

Г.А. Тюлепбердинова^{1*} , Н.А. Жолдас¹ , М.Е. Мансурова¹ ,
М.М. Кунелбаев¹ , Г.А. Амирханова¹ 

¹Әл-Фараби атындағы Қазақ ұлттық университеті, Алматы қ., Қазақстан

*e-mail: tyulepberdinova@gmail.com

ФИЗИОЛОГИЯЛЫҚ ПАРАМЕТРЛЕРГЕ НЕГІЗДЕЛГЕН СТРЕССТІ БАҒАЛАУ ЖӘНЕ БОЛЖАУ ӘДІСТЕРІ

Аңдатпа

Стресс – қазіргі қоғамдағы ең өзекті мәселелердің бірі, ол адамның психикалық және физикалық денсаулығына тікелей әсер етеді. Ұзақ мерзімді немесе бақыланбаған стресс жүрек-қан тамырлары ауруларының, иммундық жүйе әлсіреуінің және еңбек өнімділігінің төмендеуінің негізгі факторларының бірі болып табылады. Осыған байланысты стрессті уақтылы анықтау және болжау маңызды ғылыми әрі практикалық міндет болып отыр. Бұл мақалада физиологиялық көрсеткіштерге негізделген стрессті болжау мәселесі қарастырылды. Зерттеу деректері арнайы жасалған құрал арқылы тіркелді, ол жүрек соғу жиілігі (HR), тыныс алу жиілігі (RR) және тері өткізгіштігі (SC) параметрлерін жинауға мүмкіндік береді. Алынған сигналдар негізінде интегралды StressIndex есептеліп, интерквартильдік процентильдерге сәйкес стресс деңгейі төрт категорияға бөлінді: Тыныш, Төмен, Қалыпты, Жоғары. Бұл деректерді пайдалана отырып, машиналық оқыту алгоритмдері – KNN, Decision Tree, Random Forest және Gradient Boosting – қолданылды. Эксперименттік нәтижелер көрсеткендей, Random Forest моделі ең жоғары нәтижеге жетіп (hold-out дәлдігі 0.900, 5-қатпарлы кросс-валидацияда орташа дәлдігі 0.805), стрессті болжауда тұрақты және сенімді әдіс болып шықты. Алынған нәтижелер wearable құрылғыларда real-time мониторинг жасауға және пайдаланушының психофизиологиялық жағдайын ерте анықтап, алдын ала ескерту жүйелерін құруға мүмкіндік береді.

Түйін сөздер: стресс, физиологиялық көрсеткіштер, StressIndex, машиналық оқыту, киілетін құрылғылар, стресс мониторингі, психофизиологиялық жағдай.

Г.А. Тюлепбердинова¹, Н.А.Жолдас¹, М.Е.Мансурова¹, М.М. Кунелбаев¹, Г.А. Амирханова¹

¹Казахский национальный университет им. Аль-Фараби, г. Алматы, Казахстан

МЕТОДЫ ОЦЕНКИ И ПРОГНОЗИРОВАНИЯ СТРЕССА НА ОСНОВЕ ФИЗИОЛОГИЧЕСКИХ ПАРАМЕТРОВ

Аннотация

Стресс-одна из самых насущных проблем современного общества, которая напрямую влияет на психическое и физическое здоровье человека. Длительный или неконтролируемый стресс является одним из основных факторов сердечно-сосудистых заболеваний, ослабления иммунной системы и снижения производительности труда. В связи с этим своевременное выявление и прогнозирование стресса становится важной научной и практической задачей. В данной статье рассмотрена проблема прогнозирования стресса на основе физиологических показателей. Данные исследования были зарегистрированы с помощью специально разработанного инструмента, который позволяет собирать параметры частоты сердечных сокращений (HR), частоты дыхания (RR) и проводимости кожи (SC). На основе полученных сигналов был рассчитан интегральный StressIndex, и в соответствии с интерквартильными процентилями уровень стресса был разделен на четыре категории: тихий, низкий, нормальный, высокий. Используя эти данные, были использованы алгоритмы машинного обучения – KNN, Decision Tree, Random Forest и Gradient Boosting. Экспериментальные результаты показали, что модель Random Forest, достигшая наивысшего результата (точность hold-out 0.900, средняя точность 5-слойной перекрестной проверки 0.805), оказалась стабильным и надежным методом прогнозирования стресса. Полученные результаты позволяют осуществлять мониторинг real-time на wearable устройствах и создавать системы раннего выявления и предупреждения психофизиологического состояния пользователя.

Ключевые слова: стресс, физиологические показатели, StressIndex, машинное обучение, носимые устройства, мониторинг стресса, психофизиологическое состояние.

G A. Tyulepberdinova¹, N.A. Zholdas¹, M.E. Mansurova¹, M.M. Kunelbayev², G.A., Amirkhanova¹

¹Al-Farabi Kazakh National University, Almaty, Kazakhstan

METHODS OF STRESS ASSESSMENT AND PREDICTION BASED ON PHYSIOLOGICAL PARAMETERS

Abstract

Stress is one of the most pressing problems of modern society, which directly affects a person's mental and physical health. Prolonged or uncontrolled stress is one of the main factors of cardiovascular diseases, weakened immune system and decreased productivity. In this regard, timely detection and prediction of stress is becoming an important scientific and practical task. This article discusses the problem of predicting stress based on physiological indicators. These studies were recorded using a specially designed instrument that allows you to collect parameters of heart rate (HR), respiratory rate (RR) and skin conduction (SC). Based on the received signals, an integral Stress Index was calculated, and according to the interquartile percentiles, the stress level was divided into four categories: quiet, low, normal, high. Using this data, machine learning algorithms such as KNN, Decision Tree, Random Forest and Gradient Boosting were used. Experimental results showed that the Random Forest model, which achieved the highest result (hold-out accuracy 0.900, average accuracy of 5-layer cross-validation 0.805), proved to be a stable and reliable method for predicting stress. The results obtained make it possible to carry out real-time monitoring on wearable devices and create systems for early detection and prevention of the user's psychophysiological condition.

Keywords: stress, physiological indicators, StressIndex, machine learning, wearable devices, stress monitoring, psychophysiological condition.

Кіріспе

XXI ғасырда қоғам дамуының басты ерекшелігі – адам денсаулығына әсер ететін психоәлеуметтік факторлардың күшеюі. Урбанизация, жоғары қарқынмен дамитын еңбек нарығы және ақпараттық жүктеменің артуы адамдардың физиологиялық және психоэмоциялық жағдайына бұрынғыдан да көбірек қысым түсіруде. Бұл құбылыстардың ішінде стресс адам өміріне тікелей және жанама әсерімен айрықша ерекшеленеді. Ғылыми әдебиеттерде стресс тек уақытша эмоциялық күй емес, ағзаның түрлі жүйелеріне ұзақ мерзімді ықпал ететін күрделі процесс ретінде қарастырылады. Созылмалы күйзеліс жүрек-қантамыр ауруларының, диабет пен семіздіктің даму ықтималдығын арттырып, когнитивтік функциялардың төмендеуіне алып келеді [1].

Дәстүрлі тәсілдер – сауалнамалар, психометриялық тестілер және дәрігердің клиникалық бақылауы – стрессті бағалауда белгілі бір рөл атқарғанымен, олардың шектеулері айқын. Субъективті жауаптарға тәуелділік, нақты уақыт деректерінің болмауы және ұзақ мерзімді мониторинг жүргізуге жарамсыздығы бұл әдістерді қазіргі қоғам сұранысына сәйкес келмейтін деңгейде қалдырады [2]. Осы себепті соңғы онжылдықта зерттеушілер физиологиялық индикаторларды объективті өлшеу әдістеріне басымдық бере бастады.

Киілетін сенсорлық құрылғылар (wearables) стресс деңгейін бағалаудың жаңа мүмкіндіктерін ұсынады. Олар жүрек соғу жиілігі, вариабелдігі (HRV), электродермальды белсенділік (EDA/GSR), тері температурасы және қозғалыс белсенділігі сияқты параметрлерді үздіксіз тіркеуге қабілетті. Бұл деректер адамның психофизиологиялық күйін жан-жақты сипаттайды және стресс динамикасын жоғары дәлдікпен қадағалауға жағдай жасайды [3]. Free-living жағдайында unobtrusive құрылғылар арқылы деректер жинаудың кең таралуы зерттеулердің нәтижелерін нақты өмірге барынша жақындатуға мүмкіндік береді [4].

Жинақталған үлкен деректерді талдау үшін машиналық оқыту (ML) әдістері кеңінен қолданылады. ML алгоритмдері дәстүрлі статистикалық әдістерге қарағанда әлдеқайда күрделі үлгілерді анықтап, адамның физиологиялық реакциялары мен стресс деңгейі арасындағы жасырын байланыстарды таба алады. Соңғы зерттеулер маңызды белгілерді дұрыс таңдау (feature selection) модель өнімділігін айтарлықтай арттыратынын көрсетті [5].

Сонымен қатар, персонализацияланған тәсілдер әрбір адамның ерекше физиологиялық реакцияларын ескеріп, жалпыламалы модельдерден гөрі сенімді нәтиже береді [6].

Бұдан бөлек, заманауи бағыттардың бірі – мультидеңгейлі классификация. ECG мен EEG сигналдарына сүйене отырып стресс деңгейін бірнеше категорияға жіктеу тәжірибесі жүргізілуде. Мұндай тәсіл стресс динамикасын тек бинарлы түрде («бар» немесе «жоқ») емес, әртүрлі деңгейде бағалауға мүмкіндік береді. Бұл өз кезегінде медициналық және психологиялық араласуларды дер кезінде жоспарлау үшін өте құнды болып табылады [7].

Жалпы алғанда, соңғы жылдардағы әдебиеттер wearable құрылғылар мен машиналық оқытуды біріктіру стресс мониторингінің болашағын айқындайтынын көрсетеді. Дегенмен, көптеген зерттеулер дайын коммерциялық құрылғыларға сүйеніп, ғылыми жаңашылдық тұрғысынан шектеулі қалып отыр. Осы олқылықты жою үшін біздің жұмысымызда арнайы жасалған құрал арқылы алынған физиологиялық деректер талданып, машиналық оқыту алгоритмдері көмегімен стресс деңгейін болжаудың жаңа тәсілі ұсынылады. Бұл бағыт дәстүрлі әдістердің кемшіліктерін еңсеріп, қолжетімді әрі нақты уақытқа бейімделген шешімдерге жол ашады.

Зерттеу әдіснамасы

Соңғы жылдары стрессті бағалау бағытында киілетін сенсорлар мен машиналық оқытуды біріктірген зерттеулер қарқынды дамып келеді. Бұл жұмыстардың басым бөлігі физиологиялық сигналдарды жинау, олардан маңызды белгілерді бөліп алу және әртүрлі алгоритмдер арқылы стресс деңгейін классификациялауға бағытталған.

Мақалада студенттер арасында жүргізілген зерттеуде ECG, тері өткізгіштігі (GSR) және тері температурасы көрсеткіштерін тіркейтін Arduino негізіндегі құрылғы қолданылды [8]. Алынған деректерді XGBoost және басқа машиналық оқыту алгоритмдері арқылы өңдеу нәтижесінде XGBoost ең жоғары көрсеткішке жетіп, 96.17% дәлдік көрсетті. Сонымен қатар, ашық WESAD және SWELL-KW деректерінде де жоғары нәтижелер алынды, бұл арзан құрылғылар арқылы тиімді модель құрудың мүмкіндігін көрсетті.

Мақалада авторлар ұзақ мерзімді стресс мониторингін студенттердің емтихан аптасы кезінде зерттеді. Киілетін сенсорлар жүрек соғу жиілігі мен тері өткізгіштігін тіркеді, ал қосымша Ecological Momentary Assessment (EMA) әдісі қолданылды [9]. Нәтижесінде дербестендірілген модельдер жалпыламалы модельдерге қарағанда анағұрлым жақсы нәтиже көрсетті. Бұл әрбір адамның физиологиялық ерекшеліктерін ескерудің маңыздылығын дәлелдеді.

Зерттеуде авторлар құлаққа тағылатын PPG құрылғысын пайдаланып, Continuous Wavelet Transform (CWT) және CNN негізіндегі әдіс ұсынды [10]. Бастапқыда модель 92% дәлдікке жетсе, ақ шу енгізілген жағдайда 96% деңгейіне жетті. Бұл тәсіл қозғалыс артефактілеріне төзімділігімен және нақты өмірлік қолданысқа бейімділігімен ерекшеленді.

Мақалада авторлар стрессті free-living жағдайында анықтау үшін IoT және машиналық оқытуды біріктірді [11]. Авторлар SMOTE әдісімен деректер теңгерімсіздігін реттеп, бірнеше классификаторды сынады. Жоғары нәтижелер алынғанымен, ground-truth белгілеудің нақтылығы мен сенсор деректерінің тұрақтылығы мәселелері ашық күйінде қалды.

Зерттеуде авторлар мейірбикелердің стрессін анықтау үшін мультимодальды deep learning моделін (MMFD-SD) ұсынды. ECG, EDA, тері температурасы және акселерометр деректері талданып, уақыттық және жиіліктік белгілерді біріктіру арқылы модель 91% дәлдік пен 0.91 F1-баллға жетті [12]. Бұл тәсіл дәстүрлі ML әдістерінен анағұрлым сенімді нәтижелер көрсетті.

Мақалада авторлар WESAD деректер жиынтығын пайдаланып, CNN негізінде стресс классификациясын жүргізді. Жалпы модельдер 99.8% дәлдікке, ал дербестендірілген модельдер 99.6% дәлдікке қол жеткізді. ECG мен EDA сигналдары стресс болжамында ең тиімді индикаторлар ретінде анықталды [13]. Дегенмен, бұл нәтижелер эксперименттік сценарийлердің ықпалымен шектелуі мүмкін.

Мақалада зерттеушілер жүрек-қантамыр жүйесіне арналған стресс тестілерін (stress ECG, stress echocardiography) интерпретациялауда машиналық оқытудың рөлін талдады [14]. Көптеген зерттеулерде ML диагностикалық сезімталдықты 96% деңгейіне дейін арттырғанымен, деректер көлемінің аздығы мен дизайн ерекшеліктері шектеулерді көрсетті.

Мақаланың авторлары әртүрлі wearable құрылғыларды салыстырып, стресс анықтау модельдерінің reproducibility (қайта қолдану мүмкіндігі) мәселесін зерттеді [15]. Empatica E4, Polar H10 және Garmin Forerunner құрылғыларынан алынған HRV және EDA деректері салыстырылды. Garmin құрылғысы жоғары дәлдік көрсеткенімен, бір құрылғыда үйретілген модельдер басқа құрылғыларға тікелей қолданғанда әлсіз нәтиже берді. Бұл аппараттық үйлесімділіктің шектеулерін ашып көрсетті.

Мақаланың авторлары жүрек соғу жиілігі (HRV) мен физикалық белсенділік көрсеткіштеріне негізделген стресс классификациясын жүргізді. CatBoost және LightGBM сияқты ML алгоритмдері қолданылып, 94–97% дәлдікке жетті. Алайда, физикалық белсенділік контекстін ескермеген жағдайда қателік арта түсті [16].

Зерттеуде авторлар TEANet атты Transpose-Enhanced Autoencoder Network архитектурасын ұсынып, BVP сигналдарына негізделген стресс мониторингін жүргізді [17]. WESAD және RUET SPML деректерінде дәлдік 92–96% аралығында болды, ал класстар теңгерімсіздігі мәселесін тиімді шешті. Мақалада Human Heterogeneity Invariant Stress Sensing (HHISS) атты тәсіл ұсынылды. Бұл домендік жалпылауға негізделген әдіс жеке адамның физиологиялық ерекшеліктерін қысқартуға бағытталды [18]. Әртүрлі контексттерде модельдің тұрақтылығы артқанымен, нақты уақыттағы тиімділігі әлі де зерттеуді қажет етеді. Мақалада авторлар лазер-доплерлік микроциркуляция (LDF) және флуоресценттік спектроскопия (FS) сенсорларын қолданып жаңа wearable деректер жиынтығын жасады [19]. LightGBM арқылы стресс, мазасыздық және депрессия деңгейлерін болжауда ROC-AUC 0.717 және PR-AUC 0.885 нәтижелері алынды. Бұл зерттеу жаңа биомаркерлерді пайдаланудың әлеуетін көрсетті, бірақ дәлдігі ECG/EDA негізіндегі модельдерден төмен болды.

Жалпылай алғанда, соңғы зерттеулер көрсеткендей, стресс мониторингінде:

- Персонализацияланған тәсілдер жалпыламалы модельдерге қарағанда тиімді;
- Мультимодальды белгілерді біріктіру (ECG, EDA, HRV, қозғалыс) классификацияның сапасын арттырады;
- Free-living жағдайындағы деректер зертханалық ортаға қарағанда күрделірек, сондықтан модельдерді бейімдеу қажет;
- Құрылғылар арасындағы үйлесімділік пен деректер сапасы үлкен мәселе болып қалып отыр;
- Жаңа архитектуралар (мысалы, TEANet, HHISS) жалпылау және теңгерімсіз деректер мәселесін шешуге жол ашуда.

Зерттеу нәтижелері

Шолу бөлімінде қарастырылған мақалалардың салыстырмасы 1-кестеде көрсетілген.

Кесте 1. Әдебиеттер бойынша салыстырмалы талдау

№	Қатысушылар / Деректер көзі	Қолданылған құрылғылар	Қолданылған әдістер	Нәтижелер (дәлдік, метрика)
[8]	≈200 үнді студенті, стресс индукциясы	Arduino негізіндегі low-cost сенсорлар (ECG, GSR, ST)	XGBoost, RF, NB (multivariate & univariate)	Acc ≈ 96.17% (multivariate), WESAD/SWELL-KW benchmark ≈ 92–94%
[9]	≈51 студент, табиғи орта (exam vs control week)	Wristband: HR, Temp, Movement + EMA сауалдары	ML классификаторлар (individualized vs group)	AUC ≈ 0.82; жеке модельдер тиімдірек

[10]	<i>n=14, зертханалық тапсырмалар</i>	<i>In-ear Plethysmography сенсоры</i>	<i>CNN (GoogLeNet) + CWT (scalogram)</i>	<i>Acc ≈ 91.02%, F1 ≈ 90.95%</i>
[11]	<i>n=240, free-living орта</i>	<i>ECG, EDA, Temp</i>	<i>RF, SVM, NB</i>	<i>Acc ≈ 98%</i>
[12]	<i>WESAD (n=15)</i>	<i>Empatica E4, Respiban</i>	<i>Multimodal DL (CNN+LSTM, time+freq features)</i>	<i>Acc ≈ 91%, F1 ≈ 0.89</i>
[13]	<i>WESAD</i>	<i>Empatica E4</i>	<i>Random Forest</i>	<i>Acc ≈ 93%</i>
[14]	<i>Systematic review (cardiac stress test)</i>	<i>ECG, Echo</i>	<i>ML, DL мәсiлдеpi (SVM, CNN, RF)</i>	<i>Әртүрлі тиімділіктерге сапалық шолу</i>
[15]	<i>n=35 студент, lab stress tasks</i>	<i>Garmin Forerunner 55s, Empatica E4, Polar H10, Biopac MP160</i>	<i>HRV+EDA, HRV-тек; LOSO cross-validation</i>	<i>Garmin AUROC ≈ 0.961; Empatica E4 HRV+EDA ≈ 0.953; HRV-тек E4 ≈ 0.905; алдын-ала оқыту моделінде AUROC ≈ 0.723</i>
[16]	<i>n≈50+, HRV dataset</i>	<i>ECG (HRV measures)</i>	<i>SVM, RF, DT</i>	<i>Acc ≈ 85–90%</i>
[17]	<i>Multisensor wearable dataset</i>	<i>ECG, EDA, Motion sensors</i>	<i>TEANet (Transpose-Enhanced Autoencoder)</i>	<i>Acc ≈ 92%</i>
[18]	<i>Stress sensing dataset</i>	<i>HRV + multimodal sensors</i>	<i>DL (Invariant model)</i>	<i>Generalization improved, нақты % берілмеген</i>
[19]	<i>n≈60, жаңа dataset</i>	<i>Laser Doppler Flowmetry, Fluorescence spectroscopy</i>	<i>ML+DL baseline models</i>	<i>Dataset жарияланды, baseline perf. берілген</i>

Бұл зерттеуде пайдаланылған деректер алдыңғы жұмыста ұсынылған арнайы құралдан алынған [20]. Құрал жүрек соғу жиілігі (HR), тыныс алу жиілігі (RR) және тері өткізгіштігі (SC) параметрлерін тіркеп, оларды сандық деректер түрінде сақтауға мүмкіндік береді. Осы деректерге шағын сенсорлық шу енгізіліп, StressIndex интегралды көрсеткіші есептелді. StressIndex интерквартильдік процентильдер бойынша төрт категорияға бөлінді: Тыныш, Төмен, Қалыпты және Жоғары. Бұл тәсіл сынып үлестірімін теңестіруге мүмкіндік берді. 80/20 бөлінісінде жүргізілген hold-out тест нәтижелері мен 5-қатпарлы кросс-валидация нәтижелері 1-суретте көрсетілген.

(Hold-out) Модельдер бойынша қысқаша салыстыру:

	Model	Accuracy	Train_s	Pred_s
1	RandomForest	0.900	0.291527	0.012936
2	GradientBoosting	0.875	0.485851	0.001673
0	KNN	0.825	0.001133	0.002365
3	DecisionTree	0.800	0.001652	0.000237

(5-fold CV) Кеңейтілген салыстыру:

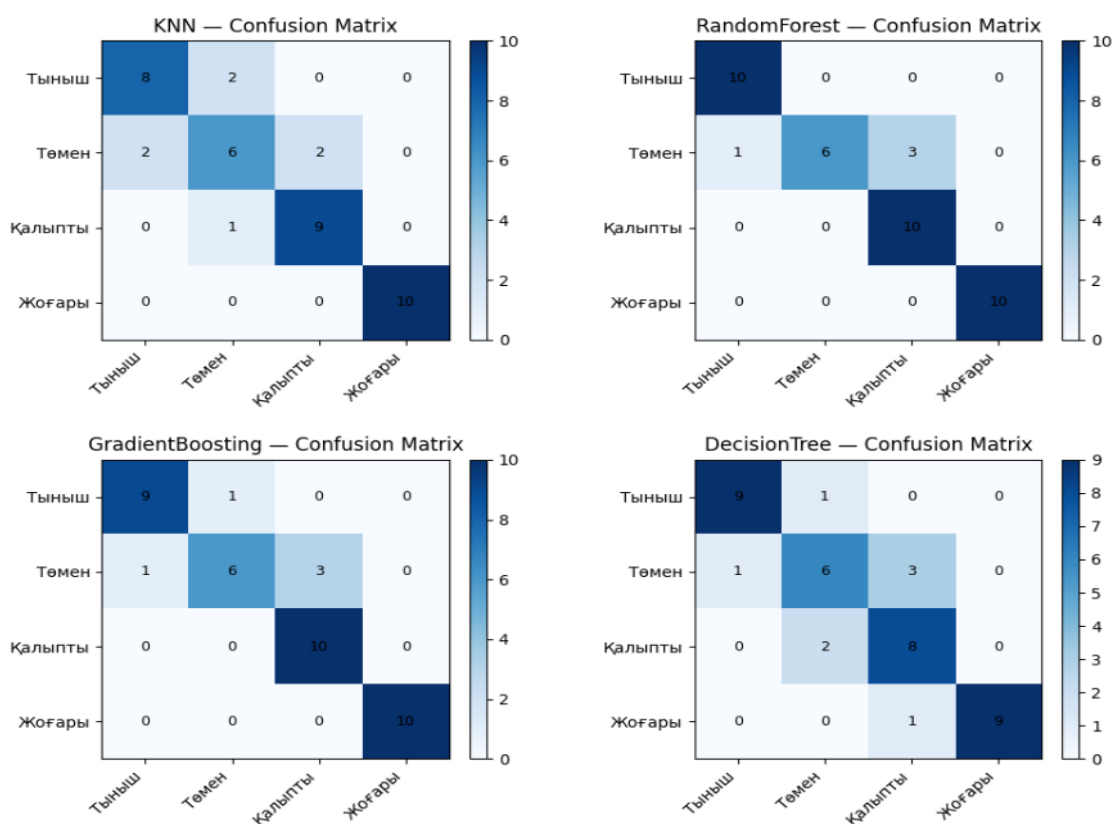
	Model	CV_Acc_Mean	CV_Acc_Std	CV_Prec_Mean	CV_Rec_Mean	CV_F1_Mean	CV_Time_s
0	KNN	0.805	0.079687	0.818170	0.805	0.803612	2.440653
1	RandomForest	0.805	0.057879	0.817675	0.805	0.805402	2.280766
2	GradientBoosting	0.795	0.076485	0.808367	0.795	0.796235	2.586860
3	DecisionTree	0.780	0.033166	0.790914	0.780	0.779615	0.055109

Сурет 1. Hold-out және 5-fold CV нәтижелері

1-суреттен көріп отырғанымыздай: Random Forest ең жоғары дәлдікке жетті (Accuracy = 0.900), Gradient Boosting – 0.875, KNN – 0.825, Decision Tree – 0.800.

Уақыт бойынша Decision Tree мен KNN ең жылдам, ал Gradient Boosting ең баяу болды. Орташа дәлдік шамамен 0.78–0.81 аралығында: KNN және Random Forest – 0.805, Gradient Boosting – 0.795, Decision Tree – 0.780. Бұл көрсеткіштер модельдердің салыстырмалы тұрақтылығын дәлелдейді.

Confusion matrix нәтижелері модельдердің әр классты ажырату қабілетін көрсетеді. RF «Тыныш» пен «Жоғары» кластарында 100% дәл нәтиже берді, бірақ «Төмен» деңгейінде қателіктер орын алды. GB мен DT модельдерінде «Төмен» мен «Қалыпты» кластарында шатасулар көбірек байқалды. Модельдердің сыныптарды қате немесе дұрыс анықтау жиілігі confusion matrix көмегімен талданды (2-сурет). Random Forest «Тыныш», «Қалыпты» және «Жоғары» сыныптарын толықтай дұрыс анықтады, тек «Төмен» күйінде аздап шатасты. KNN «Тыныш» пен «Төмен» сыныптарын жиі шатастырды. Gradient Boosting және Decision Tree де «Төмен» деңгейінде қателерге жол берді.



Сурет 2. KNN, Random Forest, Gradient Boosting және Decision Tree қателесу матрицалары

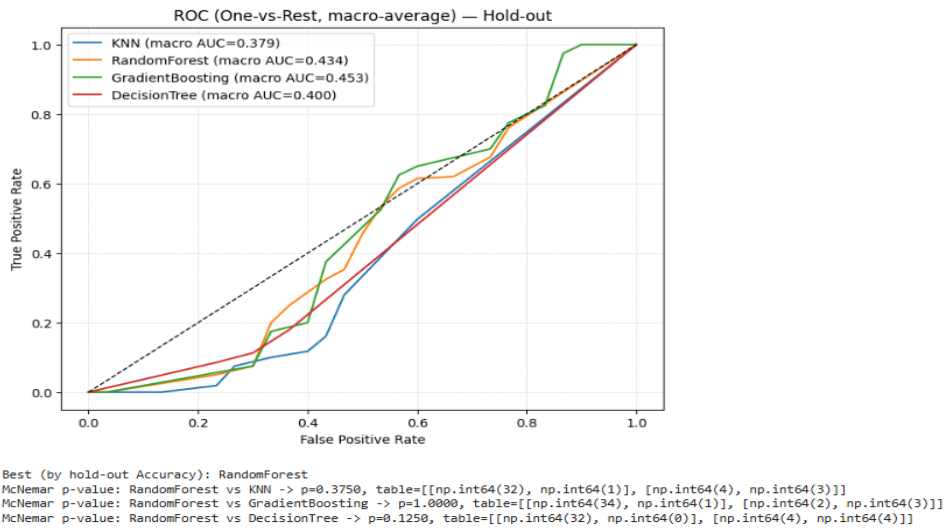
RF моделі 90% дәлдікке жетіп, WESAD деректеріндегі CNN+LSTM (Acc 0.91, F1 0.89) нәтижелерімен сәйкес келді. Free-living жағдайында алынған 98% [11] нәтижесі дерек көлемінің үлкендігімен түсіндіріледі. Ал Arduino негізіндегі жүйеде алынған 96% [8] нәтижесі көпсенсорлы комбинацияға негізделген. Бұл салыстыру біздің құралдың аз сенсорлық параметрлермен де жоғары нәтижеге қол жеткізе алатынын көрсетеді. RF моделі 90% дәлдікке жетіп, 95% CI [0.769–0.960] шегінде болды. Gradient Boosting-пен салыстырғанда айырмашылық статистикалық тұрғыдан мәнсіз ($p=1.0$), ал Decision Tree-мен салыстыруда шекті маңыздылық байқалады ($p=0.125$). Бұл RF моделінің тұрақты артықшылығын, бірақ модельдер арасындағы айырмашылықтың айқын еместігін көрсетеді.

Модельдердің берген толық метрикаларының мәндерін 2-кестеден көруге болады.

Кесте 2. Модельдердің толық метрикалары

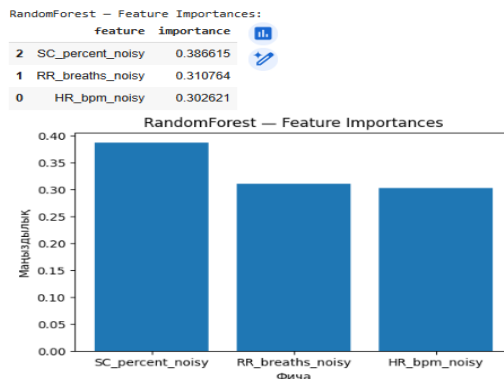
Модель	Accuracy (95% CI)	Precision (macro)	Recall (macro)	F1 (macro)
RF	0.90 [0.769–0.960]	0.920 [0.835–0.983]	0.893 [0.818–0.975]	0.893 [0.775–0.975]
GB	0.875 [0.739–0.945]	0.882 [0.769–0.975]	0.875 [0.769–0.966]	0.869 [0.746–0.966]
KNN	0.825 [0.681–0.913]	0.821 [0.699–0.934]	0.825 [0.708–0.927]	0.822 [0.696–0.925]
DT	0.80 [0.652–0.895]	0.808 [0.686–0.924]	0.808 [0.665–0.917]	0.802 [0.661–0.913]

One-vs-Rest тәсілі арқылы алынған ROC қисықтары модельдердің сыныптарды ажырату қабілетін көрсетті (3-сурет).



Сурет 3. ROC қисықтары

Gradient Boosting моделі ең жоғары макро-AUC мәніне (0.453) жетті, Random Forest – 0.434, Decision Tree – 0.400, ал KNN – 0.379 көрсетті. Бұл мәндердің барлығы орташа деңгейде болғанымен, барлық модельдер кездейсоқ классификациядан (диагональ бойынша сызық) айқын жоғары нәтиже көрсетті. ROC қисықтарының салыстырмалы талдауы бойынша Gradient Boosting моделі сыныптарды ажыратуда ең жақсы нәтижеге қол жеткізді, алайда Random Forest моделі дәлдік (Accuracy 90%) және тұрақтылық тұрғысынан озық болып шықты. Бұл ROC қисықтары мен негізгі метрикалардың бірге қарастырылуы модельдердің әртүрлі қырларын бағалауға мүмкіндік беретінін көрсетеді. Random Forest моделі бойынша feature importance талдауы (4-сурет) SC көрсеткіші ең маңызды (0.39), одан кейін тыныс алу жиілігі (0.31) және жүрек соғысы (0.30).



Сурет 4. Random Forest моделі бойынша feature importance талдауы

Бұл стресс кезінде симпатикалық жүйке жүйесінің белсенділігін бейнелейтін тері өткізгіштігінің рөлі жоғары екенін көрсетеді.

Дискуссия

Ең жоғары нәтижені Random Forest көрсетті (0.900 hold-out, 0.805 CV). Ең жылдам модель Decision Tree, бірақ дәлдігі төмен. Ең жақсы шешім – Random Forest, себебі ол дәлдігі жоғары әрі тұрақтылығы жақсы. Алынған нәтижелер көрсеткендей стресс деңгейін машиналық оқыту арқылы жоғары дәлдікпен болжауға болады. Әсіресе ансамбльдік әдістер (Random Forest, Gradient Boosting) күрделі үлгілерді тиімді үйреніп, сыныптау сенімділігін арттырады. Қателер көбіне «Төмен» және «Қалыпты» деңгейлерінде байқалды, себебі олардың физиологиялық көрсеткіштері бір-біріне жақын. Бұл болашақта қосымша көрсеткіштерді (жүрек соғу вариабельділігі – HRV, тыныс алу амплитудасы) енгізуді талап етеді. Практикалық тұрғыда бұл әдістерді real-time wearable құрылғыларға енгізу пайдаланушының стресстік жағдайын ерте анықтап, алдын ала ескерту жүйесін жасауға мүмкіндік береді.

Қорытынды

Зерттеу барысында стресс деңгейін болжау үшін арнайы жасалған құралдан алынған физиологиялық деректер (HR, RR, SC) негізінде интегралды StressIndex есептелді. Алынған деректерді машиналық оқыту алгоритмдерімен өңдеу нәтижесінде Random Forest және Gradient Boosting әдістері ең жоғары тиімділік көрсетті. Әсіресе Random Forest моделі hold-out дәлдігінде 0.900 және кросс-валидациялық орташа дәлдігінде 0.805 нәтижеге қол жеткізіп, стрессті болжауда тұрақты әрі сенімді әдіс болып шықты. Қателесу матрицаларының талдауы «Төмен» және «Қалыпты» деңгейлерін ажыратуда қиындық бар екенін көрсетті. Бұл қосымша физиологиялық параметрлерді, мысалы жүрек соғу вариабельділігін (HRV), тыныс алу амплитудасын немесе тері температурасының өзгерісін енгізудің қажеттілігін дәлелдейді. Жалпы алғанда, ұсынылған тәсіл стрессті болжаудың дәстүрлі әдістерін толықтырып қана қоймай, wearable құрылғылар арқылы нақты уақыт режимінде пайдаланушының психофизиологиялық жағдайын бақылауға мүмкіндік береді. Бұл технологияның практикалық маңызы жоғары, себебі ол ерте ескерту жүйелерін құруға және созылмалы стресс пен оған байланысты аурулардың алдын алуға жағдай жасайды.

АЛҒЫС

Бұл мақала Қазақстан Республикасы Ғылым және жоғары Білім министрлігінің қаржылық қолдауымен No. AP23488439 «Қазақстандағы студенттердің стресс мониторингі үшін IoT базасында киілетін құрылғыларды әзірлеу және енгізу» (2024-2026) жобасы аясында жүзеге асырылды.

Пайдаланылған дереккөздердің тізімі

[1] Ladakis, I., Fotopoulos, D., & Chouvarda, I. Integrative Analysis of Open Datasets for Stress Prediction // *Journal of Medical and Biological Engineering*, 2025, Vol.45, pp.385–399. <https://doi.org/10.1007/s40846-025-00958-z>

[2] Iqbal, T., Simpkin, A.J., Roshan, D., Glynn, N., Killilea, J., Walsh, J., Molloy, G., Ganly, S., Ryman, H., Coen, E., et al. Stress Monitoring Using Wearable Sensors: A Pilot Study and Stress-Predict Dataset // *Sensors*, 2022, Vol.22, 8135. <https://doi.org/10.3390/s22218135>

[3] Pinge, A., Gad, V., Jaisighani, D., Ghosh, S., & Sen, S. Detection and Monitoring of Stress Using Wearables: A Systematic Review // *Frontiers in Computer Science*, 2024, Vol.6, 1478851. <https://doi.org/10.3389/fcomp.2024.1478851>

[4] Neigel, P., Vargo, A., Tag, B., & Kise, K. Unobtrusive Stress Detection Using Wearables: Application and Challenges in a University Setting // *Frontiers in Computer Science*, 2025, Vol.7, 1575404. <https://doi.org/10.3389/fcomp.2025.1575404>

- [5] Li, Z., Xing, Y., Pi, Y., Jiang, M., & Zhang, L. A Novel Physiological Feature Selection Method for Emotional Stress Assessment Based on Emotional State Transition // *Frontiers in Neuroscience*, 2023, Vol.17, 1138091. <https://doi.org/10.3389/fnins.2023.1138091>
- [6] Bolpagni, M., Pardini, S., Dianti, M., & Gabrielli, S. Personalized Stress Detection Using Biosignals from Wearables: A Scoping Review // *Sensors*, 2024, Vol.24, 3221. <https://doi.org/10.3390/s24103221>
- [7] Hemakom, A., Atiwiwat, D., & Israsena, P. ECG and EEG Based Detection and Multilevel Classification of Stress Using Machine Learning for Specified Genders: A Preliminary Study // *PLoS ONE*, 2023, Vol.18(9), e0291070. <https://doi.org/10.1371/journal.pone.0291070>
- [8] Gedam, S., Dutta, S., & Jha, R. Analyzing Mental Stress in Indian Students Through Advanced Machine Learning and Wearable Technologies // *Scientific Reports*, 2025, Vol.15, 20610. <https://doi.org/10.1038/s41598-025-06918-6>
- [9] Tutunji, R., Kogias, N., Kapteijns, B., Krentz, M., Krause, F., Vassena, E., & Hermans, E.J. Detecting Prolonged Stress in Real Life Using Wearable Biosensors and Ecological Momentary Assessments: Naturalistic Experimental Study // *Journal of Medical Internet Research*, 2023, Vol.25, e39995. <https://doi.org/10.2196/39995>
- [10] Barki, H., & Chung, W.-Y. Mental Stress Detection Using a Wearable In-Ear Plethysmography // *Biosensors*, 2023, Vol.13, 397. <https://doi.org/10.3390/bios13030397>
- [11] Abd Al-Alim, M., Mubarak, R., Salem, N.M., & Sadek, I. A Machine-Learning Approach for Stress Detection Using Wearable Sensors in Free-Living Environments // *Computers in Biology and Medicine*, 2024, Vol.179, 108918. <https://doi.org/10.1016/j.compbiomed.2024.108918>
- [12] Xiang, J.-Z., Wang, Q.-Y., Fang, Z.-B., Esquivel, J.A., & Su, Z.-X. A Multi-Modal Deep Learning Approach for Stress Detection Using Physiological Signals: Integrating Time and Frequency Domain Features // *Frontiers in Physiology*, 2025, Vol.16, 1584299. <https://doi.org/10.3389/fphys.2025.1584299>
- [13] Calvo, A., Martin, J., & Martin, C. Early Detection of Chronic Stress Using Wearable Devices: A Machine Learning Approach with the WESAD Database // *Proceedings of the 11th International Conference on Information and Communication Technologies for Ageing Well and e-Health (ICT4AWE)*, 2025, pp.189–196. <https://doi.org/10.5220/0013209700003938>
- [14] Hadida Barzilai, D., Cohen-Shelly, M., Sorin, V., Zimlichman, E., Massalha, E., Allison, T.G., & Klang, E. Machine Learning in Cardiac Stress Test Interpretation: A Systematic Review // *European Heart Journal – Digital Health*, 2024, Vol.5(4), pp.401–408. <https://doi.org/10.1093/ehjdh/ztae027>
- [15] Amin, O.B., Mishra, V., Tapera, T., Volpe, R., & Sathyanarayana, A. Extending Stress Detection Reproducibility to Consumer Wearable Sensors // *arXiv preprint*, 2025, arXiv:2505.05694. <https://doi.org/10.48550/arXiv.2505.05694>
- [16] Singh, R., Ranjan, V., Ganguly, A., & Halder, S. Stress Classification Using Heart Rate Variability and Machine Learning Models // *Procedia Computer Science*, 2025, Vol.258, pp.4248–4256. <https://doi.org/10.1016/j.procs.2025.04.674>
- [17] Ali, M., Sarker, S.S.B., Motin, M.A., Kabir, S., Sharma, M., & Chowdhury, M. TEANet: A Transpose-Enhanced Autoencoder Network for Wearable Stress Monitoring // *arXiv preprint*, 2025, arXiv:2503.12657. <https://doi.org/10.48550/arXiv.2503.12657>
- [18] Xiao, Y., Sharma, H., Kaur, S., Bergen-Cico, D., & Salekin, A. Human Heterogeneity Invariant Stress Sensing // *arXiv preprint*, 2025, arXiv:2506.02256. <https://doi.org/10.48550/arXiv.2506.02256>
- [19] Nguyen, M., Le-Duc, K., Pham, T.-H., Nguyen, T., Luu, Q., Tran, B., Truong-Son, H., Dremin, V., Sokolovsky, S., & Rafailov, E.U. A Wearable Device Dataset for Mental Health Assessment Using Laser Doppler Flowmetry and Fluorescence Spectroscopy Sensors // *arXiv preprint*, 2025, arXiv:2502.00973. <https://doi.org/10.48550/arXiv.2502.00973>
- [20] Zholdas, N., Postolache, O., Mansurova, M., Belgibaev, B., Kunelbayev, M., & Sarsembayeva, T. Development of a Wearable Monitor to Identify Stress Levels Using Internet of Things // *Indonesian Journal of Electrical Engineering and Computer Science*, 2024, Vol.33(3), pp.1486–1499. <https://doi.org/10.11591/ijeecs.v33.i3.pp1486-1499>