского И.Д. Рудинского. – М.: Финансы и статистика, 2002.
104. Компьютерная диагностическая система «Кардиовид» : свидетельство о государственной регистрации программы для ЭВМ / О.Н. Бодин, Д.С. Логинов, И.О. Жулев, Е.А. Гладкова, А.В. Кузьмин, Н.Ю. Митрохина, И.В. Строкова, В.В. Прошкин. – № 2008610570 ; 31.01.2008.
105. Кечкер М.И. Руководство по клинической электрокардиографии. – М., 2000. – 395с.
106. Alimbayeva, Z.N., Alimbayev, C.A., Bayanbay, N.A., ...Bodin, O.N., Mukazhanov, Y.B. Portable ECG Monitoring System, International Journal of Advanced Computer Science and Applicationst. 2022, 13(4), стр. 64–76.
107. Zhadyra Alimbayeva, Kassymbek Ozhikenov, Oleg Bodin, Yerkat Mukazhanov, Development of measuring system for determining life-threatening cardiac arrhythmias in a patient's free activity, Eastern-European journal of enterprise technologies, Vol 1, No 9 (103) (2020), DOI: <https://doi.org/10.15587/1729-4061.2020.197079>.
108. Kasymbek A. Ozhikenov, Oleg N. Bodin, Mikhail N. Kramm, Fagim K. Rakhmatulloev, Yerkat B. Mukazhanov, System of Non-Invasive Electrocardiac Diagnostics, 20th International Conference of Young Specialists on Micro/Nanotechnologies and Electron Devices EDM 2019: Conference Proceedings, 2019, ISBN 978-1-7281-1752-2, DOI: 10.1109/EDM.2019.8823170.

109. СТО МОСЗ 91500.16.0002-2004 «Информационные системы в здравоохранении. Общие требования».
110. СТО МОСЗ 91500.16.0003-2004 «Информационные системы в здравоохранении. Общие требования к форматам обмена информацией».
111. K.A. Ozhikenov, Zh.N. Alimbayeva, O.N. Bodin, E.B. Mukazhanov, Development of the structure of a multicomponent filter based on The principle of adaptive aggregation of filters, 2018 IEEE 12th International Conference on Application of Information and Communication Technologies (AICT) DOI: 10.1109/ICAICT.2018.8747119.
112. Цветков В.Д. Сердце, «золотое сечение» и симметрия. – Пушино: ПНЦ РАН, 1997. – 170 с.
113. Ж. Н. Алимбаева, Н. А. Баянбай, К. А. Ожикенов, Гильберт-Хуанг түрленуі негізінде электрокардиограммаларды шуылға қарсы өңдеу, ВЕСТНИК КазНИТУ, №3 (139), 2020, Алматы.
114. Zh. Alimbayeva, Ch. Alimbayev, N. Bayanbay, K. Ozhikenov, O. Bodin, Application of neural networks for processing and cardio signal analysis, Неделя науки СПбПУ: материалы научной конференции с международным участием, 18–23 ноября 2019 г. Институт компьютерных наук и технологий. – СПб. : ПОЛИТЕХ-ПРЕСС, 2019. – 145 с.
115. Бодин О.Н., Логинов Д.С., Митрохина Н.Ю. Совершенствование ЭКГ анализа при определении электрической активности сердца / // Медицинская техника. – 2008. – № 3. – С. 23–26.
116. Laguna, Pablo, Raimon Jané, and Pere Caminal. "Automatic Detection of Wave Boundaries in Multilead ECG Signals: Validation with the CSE Database." Computers and Biomedical Research. Vol. 27, No. 1, 2014, pp. 45–60.
117. Moody, George B., and Roger G. Mark. "The impact of the MIT-BIH Arrhythmia Database." IEEE Engineering in Medicine and Biology Magazine. Vol. 20, No. 3, May–June 2011, pp. 45–50
118. H. Kaushik, D. Singh, M. Kaur, H. Alshazly, A. Zaguia, and H. Hamam, "Diabetic retinopathy diagnosis from fundus images using stacked generalization of deep models," IEEE Access, vol. 9, pp. 108276–108292, 2021
119. D. B. Saadi, G. Tanev, M. Flintrup et al., "Automatic real-time embedded QRS complex detection for a novel patch-type electrocardiogram recorder," IEEE Journal of Translational Engineering in Health and Medicine, vol. 59, no. 12, pp. 3348–3356, 2015.
120. C. Venkatesan, P. Karthigaikumar, A. Paul, S. Satheeskumaran, and R. Kumar, "ECG signal preprocessing and SVM classifier-based abnormality detection in remote healthcare applications," IEEE Access, vol. 6, no. 1, pp. 9767–9773, 2018
121. Y. Park, D. YunII, and S.-H. Kang, "Preprocessing method for performance enhancement in CNN-based STEMI detection from 12-lead ECG," IEEE Access, vol. 7, no. 7, pp. 99964–99977, 2019.
122. W. Zhu, X. Chen, Y. Wang, and L. Wang, "Arrhythmia recognition and classification using ECG morphology and segment feature analysis," IEEE/ACM Transactions on Computational Biology and Bioinformatics, vol. 16, no. 2, pp. 131–138, 2019.

ҚОСЫМША А

ТОВАРИЩЕСТВО С ОГРАНИЧЕННОЙ ОТВЕТСТВЕННОСТЬЮ



г. Алматы

21.09.2022

СПРАВКА

Об использовании результатов диссертационной работы Алимбаевой Жадьры Нурдаулетовны, представленной на соискание ученой степени доктора PhD на тему: «Нейросетевой анализ электрокардиосигнала для диагностики инфаркта миокарда»

Настоящей справкой удостоверяем, что ТОО «Central Asia Medical Industries» принял метод нейросетевого анализа кардиосигналов, предназначенный для диагностирования критического состояния сердца, определения наличия, локализации и стадии инфаркта миокарда, далее предоставления информации о наличии или отсутствия болезни лечащему врачу.

Предварительные испытания разработанного метода показали, что методики, предлагаемые в диссертационной работе Алимбаевой Ж.Н., позволяют повысить качество оказания медицинской помощи.

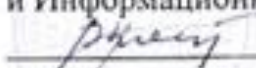
Генеральный директор



Джумагулов Н.А.

УТВЕРЖДАЮ

Директор института Автоматики
и Информационных технологий

 Ускенбаева Р.К.

“ 44 ” 09 2022г.

АКТ

Внедрения в учебный процесс института Автоматики и информационных технологий, КазНИТУ имени К.И.Сатпаева результатов диссертационного исследования Алимбаевой Жадыры Нурдаулетовны, на тему «Нейросетевой анализ электрокардиосигналов для диагностики инфаркта миокарда»

Мы, нижеподписавшиеся, Туякбаев Алтай Альшеревич, к.т.н., ассоциированный профессора и Баянбай Нурлан Амангелдіұлы, м.т.н., старший преподаватель кафедры «Робототехники и технических средств автоматики», удостоверяем факт внедрения результатов диссертационной работы Алимбаевой Жадыры Нурдаулетовны в учебный процесс кафедры «Робототехника и технические средства автоматики». Материалы исследования используются при чтении лекций и проведении практических занятий по предмету «ROB 1771-Сердечная инженерия».

Результаты диссертации обеспечивают возможность обучающимся, регистрировать, фильтровать и обрабатывать электрокардиосигналы, выделять отдельные элементы ЭКГ с применением новых способов анализа. Таким образом, повышается эффективность изучения функционирования и заболевания сердечно-сосудистой системы.

Ассоц. профессор
кафедры «Робототехники
и технических средств
автоматики», к.т.н.



Туякбаев А.А.

Старший преподаватель
кафедры «Робототехники
и технических средств
автоматики», м.т.н.



Баянбай Н.А.

РОССИЙСКАЯ ФЕДЕРАЦИЯ



ПАТЕНТ

НА ИЗОБРЕТЕНИЕ

№ 2704913

**СПОСОБ НЕЙРОСЕТЕВОГО АНАЛИЗА СОСТОЯНИЯ
СЕРДЦА**

Патентообладатель: *Федеральное государственное бюджетное
образовательное учреждение высшего образования
"Пензенский государственный университет" (ФГБОУ ВО
"Пензенский государственный университет") (RU)*

Авторы: *см. на обороте*

Заявка № 2018138788

Приоритет изобретения 02 ноября 2018 г.

Дата государственной регистрации в

Государственном реестре изобретений

Российской Федерации 31 октября 2019 г.

Срок действия исключительного права

на изобретение истекает 02 ноября 2038 г.



*Руководитель Федеральной службы
по интеллектуальной собственности*

Г.П. Ивлиев



**ЕВРАЗИЙСКАЯ ПАТЕНТНАЯ ОРГАНИЗАЦИЯ
ЕВРАЗИЙСКОЕ ПАТЕНТНОЕ ВЕДОМСТВО**

ЕВРАЗИЙСКИЙ ПАТЕНТ



ЕВРАЗИЙСКИЙ ПАТЕНТ

№ 039701

Название изобретения:

**«СПОСОБ АДАПТИВНОЙ ФИЛЬТРАЦИИ
ЭЛЕКТРОКАРДИОСИГНАЛА»**

Патентовладелец (льцы):

**НЕКОММЕРЧЕСКОЕ АКЦИОНЕРНОЕ ОБЩЕСТВО "КАЗАХСКИЙ
НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ ТЕХНИЧЕСКИЙ
УНИВЕРСИТЕТ ИМЕНИ К.И. САТПАЕВА" (KZ)**

Изобретатель (и):

**Ожикенов Касымбек Адильбекович (KZ), Бодин Олег Николаевич,
Сафронов Максим Игоревич (RU), Омарбеков Бекнур Оразгалиулы,
Ожикенова Айман Касымбековна, Алимбаев Чингиз Абдраимович,
Алимбаева Жадыра Нурдаулетовна, Баянбай Нурлан Амангелдиевич (KZ)**

Заявка №: 202191166
Дата подачи заявки: 30 апреля 2021 г.
Дата выдачи патента: 01 марта 2022 г.

Настоящим удостоверяется, что евразийский патент выдан на изобретение с формулой, опубликованной в Бюллетене Евразийского патентного ведомства «Изобретения (евразийские заявки и патенты)» № 3 / 2022 год.

При уплате установленных годовых пошлин патент действует на территории государств - участников Евразийской патентной конвенции - Азербайджанской Республики, Кыргызской Республики, Республики Армения, Республики Беларусь, Республики Казахстан, Республики Таджикистан, Российской Федерации, Туркменистана.

ИВЛИЕВ Григорий Петрович
Президент Евразийского патентного ведомства

