



Review

Digital Psychophysiology: Integrasi AI dalam Data Perilaku, Kognitif, dan Biomedis untuk Pemantauan Kesehatan Mental

Yuli Dwi Hartanto ^{1*}, Annastasya Nabila Elsa Wulandari²

1 Program Studi Keperawatan Anestesiologi, Universitas Harapan Bangsa, Purwokerto, Indonesia

2 Program Studi Informatika, Universitas Harapan Bangsa, Purwokerto, Indonesia

* Correspondence: yulihartanto@uhb.ac.id

Abstract: Advances in digital sensor technology and artificial intelligence (AI) are expanding approaches to mental health monitoring through continuous data collection in everyday settings. Smartphones, wearable sensors, and digital monitoring systems enable the acquisition of behavioral, physiological, and cognitive data that can reflect an individual's emotional dynamics, stress levels, mood changes, and psychological state. This article presents a narrative literature review that synthesizes developments in the integration of psychophysiological data and AI in digital mental health monitoring. The review covers various data sources, including neural signals, physiological indicators from wearable sensors, behavioral patterns obtained through smartphone sensing, and psychometric indicators. The analysis also covers AI approaches for multimodal data processing, ranging from machine learning and deep learning architectures to multimodal fusion strategies. The literature indicates that integrating various modalities through AI approaches has the potential to yield a more comprehensive representation of mental state dynamics by linking biological responses, daily behavioral patterns, and cognitive indicators. Despite this potential, the development of digital mental health systems still faces challenges related to dataset limitations, the heterogeneity and synchronization of multimodal data, model generalization, as well as issues of privacy and algorithmic transparency. This synthesis positions digital psychophysiology as an integrative framework that links psychophysiological measurements, digital phenotyping, and AI-based analytics to support the development of adaptive, multimodal, and sustainable mental health monitoring systems.

Received: 19 Juli 2026

Revised: 18 Agustus 2026

Accepted: 28 Agustus 2026

Published: 30 Agustus 2026



Copyright: © 2026 by the authors.

License Universitas Harapan Bangsa, Purwokerto, Indonesia. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

Kata kunci: *digital psychophysiology; artificial intelligence; kesehatan mental; digital phenotyping; multimodal fusion;*

Pendahuluan

Gangguan kesehatan mental menjadi salah satu tantangan kesehatan global yang terus berkembang dan memberikan dampak substansial terhadap kualitas hidup individu serta produktivitas sosial ekonomi masyarakat. Kondisi seperti depresi, kecemasan, gangguan bipolar, dan risiko bunuh diri berkontribusi terhadap meningkatnya beban kesehatan mental pada berbagai kelompok populasi (Linardon et al., 2025). Berbagai instrumen klinis telah dikembangkan untuk mengevaluasi kondisi psikologis, tetapi proses asesmen masih banyak bergantung pada *self-report* dan wawancara klinis yang dilakukan secara periodik. Pendekatan memiliki keterbatasan dalam menangkap fluktuasi kondisi emosional yang bersifat dinamis dan dapat berubah selama aktivitas sehari-hari (Ringwald et al., 2025).

Perkembangan teknologi digital memperluas kemampuan pemantauan kesehatan mental secara kontinu dalam lingkungan kehidupan nyata. Perangkat seperti *smartphone*, *wearable sensors*, dan sistem pemantauan digital memungkinkan akuisisi data perilaku dan respons fisiologis secara berkelanjutan (Huang et al., 2025). Pendekatan *digital phenotyping* memanfaatkan jejak perilaku dan data sensor digital untuk mengkarakterisasi dinamika kondisi psikologis individu secara temporal dalam konteks kehidupan sehari-hari (Kadirvelu et al., 2026). Data dapat mencerminkan berbagai indikator yang relevan terhadap kondisi mental, seperti pola aktivitas, mobilitas, interaksi sosial, kualitas tidur, dan dinamika fisiologis tubuh (Yang et al., 2025).

Perkembangan *artificial intelligence* (AI) memperkuat kapasitas analitik untuk mengolah data digital yang berskala besar, heterogen, dan berdimensi tinggi. Metode *machine learning* dan *deep learning* memungkinkan identifikasi pola kompleks dalam data psikofisiologis yang berasal dari berbagai modalitas, termasuk sinyal fisiologis, perilaku digital, dan indikator kognitif (Khoo et al., 2024; Baydili et al., 2025). Integrasi antarmodalitas melalui pendekatan *multimodal learning* dan *data fusion* memungkinkan model menghubungkan informasi biologis, perilaku, dan kognitif yang sebelumnya dianalisis secara terpisah. Pendekatan menyediakan landasan analitik untuk mengkarakterisasi dinamika kondisi mental secara lebih komprehensif sekaligus mendukung pengembangan sistem pemantauan berbasis data digital (L. Wang et al., 2025).

Dalam konteks tersebut, *digital psychophysiology* dapat diposisikan sebagai kerangka interdisipliner yang mengintegrasikan aktivitas neural, respons fisiologis, perilaku digital, dan indikator kognitif melalui analitik berbasis AI (Moura et al., 2023). Kerangka memungkinkan eksplorasi hubungan antara proses biologis, aktivitas sehari-hari, dan kondisi psikologis individu pada berbagai skala temporal. Analisis multimodal dalam *digital psychophysiology* juga menyediakan peluang untuk mengidentifikasi pola psikofisiologis yang berkaitan dengan dinamika emosi dan kesehatan mental melalui integrasi informasi yang berasal dari berbagai sumber data (Aledavood et al., 2025; J. Wang et al., 2024). Perspektif ini memperluas fokus pemantauan dari indikator tunggal menuju representasi multidimensional terhadap kondisi mental individu.

Literatur mengenai pemantauan kesehatan mental berbasis data digital berkembang pesat dalam beberapa tahun terakhir (Moura et al., 2023). Meskipun mengalami perkembangan tersebut, sebagian besar publikasi masih mengevaluasi modalitas secara terpisah, seperti *smartphone sensing*, *wearable physiological signals*, atau sinyal neural (Khoo et al., 2024). Pendekatan unimodal hanya menangkap dimensi tertentu dari fenomena psikologis yang bersifat multidimensional. Fragmentasi literatur antara teknik biomedis, ilmu komputer, psikologi, dan psikiatri turut membatasi integrasi konseptual antara sumber data psikofisiologis, pendekatan komputasional, dan implikasinya terhadap pemantauan kesehatan mental (Chia & Zhang, 2022). Kesenjangan menunjukkan

kebutuhan terhadap sintesis yang menghubungkan modalitas data, metode analitik berbasis AI, dan konteks aplikasinya dalam satu kerangka *digital psychophysiology* yang terintegrasi.

Artikel ini menyajikan *narrative literature review* untuk menyintesis perkembangan *digital psychophysiology* dalam pemantauan kesehatan mental berbasis AI. Sintesis difokuskan pada karakteristik dan keterkaitan sumber data psikofisiologis, pendekatan AI untuk integrasi dan analisis multimodal, serta aplikasi dalam pemantauan kondisi mental. Kajian juga mengidentifikasi tantangan metodologis dan translasi yang berkaitan dengan heterogenitas data, generalisasi model, privasi, serta transparansi algoritmik. Melalui perspektif tersebut, *digital psychophysiology* diposisikan sebagai kerangka integratif untuk menghubungkan indikator biologis, perilaku, dan kognitif dalam pengembangan sistem pemantauan kesehatan mental yang adaptif dan berkelanjutan.

Metodologi

Desain Kajian

Pendekatan tinjauan *narrative literature review* digunakan untuk mengkaji perkembangan penerapan kecerdasan buatan (*Artificial Intelligence* atau AI) dalam integrasi data psikofisiologis untuk pemantauan kesehatan mental. Pendekatan ini dipilih karena psikofisiologi digital merupakan bidang yang relatif baru dan bersifat multidisipliner dengan mengintegrasikan teknologi sensor digital, analisis perilaku, serta metode AI dalam konteks kesehatan mental. Keragaman desain riset, jenis data, dan strategi analisis pada literatur yang tersedia membatasi penerapan tinjauan sistematis yang memerlukan prosedur metodologis lebih terstruktur dan homogen. Tinjauan naratif memberikan fleksibilitas untuk mengeksplorasi literatur secara lebih luas sekaligus menghasilkan sintesis konseptual yang komprehensif mengenai perkembangan bidang tersebut.

Analisis difokuskan pada publikasi yang memanfaatkan sinyal fisiologis, data perilaku digital, dan indikator kognitif untuk mengidentifikasi penerapan AI dalam pemantauan kesehatan mental secara berkelanjutan. Integrasi literatur dari berbagai disiplin ilmu, termasuk teknik biomedis, ilmu komputer, dan psikiatri. Analisis juga mencakup penerapan berbagai metode AI dalam mendukung deteksi, prediksi, dan pemantauan kondisi kesehatan mental melalui pengolahan beragam sumber data psikofisiologis.

Seleksi dan Analisis Literatur

Proses seleksi literatur dilakukan secara bertahap untuk mengidentifikasi publikasi yang relevan dengan fokus kajian. Penelusuran awal pada tiga basis data menghasilkan 826 artikel yang terdiri atas 369 artikel dari ScienceDirect, 387 artikel dari IEEE Xplore, dan 70 artikel dari PubMed. Penyaringan berdasarkan judul dan abstrak mengeksklusi publikasi yang tidak berkaitan dengan pemanfaatan data psikofisiologis dan metode AI. Tahap menghasilkan 43 artikel yang memenuhi kriteria relevansi awal. Evaluasi terhadap teks lengkap selanjutnya menghasilkan 39 artikel setelah empat publikasi dikeluarkan karena teks lengkap tidak dapat diakses.

Tahap akhir mencakup evaluasi konseptual terhadap fokus kajian, jenis data, dan pendekatan analitis yang digunakan pada setiap publikasi. Evaluasi menghasilkan 15 artikel yang memiliki relevansi paling kuat dalam merepresentasikan perkembangan psikofisiologi digital dan pemantauan kesehatan mental berbasis AI. Analisis terhadap artikel terpilih difokuskan pada identifikasi sumber data psikofisiologis, metode AI, serta bentuk penerapannya dalam pemantauan kesehatan mental. Hasil analisis kemudian disintesis untuk menjelaskan

keterkaitan antara karakteristik data, pendekatan teknologi, dan potensi implementasinya dalam sistem pemantauan kesehatan mental berbasis digital.

Sumber Data Psikofisiologis

Sinyal Neural dan Fisiologis

Sinyal neural dan fisiologis banyak digunakan sebagai indikator objektif dalam pemantauan kondisi mental karena respons biologis tubuh berkaitan erat dengan proses emosional dan kognitif manusia. Salah satu pendekatan yang umum digunakan ialah electroencephalography (EEG), yang merekam aktivitas listrik otak dengan resolusi temporal tinggi sehingga memungkinkan analisis dinamika respons emosional secara lebih rinci. Analisis sinyal EEG dapat mengidentifikasi pola aktivitas neural yang berkaitan dengan berbagai kondisi afektif, seperti emosi, stres, dan perubahan suasana hati (Esmi et al., 2025; Kumar & Kumar, 2025). Karakteristik juga memungkinkan pemanfaatan EEG untuk mengklasifikasikan keadaan emosional dan mengembangkan sistem pengenalan emosi berbasis kecerdasan buatan (AI).

Indikator fisiologis yang diperoleh melalui sensor perangkat yang dikenakan pada tubuh juga berperan penting dalam pemantauan kondisi mental. Perangkat memungkinkan pengukuran berbagai parameter biologis secara kontinu, termasuk variabilitas denyut jantung (*heart rate variability* atau HRV), aktivitas elektrodermal (*electrodermal activity* atau EDA), pola tidur, dan aktivitas fisik yang berkaitan dengan respons stres serta perubahan kondisi emosional (Zhan et al., 2026). HRV dan EDA dapat berfungsi sebagai biomarker fisiologis untuk mengidentifikasi tingkat stres dan dinamika emosi individu. Integrasi indikator fisiologis dengan sumber data lain, seperti perilaku digital dan indikator psikometrik, berpotensi meningkatkan validitas ekologis sistem pemantauan kesehatan mental berbasis AI. Penerapan pendekatan masih menghadapi sejumlah keterbatasan yang berkaitan dengan kenyamanan penggunaan, kebutuhan perangkat khusus, dan kondisi pengukuran yang terkendali.

Sinyal Perilaku

Perilaku digital individu dapat merefleksikan berbagai aspek kondisi psikologis yang muncul selama aktivitas sehari-hari. Pendekatan fenotipe digital (*digital phenotyping*) memanfaatkan data perilaku yang dihasilkan melalui interaksi individu dengan perangkat digital, seperti telepon pintar (*smartphone*) dan perangkat wearable. Data yang umum dianalisis mencakup pola mobilitas berbasis Global Positioning System (GPS), aktivitas fisik yang direkam menggunakan akselerometer, pola penggunaan aplikasi, dan intensitas komunikasi digital. Variasi pada pola aktivitas dapat memberikan indikasi mengenai perubahan rutinitas harian, interaksi sosial, dan tingkat keterlibatan individu dengan lingkungan sekitarnya (Nickels et al., 2021).

Analisis perilaku digital juga dapat memanfaatkan data audio dan visual yang diperoleh melalui perangkat bergerak. Ekspresi wajah, pergerakan kepala, dan karakteristik suara dapat dianalisis menggunakan *computer vision* dan *speech analysis* untuk mengidentifikasi indikator emosional serta risiko gangguan kesehatan mental (Galatzer-Levy et al., 2021). mobilitas yang diperoleh dari lokasi telepon pintar juga telah dimanfaatkan untuk membedakan pola perilaku pasien dengan *bipolar disorder* dan *unipolar depression* (Faurholt-Jepsen et al., 2022). Data perilaku digital memiliki keunggulan dalam aspek skalabilitas dan kemudahan pengumpulan pada lingkungan kehidupan nyata. Meskipun memiliki keunggulan tersebut, indikator perilaku umumnya merepresentasikan kondisi psikologis secara tidak langsung. Interpretasi yang akurat memerlukan integrasi data

perilaku dengan indikator fisiologis atau penilaian mandiri untuk memperoleh gambaran kondisi kesehatan mental yang lebih komprehensif.

Penanda Kognitif dan Psikometrik

Indikator kognitif dan psikometrik memberikan informasi subjektif mengenai kondisi psikologis yang tidak selalu dapat direpresentasikan melalui data sensor digital. Instrumen psikometrik, seperti Patient Health Questionnaire-9 (PHQ-9) dan Generalized Anxiety Disorder-7 (GAD-7), digunakan untuk mengukur tingkat keparahan gejala depresi dan kecemasan secara kuantitatif. Skor yang diperoleh melalui instrumen juga dapat digunakan sebagai label referensi (*ground truth*) dalam pelatihan model AI yang memanfaatkan data perilaku digital maupun sinyal fisiologis (Zhang et al., 2025). Pendekatan penilaian sesaat ekologis (*ecological momentary assessment* atau EMA) memungkinkan pengumpulan laporan mengenai kondisi emosional secara waktu nyata (*real-time*), sehingga perubahan suasana hati dan tingkat stres dapat diamati secara longitudinal dalam aktivitas sehari-hari (Busk et al., 2020).

Tabel 1 menunjukkan bahwa pemantauan kesehatan mental digital memanfaatkan beragam sumber data, mulai dari sinyal neural dan fisiologis hingga perilaku digital serta indikator psikometrik. Sejumlah publikasi menggunakan modalitas tunggal, sedangkan publikasi lainnya mengintegrasikan beberapa sumber data melalui pendekatan multimodal untuk memperoleh representasi kondisi mental yang lebih komprehensif. Keragaman modalitas data dan metode AI menunjukkan bahwa setiap sumber data merepresentasikan aspek psikologis dan fisiologis yang berbeda, sehingga integrasi beberapa modalitas dapat memberikan informasi yang saling melengkapi.

Tabel 1. Karakteristik publikasi yang disertakan dalam tinjauan naratif

Penulis	Target Mental	Modalitas Data	Metode AI	Peserta	Temuan Utama
Busk et al., 2020	Pemantauan Suasana Hati Bipolar	EMA pada Ponsel Pintar	Bayesian Regression	84	Data penilaian diri longitudinal memungkinkan prediksi fluktuasi suasana hati.
Sanfelici et al., 2020	Prediksi Risiko Psikosis	Data Klinis Multimodal	Machine Learning Models	>3700	Penanda biologis multimodal meningkatkan akurasi prediksi risiko psikosis.
Nickels et al., 2021	Penilaian Tingkat Keparahannya Depresi	Sensor pada Ponsel Pintar	Elastic Net	384	Ciri-ciri perilaku pengguna smartphone berkorelasi dengan tingkat keparahan depresi.
Galatzer-Levy et al., 2021	Deteksi Risiko Bunuh Diri	Data Video dan Audio	Computer Vision	20	Eksresi wajah dan karakteristik bicara menjadi indikator risiko kecenderungan bunuh diri.
Faurholt-Jepsen et al., 2022	Klasifikasi Gangguan Bipolar vs. Depresi	Data Mobilitas Ponsel Pintar	Ensemble-Based Machine Learning	140	Pola mobilitas membedakan gangguan bipolar dan depresi unipolar.
Barzilay et al., 2023	Pemantauan Risiko Bunuh Diri	Sensor pada Ponsel Pintar	Machine Learning / Deep Learning	90	Pemantauan pasif berbasis perangkat seluler mendukung pemantauan risiko bunuh diri secara berkelanjutan.
M. Song et al., 2024	Pemantauan Kondisi Emosional	Pidato, Sensor yang Dapat Dipakai, dan EMA	Multimodal Deep Learning	298	Penginderaan multimodal meningkatkan akurasi pendeteksian kondisi emosional.
Rashid et al., 2024	Pemantauan Depresi	Data Ponsel Pintar dan Perangkat yang Dapat Dipakai	Machine Learning Workflow	Kelompok Besar	Fenotip digital memungkinkan pemantauan depresi secara berkelanjutan.

Martin et al., 2024	Deteksi Stres	Sensor Fisiologis	Machine Learning Models	100	Sinyal fisiologis merekam pola respons terhadap stres.
S. Song et al., 2024	Pemantauan Depresi pada Lansia	Data Ponsel Pintar dan Perangkat yang Dapat Dipakai	Multilevel Statistical Modeling	25	Fragmentasi tidur dan efisiensi tidur dapat memprediksi gejala depresi pada hari berikutnya.
Xia et al., 2025	Prediksi Gejala Depresi	Sistem Sensor pada Ponsel Pintar dan EMA	SVM dan AdaBoost	104	Data penginderaan perilaku dapat memprediksi gejala depresi.
Esmi et al., 2025	Pengenalan Emosi	Sinyal EEG dan Gerakan Mata	Change	20	Sinyal saraf multimodal meningkatkan akurasi pengenalan emosi.
Kumar & Kumar, 2025	Pengenalan Emosi	Sinyal EEG	BiLSTM	Beberapa Kumpulan Data	Model pembelajaran mendalam mengklasifikasikan pola emosi dalam sinyal EEG.
Zhang et al., 2025	Deteksi Depresi dan Kecemasan	Sensor yang Dapat Dipakai dan Berbasis Perangkat Seluler	XGBoost	10.129	Fenotip digital berskala besar mengidentifikasi indikator kesehatan mental.
Zhan et al., 2026	Prediksi Gangguan Depresi Mayor	Data Ponsel Pintar dan Perangkat yang Dapat Dipakai	Random Forest	183	Penanda biologis digital multimodal dapat memprediksi respons terhadap pengobatan.

Berdasarkan karakteristik data pada berbagai publikasi tersebut, sumber data dalam sistem pemantauan kesehatan mental digital dapat diklasifikasikan ke dalam beberapa kategori utama yang mencakup sinyal neural, indikator fisiologis, perilaku digital berbasis telepon pintar, pola mobilitas, sinyal audio dan visual, serta indikator psikometrik. Klasifikasi menggambarkan keterkaitan antara modalitas data, teknologi sensor atau sumber pengukuran, dan penerapannya dalam analisis kesehatan mental. Ringkasan kategori modalitas data psikofisiologis disajikan pada Tabel 2.

Tabel 2. Modalitas Data Psikofisiologis

Modalitas Data	Sensor / Sumber	Aplikasi Kesehatan Mental
Sinyal Saraf	Headset EEG	Pengenalan Emosi
Sinyal Fisiologis	HRV, EDA Perangkat Kenakan	Deteksi Stres
Pemantauan Perilaku Pengguna Smartphone	GPS, Penggunaan Ponsel	Pemantauan Depresi
Pola Mobilitas	Lokasi Ponsel Pintar	Pemantauan Gangguan Bipolar
Sinyal Audio/Visual	Pidato, Analisis Wajah	Deteksi Risiko Bunuh Diri
Penilaian Psikometrik	EMA, PHQ-9, GAD-7	Pemantauan Suasana Hati

Kecerdasan Buatan untuk Integrasi Multimodal

Pendekatan *Machine Learning*

Pendekatan machine learning banyak diterapkan dalam analisis kesehatan mental berbasis data digital karena mampu memodelkan hubungan antara karakteristik perilaku, indikator fisiologis, dan kondisi psikologis individu (L. Wang et al., 2025). Berbagai algoritma, seperti *Support Vector Machine* (SVM), *Random Forest*, *XGBoost*, *Elastic Net*, dan regresi logistik, digunakan untuk melakukan klasifikasi maupun prediksi kondisi mental berdasarkan data sensor dan perilaku digital (Khoo et al., 2024). Algoritma mempelajari hubungan antara fitur yang diekstraksi dari data psikofisiologis dan label kondisi mental yang diperoleh melalui instrumen psikometrik atau evaluasi klinis (Nickels et al., 2021).

Model machine learning juga banyak digunakan untuk menganalisis data penginderaan telepon pintar (*smartphone sensing*) dan perangkat wearable. Variabel yang mencakup pola mobilitas, aktivitas fisik, dan interaksi digital dapat digunakan sebagai fitur prediktor dalam model klasifikasi kondisi mental. Pemanfaatan variabel memungkinkan model mengidentifikasi pola perilaku yang berkaitan dengan gangguan suasana hati dan perubahan aktivitas sehari-hari (Faurholt-Jepsen et al., 2022). Metode *ensemble*, seperti *Random Forest* dan algoritma *boosting*, juga digunakan untuk meningkatkan stabilitas prediksi dalam analisis biomarker digital yang mengintegrasikan data telepon pintar dan sensor *wearable* (Zhan et al., 2026). Algoritma *machine learning* konvensional tetap banyak digunakan dalam analisis kesehatan mental digital karena sejumlah himpunan data memiliki ukuran sampel yang relatif kecil dan karakteristik fitur yang heterogen. Model yang memiliki tingkat interpretabilitas relatif tinggi, seperti regresi logistik, SVM, dan metode *ensemble*, memberikan keunggulan dalam aspek stabilitas model dan efisiensi komputasi. Karakteristik juga mendukung identifikasi kontribusi fitur yang berkaitan dengan kondisi mental individu secara lebih terukur.

Arsitektur Deep Learning untuk Data Psikofisiologis

Model deep learning semakin banyak diterapkan dalam analisis data psikofisiologis karena mampu memproses data berdimensi tinggi dan memiliki struktur kompleks secara efektif (NI, 2025). Pendekatan memungkinkan model mempelajari representasi fitur secara otomatis tanpa bergantung sepenuhnya pada proses rekayasa fitur secara manual. Arsitektur *Convolutional Neural Network* (CNN) dan *Long Short-Term Memory* (LSTM) digunakan untuk menganalisis data dengan karakteristik spasial dan temporal, termasuk sinyal fisiologis, data audio, dan citra ekspresi wajah. Arsitektur *Bidirectional Long Short-Term Memory* (BiLSTM) juga digunakan dalam analisis data deret waktu (*time-series*) untuk menangkap dependensi temporal pada sinyal fisiologis dan neural.

Perkembangan metode analitik menunjukkan peningkatan pemanfaatan model berbasis *Transformer* dalam pengolahan data multimodal. Mekanisme *attention* memungkinkan model mempelajari hubungan antar fitur yang berasal dari berbagai sumber data secara simultan. Kemampuan mendukung pemodelan hubungan nonlinier yang kompleks pada data psikofisiologis. Penerapan *deep learning* tetap memerlukan jumlah data yang memadai dan sumber daya komputasi yang relatif tinggi untuk mendukung proses pelatihan model. Ringkasan metode AI yang digunakan dalam pemantauan kesehatan mental digital disajikan pada Tabel 3. Tabel menunjukkan keterkaitan antara modalitas data, pendekatan analitik, bentuk penerapan, keunggulan, dan keterbatasan setiap metode.

Karakteristik data psikofisiologis memengaruhi pemilihan metode AI yang digunakan dalam proses analisis. Himpunan data yang berasal dari *smartphone sensing* dan perangkat *wearable* sering memiliki ukuran sampel relatif kecil dengan struktur fitur yang heterogen. Karakteristik mendukung penggunaan algoritma *machine learning* konvensional, seperti regresi logistik, SVM, dan *Random Forest*, karena metode dapat memberikan stabilitas model dan tingkat interpretabilitas yang memadai. Pendekatan juga memungkinkan identifikasi hubungan antara fitur perilaku digital dan kondisi psikologis secara lebih transparan pada analisis dengan jumlah partisipan terbatas.


Data biosinyal, seperti EEG dan sinyal fisiologis, serta data audio dan citra ekspresi wajah memiliki dimensi tinggi dengan pola temporal maupun spasial yang kompleks. Penerapan pendekatan *deep learning*, seperti CNN, LSTM, dan model berbasis *Transformer*, yang mampu mempelajari hubungan nonlinier pada data multimodal. Perkembangan arsitektur multimodal juga mendorong pemanfaatan *multimodal Transformer* dengan mekanisme *attention* untuk mempelajari hubungan lintas modalitas secara simultan. Integrasi sinyal fisiologis, perilaku digital, dan indikator kognitif ke dalam satu kerangka analitik terpadu.

Tabel 3. Metode Kecerdasan Buatan yang Digunakan dalam Pemantauan Kesehatan Mental

Metode AI	Modalitas Data	Aplikasi Umum	Kekuatan	Batasan	Penelitian
SVM	Data perilaku pengguna ponsel pintar, EMA	Prediksi gejala depresi	Efektif untuk kumpulan data kecil dan ruang fitur berdimensi tinggi	Kemampuan yang terbatas dalam memodelkan hubungan nonlinier yang kompleks	(Xia et al., 2025)
Model Jaringan Elastis / Regresi	Fitur sensor ponsel pintar	Prediksi tingkat keparahan depresi	Model yang dapat diinterpretasikan dan cocok untuk seleksi fitur	Kemampuan yang terbatas dalam mendeteksi pola temporal yang kompleks	(Nickels et al., 2021)
Random Forest / Pembelajaran Mesin Ensemble	Sinyal fisiologis dan data sensor yang dapat dikenakan	Deteksi stres dan klasifikasi suasana hati	Tahan terhadap data sensor yang berisik dan cocok untuk fitur-fitur yang heterogen	Berkurangnya keterbacaan dalam model ensemble berskala besar	(Faurholt-Jepsen et al., 2022 ; Martin et al., 2024 ; Zhang et al., 2025)
Gradient Boosting (XGBoost)	Fitur perilaku pada ponsel pintar	Prediksi risiko kesehatan mental	Akurasi prediksi yang tinggi dan estimasi tingkat kepentingan fitur	Rentan terhadap penyesuaian hiperparameter	(Zhang et al., 2025)
Model Bayesian	EMA dan penilaian yang dilaporkan sendiri	Pemodelan dan prediksi kondisi suasana hati	Cocok untuk pemodelan probabilistik dinamika suasana hati	Skalabilitas yang terbatas untuk kumpulan data multimodal berskala besar	(Busk et al., 2020)
CNN	Sinyal EEG, gambar wajah	Pengenalan emosi	Kemampuan ekstraksi fitur spasial yang kuat	Membutuhkan kumpulan data pelatihan yang besar	(Galatzer-Levy et al., 2021 ; Esmi et al., 2025)
LSTM / BiLSTM	Data deret waktu fisiologis	Pemantauan suasana hati dan stres	Mendeteksi ketergantungan temporal dalam sinyal fisiologis berurutan	Membutuhkan daya komputasi yang tinggi dan waktu pelatihan yang lebih lama	(Kumar & Kumar, 2025)
Multimodal Deep Learning	Pidato, sensor yang dapat dikenakan, EMA	Pemantauan kondisi emosional	Memungkinkan integrasi berbagai jenis sensor	Kompleksitas komputasi yang tinggi dan kebutuhan data yang besar	(Barzilay et al., 2023 ; M. Song et al., 2024)
Multimodal Machine Learning Workflow	Data sensor ponsel pintar dan perangkat yang dapat dikenakan	Pemantauan kesehatan mental secara berkelanjutan	Mengintegrasikan rekayasa fitur dengan pemodelan prediktif	Membutuhkan pemrosesan awal data dan sinkronisasi yang rumit	(Sanfelici et al., 2020 ;Rashid et al., 2024 ; S. Song et al., 2024)

Metode Fusi Multimodal

Integrasi berbagai sumber data psikofisiologis memerlukan pendekatan analitik yang mampu menggabungkan informasi dari modalitas dengan karakteristik berbeda. Sinyal neural, indikator fisiologis, perilaku digital, dan indikator kognitif memiliki perbedaan dalam struktur data, frekuensi pengambilan sampel, dan tingkat reliabilitas. Pendekatan fusi multimodal (*multimodal fusion*) memungkinkan model AI mengintegrasikan informasi untuk membentuk representasi kondisi mental yang lebih komprehensif (R & Pushpalatha, 2025). Integrasi data multimodal telah diterapkan dalam pemantauan kesehatan mental digital untuk mendukung deteksi kondisi emosional dan gangguan psikologis melalui pemanfaatan berbagai sumber data sensor (M. Song et al., 2024; Rashid et al., 2024).



Gambar 1. Alur konseptual kecerdasan buatan multimodal untuk integrasi data psikofisiologis dalam pemantauan kesehatan mental digital.

Literatur mengenai *multimodal machine learning* umumnya mengelompokkan strategi integrasi data ke dalam tiga pendekatan utama, yaitu fusi awal (*early fusion*), fusi akhir (*late fusion*), dan fusi hibrida (*hybrid fusion*) (Deeksha & Firdose, 2025). Fusi awal menggabungkan fitur dari berbagai sumber data sebelum proses pemodelan, sehingga model dapat mempelajari hubungan lintas modalitas melalui satu representasi fitur yang terintegrasi. Pendekatan dapat diterapkan pada sistem yang mengintegrasikan data sensor *wearable*, *smartphone sensing*, dan indikator psikometrik untuk menganalisis kondisi mental (Zhang et al., 2025; Zhan et al., 2026). Fusi akhir memproses setiap modalitas secara terpisah menggunakan model yang sesuai dengan karakteristik masing-masing data. Hasil prediksi dari setiap model selanjutnya digabungkan melalui mekanisme agregasi, seperti *voting* atau *ensemble learning*. Strategi memungkinkan setiap modalitas diproses secara independen sebelum informasi pada tingkat keputusan diintegrasikan (Barzilay et al., 2023). Kerangka konseptual integrasi data multimodal dalam sistem psikofisiologi digital disajikan pada Gambar 1.

Fusi hibrida mengombinasikan integrasi fitur pada tahap awal dengan penggabungan keluaran model pada tahap akhir dalam satu arsitektur analitik. Pendekatan dapat digunakan untuk memproses data heterogen yang mencakup sinyal fisiologis, perilaku digital, dan sinyal neural. Integrasi lintas modalitas memungkinkan model mempelajari keterkaitan antara respons biologis, aktivitas sehari-hari, dan dinamika kondisi emosional individu. Penggabungan sinyal neural dengan modalitas sensor lainnya juga menunjukkan potensi untuk meningkatkan kinerja model dalam pengenalan emosi dan analisis kondisi mental (Esmi et al., 2025). Strategi fusi multimodal berperan dalam menghubungkan informasi yang berasal dari berbagai sumber data psikofisiologis ke dalam kerangka analitik berbasis AI. Pemilihan strategi fusi perlu mempertimbangkan karakteristik setiap modalitas, tingkat sinkronisasi data, struktur fitur, serta kebutuhan komputasi model. Integrasi yang sesuai dapat mendukung pembentukan representasi kondisi mental yang menggabungkan aspek neural, fisiologis, perilaku, dan kognitif dalam sistem psikofisiologi digital.

Penerapan dalam Pemantauan Kesehatan Mental

Pemantauan Kondisi Mental secara Berkelanjutan

Pemantauan kondisi mental secara berkelanjutan menjadi salah satu penerapan utama pendekatan psikofisiologi digital. Sistem berbasis sensor digital memungkinkan pengumpulan data fisiologis dan perilaku secara pasif melalui perangkat, seperti *smartphone* dan *sensor wearable*. Data yang diperoleh mencakup berbagai indikator aktivitas sehari-hari, seperti pola mobilitas, aktivitas fisik, dan penggunaan perangkat digital. Informasi dapat digunakan untuk mengamati perubahan kondisi psikologis individu dalam lingkungan kehidupan sehari-hari (Nickels et al., 2021). Perangkat *wearable* juga memungkinkan pengukuran parameter fisiologis secara kontinu, seperti variabilitas denyut jantung (*heart rate variability* atau HRV), pola tidur, dan aktivitas fisik. Integrasi data fisiologis dengan perilaku digital memungkinkan sistem analitik mengidentifikasi perubahan keadaan emosional individu, termasuk dinamika stres dan gejala depresi (S. Song et al., 2024). Pendekatan mendukung pengembangan sistem fenotipe digital (*digital phenotyping*) yang mengintegrasikan data sensor dengan analisis berbasis kecerdasan buatan (AI) untuk memantau dinamika kesehatan mental secara longitudinal (Rashid et al., 2024).

Deteksi Dini dan Prediksi Risiko

Kecerdasan buatan juga dimanfaatkan untuk mendukung deteksi dini dan prediksi risiko gangguan kesehatan mental melalui analisis data perilaku digital dan sinyal fisiologis. Identifikasi pola yang berkaitan dengan kondisi psikologis tertentu sebelum munculnya gejala klinis yang lebih signifikan. Kemampuan dapat mendukung pengembangan sistem peringatan dini (*early warning system*) untuk mengidentifikasi perubahan yang berkaitan dengan depresi, gangguan suasana hati, dan stres kronis. Perubahan pola aktivitas sehari-hari dapat memberikan indikator yang berkaitan dengan dinamika gangguan suasana hati. Analisis pola mobilitas dan aktivitas harian, misalnya, dapat digunakan untuk membedakan karakteristik perilaku individu dengan gangguan bipolar dan depresi unipolar (Faurholt-Jepsen et al., 2022). Teknik *computer vision* dan *speech analysis* juga dapat digunakan untuk mengevaluasi ekspresi wajah serta karakteristik suara sebagai indikator perilaku yang berkaitan dengan risiko bunuh diri dalam konteks klinis

(Galatzer-Levy et al., 2021). Integrasi berbagai indikator perilaku dan fisiologis dengan model *machine learning* memungkinkan sistem memanfaatkan informasi dari beberapa sumber data untuk memprediksi risiko gangguan

kesehatan mental. Pendekatan dapat mendukung strategi intervensi dini melalui identifikasi perubahan kondisi psikologis sebelum berkembang menjadi manifestasi klinis yang lebih serius (Barzilay et al., 2023).

Pemantauan Personal dan Adaptif

Penerapan AI dalam pemantauan kesehatan mental membuka peluang bagi pengembangan sistem yang bersifat personal dan adaptif. Model analitik yang dilatih menggunakan data longitudinal individu dapat mempelajari karakteristik perilaku dan dinamika emosional yang spesifik pada setiap pengguna. Pendekatan sejalan dengan konsep psikiatri presisi (precision psychiatry), yang memanfaatkan data digital untuk menyesuaikan analisis kondisi kesehatan mental berdasarkan karakteristik individual. Data longitudinal yang diperoleh melalui sensor telepon pintar dan penilaian mandiri (self-assessment) dapat digunakan untuk memodelkan perubahan suasana hati pada individu dengan gangguan suasana hati. Analisis berbasis machine learning memungkinkan identifikasi pola personal dalam perubahan emosional sehingga proses prediksi dapat disesuaikan dengan dinamika psikologis setiap individu (Busk et al., 2020). Integrasi data multimodal yang mencakup perilaku digital, sinyal fisiologis, dan indikator psikometrik memungkinkan pembentukan profil psikologis digital yang lebih komprehensif. Profil dapat digunakan untuk mengidentifikasi pola individual yang berkaitan dengan stres, depresi, dan gangguan suasana hati. Informasi yang diperoleh selanjutnya dapat mendukung sistem pemantauan kesehatan mental dalam menghasilkan rekomendasi atau strategi intervensi yang lebih sesuai dengan karakteristik dan dinamika psikologis individu (M. Song et al., 2024).

Tantangan dan Keterbatasan

Pendekatan psikofisiologi digital berbasis kecerdasan buatan (AI) menawarkan potensi dalam mendukung pemantauan kesehatan mental, tetapi penerapannya secara luas masih menghadapi berbagai tantangan teknis. Salah satu kendala utama berkaitan dengan ketersediaan himpunan data yang relatif kecil dan heterogen. Sejumlah publikasi menggunakan jumlah partisipan yang terbatas atau mengandalkan data yang dikumpulkan dalam lingkungan eksperimental tertentu. Kondisi membatasi kemampuan model untuk melakukan generalisasi terhadap populasi yang lebih luas (Nickels et al., 2021; Esmi et al., 2025). Variasi metode pengumpulan data, jenis sensor, dan karakteristik partisipan juga dapat memengaruhi konsistensi hasil analisis.

Sistem berbasis sensor digital juga menghadapi permasalahan kehilangan data (*missing data*) yang dapat disebabkan oleh kegagalan perangkat, ketidakkonsistenan penggunaan perangkat oleh pengguna, atau gangguan selama proses pengumpulan data (Rashid et al., 2024). Integrasi data multimodal meningkatkan kompleksitas pengolahan karena sinyal neural, indikator fisiologis, perilaku digital, dan instrumen psikometrik memiliki perbedaan format data, frekuensi pengambilan sampel, serta tingkat reliabilitas. Perbedaan karakteristik dapat mempersulit proses sinkronisasi dan integrasi fitur antarmodalitas (Zhang et al., 2025).

Tantangan lain berkaitan dengan privasi, keamanan informasi, dan potensi bias pada model AI. Sistem pemantauan kesehatan mental digital dapat mengumpulkan data sensitif yang mencakup pola mobilitas, aktivitas perangkat, serta indikator fisiologis yang berkaitan dengan kondisi kesehatan individu. Perlindungan data pribadi dan penerapan prinsip etika menjadi aspek penting dalam proses pengumpulan, penyimpanan, pengolahan, dan analisis data. Kualitas serta keterwakilan data pelatihan juga dapat memengaruhi kinerja prediksi model, terutama ketika himpunan data belum merepresentasikan keragaman karakteristik populasi secara memadai (Barzilay et al., 2023).

Penerapan sistem pemantauan kesehatan mental berbasis AI pada lingkungan kehidupan nyata juga menghadapi tantangan operasional. Sejumlah sistem masih dikembangkan dan dievaluasi dalam lingkungan eksperimental sehingga penerapannya dalam praktik klinis maupun aktivitas sehari-hari memerlukan pertimbangan yang lebih luas. Aspek keberlanjutan penggunaan perangkat, tingkat penerimaan pengguna, integrasi dengan sistem pelayanan kesehatan, serta kemampuan tenaga kesehatan dalam menginterpretasikan hasil analisis menjadi faktor yang perlu diperhatikan dalam proses implementasi (Martin et al., 2024). Pengembangan metode yang lebih robust, transparan, dan kompatibel dengan infrastruktur pelayanan kesehatan diperlukan untuk mendukung penerapan teknologi pemantauan kesehatan mental digital secara lebih luas.

Arah Pengembangan Masa Depan

Perkembangan teknologi sensor digital dan kecerdasan buatan (AI) membuka peluang bagi pengembangan sistem pemantauan kesehatan mental yang lebih komprehensif (Kargarandehkordi et al., 2025). Pengembangan pada masa mendatang memerlukan ketersediaan himpunan data multimodal berskala besar yang mengintegrasikan data psikofisiologis, perilaku digital, dan indikator klinis (Khoo et al., 2024). Himpunan data yang lebih besar dan beragam dapat mendukung model AI dalam mempelajari pola psikofisiologis yang kompleks serta meningkatkan kemampuan generalisasi pada populasi dengan karakteristik yang berbeda (Z. Wang et al., 2024). Perkembangan terkini juga menunjukkan potensi multimodal foundation models dalam mempelajari representasi terintegrasi dari berbagai sumber data sensor. Kemampuan dapat mendukung analisis kondisi mental yang lebih adaptif dan kontekstual berdasarkan karakteristik data yang tersedia (Qian et al., 2025).

Arah pengembangan berkaitan dengan peningkatan transparansi dan keamanan sistem AI dalam pemantauan kesehatan mental digital (Kargarandehkordi et al., 2025). Model *deep learning* yang digunakan untuk menganalisis kondisi psikologis memiliki struktur yang kompleks sehingga proses interpretasi hasil prediksi dapat menjadi tantangan bagi tenaga kesehatan. Pendekatan kecerdasan buatan yang dapat dijelaskan (*explainable artificial intelligence* atau XAI) memungkinkan identifikasi faktor yang berkontribusi terhadap prediksi model serta mendukung transparansi proses pengambilan keputusan. Pendekatan pembelajaran yang menjaga privasi (*privacy-preserving learning*) juga semakin relevan dalam pengelolaan data kesehatan mental yang bersifat sensitif. Salah satu pendekatan ialah *federated learning*, yang memungkinkan proses pelatihan model dilakukan secara terdistribusi tanpa memusatkan data sensitif dari berbagai sumber pada satu server (Srivastava et al., 2025).

Konsep kembaran digital (*digital twin*) juga berkembang sebagai salah satu arah potensial dalam pemantauan kesehatan mental berbasis sensor (Yücel et al., 2026). *Digital twin* merepresentasikan kondisi fisiologis dan perilaku individu dalam bentuk model digital yang diperbarui secara berkelanjutan menggunakan data sensor dan interaksi digital. Pemodelan dinamika kesehatan mental secara personal berdasarkan perubahan kondisi individu dari waktu ke waktu. Pemanfaatan data longitudinal juga dapat mendukung simulasi berbagai skenario intervensi yang disesuaikan dengan karakteristik individual. Integrasi AI dengan sistem pelayanan kesehatan menjadi arah pengembangan lain yang berpotensi memperluas pemanfaatan psikofisiologi digital dalam lingkungan klinis. Integrasi dapat mendukung pengembangan sistem pendukung keputusan klinis (*clinical decision support system*) yang membantu tenaga kesehatan dalam proses pemantauan, deteksi dini, dan pengambilan keputusan klinis terkait gangguan kesehatan mental (Englhardt et al., 2024). Pengembangan ke arah memerlukan keterhubungan antara teknologi sensor, model AI, data longitudinal, dan sistem klinis agar hasil analisis dapat digunakan secara relevan dalam proses pelayanan kesehatan.

Kesimpulan

Tinjauan literatur menunjukkan bahwa integrasi data psikofisiologis dan kecerdasan buatan (AI) memberikan kerangka analitik yang relevan untuk mendukung pemantauan kesehatan mental digital. Berbagai sumber data, seperti sinyal neural, indikator fisiologis dari perangkat *wearable*, perilaku digital yang diperoleh melalui sensor telepon pintar (*smartphone*), dan indikator psikometrik, dapat memberikan informasi yang saling melengkapi mengenai kondisi mental individu. Integrasi multimodal memungkinkan sistem analitik menghubungkan respons biologis, dinamika perilaku, dan kondisi kognitif dalam membentuk representasi kondisi psikologis yang lebih komprehensif.

Metode AI, mulai dari *machine learning* hingga arsitektur *deep learning*, berperan dalam mengolah data psikofisiologis dan perilaku digital yang memiliki karakteristik heterogen. Pemanfaatan berbagai metode mendukung pengembangan sistem yang mampu memantau dinamika emosional secara berkelanjutan, mengidentifikasi perubahan kondisi psikologis, serta menyesuaikan proses pemantauan berdasarkan karakteristik individual. Pendekatan multimodal juga memperluas kemampuan analisis dengan mengintegrasikan informasi dari berbagai sumber data ke dalam kerangka pemantauan kesehatan mental yang lebih adaptif dan kontekstual.

Penerapan psikofisiologi digital berbasis AI masih menghadapi sejumlah tantangan yang berkaitan dengan keterbatasan himpunan data multimodal, kompleksitas integrasi dan sinkronisasi data, privasi informasi, serta potensi bias algoritmik. Pengembangan himpunan data yang lebih representatif, metode integrasi multimodal yang robust, pendekatan AI yang transparan, dan mekanisme perlindungan privasi menjadi aspek penting untuk mendukung penerapan teknologi tersebut. Perkembangan pada aspek berpotensi memperkuat peran psikofisiologi digital berbasis AI dalam membangun sistem pemantauan kesehatan mental yang lebih personal, adaptif, dan berkelanjutan.

Daftar Pustaka

- Deeksha, & Firdose, Dr. S. (2025). Exploring Deep Learning Approaches to Stress Recognition Data, Models, and Applications in Review. *International Journal for Research in Applied Science and Engineering Technology*, 13(9), 1319–1336. <https://doi.org/10.22214/ijraset.2025.74109>
- Aledavood, T., Luong, N., Baryshnikov, I., Darst, R., Heikkilä, R., Holmén, J., Ikäheimonen, A., Martikkala, A., Riihimäki, K., Saleva, O., Triana, A. M., & Isometsä, E. (2025). Multimodal Digital Phenotyping Study in Patients With Major Depressive Episodes and Healthy Controls (Mobile Monitoring of Mood): Observational Longitudinal Study. *JMIR Mental Health*, 12, e63622. <https://doi.org/10.2196/63622>
- Barzilay, S., Fine, S., Akhavan, S., Haruvi-Catalan, L., Apter, A., Brunstein-Klomek, A., Carmi, L., Zohar, M., Kinarty, I., Friedman, T., & Fennig, S. (2023). Real-Time Real-World Digital Monitoring of Adolescent Suicide Risk During the Six Months Following Emergency Department Discharge: Protocol for an Intensive Longitudinal Study. *JMIR Research Protocols*, 12. <https://doi.org/10.2196/46464>
- Baydili, İ., Tasci, B., & Tasci, G. (2025). Artificial Intelligence in Psychiatry: A Review of Biological and Behavioral Data Analyses. *Diagnostics*, 15(4), 434. <https://doi.org/10.3390/diagnostics15040434>
- Busk, J., Faurholt-Jepsen, M., Frost, M., Bardram, J. E., Kessing, L. V., & Winther, O. (2020). Forecasting Mood in Bipolar Disorder from Smartphone Self-assessments: Hierarchical Bayesian approach. *JMIR MHealth and UHealth*, 8(4). <https://doi.org/10.2196/15028>

- Chia, A. Z. R., & Zhang, M. W. B. (2022). Digital phenotyping in psychiatry: A scoping review. *Technology and Health Care*, 30(6), 1331–1342. <https://doi.org/10.3233/THC-213648>
- Englhardt, Z., Ma, C., Morris, M. E., Xu, X. "Orson," Chang, C.-C., Qin, L., McDuff, D., Liu, X., Patel, S., & Iyer, V. (2024). *From Classification to Clinical Insights: Towards Analyzing and Reasoning About Mobile and Behavioral Health Data With Large Language Models*. <https://doi.org/10.1145/3659604>
- Esmi, N., Shahbahrami, A., Gaydadjiev, G., & de Jonge, P. (2025). TERE: Transformer-based emotion recognition using EEG and Eye movement data. *Intelligence-Based Medicine*, 12. <https://doi.org/10.1016/j.ibmed.2025.100305>
- Faurholt-Jepsen, M., Busk, J., Rohani, D. A., Frost, M., Tønning, M. L., Bardram, J. E., & Kessing, L. V. (2022). Differences in mobility patterns according to machine learning models in patients with bipolar disorder and patients with unipolar disorder. *Journal of Affective Disorders*, 306, 246–253. <https://doi.org/10.1016/j.jad.2022.03.054>
- Galatzer-Levy, I., Abbas, A., Ries, A., Homan, S., Sels, L., Koesmahargyo, V., Yadav, V., Colla, M., Scheerer, H., Vetter, S., Seifritz, E., Scholz, U., & Kleim, B. (2021). Validation of visual and auditory digital markers of suicidality in acutely suicidal psychiatric inpatients: Proof-of-concept study. *Journal of Medical Internet Research*, 23(6). <https://doi.org/10.2196/25199>
- Huang, D., Emedom-Nnamdi, P., Onnela, J.-P., & Van Meter, A. (2025). Design and feasibility of smartphone-based digital phenotyping for long-term mental health monitoring in adolescents. *PLOS Digital Health*, 4(7), e0000883. <https://doi.org/10.1371/journal.pdig.0000883>
- Kadirvelu, B., Bellido Bel, T., Freccero, A., Di Simplico, M., Nicholls, D., & Faisal, A. A. (2026). Digital Phenotyping for Adolescent Mental Health: Feasibility Study Using Machine Learning to Predict Mental Health Risk From Active and Passive Smartphone Data. *Journal of Medical Internet Research*, 28, e72501–e72501. <https://doi.org/10.2196/72501>
- Kargarandehkordi, A., Li, S., Lin, K., Phillips, K. T., Benzo, R. M., & Washington, P. (2025). Fusing Wearable Biosensors with Artificial Intelligence for Mental Health Monitoring: A Systematic Review. *Biosensors*, 15(4), 202. <https://doi.org/10.3390/bios15040202>
- Khoo, L. S., Lim, M. K., Chong, C. Y., & McNaney, R. (2024). Machine Learning for Multimodal Mental Health Detection: A Systematic Review of Passive Sensing Approaches. *Sensors*, 24(2), 348. <https://doi.org/10.3390/s24020348>
- Kumar, A., & Kumar, A. (2025). EEG-based emotion recognition: A deep learning approach to brain region analysis. *Biomedical Signal Processing and Control*, 110. <https://doi.org/10.1016/j.bspc.2025.108111>
- Linardon, J., Chen, K., Gajjar, S., Eadara, A., Wang, S., Flathers, M., Burns, J., & Torous, J. (2025). Smartphone digital phenotyping in mental health disorders: A review of raw sensors utilized, machine learning processing pipelines, and derived behavioral features. *Psychiatry Research*, 348, 116483. <https://doi.org/10.1016/j.psychres.2025.116483>
- Martin, J., Rueda, A., Lee, G. H., Tassone, V. K., Park, H., Ivanov, M., Darnell, B. C., Beavers, L., Campbell, D. M., Nguyen, B., Torres, A., Jung, H., Lou, W., Nazarov, A., Ashbaugh, A., Kapralos, B., Litz, B., Jetly, R., Dubrowski, A., ... Bhat, V. (2024). Digital Interventions to Understand and Mitigate Stress Response: Protocol for Process and Content Evaluation of a Cohort Study. *JMIR Research Protocols*, 13. <https://doi.org/10.2196/54180>
- Moura, I., Teles, A., Viana, D., Marques, J., Coutinho, L., & Silva, F. (2023). Digital Phenotyping of Mental Health using multimodal sensing of multiple situations of interest: A Systematic Literature Review. *Journal of Biomedical Informatics*, 138, 104278. <https://doi.org/10.1016/j.jbi.2022.104278>
- NI, Y. (2025). Advancing Emotion Recognition in Wearable Devices: Core Technologies, Challenges and Practical Solutions. *Theoretical and Natural Science*, 79(1), 59–66. <https://doi.org/10.54254/2753-8818/2025.19943>

- Nickels, S., Edwards, M. D., Poole, S. F., Winter, D., Gronsbell, J., Rozenkrants, B., Miller, D. P., Fleck, M., McLean, A., Peterson, B., Chen, Y., Hwang, A., Rust-Smith, D., Brant, A., Campbell, A., Chen, C., Walter, C., Arean, P. A., Hsin, H., ... Fromer, M. (2021). Toward a mobile platform for real-world digital measurement of depression: User-centered design, data quality, and behavioral and clinical modeling. *JMIR Mental Health*, 8(8). <https://doi.org/10.2196/27589>
- Qian, K., Zhang, H., Jing, X., Hu, B., Yamamoto, Y., & Schuller, B. W. (2025). Foundation models for digital mental health: igniting the dawn. *Medicine Plus*, 2(2), 100085. <https://doi.org/10.1016/j.medp.2025.100085>
- R, R., & Pushpalatha, M. P. (2025). Advancements in AI-Driven Detection and Monitoring of Depression and Anxiety using Multimodal Digital Biomarkers and Behavioural Data. *2025 International Conference on Innovations in Intelligent Systems: Advancements in Computing, Communication, and Cybersecurity (ISAC3)*, 1–5. <https://doi.org/10.1109/ISAC364032.2025.11156233>
- Rashid, Z., Folarin, A. A., Zhang, Y., Ranjan, Y., Conde, P., Sankesara, H., Sun, S., Stewart, C., Laiou, P., & Dobson, R. J. B. (2024). Digital Phenotyping of Mental and Physical Conditions: Remote Monitoring of Patients Through RADAR-Base Platform. *JMIR Mental Health*, 11. <https://doi.org/10.2196/51259>
- Ringwald, W. R., King, G., Vize, C. E., & Wright, A. G. C. (2025). Passive Smartphone Sensors for Detecting Psychopathology. *JAMA Network Open*, 8(7), e2519047. <https://doi.org/10.1001/jamanetworkopen.2025.19047>
- Sanfelici, R., Dwyer, D. B., Antonucci, L. A., & Koutsouleris, N. (2020). Individualized Diagnostic and Prognostic Models for Patients With Psychosis Risk Syndromes: A Meta-analytic View on the State of the Art. *Biological Psychiatry*, 88(4), 349–360. <https://doi.org/10.1016/j.biopsych.2020.02.009>
- Song, M., Yang, Z., Triantafyllopoulos, A., Zhang, Z., Nan, Z., Tang, M., Takeuchi, H., Nakamura, T., Kishi, A., Ishizawa, T., Yoshiuchi, K., Schuller, B., & Yamamoto, Y. (2024). Empowering Mental Health Monitoring Using a Macro-Micro Personalization Framework for Multimodal-Multitask Learning: Descriptive Study. *JMIR Mental Health*, 11. <https://doi.org/10.2196/59512>
- Song, S., Seo, Y. Bin, Hwang, S. Y., Kim, H. Y., & Kim, J. (2024). Digital Phenotyping of Geriatric Depression Using a Community-Based Digital Mental Health Monitoring Platform for Socially Vulnerable Older Adults and Their Community Caregivers: 6-Week Living Lab Single-Arm Pilot Study. *JMIR MHealth and UHealth*, 12. <https://doi.org/10.2196/55842>
- Srivastava, S., Kansal, K., Sai, S., & Chamola, V. (2025). Secure cognitive health monitoring using a directed acyclic graph-based and AI-enhanced IoMT framework. *Digital Communications and Networks*, 11(3), 594–602. <https://doi.org/10.1016/j.dcan.2024.08.014>
- Wang, J., Ouyang, H., Jiao, R., Cheng, S., Zhang, H., Shang, Z., Jia, Y., Yan, W., Wu, L., & Liu, W. (2024). The application of machine learning techniques in posttraumatic stress disorder: a systematic review and meta-analysis. *Npj Digital Medicine*, 7(1), 121. <https://doi.org/10.1038/s41746-024-01117-5>
- Wang, L., Wang, C., Li, C., Murai, T., Bai, Y., Song, Z., Zhang, S., Zhang, Q., Huang, Y., Bi, X., & Jiang, J. (2025). AI-assisted multi-modal information for the screening of depression: a systematic review and meta-analysis. *Npj Digital Medicine*, 8(1), 523. <https://doi.org/10.1038/s41746-025-01933-3>
- Wang, Z., Wu, W., & Zeng, C. (2024). PhysioFormer: Integrating Multimodal Physiological Signals and Symbolic Regression for Explainable Affective State Prediction. *PLoS One*, 20(10). <https://doi.org/10.1371/journal.pone.0335221>
- Xia, Z., Chikersal, P., Venkatesh, S., Walker, E., Dey, A. K., & Goel, M. (2025). Longitudinal Digital Phenotyping of Multiple Sclerosis Severity Using Passively Sensed Behaviors and Ecological Momentary Assessments: Real-World Evaluation. *Journal of Medical Internet Research*, 27. <https://doi.org/10.2196/70871>
- Yang, Z., Heaukulani, C., Sim, A., Buddhika, T., Abdul Rashid, N. A., Wang, X., Zheng, S., Quek, Y. F., Basu, S., Lee, K. W., Tang, C., Verma, S., Morris, R. J. T., & Lee, J. (2025). Utility of Digital Phenotyping Based on Wrist Wearables

- and Smartphones in Psychosis: Observational Study. *JMIR MHealth and UHealth*, 13, e56185–e56185. <https://doi.org/10.2196/56185>
- Yücel, K., Özcanhan, M. H., & Ünlütürk, M. S. (2026). MTWIN: A mental health monitoring framework toward a Digital Twin. *Smart Health*, 40, 100646. <https://doi.org/10.1016/j.smhl.2026.100646>
- Zhan, Y., Liu, H., & Wang, Y. (2026). Digital phenotyping of depression: A multi-modal passive sensing approach to identifying novel behavioral and physiological markers of treatment response. *Journal of Psychiatric Research*, 194, 40–50. <https://doi.org/10.1016/j.jpsychires.2025.12.036>
- Zhang, Y., Stewart, C., Ranjan, Y., Conde, P., Sankesara, H., Rashid, Z., Sun, S., Dobson, R. J. B., & Folarin, A. A. (2025). Large-scale digital phenotyping: Identifying depression and anxiety indicators in a general UK population with over 10,000 participants. *Journal of Affective Disorders*, 375, 412–422. <https://doi.org/10.1016/j.jad.2025.01.124>