

2026

RAITM

学習ガイドと
学習目標



RAITM | Risk and AI

2026年RAIの学習ガイドと 学習目標

出題範囲と試験配分

この「RAIの学習ガイドと学習目標」文書では、RAI試験の主な出題トピックについて説明しています。GARPのAI Advisory Committee (AI顧問委員会)が、人工知能(AI)がもたらす機会とリスクを多方面から理解するために不可欠なものとして、これらのカリキュラムトピックを承認しました。カリキュラムは、これらのトピックに重要度に応じて配分されており、RAI試験が最新かつ有用であり続けるよう毎年見直されています。

学習目標は、この学習ガイドに記載されている各モジュールまたは各章の冒頭に箇条書きで表示されます。これらの学習目標には、2026年RAIカリキュラムの各モジュールまたは各章に関連する主なテーマを受験者にわかりやすく提示するという意図があります。

この文書は重要な教材です。試験対策の期間中、定期的に参照するようにしてください。

RAI試験の方針

RAI試験は実践重視です。試験問題は、2026年RAIカリキュラムの5つのモジュールで提示された概念に基づいて作成され、多くの場合、実際の業務シーンを想定した文脈で出題されます。

試験は、RAIカリキュラム全体の内容について受験者の理解度を確認するため、包括的に出題されます。試験はすべて同じ配点の多肢選択問題80問で構成されています。すべての試験問題は独立していますが、複数の問題が同じ資料(シナリオ、データセットなど)に基づいている場合もあります。

2026年RAIカリキュラム


RAIカリキュラムは、デジタル学習プラットフォームGARP Learningまたは購入可能な印刷版書籍を通じて提供されており、個人が組織におけるAIの影響を適切に管理するために必要なすべての知識分野を網羅しています。これらのモジュールで扱われるトピックは、GARPのAI顧問委員会によって審査・承認されたものです。受験前にカリキュラムを詳しく確認することを強く推奨します。モジュール1、3、4、5、およびモジュール2の各章(全10章)は、受験者が学習を進める際に指針となる一連の学習目標から始まります。各章の最後には復習問題があります。試験に登録したすべての受験者にはGARP Learningへのアクセスが提供されます。印刷版書籍とGARP Learningは同じ試験範囲の内容を提供しますが、内容の理解に役立つ多彩な補足資料(動画、読み物、ケーススタディなど)が含まれているのはGARP Learningのみです。

RAI正誤表

GARPは、RAI正誤表において、カリキュラムの説明の明確化や印刷上の誤りを定期的に更新します。GARP Learningでは、RAIカリキュラムの「レッスン」タブでRAI正誤表を確認できます。カリキュラムの誤りや矛盾と思われる点を発見された場合は、事前に正誤表を確認し、訂正済みかどうかを確認の上、各コンテンツページ下部の「Report Content Errors」(コンテンツの誤りを報告)リンクから報告してください。軽微な編集上や文法上の誤り、誤字などを含む、あらゆる種類の報告を歓迎いたします。ただし、正式なRAI正誤表に掲載されるのは、内容や質問の重大な誤りのみです。

CONTENTS

| | |
|--|----|
| 2026 年 RAI の学習ガイドと学習目標..... | 1 |
| モジュール 1: AI とリスク: 序論と概要..... | 3 |
| モジュール 2: ツールと手法..... | 4 |
| 第 1 章: ツールと手法の概要..... | 5 |
| 第 2 章: 教師なし学習..... | 6 |
| 第 3 章: 教師あり学習 – 計量経済学的手法..... | 7 |
| 第 4 章: 教師あり学習 – 機械学習手法..... | 8 |
| 第 5 章: 半教師あり学習..... | 9 |
| 第 6 章: 強化学習..... | 10 |
| 第 7 章: 教師あり学習 – モデルの推定..... | 11 |
| 第 8 章: 教師あり学習 – モデルのパフォーマンス評価..... | 12 |
| 第 9 章: 自然言語処理..... | 13 |
| 第 10 章: 生成 AI と LLM..... | 14 |
| モジュール 3: リスクとリスク要因..... | 15 |
| モジュール 4: 責任ある倫理的な AI..... | 16 |
| モジュール 5: データと AI モデルのガバナンス..... | 17 |
| RAI プログラムの顧問 およびコンテンツ執筆者..... | 18 |



モジュール 1:

AI とリスク: 序論と概要

出題比率: 5 ~ 15%

学習目標

人工知能 (AI) を導入すれば、どの組織も利用に伴い新しい種類のリスクに直面することになります。このモジュールでは、AI の歴史的背景を探り、機械学習 (ML) の方法論と生成 AI (GenAI) の両方について概要を把握し、AI/ML に伴うリスクの基本を学びます。

このモジュールを学習すると、次のことができるようになります。

- 古典的な AI の中核となる一部の原理 (探索手法、再帰性など) を説明する。
- 古典的な AI の限界について説明する。
- ディープラーニングの可能性と限界を明確に述べる。
- AI と ML の進化につながった重要なブレイクスルーを特定する。
- 強化学習、教師あり学習、教師なし学習、半教師あり学習を比較検討し、各手法の実用的な応用例を挙げる。
- AI および ML の不可解性 (Inscrutability) に関連するリスクについて論じる。
- AI システムへの過度な依存に伴うリスクについて論じる。
- AI がどのように個人、組織、社会をリスクにさらすかを論じる。

モジュール 2: ツールと手法

出題比率: 25 ~ 35%

このモジュールでは、以下の AI/ML のツールや手法について、10 個の章に分けて詳しく説明します。

- 第 1 章: ツールと手法の概要
- 第 2 章: 教師なし学習
- 第 3 章: 教師あり学習 – 計量経済学的手法
- 第 4 章: 教師あり学習 – 機械学習手法
- 第 5 章: 半教師あり学習
- 第 6 章: 強化学習
- 第 7 章: 教師あり学習 – モデルの推定
- 第 8 章: 教師あり学習 – モデルのパフォーマンス評価
- 第 9 章: 自然言語処理
- 第 10 章: 生成 AI と LLM

第 1 章: ツールと手法の概要

学習目標

機械学習 (ML) とは、予測や分類などのさまざまな用途に応じて、データのパターンを認識できるようにモデルを訓練するための多様な手法の総称です。本章では、ML の手法と応用例、潜在的な利点、そして導入時に考慮すべき点について全体像を紹介します。

本章の学習を終えると、次のことができるようになります。

- 機械学習の手法と古典的な計量経済学を区別する。
- 教師なし学習、教師あり学習、半教師あり学習、強化学習モデルの違いを区別する。
- 異なるデータタイプを区別する。
- カテゴリ変数のエンコード方法を説明する。
- データクレンジングの方法とデータクレンジングが必要な理由を説明する。
- データ準備の手法とその利点について説明する。
- データセットに対してデータスケールリングとデータ変換を適用する。
- データセットの次元を削減するために主成分分析 (PCA) がどのように用いられるかを述べる。
- 訓練用、検証用、テスト用に分割したデータの違いとそれぞれの使用方法について説明する。

第 2 章: 教師なし学習

学習目標

教師なし学習は、人工知能および機械学習において、データから直接、隠れたパターンや構造、洞察を見つけ出すための強力なアプローチです。本章では、クラスタリング分析 (しばしばセグメンテーションとも呼ばれる) に焦点を当てます。これは、教師なし学習の一般的で非常に実用的な応用例です。クラスタリングによって、データポイントをその特徴 (または「特徴量」) の類似性に基づいてグループ化することを目指します。

説明のかなりの部分を、広く採用されている手法である K-means クラスタリングに割きます。K-means の適用方法や、最適なクラスター数の決め方、そしてパフォーマンスをどのように評価するかを解説します。また、多様なリスクマネジメントのシナリオにおいて、K-means クラスタリングの本質的な強みと限界について議論します。

本章の学習を終えると、次のことができるようになります。

- クラスタリング手法を区別する。
- K-means 法でデータをクラスターに分割する仕組みを示す。
- K-means クラスタリングの長所と短所を説明する。
- クラスター内平方和 (WCSS) やクラスター間平方和 (BCSS) などのパフォーマンス指標について説明する。
- 教師なし学習において、最適なクラスター数を決定するためのさまざまな手法を適用する。
- デンドログラム (樹形図) の構造と用途について説明する。

第3章： 教師あり学習 – 計量経済学的手法

学習目標

本章では、計量経済学から生まれた教師あり学習で使われる主要モデルを取り上げます。本章は主に2部構成となっており、まず線形回帰モデルを吟味します。これは、さらに高度なアプローチの基盤となります。次に、ロジスティック回帰分析や線形判別分析など、分類問題を扱う時に用いられるモデルの種類について概説します。

主にコンピュータサイエンスを中心に発展し、機械学習とより強く結び付いている教師あり学習の手法については、第4章で扱います。

本章の学習を終えると、次のことができるようになります。

- 単回帰分析および重回帰分析の用途と制約を理解する。
- 単回帰分析および重回帰分析の結果を解釈する。
- 線形回帰モデルでよく起きる定式化の誤りの問題とその潜在的な対処法について説明する。
- ロジスティック回帰を分類問題を解くためにどのように応用できるかを説明する。
- 分類タスクで線形判別分析がどのように使われるかを説明する。

第4章： 教師あり学習 – 機械学習手法

学習目標

本章では、教師あり学習の検討をさらに進め、主にコンピューターサイエンスの分野で発展してきた強力な手法の数々に焦点を移していきます。分類問題と予測問題の両方に適用できる手法を幅広く取り上げ、直感的に理解しやすい決定木（デシジョンツリー）やK近傍法といった手法に加えて、強力なサポートベクターマシンについても説明します。また、章の大部分をニューラルネットワークの概要説明にも割いています。ニューラルネットワークは、人間の脳が情報を処理する仕組みに着想を得た汎用性の高いモデリング手法であり、時系列予測から自然言語処理まで幅広い分野で応用されています。章の最後には、オートエンコーダについて解説します。オートエンコーダは、モデルサイズを縮小する次元削減など、教師なし学習のタスクに用いられる特殊なニューラルネットワークです。

本章の学習を終えると、次のことができるようになります。

- 2種類の決定木の違いを説明し、それぞれがどのように構築され、どのように解釈されるかを述べる。
- 剪定 (Pruning) やアンサンブル手法が決定木のパフォーマンスをどのように向上させるかを説明する。
- K近傍法 (KNN) を用いて分類を行う。
- サポートベクターマシンがデータ分類にどのように使われるかを説明する。
- ニューラルネットワークがどのように構築されるかを説明し、関連する課題について論じる。
- 畳み込みニューラルネットワーク (CNN) や回帰型ニューラルネットワーク (RNN) など、高度なニューラルネットワーク構造について説明する。
- オートエンコーダが次元削減にどのように使われるのかを説明し、オートエンコーダとPCAの違いについて述べる。

第 5 章： 半教師あり学習

学習目標

実際の現場では多くの場合、完全なデータセットが用意されていることはなく、完全にラベル付けされたデータと、はるかに大量のラベルなしデータが混在しています。半教師あり学習は、教師なし学習と教師あり学習のパラダイムの間をつなぐ存在であり、両方のタイプのデータを効果的に活用するための一連の手法を提供します。本章では、半教師あり学習の中核となる概念を紹介し、これらの手法を効果的に活用するうえで満たすべき重要な前提条件を提示します。また、自己訓練と共訓練 (コートレーニング) についても詳しく解説します。この 2 つは、半教師あり学習を実務で応用する際に広く用いられている強力な手法です。

本章の学習を終えると、次のことができるようになります。

- 半教師あり学習が、教師なし学習や教師あり学習とどのように違うかを説明する。
- 効果的な半教師あり学習に必要な前提条件について述べる。
- 半教師あり学習の応用分野を挙げる。
- 半教師あり学習のトランスダクティブ手法と帰納的手法の違いを説明する。
- 半教師あり学習における自己訓練と共訓練を比較し、それぞれの長所と短所を理解する。

第 6 章: 強化学習

学習目標

本章では、機械学習の中でも独特で強力な分野である強化学習を紹介します。これまでに取り上げた教師あり学習や教師なし学習とは異なり、強化学習は試行錯誤によるフィードバックプロセスを通じてモデルを学習させます。最終的な目標は、値を予測したり観測値を分類したりすることではなく、長期的な累積報酬を最大化するような、最適な一連の行動を学習することです。したがって、強化学習モデルの「出力」とは、推奨される行動または意思決定のための方策です。

本章の学習を終えると、次のことができるようになります。

- 強化学習の主な原理と、背後にある枠組みについて説明する。
- 探索 (exploration)、活用 (exploitation)、 ϵ -greedy 方策を比較し、違いを説明する。
- 多腕バンディット (MAB) 問題の文脈において強化学習を説明する。
- モンテカルロ法と時間差分法の違いを説明する。
- 深層強化学習について説明する。
- 価値ベースと方策ベースの強化学習手法を比較し、違いを説明する。

第7章： 教師あり学習 – モデルの推定

学習目標

本章では、第3章および第4章で紹介した基礎的な教師あり学習モデルを踏まえて、教師あり学習モデルの推定という重要なプロセスに焦点を当てて解説します。モデルがラベル付きデータからどのようにパラメータを推定して「学習」を進めていくのか、その仕組みを探ります。また、2つの主要な推定パラダイムである最小二乗法と最尤法を取り上げます。さらに、特に複雑で非線形なモデルのパラメータ推定において、現代の機械学習で主力となっている強力な勾配降下法についても解説します。本章では、バイアスとバリエーション（偏りと分散）のトレードオフ、過学習（オーバーフィッティング）や過小適合（アンダーフィッティング）の問題、そして正則化や交差検証といった、より頑健で信頼性の高いモデルを構築するための手法など、主要概念についての重要な洞察も提供します。

本章の学習を終えると、次のことができるようになります。

- 最小二乗法 (OLS)、非線形最小二乗法 (NLS)、最尤推定法 (MLE) を比較し、それぞれの違いを述べる。
- 勾配降下法がモデルパラメータの推定にどのように用いられるかを説明する。
- バッチ (最急) 勾配降下法、確率的勾配降下法、および動的学習率の手法が、収束を改善するためにどのように利用されているかを述べる。
- ニューラルネットワークで最適な重みを求めるために、バックプロパゲーション (誤差逆伝播法) がどのように使われるかを説明する。
- ニューラルネットワークの訓練時に生じる計算上の課題と、その解決策を理解する。
- 過小適合 (アンダーフィッティング) と過学習 (オーバーフィッティング) について説明し、それらの原因を述べる。
- モデルのバイアスとバリエーション (偏りと分散) のトレードオフについて説明する。
- モデルの予測精度と解釈可能性のトレードオフについて説明する。
- 過学習を防ぐために正則化手法がどのように用いられるかを説明する。
- 交差検証、層化 (stratified) 交差検証、ブートストラップ法について説明する。
- グリッドサーチ法をハイパーパラメータの調整にどのように利用できるかを説明する。

第 8 章: 教師あり学習 – モデルのパフォーマンス評価

学習目標

本章では、教師あり学習モデルのパフォーマンスを理解するための適切な用語と技術的基盤、そして適切なモデルパフォーマンス指標を選択するために考えるべき問いについて解説します。

本章の学習を終えると、次のことができるようになります。

- 教師あり学習モデルのパフォーマンスを評価するために用いられる指標について説明する。
- 連続値を予測するモデルおよび分類モデルのパフォーマンスを、さまざまな指標を用いて評価する。
- 真陽性率と偽陽性率の関係、およびこのトレードオフが ROC (Receiver Operating Curve) 曲線を用いてどのように示されるかを説明する。
- ビジネスのニーズに基づいて、分類モデルの意思決定の閾 (しきい) 値をどのように選択するかを説明する。

第 9 章:

自然言語処理

学習目標

自然言語処理 (NLP) は、コンテンツ分析、テキストマイニング、計算言語学とも呼ばれ、機械学習の中でも最も刺激的で急速に発展している応用分野の 1 つです。NLP は、非構造化された自由形式のテキストデータを扱い、人間の言語 (書き言葉と話し言葉の両方) を理解し分析します。

本章では、NLP モデルについて一通り説明します。NLP モデルで使用するためのテキスト情報の準備、機械学習を用いない NLP 手法と機械学習を用いる NLP 手法、そして NLP モデルの適合度の評価方法などを紹介します。

本章の学習を終えると、次のことができるようになります。

- 自然言語処理 (NLP) の応用について説明する。
- NLP の前処理手順を説明する。
- Bag of Words (BoW) および n-gram のアプローチについて説明する。
- 辞書アプローチと機械学習アプローチについて説明し、それぞれの利点と限界を述べる。
- 文書内の単語に適切な重み付けを行うために、TF-IDF (Term Frequency-Inverse Document Frequency: 単語出現頻度-逆文書頻度) がどのように用いられるかを説明する。
- 文書を分類するためにナイーブベイズ分類器がどのように用いられるかを説明する。
- NLP モデルを評価する際に考慮すべき要素について説明する。

第 10 章: 生成 AI と LLM

学習目標

生成 AI (GenAI) 技術の急速な進歩は、2020 年代における重要な出来事です。今では、リスクマネジメントを含む幅広い分野でこの技術が応用されています。リスク管理者がこの変革的な技術を十分に理解しておくことは不可欠です。本章では、生成 AI と大規模言語モデル (LLM) の関係、およびそれらを支えるツールや技術について説明します。

本章の学習を終えると、次のことができるようになります。

- コンテンツのモダリティ (種類) とモデリングアルゴリズムに基づく生成 AI の分類法を説明する。
- 埋め込みを使って単語ベクトルを表現する方法と、その利点および限界について解説する。
- 単語埋め込みを使って単語同士を比較する方法について説明する。
- Word2Vec の 2 つのアーキテクチャの違いを説明する。
- 文中の単語同士の関係の捉え方という点で、回帰型ニューラルネットワーク (RNN)、LSTM、およびトランスフォーマーの違いを説明する。
- LLM の基本構造と、概念レベルでどのように訓練されるかを説明する。
- LLM におけるプロンプトエンジニアリングについて説明する。
- コンテキスト長とステータス性が LLM のパフォーマンスおよびユーザーとの対話に与える影響について説明する。
- Temperature (温度)、Top-K、Top-P の各パラメータが LLM の創造性、予測可能性、出力品質にどのように影響するかを説明する。
- 生成 AI および LLM のパフォーマンス評価における課題について論じ、出力を評価するためのさまざまな方法について説明する。
- エージェント AI と生成 AI の違いを説明する。
- 生成 AI と LLM の応用分野を説明する。

モジュール 3: リスクとリスク要因

出題比率: 15 ~ 25%

学習目標

このモジュールでは、AI の開発および導入に関連する主なリスクについて包括的に概観します。「公正」なアルゴリズムの作成に関連する多くの課題について説明し、アルゴリズムの公正性に影響を与えるさまざまなバイアスの要因を浮き彫りにしています。また、説明可能性と解釈可能性という 2 つの問題のほか、人間の自律性へのリスク、AI による操作のリスク、評判リスク、存続に関わるリスク、そしてグローバルなリスクや課題など、注目すべきリスクも扱います。

このモジュールを学習すると、次のことができるようになります。

- 個人の公平性と集団の公平性の概念を説明し、違いを見分ける。
- 集団の公平性のさまざまな指標について説明する。
- 公平性のさまざまな概念や指標に伴うトレードオフについて述べる。
- アルゴリズムのバイアスや不公平の原因を説明する。
- 説明可能性、解釈可能性、透明性について説明する。
- AI アルゴリズムの説明可能性を高める手法について説明する。
- AI が人間の自律性、安全性、ウェルビーイングに及ぼすリスクについて述べる。
- AI に関連する評判リスクの原因と、そうしたリスクを緩和するための戦略について説明する。
- AI に関連するグローバルな課題とリスクについて述べる。
- 生成 AI の利用によって生じる特有のリスクと、それに対処するために可能な解決策について述べる。

モジュール 4: 責任ある倫理的な AI

出題比率: 15 ~ 25%

学習目標

このモジュールでは、モジュール 3 で検討されたリスクを踏まえ、倫理原則とガバナンスが AI 技術の開発と導入における信頼性、安全性、公正性の向上にどのように寄与するかを考察します。また、AI に適用可能なさまざまな倫理的枠組み、AI に伴うガバナンスの課題、そして AI をめぐる現在のグローバルガバナンスイニシアチブも提示しています。

このモジュールを学習すると、次のことができるようになります。

- 実践倫理の枠組みを導入することによる潜在的な利点について述べる。
- 結果主義、義務論、徳倫理学を比較し、違いを説明する。
- 無害性、善行、正義、自律性、説明可能性の原則について述べる。
- アルゴリズムのバイアスや不公平の原因と、それに対処するための戦略について述べる。
- プライバシーに関する重要な倫理原則を説明する。
- 現在の規制環境と AI に関連するガバナンスの課題について述べる。

モジュール 5: データと AI モデルのガバナンス

出題比率: 15 ~ 25%

学習目標

このモジュールでは、データおよびモデルガバナンスについて説明し、AI/ML モデルのライフサイクル全体 (モデル開発からパフォーマンスモニタリング、廃止まで) にわたって、企業独自のモデル検証の枠組みを確立するための基礎を提供します。さらに、AI/ML モデルの不透明性や、これらのモデルの学習に用いるデータの適切なガバナンスの必要性についても取り上げています。このモジュールでは、生成 AI の新たなガバナンス課題についてさらに詳しく検討し、組織やリスク専門家の指針となる実践的なアプローチや評価手法を紹介します。提示する原則は幅広い業界に適用されますが、主に金融分野に焦点を当てています。この分野が正式な規制監督の対象であるためです。

このモジュールを学習すると、次のことができるようになります。

- データガバナンスの枠組みの要素を説明する。
- モデルガバナンスの枠組みの要素を説明する。
- モデル開発およびテストプロセスの手順を説明する。
- モデル検証およびその重要性について述べる。
- モデルガバナンスに関する方針および手順について述べる。
- AI/ML アプリケーションをモデルインベントリに登録する際に考慮すべき要素を説明する。
- モデルリスクマネジメントに関連する役割と責任について述べる。
- AI モデルと ML モデルでモデルレビューの枠組みがどのように違うかを説明する。
- モデルの実装および適応に関する手順を説明する。
- モデル結果の誤解釈につながりうる原因について述べる。
- 生成 AI に関するガバナンスの課題と、その対処として考えられる解決策について述べる。

RAI プログラムの顧問 およびコンテンツ執筆者

Amine Aboussalah, 博士 (Ph.D)、ニューヨーク大学、Finance & Risk Engineering 学部助教授

***Joseph Breeden, 博士 (Ph.D)**、Deep Future Analytics CEO、Model Risk Management International Association 社長

Chris Brooks, 博士 (Ph.D)、ブリストル大学、金融学教授

***Agostino Capponi, 博士 (Ph.D)**、コロンビア大学 IEOR 学部教授、Center for Digital Finance and Technologies 所長

***Manish Chakrabarti, 博士 (Ph.D)**、Vanguard、モデルガバナンス責任者

***Rama Cont, 博士 (Ph.D)**、オックスフォード大学、Oxford Mathematical and Computational Finance Group 代表

***Charles Currat, 博士 (Ph.D)**、FRM、Wells Fargo Investment Institute、定量モデリング部門責任者

***Lucy da Piedade**、ドイツ銀行、Group Controls Office 責任者

Thomas Dahlin、センチニアル銀行、最高モデルリスク責任者

***Alexander Denev, 博士 (Ph.D)**、FRM、Turnleaf Analytics 共同創業者

***Chris Donohue, 博士 (Ph.D)**、GARP、GARP Benchmarking Initiative (GBI)、マネージング・ディレクター

***Kenneth Doucet**、GARP、Content, Information and Continuing Education、シニア・ヴァイス・プレジデント

Michael Dowling, 博士 (Ph.D)、ダブリンシティ大学、金融学教授

***Raghurami Etukuru, 博士 (Ph.D)**、FRM、AISCENCES.AI、創設者兼主任 AI 科学者

Paul Feehan, 博士 (Ph.D)、ラトガース大学、数学特別教授

***Kay Firth-Butterfield**、Good Tech Advisory LLC、CEO

Michael Imerman, 博士 (Ph.D)、カリフォルニア大学アーバイン校 (UC Irvine)、金融学教育助教授

Satyajit Karnik, 博士 (Ph.D)、ジョージア工科大学、金融学講師

***Lukas Kölbl, 博士 (Ph.D)**、FRM、Accenture DACH、Data and AI、マネージング・ディレクター

***William May**、GARP、Certification and Educational Programs、Global Head、マネージング・ディレクター

***Peter Millican, 博士 (Ph.D)**、オックスフォード大学、Institute for Ethics in AI、哲学教授兼 Head of Education and Outreach

***Yogesh Mudgal**、JP Morgan Chase、Risk、Runtime Compute 責任者

Manuela Pedio, 博士 (Ph.D)、ブリストル大学、金融学上級講師

***Carina Prunkl, 博士 (Ph.D)**、ユトレヒト大学、技術倫理助教授

Peter Quell, 博士 (Ph.D)、DZ BANK AG、Portfolio Analytics for Market and Credit Risk 責任者

***Anand Rao, 博士 (Ph.D)**、カーネギーメロン大学、Applied Data Science and Artificial Intelligence 名誉教授 (Distinguished Service Professor)、PwC、Global AI Lead (退任)

***Alberto Rossi, 博士 (Ph.D)**、ジョージタウン大学、金融学教授兼 AI, Analytics and Future of Work Initiative 所長

Evan Sekeris, 博士 (Ph.D)、Capital One、最高モデルリスク責任者、FRM 顧問委員会メンバー

***Rajesh Shekhar**、FRM、Numanic 創業者

***Stephen Slade, 博士 (Ph.D)**、FRM、イェール大学、コンピューターサイエンス上級講師

***Agus Sudjianto, 博士 (Ph.D)**、H2O.ai、Risk and Technology、シニア・ヴァイス・プレジデント

Carissa Veliz, 博士 (Ph.D)、オックスフォード大学、Institute for Ethics in AI、准教授

Jennifer Voitle、FRM、モデル検証エキスパート

Samuel Po-Shing Wong, 博士 (Ph.D)、機械学習および応用統計学の独立研究者

***Bo Xu**、FRM、BCG、AI リード、プリンシパル

***Qiuyan Xu, 博士 (Ph.D)**、FRM、Gravitate AI、CEO

Kishore Yalamanchili, 博士 (Ph.D)、GARP、リスクコンテンツ担当ディレクター

* 顧問委員会メンバー



garp.org

GARP について | Global Association of Risk Professionals® (グローバルリスク専門家協会、GARP) は、リスク管理の実践向上を目指す超党派の非営利会員組織です。GARP は、金融リスクマネージャー (FRM®) という業界をリードする国際認定資格に加え、サステナビリティ & 気候リスク (SCR®) 証明書、Risk and AI (RAI)™ 検定、そして継続的専門能力開発 (CPD) を通じた持続的な教育機会を提供しています。GARP は、GARP Benchmarking Initiative (GBI)® および GARP Risk Institute を通じて、リスク管理に関する研究を支援し、実務者、学者、規制当局の間で協力を促進しています。

1996年に設立され、評議員会によって運営されている GARP は、ニュージャージー州ジャージーシティに本部を置き、ロンドンおよび香港にオフィスを有しています。

詳細については、garp.org をご覧ください。

© 2026 Global Association of Risk Professionals. All rights reserved. (04.26)

本部

111 Town Square Place
14th Floor
Jersey City, New Jersey
07310 USA
+1 (201) 719.7210

ロンドン

17 Devonshire Square
4th Floor
London, EC2M 4SQ UK
+44 (0) 20 7397.9630

香港

The Center
99 Queen's Road Central
Office No. 5510
55th Floor
Central, Hong Kong SAR,
China
+852 3168.1532