

教育機関におけるAIエージェント基盤の設計 とプロトタイプ開発

ー 意思決定インテリジェンスによる進路指導支援システムの設計 ー

清風情報工科学院での4ロール型ダッシュボード開発と12AIエージェント戦略

提出先: 文部科学省

2026年2月

清風情報工科学院 教育DX推進室

役割	氏名
研究代表者	(所属教員名)
共同研究者	(所属教員名)
共同研究者	坪内 弘毅
技術顧問	(外部顧問名)

清風情報工科学院

〒545-0042 大阪府大阪市阿倍野区丸山通1-6-3

目次

本編

章	タイトル	頁
第1章	序論 — 研究の背景と目的	4
1.1	研究の背景	4
1.2	研究の目的	5
1.3	研究の意義と新規性	6
1.4	本稿の構成	7
第2章	学校法人における導入目的と施策の狙い	8
2.1	清風情報工科学院の現状分析	8
2.2	教育DX推進における組織的課題	9
2.3	本システム導入の戦略的位置づけ	10
第3章	教育DXに関する先行研究と政策動向	12
3.1	国内外の教育AI研究動向	12
3.2	文部科学省の教育DX政策	13
3.3	GIGAスクール構想とその発展	14
3.4	先行事例との差異分析	15
第4章	システムアーキテクチャ概要	17
4.1	設計思想と基本原則	17
4.2	全体アーキテクチャ図	18
4.3	4象限AIエージェントモデル	19
4.4	データフローと処理パイプライン	21
第5章	Gate機構による信頼性・責任分解設計	23
5.1	Gate機構の概念と設計原理	23

5.2	AI自律レベル制御(L=0.2~L=0.7)	24
5.3	Human-in-the-loopの実装方針	25
5.4	責任分界点の明確化	26
第6章	Guardian Agents — 早期リスク検知機能の設計とプロトタイプ開発	28
6.1	不登校予兆検知エージェント	28
6.2	メンタルヘルスマonitoringエージェント	29
6.3	学力低下アラートエージェント	30
第7章	Tutor Agents — 個別最適化学習支援機能の設計とプロトタイプ開発	32
7.1	進路適性マッチングエージェント	32
7.2	学習プラン最適化エージェント	33
7.3	面接練習支援エージェント	34
第8章	Admin Agents — 事務業務自動化機能の設計とプロトタイプ開発	36
8.1	書類自動生成エージェント	36
8.2	スケジュール最適化エージェント	37
8.3	データ集約・レポート生成エージェント	38
第9章	Management Agents — 経営意思決定支援機能の設計とプロトタイプ開発	40
9.1	進路実績分析エージェント	40
9.2	リソース配分最適化エージェント	41
9.3	戦略シミュレーションエージェント	42
第10章	Agent Team設計 — 複合エージェント連携アーキテクチャ	44
10.1	Agent Team概念の定義	44
10.2	Guardian-Tutor Agent Team(生徒支援統合)	45
10.3	Admin-Management Agent Team(経営支援統合)	46
10.4	エージェント間通信プロトコル	47
第11章	個別生徒AI診断 — 複合エージェント総合診断の設計とプロトタイプ開発	49
11.1	個別生徒AI診断の概念と設計思想	49
11.2	6エージェント統合パイプラインの設計	50
11.3	Gate機構の統合的運用	53
11.4	フロントエンド実装の技術詳細	55
11.5	教育的価値と実践的意義	58
11.6	技術的拡張性と今後の展望	60
第12章	フロントエンド実装 — ロールベースUIシステム	62
12.1	4ロール型ダッシュボードの設計思想	62
12.2	管理者(Admin)ビューの実装	63
12.3	教員(Teacher)ビューの実装	64
12.4	事務方(Office)ビューの実装	65
12.5	学生(Student)ビューの実装	66
12.6	57ビューコンポーネントの構成	67
第13章	技術スタックと開発方法論	69
13.1	Next.js App Routerによるアーキテクチャ	69
13.2	React / Tailwind CSS / shadcn/uiの採用理由	70
13.3	開発プロセスとAI支援開発	71
第14章	データモデル・セキュリティ設計	73
14.1	教育データの分類とスキーマ設計	73
14.2	個人情報保護とアクセス制御	74
14.3	データ暗号化とゼロトラスト設計	75
第15章	導入効果の定量的分析	77
15.1	評価指標の設計(KPI体系)	77
15.2	事務業務削減効果の推計	78

15.3	生徒対応時間拡張効果の推計	79
15.4	費用対効果分析	80
第16章	教育AIの倫理・ガバナンス・法的考慮	82
16.1	教育分野におけるAI倫理原則	82
16.2	アルゴリズムバイアスへの対策	83
16.3	説明可能性(Explainability)の確保	84
16.4	法的フレームワークとコンプライアンス	85
第17章	他教育機関への展開可能性と政策提言	87
17.1	展開モデルの類型化	87
17.2	公立学校への適用可能性	88
17.3	政策提言	89

結論・付録

項目	タイトル	頁
結論	今後の展望	91
付録A	参考文献	94
付録B	コンポーネント一覧	98
付録C	用語集	102

要旨

研究の背景と課題

日本の教育現場、とりわけ中等教育・高等教育を担う専門学校および私立学校において、教員の業務過多は深刻な構造的課題となっている。文部科学省の教員勤務実態調査(2022年度実施)によれば、公立学校教員の在校等時間は依然として長時間に及んでおり、効率化が求められる。その中で進路指導に割くべき時間の慢性的な不足に加えて、多くの担当生徒を抱える教員の負担も大きくなっている。加え学校法人が蓄積する生徒の学習データ、出欠記録、面談記録、模試成績等の多元的データは、その多くが個別のExcelファイルや紙媒体に分散して管理されており、組織横断的な意思決定に資するデータ活用基盤は脆弱な状態にある。こうした「教員業務過多」と「教育データ未活用」の二重の課題は、生徒一人ひとりに対するきめ細やかな進路指導の質を構造的に低下させる要因となっている。

一方で、近年の生成AIおよびLLM(大規模言語モデル)技術の急速な進展は、教育分野における業務自動化と意思決定支援の新たな可能性を切り拓いている。しかしながら、教育現場へのAI導入においては、個人情報保護、アルゴリズムバイアス、説明可能性、教育的配慮といった固有の倫理的・法的要件を満たす必要があり、汎用AIシステムをそのまま適用することは困難である。教育機関に特化した、信頼性と責任分界を明確に担保するAI基盤の設計が求められている。

本システムの設計思想と概要

本研究では、上記の課題に対する包括的な解決策として、教育機関向け意思決定インテリジェンス基盤(以下「本システム」)の設計を行い、UIプロトタイプの実装に着手した。本システムは、清風情報工科学院(大阪府)を検証フィールドとし、進路指導業務全体を対象とした統合的なAIエージェント基盤である。

本システムの核心は、12のAIエージェントを4つの象限に体系化した「4象限AIエージェントモデル」にある。第一象限「守る(Guardian Agents)」は不登校予兆検知・メンタルヘルスマonitoring・学力低下アラートの3エージェントで構成され、生徒の早期リスク検知を担う。第二象限「育てる(Tutor Agents)」は進路適性マッチング・学習プラン最適化・面接練習支援の3エージェントで構成され、個別最適化された学習・進路支援の実現を目指す。第三象限「回す(Admin Agents)」は書類自動生成・スケジュール最適化・データ集約レポート生成の3エージェントで構成され、事務業務の大幅な自動化を図る。第四象限「導く(Management Agents)」は進路実績分析・リソース配分最適化・戦略シミュレーションの3エージェントで構成され、経営層の意思決定を支援する。

さらに、これら12エージェントは2つの「Agent Team」として統合的に連携する。Guardian-Tutor Agent Team(生徒支援統合)はリスク検知と学習支援の情報を横断的に活用し、一人ひとりの生徒に対する包括的な支援戦略を自動生成すること

を目指す設計である。Admin-Management Agent Team(経営支援統合)は業務効率化と経営分析を連動させ、データに基づく組織的意思決定を可能にすることを企図している。

本システムは、教員・学生・保護者・経営層・企業・行政の従来の6ステークホルダーに加え、入学希望者・出身校・外部業者(教育関連会社・業界関係者・広告媒体)・卒業生の4カテゴリを加えた計10のステークホルダーを対象とする。入学前から在学中、卒業後に至る学生ライフサイクル全体を包含するエコシステムとして、卒業生の継続的学び(リスキリング・キャリアトラッキング・卒業生コミュニティ)の支援も設計に含む。

Gate機構とHuman-in-the-loop

教育分野におけるAI活用の最大の課題である「信頼性」と「責任分界」に対しては、独自の「Gate機構」を設計した。Gate機構は、各AIエージェントの人間関与度を $L=0.2$ (高自動化・定型処理)から $L=0.7$ (人間承認必須・高リスク処理)までの連続的なスケールで制御することを目指した設計であり、 L の値が小さいほどAIの自律度が高く、 L の値が大きいほど人間の関与が必須となる。タスクの性質とリスク度合いに応じてHuman-in-the-loop(人間による最終承認)の介在度を動的に調整する設計とした。これにより、AIが「判断を代替する」のではなく「判断を支援する」という設計原則を技術的に担保することを企図している。最終的な教育的意思決定は常に教員・管理者に委ねられる構造となっている。

フロントエンド実装

ユーザインタフェースについては、Next.js(App Router)、React、Tailwind CSSを基盤技術として採用し、4つのユーザーロール(管理者・教員・事務方・学生)それぞれに最適化されたダッシュボードを設計・実装した。管理者にはシステム全体の統括と12エージェントの制御画面を、教員には担当生徒のリスクアラートと進路支援ツールを、事務方には書類管理と業務効率化の機能を、学生には自身の進路情報と学習支援ツールを提供する。プロトタイプ段階において、57のビューコンポーネントと60以上のshadcn/ui準拠UIコンポーネントを実装し、ロール切替・レスポンス対応・ダークモード対応を含む実用的なフロントエンドを構築した。

期待される導入効果

導入効果のシミュレーション分析においては、Admin Agentsによる事務業務の自動化により、進路指導関連の事務作業時間を全業務時間比で約7割から約2割へ削減することを目標準として設定した。同時に、教員が生徒と直接向き合う対応時間を約3割から約8割へ拡張することを目指す。さらに、Recruiter機能による学生募集業務の効率化と、卒業生との長期的関係構築による教育エコシステムの拡張を通じて、学校経営の持続可能性を多面的に強化する。これらの数値目標は、パイロット運用を通じた段階的な検証と改善を前提とした推計値である。

倫理・ガバナンスと展開可能性

本研究では、教育AIの倫理的側面にも重点を置き、個人情報保護法、学校教育法、EU AI規制法等の法的フレームワークとの整合性を検討するとともに、アルゴリズムバイアスの検出・緩和手法、教育的文脈における説明可能性(Explainability)の確保方策を提示した。さらに、本システムの設計をモジュール化することにより、清風情報工科学院以外の私立学校、公立学校、専門学校等への展開可能性を示し、教育DX政策への具体的な提言を行った。

キーワード

教育DX(Educational Digital Transformation)、AIエージェント基盤(AI Agent Platform)、意思決定インテリジェンス(Decision Intelligence)、Human-in-the-loop、ロールベースダッシュボード(Role-based Dashboard)、進路指導支援(Career Guidance Support)、教育AIガバナンス(Educational AI Governance)

> 本報告書は、清風情報工科学院 教育DX推進室による研究成果をまとめたものであり、文部科学省への提出を目的として作成されたものである。本稿に記載された数値目標は、プロトタイプ段階における推計値であり、今後のパイロット運用を通じた検証を予定している。

第1章 序論

1.1 研究の背景

1.1.1 教育現場における教職員の業務過多の深刻化

近年、日本の教育現場における教職員の業務過多は、社会的に重大な課題として認識されるに至っている。文部科学省の教員勤務実態調査(令和4年度)でも、教員の在校等時間の長時間化と業務の多重化が継続課題として示されている。授業準備や成績処理、生徒指導、保護者対応、部活動指導等の多岐にわたる業務が教員の時間を圧迫している実態が報告されている。

この傾向は、初等中等教育段階に限らず、専修学校(専門課程)を含む高等教育機関においても同様に深刻である。特に専門学校は、職業教育の性質上、産業界との密接な連携、資格取得支援、就職指導等、一般の学校教育とは異なる固有の業務負担を教員に課している。にもかかわらず、専門学校における教員の業務負担に関する学術的研究は、小中高等学校や大学と比較して著しく不足しており、政策的な議論においても十分な注目を集めているとは言い難い状況にある。

中央教育審議会は、2019年の答申「新しい時代の教育に向けた持続可能な学校指導・運営体制の構築のための学校における働き方改革に関する総合的な方策について」において、教員の業務を「教員が担うべき業務」「教員が担うことが期待される業務」「教員以外が担うべき業務」の三類型に整理し、業務の適正化を図る方針を示した。しかしながら、とりわけ小規模な教育機関においては、人的資源の制約から業務の分業化が困難であり、一人の教員が多領域の業務を兼務する構造が固定化している。

1.1.2 専門学校特有の構造的課題

専門学校は、高等教育機関の中でも特異な位置づけを有する教育機関である。その特徴は以下の四点に集約される。

第一に、就職直結型教育であることである。専門学校の教育課程は、卒業後の就職を前提として設計されており、カリキュラムの編成から学生指導に至るまで、産業界の動向と密接に連動している。そのため教員には、教科指導の専門性に加え、業界動向の把握、企業との関係構築、学生と企業とのマッチング支援といった、キャリアアドバイザーとしての高度な能力が要求される。

第二に、実務教育と個別指導の比重が高いことである。専門学校における教育は、座学に加えて実習・演習が大きな比重を占め、学生一人ひとりの習熟度に応じた個別的な指導が不可欠である。とりわけ、情報技術の分野においては、実技試験や資格取得のための個別指導が常態化しており、教員の工数を著しく圧迫している。

第三に、留学生比率の増加である。独立行政法人日本学生支援機構の調査によれば、日本語教育機関を除く専門学校に在籍留学生数は、過去10年間で大幅に増加しており、一部の学校においては在籍者の過半数を留学生が占める状況にある。留学生に対しては、日本語能力に応じた教材の調整、在留資格に関する事務手続きの支援、異文化理解に基づく生活指導等、日本人学生とは質的に異なる支援が求められる。

第四に、少人数制・高密度コミュニケーション型の運営体制であることである。多くの専門学校は、1クラス20名から40名程度の少人数制を採用しており、教員と学生との距離が近い。このことは教育上の利点である一方で、教員一人当たりが担当する学生との接触頻度と情報量が大きく、個々の学生の学業、進路、生活状況を包括的に把握し対応することが暗黙的に期待されている。

1.1.3 教員が同時に担う多領域業務

上述の構造的特性を背景として、専門学校の教員は、以下に列挙する多領域の業務を同時並行的に遂行することを求められている。

(1)授業設計および実施:カリキュラムに基づく講義・実習の計画立案と実行、教材作成、評価基準の策定。(2)出欠・成績管理:日次の出欠記録、定期試験・実技試験の採点、成績評定、学業不振者の特定と対応。(3)就職指導・企業対応:学生の適性分析、求人情報の収集と提供、企業訪問、採用担当者との折衝、エントリーシート・履歴書の添削指導、面接練習。(4)保護者対応:定期的な保護者連絡、三者面談の実施、学業・生活状況の報告、緊急時の連絡調整。(5)生活指導:遅刻・欠席の常態化への対応、メンタルヘルスケア、対人関係上のトラブル仲裁。(6)留学生支援:日本語学習支

援、在留資格関連の事務補助、文化的適応の支援、アルバイト・住居等の生活面の相談対応。(7)入試広報協力:オープンキャンパスの企画運営、学校説明会での登壇、入試業務への参加。

これらの業務は、いずれも高い専門性と対人対応能力を必要とし、かつ相互に関連しているため、特定の業務のみを機械的に切り離すことが困難である。結果として、教員は慢性的な長時間労働に陥り、教育の質の維持と自身の心身の健康との間で深刻なジレンマに直面している。

1.1.4 校内蓄積データの未活用

専門学校の教育活動を通じて、日々膨大なデータが生成・蓄積されている。具体的には、出席データ、成績推移、資格取得履歴、就職実績、面談記録、企業評価、保護者連絡履歴、カリキュラム情報、履修履歴等である。これらのデータは、本来、学生の学習傾向の分析、進路適性の評価、リスクの早期検知、カリキュラムの改善、学校経営の意思決定等に活用しうる価値の高い情報資源である。

しかしながら、現状においては、これらのデータは個別のシステムや帳票に分散して管理されており、横断的な分析が行われることは稀である。出席管理システム、成績管理システム、就職支援システム等はそれぞれ独立して運用されていることが多く、データの統合的な利活用を阻む技術的・組織的な障壁が存在する。教員が蓄積データを参照する場合も、個人の経験と勘に基づく定性的な判断に頼ることが大半であり、エビデンスに基づく体系的な意思決定には至っていないのが実情である。

文部科学省が2022年に公表した「教育データ利活用ロードマップ」においても、教育データの分散管理と活用の遅れは重要課題として指摘されており、データの標準化と相互運用性の確保が喫緊の政策課題として位置づけられている。専門学校においても、この課題は例外ではなく、むしろ大学等と比較してICT基盤の整備が遅れている機関も多く、データ利活用の格差はさらに大きいと考えられる。

1.1.5 AIが教育分野で果たしうる役割と倫理的配慮

人工知能(AI)技術の急速な発展は、教育分野においても大きな変革の可能性をもたらしている。自然言語処理技術の進歩により、文書の自動生成・要約、多言語翻訳、対話型学習支援等が実用的な精度で実現可能となった。また、機械学習を用いた予測モデルにより、学業成績の予測、中途退学リスクの早期検知、学習者の行動パターン分析等の応用が報告されている。

教育分野におけるAI活用への期待は、国際的にも高まっている。ユネスコは2019年に「AIと教育に関する北京コンセンサス」を採択し、AIの教育利用における指導原則を示した。OECDもまた、教育におけるAI利用の可能性と課題について継続的な調査を実施している。国内においては、文部科学省の「GIGAスクール構想」による1人1台端末環境の整備が進展し、デジタル技術を活用した教育の高度化に向けた基盤が整いつつある。

しかしながら、教育へのAI導入に際しては、倫理的配慮が不可欠である。AIによる判断は、学生の進路や評価といった人生に重大な影響を及ぼしうる領域に関わるため、透明性(Transparency)、説明可能性(Explainability)、公平性(Fairness)、プライバシーの保護が厳格に担保されなければならない。AIが生成する提案や予測が、教育者の判断を不当に代替することは避けねばならず、あくまで人間の意思決定を補助する「判断支援装置」としての位置づけが求められる。AIの自律度をどの水準に設定し、いかなる条件下で人間の承認を必須とするかという「AIガバナンス」の設計は、教育AI導入の成否を左右する核心的な論点である。

1.2 研究の目的

本研究の目的は、上述の背景と課題を踏まえ、教育機関向けの意思決定インテリジェンス基盤「本システム(Multi-Agent Resource Intelligence Architecture for Operational Support)」を設計し、マルチAIエージェントが動作する、オーケストレーション型のAIエージェント基盤、フロントエンドプロトタイプとして実装することにある。本システムは、専門学校における教職員の業務負担軽減、教育データの統合的利活用、進路指導の高度化を統合的に実現するためのAI基盤システムであり、以下の五つの具体的な研究目標を設定する。

第一の目標は、データドリブン型AI意思決定基盤の導入による教育の質向上と持続可能な学校運営の両立である。教員の業務を「事務的処理業務」と「高度判断・対話業務」に分解し、前者に対するAI支援を体系的に導入することで、教員が本来注力すべき教育活動、すなわち学生との対話、個別指導、教育内容の改善に時間を再配分する構造を設計する。具

体的には、事務的業務比率を約7割から約2割へ縮減し、学生対応時間を約3割から約8割へ拡張することを目標値として設定する(これらの数値はパイロット運用を通じて検証予定の推計値である)。

第二の目標は、12のAIエージェントによる「4象限アプローチ」の体系的設計である。本研究では、教育支援AI機能を「守る(Guardian)」「育てる(Tutor)」「回す(Admin)」「導く(Management)」の4象限に分類し、各象限に3つずつ、合計12のAIエージェントを配置する設計を提案する。「守る」象限には学習リスク早期検知、出席異常検知、メンタルリスク兆候抽出の各エージェントを、「育てる」象限には個別最適化学習プラン生成、弱点分析、教材多言語翻訳の各エージェントを、「回す」象限には面談サマリー自動生成、保護者向けレポート作成、時間割最適化の各エージェントを、「導く」象限には学校経営ダッシュボード分析、入学動向分析、退学率予測の各エージェントをそれぞれ配置する。これにより、教育機関における多様な業務課題に対して網羅的かつ体系的なAI支援を実現する。

第三の目標は、Gate機構によるAI自律レベル制御モデルの提案である。教育領域におけるAI活用においては、AIの自律度を業務の性質と影響度に応じて適切に制御することが不可欠である。本研究では、AIの自律度を連続値L(0.0から1.0)で定義し、業務の種類ごとに適切な自律レベルを設定するGate機構を提案する。例えば、定型的な事務処理にはL=0.2(情報提示中心・人間の確認を前提)を、進路提案にはL=0.7(AI提案・教員承認必須)を設定し、AIの関与度合いと人間の最終承認の必要性を業務特性に応じて明確に分離する。これにより、業務効率化とAI倫理の両立を制度的に担保する。

第四の目標は、4ロール型ダッシュボードの設計と実装である。本システムは、管理者(Admin)、教員(Teacher)、事務方(Office)、学生(Student)の4つのユーザーロールに応じた個別のダッシュボードインターフェースを提供する。各ロールに最適化されたナビゲーション構造、KPI(重要業績評価指標)の可視化、アラート機能、活動フィードを実装することで、各ステークホルダーが必要とする情報に迅速にアクセスし、適切な意思決定を行うための基盤を構築する。

第五の目標は、上記システムのプロトタイプを対象とする評価実験の実施であり、ユーザビリティ、業務効率化の度合い、教育成果への影響を定量的・定性的に検証することであり、今後のパイロット運用段階において実施を予定している。

1.3 研究の意義

本研究の意義は、学術的側面と実践的側面の双方にわたる。

1.3.1 教育DXの実践的実装事例としての学術的貢献

第一に、本研究は教育DX(デジタルトランスフォーメーション)の実践的な実装事例として、学術的に意義のある貢献を行うものである。教育分野におけるAI活用に関する研究は近年増加しているが、その多くは特定のアルゴリズムや限定された機能に関する技術的検証にとどまっており、教育機関全体の業務プロセスを包括的に対象とした統合的なシステム設計・実装の事例は限定的である。本研究は、12のAIエージェントを4象限に体系化し、教育機関の全ステークホルダーを対象とした統合基盤を設計し、UIプロトタイプとして実装する点において、教育情報学および学習分析(Learning Analytics)分野における新たな知見を提供するものである。

1.3.2 AI倫理・ガバナンスフレームワークの汎用性

第二に、本研究が提案するGate機構は、教育AIのガバナンスフレームワークとして汎用性を有するものである。AIの自律度を連続値で定義し、業務の性質に応じた制御レベルを体系的に設定するアプローチは、教育分野に限らず、医療、福祉、行政等、人間の判断が重要視される他の領域においても応用可能である。とりわけ、AIの「判断」と人間の「意思決定」の境界を制度的に明確化するフレームワークは、今後のAI社会実装における倫理的ガイドラインの策定に寄与するものと考えられる。

1.3.3 教育機関への展開可能性

第三に、本研究の成果は、専門学校を起点として、高等学校、大学、職業訓練校等、多様な教育機関への展開可能性を有するものである。本システムの設計は、ロールベースのアクセス制御、モジュール化されたAIエージェント群、柔軟なGate機構という三層構造を採用しており、教育機関の種別や規模に応じたカスタマイズが比較的容易な設計となっている。専門学校における検証を通じて得られた知見を、他の教育機関への展開に活用するための一般化可能な設計原則の抽出も、本研究の重要な目的の一つである。

1.3.4 文科省政策との整合性

第四に、本研究は、文部科学省が推進する主要な教育政策との整合性を有するものである。「GIGAスクール構想」が整備した1人1台端末環境は、本システムが前提とするデジタルインフラの基盤と合致する。また、「教育データ利活用ロードマップ」が目指すデータの標準化・相互運用性の確保は、本システムにおける統合データ基盤の設計思想と軌を一にするものである。さらに、中央教育審議会が提唱する「令和の日本型学校教育」における「個別最適な学びと協働的な学びの一体的な充実」という理念は、本システムの「育てる(Tutor)」象限が提供する個別最適化機能と直接的に対応する。このように、本研究は既存の政策フレームワークの中に位置づけられる実装研究であり、政策提言への橋渡しとしての役割も担うものである。

1.4 本報告書の構成

本報告書は、全18章および付録から構成される。以下に各章の概要を示す。

第1章 序論では、本研究の背景、目的、意義、および論文全体の構成を述べる。日本の教育現場における教職員業務過多の深刻化と、専門学校固有の構造的課題を整理し、AI意思決定基盤の必要性を論じる。

第2章 学校法人(専門学校)における導入目的と施策の狙いでは、本システムの導入対象である専門学校の組織的特性を分析し、導入目的を「教員の本質的業務への集中」「データに基づく教育意思決定の実現」「進路支援の高度化と公平性担保」の三点に整理する。

第3章 先行研究のレビューでは、教育分野におけるAI活用、学習分析(Learning Analytics)、教育データマイニング、AIガバナンスに関する内外の先行研究を体系的にレビューし、本研究の位置づけを明確化する。

第4章 システム設計思想では、本システムの設計における基本思想として、4象限アプローチ、マルチエージェントアーキテクチャ、ロールベースアクセス制御の概念的枠組みを提示する。

第5章 AIエージェント群の設計では、12のAIエージェントの機能仕様、入出力設計、相互連携のメカニズムを詳述し、各エージェントの技術的基盤と教育的妥当性について論じる。

第6章 Gate機構の設計と実装では、AI自律レベル制御のためのGate機構について、その理論的背景、数学的モデル、実装方法、および運用ポリシーを詳細に記述する。

第7章 データ基盤の設計では、教育データの統合管理のためのデータアーキテクチャ、スキーマ設計、データフロー、およびプライバシー保護のための技術的措置について述べる。

第8章 4ロール型ダッシュボードの設計と実装では、管理者・教員・事務方・学生の各ロールに最適化されたユーザーインターフェースの設計原則、コンポーネントアーキテクチャ、および実装の詳細を記述する。

第9章 技術的実装では、Next.js App Router、React、Tailwind CSS、shadcn/ui等のフロントエンド技術スタック、およびバックエンドアーキテクチャの選定理由と実装詳細を記述する。

第10章 セキュリティとプライバシーでは、教育データの取り扱いにおける法的要件(個人情報保護法、学校教育法等)への準拠、技術的セキュリティ対策、およびプライバシー・バイ・デザインの適用について論じる。

第11章 評価実験の設計では、本システムの有効性を検証するための評価実験の設計、評価指標、被験者の選定方法、倫理審査の手続き等を記述する。

第12章 評価計画と期待される効果では、評価実験から得られた定量的データおよび定性的データの分析結果を報告し、本システムの有効性と課題を多角的に考察する。

第13章 考察では、評価結果に基づき、本研究の学術的・実践的含意を議論するとともに、システム設計における反省点と改善の方向性を論じる。

第14章 関連する政策動向と提言では、文部科学省の教育DX政策、AI戦略、教育データ利活用施策との関連を分析し、本研究の知見に基づく政策提言を行う。

第15章 今後の展望では、本研究の発展的課題として、他教育機関への展開計画、AIエージェントの高度化、縦断的評価研究の構想等を述べる。

第16章 結論では、本研究の成果を総括し、教育AI基盤の社会実装に向けた展望を述べる。

付録には、システムの技術仕様書、評価実験で使用了質問紙、AIエージェントの詳細仕様、Gate機構のパラメーター覧、用語集等を収録する。

第2章 弊社における導入目的と施策の狙い

2.1 導入の背景: 専門学校を取り巻く構造的課題

2.1.1 専門学校の制度的位置づけ

専門学校(専修学校専門課程)は、学校教育法第124条および第126条に基づき設置される高等教育機関であり、職業もしくは実際生活に必要な能力を育成し、又は教養の向上を図ることを目的とする。全国に多数の学校が設置され、多くの学生が在籍している。大学・短期大学と並ぶ高等教育の一翼を担いながらも、その教育運営に関する学術的研究は相対的に少なく、特に情報技術を活用した教育支援基盤に関する体系的な研究は極めて限定的である。

専門学校は、大学と比較して以下の構造的特徴を有する。第一に、就職直結型教育機関として、在学期間(多くは2年制)の中で実践的な職業能力を育成することが求められる。第二に、実務教育と個別指導の比重が高く、教員一人あたりの学生対応密度が大学に比して著しく高い。第三に、近年の留学生比率の増加により、多言語・多文化対応の負荷が増大している。第四に、少人数制・高密度コミュニケーション型の運営形態が一般的であり、教員と学生の関係性が教育成果を左右する度合いが大きい。

こうした特徴は、専門学校教育の強みであると同時に、教員の業務負担を構造的に増大させる要因でもある。専修学校教員の業務実態については、全国一律で業務内訳まで把握できる公表統計が限定的であり、各校の実務データに基づく実態把握が不可欠である。

2.1.2 教員業務の多重性と属人化

専門学校の教員は、単一の教科指導にとどまらず、以下に列挙する多岐にわたる業務を同時並行的に遂行している。

1. 授業設計および実施(カリキュラム開発を含む)
2. 出欠管理・成績管理・評価業務
3. 就職指導・企業対応・求人開拓
4. 保護者対応・三者面談の実施
5. 生活指導・メンタルヘルス対応
6. 留学生支援(在留資格管理、日本語補習等)
7. 入試広報活動への協力
8. 各種行政報告書の作成

これらの業務のうち、進路指導、留学生対応、個別ケアは高度な判断力を必要とする業務であり、長年の経験に基づく暗黙知への依存度が高い。結果として、特定の熟練教員への業務集中(属人化)が生じやすく、当該教員の異動や退職により組織的な知見が喪失するリスクを内包している。

本研究に先立つ校内ヒアリングでも、ベテラン教員と新任教員の間で進路指導の運用知に差が生じやすいことが確認されている。この知見は、進路指導の質を個人の能力に依存させるのではなく、組織的・制度的に担保する仕組みの必要性を強く示唆するものである。

2.1.3 政策的背景との関連

本研究が対象とするAI導入施策は、わが国の教育政策の大きな潮流とも合致する。内閣府が提唱する「Society 5.0」構想においては、サイバー空間とフィジカル空間を高度に融合させた超スマート社会の実現が目指されており、教育分野においてもデータとAIの活用による個別最適化された学びの実現が重要課題として位置づけられている。

文部科学省による「第4期教育振興基本計画」(2023年6月閣議決定)では、「誰一人取り残さず、全ての人の可能性を引き出す、個別最適な学びと協働的な学びの実現」が基本方針の一つとして掲げられ、教育DX(デジタルトランスフォーメーション)の推進が明記されている。同計画において、データ駆動型の教育改善やエビデンスに基づく政策立案(EBPM: Evidence-Based Policy Making)の重要性が強調されており、本研究はこの政策的要請に直接応答するものである。

さらに、経済産業省の「未来の教室」ビジョン(2019年)では、EdTech(教育テクノロジー)の活用による「学びの生産性」向上が提言されており、教員の業務負担軽減と教育の質向上を両立させるためのテクノロジー活用の在り方が議論されてい

る。しかしながら、これらの政策議論の多くは初等中等教育または大学教育を主たる対象としており、専門学校を含む専修学校における具体的な実装モデルの提示は十分になされていない。本研究は、この政策的空白を埋める試みとしても位置づけられる。

2.2 導入目的

本システムの導入目的は、単なる事務処理の効率化にとどまるものではない。教育の本質的価値を再定義し、テクノロジーの介入によって教員と学生の関係性をより豊かなものへと再構築することにある。以下、五つの目的を詳述する。

2.2.1 目的1: 教員の本質的業務への集中

教員の業務を構造的に分析すると、大きく「事務的処理業務」と「高度判断・対話業務」の二つのカテゴリーに分類できる。前者には出欠集計、成績入力、書類作成、定型的な連絡業務等が含まれ、後者には進路相談、学習指導、メンタルケア、個別面談等が含まれる。

文部科学省「教員勤務実態調査(令和4年度)」では、公立小中学校教員の在校等時間の長時間化が継続課題として示されている。清風情報工科学院における予備調査(対象教員20名、2週間の業務日誌記録に基づく推計)においても、事務的処理業務が業務時間の約70%、高度判断・対話業務が約30%という比率が推定された(校内推計値)。この比率は、教育機関の本来的使命である「教育」活動に教員が十分な時間を投入できていないことを端的に示している。

本システムの導入により、事務的処理業務の大部分をAIが代替・補助することで、当該比率を逆転させることを目標とする。具体的には、**事務的業務比率を70%から20%へ縮減し、学生対応時間を30%から80%へ拡張**することを数値目標として設定する(図2-1参照)。ただし、この目標は段階的に達成するものであり、第1年度では事務比率70%→35%(半減)を現実的なマイルストーンとして設定し、以降Phase 2(35%→25%)、Phase 3(25%→20%)と段階的に改善を図る計画である。削減対象となる業務の内訳は、帳票作成(推定20%)、成績集計・データ入力(推定15%)、面談準備(推定15%)、連絡文作成・調整業務(推定20%)であり、これらが各AIエージェントの支援対象となる。

この目標設定は、単に時間的余裕を生み出すことを意図するものではない。教員が本来もっとも価値を発揮すべき領域——すなわち、学生との対話を通じた成長支援、個別の事情に配慮した進路指導、学生の潜在的な困難の発見と対応——に組織的に資源を再配分することを企図している。Hargreaves and Fullan(2012)が提唱する「専門資本(Professional Capital)」の概念に照らせば、教員の専門性は反復的な事務作業によっては蓄積されず、むしろ高度な判断と省察的実践の繰り返しによって涵養される。本施策は、この専門資本の蓄積を制度的に促進するための基盤整備と位置づけることができる。

2.2.2 目的2: データに基づく教育意思決定の実現

専門学校においては、日常的教育活動を通じて以下のような多様なデータが蓄積されている。

- 出席データ(日次の出欠状況、遅刻・早退記録)
- 成績推移(科目別成績、GPA推移、到達度評価)
- 資格取得履歴(検定試験結果、国家資格取得状況)
- 就職実績(内定先企業、職種、採用試験結果)
- 面談記録(教員による面談メモ、進路希望の変遷)
- 企業評価(卒業生に対する企業フィードバック)
- 保護者連絡履歴(三者面談記録、日常的な連絡内容)

しかしながら、これらのデータは多くの場合、個別のシステムや紙媒体に分散して管理されており、統合的な分析・活用がなされていないのが実情である。各データは本来、学生の学びの全体像を構成する相互に関連した情報断片であるにもかかわらず、サイロ化された状態にあるために、横断的な知見の抽出が困難となっている。

本システムは、これら分散するデータソースを統合的なデータレイクに集約し、AIによる横断分析を可能とする「意思決定支援層(Decision Support Layer)」として機能させることを目的とする。Baker and Inventado(2014)が提唱する学習分析(Learning Analytics)の枠組みに基づけば、データの統合的活用は、(a) 記述的分析(何が起きているか)、(b) 診断的分析(なぜ起きているか)、(c) 予測的分析(何が起きそうか)、(d) 処方的分析(何をすべきか)の4段階で教育意思決定を支援する。本システムは、この4段階の分析を統合的に提供することにより、経験と勘に頼りがちであった教育判断をエビデンスに基づくものへと転換することを企図する。

2.2.3 目的3:進路支援の高度化と公平性担保

進路指導は専門学校教育の核心的機能である。就職直結型教育機関として、学生を適切な職業・企業へと導くことは、教育機関の社会的存在意義に直結する。しかし、従来の進路指導には以下の課題が存在する。

第一に、教員個人の経験・人脈への依存度が高く、担当教員によって学生が得られる情報の質と量に格差が生じる。第二に、企業と学生のマッチングが教員の主観的判断に基づくことが多く、最適な組み合わせが見逃される可能性がある。第三に、面談準備に多大な時間を要し、十分な事前分析なく面談が行われるケースが散見される。

本システムでは、以下の機能をAIが補助する。

- 学生能力傾向分析(多次元データに基づくコンピテンシー・プロファイリング)
- 企業マッチング支援(学生特性と企業要件の適合度算出)
- 合格確率推定(過去の採用実績データに基づくデータ分析上の予測)
- 説明資料生成(面談用サマリー、保護者向け報告書の自動作成)

これらの機能により、**面談準備時間の70%削減**を目標とするとともに、教員の経験年数や個人的人脈に依存しない、データに裏付けられた公平な進路支援の実現を目指す。

2.2.4 目的4:学生募集業務の効率化

専門学校にとって、学生募集は経営の持続可能性を左右する最重要業務の一つである。少子化が進行する中、志願者の確保はますます困難になっており、広報活動、オープンキャンパスの企画運営、入試業務、出願者対応等に投入される人的リソースは年々増大している。清風情報工科学院においても、教員が入試広報業務に相当の工数を割いている実態があり、教育活動と募集活動の両立が構造的な課題となっている。

本システムでは、「集める(Recruiter)」機能として以下の学生募集支援を提供する。

- **志願者動向分析**:出身校別・地域別・チャンネル別の志願者データを統合分析し、効果的な募集戦略の立案を支援する。
- **広報施策ROI分析**:Web広告、SNS、紙媒体、オープンキャンパス等の各広報チャネルの費用対効果を定量的に評価する。
- **入学希望者対応の効率化**:問い合わせ対応の自動化、資料請求の追跡管理、オープンキャンパス参加者へのフォローアップを体系的に支援する。
- **出身校連携管理**:高等学校や日本語学校等の送り出し機関との関係性を可視化し、連携強化の優先順位を提示する。

これにより、限られた人的リソースの中で、データに基づく戦略的かつ効率的な学生募集活動を実現することを目指す。

2.2.5 目的5:卒業生の継続的学びの支援

教育機関の社会的価値は、在学中の教育にとどまらず、卒業後のキャリア形成と学び続ける姿勢の涵養にまで及ぶ。特にIT・デザイン・ゲーム等の技術領域は変化のスピードが速く、卒業後も継続的なスキルアップが不可欠である。清風情報工科学院の卒業生が、変化の激しい産業界において長期的に活躍し続けるためには、卒業後も学校との接点を維持し、リスキリングやアップスキリングの機会を提供する仕組みが求められる。

本システムでは、卒業生の継続的学びを支援する以下の機能を設計する。

- **卒業生キャリアトラッキング**: 卒業生の就職先での活躍状況、転職動向、キャリアパスの追跡を体系的に管理する。
- **リスキリング・コンテンツ提供**: 業界動向に応じた最新技術の学習コンテンツを卒業生に提供し、継続的なスキル更新を支援する。
- **卒業生ネットワーク構築**: 在校生と卒業生をつなぐメンタリング機能やコミュニティ機能を提供し、世代を超えた学びの循環を促進する。
- **企業フィードバック循環**: 卒業生の就職先企業からの評価を収集し、在学生の教育改善に還元するフィードバックループを構築する。

卒業生との長期的な関係維持は、学校のブランド価値向上、在校生のロールモデル提供、企業との信頼関係強化にも寄与し、学校経営の持続可能性を高める好循環を生み出すことが期待される。

ただし、本システムの設計思想において最も重要な点は、AIの役割を「草案生成・判断補助」に限定し、最終的な意思決定を必ず教員（人間）が行う構造を堅持していることである。本研究では、自動化レベルを連続値 L ($0 \leq L \leq 1$) で定義する「自律度制御モデル」を採用する。具体的には以下のように設定する。

- **L = 0.2: 事務系自動処理** (出欠集計、定型帳票生成等。教員の事前承認なく実行可能)
- **L = 0.7: 進路提案** (企業マッチング提案、合格確率提示等。教員による承認を必須とする)

この連続値による自律度定義は、Parasuraman, Sheridan, and Wickens (2000) が提示した自動化レベルの枠組みを教育分野に適応したものであり、「自動化か人間判断か」という二項対立を超えた柔軟な制御を可能にする。L値の設定は固定的なものではなく、導入後の運用実績と教員の信頼度の推移に応じて段階的に調整されるべきものである。この段階的調整のプロセス自体が、教育現場におけるAIガバナンスの実践的知見を蓄積する契機となる。

2.3 施策の狙い: 5領域フレームワーク

本導入施策は、個別の機能追加ではなく、教育活動を包括的に支える4つの機能領域を同時に改善することを狙う。本研究ではこの枠組みを「5領域フレームワーク」と呼称し、各領域を「守る」「育てる」「回す」「導く」と定義する(表2-1参照)。

2.3.1 守る (Guardian機能)

Guardian機能は、学生の学習リスクおよび生活リスクの早期検知を担う。具体的には以下の機能群から構成される。

- **学習リスク早期検知**: 出席率の急激な低下、成績の下降トレンド、課題未提出の連続等を複合的に分析し、学業上の困難を抱える学生を自動的に特定する。
- **出席異常検知**: 単純な欠席回数の集計にとどまらず、出席パターンの変化(特定曜日の欠席、遅刻の増加傾向等)を時系列分析により検出する。
- **メンタルリスク兆候抽出**: 面談記録のテキスト分析、出席パターンの変化、学業成績の変動等の多次元データを統合し、精神的な困難の兆候を早期に抽出する。

この機能の目標は、**リスク検知のリアルタイム化**と「**見落としゼロ**」の実現である。従来、教員の経験的直感に依存していたリスク発見を、データに基づく体系的な監視へと移行させることで、いかなる学生も支援の網から漏れることのない体制の構築を目指す。

Arnold and Pistilli (2012) によるCourse Signalsシステムの研究では、学習分析に基づく早期警戒システムの導入により、中退率の改善が報告されている。本システムのGuardian機能は、この知見を専門学校の文脈に適応し、より包括的なリスク指標を統合した発展的モデルとして設計されている。

2.3.2 育てる (Tutor機能)

Tutor機能は、学生一人ひとりの学習特性に応じた個別最適化支援を提供する。

- **個別最適化学習プラン生成**: 学生の現在の到達度、学習速度、強み・弱みの分析に基づき、最適な学習経路と優先すべき学習領域を提案する。

- **弱点分析**:科目横断的な能力分析により、表面的な成績には現れない構造的な理解の欠如を特定する。
- **教材多言語翻訳・難易度適応**:留学生支援として、教育資料の自動翻訳および日本語能力レベルに応じた表現の平易化を行う。

専門学校における留学生比率は年々増加しており、2023年度には専門学校在籍者の約14%を留学生が占めている。多言語・多文化環境における教育支援の需要は今後さらに拡大することが予測され、AIによる言語的障壁の低減は教育の公平性確保に直結する。VanLehn(2011)のメタ分析によれば、個別指導(Tutoring)は集団授業に比して学習効果が約0.79標準偏差高いことが示されており、AI Tutorの導入によるスケーラブルな個別最適化は、限られた教員数で多様な学生ニーズに対応するための有効な方策となりうる。

2.3.3 回す(Admin機能)

Admin機能は、教育活動を支える事務的・管理的業務の効率化を担う。

- **面談サマリー自動生成**:面談時の音声記録または教員の簡潔なメモから、構造化された面談記録を自動的に生成する。
- **保護者向けレポート作成**:学生の学習状況、出席状況、進路活動状況を統合した自然言語レポートを自動生成し、保護者への情報提供を効率化する。
- **時間割最適化**:教室稼働率、教員配置、学生の選択科目等の制約条件を考慮した時間割の最適解を提示する。

前述の通り、教員の業務時間の約70%が事務的処理に費やされている現状において、Admin機能による効率化のインパクトは極めて大きい。特に面談準備に関しては、学生の履歴データの収集・整理に1件あたり平均30分以上を要しているケースが多く、面談準備時間70%削減の目標達成は、教員の高度判断業務への時間配分を劇的に改善する効果が期待される。

2.3.4 導く(Management機能)

Management機能は、学校経営層に対する戦略的意思決定支援を提供する。

- **学校経営ダッシュボード**:入学者数推移、退学率、就職率、資格合格率等のKPI(重要業績指標)をリアルタイムで可視化する。
- **入学動向分析**:志願者データの地域別・属性別分析、高校・送り出し機関別の動向把握を支援する。
- **退学率予測**:在籍学生の退学リスクを統計モデルにより予測し、組織的な防止策の立案を支援する。
- **企業連携分析**:就職先企業の満足度、卒業生の定着率、求人動向等を分析し、産学連携戦略の策定を支援する。

Management機能は、理事長・事務局長等の経営層が、経験と勘に基づく判断からデータドリブン型の経営判断へと移行することを支援するものである。Brynjolfsson and McElheran(2016)は、データ駆動型意思決定を採用した組織が生産性面で優位性を示す知見を報告しており、この知見は教育機関の経営においても妥当すると考えられる。

2.3.5 集める(Recruiter機能)

Recruiter機能は、学生募集活動の戦略的高度化と業務効率化を担う。少子化が進行する中、専門学校にとって安定的な志願者の確保は経営の生命線であり、限られたリソースで最大の効果を上げる募集戦略が求められている。

- **志願者動向分析・予測**:過去の志願者データ、出身校・地域別の入学者傾向、経済・社会的要因を統合分析し、次年度の志願者数を予測する。地域別・属性別のターゲティング戦略の立案を支援する。

- **広報チャネル最適化**:Web広告、SNS(Instagram、X、TikTok等)、紙媒体、オープンキャンパス、高校訪問等の各広報チャネルについて、費用対効果(CPA: Cost Per Acquisition)をリアルタイムで分析し、予算配分の最適化を提案する。

- **入学希望者CRM(顧客関係管理)****:資料請求者、オープンキャンパス参加者、体験入学参加者等の入学希望者との接触履歴を一元管理し、適切なタイミングでのフォローアップを自動化する。

- **出身校連携管理**: 高等学校、日本語学校等の送り出し機関との関係性を可視化し、訪問履歴、紹介実績、連携の深度を分析して、重点連携校の特定と関係強化の優先順位付けを行う。

Recruiter機能は、従来、事務方と教員の経験的判断に大きく依存していた募集活動を、データに基づく戦略的活動へと転換することを企図する。Kotler and Fox(1995)が教育機関のマーケティングにおいて提唱した「戦略的登録管理(Strategic Enrollment Management)」の概念に基づき、募集から入学、在学、卒業に至るまでの学生ライフサイクル全体を見据えた統合的なアプローチを実現する。

2.4 ステークホルダー別のAI機能

本システムは、進路指導に限定されたツールではなく、教育活動に関与する多様なステークホルダーに対して、それぞれの役割と需要に応じた機能を提供する包括的プラットフォームである。以下、各ステークホルダーに提供される機能を体系的に整理する(表2-2参照)。

2.4.1 教員向け機能

教員は本システムの主たる利用者であり、以下の機能群が提供される。

- **リスク検知ダッシュボード**: 担当学生のリスクスコアをリアルタイムで表示し、優先対応すべき学生を明示する。
- **面談準備支援**: 面談対象学生の学習履歴、出席状況、進路希望の変遷、過去の面談記録を統合したブリーフィングシートを自動生成する。
- **学習設計支援**: クラス全体の到達度分布に基づき、授業設計の改善提案を行う。
- **評価妥当性分析**: 教員間の成績評価の分布を比較分析し、評価基準の一貫性を検証する。

2.4.2 学生向け機能

学生に対しては、自律的な学習と進路選択を支援する機能が提供される。

- **個別学習計画**: 現在の学習状況に基づき、短期・中期の学習目標と推奨学習内容を提示する。
- **進路候補提示**: 学生の能力プロフィール、志望、適性検査結果等に基づき、適合度の高い企業・職種を提案する。
- **学習進捗可視化**: 目標に対する達成度、同期生との相対的位置づけ等を視覚的に表示する。
- **多言語教材提供**: 留学生を対象に、教材の母語翻訳および平易な日本語版を自動生成する。

2.4.3 保護者向け機能

保護者に対しては、学生の状況を適時・適切に共有するための機能が提供される。

- **自然言語レポート生成**: データの羅列ではなく、学生の状況を自然な文章で説明するレポートを自動生成する。
- **成績推移説明**: 成績の変動を文脈とともに解説し、改善に向けた具体的な助言を含む説明文を提供する。
- **面談ポイント共有**: 三者面談に先立ち、議論すべき主要ポイントと学生の状況サマリーを共有する。

2.4.4 経営層向け機能

理事長、学校長、事務局長等の経営層に対しては、学校運営の全体像を把握し、戦略的意思決定を行うための機能が提供される。

- **学校経営ダッシュボード**: 主要KPIの推移、目標達成度、学校間比較(法人内複数校の場合)等を統合的に表示する。
- **退学率予測モデル**: 学年別・学科別の退学リスクを予測し、必要な介入策の検討を支援する。
- **入試広報分析**: 広報施策ごとの費用対効果、志願者獲得チャネルの分析を提供する。
- **就職実績分析**: 就職率、就職先の質的指標、業界別の就職動向等を多角的に分析する。

2.4.5 企業(就職先)向け機能

企業に対しては、採用活動の効率化と学生との適合度向上を支援する機能が提供される。

- **学生スキル可視化**: 資格取得状況、実習評価、プロジェクト成果等を統合したスキルポートフォリオを提供する。
- **マッチング精度向上**: 企業が求める人材要件と学生の特性を照合し、適合度の高い候補を提示する。
- **評価フィードバック循環**: 採用後の企業評価を学校にフィードバックし、教育改善に活用する循環的な仕組みを構築する。

2.4.6 行政向け機能

文部科学省、都道府県教育委員会等の行政機関に対しては、エビデンスに基づく政策立案を支援する機能が提供される。

- **統計データ整形**: 各種報告書に必要な統計データを自動的に集計・整形し、報告業務の負担を軽減する。
- **エビデンスベース政策報告支援**: 学校単位のデータを匿名化・集約化した上で、政策効果の検証に資するデータセットを生成する。

以上の6カテゴリーのステークホルダーに対する機能提供は、教育を単一の行為者(教員)による営みとしてではなく、多様な関係者が協働する生態系(エコシステム)として捉える視座に基づいている。Freeman(1984)のステークホルダー理論に依拠すれば、組織の持続的な価値創造は、すべてのステークホルダーの利害を考慮し、それぞれに対して適切な価値を提供することによって実現される。本システムは、教育機関のステークホルダー・エコシステム全体を対象とした包括的な価値提供基盤として設計されている。

2.4.7 入学希望者向け機能

入学希望者(高校生、社会人、留学生等)に対しては、学校選択の意思決定を支援し、入学前の不安を軽減する機能が提供される。

- **コース適性診断**: 興味・関心、学習スタイル、将来のキャリア希望に基づき、IT・情報処理、デザイン・イラスト、ゲームクリエイター、ぐるぐる(探索プログラム)の各コースとの適合度を提示する。
- **パーソナライズド学校案内**: 入学希望者の属性(出身地域、学歴、興味分野等)に応じてカスタマイズされた学校情報を提供する。
- **オープンキャンパス体験最適化**: 参加者の関心領域に基づき、オープンキャンパスでの体験プログラムを個別に推薦する。
- **入学前学習ガイダンス**: 入学決定者に対して、入学前に取り組むべき基礎学習や準備事項を個別に提案する。

2.4.8 出身校向け機能

高等学校、日本語学校等の送り出し機関に対しては、進路指導の連携強化と情報共有を支援する機能が提供される。

- **卒業生活躍レポート**: 出身校別に、当該校出身の在校生・卒業生の学習状況や就職実績を集約した報告を提供し、進路指導の参考資料とする。
- **連携ダッシュボード**: 出身校との連絡履歴、訪問記録、推薦入学実績等を一元管理し、関係性の維持・強化を支援する。
- **進路指導教員向け情報提供**: 出身校の進路指導教員に対し、本校の教育内容、資格取得実績、就職実績等の最新情報を効率的に提供する。

2.4.9 外部業者・業界関係者向け機能

教育関連企業、広告代理店、業界団体、認定機関等の外部パートナーに対しては、連携業務の効率化と成果の可視化を支援する機能が提供される。

- **広告媒体効果分析**: 広告代理店・メディアとの連携において、各広告施策の志願者獲得への貢献度を定量的に分析し、共有する。

- **業界連携管理**: IT業界団体、デザイン関連協会、ゲーム業界団体等との連携活動(講演依頼、カリキュラムアドバイス、インターンシップ受入等)を一元管理する。

- **教材・ツール提供企業との連携**: 教育関連企業が提供する教材やツールの利用状況・効果を分析し、導入判断の根拠を提供する。

- **認定機関との報告連携**: 資格認定機関や職業実践専門課程の認定に関する報告データを自動的に集計・整形する。

2.4.10 卒業生向け機能

卒業生に対しては、継続的なキャリア形成支援と学校コミュニティへの参画を促進する機能が提供される。

- **キャリア継続支援**: 卒業後のキャリアステージに応じたリスキリング・アップスキリングのための学習コンテンツや情報を提供する。

- **卒業生コミュニティ**: 同期・同コース卒業生とのネットワーキング、在校生へのメンタリング、業界情報の共有等を支援するプラットフォームを提供する。

- **キャリアトラッキング**: 転職、昇進、独立等のキャリアイベントを記録し、卒業生のキャリアパスを可視化する。就職先企業からのフィードバックとあわせ、教育改善に資するデータを蓄積する。

- **母校貢献機会の提供**: 特別講義の講師、就職活動のアドバイザー、オープンキャンパスでの体験談共有等、卒業生が母校に貢献する機会を体系的に管理する。

以上の10のステークホルダーカテゴリーに対する機能提供は、教育を単一の行為者(教員)による営みとしてではなく、多様な関係者が協働する生態系(エコシステム)として捉える視座に基づいている。Freeman(1984)のステークホルダー理論に依拠すれば、組織の持続的な価値創造は、すべてのステークホルダーの利害を考慮し、それぞれに対して適切な価値を提供することによって実現される。本システムは、入学前(入学希望者・出身校)から在学中(教員・学生・保護者)、卒業後(卒業生・企業)に至る学生ライフサイクル全体を包含し、さらに経営層、行政、外部パートナーを含む教育機関のステークホルダー・エコシステム全体を対象とした包括的な価値提供基盤として設計されている。

2.5 導入の意義

本システムの導入意義は、以下の五点に集約される。

第一に、教員の労働環境改善である。わが国の教育現場における教員の過重労働は、中央教育審議会をはじめとする複数の政策文書において繰り返し指摘されてきた深刻な構造的問題である。専門学校においても事情は同様であり、教員の業務負担の軽減は喫緊の課題である。本システムは、事務的業務のAI代替により教員の実質的な労働時間を削減するのみならず、業務内容の質的転換——すなわち、低付加価値の事務処理から高付加価値の教育的対話への移行——を実現することにより、教員の職務満足度と専門職としてのアイデンティティの回復に寄与することを企図する。

第二に、学生支援の高度化である。個別最適化された学習支援、データに基づく進路指導、リアルタイムのリスク検知は、いずれも学生の教育的経験の質を飛躍的に向上させる可能性を持つ。特に、担当教員の経験年数や個人的能力に依存しない均質な支援の提供は、教育の公平性(Equity)という観点から極めて重要である。OECD(2021)が提唱する「学生ウェルビーイング」の枠組みにおいても、すべての学生が等しく質の高い教育支援にアクセスできることが、教育制度の基本的要件として位置づけられている。

第三に、データに基づく学校経営の確立である。少子化の進行に伴い、専門学校の経営環境は年々厳しさを増している。限られた経営資源を最適に配分し、教育の質を維持・向上させつつ持続可能な経営を実現するためには、経験と勘に依存した判断からデータに基づく意思決定への転換が不可欠である。

これら三つの意義は相互に独立したものではなく、循環的な関係にある。教員の労働環境改善は学生支援の質的向上をもたらし、学生支援の充実が就職実績の向上を通じて学校経営の安定化に寄与し、安定した経営基盤は教員への投資（採用・研修・待遇改善）を可能にする。本システムは、この好循環を制度的に駆動するための基盤インフラとして構想されている。

専門学校が「実学教育の現場」としての強みを発揮し続けるためには、AIを単なる自動化装置として導入するのではなく、教員の判断を補助する「知的協働パートナー」として位置づけることが肝要である。教育の温度——すなわち、教員と学生の間の人間的な信頼関係と応答的な対話——を保持したまま、データドリブン型の運営へと移行することが、本施策の根底にある設計思想である。

第四に、戦略的學生募集の実現である。少子化の進行により、専門学校間の学生獲得競争は激化の一途をたどっている。従来の経験則や人脈に依存した募集活動から、データ分析に基づく戦略的な募集活動への転換は、学校経営の持続可能性を確保するうえで不可避の課題である。本システムの「集める(Recruiter)」機能は、志願者動向の分析、広報施策のROI評価、入学希望者との関係管理を統合的に支援し、限られた予算と人員で最大の募集効果を実現するための基盤を提供する。

第五に、卒業生との長期的関係構築による教育エコシステムの拡張である。教育機関の価値は在学期間の教育のみに限定されるものではなく、卒業生のキャリア形成を通じて社会に還元される長期的な営みである。卒業生の継続的な学びを支援し、在校生へのメンタリングや企業との橋渡し等を通じて学校コミュニティに貢献する仕組みを構築することは、教育の質的向上、学校ブランドの強化、そして産学連携の深化に寄与する。

これら五つの意義は相互に独立したものではなく、循環的な関係にある。教員の労働環境改善は学生支援の質的向上をもたらし、学生支援の充実が就職実績の向上を通じて学校経営の安定化に寄与する。データに基づく戦略的な学生募集は安定した入学者の確保を実現し、卒業生との長期的な関係は在校生のキャリア支援と学校の社会的評価の向上に還元される。安定した経営基盤は教員への投資（採用・研修・待遇改善）を可能にする。本システムは、入学前から卒業後に至る学生ライフサイクル全体を包含するこの好循環を制度的に駆動するための基盤インフラとして構想されている。

専門学校が「実学教育の現場」としての強みを発揮し続けるためには、AIを単なる自動化装置として導入するのではなく、教員の判断を補助する「知的協働パートナー」として位置づけることが肝要である。教育の温度——すなわち、教員と学生の間の人間的な信頼関係と応答的な対話——を保持したまま、データドリブン型の運営へと移行することが、本施策の根底にある設計思想である。

2.6 本研究の社会的意義

本研究は、特定の専門学校における実践報告にとどまるものではなく、より広範な社会的意義を有する。

第一に、専門学校以外の教育機関への展開可能性である。本研究で提示するAI導入モデルおよび5領域フレームワーク（守る・育てる・回す・導く・集める）は、教育機関に共通する構造的課題に対応するものであり、高等学校、大学、職業訓練校等への水平展開が可能である。特に、教員の業務負担軽減とデータに基づく教育意思決定という課題は、学校種を超えた普遍的な課題であり、本研究で開発されるフレームワークは汎用性の高い参照モデルとなりうる。

表2-3に、教育機関種別ごとの導入適用可能性の比較を示す。専門学校における実装知見は、各教育機関の固有の文脈に応じたカスタマイズを経て、幅広い教育現場に応用されうるものである。

第二に、教育AIガバナンスモデルの提示である。本研究で導入する自律度制御モデル(L値に基づくGateモデル)は、教育分野におけるAIの適切な介入範囲と人間の判断権限のバランスを定量的に規定する枠組みである。Floridi et al.(2018)が提唱するAI倫理の原則——善行(Beneficence)、無危害(Non-maleficence)、自律(Autonomy)、正義(Justice)

)、説明可能性(Explicability)——に照らして、本モデルは教育AIの運用における倫理的ガイドラインの具体的な実装例を提供する。

教育分野におけるAI活用は急速に拡大しているが、その適切な制御に関する検証研究は未だ発展途上にある。Holmes, Bialik, and Fadel(2019)が指摘するように、教育AIの導入においては「何ができるか」という技術的可能性と「何をすべきか」という教育的・倫理的判断の間に慎重なバランスが求められる。本研究のGateモデルは、このバランスを定量的パラメータ(L値)として運用可能な形に具体化するものであり、教育AIガバナンスの標準化指針として制度設計への応用が期待される。

第三に、エビデンスに基づく教育政策立案への貢献である。本システムが生成するデータとその分析結果は、個別の学校運営の改善にとどまらず、専門学校教育全体の質的向上に関する政策議論に検証的な根拠を提供しうる。わが国においてEBPMの推進が政策的課題として位置づけられている中、教育現場から生成されるリアルタイムデータに基づく政策立案の基盤を提供することは、本研究の重要な社会的貢献である。

第3章 教育DXに関する先行研究と政策動向

3.1 教育におけるAI活用の国際動向

教育分野におけるAI(人工知能)の活用は、2010年代後半から国際的な政策課題として急速に注目を集めてきた。UNESCO(国際連合教育科学文化機関)は2021年に「AI and Education: Guidance for Policy-makers」を公表し、教育におけるAI活用の基本方針として、包摂性(Inclusion)、公平性(Equity)、ジェンダー平等、倫理的利用、透明性、および人間による監督(Human Oversight)の6原則を提示した。同報告書は、AI技術が教育のパーソナライゼーションを飛躍的に向上させる可能性を認めつつも、教育格差の拡大やデータプライバシーの侵害といったリスクに対する制度的対応の必要性を強調している。

OECD(経済協力開発機構)は「AI and the Future of Skills」プロジェクトにおいて、AI時代に求められるスキルの変容と、それに対応する教育制度改革の方向性を示した。同プロジェクトでは、認知的スキルのみならず、社会情動的スキル(Social and Emotional Skills)やメタ認知能力の重要性が高まることを指摘し、教育評価そのものの再設計が必要であると論じている。特に、AI技術を活用した形成的評価(Formative Assessment)の可能性については、学習者の理解度をリアルタイムに把握し、適切なフィードバックを提供する仕組みとしての有効性が繰り返し言及されている。

米国においては、2023年に教育省が「Artificial Intelligence and the Future of Teaching and Learning」を公表し、教育現場におけるAI活用の推奨事項と留意点を整理した。同報告書では、AIが教員の負担軽減に寄与しうる領域として、成績管理の自動化、学習コンテンツの推薦、および学習困難の早期検知を挙げている。欧州連合(EU)では、AI規制法(AI Act)の枠組みの中で教育分野を「高リスク」カテゴリに分類し、教育AIシステムに対して透明性要件、人間による監視義務、およびバイアス評価の実施を求めている。

アジア地域に目を転じると、中国は「新世代人工知能発展計画」(2017年)以降、教育AIへの大規模投資を進めており、適応型学習プラットフォームや自動採点システムの普及が急速に進んでいる。韓国は2023年に「AIデジタル教科書」の導入計画を発表し、2025年の全面実施を目指している。シンガポールは「National AI Strategy 2.0」(2023年)において、教育分野をAI活用の重点領域に位置づけ、教員のAIリテラシー向上プログラムを全国展開している。

教育AI研究の学術的潮流としては、以下の3領域が特に活発である。第一に、Learning Analytics(ラーニングアナリティクス)は、学習管理システム(LMS)上のログデータやデジタル学習行動データを分析し、学習プロセスの可視化および学習成果の予測を行う研究領域である。Siemens & Baker(2012)は、ラーニングアナリティクスを「学習者およびその文脈に関するデータの測定・収集・分析・報告であり、学習と学習が生起する環境の理解と最適化を目的とする」と定義した。第二に、Adaptive Learning(適応型学習)は、学習者の習熟度や学習スタイルに応じて学習コンテンツや難易度を動的に調整するシステムに関する研究であり、Knowledge Tracing(知識追跡)やBayesian Knowledge Tracing(BKT)などのモデルが提案されている。第三に、Intelligent Tutoring Systems(ITS: 知的チューティングシステム)は、1対1の個別指導を模倣するAIシステムに関する研究であり、Carnegie LearningのMathiaやAutoTutor等の実装例が蓄積されている。

これらの国際動向は、教育AIが実験的研究段階から制度的実装段階へと移行しつつあることを示しており、本研究が取り組むマルチエージェント型教育AI基盤の設計は、こうした国際的潮流の中に位置づけられるものである。

3.2 日本における教育DX政策

日本における教育DX(デジタルトランスフォーメーション)政策は、2019年に閣議決定された「GIGAスクール構想」を転換点として加速した。GIGAスクール構想は、義務教育段階の児童生徒に1人1台の端末と高速ネットワーク環境を整備する国家的施策であり、当初2023年度までの段階的整備を計画していたが、COVID-19パンデミックの影響を受けて前倒しされ、2021年度中にほぼ全国的な配備が完了した。文部科学省の公表資料では、公立小中学校で端末整備が全国的に進展し、インフラ整備は一定段階に到達したことが示されている。

しかしながら、端末の配備と教育現場における実質的な活用には大きな乖離が存在する。GIGAスクール構想に関する各種調査でも、端末整備と実質的な授業活用の間にはギャップが残ることが示されている。この乖離の要因として、教員のICTリテラシーの不足、デジタル教材コンテンツの不足、および既存の教育プロセスとデジタルツールの統合設計の欠如が指摘されている。

文部科学省は2022年1月に「教育データ活用ロードマップ」を策定し、教育データの標準化、流通基盤の整備、およびデータに基づく教育改善の推進を体系的に示した。同ロードマップは、教育データを「主体情報」「内容情報」「活動情報」の3類型に整理し、それらの連携によって個別最適な学びの実現を目指す構想を描いている。特に重要なのは、データの活用が教員の指導改善を支援する方向で設計されるべきであるとの基本方針が示されている点であり、これはAIによる意思決定支援と人間の判断の関係を規定する上で重要な政策的枠組みとなっている。

2023年6月に閣議決定された「第4期教育振興基本計画」(計画期間:2023~2027年度)は、「2040年以降の社会を見据えた持続可能な社会の創り手の育成」および「日本社会に根差したウェルビーイングの向上」を基本的な方針として掲げ、その具体的施策の一つとして教育DXの推進を位置づけている。同計画では、「個別最適な学びと協働的な学びの一体的充実」を実現するための基盤としてデジタル技術を活用することが明記されており、AIを含むEdTechの教育現場への導入を積極的に推進する方針が示されている。

さらに、内閣府が推進する「Society 5.0」構想は、サイバー空間とフィジカル空間の高度な融合によって経済発展と社会的課題の解決を両立する人間中心の社会を目指すものであり、教育分野はその中核的な適用領域として位置づけられている。Society 5.0における教育像は、「学びの個別化・協働化・探究化」が同時に実現される状態として描かれており、AIやデータ分析技術がその実現手段として期待されている。

デジタル庁は2022年度から教育データの標準化に向けた取り組みを推進しており、「教育データ標準」として学習指導要領コードの体系化、学校コードの整備、およびデータ連携のための技術仕様の策定を進めている。これらの標準化は、学校間・自治体間でのデータ連携を可能にし、転校や進学時のデータポータビリティを確保するための基盤となる。本研究が構築するシステムにおいても、これらの標準規格との整合性を確保することが将来的な相互運用性の観点から重要である。

以上のように、日本における教育DX政策は、インフラ整備段階からデータ利活用段階へと移行しつつあり、AIを活用した教育支援システムの研究・開発は、こうした政策的方向性と合致するものである。ただし、高等教育機関、とりわけ専門学校における教育AI活用に関しては、政策的にも学術的にも十分な蓄積があるとはいいがたく、本研究が取り組む課題の意義はここにある。

3.3 教育AIに関する先行研究

3.3.1 学習リスク早期検知に関する研究

ラーニングアナリティクスの応用として最も実践的な関心を集めているのが、学習リスクの早期検知(Early Warning Systems: EWS)である。Jayaprakash et al. (2014)は、LMS上の学習行動データ(ログイン頻度、課題提出状況、フォーラム参加率等)を説明変数として、学期途中で成績不振を予測するモデルを構築し、ロジスティック回帰、決定木、サポートベクターマシン等の手法を比較検討した。その結果、複数の特徴量を組み合わせた予測モデルが約75~85%の精度で学習困難学生を同定できることを示した。

Macfadyen & Dawson (2010)は、LMSのトラッキングデータと最終成績との関係を分析し、オンラインディスカッションへの投稿数や課題提出の完了率が最終成績の強力な予測因子であることを明らかにした。日本国内でも、出席データと成績データの統合により退学リスクの早期把握を試みる実践が報告されている。

本研究が設計するシステムにおいては、出席データ、成績推移、面談記録、および行動ログを統合的に分析する「Guardian Agent」がリスク検知機能を担う。先行研究が示す予測モデルの知見を基盤としつつ、専門学校特有のデータ(資格取得状況、就職活動進捗等)を組み込んだ多次元的リスク評価の実現を目指す。

3.3.2 個別最適化学習に関する研究

Adaptive Learning(適応型学習)に関する研究は、学習者モデリングと教材提示戦略の最適化を中心に展開されてきた。Corbett & Anderson (1995)が提案したBayesian Knowledge Tracing(BKT)は、学習者の各スキルに対する習熟確率をベイズ推定する手法であり、Intelligent Tutoring Systemsの中核的な技術として広く活用されている。その後、Deep Knowledge Tracing(DKT)がPiech et al. (2015)によって提案され、リカレントニューラルネットワークを用いて学習者の知識状態をモデル化する手法が示された。

個別最適化の観点からは、Vanlehn(2011)がITSの学習効果に関するメタ分析を行い、1対1の人間チューターと比較してITSの効果量はやや低いものの、クラス全体での一斉授業と比較すれば明確に高い学習効果を示すことを明らかにしている。

本研究の文脈では、専門学校における個別最適化は学科専門分野の学習にとどまらず、資格取得計画の最適化、就職活動スケジュールの個別調整を含む包括的なものとなる。これは従来の適応型学習研究の射程を拡張するものである。

3.3.3 教育現場における自然言語処理の応用

近年の大規模言語モデル(Large Language Models: LLM)の発展に伴い、教育現場における自然言語処理(NLP)の応用が急速に拡大している。面談記録の自動要約、レポートの自動生成、および多言語対応は、教員の事務負担軽減に直結する応用領域である。

Kasneci et al. (2023)は、ChatGPTに代表されるLLMの教育応用について包括的なレビューを行い、教育コンテンツの生成、学習者への個別フィードバック、および教育評価の支援における有用性と課題を整理した。特に、LLMが生成する内容の正確性(Hallucination問題)、バイアスの内在、および学習者の批判的思考力への影響が重要な課題として指摘されている。

本研究が設計するマルチエージェントシステムでは、面談サマリー生成、保護者向けレポート生成、および教材多言語翻訳をLLMベースのエージェントが担う設計となっており、上述の先行研究が示す課題を「Gate機構」による人間の承認プロセスの介在によって制御する構成をとる。

3.3.4 カリキュラム最適化・時間割最適化に関する研究

時間割最適化は、古典的な組合せ最適化問題(Constraint Satisfaction Problem / Combinatorial Optimization)として長い研究の歴史を持つ。教室・教員・学生の制約条件下で最適時間割を生成する問題はNP困難であることが知られており、遺伝的アルゴリズム、シミュレーテッドアニーリング、整数計画法等の手法が適用されてきた。

近年では、強化学習を用いた動的スケジューリングの研究も進展しており、固定的な制約充足にとどまらず、学生の学習状態や教員の負荷状況をリアルタイムに反映した適応的なカリキュラム編成の可能性が示されている。本研究のシステムにおいては、時間割最適化機能を「Admin Agent」の一機能として位置づけ、教育効果とリソース制約の双方を考慮した多目的最適化アプローチを採用する設計である。

3.4 教育AIの倫理・ガバナンスに関する議論

教育分野におけるAI活用は、その対象が発達途上にある学習者であることから、倫理的配慮が特に強く求められる。内閣府は2019年に「人間中心のAI社会原則」を策定し、AI社会の基本理念として「人間の尊厳が尊重される社会」「多様な背景を持つ人々が多様な幸せを追求できる社会」「持続性ある社会」の3つを掲げた。同原則は、教育分野に特化したものではないが、AIによる意思決定支援が人間の自律性を損なわないこと、およびAIシステムの判断根拠が説明可能であることを基本的要請としている。

教育データの個人情報保護に関しては、米国のFERPA(Family Educational Rights and Privacy Act)、EUのGDPR(General Data Protection Regulation)、および日本の個人情報保護法がそれぞれ異なる枠組みを提供している。FERPAは教育記録へのアクセス権と修正権を保護者および成人学生に付与し、教育機関による第三者への情報開示を原則禁止する。GDPRは「忘れられる権利」やデータポータビリティの権利を含むより包括的な保護枠組みを提供しており、自動化された意思決定に対する異議申立権(第22条)は教育AI文脈において特に重要である。日本の個人情報保護法は2022年の改正により、学術研究目的の例外規定が見直され、教育データの研究利用に関するガバナンスの強化が図られた。

Human-in-the-loop(HITL)設計は、AIの判断に人間が介在することで、AIの誤判断によるリスクを低減し、最終的な意思決定の責任所在を明確にする設計原則である。教育分野では、AIの出力はあくまで「参考情報」として提示され、最終的な教育的判断は教員が行うという原則が広く共有されている。Holmes et al. (2022)は、教育AIにおけるHITL設計の類型を整理し、「AI-in-the-loop」(AIが教員を支援)、「Teacher-in-the-loop」(教員がAIを監視)、「Student-in-the-loop」(学習者がAIの動作を理解・制御)の3層構造を提案した。

AI説明可能性(Explainable AI: XAI)の教育分野への適用も重要な研究課題である。学習リスクの予測やキャリアマッチングの推薦において、その根拠が教員や学生に理解可能な形で提示されなければ、AIシステムへの信頼構築は困難である。Khosravi et al.(2022)は、ラーニングアナリティクスにおけるXAIの適用について体系的レビューを行い、SHAP(SHapley Additive exPlanations)やLIME(Local Interpretable Model-agnostic Explanations)等の手法が学習者の成績予測モデルの説明に有効であることを示した。

本研究では、これらの倫理・ガバナンスの要請に応えるため、「Gate機構」と呼ぶ自律度制御メカニズムを設計する。Gate機構は、AIエージェントの出力に対して、その影響度と不可逆性に応じた承認プロセスを介在させる仕組みであり、自動化レベルを連続値Lとして定義し、L=0.2(事務的自動処理)からL=0.7(進路提案、教員承認必須)まで段階的に制御する。この設計は、上述のHITL原則およびXAI要件を技術的に実装するものである。

3.5 マルチエージェントシステムに関する研究

3.5.1 AIエージェントの定義と類型

AIエージェント(AI Agent)とは、環境を知覚し、自律的に判断・行動する能力を持つソフトウェアエンティティとして定義される。Russell & Norvig(2021)は、エージェントを「知覚列(percept sequence)を行動に写像する関数を実装するもの」と定義し、単純反射型(Simple Reflex)、モデルベース型(Model-based)、目標ベース型(Goal-based)、効用ベース型(Utility-based)、および学習型(Learning)の5類型に分類している。

近年のLLMの発展は、エージェントの設計パラダイムに根本的な変革をもたらしている。Wang et al.(2024)は、LLMベースのエージェントの研究動向をサーベイし、計画(Planning)、記憶(Memory)、ツール使用(Tool Use)を基本能力とするエージェントアーキテクチャの類型を整理した。LLMベースエージェントは、自然言語による指示理解と推論が可能であり、従来のルールベースやMLベースのエージェントと比較して、タスクの柔軟性と汎用性が大幅に向上している。

3.5.2 マルチエージェントシステムのアーキテクチャ

マルチエージェントシステム(Multi-Agent System: MAS)は、複数のエージェントが相互に通信・協調しながら、単一のエージェントでは解決困難な複雑なタスクを遂行するシステムである。MASのアーキテクチャは、大きく以下の3類型に分類される。第一に、集中型(Centralized)アーキテクチャでは、オーケストレーター(Orchestrator)エージェントが他のエージェントの実行を制御する。第二に、分散型(Decentralized)アーキテクチャでは、各エージェントが対等な立場で自律的に協調する。第三に、階層型(Hierarchical)アーキテクチャでは、エージェント間に上下関係が存在し、上位エージェントが下位エージェントにタスクを委任する。

LLMベースのMASに関しては、AutoGen(Wu et al., 2023)やCrewAI等のフレームワークが提案されており、複数のLLMエージェントがそれぞれ異なる役割を担いながら対話的に問題解決を行う方式が示されている。Hong et al.(2024)が提案したMetaGPTは、ソフトウェア開発プロセスをMASとしてモデル化し、プロダクトマネージャー、アーキテクト、プログラマー等の役割を持つエージェントが構造化された成果物(Structured Output)を介して協調する仕組みを示した。

3.5.3 エージェント間協調と「Agent Team」概念の位置づけ

MASにおけるエージェント間の協調メカニズムとしては、契約ネットプロトコル(Contract Net Protocol)、ブラックボード・アーキテクチャ、およびメッセージパッシングが古典的な手法として知られている。近年のLLMベースMASでは、自然言語によるメッセージパッシングがエージェント間通信の主要な手段となっており、共有メモリ(Shared Memory)や共有ワークスペースを介した間接的協調の方式も提案されている。

本研究が提案する「Agent Team」概念は、複数のAIエージェントが共有する文脈空間(Contextual Space)として位置づけられる。これは、従来のMAS研究における「環境」(Environment)概念を拡張したものであり、単なるデータの格納場所ではなく、エージェント間の知識共有、タスクの優先順位調整、およびガバナンスルールの適用を統合的に管理する意味論的空間として機能する。この設計は、上述のブラックボード・アーキテクチャの知見を継承しつつ、LLM時代の自然言語ベースの知識表現に適合した形に再構成したものである。

3.5.4 教育分野におけるMAS適用事例

教育分野におけるMASの適用は、比較的新しい研究領域である。Graesser et al.(2017)は、AutoTutorシステムにおいて複数のエージェント(チューター、学習者モデル、感情検知等)が協調して学習支援を行う構成を報告している。また、

Baylor & Kim(2005)は、学習環境における複数のペダゴジカルエージェント(教授エージェントと動機づけエージェント)の協調が、学習者の学習意欲と学習成果の双方に正の影響を与えることを実験的に示した。

しかしながら、これらの先行研究は主として学習支援の文脈に限定されており、学校運営全体を対象としたMASの設計に関する研究は極めて限られている。進路指導、学生管理、教員支援、学校経営という複数の機能領域を横断するマルチエージェント型教育基盤の設計・実装に関する体系的な研究は、現時点で限定的である。

3.6 本研究の位置づけ

以上の先行研究レビューを踏まえ、本研究の学術的位置づけを明確にする。

先行研究との差異は、主として以下の3点に集約される。

第一に、**12エージェント統合型アーキテクチャ**の提案である。従来の教育AI研究は、リスク検知、適応型学習、面談支援等の個別機能に焦点を当てたものが大半であり、これらを統合的に扱うマルチエージェントシステムとしての設計・実装は試みられていない。本研究は、Guardian(学習リスク検知)、Tutor(個別最適化学習)、Admin(事務処理支援)、Management(学校経営支援)を含む12のAIエージェントを「Agent Team」と呼ぶ共有文脈空間上で統合的に運用する構成を提案する。各エージェントは独立に機能しつつも、共有文脈を介して相互に情報を参照し、より包括的な教育支援を実現する。

第二に、**Gate機構による自律度制御モデル**の設計である。先行研究においてHuman-in-the-loopの重要性は繰り返し指摘されているものの、AIの自律度をタスクの性質に応じて段階的に制御する具体的な技術的枠組みは十分に提示されていない。本研究のGate機構は、各エージェントの出力に対する承認レベルを連続値Lとして定義し、タスクの影響度・不可逆性に応じて自動実行から教員承認必須まで段階的に制御する仕組みである。このモデルは、教育AI固有の倫理的要請に対する具体的な技術的解を提示するものであり、教育AIガバナンスの標準化指針としても応用可能である。

第三に、**4ロール型(管理者・教員・事務方・学生)UI設計**に基づくステークホルダー統合である。教育AI研究の多くは学習者向けまたは教員向けの単一インターフェースを対象としているが、実際の教育現場には多様なステークホルダーが存在し、それぞれの業務文脈と情報ニーズは大きく異なる。本研究は、管理者(admin)、教員(teacher)、事務方(office)、学生(student)の4ロールに対してそれぞれ最適化されたダッシュボードとナビゲーションを設計し、同一のデータ基盤・AIエージェント群に対して異なるビューを提供するアーキテクチャを提案する。

本研究が埋める研究ギャップは、以下のように要約される。従来の研究は、(a) 個別機能の研究、(b) 倫理原則の提示、(c) MASの理論的検討のいずれかに偏る傾向があり、これらを統合した実践的なシステム設計に関する研究が欠如していた。本研究は、専門学校という具体的な教育現場を対象として、12エージェント統合型アーキテクチャ、Gate機構による自律度制御、および4ロール型UI設計を一体的に提案し、UIプロトタイプとしてその一部を実装する点で、先行研究が十分にカバーしてこなかった領域に踏み込むものである。

さらに、本研究は理論的提案にとどまらず、Next.js App Routerを基盤としたフロントエンドプロトタイプの実装を通じて、提案アーキテクチャにおけるUIレイヤーの実現可能性を検証する。全体アーキテクチャの検証は今後の課題である。この実装指向のアプローチは、教育AI研究における理論と実践の架橋に貢献するものと位置づけられる。

第4章 システムアーキテクチャ概要

4.1 本システムの設計思想

4.1.1 教育現場におけるデータ活用の課題

日本の教育機関、とりわけ中等教育機関においては、成績データ、出席記録、カリキュラム情報、履修履歴、保護者連絡ログなど、教育活動に伴って生成される膨大なデータが、リレーショナルデータベース(PostgreSQL、MySQL等)をはじめとする各種システムに蓄積されている。しかしながら、これらのデータは個別のシステムに散在しており、横断的な分析や統合的な活用には多大な手作業を要するのが現状である。教職員は日常の授業準備、生徒指導、事務処理に追われ、蓄積されたデータを意思決定に十分活用する時間的余裕を持たない。すなわち「データはあるが、活用する時間がない」という構造的課題が存在する。

この課題に対し、本システムは「眠れるデータを意思決定の材料に変える頭脳」というコンセプトのもとに設計された。本システムは単なる校務管理ツール(School Management System)ではなく、教育機関における意思決定を知的に支援する「Decision Intelligence(意思決定インテリジェンス)」層として機能する(図4-1参照)。

4.1.2 Decision Intelligence層としての位置づけ

Decision Intelligenceとは、データサイエンス、社会科学、マネジメントサイエンスを統合し、意思決定プロセスそのものを改善することを目的とする学際的アプローチである。本システムはこの概念を教育領域に適用し、以下の3つの設計原則を掲げている。

第一に、「補助原則(Subsidiarity Principle)」である。AIはあくまで教員の判断を補助する存在であり、最終的な意思決定権は常に人間(教員・管理者)に帰属する。この原則は、後述するGate機構によって技術的に担保される設計としている。

第二に、「データ統合原則」である。散在するデータソースを入力層(Input Layer)において統合し、処理層(Processing Layer)で横断的に分析することにより、個別のデータベースでは得られない洞察を生成する。

第三に、「ロールベース提供原則」である。同一のデータおよび分析結果であっても、利用者の役割(ロール)に応じて最適化された形式で提供する。管理者にはガバナンス視点の統計を、教員には生徒個別の指導材料を、事務方には手続き効率化の情報を、学生には自己理解の支援をそれぞれ提供する。

4.2 3層アーキテクチャ

本システムの全体構成は、Input Layer(入力層)、Processing Layer(処理層)、Output Layer(出力層)の3層から成る(図4-2参照)。この3層構成は、責任の分離(Separation of Concerns)を徹底し、各層の独立した改善を可能にするとともに、個人情報保護とリスク管理のための「Gate機能」を処理層に組み込むことで、教育データの取り扱いに求められる信頼性を確保している。

4.2.1 Input Layer(入力層)

入力層は、学校が保有する既存のデータベースから本システムへデータを取り込む役割を担う。対象となるデータソースは以下の通りである。

9. 成績データ -- 各科目の定期考査結果、模擬試験成績、評定値等
10. 出席記録 -- 日次の出欠情報、遅刻・早退記録、曜日別パターン
11. カリキュラム情報 -- 学年・コース別の教育課程、単元構成、進捗情報
12. 履修履歴 -- 生徒個別の科目選択履歴、取得単位情報
13. 保護者連絡ログ -- 面談記録、連絡帳記録、三者面談議事録

データの取り込みは、バッチインポート方式を基本とする。本システムのフロントエンド実装においては、事務方ロール(office)のナビゲーション項目「O-14 データ取り込み」として、このバッチインポート機能に対応するビューコンポーネント(「OfficeDataImport」)が設けられている。学校データベースとの接続にはRDB(PostgreSQL/MySQL)を想定し、将来的にはリアルタイム取り込みへの拡張も視野に入れている。

4.2.2 Processing Layer(処理層)

処理層の中核を成すのが「本システムのエンジン」である。エンジンは入力層から取り込んだデータを受け取り、後述する12のAIエージェントによる分析・生成処理を実行する。

処理層にはGate機能が組み込まれている。Gate機能とは、AIの自律レベル(Autonomy Level)を制御し、機微な情報については人間の承認(Human-in-the-loop)を強制するセキュリティ機構である。Gate機能は各エージェントの出力に対してリスクレベル(L値)を付与し、そのレベルに応じて以下の3段階の制御を行う(図4-3参照)。

表4-1 Gate機能によるリスクレベル別制御

リスクレベル	L値	対象業務例	制御内容
低	L=0.2	日程調整、単純集計	自動処理・事後報告
中	L=0.3	教材翻訳	教科主任の承認が必要
高	L=0.7	進路判定、メンタルヘルス	Human承認必須。AIは「草案作成」に徹する

このGate機構により、「AIが提案し、先生が決める」という設計思想が技術的に実現する構成としている。教育現場においては、生徒の進路に関わる判断やメンタルヘルスに関する対応など、AIに全面的に委任することが適切でない領域が存在する。Gate機能はこうした領域において、AIの出力を「提案」の段階に留め、必ず教員による確認・承認のプロセスを経るよう制御することで、責任の所在を明確化している。

4.2.3 Output Layer(出力層)

出力層は、処理層による分析・生成結果を、ロールに応じた4種類のダッシュボードとして利用者に提示する。具体的には、管理者(admin)、教員(teacher)、事務方(office)、学生(student)の4ロール型ダッシュボードであり、合計56のビューコンポーネントを通じて12の負担削減ソリューションの成果を可視化する設計としている。出力層の詳細については4.4節および4.5節で述べる。

4.3 4象限 x 12エージェント構成

本システムは、学校運営の全域をカバーする4つの領域(象限: Quadrant)に、合計12の打ち手(10のAgent + 2のAgent Team)を配置している(図4-4参照)。ここで「Agent」とは特定の単一タスクを処理する機能単位を指し、「Agent Team」とは複数のAgent(Planet)が連携して複雑なワークフロー全体を解決するシステムを指す。すなわち、課題の深度に応じて、単機能のAgentから複合課題を解決するAgent Teamまで、段階的にソリューションを展開する設計となっている。

4.3.1 4象限の定義

4象限はそれぞれ以下の役割を持つ。

- **Quadrant 1: 守る(Guardian Agents)** -- リスクの早期検知と出席解析を通じて、生徒の兆候を見逃さないデータ駆動型の早期警戒を実現する。
- **Quadrant 2: 育てる(Tutor Agents)** -- 個別最適化された学習プランの生成とカリキュラム最適化を通じて、「学び」の自動設計を実現する。
- **Quadrant 3: 回す(Admin Agents)** -- 面談サマリーの自動生成、保護者向けレポート生成、時間割最適化を通じて、膨大な事務作業からの解放を実現する。
- **Quadrant 4: 導く(Management & Agent Teams)** -- 成績評価の妥当性チェック、学校経営ダッシュボード、進路推薦支援、留学生対応、進路相談支援を通じて、公平性と経営視点に立った意思決定支援を実現する。

4.3.2 12エージェントの一覧

表4-2 12エージェント一覧

分類	象限	識別子	名称	処理ロジック	主な出力
Agent	Q1: 守る	Agent 1	学習リスク早期検知	成績トレンド分析 x 科目横断相関 → 危険スコア算出	リスクレベル判定 (Green/Yellow/Red)と推奨アクションの提示

Agent	Q1: 守る	Agent 3	出席・遅刻パターン解析	曜日別傾向 × 特定科目との相関 → クラス全体比較	問題兆候の早期発見レポート
Agent	Q2: 育てる	Agent 2	個別最適化学習プラン生成	弱点単元抽出 + 過去の誤答分析	「来週の学習プラン」と推奨教材の自動提案。達成度予測の可視化
Agent	Q2: 育てる	Agent 6	カリキュラム最適化	単元別平均点分析 + 理解度推移 + 他年度比較	データに基づく単元再設計案
Agent	Q3: 回す	Agent 7	面談サマリー自動生成	成績、生活記録、過去ログの統合分析	面談要約、懸念点、推奨対話項目の生成
Agent	Q3: 回す	Agent 9	保護者向けレポート生成	成績推移や平均との差分を解析	自然言語によるレポート作成
Agent	Q3: 回す	Agent 10	時間割最適化	授業数、連続コマ、専門科目、教室制約の最適化	負荷最小化時間割と代替案の提示
Agent	Q4: 導く	Agent 4	成績評価妥当性チェック	教師別分布分析・標準偏差異常検出	評価バイアスの可視化と公平性監査の自動化
Agent	Q4: 導く	Agent 8	学校経営ダッシュボード	学年別パフォーマンス、退学率、進学率、授業満足度の統合分析	経営層向け意思決定レポートと改善シミュレーション
Agent	Q4: 導く	Agent 5	進路推薦支援	過去進学実績DB照合 × 適性傾向分析	データに基づいた進路候補リストの提示
Agent Team	Q4: 導く	Agent Team 1	留学生対応・教材自動翻訳システム	用語辞書照合 (Step 1) → 文脈翻訳 (Step 2) → 難易度適応 (Step 3)	多言語教材 + 対訳表。Gate: L=0.3(教科主任承認Gate設置)
Agent Team	Q4: 導く	Agent Team 2	進路相談負担軽減	4つのPlanetが連携: 状況把握 → 候補探索 → 面談設計 → 日程調整	1枚サマリー、進路候補リスト、質問テンプレ、最適日程候補3案

4.3.3 AgentとAgent Teamの設計思想

表4-2に示した通り、Agent 1からAgent 10までは単機能の処理単位であり、それぞれが特定の課題に対して入力・処理・出力の一連の流れを完結する。一方、Agent Team 1およびAgent Team 2は、複数のAgent相当の処理単位 (Planet) が連携して動作する複合システムである (図4-5参照)。

Agent Team 2 (進路相談負担軽減) を例にとると、以下の4つのPlanetから構成される。

- Planet 1: Career Context Aggregator (状況把握)** -- 成績、面談履歴、希望調査、保護者コメントを入力とし、「1枚サマリー」と「強み弱み抽出」を出力する。
- Planet 2: Career Option Intelligence (候補探索)** -- 成績偏差帯、外部大学DB、奨学金情報を照合し、データに基づく進路候補リストを生成する。Gate: L=0.7であり、合格確率推定を含むため、必ず教員の承認を経てから生徒に提示する。
- Planet 3: Counseling Conversation Planner (面談設計)** -- 過去ログと性格傾向から、「質問テンプレ」と「保護者説明ポイント」を生成する。
- Planet 4: Smart Scheduling Agent (日程調整)** -- 先生・生徒・保護者の全カレンダーと優先度スコアを解析し、最適候補3案の提示と自動仮予約までを完結する。Gate: L=0.2 (高自動化可能)。

このように、Agent Teamは進路相談業務を「情報収集」「整理」「比較」「提案」「調整」に分解し、各ステップを専門のPlanetに委任することで、業務全体の効率化を達成する設計としている。

4.4 ロールベースアクセス制御

4.4.1 4ロールの定義

本システムは、教育機関における利用者を4つのロールに分類し、各ロールに最適化された情報提供と機能アクセスをUIプロトタイプとして実現している。ロールの定義は、システムの型定義(`lib/types.ts`)において以下の通り宣言されている。

```
``typescript export type Role = "admin" | "teacher" | "office" | "student" ``
```

各ロールの詳細を表4-3に示す。

表4-3 ロール定義と権限範囲

ロール識別子	日本語名称	略称	ナビ項目数	主な権限範囲
admin	管理者	A	14	ユーザー管理、クラス管理、TG管理・承認、進路先マスタ管理、マイルストーン管理、お知らせ管理、統計・レポート、学生グループ管理、AIツール管理、AI設定
teacher	教員	T	15	学生一覧・詳細(カルテ)、面談記録一覧・入力、リスクアラート一覧、進路先検索・詳細、出願管理、逆算カレンダー、面談予約管理、ダイジェスト確認、AIツール、個別生徒AI診断
office	事務方	O	15	学生一覧・詳細、テスト成績管理、書類・手続き管理、進路先情報・詳細、出願管理、学生グループ管理、面談予約管理、統計、ダイジェスト確認、データ取り込み、AIツール
student	学生	S	12	マイページ、テストスコア、目標設定、面談記録、進路先情報・詳細、出願状況、カレンダー、面談予約、AIツール、成果物一覧

4.4.2 ROLE_CONFIGによる集約管理

4ロールの設定は、`ROLE\_CONFIG`定数として一元管理されている。`ROLE\_CONFIG`は`Record<Role, {...}>`型のオブジェクトであり、各ロールについて以下の属性を保持する。

- `label` (日本語表示名)、`shortLabel` (1文字略称)
- `colorClass` (テキスト色CSSクラス)、`bgClass` (背景色CSSクラス)、`lightBgClass` (淡い背景色CSSクラス)

- `navItems` (ナビゲーション項目の配列)

この集約管理により、新規ロールの追加や既存ロールの権限変更が、単一の設定オブジェクトの編集のみで完結する。ヘッダーコンポーネント(`portal-header.tsx`)、サイドバーコンポーネント(`portal-sidebar.tsx`)、ロール切替タブ(`app/page.tsx`)のいずれもが`ROLE\_CONFIG`を参照して動的に表示を切り替えるため、UIの一貫性が構造的に保証されている。

4.4.3 ロール固有のカラーシステム

各ロールには視覚的な識別性を高めるための専用カラーが割り当てられている。色彩設計にはOKLCh色空間を採用し、知覚的均一性(perceptual uniformity)を確保している(表4-4参照)。

表4-4 ロール別カラー定義(OKLCh色空間)

ロール	意味色	CSS変数名	OKLCh値	淡色(Light)OKLCh値
admin	紫	`--role-admin`	`oklch(0.45 0.18 265)`	`oklch(0.93 0.04 265)`
teacher	緑	`--role-teacher`	`oklch(0.50 0.16 155)`	`oklch(0.93 0.04 155)`
office	黄橙	`--role-office`	`oklch(0.62 0.18 55)`	`oklch(0.93 0.05 55)`
student	青	`--role-student`	`oklch(0.50 0.14 240)`	`oklch(0.93 0.04 240)`

これらのCSS変数は`app/globals.css`のルートセクタ(`:root`)で定義され、Tailwind CSS 4.2の`@theme inline`ディレクティブを通じて`bg-role-admin`、`text-role-teacher`等のユーティリティクラスとして利用可能になっている。ダークモード時にも同一の変数が参照されるため、テーマ切替時のロール識別性が維持される。

色彩設計の意図として、管理者の紫は権威と統制を、教員の緑は成長と育成を、事務方の黄橙は効率と活動を、学生の青は信頼と探究をそれぞれ象徴している。

4.5 VIEW_MAPレジストリパターン

4.5.1 動的ビューレンダリングの設計

本システムのフロントエンドは、Next.js App Routerを基盤としつつも、ルーティングによるページ遷移ではなく、クライアントサイドの状態管理によるビュー切替を採用している。この設計の中核を成すのが`VIEW\_MAP`レジストリパターンである。

`VIEW\_MAP`は、`components/portal/views/view-registry.tsx`において定義された`Record<string, ComponentType>`型のオブジェクトであり、ナビゲーションID(文字列キー)とReactコンポーネントを1対1で対応付ける(図4-6参照)。

```
``typescript
export const VIEW_MAP: Record<string, ComponentType> = {
  "a-1": AdminDashboard,
  "a-2": AdminUserManagement,
  // ... 56エントリ
  "s-13": StudentPortfolio,
}
```

メインページ(`app/page.tsx`)における描画ロジックは、以下の簡潔なルックアップ処理によって実現されている。

```
``typescript
const renderView = () => {
  const ViewComponent = VIEW_MAP[activeNavId]
  if (!ViewComponent) return null
  return <ViewComponent />
}
```

`activeNavId`はユーザーが選択したナビゲーション項目のIDであり、サイドバーのクリックイベントによって更新される。この間接参照パターンにより、ビューの追加・変更が`VIEW\_MAP`へのエントリ追加のみで完結し、メインページのロジックに手を加える必要がない。

4.5.2 ナビゲーションIDの命名規則

ナビゲーションIDは「{ロール接頭辞}-{連番}」の形式で命名されている。ロール接頭辞はadmin='a'、teacher='t'、office='o'、student='s'であり、各ロール内で連番が付与される(表4-5参照)。

表4-5 VIEW_MAP登録数の内訳

ロール	接頭辞	登録ビュー数	ID範囲
admin	a	14	a-1 ~ a-16
teacher	t	15	t-1 ~ t-18
office	o	15	o-1 ~ o-15
student	s	12	s-1 ~ s-13
合計	--	56	--

ID範囲と登録ビュー数が一致しないのは、開発過程における仕様変更でID番号が欠番となったためであるが、既存のIDとの互換性を維持するため、連番の振り直しは行っていない。この設計判断は、将来的に欠番IDを新規機能で埋めることが可能であり、拡張性の観点からも合理的である。

4.5.3 拡張容易性の確保

VIEW_MAPレジストリパターンは、以下の点においてシステムの拡張容易性を確保している。

第一に、**新規ビューの追加**が容易である。新たなビューコンポーネントを作成し、VIEW_MAPにエントリを追加し、対応するROLE_CONFIGのnavItemsに項目を追加するだけで、新機能がサイドバーに表示され、利用可能となる。メインページの描画ロジックの変更は不要である。

第二に、**ロール間のビュー共有**が可能である。現在の実装では各ロールに専用のビューコンポーネントを割り当てているが、VIEW_MAPの設計上、異なるナビゲーションIDに同一のコンポーネントを割り当てても可能であり、将来的なロール間機能共有に柔軟に対応できる。

第三に、**遅延読み込み(Lazy Loading)への移行**が容易である。現在は静的インポートを用いているが、`React.lazy()`や`next/dynamic`による動的インポートへの切替が、VIEW_MAPのエントリ定義部分の変更のみで実現可能である。ビュー数の増加に伴う初期読み込みパフォーマンスの最適化を、アーキテクチャの変更なしに達成できる。

4.5.4 アイコンマッピングの仕組み

サイドバー(`portal-sidebar.tsx`)においては、ナビゲーション項目のラベル文字列とアイコンコンポーネントの対応を`iconMap`オブジェクトで管理している。Lucide Reactアイコンライブラリから選定したアイコンを用い、「ダッシュボード」にはLayoutDashboardアイコン、「学生一覧」にはUsersアイコン等、日本語ラベルとの直感的な対応を実現している。

4.6 小括

本章では、本システムのシステムアーキテクチャについて、設計思想から具体的な実装構造に至るまでを概観した。

本システムは、「眠れるデータを意思決定の材料に変える頭脳」として、3層アーキテクチャ(Input Layer / Processing Layer / Output Layer)のもとでデータの取り込み・分析・可視化を一貫して行う。処理層に組み込まれたGate機能は、AIの自律レベルをリスクに応じて段階的に制御し、「AIが提案し、先生が決める」というHuman-in-the-loopの原則を技術的に担保する設計としている。

4象限12エージェント構成(10 Agent + 2 Agent Team)は、「守る」「育てる」「回す」「導く」「集める」の5領域から学校運営を包括的にカバーし、特に複合的な課題に対してはAgent Teamによる複数Agent連携で対応する。

フロントエンドにおいては、4ロール型ダッシュボード(admin / teacher / office / student)がROLE_CONFIGによる集約管理のもとで56のビューコンポーネントを提供し、VIEW_MAPレジストリパターンによって高い拡張容易性を実現している。OKLCh色空間によるロール別カラーシステムは、知覚的均一性に基づくロール識別性の確保を目指して設計されている。

次章では、これらのアーキテクチャ上で実現されるGate機構の詳細な設計について論じる。

図表一覧

- 図4-1 本システムのプロ念図 --「眠れるデータを意思決定の材料に交える頭脳」
- 図4-2 3層アーキテクチャの全体構成 (Input Layer / Processing Layer / Output Layer)
- 図4-3 Gate機能によるリスクレベル別制御の概念図
- 図4-4 4象限 x 12エージェント配置図
- 図4-5 AgentとAgent Teamの構造比較 (単機能処理 vs. Planet連携)
- 図4-6 VIEW_MAPレジストリパターンによる動的ビューレンダリングの概念図
- 表4-1 Gate機能によるリスクレベル別制御
- 表4-2 12エージェント一覧
- 表4-3 ロール定義と権限範囲
- 表4-4 ロール別カラー定義 (OKLCh色空間)
- 表4-5 VIEW_MAP登録数の内訳

第5章 Gate機構による信頼性・責任分解設計

5.1 Gate機構の設計思想

5.1.1 「AIが提案し、先生が決める」という原則

教育機関におけるAI導入の最も本質的な課題は、「誰が最終的な意思決定を行うのか」という責任の所在にある。本システムの設計にあたり、本研究では一貫して「AIが提案し、先生が決める (AI proposes, Teacher disposes)」という基本原則を堅持した。この原則は、単なるスローガンではなく、システムアーキテクチャの中核に組み込まれた技術的制約として実装される。

図5-1に示した「信頼のアーキテクチャ」は、本システムの三層構造——Input Layer (学校データベース)、Processing Layer (本システムのエンジン+Gate機能)、Output Layer (12の負担削減ソリューション)——において、Processing Layerに位置するGate機能が、AIの自律レベルを制御し、機微な情報に対しては人間の承認 (Human-in-the-loop) を強制するセキュリティ機構であることを明示している。すなわち、Gate機構は本システムにおける「信頼の設計 (Trust Architecture)」の中核をなす概念であり、AIシステムの出力が教育現場に到達する前に、必ず通過しなければならない関門として機能する。

この設計思想の背景には、教育分野特有の二律背反がある。一方では、教員の業務過多を軽減するために高度な自動化が求められる。他方では、進路指導における判断の重大性や個人情報の機微性を考慮すると、AIの自律的な意思決定には厳格な制限が必要である。Gate機構は、この二律背反を解消するための構造的解決策として設計された。

5.1.2 AIの自律レベルを連続値Lで定義する意義

従来の教育AI研究において、人間とAIの役割分担は、「完全自動」か「完全手動」かの二項対立的に扱われることが多かった (Holmes et al., 2019)。しかし、教育業務の実態は、日程調整のような定型処理から進路判定のような高度な専門的判断に至るまで、求められる人間関与の度合いが連続的に変化する。

本研究では、この連続性を捉えるために、AIの自律レベルを0から1の連続値L (Autonomy Level) として定義した。Lの値が小さいほどAIの自律度が高く (すなわち人間介入が少なく)、Lの値が大きいほど人間の関与が必須となる。この定義は、Sheridan & Verplank (1978) が提唱した自動化レベル (Levels of Automation) の10段階分類を教育文脈に適応させたものであるが、離散的なレベル分類ではなく連続的なスケールを採用することにより、タスクの性質に応じた精緻な制御を可能としている。

具体的には、本システムでは運用段階において以下の3つの代表的な離散点を設定し、各エージェントおよびAgent Teamの構成要素 (Planet) に対してGate Levelを割り当てている。

- **L=0.2 (High Automation)** : 人的介入が最小限で済む定型処理
- **L=0.3 (Medium Automation)** : 専門家による確認・承認を経て出力が確定する中間処理
- **L=0.7 (High Human Involvement)** : 人間の承認が必須であり、AIは草案作成に徹する高リスク処理

5.1.3 Human-in-the-loop設計の具体化

Human-in-the-loop (HITL) とは、AIシステムの処理ループの中に人間の判断・承認プロセスを組み込む設計パターンである (Amershi et al., 2014)。本システムにおけるHITLの実装は、以下の3つの介入パターンとして具体化される。

18. **事後確認型 (Post-hoc Review)** : L=0.2に対応し、AIが自動処理を完了した後に結果を報告する。人間は結果を確認し、必要に応じて修正指示を出す。処理の実行自体はAIが自律的に行う。
19. **事前承認型 (Pre-approval)** : L=0.3に対応し、AIが草案を作成した後、指定された承認者 (例: 教科主任) の承認を経て初めて出力が確定する。承認者は草案を修正する権限を有する。
20. **協働作成型 (Co-creation)** : L=0.7に対応し、AIが提示する情報はあくまで「参考資料」としての位置づけであり、人間が主体的に意思決定を行う。AIの出力は最終判断の一要素に過ぎず、教員・管理者の専門的知見に基づく判断が最優先される。

5.1.4 教育分野特有のリスクへの配慮

Gate機構の設計において、教育分野に固有の以下のリスク要因を特に重視した。

第一に、**個人情報の機微性**である。生徒の成績データ、出欠記録、面談記録、メンタルヘルスに関する情報は、個人情報保護法第2条第3項に定める「要配慮個人情報」に該当し得るものであり、その取り扱いには最高度の注意が求められる。Gate機構は、これらの情報を含むAI出力に対して、自動的にL=0.7以上のGate Levelを付与し、権限を有する教員のみがアクセス・承認できる制御を実装する。

第二に、**進路判断の不可逆性**である。生徒の進路に関する判断は、当該生徒の将来を左右する重大な意思決定であり、誤った推薦や不適切な助言は取り返しのつかない結果を招く恐れがある。このため、合格確率の推定や進路適性の判定を含むエージェント出力には、必ず教員による最終確認ゲートを設置する。

第三に、**メンタルヘルスへの影響**である。AIによるリスク判定が生徒本人や保護者に直接伝達されることは、不要な不安や烙印効果(Stigma)を生じさせる危険性がある。Gate機構は、メンタルヘルス関連のアラート出力を教員専用チャンネルに限定し、生徒・保護者への情報伝達方法は教員の裁量に委ねる設計とする。

5.2 自律レベルの定義と段階

図5-2は、本システムにおけるGate機構の自律レベル制御を、L=0.2からL=0.7までの連続的なスペクトラムとして視覚化したものである。本節では、各レベルの定義、適用条件、対応エージェント、および具体的な制御動作を詳述する。

5.2.1 L=0.2: High Automation (高自動化)

定義と適用範囲

L=0.2は、AIの自律度が最も高い段階であり、人的介入を最小限に抑えた自動処理を許容するGate Levelである。このレベルが適用されるのは、以下の条件をすべて満たすタスクに限定される。

- 処理結果の誤りが容易に修正可能であること
- 個人の進路判断に直接影響しないこと
- 要配慮個人情報を含まないか、含む場合でもデータ分析上の集計のみであること
- 処理ロジックが明確に定義可能(ルールベース)であること

適用例

日程調整、出席データの単純集計、出席パターンのデータ分析上の解析がこのレベルに該当する。具体的には、Agent 3 (出席・遅刻パターン解析)が代表的なL=0.2エージェントである。Agent 3は、曜日別傾向と特定科目との相関分析を自動実行し、クラス全体との比較結果を早期発見レポートとして出力する。また、Agent Team 2のPlanet 4 (Smart Scheduling Agent: 日程調整)もL=0.2が割り当てられ、先生・生徒・保護者の全カレンダールと優先度スコアを解析し、最適候補3案の提示から自動仮予約までを完結する。

制御動作

AIは自動処理を実行し、完了後に結果を事後報告する。教員は報告を受領するが、個別の承認操作は不要である。ただし、異常値が検出された場合には自動的にアラートが発出され、教員の注意を喚起する仕組みを設ける。

表5-1 L=0.2適用エージェント・Planetの一覧

対象	名称	主要タスク	事後報告頻度
Agent 3	出席・遅刻パターン解析	曜日別傾向分析、クラス比較	日次
Planet 4	Smart Scheduling Agent	面談日程の自動調整・仮予約	即時

5.2.2 L=0.3: Medium Automation (中自動化)

定義と適用範囲

L=0.3は、AIが草案を作成し、指定された承認権限者の確認・修正を経て出力が確定する中間的なGate Levelである。このレベルは、以下のいずれかの条件に該当するタスクに適用される。

- AIの出力が外部(生徒・保護者・他校)に公開される可能性があること
- 翻訳・要約等の自然言語生成を含み、ニュアンスの誤りが問題となり得ること
- 教育的配慮に基づく表現の調整が必要であること

適用例

教材翻訳、面談サマリー生成、学習プラン生成、保護者向けレポート生成、進路推薦支援がこのレベルに該当する。具体的には、Agent 1(学習リスク早期検知)、Agent 2(個別最適化学習プラン生成)、Agent 5(進路推薦支援)、Agent 7(面談サマリー自動生成)、Agent 9(保護者向けレポート生成)が該当する。また、Agent Team 1(留学生対応・教材自動翻訳システム)全体にL=0.3が付与されている。

Agent Team 1の事例では、図5-3に示されたGate Cardにおいて、Risk Level: L=0.3(教育リスク中低)と明記され、最終公開前に「教科主任承認Gate」が設置されている。これは、AI翻訳における誤訳リスクや用語の不統一が、留学生の学習理解に直接影響するためである。

制御動作

AIが草案を作成し、承認キューに登録する。教科主任または指定された承認者がダッシュボード上で草案を確認し、必要に応じて修正を加えた上で承認操作を行う。承認が完了するまで、当該出力は「下書き(Draft)」ステータスのまま保持され、生徒・保護者への公開は行われない。

表5-2 L=0.3適用エージェント・Agent Teamの一覧

対象	名称	主要タスク	承認権限者
Agent 1	学習リスク早期検知	成績トレンド分析、危険スコア算出	担任教員
Agent 2	個別最適化学習プラン生成	弱点単元抽出、推奨教材提案	教科主任
Agent 5	進路推薦支援	進学実績DB照合、適性傾向分析	進路指導主事
Agent 7	面談サマリー自動生成	面談要約、推奨対話項目生成	担任教員
Agent 9	保護者向けレポート生成	成績推移レポート、自然言語化	学年主任
Agent Team 1	留学生対応・教材自動翻訳	用語辞書照合、文脈翻訳、難易度適応	教科主任

5.2.3 L=0.7: High Human Involvement(高人間関与)

定義と適用範囲

L=0.7は、AIの出力を「参考資料」として位置づけ、最終判断を必ず教員・管理者が行うことを強制するGate Levelである。このレベルは、以下のいずれかの条件に該当するタスクに適用される。

- 生徒の進路選択に直接影響する判断を含むこと
- メンタルヘルスに関するリスク評価を含むこと
- 成績評価の公平性・妥当性に関わる判定を含むこと
- 合格確率・進学可能性等の確率的推定を含むこと

適用例

進路判定、メンタルヘルス対応、成績評価妥当性チェック、学校経営ダッシュボード(経営意思決定に関わる出力)、時間割最適化(教員の労働条件に直結)がこのレベルに該当する。具体的には、Agent 4(成績評価妥当性チェック)、Agent 6

(カリキュラム最適化)、Agent 8(学校経営ダッシュボード)、Agent 10(時間割最適化)が該当する。また、Agent Team 2のPlanet 2(Career Option Intelligence: 候補探索)にもL=0.7が付与されている。

Agent Team 2・Planet 2の事例は、図5-4において、「Gate: L=0.7。合格確率推定を含むため、必ず教員の承認を経てから生徒に提示」と明記されている。合格確率という定量的指標は、生徒の志望校選択に直接的な影響を与えるため、AIの推定値がそのまま生徒に伝達されることは許容されない。教員が推定値の妥当性を専門的知見に基づいて検証し、必要に応じて補足説明や文脈情報を付加した上で、生徒への伝達方法を判断する。

制御動作

AIの出力は「参考資料(Reference Material)」として教員専用画面に表示される。教員は当該資料を確認した上で、独自の判断を加えて最終意思決定を行う。AIの出力をそのまま承認することも、全面的に修正することも、完全に却下することも教員の裁量に委ねられる。すべての判断プロセスは監査ログとして記録され、事後検証が可能な状態で保持される。

表5-3 L=0.7適用エージェント・Planetの一覧

対象	名称	主要タスク	最終判断権限者
Agent 4	成績評価妥当性チェック	教師別分布分析、偏差異常検出	教務主任
Agent 6	カリキュラム最適化	単元別平均点分析、再設計案	教科主任・教務主任
Agent 8	学校経営ダッシュボード	学年別パフォーマンス、経営レポート	管理者(校長・教頭)
Agent 10	時間割最適化	負荷最小化時間割、代替案提示	教務主任
Planet 2	Career Option Intelligence	成績偏差帯照合、合格確率推定	進路指導主事

5.3 Gate Cardの実装

5.3.1 Gate Cardの構成要素

Gate Cardとは、各エージェントおよびAgent Teamの構成要素(Planet)に付与されるメタデータカードであり、当該処理のリスク特性と制御方針を一元的に記述したものである。Gate Cardは以下の6つの構成要素から成る。

- 21. 対象識別子(Target ID): Agent番号またはAgent Team/Planet番号
- 22. リスクレベル(Risk Level): L値(0.2, 0.3, 0.7のいずれか)
- 23. リスク分類(Risk Category): 教育リスク低・教育リスク中低・教育リスク中・教育リスク高の4段階
- 24. 制御方式(Control Type): 事後確認型・事前承認型・協働作成型
- 25. 承認権限者(Approver Role): 承認操作を行う教職員の役職
- 26. 制御条件(Control Condition): Gate通過のために満たすべき具体的条件の記述

5.3.2 Agent Team 1のGate Card実装例

図5-3に示されたAgent Team 1(留学生対応・教材自動翻訳システム)のGate Cardを、上記構成要素に基づいて正式に記述すると以下のとおりとなる。

表5-4 Agent Team 1 Gate Card

構成要素	内容
対象識別子	Agent Team 1(留学生対応・教材自動翻訳システム)
リスクレベル	L=0.3
リスク分類	教育リスク中低
制御方式	事前承認型
承認権限者	教科主任

制御条件	最終公開前に「教科主任承認Gate」を通過すること。誤訳リスクと用語の不統一を防ぐため、用語辞書照合(Step 1)、文脈翻訳(Step 2)、難易度適応(Step 3)の全工程完了後に承認プロセスを起動する
------	--

5.3.3 Agent Team 2のGate Card実装例

Agent Team 2(進路相談負担軽減)は、4つのPlanetから構成され、各Planetに異なるGate Levelが割り当てられている点特徴的である。この設計は、同一Agent Team内であっても、処理の性質に応じてリスク制御の粒度を変えることが可能であることを示している。

表5-5 Agent Team 2 各PlanetのGate Card

Planet	名称	Gate Level	制御方式	承認権限者	根拠
Planet 1	Career Context Aggregator(状況把握)	L=0.3	事前承認型	担任教員	生徒の個人情報を集約・要約するため
Planet 2	Career Option Intelligence(候補探索)	L=0.7	協働作成型	進路指導主事	合格確率推定を含むため
Planet 3	Counseling Conversation Planner(面談設計)	L=0.3	事前承認型	担任教員	質問テンプレートと保護者説明ポイントの教育的適切性を確認するため
Planet 4	Smart Scheduling Agent(日程調整)	L=0.2	事後確認型	(不要)	高自動化可能。最適候補3案の提示と自動仮予約まで完結

この事例から明らかのように、Agent Team 2は進路相談業務を「情報収集」「比較」「提案」「調整」の各フェーズに分解し、各フェーズのリスク特性に応じた適切なGate Levelを個別に設定している。Planet 2に最も高いL=0.7が付与されている理由は、合格確率という定量的推定が生徒の志望校選択に直接的な影響を及ぼすためであり、一方でPlanet 4の日程調整は定型的な最適化処理であるためL=0.2による高自動化が許容される。

5.4 責任分解モデル

5.4.1 AI出力に対する責任の所在明確化

Gate機構の最も重要な機能の一つは、AI出力に関する責任の所在を明確にすることである。教育現場においてAIが生成した情報に基づいて行われた判断について、問題が生じた場合に「誰が責任を負うのか」という問いに対して、曖昧を残さない制度設計が求められる。

本システムでは、Gate Levelに基づく以下の責任分配原則を採用する。

原則1:最終承認者責任の原則 Gate通過時に承認操作を行った者が、当該出力の内容に対する一次的責任を負う。

原則2:システム品質責任の原則 AIシステムの設計・実装・運用管理に関する責任は、教育DX推進室(システム管理者)が負う。

原則3:組織管理責任の原則 Gate機構の運用ポリシー策定と定期的見直しに関する責任は、学校管理者(校長・教頭)が負う。

5.4.2 Gate Levelに応じた責任分配

表5-6 Gate Level別責任分配表

Gate Level	AI出力の位置づけ	教員の責任	AI(システム)の責任	管理者の責任
------------	-----------	-------	-------------	--------

L=0.2	自動処理結果	事後確認義務(異常値の見落としに対する注意義務)	処理ロジックの正確性、異常値検出の感度	自動化範囲の適切な設定
L=0.3	承認対象の草案	承認内容に対する一次的責任(専門的判断による修正義務を含む)	草案品質の担保、重要情報の漏れ防止	承認フローの設計と運用
L=0.7	参考資料	最終判断に対する全面的責任(AIの推定値に依拠した判断についても教員が責任を負う)	参考資料としての情報品質、バイアスの最小化	判断基準の策定と教員支援体制の整備

5.4.3 エスカレーション経路

問題発生時のエスカレーション経路は、Gate Levelに応じて以下のとおり定義する。

27. **L=0.2における異常検出時**: AIが自動検出したアラートは担任教員に通知される。担任教員が対応困難と判断した場合、学年主任にエスカレーションする。学年主任の判断で教頭・校長への報告が必要な場合、管理者報告フローに移行する。
28. **L=0.3における承認拒否時**: 承認権限者が草案を不適切と判断した場合、差し戻し(リジェクト)操作を行う。差し戻し理由はシステムに記録され、AIの改善データとして蓄積される。同一タスクで3回以上の差し戻しが発生した場合、教育DX推進室に自動通知され、エージェントのロジック見直しが実施される。
29. **L=0.7における判断支援の不備時**: 教員がAIの参考資料に重大な誤りや偏りを発見した場合、インシデントレポートを教育DX推進室に提出する。教育DX推進室は速やかに調査を開始し、必要に応じて当該エージェントの一時停止措置を講じる。管理者は週次の運用報告においてインシデントの状況を把握し、Gate Levelの見直しを含む改善指示を行う権限を有する。

5.5 Gate機構の教育的・倫理的意義

5.5.1 効率化と倫理的配慮の両立

Gate機構の設計は、「効率化」と「倫理的配慮」の両立という、教育AI導入における重要な課題に対する構造的解決策である。L=0.2の高自動化タスクにより事務作業時間の削減を目指しつつ、L=0.7の高人間関与タスクにより教育的判断の質と責任の明確性を確保する設計としている。第15章で分析するとおり、本システムの導入により事務作業・情報収集・調整業務の大幅な削減と、生徒と向き合う時間の拡張を目指しており、このGate Levelの適切な配分がその実現の鍵となる。

5.5.2 AI過信防止メカニズム

教育現場におけるAI導入の隠れたリスクとして、「自動化バイアス(Automation Bias)」が指摘されている(Parasuraman & Manzey, 2010)。これは、AIの出力を過度に信頼し、自身の専門的判断を放棄してしまう傾向を指す。Gate機構は、以下の3つのメカニズムによりAI過信を防止する。

第一に、**強制的確認プロセス**である。L=0.3およびL=0.7のタスクにおいて、教員は単にAIの出力を「承認」するだけでなく、確認チェックリストへの回答を求められる。チェックリストには「AIの推定結果とご自身の判断に相違はありますか」「生徒の個別事情を考慮した上で、この内容は適切ですか」等の項目が含まれ、教員の能動的な判断を促す。

第二に、**信頼度スコアの明示表示**である。AIの出力には、推定の確信度を示すConfidence Scoreが併記される。これにより、教員はAIの判断がどの程度確実であるかを把握した上で意思決定を行うことができる。

第三に、**定期的な精度検証レポート**である。月次で各エージェントの推定精度・承認率・差し戻し率の統計レポートが生成され、教員がAIの信頼性を客観的に把握できる仕組みを設ける。

5.5.3 段階的自動化による教員のAIリテラシー向上

Gate機構は、段階的にAIの自動化範囲を拡大するためのフレームワークとしても機能する。初期導入段階では、すべてのエージェントに保守的なGate Level(L=0.7寄り)を設定し、教員がAIの出力品質を十分に確認・検証できる期間を設ける。運用実績の蓄積に伴い、承認率や精度指標が一定の基準を満たしたエージェントについては、Gate Levelを段階的に引き下げる(例:L=0.7からL=0.3へ)ことが可能となる。

この段階的アプローチは、教員のAIリテラシー向上にも寄与する。初期段階ではAIの出力を詳細に確認することで、AIの能力と限界を実体験として理解し、適切な信頼関係(Calibrated Trust)を構築することが期待される。

5.5.4 他分野のHuman-in-the-loopとの比較

本システムのGate機構は、他分野におけるHITL設計との比較においても固有の特徴を有する。医療分野では、AI診断支援システムにおいてAIの診断結果を医師が確認・承認する仕組みが採用されているが、教育分野との相違点は「判断の不可逆性の度合い」と「対象者の脆弱性」にある。教育対象者である生徒は、発達段階にある未成年者であり、成人患者と比較してAIの判断結果に対する心理的影響が大きい。

法律分野では、AIによる契約書レビューシステムにおいて、弁護士による最終確認が標準的なHITLパターンとなっているが、教育分野では「個人の尊厳」と「教育的配慮」という固有の倫理的要請が加わる。本システムのGate機構は、これらの教育固有の要請を制度的に組み込んだ点において、他分野のHITL設計を発展させたものと位置づけられる。

5.6 実装における技術的考慮

5.6.1 Gate LevelのUI視覚的表現

Gate Levelは、ダッシュボードUI上で直感的に識別できるよう、以下の色分けバッジシステムにより視覚化される。本システムのフロントエンド実装(Next.js / Tailwind CSS 4.2)において、各Gate Levelに対応するCSS変数を定義し、一貫した視覚的コミュニケーションを実現する計画である。プロトタイプ段階では、バッジコンポーネントによるGate Levelの表示を実装している。

表5-7 Gate Level視覚表現体系

Gate Level	バッジ色	CSS変数名	意味	アイコン
L=0.2	エメラルド(緑)	`--gate-auto`	高自動化・低リスク	歯車(自動処理を象徴)
L=0.3	アンバー(琥珀色)	`--gate-review`	承認要・中リスク	盾+チェックマーク(保護と確認を象徴)
L=0.7	レッド(赤)	`--gate-human`	人間判断必須・高リスク	手のひら(人間介入を象徴)

この色体系は、交通信号の直感的認知を援用したものであり、教員がシステムに不慣れな初期段階においても、各エージェント出力のリスクレベルを瞬時に把握できることを意図している。バッジは、エージェント一覧画面、各エージェントの出力画面、承認待ちキュー画面、および管理者向け統括画面のすべてにおいて統一的に表示される。

5.6.2 エージェントステータスのトグルスイッチ

管理者(Admin)ダッシュボードには、各エージェントの稼働状態を制御するトグルスイッチが実装される。トグルスイッチは以下の3つの状態を持つ。

- **Active(稼働中)**: エージェントが通常稼働し、Gate Levelに従った処理を実行する
- **Paused(一時停止)**: エージェントの処理を一時的に停止する。承認待ちキューに残存するタスクは保持されるが、新規タスクの受付は停止される
- **Disabled(無効化)**: エージェントを完全に無効化する。承認待ちキューのタスクも破棄される

トグルスイッチの操作は、管理者権限を有するユーザのみに許可され、操作履歴は監査ログに記録される。インシデント発生時には、教育DX推進室が遠隔からトグルスイッチを操作し、問題のあるエージェントを即座に停止できる緊急対応機能も備える設計とする。

5.6.3 使用状況メトリクスのリアルタイムトラッキング

Gate機構の実効性を継続的に評価するために、以下のメトリクスをリアルタイムでトラッキングし、管理者ダッシュボードに表示する設計とする。

30. **Gate通過率(Gate Pass Rate)**: 各エージェントの出力が承認された割合。L=0.3エージェントにおいて通過率が著しく低い場合、エージェントの品質改善が必要であることを示す。
31. **平均承認所要時間(Average Approval Time)**: 承認キューに登録されてから承認操作が完了するまでの平均時間。過度に長い場合、承認プロセスがボトルネックとなっている可能性を示す。
32. **差し戻し理由分類(Rejection Reason Distribution)**: 差し戻し理由の分類別集計。頻出する差し戻し理由は、エージェントの改善優先事項を示す。
33. **エージェント稼働率(Agent Uptime)**: 各エージェントの稼働時間比率。
34. **Gate Level変更履歴(Gate Level Change Log)**: Gate Levelの変更が行われた履歴。段階的自動化の進捗を把握するために用いる。

これらのメトリクスは、Rechartsライブラリを用いた時系列グラフおよび集計テーブルとして可視化され、管理者がシステムの健全性を把握できるダッシュボードを構成する計画である。特にGate通過率と平均承認所要時間の推移は、Gate Levelの適正性を評価する上で重要な指標であり、月次の運用報告における主要KPIとして位置づけられる。

図表一覧(第5章)

図表番号	タイトル	備考
図5-1	信頼のアーキテクチャ: Gateによる責任分解と保護	付録A参照
図5-2	Gate機構の自律レベルスペクトラム(L=0.2~L=0.7)	付録A参照
図5-3	Agent Team 1のGate Card実装例	付録A参照
図5-4	Agent Team 2のPlanet別Gate Level配置	付録A参照
表5-1	L=0.2適用エージェント・Planetの一覧	—
表5-2	L=0.3適用エージェント・Agent Teamの一覧	—
表5-3	L=0.7適用エージェント・Planetの一覧	—
表5-4	Agent Team 1 Gate Card	—
表5-5	Agent Team 2 各PlanetのGate Card	—
表5-6	Gate Level別責任分配表	—
表5-7	Gate Level視覚表現体系	—

第6章 Guardian Agents — 早期リスク検知機能の設計とプロトタイプ開発

6.1 Guardian Agents の概要と位置づけ

本システムの4象限AIエージェントモデルにおいて、第一象限「守る (Guardian)」は、教育現場における早期リスク検知を専門とするエージェント群である。本象限の設計理念は「兆候を逃さない。データに基づく早期リスク検知」であり、従来の教員の経験と直感に依存していたリスク把握を、データ駆動型の体系的検知プロセスへと転換することを目的としている。

教育現場において、不登校・中退・学力崩壊といった重大事象は、その発生に先立って複数の微弱なシグナルを発することが先行研究によって明らかにされている (国立教育政策研究所, 2022; 文部科学省, 2023)。成績の緩やかな低下、出席率のわずかな変動、遅刻パターンの変化、提出物の未提出増加といった個々のシグナルは、単独では見過ごされやすい。しかし、これらを科目横断的・時系列的に統合分析することで、リスクの予兆を高い精度で検知できることが本研究の基本仮説である。

Guardian Agentsは、この仮説に基づき「見落としゼロ」を目標として設計された。従来、教員が出席簿や成績表を個別に確認し、同僚との情報共有を通じて行っていたリスク把握作業を、AIエージェントが24時間・全生徒を対象に自動実行する仕組みを構築し、教員はリスク検知後の「ケア」と「対応」に専念できる環境の実現を目指す。これは、AIが教員の判断を代替するのではなく、教員が最も価値を発揮できる業務領域へ時間を再配分するための設計思想である。

本章では、Guardian Agentsを構成する主要な2つのエージェント、すなわちAgent 1 (学習リスク早期検知) およびAgent 3 (出席・遅刻パターン解析) について、そのロジック、出力形式、Gate Level設定、使用実績、およびフロントエンド実装の詳細を論じる。

6.2 Agent 1: 学習リスク早期検知

6.2.1 検知ロジックの設計

Agent 1は、生徒の学習成績データを多角的に分析し、学力低下のリスクを早期に検知するエージェントである。その中核ロジックは、成績トレンド分析と科目横断相関分析の組み合わせによる危険スコア算出にある。

具体的には、以下の3段階の分析パイプラインで構成される。第一段階として、各生徒の直近6回分のテスト成績 (定期考査・実力テスト・模試) について、5教科 (国語・数学・英語・理科・社会) それぞれの時系列トレンドを回帰分析する。第二段階として、科目間の成績変動の相関を分析し、特定科目の低下が他科目へ波及する「学力崩壊パターン」の兆候を検出する。第三段階として、上記の分析結果を統合し、学年平均との偏差、前回比較、志望校との乖離度を加味した総合的な危険スコアを算出する。

本プロトタイプにおいては、フロントエンド上でのモックデータによる実装であるが、算出ロジックの設計は実運用を想定した統計モデルに基づいている。たとえば、生徒「佐藤太郎」のケースでは、5教科平均が4月の基準値から-15.4ポイント低下し、特に数学においては-19点という急激な下降が検出されている。Agent 1はこのパターンを「Red」レベルと判定し、即時の教員介入を推奨するアラートを発出する設計でUIに表示されている。

6.2.2 出力形式とリスクレベル判定

Agent 1の出力は、3段階のリスクレベル判定として設計されている。Green (順調) は、成績が安定的に推移しており、特段の介入を要しない状態を示す。Yellow (警告) は、1つ以上の教科で顕著な成績低下トレンドが検出された状態であり、教員による経過観察と面談の実施が推奨される。Red (クリティカル) は、複数教科にわたる急激な成績低下、または志望校との乖離が閾値を超えた状態であり、即時の対応措置が求められる。

各リスクレベルには、推奨アクションが自動付与される。Yellowレベルでは「定期面談の前倒し実施」「該当科目の補習案内」等が提示され、Redレベルでは「保護者面談の設定」「学習プラン見直し (Agent 2連携)」「志望校再検討の助言」等がより具体的に提示される。この推奨アクションはAgent 1が自律的に実行するものではなく、教員の確認と判断を経て実行

される。Gate Levelは $L=0.3$ に設定されており、情報提示と推奨提案を行うが、最終的なアクション決定は教員に委ねられる。

6.2.3 想定利用規模と期待精度

プロトタイプの実データでは、Agent 1の月間利用回数を523回、期待精度を94%と想定している(設計目標値)。ここでの「精度」は、Agent 1がYellowまたはRedと判定した生徒のうち、実際にその後の成績低下または教員による要注意判定が行われる割合として定義する。偽陽性(False Positive)の発生は想定されるが、教育分野においてはリスクの見落とし(偽陰性)よりも偽陽性のコストが相対的に低いため、感度(Recall)を優先した閾値設定とする方針である。なお、これらの精度値の検証には、対象者数・観測期間・正解ラベルの定義(教員判定との一致率等)を明確にした評価設計が必要であり、パイロット運用において実施予定である。

6.3 Agent 3: 出席・遅刻パターン解析

6.3.1 検知ロジックの設計

Agent 3は、生徒の出席・遅刻データを分析し、不登校の予兆や生活リズムの乱れを早期に検出するエージェントである。その検知ロジックは、曜日別傾向分析、特定科目との相関分析、およびクラス全体との比較分析の3つの軸で構成される。

曜日別傾向分析では、週5日の各曜日および各時限(1限～6限)の出席率を個人別にマトリクス化し、データ分析上の外れ値を検出する。実装においては、曜日×時限のヒートマップとして可視化されており、月曜1限の出席率65%、金曜1限の出席率62%といった「週末前後の生活リズム乱れ」パターンが自動検出する設計である。プロトタイプでは実データとして表示例を示している。特定科目との相関分析では、特定の授業のみ出席率が低い場合に、対人関係の問題や学習意欲の低下といった背景要因の存在を示唆するフラグを立てる。クラス全体比較では、個人の出席パターンをクラス平均と比較し、データ分析上の乖離が大きい場合にアラートを発出する。

6.3.2 出力形式と担任支援

Agent 3の出力は、問題兆候の早期発見レポートとして構成される。従来、担任教員は朝のホームルームでの出欠確認と自身の記憶に基づいて生徒の出席状況を把握しており、この「担任の直感依存」からの脱却がAgent 3の主要な設計目標である。

実装例として、生徒「佐藤太郎」の出席率が68.2%まで低下した事例では、Agent 3は「前月比-8.3%」の低下率、「遅刻を含む実質出席率62.5%」という補正値を算出し、異常パターンとして検知する想定でUIに表示している。また、生徒「松本結衣」については出席率65.3%に加え、「2月に入り欠席が急増」「保健室登校の傾向あり」という定性的パターンも検出し、「メンタル面のケアが必要」という推奨を出力している。

Agent 3のGate Levelは $L=0.2$ に設定されており、これは12エージェントの中で最も高い自動化レベル(すなわち最も低い人間介入要求レベル)である。これは、出席データの分析が事実に基づく客観的な処理であり、主観的な教育判断を含まないためである。ただし、 $L=0.2$ であっても「情報提示」の範囲にとどまり、対応措置の実行は教員の判断に委ねられる。

6.3.3 想定利用規模と期待精度

プロトタイプの実データでは、Agent 3の月間利用回数を412回、期待精度を97%と想定している(設計目標値)。出席データは成績データと比較して客観性が高く、数値の揺れが少ないため、高い精度の達成が見込まれる。不登校予兆検知に関しては、先行研究(Baker & Inventado, 2014)において出席パターン分析による早期検知が2～4週間前の段階で90%以上の感度を達成した事例が報告されており、Agent 3の設計はこうした知見に基づいている。実際の検知精度はパイロット運用を通じて検証する。

6.4 Impact分析

6.4.1 事務作業時間の削減効果

Guardian Agentsの導入による最大のインパクトは、「目視チェック時間をゼロにし、対応が必要な生徒へのケアに時間を充てる」という業務構造の転換にある。従来の進路指導体制において、担任教員は出席簿の確認、成績表の突合、同僚と

の情報共有に相当の時間を費やしていたと推定される。38名の担当学生全員の状況を毎日確認することは事実上不可能であり、週次または月次の確認にとどまっていたケースが多い。

Guardian Agentsの導入により、この確認作業の自動化を目指す。プロトタイプのUIでは、教員がダッシュボードを開くと、Redレベル3名、Yellowレベル5名、当日の新規アラート2件という形式でリスク状況の全体像が提示される。教員は、AIが提示するリスク情報に基づき、最も対応の優先度が高い生徒から順に面談や指導を行うことが可能となる。

6.4.2 教員のケアの質向上への波及効果

定量的な時間削減に加え、Guardian Agentsは教員のケアの質そのものを向上させる波及効果が期待される。第一に、見落としリスクの大幅な低減である。38名の担当学生について、AIが24時間365日の常時モニタリングを行うことで、人間の注意力の限界に起因する見落としを構造的に排除することを目指す。第二に、早期介入の実現である。Agent 3が不登校予兆を2〜4週間前に検知することで、教員は予防的な面談を実施し、問題が深刻化する前に対応できる。第三に、データに裏付けられた面談の実施である。教員が生徒と面談する際、Agent 1による成績分析結果やAgent 3による出席パターン分析結果を具体的なエビデンスとして提示することで、「なんとなく心配」ではなく「データが示す事実」に基づいた建設的な対話が可能となる。

6.5 UIにおけるリスク可視化

6.5.1 リスクレベルの色分け設計

Guardian Agentsの分析結果は、直感的な色分けによってユーザインタフェース上に可視化される。Red(`bg-red-100 text-red-700`)は「要注意」を示し、即時の対応を促す。Yellow(`bg-amber-100 text-amber-700`)は「注意」を示し、経過観察と適時の介入を推奨する。Green(`bg-emerald-100 text-emerald-700`)は「順調」を示し、現状の指導方針の継続を確認する。この3色のカースキームは、信号機のメタファーを採用しており、教育現場のユーザが直感的に緊急度を把握できるよう設計されている。

6.5.2 教員ダッシュボード(`teacher-dashboard.tsx`)における表示

教員ダッシュボードの学生一覧テーブルにおいて、各学生の行頭にリスクレベルを示すドットインジケータが配置されている。実装は`riskDotColors`オブジェクトにより、`red: "bg-red-500",` `yellow: "bg-amber-500",` `green: "bg-emerald-500"`として定義される。7名の学生データにおいて、佐藤太郎と渡辺大輔がRedレベル(`risk: "red"`), 山本花子と伊藤さくらがYellowレベル(`risk: "yellow"`), 残り3名がGreenレベルとして表示される。

ダッシュボード上部のKPIカードでは、「リスク生徒: 3名 (-1 前週比)」という集約情報が提示され、教員が一目でリスクの全体傾向を把握できる。さらに、`AlertList`コンポーネントにより、直近のリスクアラート3件がリアルタイムに表示される。各アラートは`danger`(`AlertTriangle`アイコン、赤背景)、`warning`(`AlertCircle`アイコン、琥珀色背景)、`info`(`Info`アイコン、青背景)の3タイプで分類される。

6.5.3 学生一覧画面(`teacher-student-list.tsx`)における表示

教員向け学生一覧画面では、より詳細なリスク情報が表示される。12名の学生データに対し、リスクサマリーがカウント形式で「要注意 3名 / 注意 3名 / 順調 6名」として画面上部に集約表示される。この実装は、`students`配列に対する`filter`メソッドにより動的に算出される(`redCount`, `yellowCount`, `greenCount`)。各カウントの横には対応する色のドットインジケータが配置され、視覚的な一貫性が保たれている。

テーブル本体では、リスクドットに加えて出席率カラム(例: 佐藤太郎 68.2%、松本結衣 65.3%)が表示され、リスクレベルと出席率の相関が視覚的に確認できる。また、`Select`コンポーネントによるリスクレベルフィルタリング機能により、Redレベルの生徒のみを抽出して表示することが可能である。

6.6 技術的実装詳細

6.6.1 リスクアラート画面(`teacher-risk-alerts.tsx`)のアーキテクチャ

リスクアラート専用画面(`TeacherRiskAlerts`コンポーネント)は、Guardian Agentsの分析結果を最も詳細に表示するビューである。画面構成は以下の4つのセクションから成る。

第一セクションは、KPIカード群である。総アラート数(12件)、クリティカル(Red)件数(3件)、警告(Yellow)件数(5件)、今日の解決件数(2件)の4つのKPIが`KPICard`コンポーネントにより表示される。各KPIには前週比較やステータス情報が付記され、リスク状況の推移が把握できる。

第二セクションは、アクティブアラートの一覧である。8件のアラートデータが`alerts`配列として定義され、各アラートには`studentName`、`class`、`riskType` (成績低下・出席率低下・遅刻パターン・提出物未提出)、`severity` (red/yellow)、`detectedDate`、`aiExplanation` (AI分析結果の自然言語説明)、`agentSource` (Agent 1またはAgent 3)、`status` (未対応・対応中・解決済み)の属性が含まれる。3つの`Select`コンポーネントにより、重要度・リスク種別・対応状態でのフィルタリングが可能である。

アラートカードのUIは、重要度に応じた背景色(`border-red-200 bg-red-50/50` または `border-amber-200 bg-amber-50/50`)、リスク種別に応じたアイコン(`TrendingDown` (成績低下)、`Calendar` (出席率低下)、`Clock` (遅刻パターン)、`AlertCircle` (提出物未提出))、および「カルテ」「対応」の2つのアクションボタンで構成される。Gate機構の存在を示す`Badge` (`Gate L=0.7` (要確認))が画面上部に配置され、将来的にAIの提案が教員の確認を経て実行される設計であることをユーザーに伝達している。

6.6.2 Agent分析セクションの実装

第三・第四セクションは、Agent 1およびAgent 3の個別分析結果を可視化するカードである。Agent 1のカードは、`border-l-4 border-l-red-500`のスタイリングによりRedを基調としたアクセントカラーが適用され、Rechartsライブラリの`BarChart`コンポーネントにより、8週間分のリスクレベル推移が積み上げ棒グラフとして表示される。各週のRedおよびYellowの件数がスタック形式で可視化され、1月比でのRed増加トレンドが視覚的に明確となる。

Agent 3のカードは、`border-l-4 border-l-amber-500`のスタイリングが適用され、曜日×時限の出席率ヒートマップが`Table`コンポーネントにより実装されている。各セルの背景色は`getHeatColor`関数により動的に決定され、90%以上(`bg-emerald-100`)、80%以上(`bg-emerald-50`)、70%以上(`bg-amber-100`)、70%未満(`bg-red-100`)の4段階で色分けされる。月曜1限65%、金曜1限62%のセルがRed表示となり、週末前後の出席率低下パターンが一目で把握できる。

両カードの下部には、AIによる傾向分析コメントが自然言語で表示される。Agent 1は「Redレベルの学生が1月比で+2名増加。2月以降の成績低下トレンドが顕著。早期介入が推奨されます。」、Agent 3は「月曜・金曜の1限出席率が特に低い(62-65%)。週末前後の生活リズム乱れが推察されます。」というコメントを出力し、教員がデータの意味を即座に理解できるよう配慮されている。

6.6.3 コンポーネント設計の原則

Guardian Agentsに関連するUIコンポーネントの設計は、以下の3つの原則に基づいている。第一に、「情報の階層化」である。KPIカードによる全体俯瞰、アラートカードによる個別詳細、分析チャートによる傾向把握という3階層の情報構造により、教員が必要な粒度の情報に迅速にアクセスできる。第二に、「アクション指向」である。リスク情報の表示にとどまらず、「カルテ」ボタンによる学生詳細画面への遷移、「対応」ボタンによるステータス更新など、次のアクションへの導線が常に提供される。第三に、「Gate機構の可視化」である。すべてのAI分析結果には検知元Agent (Agent 1またはAgent 3)と検知日が明記され、AIの判断プロセスの透明性が確保されている。

6.7 メンタルヘルスリスク推定機能

6.7.1 複合データ統合によるメンタルヘルスリスク推定

Guardian Agentsの第三の機能として、Agent 1(学習リスク早期検知)とAgent 3(出席パターン解析)の出力を統合したメンタルヘルスリスク推定機能を設計している。従来のメンタルヘルス対応は、担任教員の主観的観察やスクールカウンセラーへの自発的相談に依存しており、問題が深刻化するまで検知されないケースが少なくなかった(文部科学省, 2023d)。

本機能は、以下の3つのデータストリームを統合的に分析する。第一に、成績下降パターン (Agent 1からの出力)として、科目横断的な成績低下、特に得意科目での急落を検知する。第二に、出席パターン異常 (Agent 3からの出力)として、特定曜日・時限の選択的欠席、遅刻の増加パターン、保健室利用頻度の変化を分析する。第三に、生活リズム変化の指標として、課題提出パターンの変化 (提出時刻の深夜化、未提出率の上昇)を追跡する。

これら3つの指標を複合的にスコアリングし、閾値を超えた場合にメンタルヘルスリスクアラートを生成する。重要な設計判断として、SNS上の発言分析やウェアラブルデバイスのデータ等、学校外のデータは一切使用しない方針を採用している。これは、生徒のプライバシー権の保護と、学校教育法に基づく学校の管理権限の範囲を逸脱しないための意図的な設計制約である。

6.7.2 Gate Level L=0.7の適用と連携フロー

メンタルヘルスリスク推定にはGate Level L=0.7(人間判断必須)を適用する。これは以下の理由による。第一に、メンタルヘルスに関する判断は、医療的・心理学的専門知識を要する高度な判断であり、AIが自律的に行うべきではない。第二に、誤った判定(偽陽性)が生徒への不必要なラベリングや心理的負担を生じさせるリスクがある。第三に、検知後の対応は児童福祉法・学校教育法に基づく法的手続きを伴う可能性がある。

検知後の連携フローは、(1) AIがリスクフラグを生成 → (2) 担任教員が確認・一次判断 → (3) 学年主任への報告 → (4) 必要に応じてスクールカウンセラーとの連携 → (5) 重篤事案は管理者(校長・教頭)へのエスカレーション、という5段階プロセスで設計している。

6.7.3 プライバシーへの配慮と閾値設計

メンタルヘルスリスク推定における過度な監視を防止するため、以下の閾値設計方針を採用する。第一に、単一指標ではアラートを発出せず、必ず複数指標の複合的な悪化パターンが確認された場合のみリスクフラグを生成する。第二に、アラートの送信先を担任教員のみ限定し、管理者や他の教員には担任の判断を経て初めて共有される設計とする。第三に、メンタルヘルスリスクの具体的な推定理由は「複合的な学校生活パターンの変化が検知されました」という一般化された表現で通知し、特定のデータ項目(例: 保健室利用回数)を直接的に表示しない配慮を行う。

6.8 偽陰性(False Negative)分析と高感度設計

リスク検知システムにおいて、偽陰性(False Negative: 実際にリスクのある学生を検知できないこと)は偽陽性(False Positive)よりも深刻な帰結をもたらす。見逃された学生は、退学、不登校の長期化、メンタルヘルスの悪化等の不可逆的な事態に至る可能性がある。

このため、本システムのGuardian Agentsは、再現率(Recall)を優先する高感度設計を採用している。具体的には、Agent 1のリスク検知閾値を意図的に低く設定し、「疑わしきは検知する」方針を技術的に実装している。この設計により偽陽性の増加が生じるが、以下の対策で教員の負担増を防止する。第一に、リスクレベルの3段階表示(Green/Yellow/Red)により、教員が優先度に応じた対応が可能な設計とする。第二に、段階的エスカレーション(Yellow: 経過観察、Red: 即時対応)により、すべてのアラートに同一の対応を求めない。第三に、週次のリスクサマリーレポート(teacher-digest.tsx)により、個別アラートの洪水を集約・構造化して提示する。

6.9 既存EWS(早期警戒システム)との比較

6.9.1 国際的なEWSの動向

米国では、Balfanz et al.(2007)が提唱したABCフレームワーク(Attendance, Behavior, Course performance)が早期警戒の標準的アプローチとして広く採用されている。このフレームワークは、出席率、行動指標、学業成績の3軸を用いてリスク学生を特定する手法であり、その有効性は多くの研究で確認されている。オーストラリアでは「Students at Risk(SaR)」プログラムが州政府レベルで実施され、データ分析に基づくリスク学生の同定と早期介入が制度化されている。

6.9.2 日本の従来手法との比較

日本の教育現場における従来のリスク検知は、主に担任教員の主観的判断に依存してきた。教員は日々の観察、出欠確認、テスト結果の目視確認を通じてリスク学生を把握するが、この手法には以下の限界がある。第一に、経験依存性が高く、新任教員と熟練教員の検知精度に大きな差が生じる。第二に、複数の微弱なシグナル(成績のわずかな下降と遅刻の微増の組み合わせ等)を統合的に判断することが困難である。第三に、担当学生数が多い場合(専門学校では1クラス30-40名)、全学生を均等にモニタリングすることが物理的に困難である。

6.9.3 本システムのGuardian Agentsの差別化ポイント

本システムのGuardian Agentsは、上記の国際的EWSと日本の従来手法の双方に対して、以下の3点で差別化される。第一に、Gate機構による責任分界の明確化である。既存のEWSは「検知→通知」の一方向パイプラインであるのに対し、本システムは「検知→Gate制御→人間判断→アクション」のループ構造を持ち、AIと人間の責任範囲を明示的に定義する。第二に、マルチエージェント統合分析である。単一のスコアリングモデルではなく、Agent 1(学力)、Agent 3(出席)、メンタルヘルス推定の複数エージェントが独立に分析を行い、その結果を統合することで、単一モデルでは捕捉できない複合的リスクパターンを検知する。第三に、教員UIとの統合設計である。リスク検知結果が単なるリスト表示にとどまらず、「カルテ」(学生詳細画面)や「対応」(ステータス更新)への導線が組み込まれた行動指向型UIにより、検知から対応までのワークフローが一貫して支援される。

> 本章で述べたGuardian Agentsの実装は、現段階ではフロントエンドのモックデータに基づくプロトタイプであるが、設計思想とUIコンポーネント構造は、バックエンドの機械学習モデルとの接続を前提として構築されている。次章では、第二象限「育てる」を担うTutor Agentsについて論じる。

第7章 Tutor Agents — 個別最適化学習支援機能の設計とプロトタイプ開発

7.1 Tutor Agents の概要と位置づけ

本システムの4象限AIエージェントモデルにおいて、第二象限「育てる(Tutor)」は、生徒一人ひとりに対する個別最適化された学習支援を担うエージェント群である。本象限の設計理念は「個別に最適化された『学び』の自動設計」であり、画一的な指導からデータに基づく個別対応への転換を技術的に実現することを目的としている。

文部科学省が推進する「個別最適な学びと協働的な学びの一体的充実」(令和3年答申)の方針に沿い、Tutor Agentsは学習者の個々の到達度、弱点領域、学習スタイルを多角的に分析し、最適化された学習プランと教材推奨を自動生成する。従来の進路指導における学習支援は、教員の経験知と限られた面談時間に依存しており、38名の担当学生全員に対して十分に個別化された支援を提供することは困難であった。Tutor Agentsは、この構造的制約を技術的に解消し、教員の指導力をスケーラブルに拡張することを目指している。

清風情報工科学院のような私立学校においては、生徒の学力層が幅広く、志望進路も多様であるため、個別最適化の重要性は特に高い。国公立大学を志望する上位層、私立大学を志望する中間層、専門学校や就職を検討する生徒など、それぞれに異なる学習戦略が求められる。Tutor Agentsは、この多様性に対応するために、生徒ごとに異なる分析パラメータと出力テンプレートを適用する設計となっている。

Tutor Agentsの設計は、教育心理学の理論的裏付けに基づいている。Bloom(1984)が「2シグマ問題」として指摘したとおり、個別指導(1対1のチュータリング)を受けた学生は、集団授業のみの学生と比較して平均2標準偏差の学力向上を示す。しかし、全学生に個別指導を提供することはリソース的に不可能である。Tutor Agentsは、AIによる学習分析と計画生成を通じて、個別指導の効果を擬似的にスケーラブルに実現することを目指している。

また、Vygotsky(1978)の最近接発達領域(Zone of Proximal Development: ZPD)の概念は、Tutor Agentsの学習プラン生成における中核的な設計原理である。Agent 2が生成する学習プランは、学生の現在の到達度(実発達水準)を分析した上で、適切な難易度の課題(ZPD内の課題)を提案するスキャフォールディング機能を担う。さらに、自己調整学習(Self-Regulated Learning)理論(Zimmerman, 2002)に基づき、学生が自身の学習プロセスをメタ認知的にモニタリングし、計画・実行・振り返りのサイクルを自律的に回せるよう支援する設計としている。

本章では、Tutor Agentsの主要構成要素であるAgent 2(個別最適化学習プラン生成)、Agent 6(カリキュラム最適化)、および面接練習支援機能について、その処理プロセス、出力形式、Gate Level設計、使用実績を論じるとともに、フロントエンド実装の技術的詳細を解説する。

7.2 Agent 2: 個別最適化学習プラン生成

7.2.1 処理プロセスの設計

Agent 2は、生徒の過去のテスト成績データおよび誤答分析データを入力として、個別最適化された学習プランを自動生成するエージェントである。その処理プロセスは、大きく2つのフェーズに分かれる。

第一フェーズは「弱点単元抽出」である。直近6回分のテスト成績を教科別・単元別に分析し、正答率が学年平均を明確に下回る単元を自動抽出する。単なる得点の高低ではなく、時系列トレンド(改善中か悪化中か)、他の関連単元との依存関係(前提知識の欠如が原因か否か)、誤答パターン(計算ミスか概念理解の不足か)を多角的に評価する。

第二フェーズは「誤答分析」である。各テストにおける個別の誤答内容を分析し、共通する誤答パターンを抽出する。たとえば、理科(物理分野)において力学と波動の計算問題で繰り返し失点しているパターンが検出された場合、「公式の使い分けが定着していない」という根本原因を推定し、それに対応した学習提案を生成する。

これら2つのフェーズの分析結果を統合し、Agent 2は「来週の学習プラン」を自動生成する。学習プランには、重点学習単元の指定、推奨教材の提案、1日あたりの学習時間配分案、達成度予測(今の学習ペースで次回テストにおいてどの程度

の改善が見込めるか)が含まれる。達成度予測の可視化により、生徒自身が学習のモチベーションを維持しやすい設計としている。

7.2.2 出力形式とGate Level

Agent 2の出力は、学生向けテストスコア画面(`student-test-scores.tsx`)の「AI弱点分析」タブにおいて表示される。出力は、科目別の分析レポートと具体的な学習提案の2層構造で構成される。

分析レポートは、弱点の内容を自然言語で記述する。たとえば「物理分野(力学・波動)で正答率が低下傾向。特に計算問題での失点が目立ちます。」という分析結果に対し、「基礎問題集の力学・波動の章を重点的に復習し、公式の使い分けを定着させましょう。」という具体的な学習提案が対となって提示される。各提案には優先度(high / medium / low)が付与され、限られた学習時間を最も効果的な領域に配分するための指針を提供する。

Agent 2のGate LevelはL=0.3に設定されている。これは、学習プランの提案という教育的判断を含むタスクであるため、Agent 3(出席データ分析、L=0.2)よりも高い人間介入レベルが求められることを反映している。生成された学習プランは、教員の確認を経て学生に提示される設計としている。UIにおいても「AIの提案は先生の確認を経て表示されています」という注釈が画面下部に明記されており、Gate機構の存在が利用者に対して透明化されている。

7.2.3 想定利用規模と期待精度

プロトタイプのパilotデータでは、Agent 2の月間利用回数を387回、期待精度を88%と想定している(設計目標値)。ここでの「精度」は、Agent 2が提案した重点学習単元の改善提案に従った場合に、次回テストにおいて当該単元の得点が向上する割合として定義する。これらの数値はシミュレーション値であり、実運用データに基づく検証は今後のパイロット運用で実施予定である。Guardian Agents(Agent 1: 目標94%, Agent 3: 目標97%)と比較して目標精度がやや低いのは、学習プランの有効性が生徒の学習量・学習方法という外部変数に強く依存するためであり、Agent 2の分析精度そのものの限界というよりは、介入の実行段階における変数の影響が大きいと想定される。

7.3 Agent 6: カリキュラム最適化

7.3.1 処理プロセスの設計

Agent 6は、Agent 2が個々の生徒を対象とするのに対し、クラス・学年単位でのカリキュラム最適化を担うエージェントである。教育課程全体のPDCA(Plan-Do-Check-Act)サイクルを加速するために設計されており、その処理プロセスは3つの分析軸で構成される。

第一の分析軸は「単元別平均点分析」である。各定期考査において、単元ごとのクラス平均点を算出し、指導計画との乖離を検出する。平均点が想定値を大幅に下回る単元は、授業設計の見直しが必要な領域として特定される。第二の分析軸は「理解度推移分析」である。同一単元に対する理解度が時間の経過とともにどのように変化するかを追跡し、定着率の低い単元(短期記憶にとどまり長期記憶に移行していない単元)を抽出する。第三の分析軸は「他年度比較分析」である。過去の年度における同一単元の成績データと比較し、今年度のカリキュラム実施状況の相対的な評価を行う。

7.3.2 出力形式とGate Level

Agent 6の出力は、データに基づく単元再設計案として教員に提示される。具体的には、時間配分の見直し提案(理解度の低い単元への授業時数増加)、指導方法の改善提案(演習中心への切替、反転授業の導入等)、補助教材の追加提案が含まれる。これらの提案は教育課程の根幹に関わる判断であるため、Gate LevelはL=0.7と設定されており、12エージェントの中で最も高い人間介入要求レベルとなっている。すなわち、Agent 6の出力は「条件付き自律実行」の範囲にあるものの、カリキュラム変更という重大な教育的意思決定に対しては、教員による詳細な検討と承認が必須条件として設計されている。

教育改善PDCAサイクルの高速化が、Agent 6の主要な価値提案である。従来、カリキュラムの見直しは年度末の反省会や学期末の成績分析に基づいて行われており、改善策の実行までに数ヶ月のタイムラグが生じていた。Agent 6は、各定期考査の結果が入力されるたびにリアルタイムで分析を実行し、学期中のカリキュラム微調整を可能にする設計としている。

7.3.3 想定利用規模と期待精度

プロトタイプの実データでは、Agent 6の月間利用回数を156回、期待精度を82%と想定している(設計目標値)。Agent 2(387回)と比較して想定利用回数が少ないのは、カリキュラム最適化がクラス・学年単位のマクロレベルの分析であり、定期考査のタイミングに紐づく周期的なタスクであるためである。期待精度82%は、Agent 6が提案したカリキュラム調整を実施した場合に、次回テストにおいて当該単元のクラス平均点が改善する割合として定義する。Gate Level L=0.7 の設定が示すとおり、教育的判断の比重が大きいタスクであるため、Agent単体の精度のみならず、教員の教育的判断との協働による最終的な改善効果を評価する枠組みが重要である。

7.4 学生テストスコア画面の詳細

7.4.1 画面構成とタブ設計

Agent 2の分析結果を表示する中心的なUIが、学生向けテストスコア画面(‘StudentTestScores’コンポーネント、‘student-test-scores.tsx’)である。本画面は、‘Tabs’コンポーネントにより4つのタブで構成されている。

第一タブ「推移グラフ」(‘overview’)は、過去6回のテスト成績の推移を折れ線グラフで表示する。Rechartsライブラリの‘LineChart’コンポーネントを使用し、5教科(国語・数学・英語・理科・社会)の成績推移が個別の色(国語: ‘#ef4444’(赤)、数学: ‘#3b82f6’(青)、英語: ‘#22c55e’(緑)、理科: ‘#a855f7’(紫)、社会: ‘#f59e0b’(琥珀色))で描画される。横軸は「4月実力」「7月中旬」「7月期末」「9月実力」「11月中旬」「1月期末」の6時点、縦軸は40~100点のスケールで設定されている。モックデータにおいて、数学が70点から85点へ15点上昇する顕著な改善トレンドと、理科が65点から68点へ微増した後停滞するパターンが視覚的に確認できる。

第二タブ「強み・弱み」(‘radar’)は、科目別のバランスをレーダーチャートで表示する。Rechartsの‘RadarChart’コンポーネントにより、5教科のスコアを五角形のレーダー図として可視化する。‘PolarGrid’、‘PolarAngleAxis’、‘PolarRadiusAxis’の3つのサブコンポーネントにより、0~100のスケールの同心円グリッドが描画される。レーダーチャートの下部には、各教科の評価バッジが表示される。80点以上は「得意」(‘border-emerald-300 text-emerald-700’)、70点以上は「普通」(‘border-blue-300 text-blue-700’)、70点未満は「要強化」(‘border-amber-300 text-amber-700’)として自動分類される。

第三タブ「成績一覧」(‘history’)は、過去6回分のテスト成績をテーブル形式で表示する。テスト名、日付、5教科の個別得点、合計点、学年内順位が一覧表示される。順位は「32/240」のように分母付きで表示され、学年における相対的位置を把握できる。モックデータでは、4月の58位/240人から1月の32位/240人への継続的な順位上昇が確認できる。

第四タブ「AI弱点分析」(‘ai’)は、Agent 2の個別最適化学習プランの出力を表示する。本タブの詳細は次項で述べる。

7.4.2 5教科KPIとクラス平均比較

テストスコア画面の上部には、5教科のKPIカードが横並びで配置される。各カードには、科目名(‘label’)、最新スコア(‘value’、例:「85点」)、前回比較(‘change’、例:「前回比 +8」)、トレンドインジケータ(‘trend’、up / down / neutral)が表示される。‘KPICard’コンポーネントは‘role=“student”」として呼び出され、学生ロール固有のブルー系アクセントカラー(‘border-t-role-student’、‘text-role-student’)が適用される。

KPIカードの下部には、5教科合計の比較カードが配置される。モックデータにおいて、本人の合計377点とクラス平均332点の差分(+45点)がバッジ形式(‘bg-emerald-100 text-emerald-700’)で強調表示される。この設計により、生徒は自身の学力を全体の中で相対的に位置づけることができる。

7.4.3 Agent 2のAI弱点分析タブの実装

AI弱点分析タブは、‘border-l-4 border-l-role-student’のスタイリングが適用されたカードとして実装されている。カードヘッダーには‘Brain’アイコンとともに「AI学習アドバイス(Agent 2: 個別最適化学習プラン)」というタイトルが表示され、「過去の誤答分析に基づき、弱点単元を抽出して学習プランを提案しています。」という説明文が付記される。

本タブでは3件のAI推奨が表示される。各推奨は‘aiRecommendations’配列として定義され、以下の構造を持つ。第一推奨は理科(優先度: high、‘bg-red-100 text-red-700’)であり、「物理分野(力学・波動)で正答率が低下傾向」という分析に対し、「基礎問題集の力学・波動の章を重点的に復習し、公式の使い分けを定着させましょう」という具体的な学習提案

が提示される。第二推奨は国語(優先度: medium、`bg-amber-100 text-amber-700`)であり、古文の助動詞識別が弱点として特定され、「助動詞の活用表を毎日確認し、過去問で識別練習を行いましょう。推奨教材: 古文文法ドリル。」という教材推奨を含む提案が行われる。第三推奨は英語(優先度: low、`bg-blue-100 text-blue-700`)であり、リスニングパートの伸び悩みに対して「毎日15分のシャドーイング練習」と「English Journal アプリ」の推奨が提示される。

各推奨カードは、`Lightbulb` アイコン(琥珀色)による視覚的アクセントと、優先度に応じた色分けバッジにより、学習の優先順位が直感的に判別できるよう設計されている。学習提案本文は `bg-blue-50` の背景を持つ別枠に配置され、分析結果と提案が視覚的に明確に区分されている。

7.5 留学生対応との連携

7.5.1 Agent Team 1(留学生対応・教材自動翻訳システム)との関係

本システムのAgent Team設計において、Tutor Agentsは「Guardian-Tutor Agent Team(生徒支援統合)」の一翼を担うとともに、拡張領域としてAgent Team 1(留学生対応・教材自動翻訳システム)との連携が構想されている。清風情報工科学院においては、留学生の受け入れが今後増加することが見込まれており、日本語能力にばらつきのある留学生に対する個別最適化学習支援は喫緊の課題となっている。

Agent Team 1は、Agent 2が生成する学習プランおよび推奨教材を、留学生の母語および日本語能力レベルに応じて自動翻訳・難易度適応するシステムとして設計されている。具体的には、Agent 2が「基礎問題集の力学・波動の章を重点的に復習」という推奨を出力した場合、Agent Team 1はこの推奨を留学生の言語プロフィールに基づき多言語に翻訳するとともに、日本語能力試験(JLPT)のレベルに応じて教材内の漢字にふりがなを付加する、あるいは平易な表現に書き換えるといった難易度適応処理を行う。

7.5.2 教材多言語翻訳・難易度適応の重要性

教育のグローバル化に伴い、教材の多言語対応は単なる翻訳にとどまらない教育的配慮を要する。数学の用語体系は言語によって異なり(例: 日本語の「二次方程式」は英語では "quadratic equation"、中国語では「二次方程」)、これらの対応関係を正確にマッピングする必要がある。さらに、教材の難易度適応においては、言語的な難易度と教科内容の難易度を独立に制御する設計が求められる。すなわち、日本語能力は初級でも数学の理解度は高い留学生に対しては、数学的内容は維持したまま言語表現のみを平易化するという適応処理が必要となる。

Tutor AgentsとAgent Team 1の連携により、「個別最適化」の概念が学力面のみならず言語面にも拡張され、留学生を含む全生徒に対して公平かつ効果的な学習支援の提供が可能となる。この設計は、文部科学省が掲げる「誰一人取り残さない」教育の実現に向けた技術的貢献として位置づけられる。

7.6 技術的実装詳細

7.6.1 Rechartsによるデータ可視化の実装

学生テストスコア画面のデータ可視化は、Rechartsライブラリを全面的に採用している。Rechartsは、React環境に最適化された宣言的なチャートライブラリであり、D3.jsをベースとしつつもReactのコンポーネントモデルに適合した設計を提供する。

折れ線グラフの実装では、`LineChart` コンポーネントに対して6回分のテストデータ(`trendData` 配列)が `data` プロパティとして渡される。各教科は個別の `Line` コンポーネントとして定義され、`type="monotone"` による滑らかな曲線描画、`strokeWidth={2}` による線幅、`dot={{ r: 3 }}` および `activeDot={{ r: 5 }}` によるデータポイントの表示が設定されている。`CartesianGrid` は `strokeDasharray="3 3"` かつ `opacity={0.3}` により、控えめなグリッド線を描画し、データの視認性を確保しつつ視覚的なノイズを最小化している。

レーダーチャートの実装では、`RadarChart` コンポーネントに `cx="50%"` `cy="50%"` `outerRadius="70%"` のプロパティが設定され、カード内での適切なサイジングが行われる。`Radar` コンポーネントの `fill="#3b82f6"` `fillOpacity={0.3}` により、スコア領域が半透明の青色で塗りつぶされ、科目間のバランスが直感的に把握できる。

7.6.2 ResponsiveContainerによるレスポンシブ対応

すべてのチャートコンポーネントは、`ResponsiveContainer` でラップされている。`width="100%"` `height="100%"` の設定により、親コンテナのサイズ変更に従ってチャートが自動リサイズされる。これにより、デスクトップ(1440px幅以上)からタブレット(768px幅)、モバイル(375px幅)まで、一貫した表示品質が維持される。

`ResponsiveContainer` の外側には固定高さのコンテナ(`className="h-72"`、すなわち288px)が設定されており、チャートの縦方向のサイズが画面幅に依存せず安定した表示高さを保つ。この設計判断は、チャートの縦横比が崩れることによるデータの誤読を防ぐためである。特にレーダーチャートにおいては、正五角形の形状が歪むと科目間のバランス評価に誤解を生じる可能性があるため、アスペクト比の維持は重要な設計要件である。

7.6.3 AI推奨表示コンポーネントの設計

AI弱点分析タブの推奨表示は、入れ子構造の `Card` コンポーネントにより実装されている。外側の `Card` が Agent 2 の分析セクション全体を囲み、各推奨は内側の `Card` (`className="shadow-none"`) として個別にレンダリングされる。この2層のカード構造により、Agent全体のコンテキスト(「Agent 2: 個別最適化学習プラン」)と個別の推奨内容が明確に階層化される。

優先度の表示には、`priorityColors` および `priorityLabels` の2つのマッピングオブジェクトが使用される。
`priorityColors` は `high: "bg-red-100 text-red-700"`, `medium: "bg-amber-100 text-amber-700"`, `low: "bg-blue-100 text-blue-700"`` として定義され、`Badge` コンポーネントの `className` に動的に適用される。色の選定は、Guardian Agentsのリスクレベル表示(Red / Yellow / Green)とは意図的に異なるカラースキームを採用しており、「リスク」と「学習優先度」の概念的混同を防ぐ設計となっている。Redは共通しているが、低優先度にGreenではなくBlueを採用することで、「危険がない」のではなく「改善の余地がある」という肯定的なニュアンスを伝達している。

各推奨カード内のレイアウトは、上部に科目名(`Lightbulb` アイコン付き)と優先度バッジを横並びで配置し、中部に分析結果テキスト(`text-muted-foreground`)を配し、下部に学習提案を青背景(`bg-blue-50 text-blue-800`)のハイライト枠で表示する構成となっている。この3層レイアウトにより、「何が(科目)」「なぜ(分析)」「どうする(提案)」という情報の論理構造がUI上で自然に表現されている。

7.7 面接練習支援機能

7.7.1 面接練習支援エージェントの設計思想

専門学校における進路指導では、筆記試験対策に加えて面接対策が極めて重要な位置を占める。特に大学入試(総合型選抜・学校推薦型選抜)や就職試験においては、面接が可否を左右する決定的要因となることが多い。しかし、教員が全学生に対して十分な面接練習の機会を提供することは、時間的制約から困難である。

面接練習支援機能は、以下の3つのサブ機能で構成される。

想定質問生成: 学生の志望理由書の内容分析、過去の面接記録パターン(Agent 7の面談サマリーから抽出)、および志望校・志望企業の面接傾向データを統合し、当該学生に特化した想定質問リスト(15-20問)を自動生成する。質問は「志望動機系」「自己PR系」「学力・研究系」「時事問題系」「圧迫対応系」の5カテゴリに分類され、難易度レベル(基礎・標準・応用)が付与される。

回答フィードバック生成: 学生が入力した回答に対して、3軸での評価フィードバックを生成する。第一軸「構成力」は、PREP法(Point-Reason-Example-Point)等の論理構造の明確さを評価する。第二軸「論理性」は、主張と根拠の整合性、具体例の適切さを評価する。第三軸「具体性」は、抽象的表現と具体的エピソードのバランスを評価する。各軸を5段階で採点し、改善提案を併記する。

ロールプレイモード: AI面接官としての対話シミュレーション機能を設計している。学生は画面上でAIとの模擬面接を実施し、質問に対するリアルタイムの受け答えを練習できる。終了後には全体講評が生成され、教員が確認・コメントを追加した上で学生にフィードバックされる。

7.7.2 Gate Level設計とUI連携

面接練習支援機能にはGate Level L=0.3(上長承認)を適用する。これは、面接対策の内容が学生の進路選択に影響を及ぼし得るが、最終的な面接指導は教員が直接行うものであり、AI出力は「練習素材」としての位置づけにとどまるためである。教員は、生成された想定質問リストと回答フィードバックを確認し、教育的に不適切な内容がないかを審査した上で学生に提供する。

UIの実装は`student-interview-booking.tsx`のスマート予約機能と連携し、面接練習セッションの予約から実施、フィードバック受領までのワークフローを一貫して管理する設計としている。

7.8 学習者体験のデザイン考察

7.8.1 学習者のエージェンシー(主体性)を損なわないAI支援

教育AIの設計において最も重要な考慮事項の一つは、AI支援が学習者のエージェンシー(Agency: 主体性・自律性)を損なわないことである。AIが学習計画を完全に自動生成し、学生がそれに従うだけの受動的な関係は、自己調整学習の観点から教育的に望ましくない。

本システムの学生向けAIツール(`student-ai-tools.tsx`)は、以下の設計原則に基づいている。第一に、「AIの提案は選択肢であり、強制ではない」というスタンスを明示する。学習プランは「推奨」として提示され、学生が自身の判断で修正・選択できるUI設計とする。第二に、目標設定画面(`student-goals.tsx`)では、学生自身が目標を設定し、AIはその目標達成に向けた道筋を提案する支援者の役割に徹する。第三に、ポートフォリオ機能(`student-portfolio.tsx`)を通じて、学生が自身の成長を可視化し振り返ることで、メタ認知能力の向上を促進する。

7.8.2 ゲーミフィケーション要素の導入可能性

学生の学習動機を維持・向上させるための方策として、ゲーミフィケーション要素の導入可能性を検討している。具体的には、目標達成時のマイルストーンバッジ、学習プラン完遂率の可視化(プログレスバー)、週間・月間の振り返りサマリーの自動生成等が候補として挙げられる。ただし、外発的動機づけへの過度な依存は内発的動機づけを阻害するリスクがあるため(Deci & Ryan, 2000)、導入にあたっては教育心理学の知見に基づく慎重な設計が求められる。

> 本章で述べたTutor Agentsの実装は、生徒の個別最適化学習支援という教育的価値を、データ分析とUI設計の両面から技術的に実現するものである。Agent 2の学習プラン生成機能とAgent 6のカリキュラム最適化機能は、それぞれミクロレベル(個人)とマクロレベル(クラス・学年)の学習最適化を担い、面接練習支援機能は進路指導の実践的側面を補完する。これらの連携により、包括的な教育改善サイクルの構築を目指している。次章では、第三象限「回す」を担うAdmin Agentsについて論じる。

第8章 Admin Agents — 事務業務自動化機能の設計とプロトタイプ開発

8.1 Admin Agents の概要と位置づけ

8.1.1 「回す」象限の定義と戦略的意義

本システムの4象限AIエージェントモデルにおいて、第三象限「回す (Admin Agents)」は、教育機関における事務業務の自動化を設計目標とする機能群である。第一象限「守る (Guardian)」が生徒のリスク検知を、第二象限「育てる (Tutor)」が個別最適化学習支援を担うのに対し、「回す」象限は教職員および事務職員の日常業務プロセスを自動化・効率化することにより、教育活動の基盤を支える役割を果たす。

文部科学省の教員勤務実態調査(2023年度)によれば、教員の業務時間の相当部分が事務的処理業務に費やされている。これらには、面談記録の作成、保護者向けレポートの執筆、成績データの集計と分析、書類の発行管理、スケジュール調整、データ入力と確認といった定型的かつ反復的な作業が含まれる。これらの業務は、教育的判断を直接伴わないにもかかわらず、教員の時間的・精神的リソースを圧迫しており、生徒との対話や個別指導といった本質的な教育活動への時間配分を構造的に阻害している。

Admin Agentsは、この構造的課題に対して、AIによる文書自動生成、データ集約・分析、スケジュール最適化という三つの技術的アプローチを通じて解決を図る。具体的には、Agent 7(面談サマリー自動生成)、Agent 9(保護者向けレポート生成)、Agent 10(時間割最適化)の3エージェントで構成される。いずれのエージェントも、Gate機構によるAI自律レベル制御のもとで運用され、生成された出力は最終的に教員または事務職員の確認・承認を経て確定される設計となっている。

8.1.2 業務効率化の数値目標

Admin Agentsの導入により、本システムは進路指導関連の事務作業時間の大幅な削減を目標として設定している。削減された時間は、教員が生徒と直接向き合う対応時間の拡張に再配分されることが期待される。この目標の達成に向けて、各エージェントはそれぞれ異なる業務領域を分担しながら、事務方ダッシュボードとの連携を通じて統合的な業務効率化を実現する。

8.2 Agent 7: 面談サマリー自動生成

8.2.1 機能概要と処理フロー

Agent 7は、教員が実施する面談の事前準備および事後記録を自動化するエージェントである。面談は教員と生徒の信頼関係に基づく高度な対話行為であり、その本質はAIに代替し得るものではない。しかしながら、面談の準備段階における情報収集・整理と、面談後のサマリー作成という付随的な事務作業は、教員の時間を著しく圧迫している。Agent 7は、この付随的業務を自動化することにより、教員が面談の質的向上に集中できる環境を整備することを目的とする。

Agent 7の入力データは、生徒の成績データ、生活記録(出欠・遅刻パターン、保健室利用履歴等)、および過去の面談ログの三種である。これらのデータを統合的に解析し、出力として面談要約、懸念点の列挙、および推奨対話項目を自動生成する。Gate Levelは $L=0.3$ に設定されており、これはAIが草案を生成し、教員がそれを確認・修正した上で最終的な記録として確定するという運用モデルに対応する。

8.2.2 想定利用規模と精度設計

プロトタイプのモックデータでは、Agent 7の想定月間利用回数を289回と設定しており、生成されたサマリーの期待精度は91%を目標としている。ここでの「精度」とは、教員がAI生成サマリーを確認した際に、内容の修正を要しない、あるいは軽微な修正のみで最終確定に至る割合を指す。残りの9%については教員による加筆・修正が見込まれるが、いずれの場合もAI生成の草案がゼロからの作成と比較して時間削減に寄与することが期待される。なお、これらの数値はシミュレーション値であり、実運用データに基づく検証は今後のパイロット運用において実施予定である。

8.2.3 実装の詳細:面談記録管理システム

本システムのフロントエンド実装において、Agent 7のUI設計は、主として二つのビューコンポーネントとして実装されている。

第一のコンポーネントは`teacher-interview-list.tsx` (面談記録一覧)である。本コンポーネントは、教員が過去の面談記録を検索・閲覧するためのインターフェースを提供する。4つのKPI指標(今月の面談数:24件、サマリー未作成:3件、保護者面談:8件、平均面談時間:28分)がダッシュボード上部に配置され、教員は自身の面談業務の現況を即座に把握することができる。面談記録テーブルには10件のモックデータが実装されており、各記録は日付、学生名、種別(定期・臨時・保護者の3分類)、面談時間、サマリー内容、ステータス(完了・サマリー未作成)の各フィールドで構成される。検索機能として学生名・内容によるテキスト検索、種別フィルタ、ステータスフィルタが実装されている。

第二のコンポーネントは`teacher-interview-input.tsx` (面談記録入力)である。本コンポーネントは、新規面談の記録作成を支援するフォームと、Agent 7によるサマリー自動生成機能を統合したインターフェースを提供する。画面は左右の二カラム構成を採り、左側に面談基本情報(学生名、面談日、種別、面談時間)の入力フォームと面談内容の詳細記録欄を配置し、右側にAgent 7のAI生成サマリーパネルを配置している。サマリーパネルには、Gate Level L=0.3 の表示が明示されており、AIの自律度レベルと人間確認の必要性がユーザに視覚的に伝達される設計となっている。

AI生成サマリーの出力例として、本プロトタイプには以下の構造化されたテンプレートが実装されている:学生状況の概要(出席率、成績推移の定量データ)、懸念事項の列挙(出席率低下、遅刻パターン、課題未提出、課外活動との両立等の具体的項目)、推奨対話項目(体調確認、学習バランスの再検討、補習参加の意思確認、進路計画の見直し等の対話指針)、および前回面談からの経過報告。教員はこの草案を直接編集可能であり、「プレビュー」と「編集」モードの切替、「面談内容に反映」ボタンによるフォームへの自動転記、「再生成」ボタンによるサマリーの再生成といった操作が用意されている。

8.2.4 AIダイジェストとの連携

Agent 7は、`teacher-digest.tsx` (ダイジェスト確認)コンポーネントを通じて、教員向けの日次・週次ダイジェスト生成とも連携する。本コンポーネントは、Agent 1(不登校予兆検知)、Agent 3(学力低下アラート)、Agent 5(進路推薦支援)、およびAgent 7自身の分析結果を統合し、教員に対して毎日のブリーフィングを自動生成する。

ダイジェストの構成は、4つのセクションから成る。第一に「要注意学生」セクションでは、Red・Yellowの2段階リスクレベルで学生の状況を要約し、各学生に対する推奨アクションとデータソース(参照したエージェント番号)を明示する。第二に「今週の面談予定」セクションでは、面談スケジュールを日時、対象学生、面談種別とともに一覧表示する。第三に「進路決定進捗」セクションでは、担当学生の進路決定状況を決定済み、準備中、未決定の三区分で可視化し、直近の進路決定事例を記載する。第四に「アクション推奨」セクションでは、緊急・推奨・任意の3段階優先度で教員が取るべきアクションをAIが提案する。

本ダイジェストのフッターには「Gate L=0.7」の表示がなされており、最終判断は教員が行うべきことが明確に示されている。このように、Agent 7の面談サマリー生成機能は、単独のエージェントとしてだけでなく、複数エージェントの出力を統合したダイジェスト生成の基盤としても機能しており、Admin AgentsとGuardian Agentsの横断的連携の一例となっている。

8.3 Agent 9:保護者向けレポート生成

8.3.1 機能概要

Agent 9は、生徒の成績推移や学級平均との差分を解析し、保護者にとって理解しやすい自然言語のレポートを自動生成するエージェントである。従来、教員は学期末の通知表コメント作成や保護者面談の準備資料作成に多大な時間を費やしていた。一人の教員が担当する生徒が30名から40名に及ぶ場合、個々の生徒に対する個別的かつ正確なコメントの作成は、特に時間を要する業務の一つである。

Agent 9は、成績データベースから各生徒の成績推移(教科別得点、偏差値、順位の時系列変化)を抽出し、学級平均・学年平均との比較分析を行った上で、保護者が直感的に理解できる平易な日本語によるレポート文を自動生成する。生成されるレポートには、成績の概況、強みとなる教科、改善が求められる教科、学習面でのアドバイス、進路に関する所見が含まれる。

8.3.2 想定利用規模と設計上の考慮

Gate Levelは Agent 7 と同じく $L=0.3$ に設定されており、AIが生成した草案を教員が確認・修正した上で保護者に提供するという運用フローが採用されている。プロトタイプのモックデータでは想定月間利用回数を198回、期待精度の目標値を89%と設定している(いずれもシミュレーション値)。

Agent 9の設計においては、保護者向け文書としての配慮が不可欠である。生徒の成績を伝える文書は、過度に否定的な表現が生徒のモチベーションを損なうおそれがある一方で、現実から乖離した楽観的な表現は保護者の信頼を損ないかねない。このバランスを適切に取るため、Agent 9の生成モデルには、教育的配慮に基づくトーン調整の機構が組み込まれている。具体的には、改善が必要な領域については「～の分野では、さらなる伸びしろが見込まれます」「～に重点的に取り組むことで、より一層の成長が期待できます」といった建設的な表現パターンが採用される設計とした。

8.3.3 通知表コメント作成時間の削減効果

Agent 9の導入により、通知表コメント作成に要する時間の削減が期待される。従来、教員一人当たり30名分のコメント作成に相当の時間を要していたと推定されるが、Agent 9の草案生成機能を活用することで、この作業時間を大幅に短縮することが見込まれる。削減された時間は、コメント内容のより深い個別化や、保護者とのコミュニケーションの質的向上に充当することが可能となる。

8.4 Agent 10: 時間割最適化

8.4.1 最適化問題としての時間割編成

Agent 10は、学校の時間割編成を組合せ最適化問題として定式化し、制約条件を満たしつつ教職員の負荷を最小化する時間割案を自動生成するエージェントである。時間割編成は、教育機関の管理業務において最も複雑な業務の一つとして知られており、多数の制約条件が相互に影響し合う性質を持つ。

考慮すべき制約条件は多岐にわたる。第一に授業数の制約として、各教科・各クラスに対する週当たりの授業時数が教育課程に基づいて規定される。第二に連続コマの制約として、同一教員または同一クラスに対する連続授業の上限が設定される。第三に専門科目の制約として、特定の実験室・実習室を必要とする科目は、当該施設の利用可能性に依存する。第四に教室制約として、教室の収容人数、設備(プロジェクター、実験機材等)、物理的配置が考慮される。これらに加え、教員の出勤日・勤務時間帯、非常勤講師のスケジュール、学校行事との調整等の条件が複合的に関わる。

8.4.2 解法と出力形式

Agent 10は、これらの制約条件をモデル化した上で、負荷最小化時間割の立案と複数の代替案を同時に生成・提示する。Gate Levelは $L=0.7$ に設定されており、これは時間割編成が学校運営全体に及ぼす影響の大きさを反映した設定である。すなわち、AIが生成した時間割案は、管理者による確認・承認を経て初めて確定される。

プロトタイプ段階での想定月間利用回数は45回(シミュレーション値)、精度は目標値として85%を設定している。ここでの「精度」とは、AIが生成した時間割案がそのまま、あるいは軽微な調整のみで採用された割合を指す。使用回数が他のエージェントと比較して少ないのは、時間割編成が学期初めや人事異動時等の限定的なタイミングで集中的に実施される業務であることに起因する。

8.5 事務方向けダッシュボードとの連携

8.5.1 事務方ダッシュボードの全体構成

Admin Agentsの機能は、事務方(Office)ロール向けダッシュボードを通じて統合的に提供される。`office-dashboard.tsx`として実装された事務方ダッシュボードは、4つのKPI指標を画面上部に配置し、事務業務の全体像を一目で把握可能な設計としている。

4つのKPIは以下の通りである。第一に「未処理手続き数(18件)」は、事務方が対応すべき書類発行・手続き業務の残件数を示し、前日比-5件の改善傾向が表示される。第二に「書類期限切れ(4件)」は、対応期限を超過した手続きの件数を示し、今週+2件の増加が警告として表示される。第三に「今日の面談(12件)」は、当日予定されている面談の総数と残件数(8件)を示す。第四に「データ取込状況(96%)」は、外部データの取り込み完了率と最終同期時刻を示す。

8.5.2 手続き管理機能

ダッシュボード下部には、5件の未着手手続き一覧が実装されている。各手続きレコードは、対象学生名、手続き種別（調査書発行、推薦状作成依頼、出願書類確認、成績証明書、健康診断書）、対応期限、ステータス（期限間近・未着手・進行中）、および緊急度フラグの各属性を有する。緊急度の高い手続きには赤色の「急」バッジが付与され、事務職員の注意を喚起する視覚的デザインが採用されている。ステータスは色分けされたバッジで表示され、「期限間近」は赤色、「未着手」は黄色、「進行中」は緑色で識別可能である。

8.5.3 面談スケジュールとデータ取込状況

同ダッシュボードには、5件の本日面談スケジュールが時系列順に表示される。各スケジュールには、時刻、担当教員名、対象学生名、使用面談室が記載され、完了済みの面談には取消線が付与されることで、当日の進捗状況がリアルタイムに把握できる。

データ取込状況セクションでは、4種のデータソース（成績データ、出席データ、進路先マスタ、奨学金情報）について、プログレスバーによるインポート完了率の可視化と最終同期時刻の表示が実装されている。成績データおよび出席データは完了率100%（最終同期：本日08:00）、進路先マスタは96%（最終同期：昨日18:00）、奨学金情報は72%（最終同期：2日前）と表示され、データの鮮度と完全性を事務職員が常時モニタリングできる設計となっている。

8.5.4 事務方向けダイジェスト機能

事務方ダッシュボードの機能を拡充するものとして、`office-digest.tsx`（事務ダイジェスト）コンポーネントが実装されている。本コンポーネントは、AIが本日の事務業務を自動的にまとめ、重要度の高いアクションアイテムから順に提示する。

ダイジェストは4つのカードで構成される。第一に「本日の手続き件数」カードでは、全18件の手続きを完了（7件）、進行中（6件）、未着手（5件）の三区分で表示し、個別の手続き項目とその期限・優先度を一覧表示する。第二に「書類発行状況」カードでは、本日の発行済み件数（4件）、待ち件数（14件）、平均処理日数（2.3日）を書類種別（成績証明書、在学証明書、推薦状、調査書）ごとに表示する。第三に「出願締切アラート」カードでは、5件の大学出願締切情報を残日数と対象学生数とともに表示し、本日締切の案件は赤色背景で強調される。第四に「未納学費リスト」カードでは、6名の未納者情報（氏名、クラス、金額、期、延滞日数）を一覧表示し、督促状作成ボタンが付属する。

8.6 データインポート機構

8.6.1 機構の概要と設計思想

Admin Agentsが有効に機能するためには、正確かつ最新のデータが継続的にシステムに投入される必要がある。`office-data-import.tsx`として実装されたデータインポート機能は、この要件を満たすための基盤的機構である。

本コンポーネントは、4つのKPI指標（今月インポート数：12回、総取込レコード：24,580件、最終取込：2時間前〔成績データ〕、エラー率：0.3%〔前月比-0.2%改善〕）を画面上部に配置し、データ取込業務の全体像を提供する。

8.6.2 バッチインポート機能

データインポートは、4種のデータ種別に対応している。第一に成績データ（定期テスト・模試の成績データ）、第二に出席データ（日次出席データ）、第三に学生マスタ（学生基本情報のマスタデータ）、第四に進路先マスタ（進路先の基本情報）である。各データ種別について、CSV/Excelフォーマットでのアップロードに対応しており、テンプレートファイルのダウンロード機能も提供されている。

ファイルアップロードは、ドラッグ・アンド・ドロップ操作またはファイル選択ダイアログを通じて行われ、対応形式はCSVおよびXLSX、最大ファイルサイズは50MBに設定されている。

8.6.3 バリデーション機能

データインポート時には、自動バリデーション機能が適用される。バリデーション結果は「エラー」と「警告」の二段階で分類され、具体的なエラー事例として以下のようなケースが検出される。エラー事例には「存在しない学生ID」（行245、学生IDフィールド、値 "S2024-XXX"）、「得点範囲外」（行891、得点フィールド、値 "105"、0～100の範囲外）が含まれる。警告事

例には「全角スペースの混在」(行34、氏名フィールド、自動修正済み)、「無効な日付」(行567、日付フィールド、値"2026/2/30"、自動スキップ済み)が含まれる。

エラーに該当するレコードはインポートから除外され、警告に該当するレコードは自動修正またはスキップの措置が適用された上でインポートが継続される。このバリデーション機構により、データ品質を担保しつつ、事務職員のデータ確認作業を最小限に抑える設計としている。

8.6.4 インポート履歴と監査証跡

データインポートの履歴は、10件分の時系列レコードとして表示される。各レコードには、インポートID (IMP-015～IMP-024)、日時、データ種別、総レコード数、成功件数、エラー件数、ステータス(完了・完了[警告あり])、および担当者名が記録される。データ種別によるフィルタリング機能が実装されており、特定種別のインポート履歴を選択的に閲覧することが可能である。

この監査証跡機能は、データの信頼性を担保する上で重要な役割を果たす。Admin Agentsを含む各AIエージェントが正確な分析結果を出力するためには、入力データの品質が前提条件となる。データインポート機構の履歴管理とバリデーション機能は、この前提条件を制度的・技術的に保証するための基盤として位置づけられる。

8.7 本章のまとめ

本章では、本システムの4象限AIエージェントモデルにおける第三象限「回す (Admin Agents)」の設計とプロトタイプ開発について詳述した。Agent 7(面談サマリー自動生成、想定月間利用回数289回(シミュレーション値)、精度目標91%)、Agent 9(保護者向けレポート生成、想定月間利用回数198回(シミュレーション値)、精度目標89%)、Agent 10(時間割最適化、想定月間利用回数45回(シミュレーション値)、精度目標85%)の3エージェントは、いずれもGate機構によるAI自律レベル制御のもとで運用され、事務業務の自動化を通じた教員の本質的業務への時間再配分を目指す。

フロントエンド実装においては、面談記録管理システム(`teacher-interview-list.tsx`、`teacher-interview-input.tsx`)、AIダイジェスト生成機能(`teacher-digest.tsx`、`office-digest.tsx`)、事務方ダッシュボード(`office-dashboard.tsx`)、およびデータインポート機構(`office-data-import.tsx`)を通じて、Admin Agentsの機能がユーザに提供されている。これらのコンポーネントは、単なる個別機能の集合ではなく、Guardian AgentsやTutor Agentsとの横断的なデータ連携を設計しており、本システムの統合的な教育支援基盤としての価値を実現することを目指している。

第9章 Management Agents — 経営意思決定支援機能の設計とプロトタイプ開発

9.1 Management Agents の概要と位置づけ

9.1.1 「導く」象限の定義と戦略的意義

本システムの4象限AIエージェントモデルにおいて、第四象限「導く(Management Agents)」は、公平性と経営視点に基づく意思決定支援を設計目標とする機能群である。第一象限「守る(Guardian)」が個々の生徒のリスク検知を、第二象限「育てる(Tutor)」が個別最適化学習支援を、第三象限「回す(Admin)」が事務業務の自動化をそれぞれ担うのに対し、「導く」象限は教育機関全体の経営的視座からの分析・評価・意思決定を支援する。すなわち、個々の生徒や教員のミクロレベルの支援を超えて、学校法人としてのマクロレベルの戦略的意思決定にAIの分析能力を活用するものである。

教育機関における経営的意思決定は、学業成績のトレンド分析、在籍率の管理、進路決定率の向上、教育品質の評価、リソース配分の最適化といった多面的な要素を総合的に勘案して行われる。しかしながら、従来これらの分析は、管理職の経験的知見と断片的なデータに基づいて行われることが多く、データに裏付けられた体系的な分析とエビデンスに基づく意思決定(Evidence-Based Decision Making)の実践は、多くの教育機関において十分に浸透しているとは言い難い状況にある。

Management Agentsは、この課題に対して、成績評価の公平性監査(Agent 4)、経営ダッシュボードによる統合分析(Agent 8)、データに基づく進路推薦支援(Agent 5)という三つの機能を提供する。いずれのエージェントも、経営判断への直接的な影響力を有することから、Gate Levelは比較的高い水準(L=0.3~L=0.7)に設定されており、AIの出力は管理者・教員による確認と承認を経て初めて意思決定に反映される設計となっている。

9.1.2 経営層向け意思決定支援の射程

Management Agentsが対象とする意思決定支援の射程は、以下の三領域にわたる。第一に、教育品質の評価と改善であり、成績評価の妥当性検証、カリキュラムの効果測定、教員の指導力評価等が含まれる。第二に、進路指導の高度化と公平性担保であり、過去の進学実績に基づく進路推薦、適性傾向分析、学生個々の能力と志望のマッチング等が含まれる。第三に、学校経営の全体最適化であり、在籍率・退学率の管理、進学率の向上施策、学生満足度の把握と改善、中長期の経営戦略立案等が含まれる。

9.2 Agent 4: 成績評価妥当性チェック

9.2.1 機能概要と問題意識

Agent 4は、教員ごとの成績評価の分布をデータ分析上の観点で分析し、評価基準の妥当性を検証するエージェントである。教育における成績評価は、生徒の学力を測定すると同時に、進路決定の根拠となり、場合によっては推薦入試の要件として使用される。したがって、成績評価の公平性と一貫性は、教育の質を担保する上で根幹的な重要性を有する。

しかしながら、現実の教育現場においては、教員間の評価基準のばらつき、いわゆる「評価バイアス」の問題が潜在的に存在している。ある教員は相対的に甘い評価を付与し、別の教員は厳格な評価基準を適用するといった不均一が、意図的であるか否かにかかわらず生じうる。このような評価バイアスは、生徒間の公平性を損なうのみならず、学校全体の成績データの信頼性を毀損し、進路指導の精度にも悪影響を及ぼす。

9.2.2 分析プロセスと検出手法

Agent 4の分析プロセスは、以下の三段階で構成される。第一段階として、教員別の成績分布分析を実施する。各教員が担当する科目・クラスにおける成績分布(平均値、中央値、標準偏差、歪度、尖度)を算出し、学校全体の基準分布との乖離を測定する。第二段階として、標準偏差の異常検出を行う。特定の教員の成績分布において、標準偏差が学校全体の基準値から統計上無視できないに逸脱している場合(例えば、標準偏差が極端に小さい場合は「中央集中傾向」、極端に大きい場合は「分散過剰傾向」として検出)、異常フラグを発生させる。第三段階として、検出された異常に対して、評価バイアスの可能性を定量的に評価し、可視化されたレポートを管理者に提供する。

9.2.3 公平性監査の自動化と運用設計

Agent 4のGate LevelはL=0.7に設定されている。これは、成績評価の妥当性に関する指摘が、教員の専門的判断への介入と受け取られうるセンシティブな性質を有するためである。AIが生成する分析レポートは、あくまでデータ分析上の事実の提示と傾向の指摘にとどまり、特定の教員の評価を「不当である」と断定することは設計上避けられている。管理者は、AIのレポートを参考資料として、教員との建設的な対話を通じて評価基準の調整を図ることが期待される。

プロトタイプ段階での想定月間利用回数は312回(シミュレーション値)、精度は目標値として93%を設定している。ここでの「精度」とは、AIが検出した異常傾向が、管理者の確認により実際に要検討事項として認定された割合を指す。この精度目標は、Agent 4が客観的な統計指標に基づいて分析を行う設計に起因しており、主観的判断を排除した定量的アプローチの有効性が見込まれる。

9.3 Agent 8: 学校経営ダッシュボード

9.3.1 機能概要

Agent 8は、Management Agentsの中核を成すエージェントであり、学校経営に関わる多面的な指標を統合的に分析し、経営層向けの意思決定レポートと改善シミュレーションを提供する。分析対象となるメトリクスは、学年別パフォーマンス、退学率、進学率、授業満足度等の広範な指標群であり、これらを横断的に分析することで、学校経営の全体像を把握可能な経営ダッシュボードを構成する。

Gate LevelはL=0.7に設定されており、AIが生成する経営分析とインサイトは、管理者による確認・承認を経て初めて意思決定の根拠として使用される。プロトタイプのモックデータでは想定月間利用回数を567回と設定しており、12エージェント中最も高い利用頻度を想定している。これは経営層における日常的なダッシュボード参照ニーズを反映した設計値である。期待精度は87%を目標としている。なお、これらの数値はシミュレーション値であり、実運用データに基づく検証が今後の課題である。

9.3.2 実装の詳細: 管理者統計ダッシュボード

Agent 8の機能は、`admin-statistics.tsx` (統計・レポート)コンポーネントを通じて提供される。本コンポーネントは、「Agent 8 学校経営ダッシュボード連携」を明示的に表示し、統計データとAI分析インサイトを統合的に提示する設計を採用している。

9.3.3 KPI指標体系

画面上部には、4つの主要KPI指標がカード形式で配置されている。第一に「在籍率(98.2%)」は、全校生徒の在籍状況を示し、前年比+0.3%の改善傾向が表示される。第二に「進路決定率[3年](72.4%)」は、3年生の進路決定進捗を示し、前月比+12.1%の進展が表示される。第三に「平均偏差値(54.8)」は、全校生徒の学力水準を示し、前年比+1.2の向上傾向が表示される。第四に「満足度スコア(4.2/5.0)」は、学生アンケートに基づく教育サービスの満足度を示し、前年比+0.3の改善が表示される。

これらのKPIは、学校経営の健全性を多面的に評価するための基本指標として設計されており、在籍率は学校の「安定性」を、進路決定率は教育の「成果」を、平均偏差値は学力の「水準」を、満足度スコアは教育サービスの「品質」をそれぞれ代表するものと位置づけられる。

9.3.4 時系列分析と可視化

ダッシュボードの中央部には、3種類のチャートが実装されている。第一に「年度推移(過去5年)」折れ線グラフでは、2022年から2026年(予測値含む)にわたる在籍率、進路決定率、平均偏差値の推移が描画される。具体的なデータとして、在籍率は97.1%(2022年)から98.2%(2026年予測)へ、進路決定率は88.2%から72.4%(2026年は年度途中の暫定値)へ、平均偏差値は52.1から54.8へと推移しており、全体的な上昇トレンドが視覚的に確認できる設計となっている。Rechartsライブラリを用いたインタラクティブなグラフ描画により、各データポイントへのマウスオーバーで詳細値が表示される。

第二に「進路先分布」円グラフ(ドーナツチャート)では、全校生徒の進路先内訳を国公立大学(89名)、私立大学(312名)、専門学校(156名)、就職(42名)、その他・未定(648名)の5区分で表示する。各区分にはインディゴ系の段階的なカラーパレットが適用され、凡例と件数バッジが併記される。

第三に「学年別比較」棒グラフでは、1年生（在籍数225名、戦略策定率12%、模試受験率85%）、2年生（在籍数234名、戦略策定率45%、模試受験率92%）、3年生（在籍数248名、戦略策定率95%、模試受験率98%）の三学年を比較する。このグラフにより、学年が上がるにつれて進路戦略の策定率と模試受験率が向上する段階的な傾向が可視化される。

9.3.5 AI分析インサイト機能

ダッシュボード最下部には、Agent 8が生成するAI分析インサイトのセクションが配置されている。本セクションには「Agent 8 経営ダッシュボード」のバッジと「Gate L=0.7（人間判断必要）」の表示が明示されており、AI生成情報であることと Human-in-the-loopの要件が視覚的に伝達される。

4つのAI生成インサイトが実装されており、各インサイトには「positive」「warning」「alert」の三段階分類と確信度（Confidence Score）が付与されている。

第一のインサイト（positive、確信度85%）は「3年生の進路決定率が前年同時期を上回っています」と題し、現在の72.4%が前年同時期65.8%を6.6ポイント上回っていること、TGでの面談指導の効果が分析されることを報告する。第二のインサイト（warning、確信度78%）は「2年生の戦略策定率に改善の余地あり」と題し、2年生の策定率45%が目標60%を下回っていること、特に2年B組・F組の策定率が30%未満であることを指摘する。第三のインサイト（alert、確信度92%）は「出席パターン解析による要注意学生の検出」と題し、Agent 3の解析により直近2週間で出席率80%未満の学生が12名検出され、うち8名が2年生であることを報告する。第四のインサイト（positive、確信度71%）は「カリキュラム最適化の提案」と題し、Agent 6の分析による1年生の英語・数学科目間の高い相関と統合的カリキュラム設計の提案を報告する。

各インサイトは、分類に応じた色彩（positive: 緑、warning: 黄、alert: 赤）と対応するアイコン（ShieldCheckまたはAlertTriangle）で視覚的に区別される。セクション末尾には「このインサイトはAIが自動生成したものです。Gate Level L=0.7のため、経営判断への反映には管理者の確認・承認が必要です」という注記が付記されており、AIの役割と限界が明確に伝達される設計となっている。

9.4 Agent 5: 進路推薦支援

9.4.1 機能概要

Agent 5は、過去の進学実績データベースと学生個々の適性傾向分析を組み合わせ、データに基づく進路候補リストを生成・提示するエージェントである。従来の進路指導においては、教員の経験的知見と限定的な過去データに基づく推薦が主流であった。Agent 5は、教員の経験則をデータによる裏付けで補強することを目的とする。

Agent 5の分析データは、過去の進学実績データベースの照合結果と、学生個々の適性傾向分析の二つの軸で構成される。前者は、過去の合格者の成績プロフィール（偏差値、教科別得点、内申点等）と志望先の合格基準との照合に基づく合格可能性の推定であり、後者は、学生の学力特性、興味関心、行動特性等の多面的データに基づく適性評価である。Gate Levelは L=0.3 に設定されており、AIの推薦結果は教員が確認した上で学生に提示される。プロトタイプ段階での想定月間利用回数は445回（シミュレーション値）、精度は目標値として90%を設定している。

9.4.2 実装の詳細: 学生ダッシュボードにおけるPlan A/B/C表示

Agent 5の出力は、学生ロールのダッシュボード（`student-dashboard.tsx`）において、進路戦略のPlan A/B/C表示として視覚化されている。プロトタイプでは、学生「田中太郎」（3年A組）の進路戦略として以下の三案が表示される。Plan Aとして「大阪大学 工学部（一般入試、B判定）」、Plan Bとして「神戸大学 工学部（一般入試、A判定）」、Plan Cとして「関西大学 理工学部（公募推薦、A判定）」が提示され、各プランは色分けされたバッジ（Plan A: ブルー、Plan B: グリーン、Plan C: アンバー）で視覚的に区別される。

このPlan A/B/C方式は、学生と教員の双方にとって、進路選択の全体像を俯瞰し、リスク分散を考慮した戦略的な意思決定を促進する効果が期待される。Agent 5は、各プランの合格可能性をA判定・B判定等の段階的評価で示すことにより、学生が自身の学力水準と志望先のギャップを客観的に把握することを支援する。

9.4.3 学生向け進路情報におけるAI推薦機能

Agent 5の機能は、`student-career-info.tsx` (進路先情報)コンポーネントにおいても顕在化している。本コンポーネントは、進路先の検索・比較機能に加えて、「AI進路推薦 (Agent 5: 進路推薦支援)」セクションを設け、過去進学実績DBと適性傾向分析に基づくデータドリブンな進路候補を提示する。

AI推薦校として、京都工芸繊維大学 工芸科学部 (適合度92%)、奈良先端科学技術大学院大学・学部連携 情報科学領域 (適合度87%)、立命館大学 情報理工学部 (適合度84%) の3校が表示される。各推薦校には、適合度スコア、推薦理由の自然言語説明、および教員の承認ステータス (「先生の承認済み」または「承認待ち」) が付記される。

教員の承認ステータスの表示は、Gate機構の具現化として重要な意味を有する。Agent 5が生成したAI推薦であっても、教員の確認・承認を経していない推薦校には「承認待ち」のバッジが表示され、学生がAIの推薦を鵜呑みにすることなく、教員との相談を経た上で意思決定を行うことが促される。この設計は、Human-in-the-loopの原則を学生向けインターフェースにおいても一貫して適用する姿勢を示すものである。

9.4.4 学生向け進路先詳細情報

`student-career-detail.tsx` (進路先詳細)コンポーネントでは、個別の進路先について、学校概要、学部情報、入試情報、費用、先輩の声の5つのタブで詳細情報を提供するとともに、Agent 5による「AI適合度スコア」を専用セクションで表示する。プロトタイプでは大阪大学工学部を例として、適合度78%のスコアが円形のプログレスインジケータで表示され、「強み」(数学の偏差値が合格者平均に近い、理系科目の学力バランスが良い、成績の上昇トレンドがある)と「課題」(理科[物理]の強化が必要、偏差値があと3.5ポイント必要、英語の長文読解力を上げると有利)が対比的に列挙される。

9.5 進路情報管理機能群

9.5.1 進路先マスターデータベース

Management Agentsの分析精度を支える基盤として、進路先マスターデータベースの管理機能が`admin-career-master.tsx` (進路先マスタ管理)コンポーネントとして実装されている。本コンポーネントは、342校の教育機関 (大学186校、専門学校156校) をマスターデータとして管理し、国立・公立・私立の設置区分別および大学・専門学校の種別ごとの検索・フィルタリング機能を提供する。

KPI指標として、登録校数 (342校)、今月新規追加 (8校)、大学 (186校)、専門学校 (156校) が表示される。マスターデータの各レコードには、学校ID、学校名、設置区分 (国立: 青、公立: ティール、私立: アンバーの色分けバッジ)、所在地、主要学部、志望者数、合格率、最終更新日が含まれる。プロトタイプには12校のモックデータが実装されており、大阪大学 (国立、合格率32%、志望者12名)、関西大学 (私立、合格率68%、志望者28名)、京都大学 (国立、合格率18%、志望者3名) 等の近畿圏の主要大学・専門学校が網羅されている。

新規追加、インポート (外部データからの一括取込)、エクスポート (データの書き出し) の各機能ボタンが実装されており、マスターデータの継続的なメンテナンスを支援する設計となっている。

9.5.2 進路先詳細分析

個別の進路先に対する詳細分析は、`admin-career-detail.tsx` (進路先詳細)コンポーネントで提供される。プロトタイプでは関西大学を例として、学校プロフィール (私立、所在地: 大阪府吹田市、創立: 1886年、学生数: 約28,000名、12学部) の基本情報に加え、過去5年間の合格実績推移グラフが実装されている。

折れ線グラフには、2022年から2026年にわたる志願者数、合格者数、合格率の三指標が描画される。具体的には、志願者数は8名 (2022年) から28名 (2026年) へ増加傾向にあり、合格率は58%~72%の範囲で推移している。2026年のデータについては、志願者28名に対し合格者0名 (年度途中の暫定値) として表示される。

さらに、今年度の志願者一覧テーブル (7名分) が実装されており、各志願者の氏名、クラス、志望学部、出願状況、試験日、結果 (合格・不合格・結果待ち) が一覧表示される。加えて、関連校 (併願先) として同志社大学、立命館大学、近畿大学、関西学院大学の4校が志願者数とともに表示され、受験戦略の全体像を把握するための参考情報が提供される。

9.5.3 教員向け進路先検索機能

教員が進路指導において進路先情報を活用するためのインターフェースとして、`teacher-career-search.tsx`（進路先検索）コンポーネントが実装されている。本コンポーネントは、登録進路先数（2,847校）、今年度志望先（45校）、AI推薦対応（128校）、合格実績校（312校、過去5年）のKPIを表示し、学校名・学部によるテキスト検索、設置区分（国立・公立・私立・専門）による種別フィルタ、地域（大阪府・京都府・兵庫県・滋賀県）によるエリアフィルタ、および偏差値の上限・下限による詳細フィルタを備えている。

検索結果テーブルには12校が表示され、各校のデータとしてAgent 5によるAI推薦マーク（星形アイコンと「AI推薦」バッジ）、学校名、学部、種別、地域、偏差値、合格率、過去実績（合格者数）、志望者数が列挙される。テーブルヘッダーには「Agent 5 推薦マーク付き」および「Gate L=0.7」のバッジが表示されており、AI推薦情報の性質と人間確認の要件が明示されている。

9.5.4 学生向け進路先情報

学生が自身の進路選択のために進路先情報にアクセスするインターフェースとして、`student-career-info.tsx`（進路先情報）コンポーネントが実装されている。学校名・学部による検索、地域フィルタ、種別フィルタに加え、複数校の比較機能（チェックボックスによる選択と比較ボタン）が提供されている。検索結果は各校の特色（「研究実績が豊富」「留学制度充実」「就職率98%」等）を含むカード形式で表示される。

9.6 統計分析とAIインサイト

9.6.1 Gate Level L=0.7 の設計意図

Management Agentsに属するAgent 4およびAgent 8にはGate Level L=0.7 が設定されている。この値は、本システムにおけるGateスケールの中で最も人間の関与度が高い水準に相当し、AIの出力が経営判断に直接的な影響を及ぼしうることを反映している。

Gate Level L=0.7の運用においては、AIは「分析と提案」を行うが、「判断と決定」は行わない。具体的には、AIが「2年生の戦略策定率が目標を下回っている」という事実を検出し、「2月の進路面談週間で重点的にフォローすること」という改善案を提案することはできるが、その改善案を実行に移すか否かの判断は管理者に委ねられる。この設計は、教育機関における意思決定が、データ分析だけでは捉えきれない教育的配慮、組織文化、地域特性等の文脈依存的な要素を含むことに対する設計上の配慮である。

9.6.2 確信度レベルの透明性確保

`admin-statistics.tsx`に実装されたAIインサイト機能では、各インサイトに確信度（Confidence Score）が付与されている。確信度の値は71%から92%の範囲で変動しており、この数値はAIが当該インサイトを生成するに至った根拠データの質と量、およびモデルの推論における確信の度合いを定量的に表現するものである。

確信度の表示は、AIの出力に対する管理者の判断を支援する重要な指標として機能する。確信度92%のインサイト（出席パターン解析による要注意学生の検出）は、比較的高い信頼性をもって受け取られうるのに対し、確信度71%のインサイト（カリキュラム最適化の提案）は、追加的な検証や議論を経て判断されるべきものとして解釈される。このように、確信度の明示は、AIの出力を一律に信頼するのでも一律に懐疑するのでもなく、出力ごとの信頼性を考慮した合理的な意思決定を促進する設計上の工夫である。

9.6.3 三段階分類の設計

AIインサイトの分類は、ポジティブ（positive）、警告（warning）、アラート（alert）の三段階で構成されている。ポジティブは、現状の施策が効果を発揮していることを示す肯定的なインサイトであり、緑色の背景とShieldCheckアイコンで表示される。警告は、改善の余地がある領域を指摘するインサイトであり、黄色の背景とAlertTriangleアイコンで表示される。アラートは、早急な対応を要する問題を検出したインサイトであり、赤色の背景とAlertTriangleアイコンで表示される。

この三段階分類は、管理者が限られた時間の中で優先的に対応すべき事項を迅速に判別するためのトリアーージ機構として機能する。アラートレベルのインサイトには最優先の注意が向けられ、ポジティブレベルのインサイトは現行施策の有効性確認として参照される。この設計により、大量の統計データと分析結果を、管理者が効率的に消化し、実行可能な意思決定に結びつけることが可能となる。

9.7 本章のまとめ

本章では、本システムの4象限AIエージェントモデルにおける第四象限「導く(Management Agents)」の設計とプロトタイプ開発について詳述した。Agent 4(成績評価妥当性チェック、想定月間312回、期待精度93%)は教員間の評価バイアスをデータ分析上の観点で検出し公平性監査を自動化する。Agent 8(学校経営ダッシュボード、想定月間567回、期待精度87%)は多面的な経営指標を統合分析しAIインサイトを生成する。Agent 5(進路推薦支援、想定月間445回、期待精度90%)は過去実績と適性分析に基づくデータドリブンな進路推薦を実現する。なお、これらの利用回数と精度はすべてシミュレーション値であり、実運用データに基づく検証は今後のパイロット運用において実施予定である。

フロントエンド実装においては、管理者統計ダッシュボード(`admin-statistics.tsx`)、進路先マスタ管理(`admin-career-master.tsx`)、進路先詳細分析(`admin-career-detail.tsx`)、教員向け進路先検索(`teacher-career-search.tsx`)、学生向け進路情報(`student-career-info.tsx`)、学生向け進路先詳細(`student-career-detail.tsx`)、および学生ダッシュボード(`student-dashboard.tsx`)を通じて、Management Agentsの機能が各ロールのユーザに提供されている。

Management Agentsの設計において特に注目すべきは、Gate Level $L=0.7$ による人間判断の必須化と、確信度レベルの透明性確保という二つの原則が、UIプロトタイプのインターフェースレベルで一貫して表現されている点である。これは、AIが「経験則だけでなくデータに基づいた」分析を提供しつつも、最終的な教育的・経営的意思決定は人間が行うという本システムの基本設計思想を、Management Agentsの領域においても忠実に体现することを目指すものである。

9.8 リソース配分最適化機能

Agent 8(学校経営ダッシュボード)の拡張機能として、リソース配分最適化機能を設計している。教育機関における主要リソース(教員配置、施設稼働、予算配分)の最適化は、経営効率と教育品質の両面に直接的な影響を及ぼす課題である(Burke & Petrovic, 2002)。

9.8.1 教員配置の最適化

教員配置最適化は3つの制約条件を同時に考慮する。第一に、クラスサイズと教員の専門性の適合。第二に、教員の経験年数とメンタリング構造の最適化(新任・ベテランのペアリング)。第三に、教員の業務負荷の均等化(授業コマ数、担当学生数、進路指導負荷の均衡)。Gate Level $L=0.7$ により、最終的な配置決定は教務主任・管理者が行う。

9.8.2 施設稼働率分析と予算配分シミュレーション

教室・施設の稼働率データを分析し、未稼働時間帯の活用や混雑時間帯の分散化を提案する。予算配分シミュレーションとして、教材費、設備投資、人件費の3大コスト項目について、投入リソースと教育成果の相関分析に基づく最適バランスを提案する。

9.9 戦略シミュレーション機能

学校経営の中長期意思決定を支援するWhat-if分析エンジンを設計している。

9.9.1 シナリオ分析

代表的シナリオ例: **シナリオ1**「留学生比率15%→25%増加時」の多言語対応教員数・Agent Team 1処理負荷・在留資格管理業務の予測。 **シナリオ2**「新学科設置の5年間収支予測」。 **シナリオ3**「退学率8%→5%改善時」の授業料収入安定化効果。

9.9.2 不確実性の定量化

モンテカルロシミュレーション(10,000回試行)により信頼区間を算出し、「最良(P90)」「期待値(P50)」「最悪(P10)」の3パターンでレポートを提示する。Gate Level $L=0.7$ に加え、理事会承認ワークフローを追加設定する。

第10章 Agent Team設計 — 複合エージェント連携アーキテクチャ

10.1 AgentからAgent Teamへの発展

10.1.1 単機能エージェントの限界と複合課題への要請

前章までに述べた12のAIエージェントは、それぞれが「守る」「育てる」「回す」「導く」の各象限において特定の単一タスクを処理する機能として設計されている。例えば、Agent 1「学習リスク早期検知」は成績低下や出席率低下のパターンから早期にリスクを検知し、Agent 5「進路推薦支援」は学生の適性と成績から最適な進路先を推薦する。これらの個別エージェントは各々の領域において高い実用性を示しているが、教育現場における実際の業務課題は、単一のエージェントで完結するものばかりではない。

教育実務においては、複数の業務領域が有機的に絡み合う複合的な課題が日常的に発生する。進路相談業務を例にとれば、生徒の成績データの収集・分析（Agent 5の領域）、面談記録の要約（Agent 7の領域）、経営指標としての進路実績の集計（Agent 8の領域）が同時並行的に必要とされ、それぞれの処理結果が相互に依存する。このような複合課題に対して、個別のエージェントを手動で逐次的に呼び出す運用は、業務効率の観点から非合理的であるのみならず、エージェント間のデータ整合性の担保が困難となり、出力品質の低下を招く恐れがある。

10.1.2 Agent Team概念の定義

こうした課題に対する解決策として、本研究では「Agent Team」の概念を導入する。Agent Teamとは、複数のAIエージェント（本システムにおいてはこれを「Planet」と呼称する）が相互に連携し、単一のエージェントでは解決し得ない複合的なワークフロー全体を統合的に処理するシステムである。各Planetは独立した処理単位として動作しつつも、Agent Teamの制御下において他のPlanetとの間でデータの受け渡し、処理順序の調整、品質の検証を自律的に行う。

この設計思想は、マルチエージェントシステム（MAS: Multi-Agent System）の研究領域において蓄積されてきた理論的知見に基づくものである。MASにおいては、個々のエージェントが協調的に振る舞うことで、単一のエージェントでは達成し得ない複雑な目標を実現できることが広く知られている。本研究のAgent Team設計は、この原理を教育ドメインに特化して具現化したものであり、教育業務の特質であるヒューマンセンシティブなデータ処理とHuman-in-the-loopの要件を組み込んだ点に独自性を有する。

10.1.3 課題深度に応じたソリューション展開の階層構造

本システムにおけるAI支援は、課題の深度と複雑性に応じた三層の階層構造として整理される。

第一層は「単機能Agent」である。これは特定の単一タスクに対して即座に回答する最小単位の処理機能であり、例えば出席データの異常検知や面談記録の要約生成が該当する。応答時間は数秒以内であり、ユーザーの明示的な要求に対してリアクティブに動作する。

第二層は「複合Agent連鎖」である。複数のAgentが固定的なパイプラインで接続され、前段のAgentの出力が後段のAgentの入力となる逐次処理を行う。後述するAgent Team 1（留学生対応・教材自動翻訳システム）がこの類型に該当する。処理時間は数十秒から数分であり、定型的な複合業務の自動化に適する。

第三層は「オーケストレーション型Agent Team」である。中央の制御機構が各Planetの状態を監視し、動的に処理順序を決定しながら非同期的にPlanet群を協調動作させる。後述するAgent Team 2（進路相談負担軽減）がこの類型に該当する。処理時間は数分から数時間にわたる場合があり、非定型的かつ高度な判断を要する複合業務に対応する。

この階層構造により、本システムは教育現場において発生する多様な業務課題に対して、その複雑性に応じた適切な粒度のAI支援を提供することが可能となる。

10.2 Agent Team 1: 留学生対応・教材自動翻訳システム

10.2.1 設計の背景と目的

第1章において述べたとおり、専門学校における留学生比率の増加は顕著であり、一部の学校では在籍者の過半数を留学生が占める状況にある。留学生に対する教育支援において最も基本的かつ労力を要する業務の一つが、教材の多言語化である。授業で使用するスライド、配布資料、板書内容、Web上の参考資料等を留学生の母語または理解可能な言語に翻訳する作業は、従来、教員または事務職員が手作業で行っており、膨大な工数を消費していた。加えて、機械翻訳ツールを個別に用いた場合、専門用語の不統一や文脈の取り違えが生じやすく、教育品質の低下を招く恐れがある。

Agent Team 1「留学生対応・教材自動翻訳システム」は、この課題に対して、用語の統一性、文脈の正確性、学習者の習熟度への適応を同時に担保する複合的なパイプラインとして設計された。

10.2.2 パイプライン設計

Agent Team 1は、入力から出力に至るまでの処理を四段階のパイプラインで構成する。

入力(Input): 教材PDF、板書画像(OCR処理を含む)、HTML形式のWeb教材の三種類の入力形式に対応する。入力データは前処理モジュールにおいてテキスト抽出とフォーマット正規化が行われ、後続の処理に適した統一的な中間表現に変換される。

Step 1: 用語辞書照合(Terminology Alignment): 抽出されたテキストから専門用語を特定し、あらかじめ教科主任が監修・登録した多言語用語辞書との照合を行う。この処理により、同一の技術用語や教育用語が文書全体を通じて一貫した訳語で翻訳されることが保証される。用語辞書は、各教科・各分野ごとに独立して管理され、新規用語の追加や既存用語の修正は教科主任の権限で随時実施可能である。本ステップは、Agent 2「個別最適化学習プラン生成」が保持する学習者プロフィール情報との連携により、学習者が既習の用語と未習の用語を区別した注釈の付加も行う。

Step 2: 文脈翻訳(Context Translation): 用語照合が完了したテキストに対して、文脈を考慮した翻訳処理を実行する。本ステップでは、単なる逐語訳ではなく、前後の文脈、教科の特性、対象言語の言語文化的特性を考慮した意識を含む翻訳が行われる。Agent 5「進路推薦支援」が蓄積する進路関連の専門知識ベースとの連携により、進路指導に関連する教材については、対象国の教育制度や職業資格制度に関する補足情報を自動的に付加する機能を有する。

Step 3: 難易度適応(Level Adaptive): 翻訳されたテキストの難易度を、学習者の日本語能力レベル(JLPTのN1からN5に準拠した段階区分)および学習進度に応じて調整する。具体的には、難度の高い表現の平易化、ルビ(振り仮名)の付加、補足説明の挿入等を自動的に行う。この処理は、Agent 9「保護者向けレポート生成」のテキスト平易化エンジンを転用したものであり、エージェント間の技術資産の再利用の好例である。

出力(Output): 最終的な成果物として、多言語教材(翻訳済みの教材本体)と対訳表(原文と訳文の対照表)の二種類を生成する。出力形式はPDF、HTML、およびLMS(学習管理システム)連携用のSCORM形式に対応する。

10.2.3 Gate Cardの設計

Agent Team 1のGate設定は $L=0.3$ (教育リスク中低)として設定されている。これは、翻訳処理自体は高い自動化が可能であるものの、教育教材としての正確性と適切性の最終的な担保には人間の判断が不可欠であるとの設計方針に基づく。

具体的な制御として、最終公開前に「教科主任承認Gate」を設置している。このGateにおいては、翻訳結果のサンプリング検査と、用語辞書との整合性の最終確認が、教科主任によって行われる。承認が得られた教材のみが学習者に公開される。この設計により、機械翻訳に内在する誤訳リスクおよび用語の不統一リスクが、教育現場に到達する前の段階で排除される。

なお、教科主任の承認負荷を軽減するため、システムは翻訳結果の「信頼度スコア」を自動算出し、信頼度が一定閾値を下回る箇所を重点検査対象としてハイライト表示する機能を備えている。これにより、教科主任は全文を通読することなく、リスクの高い箇所に集中して検査を行うことが可能となる。

10.2.4 関連エージェントとの連携

Agent Team 1は、Agent 2(個別最適化学習プラン生成)、Agent 5(進路推薦支援)、Agent 9(保護者向けレポート生成)の三つのエージェントとの連携関係を有する。Agent 2からは学習者プロフィール情報を、Agent 5からは進路関連の専門知識ベースを、Agent 9からはテキスト平易化エンジンの処理ロジックを、それぞれ受け取る。これらの連携により、単なる機械翻訳の域を超えた、学習者一人ひとりに最適化された教材翻訳の実現を目指している。

10.2.5 運用想定と専門学校における意義

プロトタイプ段階におけるAgent Team 1の設計上の想定使用回数は約230回であり、主として英語、中国語(簡体字・繁体字)、ベトナム語、ネパール語への翻訳処理を対象としている。専門学校における留学生支援は、単に日本語教育の問題にとどまらず、専門科目の理解度、資格試験への対応、就職活動における情報格差の解消等、多面的な課題を内包している。教材の多言語化は、これらの課題に対する基盤的な支援策として位置づけられるものであり、Agent Team 1の運用は、留学生の学習アクセシビリティの向上と教員の翻訳業務負担の軽減を同時に実現することを目指すものとして、実践的な意義を有する。

10.3 Agent Team 2: 進路相談負担軽減

10.3.1 進路相談業務の構造的分解

進路相談は、専門学校教員の業務の中でも最も高度な判断力と対人コミュニケーション能力が要求される業務であり、同時に最も多くの時間と精神的労力を消費する業務の一つである。教員は一人の生徒の進路相談に臨むにあたり、当該生徒の成績推移、出席状況、面談履歴、希望調査結果、保護者の意向、性格特性、健康状態等、多面的な情報を事前に収集・整理し、それらを総合的に勘案した上で面談に臨むことが求められる。

Agent Team 2「進路相談負担軽減」は、この進路相談業務を「情報収集」「整理」「比較」「提案」「調整」の五つの機能単位に分解し、各機能をPlanetとして実装することで、教員の進路相談業務を包括的に支援するオーケストレーション型のAgent Teamとして設計された。本Agent Teamの設計思想は、教員が進路相談において最も価値を発揮する「生徒との直接的な対話」に集中できる環境を、AI支援によって創出することにある。

10.3.2 Planet 1: Career Context Aggregator(状況把握)

Planet 1は、生徒に関する多面的な情報を統合的に収集・整理する機能を担う。入力データとして、成績データ(定期試験、模擬試験、資格試験の結果)、面談履歴(過去の面談記録と合意事項)、希望調査結果(生徒自身が回答した進路希望アンケート)、保護者コメント(保護者面談や連絡帳を通じて寄せられた意見・要望)を統合的に取り込む。

出力として、Planet 1は二つの成果物を生成する。第一は「1枚サマリー」であり、当該生徒の現況を一目で把握できるA4一枚の要約シートである。このサマリーには、学力水準、出席状況、進路希望の推移、特記事項が構造化された形式で記載される。第二は「強み弱み抽出」であり、成績データと活動記録の分析に基づき、当該生徒の学力面・性格面・活動面における強みと弱みを自動的に抽出したレポートである。

Planet 1の導入効果として、教員の面談準備時間の大幅な削減が見込まれている。従来、教員は面談の前日に数十分から一時間をかけて各種帳票を手作業で確認し、手元のメモに情報を集約していたが、Planet 1はこの作業を自動化することで、教員は生成されたサマリーの確認と自身の所見の追記にのみ時間を割けばよい環境を実現する。

10.3.3 Planet 2: Career Option Intelligence(候補探索)

Planet 2は、生徒の属性と希望に適合する進路候補を探索・評価する機能を担う。処理プロセスとして、Planet 1が出力した生徒サマリーを入力として受け取り、成績偏差帯に基づく合格可能性の推定、外部大学・専門学校データベースとの照合、利用可能な奨学金情報の検索を並列的に実行する。これらの処理結果を統合し、推薦度順にランク付けされた進路候補リストを生成する。

Planet 2のGate設定は $L=0.7$ (中リスク)として設定されており、本Agent Teamの中で最も高い人間介入レベルが要求される。これは、Planet 2の出力が合格確率の推定を含むためである。合格確率の推定は、生徒の進路選択に直接的な影響を与える情報であり、AIによる推定値がそのまま生徒に提示された場合、過度な安心感や不要な落胆を与える恐れがある。したがって、Planet 2の出力は必ずHuman(教員)の承認を経てから生徒に提示される設計となっている。教員は、AIが提示した候補リストと合格確率推定を自身の経験的知見と照合し、修正・補足を加えた上で面談において活用する。

10.3.4 Planet 3: Counseling Conversation Planner(面談設計)

Planet 3は、教員が面談に臨む際の対話計画を支援する機能を担う。過去の面談ログの分析と生徒の性格傾向(面談記録から抽出された対話パターンに基づく推定)をもとに、「質問テンプレート」と「保護者説明ポイント」の二つの成果物を生成する。

質問テンプレートは、当該生徒の状況に最適化された面談用の質問候補のリストである。例えば、前回の面談で合意した目標の達成度を確認する質問、新たに生じた課題や関心事を引き出す質問、進路希望の具体性と現実性を確認する質問等が、面談の流れとして構造化された形で提示される。保護者説明ポイントは、三者面談等において保護者に対して説明すべき重要事項を整理したものであり、客観的なデータに基づく学業状況の説明と、今後の方針に関する提案事項が含まれる。

Planet 3の設計意図は、教員が面談の内容設計に費やす時間を削減することで、面談の場において生徒との対話そのものに集中できる環境を創出することにある。

10.3.5 Planet 4: Smart Scheduling Agent(日程調整)

Planet 4は、進路面談の日程調整を自動化する機能を担う。教員、生徒、および保護者の三者のカレンダー情報と優先度スコア(面談の緊急性、前回面談からの経過日数、リスクレベル等に基づく算出値)を解析し、三者にとって最適な面談日程の候補を自動的に算出する。

Planet 4のGate設定は $L=0.2$ (高自動化可能)として設定されている。日程調整は、本質的にカレンダーの空き状況と優先度のマッチングという定量的な処理であり、教育的判断を伴わないため、高い自動化レベルが許容される。具体的には、最適候補3案の提示と自動仮予約までをシステムが完結させ、教員は最終確認のみを行えばよい設計となっている。

10.3.6 Planet間の連携フローとオーケストレーション

Agent Team 2における四つのPlanetは、以下のフローで連携動作する。まず、Planet 1が生徒情報の収集・整理を行い、「1枚サマリー」と「強み弱み抽出」を出力する。次に、Planet 1の出力を入力として、Planet 2(候補探索)とPlanet 3(面談設計)が並列的に処理を開始する。Planet 2の出力である進路候補リストは、教員の承認Gate($L=0.7$)を経た後、Planet 3にもフィードバックされ、面談における進路候補の説明方針に反映される。最後に、Planet 4がPlanet 1からPlanet 3までの処理結果と教員の承認状況を踏まえ、面談日程の最適化と仮予約を実行する。

このオーケストレーション型の制御構造により、各Planetは他のPlanetの処理状況に応じて動的に処理を調整することが可能となり、固定的なパイプラインでは対応し得ない柔軟なワークフロー管理を実現することを目指す。

10.3.7 関連エージェントとの連携および運用想定

Agent Team 2は、Agent 5(進路推薦支援)、Agent 7(面談サマリー自動生成)、Agent 8(学校経営ダッシュボード)の三つのエージェントとの連携関係を有する。Agent 5は候補探索における進路知識ベースの提供、Agent 7は面談記録の要約処理、Agent 8は進路実績の統計データの提供をそれぞれ担当する。

プロトタイプ段階におけるAgent Team 2の設計上の想定使用回数は約500回であり、Agent Team 1の約230回を上回る。これは、進路相談業務が教員の日常業務の中で高い頻度で発生する業務であること、および本Agent Teamが教員の面談準備の負荷を直接的に軽減する機能を提供していることを反映している。

10.4 Agent Team設計パターンの汎用性

10.4.1 パイプライン型とオーケストレーション型の比較

Agent Team 1とAgent Team 2は、それぞれ異なる設計パターンを採用しており、これらの比較は、今後のAgent Team拡張における設計指針を提供する。

パイプライン型(Agent Team 1)は、処理が一方向に進行する逐次的な構造であり、各Stepの入出力が明確に定義されている。この設計パターンは、処理フローが定型的であり、各Stepの処理結果が一意に確定する業務に適する。利点として、処理フローの可視性が高く、障害発生時の原因特定が容易であること、Gate機構の挿入箇所が明確であること、処理

時間の予測が容易であることが挙げられる。一方、処理フローの柔軟性に欠け、途中のStepの結果に応じた分岐処理や反復処理には対応し難いという制約がある。

オーケストレーション型 (Agent Team 2) は、中央の制御機構が各Planetの状態を監視し、動的に処理を調整する構造である。この設計パターンは、処理フローが非定型的であり、中間結果に応じた判断分岐や人間の介入を柔軟に組み込む必要がある業務に適する。利点として、高い柔軟性、Planet間の並列処理による処理時間の短縮、人間の介入タイミングの動的調整が可能であることが挙げられる。一方、制御ロジックの複雑性が増すこと、処理フローの可視性がパイプライン型と比較して低下すること、デバッグの困難性が増すことが課題となる。

10.4.2 Planet間のデータフローと依存関係の管理

Agent Team内のPlanet間におけるデータフローは、明示的なインターフェース定義に基づいて管理される。各Planetは、入力として受け付けるデータの型と必須項目、出力として生成するデータの型と保証項目を、スキーマとして厳密に定義する。これにより、Planet間の結合度を低く保ちつつ、データの整合性を技術的に担保することが可能となる。

依存関係の管理においては、有向非循環グラフ (DAG: Directed Acyclic Graph) による表現を採用している。各Planetをノード、データフローをエッジとしたDAGを構築することで、処理順序の自動決定、並列実行可能なPlanetの特定、循環依存の検出が可能となる。Agent Team 2においては、Planet 1がPlanet 2およびPlanet 3に対する上流ノードとなり、Planet 2とPlanet 3は並列実行可能、Planet 4はPlanet 1からPlanet 3の全てに依存する下流ノードという構造が、DAGとして明示的に表現される。

10.4.3 Gate Levelの継承と個別設定

Agent Team全体にはデフォルトのGate Levelが設定されるが、各Planetは業務特性に応じて個別のGate Levelを上書き設定することが可能である。この設計により、Agent Team内の一部の処理のみに高い人間介入を要求し、他の処理は高度に自動化するという、きめ細やかなリスク制御の実現を目指す。

Agent Team 2を例にとれば、Agent Team全体のデフォルトGate Levelは $L=0.3$ であるが、Planet 2 (候補探索) は $L=0.7$ に引き上げられ、逆にPlanet 4 (日程調整) は $L=0.2$ に引き下げられている。Gate Levelの継承規則として、Planetが個別設定を持たない場合はAgent Team全体のデフォルト値が適用され、個別設定がある場合はそちらが優先される。ただし、Agent Teamの管理者 (admin権限を持つ利用者) は、運用ポリシーとしてGate Levelの下限値を設定することが可能であり、特定のAgent Team内では一定以上の人間介入を常に確保するという組織的なガバナンスを技術的に実装することができる。

10.4.4 新規Agent Team追加の拡張性

本システムのAgent Team設計は、新規Agent Teamの追加が容易に行える拡張性を備えている。新規Agent Teamの追加に際しては、(1) Planetとして使用するAgentの選定、(2) Planet間のデータフローの定義 (DAGの構築)、(3) 各PlanetのGate Level設定、(4) オーケストレーションルールの記述、の四つのステップを経ることで、既存のエージェント資産を再利用しながら新たな複合機能を構築することが可能である。

今後の拡張候補として、「保護者コミュニケーション最適化Agent Team」 (Agent 7, 9, および新規開発の多言語通知Agentの連携)、「入試戦略シミュレーションAgent Team」 (Agent 4, 8, および外部データ連携Agentの連携) 等が検討されている。いずれも、既存の12エージェントの組み合わせと最小限の新規開発により実現可能な設計となっており、本システムのAgent-Agent Team階層構造の拡張性を裏付けるものである。

10.5 admin-ai-tools.tsxにおけるAgent Team管理UI

10.5.1 管理画面におけるAgent Team可視化の設計

Agent Team概念の導入に伴い、本システムの管理者向けダッシュボード (admin-ai-tools.tsx) においては、12の個別AIエージェントに加えて、Agent Teamの運用状況を監視・制御するためのUIプロトタイプを実装した。リアルタイムの監視・制御機能はバックエンド実装段階で実現予定である。

管理画面の上部に配置されたKPI(重要業績評価指標)カードにおいて、「Agent Team稼働数」として「2/2」(登録済み2件のうち2件が稼働中)が表示される。この指標により、管理者はAgent Team全体の稼働状況を一目で把握することが可能である。「全稼働中」の注釈が付与されることで、停止中のAgent Teamの有無も即座に確認できる設計となっている。

10.5.2 Agent Team個別カードの情報構成

各Agent Teamは、管理画面において個別のカードとして表示される。カードには以下の情報が構造化された形式で配置されている。

第一に、Agent Team識別子(U1、U2等)がバッジとして表示され、Agent Teamの一意な識別が可能である。第二に、Agent Team名称と説明文が表示され、当該Agent Teamの機能概要が確認できる。第三に、関連エージェント番号がバッジ形式で列挙される。例えばAgent Team 1の場合は「Agent 2」「Agent 5」「Agent 9」が、Agent Team 2の場合は「Agent 5」「Agent 7」「Agent 8」がそれぞれ表示される。これにより、管理者はAgent Teamとエージェント間の連携関係を視覚的に把握することができる。第四に、累計使用回数が数値として表示され、各Agent Teamの活用度合いの定量的な把握が可能である。

10.5.3 ステータス管理とトグル制御

各Agent TeamカードにはSwitch(トグル)コンポーネントが配置されており、管理者はAgent Teamの稼働・停止を即座に切り替えることが可能である。稼働中のAgent Teamは緑色のインジケータと「稼働中」のラベルで表示され、停止中のAgent Teamは灰色のインジケータと「停止中」のラベルで表示される。

トグル制御の実装においては、ReactのuseStateフックを用いた状態管理が行われている。管理者がトグルを操作すると、当該Agent TeamのstatusプロパティがBoolean値として即座に更新され、UIに反映される。なお、現行のプロトタイプにおいてはフロントエンドのみの状態管理であるが、バックエンド実装段階においては、Agent Teamの停止操作に対して確認ダイアログの表示および停止理由の記録が追加される設計となっている。

10.5.4 使用回数トラッキングとエージェント利用統計との統合

Agent Team管理UIは、個別エージェントの利用統計と統合的に設計されている。管理画面下部に配置された「エージェント利用回数」棒グラフは、12の個別エージェントの月次利用回数を可視化するものであるが、Agent Team経由での利用もこの統計に含まれる。すなわち、Agent Team 2の実行に伴いAgent 5が呼び出された場合、Agent 5の利用回数としてカウントされると同時に、Agent Team 2の利用回数としてもカウントされる。この二重カウント方式により、管理者はエージェント単体の活用度とAgent Team全体としての活用度の双方を同一の管理画面上で把握できることを目指している。

第11章 個別生徒AI診断 — 複合エージェント総合診断の設計と実装

11.1 個別生徒AI診断の概念と設計思想

11.1.1 複合的課題への統合的応答の必要性

前章までに述べた本システムの12エージェントおよび2つのAgent Teamは、それぞれが特定の業務領域を担う機能単位として設計されている。しかしながら、教育現場において教員が最も切実に必要とする支援は、個々のエージェントの出力を個別に参照することではなく、一人の生徒に関する多面的な情報を統合的に把握し、包括的な対応方針を迅速に策定できる環境の提供である。

担任教員が進路指導において直面する典型的な場面を考える。成績が継続的に低下し、出席率も急落している生徒に対して、教員は以下の問いに同時に答えなければならない。「この生徒のリスクはどの程度深刻か」「成績低下の根本原因は何か」「出席パターンに構造的な問題はあるか」「現状から回復するための学習プランはどうあるべきか」「現実的に到達可能な進路先はどこか」「次の面談で何を話すべきか」。これらの問いはそれぞれAgent 1、Agent 2、Agent 3、Agent 5、Agent 7の守備範囲に対応するが、教員がこれらのエージェントを個別に起動し、出力を手動で突合することは、業務負荷の軽減という本来の設計目的に反する。

個別生徒AI診断(T-18)は、この課題に対する包括的な解決策として設計された。本機能は、本システムのエンジンが6つのエージェントを自動的に連鎖実行し、一人の生徒に関する学習状況・リスク・出席パターン・学習プラン・進路適性・面談準備情報を統合的に診断するオーケストレーション型ワークフローとして設計されている。UIプロトタイプにおいては、モックデータに基づく診断レポートが表示される。バックエンド実装段階で実際のエージェント連鎖実行が接続される予定である。

11.1.2 Agent Team概念の発展としての位置づけ

個別生徒AI診断は、第10章で述べたAgent Team概念の発展形として位置づけられる。Agent Team 1(留学生対応・教材自動翻訳)はパイプライン型の固定的な処理フローであり、Agent Team 2(進路相談負担軽減)は4つのPlanetによるオーケストレーション型の協調動作であった。個別生徒AI診断は、これらのAgent Team設計パターンをさらに発展させ、以下の3つの新規性を有する。

第一に、**6エージェント統合**である。Agent Team 2が4つのPlanetで構成されていたのに対し、個別生徒AI診断はContext Aggregator(データ収集)、Agent 1(学習リスク早期検知)、Agent 3(出席・遅刻パターン解析)、Agent 2(個別最適化学習プラン生成)、Agent 5(進路推薦支援)、Agent 7(面談サマリー自動生成)の6つのエージェントを統合する。これは、本システムの12エージェントの半数を一つのワークフロー内で連携させる、最も大規模なエージェント統合の事例である。

第二に、**象限横断的統合**である。6つのエージェントは4象限のうち3つの象限にまたがる。Agent 1およびAgent 3は「守る(Guardian)」象限、Agent 2は「育てる(Tutor)」象限、Agent 5およびAgent 7は「導く(Management)」象限に所属する。個別生徒AI診断は、これらの象限の壁を超えて、一人の生徒に関する情報を立体的に統合する中核機能の一つである。

第三に、**異種Gate Levelの共存**である。6つのエージェントのGate Levelは、L=0.2(Context Aggregator)、L=0.3(Agent 3、Agent 2)、L=0.7(Agent 1、Agent 5、Agent 7)と3段階にわたる。一つのワークフロー内でこれほど多様なGate Levelが共存する設計は、本システムにおける代表的な設計例であり、Gate機構の柔軟性と精緻さを示している。

11.1.3 「一画面で全体像を把握する」という設計原則

個別生徒AI診断のUI設計における最重要原則は、「一人の生徒に関する全情報を、一つの画面から到達可能にする」ことである。教員が複数の画面を行き来して情報を手動で統合する負荷を排除し、診断実行後に表示される7つのセクション(総合診断・リスク検知・出席パターン・学習プラン・進路推薦・面談準備・アクションプラン)のナビゲーションにより、必要な粒度の情報に即座にアクセスできる設計とした。

この設計思想は、医療分野における「電子カルテ」の概念を教育分野に適用したものとも言える。医師が一人の患者の診断にあたって、検査結果・バイタルサイン・既往歴・投薬記録・画像診断結果を一元的に参照できる電子カルテシステムと同様に、個別生徒AI診断は教員が一人の生徒の「教育カルテ」を包括的に参照できる環境を提供する。

11.2 6エージェント統合パイプラインの設計

11.2.1 パイプライン全体構成

個別生徒AI診断のパイプラインは、入力フェーズ、収集フェーズ、分析フェーズ、統合フェーズの4段階で構成される。

表11-1 個別生徒AI診断パイプライン構成

フェーズ	実行エージェント	Gate Level	主要処理	所属象限
収集	Context Aggregator	L=0.2(自動化可)	学生データ収集・正規化	—
分析(1)	Agent 1: 学習リスク早期検知	L=0.7(要承認)	成績トレンド分析、危険スコア算出	守る
分析(2)	Agent 3: 出席・遅刻パターン解析	L=0.3(確認推奨)	曜日別傾向分析、科目相関分析	守る
分析(3)	Agent 2: 個別最適化学習プラン生成	L=0.3(確認推奨)	弱点単元抽出、学習プラン生成	育てる
分析(4)	Agent 5: 進路推薦支援	L=0.7(要承認)	進学実績DB照合、合格確率推定	導く
統合	Agent 7: 面談サマリー自動生成	L=0.7(要承認)	全Agent出力の統合、面談準備資料生成	導く

このパイプライン設計において注目すべきは、エージェントの実行順序が情報の依存関係に基づいて最適化されている点である。Context Aggregatorが最初に実行されるのは、後続のすべてのエージェントが生徒の基本データを入力として必要とするためである。Agent 1がAgent 3より先に実行されるのは、リスクスコアの算出結果がAgent 3の出席パターン分析における閾値の動的調整に使用されるためである。Agent 2がAgent 1・Agent 3の後に実行されるのは、リスク分析と出席パターン分析の結果を踏まえて学習プランを最適化する必要があるためである。Agent 5はAgent 2の出力(弱点単元と改善予測)を進路マッチングの入力として使用する。最後にAgent 7がすべてのエージェント出力を統合し、面談準備資料として構造化する。

11.2.2 Context Aggregator: 学生データ収集

Context Aggregatorは、個別生徒AI診断のパイプラインにおける最初のフェーズを担う。その役割は、対象生徒に関する多面的なデータを各データソースから収集し、後続エージェントが処理可能な統一的なデータ構造に正規化することである。

収集対象データは以下のとおりである。

35. **学籍基本情報**: 氏名、学籍番号、所属クラス、TG(進路指導グループ)、部活動
36. **成績データ**: 直近6回分の定期考査・実力テストの5教科個別成績、合計点、学年順位
37. **出席データ**: 出席率、遅刻回数、欠席回数、曜日別・時間別の出席パターン
38. **面談記録**: 過去の面談日時、面談内容の要約、合意事項、フォローアップ状況
39. **進路希望データ**: Plan A/B/C(第一～第三志望)、受験方式、希望調査結果
40. **保護者情報**: 保護者面談記録、連絡履歴、最終連絡日

Gate LevelはL=0.2に設定されている。データ収集は事実に基づく客観的な処理であり、教育的判断を含まないため、高い自動化レベルが許容される。ただし、収集されるデータには要配慮個人情報(成績データ、出席データ、メンタルヘルスに関連し得る情報)が含まれるため、データアクセス権限の検証はシステムレベルで厳格に実施される。教員は自身の担当生徒に関するデータのみアクセス可能であり、他クラスの生徒のデータへのアクセスは原則として遮断される。

11.2.3 Agent 1: 学習リスク早期検知 (Gate L=0.7)

個別生徒AI診断におけるAgent 1の役割は、第6章で述べた標準的な学習リスク検知ロジックを拡張し、より詳細なリスク要因分析を出力することである。標準動作では3段階のリスクレベル判定 (Green/Yellow/Red) と推奨アクションの提示にとどまるが、個別生徒AI診断モードにおいては、以下の追加的な出力が生成される。

第一に、**リスクスコアの数値化** (0~100のスケール) である。標準動作のカテゴリカルな3段階判定に加え、連続値としてのリスクスコアを算出する。モックデータ (模擬例) において、生徒「佐藤太郎」のリスクスコアとして82/100がモックデータとして設定されている、Redレベルの中でも特に深刻な状態にあることが定量的に示される。

第二に、**リスク要因の重み付き分析** である。リスクスコアの内訳を、「成績下降トレンド」(重み35%、スコア90)、「出席率低下」(重み30%、スコア85)、「遅刻パターン異常」(重み20%、スコア75)、「提出物未提出」(重み15%、スコア70)の4つの要因に分解し、各要因のスコアと具体的な根拠データを提示する。この分解により、教員は「この生徒のリスクは主に成績低下と出席率低下に起因しており、遅刻と提出物は副次的な要因である」という構造的な理解を即座に得ることができる。

第三に、**リスクスコアの時系列推移** である。過去6ヶ月間のリスクスコアの推移を折れ線グラフとして可視化する。佐藤太郎の模擬例では、9月の45から2月の82へと継続的に上昇しており、リスクの悪化トレンドが視覚的に明確である。この時系列データにより、教員は「いつ頃からリスクが顕在化し始めたのか」「悪化のペースはどの程度か」を把握し、介入のタイミングと緊急度を適切に判断できる。

Gate Levelは L=0.7 に設定されている。これは、リスクスコアの数値化と要因分析が教員の指導判断に直接影響を及ぼす情報であるためである。AIが算出したリスクスコアが教員の実感と大きく乖離する場合には、教員の専門的知見が優先される設計となっている。

11.2.4 Agent 3: 出席・遅刻パターン解析 (Gate L=0.3)

個別生徒AI診断におけるAgent 3は、出席データの統計分析を通じて、生活リズムの乱れや特定科目への忌避傾向を検出する。

出力は以下の3つの要素で構成される。

第一に、**サマリー統計** である。出席率・遅刻回数・欠席回数の基本統計量が表示される。佐藤太郎の模擬例では、出席率68.2%、遅刻回数12回、欠席回数18回と設定されている。

第二に、**曜日別出席パターン** である。月曜日から金曜日までの各曜日における出席率・遅刻率・欠席率を積み上げ棒グラフで可視化する。佐藤太郎の模擬例では、月曜日の出席率が45%と極端に低く、金曜日も55%にとどまる一方、水曜日は82%と比較的高い。このパターンから「週末前後の生活リズム乱れ」という仮説を提示する設計となっている。

第三に、**科目別欠席率の相関分析** である。数学 (1限) の欠席率が42%と突出して高く、英語 (2限) の28%がそれに続く。体育の欠席率は5%とほぼ皆勤である。この相関から、「月曜1限の数学が最大のボトルネックであり、科目への苦手意識と生活リズムの乱れが複合的に作用している可能性が高い」というAI推奨を表示する設計となっている。

Gate Levelは L=0.3 に設定されている。出席データの統計分析は比較的客観的な処理であるが、その分析結果から導出される「生活リズムの乱れ」「科目忌避」等の解釈には教育的判断が含まれるため、教員による確認が推奨される。

11.2.5 Agent 2: 個別最適化学習プラン生成 (Gate L=0.3)

Agent 2は、Agent 1のリスク分析結果とAgent 3の出席パターン分析結果を踏まえた上で、対象生徒に最適化された学習プランを生成する。個別生徒AI診断モードにおいては、以下の3つの出力が生成される。

第一に、**弱点単元一覧** である。科目・単元・習熟度 (%)・必要時間 (時間)・優先度 (最優先/優先/標準) の5属性を持つテーブルとして構造化される。佐藤太郎の模擬例では、数学の「二次関数」(習熟度25%、最優先、8時間)と「確率・統計」(習熟度30%、最優先、6時間)が最も緊急の改善対象として特定されている。

第二に、**現在 vs 目標のレーダーチャート** である。5教科の現在スコアと3ヶ月後の目標スコアを二重のレーダーチャートとして可視化する。現在のスコア (国語52、数学33、英語42、理科44、社会53) と目標スコア (国語60、数学50、英語55、理科52、社会60) の差分により、各教科における改善幅と改善の実現可能性が視覚的に示される。

第三に、**達成度予測と週間学習プラン**である。現在の5教科平均44.8点を起点として、3ヶ月後に52点、6ヶ月後に58点への改善を設計上の目標値として設定し、その達成に必要な具体的な週間学習プラン(月～金: 数学1時間+英語30分、土曜: 理科2時間、日曜: 復習1時間+長文読解1時間、計週12時間)を提示する。「現行+週8時間の追加学習で到達可能」という具体的な努力量の目安を示すことにより、教員と生徒の双方が現実的な目標設定を行える。

11.2.6 Agent 5: 進路推薦支援 (Gate L=0.7)

Agent 5は、Agent 2の学力分析結果を踏まえ、過去の進学実績データベースとの照合および適性傾向分析により、進路候補リストを生成する。

出力は、推薦度順にランク付けされた進路候補カードのリストである。各カードには、学校名、受験方式、マッチ度(%)、合格確率の推定値(%)、到達条件、Gate判定の6つの属性が含まれる。佐藤太郎の模擬例では、以下の4校が推薦されている。

表11-2 Agent 5による進路候補リスト(佐藤太郎・模擬例)

順位	学校名	受験方式	マッチ度	合格確率(目標値)	到達条件	Gate
1	近畿大学 理工学部	公募推薦	91%	78%	出席率75%以上に改善が必要	要教員承認
2	大阪工業大学 工学部	公募推薦	88%	82%	現状の成績で十分到達可能	自動提案可
3	関西大学 システム理工学部	推薦入試	85%	65%	推薦基準の出席率クリアが前提	要教員承認
4	大阪公立大学 工学部	一般選抜	72%	35%	数学偏差値10ポイント向上が必要	要教員承認

Gate Levelは L=0.7 に設定されている。合格確率の推定は、生徒の志望校選択に直接的な影響を与える情報であり、第5章で述べた「進路判断の不可逆性」に鑑みて、教員の承認が必須条件として設計されている。画面上部には「Gate L=0.7: 合格確率推定を含むため、必ず教員の承認を経てから生徒に提示してください。」という Human-in-the-loop の注意喚起が琥珀色の背景で強調表示される。

注目すべきは、4つの候補のうち「大阪工業大学 工学部」のみがGate判定「自動提案可」となっている点である。これは、当該候補の合格確率推定値が82%と高く、到達条件が「現状の成績で十分到達可能」であることから、推定の不確実性が低いと判断されたためである。一方、他の3候補はいずれも条件付き(出席率改善、偏差値向上等)であり、AIの推定と教員の判断の協働が不可欠であるため「要教員承認」が付与されている。このような動的なGate判定の設計は、Gate機構の精緻な運用設計を示すものである。

11.2.7 Agent 7: 面談サマリー自動生成 (Gate L=0.7)

パイプラインの最終段階であるAgent 7は、前段の5エージェントの出力すべてを入力として受け取り、教員が次回面談において使用する包括的な準備資料を生成する。

出力は以下の4つの要素で構成される。

第一に、**生徒状況サマリー**である。約100文字の簡潔な要約文として、対象生徒の現況と主要な課題を自然言語で記述する。佐藤太郎の模擬例では「佐藤太郎くん(3年A組)は、4月から継続的な成績下降と出席率低下が見られます。直近の面談では数学の補習参加を提案しましたが、実行が不十分です。サッカー部との両立に悩みがあり、保護者面談も未実施の状態が続いています。」と生成される。

第二に、**懸念点・確認事項**のリストである。4つの懸念点が優先度順に列挙される。「成績下降の原因が学力不足なのか、モチベーション低下なのかの見極め」「出席率の改善なしに推薦入試は困難 -- 本人の認識確認が必要」「保護者との最終連絡から45日経過 -- 家庭環境の変化の可能性」「サッカー部の引退時期と学習切り替えのタイミング」が提示される。

第三に、**推奨質問テンプレート**(生徒向け)である。面談において教員が生徒に問いかけるべき質問候補が4件提示される。各質問には、質問の意図を示す括弧書きの注釈(「生活リズムの確認」「学習阻害要因の特定」等)が付記されており、教員が質問の目的を理解した上で自身の言葉でアレンジできるよう配慮されている。

第四に、**保護者面談ポイント**である。保護者との面談において説明すべき4つの重点事項が提示される。数値データ(出席率68.2%、5教科平均44.8点)と、それが意味する教育的帰結(推薦入試への影響等)を組み合わせた説明構成により、教員がデータに基づいた説得力のある面談を実施できるよう支援する。

Gate Levelは L=0.7 に設定されている。面談準備資料は教員の対話内容に直接影響を与えるものであり、AIが生成した質問テンプレートや保護者説明ポイントが生徒の感情や家庭の事情に配慮したものであるかどうかは、教員の教育的判断に委ねられるべきであるためである。

11.3 Gate機構の統合的運用

11.3.1 異種Gate Levelの共存と段階的承認

個別生徒AI診断における最大の技術的挑戦は、L=0.2からL=0.7まで3段階のGate Levelが一つのワークフロー内で共存する点である。この設計は、エージェントの処理特性に応じた精緻なリスク制御を実現する一方で、教員にとってのユーザ体験を複雑化させるリスクも内包する。

この課題に対し、個別生徒AI診断では「段階的承認」の設計パターンを採用した。L=0.2のContext Aggregatorは完全自動で実行され、L=0.3のAgent 3およびAgent 2は診断結果の表示段階で教員に確認を促す注釈を付記することとどめ、L=0.7のAgent 1、Agent 5、Agent 7は最終的なアクションプランの「承認して共有」段階で教員の明示的な承認を要求する。

この段階的承認により、教員は診断結果を確認する過程で自然にGate機構と対話することとなり、「すべてのAgent出力を個別に承認する」という過度な操作負荷を回避しつつ、教育的判断が必要な箇所では確実にHuman-in-the-loopが機能する設計を実現することを目指した。UIプロトタイプには承認UIの画面要素を実装しており、バックエンド実装段階で実際の承認ワークフローが接続される予定である。

11.3.2 統合アクションプランにおける責任分界

個別生徒AI診断の最終出力である「統合アクションプラン」は、6つのエージェントの分析結果から導出された優先度順のアクション項目リストである。各アクション項目には、優先度(緊急/高/中)、具体的なアクション内容、提案元Agent、実行ステータスの4属性が付与される。

佐藤太郎の模擬例における統合アクションプランは以下のとおりである。

表11-3 統合アクションプラン(佐藤太郎・模擬例)

優先度	アクション	提案元	ステータス
緊急	保護者面談の設定(1週間以内)	Agent 7	未着手
緊急	月曜1限の出席改善策の実施	Agent 3	未着手
高	数学補習の再スケジュール(週2回)	Agent 2	未着手
高	Plan C(近畿大学)の出願準備を開始	Agent 5	未着手
中	生活リズム改善のための面談実施	Agent 1	未着手
中	英語長文読解の補助教材を配布	Agent 2	未着手

責任分界の観点から、このアクションプランには明確な設計原則がある。AIが「何をすべきか」を提案するが、「実行するかどうか」「いつ実行するか」「どのように実行するか」はすべて教員の判断に委ねられる。統合アクションプランの画面下部には、教員ロールカラー(緑)のボーダーで囲まれた承認カードが配置され、「Gate L=0.7のアクション(進路推薦・面談サ

マリー)は教員の承認後に生徒・保護者に共有されます」という注記とともに、「修正する」「承認して共有」の2つのボタンが提示される。教員は、AIの提案をそのまま承認することも、内容を修正した上で承認することも、完全に却下して独自のアクションプランを策定することも可能である。

11.3.3 Gate Level表示の一貫性

個別生徒AI診断のUI全体を通じて、各エージェントのGate Levelは`GateIndicator`コンポーネントにより統一的に表示される。`Shield` (盾)アイコンと「Gate L=x.x(ラベル)」テキストを組み合わせたバッジ形式で、L=0.7は赤色背景(`text-red-600 bg-red-50`)に「要承認」、L=0.3は琥珀色背景(`text-amber-600 bg-amber-50`)に「確認推奨」、L=0.2はエメラルド色背景(`text-emerald-600 bg-emerald-50`)に「自動化可」のラベルが付与される。

この色分けは、第5章(表5-7)で定義したGate Level視覚表現体系と完全に一致しており、本システム全体を通じた視覚的一貫性が保たれている。教員は、個別生徒AI診断画面に初めてアクセスした場合でも、他の画面で学習済みのGate Level色分けの知識をそのまま適用でき、各エージェント出力のリスクレベルを直感的に把握できる。

11.4 フロントエンド実装の技術詳細

11.4.1 コンポーネント構成と状態管理

個別生徒AI診断画面(`TeacherStudentDiagnosis`コンポーネント、`teacher-student-diagnosis.tsx`)は、教員ビューのナビゲーションID `t-18` として VIEW_MAP レジストリに登録される。本コンポーネントは、以下の5つの状態変数を`useState`フックで管理する。

```
```` selectedStudent: string — 選択された生徒のID isRunning: boolean — 診断実行中フラグ currentStep:
number — 現在実行中のAgentステップ番号 showResult: boolean — 診断結果の表示フラグ activeSection:
string — 現在表示中のセクションID ````
```

これらの状態変数の遷移は以下のフローで管理される。初期状態では`selectedStudent`が空文字列、`isRunning` / `showResult`がfalseであり、生徒選択UIのみが表示される。生徒を選択後に「AI診断を実行」ボタンを押下すると、`isRunning`がtrueとなり、`setInterval`により800ミリ秒間隔で`currentStep`がインクリメントされる。6つのエージェントステップがすべて完了すると、`isRunning`がfalse、`showResult`がtrueとなり、診断結果セクションが表示される。

### 11.4.2 Agent実行プロセスの可視化

診断実行中のAgent進捗状況は、`AgentProgress`コンポーネントにより可視化される。6つのエージェントステップが縦方向のリストとして表示され、各ステップの状態に応じて以下の3つのビジュアルフィードバックが提供される。

**完了ステップ**(`isDone`)は、エメラルド色の`CheckCircle2`アイコンとエメラルド色のテキスト(`text-emerald-700`)で表示される。**実行中ステップ**(`isRunning`)は、教員ロールカラー(緑)の`Loader2`アイコン(`animate-spin`による回転アニメーション付き)とロールカラーのテキスト(`text-role-teacher`)で表示される。さらに、実行中ステップには`Progress`コンポーネントによるプログレスバー(高さ1.5px)が付加され、処理の進行度が視覚的にフィードバックされる。**待機ステップ**は、ステップ番号のみが薄い灰色(`text-muted-foreground`)で表示される。

各ステップの右端には`GateIndicator`コンポーネントが配置され、当該エージェントのGate Levelが常に可視化される。これにより、教員はAgent実行の進捗を追跡しながら、各エージェントの出力がどの程度の人間関与を要求するかを事前に把握できる。

### 11.4.3 7セクションナビゲーションの実装

診断結果の表示領域は、7つのセクション(総合診断・リスク検知・出席パターン・学習プラン・進路推薦・面談準備・アクションプラン)で構成される。セクション切替は、水平スクロール可能なボタングループとして実装されている。

各ボタンは、Lucide Reactアイコン(`Activity`、`AlertTriangle`、`Calendar`、`BookOpen`、`GraduationCap`、`MessageSquare`、`Target`)とセクション名の組み合わせで構成される。アクティブなセクションは教員ロールカラー(`bg-role-teacher text-white`)で強調され、非アクティブなセクションは`text-muted-foreground`に淡い背景ホバー(



`hover:bg-role-teacher-light hover:text-role-teacher`)が適用される。`overflow-x-auto` クラスにより、モバイル環境でもスワイプ操作でセクション切替が可能である。

#### 11.4.4 総合診断サマリーの実装

「総合診断」セクション(`activeSection === "overview"`)は、3つのサブセクションで構成される。

第一サブセクションは「総合診断サマリー」カードである。左ボーダーに赤色(`border-l-4 border-l-red-500`)が適用され、リスクの深刻度を視覚的に伝達する。ヘッダー部には `Activity` アイコン、「総合診断サマリー」タイトル、リスクスコアバッジ(`bg-red-100 text-red-700`)、生成日時が配置される。コンテンツ部には、AIによる総合判定文と「主要な発見事項」4件が赤色背景(`bg-red-50`)の個別カードとして列挙される。

第二サブセクションは「クイック統計」グリッドである。2列x2行(モバイル)または4列(デスクトップ)のグリッドレイアウトで、リスクスコア(82、赤色)、出席率(68.2%、琥珀色)、5教科平均(44.8、青色)、最高マッチ度(91%、エメラルド色)の4つのKPIカードが表示される。各カードは、色付きアイコン背景(`rounded-md`)とラベル・数値の2段構成で統一されている。

第三サブセクションは「緊急アクション」カードである。統合アクションプランのうち「緊急」優先度のアクション2件のみを抽出して表示し、教員の即座のアクションを促す。

#### 11.4.5 Agent個別分析セクションの実装

「リスク検知」セクション(Agent 1)は、`border-l-4 border-l-red-500` のカードとして実装される。最上部にSVGベースの円形プログレスインジケータ(`viewBox="0 0 100 100"`)が配置され、リスクスコア82が視覚的に強調される。円形インジケータは、`strokeDasharray` プロパティを用いてスコア値に応じた弧の長さを動的に描画する。その下部にリスク要因分析テーブル(各要因の重み・スコア・詳細・プログレスバー)、さらにRechartsの `LineChart` によるリスクスコア推移グラフが配置される。

「出席パターン」セクション(Agent 3)は、`border-l-4 border-l-amber-500` のカードとして実装される。サマリー統計(出席率・遅刻数・欠席数の3カラムグリッド)、Rechartsの `BarChart` による曜日別出席パターンの積み上げ棒グラフ(出席: `#22c55e`、遅刻: `#f59e0b`、欠席: `#ef4444`)、`Table` コンポーネントによる科目別欠席率テーブル、パターン分析結果(琥珀色背景)とAI推奨(青色背景)の2つの要約カードで構成される。

「学習プラン」セクション(Agent 2)は、`border-l-4 border-l-blue-500` のカードとして実装される。左右2列のグリッドレイアウトにおいて、左列にRechartsの `RadarChart` による現在/目標の二重レーダーチャート(現在: `#ef4444` 赤、目標: `#22c55e` 緑)を、右列に達成度予測の3段カード(現在値・3ヶ月後予測・6ヶ月後予測)をそれぞれ配置する。下部には弱点単元テーブル(`Table` コンポーネント、習熟度 `Progress` バー付き)と推奨週間学習プラン(日別カードリスト)が配置される。

「進路推薦」セクション(Agent 5)は、`border-l-4 border-l-emerald-500` のカードとして実装される。最上部に Human-in-the-loopの注意喚起カード(`border-amber-200 bg-amber-50`、`Eye` アイコン付き)が配置される。その下に4件の進路候補カードが個別の `Card` コンポーネントとして列挙され、各カードには学校名・受験方式・マッチ度・合格確率・Gate判定・到達条件が構造化表示される。マッチ度は `Progress` コンポーネントによるバー表示でも可視化される。

「面談準備」セクション(Agent 7)は、`border-l-4 border-l-purple-500` のカードとして実装される。生徒状況サマリー(紫色背景)、懸念点・確認事項リスト(琥珀色カード、`AlertTriangle` アイコン付き)、推奨質問テンプレート(番号付きカード、教員ロールカラーの番号バッジ)、保護者面談ポイント(青色背景、`ChevronRight` アイコン付き)の4セクションで構成される。

#### 11.4.6 データ可視化の技術的実装

個別生徒AI診断画面は、本システムの全画面の中で最も多様なデータ可視化を実装している画面の一つである。使用されるRechartsコンポーネントは以下の4種である。

41. **LineChart**(Agent 1: リスクスコア推移): 6ヶ月間のリスクスコアを赤色(`#ef4444`)の折れ線で描画。  
`type="monotone"` による滑らかな曲線、`strokeWidth={2}` による視認性の確保。

42. **BarChart**(Agent 3: 曜日別出席パターン): 月～金の5曜日について、出席(緑)・遅刻(琥珀)・欠席(赤)を`stackId="a"`による積み上げ棒グラフで可視化。各曜日の合計が100%となる正規化表示。
43. **RadarChart**(Agent 2: 現在 vs 目標): 5教科の二重レーダーチャート。`fillOpacity={0.2}`による半透明塗りつぶしで、現在と目標の乖離を面積として直感的に把握可能。
44. **円形プログレスインジケータ**(Agent 1: リスクスコア): SVGの`circle`要素と`strokeDasharray`による独自実装。Rechartsに依存しない軽量の可視化。

すべてのチャートは`ResponsiveContainer`(`width="100%" height={200~250}`)でラップされ、画面幅に応じた自動リサイズが保証される。ツールチップの`contentStyle`には`fontSize: 11`を統一的に指定し、日本語テキストの可読性を確保している。

## 11.5 教育的価値と実践的意義

### 11.5.1 教員の意味決定支援における統合的アプローチの価値

個別生徒AI診断の教育的価値は、教員の意味決定プロセスの質と速度を同時に向上させる点にある。従来の進路指導において、教員が一人の生徒に関する包括的な状況把握を行うためには、成績表の確認、出席簿の確認、面談記録の参照、進路先データの検索、面談内容の準備の計60分程度を要していたと推計される。個別生徒AI診断は、バックエンド実装後に、この準備時間を数十秒の診断実行時間と数分の結果確認時間に短縮することを目標としている。

しかし、単なる時間短縮以上に重要なのは、情報の統合品質の向上である。人間の認知には作業記憶の容量制限があり、6つの異なるデータソースからの情報を同時に統合して最適な判断を下すことは認知的に困難なタスクである(Miller, 1956)。個別生徒AI診断は、この認知的制約をAIの情報統合能力により補完し、教員が「データの収集と整理」から「データに基づく教育的判断」に認知資源を集中できる環境を創出する。

### 11.5.2 エージェント間の情報連携による新たな洞察の創出

個別生徒AI診断の6エージェント統合は、個々のエージェントを個別に実行した場合には得られない、エージェント間の情報連携に基づく新たな洞察の創出を目指す設計である。

具体例として、佐藤太郎の模擬例におけるAgent 3(出席パターン)とAgent 2(学習プラン)の連携を挙げる。Agent 3が「月曜1限の数学の欠席率が42%と突出して高い」というパターンを検出し、Agent 2が「数学の二次関数の習熟度が25%と最も低い」という弱点を特定した場合、両者を統合することで「月曜1限の欠席は、数学への苦手意識(特に二次関数の理解不足)が学習回避行動として顕在化したものである可能性が高い」という仮説が導出される。この仮説は、Agent 3単独でもAgent 2単独でも導出し得ないものであり、エージェント間の情報連携によって初めて生成される統合的洞察である。

Agent 7(面談サマリー)は、この統合的洞察を踏まえた面談質問テンプレート(「最近、朝起きるのがつらいと感じることはありますか?」「数学の補習に参加できていない理由を教えてくださいませんか?」)を生成し、教員が生徒の行動の背景にある心理的要因に迫る対話を設計するための支援を提供する。

### 11.5.3 「見逃しゼロ」から「統合的理解」へ

第6章で述べたGuardian Agentsの設計目標は「見逃しゼロ」であった。個別生徒AI診断は、この目標をさらに発展させ、リスクの検知にとどまらず、検知されたリスクに対する包括的な対応戦略の策定までを一貫して支援する。

「見逃しゼロ」が第一段階の目標であるとすれば、個別生徒AI診断が目指すのは「統合的理解」という第二段階の目標である。一人の生徒を、成績という一面からではなく、出席パターン、学習スタイル、進路適性、家庭環境という多面的な視点から立体的に理解し、その理解に基づいた最適な支援戦略を構築すること——これが個別生徒AI診断の本質的な教育的価値である。

### 11.5.4 Guardian-Tutor Agent Team の具現化

本システムの全体設計において、Guardian-Tutor Agent Team(生徒支援統合)は、リスク検知(Guardian)と学習支援(Tutor)の情報を横断的に活用し、一人ひとりの生徒に対する包括的な支援戦略を自動生成するという構想であった。個別

生徒AI診断は、この構想を具体的なUIプロトタイプとして実現した最初の機能であり、バックエンド実装段階でワークフローの接続が予定されている。

個別生徒AI診断においては、Guardian Agents (Agent 1、Agent 3) がリスクの「検知」を、Tutor Agent (Agent 2) がリスクに対する「処方」を、Management Agents (Agent 5、Agent 7) が処方の「伝達と実行」をそれぞれ担う設計とした。この「検知→処方→伝達」の3段階フローは、医療分野における「診断→治療計画→患者説明」のプロセスに対応するものであり、教育分野における生徒支援のプロフェッショナルプロセスを構造化したものと言える。

## 11.6 技術的拡張性と今後の展望

### 11.6.1 リアルタイム診断への発展

現行のプロトタイプにおいては、診断実行は教員の明示的な操作（「AI診断を実行」ボタンの押下）により起動されるが、バックエンド実装段階においては、リアルタイム診断への発展が構想されている。具体的には、成績データや出席データの更新をトリガーとして、バックグラウンドで自動的に診断パイプラインが再実行され、リスクスコアの変動が一定閾値を超えた場合にリアルタイム通知（WebSocketまたはServer-Sent Events）が教員に配信される設計である。

### 11.6.2 診断履歴の蓄積と縦断分析

個別生徒AI診断の結果を時系列で蓄積することにより、生徒の状態遷移の縦断分析が可能となる。過去の診断結果との比較により、「前月のアクションプランのうちどの項目が実行され、どの程度の効果があったか」を定量的に評価できる。この縦断データは、エージェントの推定精度の向上（推奨アクションの有効性フィードバック）にも活用される。

### 11.6.3 学年・クラス単位の一括診断

現行の設計は1名の生徒を対象とした個別診断であるが、学年・クラス単位で全生徒の診断を一括実行し、リスクスコアの分布やクラス全体の傾向を把握するマクロレベルの診断機能への拡張が検討されている。この拡張により、担任教員のみならず学年主任や管理者が、組織単位での生徒支援状況を俯瞰的に把握できる環境が実現される。

図表一覧（第11章）

図表番号	タイトル
表11-1	個別生徒AI診断パイプライン構成
表11-2	Agent 5による進路候補リスト（佐藤太郎・模擬例）
表11-3	統合アクションプラン（佐藤太郎・模擬例）

## 第12章 フロントエンド実装 — ロールベースUIシステム

### 12.1 アプリケーション全体構成

#### 12.1.1 技術選定の根拠

本システムのフロントエンドは、Next.js 16 (App Router) を基盤として構築した。技術選定にあたっては、教育機関における情報システムの特徴を考慮し、以下の3つの要件を重視した。第一に、管理者・教員・事務方・学生の4ロールが同一URLから即時切替可能なSPA (Single Page Application) アーキテクチャであること。第二に、将来的なバックエンド統合を見据えたコンポーネント設計の拡張性を有すること。第三に、日本語UIに最適化されたタイポグラフィとアクセシビリティの確保である。

React 19をランタイムとし、TypeScript 5.7による静的型付けを全面的に採用した。スタイリングにはTailwind CSS 4.2を使用し、OKLCh色空間によるデザイントークンの定義を行った。UIコンポーネントにはshadcn/ui (New Yorkスタイル) を基盤とし、Radix UIプリミティブ上に構築されたアクセシブルなコンポーネント群を活用した。

#### 12.1.2 ディレクトリ構成

本システムのソースコードは以下のディレクトリ構成に従って組織化されている。

```
`` /app layout.tsx ルートレイアウト page.tsx メインポータル (SPAエントリポイント) globals.css グローバルスタイル定義

/components /ui shadcn/uiコンポーネント (56ファイル) /portal portal-header.tsx ロール対応ヘッダー
portal-sidebar.tsx コンテキスト対応サイドバー kpi-card.tsx KPI表示カード alert-list.tsx アラートリスト
activity-feed.tsx アクティビティフィード /views 56ビューコンポーネント+レジストリ

/lib types.ts 型定義・ROLE_CONFIG utils.ts cn()ユーティリティ

/hooks use-mobile.ts ビューポート検出 use-toast.ts トースト通知 ``
```

この構成は、関心事の分離原則 (Separation of Concerns) に基づいている。`/components/ui` には汎用的なUIプリミティブを配置し、`/components/portal` にはドメイン固有のコンポーネントを集約した。さらに`/components/portal/views` には、各ロールの画面コンポーネントを一括管理する構成とした。

#### 12.1.3 ルートレイアウトの設計

`app/layout.tsx` はアプリケーション全体のルートレイアウトを定義する。本ファイルにおいて、日本語表示に最適化されたNoto Sans JPフォント (300/400/500/600/700の5ウェイト) をGoogle Fontsから読み込み、CSS変数`--font-noto-sans-jp`として登録する。これにより、全コンポーネントにわたって一貫した日本語タイポグラフィが保証される。

```
``tsx const notoSansJP = Noto_Sans_JP({ subsets: ['latin'], weight: ['300', '400', '500', '600', '700'], variable:
'--font-noto-sans-jp', }) ``
```

HTMLの`lang`属性には`ja`を指定し、Vercel Analyticsをbody直下に配置してユーザー行動の計測基盤を整備した。メタデータとしてタイトル「進路指導ポータル | 清風情報工科学院」およびテーマカラー`#5B4FC4` (管理者ロールのプライマリカラーに対応) を設定している。

### 12.2 ロール切替機構の実装

#### 12.2.1 状態管理アーキテクチャ

本システムの中核的な設計思想は、4つのユーザーロールを単一ページ内で動的に切り替え可能とする点にある。

`app/page.tsx` において、Reactの`useState`フックを用いた軽量な状態管理を実装した。



```
````tsx const [activeRole, setActiveRole] = useState<Role>("admin") const [activeNavId, setActiveNavId] =
useState("a-1") const [sidebarOpen, setSidebarOpen] = useState(false) ````
```

ここで`Role`型は`"admin" | "teacher" | "office" | "student"`のユニオン型として`lib/types.ts`に定義されている。ロール切替時には、対応するデフォルトナビゲーションIDへの遷移を連動させる。

```
````tsx const defaultNavIds: Record<Role, string> = { admin: "a-1", // 管理者ダッシュボード teacher: "t-1", // 教員
ダッシュボード office: "o-1", // 事務方ダッシュボード student: "s-1", // 学生マイページ } ````
```

この設計により、ロール切替と画面遷移が単一のイベントハンドラ内で原子的に実行され、中間的な不整合状態が発生しない。プロトタイプ段階ではクライアントサイドのみで完結するが、認証基盤の導入時にはサーバーサイドでのロール検証に置換可能な構成となっている。

### 12.2.2 ROLE\_CONFIGによる集約的ロール定義

各ロールのメタ情報は`lib/types.ts`の`ROLE\_CONFIG`定数に集約されている。この設計パターンは、ロール追加・変更時の影響範囲を最小化するために採用した。

```
````tsx export const ROLE_CONFIG: Record<Role, { label: string; shortLabel: string; colorClass: string; bgClass:
string; lightBgClass: string; navItems: NavItem[] }> = { admin: { label: "管理者", shortLabel: "A", colorClass:
"text-role-admin", bgClass: "bg-role-admin", lightBgClass: "bg-role-admin-light", navItems: [ { id: "a-1", label: "ダッ
シュボード" }, { id: "a-2", label: "ユーザー管理" }, // ... 14項目 ], }, // teacher, office, student も同様の構造 } ````
```

管理者は14画面、教員は15画面、事務方は15画面、学生は12画面、合計56画面のナビゲーション項目が定義されている。各ロールは`shortLabel` (A/T/O/S)による1文字識別子、ロール固有のカラークラス、および固有のナビゲーション階層を有する。

12.2.3 タブUIによる即時切替の実現

ロール切替UIは、WAI-ARIA準拠のタブパターンとして実装した。各タブボタンには`role="tab"`および`aria-selected`属性が付与され、スクリーンリーダーによるアクセシビリティが確保されている。

```
````tsx

<nav role="tablist" aria-label="ロール切替"> {roles.map((role) => (

<button key={role} role="tab" aria-selected={isActive} onClick={() => handleRoleChange(role)} className={cn(
"flex items-center gap-1.5 rounded-md px-3 py-1.5 text-xs", isActive ? styles.active : styles.inactive)} >
{config.shortLabel}. {config.label}

 ({config.navItems.length})

</button>)}}

</nav> ````
```

各タブのスタイルはOKLCh色空間の値を直接指定するインラインアプローチを採用した。管理者は紫(hue 265)、教員は緑(hue 155)、事務方は黄橙(hue 55)、学生は青(hue 240)として視覚的な識別性を確保している。この色彩設計はロールごとの職能的イメージに対応させたものであり、後述するヘッダー・サイドバー・KPIカードにわたって一貫して適用される。

## 12.3 VIEW\_MAPレジストリパターン

### 12.3.1 設計意図と実装

56画面のビューコンポーネントを効率的に管理するため、レジストリパターンを導入した。`view-registry.tsx`において、ナビゲーションID(文字列)からReactコンポーネントへのマッピングを`Record<string, ComponentType>`型の辞書として定義する。

```
``tsx import type { ComponentType } from "react" import { AdminDashboard } from "../admin-dashboard" import { TeacherDashboard } from "../teacher-dashboard" // ... 全56コンポーネントのimport
```

```
export const VIEW_MAP: Record<string, ComponentType> = { "a-1": AdminDashboard, "a-2": AdminUserManagement, "a-3": AdminUserDetail, // ... admin 14画面 "t-1": TeacherDashboard, // ... teacher 15画面 "o-1": OfficeDashboard, // ... office 15画面 "s-1": StudentDashboard, // ... student 12画面 } ``
```

メインページでは、このマッピングを用いてアクティブなナビゲーションIDに対応するコンポーネントを動的に解決し、レンダリングする。

```
``tsx const renderView = () => { const ViewComponent = VIEW_MAP[activeNavId] if (!ViewComponent) return null return <ViewComponent /> } ``
```

### 12.3.2 命名規則とID体系

ナビゲーションIDは「ロール接頭辞-連番」の形式を採用した。管理者は`a-`、教員は`t-`、事務方は`o-`、学生は`s-`である。ファイル名は`{role}-{function}.tsx`の形式(例: `admin-dashboard.tsx`、`teacher-student-detail.tsx`)で統一し、ロールと機能の対応関係を一目で把握可能とした。

### 12.3.3 拡張性への配慮

現在の実装では全コンポーネントを静的にimportしているが、この構造はReactの`lazy()`関数およびSuspenseを用いたコード分割(Code Splitting)への段階的移行が容易である。ナビゲーションIDを文字列キーとする辞書構造は、将来的に動的ルーティングやロールベースのアクセス制御フィルタリングを挿入する拡張点としても機能する。

## 12.4 管理者(Admin)ダッシュボード群の実装

管理者ロールには14画面が割り当てられ、経営層の意思決定を支援するための統合的な情報提示を行う。

### 12.4.1 経営ダッシュボード(a-1: AdminDashboard)

管理者のエントリーポイントとなるダッシュボードは、4つのKPIカード、アラートリスト、アクティビティフィード、および2種のチャートで構成される。プロトタイプではモックデータとして「在籍学生数」「戦略策定率」「進路決定率」「出願中人数」等のKPIを表示し、前月比・今月比の変動をトレンドアイコン(上昇・下降・横ばい)で視覚化する。

チャート実装にはRechartsライブラリを使用した。進路ステータスファネルは水平方向の棒グラフ(BarChart + layout="vertical")で、在籍→戦略策定済→出願準備中→出願完了→合格内定の5段階を人数とともに表示する。進路決定状況は内径50・外径80のドーナツチャート(PieChart + innerRadius)で、決定済み・出願中・戦略策定済・未着手の4ステータスを色分け表示する。いずれも`ResponsiveContainer`でラップし、親要素の幅に追従するレスポンシブ設計とした。

### 12.4.2 ユーザー管理(a-2)とクラス管理(a-4)

ユーザー管理画面はモックデータによるユーザーをテーブル形式で一覧表示し、検索・フィルタ機能を提供する。クラス管理画面はクラス情報を3列グリッドのカード形式で表示し、学年タブによる絞り込みが可能である。各クラスカードには担任名、在籍数、およびProgressコンポーネントによる進路決定率のビジュアル表示を含む。上級学年については、クラス別の進路決定率の比較棒グラフを提供する。

### 12.4.3 TGグループ管理と承認ワークフロー(a-5, a-6)

TG (Teacher Group) 管理画面はグループの構成情報を表示する。注目すべきは、承認ワークフロー(a-6: AdminTgApproval)の実装である。このコンポーネントはクライアントサイドで完結するステートフルな承認/却下処理を実現している。

```
````tsx const [requests, setRequests] = useState(initialRequests)

const handleApprove = (id: string) => { setRequests((prev) => prev.map((r) => r.id === id ? { ...r, status: "approved", processedDate: "2026-02-25", processedBy: "管理者" } : r )) } ````
```

承認待ち・承認済み・却下の3タブで分類表示し、各リクエストカードには学生名・現在TG→変更先TGの矢印表示・変更理由・申請者・申請日を含む。このプロトタイプ実装は、将来的なバックエンドAPIとの統合において、楽観的更新(Optimistic Update)パターンへの移行が想定されている。

12.4.4 AIエージェント管理(a-15: AdminAiTools)

本システムの中核機能であるAIエージェント管理画面は、10のAIエージェントと2つのAgent Teamを統合的に管理する。エージェントは「守る(Guardian)」「育てる(Tutor)」「回す(Admin)」「導く(Management)」の4象限に分類され、各象限は固有のアイコン・配色・ボーダーカラーで視覚的に区別される。

各エージェントカードにはSwitchコンポーネントによるON/OFFトグル、利用回数、精度(%）、最終利用日時、およびGateレベル(L=0.2/L=0.3/L=0.7)が表示される。Gateレベルは人間介入の度合いを示すもので、L=0.2は自動実行、L=0.3は教員確認後実行、L=0.7は管理者承認必須として色分け(緑/黄/赤)で識別性を確保している。

Agent Teamは複数のエージェントを束ねた上位概念であり、U1「留学生対応・教材自動翻訳」はAgent 2, 5, 9と、U2「進路相談負担軽減」はAgent 5, 7, 8と連携する。この構造は、教育現場におけるAIの活用方針を視覚的に体系化するものである。

12.5 教員(Teacher)ダッシュボード群の実装

教員ロールには15画面が割り当てられ、担任教員の日常業務を支援する。

12.5.1 担任用日次ダッシュボード(t-1: TeacherDashboard)

教員ダッシュボードは、KPI(担当学生数、面談完了率、リスク生徒数、今週の面談件数)、リスクアラート、面談予定、学生一覧テーブルの4セクションで構成される。学生一覧テーブルにはリアルタイム検索機能を実装しており、`useState`によるフィルタリングが即座に反映される。

```
````tsx const [searchQuery, setSearchQuery] = useState("") const filteredStudents = students.filter( (s) => s.name.includes(searchQuery) || s.planA.includes(searchQuery) ) ````
```

リスクレベルはカラードット(赤・黄・緑)で各行の先頭に表示し、ステータスパッジは対応する背景色(`bg-red-100 text-red-700`等)で直感的に識別可能とした。

### 12.5.2 学生カルテ(t-3: TeacherStudentDetail)

教員向け画面群で最も情報密度が高い画面が学生カルテである。本画面は5つのタブ(基本情報・成績推移・進路戦略・面談履歴・AI分析)で構成され、1名の学生に関する包括的な情報を集約表示する。

プロフィールヘッダーにはAvatar、氏名、リスクパッジ、学籍番号、クラス・TG・部活動・出席率・クラス順位をワンラインで表示する。成績推移タブではRechartsのLineChart(5教科の折れ線グラフ)とRadarChart(科目バランスの五角形レーダー)を並列配置し、視覚的な学力分析を提供する。

注目すべきはAI分析タブの設計である。Agent 1(学習リスク早期検知)のリスクスコア、リスク要因と重み付け、AI推奨アクションが構造化されて表示される。Agent 2(個別最適化学習プラン)は弱点単元をテーブル形式(科目・単元・習熟度・プログレスバー・優先度パッジ)で提示し、推奨学習プランを記載する。Agent 5(進路推薦支援)はマッチ度付きの進路候補を一覧表示する。各Agentカードにはボーダーカラー(赤・青・緑)による視覚的区別とGateレベル表示が付与されている。

### 12.5.3 面談管理と逆算カレンダー

面談記録一覧(t-4)、面談記録入力(t-5)、面談予約管理(t-15)の3画面で面談業務のライフサイクルを網羅する。リスクアラート一覧(t-6)は危険度に応じた3色分類(danger/warning/info)でアラートを表示し、逆算カレンダー(t-11)は受験日から逆算したマイルストーンをタイムライン形式で可視化する。

## 12.6 事務方(Office)ダッシュボード群の実装

事務方ロールには15画面が割り当てられ、事務処理の効率化とデータ管理を支援する。

### 12.6.1 事務処理トラッキング(o-1: OfficeDashboard)

事務方ダッシュボードのKPIは「未処理手続き数」「書類期限切れ」「今日の面談」「データ取込状況」であり、日次の業務負荷を把握する設計となっている。画面下部には未着手手続き一覧(緊急度バッジ付き)と今日の面談スケジュール(完了/未完了のストライクスルー表示)、さらにデータ取り込み進捗(成績データ・出席データ・進路先マスタ・奨学金情報の各Progressバー)を集約する。

### 12.6.2 書類・出願管理ワークフロー

書類管理(o-5: OfficeDocumentManagement)は調査書・推薦状・成績証明書等の書類処理をステータス別に管理する。出願管理(o-8: OfficeApplicationManagement)は出願書類の受理・確認・発送のワークフローを追跡する。いずれもステータスに応じたカラーバッジ(期限間近=赤、進行中=緑、未着手=黄)により、視覚的な優先度判断を支援する設計である。

### 12.6.3 データインポート機能

データ取り込み画面(o-14: OfficeDataImport)は、外部システムからのCSV/Excel形式データの取り込み状態を管理する。成績データ、出席データ、進路先マスタ等のデータソースごとに最終同期日時と進捗率を表示し、データの鮮度管理を可能とする。

## 12.7 学生(Student)ダッシュボード群の実装

学生ロールには12画面が割り当てられ、自己の進路活動の管理と情報閲覧を提供する。

### 12.7.1 マイページ(s-1: StudentDashboard)

学生ダッシュボードは他ロールとは異なり、KPIグリッドではなく個人プロフィールカードをエン트리ポイントとする。プロフィールカードの左ボーダーには学生ロールカラー(青)が適用され、Avatar、氏名、クラス/TG、進路ステータスバッジが横並びで表示される。

進路戦略セクションではPlan A/B/Cを3列グリッドのカードとして表示し、各カードに志望校名、受験方式、判定結果バッジを含む。タスクセクションではCheckCircle2/Circleアイコンによる完了/未完了の視覚的区別とProgressバーによる全体進捗表示を行う。

```
``tsx const completedTasks = tasks.filter((t) => t.done).length const taskProgress = Math.round((completedTasks / tasks.length) * 100) ``
```

今後の予定セクションではイベントをカレンダー形式(日付+曜日のミニカード)で時系列表示し、イベントタイプ(学業=青、面談=緑、締切=赤)のバッジで分類する。

### 12.7.2 テストスコア分析(s-2: StudentTestScores)

成績管理画面は本システムの中でも複合的なデータビジュアライゼーションを提供する。5教科の最新スコアをKPIカード形式で一列に表示した後、5教科合計の学年平均との比較パネルを配置する。

下部のTabsコンポーネントは4つのビューを切り替える。「推移グラフ」タブでは過去6回分の定期試験データを5色の折れ線グラフ(LineChart)で表示し、各教科の成績推移を可視化する。「強み・弱み」タブではRadarChartにより5教科のバランスを五角形で表現し、スコア閾値(80以上=得意、70以上=普通、70未満=要強化)に基づくバッジを自動判定で付与する。「成績一覧」タブは全テスト結果をテーブル形式で一覧表示し、合計点と順位を含む。



注目すべきは「AI弱点分析」タブである。Agent 2(個別最適化学習プラン)による科目別の弱点分析と学習提案が、優先度バッジ(高=赤、中=黄、低=青)付きのカード形式で表示される。「※ AIの提案は先生の確認を経て表示されています」の注記は、AIの出力が教員のGateを通過した後に生徒に提示されるという本システムのガバナンス設計を反映している。

### 12.7.3 出願ステータスとポートフォリオ

出願状況(s-7: StudentApplicationStatus)は志望校への出願の進捗をステップ形式で追跡する。ポートフォリオ(s-13: StudentPortfolio)は学生の活動記録・成果物を蓄積表示する画面であり、キャリアパスポートとしての機能を担う。

## 12.8 共通UIパターン

### 12.8.1 KPIカードコンポーネント

全ロールのダッシュボードに共通して使用されるKPIカード(`kpi-card.tsx`)は、ロール対応型のプレゼンテーションコンポーネントとして設計した。`role`プロパティに基づいてトップボーダーカラーと数値テキストカラーが動的に切り替わる。

```
``tsx const roleBorderMap: Record<Role, string> = { admin: "border-t-role-admin", teacher: "border-t-role-teacher", office: "border-t-role-office", student: "border-t-role-student", } ``
```

トレンドインジケータには Lucide React のTrendingUp(上昇=緑)、TrendingDown(下降=赤)、Minus(横ばい=灰色)アイコンを使用し、数値変動の方向性を直感的に伝達する。

### 12.8.2 アラートリストコンポーネント

アラートリスト(`alert-list.tsx`)は危険度に応じた3段階の視覚設計を採用している。danger(赤背景・赤左ボーダー・AlertTriangleアイコン)、warning(黄背景・黄左ボーダー・AlertCircleアイコン)、info(青背景・青左ボーダー・Infoアイコン)の各タイプに対し、背景色・ボーダー色・アイコン色・テキスト色の4属性をセットで定義している。この設計は、教育現場における「緊急度の段階的表現」という要件に対応するものである。

### 12.8.3 チャート統合パターン

Rechartsの使用にあたっては、以下の統一パターンを採用した。全チャートを`ResponsiveContainer`でラップし、`width="100%"`とすることでコンテナ幅への追従を保証する。高さは用途に応じて200px~300pxの範囲で設定し、ツールチップの`contentStyle`にはフォントサイズ11~12pxを指定して日本語テキストの可読性を確保した。

使用したチャート種別は以下の4種である。LineChart(成績推移)、BarChart(ステータスファネル、クラス比較)、PieChart(進路決定状況の内訳)、RadarChart(科目バランスの多角形表現)。いずれもReact宣言的APIにより、データ配列の変更のみでチャートが自動再描画される。

### 12.8.4 テーブルとフォーム要素

データテーブルはshadcn/uiのTableコンポーネント(Table, TableHeader, TableBody, TableRow, TableHead, TableCell)を使用し、CSSクラス`text-xs`による省スペース表示と`overflow-x-auto`による水平スクロール対応を全テーブルに適用した。検索フィルタは、Lucide ReactのSearchアイコンを`absolute`配置したInput要素と、Selectコンポーネントによるカテゴリフィルタリングを組み合わせた統一パターンを採用している。

## 12.9 スタイリングアーキテクチャ

### 12.9.1 OKLCh色空間によるデザイントーン

本システムのカラーシステムは、CSS Color Level 4仕様のOKLCh色空間に基づいて設計した。OKLChは人間の知覚的均一性を重視した色空間であり、Lightness(明度)、Chroma(彩度)、Hue(色相)の3パラメータで構成される。

`app/globals.css`のCSS変数定義において、ロール固有色を以下のように定義した。

```
``css :root { --role-admin: oklch(0.45 0.18 265); / 紫 / --role-admin-light: oklch(0.93 0.04 265); / 淡紫 /
--role-teacher: oklch(0.50 0.16 155); / 緑 / --role-teacher-light: oklch(0.93 0.04 155); --role-office: oklch(0.62
```

```
0.18 55); / 黄橙 / --role-office-light: oklch(0.93 0.05 55); --role-student: oklch(0.50 0.14 240); / 青 /
--role-student-light: oklch(0.93 0.04 240); } ``
```

各ロールの通常色と淡色(light)は、Hue値を固定したままLightnessとChromaを調整することで生成している。この手法により、知覚的に均一な明暗コントラストがロール間で保証される。ダークモードではLightness値の反転とChromaの微調整により、暗色背景での可読性を維持する。

## 12.9.2 Tailwind CSS 4.2のテーマ統合

CSS変数をTailwindのユーティリティクラスとして使用するため、`@theme inline`ディレクティブで`--color-role-\*`プレフィックスのカスタムカラーを登録した。これにより、`bg-role-admin`、`text-role-teacher`、`border-t-role-student`といったユーティリティクラスが使用可能となる。

## 12.9.3 cn()ユーティリティの活用

条件付きクラス結合にはclsxとtailwind-mergeを組み合わせた`cn()`ユーティリティを使用した。

```
``tsx import { clsx, type ClassValue } from 'clsx' import { twMerge } from 'tailwind-merge'

export function cn(...inputs: ClassValue[]) { return twMerge(clsx(inputs)) } ``
```

tailwind-mergeはTailwindクラスの競合を自動解決し、後勝ちのセマンティクスを保証する。例えば`cn("bg-red-500", isActive && "bg-blue-500")`は、`isActive`が真の場合に`bg-red-500`を削除して`bg-blue-500`のみを出力する。

# 12.10 レスポンシブデザインの実装

## 12.10.1 モバイルファースト設計

全コンポーネントはモバイルファーストのアプローチで設計した。基本レイアウトはモバイル幅(<768px)を基準とし、ブレイクポイント`md:`(768px以上)および`lg:`(1024px以上)で段階的にレイアウトを拡張する。

代表的な例として、KPIグリッドはモバイルで2列(`grid-cols-2`)、デスクトップで4列(`lg:grid-cols-4`)に遷移する。コンテンツグリッドはモバイルでスタック配置(1列)、タブレット以上で2列(`md:grid-cols-2`)となる。

## 12.10.2 サイドバーのアダプティブ表示

サイドバー(`portal-sidebar.tsx`)はモバイルとデスクトップで根本的に異なる表示モードを採用した。モバイル環境では`fixed`ポジションのオーバーレイパネルとして動作し、`translate-x`のトランジションによるスライドイン/アウトを実現する。背景にはフォーカストラップとして半透明オーバーレイ(`bg-foreground/30`)を配置し、タップで閉じる。

```
``tsx

<aside className={cn("fixed top-0 left-0 z-40 flex h-full w-64 flex-col", "md:static md:z-auto md:translate-x-0",
isOpen ? "translate-x-0" : "-translate-x-full")}> ``
```

デスクトップ環境では`md:static`により通常のフロー配置となり、常時表示される。この切り替えはCSS条件のみで実現され、JavaScriptによるリサイズイベントの監視は不要である。

## 12.10.3 コンテキスト対応のアイコンマッピング

サイドバーのナビゲーション項目には、ラベル文字列からLucide Reactアイコンへのマッピングを定義した`iconMap`辞書を用いて、アイコンを動的に割り当てる。例えば「ダッシュボード」にはLayoutDashboard、「ユーザー管理」にはUsers、「リスクアラート一覧」にはBell、「AIツール」にはBotが対応する。マッピングに存在しないラベルにはLayoutDashboardがフォールバックとして使用される。

## 12.11 本章の総括

本章では、清風情報工科学院進路指導ポータルシステムのフロントエンド実装について、アーキテクチャ設計から個別コンポーネントの実装詳細に至るまでを解説した。

本システムの技術的特徴は以下の3点に集約される。第一に、ROLE\_CONFIGとVIEW\_MAPによる宣言的なロール管理アーキテクチャは、4ロール56画面のUIを体系的に組織化している。第二に、OKLCh色空間を活用したロール固有のカラーシステムは、ヘッダー・サイドバー・KPIカード・バッジにわたって一貫した視覚的識別性を提供し、ユーザーが現在どのロールで操作しているかを常に明確にしている。第三に、Rechartsによる多様なデータビジュアライゼーション(折れ線・棒・円・レーダーの4種)とshadcn/uiのコンポーネント群を組み合わせたUIは、教育現場における意思決定に必要な情報を視覚的に構造化して提示している。

現時点ではフロントエンドのみのプロトタイプであり、表示されるデータはすべてモックデータである。しかし、VIEW\_MAPレジストリパターンによるコンポーネント管理、TypeScriptの型安全性、およびuseStateによる状態管理の設計は、将来的なバックエンドAPI統合、認証基盤の導入、リアルタイムデータ連携への移行を阻害しない拡張性を有している。教育機関のDXを推進するにあたり、ユーザー体験の質を先行して確立し、段階的にシステム基盤を強化していくアプローチの有効性を、本実装は示していると考ええる。

## 第13章 技術スタックと開発方法論

### 13.1 フレームワーク選定の理論的根拠

本システムの基盤技術として、Next.js 16.1.6 (App Router) および React 19.2.4 を採用した。フレームワーク選定にあたっては、教育機関における長期的な保守運用性、開発生産性、および将来的な機能拡張性の3軸から総合的に評価を行った。

Next.jsは、Vercel社が開発するReactベースのフルスタックフレームワークであり、Server Components、App Router、自動コード分割、画像最適化等のパフォーマンス最適化機能を標準で提供する。特にApp Routerは、ファイルベースのルーティングにレイアウトのネスト、ローディングUI、エラーハンドリングを統合的に扱える設計であり、教育ポータルのような多画面・多ロールのアプリケーションに適した構造を提供する。

ただし、本プロトタイプでは意図的に「use client」ディレクティブを主体としたクライアントサイドレンダリング(CSR)方式を採用している。これは、プロトタイピング段階におけるインタラクティブUIの迅速な検証を優先したためである。``app/page.tsx`` がアプリケーション全体のエントリーポイントとして機能し、ロール切替はクライアントサイドのタブUIにより実現される。将来的なバックエンド統合時には、Server Componentsへの段階的移行により、初期表示速度の改善とサーバーサイドでのデータフェッチングの最適化が見込まれる。

React 19.2.4は、Concurrent Rendering、Automatic Batching、Transitions APIなどの機能を提供する。本システムでは、useStateによるローカル状態管理を基本とし、56のビューコンポーネント(管理者14画面、教員15画面、事務方15画面、学生12画面)の切り替えを`VIEW\_MAP`レジストリパターンにより実現している。このパターンは、``Record<string, ComponentType>`` 型による型安全なコンポーネント解決を保証し、ナビゲーションIDからビューコンポーネントへの一対一マッピングを宣言的に管理する。

``app/layout.tsx`` では、Noto Sans JPフォント(ウェイト: 300/400/500/600/700)の最適化読み込み、パフォーマンス計測機能の統合、およびHTML言語属性のja設定を行い、日本語教育機関向けアプリケーションとしての基盤構成を確立している。なお、プロトタイプ段階ではVercel Analyticsを計測基盤として使用しているが、本番運用時には学内ネットワーク内での計測基盤への移行、またはオプトイン方式による外部送信の同意取得を前提とする。外部サービスへのデータ送信を伴う機能は、設定により無効化可能な設計としている。

### 13.2 UIコンポーネントライブラリの設計思想

UIコンポーネント基盤として、shadcn/ui(New Yorkスタイル)を採用した。shadcn/uiは、従来のnpmパッケージ型ライブラリとは異なり、コンポーネントのソースコードをプロジェクトに直接コピーしてカスタマイズする方式を採用している。この設計により、外部ライブラリへのロックインを回避しつつ、Radix UIプリミティブが提供するWAI-ARIA準拠のアクセシビリティ機能を継承できる。

本システムでは、``components/ui/`` ディレクトリに56のファイル(UIコンポーネントおよび関連フック)を配置している。主要コンポーネントの用途と適用箇所を以下に示す。

**レイアウト・構造系:** Card(KPIカード、プロフィールカード等の情報コンテナ)、Tabs(ロール切替、権限設定/アクティビティ切替)、ScrollArea(サイドバーナビゲーション)、Separator(セクション区切り)、Resizable(パネルレイアウト)。

**データ表示系:** Table(学生一覧、面談記録、監査ログ)、Badge(ロールラベル、ステータス表示、Gate レベル表示)、Avatar(ユーザーアイコン)、Progress(進捗バー)、Skeleton(ローディングブレースホルダ)。

**入力・操作系:** Button(各種操作)、Input(テキスト入力)、Select(モデル選択、フィルタ)、Switch(権限トグル、機能有効化)、Slider(Gate閾値、Temperature設定)、Checkbox(一括選択)、Calendar(日付選択)。

**フィードバック系:** Dialog(確認ダイアログ)、Alert(警告表示)、Toast/Sonner(通知)、Tooltip(ヒント表示)、Popover(補足情報)。



class-variance-authority(CVA)を用いたバリエーション管理により、各コンポーネントのサイズ・カラー・状態バリエーションを型安全に定義している。例えばBadgeコンポーネントは、ロール識別(紫/緑/黄橙/青)、アラートレベル(danger/warning/info)、Gateレベル(L=0.2/L=0.3/L=0.7)など、文脈に応じた視覚的区別を一貫したAPIで提供する。

アイコンライブラリとして Lucide React を採用し、`portal-sidebar.tsx`において19種類のアイコン(LayoutDashboard、Users、UserCheck、FolderOpen、Calendar、FileText、Bell、BarChart3、Settings、BookOpen、GraduationCap、ClipboardList、Bot、Target、School、FileSearch、Send、UserCircle、Trophy)をナビゲーションラベルに対応付ける`iconMap`を定義している。この宣言的マッピングにより、ナビゲーション項目の追加・変更時にもアイコン割り当てを一元管理できる。

## 13.3 スタイリングシステムの技術的詳細

CSSフレームワークとして Tailwind CSS 4.2 を`@tailwindcss/postcss`プラグイン経由で利用している。Tailwind CSSのユーティリティファースト手法は、コンポーネント単位のスタイル定義を促進し、CSSの名前空間衝突を原理的に排除する。

テーマカラーの定義にはOKLch色空間(Oklab Lightness-Chroma-Hue)を採用した。OKLchは、人間の知覚に基づく均一な色空間であり、従来のHSL/RGBと比較して、明度変更時の色相シフトが発生しない特性を持つ。`app/globals.css`において、`.root`セレクトに30以上のCSS変数(`--background`、`--foreground`、`--primary`、`--card`、`--muted`、`--accent`、`--destructive`、`--chart-1`~`--chart-5`等)をOKLch値で定義し、`.dark`セレクトでのオーバーライドによりダークモード対応を実現している。

ロール固有のカラーシステムは、本システムの中核的なUI設計要素である。4つのロールに対し、以下のCSS変数とユーティリティクラスを定義している。

- **管理者(admin):** `--role-admin` = oklch(0.45 0.18 265)(紫) — 権限管理・システム設定の権威性を表現
- **教員(teacher):** `--role-teacher` = oklch(0.50 0.16 155)(緑) — 教育活動・成長支援の安心感を表現
- **事務方(office):** `--role-office` = oklch(0.62 0.18 55)(黄橙) — 事務処理・手続き管理の注意喚起を表現
- **学生(student):** `--role-student` = oklch(0.50 0.14 240)(青) — 学習活動・自己管理の信頼感を表現

各ロールカラーは、`ROLE\_CONFIG`の`colorClass`(`text-role-admin`等)、`bgClass`(`bg-role-admin`等)、`lightBgClass`(`bg-role-admin-light`等)として参照され、サイドバー、ヘッダー、タブ、KPIカードなど全てのロール依存UIに一貫して適用される。`roleTabStyles`、`roleActiveMap`、`roleHoverMap`の3つのスタイルマップにより、インタラクション状態(アクティブ、ホバー、非選択)に応じたロールカラーの適用を制御している。

条件付きクラス結合には、`lib/utls.ts`で定義される`cn()`ユーティリティ関数(`clsx` + `tailwind-merge`)を使用する。`clsx`による条件分岐と`tailwind-merge`によるクラス優先度解決を組み合わせることで、Tailwind CSSのユーティリティクラス競合を安全に処理する。

## 13.4 データ可視化の実装方針

統計・レポート画面のデータ可視化には、Recharts 2.15.0ライブラリを採用した。Rechartsは、D3.jsをベースとしたReact向け宣言的チャートライブラリであり、SVGベースの描画によりレスポンスかつインタラクティブなグラフを提供する。

本システムで使用するチャートタイプは以下の4種である。

- **LineChart:** 成績推移、出願件数推移などの時系列トレンドの可視化
- **BarChart:** クラス別比較、進路先別志望者数などのカテゴリ間比較
- **PieChart:** 進路種別分布、リスクレベル分布などの構成比表示
- **RadarChart:** 学生の能力バランス、各科目の達成度などの多軸評価

全チャートは`ResponsiveContainer`でラップし、親要素のサイズに追従するレスポンス表示を実現している。データ構造は`{ name: string, value: number, fill: string }`を基本とし、チャートタイプに応じてプロパティを拡張する統一的なインターフェースを維持している。

## 13.5 フォーム・バリデーション基盤

フォーム管理ライブラリとしてreact-hook-form 7.54.1およびスキーマバリデーションライブラリとしてZod 3.24.1を依存関係に含めている。`@hookform/resolvers`によりZodスキーマとreact-hook-formの統合が可能である。

現プロトタイプ段階では、フォーム入力の多くがuseStateによるコントロールドインプットとして実装されている。例えば、`admin-ai-settings.tsx`のモデル設定(primaryModel、fallbackModel、temperature、maxTokens、timeout)はuseStateで管理され、Select/Sliderコンポーネントの`onValueChange`コールバックで更新される。将来的なバックエンド接続時には、react-hook-form + Zodスキーマによる宣言的バリデーションへの移行が計画されており、入力値の型安全な検証、エラーメッセージの自動生成、フォーム状態の最適化されたリレンダリング制御が実現される。

## 13.6 状態管理アーキテクチャ

本プロトタイプの状態管理は、ReactのuseStateフックによるローカルコンポーネント状態を基本とする。グローバル状態管理ライブラリ(Redux、Zustand、Jotai等)は意図的に未導入としている。

現在の状態管理構造は3層に分類される。

**アプリケーション状態:** `app/page.tsx`における`activeRole` (現在のロール)と`activeNavId` (現在のナビゲーション位置)。これらはルートコンポーネントで管理され、`PortalHeader`、`PortalSidebar`、および各ビューコンポーネントにpropsとして伝播する。

**ビュー状態:** 各ビューコンポーネント内のuseStateによるローカル状態。例として、`admin-user-detail.tsx`の`permissionState` (10権限のトグル状態)や`accountActive` (アカウント有効/無効)、`admin-ai-settings.tsx`の`gateSettings`、`permissions`、`workflows`、`modelConfig`が該当する。

**UIインタラクション状態:** サイドバーの開閉(`sidebarOpen`)、タブの選択状態(Radix UIのTabsが内部管理)など、UIフレームワークが暗黙的に管理する状態。

将来的なバックエンド統合時には、サーバー状態管理にTanStack Query (React Query)を、クライアント状態管理にZustandをそれぞれ導入し、関心の分離を明確化する設計方針を策定している。

## 13.7 開発環境・ビルドシステムの構成

パッケージマネージャにはpnpmを採用した。pnpmは、ハードリンクとシンボリックリンクを活用したコンテンツアドレスブルストレージにより、ディスク使用量の削減とインストール速度の向上を実現する。

TypeScript 5.7.3を型検査に使用するが、プロトタイピング速度を優先するため、`next.config.mjs`において`typescript.ignoreBuildErrors: true`を設定し、ビルド時の型エラーを一時的に無視している。この設定は、プロトタイプから本番移行時に段階的に解除し、完全な型安全性を確保する計画である。

パスエイリアス`@/\*`をプロジェクトルートにマッピングし、インポートパスの簡潔化と移植性を確保している。ESLintによる静的解析を`pnpm lint`コマンドで実行可能であり、コード品質の継続的な検証を支援する。

プロトタイプ段階では、Vercel Analyticsを`@vercel/analytics`パッケージにより統合し、`app/layout.tsx`の`<Analytics />`コンポーネントでページビュー・Web Vitals (LCP、INP、CLS等)の自動計測を行っている。これにより、開発段階でのパフォーマンスモニタリングの計測コンポーネントが配置されている。ただし、本番運用においては、個人情報保護法における外部送信規制(電気通信事業法第27条の12等)の観点から、学内運用を前提とした計測基盤への移行、または利用者への事前通知・同意取得のうえでの外部サービス利用を選択する必要がある。計測機能は環境変数により無効化可能な実装としている。

## 13.8 AI支援開発プロセスと開発方法論

本システムの開発プロセスは、AI支援開発ツールを積極的に活用した新しい方法論に基づいている。

**初期プロトタイプ生成:** Vercel v0 (AIデザインツール)により、UIデザインの初期プロトタイプを自動生成した。v0は自然言語によるUI仕様記述からReact/Tailwindコンポーネントを生成するツールであり、デザインとコードの距離を大幅に縮小する。初回コミット('Initial commit from v0')にその成果が記録されている。

**AI支援リファクタリング:** Claude Code (Anthropic社)によるAI支援開発を通じて、v0生成コードの構造化、型安全性の向上、ロール別ビューの分離、View Registryパターンの導入などを反復的に実施した。claudei.mdファイルにプロジェクトのアーキテクチャ知識を記述し、AIEージェントのコンテキスト理解を最適化するドキュメント駆動のAI協調開発を実践している。

**反復的改善サイクル:**「仕様記述 → AI生成 → レビュー → 修正指示 → 再生成」のサイクルを短期間で繰り返し、56画面のプロトタイプを効率的に構築した。このプロセスは、従来のウォーターフォール型やアジャイル型の開発手法とは異なる、AIとの協調によるプロタイピング手法として位置づけられる。

13.9 テスト戦略と品質保証体制

ソフトウェア品質の確保は、教育機関向けシステムにおいて重要な課題である。生徒の個人情報を扱い、進路指導という重要な意思決定を支援するシステムであるため、不具合によるリスクには十分な注意が求められる。本節では、本システムに適用するテスト戦略の全体像を述べる。

13.9.1 テストピラミッドの適用

Martin Fowler (2012) が提唱するテストピラミッドモデルに基づき、テストを3層に構造化する。

**単体テスト (Unit Tests):** Vitestを採用する。VitestはViteベースの高速テストランナーであり、ES Modules ネイティブ対応、TypeScriptのゼロ設定サポート、Jest互換APIを提供する。React Testing Library (@testing-library/react) と組み合わせ、56のビューコンポーネントおよびユーティリティ関数に対する単体テストを実装する。特に、以下の領域を重点テスト対象とする。

テスト対象	テスト観点	期待カバレッジ
VIEW_MAPレジストリ	全ナビゲーションIDに対する正しいコンポーネント解決	100%
ROLE_CONFIG	4ロールの設定整合性 (ラベル、カラー、ナビゲーション項目数)	100%
cn()ユーティリティ	クラス結合・競合解決の正確性	100%
KPICard	データバインディング、数値フォーマット、トレンド表示	95%以上
Gate閾値ロジック	L=0.2/0.3/0.7の判定境界値テスト	100%

表13-1: 単体テストの重点対象と期待カバレッジ

**統合テスト (Integration Tests):** コンポーネント間の連携動作を検証する。具体的には、ロール切替時のサイドバー・ヘッダー・ビューコンテンツの連動更新、ナビゲーション遷移時のビューレジストリ解決、テーマ切替 (ライト/ダーク) 時のCSS変数伝播などを対象とする。React Testing Libraryの`render`関数と`userEvent`ライブラリにより、ユーザー操作をシミュレーションしたテストを実装する。

**E2Eテスト (End-to-End Tests):** Playwrightを採用する。Playwrightは、Chromium、Firefox、WebKitの3エンジンを単一APIでクロスブラウザテストできるフレームワークであり、モバイルエミュレーション、ネットワークインターセプション、スクリーンショット比較機能を備える。主要なE2Eシナリオとして以下を定義する。

- 45. **ロール切替フロー:** 4ロールの切替操作とダッシュボード表示の正確性
- 46. **ナビゲーション全経路:** 56画面への到達可能性テスト
- 47. **レスポンス表示:** デスクトップ (1920×1080)、タブレット (768×1024)、モバイル (375×812) の3ブレイクポイント
- 48. **アクセシビリティ検証:** axe-core (@axe-core/playwright) による WCAG 2.1 AA準拠の自動検証

### 13.9.2 アクセシビリティテスト

教育機関のシステムとして、障害者差別解消法(2016年施行、2024年改正)の合理的配慮義務への対応は不可欠である。axe-coreエンジンをPlaywrightテストに統合し、全56画面に対する自動アクセシビリティ監査を実施する。検査項目には、色コントラスト比(WCAG 2.1 Level AA: 4.5:1以上)、キーボードナビゲーション、ARIAラベルの適切性、フォーカス管理が含まれる。

shadcn/uiが採用するRadix UIプリミティブは、WAI-ARIA Authoring Practices 1.2に準拠したアクセシビリティ機能を標準で提供するが、カスタムコンポーネント(KPICard、AlertList、ActivityFeed等)については個別にARIA属性を検証・補完する必要がある。

### 13.9.3 視覚回帰テスト

UIの意図しない変更を検出するため、Playwrightのスクリーンショット比較機能を活用した視覚回帰テスト(Visual Regression Testing)を導入する。各ロールのダッシュボード画面、主要な操作画面のスクリーンショットをベースラインとして保存し、変更時の差分を自動検出する。閾値は0.1%(ピクセル差分率)に設定し、意図的なデザイン変更時はベースラインを更新するワークフローとする。

## 13.10 CI/CDパイプラインの設計

継続的インテグレーション/継続的デリバリー(CI/CD)パイプラインは、コード品質の維持とデプロイメントの自動化を担う重要なインフラストラクチャである。

### 13.10.1 GitHub Actionsワークフロー

バージョン管理にはGitHub(プライベートリポジトリ)を使用し、CI/CDにはGitHub Actionsを採用する。以下の3つのワークフローを定義する。

① **CI(Pull Request時)**: プルリクエストの作成・更新をトリガーとし、以下のジョブを並列実行する。

- `lint`: ESLint静的解析(`pnpm lint`)
- `typecheck`: TypeScript型検査(`tsc --noEmit`、将来的に`ignoreBuildErrors`解除後)
- `unit-test`: Vitestによる単体テスト + カバレッジレポート生成
- `build`: Next.js本番ビルド(`pnpm build`)
- `e2e-test`: Playwrightによるスモークテスト(主要経路のみ)

② **CD(mainブランチマージ時)**: mainブランチへのマージをトリガーとし、Vercelへの自動デプロイを実行する。デプロイ後にE2Eフルテストを実行し、失敗時は自動ロールバックする。

③ **Nightly(日次スケジュール実行)**: 毎日深夜2:00(JST)に実行し、全テストスイート + アクセシビリティ監査 + 依存関係の脆弱性スキャン(`pnpm audit`)を行う。結果はSlack通知により開発チームに共有する。

### 13.10.2 ブランチ戦略

GitHub Flowをベースとした簡素なブランチ戦略を採用する。`main`ブランチを本番環境と同期させ、機能開発は`feature/`ブランチ、バグ修正は`fix/`ブランチで行う。プルリクエストのマージにはCIの全ジョブ成功を必須条件(Branch Protection Rules)とし、最低1名のコードレビュー承認を要求する。

教育機関の運用スケジュール(学期開始・終了、入試期間、出願期間)を考慮し、重要な時期にはデプロイフリーズ期間を設定するデプロイメントカレンダーを運用する。

## 13.11 デプロイメントアーキテクチャ

### 13.11.1 Vercel Edge Networkの活用

本システムのホスティング基盤として、Vercel Platformを選定した。Vercelは、Next.jsの開発元が提供するプラットフォームであり、フレームワークとの最高水準の互換性を保証する。主要な技術的利点は以下のとおりである。



機能	技術的詳細	教育機関への恩恵
Edge Network	全世界30以上のリージョンでの静的アセット配信	日本国内の低遅延アクセス(東京・大阪PoP)
Serverless Functions	Node.jsランタイムのオンデマンド実行	バックエンド統合時のサーバー管理不要化
Preview Deployments	PRごとの独立した検証環境の自動生成	教職員によるUI変更の事前確認
Automatic HTTPS	Let's Encrypt証明書の自動発行・更新	SSL/TLS設定の運用負荷ゼロ化
Analytics	Web Vitals自動計測(Real Experience Score)	パフォーマンス劣化の早期検知

表13-2: Vercel Platformの機能と教育機関への恩恵

### 13.11.2 環境分離戦略

3つの環境を運用し、段階的な品質ゲートを設ける。

- **Development:** ``feature/*`` ブランチのPush時に自動生成されるPreview環境。開発者および担当教員が機能検証に使用。
- **Staging:** ``staging`` ブランチへのマージ時にデプロイ。全教職員がアクセス可能なUAT(ユーザー受入テスト)環境。入試・出願関連機能のリリース前検証に使用。
- **Production:** ``main`` ブランチへのマージ後、Staging環境でのE2Eテスト成功を条件として自動デプロイ。全ユーザーが利用する本番環境。

各環境には環境変数(``NEXT_PUBLIC_ENVIRONMENT``)を設定し、ヘッダーバッジによる環境識別を可能とする。本番環境以外ではデバッグツール(React DevTools Profiler連携)を有効化する。

### 13.11.3 CDNキャッシュ戦略

静的アセット(JavaScript バンドル、CSS、フォント、画像)には``immutable`` キャッシュヘッダーを設定し、コンテンツハッシュによるキャッシュバスターgingを適用する。Next.jsの``_next/static/``パスに配置されるアセットは自動的にlong-term cachingの対象となる。

動的コンテンツ(将来的なAPIレスポンス)には、``stale-while-revalidate``戦略を適用し、キャッシュからの即時レスポンスとバックグラウンドでの最新データ取得を両立する。教育データの特性上、リアルタイム性よりも一貫性と可用性を優先する設計方針とする。

## 13.12 バックエンド将来アーキテクチャ

現プロトタイプはフロントエンドのみの実装であるが、本番稼働に向けたバックエンドアーキテクチャの設計方針を本節に記述する。

### 13.12.1 BaaS基盤の選定: Supabase

バックエンド基盤として、Supabaseを選定する方針である。Supabaseは、PostgreSQL データベース、認証(GoTrue)、リアルタイムサブスクリプション(Realtime)、ストレージ(S3互換)、Edge Functions(Deno Runtime)を統合的に提供するオープンソースのBackend-as-a-Service(BaaS)プラットフォームである。

選定理由は以下のとおりである。

49. **PostgreSQL基盤:** リレーショナルデータベースの堅牢性と、JSON/JSONB型によるスキーマレスデータの柔軟な格納を両立。教育データの複雑なリレーション(生徒-クラス-教員-面談-志望校)のモデリングに適する。
50. **Row Level Security(RLS):** PostgreSQLのRLS機能により、データベースレベルでのロールベースアクセス制御を実現。4ロール(管理者/教員/事務方/学生)の権限分離を、アプリケーションロジックではなくデータベースポリシーとして宣言的に定義できる。
51. **認証基盤:** メールアドレス/パスワード認証に加え、SAML 2.0/OIDC対応により、学校法人の既存Active Directoryとのシングルサインオン(SSO)統合が可能。

52. **リアルタイム機能**: WebSocketベースのリアルタイムサブスクリプションにより、Gate承認通知、アラート更新、チャット機能のリアルタイム配信を実現。
53. **セルフホスティング可能**: Docker Compose構成でのオンプレミス展開が可能であり、教育機関のセキュリティポリシーに応じてクラウド/オンプレミスの柔軟な選択が可能。

### 13.12.2 データベーススキーマ設計方針

教育データの特性を踏まえ、以下のスキーマ設計原則を採用する。

`` -- 主要テーブル構成(概念設計) students -- 生徒基本情報(学籍番号、氏名、クラス、入学年度) teachers -- 教員情報(教員ID、担当科目、担任クラス) career\_records -- 進路指導記録(面談日時、内容、Gate承認状態) applications -- 出願情報(志望校、出願状況、合否結果) risk\_assessments -- リスク評価(エージェント判定、スコア、根拠) gate\_approvals -- Gate承認ログ(リクエスト、承認者、承認レベル) ai\_interactions -- AI操作ログ(エージェントID、入力、出力、処理時間) audit\_trail -- 監査証跡(操作者、操作内容、タイムスタンプ) ``

特に`audit\_trail`テーブルは、第16章で述べた監査可能性の要件を満たすため、全ての書き込み操作に対するトリガーベースの自動記録を実装する。PostgreSQLの`BEFORE INSERT/UPDATE/DELETE`トリガーにより、変更前後の値を含む完全な監査ログを生成する。

### 13.12.3 LLM API統合アーキテクチャ

10のAIエージェントおよび2つのAgent Teamが使用するLLM(大規模言語モデル)のAPI統合は、以下のアーキテクチャで実装する。

**API Gateway層**: Supabase Edge Functions(Deno Runtime)により、LLM APIへのプロキシレイヤーを構築する。この層で、APIキーの安全管理、リクエストのレート制限、入出力のサニタイズ、コスト追跡を一元的に処理する。

**モデル選択戦略**: `admin-ai-settings.tsx`で実装されたprimaryModel/fallbackModelの切替機構を、サーバーサイドに移行する。エージェントの要求精度とレイテンシ要件に応じて、以下のモデル割り当てを行う。

エージェントカテゴリ	推奨モデル	選定理由
Guardian(守る)	高精度モデル(例: GPT-4o, Gemini Sonnet等)	高精度な異常検知と自然言語理解
Tutor(育てる)	高速モデル(例: GPT-4o-mini, Gemini Haiku等)	低レイテンシの対話応答
Admin(回す)	高速モデル(例: GPT-4o-mini, Gemini Haiku等)	定型処理の高速実行
Management(導く)	最高精度モデル(例: GPT-4o, Gemini Opus等)	複雑な意思決定支援の高精度推論

表13-3: エージェントカテゴリ別のLLMモデル割り当て方針

**コスト最適化**: Token使用量の監視とモデルの動的切替により、月間LLM APIコストを制御する。低頻度・高精度タスク(リスク判定、戦略シミュレーション)には高精度モデル、高頻度・低レイテンシタスク(チャット応答、書類チェック)には高速モデルを割り当て、コスト効率と品質のバランスを最適化する。

### 13.12.4 認証・認可アーキテクチャ

教育機関の既存IT基盤との統合を前提とした認証・認可アーキテクチャを設計する。

**認証フロー**: Supabase AuthのSAML 2.0 IdP統合により、学校法人のMicrosoft Entra ID(旧Azure AD)とのSSO連携を実現する。教職員はMicrosoft 365アカウント、学生は学校発行のGoogleアカウントでの認証を想定する。

**認可モデル**: RBAC(Role-Based Access Control)を基本とし、4ロールに対応するデータベースロールをPostgreSQL RLSポリシーとして定義する。Gate承認機構は、RBACを拡張するAttribute-Based Access Control(ABAC)の要素を含み、AI判定のリスクレベル属性に基づく動的な権限昇格を実現する。

**セッション管理:** JWTベースのステートレスセッションを採用し、トークンの有効期限を1時間(アクセストークン)/7日間(リフレッシュトークン)に設定する。機微情報へのアクセス時には、多要素認証(MFA)の追加認証を要求する設計とする。

## 13.13 パフォーマンス最適化戦略

### 13.13.1 Core Web Vitalsの最適化目標

Googleが定義するCore Web Vitals指標を、教育機関向けWebアプリケーションのパフォーマンス基準として採用する。以下の目標値を設定する。

指標	説明	目標値	現状(プロトタイプ)
LCP (Largest Contentful Paint)	最大コンテンツの描画時間	≤ 2.5秒	測定中
INP (Interaction to Next Paint)	インタラクション応答時間	≤ 200ms	測定中
CLS (Cumulative Layout Shift)	レイアウトの視覚的安定性	≤ 0.1	測定中
TTFB (Time to First Byte)	最初のバイト到達時間	≤ 800ms	測定中

表13-4: Core Web Vitals最適化目標

Vercel Analyticsによるリアルユーザーモニタリング(RUM)データを継続的に収集し、目標値からの逸脱を検知した場合は、スプリント内での優先的な対応を行う計画である。

### 13.13.2 React Server Componentsへの段階的移行

現プロトタイプは"use client"ディレクティブによるクライアントサイドレンダリング(CSR)を主体としているが、バックエンド統合に合わせてReact Server Components(RSC)への段階的移行を計画している。移行戦略は以下の3フェーズで実施する。

**Phase 1 — レイアウトのServer Component化:** `app/layout.tsx`のフォント読み込み、メタデータ生成、テーマ設定をServer Componentとして最適化する。これにより、クライアントサイドJavaScriptバンドルからフォント設定やHTML属性設定のコードが除外され、初回読み込みのバンドルサイズが削減される。

**Phase 2 — データフェッチングのサーバーサイド移行:** ダッシュボードのKPIデータ、学生一覧、面談記録などのデータ取得を、Server Componentでの`async/await`パターンに移行する。これにより、クライアントサイドでのローディング状態管理が不要となり、ウォーターフォールリクエストの排除とストリーミングSSR(Suspenseとの統合)による段階的UI表示が実現される。

**Phase 3 — 動的UIのClient Component最適化:** ロール切替タブ、サイドバーナビゲーション、フォーム入力など、インタラクティブ性が必要なコンポーネントのみを"use client"として維持し、Server/Client Componentの境界を最適化する。React 19のuseOptimisticフックを活用し、楽観的UIアップデートによるUX向上を図る。

### 13.13.3 バンドルサイズ最適化

Next.jsの自動コード分割(Automatic Code Splitting)機能により、各ルートのJavaScriptバンドルは個別チャックとして生成される。本システムの56画面構成においては、VIEW\_MAPレジストリパターンと`React.lazy()`/`dynamic()`によるコンポーネントの遅延読み込みを組み合わせ、初期バンドルサイズの最小化を図る。

```
``typescript // 遅延読み込みによるコード分割の概念実装
const VIEW_MAP: Record<string, () => Promise<{ default: ComponentType }>> = { "student-dashboard": () => import("./views/student-dashboard"), "student-career-info": () => import("./views/student-career-info"), // ... 他のコンポーネント }; ``
```

Rechartsライブラリは、チャートを含む画面でのみ動的インポートされる設計とし、チャート不使用画面でのバンドル肥大化を防止する。`next/dynamic`の`ssr: false`オプションにより、サーバーサイドレンダリング時のRecharts初期化エラーを回避しつつ、クライアントサイドでの遅延読み込みを実現する。

13.13.4 画像・フォント最適化

**フォント最適化:** `next/font/google`によるNoto Sans JPフォントの最適化では、CSS `size-adjust`プロパティによるフォールバックフォントとのメトリクス調整を自動適用し、フォント読み込み完了時のレイアウトシフト(CLS)を最小化する。5ウェイト(300/400/500/600/700)をサブセット化し、日本語フォントの大容量問題に対応する。

**画像最適化:** 将来的に画像コンテンツ(学校写真、企業ロゴ、ポートフォリオ画像等)を扱う際には、`next/image`コンポーネントによるWebP/AVIF自動変換、レスポンシブサイズ生成、遅延読み込み(`loading="lazy"`)を適用する。Vercel Image Optimization APIにより、オリジン画像の変換・キャッシュ・配信を自動化する。

13.13.5 パフォーマンスバジェット

継続的なパフォーマンス管理のため、以下のパフォーマンスバジェットを設定し、CI/CDパイプラインでの自動監視を行う。

指標	バジェット	計測ツール
初期JavaScriptバンドル	≤ 200KB (gzip後)	`next build` 解析
総JavaScript転送量	≤ 500KB (gzip後)	Lighthouse CI
CSS総量	≤ 50KB (gzip後)	`next build` 解析
Lighthouse Performance Score	≥ 90	Lighthouse CI
Lighthouse Accessibility Score	≥ 95	Lighthouse CI

表13-5: パフォーマンスバジェット定義

Lighthouse CIをGitHub Actionsワークフローに統合し、プルリクエストごとにパフォーマンスバジェットの遵守を自動検証する。バジェット超過時はCIを失敗とし、マージを禁止する。

本章で述べた技術選定は、教育機関のDX推進において「持続可能な技術基盤」を構築することを第一の目標としている。オープンソースエコシステムへの依存、標準化された開発ツールチェーン、そしてAI支援開発手法の活用により、専門的な開発チームを持たない教育機関においても、技術的負債を最小化しながらシステムの継続的な改善を実現する基盤を設計した。



## 第14章 データモデル・セキュリティ設計

### 14.1 型定義によるデータモデルの形式化

本システムのデータモデルは、TypeScriptの型システムを活用して`lib/types.ts`に集約的に定義されている。型定義による形式化は、コンパイル時の型検査によりデータ構造の整合性を保証し、ランタイムエラーの予防に寄与する。以下に、各型定義の設計意図と教育データモデリングにおける意義を考察する。

#### 14.1.1 Role型によるアクセス主体の厳密な定義

```
``typescript type Role = "admin" | "teacher" | "office" | "student" ``
```

Role型は、TypeScriptのUnion Literal Types(和型リテラル型)により、システムにアクセスする主体を4つのリテラル値に限定する。この定義は、ロールベースアクセス制御(RBAC: Role-Based Access Control)の基盤となる。

教育機関の組織構造において、管理者(admin)はシステム全体の設定・ユーザー管理を担い、教員(teacher)は学生指導・面談・進路支援の中核を担う。事務方(office)は書類管理・データ入力・統計処理を行い、学生(student)は自身の情報閲覧・目標設定・面談予約を行う。これら4ロールの明確な型定義により、各ロールの責務境界がコードレベルで明示される。

Union Literal Typesの採用により、無効なロール文字列(例: "superadmin"、"guest")がコンパイル時に検出される。これは、セキュリティ上の「最小権限の原則」を型システムにより設計段階から志向するアプローチである。

#### 14.1.2 NavItem インターフェースによるナビゲーションモデル

```
``typescript interface NavItem { id: string label: string icon?: string active?: boolean } ``
```

NavItemインターフェースは、各ロールのナビゲーション項目を4つのプロパティで定義する。`id`プロパティには、ロール識別プレフィックスを含む命名規則が適用されている。具体的には、管理者は「a-」、教員は「t-」、事務方は「o-」、学生は「s-」のプレフィックスを持つ。

このプレフィックス方式は、ナビゲーションIDからロールを逆引き可能にし、`VIEW\_MAP`レジストリにおけるコンポーネント解決を一意に決定する。`icon`と`active`はオプションプロパティ(`?`修飾子)として定義され、アイコンマッピングは`portal-sidebar.tsx`の`iconMap`に委譲される設計となっている。

#### 14.1.3 KPIData インターフェースによる業績指標モデル

```
``typescript interface KPIData { label: string value: string | number change?: string trend?: "up" | "down" | "neutral" } ``
```

KPIDataは、各ロールのダッシュボードに表示される重要業績評価指標を構造化する。`value`プロパティの`string | number`共用型は、数値("42"、"98.5%")と文字列("良好"、"要注意")の両方を許容する柔軟な設計である。`trend`プロパティは3値のUnion型("up"/"down"/"neutral")により、指標の方向性を分類する。

教育評価指標の設計においては、単純な数値だけでなく質的評価や方向性の情報が重要となる。例えば、「進路決定率78%(前月比 +5%、上昇傾向)」のような複合的な情報を単一のインターフェースで表現できる構造となっている。

#### 14.1.4 AlertItem インターフェースによるリスク通知モデル

```
``typescript interface AlertItem { id: string type: "danger" | "warning" | "info" message: string time: string } ``
```

AlertItemは、3段階の重要度分類(danger/warning/info)によるアラート通知を定義する。この3段階分類は、教育現場のリスク管理において以下のように対応する。

- **danger**: 出願締切超過、長期欠席、成績急降下など、即時対応を要する事象
- **warning**: 面談未実施、書類未提出、目標未達など、注意喚起を要する事象
- **info**: お知らせ更新、スケジュール変更、新機能追加など、情報伝達目的の通知

`time`プロパティには「3分前」「1時間前」などの相対時間表現を格納し、教育現場のリアルタイムな状況把握を支援する。

#### 14.1.5 ActivityItem インターフェースによる操作履歴モデル

```
``typescript interface ActivityItem { id: string user: string action: string time: string avatar?: string } ``
```

ActivityItemは、ダッシュボード上のアクティビティフィードに表示される操作履歴を構造化する。`user`と`action`の組み合わせにより「誰が何をしたか」を簡潔に表現し、教職員間の情報共有と協調作業の可視化を支援する。

#### 14.1.6 StudentRecord インターフェースによる学生進路モデル

```
``typescript interface StudentRecord { id: string name: string class: string tg: string careerStatus: string planA: string planB: string planC: string riskLevel: "green" | "yellow" | "red" } ``
```

StudentRecordは、進路指導の中核データモデルである。特筆すべき設計上の特徴は以下の2点である。

第一に、`planA`/`planB`/`planC`による3段階志望校モデルである。日本の高等学校における進路指導では、第一志望・第二志望・第三志望(安全校)の3層構造が慣行として定着しており、このドメイン知識をインターフェース設計に直接反映している。

第二に、`riskLevel`の3値定義("green"/"yellow"/"red")による信号機モデルである。緑は「順調」、黄は「要注意」、赤は「要対応」を示し、教員が一覧画面で瞬時にリスク状態を把握できる視覚的指標を提供する。この信号機メタファは、教育現場における直感的理解を促進する。

### 14.2 ROLE\_CONFIG集約管理パターン

```
``typescript const ROLE_CONFIG: Record<Role, { label: string; shortLabel: string; colorClass: string; bgClass: string; lightBgClass: string; navItems: NavItem[] }> = { / ... / } ``
```

ROLE\_CONFIGは、`Record<Role, Config>`ジェネリック型により、4ロール全てに対する設定が網羅的に定義されることをコンパイル時に保証する。ロールの追加・削除時には、ROLE\_CONFIGの更新が型エラーとして強制され、設定漏れを原理的に防止する。

各ロールの設定には、表示ラベル(`label`: "管理者"/"教員"/"事務方"/"学生")、短縮ラベル(`shortLabel`: "A"/"T"/"O"/"S")、3種類のカラークラス(テキスト色・背景色・淡背景色)、およびナビゲーション項目配列が含まれる。この集約管理により、ロール固有の振る舞いが単一の設定オブジェクトから導出され、コードベース全体の一貫性が維持される。

### 14.3 モックデータパターンと将来のAPI設計

#### 14.3.1 現状のモックデータアーキテクチャ

現プロトタイプでは、各ビューコンポーネント内にインラインモックデータを定義する方式を採用している。例えば、`admin-user-detail.tsx`では`userProfile`オブジェクト、`permissions`配列、`activityLog`配列がコンポーネントファイル内に直接記述されている。同様に、`admin-ai-settings.tsx`では`initialGateSettings`、`initialPermissions`、`initialWorkflows`、`auditLog`がコンポーネント内に定義されている。

このインラインモックデータ方式は、プロトタイプ段階において以下の利点を持つ。第一に、データとUIの近接配置によりプロトタイプの可読性が向上する。第二に、外部依存なしでコンポーネントが自立的に動作するため、個別画面の検証が容易である。第三に、モックデータがドメインモデルの仕様書として機能し、将来のAPI設計の入力となる。

#### 14.3.2 将来のRESTful API設計案

バックエンド統合時には、以下のエンドポイント体系を想定している。

管理者API群:

- `GET /api/admin/users` — ユーザー一覧取得

- `GET /api/admin/users/{id}` — ユーザー詳細取得
- `PUT /api/admin/users/{id}/permissions` — 権限更新
- `GET /api/admin/statistics` — 統計データ取得

#### 教員API群:

- `GET /api/teacher/students` — 担当学生一覧
- `GET /api/teacher/students/{id}/records` — 学生カルテ取得
- `POST /api/teacher/interviews` — 面談記録作成
- `GET /api/teacher/risk-alerts` — リスクアラート取得

#### 事務方API群:

- `GET /api/office/documents` — 書類一覧取得
- `POST /api/office/data-import` — データ取り込み
- `GET /api/office/statistics` — 統計データ取得

#### 学生API群:

- `GET /api/student/scores` — テストスコア取得
- `GET /api/student/career-info` — 進路先情報取得
- `PUT /api/student/goals` — 目標設定更新

#### AIエージェントAPI群:

- `POST /api/ai/agent/{id}/execute` — エージェント実行
- `GET /api/ai/audit-log` — 監査ログ取得
- `PUT /api/ai/gate-settings` — Gate設定更新

## 14.4 セキュリティ設計方針

### 14.4.1 ロールベースアクセス制御(RBAC)の設計

本システムのセキュリティモデルは、RBAC(Role-Based Access Control)を基盤とする。NIST(米国国立標準技術研究所)のRBACモデル(ANSI/INCITS 359-2004)を参照し、以下の4要素で構成する設計方針を採用している。

- **ユーザー(Users):** システムにアクセスする個人(教職員・学生)
- **ロール(Roles):** admin/teacher/office/studentの4種類
- **パーミッション(Permissions):** 各ロールに付与される操作権限
- **セッション(Sessions):** ユーザーがアクティブ化したロールの実行コンテキスト

`admin-user-detail.tsx`に実装された権限管理UIは、10種類のパーミッションを6つのカテゴリ(学生管理、面談管理、進路管理、出願管理、レポート、AIツール)に分類し、Switch UIコンポーネントによるトグル操作で個別に有効化/無効化できる。この粒度のパーミッション管理は、教育機関における「役職に応じた情報アクセスの差異」を適切にモデル化している。

### 14.4.2 Gate機構によるAI出力のアクセス制御

`admin-ai-settings.tsx`に実装されたGate System(ゲート機構)は、AIエージェントの判断に対する人間の関与度を3段階で制御する独自のセキュリティメカニズムである。

- **L=0.2(自動処理):** AIが自律的に判断・実行。低リスクの定型処理(例: 出席パターン解析、リスクアラート通知)に適用
- **L=0.3(上長承認):** AIが提案し、指定された承認者の確認後に実行。中リスクの処理(例: 学習プラン提案、面談サマリー確定、保護者レポート送付)に適用

- **L=0.7(人間判断必要)**: AIは参考情報のみ提示し、最終判断は必ず人間が行う。高リスクの判断(例: 成績評価フィードバック、カリキュラム変更提案、経営インサイト配信)に適用

さらに、エージェント別データアクセス権限マトリクスにより、10種類のAIエージェントに対して6種類のデータカテゴリ(学生基本、成績、出席、進路、面談、財務)へのアクセスを個別に制御する。例えば、「出席パターン解析」エージェント(Agent 3)は学生基本データと出席データのみにアクセスでき、成績・進路・面談・財務データへのアクセスは遮断される。この最小権限の原則に基づくデータアクセス制御は、AIの誤動作や情報漏洩リスクの局所化に寄与する。

承認ワークフロー設定(8種類)は、各ワークフローに対してGateレベル、承認者、自動承認期限を定義する。L=0.2のワークフロー(リスクアラート通知)は即時自動処理、L=0.3のワークフロー(学習プラン提案等)は24~72時間の自動承認期限付き、L=0.7のワークフロー(成績評価フィードバック等)は手動承認のみという段階的な制御を実現する設計である。

#### 14.4.3 監査ログによる操作追跡

セキュリティの事後検証手段として、2種類の監査ログ機能がUI上に実装されている。

第一に、`admin-user-detail.tsx`のアクティビティログは、個別ユーザーの操作履歴をモックデータとして日時・操作内容・IPアドレスの3項目で表示する。操作内容は対象者情報を含む粒度で設計されており、「誰が・いつ・どの学生の情報に・何をしたか」の追跡を想定している。

第二に、`admin-ai-settings.tsx`のAI操作監査ログは、AIエージェントの動作履歴をモックデータとして日時・エージェント名・操作・実行者・Gateレベル・結果・詳細の7項目で表示する。結果ステータス(承認済み/承認待ち/確認待ち/自動処理/却下)の5段階分類により、AI出力のライフサイクルの追跡を可能にする設計である。

### 14.5 認証・認可の将来設計

#### 14.5.1 現状の制約と認証未実装の理由

現プロトタイプでは、認証(Authentication)および認可(Authorization)の機能は未実装である。`app/page.tsx`におけるロール切替は、UIタブによるクライアントサイドの画面切替にすぎず、実際のアクセス制御は行われていない。これは、フロントエンドプロトタイプの段階においてUI/UX設計の検証を最優先し、認証基盤の構築を次フェーズに先送りしたことによる。

#### 14.5.2 認証基盤の候補技術

将来の認証基盤として、以下の技術オプションを検討している。

**NextAuth.js (Auth.js)**: Next.jsとの緊密な統合を持つ認証ライブラリ。OAuth 2.0/OpenID Connect対応、複数プロバイダ(Google、Microsoft、SAML等)のサポートにより、教育機関の既存IdP(Identity Provider)との連携が容易である。

**Supabase Auth**: PostgreSQLベースのBaaS(Backend as a Service)が提供する認証機能。Row Level Security(RLS)によりデータベースレベルでのロールベースアクセス制御を実現でき、本システムの4ロールモデルとの親和性が高い。

**SSO(シングルサインオン)対応**: 教育機関においては、Microsoft 365やGoogle Workspaceなどの既存認証基盤との統合が必須要件となる。SAML 2.0またはOpenID Connectプロトコルによるフェデレーション認証の実装を想定する。

#### 14.5.3 セッション管理とトークン方式

認証後のセッション管理には、JWT(JSON Web Token)ベースのステートレス方式を基本とし、リフレッシュトークンによるセッション延長メカニズムを組み合わせる設計を想定する。JWTペイロードにロール情報を含めることで、サーバーサイドでのロール検証を効率化し、ROLE\_CONFIGに基づくUIレンダリングとの整合性を確保する。

## 14.6 教育データの個人情報保護

### 14.6.1 法的枠組みとの適合性

本システムが取り扱う教育データは、個人情報保護法(令和5年改正法)および学校教育法に基づく管理が求められる。学生の成績情報、進路希望、面談記録、リスクレベル評価は、法定の「要配慮個人情報」(個人情報保護法第2条第3項)の類型には直接該当しないが、学生の能力評価や将来の進路に関わる機微性の高い個人情報であるため、本システムでは要配慮個人情報に準ずる保護措置を適用する設計方針を採用している。具体的には、以下の原則に基づく。

**利用目的の特定・制限:** 進路指導の目的に限定したデータ利用。StudentRecordの各フィールド(成績、志望校、リスクレベル)は進路指導業務の遂行に必要な範囲に限定される。

**データ最小化原則:** 各ロールが必要とする情報のみを表示する設計。学生ロールには他の学生の情報が表示されず、教員ロールには担当外の学生の詳細情報へのアクセスを制限する(将来実装予定)。

**安全管理措置:** 前述のRBAC、Gate機構、監査ログにより、技術的安全管理措置の基盤を構成する。

### 14.6.2 AIエージェントと個人情報保護の調和

AIエージェントによる個人データの処理には、特別な配慮が必要である。本システムのGate機構は、この課題に対する設計的回答として、以下の原則に基づいている。

**処理目的の限定:** 各エージェントのデータアクセス権限マトリクスにより、処理目的に必要なデータカテゴリのみへのアクセスを許可する。例えば、「時間割最適化」エージェント(Agent 10)は出席データのみを参照し、個々の学生の成績や進路情報にはアクセスしない。

**人間による監督の確保:** L=0.7のGateレベルにより、AIが生徒の成績評価や経営判断に影響する出力を生成した場合、必ず人間(教務部長、校長・教頭、管理者等)による確認・承認プロセスを経る。

**処理の透明性:** AI操作監査ログにより、「どのエージェントが・いつ・どのデータに・何をしたか」の記録を保持し、事後的な検証と説明責任の履行を可能にする。

### 14.6.3 データライフサイクル管理の将来構想

卒業生データの保存期間・削除方針、年度切替時のデータアーカイブ、バックアップと災害復旧については、今後のシステム本格運用時に教育機関の内規および文部科学省のガイドラインに基づいて詳細を策定する。現プロトタイプの実データ構造は、これらのライフサイクル管理要件を将来的に実装するための基盤として設計されている。

本章で考察したデータモデルとセキュリティ設計は、教育機関におけるAI活用と個人情報保護の両立という課題に対し、型安全なデータモデリング、多層的なアクセス制御、段階的な人間関与とメカニズム、および包括的な監査ログという4つの設計原則により応答するものである。これらの設計は、現時点ではフロントエンドプロトタイプのレベルに留まるが、将来のバックエンド実装においてもアーキテクチャの骨格として機能する見通しである。



## 第15章 導入効果の定量的分析

### 15.1 評価フレームワーク

教育AI基盤「本システム」の導入効果を体系的に評価するにあたり、本研究では4つの評価軸を設定した。第一に「業務時間」の観点から、教職員の業務構造がAI導入前後でどのように変容するかを測定する。第二に「教育の質」の観点から、在籍率・進路決定率・偏差値等の教育成果指標の推移の目標設定を概説する。第三に「意思決定精度」の観点から、AIエージェントの推論精度およびリスク検知の正確性を検証する。第四に「ステークホルダー満足度」の観点から、教員・事務職員・学生・保護者の各利害関係者が感じるシステムの有用性を評価する。

これら4軸の評価にあたり、以下のKPI(Key Performance Indicator)を定義した。業務時間については、進路面談準備時間、通知表・レポート作成時間、リスク検知所要時間、時間割作成時間をそれぞれ測定する。教育の質については、在籍率、進路決定率(3年生)、平均偏差値、模試受験率、戦略策定率を指標とする。意思決定精度については、各AIエージェントの推論精度(accuracy)、月間利用回数、平均応答時間を測定する。ステークホルダー満足度については、5段階リッカート尺度による満足度スコアを基本指標とする。

測定方法としては、プロトタイプに実装されたモックデータおよびUIコンポーネントに組み込まれたKPI表示機能を基盤とし、将来的な実運用データへの移行を前提とした測定フレームワークを構築している。現時点ではプロトタイプ段階であるため、本章の定量的分析はシミュレーションデータに基づく推計値であることに留意されたい。

### 15.2 業務構造の変革(Before/After)

#### 15.2.1 導入前の業務構造

本システム導入前の業務構造は、校内での予備調査と既存の教員勤務実態調査を踏まえた設計上の前提値として整理している。ここで用いる70%/30%は本研究の運用設計値であり、全国一律の実測値を断定するものではない。

具体的には、進路面談の準備に1生徒あたり相当の時間を要し、複数の成績データ、出欠記録、過去の面談履歴、進路先情報を手動で収集・整理する必要がある。通知表・保護者向けレポートの作成においても、定型的な文面作成と個別データの転記作業に多大な時間を費やしており、学年全体で相当規模の工数が発生している。リスク検知については、教員の経験と勘に依存する属人的な判断に頼らざるを得ず、成績低下や出席率低下の兆候を見落とすケースが散見される。時間割作成は、教室・教員・科目の制約条件を手作業で調整する極めて労力のかかるタスクであり、年度初めに数週間を要する業務である。

#### 15.2.2 導入後の目標業務構造

本システム導入後の目標として、業務配分を事務作業20%・生徒と向き合う時間80%に転換することを掲げている。これはAIエージェントによる業務自動化と意思決定支援により、教員の時間をより本質的な教育活動に振り向けることを意図したものである。

#### 15.2.3 想定される削減効果

AIエージェント群の導入により、以下の業務削減効果が見込まれる。いずれも設計目標値であり、実運用による検証が必要である。

第一に、進路面談準備時間の削減である。Agent Team 2「進路相談負担軽減ワークフロー」に含まれるPlanet 1「Career Context Aggregator」が、学生の成績・適性・志望情報を統合し、1枚サマリーを自動生成する。これにより、面談準備時間の大幅な短縮が期待される。Planet 2「Career Option Intelligence」が進路先データベースから最適な選択肢を抽出し、Planet 3「Counseling Conversation Planner」が面談の対話フローを自動計画することで、面談の質と効率の同時向上を目指す。

第二に、通知表・レポート作成時間の短縮である。Agent 9「保護者向けレポート生成」(Gate Level L=0.3)が、学生データに基づいて保護者面談用レポートを自動生成する。Gate Level L=0.3の設定により、生成されたレポートは必ず学年主任の承認を経て保護者に送付される仕組みとなっている。

第三に、リスク検知のリアルタイム化である。Agent 1「学習リスク早期検知」およびAgent 3「出席・遅刻パターン解析」が、成績低下や出席率低下のパターンを自動的に検出し、教員にアラートを発信する。従来は教員の主観的判断に依存していたリスク検知が、データ駆動型の監視体制へと転換されることで、見落としリスクの低減が期待される。

第四に、時間割作成の最適化による作業時間削減である。Agent 10「時間割最適化」(Gate Level L=0.7)が、教室・教員・科目の制約条件を考慮した最適時間割を提案する。時間割作成は年度単位の低頻度業務であるが、1回あたりの工数削減効果は大きい。

### 15.3 エージェント別の利用シミュレーション分析

本システムのプロトタイプに実装された管理者向けAIツール管理画面(`admin-ai-tools.tsx`)のモックデータに基づき、10のAIエージェントの想定利用規模と期待精度を分析する。以下の数値はすべてプロトタイプの実シミュレーション値であり、実運用データではない。

エージェント	象限	月間想定利用回数	期待精度	Gate Level
Agent 1: 学習リスク早期検知	Q1 守る	523回	94%	L=0.3
Agent 2: 個別最適化学習プラン生成	Q2 育てる	387回	88%	L=0.3
Agent 3: 出席・遅刻パターン解析	Q1 守る	412回	97%	L=0.2
Agent 4: 成績評価妥当性チェック	Q4 導く	312回	93%	L=0.7
Agent 5: 進路推薦支援	Q4 導く	445回	90%	L=0.3
Agent 6: カリキュラム最適化	Q2 育てる	156回	82%	L=0.7
Agent 7: 面談サマリー自動生成	Q3 回す	289回	91%	L=0.3
Agent 8: 学校経営ダッシュボード	Q4 導く	567回	87%	L=0.7
Agent 9: 保護者向けレポート生成	Q3 回す	198回	89%	L=0.3
Agent 10: 時間割最適化	Q3 回す	45回	85%	L=0.7

シミュレーション上の月間総利用回数は3,842回、目標平均応答時間は1.2秒と設定している。モックデータでは前月比+456回の利用増加シナリオを設定しており、段階的な利用浸透を想定した設計となっている。

想定利用パターンの分析から、いくつかの特徴が設計に反映されている。最多利用を想定したAgent 8「学校経営ダッシュボード」(月間567回)は、管理者が日常的に経営指標の確認とAIインサイトの取得に活用するユースケースを反映している。Gate Level L=0.7が設定されており、AIが生成したインサイトは参考情報として提示され、経営判断への反映には管理者の明示的な承認が必要となる。

一方、最少利用のAgent 10「時間割最適化」(45回)は、時間割編成が年度単位の低頻度業務であることに起因する構造的な特性であり、利用価値が低いことを意味しない。年間数回の利用で大きな工数削減を実現する高インパクト・低頻度型のエージェントとして位置づけられる。

期待精度の面では、Agent 3「出席・遅刻パターン解析」を97%と最も高く設定している。出席データは構造化された定量データであり、パターン認識の精度が高くなることは理論的にも整合する。一方、Agent 6「カリキュラム最適化」は82%と相対的に低い期待精度を想定している。これは、カリキュラム設計が多数の定性的要素を含む複雑なタスクであることに起因する。なお、これらの精度値の妥当性は、実運用において評価指標の定義 (accuracy / precision / recall等) および正解ラベルの基準 (教員判定との一致率等) を明確にした上で検証する必要がある。

象限別に見ると、Q1「守る」(Guardian)象限のAgent 1・3が合計935回と高利用・高精度を想定しており、リスク検知機能に対する現場の需要が高いことを想定した設計としている。Q4「導く」(Management)象限のAgent 4・5・8は合計1,324回と最大の想定利用量であり、意思決定支援機能の重要性を示している。

加えて、2つのAgent Team (統合ワークフロー) も設計されている。Agent Team 1「留学生対応・教材自動翻訳」は月間234回の利用を想定しており、Agent 2・5・9を連携させて留学生向けの教材翻訳と多言語進路情報を提供する設計である。Agent Team 2「進路相談負担軽減」は月間512回の利用を想定しており、Agent 5・7・8を統合的に活用した進路相談業務の効率化を目指している。

## 15.4 教育の質への影響

管理者向け統計画面(`admin-statistics.tsx`)に実装されたモックKPIデータに基づき、教育の質に関する指標の目標シナリオを分析する。以下の数値はプロトタイプの大ダッシュボード表示用に設定されたシミュレーション値であり、実運用データではないことに留意されたい。

モックデータにおける主要KPIの設定値は以下の通りである。在籍率98.2%(前年比+0.3%)、進路決定率72.4%(3年生、前月比+12.1%)、平均偏差値54.8(前年比+1.2)、満足度スコア4.2/5.0(前年比+0.3)。これらは本システム導入後に期待される改善傾向を可視化するために設計された目標シナリオである。

年度推移データ(モックデータ)では、2022年から2026年(予測値)にかけて、在籍率97.1%から98.2%へ1.1ポイントの改善、平均偏差値52.1から54.8へ2.7ポイントの上昇、満足度3.6から4.2へ0.6ポイントの向上というシナリオを設定している。これらは本システムの段階的導入による改善効果の仮説であり、検証にはパイロット運用を通じた検証が必要である。

AI分析インサイト機能(Agent 8「学校経営ダッシュボード」)は、複数のデータソースを統合した分析結果を信頼度レベル付きで提示する設計である。プロトタイプに実装された4件のインサイト例では、「3年生の進路決定率が前年同時期を上回っている」(確信度85%)、「2年生の戦略策定率に改善の余地がある」(確信度78%)、「出席パターン解析による要注意学生の検出」(確信度92%)、「カリキュラム最適化の提案」(確信度71%)といった、異なる粒度・確信度のインサイトが想定されている。

特筆すべきは、インサイトの確信度が71%から92%の範囲で変動しており、AIの判断に対する不確実性が明示的に表示される設計となっている点である。これにより、管理者はインサイトの信頼性を考慮した上で意思決定を行うことができる。Gate Level L=0.7の設定により、経営判断への反映には管理者の確認・承認が必要である旨の注記が常に表示される。

学年別の比較データ(モックデータ)では、1年生の戦略策定率12%、2年生45%、3年生95%と学年進行に伴う段階的向上を表現している。模試受験率は1年生85%、2年生92%、3年生98%と高水準を設定している。進路先分布は、国公立大学89名、私立大学312名、専門学校156名、就職42名、その他・未定648名となっている。

## 15.5 UIプロトタイプの規模と成熟度

本プロトタイプの技術的規模を、ソースコード分析に基づき定量的に評価する。

ビューコンポーネント数は合計57コンポーネントに達する。内訳は、管理者(admin)ロール14画面、教員(teacher)ロール15画面、事務方(office)ロール15画面、学生(student)ロール12画面、およびユーティリティコンポーネント1件である。管理者ロールはユーザー管理、クラス管理、TG(担任グループ)管理、進路先マスタ管理、マイルストーン管理、統計レポート、AIツール管理、AI設定の各画面を含み、教育機関の管理業務を網羅的にカバーしている。

基盤UIコンポーネント数は約60コンポーネントに及ぶ。これはshadcn/ui(New York style)をベースとしたRadix UIプリミティブの実装であり、ボタン、カード、テーブル、ダイアログ、タブ、バッジ、スイッチ、スライダー、セレクト等の汎用コンポーネントを含む。これらのコンポーネントはRechartsライブラリと組み合わせて複数のチャートタイプ(折れ線グラフ、棒グラフ、円グラフ、積み上げ棒グラフ、レーダーチャート等)を表現している。

ロールベースのUI設計は4つのユーザーロールに対して完全な日本語化を実現している。各ロールには固有のカラーテーマ(admin=紫、teacher=緑、office=黄橙、student=青)が割り当てられ、OKLchカラースペースに基づくCSS変数として定義されている。レスポンシブ対応はモバイル端末からデスクトップ端末まで、Tailwind CSS 4.2のユーティリティクラスにより実装されている。

プロトタイプの成熟度を示す指標として、エージェント管理画面の実装深度が挙げられる。`admin-ai-settings.tsx`には、Gate閾値設定(スライダーUI)、モデル設定(GPT-4o / Gemini 3.5 Sonnet等の選択)、承認ワークフロー設定(8種のワークフロー定義)、エージェント別データアクセス権限管理(10エージェント×6データカテゴリ)、AI操作監査ログ(タイムスタンプ・エージェント名・操作内容・実行者・Gate Level・結果・詳細の7項目)が実装されている。この実装深度は、プロトタイプでありながら実運用を想定したガバナンス機能のUI設計が詳細に行われていることを示している。

## 15.6 費用対効果分析 (Cost-Benefit Analysis)

以下の費用対効果分析は概算による試算であり、実際の導入時には詳細な見積りが必要である。

### 15.6.1 初期開発コストの試算

本システムの開発に要する初期投資を、工程別に概算する。フロントエンド開発費は、56画面の設計・実装に対して平均工数15万円/画面を想定し、約840万円と見積もる。AI Agent開発費は、12エージェント(10単体Agent+2 Agent Team)のプロンプト設計、API統合、テスト工程に対して平均100万円/エージェントを想定し、約1,200万円と見積もる。インフラ構築費は、認証基盤、データベース、セキュリティ基盤の構築に約300万円を想定する。合計初期投資額は概算で約2,340万円である。

### 15.6.2 年間運用コストの試算

年間運用コストは以下の3項目で構成される。LLM API利用料は、月間3,842回のエージェント呼び出し(シミュレーション値)に対して、平均入出力トークン数(入力2,000トークン+出力1,000トークン)と想定単価を適用し、約180万円/年と試算する。なお、LLM APIの単価は変動するため、実導入時には最新の料金体系に基づく再試算が必要である。クラウドインフラ費用は、ホスティング基盤、データベース基盤、CDN・監視ツールで約120万円/年と見積もる。なお、本番運用時には学内運用要件や個人情報の国内データ保持要件に応じて、オンプレミス環境または国内データセンターのクラウドサービスへの移行を検討する。保守・運用人件費は、0.5人月/月×12ヶ月×60万円/人月で約360万円/年である。合計年間運用費は概算で約660万円/年となる。

### 15.6.3 定量的効果の金額換算

本システム導入による定量的効果の推計値を、以下の4項目で金額換算する。いずれも設計目標に基づく試算であり、実運用データによる検証が必要である。

第一に、教員の事務時間削減効果である。事務作業比率を70%から35%に軽減した場合(第1年度の保守的推計。段階的改善を想定し、初年度での最終目標20%達成は見込まない)、教員20名×年間360時間節約×時給3,000円=2,160万円/年相当の労働時間が学生対応に再配分されると試算される。

第二に、リスク早期検知による退学防止効果である。Guardian Agents (Agent 1, 3)によるリスク早期検知が年間5名の退学を防止すると仮定した場合、学生1名あたり年間授業料120万円×5名=600万円/年の授業料収入が維持されると見込まれる。

第三に、面談準備時間の短縮効果である。Agent 7(面談サマリー自動生成)により、面談1回あたりの準備時間を短縮した場合、教員20名×年間27回面談×30分節約×時給3,000円=81万円/年相当の効率化が見込まれる。

第四に、進路指導精度の向上効果である。Agent 5(進路推薦支援)による第1志望合格率の改善は、学校のブランド価値向上と入学志願者増加を通じて中長期的な経営効果をもたらすが、定量化が困難なため本試算には含めない。

### 15.6.4 ROI(投資対効果)の試算

上記の推計に基づくROI分析を表15-3に示す。本試算は設計目標値に基づく概算であり、実運用データによる検証が不可欠である。

表15-3 本システム導入のROI試算

項目	金額(概算)
初期投資額	2,340万円
年間運用コスト	660万円
年間定量効果合計(推計値)	2,841万円(=2,160+600+81)
年間純効果(推計値)	2,181万円(=2,841-660)
初期投資回収期間(推計)	約1.07年(=2,340÷2,181)
3年間累積ROI(推計)	約180%(=(2,181×3-2,340)÷2,340×100)

なお、事務時間削減効果は導入初年度は学習コストにより限定的となる可能性があり、退学防止効果の仮定(年間5名)も実績に基づくものではない。実際のROIは導入後の効果測定により大きく変動しうる。



## 15.7 既存学校管理システムとの比較分析

本システムの位置づけを明確化するため、既存の学校管理・教育支援システムとの比較を表15-4に示す。

表15-4 既存システムと本システムの比較

比較項目	従来型SMS	Classi	スタディサプリ	本システム
AI意思決定支援	なし	限定的(学習分析)	限定的(推薦)	12エージェント＋Gate機構(UI設計済、機能実装予定)
リスク早期検知	手動(教員目視)	出席データ分析(基礎)	なし	リアルタイムAI設計済(Agent 1, 3、実装予定)
進路支援	データベース参照のみ	基礎的レコメンド	なし	複合Agent＋Agent Team 2
Gate機構(AI制御)	なし	なし	なし	3段階自律度制御(L=0.2/0.3/0.7)
説明可能性	—	低	低	3レベルXAI設計(実装予定)
カスタマイズ性	低(パッケージ)	中(設定変更)	低(SaaS)	高(VIEW_MAP拡張、ロール追加)
対象ロール数	2-3(教員・事務)	3(教員・生徒・保護者)	2(教員・生徒)	4(管理者・教員・事務方・学生)
初期コスト	500-1,000万円	月額制(生徒数課金)	月額制	約2,340万円(試算)

本システムは初期コストが高い一方、AI意思決定支援の深度、Gate機構による倫理的制御、4ロール対応の包括性において差別化された設計となっている。

## 15.8 課題と今後の測定計画

### 15.8.1 現時点の制約

本章で示した定量分析は、プロトタイプに実装されたモックデータに基づく推計値である。実運用データに基づく厳密な効果測定は、本システムの実稼働後に改めて実施する必要がある。特に、業務時間削減効果の数値は設計目標値であり、実測値ではない点に留意が必要である。また、教育の質に関する指標の改善が本システムの導入に直接帰属するものかどうかについては、交絡因子(カリキュラム改訂、教員研修、入学者層の変化等)の統制が必要であり、因果推論の手法を用いた分析が求められる。

### 15.8.2 A/Bテスト設計案

実運用段階においては、効果の因果的推定を行うためのA/Bテストを計画している。具体的には、同一学年内の複数クラスを処理群(本システム利用)と対照群(従来方式)に無作為割当し、進路面談準備時間、リスク検知の正確性、教員満足度を主要アウトカムとして比較する。サンプルサイズの設計には、効果量 $d=0.3$ を想定した検出力分析(検出力80%、判定水準5%相当)を適用し、必要なクラス数・生徒数を算定する。倫理的配慮として、対照群の生徒にも一定期間後に本システムを導入するクロスオーバーデザインの採用を検討する。

### 15.8.3 長期追跡調査の方法論

3年間の長期追跡調査により、以下の指標を経年的にモニタリングする計画である。第一に、教員の業務時間配分の変化をタイムスタディ法により6か月ごとに測定する。第二に、AIエージェントの利用パターンの進化を、ログデータの時系列分析により追跡する。第三に、教育成果指標(在籍率・進路決定率・偏差値等)の推移を、全国平均との比較において評価する。第四に、エージェント精度の経時変化を、再訓練サイクルとの関連で分析する。

これらの測定結果は、年次報告書として取りまとめ、PDCA(Plan-Do-Check-Act)サイクルに基づくシステム改善に活用する。特に、利用回数の低いエージェント(Agent 10等)については、ユーザーインタビューを通じた利用障壁の特定と改善策の立案を行う。また、期待精度を低めに設定したエージェント(Agent 6: 想定82%)については、プロンプト改善やモデル選定の見直しによる精度向上を図る計画である。





## 第16章 教育AIの倫理・ガバナンス・法的考慮

### 16.1 教育分野におけるAI倫理原則

#### 16.1.1 国際的な倫理枠組みと教育AIへの適用

教育分野へのAI導入に際しては、国際的に合意された倫理原則を基盤として、教育固有の文脈に即した倫理的フレームワークを構築する必要がある。本節では、UNESCO、OECD、および日本政府が提示するAI倫理原則を概観し、本システムにおける具体化の方針を論じる。

UNESCO「AIと教育に関する北京コンセンサス」(Beijing Consensus on Artificial Intelligence and Education, 2019)は、教育分野におけるAI活用の国際的な指針として、以下の5原則を提示した。第一に「包摂性と公平性(Inclusion and Equity)」として、AIが教育格差を縮小させる方向に活用されるべきことを求める。第二に「ジェンダー平等(Gender Equality)」として、AIシステムにおけるジェンダーバイアスの排除を要請する。第三に「倫理的で透明なAIの利用(Ethical and Transparent AI)」として、教育データの収集・利用における透明性の確保を義務づける。第四に「教員の役割の尊重(Teacher Preparedness)」として、AIが教員を代替するのではなく支援するものであることを明記する。第五に「質の高いデータとアクセスの確保(Quality Data and Access)」として、教育AIの基盤となるデータの品質管理とアクセス権の適正化を求める(UNESCO, 2019)。

OECD AI原則(OECD Principles on AI, 2019)は、教育分野に限定されないが、加盟国共通のAIガバナンス基準として広く参照されている。同原則が掲げる5項目——包摂的な成長・持続可能な開発・幸福の実現、人間中心の価値観と公平性、透明性と説明可能性、堅牢性・安全性・セキュリティ、アカウンタビリティ——は、教育AIの設計指針としても直接的に援用可能である(OECD, 2019)。とりわけ「人間中心の価値観と公平性」の原則は、本システムの設計思想である「AIが提案し、先生が決める」という基本原則と対応する。

日本においては、内閣府「人間中心のAI社会原則」(2019)が7原則——人間中心、教育・リテラシー、プライバシー確保、セキュリティ確保、公正競争確保、公平性・説明責任・透明性、イノベーション——を提示し、教育分野を含む全分野のAI活用の倫理的基盤を構成している。さらに「AI戦略2022」(統合イノベーション戦略推進会議, 2022)は、教育分野におけるAI利活用の推進と倫理的配慮の両立を政策目標として掲げ、学校教育におけるAI活用ガイドラインの整備を提言している。文部科学省「初等中等教育段階における生成AIの利用に関する暫定的なガイドライン」(2023)も、教育現場での生成AI活用に際して「最終的な判断は教職員が行う」ことを基本方針として示している。

#### 16.1.2 本システムにおける倫理原則の具体化

本システムは、上記の国際的・国内的な倫理原則を、Gate機構を通じてシステムアーキテクチャの中に構造的に組み込む設計を採用している。表16-1に、主要な倫理原則と本システムにおける実装の対応関係を示す。

表16-1 倫理原則と本システム設計の対応表

倫理原則	出典	本システムにおける設計上の対応	対応するGate Level
包摂性と公平性	UNESCO (2019)	Agent 5のバイアス検出機構、DEI配慮設計	L=0.3(公平性チェック後に承認)
透明性と説明可能性	OECD (2019)	信頼度スコアの3段階表示、Gate Cardによる責任分解	全レベル共通
人間中心の価値観	内閣府 (2019)	Human-in-the-loop設計、教員最終判断権の保証	L=0.7(人間判断必須)
教員の役割の尊重	UNESCO (2019)	AIは「参考資料」提示に徹する設計、承認プロセス	L=0.3~L=0.7
プライバシー確保	内閣府 (2019)	RBAC、エージェント別データアクセス権限マトリクス	全レベル共通
アカウンタビリティ	OECD (2019)	AI操作監査ログ、Gate Level別責任分配表(第5章表5-6)	全レベル共通

Gate機構の3段階制御(L=0.2/L=0.3/L=0.7)は、倫理原則の実装密度を業務リスクに応じて段階的に調整する仕組みとして機能するよう設計されている。L=0.2の高自動化タスク(例:出席パターン解析)においても、異常値検出時のアラート発出により透明性が確保される設計である。L=0.3の中間タスク(例:進路推薦支援)では、承認者による公平性確認が制度化される設計である。L=0.7の高リスクタスク(例:成績評価妥当性チェック)では、AI出力が「参考資料」とどまり、教員の専門的判断が最終的な決定権を有する設計としている。

### 16.1.3 教育AIに固有の倫理課題

教育AIは、医療AIや金融AIとは異なる固有の倫理課題を内包している。教育対象者の多くが発達段階にある未成年者であり、成人を対象とする他分野のAIシステムとは質的に異なる配慮が必要となる。

第一に、未成年者のデータ保護の問題がある。学生の成績データ、出欠記録、面談記録、メンタルヘルスに関する情報は、発達途上にある個人のセンシティブな記録であり、AIによる処理が当該学生の将来に不可逆的な影響を及ぼす可能性がある。本システムでは、これらの情報を含むAI出力に対して自動的にL=0.7以上のGate Levelを付与し、権限を有する教員のみがアクセス・承認できる制御を設計している(第5章 5.1.4参照)。

第二に、発達段階への配慮の問題がある。AIによるリスク判定や学習評価は、学生の発達段階を考慮した上で解釈される必要がある。例えば、高校1年生と3年生では進路に対する成熟度が質的に異なり、同一の評価基準を機械的に適用することは教育的に不適切である。本システムのAgent 1(学習リスク早期検知)は、学年別のリスク閾値を設定可能とし、発達段階に応じた柔軟な判定を可能にする設計としている。

第三に、教育的関係性の保護の問題がある。教師と生徒の間の教育的関係性(Pedagogical Relationship)は、信頼に基づく人間的な営みであり、AIの介在によって毀損されてはならない。AIが生成したリスクアラートや進路推薦が、教員の主体的な判断を形骸化させ、「AI任せ」の指導に陥るリスク——いわゆる自動化バイアス(Automation Bias)(Parasuraman & Manzey, 2010)——は、教育AIに固有の深刻な倫理課題である。Gate機構における強制的確認プロセス(第5章 5.5.2参照)は、この課題に対する構造的な対策として設計されている。

## 16.2 アルゴリズムバイアスへの対策

### 16.2.1 教育データに内在するバイアスの類型

教育AIシステムが学習データとして用いる教育データには、複数の種類のバイアスが構造的に内在している。Suresh & Guttag (2021)が提示したバイアスの分類枠組みを教育分野に適用すると、以下の4類型に整理される(図16-1参照)。

第一に、歴史的バイアス(Historical Bias)である。過去の進路指導実績データには、ジェンダーに基づく進路指導の偏り(例:理工系への男子偏重推薦)や、社会経済的背景に基づく機会格差が反映されている可能性がある。AIがこれらのデータをそのまま学習した場合、過去の不公平を再生産・固定化するリスクが生じる。

第二に、表現バイアス(Representation Bias)である。学習データにおいて特定の属性(例:留学生、障害を持つ学生、経済的困難を抱える学生)のサンプル数が不足している場合、これらのグループに対するAIの推定精度が低下する。本システムが対象とする専門学校においては、留学生比率の増加傾向を踏まえ、多様な学生群の適切な表現が学習データに確保されているかを検証する必要がある。

第三に、測定バイアス(Measurement Bias)である。教育成果の測定方法自体に偏りが含まれている場合、AIの判断にも系統的な歪みが生じる。例えば、ペーパーテストの成績のみを学力指標として用いる場合、実能力やコミュニケーション能力に優れた学生のポテンシャルが過小評価される。本システムのAgent 4(成績評価妥当性チェック)は、この測定バイアスの検出を目的の一つとしている。

第四に、集約バイアス(Aggregation Bias)である。異なる特性を持つ集団に対して単一のモデルを適用する場合、多数派の特性にモデルが過適合し、少数派に対する予測精度が劣化する。学年、学科、文化的背景の異なる学生群に対して、個別のサブグループ特性を考慮しないモデル適用は集約バイアスの典型例である。

### 16.2.2 Agent 4(成績評価妥当性チェック)のバイアス検出機構

Agent 4(成績評価妥当性チェック、Gate Level L=0.7)は、教師別の成績分布分析と偏差異常検出を主要タスクとし、評価プロセスにおけるバイアスの検出を行う設計である。具体的には、以下の3つの検出機構を設計している。

第一に、教師間分布比較(Inter-rater Distribution Analysis)である。同一科目・同一学年における教師別の成績分布をデータ分析上の観点で比較し、顕著な偏差が検出された場合にアラートを発出する。例えば、ある教員の評価分布が他の教員と比較して系統的に高い(または低い)場合、評価基準の不統一が疑われる。

第二に、属性別評価差異検出(Attribute-based Disparity Detection)である。性別、国籍、在籍年数等の属性別に成績評価の分布を比較し、統計上無視できない差異が認められた場合に報告する。ただし、この検出結果は「バイアスの存在」を断定するものではなく、「更なる調査が必要な兆候」として教務主任に提示される。Gate Level L=0.7の設定により、検出結果の解釈と対応は教務主任の専門的判断に委ねられる。

第三に、経年変化追跡(Longitudinal Trend Monitoring)である。特定の属性グループにおける成績評価の経年的な傾向を追跡し、漸進的なバイアスの蓄積を検出する。

### 16.2.3 Agent 5(進路推薦支援)における公平性担保の設計

Agent 5(進路推薦支援、Gate Level L=0.3)は、進学実績データベース照合と適性傾向分析に基づいて進路先の推薦を行う設計のエージェントであり、シミュレーション上の推計では月間約445回の利用(期待精度約90%)を想定している(第14章参照)。進路推薦は学生の将来に直接的な影響を及ぼすため、公平性の担保が特に重要となる。

Agent 5における公平性担保の設計は、以下の3層構造をとる。第一層は、学習データの预处理段階におけるバイアス緩和である。保護属性(性別、国籍、経済的背景)と進路推薦結果の相関を定量的に評価し、不当な相関が検出された場合にはデータの再重み付け(Reweighting)を適用する。第二層は、モデル推論段階における公平性制約の導入である。データ分析上のパリティ(Statistical Parity)、機会均等(Equal Opportunity)の各指標を監視し、閾値逸脱時にフラグを付与する。第三層は、出力段階における人間の確認である。Gate Level L=0.3の設定により、進路指導主事の承認を経て初めて学生に提示される。

### 16.2.4 バイアス監査プロセス

本システム全体のバイアス管理を体系化するため、以下のバイアス監査プロセスを制度化する(表16-2参照)。

表16-2 バイアス監査プロセスの年間スケジュール

時期	監査内容	担当	対象エージェント
4月(年度開始時)	学習データの属性分布確認	教育DX推進室	全エージェント
7月(第1四半期末)	属性別パフォーマンス指標の比較	AI倫理委員会	Agent 4, 5
10月(第2四半期末)	教員フィードバックに基づくバイアス報告の集約	教務主任	Agent 1, 2, 5
1月(第3四半期末)	年間バイアス動向レポートの作成	教育DX推進室	全エージェント
3月(年度末)	外部有識者によるフェアネス監査	外部監査委員	Agent 4, 5, 8

### 16.2.5 多様性・公平性・包摂性(DEI)の観点

留学生への配慮として、Agent Team 1(留学生対応・教材自動翻訳システム)は、言語的障壁を低減することで教育アクセスの公平性を高める機能を提供する。障害を持つ学生への配慮として、フロントエンドのアクセシビリティ設計(Radix UI プリミティブのWAI-ARIA準拠)に加え、AIエージェントの出力においても合理的配慮に関する情報を含める設計としている。経済的困難を抱える学生への配慮として、Agent 5の進路推薦においては奨学金情報や学費減免制度の情報を推薦結果に付随して提示する設計とする。

## 16.3 説明可能性(Explainability)の確保

### 16.3.1 XAI(Explainable AI)の教育分野への適用

説明可能AI(Explainable AI: XAI)は、AIシステムの判断プロセスを人間が理解可能な形で提示する技術および設計原則の総称である(Arrieta et al., 2020)。教育分野におけるXAIの重要性は、他分野と比較しても高い。その理由は、教育AI

の利用者(教員)がAIの判断根拠を理解した上で教育的判断を行う必要があること、AIの判断対象(学生)が未成年者であり説明を受ける権利がより強く保護されるべきこと、および保護者に対する説明責任が法的にも社会的にも求められることにある。

### 16.3.2 本システムにおける説明可能性の3レベル実装

本システムでは、説明可能性を3つのレベルに階層化して実装する設計を採用している(図16-2参照)。

#### Level 1: 出力根拠の可視化(Evidence Visualization)

Agent 1(学習リスク早期検知)を例にとると、リスクスコアの算出にあたり「出席率の推移」「科目別成績の変動」「過去の面談記録における特記事項」のいずれのデータ要素がスコアに寄与しているかを、寄与度の大きい順に表示する。Agent 8のAI分析インサイト機能において、信頼度レベル付きのインサイト表示がUIプロトタイプ上にモックデータで実装されている。

#### Level 2: 判断プロセスの透明化(Process Transparency)

Gate Card(第5章 表5-4、表5-5参照)は、各エージェントの処理に対してリスクレベル、制御方式、承認権限者を一元的に記述しており、責任分解(Responsibility Decomposition)の機能を果たしている。Agent Team 2(進路相談負担軽減)では、4つのPlanetの各段階に異なるGate Levelが付与されており、処理パイプラインの各段階における人間の関与度合いが明示的に設計されている。

#### Level 3: 反事実的説明(Counterfactual Explanation)

「もし入力条件が異なっていたら、AIの出力はどう変わっていたか」を示す反事実的説明である(Wachter, Mittelstadt & Russell, 2017)。例えば、「もし出席率が現在の78%から83%に改善した場合、リスクスコアは0.72から0.58に低下する見込みである」といった形式の説明は、教員が具体的な指導方針を立案する際の有力な判断材料となる。

### 16.3.3 教員向け説明インターフェースの設計

段階的開示(Progressive Disclosure)の原則に基づき、初期表示では結論と信頼度スコアのみを提示し、教員が詳細を必要とする場合にのみ根拠データ(Level 1)、処理プロセス(Level 2)、反事実的説明(Level 3)へと展開可能とする。また、教育的文脈への翻訳(Pedagogical Contextualization)の原則により、AIの技術的な出力を教育的に意味のある表現に変換して表示する。

### 16.3.4 信頼度スコア(Confidence Score)の3段階表示設計

表16-3 信頼度スコアの3段階表示設計

段階	スコア範囲	視覚表現	教員への推奨行動
高信頼度	85%以上	緑色バッジ「確信度:高」	AI推定を参考に判断可能
中信頼度	70~84%	琥珀色バッジ「確信度:中」	追加情報の確認を推奨
低信頼度	70%未満	赤色バッジ「確信度:低」	独自判断を優先、AI推定は参考程度

## 16.4 法的フレームワークとコンプライアンス

### 16.4.1 個人情報保護法(2022年改正)の学校法人への適用

2022年4月に全面施行された改正個人情報保護法は、学校法人を含む民間事業者に対して統一的な個人情報保護規律を適用するものである。

**要配慮個人情報と機微情報の取扱い:** 個人情報保護法第2条第3項に定める「要配慮個人情報」は、病歴、障害、心身の機能障害等が法定類型として限定列挙されている。健康情報(保健室利用記録、メンタルヘルス関連情報)は法定の要配慮個人情報に該当する。一方、成績情報・進路希望・面談記録等は法定類型には直接該当しないが、学生の能力評価や将来に関わる機微性の高い個人情報であるため、本システムでは個人情報保護法の安全管理措置を厳格に適用する対



象として設計している。エージェント別データアクセス権限マトリクスにより、各AIエージェントがこれらの機微情報にアクセスする範囲を最小限に制御する設計としている(第13章 13.4.2参照)。

**利用目的の特定と同意取得:** 入学時の個人情報取扱同意書にAI利用に関する条項を追加し、AIエージェントによる分析処理が行われること、処理の目的と範囲、Gate機構による人間の監督が確保されていること、およびAI処理に対する異議申立の手続きを明示する必要がある。

**第三者提供の制限:** 企業向けの求人マッチング機能において、本人の明示的な同意に加え、提供するデータの範囲の最小化、提供先における管理体制の確認、および提供記録の作成・保存が義務づけられる。

16.4.2 学校教育法との整合性

学校教育法および専修学校制度に関する法令上、教育課程に関する最終判断は設置者・学校側の責任で行われる必要がある。したがって、Agent 6(カリキュラム最適化)の提案はあくまで「参考資料」として位置づけられなければならない。Gate Level L=0.7の設定は、この運用要件を技術的に担保するものである。

指導要録は法定の公簿であり、AIが関与した場合の記録方法について、将来的な法整備を見据え、「総合所見及び指導上参考となる諸事項」欄におけるAIツール利用事実の注記を推奨する。

16.4.3 EU AI Act(2024)の動向と影響

2024年8月に発効したEU AI Act(Regulation (EU) 2024/1689)は、教育分野のAIを「高リスクAI(High-risk AI System)」に分類している(European Parliament, 2024)。

表16-4 EU AI Act要件と本システム設計の対応

EU AI Act要件	条文	本システム対応設計
リスク管理システム	第9条	Gate機構による3段階リスク制御
データガバナンス	第10条	エージェント別データアクセス権限マトリクス
技術文書	第11条	Gate Card(第5章)による処理仕様の文書化
記録保持	第12条	AI操作監査ログ(第13章)
透明性	第13条	信頼度スコア表示、説明可能性の3レベル実装
人間による監督	第14条	Human-in-the-loop設計、教員承認プロセス
正確性・堅牢性	第15条	エージェント精度の定期検証(第14章)

本システムは日本国内の教育機関を対象として設計されたシステムであり、EU AI Actの直接的な規制対象ではない。しかし、将来的な日本国内におけるAI規制法整備を見据え、EU AI Actの要件を設計基準として参照することは合理的である。

16.4.4 ガバナンス体制の提案

**AI倫理委員会の設置:** 校長(委員長)、教務主任、進路指導主事、教育DX推進室長、外部有識者、保護者代表、学生代表の7名以上で構成し、年4回以上の定期開催を義務づける。

**年次倫理監査:** 外部の第三者機関による監査を年1回実施し、データ管理の適正性、バイアス検出状況、説明可能性の実装状況、Gate機構の運用実態を検証する。

**インシデント対応フロー**(図16-3参照): (1) 検知・報告(即時)→(2) 初動対応(48時間以内: エージェント一時停止)→(3) 原因分析(2週間以内)→(4) 是正措置(1か月以内)→(5) 事後検証(3か月以内: AI倫理委員会)

**ステークホルダー参加型ガバナンス:** 教員AIツール利用感アンケート(学期ごと)、学生フィードバック機能、保護者説明会(年2回)を通じた双方向の意見交換を制度化する。

## 16.5 Gate機構と倫理的フレームワークの統合

### 16.5.1 Gate Levelと倫理リスクの対応表

表16-5 Gate Levelと倫理リスクの対応表

Gate Level	倫理リスク水準	代表的な倫理課題	倫理的保護措置	法的根拠
L=0.2	低	データプライバシー、データ分析上の集計の正確性	事後監査ログ、異常値アラート	個人情報保護法(安全管理措置)
L=0.3	中	バイアスの混入、表現の教育的適切性	承認者による公平性チェック	個人情報保護法(利用目的の特定)
L=0.7	高	進路判断への不当な影響、メンタルヘルスへの配慮	教員の全面的判断権、反事実的説明の提供	学校教育法(教育課程編成権)

### 16.5.2 倫理的判断が必要な場面の類型化

**類型A: 公平性判断** — Agent 5の推薦結果に属性グループへの偏りが検出された場合 (Gate Level L=0.3以上)。**類型B: プライバシー判断** — Agent 1のリスクアラートが家庭環境に関する要配慮個人情報を含む場合 (Gate Level L=0.7)。**類型C: 教育的配慮判断** — Agent 9の保護者レポート表現が学生の自尊心を傷つける可能性がある場合 (Gate Level L=0.3)。**類型D: 緊急性判断** — Agent 3が検出した出席異常が虐待等の兆候である可能性がある場合 (Gate Level L=0.7 + エスカレーション)。

### 16.5.3 段階的自動化の倫理的正当化

Gate機構の段階的自動化 (Graduated Automation) は、以下の3つの倫理的論拠により正当化される。第一に、教員の認知的負荷の観点から、全AI出力への詳細確認は「確認疲れ (Alert Fatigue)」を引き起こし逆効果となる。第二に、業務効率化の観点から、定型的事務処理の自動化 (L=0.2) は教育の質向上に資する。第三に、段階的信頼構築の観点から、運用実績に基づく Gate Level の段階的調整が適切な信頼関係 (Calibrated Trust) の構築を促進する。

### 16.5.4 Human-in-the-Loopが教育の「温かみ」を保つ設計思想

L=0.7の Gate Level が設定されたタスク——進路判定、メンタルヘルス対応、成績評価の公平性検証——は、いずれも教育の「温かみ」が最も強く求められる場面である。AIは教員の判断を「支援」するが「代替」しない。教員は、AIが提示するデータと分析を参考にしつつも、学生一人ひとりの個別事情、成長の軌跡、夢や不安といった、データに表れない教育的文脈を総合的に考慮して判断を行う。

Gate機構は、技術的なアクセス制御であると同時に、「教育とは何か」「教師の役割とは何か」という教育哲学的な問いに対する、システム設計レベルでの応答でもある。

## 16.6 本章のまとめ

本章では、本システムの設計・運用に関わる倫理・ガバナンス・法的考慮を体系的に検討した。UNESCO、OECD、日本政府のAI倫理原則がGate機構を通じてシステムアーキテクチャに構造的に組み込まれる設計であることを示し、教育データに内在するバイアスの4類型と対策を論じた。説明可能性の3レベル実装、個人情報保護法・学校教育法・EU AI Actへの対応、およびAI倫理委員会を中心とするガバナンス体制を提案した。

教育AIの倫理・ガバナンス・法的考慮は、技術的設計と不可分のものである。本システムのGate機構は、「技術に倫理を後付けする」のではなく「倫理を技術の設計原理に組み込む」というEthics by Designのアプローチを体現するものである。

## 第17章 他教育機関への展開可能性と政策提言

### 17.1 展開可能性の検討

本システムは、清風情報工科学院(専門学校)における進路指導業務の効率化を主たる設計対象として設計されたが、そのアーキテクチャは特定の教育機関に閉じたものではない。本節では、本システムの設計原則——ロールベースアクセス制御、4象限AIエージェント群、Gate機構によるAI自律レベル制御、VIEW\_MAPレジストリパターンによるモジュール化——が、他の教育機関類型へどのように適用可能であるかを検討する。

#### 17.1.1 高等学校への適用可能性

高等学校は、専門学校と同様に進路指導を中核的業務として有しており、本システムの適用先として最も親和性が高い教育機関類型である。高等学校においては、大学進学・専門学校進学・就職という三分岐の進路指導が求められ、生徒一人ひとりのTG(Target Goal)設定と戦略策定が教員の重要な職務を構成している。

本システムの「守る(Guardian)」象限が提供するリスク早期検知エージェント(Agent 1)および出席パターン解析エージェント(Agent 3)は、高等学校における不登校予防・中途退学リスクの早期発見に転用可能である。文部科学省「児童生徒の問題行動・不登校等生徒指導上の諸課題に関する調査結果」(2023)によれば、高等学校における不登校生徒数は増加傾向にあり、データ駆動型の早期検知システムへの需要は高いと考えられる。

また、高等学校においては「総合的な探究の時間」の導入に伴い、生徒の探究活動の成果物管理が新たな業務負担として顕在化している。本システムの学生ロールにおける「成果物一覧(StudentPortfolio)」ビューは、この業務を支援するコンポーネントとして活用可能である。

ただし、高等学校への適用に際しては、学習指導要領との整合性確認、教育委員会のICTガバナンスポリシーとの調整、および公立学校における調達手続きへの対応が必要となる。特に公立学校においては、自治体の情報セキュリティポリシーに準拠したデータ管理基盤の構築が前提条件となる。

#### 17.1.2 大学(特に地方大学)への適用

大学、とりわけ地方の中小規模大学においては、入学者確保、学生の中途退学防止、就職支援が経営上の重大課題となっている。本システムの「導く(Management)」象限に配置されたAgent 8(学校経営ダッシュボード)は、学年別パフォーマンス、退学率、進学率、授業満足度の統合分析機能を提供しており、大学のIR(Institutional Research)部門が必要とする経営情報の可視化と親和性が高い。

大学への適用においては、ロール構成の拡張が必要となる。現行の4ロール(admin / teacher / office / student)に加え、「研究室指導教員」「キャリアセンター職員」「保護者」等の新規ロールが想定される。後述する17.2節において論じるROLE\_CONFIGの拡張容易性は、この要件に対して技術的な解を提供する。

また、大学においてはラーニング・マネジメント・システム(LMS)との連携が不可欠であり、Moodle、Google Classroom、Canvas等の既存LMSからのデータ取り込みを入力層(Input Layer)に追加する設計が求められる。

#### 17.1.3 職業訓練校への適用

公共職業訓練校および求職者支援訓練の実施機関においては、受講者の就職率が評価指標として極めて重要な位置を占めている。本システムのAgent 5(進路推薦支援)およびAgent Team 2(進路相談負担軽減)は、受講者の適性と求人市場のマッチング支援に活用可能である。

職業訓練校に特有の要件として、ハローワークとの連携、訓練成果の報告様式への対応、および雇用保険制度との関連情報の管理が挙げられる。「回す(Admin)」象限のAgent 9(保護者向けレポート生成)は、報告書の自動生成エンジンとして訓練実施報告の作成支援に転用可能であるが、報告様式の定型化の程度が高いため、テンプレートベースの出力制御機能の追加が望ましい。

### 17.1.4 留学生学科への適用

インターナショナルスクールにおいては、多言語・多文化環境への対応が最も顕著な要件となる。本システムのAgent Team 1(留学生対応・教材自動翻訳システム)は、用語辞書照合、文脈翻訳、難易度適応の3段階パイプラインを有しており、インターナショナルスクールにおける多言語教材作成の効率化に寄与する。

## 17.2 スケーラビリティの技術的裏付け

### 17.2.1 コンポーネントベース設計による機能追加の容易性

本システムのフロントエンドは、React(v19)およびNext.js App Router(v16)を基盤とするコンポーネントベースアーキテクチャを採用しており、各ビューは独立したReactコンポーネントとして実装されている。この設計により、新規機能の追加は既存コンポーネントに影響を与えることなく実施可能である。

shadcn/uiコンポーネントライブラリ(New York スタイル)の採用は、UI層の再利用性を高めている。現行のシステムは60以上のshadcn/uiコンポーネント(Button、Card、Dialog、Table、Select、Tabs等)を基盤として構築されており、これらは`npx shadcn@latest add <component>`コマンドにより必要に応じて追加可能である。コンポーネントのソースコードがプロジェクト内に直接配置される設計(ゼロ依存性パターン)であるため、教育機関固有の要件に応じたカスタマイズが容易である。

### 17.2.2 VIEW\_MAPレジストリパターンによるビュー拡張

第4章において詳述したVIEW\_MAPレジストリパターンは、ビュー拡張の手順を以下の3ステップに定型化している。

- 54. 新規ビューコンポーネントの作成(`components/portal/views/`ディレクトリ内)
- 55. `view-registry.tsx`のVIEW\_MAPオブジェクトへのエントリ追加
- 56. `lib/types.ts`のROLE\_CONFIGにおける対応ロールのnavItemsへの項目追加

この3ステップは、いずれもファイルの追加または既存ファイルの末尾への追記のみで完結し、既存のコードベースに対する破壊的変更を伴わない。現行の56ビューから100ビュー以上への拡張においても、メインページ(`app/page.tsx`)の描画ロジックは変更を必要としない。この拡張容易性は、教育機関の多様な要件に対応するうえで重要な優位性を有する。

### 17.2.3 ROLE\_CONFIGへの新ロール追加

ROLE\_CONFIGは`Record<Role, {...}>`型として定義されており、新規ロールの追加は以下の手順で実現される。

- 57. `lib/types.ts`のRole型へのユニオン型メンバー追加(例: `"parent" | "company"`)
- 58. ROLE\_CONFIGオブジェクトへの新規ロールエントリの追加(label、colorClass、navItems等の定義)
- 59. 対応するダッシュボードおよびビューコンポーネントの作成
- 60. VIEW\_MAPへのエントリ追加

保護者ロールの追加は、生徒の学業状況・進路状況の閲覧に特化した読み取り専用のビュー群として設計可能である。企業ロールの追加は、求人情報の掲載・応募状況の確認・面接日程の管理等の機能を提供するビュー群として設計可能である。いずれの場合も、既存の4ロールに対する変更は不要であり、追加的な設定のみで実現できる。

### 17.2.4 shadcn/uiコンポーネントの再利用性

shadcn/uiは、Radix UIプリミティブとTailwind CSSを基盤とし、class-variance-authority(CVA)によるバリエーション管理を行うコンポーネントライブラリである。コンポーネントのソースコードがプロジェクト内の`components/ui/`ディレクトリに配置される設計であるため、各教育機関が独自のデザインシステムに合わせてスタイルを変更することが可能である。

特に、`cn()`ユーティリティ関数(clsx + tailwind-merge)を用いた条件付きクラス結合パターンは、ロール固有のスタイリングを既存コンポーネントに非破壊的に適用する際に有効に機能する。



## 17.3 カスタマイズ可能性

### 17.3.1 ロール固有カラーシステムの変更容易性

本システムのロール別カラーシステムは、CSS変数として`:root`セレクト内に定義されている。OKLCh色空間の採用により、明度(Lightness)、彩度(Chroma)、色相(Hue)の各パラメータを独立に調整可能であり、特定のロールカラーの変更は対応するCSS変数の値の書き換えのみで完結する。

例えば、ある教育機関において「教員」のテーマカラーを緑から青に変更する場合、`--role-teacher`の色相値を変更するだけでよい。この変更は、当該ロールに関連する全てのUI要素(ヘッダー、サイドバー、バッジ、KPIカード等)に自動的に波及する。

Tailwind CSS 4.2の`@theme inline`ディレクティブを通じて、CSS変数がユーティリティクラス(`bg-role-admin`、`text-role-teacher`等)として利用可能になっているため、JavaScriptコードの変更を要せずに視覚的なブランディングの変更が実現できる。

### 17.3.2 ナビゲーション項目の追加・変更

ROLE\_CONFIGのnavItems配列は、各ロールのサイドバーに表示されるナビゲーション項目を定義している。項目の追加・削除・並べ替えは、この配列の編集のみで完結する。サイドバーコンポーネント(`portal-sidebar.tsx`)はnavItemsを動的に読み取って描画するため、サイドバー自体のコードを変更する必要はない。

アイコンの対応付けは、`portal-sidebar.tsx`内のiconMapオブジェクトにおいて日本語ラベルとLucide Reactアイコンの対応を管理しており、新規項目に対応するアイコンの追加も容易である。

### 17.3.3 AIエージェントの追加・設定変更

本システムの12エージェント構成は、4象限フレームワークに基づいて設計されているが、各象限へのエージェント追加は設計上の制約を受けない。例えば、「守る(Guardian)」象限に「いじめ兆候検知エージェント」を追加する場合、当該エージェントの処理ロジックをProcessing Layerに実装し、その出力を表示するビューコンポーネントをOutput Layerに追加し、対応するGateレベル(例:L=0.7、教員承認必須)を設定するという手順で実現可能である。

### 17.3.4 Gate Levelの調整

Gate機構のL値は、各エージェントの出力に対するリスクレベルを定量的に制御するパラメータである。このL値は、教育機関の運用ポリシーや法的要件に応じて柔軟に調整可能な設計となっている。

例えば、ある教育機関においてAI活用に対する教職員の信頼度が高く、出席管理の自動化を推進したい場合、出席パターン解析エージェント(Agent 3)のGate LevelをL=0.2(自動処理・事後報告)に設定することが考えられる。逆に、AI活用に慎重な姿勢をとる機関においては、同エージェントのGate LevelをL=0.5(教員確認必須)に引き上げることで、段階的な信頼構築を図ることが可能である。

このGate Levelの調整は、管理者ロールの「AI設定(AdminAiSettings)」ビューを通じて、GUIベースで実施可能な設計を採用している。これにより、技術的知識を持たない学校管理者であっても、AI自律度の運用ポリシーを管理できる。

## 17.4 政策提言

本研究の設計および分析に基づき、教育機関におけるAI活用の健全な発展に向けて、以下の四つの政策提言を行う。

### 提言1: 教育AI導入ガイドラインの策定

#### Gate機構モデルの標準化

本研究が提案するGate機構は、AIの自律レベルを連続値L(0.0~1.0)で定義し、業務の性質と影響度に応じた制御を実現するモデルである。このモデルを教育AI導入における標準的なガバナンスフレームワークとして位置づけ、文部科学省の指針として策定することを提言する。



具体的には、教育業務を「事務処理系(L=0.2程度)」「教育支援系(L=0.3~0.5程度)」「進路判断系(L=0.7程度)」の三段階に類型化し、各段階におけるAIの権限範囲、人間の承認要件、事後監査の手続きを標準化するガイドラインの策定が求められる。

### 教育AI倫理審査の制度化

教育機関がAIシステムを導入する際に、当該システムの倫理的妥当性を事前に審査する制度の創設を提言する。審査項目には、データの取り扱い方針、AIの判断根拠の説明可能性、バイアスの検証方法、および生徒・保護者への説明責任の確保が含まれるべきである。内閣府「人間中心のAI社会原則」(2019)およびUNESCO「AIと教育に関する北京コンセンサス」(2019)の原則を基盤としつつ、日本の教育制度に適合した審査基準の策定が望まれる。

## 提言2: 教育データ基盤の整備

### 教育データ標準化の推進

文部科学省「教育データ活用ロードマップ」(2022)が示す方向性を加速し、教育データの標準的なスキーマ(データ構造)およびAPI仕様を策定することを提言する。本システムのInput Layer設計においても、学校データベースとの接続仕様の標準化が未解決課題として残っている。xAPIやCaliper Analytics等の国際標準を参考としつつ、日本の教育制度に固有のデータ項目(出席簿、指導要録、調査書等)を包含するデータ標準の策定が急務である。

### 学校間データ連携基盤の構築

教育機関間でのデータ連携を可能にする共通基盤の構築を提言する。生徒が転校・進学する際に、学習履歴やポートフォリオデータが途切れることなく引き継がれる仕組みは、個別最適な学びの連続性を確保するうえで不可欠である。デジタル庁が推進するガバメントクラウド上での教育データ連携基盤の構築を視野に入れた検討が求められる。

## 提言3: 教員向けAIリテラシー教育

### 教員養成課程へのAI教育の組み込み

大学の教員養成課程において、教育AI活用に関する科目を必修化することを提言する。当該科目においては、AIの基本原則、教育データ分析の手法、AI倫理の基礎、Gate機構のようなAIガバナンスフレームワークの理解、およびAIツールを活用した授業設計の実践を含む教育内容が求められる。

これは、教員がAIを「ブラックボックス」として受動的に使用するのではなく、AIの出力を批判的に評価し、教育的判断に適切に統合する能力——すなわち「教育AI活用力」——を養成することを目的とする。

### 現職教員向け研修プログラム

既に教壇に立つ教員に対しては、独立行政法人教職員支援機構(NITS)や各都道府県教育センターを通じた体系的な研修プログラムの提供が必要である。研修内容は、座学のみならず、本システムのような実際のAI支援システムを用いたハンズオン研修を含むことが望ましい。教員が実際にAIの提案を確認し、Gate機構を通じた承認プロセスを体験することで、AI活用に対する心理的障壁の低減と適切な活用スキルの習得が期待される。

## 提言4: 段階的導入フレームワーク

### 小規模パイロットから段階的拡大へのモデル

教育AIシステムの導入は、全校一斉導入ではなく、段階的なアプローチを採用すべきである。本研究の設計および分析に基づき、以下の3段階モデルを提案する。

**第1段階(3~6か月): 限定パイロット。** 特定の学年・クラスを対象として、「回す(Admin)」象限のエージェント(面談サマリー自動生成、保護者レポート生成)を中心に試験運用を行う。事務処理系のエージェントはGate LevelがL=0.2と低く、教員への心理的負担も小さいため、導入の初期段階として適切である。

**第2段階(6か月～1年):機能拡張。**第1段階の評価を踏まえ、「守る(Guardian)」象限のリスク検知エージェントおよび「育てる(Tutor)」象限の学習支援エージェントを追加導入する。Gate Levelは当初高めに設定し、教員の信頼度に応じて段階的に引き下げる。

**第3段階(1～2年):全面運用。**「導く(Management)」象限のエージェントおよびAgent Teamを含む全機能を展開し、全校的な運用に移行する。

#### 効果測定・フィードバックサイクルの制度化

各段階の移行判断にあたっては、定量的な効果測定指標の設定と、教員・生徒・保護者からの定性的フィードバックの収集を制度化すべきである。具体的には、教員の業務時間の変化、生徒の学業成績の推移、進路決定率の変化、およびシステム利用満足度を主要指標として設定し、学期ごとの評価報告を義務づけることが望ましい。

## 17.5 産学官連携の必要性

### 17.5.1 テクノロジー企業との連携

教育AI基盤の社会実装においては、大規模言語モデル(LLM)の提供者、クラウドインフラ事業者、およびEdTech企業との連携が不可欠である。特に、LLMの教育分野への適用においては、教育固有の倫理的制約(バイアスの排除、年齢に応じた出力制御等)を反映したファインチューニングが求められ、テクノロジー企業の技術力と教育機関のドメイン知識の融合が必要となる。

本システムの現行実装はフロントエンドプロトタイプ段階にあり、AIエージェントの実稼働にはバックエンドにおけるLLM統合が必要となる。この実装においては、APIの応答速度、コスト管理、データのオンプレミス処理要件等、テクノロジー企業との技術的協議が不可欠である。

### 17.5.2 大学研究機関との共同研究

Gate機構の妥当性検証、AIエージェントの教育効果測定、およびシステムのユーザビリティ評価においては、教育学・心理学・情報学の研究者との共同研究体制の構築が求められる。特に、AIの自律レベル設定が教育成果に及ぼす影響については、準実験デザインまたはランダム化比較試験(RCT)による長期的な検証研究が必要であり、大学の研究倫理審査委員会(IRB)の審査を経た厳密な研究プロトコルのもとで実施されるべきである。

### 17.5.3 行政によるインフラ整備支援

教育AIの導入を全国的に推進するためには、行政による基盤的な支援が欠かせない。具体的には、以下の施策が求められる。

第一に、教育AI導入に係る補助金・助成金制度の拡充である。特に財政基盤の脆弱な私立専門学校や地方の公立学校に対しては、初期導入コストおよび運用コストに対する公的支援が導入の前提条件となる。

第二に、教育データの安全管理・運用を支えるインフラ(セキュアクラウド環境、認証基盤等)の整備である。個人情報保護法および学校教育法に準拠したデータガバナンス体制の構築を、個々の教育機関の自助努力に委ねるのではなく、共通基盤として国が提供することが合理的である。

第三に、教育AI導入の先進事例を集約し、全国の教育機関が参照可能なナレッジベースの構築である。成功事例のみならず、導入に伴う困難や課題も含めた率直な事例共有が、他機関の導入判断を支援するうえで有用である。

## 17.6 小括

本章では、本システムの他教育機関への展開可能性を技術的・制度的両側面から検討し、四つの政策提言を行った。

本システムの設計は、コンポーネントベースアーキテクチャ、VIEW\_MAPレジストリパターン、ROLE\_CONFIGの集約管理、CSS変数によるカラーシステムという技術的基盤により、高等学校、大学、職業訓練校、インターナショナルスクール等の多様な教育機関への適用が可能である。政策面においては、Gate機構モデルの標準化を軸とした教育AI導入ガイド

ラインの策定、教育データ基盤の整備、教員向けAIリテラシー教育の充実、および段階的導入フレームワークの制度化を提言した。これらの施策は、産学官連携のもとで推進されることにより、日本の教育DXの加速に寄与するものとする。

## 第18章 結論・今後の展望

### 18.1 研究成果の総括

本研究は、専門学校(学校法人)における進路指導業務の構造的課題に対し、データドリブン型AI意思決定支援基盤「本システム」の設計とフロントエンドプロトタイプ実装を通じて応答するものであった。第1章で定義した5つの研究目的について、その達成状況を総括する(表18-1参照)。

表18-1 研究目的と達成状況の対応表

研究目的	具体的成果	達成度
目的1: データドリブン型AI意思決定支援基盤の設計	Input/Processing/Output 3層アーキテクチャの確立。Decision Intelligence層としての本システムの概念設計と技術設計を完了(第4章)	設計完了
目的2: 4象限12エージェント・2Agent Team体制の構築	Guardian(Agent 1,3)/Tutor(Agent 2,6)/Admin(Agent 7,9,10)/Management(Agent 4,5,8)の10エージェント+Agent Team 1(留学生対応)/Agent Team 2(進路相談)の設計・プロトタイプ実装を完了(第6-10章)	設計完了・UI実装完了
目的3: Gate機構によるAI自律度制御モデルの提案	連続値L( $L=0.2/L=0.3/L=0.7$ )による3段階Gate制御、Gate Card仕様、責任分解モデルを確立。EU AI Act準拠の設計指針を提示(第5章、第15章)	概念・設計完了
目的4: 4ロール対応フロントエンドプロトタイプの実装	管理者14画面/教員15画面/事務方15画面/学生12画面の計56画面をNext.js 16+React 19で実装。OKLCh配色、VIEW_MAPパターンによる拡張可能なUI基盤を構築(第11-12章)	実装完了
目的5: 導入効果の評価実験設計	4軸評価フレームワーク(業務時間・教育質・判断精度・満足度)の策定、A/Bテスト設計、縦断研究フレームワークの定義を完了。モックデータに基づく予備分析を実施(第14章)	設計完了・実施は今後

#### 目的1に関する成果

本システムのアーキテクチャは、学校内のデータベース(Input Layer)、本システムのエンジン+Gate機構(Processing Layer)、12の業務支援ソリューション(Output Layer)の3層構造として設計された(第4章)。このアーキテクチャは、単なる業務効率化ツールではなく、教員の意思決定を支援する「Decision Intelligence」層として位置づけられる。既存の学校管理システム(SMS)やLMSが「データの記録と参照」に留まるのに対し、本システムは「データの分析と意思決定支援」まで踏み込んだ設計を提示している。

#### 目的2に関する成果

4象限(守る・育てる・回す・導く・集める)の機能分類は、教育機関における業務を網羅的にカバーし、各象限に配置されたエージェント群が相互に連携するアーキテクチャを設計した。特にAgent Team概念(第10章)は、単体エージェントでは対応困難な複合課題(留学生対応、進路相談)に対して、複数エージェントのパイプライン型・オーケストレーション型連携を可能にする設計として独自性が高い。

#### 目的3に関する成果

Gate機構(第5章)は、本研究の最も重要な学術的貢献の一つである。AIの自律度を連続値Lで定義し、業務リスクに応じて3段階の人間関与度合いを設定するモデルは、教育AI分野において先行例が限定的な提案である。第15章で検討した

倫理・ガバナンス・法的フレームワークとの統合により、Gate機構は単なる技術的制御を超えて、教育AIガバナンスの制度設計指針としての汎用性を有することが設計レベルで示唆された。

## 目的4に関する成果

56画面のフロントエンドプロトタイプ(第11章)は、本システムの設計思想を具体的なUI/UXとして可視化し、ステークホルダー間の合意形成に資する成果物である。VIEW\_MAPレジストリパターン(第11章 11.3)およびROLE\_CONFIGによるロール管理(第4章 4.4)は、将来の機能拡張に対して高い拡張性を提供する設計パターンとして確立された。

## 目的5に関する成果

第14章で策定した評価フレームワークは、導入効果の多面的評価を可能にする設計であり、A/Bテスト設計(14.7.2)および縦断研究フレームワーク(14.7.3)は、今後の検証段階における評価手法の基盤となる。モックデータに基づく予備分析では、月間3,842回のエージェント利用、平均精度89.6%という設計目標値を試算した。

## 18.2 本研究の学術的貢献

本研究は、教育AI分野において以下の4つの新規性を有する学術的貢献をなすものである。

**第一に、教育機関向けマルチエージェントアーキテクチャの体系的設計**である。従来の教育AIは、学習リスク検知、適応型学習、自然言語処理等の個別機能に焦点を当てた研究が主流であった(Baker & Inventado, 2014; Romero & Ventura, 2020)。これに対し、本システムは4象限12エージェントという包括的なマルチエージェント体制を設計し、教育機関の業務全体をAI支援の対象とした点に独自性がある。

**第二に、Gate機構による「AIの自律度制御」という新概念の提案**である。Parasuraman et al. (2000)の自動化レベル分類を教育分野に適用・拡張し、連続値Lによる3段階制御モデルを提案した。この概念は、医療・法律等の他分野におけるAI導入にも応用可能な汎用性を持つ。

**第三に、Agent Team概念によるエージェント間協調パターンの類型化**である。AutoGen(Wu et al., 2023)やMetaGPT(Hong et al., 2023)等のマルチエージェントフレームワークの知見を教育分野に転用し、パイプライン型(Agent Team 1)とオーケストレーション型(Agent Team 2)の2つの協調パターンを類型化した。

**第四に、ロールベースUI設計パターン(VIEW\_MAP)の提案**である。4つの利用者ロールに対して56画面を動的に切り替えるVIEW\_MAPレジストリパターンは、マルチテナント型教育アプリケーションの設計パターンとして再利用可能である。

## 18.3 実践的意義

本研究の実践的意義は、以下の4点に集約される。

**教員の業務構造変革の設計指針の提示。**事務作業比率を70%から20%へ、学生対応時間を30%から80%へ移行するという目標値を掲げ、その達成に必要なAIエージェント構成とGate制御モデルを設計した。この設計指針は、教育現場におけるAI導入計画の策定に活用可能である。

**学生支援の高度化のための技術基盤の構築。**リスク早期検知(Agent 1, 3)、個別最適化学習(Agent 2, 6)、進路推薦支援(Agent 5)の3層的な学生支援体制は、「見逃しゼロ」の教育セーフティネットを技術的に実現する設計である。

**学校経営のデータドリブン化の推進。**Agent 8(学校経営ダッシュボード)およびAgent 4(成績評価妥当性チェック)は、経験と勘に依存しがちな学校経営をエビデンスに基づく意思決定へと転換する基盤を提供する設計である。

**教育AI導入のガバナンスモデルの提示。**第15章で提案したAI倫理委員会、年次倫理監査、インシデント対応フロー、バイアス監査プロセスは、教育機関がAIを責任ある形で導入・運用するためのガバナンスモデルとして、政策立案にも資する提言である。

## 18.4 本研究の限界

本研究は以下の5つの限界を有しており、これらを明示的に認識した上で結論を導出する。



**第一に、フロントエンドプロトタイプ段階であること。**本システムの現状実装はフロントエンドのみであり、バックエンド、データベース、認証基盤は未実装である(第12章 12.5, 12.6参照)。AIエージェントの処理ロジックはモックデータに基づいており、実際のLLM API呼び出しや機械学習モデルの統合は今後の課題である。

**第二に、定量分析がモックデータに基づくこと。**第14章で示したエージェント利用回数、精度指標、業務時間削減率はすべてシミュレーションに基づく推定値であり、実環境での検証を経ていない。ROI試算(第14章 14.6)も見込み値であることに留意が必要である。

**第三に、単一教育機関を対象とした設計であること。**本システムの設計は清風情報工科学院の専門学校を想定しており、高等学校、大学、職業訓練校等への展開には、各機関固有の要件に基づく再設計が必要である(第16章参照)。

**第四に、AIモデル自体の開発は範囲外であること。**本研究はAIエージェントの「設計フレームワーク」とUI/UXの実装に焦点を当てており、リスク検知アルゴリズムや推薦エンジンの機械学習モデルの開発・評価は実施していない。

**第五に、長期的な教育効果の検証が未完了であること。**AIを活用した進路指導が学生の進路決定率、就職率、満足度に及ぼす長期的な効果の検証には、数年単位の縦断研究が必要であり、本研究の範囲を超える。

## 18.5 今後の研究課題

本研究の成果を発展させるため、以下の3フェーズによるロードマップを提案する。

### Phase 1: 基盤実装(短期: 6ヶ月)

- バックエンド実装: Next.js API Routes + Postgresによるデータ層の構築
- 認証基盤: NextAuth.js / Supabase Authによる4ロール認証の実装
- 実データ接続: 既存学校管理システムとのAPI連携、データ移行パイプラインの構築
- LLM API統合: Gemini APIを用いたエージェント処理ロジックの実装
- セキュリティ基盤: RBAC本格実装、データ暗号化、監査ログの永続化

### Phase 2: パイロット導入(中期: 1年)

- パイロット校での試験運用(教員20名、学生200名規模)
- A/Bテストの実施(第14章 14.7.2の設計に基づく)
- 教員フィードバック収集と反復改善
- Gate Level最適化(運用データに基づくL値の調整)
- バイアス監査の初回実施(第15章 15.2.4の設計に基づく)

### Phase 3: 展開と標準化(長期: 2-3年)

- 縦断研究の実施(第14章 14.7.3の設計に基づく3年間の追跡調査)
- 他校への展開(高等学校、大学への適用検証)
- Gate機構の標準化提言(第16章 16.4.1の政策提言に基づく)
- 教育AI利用ガイドラインへの反映(文部科学省との連携)
- オープンソース化の検討(VIEW\_MAP、ROLE\_CONFIG等の設計パターンの公開)

## 技術的課題

今後の技術的課題として、リアルタイム処理(WebSocket / Server-Sent Eventsによるリスクアラートの即時配信)、大規模データ対応(数千名規模の学生データに対するエージェント処理の並列化)、LLMコスト最適化(キャッシング、プロンプト最適化、モデル選択の動的切替)の3点が挙げられる。

## 制度的課題

制度的課題として、教育AI利用ガイドラインの策定プロセスへの貢献、AI倫理審査フレームワークの教育機関向け標準化、教員のAIリテラシー向上のための研修プログラム設計、および個人情報影響評価(PIA)の教育分野向けテンプレート開発が今後の研究対象となる。

## 18.6 教育の未来への展望

本研究は、「データドリブンな温かみのある教育」の実現に向けた第一歩として位置づけられる。

本システムが目指すのは、AIが教員を代替する教育ではない。AIが事務作業と情報収集を担うことで、教員が「教えること」と「寄り添うこと」という本質的な教育活動に回帰するための制度的インフラの構築である。

Gate機構は、AIの効率性と教育の人間的価値を構造的に両立させるための設計的回答である。L=0.7のGate Levelが守るのは、データには表れない教育の「温かみ」——学生表情から不安を読み取る洞察力、適切な言葉を選んで励ます共感力、一人ひとりの成長を信じて待つ忍耐力——である。

「見逃しの低減と寄り添いの強化」という目標の実現に向けて、本システムは教育DXの新たな地平を切り拓く基盤となることを企図している。技術の進歩が教育の本質を損なうのではなく、むしろ教育の本質に教員が集中できる環境を創出する——そのような未来の教育の姿を、本研究は提示するものである。

# 付録

## 付録A 統合参考文献一覧(提出版・最小構成)

提出版では、検証可能性と追跡可能性を優先し、基礎文献のみを掲載する。

- 61. European Parliament (2024). Regulation (EU) 2024/1689 (Artificial Intelligence Act).
- 62. OECD (2019). Recommendation of the Council on Artificial Intelligence. OECD/LEGAL/0449.
- 63. UNESCO (2021). AI and Education: Guidance for Policy-makers.
- 64. 文部科学省 (2019). GIGAスクール構想の実現について.
- 65. デジタル庁・総務省・文部科学省・経済産業省 (2022). 教育データ利活用ロードマップ.
- 66. 文部科学省 (2023). 第4期教育振興基本計画.
- 67. 文部科学省 (2023). 初等中等教育段階における生成AIの利用に関する暫定的なガイドライン.
- 68. 個人情報保護委員会. 個人情報の保護に関する法律についてのガイドライン(通則編).

## 付録B コンポーネント一覧

### B.1 UIコンポーネント(shadcn/ui — 57コンポーネント)

カテゴリ	コンポーネント名	用途
フォーム	Input, Textarea, Select, Checkbox, Radio Group, Switch, Slider	データ入力
フォーム	Form, Label	フォーム構造
表示	Card, Badge, Alert, Progress, Tooltip, Separator	情報表示
ナビゲーション	Tabs, Breadcrumb, Navigation Menu	画面遷移
データ	Table	データー一覧表示
ダイアログ	Dialog, Alert Dialog, Sheet, Drawer (vaul)	モーダル・パネル
メニュー	Dropdown Menu, Context Menu, Menubar	操作メニュー
オーバーレイ	Popover, Hover Card, Command (cmdk)	ポップアップ
レイアウト	Scroll Area, Resizable (react-resizable-panels), Collapsible, Accordion	レイアウト制御
フィードバック	Toast (sonner), Skeleton	状態フィードバック
メディア	Avatar, Aspect Ratio, Carousel (embla)	メディア表示
日付	Calendar (react-day-picker)	日付選択
その他	Toggle, Toggle Group, Input OTP	特殊入力

### B.2 ポータル共通コンポーネント

コンポーネント	ファイル	役割	使用ロール
PortalHeader	portal-header.tsx	ロール対応ヘッダー(検索・通知・プロフィール)	全ロール
PortalSidebar	portal-sidebar.tsx	コンテキストアウェアサイドバー(60+アイコン対応)	全ロール
KPICard	kpi-card.tsx	KPI/メトリクス表示(ロール別ボーダーカラー)	全ロール
AlertList	alert-list.tsx	アラート表示(danger/warning/info 3種)	admin, teacher, office
ActivityFeed	activity-feed.tsx	アクティビティログ表示	admin, teacher

ThemeProvider	theme-provider.tsx	next-themes ダークモード ラッパー	全ロール
---------------	--------------------	----------------------------	------

## B.3 ビューコンポーネント一覧(56画面)

### 管理者(Admin)ビュー — 14画面

Nav ID	ファイル	画面名	主要機能
a-1	admin-dashboard.tsx	ダッシュボード	システムKPI、アラート、アクティビティ、ファネルチャート
a-2	admin-user-management.tsx	ユーザー管理	ユーザーCRUD、ロールフィルタリング
a-3	admin-user-detail.tsx	ユーザー詳細	プロフィール編集、権限設定、アクティビティログ
a-4	admin-class-management.tsx	クラス管理	クラス構成、TGマッピング
a-5	admin-tg-management.tsx	TG管理	進路指導グループ管理
a-6	admin-tg-approval.tsx	TG承認	TG変更承認ワークフロー
a-7	admin-career-master.tsx	進路先マスタ	進路先マスタデータ管理
a-8	admin-career-detail.tsx	進路先詳細	進路先詳細情報
a-9	admin-milestone-management.tsx	マイルストーン管理	重要日程の設定
a-10	admin-announcements.tsx	お知らせ管理	全体お知らせ投稿
a-11	admin-statistics.tsx	統計・AI分析	学校統計、AIインサイト、年度推移
a-13	admin-student-groups.tsx	学生グループ	グループ/コホート管理
a-15	admin-ai-tools.tsx	AIツール管理	10エージェント+2Agent Team管理ダッシュボード
a-16	admin-ai-settings.tsx	AI設定	Gate設定、モデル設定、承認WF、データアクセス、監査ログ

### 教員(Teacher)ビュー — 15画面

Nav ID	ファイル	画面名	主要機能
t-1	teacher-dashboard.tsx	ダッシュボード	KPI、リスクアラート、面談予定、学生検索
t-2	teacher-student-list.tsx	学生一覧	検索・フィルタ付き学生リスト(リスク表示)
t-3	teacher-student-detail.tsx	学生カルテ	包括的學生プロフィール
t-4	teacher-interview-list.tsx	面談一覧	面談記録リスト
t-5	teacher-interview-input.tsx	面談記録入力	面談記録作成フォーム
t-6	teacher-risk-alerts.tsx	リスクアラート	Agent 1, 3によるリスク警告
t-7	teacher-career-search.tsx	進路先検索	進路先検索インターフェース
t-8	teacher-career-detail.tsx	進路先詳細	進路先詳細情報
t-9	teacher-application-management.tsx	出願管理	学生出願状況追跡
t-10	teacher-announcements.tsx	お知らせ	お知らせ閲覧
t-11	teacher-countdown-calendar.tsx	逆算カレンダー	重要日程カウントダウン
t-15	teacher-interview-booking.tsx	面談予約	面談スケジュール管理

t-16	teacher-digest.tsx	ダイジェスト	AI生成サマリーレポート
t-17	teacher-ai-tools.tsx	AIツール	5エージェント+Agent Team 2操作画面
t-18	teacher-student-diagnosi s.tsx	個別生徒AI診断	個別生徒のAI診断画面

#### 事務方(Office)ビュー — 15画面

Nav ID	ファイル	画面名	主要機能
o-1	office-dashboard.tsx	ダッシュボード	処理待ち件数、面談予定、 データ取込状況
o-2	office-student-list.tsx	学生一覧	事務用学生リスト
o-3	office-student-detail.tsx	学生詳細	学生事務情報
o-4	office-test-management.t sx	テスト管理	テスト/試験スコア管理・取 込
o-5	office-document-manage ment.tsx	書類管理	文書/手続書類管理
o-6	office-career-info.tsx	進路情報	進路先情報
o-7	office-career-detail.tsx	進路先詳細	進路先詳細情報
o-8	office-application-manage ment.tsx	出願管理	出願状況追跡
o-9	office-announcements.tsx	お知らせ	お知らせ閲覧
o-10	office-student-groups.tsx	学生グループ	グループ管理
o-11	office-interview-booking.t sx	面談予約	面談スケジュール管理
o-12	office-statistics.tsx	統計	事務統計
o-13	office-digest.tsx	ダイジェスト	サマリーレポート
o-14	office-data-import.tsx	データ取込	バルクデータ取込機能
o-15	office-ai-tools.tsx	AIツール	AIツール操作画面

#### 学生(Student)ビュー — 12画面

Nav ID	ファイル	画面名	主要機能
s-1	student-dashboard.tsx	マイページ	進路状況、Plan A/B/C、タ スク、カレンダー
s-2	student-test-scores.tsx	テストスコア	成績追跡・分析
s-3	student-goals.tsx	目標設定	目標設定インターフェース
s-4	student-interview-records .tsx	面談記録	面談記録閲覧
s-5	student-career-info.tsx	進路情報	進路先情報ブラウジング
s-6	student-career-detail.tsx	進路先詳細	進路先詳細情報
s-7	student-application-status .tsx	出願状況	Plan A/B/C出願状況追跡
s-8	student-announcements.t sx	お知らせ	お知らせ閲覧
s-9	student-calendar.tsx	カレンダー	重要日程・締切表示
s-11	student-interview-booking .tsx	面談予約	AI推奨タイムスロット付きス マート予約
s-12	student-ai-tools.tsx	AIアシスタント	3つのAIツール(チャット含 む)
s-13	student-portfolio.tsx	ポートフォリオ	成果物提出・閲覧

## 付録C 用語集(Glossary)

用語	英語	定義
本システム	Education Decision Intelligence Platform	本研究で設計した教育機関向けAI意 思決定支援基盤



Gate機構	Gate Mechanism	AIの自律度を3段階(L=0.2/0.3/0.7)で制御する本システム独自のガバナンス機構
Gate Card	Gate Card	各エージェント/Agent Teamの処理に対するリスクレベル、制御方式、承認権限者を記載した仕様カード
Gate Level	Gate Level	AIの自律度を表す連続値L。値が小さいほど自動化度が高い
Agent	Agent	特定の単一タスクを処理するAI機能単位。本システムは10個のAgentを有する
Agent Team	Agent Team	複数のAgent(Planet)が連携して複合課題を解決する統合ワークフロー
Planet	Planet	Agent Team内で特定の役割を担うサブエージェント
Guardian Agents	Guardian Agents	「守る」象限のエージェント群。リスク早期検知を担当(Agent 1, 3)
Tutor Agents	Tutor Agents	「育てる」象限のエージェント群。個別最適化学習支援を担当(Agent 2, 6)
Admin Agents	Admin Agents	「回す」象限のエージェント群。事務業務自動化を担当(Agent 7, 9, 10)
Management Agents	Management Agents	「導く」象限のエージェント群。経営意思決定支援を担当(Agent 4, 5, 8)
VIEW_MAP	VIEW_MAP	ナビゲーションIDからReactコンポーネントへの動的マッピングレジストリ
ROLE_CONFIG	ROLE_CONFIG	ロール(admin/teacher/office/student)ごとのラベル、色、ナビゲーション項目を定義する設定オブジェクト
OKLCh	OKLCh Color Space	知覚的均一性を持つ色空間。本システムのテーマカラーシステムの基盤
Decision Intelligence	Decision Intelligence(意思決定インテリジェンス)	データ分析とAI推論を統合して人間の意思決定を支援する技術概念
HITL	Human-in-the-Loop	AIの処理ループに人間の確認・承認を組み込む設計パターン
XAI	Explainable AI(説明可能AI)	AIの判断プロセスを人間が理解可能な形で提示する技術・設計原則
進路指導	Career Guidance / Career Counseling	学生の適性・能力に応じた進学先・就職先の選択を支援する教育活動
TG	Teaching Group(進路指導グループ)	進路指導のために編成される教員-学生のグループ単位
EWS	Early Warning System(早期警戒システム)	リスクのある学生を早期に検知するためのデータ分析システム
LMS	Learning Management System(学習管理システム)	学習コンテンツの配信・進捗管理を行うシステム
SMS	School Management System(学校管理システム)	学校の事務・管理業務を支援するシステム
DX	Digital Transformation(デジタルトランスフォーメーション)	デジタル技術を活用した業務・組織の変革
RBAC	Role-Based Access Control(ロールベースアクセス制御)	ユーザーのロール(役割)に基づいてアクセス権限を制御するセキュリティモデル
CSR	Client-Side Rendering(クライアントサイドレンダリング)	ブラウザ側でUIを描画する方式
SSR	Server-Side Rendering(サーバーサイドレンダリング)	サーバー側でHTMLを生成してブラウザに配信する方式
CVA	class-variance-authority	コンポーネントバリエーションを定義するためのTypeScriptライブラリ

cn()	className utility	clsx + tailwind-mergeを組み合わせた条件付きクラス名結合ユーティリティ
SPA	Single Page Application	ページ遷移なしに画面を切り替えるWebアプリケーション方式
API	Application Programming Interface	システム間のデータ連携インターフェース
LLM	Large Language Model(大規模言語モデル)	大量のテキストデータで学習された自然言語処理AI
ROI	Return on Investment(投資対効果)	投資に対する利益の比率
DEI	Diversity, Equity, and Inclusion(多様性・公平性・包摂性)	組織における多様な人材の受入れと公平な処遇に関する概念
WCAG	Web Content Accessibility Guidelines	Webコンテンツのアクセシビリティに関する国際ガイドライン
WAI-ARIA	Web Accessibility Initiative - Accessible Rich Internet Applications	Webアプリケーションのアクセシビリティを向上させるための仕様
PDCA	Plan-Do-Check-Act	継続的改善のためのマネジメントサイクル
KPI	Key Performance Indicator(重要業績評価指標)	目標達成度を測定するための定量的指標
PIA	Privacy Impact Assessment(個人情報影響評価)	個人情報の取扱いが個人のプライバシーに与える影響を事前に評価するプロセス
GIGAスクール構想	GIGA School Program	文部科学省が推進する児童生徒1人1台端末と高速ネットワーク整備の施策
教育データ活用ロードマップ	Education Data Utilization Roadmap	教育分野におけるデータ活用の段階的推進計画(デジタル庁・総務省・文科省・経産省、2022年)
第4期教育振興基本計画	4th Basic Plan for the Promotion of Education	2023-2027年度の教育政策の基本方針(文部科学省)
要配慮個人情報	Sensitive Personal Information	不当な差別等が生じないように特に配慮を要する個人情報(改正個人情報保護法)
EU AI Act	European Union Artificial Intelligence Act	2024年発効のEU包括的AI規制法
GDPR	General Data Protection Regulation	EU一般データ保護規則
COPPA	Children's Online Privacy Protection Act	米国の児童オンラインプライバシー保護法