

## 第5分科会

### 高次の能力を捉えるための評価 ～どのような評価がどのような能力を捉えることに適しているのか を課題づくりも含めて考える～

報告者

**大塚 雄作** 独立行政法人大学入試センター 試験・研究統括官/教授

**松下 佳代** 京都大学 高等教育研究開発推進センター 教授

コーディネーター兼報告者

**斎藤 有吾** 京都大学 高等教育研究開発推進センター 特定助教

【参加者 67名】

昨今、アクティブ・ラーニングの趨勢とともに、高次の(統合的な)能力の評価法に関する議論が多く行われている。しかし、例えばルーブリックなど評価基準への注目は集まっているが、当該の能力を可視化するための課題の作成やその良し悪しの検討といったことに関する議論はまだ発展の途上にある。

そこで、日本の高等教育研究における教育評価の第一人者とともに、高次の能力を捉えるための評価と課題づくりに関して議論する。



## 高次の能力を捉えるための評価

～どのような評価がどのような能力を捉えることに適しているのかを課題づくりも含めて考える～

京都大学 高等教育研究開発推進センター 特定助教 斎藤 有吾

---

---

### 概要

昨今、アクティブ・ラーニングの趨勢とともに、高次の（統合的な）能力の評価法に関する議論が多く行われている。しかし、例えばルーブリックなど評価基準への注目は集まっているが、当該の能力を可視化するための課題の作成やその良し悪しの検討といったことに関する議論はまだ発展の途上にある。そこで、本分科会では、日本の高等教育研究における教育評価の第一人者である、大塚 雄作 独立行政法人大学入試センター試験・研究統括官／教授と松下 佳代 京都大学高等教育研究開発推進センター教授とともに、高次の能力を捉えるための評価と課題づくりに関して議論した。

### 1.分科会のねらいと問題意識

昨今の高等教育では、学問の基本的な知識を獲得するだけでなく、知識の活用能力や創造性、生涯を通じて学び続ける能力などを培うことが重視されている。また、それだけでなく、それらを学習成果として客観的な指標で捉えて可視化することが求められている。近年では、高大接続の視点で入試改革の議論にも発展している。詳細は学士課程答申、質的転換答申、高大接続答申（中央教育審議会, 2008；2012；2014）を参照されたい。

例えば学士力の「統合的な学習経験と創造的思考力」は、「これまでに獲得した知識・技能・態度等を総合的に活用し、自らが立てた新たな課題にそれらを適用し、その課題を解決する能力」（中央教育審議会, 2012, p.13）とある。これは知識・理解のレベルを超えた高次の（統合的な）能力であり、このような能力をどのように捉えることができるのかという議論を進めていく必要がある。昨今の高等教育における学習成果の可視化の方法を概観すると、GPA、教育関連企業が開発した汎用的技能や社会人基礎力を評価するためのテスト、学生調査などが多用されている。しかし、それらの方法で、大学のディプロマ・ポリシーに対応するような、知識や理解のレベルを超えた能力を捉えることはできるのだろうか。なお、これらさまざまな学習評価を整理するものとして松下（2017）の＜直接評価・間接評価＞、＜量的評価・質的評価＞、＜科目レベル・プログラムレベル・機関レベル＞といった3つの軸による分類が参考になる。合わせて参照されたい。

さて、これまで多用されている評価以外の方法で、特に高次の（統合的な）能力を捉えようとする動きもいくつか挙げることができる。例えば、科目レベルのパフォーマンス評価をプログラムレベルの学習成果の可視化のための指標として用いようとする新潟大学歯学部事例（小野, 2017）や、大学教員がテスト問題を共同で作成するとともに、作成したテスト問題を広く共有することを通して、コンピテンスと学習成果についての対話を喚起し、共通理解を形成することを目指す取り組み（Tuningテスト問題バンク；深堀, 2017）などが挙げられる。この2つはどちらも高次の（統合的な）能力を捉えようとする試みだが、前者は標準化を志向せず、後者は標準化を志向しているという違いがある。本分科会企画者兼コーディネーターである斎藤 有吾 京都大学高等教育研究開発推進センター特定助教は、その2つの取り組みに関わっているが、両者に共通して実感した問題点として、捉えようとする能力に対応する「評価課題」と「評価基準」を作成することは、当該の専門分野の大学教員でも困難であるということである。これらは本来ワンセットで議論されるべきことであるが、ルーブリックなど評価基準への議論や研究は多くなされてきている一方で、評価課題の作成に関する議論はまだ途上である。

そこで本分科会では、大規模標準テストなどに代表される量的評価の第一人者である大塚教授と、パフォーマンス評価などに代表される質的評価の第一人者である松下教授から、それぞれの立場から高次の（統合的な）能力を捉えるための評価、特に評価課題づくりに関して、ご講演を頂いた。また、講演の後に、2つの講演の内容を深めると共に、そのような評価課題の良し悪しを検討する視点を、異なる立場を超えて共有することを目的として、参加者が量的評価と質的評価の立場に分かれ、実際に高次の（統合的な）能力を捉えるための評価課題を作成するグループワー

クを行った。

## 2.分科会の構成と内容

第5分科会のタイムテーブルを表1に示す。まず、松下教授から、高次の（統合的な）能力とはどのような能力を指すのか、評価をする際にどのようなことを考えるべきなのか、学習評価における＜直接評価・間接評価＞、＜量的評価・質的評価＞という軸による分類、パフォーマンス評価やルーブリックに関する基本事項の説明が行われた。パフォーマンス評価は質的評価であり直接評価である。その後、パフォーマンス評価の3つの事例が紹介された。3つの事例はそれぞれ、パフォーマンス評価をデザインする際にポイントとなる①評価したい能力、②求めるパフォーマンス、③設定する評価課題、④設定する評価基準、⑤評価する主体などが、それぞれ異なるものであり、比較して検討することが可能なものであった。それらの中でも、デジタル・リテラシーの評価の事例は、知識の活用を把握することができ、しかも評価負担が小さい評価の開発に関するものであり、講演後のグループワークに直結する情報が提供された。

次に大塚教授から、量的評価の視点から、良問とはどのような要件を満たすものなのかということや、記述式課題とその採点の問題点について、事例を交えて詳しい説明がなされた。例えば、大規模な標準テストは、量的評価が基盤とする教育測定学（テスト理論）の専門的知見からの検証が求められるものであり、それぞれの問題（項目）の特性や、試験全体から得られる尺度得点の信頼性・妥当性の検討などが欠かせない。また、「良問」は問題それ自体が決めるものではなく、試験全体の枠組みにおいて議論されるべき相対的なものである。このように、質的評価とは明らかに異なった視点から、特定の能力を捉えるための評価のポイントが明らかにされた。加えて、昨今の大学入試改革の議論において、知識・理解より高次の能力を捉えることを目的として導入が叫ばれている記述式課題に関して、採点（評価）者間の信頼性の担保の困難さや、採点にかかる時間やコストなどの問題点が指摘された。

このように参加者には、＜量的評価・質的評価＞の双方の立場から、評価課題や評価基準を作成する際に留意すべきこと



表1 第5分科会 タイムテーブル

	タイム枠	演目・登壇者等	内容・テーマ等
	10:00～10:10 (10分)	開会挨拶・趣旨説明	第5分科会の趣旨説明
午前	10:10～11:00 (50分)	第1発表：松下 住代 先生	テーマ：高次の能力を捉えるための評価－パフォーマンス評価のデザイン－
	11:00～11:50 (50分)	第2発表：大塚 雄作 先生	テーマ：テストをテストする視点～共通テストの良問とは～
	11:50～12:00 (10分)	午後の趣旨説明と質問の記入	
	12:00～13:30 (90分)	昼休み	
午後	13:30～13:40 (10分)	質疑への応答	
	13:40～13:50 (10分)	第3発表：斎藤 有吉	テーマ：高次の能力を捉えるための評価のデザインとグループワークの説明
	13:50～14:30 (40分)	グループワーク	
	14:30～14:40 (10分)	発表準備	
	14:40～15:10 (30分)	発表と投票	
	15:10～15:25 (15分)	3グループ発表と講評	
	15:25～15:30 (5分)	ワークシート記入	

や、それらの良し悪しをどのように検討したらよいのかという視点が提供された。

そして午後の部のグループワークでは、参加者にデジタル・リテラシーを捉えるための評価課題を作成する課題が与えられた。量的評価の視点から、選抜試験に用いるという設定のもと、デジタル・リテラシーを捉えるパフォーマンス評価型の課題づくりを行う7グループと、質的評価の視点から、科目の終了時の総括的評価に用いるという設定のもと、パフォーマンス課題づくりを行う7グループに分けられた。どちらもグループメンバーは5名以内となるように調整された。

グループワークによって作成された課題（成果物）をポスター発表形式で発表してもらい、講演者2名の審査と参加者同士の投票によって、優れた課題を作成したグループには「大塚賞」「松下賞」「オーディエンス賞」が与えられた。各グループは、定められた条件設定のもとで、高次の（統合的な）能力を捉えるための評価をつくることの困難さを実感したようであった。また、講演者2名の講評によって、新たな気づきを得た参加者も散見された。加えて、一方の条件設定のもとで作成されて「良い」と考えられた課題が、もう一方の条件設定のもとでは必ずしも「良い」といえなくなる可能性など、＜量的評価・質的評価＞それぞれの視点を往還する必要性を意識する重要な契機となったようであった。

2名の講演者には、講演内容やグループワークに関して提案や議論をいただきつつ、分科会当日まで熱心に準備を進めて頂いた。また参加者の皆様には、拙いコーディネートにも関わらず、積極的にグループワークに関与していただき、その成果物からさらなる論点を提供していただいた。最後に、会場のスタッフの皆様の臨機応変な対応によって、トラブルなく分科会を終了することができた。紙上を借りて厚く御礼を申し上げる。

第5分科会コーディネーター

斎藤 有吾（京都大学 高等教育研究開発推進センター 特定助教）

(ugo.saito@gmail.com)

#### 参考文献

中央教育審議会（2008）『学士課程教育の構築に向けて』（答申）

中央教育審議会（2012）『新たな未来を築くための大学教育の質的転換に向けて～生涯学び続け、主体的に考える力を育成する大学へ～』（答申）

中央教育審議会（2014）『新しい時代にふさわしい高大接続の実現に向けた高等学校教育、大学教育、大学入学者選抜の一体的改革について』（答申）

深堀聰子（2017）「エンジニアリング教育の達成度評価～テスト問題バンクの取り組み～第1回:連載にあたって:テスト問題バンクの活動について」『日本機械学会誌』120（1178）, 38-39.

松下佳代（2017）「学習成果とその可視化（特集 高等教育研究のニューフロンティア）」『高等教育研究』20,93-112.

小野和宏（2017）『パフォーマンス評価と教育の質保証－新潟大学歯学部取組－』,東邦大学医学部FD講演会講演資料,2017年8月3日,アワーズイン阪急,東京.

# テストをテストする視点 ～共通テストの良問とは～

独立行政法人大学入試センター 試験・研究統括官/教授 大塚 雄作

第23回FDフォーラム・第5分科会  
『高次の能力を促すための評価』  
@京都産業大学 2018. 3. 4

## テストをテストする視点 ～共通テストの良問とは～

大学入試センター 試験・研究統括官/教授  
大塚 雄作



### 1. 良問の要件を探る

- (1) テストスタンダードが定める要件
- (2) 試験の枠組みによる制約
- (3) 測定目的との関連性 — 何を測りたいのか
- (4) 教育へのインパクト

2

### (1) テストスタンダードが定める要件

#### 1.1 テストの基本設計

開発者は**利用目的**や場面にあわせて、測定内容、測定形式、実施方法・手続、結果の利用方法、適用を想定する対象者の範囲などを明確に定め、**基本設計**を行う。

#### 1.2 測定内容の定義と構造化

開発者は、測定しようとする能力、学力、性格、行動などの特性を明確に定義し、それが表現できるような**適切な尺度を構成**する。なお、測定しようとする特性が複数の下位の特性で構成される場合は、その構造を明らかにし、それらも測定できるように複数の下位尺度を設計する。



3

### (1) テストスタンダードが定める要件

#### 1.5 採点手続の設計

テストの開発においては、その採点手続を詳細かつ具体的に示すべきである。客観式テストにおいては、採点手続の理論的根拠を明らかにする。主観的評定においては、**評定基準および評定手順を明確に設定**する。

#### 1.6 尺度化の方法

採点結果から尺度得点を求める場合は、さまざまな尺度化の方法の中から、最も適切な方法を吟味して選択する。その選択根拠は、求めに応じて説明できるように記録しておくべきである。

#### 1.7 尺度の標準化

汎用されるテストは、規準とする集団を明確に定め、その集団における相対的位置づけによって尺度化することが望ましい（この手続を「標準化」という）。標準化においては、用いた標本と標準化手続について記録し、公開する、また、標準化の結果は定期的にその有効性を確認し、改訂の必要性の有無を検討する。



4

### (1) テストスタンダードが定める要件

#### 1.10 尺度得点の確からしさの推定と公開

開発者は、構成された尺度得点がどの程度安定しているかを、しかるべき統計指標を算出して検討し（この過程を「**信頼性の確認**」という）、その結果を公開すべきである。なお、テストが複数の下位テストから構成される場合は、それぞれの下位テストごとに検討し、その結果を公開すべきである。

#### 1.11 尺度得点の適切さの確認

開発者は、構成された尺度が測定内容として定義された特性をどの程度適切に測定しているかを多面的に検討し（この過程を「**妥当性の確認**」という）、その結果を公開すべきである。



5

### (1) テストスタンダードが定める要件

★特に大規模な標準的テストは **教育測定学等の専門的知見からの検証が求められる。**

- 「信頼性」・「測定誤差」
- 「妥当性」・「構成概念」
- 「識別力」・「情報量」
- 「尺度得点」・「標準化」
- etc.

★形成的評価においても、それに利用される評価情報、そのベースとなる測定値などについては、**信頼性・妥当性・識別力などは、的確な評価に結び付くためには必要不可欠な要件**と言える。

6

### (2) 試験の枠組みによる制約

■ 学力・能力テストの設計と開発

1. テストの目的 : テスト開発の諸側面 = テストの目的に依存
2. テストの設計 : 外的背景要因 (受験者集団・時間的制約・等) を踏まえ、内的テスト属性 (項目内容・項目の型・採点基準・項目数・等) の設計
3. 項目の開発 : 項目の型を定め、具体的に項目を作成
4. 項目の評価 : 難易度・識別力等の統計的項目評価  
専門家による項目の内容的評価
5. 項目の選択 : 一部の統計指標のみならず、識別力・迷わせ分析、  
専門家の内容評価など、総合的観点から選択
6. テストの構成 : 項目の配列・項目のレイアウト・等

\* J.ミルマン・J.グリーン (1989)、大塚雄作 (訳) (1992)、第8章 学力・能力テストの設計と開発 R.L.リン (編) 『教育測定学・下』、3-53. C.S.L.学習評価研究所 より



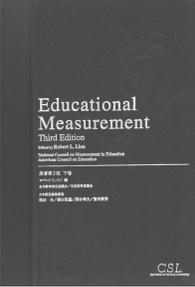
### (2) 試験の枠組みによる制約

■ テスト開発計画におけるいくつかの問題点

◆ 外的な文脈的要因  
テストの目的は何か?  
だれがテストを受けるか?  
どの程度のテスト時間が利用可能か?  
どのようにテストが施行されるか?

◆ 内的なテスト属性  
テストが対象とする範囲は何か?  
項目の形式としてどのようなタイプのもものが利用されるか?  
どれだけの数の項目を作成するか?  
どのような項目の計量的特徴が望まれるのか?  
項目はどのように評価され選別されるか?  
項目やテストはどのように得点化されるか?  
どのようなテストの計量的特性が望まれるのか?

\* J.ミルマン・J.グリーン (1989)、大塚雄作 (訳) (1992)、第8章 学力・能力テストの設計と開発 R.L.リン (編) 『教育測定学・下』、3-53. C.S.L.学習評価研究所 より



### (2) 試験の枠組みによる制約

★ テストの枠組みをどう定めるか、外的な文脈的要因による制約は何かによって、テストに含まれる良問の評価は違ってくる。

★ ある問を良問とするためには、テストの枠組みや外的な文脈的要因を それに合わせて変更する必要がある。

★ 適切な枠組みを設定することによって、目的に応じた「測定=テスト」が保障されることになる。

### (3) 測定目的との関連性 — 何を測りたいのか

● 学力・能力テスト (調査) の目的のいろいろ

テストの対象と目的	教育課程 (カリキュラム)			対応	
	前	中	後		
個人	診断・指導	診断的評価 配置 選択	診断 形成的評価 ガイダンス	成績 総括的評価 進級	個人的指導・保護者等への報告
	選抜・資格	入学試験		資格・検定試験	
集団	調査・研究	教育課程前 の状況把握	教育課程 の評価 全国学力調査	教育課程 の効果把握 PISA調査	全体的状況報告 (国・県・学校等)

\* J.ミルマン・J.グリーン (1989)、大塚雄作 (訳) (1992)、第8章 学力・能力テストの設計と開発 R.L.リン (編) 『教育測定学・下』、3-53. C.S.L.学習評価研究所 より改編

### (3) 測定目的との関連性—何を測りたいのか

★ 選抜試験と調査の違い を認識すべきである

- > 選抜試験: 個人差を識別する → 個人の尺度得点の信頼性 → 十分な項目数の準備等が必要
- > 調査: 集団の特徴を知る → 集団における得点の信頼性 → 偏りのない十分な標本サイズの確保

★ 総括的評価と形成的評価の違い を認識すべきである

- > 総括的評価: 尺度得点等による数量的指標 (集団における相対的位置を表す標準化指標など)
- > 形成的評価: 個人個人の学習状況・個性に応じた質的表現 (パフォーマンスを教師等が把握して改善のためにアドバイス)

### (4) 教育へのインパクト

■ 評価の流れ  
Input → Process → Output → Outcome → Impact = washback effect

■ テストのインパクト = 波及効果 washback effect ... 波及のあり方は多様

- > 「妥当性」の要件として「ポジティブな波及効果を持つこと」を取り上げる考え方も = 波及妥当性 washback validity
- ・ 評価の学習規定性 学習への方向づけの期待
- ・ 大規模テスト = 教育利用 (授業の教材などとして)
- > ネガティブな波及効果 → テスト得点の妥当性は流動的
- ・ テストワイズネス test-wiseness 選択肢の長さなどの手がかりを利用する力
- ・ テストスキル test-taking skill 適切な時間配分など自分の力を発揮するためのスキル

G. 村山航 (2006)、テスト形式が学習方略に与える影響とそのプロセスの解明 東京大学教育学研究科博士論文



### ● 採点の観点とルーブリック例

【問題寸評】 (試験翌週に学生への配付資料に採点基準等を掲載)

【問25】 採点の基準 (ある意味でのrubric) は、おおよそ、以下の通り。

①「**取り上げた能力**」および「**それを育てる教育**」が**具体的に提示されているか**： 4 = 「能力」が的確に取り上げられ、その育成にふさわしい教育が具体的に提案されている。 3 = 提案はあるが、その関連性や具体性などに十分とは言えない部分がある。 2 = 提案はあるが関連性や具体性などが十分とは言えない。 1 = 記述を試みているが、十分な提案にはなっていない。 0 = この点に関する記述がない。

②**その教育の過程で行われるべき教育評価手法**： 4 = ①で取り上げた「教育」等に適切な評価手法が具体的に記述されている。 3 = 提案はあるが、その教育へのつながりや具体性などに十分とは言えない部分がある。 2 = 提案はあるがその教育へのつながりや具体性などの点で十分ではない。 1 = 記述を試みているが、十分な提案にはなっていない。 0 = この点に関する記述がない。

③「**取り上げた能力**」を**的確に評価する入試方法の提案**： 4 = ①で取り上げた「能力」等を的確に評価する入試方法が具体的に提案されている。 3 = 提案はあるが、その「能力」への関連性や具体性などに十分とは言えない部分がある。 2 = 提案はあるがその関連性や具体性などの点で十分ではない。 1 = 記述を試みているが、十分な提案にはなっていない。 0 = この点に関する記述がない。

等々、**全10観点**により採点 → 10観点の合計点のα係数=0.859とします(内部一貫性の程度を示す)

19

### ● 論述式問題の全体得点上位者の解答例とコメントの提示

◆今後の教育においてはとりわけ「生理を通じ不断に主体的に学び考える力」が重要であると私は考える。なにかひとつも複数でもかまわないが、自分がこれなら夢中になれるという人生における研究対象があれば美らある有意義な生活を送ることができると思うから。さてそのように力を高校までにいかして育んでいけばいいかという点だが、やはり何をやるにしても基本的な知識やスキルは必要不可欠である。それを身につけるためには目的をあらかじめ設定するよう工学的アプローチではなく、多角的視点から評価していくために**「学生目アプローズ**」を取り入れていく必要がある。→ **児童性の低**その活動力であって別視点から考えると非常に有用であったり学習者自身のモチベーション向上につながるという点も考慮する。それを評価者が具体的に評価するのは非常に困難なので、トリアージルーティンも欠かせないことである。さてその評価をいかにして評価者(学習者)およびステークホルダーに伝達するかという**説明責任**の問題が出てくるのであるが、ポートフォリオ・アセスメントとルーブリックの活用が有効ではないかと思う。ポートフォリオによって学習者の到達度やそこに至るまでのプロセスを評価者ともに自己評価することができ、ルーブリックによって現段階で学習者に不足している事項を確認することもできる。あるいは学習共同体というものを構築するならば、一斉テストを実施し、その相対評価の結果から学力の近い者同士でグループを組んでお互いの弱点を補完し合うのも良いかもしれない。このように目標準拠評価と集団準拠評価を上手に融合していくことが望ましいと思われる。そして高校までに学習者が身につけた知識やスキルの**総合的評価**として大学入試は位置づけられるべきである。あるいは今後の大学での身の振る方々を考慮するためのスタンプという意味では診断的評価としての機能も備えていくとも思える。そこで前述の力をどのようにして把握すればよいかが、基本的には現行のままで良いと思う。つまり第一段階として大学入試センター共通一次試験で基本的な知識と処理スピードおよび**論述力**を測定し、第二段階として大学の二次試験を実施する。いざいざ試験改革の余地は大にあると思うが、教育現場のシステムの改革が優先されるべきだと思う。(979字)

→ 後半が強く、「個別力」の言葉の使われ方は微妙だが、前半は、ポートフォリオ評価、ルーブリック、自己評価などの用語も活用され、的確に記述されている。高校教育の総合評価として、また、大学教育の診断的評価としての大学入試の位置づけ方もよい。高校までの教育入試そのものの評価に関しては、十分な記述がないのが残念であるが、全体的にコンパクトに展開されており、**好感の持てる回答**である。

20

### (2) 受検者のレベルによって異なる採点基準

ex. 「**テスト得点の信頼性と妥当性について論じなさい**」の採点基準案

A = 信頼性・妥当性の意味がそれぞれ正確に把握されており、その検証方法についても適切に触れられている。また、信頼性と妥当性の関係性(信頼性が高くないと高い妥当性は得られない、信頼性を高めることによって妥当性が高くなる場合があるなど)について的確に論じられている。

B = 信頼性・妥当性の意味とその検証方法については把握しているが、その両者の関係性については十分に論じられていない。あるいは、両者の関係性については触れられているが、検証方法について触れられていない。

C = 信頼性・妥当性の意味については正確に把握されているが、その検証法、及び、両者の関係性については触れられていない。

D = 信頼性・妥当性について両方の意味を正確に把握しているとはみなされない。

◆問題の難易度を下げるとすれば・・・

A' = 信頼性と妥当性の両方の意味が正確に把握されている。

B' = 信頼性と妥当性の一方の意味は正確に把握されている。もしくは、やや曖昧さがある。

C' = 信頼性と妥当性の意味が全く捉えられていないとは言えないが、把握していない可能性も窺える。

D' = 両方の語の意味がほとんど把握されていない。

21

### (3) 採点者信頼性の問題

▶記述式採点は「採点者信頼性」を高く維持することが難しい

一人の採点者内でも採点基準は変動しがち

採点者間の採点結果の変動はかなり大きい(右図参照→)

Cy. 池田 央 (1992)、『テストの科学』日本文化科学社

▶海外の記述式を採用している試験では、アピール・センターを設置して、記述式問題の採点に関わるクレームを受け付けている場合もある

22

### ● 記述式問題の得点の妥当性

◇条件付き記述式問題

制限字数、段落の分け方の指定、用いる用語の指定などにより、その条件ごとに採点を行い、それらの正答パターンに従って、点数や評定段階を割り振る方法

▶この方法によって、採点の安定性が確保され、得点の信頼性を担保することができる

▶しかし、得点の妥当性が犠牲になる場合がある

ex. 全国学力調査の記述式問題例→

★事前に十分な信頼性、妥当性に関わる検証研究の積み重ねの要

問題番号	解答形式	正答
三	(原簿の写本) 次の条件を満たして解答している。 ① アに、【雑誌の記事】を読んで「宇宙エレベーター」について疑問に思ったことを一つあげている。 ② アに、「なぜ」、「どのような(点)」、「どのくらい」という言葉の「何か」を使っ て、二文字以上、四十文字以内で書いている。 ③ イに、必要なしの理由を二つ書いている。 (注) ①・② 宇宙エレベーターは、なぜ長い期間にかかって降り差し使うことが可能なの か。(37字) イ 図書の分類によって、自然科学に属する本が置いてある棚に行く。 イ 図書検索画面のメニューから「宇宙エレベーター」と入力して検索する。 ④ 宇宙エレベーターの表現は、どのような表現があるか。(28字)	正答
三	条件①、②を満たし、条件③を満たさないで解答しているもの (例) ア アーランド・クックの船は、先上りのどこに自から登陸して行く。(36字) イ (例) ④ 宇宙エレベーターに乗るための費用は出らんのか。(34字)	誤答

http://www.mext.go.jp/a\_menu/shotou/gakuryoku-chousa/sonota/1347088.htm

23

### (4) 採点コストと労力の問題

★現段階では、大規模・共通一斉試験に記述式問題を導入する最大の問題点は採点の過程にあり、それにかかる時間、コスト、信頼性などの課題あり

★現行日程では、マークシート採点でさえ、マークの濃度や修正の仕方、あるいは消しゴムの浮などの要因によって、2度読み込んで同じマークと認定できない場合の確認作業など、現行のスケジュールでも精一杯というのが現実

★採点の信頼感を確保するために、民間が担当するにしても、大学入試センターが担当するにしても、高校教員、大学教員をいかに確保するかが問われることになると考えられる。→当事者意識を持つべし

24





# 高次の能力を捉えるための評価 ーパフォーマンス評価のデザインー

京都大学 高等教育研究開発推進センター 教授 松下 佳代

第23回FDフォーラム・第5分科会

2018.3.4@京都産業大学

## 高次の能力を捉えるための評価 ーパフォーマンス評価のデザインー

松下 佳代  
京都大学・高等教育研究開発推進センター  
matsushita.kayo.7r@kyoto-u.ac.jp

### この分科会のねらい

- 「高次の能力を捉えるための評価」  
～どのような評価がどのような能力を捉えることに適しているのかを課題づくりも含めて考える～
- 背後にある問題意識
  - 昨今、高次の(統合的な)能力の評価法に関する議論が多く行われている。
  - しかし、例えばルーブリックなど評価基準への注目は集まっているが、当該の能力を可視化するための課題の作成やその良し悪しの検討といったことに関する議論はまだ発展の途上にある。

3

第5分科会

### 高次の(統合的な)能力とは？

#### ● 高次の (higher-order)

\*ブルーム・タクソノミーの上位3つの認知プロセス  
(=分析・総合・評価)を指して使われることが多い

=因果関係を分析したり、複数の関係や構造を総合したり、政策や価値判断を評価したりするような複雑な思考(田中編, 2005, p. 99)

=<暗記した知識の再生やなじみのある文脈での適用>以上の認知プロセス

ブルーム・タクソノミー(オリジナル版)



#### ● 統合的な(integrative)

=複数の単元や科目をまたがって、知識・技能を統合することを求められる

4

### OUTLINE

- 評価の枠組み
- パフォーマンス評価の事例(1)  
ー京都大学初年次ゼミでのレポート評価ー
- パフォーマンス評価の事例(2)  
ー新潟大学歯学部のPBL評価ー
- パフォーマンス評価の事例(3)  
ーデジタル・リテラシーの評価ー
- まとめ

5

### 評価の枠組み

6

### 「ルーブリック評価」か、「パフォーマンス評価」か

#### ● 「ルーブリック評価」?

- performance assessment 391万ヒット
- rubric(-based) assessment 4.8万(9千)ヒット (Google検索)

→「ルーブリック評価」は日本の、特に大学教育のジャーゴン

#### ● パフォーマンス評価とルーブリックの関係

- ルーブリックはパフォーマンス評価の評価基準の一つ
- パフォーマンス評価と切り離れたルーブリックの議論は意味がない

7

### 評価の枠組み

観察可能

パフォーマンス

観察不可能

コンピテンス (能力)

可視化

解釈

評価課題

評価基準

- どんな能力も、それ自体は観察不可能。
- そこで、能力を、何らかの 評価課題を通じて可視化させ、観察可能なパフォーマンスにする。
- そして、そのパフォーマンスを、評価基準を介して解釈することで、パフォーマンスの背後にある能力を推論する。

\*コンピテンス≒コンピテンシー

「評価とは、学生が知っていることについての合理的な推論を行うために、学生の行動の観察やデータの産出を行うよう作られたツールである」(NRC, 2001, p.47)

### 評価で考えるべきこと

- ①コンピテンス(コンピテンシー)
  - どんな能力を評価するか？(←どんな能力を目標とするか)
- ②パフォーマンス
  - どんなパフォーマンスを求めるか？
  - (授業中の応答・言動、テスト、作品(プロダクト)、実演など)
- ③可視化
  - どんな評価課題を設定するか？
- ④解釈
  - どんな評価基準を設定するか？
- ⑤評価主体
  - 誰が評価するのか？(学生自身、教師、上級学校、テスト機関、実習先など)

### 学習評価の4つのタイプ

(松下, 2012; 松下他, 2016)

### 間接評価と直接評価

(Banta & Palomba, 2015)

- 間接評価
  - 学生の学習行動や学習についての自己報告を通じて、学習成果を間接的に評価
  - 質問紙やミニッツペーパーなど

何ができると思っているか？
- 直接評価
  - 学生の知識や能力の表出を通じて、学習成果を直接的に評価
  - 客観テストやパフォーマンス評価など

何ができるか？

### 量的評価と質的評価

(松下, 2017)

	量的評価	質的評価
学問的基盤	心理測定学	解釈学、構成主義的学習論など
評価データ	量的データ	質的データ
評価対象	集団または個人	個人
評価目的	選抜、組織的な教育改善、アカウントビリティなど	学習や指導の改善など
評価課題	細かく分割された問題 文脈独立的	複合的な課題 文脈依存的
評価基準	客観性を重視	間主観性を重視
評価結果	数値	文章や数値
評価機能	主に総括的評価	主に形成的評価
評価方法	客観テスト・標準テスト、 質問紙調査など	パフォーマンス評価・ポートフォリオ 評価、ミニッツペーパーなど

cf. アセスメント・ポリシー(「質的転換答申」J2012.8)

「特に、成果の評価に当たっては、学習時間の把握といった学修行動調査やアセスメント・テスト(学修到達度調査)、ルーブリック、学修ポートフォリオ等、どのような具体的な測定手法を用いたかを併せて明確にする。」

## パフォーマンス評価 (タイプIV)

観察可能  
パフォーマンス (作品・実演)

可視化  
評価課題  
パフォーマンス課題

解  
積  
評価基準  
ルーブリック

観察不可能  
コンピテンス (能力)

- 2つのアプローチ (Messick, 1994)
  - 【1】パフォーマンスそのものに焦点 (例) 芸術コンテスト、スポーツ競技
  - 【2】パフォーマンスを可能にしているコンピテンス(能力)に焦点  
\* 特に教育ではこの視点が重要

14

## パフォーマンス課題

- パフォーマンス課題 (performance task)
  - 学習者のパフォーマンスを評価するためにデザインされた課題
  - リアルな文脈のもとで、さまざまな知識やスキルを総合して使いこなすことを求めるような課題  
「簡単にパフォーマンス評価の意図をいえば、テストの内容を、基準となるパフォーマンスで示される批判的な思考や知識の総合を求めるものにしていこうとするところにある」(ギブス, 2001, p.16)
- 大学教育の現状
  - パフォーマンス課題は多く使われている
    - 実技(医療・教員養成など)、演奏や創作物(芸術分野)、製作物(PBLなど)、レポート・卒業論文、プレゼン・口頭試問など
  - しかし、評価基準については、ほとんど主観にゆだねられていた

15

## ルーブリック

- ルーブリックとは
  - ＝パフォーマンスを能力の表れとして解釈し、その質(よさ・見事さ・美しさ)を段階的・多面的に評価するための評価基準表
  - 「専門家の鑑識眼」を明示化し、共有できるようにするツール
  - パフォーマンスの質を量的表現に変換する(質的評価と量的評価をつなぐ)働きも

		レベル4	レベル3	レベル2	レベル1	← レベル
観点 (標準)	観点1	.....	.....	.....	.....	
	観点2	.....	.....	.....	.....	
	観点3	.....	.....	.....	.....	
	観点4	.....	.....	.....	.....	← 記述語 (descriptor)

16

## ルーブリックのタイプ

- (a) 構造
  - 観点を複数設定して分析的に評価する「分析的(観点別)ルーブリック」
  - 観点を分けずに全体的に評価する「全体的(包括的)ルーブリック」
- (b) スコープ(適用範囲)
  - ある領域で一般的に適用できる「一般的ルーブリック」
  - 当該課題だけに適用される「課題特殊のルーブリック」
- (c) スパン(対象期間)
  - 複数年にまたがって使われる「長期的ルーブリック」
  - 採点のためにスナップショット的に使われる「採点用ルーブリック」

17

## パフォーマンス評価の事例(1)

— 京都大学初年次ゼミでのレポート評価 —

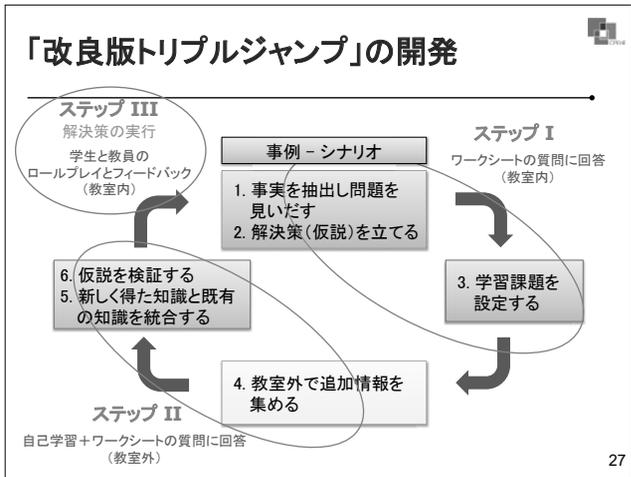
18

## 私自身の授業での取り組み

- 全学共通科目「学力・学校・社会」(初年次セミナー)
  - 【目標】
    - 内容に関する目標: 学力・能力を軸として、学校(大学を含む)と社会の関係について考え、自分なりの見方をもつ。
    - 能力に関する目標: 批判的に読み、議論し、書くことができるようになる。
  - 【授業構成】
    - 前半: 講義とディスカッション
    - 後半: プレゼンテーションとピア・レスポンス
  - 【評価】
    - 最終レポート課題: 「授業に関連するテーマを自分で設定し、モデルにそって論を構成する。プレゼンテーションの内容について、フロアからの意見・感想・質問をふまえて修正・補足し、文章化する。」
    - ルーブリックの活用 (新潟大学歯学部で共同開発したもの)

19





### パフォーマンス課題のシナリオ

「わたし、困っています」

あなたは新潟大学医学総合病院の歯科衛生士です。  
今日は担当患者:高橋勇蔵(67歳・男性)の2回目の診療日です。高橋勇蔵は中等度の歯周病があり、初回は歯周検査と病状説明を行いました。

**あなた:**高橋さん、お口の具合はいかがですか。前回、タバコをやめるようお話ししましたが、禁煙されましたか。  
**高橋:**してないよ。私はね、タバコをやめくらないなら死んだ方がましだと思っているよ。この前、国から送られてきたアンケートにも「生きがいはタバコを吸うこと」と書いてくれた。相変わらず1日40本は吸っている。歯科に来て、なんでタバコをやめるよう言われなきゃならんのだね。  
**あなた:**でも、高橋さんは糖尿病もあるし、やめた方がいいと思いますが…。  
**高橋:**糖尿病は関係なからう。ここは歯科だろう。おやおや、内科と間違えたかな。  
**あなた:**歯科ですけど…。とにかく、前回言ったことと同じことを言いますが、まずはタバコをやめてください、いいですね。  
**高橋:**ああ、わかった。あんたはタバコが嫌いだな。

28



### 新たに加えたステップIII

- **ロールプレイ**
  - 学生は、模擬患者役の教員とやりとりしながら禁煙指導のロールプレイ
  - ロールプレイを観察しながら、3人の教員が、ループリックにそって評価(約7分)
- +
- **フィードバック**
  - ロールプレイ終了後、教員からすぐに、結果(改善点やアドバイスなど)をフィードバック(約8分)
  - = 学期最後の総括的評価だが、形成的評価としての機能を強化

30

### ループリック (小野他, 2015)

観点	問題発見～最終解決策の提案(ステップI-II)					
	1. 問題発見	2. 解決策の着想	3. 学習課題の設定	4. 学習結果とリソース	5. 解決策の検討	6. 最終解決策の提案
観点の説明	シナリオの事実から、問題を見いだす。	解決の目標を定め、いくつかの解決策を立案する。	問題の解決に必要な学習課題を設定する。	信頼できるリソースから、学習課題を調査する。	解決策の有効性や実行可能性を検討する。	問題に対して最終的な解決策を提案する。
レベル3	解決策の実行(ステップIII)					
レベル2	観点	7-1. 追加情報の収集	7-2. 情報の統合	7-3. 共感的態度	7-4. コミュニケーション	
レベル1	観点の説明	禁煙を働きかける上で必要となる追加情報を患者とのやりとりを通じて収集する。	禁煙を働きかける上で有用な情報を結びつけて理解する。	患者の考えや価値観に配慮して禁煙を働きかける。	自分の考えを患者にわかりやすく説明する。	
レベル3						
レベル2		長期的ループリックとして開発				
レベル1						
レベル0						

### 学生の意見・感想

- 「ステップIIIを行うことで、PBLが将来現場に出た時に役立つものになるのだと分かりました。」
- 「トリプルジャンプを行ってみて、現在のPBLよりも終わった後の手応えがとてもありました。トリプルジャンプは、調べ学習を行って分かった事柄を患者にどのように説明したらよいか考えなくてはいけません。ただ調べて終わりではなく、次のステップがトリプルジャンプにはあるので、自分の勉強した内容を自分の頭できちんと整理しなければなりません。よって、調べたことが自分のものになり、ためになりました。」
- 「これまでのPBLと違い、すべての作業を自分一人で行うので、大変さは感じました。調べきれなかったところは他の人が調べてきてくれるだろうという期待ができないので、今までで一番学習したように思います。大変さはあるのですが、すべて自分の責任になってくるので、モチベーションがあがって頑張れたのかもかもしれません。」
- 「やったらやっただけ身になるような気がします。また、自分がどれくらい成長できるかが分かるので、ただ学習しているだけよりも、もしかしら手ごたえがあるかもしれません。実際一人ずつ評価コメントしなくてはならない先生方には大きな負担になるかもしれないのですが。」

32

### 改良版トリプルジャンプ(MTJ)の特徴

- 一人PBL
  - デメリット…「協同的に取り組む能力」は評価できない
  - メリット…「将来出会う現実の状況にはより近い」
- PBLを補強
  - 通常のPBLサイクルは「解決策の検討」までで、「解決策の実行」「結果の評価」が欠落 → ステップIIIで補強
- 学習としての評価
  - 学生にとって、単なる「学習の評価 (assessment of learning)」ではなく、「学習としての評価 (assessment as learning)」になっている

33

### パフォーマンス評価の事例(3) ーデジタル・リテラシーの評価ー

34

### デジタル・リテラシー (civic online reasoning) の評価

- 評価課題
 

On March 11, 2011, there was a large nuclear disaster at the Fukushima Daiichi Nuclear Power Plant in Japan. This image was posted on Imgur, a photo sharing website, in July 2015.



Does this post provide strong evidence about the conditions near the Fukushima Daiichi Power Plant? Explain your reasoning.

\*この課題は高校生対象 (Wineburg et al., 2016, p. 16)

35

### 評価基準 (ルーブリック)

\* 全体的・課題特殊のルーブリック

MASTERY	生徒は、この投稿は強いエビデンスにならないと論じ、投稿の出处 (例えば、投稿者についてわれわれは何も知らない) や写真の出处 (この写真がどこで撮られたかわからない) などの疑問を呈する。	結論○ 理由○
EMERGING	生徒は、この投稿は強いエビデンスにならないと論じるが、その説明は、投稿や写真の出处を考慮したものではないか、あるいは、説明が途中で終わっている。	結論○ 理由△
BEGINNING	生徒は、この投稿は強いエビデンスになると論じる。または、不正確な (あるいは一貫性のない) 推論を用いる。	結論× 理由×

(Wineburg et al., 2016, p. 18を一部改変)

36

### デジタル・リテラシーの評価

- 先行研究
  - Stanford History Education Group (SHEG) の実践研究 (<https://sheg.stanford.edu/civic-online-reasoning>)
- デジタル・リテラシー (Civic Online Reasoning) とは
  - オンライン環境にあふれる情報の信頼性を判断する能力
  - ポスト真実の時代を生きる市民に求められる能力
  - 3つのコンピテンシーからなる
 

- ① 誰が提示された情報の背後にいるのかを同定する
    - ② 提示されたエビデンスを評価する
    - ③ 他の情報源が言っていることを調べる (lateral reading)

\* Fukushimaの問題は①②のコンピテンシーを評価

37

### SHEGの評価開発の特徴

- 従来の評価: 2つの極

<b>客観テスト</b> (多肢選択)	<b>論述試験 (DBQ)</b> (複数の一次資料を使った小論文)	
《知識の活用》 (knowledge in action)	低	高
《評価負担》	小	大

↓

- 「知識の活用を把握することができ、しかも評価負担が小さい評価」の開発

38



## 文献

- Banta, T., & Palomba, C. (2015). *Assessment essentials: Planning, implementing, and improving assessment in higher education* (2nd ed.). San Francisco: Jossey Bass.
- Earl, L. M. (2003). *Assessment as learning: Using classroom assessment to maximize student learning*. Thousand Oaks, CA: Corwin Press.
- Gipps, C. V. (1994). *Beyond testing: Toward a theory of educational assessment*. Falmer Press.
- キップス, C. V. (2001). 『新しい評価を求めて—テスト教育の終焉—』(鈴木秀幸訳) 論創社.
- 牧野由香里 (2008). 『「議論」のデザイン』ひつじ書房.
- 松下佳代 (2007). 『パフォーマンス評価』日本標準.
- 松下佳代 (2012). 「パフォーマンス評価による学習の質の評価—学習評価の構図の分析にもとづいて—」『京都大学高等教育研究』第18号, 75-114.
- 松下佳代 (2016). 「アクティブラーニングをどう評価するか」松下佳代・石井英真(編)『アクティブラーニングの評価』東信堂, 3-25.
- 松下佳代・小野和宏・高橋雄介 (2013). 「レポート評価におけるルーブリックの開発とその信頼性の検討」『大学教育学会誌』第35巻第1号, 107-115.
- McGrew, S., Ortega, T., Breakstone, J., & Wineburg, S. (Fall 2017). The challenge that's bigger than fake news: Civic online reasoning in a social media environment. *American Educator*, 41, 4-9.
- Messick, S. (1994). The psychology of educational measurement. *Journal of Educational Measurement*, 21(3), 215-237.
- Mtshali, N. G., & Middleton, L. (2011). The triple jump assessment: Aligning learning and assessment. In T. Barrett & S. Moore (Eds.), *New approaches to problem-based learning: Revitalising your practice in higher education*. New York: Routledge.

47

- National Research Council. (2001). *Knowing what students know: The science and design of educational assessment*. Committee on the Foundations of Assessment. Pelligrino, J., Chudowsky, N., & Glaser, R., editors. Board on Testing and Assessment, Center for Education, Division of Behavioral and Social Sciences and Education. Washington, DC: National Academy Press.
- 小野和宏・大内章嗣・前田健康 (2011). 「学習者主体PBLカリキュラムの構築—新潟大学歯学部口腔生命福祉学科7年のあゆみ—」『新潟歯学会誌』41(1), 1-12.
- 小野和宏・松下佳代・斎藤有吾 (2014). 「PBLにおける問題解決能力の直接評価—改良版トリプルジャンプの試み—」『大学教育学会誌』36巻1号, 123-132.
- 小野和宏・松下佳代 (2015). 「教室と現場をつなぐPBL—学習としての評価を中心に—」松下佳代・京都大学高等教育研究開発推進センター編『ディープ・アクティブラーニング—大学授業を深化させるために—』助草書房, 215-240.
- 小野和宏・松下佳代 (2016). 「初年次教育におけるレポート評価」松下佳代・石井英真編『アクティブラーニングの評価』東信堂, 26-43.
- 田中耕治編 (2005). 『よくわかる教育評価』ミネルヴァ書房.
- Toulmin, S. E. (1958). *The uses of argument*. Cambridge, UK: Cambridge University Press. トウールミン, S. (2011). 『議論の技法—トウールミンモデルの原点—』(戸田山和久・福澤一吉訳) 東京図書.
- Wiggins, G. & McTighe, J. (2005). *Understanding by design* (Expanded 2nd ed.). Alexandria, VA: Association for Supervision and Curriculum Development. ウィギンズ, G. & マクタイ, J. (2012). 『理解をもたらしカリキュラム設計—「逆向き設計」の理論と方法—』(西岡加名恵訳) 日本標準.
- Wineburg, S., McGrew, S., Breakstone, J., & Ortega, T. (2016). *Evaluating information: The cornerstone of civic online reasoning*. (<http://purl.stanford.edu/fv751yt5934>) (2017.8.27アクセス)

48

