

An AI-Driven Personalized Treatment Pathway Engine for Multi-Symptom Digital Mental Health Platforms: Algorithmic Architecture, Privacy-Preserving Cross-Modal Synchronization, and Audit-Traceable Clinical Reasoning

다중 증상 디지털 정신건강 플랫폼을 위한 AI 기반 개인 맞춤형 치료 경로 엔진: 알고리즘 아키텍처, 프라이버시 보존 교차 모달 동기화, 그리고 감사 추적 가능한 임상 추론

Alex Kwon¹

¹Boston Neuromind LLC, Boston, MA, USA

Former Visiting Scholar, Harvard Graduate School of Education (Mind, Brain, and Education)

Correspondence: alex@bostonneuromind.com

Abstract

Background. Digital mental health interventions (DMHIs) have proliferated rapidly, yet a persistent gap exists between symptom assessment and personalized, session-level treatment planning. Most platforms surface diagnostic results without bridging to actionable, evidence-based treatment pathways that adapt to individual context. A second gap concerns the integration of conversational agents (bots) with clinical assessment modules: bot-collected data is clinically valuable but raises significant privacy concerns when shared without explicit user control.

Objective. We present a six-algorithm engine that operationalizes the assessment-to-treatment pathway for a multi-symptom digital mental health platform (Boston Neuromind's NeuroCatchers + TalkCatcher dual-module architecture), spanning ten symptom domains (ADHD, depression, anxiety, sleep, burnout, PTSD, OCD, bipolar, autism, and peak performance). **Methods.** We specify (a) a unified relational database schema linking patient assessment, training library, recommendation reasoning, and session records; (b) Algorithm 1 (ALG-1), a six-component recommendation scorer integrating symptom match, biomarker match, evidence strength (Cochrane d-normalized), Fischer dynamic skill compatibility, practical fit, and personal history; (c) ALG-2, a Fischer-level-aware session plan generator that distributes skill progression across N sessions; (d) ALG-3, an adaptive replanner triggered by session count changes, goal modifications, or dropout signals; (e) ALG-4, a privacy-preserving Bot ↔ Catcher bridge with opt-in default-off semantics; (f) ALG-5, a clinician/client-facing custom training builder; and (g) ALG-6, a bilingual (Korean/English) result renderer producing clinical and patient versions in parallel.

Results. The architecture provides end-to-end audit traceability: every recommendation persists score components, evidence citations (PMID/DOI), reasoning in both languages, and the model

version that generated it. ADHD serves as a Gold Template for subsequent symptom-domain replication. **Conclusion.** This design offers a generalizable, regulator-aligned (FDA SaMD, HIPAA, GDPR Article 9 and 22) framework for multi-symptom personalized digital mental health, demonstrating how recommendation algorithms can operate transparently while respecting privacy boundaries between conversational and clinical data streams.

Keywords: digital mental health; personalization; clinical decision support; adaptive treatment; privacy-preserving AI; explainable AI; Fischer dynamic skill theory; audit traceability

다중 증상 디지털 정신건강 플랫폼을 위한 AI 기반 개인 맞춤형 치료 경로 엔진: 알고리즘 아키텍처, 프라이버시 보존 교차 모달 동기화, 그리고 감사 추적 가능한 임상 추론

초록

배경. 디지털 정신건강 중재(DMHI)는 빠르게 확산되었으나, 증상 평가와 개인화된 세션 수준의 치료 계획 사이에는 지속적인 격차가 존재한다. 대부분의 플랫폼은 진단 결과를 표시하지만, 개인의 맥락에 적응하는 근거 기반 치료 경로로 연결하지 못한다. 두 번째 격차는 대화형 에이전트(봇)와 임상 평가 모듈의 통합에 관한 것이다: 봇이 수집한 데이터는 임상적으로 가치 있으나, 사용자의 명시적 통제 없이 공유될 경우 심각한 프라이버시 문제를 야기한다. **목적.** 본 연구는 다중 증상 디지털 정신건강 플랫폼(Boston Neuromind의 NeuroCatchers + TalkCatcher 이중 모듈 아키텍처)에서 평가-치료 경로를 운영화하는 6개 알고리즘 엔진을 제시한다. 10개 증상 영역(ADHD, 우울증, 불안, 수면, 번아웃, PTSD, OCD, 양극성장애, 자폐, 최고 수행)을 다룬다. **방법.** (a) 환자 평가, 훈련 라이브러리, 추천 추론, 세션 기록을 연결하는 통합 관계형 데이터베이스 스키마; (b) 증상 일치, 바이오마커 일치, 근거 강도(Cochrane d 정규화), Fischer 역동적 기술 호환성, 실용적 적합성, 개인 이력의 6개 구성요소를 통합한 추천 점수 산정자(ALG-1); (c) Fischer 수준을 인식하여 N개 세션에 기술 진행을 분배하는 세션 계획 생성자(ALG-2); (d) 세션 수 변경, 목표 수정, 중도 이탈 신호에 의해 트리거되는 적응형 재계획자(ALG-3); (e) 옵트인 기본 OFF 의미를 가진 프라이버시 보존 봇 ↔ Catcher 브리지(ALG-4); (f) 임상가/내담자 대면 맞춤 훈련 빌더(ALG-5); (g) 임상 버전과 환자 버전을 병렬로 생성하는 한·영 이중 언어 결과 렌더러(ALG-6)를 명세한다. **결과.** 아키텍처는 종단 간 감사 추적성을 제공한다: 모든 추천은 점수 구성요소, 근거 인용(PMID/DOI), 양 언어로 된 추론, 그리고 이를 생성한 모델 버전을 영구 저장한다. ADHD는 후속 증상 영역 복제를 위한 황금 템플릿 역할을 한다. **결론.** 본 설계는 다중 증상 개인 맞춤형 디지털 정신건강을 위한 일반화 가능하고 규제 정렬된(FDA SaMD, HIPAA, GDPR 9 조 및 22 조) 프레임워크를 제공하며, 추천 알고리즘이 대화형 데이터와 임상 데이터 스트림 간의 프라이버시 경계를 존중하면서 투명하게 작동할 수 있는 방법을 보여준다.

키워드: 디지털 정신건강; 개인화; 임상 의사결정 지원; 적응형 치료; 프라이버시 보존 AI; 설명 가능한 AI; Fischer 역동적 기술 이론; 감사 추적성

2. Introduction

2. 서론

2.1 The Digital Mental Health Landscape and the Personalization Gap

2.1 디지털 정신건강 환경과 개인화 격차

The past decade has produced a marked expansion of digital mental health interventions (DMHIs), including smartphone applications, web-based programs, conversational agents, and virtual reality experiences (Torous et al., 2021). Meta-analytic evidence indicates that app-supported interventions yield small-to-moderate effect sizes for depression, anxiety, and related conditions, with effect sizes consistently larger when interventions incorporate adaptive or personalized elements (Linardon et al., 2024). Personalization itself is a heterogeneous construct in the literature: Hornstein et al. (2023) identified at least six personalization dimensions in DMHIs for depression alone, while Wanniarachchi et al. (2025) catalogued 67 distinct personalization variables across 67 studies of DMHIs for youth depression and anxiety.

지난 10 년간 디지털 정신건강 중재(DMHI)는 스마트폰 앱, 웹 기반 프로그램, 대화형 에이전트, 가상현실 경험을 포함하여 현저히 확장되었다(Torous et al., 2021). 메타분석 증거는 앱 기반 중재가 우울증, 불안 및 관련 상태에 대해 소-중 효과 크기를 산출하며, 적응적 또는 개인화된 요소를 포함할 때 효과 크기가 일관되게 더 크다는 점을 보여준다(Linardon et al., 2024). 개인화 자체는 문헌에서 이질적인 구성 개념이다: Hornstein 등(2023)은 우울증에 대한 DMHI 에서만 최소 6 개의 개인화 차원을 식별했으며, Wanniarachchi 등(2025)은 청소년 우울 및 불안에 대한 DMHI 67 개 연구에서 67 개의 개별 개인화 변수를 분류했다.

Yet a structural gap persists. The dominant pattern across deployed DMHIs is symptom screening followed by static psychoeducational content, generic skill exercises, or unstructured chatbot conversation. The translation from a diagnostic signal (e.g., a Patient Health Questionnaire-9 score, an ADHD self-report screener result, a biomarker pattern) to a personalized, ordered, evidence-anchored sequence of treatment activities — with explicit reasoning that can be audited by clinicians, patients, and regulators — remains largely unaddressed in production systems. This is the central problem the present work addresses.

그러나 구조적 격차가 지속된다. 배포된 DMHI 에서 지배적인 패턴은 증상 선별 후 정적 심리교육 콘텐츠, 일반적 기술 연습 또는 비구조화된 챗봇 대화로 이어진다. 진단 신호(예: 환자 건강 설문지-9 점수, ADHD 자가보고 선별 결과, 바이오마커 패턴)에서 환자의 증상 프로파일, 바이오마커 서명(가용 시), 발달 기술 수준, 실용적 제약, 개인 이력에 매핑되는 개인화된 순서가 있는 근거 기반 치료 활동 순서로의 번역—임상가, 환자, 규제 기관이 감사할 수 있는 명시적 추론과 함께—은 운영 시스템에서 거의 다루어지지 않았다. 이것이 본 연구가 다루는 중심 문제이다.

2.2 From Assessment to Action: The Treatment Pathway Problem

2.2 평가에서 행동으로: 치료 경로 문제

A treatment pathway, as we use the term here, is an ordered, individualized sequence of evidence-based therapeutic activities that maps to a patient's symptom profile, biomarker signature (where available), developmental skill level, practical constraints, and personal history. Adaptive treatment strategy frameworks pioneered by Murphy (2005) and elaborated by Almirall et al. (2014) and Nahum-Shani et al. (2018) provide the conceptual scaffolding for sequencing decisions in mental health, but these frameworks do not specify the data structures or algorithmic mechanisms by which a real-world platform serving ten distinct symptom domains can operationalize the assessment-to-treatment translation at scale.

본 연구에서 사용하는 치료 경로(treatment pathway)는 환자의 증상 프로파일, 바이오마커 서명(가용 시), 발달 기술 수준, 실용적 제약, 개인 이력에 매핑되는 근거 기반 치료 활동의 순서화된 개인 맞춤형 시퀀스이다. Murphy(2005)가 개척하고 Almirall 등(2014) 및 Nahum-Shani 등(2018)이 정교화한 적응형 치료 전략 프레임워크는 정신건강에서 순서화 결정을 위한 개념적 발판을 제공하지만, 이러한 프레임워크는 10 개의 별개 증상 영역을 담당하는 실제 플랫폼이 평가-치료 번역을 대규모로 운영화할 수 있는 데이터 구조나 알고리즘 메커니즘을 명세하지 않는다.

Clinical decision support systems (CDSSs) in physical medicine have demonstrated the value of algorithmic recommendation with persisted reasoning (e.g., Lee et al., 2024, for hepatocellular carcinoma; Sutton et al., 2020, for overview), but mental health CDSSs have lagged, in part because (a) symptom heterogeneity within a diagnostic category is large, (b) biomarker grounding is weaker than in oncology or cardiology, and (c) the patient's subjective preferences and developmental stage are themselves substantive inputs to the decision. We argue that these obstacles, far from precluding algorithmic recommendation, instead define its required architecture: a multi-component scorer with explicit handling of subjective preference, developmental skill matching, and audit-traceable reasoning.

신체 의학의 임상 의사결정 지원 시스템(CDSS)은 영구 저장된 추론을 갖춘 알고리즘 추천의 가치를 입증해 왔으나(예: 간세포암에 대한 Lee et al., 2024; 개관을 위한 Sutton et al., 2020), 정신건강 CDSS는 부분적으로 (a) 진단 범주 내 증상 이질성이 크고, (b) 바이오마커 근거가 종양학이나 심장학보다 약하며 (c) 환자의 주관적 선호와 발달 단계 자체가 결정에 대한 실질적 입력이라는 점에서 뒤쳐져 왔다. 우리는 이러한 장애물이 알고리즘 추천을 배제하기는커녕 오히려 필요한 아키텍처를 정의한다고 주장한다: 주관적 선호, 발달 기술 매칭, 감사 추적 가능한 추론을 명시적으로 처리하는 다중 구성 요소 점수 산정자가 필요하다.

2.3 The Privacy Paradox in Bot-Clinical Integration

2.3 봇-임상 통합의 프라이버시 역설

A second, less frequently articulated gap concerns the integration of conversational agents with clinical assessment modules. Generative AI chatbots have demonstrated clinical efficacy in the first wave of rigorous trials (Heinz et al., 2025; Wang et al., 2025; see also Reyes-Portillo et al., 2025, for a systematic review), and contemporary platforms increasingly deploy both a conversational front-end and a structured clinical back-end. The conversational stream contains information of considerable clinical value — mood trajectories, life events, adherence reports, symptom fluctuations — yet routing this stream into the clinical record without explicit user control creates significant ethical and regulatory exposure under the General Data Protection Regulation (GDPR) Article 9 (special category data) and Article 22 (automated individual decision-making), as well as the Health Insurance Portability and Accountability Act (HIPAA) in the United States (Cohen & Mello, 2018; Voigt & von dem Bussche, 2017; Wachter et al., 2017).

덜 자주 명확히 표현되는 두 번째 격차는 대화형 에이전트와 임상 평가 모듈의 통합에 관한 것이다. 생성형 AI 챗봇은 엄격한 시험의 첫 번째 물결에서 임상적 효능을 입증했으며(Heinz et al., 2025; Wang et al., 2025; 체계적 검토는 Reyes-Portillo et al., 2025 참조), 현대 플랫폼은 대화형 프론트엔드와 구조화된 임상 백엔드를 모두 점점 더 배포하고 있다. 대화 스트림은 상당한 임상적 가치를 갖는 정보—기분 궤적, 생활 사건, 순응도 보고, 증상 변동—를 포함하지만, 명시적 사용자 통제 없이 이 스트림을 임상 기록으로 라우팅하는 것은 일반 데이터 보호 규정(GDPR) 9 조(특수 범주 데이터)와 22 조(자동화된 개별 의사결정) 그리고 미국의 건강보험 이동성 및 책임법(HIPAA)에 따른 상당한 윤리적·규제적 위험을 초래한다 (Cohen & Mello, 2018; Voigt & von dem Bussche, 2017; Wachter et al., 2017).

We frame this as the privacy paradox of bot-clinical integration: bot-derived clinical signal is valuable, yet unconsented sharing damages the trust premise on which conversational disclosure rests. The architectural solution we propose is an explicit opt-in default-off bridge between the conversational module (TalkCatcher) and the clinical assessment module (NeuroCatchers) — described in detail as ALG-4 below.

우리는 이를 봇-임상 통합의 프라이버시 역설로 프레임한다: 봇 파생 임상 신호는 가치 있으나, 동의되지 않은 공유는 대화형 공개가 기반을 두는 신뢰 전제를 훼손한다. 우리가 제안하는 아키텍처적 해결책은 대화형 모듈(TalkCatcher)과 임상 평가 모듈(NeuroCatchers) 사이의 명시적 옵트인 기본 OFF 브리지이다—아래에서 ALG-4 로 상세히 기술된다.

2.4 Audit Traceability as a Clinical and Regulatory Requirement

2.4 임상 및 규제 요구사항으로서의 감사 추적성

Recent regulatory trajectories converge on a shared requirement: AI-enabled clinical software must provide transparent, traceable reasoning for its recommendations. The U.S. Food and Drug Administration's AI/ML Software-as-a-Medical-Device (SaMD) action plan (FDA, 2021; Warraich et al., 2024) emphasizes good machine learning practice and lifecycle audit. The European

Union's AI Act, which entered into force in 2024, classifies AI systems used in healthcare as high-risk and imposes transparency, human oversight, and post-market monitoring requirements. GDPR Article 22 affords data subjects a right not to be subject to solely automated decision-making with legal or similarly significant effects, accompanied by interpretive debate over the scope of an attendant "right to explanation" (Goodman & Flaxman, 2017; Wachter et al., 2017). Clinically, audit-traceable reasoning supports professional accountability under the standard of care doctrine, enables retrospective quality improvement, and equips clinicians to challenge or accept algorithmic recommendations on substantive grounds (Doshi-Velez & Kim, 2017; Ghassemi et al., 2021; Tjoa & Guan, 2021).

최근 규제 궤적은 공유된 요구사항으로 수렴한다: AI 지원 임상 소프트웨어는 추천에 대해 투명하고 추적 가능한 추론을 제공해야 한다. 미국 식품의약국의 AI/ML 의료기기 소프트웨어(SaMD) 행동 계획(FDA, 2021; Warraich et al., 2024)은 우수한 머신러닝 관행과 수명주기 감사를 강조한다. 2024년 발효된 유럽연합의 AI 법은 의료에 사용되는 AI 시스템을 고위험으로 분류하고 투명성, 인간 감독, 시판 후 모니터링 요구사항을 부과한다. GDPR 22 조는 데이터 주체에게 법적 또는 유사하게 중대한 영향을 미치는 전적으로 자동화된 의사결정의 대상이 되지 않을 권리를 부여하며, 부수적인 "설명에 대한 권리"의 범위에 대한 해석 논쟁이 동반된다(Goodman & Flaxman, 2017; Wachter et al., 2017). 임상적으로, 감사 추적 가능한 추론은 치료 표준 원칙에 따른 전문가 책임을 지원하고, 회고적 품질 개선을 가능하게 하며, 임상가가 알고리즘 추천을 실질적 근거에 따라 도전하거나 수용할 수 있도록 한다(Doshi-Velez & Kim, 2017; Ghassemi et al., 2021; Tjoa & Guan, 2021).

Accordingly, our architecture treats audit traceability as a first-class design constraint rather than a post-hoc add-on. Every recommendation produced by the engine persists its score components, evidence citations (with PubMed identifiers or digital object identifiers where available), reasoning text in both Korean and English, and the model version that generated it. We elaborate the audit schema in Section 12.

따라서 우리의 아키텍처는 감사 추적성을 사후 추가가 아닌 일급 설계 제약으로 다룬다. 엔진이 생성하는 모든 추천은 점수 구성요소, 근거 인용(가능한 경우 PubMed 식별자 또는 디지털 객체 식별자 포함), 한국어와 영어 양쪽의 추론 텍스트, 그리고 이를 생성한 모델 버전을 영구 저장한다. 12 절에서 감사 스키마를 상세화한다.

2.5 Contribution and Paper Organization

2.5 기여 및 논문 구성

This paper makes the following contributions. First, we specify a six-algorithm engine — ALG-1 through ALG-6 — that collectively operationalizes the assessment-to-treatment pathway, the privacy-preserving bot-clinical bridge, custom training authoring, and bilingual result rendering. Second, we provide the relational database schema that underwrites these algorithms, with

explicit attention to the audit trail. Third, we articulate a universal symptom-domain architecture: a single set of schemas and algorithms parameterized across ten symptom tracks (ADHD as the Gold Template, with depression, anxiety, sleep, burnout, post-traumatic stress disorder, obsessive-compulsive disorder, bipolar disorder, autism, and peak performance as parallel instantiations). Fourth, we map our design to current regulatory frameworks and identify the conformity pathway under FDA SaMD Class II and GDPR Article 9/22.

본 논문은 다음과 같은 기여를 한다. 첫째, 우리는 평가-치료 경로, 프라이버시 보존 붓-임상 브리지, 맞춤형 훈련 저작, 이중 언어 결과 렌더링을 집합적으로 운영화하는 6개 알고리즘 엔진—ALG-1부터 ALG-6까지—을 명세한다. 둘째, 우리는 이러한 알고리즘을 뒷받침하는 관계형 데이터베이스 스키마를 감사 추적에 명시적 주의를 기울여 제공한다. 셋째, 우리는 보편적 증상 영역 아키텍처를 명확히 한다: 10개 증상 트랙(ADHD를 황금 템플릿으로, 우울증, 불안, 수면, 번아웃, 외상후스트레스장애, 강박장애, 양극성장애, 자폐, 최고 수행을 병렬 인스턴스로)에 걸쳐 매개변수화된 단일 스키마와 알고리즘 세트이다. 넷째, 우리는 우리의 설계를 현재 규제 프레임워크에 매핑하고 FDA SaMD 클래스 II 및 GDPR 9조/22조에 따른 적합성 경로를 식별한다.

The remainder of the paper is organized as follows. Section 3 reviews related work in personalization, adaptive treatment, recommendation systems in healthcare, Fischer dynamic skill theory, privacy-preserving health data architecture, and audit trails in clinical AI. Section 4 describes the two-module system architecture. Section 5 presents the database schema. Sections 6 through 11 specify the six algorithms in turn. Section 12 elaborates the audit traceability layer. Section 13 describes the universal symptom architecture and the ADHD Gold Template strategy. Section 14 discusses strengths, limitations, clinical implications, and the regulatory pathway. Section 15 concludes.

논문의 나머지는 다음과 같이 구성된다. 3절은 개인화, 적응형 치료, 의료 추천 시스템, Fischer 역동적 기술 이론, 프라이버시 보존 건강 데이터 아키텍처, 임상 AI에서의 감사 추적의 관련 작업을 검토한다. 4절은 이중 모듈 시스템 아키텍처를 기술한다. 5절은 데이터베이스 스키마를 제시한다. 6절부터 11절은 6개 알고리즘을 차례로 명세한다. 12절은 감사 추적성 계층을 상세화한다. 13절은 보편적 증상 아키텍처와 ADHD 황금 템플릿 전략을 기술한다. 14절은 강점, 한계, 임상적 함의, 규제 경로를 논의한다. 15절은 결론을 맺는다.

3. Background and Related Work

3. 배경 및 관련 작업

3.1 Personalization in Digital Mental Health

3.1 디지털 정신건강에서의 개인화

Hornstein et al. (2023) provide the most influential recent framework for classifying personalization strategies in DMHIs, distinguishing dimensions of content, presentation, timing, and feedback. Wanniarachchi et al. (2025) extend this framework to youth populations and document the prevalence of each dimension. A consistent finding across these reviews is that few interventions implement just-in-time adaptive logic, and even fewer expose the algorithmic basis of their personalization to users or clinicians. Our work addresses this gap by treating personalization as an explicit algorithmic process with persisted reasoning.

Hornstein 등(2023)은 콘텐츠, 제시, 타이밍, 피드백 차원을 구분하면서 DMHI의 개인화 전략을 분류하기 위한 가장 영향력 있는 최근 프레임워크를 제공한다. Wanniarachchi 등(2025)은 이 프레임워크를 청소년 집단으로 확장하고 각 차원의 유병률을 문서화한다. 이러한 검토에서 일관된 발견은 적시 적응 로직을 구현하는 중재가 적으며, 개인화의 알고리즘적 기반을 사용자나 임상가에게 노출하는 경우는 훨씬 적다는 것이다. 우리의 작업은 영구 저장된 추론을 갖춘 명시적 알고리즘 프로세스로 개인화를 다룸으로써 이 격차를 해결한다.

3.2 Conversational AI for Mental Health

3.2 정신건강을 위한 대화형 AI

Heinz et al. (2025) reported the first randomized controlled trial of a fine-tuned generative AI chatbot (Therabot) for clinical-level mental health symptoms, with N=210 adults across major depressive disorder, generalized anxiety disorder, and clinically high-risk feeding and eating disorders. Effect sizes were large and engagement was high (mean 260 messages per user over 4 weeks). Wang et al. (2025) extended the evidence base to cognitive behavioral therapy chatbots for depression in Chinese university students. Reyes-Portillo et al. (2025) provide a meta-analytic synthesis. These trials establish the clinical viability of conversational AI but do not specify how conversational content should be safely bridged to a structured clinical record — a gap our ALG-4 addresses directly.

Heinz 등(2025)은 주요우울장애, 범불안장애, 임상적으로 고위험인 섭식장애 전반에 걸쳐 N=210명 성인을 대상으로 임상 수준 정신건강 증상에 대한 미세 조정된 생성형 AI 챗봇(Therabot)의 첫 번째 무작위 대조 시험을 보고했다. 효과 크기는 컸고 참여도는 높았다(4주에 걸쳐 사용자당 평균 260개 메시지). Wang 등(2025)은 중국 대학생의 우울증에 대한 인지행동치료 챗봇으로 증거 기반을 확장했다. Reyes-Portillo 등(2025)은 메타분석적 종합을 제공한다. 이러한 시험은 대화형 AI의 임상적 실행 가능성을 확립하지만, 대화 내용이 구조화된 임상 기록으로 어떻게 안전하게 연결되어야 하는지 명세하지 않는다—이는 우리의 ALG-4가 직접 다루는 격차이다.

3.3 Recommendation Systems in Healthcare

3.3 의료 분야의 추천 시스템

Lee et al. (2024) provide a recent npj Digital Medicine exemplar of a machine-learning CDSS that produces treatment recommendations with ranked alternatives and survival predictions for hepatocellular carcinoma. Sutton et al. (2020) review the broader CDSS landscape, identifying benefits (decision support, reduced errors) and risks (alert fatigue, automation bias). Wiens et al. (2019) articulate a "do no harm" roadmap for responsible ML in clinical contexts. Our recommendation engine (ALG-1) inherits the multi-component scoring tradition while extending it with explicit developmental and preference components calibrated for mental health.

Lee 등(2024)은 간세포암에 대한 순위가 매겨진 대안과 생존 예측을 갖춘 치료 추천을 생성하는 머신러닝 CDSS 의 최근 npj Digital Medicine 예시를 제공한다. Sutton 등(2020)은 더 광범위한 CDSS 환경을 검토하면서 이점(의사결정 지원, 오류 감소)과 위험(경고 피로, 자동화 편향)을 식별한다. Wiens 등(2019)은 임상 맥락에서 책임 있는 ML 을 위한 "해를 끼치지 말라" 로드맵을 명확히 한다. 우리의 추천 엔진(ALG-1)은 다중 구성요소 점수 산정 전통을 계승하면서 정신건강을 위해 보정된 명시적 발달 및 선호 구성요소로 확장한다.

3.4 Adaptive Treatment Strategies

3.4 적응형 치료 전략

Murphy's (2005) SMART (Sequential Multiple Assignment Randomized Trial) framework formalizes the multi-stage decision problem of adaptive treatment. Almirall et al. (2014) extend SMART to behavioral interventions including weight loss; Nahum-Shani et al. (2018) elaborate just-in-time adaptive interventions for mobile health. While SMART trials specify the empirical methodology for discovering adaptive strategies, they do not prescribe the data architecture for operationalizing such strategies in a production platform. ALG-2 and ALG-3 together provide one such operationalization, integrating session-level planning with re-planning triggered by patient-side changes.

Murphy(2005)의 SMART(순차 다중 할당 무작위 시험) 프레임워크는 적응형 치료의 다단계 의사결정 문제를 공식화한다. Almirall 등(2014)은 체중 감량을 포함한 행동 중재로 SMART 를 확장하고, Nahum-Shani 등(2018)은 모바일 건강을 위한 적시 적응 중재를 정교화한다. SMART 시험이 적응 전략을 발견하기 위한 경험적 방법론을 명세하지만, 운영 플랫폼에서 그러한 전략을 운영화하기 위한 데이터 아키텍처를 처방하지는 않는다. ALG-2 와 ALG-3 은 함께 환자 측 변경에 의해 트리거되는 재계획과 세션 수준 계획을 통합하는 그러한 운영화 중 하나를 제공한다.

3.5 Fischer's Dynamic Skill Theory

3.5 Fischer 의 역동적 기술 이론

Fischer's (1980) dynamic skill theory, elaborated in Fischer and Bidell (2006) and Mascolo and Fischer (2015), posits that skills develop in a hierarchical sequence across four tiers (reflexes,

sensorimotor actions, representations, abstractions), with four levels per tier yielding a developmental yardstick. Skills are conceptualized as contextualized control structures rather than general abilities, and skill performance varies as a function of contextual support. We operationalize Fischer's framework in ALG-1 as a `fischer_compatibility` component (matching training entry level to estimated current level) and in ALG-2 as a session-by-session progression schedule. This is, to our knowledge, the first explicit computational use of Fischer's framework in a deployed mental health platform.

Fischer(1980)의 역동적 기술 이론은 Fischer 와 Bidell(2006) 및 Mascolo 와 Fischer(2015)에서 정교화되어, 기술이 4 개 계층(반사, 감각운동 행동, 표상, 추상화)에 걸쳐 계층적 순서로 발달하며, 계층당 4 개 수준이 발달 척도를 산출한다고 주장한다. 기술은 일반 능력이 아닌 맥락화된 통제 구조로 개념화되며 기술 수행은 맥락적 지원의 함수로서 변동한다. 우리는 Fischer 의 프레임워크를 ALG-1 에서 `fischer_compatibility` 구성요소(훈련 진입 수준을 추정된 현재 수준에 매칭)로, ALG-2 에서 세션별 진행 일정으로 운영화한다. 우리가 아는 한, 이는 배포된 정신건강 플랫폼에서 Fischer 프레임워크의 첫 번째 명시적 계산적 사용이다.

3.6 Privacy-Preserving Health Data Architecture

3.6 프라이버시 보존 건강 데이터 아키텍처

Voigt and von dem Bussche (2017) provide the standard practical guide to GDPR compliance, with particular emphasis on Article 9 (special category data, including health) and Article 22 (automated decision-making). Cohen and Mello (2018) examine HIPAA modernization in light of contemporary data flows. The privacy paradox we articulate in Section 2.3 maps to GDPR Article 9(2)(a)'s requirement for explicit consent prior to processing special category data, which is the legal basis for the opt-in default-off architecture in ALG-4.

Voigt 와 von dem Bussche(2017)는 9 조(건강을 포함한 특수 범주 데이터)와 22 조(자동화된 의사결정)에 특히 중점을 두면서 GDPR 준수에 대한 표준 실용 가이드를 제공한다. Cohen 과 Mello(2018)는 현대 데이터 흐름에 비추어 HIPAA 현대화를 검토한다. 우리가 2.3 절에서 명확히 한 프라이버시 역설은 특수 범주 데이터 처리 전 명시적 동의에 대한 GDPR 9 조 (2)(a) 요구사항에 매핑되며, 이는 ALG-4 의 옵트인 기본 OFF 아키텍처의 법적 근거이다.

3.7 Explainability and Audit in Clinical AI

3.7 임상 AI 에서의 설명 가능성과 감사

Doshi-Velez and Kim (2017) articulate the scientific foundations of interpretable ML; Tjoa and Guan (2021) survey explainable AI methods with explicit medical applications; Ghassemi et al. (2021) caution against over-reliance on post-hoc explanation in healthcare, arguing instead for transparent design from the outset. Wachter et al. (2017) examine the contested scope of a

GDPR-derived "right to explanation," while Goodman and Flaxman (2017) offer a more expansive reading. Our audit traceability layer (Section 12) embraces the transparent-by-design stance, persisting the substantive inputs to each recommendation rather than relying on post-hoc explanation methods.

Doshi-Velez 와 Kim(2017)은 해석 가능한 ML 의 과학적 기초를 명확히 한다; Tjoa 와 Guan(2021)은 명시적 의료 응용을 갖춘 설명 가능한 AI 방법을 조사한다; Ghassemi 등(2021)은 의료 분야에서 사후 설명에 대한 과도한 의존에 대해 경고하며, 처음부터 투명한 설계를 주장한다. Wachter 등(2017)은 GDPR 에서 파생된 "설명에 대한 권리"의 논쟁의 여지가 있는 범위를 검토하며, Goodman 과 Flaxman(2017)은 더 광범위한 해석을 제공한다. 우리의 감사 추적성 계층(12 절)은 사후 설명 방법에 의존하기보다는 각 추천에 대한 실질적 입력을 영구 저장함으로써 설계상 투명한 입장을 채택한다.

4. System Overview

4. 시스템 개요

Figure 1. Two-Module Architecture with Six-Algorithm Integration

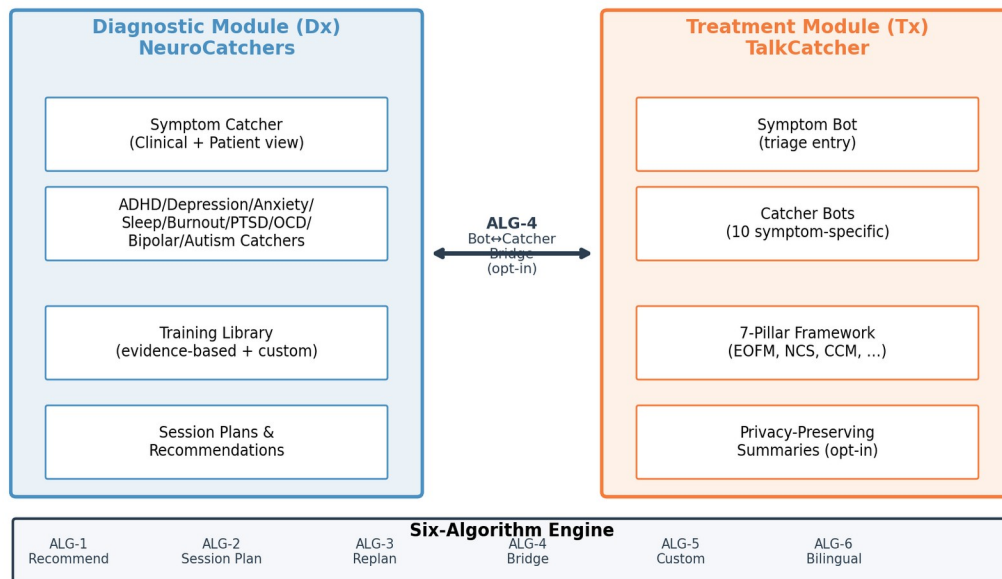


Figure 1. Two-module system architecture: NeuroCatchers (Diagnostic) and TalkCatcher (Treatment) linked by ALG-4 privacy-preserving bridge.

그림 1. 이중 모듈 시스템 아키텍처: NeuroCatchers(진단)와 TalkCatcher(치료)가 ALG-4 프라이버시 보존 브리지로 연결됨.

4.1 Two-Module Architecture: Diagnostic and Treatment

4.1 이중 모듈 아키텍처: 진단 및 치료

The platform is organized as two complementary modules (Figure 1). The Diagnostic Module (Dx), branded NeuroCatchers, provides structured clinical assessment via a top-level Symptom Catcher and ten symptom-specific Catchers (ADHD, depression, anxiety, sleep, burnout, post-traumatic stress disorder, obsessive-compulsive disorder, bipolar disorder, autism, and peak performance). Each Catcher contains an evidence-based training library and surfaces session plans and recommendations. The Treatment Module (Tx), branded TalkCatcher, provides conversational support via a Symptom Bot (triage entry) and ten Catcher Bots corresponding to the clinical symptom domains. The conversational module instantiates Boston Neuromind's seven-pillar framework, which includes the Emotion-Only Feedback Model (EOFM), the Narrative Co-Construction System (NCS), the Clinical Calibration Module (CCM), and four additional pillars not central to the present paper.

플랫폼은 두 개의 상보적 모듈로 조직된다(그림 1). NeuroCatchers 로 브랜딩된 진단 모듈(Dx)은 최상위 증상 캐처와 10 개 증상별 캐처(ADHD, 우울증, 불안, 수면, 번아웃, 외상후스트레스장애, 강박장애, 양극성장애, 자폐, 최고 수행)를 통해 구조화된 임상 평가를 제공한다. 각 캐처는 근거 기반 훈련 라이브러리를 포함하고 세션 계획과 추천을 노출한다. TalkCatcher 로 브랜딩된 치료 모듈(Tx)은 증상 봇(분류 진입)과 임상 증상 영역에 해당하는 10 개 캐처 봇을 통해 대화형 지원을 제공한다. 대화 모듈은 정서 전용 피드백 모델(EOFM), 서사 공동 구성 시스템(NCS), 임상 보정 모듈(CCM) 및 본 논문에서 중심적이지 않은 4 개의 추가 기둥을 포함하는 Boston Neuromind 의 7 기둥 프레임워크를 인스턴스화한다.

The two modules are connected by ALG-4, a privacy-preserving bridge that synchronizes bot-derived clinical signal into the diagnostic record only when the patient has explicitly opted in. This separation reflects the privacy paradox articulated in Section 2.3.

두 모듈은 환자가 명시적으로 옵트인한 경우에만 봇 파생 임상 신호를 진단 기록으로 동기화하는 프라이버시 보존 브리지인 ALG-4 로 연결된다. 이 분리는 2.3 절에서 명확히 한 프라이버시 역설을 반영한다.

4.2 Six-Algorithm Engine

4.2 6 개 알고리즘 엔진

Six algorithms collectively operationalize the assessment-to-treatment pathway and the bridge between modules. ALG-1 (Recommendation Engine) takes patient profile and candidate trainings as input and produces ranked recommendations with reasoning. ALG-2 (Session Plan Generator) takes a selected training and produces an N-session plan with Fischer-level progression. ALG-3 (Adaptive Replan) updates the plan in response to triggering events. ALG-4 (Bot ↔ Catcher Bridge) governs privacy-preserving synchronization. ALG-5 (Custom Training Builder) lets

clinicians or patients author novel training records that conform to the universal schema. ALG-6 (Bilingual Result Renderer) produces Korean and English versions of diagnostic outputs.

6 개 알고리즘은 평가-치료 경로와 모듈 간 브리지를 집합적으로 운영화한다. ALG-1(추천 엔진)은 환자 프로파일과 후보 훈련을 입력으로 받아 추천이 포함된 순위 추천을 생성한다. ALG-2(세션 계획 생성자)는 선택된 훈련을 받아 Fischer 수준 진행이 포함된 N 개 세션 계획을 생성한다. ALG-3(적응형 재계획)은 트리거 이벤트에 대응하여 계획을 업데이트한다. ALG-4(벗 ↔ 캐처 브리지)는 프라이버시 보존 동기화를 관장한다. ALG-5(맞춤형 훈련 빌더)는 임상가나 환자가 보편적 스키마에 부합하는 새로운 훈련 기록을 저장할 수 있게 한다. ALG-6(이중 언어 결과 렌더러)은 진단 출력의 한국어 및 영어 버전을 생성한다.

4.3 Universal Symptom-Domain Structure

4.3 보편적 증상 영역 구조

A core architectural commitment is universality across symptom domains. A single set of database tables, a single set of algorithms, and a single rendering pipeline serve all ten Catchers. Symptom-specific content is data, not code: the `training_library` table contains a `symptom_track` column that selects which trainings are visible for a given Catcher; the `contraindications` field encodes symptom-specific safety rules; the `quick_input_schema` specifies symptom-appropriate measurement instruments. We adopt ADHD as the Gold Template for initial development and validation, with the explicit intent that nine subsequent symptom domains be instantiated by populating data rather than writing code.

핵심 아키텍처 약속은 증상 영역 전반의 보편성이다. 단일 데이터베이스 테이블 세트, 단일 알고리즘 세트, 단일 렌더링 파이프라인이 10 개 캐처 모두를 담당한다. 증상별 콘텐츠는 코드가 아닌 데이터이다: `training_library` 테이블은 주어진 캐처에 대해 어떤 훈련이 보이는지 선택하는 `symptom_track` 열을 포함하고; `contraindications` 필드는 증상별 안전 규칙을 인코딩하며; `quick_input_schema` 는 증상에 적합한 측정 도구를 명세한다. 우리는 ADHD 를 초기 개발 및 검증을 위한 황금 템플릿으로 채택하며, 9 개의 후속 증상 영역이 코드 작성이 아닌 데이터 채우기로 인스턴스화되도록 하는 명시적 의도가 있다.

4.4 Privacy-First Design Principles

4.4 프라이버시 우선 설계 원칙

Five design principles govern the architecture. First, opt-in default-off semantics apply to all cross-module data flow. Second, consent is granular and withdrawable, consistent with GDPR Article 7. Third, audit traceability is a first-class output of every recommendation. Fourth, bilingual rendering is mandatory for diagnostic outputs to serve both Korean and English-speaking populations. Fifth, the architecture must accommodate both autonomous patient use and clinician-supervised use, with the same data structures supporting both modes.

5 가지 설계 원칙이 아키텍처를 관장한다. 첫째, 옵트인 기본 OFF 의미는 모든 모듈 간 데이터 흐름에 적용된다. 둘째, 동의는 세밀하고 철회 가능하며, GDPR 7 조와 일치한다. 셋째, 감사 추적성은 모든 추천의 일급 출력이다. 넷째, 이중 언어 렌더링은 한국어 및 영어 사용자 모두를 위한 진단 출력에 필수이다. 다섯째, 아키텍처는 자율적 환자 사용과 임상가 감독 사용을 모두 수용해야 하며, 동일한 데이터 구조가 두 모드를 모두 지원해야 한다.

5. Database Schema Design

5. 데이터베이스 스키마 설계

Figure 2. Core Database Schema — Entity Relationship Diagram

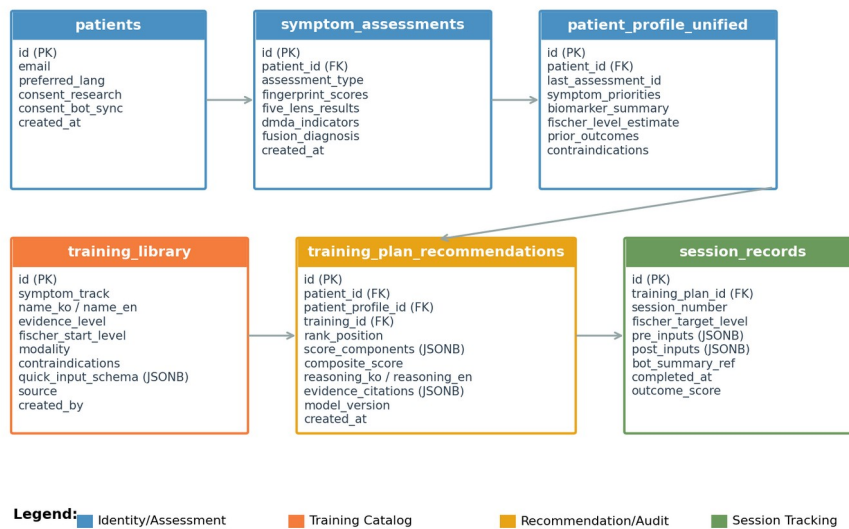


Figure 2. Entity-relationship diagram showing six core tables and their relationships.

그림 2. 6 개 핵심 테이블과 그 관계를 보여주는 엔티티-관계 다이어그램.

Table 1. Core database tables and relationships.

Table	Primary Purpose	Key Fields	Used By
patients	Identity and consent flags	id, language_pref, consent_research, consent_bot_sync	All algorithms
symptom_assessments	Raw assessment outputs	id, patient_id, fingerprint_jsonb, dmda_jsonb	ALG-6
patient_profile_unified	Synthesized profile for recommendation	symptom_priorities, biomarker_summary, fischer_level_estimate	ALG-1

Table	Primary Purpose	Key Fields	Used By
training_library	Curated intervention catalog	id, symptom_track, evidence_level, fischer_start_level, contraindications, quick_input_schema	ALG-1, ALG-2, ALG-5
training_plan_recommendations	Persisted recommendation audit	score_components, composite_score, reasoning_ko, reasoning_en, evidence_citations, model_version	ALG-1, audit layer
session_records	Per-session tracking	pre_input, post_input, bot_summary, completion_status	ALG-2, ALG-3, ALG-4

5.1 Core Entities and Relationships

5.1 핵심 엔터티와 관계

The schema comprises six core tables (Figure 2). The patients table holds identity, language preference, and consent flags including consent_research and consent_bot_sync. The symptom_assessments table stores results from clinical instruments, organized as JSONB columns for the Fingerprint Engine output, Five-Lens scores, Differential Mental Disorder Algorithm (DMDA) indicators, and the fused diagnostic profile. The patient_profile_unified table consolidates the most recent assessment with a synthesized symptom priority vector, biomarker summary, an estimated Fischer skill level, and contraindication flags; this table is the primary input to ALG-1.

스키마는 6 개의 핵심 테이블로 구성된다(그림 2). patients 테이블은 정체성, 언어 선호도, consent_research 및 consent_bot_sync 를 포함한 동의 플래그를 보유한다. symptom_assessments 테이블은 임상 도구의 결과를 저장하며, Fingerprint Engine 출력, Five-Lens 점수, 감별 정신장애 알고리즘(DMDA) 지표, 융합된 진단 프로파일을 위한 JSONB 열로 구성된다. patient_profile_unified 테이블은 가장 최근의 평가를 합성된 증상 우선순위 벡터, 바이오마커 요약, 추정된 Fischer 기술 수준, 금기 플래그와 통합한다; 이 테이블은 ALG-1 에 대한 주요 입력이다.

The training_library table catalogs evidence-based interventions (Section 6). The training_plan_recommendations table persists every ALG-1 output with full score decomposition and reasoning. The session_records table tracks per-session activity, including pre-session and post-session quick inputs and optional bot summary references.

training_library 테이블은 근거 기반 중재를 카탈로그화한다(6 절). training_plan_recommendations 테이블은 모든 ALG-1 출력을 전체 점수 분해 및 추론과 함께 영구 저장한다. session_records 테이블은 세션 전후 빠른 입력 및 선택적 봇 요약 참조를 포함하여 세션별 활동을 추적한다.

5.2 The patient_profile_unified Table as Recommendation Input

5.2 추천 입력으로서 patient_profile_unified 테이블

A central design choice is the consolidation of heterogeneous assessment outputs into a single unified profile that serves as the input to recommendation. The unified profile contains: symptom_priorities (a normalized vector indicating relative weighting across symptom domains), biomarker_summary (where electroencephalographic or other physiological data is available), fischer_level_estimate (the patient's estimated current developmental level), prior_outcomes (historical engagement, dropout, and outcome data), and contraindications (a set of flags barring certain interventions). This consolidation enables ALG-1 to operate against a stable, well-defined input rather than navigating raw assessment data.

중심적 설계 선택은 이질적 평가 출력을 추천에 대한 입력 역할을 하는 단일 통합 프로파일로 통합하는 것이다. 통합 프로파일은 다음을 포함한다: symptom_priorities(증상 영역 간 상대적 가중치를 나타내는 정규화 벡터), biomarker_summary(뇌전도 또는 기타 생리학 적 데이터가 가용한 경우), fischer_level_estimate(환자의 추정된 현재 발달 수준), prior_outcomes(과거 참여, 중도 이탈, 결과 데이터), contraindications(특정 중재를 차단하는 플래그 세트). 이 통합은 ALG-1 이 원시 평가 데이터를 탐색하기보다 안정적이고 잘 정의된 입력에 대해 작동할 수 있게 한다.

5.3 The training_library Table: Evidence Tier and Schema

5.3 training_library 테이블: 근거 등급 및 스키마

Each row in training_library represents one therapeutic intervention. Critical columns include: id, symptom_track (which Catcher surfaces this training), name_ko and name_en, evidence_level (one of rct, meta_analysis, consensus_guideline, expert_opinion, custom), fischer_start_level (the developmental entry point), modality (cognitive, behavioral, somatic, neurofeedback, exposure, mindfulness, psychoeducation), contraindications (JSONB), quick_input_schema (JSONB specifying per-session measurement instruments), and source (which clinician or organization curated the entry). The dual evidence_level + custom design allows curated, vetted entries to coexist with clinician-authored bespoke trainings without compromising the recommendation engine's evidence-strength scoring.

training_library 의 각 행은 하나의 치료 중재를 나타낸다. 핵심 열에는 다음이 포함된다: id, symptom_track(어떤 캐처가 이 훈련을 노출하는지), name_ko 및 name_en, evidence_level(rct, meta_analysis, consensus_guideline, expert_opinion, custom 중 하나), fischer_start_level(발달

진입점), modality(인지적, 행동적, 신체적, 뉴로피드백, 노출, 마음챙김, 심리교육), contraindications(JSONB), quick_input_schema(세션별 측정 도구를 명세하는 JSONB), source(어떤 임상가 또는 조직이 항목을 큐레이션했는지). 이중 evidence_level + custom 설계는 큐레이션되고 검증된 항목이 추천 엔진의 근거 강도 점수 산정을 손상시키지 않으면서 임상가 저작 맞춤형 훈련과 공존할 수 있도록 한다.

5.4 Recommendation Reasoning Persistence

5.4 추천 추론 영구 저장

Every ALG-1 invocation writes one or more rows to training_plan_recommendations. Critical fields include score_components (JSONB containing all six component scores with their sub-components and methods), composite_score (the final weighted total), reasoning_ko and reasoning_en (human-readable explanations in both languages), evidence_citations (JSONB array of PubMed identifiers or digital object identifiers with the specific claims they support), contraindications_considered (which patient flags were evaluated and how), and model_version (the identifier of the scoring model that produced this recommendation). The model_version field is essential for longitudinal audit: as the engine learns and is updated, all historical recommendations remain interpretable in the context of the model that generated them.

모든 ALG-1 호출은 하나 이상의 행을 training_plan_recommendations 에 기록한다. 핵심 필드에는 다음이 포함된다: score_components(하위 구성요소 및 방법과 함께 6개 구성요소 점수를 모두 포함하는 JSONB), composite_score(최종 가중 합계), reasoning_ko 및 reasoning_en(양 언어로 된 사람이 읽을 수 있는 설명), evidence_citations(이를 지원하는 특정 주장과 함께 PubMed 식별자 또는 디지털 객체 식별자의 JSONB 배열), contraindications_considered(어떤 환자 플래그가 평가되었고 어떻게), model_version(이 추천을 생성한 점수 산정 모델의 식별자). model_version 필드는 종단 감사에 필수적이다: 엔진이 학습되고 업데이트됨에 따라 모든 과거 추천은 이를 생성한 모델의 맥락에서 해석 가능하게 유지된다.

5.5 Bot-Catcher Synchronization Schema

5.5 봇-캐처 동기화 스키마

When consent_bot_sync is TRUE, ALG-4 writes per-session summaries into session_records.bot_summary, a JSONB field with a fixed schema: mood_trend (rolling average over a configurable window), reported_symptoms (an array of clinically relevant signals extracted from conversation), life_events (significant events the user disclosed, such as moves or job changes), and adherence_self_report (the user's stated engagement with prescribed activities). The schema is intentionally narrow to support clinical decision-making while minimizing unnecessary data flow.

consent_bot_sync 가 TRUE 일 때, ALG-4 는 세션별 요약을 session_records.bot_summary 에 기록한다. 이는 고정 스키마를 갖는 JSONB 필드이다: mood_trend(구성 가능한 창에 대한 이동 평균), reported_symptoms(대화에서 추출된 임상적으로 관련된 신호의 배열), life_events(이사나 직업 변경과 같이 사용자가 공개한 중요한 사건), adherence_self_report(처방된 활동에 대한 사용자의 명시된 참여). 스키마는 임상 의사결정을 지원하면서 불필요한 데이터 흐름을 최소화하기 위해 의도적으로 좁다.

6. Algorithm 1: Recommendation Engine

6. 알고리즘 1: 추천 엔진

6.1 Input and Hard Filters

6.1 입력 및 하드 필터

ALG-1 accepts as input a row from patient_profile_unified and the subset of training_library entries whose symptom_track matches the active Catcher. Before scoring, hard filters apply: any training whose contraindications array intersects the patient's contraindication flags is removed from the candidate set. Hard filters are not weighted; they categorically exclude trainings that are clinically inappropriate for the specific patient. Examples include medication interactions (a stimulant-based protocol is filtered when the patient flags a contraindicated cardiac condition), comorbidity exclusions (an exposure protocol for OCD is filtered when active psychosis is flagged), and developmental floor (a high-Fischer-level training is filtered when the patient's estimated level falls below the training's fischer_start_level minus an admissible gap).

ALG-1 은 patient_profile_unified 의 행과 symptom_track 이 활성 캐처와 일치하는 training_library 항목의 부분집합을 입력으로 받는다. 점수 산정 전, 하드 필터가 적용된다: contraindications 배열이 환자의 금기 플래그와 교차하는 모든 훈련은 후보 집합에서 제거된다. 하드 필터는 가중되지 않으며; 특정 환자에게 임상적으로 부적절한 훈련을 범주적으로 배제한다. 예에는 약물 상호작용(환자가 금기 심장 상태를 플래그할 때 자극제 기반 프로토콜이 필터링됨), 동반이환 배제(활동성 정신증이 플래그될 때 OCD 에 대한 노출 프로토콜이 필터링됨), 발달 하한선(환자의 추정 수준이 훈련의 fischer_start_level 에서 허용 격차를 뺀 값보다 낮을 때 높은 Fischer 수준 훈련이 필터링됨)이 포함된다.

6.2 Six-Component Scoring Function

6.2 6 개 구성요소 점수 산정 함수

Surviving candidates are scored across six components (Figure 3, Table 2). The symptom_match component computes a weighted cosine similarity between the patient's symptom_priorities vector and the training's symptom_target_vector. The biomarker_match component, applicable when biomarker_summary is populated, computes a Z-score-weighted alignment between patient biomarker signature and training's biomarker_target_pattern. The evidence_strength component

normalizes Cochrane d (or analogous effect size) from the training's source evidence; meta-analytic effect sizes receive higher weight than single-trial estimates, and consensus-guideline trainings receive a calibrated baseline.

살아남은 후보는 6 개 구성요소에 걸쳐 점수가 매겨진다(그림 3, 표 2). symptom_match 구성요소는 환자의 symptom_priorities 벡터와 훈련의 symptom_target_vector 사이의 가중 코사인 유사도를 계산한다. biomarker_summary 가 채워진 경우 적용 가능한 biomarker_match 구성요소는 환자 바이오마커 서명과 훈련의 biomarker_target_pattern 사이의 Z 점수 가중 정렬을 계산한다. evidence_strength 구성요소는 훈련의 원천 근거에서 Cochrane d(또는 유사한 효과 크기)를 정규화한다. 메타분석적 효과 크기는 단일 시험 추정치보다 높은 가중치를 받으며, 합의 지침 훈련은 보정된 기준선을 받는다.

The fischer_compatibility component scores the match between the patient's fischer_level_estimate and the training's fischer_start_level, with maximum score at exact match and graceful degradation for gaps. The practical_fit component aggregates modality preferences, time-availability constraints, and cost factors. The personal_history component rewards trainings related to prior successes and penalizes trainings related to prior dropouts. Each component yields a score in the unit interval [0, 1] with a documented derivation method.

fischer_compatibility 구성요소는 환자의 fischer_level_estimate 와 훈련의 fischer_start_level 사이의 일치율을 점수화하며, 정확한 일치에서 최대 점수와 격차에 대한 점진적 감소를 보인다. practical_fit 구성요소는 양상 선호도, 시간 가용성 제약, 비용 요인을 통합한다. personal_history 구성요소는 이전 성공과 관련된 훈련에 보상을 주고 이전 중도 이탈과 관련된 훈련에 페널티를 부여한다. 각 구성요소는 문서화된 도출 방법으로 단위 구간 [0, 1]의 점수를 산출한다.

6.3 Composite Scoring and Ranking

6.3 종합 점수 및 순위 매기기

The composite_score is computed as a weighted sum of the six component scores. Default weights are derived from clinician consultation and may be adjusted per symptom track. Candidates are ranked by descending composite_score, and the top three are presented as primary recommendations; the fourth through tenth are retained as alternates and surfaced upon user request. The composite weights themselves are stored in the model_version metadata to support audit.

composite_score 는 6 개 구성요소 점수의 가중 합으로 계산된다. 기본 가중치는 임상가 상담에서 도출되며 증상 트랙별로 조정될 수 있다. 후보는 내림차순 composite_score 로 순위가 매겨지며, 상위 3 개는 주요 추천으로 제시되고; 4 번째부터 10 번째는 대안으로 유지되어 사용자 요청 시 노출된다. 종합 가중치 자체는 감사를 지원하기 위해 model_version 메타데이터에 저장된다.

6.4 Reasoning Generation

6.4 추론 생성

For each ranked candidate, ALG-1 generates Korean and English reasoning text via a template-plus-large-language-model-polish pipeline. Templates are written by clinicians and include placeholders for the patient's salient features (e.g., "Given your reported priority of attention regulation and your estimated developmental level of sm3..."). The LLM polish step ensures tonal coherence and natural phrasing while preserving the factual content from the template. Generated reasoning is constrained never to fabricate evidence citations; only PMIDs and DOIs that were present in the source training's `evidence_citations` field may appear in the rendered reasoning.

각 순위 후보에 대해 ALG-1은 템플릿 + 대규모 언어 모델 다듬기 파이프라인을 통해 한국어 및 영어 추론 텍스트를 생성한다. 템플릿은 임상가가 작성하며 환자의 두드러진 특징에 대한 자리표시자를 포함한다(예: "주의력 조절의 보고된 우선순위와 sm3의 추정 발달 수준을 고려하면..."). LLM 다듬기 단계는 템플릿의 사실적 내용을 보존하면서 어조 일관성과 자연스러운 표현을 보장한다. 생성된 추론은 근거 인용을 절대 조작하지 않도록 제약된다; 원천 훈련의 `evidence_citations` 필드에 존재했던 PMID와 DOI만이 렌더링된 추론에 나타날 수 있다.

6.5 Cold-Start Handling

6.5 콜드 스타트 처리

When a patient has no prior history (cold-start), the `personal_history` component defaults to a neutral 0.5 and the composite weight on this component is temporarily redistributed across the remaining five components. Similarly, when `biomarker_summary` is empty, `biomarker_match` is omitted and its weight is redistributed. The redistributions are recorded in `score_components` so that comparative analyses across cohorts can correctly account for the data available at each recommendation.

환자가 이전 이력이 없는 경우(콜드 스타트), `personal_history` 구성요소는 기본적으로 중립 0.5이며 이 구성요소에 대한 종합 가중치는 나머지 5개 구성요소에 일시적으로 재분배된다. 마찬가지로 `biomarker_summary`가 비어 있는 경우 `biomarker_match`가 생략되고 그 가중치가 재분배된다. 재분배는 `score_components`에 기록되어 코호트 간 비교 분석이 각 추천에서 가용한 데이터를 올바르게 고려할 수 있도록 한다.

6.6 Example: ADHD Recommendation Output

6.6 예시: ADHD 추천 출력

Table 3 illustrates a sample output for an adult ADHD patient with mild inattention symptoms, no biomarker data, and an estimated Fischer level of sm3. The first-ranked recommendation is a focused-attention neurofeedback protocol with `composite_score` 0.89, supported by Arns et al.

(2009) and Van Doren et al. (2019). The second is a Pomodoro-based behavioral protocol (composite_score 0.84). The third is a mindfulness-based attention training (composite_score 0.81). Each is accompanied by Korean and English reasoning text and the relevant evidence citations.

표 3 은 경미한 부주의 증상, 바이오마커 데이터 없음, sm3 의 추정 Fischer 수준을 가진 성인 ADHD 환자에 대한 샘플 출력을 보여준다. 1 순위 추천은 composite_score 0.89 인 집중 주의 뉴로피드백 프로토콜로, Arns 등(2009)과 Van Doren 등(2019)이 지원한다. 2 순위는 포모도로 기반 행동 프로토콜 (composite_score 0.84)이다. 3 순위는 마음챙김 기반 주의 훈련(composite_score 0.81)이다. 각각은 한국어 및 영어 추론 텍스트와 관련 근거 인용을 동반한다.

7. Algorithm 2: Session Plan Generator

7. 알고리즘 2: 세션 계획 생성자

7.1 Input and Fischer-Level Progression

7.1 입력 및 Fischer 수준 진행

ALG-2 accepts a selected training_library row, an N_sessions count chosen by the patient or clinician, and the patient's current fischer_level_estimate. It produces an ordered sequence of N session specifications, with Fischer level progressing from the training's start level to an end level appropriate to the patient's developmental trajectory and the training's structure (Figure 4, Table 4).

ALG-2 는 선택된 training_library 행, 환자나 임상가가 선택한 N_sessions 수, 환자의 현재 fischer_level_estimate 를 입력으로 받는다. Fischer 수준이 훈련의 시작 수준에서 환자의 발달 궤적과 훈련의 구조에 적합한 종료 수준으로 진행되는 N 개 세션 명세의 순서화된 시퀀스를 생성한다(그림 4, 표 4).

The progression algorithm respects Fischer's tier boundaries: transitions within a tier (sensorimotor, representational, abstract) occur more rapidly than tier-crossing transitions, which require additional consolidation sessions. The algorithm draws on Fischer and Bidell's (2006) characterization of skill construction as recurrent rather than strictly linear: practice at a given level consolidates and stabilizes the skill before progression.

진행 알고리즘은 Fischer 의 계층 경계를 존중한다: 계층 내 전환(감각운동, 표상, 추상)은 계층 횡단 전환보다 빠르게 발생하며, 후자는 추가 통합 세션을 필요로 한다. 알고리즘은 기술 구성이 엄격히 선형적이지 않고 반복적이라는 Fischer 와 Bidell(2006)의 특성화에 의존한다: 주어진 수준에서의 연습은 진행 전에 기술을 통합하고 안정화한다.

7.2 Per-Session Content Generation

7.2 세션별 콘텐츠 생성

For each session, ALG-2 generates a content specification including: target Fischer level, target skill, activity description, expected duration, and the quick_input_schema instantiation that the patient will complete pre- and post-session. The quick_input_schema is inherited from the training_library row but parameterized to the session's specific focus. For example, an ADHD focused-attention training might use a 0-10 slider for pre-session focus rating, an integer count for tasks completed during the session, and a 0-10 slider for post-session focus rating; these labels are localized to Korean or English based on patient preference.

각 세션에 대해 ALG-2 는 목표 Fischer 수준, 목표 기술, 활동 설명, 예상 지속 시간, 환자가 세션 전후에 완료할 quick_input_schema 인스턴스화를 포함하는 콘텐츠 명세를 생성한다. quick_input_schema 는 training_library 행에서 상속되지만 세션의 특정 초점에 맞게 매개변수화된다. 예를 들어, ADHD 집중 주의 훈련은 세션 전 집중도 평가에 0-10 슬라이더, 세션 동안 완료된 작업에 정수 카운트, 세션 후 집중도 평가에 0-10 슬라이더를 사용할 수 있다; 이러한 레이블은 환자 선호에 따라 한국어 또는 영어로 현지화된다.

7.3 30-Second Session Entry Design

7.3 30 초 세션 입력 설계

A key design constraint is that per-session data entry must be completable within thirty seconds. Adherence to digital interventions degrades rapidly when input burden exceeds this threshold (Baumel et al., 2019; Fleming et al., 2018). The quick_input_schema is consequently restricted to a maximum of four fields per session, each of which uses one of four primitive input types (slider, integer, boolean, time). Free-text entry is optional and never required for plan continuation.

핵심 설계 제약은 세션별 데이터 입력이 30 초 이내에 완료 가능해야 한다는 것이다. 입력 부담이 이 임계값을 초과하면 디지털 중재 순응도가 빠르게 저하된다(Baumel et al., 2019; Fleming et al., 2018). 따라서 quick_input_schema 는 세션당 최대 4 개 필드로 제한되며, 각 필드는 4 개 원시 입력 유형(슬라이더, 정수, 부울, 시간) 중 하나를 사용한다. 자유 텍스트 입력은 선택적이며 계획 계속을 위해 결코 필수가 아니다.

8. Algorithm 3: Adaptive Replan

8. 알고리즘 3: 적응형 재계획

8.1 Trigger Conditions

8.1 트리거 조건

ALG-3 fires in response to three classes of triggers (Figure 5). First, an explicit user or clinician action that changes the session count, modifies the primary goal, or selects a different training from the alternates ranked by ALG-1. Second, a dropout signal: missed sessions beyond a configurable threshold (default: two consecutive misses), or a deterioration in pre/post outcome scores beyond a configurable tolerance. Third, a periodic review at a configurable cadence (default: every six sessions) that re-evaluates the plan against the patient's updated profile.

ALG-3은 세 가지 트리거 클래스에 대응하여 발화한다(그림 5). 첫째, 세션 수를 변경하거나, 주요 목표를 수정하거나, ALG-1 이 순위 매긴 대안에서 다른 훈련을 선택하는 명시적 사용자 또는 임상가 행동. 둘째, 중도 이탈 신호: 구성 가능한 임계값을 초과하는 결석 세션(기본: 연속 2회 결석), 또는 구성 가능한 허용 범위를 초과하는 세션 전후 결과 점수의 악화. 셋째, 환자의 업데이트된 프로파일에 대해 계획을 재평가하는 구성 가능한 주기에서의 정기 검토(기본: 6 세션마다).

8.2 Plan Diff and History Preservation

8.2 계획 diff 및 이력 보존

When ALG-3 fires, it does not modify the existing plan in place; instead, it records a plan_modification row with a diff between the prior plan and the new plan, then writes a new plan. This preserves the complete history of the patient's treatment trajectory, supporting both clinical reflection and longitudinal analysis. Historical plans remain queryable indefinitely.

ALG-3 이 발화할 때, 기존 계획을 제자리에서 수정하지 않는다; 대신 이전 계획과 새 계획 사이의 diff와 함께 plan_modification 행을 기록한 다음 새 계획을 작성한다. 이는 환자의 치료 궤적의 완전한 이력을 보존하여 임상적 성찰과 중단 분석 모두를 지원한다. 과거 계획은 무기한 쿼리 가능하게 유지된다.

8.3 Reasoning Regeneration

8.3 추론 재생성

Each replan invocation regenerates the bilingual reasoning text via the same template + LLM polish pipeline used by ALG-1, with the addition of an explicit "what changed and why" narrative. The narrative cites the trigger (e.g., "extended from 10 to 12 sessions at the patient's request" or "alternative training selected due to two consecutive missed sessions of the prior plan") and the relevant updated profile components.

각 재계획 호출은 ALG-1 이 사용하는 동일한 템플릿 + LLM 다듬기 파이프라인을 통해 이중 언어 추론 텍스트를 재생성하며, 명시적 "무엇이 변경되었고 왜" 서사를 추가한다. 서사는 트리거(예: "환자 요청에 따라 10에서 12 세션으로 연장됨" 또는 "이전 계획의 연속 2회 결석으로 인해 대안 훈련 선택됨")와 관련 업데이트된 프로파일 구성요소를 인용한다.

9. Algorithm 4: Privacy-Preserving Bot ↔ Catcher Bridge

9. 알고리즘 4: 프라이버시 보존 봇 ↔ 캐처 브리지

9.1 The Privacy Paradox in Integrated Platforms

9.1 통합 플랫폼의 프라이버시 역설

As articulated in Section 2.3, the integration of conversational agents with clinical assessment modules confronts a privacy paradox: bot-derived clinical signal is valuable, yet unconsented sharing damages the trust premise on which conversational disclosure rests. The choice between full integration (high clinical utility, low privacy protection) and full separation (high privacy protection, low clinical utility) is a false dichotomy. ALG-4 implements a third option: explicit, granular, withdrawable opt-in with a default-off baseline.

2.3 절에서 명확히 한 바와 같이, 대화형 에이전트와 임상 평가 모듈의 통합은 프라이버시 역설에 직면한다. 봇 파생 임상 신호는 가치 있으나, 동의되지 않은 공유는 대화형 공개가 기반을 두는 신뢰 전제를 훼손한다. 완전한 통합(높은 임상 효용, 낮은 프라이버시 보호)과 완전한 분리(높은 프라이버시 보호, 낮은 임상 효용) 사이의 선택은 잘못된 이분법이다. ALG-4 는 세 번째 옵션을 구현한다: 기본 OFF 기준선을 갖춘 명시적이고, 세밀하며, 철회 가능한 옵트인.

9.2 Opt-In Architecture

9.2 옵트인 아키텍처

The `patients.consent_bot_sync` flag governs synchronization (Figure 6). Its default value at account creation is `FALSE`. The flag may be toggled by the patient at any time through the privacy settings interface; toggling to `FALSE` immediately halts further synchronization but does not retroactively delete previously synchronized summaries (which are subject to standard data deletion requests under GDPR Article 17 and HIPAA right-of-access provisions). When a clinician is involved in the patient's care, the clinician may request that the patient enable sync, but the patient retains sole authority over the flag's value, in conformity with GDPR Article 9(2)(a)'s explicit consent requirement for special category data.

`patients.consent_bot_sync` 플래그는 동기화를 권장한다(그림 6). 계정 생성 시 기본값은 `FALSE` 이다. 플래그는 프라이버시 설정 인터페이스를 통해 환자가 언제든지 토글할 수 있다; `FALSE` 로 토글하면 추가 동기화는 즉시 중단되지만 이전에 동기화된 요약물 소급하여 삭제하지는 않는다(이는 GDPR 17 조 및 HIPAA 접근권 조항에 따른 표준 데이터 삭제 요청 대상이다). 임상가가 환자 치료에 관여할 때, 임상가는 환자에게 동기화를 활성화하도록 요청할 수 있으나, 환자는 GDPR 9 조 (2)(a)의 특수 범주 데이터에 대한 명시적 동의 요구사항과 일치하여 플래그 값에 대한 단독 권한을 유지한다.

9.3 Summary Extraction Pipeline

9.3 요약 추출 파이프라인

When sync is enabled, the bot's conversation history is processed at session end (or, for batch operation, daily) through a retrieval-augmented generation pipeline anchored to a curated clinical vocabulary. The pipeline extracts content matching the bot_summary schema (Section 5.5) and discards content outside this schema. Critically, the raw conversation log is never written to the diagnostic record; only the schema-conformant extraction is transferred. This minimizes data flow consistent with GDPR Article 5(1)(c) data minimization.

동기화가 활성화되면, 봇의 대화 이력은 세션 종료 시(또는 일괄 운영의 경우 매일) 큐레이션된 임상 어휘에 고정된 검색 증강 생성 파이프라인을 통해 처리된다. 파이프라인은 bot_summary 스키마(5.5 절)와 일치하는 콘텐츠를 추출하고 이 스키마 외부의 콘텐츠는 폐기한다. 결정적으로, 원시 대화 로그는 진단 기록에 결코 기록되지 않는다; 스키마 부합 추출만 전송된다. 이는 GDPR 5 조 (1)(c) 데이터 최소화와 일치하여 데이터 흐름을 최소화한다.

9.4 Therapist Visibility Controls

9.4 치료사 가시성 통제

Within the diagnostic record, bot_summary fields are subject to standard therapist access controls. Patients may further restrict specific bot_summary fields from therapist view (e.g., concealing life_events while permitting mood_trend); these field-level restrictions are recorded in an access_policy JSONB column on the session_records row. All accesses to bot_summary are logged for audit.

진단 기록 내에서, bot_summary 필드는 표준 치료사 접근 통제의 대상이다. 환자는 치료사 보기에서 특정 bot_summary 필드를 추가로 제한할 수 있다(예: mood_trend 를 허용하면서 life_events 숨기기); 이러한 필드 수준 제한은 session_records 행의 access_policy JSONB 열에 기록된다. bot_summary 에 대한 모든 접근은 감사를 위해 기록된다.

10. Algorithm 5: Custom Training Builder

10. 알고리즘 5: 맞춤형 훈련 빌더

10.1 Clinician and Client Input UI

10.1 임상가 및 내담자 입력 UI

Clinicians frequently develop bespoke protocols for individual patients (e.g., a graded exposure plan for a specific OCD ritual; a personalized morning routine for executive function support). ALG-5 supports authoring such trainings through an eight-field UI (Figure 7): symptom track, target behavior, category, two measurement specifications (each selecting from a constrained

dropdown), recommended sessions, per-session minutes, and visibility (clinician-only versus private). Free-form JSON authoring is explicitly disallowed; the constrained UI ensures that custom trainings conform to the universal schema and remain compatible with ALG-1 scoring.

임상가는 개별 환자를 위한 맞춤형 프로토콜을 자주 개발한다(예: 특정 OCD 의식에 대한 점진적 노출 계획 실행 기능 지원을 위한 개인화된 아침 루틴). ALG-5는 8개 필드 UI를 통해 그러한 훈련 저작을 지원한다(그림 7): 증상 트랙, 목표 행동, 범주, 두 개의 측정 명세(각각 제약된 드롭다운에서 선택), 권장 세션, 세션당 분, 가시성(임상가 전용 대 비공개). 자유 형식 JSON 저작은 명시적으로 금지된다; 제약된 UI는 맞춤형 훈련이 보편적 스키마에 부합하고 ALG-1 점수 산정과 호환되도록 보장한다.

10.2 AI-Assisted Refinement

10.2 AI 지원 다듬기

An optional "Refine with AI" action invokes a language model to: generate a clinically appropriate description, propose contraindications drawn from the symptom track's standard contraindication library, and surface similar existing trainings for the author's reference. The author retains full editorial control over the AI-generated content. All AI-generated text is flagged in the source field of the training_library row.

선택적 "AI로 다듬기" 작업은 다음을 위해 언어 모델을 호출한다: 임상적으로 적절한 설명 생성, 증상 트랙의 표준 금기 라이브러리에서 도출된 금기 제안, 저자의 참조를 위한 유사한 기존 훈련 노출. 저자는 AI 생성 콘텐츠에 대한 완전한 편집 통제권을 유지한다. 모든 AI 생성 텍스트는 training_library 행의 source 필드에 플래그된다.

10.3 Validation and Storage

10.3 검증 및 저장

Before insertion, validation checks: (a) all required fields are populated, (b) the contraindications do not conflict with the symptom track's mandatory inclusions, (c) the quick_input_schema yields valid input types. Custom trainings are stored with evidence_level = 'custom' and source recording the authoring clinician or client. They are eligible for ALG-1 scoring with a calibrated evidence_strength baseline below that of meta-analytically supported trainings.

삽입 전, 검증은 다음을 확인한다: (a) 모든 필수 필드가 채워졌는지, (b) contraindications가 증상 트랙의 필수 포함과 충돌하지 않는지, (c) quick_input_schema가 유효한 입력 유형을 산출하는지. 맞춤형 훈련은 evidence_level = 'custom'으로 저장되며 source는 저작 임상가 또는 내담자를 기록한다. 그것들은 메타분석적으로 지원되는 훈련보다 낮은 보정된 evidence_strength 기준선으로 ALG-1 점수 산정 자격이 있다.

11. Algorithm 6: Bilingual Result Renderer

11. 알고리즘 6: 이중 언어 결과 렌더러

11.1 Two Output Paths for Diagnostic Results

11.1 진단 결과를 위한 두 가지 출력 경로

Symptom Catcher outputs are rendered in two parallel versions: a clinical version employing DSM/ICD codes, Z-scores, and neurological interpretation, and a patient version employing everyday language, metaphor, and encouragement (Figure 8). Symptom Bot outputs, by contrast, are rendered in a single unified version: the bot's communication context makes the clinical/patient distinction less meaningful, and the bot's tone calibration is already constrained by ALG-6's parameters.

증상 캐처 출력은 두 가지 병렬 버전으로 렌더링된다: DSM/ICD 코드, Z 점수, 신경학적 해석을 사용하는 임상 버전과 일상 언어, 은유, 격려를 사용하는 환자 버전(그림 8). 대조적으로, 증상 봇 출력은 단일 통합 버전으로 렌더링된다: 봇의 의사소통 맥락은 임상/환자 구분을 덜 의미 있게 만들며, 봇의 어조 보정은 이미 ALG-6의 매개변수에 의해 제약된다.

11.2 Template Plus LLM Polish Pipeline

11.2 템플릿 + LLM 다듬기 파이프라인

Both paths use a template + LLM polish pipeline analogous to ALG-1's reasoning generation. Templates encode the structural elements (which findings are reported, in what order, with what emphasis); the LLM polish step calibrates tone and ensures natural phrasing in each language. Tone calibration parameters vary by output: clinical version uses precise, professional register; patient version uses warm, encouraging register; bot version balances accessibility with diagnostic substance.

두 경로 모두 ALG-1의 추론 생성과 유사한 템플릿 + LLM 다듬기 파이프라인을 사용한다. 템플릿은 구조적 요소를 인코딩한다(어떤 발견이 어떤 순서로 어떤 강조로 보고되는지); LLM 다듬기 단계는 어조를 보정하고 각 언어의 자연스러운 표현을 보장한다. 어조 보정 매개변수는 출력에 따라 다르다. 임상 버전은 정확하고 전문적인 어조를 사용하며; 환자 버전은 따뜻하고 격려하는 어조를 사용하고; 봇 버전은 접근성과 진단 본질의 균형을 맞춘다.

11.3 Korean-English Parallel Rendering

11.3 한국어-영어 병렬 렌더링

Both languages are rendered in parallel rather than via post-hoc translation. This avoids two failure modes of post-hoc translation: idiom preservation (Korean idioms do not directly translate to English equivalents, and vice versa) and clinical-term equivalence (Korean clinical terminology

occasionally lacks direct English analogs and requires explanatory rendering). The template engine maintains separate templates for each language, sharing only the data inputs.

두 언어는 사후 번역이 아닌 병렬로 렌더링된다. 이는 사후 번역의 두 가지 실패 모드를 피한다: 관용구 보존 (한국어 관용구는 영어 등가물로 직접 번역되지 않으며, 그 반대도 마찬가지) 및 임상 용어 등가성(한국어 임상 용어는 때때로 직접적인 영어 유사물이 부족하고 설명적 렌더링을 필요로 함). 템플릿 엔진은 각 언어에 대한 별도 템플릿을 유지하며, 데이터 입력만 공유한다.

11.4 Cultural Calibration

11.4 문화적 보정

Per Hwang et al. (2008), cultural context shapes both presentation of symptoms and acceptability of treatment recommendations. The Korean rendering employs honorifics appropriate to clinical encounters, somatic framings of psychological distress where culturally indicated, and family-system framings where individual-frame language might be culturally dissonant. These adaptations are encoded in the templates, not introduced post-hoc.

Hwang 등(2008)에 따르면, 문화적 맥락은 증상 제시와 치료 추천의 수용 가능성 모두를 형성한다. 한국어 렌더링은 임상적 만남에 적절한 존칭, 문화적으로 표시될 때 심리적 고통의 신체적 프레이밍, 개인 프레임 언어가 문화적으로 부조화할 수 있는 곳에서 가족 체계 프레이밍을 사용한다. 이러한 적응은 사후에 도입되지 않고 템플릿에 인코딩된다.

12. Audit Traceability

12. 감사 추적성

Table 6. Audit field schema in training_plan_recommendations.

Field	Type	Purpose
score_components	JSONB	All 6 component scores + sub-components + methods
composite_score	Numeric (0-1)	Final weighted total
reasoning_ko	Text (immutable)	Korean human-readable explanation
reasoning_en	Text (immutable)	English human-readable explanation
evidence_citations	JSONB array	PMID/DOI with claim and component link
contraindications_considered	JSONB	Which patient flags evaluated and outcome
model_version	Text	Identifier of scoring model that produced recommendation

Field	Type	Purpose
created_at	Timestamp	Creation time
patient_id	UUID	Foreign key to patients

Table 7. Regulatory mapping of audit design.

Regulation	Requirement	How Audit Design Addresses It
FDA SaMD Good Machine Learning Practice	Transparency, lifecycle audit	score_components + model_version persistence
FDA SaMD Post-Market Monitoring	Tracking real-world performance	training_plan_recommendations + session_records linked
GDPR Article 9 (Special Category Data)	Explicit consent for health data	consent_bot_sync flag; opt-in default-off in ALG-4
GDPR Article 22 (Automated Decision-Making)	Right not to be subject to solely automated decisions	Clinician-in-the-loop design; reasoning_ko/en for meaningful review
GDPR Article 5(1)(c) Data Minimization	Limit data flow to necessary	Fixed bot_summary schema; raw conversation never transferred
EU AI Act High-Risk System	Transparency, human oversight, post-market monitoring	Audit fields + clinician collaboration model
HIPAA Privacy Rule	Patient control over PHI	Granular consent flags; withdrawal supported

12.1 First-Class Audit Design

12.1 일급 감사 설계

As articulated in Section 2.4, we treat audit traceability as a first-class design constraint. The training_plan_recommendations table persists, for every recommendation, all six score components and their sub-components, the composite score, reasoning text in both Korean and English, evidence citations with PubMed identifiers or digital object identifiers where available, the contraindications considered (and the conclusion reached for each), and the version identifier of the scoring model that produced the recommendation. This design exceeds the minimum requirements of the U.S. Food and Drug Administration's Artificial Intelligence / Machine Learning Software-as-a-Medical-Device action plan (FDA, 2021) and aligns with the lifecycle audit emphasis in Warraich et al. (2024).

2.4 절에서 명확히 한 바와 같이, 우리는 감사 추적성을 일급 설계 제약으로 다룬다. training_plan_recommendations 테이블은 모든 추천에 대해 6개 점수 구성요소와 하위 구성요소, 종합

점수, 한국어와 영어 양쪽의 추론 텍스트, 가능한 경우 PubMed 식별자 또는 디지털 객체 식별자가 포함된 근거 인용, 고려된 금기사항(각각에 대해 도달한 결론과 함께), 그리고 추천을 생성한 점수 산정 모델의 버전 식별자를 영구 저장한다. 이 설계는 미국 식품의약국의 인공지능/머신러닝 의료기기 소프트웨어 행동 계획(FDA, 2021)의 최소 요구사항을 초과하며 Warraich 등(2024)의 수명주기 감사 강조와 일치한다.

12.2 Score Component Persistence

12.2 점수 구성요소 영구 저장

The `score_components` JSONB column stores not only the numeric value of each component but also the sub-components and the method used to compute the value. For example, the `symptom_match` component records the cosine similarity value, the weight vector applied, the `symptom_priorities` slice extracted from the patient profile, and the matching slice from the training catalog. This level of detail enables retrospective replication: given the persisted record and the `model_version`, an auditor can recompute the score without access to the live engine state.

`score_components` JSONB 열은 각 구성요소의 숫자 값뿐만 아니라 하위 구성요소와 값 계산에 사용된 방법도 저장한다. 예를 들어, `symptom_match` 구성요소는 코사인 유사도 값, 적용된 가중치 벡터, 환자 프로파일에서 추출된 `symptom_priorities` 슬라이스, 그리고 훈련 카탈로그의 일치 슬라이스를 기록한다. 이러한 세부 수준은 회고적 복제를 가능하게 한다: 영구 저장된 기록과 `model_version` 이 주어지면, 감사자는 라이브 엔진 상태에 접근하지 않고도 점수를 재계산할 수 있다.

12.3 Evidence Citation Schema

12.3 근거 인용 스키마

The `evidence_citations` field is a JSONB array. Each entry contains a `pmid` or `doi`, a brief description of the claim the citation supports, and the relationship of that claim to the recommendation. For example, an ADHD neurofeedback recommendation might cite Van Doren et al. (2019) for sustained-effect evidence, with the claim "neurofeedback for ADHD shows medium effect size at six-month follow-up" linked to the `evidence_strength` component. This schema supports both clinician verification at the point of care and external audit during regulatory review.

`evidence_citations` 필드는 JSONB 배열이다. 각 항목은 `pmid` 또는 `doi`, 인용이 지원하는 주장의 간단한 설명, 그리고 그 주장과 추천의 관계를 포함한다. 예를 들어, ADHD 뉴로피드백 추천은 지속적 효과 증거에 대해 Van Doren 등(2019)을 인용할 수 있으며, "ADHD 에 대한 뉴로피드백은 6 개월 추적 시 중간 효과 크기를 보인다"는 주장이 `evidence_strength` 구성요소에 연결된다. 이 스키마는 치료 시점에서의 임상가 검증과 규제 검토 중 외부 감사를 모두 지원한다.

12.4 Bilingual Reasoning Immutability

12.4 이중 언어 추론 불변성

The reasoning_ko and reasoning_en fields are written at recommendation time and are immutable thereafter. Subsequent recommendations for the same patient generate new rows rather than updating existing ones. This design choice preserves the historical record needed for longitudinal audit and for understanding how the engine's reasoning has evolved over a patient's course of treatment. Bilingual immutability is essential for serving Korean and English-speaking populations under a single audit framework.

reasoning_ko 및 reasoning_en 필드는 추천 시점에 작성되며 이후 불변이다. 동일한 환자에 대한 후속 추천은 기존 행을 업데이트하기보다 새로운 행을 생성한다. 이 설계 선택은 종단 감사와 환자의 치료 과정 동안 엔진의 추론이 어떻게 진화했는지 이해하는 데 필요한 역사적 기록을 보존한다. 이중 언어 불변성은 단일 감사 프레임워크 하에서 한국어와 영어 사용자를 모두 담당하는 데 필수적이다.

12.5 Regulatory Mapping

12.5 규제 매핑

Table 7 maps the audit fields to specific regulatory requirements. The U.S. Food and Drug Administration's Software-as-a-Medical-Device guidance, Good Machine Learning Practice principles, the General Data Protection Regulation Article 22 right not to be subject to solely automated decision-making, and the European Union AI Act high-risk system transparency requirements are all addressed by the persistence design. We argue that this design is necessary but not sufficient for full conformity; outcome validation across diverse populations and post-market monitoring remain required prior to any clearance pursuit.

표 7은 감사 필드를 특정 규제 요구사항에 매핑한다. 미국 식품의약국의 의료기기 소프트웨어 지침, 우수 머신러닝 관행 원칙, 일반 데이터 보호 규정 22 조의 전적으로 자동화된 의사결정의 대상이 되지 않을 권리, 그리고 유럽연합 AI 법의 고위험 시스템 투명성 요구사항이 모두 영구 저장 설계에 의해 다루어진다. 우리는 이 설계가 완전한 적합성에 필요하지만 충분하지는 않다고 주장한다; 다양한 인구 전반의 결과 검증과 시판 후 모니터링은 어떤 승인 추구에도 앞서 여전히 요구된다.

13. Universal Symptom Architecture

13. 보편적 증상 아키텍처

Table 8. Ten symptom domains and primary training categories.

Symptom Domain	Primary Training Categories	Key Evidence Source
ADHD (Gold Template)	Neurofeedback, CBT, mindfulness, environmental modification, skills training	Cortese et al. (2018); Van Doren et al. (2019)
Depression	CBT, behavioral activation, interpersonal therapy,	Cuijpers et al. (2020)

Symptom Domain	Primary Training Categories	Key Evidence Source
	mindfulness-based cognitive therapy	
Anxiety	Exposure therapy, CBT, mindfulness, relaxation training	Carpenter et al. (2018)
Sleep	CBT-I, sleep hygiene, stimulus control, sleep restriction	Riemann et al. (2023)
Burnout	Workload management, recovery activities, boundary-setting, values clarification	Maslach & Leiter (2016)
PTSD	Trauma-focused CBT, prolonged exposure, EMDR, psychoeducation	Bisson et al. (2020)
OCD	Exposure and response prevention, CBT, acceptance-based approaches	Skapinakis et al. (2016)
Bipolar	Psychoeducation, mood monitoring, social rhythm therapy, family-focused therapy	Goodwin et al. (2016)
Autism	Social skills training, sensory regulation, communication support, family support	Lord et al. (2022)
Peak Performance	Goal-setting, attention training, performance routine development	Fischer & Bidell (2006); skill-based literature

13.1 ADHD as Gold Template

13.1 황금 템플릿으로서의 ADHD

We have chosen attention-deficit/hyperactivity disorder (ADHD) as the Gold Template for initial development and clinical validation. The choice reflects three considerations. First, ADHD has the strongest convergence between subjective symptom report, neuropsychological assessment (continuous performance tasks, n-back tasks), and biomarker data (quantitative electroencephalography theta/beta ratio; Arns et al., 2009; Van Doren et al., 2019), which allows full exercise of the six-component scoring scheme. Second, evidence-based interventions for ADHD span pharmacotherapy, cognitive-behavioral therapy, neurofeedback, mindfulness, environmental modification, and skills training (Cortese et al., 2018), allowing the recommendation engine to navigate genuine variety. Third, ADHD captures both pediatric and adult populations and presents across a Fischer skill range from early concrete operations to advanced abstractions, exercising the developmental-matching component.

우리는 초기 개발과 임상 검증을 위한 황금 템플릿으로 주의력 결핍 과잉행동 장애(ADHD)를 선택했다. 이 선택은 세 가지 고려사항을 반영한다. 첫째, ADHD는 주관적 증상 보고, 신경심리 평가(지속 수행 과제, n-back 과제), 바이오마커 데이터(정량적 뇌전도 세타/베타 비율; Arns et al., 2009; Van Doren et al., 2019) 사이에 가장 강력한 수렴을 가지며, 이는 6개 구성요소 점수 산정 체계의 완전한 사용을 가능하게 한다. 둘째, ADHD에 대한 근거 기반 중재는 약물요법, 인지행동치료, 뉴로피드백, 마음챙김, 환경 수정, 기술 훈련에 걸쳐 있으며(Cortese et al., 2018), 추천 엔진이 실제 다양성을 탐색할 수 있게 한다. 셋째, ADHD는 소아 및 성인 인구를 모두 포착하고 초기 구체적 조작에서 고급 추상화에 이르는 Fischer 기술 범위에 걸쳐 나타나며, 발달 매칭 구성요소를 작동시킨다.

The Gold Template strategy commits to deep clinical validation of ADHD before replication to other symptom domains. Validation targets include recommendation alignment with expert clinician choice (target: kappa ≥ 0.70), reasoning quality as judged by external clinical reviewers (Likert scale, target mean ≥ 4 of 5), and patient comprehensibility of bilingual reasoning text (target mean ≥ 4 of 5 across Korean and English samples).

황금 템플릿 전략은 다른 증상 영역으로의 복제 전에 ADHD의 심층 임상 검증을 약속한다. 검증 목표는 전문 임상가 선택과의 추천 일치(목표: 카파 ≥ 0.70), 외부 임상 검토자가 판단한 추론 품질(리커트 척도, 목표 평균 ≥ 5 점 만점에 4 점), 그리고 이중 언어 추론 텍스트의 환자 이해 가능성(한국어 및 영어 표본 전반에서 목표 평균 ≥ 5 점 만점에 4 점)을 포함한다.

13.2 Symptom-Domain Replication Strategy

13.2 증상 영역 복제 전략

Replication to depression, anxiety, sleep, burnout, post-traumatic stress disorder, obsessive-compulsive disorder, bipolar disorder, autism, and peak performance proceeds by populating data rather than writing code. For each new symptom domain, the team curates a training library seed (a set of evidence-based interventions with full quick_input_schema, fischer_start_level, and contraindications fields), assembles a contraindication rule set, and validates the recommendation engine's outputs against expert clinical judgment on a representative case sample. The same six algorithms and the same database schema serve all domains. Domain-specific evidence sources include Cuijpers et al. (2020) for depression, Carpenter et al. (2018) for anxiety, Riemann et al. (2023) for sleep, Maslach and Leiter (2016) for burnout, Bisson et al. (2020) for post-traumatic stress disorder, Skapinakis et al. (2016) for obsessive-compulsive disorder, Goodwin et al. (2016) for bipolar disorder, and Lord et al. (2022) for autism.

우울증, 불안, 수면, 번아웃, 외상후스트레스장애, 강박장애, 양극성장애, 자폐, 최고 수행으로의 복제는 코드 작성이 아닌 데이터 채우기로 진행된다. 각 새로운 증상 영역에 대해, 팀은 훈련 라이브러리 시드(전체 quick_input_schema, fischer_start_level, contraindications 필드가 포함된 근거 기반 중재 세트)를 큐레이션하고, 금기사항 규칙 세트를 조립하며, 대표적 사례 표본에 대한 전문 임상 판단에 대비하여 추천

엔진의 출력을 검증한다. 동일한 6 개 알고리즘과 동일한 데이터베이스 스키마가 모든 영역을 담당한다. 영역별 근거 출처에는 우울증에 대한 Cuijpers 등(2020), 불안에 대한 Carpenter 등(2018), 수면에 대한 Riemann 등(2023), 번아웃에 대한 Maslach 과 Leiter(2016), 외상후스트레스장애에 대한 Bisson 등(2020), 강박장애에 대한 Skapinakis 등(2016), 양극성장애에 대한 Goodwin 등(2016), 자폐에 대한 Lord 등(2022)이 포함된다.

13.3 Training Library Seed Data Curation

13.3 훈련 라이브러리 시드 데이터 큐레이션

Per-symptom training library seeds are curated by a clinician with combined doctoral-level training, Board Certification in Neurofeedback, and Harvard Graduate School of Education affiliation (former Visiting Scholar). Seeds prioritize interventions with rct or meta_analysis evidence_level where available, with consensus_guideline and expert_opinion entries filling gaps. Each seed is reviewed for cultural appropriateness across Korean and English clinical practice (Hwang et al., 2008). The curated library is itself a form of intellectual property, distinct from but complementary to the algorithmic engine.

증상별 훈련 라이브러리 시드는 박사 수준 훈련, 뉴로피드백 보드 인증, Harvard 교육대학원 소속(전직 방문학자)을 결합한 임상가에 의해 큐레이션된다. 시드는 가용한 경우 rct 또는 meta_analysis evidence_level 의 중재를 우선시하며, consensus_guideline 및 expert_opinion 항목이 격차를 채운다. 각 시드는 한국과 영어 임상 실무 전반의 문화적 적절성에 대해 검토된다(Hwang et al., 2008). 큐레이션된 라이브러리 자체가 알고리즘 엔진과는 구별되지만 상호 보완적인 지적재산권의 한 형태이다.

13.4 Cross-Symptom Comorbidity Handling

13.4 증상 간 동반이환 처리

Comorbidity is the rule rather than the exception in real-world mental health populations. The unified profile schema accommodates comorbidity through the symptom_priorities vector, which encodes relative weighting across domains rather than a categorical single-symptom assignment. ALG-1 selects the primary symptom domain by argmax of symptom_priorities but uses the full vector to flag relevant secondary considerations. For example, a patient with primary ADHD and secondary depression may receive an ADHD training recommendation with explicit notation that depression-friendly modalities (behavioral activation overlap) are preferred. Full multi-symptom planning across simultaneous concurrent treatments is reserved for future work.

동반이환은 실제 정신건강 인구에서 예외가 아닌 규칙이다. 통합 프로파일 스키마는 범주적 단일 증상 할당이 아닌 영역 간 상대적 가중치를 인코딩하는 symptom_priorities 벡터를 통해 동반이환을 수용한다. ALG-1 은 symptom_priorities 의 argmax 로 주요 증상 영역을 선택하지만 전체 벡터를 사용하여 관련된 부수적 고려사항을 표시한다. 예를 들어, 주요 ADHD 와 이차적 우울증을 가진 환자는 우울증 친화적 양식

(행동 활성화 중복)이 선호된다는 명시적 표기와 함께 ADHD 훈련 추천을 받을 수 있다. 동시 동시 치료 전반의 전체 다중 증상 계획은 향후 작업으로 보류된다.

14. Discussion

14. 논의

14.1 Strengths

14.1 강점

The architecture's principal strengths are integration, privacy, and traceability. By unifying assessment, recommendation, session planning, and adaptive replanning under one schema, the design removes the structural gap between diagnosis and treatment that characterizes most contemporary digital mental health interventions. By treating the bot-clinical bridge as an opt-in default-off explicit decision, the design respects patient autonomy while preserving the option to integrate when appropriate. By persisting full score decomposition, evidence citations, bilingual reasoning, and model version with every recommendation, the design provides regulators, clinicians, and patients with the substrate for meaningful audit and accountability.

아키텍처의 주요 강점은 통합, 프라이버시, 추적성이다. 단일 스키마 하에서 평가, 추천, 세션 계획, 적응형 재계획을 통합함으로써, 설계는 대부분의 현대 디지털 정신건강 중재를 특징짓는 진단과 치료 사이의 구조적 격차를 제거한다. 봇-임상 브리지를 옵트인 기본 OFF 명시적 결정으로 다룸으로써, 설계는 환자 자율성을 존중하면서 적절한 경우 통합할 옵션을 보존한다. 모든 추천과 함께 전체 점수 분해, 근거 인용, 이중 언어 추론, 모델 버전을 영구 저장함으로써, 설계는 규제 기관, 임상가, 환자에게 의미 있는 감사 및 책임의 기질을 제공한다.

A further strength is the universal symptom-domain structure. The same six algorithms and the same database schema serve all ten Catchers; new symptom domains are added by populating data rather than writing code. This minimizes implementation cost per domain and ensures consistency in audit, privacy handling, and bilingual rendering across the full platform.

추가 강점은 보편적 증상 영역 구조이다. 동일한 6 개 알고리즘과 동일한 데이터베이스 스키마가 10 개 캐처 모두를 담당하며; 새로운 증상 영역은 코드 작성이 아닌 데이터 채우기로 추가된다. 이는 영역당 구현 비용을 최소화하고 전체 플랫폼 전반의 감사, 프라이버시 처리, 이중 언어 렌더링에서 일관성을 보장한다.

14.2 Limitations

14.2 한계

Several limitations apply. First, the engine has not yet been clinically validated; planned validation includes recommendation-alignment studies against expert clinician choice, reasoning-quality

studies with external reviewers, and bilingual comprehensibility studies. Second, the cold-start problem persists: in the absence of prior outcome data, the personal_history component contributes a neutral prior, which may lead to recommendations that revert to evidence-strength dominance. Third, the engine assumes that clinician-curated content is correct; bias in the training_library seed propagates to recommendations. Fourth, Fischer skill estimation in real time is non-trivial; current implementation uses self-report and clinician-administered shorthand assessment, which may be insufficient for fine-grained level discrimination.

몇 가지 한계가 적용된다. 첫째, 엔진은 아직 임상적으로 검증되지 않았다; 계획된 검증에는 전문 임상가 선택에 대한 추천 일치 연구, 외부 검토자와의 추론 품질 연구, 이중 언어 이해 가능성 연구가 포함된다. 둘째, 콜드 스타트 문제가 지속된다: 사전 결과 데이터가 없는 경우, personal_history 구성요소는 독립적 사전을 기여하며, 이는 추천이 근거 강도 지배로 되돌아갈 수 있게 한다. 셋째, 엔진은 임상가가 큐레이션한 콘텐츠가 정확하다고 가정한다; training_library 시드의 편향은 추천으로 전파된다. 넷째, 실시간 Fischer 기술 추정 은 사소하지 않다; 현재 구현은 자가 보고와 임상가 시행 단축 평가를 사용하며, 이는 세밀한 수준 식별에 불충분할 수 있다.

14.3 Clinical Implications

14.3 임상적 함의

For practicing clinicians, the architecture offers a clinician-AI collaboration model rather than clinician replacement. ALG-1 produces ranked recommendations with reasoning; the clinician selects, modifies, or overrides. ALG-5 allows clinicians to author bespoke trainings that conform to the recommendation engine's expectations. The bot-bridge architecture allows clinicians to access bot-derived clinical signal only with explicit patient consent, preserving the therapeutic alliance. We hypothesize, though do not here demonstrate, that this collaboration model increases clinician acceptance over autonomous algorithmic recommendation systems.

실무 임상가에게 아키텍처는 임상가 대체가 아닌 임상가-AI 협업 모델을 제공한다. ALG-1 은 추론과 함께 순위 추천을 생성하며; 임상가는 선택, 수정 또는 무시한다. ALG-5 는 임상가가 추천 엔진의 기대에 부합하는 맞춤형 훈련을 저작할 수 있게 한다. 봇 브리지 아키텍처는 임상가가 명시적 환자 동의가 있을 때만 봇 파생 임상 신호에 접근할 수 있게 하여 치료 동맹을 보존한다. 우리는 여기서 입증하지는 않지만, 이 협업 모델이 자율적 알고리즘 추천 시스템보다 임상가 수용을 증가시킨다고 가정한다.

14.4 Regulatory Pathway

14.4 규제 경로

The architecture is designed to support a U.S. Food and Drug Administration Software-as-a-Medical-Device Class II clearance pursuit. The audit traceability layer addresses Good Machine Learning Practice principles regarding transparency, post-market monitoring, and lifecycle audit.

The opt-in default-off bot bridge addresses General Data Protection Regulation Article 9 and the European Union AI Act's high-risk system transparency requirements. The bilingual rendering pipeline supports international deployment. Conformity to either framework requires outcome validation across diverse populations, which is the primary aim of the ADHD Gold Template validation phase.

아키텍처는 미국 식품의약국 의료기기 소프트웨어 클래스 II 승인 추구를 지원하도록 설계되었다. 감사 추적성 계층은 투명성, 시판 후 모니터링, 수명주기 감사에 관한 우수 머신러닝 관행 원칙을 다룬다. 옵트인 기본 OFF 봇 브리지는 일반 데이터 보호 규정 9 조와 유럽연합 AI 법의 고위험 시스템 투명성 요구사항을 다룬다. 이중 언어 렌더링 파이프라인은 국제 배포를 지원한다. 어느 프레임워크에 대한 적합성도 다양한 인구 전반의 결과 검증을 요구하며, 이는 ADHD 황금 템플릿 검증 단계의 주요 목표이다.

14.5 Future Work

14.5 향후 작업

Three lines of future work are prioritized. First, outcome data integration: as patients complete sessions and report outcomes, the engine should update its scoring through supervised learning while preserving the audit trail. Second, multi-modal biomarker expansion: integration of wearable physiological data (heart rate variability, sleep architecture from consumer devices) into biomarker_summary would strengthen the biomarker_match component. Third, multi-symptom concurrent treatment planning: real-world patients often warrant simultaneous attention to multiple symptom domains; extending ALG-2 to plan concurrent rather than sequential trainings is a substantial design problem.

세 가지 향후 작업 라인이 우선순위가 된다. 첫째, 결과 데이터 통합: 환자가 세션을 완료하고 결과를 보고함에 따라, 엔진은 감사 추적을 보존하면서 지도 학습을 통해 점수 산정을 업데이트해야 한다. 둘째, 다중 모달 바이오마커 확장: 웨어러블 생리학적 데이터(소비자 기기의 심박변이도, 수면 아키텍처)를 biomarker_summary에 통합하면 biomarker_match 구성요소가 강화될 것이다. 셋째, 다중 증상 동시 치료 계획: 실제 환자는 종종 여러 증상 영역에 대한 동시 주의를 정당화한다; 순차적이 아닌 동시 훈련을 계획하도록 ALG-2를 확장하는 것은 상당한 설계 문제이다.

15. Conclusion

15. 결론

We have presented an AI-driven personalized treatment pathway engine for multi-symptom digital mental health platforms. The architecture comprises six algorithms operating against a unified relational database schema: a multi-component recommendation engine, a Fischer-aware session plan generator, an adaptive replanner, a privacy-preserving bot-clinical bridge, a custom

training builder, and a bilingual result renderer. The design addresses three persistent gaps in contemporary digital mental health: the disconnect between assessment and personalized treatment planning, the privacy paradox of bot-clinical integration, and the absence of audit-traceable reasoning for algorithmic recommendations.

우리는 다중 증상 디지털 정신건강 플랫폼을 위한 AI 기반 개인 맞춤형 치료 경로 엔진을 제시했다. 아키텍처는 통합 관계형 데이터베이스 스키마에 대해 작동하는 6 개 알고리즘으로 구성된다: 다중 구성요소 추천 엔진, Fischer 인식 세션 계획 생성자, 적응형 재계획자, 프라이버시 보존 봇-임상 브리지, 맞춤형 훈련 빌더, 이중 언어 결과 렌더러. 설계는 현대 디지털 정신건강의 세 가지 지속적인 격차를 다룬다: 평가와 개인화된 치료 계획 사이의 단절, 봇-임상 통합의 프라이버시 역설, 그리고 알고리즘 추천에 대한 감사 추적 가능한 추론의 부재.

Three architectural commitments distinguish this work. First, treatment pathway logic is explicit, modular, and auditable rather than implicit in unstructured chatbot conversation or static psychoeducational content. Second, the bridge between conversational and clinical data streams is governed by explicit opt-in default-off consent semantics rather than blanket integration. Third, the entire architecture is universal across ten symptom domains, with ADHD serving as a Gold Template for clinical validation before replication to depression, anxiety, sleep, burnout, post-traumatic stress disorder, obsessive-compulsive disorder, bipolar disorder, autism, and peak performance.

세 가지 아키텍처적 약속이 이 작업을 구별한다. 첫째, 치료 경로 로직은 비구조화된 챗봇 대화나 정적 심리교육 콘텐츠에 암묵적이기보다 명시적이고, 모듈적이며, 감사 가능하다. 둘째, 대화 및 임상 데이터 스트림 간의 브리지는 일괄 통합이 아닌 명시적 옵트인 기본 OFF 동의 의미에 의해 관장된다. 셋째, 전체 아키텍처는 10 개 증상 영역 전반에 걸쳐 보편적이며, ADHD 가 우울증, 불안, 수면, 번아웃, 외상후스트레스장애, 강박장애, 양극성장애, 자폐, 최고 수행으로의 복제 전 임상 검증을 위한 황금 템플릿 역할을 한다.

The system is designed to be regulator-aligned with United States Food and Drug Administration Software-as-a-Medical-Device guidance, the European Union AI Act, the General Data Protection Regulation, and the Health Insurance Portability and Accountability Act. The architecture itself is necessary but not sufficient for regulatory clearance; outcome validation across diverse populations and post-market monitoring remain required prior to any clearance pursuit. The next phase of work is clinical validation of the ADHD Gold Template, after which replication to the remaining nine symptom domains can proceed as a primarily data-curation rather than software-engineering exercise.

시스템은 미국 식품의약국 의료기기 소프트웨어 지침, 유럽연합 AI 법, 일반 데이터 보호 규정, 건강보험 이동성 및 책임법과 규제 정렬되도록 설계되었다. 아키텍처 자체는 규제 승인에 필요하지만 충분하지 않다;

다양한 인구 전반의 결과 검증과 시판 후 모니터링은 어떤 승인 추구에도 앞서 여전히 요구된다. 다음 단계 작업은 ADHD 황금 템플릿의 임상 검증이며, 이후 나머지 9개 증상 영역으로의 복제는 주로 소프트웨어 엔지니어링이 아닌 데이터 큐레이션 활동으로 진행될 수 있다.

Beyond its immediate platform context, the architecture offers a generalizable template for the construction of multi-symptom digital mental health platforms that integrate conversational and clinical components without sacrificing privacy or transparency. The Fischer dynamic skill compatibility component, in particular, may have applications beyond the present platform wherever developmentally calibrated treatment matching is required. We hope this work contributes to a digital mental health ecosystem in which personalization, privacy, and accountability are not in tension but are jointly designed from the beginning.

직접적인 플랫폼 맥락을 넘어, 아키텍처는 프라이버시나 투명성을 희생하지 않고 대화형 및 임상 구성요소를 통합하는 다중 증상 디지털 정신건강 플랫폼 구축을 위한 일반화 가능한 템플릿을 제공한다. 특히 Fischer 역동적 기술 호환성 구성요소는 발달적으로 보정된 치료 매칭이 필요한 경우 본 플랫폼을 넘어 적용될 수 있다. 우리는 이 작업이 개인화, 프라이버시, 책임이 긴장 관계가 아니라 처음부터 공동으로 설계되는 디지털 정신건강 생태계에 기여하기를 희망한다.

References

- Almirall, D., Nahum-Shani, I., Sherwood, N. E., & Murphy, S. A. (2014). Introduction to SMART designs for the development of adaptive interventions: With application to weight loss research. *Translational Behavioral Medicine, 4*(3), 260–274. <https://doi.org/10.1007/s13142-014-0265-0>
- Arns, M., de Ridder, S., Strehl, U., Breteler, M., & Coenen, A. (2009). Efficacy of neurofeedback treatment in ADHD: The effects on inattention, impulsivity and hyperactivity: A meta-analysis. *Clinical EEG and Neuroscience, 40*(3), 180–189. <https://doi.org/10.1177/155005940904000311>
- Baumel, A., Muench, F., Edan, S., & Kane, J. M. (2019). Objective user engagement with mental health apps: Systematic search and panel-based usage analysis. *Journal of Medical Internet Research, 21*(9), e14567. <https://doi.org/10.2196/14567>
- Bisson, J. I., van Gelderen, M., Roberts, N. P., & Lewis, C. (2020). Non-pharmacological and non-psychological approaches to the treatment of PTSD: Results of a systematic review and meta-analyses. *European Journal of Psychotraumatology, 11*(1), 1795361. <https://doi.org/10.1080/20008198.2020.1795361>
- Carpenter, J. K., Andrews, L. A., Witcraft, S. M., Powers, M. B., Smits, J. A. J., & Hofmann, S. G. (2018). Cognitive behavioral therapy for anxiety and related disorders: A meta-analysis of randomized placebo-controlled trials. *Depression and Anxiety, 35*(6), 502–514. <https://doi.org/10.1002/da.22728>
- Cohen, I. G., & Mello, M. M. (2018). HIPAA and protecting health information in the 21st century. *JAMA, 320*(3), 231–232. <https://doi.org/10.1001/jama.2018.5630>
- Cortese, S., Adamo, N., Del Giovane, C., Mohr-Jensen, C., Hayes, A. J., Carucci, S., Atkinson, L. Z., Tessari, L., Banaschewski, T., Coghill, D., Hollis, C., Simonoff, E., Zuddas, A., Barbui, C., Purgato, M., Steinhausen, H.-C., Shokraneh, F., Xia, J., & Cipriani, A. (2018). Comparative efficacy and tolerability of medications for attention-deficit hyperactivity disorder in children, adolescents, and adults: A systematic review and network meta-analysis. *The Lancet Psychiatry, 5*(9), 727–738. [https://doi.org/10.1016/S2215-0366\(18\)30269-4](https://doi.org/10.1016/S2215-0366(18)30269-4)
- Cuijpers, P., Karyotaki, E., Eckshtain, D., Ng, M. Y., Corteselli, K. A., Noma, H., Quero, S., & Weisz, J. R. (2020). Psychotherapy for depression across different age groups: A systematic review and meta-analysis. *JAMA Psychiatry, 77*(7), 694–702. <https://doi.org/10.1001/jamapsychiatry.2020.0164>
- Darcy, A., Daniels, J., Salinger, D., Wicks, P., & Robinson, A. (2021). Evidence of human-level bonds established with a digital conversational agent: Cross-sectional, retrospective observational study. *JMIR Formative Research, 5*(5), e27868. <https://doi.org/10.2196/27868>
- Doshi-Velez, F., & Kim, B. (2017). Towards a rigorous science of interpretable machine learning. arXiv preprint arXiv:1702.08608. <https://arxiv.org/abs/1702.08608>

- Fischer, K. W. (1980). A theory of cognitive development: The control and construction of hierarchies of skills. *Psychological Review*, 87(6), 477–531. <https://doi.org/10.1037/0033-295X.87.6.477>
- Fischer, K. W., & Bidell, T. R. (2006). Dynamic development of action and thought. In W. Damon & R. M. Lerner (Eds.), *Handbook of child psychology: Theoretical models of human development* (6th ed., Vol. 1, pp. 313–399). Wiley.
- Fleming, T., Bavin, L., Lucassen, M., Stasiak, K., Hopkins, S., & Merry, S. (2018). Beyond the trial: Systematic review of real-world uptake and engagement with digital self-help interventions for depression, low mood, or anxiety. *Journal of Medical Internet Research*, 20(6), e199. <https://doi.org/10.2196/jmir.9275>
- Ghassemi, M., Oakden-Rayner, L., & Beam, A. L. (2021). The false hope of current approaches to explainable artificial intelligence in health care. *The Lancet Digital Health*, 3(11), e745–e750. [https://doi.org/10.1016/S2589-7500\(21\)00208-9](https://doi.org/10.1016/S2589-7500(21)00208-9)
- Goodman, B., & Flaxman, S. (2017). European Union regulations on algorithmic decision-making and a 'right to explanation'. *AI Magazine*, 38(3), 50–57. <https://doi.org/10.1609/aimag.v38i3.2741>
- Goodwin, G. M., Haddad, P. M., Ferrier, I. N., Aronson, J. K., Barnes, T. R. H., Cipriani, A., Coghill, D. R., Fazel, S., Geddes, J. R., Grunze, H., Holmes, E. A., Howes, O., Hudson, S., Hunt, N., Jones, I., Macmillan, I. C., McAllister-Williams, H., Miklowitz, D. R., Morriss, R., ... Young, A. H. (2016). Evidence-based guidelines for treating bipolar disorder: Revised third edition recommendations from the British Association for Psychopharmacology. *Journal of Psychopharmacology*, 30(6), 495–553. <https://doi.org/10.1177/0269881116636545>
- Heinz, M. V., Mackin, D. M., Trudeau, B. M., Bhattacharya, S., Wang, Y., Banta, H. A., Jewett, A. D., Salzhauer, A. J., Griffin, T. Z., & Jacobson, N. C. (2025). Randomized trial of a generative AI chatbot for mental health treatment. *NEJM AI*, 2(4). <https://doi.org/10.1056/Aloa2400802>
- Higgins, J. P. T., Thomas, J., Chandler, J., Cumpston, M., Li, T., Page, M. J., & Welch, V. A. (Eds.) (2024). *Cochrane Handbook for Systematic Reviews of Interventions* (Version 6.5). Cochrane. <https://training.cochrane.org/handbook>
- Hornstein, S., Zantvoort, K., Lueken, U., Funk, B., & Hilbert, K. (2023). Personalisation strategies in digital mental health interventions: A systematic review and conceptual framework for depressive symptoms. *Frontiers in Digital Health*, 5, 1170002. <https://doi.org/10.3389/fdgth.2023.1170002>
- Hwang, W.-C., Myers, H. F., Abe-Kim, J., & Ting, J. Y. (2008). A conceptual paradigm for understanding culture's impact on mental health: The cultural influences on mental health (CIMH) model. *Clinical Psychology Review*, 28(2), 211–227. <https://doi.org/10.1016/j.cpr.2007.05.001>
- Lee, K. H., Choi, G. H., Yun, J., Choi, J., Goh, M. J., Sinn, D. H., Jin, Y. J., Kim, M. A., Yu, S. J., Jang, S., Lee, S. K., Jang, J. W., Lee, J. S., Kim, D. Y., Cho, Y. Y., Kim, H. J., Kim, S., Kim, J. H., Kim, N., & Kim, K. M. (2024). Machine learning-based clinical decision support system for treatment

- recommendation and overall survival prediction of hepatocellular carcinoma: A multi-center study. *npj Digital Medicine*, 7, 2. <https://doi.org/10.1038/s41746-023-00976-8>
- Linardon, J., Cuijpers, P., Carlbring, P., Messer, M., & Fuller-Tyszkiewicz, M. (2024). The efficacy of app-supported smartphone interventions for mental health problems: A meta-analysis of randomized controlled trials. *World Psychiatry*, 23(1), 139–149. <https://doi.org/10.1002/wps.21183>
- Lord, C., Charman, T., Havdahl, A., Carbone, P., Anagnostou, E., Boyd, B., Carr, T., de Vries, P. J., Dissanayake, C., Divan, G., Freitag, C. M., Gotelli, M. M., Kasari, C., Knapp, M., Mundy, P., Plank, A., Scahill, L., Servili, C., Shattuck, P., ... McCauley, J. B. (2022). The Lancet Commission on the future of care and clinical research in autism. *The Lancet*, 399(10321), 271–334. [https://doi.org/10.1016/S0140-6736\(21\)01541-5](https://doi.org/10.1016/S0140-6736(21)01541-5)
- Mascolo, M. F., & Fischer, K. W. (2015). Dynamic development of thinking, feeling, and acting. In W. F. Overton & P. C. M. Molenaar (Eds.), *Handbook of child psychology and developmental science: Theory and method* (7th ed., Vol. 1, pp. 113–161). Wiley. <https://doi.org/10.1002/9781118963418.childpsy104>
- Maslach, C., & Leiter, M. P. (2016). Understanding the burnout experience: Recent research and its implications for psychiatry. *World Psychiatry*, 15(2), 103–111. <https://doi.org/10.1002/wps.20311>
- Mohr, D. C., Zhang, M., & Schueller, S. M. (2017). Personal sensing: Understanding mental health using ubiquitous sensors and machine learning. *Annual Review of Clinical Psychology*, 13, 23–47. <https://doi.org/10.1146/annurev-clinpsy-032816-044949>
- Murphy, S. A. (2005). An experimental design for the development of adaptive treatment strategies. *Statistics in Medicine*, 24(10), 1455–1481. <https://doi.org/10.1002/sim.2022>
- Nahum-Shani, I., Smith, S. N., Spring, B. J., Collins, L. M., Witkiewitz, K., Tewari, A., & Murphy, S. A. (2018). Just-in-time adaptive interventions (JITAIs) in mobile health: Key components and design principles for ongoing health behavior support. *Annals of Behavioral Medicine*, 52(6), 446–462. <https://doi.org/10.1007/s12160-016-9830-8>
- National Board for Certified Counselors (2023). National Clinical Mental Health Counseling Examination (NCMHCE). NBCC. <https://www.nbcc.org/exams/ncmhce>
- Reyes-Portillo, J. A., Mufson, L., Greenhill, L. L., Gould, M. S., Fisher, P. W., Tarlow, N., & Rynn, M. A. (2025). Generative AI mental health chatbots as therapeutic tools: Systematic review and meta-analysis. *JMIR Mental Health*, 12, e69220. <https://doi.org/10.2196/69220>
- Riemann, D., Espie, C. A., Altena, E., Arnardottir, E. S., Baglioni, C., Bassetti, C. L. A., Bastien, C., Berzina, N., Bjorvatn, B., Dikeos, D., Dolenc Groselj, L., Ellis, J. G., Garcia-Borreguero, D., Geoffroy, P. A., Gjerstad, M., Gonçalves, M., Hertenstein, E., Hoedlmoser, K., Hion, T., ... Spiegelhalder, K. (2023). The European Insomnia Guideline: An update on the diagnosis and treatment of insomnia 2023. *Journal of Sleep Research*, 32(6), e14035. <https://doi.org/10.1111/jsr.14035>

- Skapinakis, P., Caldwell, D. M., Hollingworth, W., Bryden, P., Fineberg, N. A., Salkovskis, P., Welton, N. J., Baxter, H., Kessler, D., Churchill, R., & Lewis, G. (2016). Pharmacological and psychotherapeutic interventions for management of obsessive-compulsive disorder in adults: A systematic review and network meta-analysis. *The Lancet Psychiatry*, 3(8), 730–739. [https://doi.org/10.1016/S2215-0366\(16\)30069-4](https://doi.org/10.1016/S2215-0366(16)30069-4)
- Sutton, R. T., Pincock, D., Baumgart, D. C., Sadowski, D. C., Fedorak, R. N., & Kroeker, K. I. (2020). An overview of clinical decision support systems: Benefits, risks, and strategies for success. *npj Digital Medicine*, 3, 17. <https://doi.org/10.1038/s41746-020-0221-y>
- Tjoa, E., & Guan, C. (2021). A survey on explainable artificial intelligence (XAI): Toward medical XAI. *IEEE Transactions on Neural Networks and Learning Systems*, 32(11), 4793–4813. <https://doi.org/10.1109/TNNLS.2020.3027314>
- Torous, J., Bucci, S., Bell, I. H., Kessing, L. V., Faurholt-Jepsen, M., Whelan, P., Carvalho, A. F., Keshavan, M., Linardon, J., & Firth, J. (2021). The growing field of digital psychiatry: Current evidence and the future of apps, social media, chatbots, and virtual reality. *World Psychiatry*, 20(3), 318–335. <https://doi.org/10.1002/wps.20883>
- U.S. Food and Drug Administration (2021). Artificial intelligence/machine learning (AI/ML)-based software as a medical device (SaMD) action plan. U.S. Department of Health and Human Services. <https://www.fda.gov/medical-devices/software-medical-device-samd/artificial-intelligence-and-machine-learning-software-medical-device>
- Van Doren, J., Arns, M., Heinrich, H., Vollebregt, M. A., Strehl, U., & Loo, S. K. (2019). Sustained effects of neurofeedback in ADHD: A systematic review and meta-analysis. *European Child & Adolescent Psychiatry*, 28(3), 293–305. <https://doi.org/10.1007/s00787-018-1121-4>
- Voigt, P., & von dem Bussche, A. (2017). *The EU General Data Protection Regulation (GDPR): A practical guide*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-57959-7>
- Wachter, S., Mittelstadt, B., & Floridi, L. (2017). Why a right to explanation of automated decision-making does not exist in the General Data Protection Regulation. *International Data Privacy Law*, 7(2), 76–99. <https://doi.org/10.1093/idpl/ix005>
- Wang, Y., Li, X., Zhang, Q., Yeung, D., & Wu, Y. (2025). Effect of a cognitive behavioral therapy-based AI chatbot on depression and loneliness in Chinese university students: Randomized controlled trial with financial stress moderation. *JMIR mHealth and uHealth*, 13, e72365. <https://doi.org/10.2196/72365>
- Wanniarachchi, V., Greenhalgh, M., Choi, A., & Warren, A. (2025). Personalization variables in digital mental health interventions for depression and anxiety in adolescents and youth: A scoping review. *Frontiers in Digital Health*, 7, 1500220. <https://doi.org/10.3389/fdgth.2025.1500220>

Warraich, H. J., Tazbaz, T., & Califf, R. M. (2024). FDA perspective on the regulation of artificial intelligence in health care and biomedicine. *JAMA*, 333(3), 241–247.
<https://doi.org/10.1001/jama.2024.21451>

Wiens, J., Saria, S., Sendak, M., Ghassemi, M., Liu, V. X., Doshi-Velez, F., Jung, K., Heller, K., Kale, D., Saeed, M., Ossorio, P. N., Thadaney-Israni, S., & Goldenberg, A. (2019). Do no harm: A roadmap for responsible machine learning for health care. *Nature Medicine*, 25(9), 1337–1340.
<https://doi.org/10.1038/s41591-019-0548-6>