

AIが予測する 建設プロジェクト初期段階の工事費

株式会社日本設計 PM・CM部 副部長 伊藤 一義
シニアエンジニア 加藤 泰正

1 はじめに

建設プロジェクトにおいて、発注者と設計者との意思疎通に最もデリケートな要素となるのはコストである。特にプロジェクト初期段階において、最初に算出する目標工事費は、後々のコストマネジメントに大きな影響を与えるため、少しでも多くのデータを基に工事費を算出することが望ましい。また、工事費算出のためのデータ量を増やし、計画の特徴を的確に反映した工事費を算出することが、プロジェクトを円滑に進める第一歩とも考える。しかし、プロジェクト初期段階においては、工事費算出のためのデータ量を増やすにも限界がある。

従来、プロジェクト初期段階の目標工事費は類似案件データを補正する形で算出されてきたが、我々は今後のAI（人工知能）技術の進展を見据え、より多くのデータを活用できる第二の方法として、ニューラルネットワークを用いた予測ツールを開発した¹⁾。その背景、考え方、内容等について、以下に説明する。

2 コストマネジメント及び初期段階の課題

我々が行うCM業務におけるコストマネジメントは、五つのマネジメント領域（統合マネジメント、品質マネジメント、スケジュールマネジメント、コストマネジメント、情報マネジメント）の

うちの主要なマネジメントの一つになる。

コストマネジメントとは、建設プロジェクトの目的・ニーズに対して、最適な品質・コストを実現するための統合的・継続的コスト管理活動であり、主な実施内容は次のようになる。

- ①基本計画における工事費の算出
- ②設計段階における
 - ・コストプランニング
 - ・コストのモニタリング
 - ・コストレビュー
 - ・概算工事費の内容確認

特に、基本構想、基本計画等の初期段階の工事費は、基本設計・実施設計まで連続的に実施するコストマネジメントの基準となる工事費になるため、慎重に算出することが必要になる。

プロジェクト初期段階の工事費は、類似事例の延床面積当たり単価を補正し算出することが一般的であり、通常は次の手順で算出する。

- ①延床面積、構造形式、用途が類似する案件を選定する。
- ②特殊要因を調整する。

例) 杭の有無等の基礎形式、特殊設備の有無

- ③類似案件の延床面積当たり単価に対して、時点補正、地域間補正を行う。

時点補正は建築費指数の時系列指数、地域間補正は都市間格差指数を利用する。

実際の業務では、延床面積、構造形式、用途が類似する案件数は多くなく、特定の案件の補正となることが多い。

案件が少ない場合、隠れた特殊性が排除できない可能性があり、個別の特殊性の影響を低減するためには案件数を増やす必要がある。案件数を増やす方法としては対象期間を広くすることが考えられるが、そうすると図1に示すように建築費指数（建設工業経営研究会）と当社の年度別平均工事費の推移の乖離が大きくなる。このことは、建築費指数による時点補正の限界を示していると考えられる。

3 AI手法の概要²⁾

近年、画像認識や自動運転等の様々な分野でAIが実績を上げつつあり、注目されている。AIの特長の一つとして、大量データを学習できることが挙げられる。これは機械学習とも言われるが、人が一定の経験を通じて獲得する判断力は、この機械学習をうまく活用することで一部代替できるのではないかと期待されている。AIの学習できるデータ量は人をはるかに凌駕するので、一層の期待感はある。

AI手法の一つとして注目度の高いニューラルネットワークは、脳の神経細胞ネットワークを模した構造をしており、入力層、中間層、出力層をそれぞれ構成するニューロン及び、各ニューロン間の信号量を調整する重み係数からなる（図2）。中間層を深くしたディープラーニングは、重み（図2の線の部分）の数が膨大となり、高度な学習ができると言われている。逆に中間層をなくしたパターンは統計手法の一つである線形重回帰分析のモデルに類似するものとなる。この二つのモデルを比較すると、中間層を持つニューラルネットワークの表現力は絶大なものであることが直感的に理解できる。

ニューラルネットワークの重み係数は、出力層における出力と正解の誤差（損失関数）が最小になるように、バックプロパゲーションというアルゴリズムによって算出される。出力層から入力層に向けて誤差を逆伝搬させ、その誤差量を基に重み係数の値を修正しながら、順伝搬と逆伝搬を繰り返し、最適値を探索する。学習はこのバック


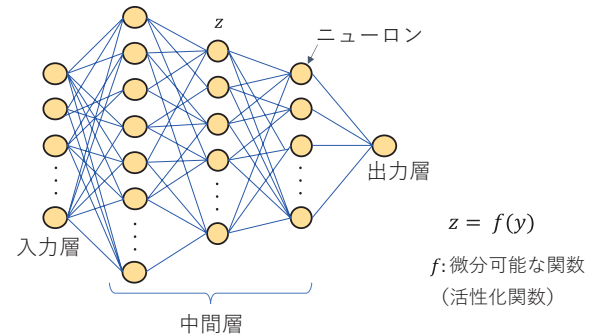


図1 建築費指数と当社の年度別平均工事費推移の比較

■ AI手法（ニューラルネットワーク）



■ 統計手法（線形重回帰分析）




図2 ニューラルネットワーク及び線形重回帰分析のイメージ




図3 過学習のイメージ

ロパゲーションによって行われる。

ニューラルネットワークは回帰と分類の各問題を扱うことができる。回帰は種々のデータの傾向から、目的とする連続的な数値を予測するもので、今回の工事費予測がこれに該当する。分類は種々のデータを離散的な値に分類するもので、画像認識等が相当する。現在、AIは2000年代から始まる第3次ブームの中にあり、これら双方の問題に対し、ディープラーニングを主として様々な分野に適用が試みられている。

一方、学習においては過学習が発生するケースがある。学習能力が高いために、学習データをそのまま暗記してしまうような現象である。このような場合、学習をさせていないデータに対しては、予測が大きく外れることになる(図3)。このようなこともあり、学習に際しては、質の良いデータを収集、使用するということが重要な視点となる。

学習がうまくいっているかを見極める方法として、通常は学習をさせていない複数の検証データを用い、実績値と予測値の乖離状況を評価する方法がとられる。学習に使ったデータによる予測値と検証データによる予測値の分布を比較することで、過学習の状況がある程度判断できる。

過学習の対策としては、学習データ量を増やす、ネットワークモデルを簡略化する、一部のニューロンをドロップアウトさせる、または、損失関数に正則化項を考慮する等の方法が挙げられる。

その他、ニューラルネットワークを用いて解を得るためには、層の数や層の中のニューロンの数、活性化関数(図2)や損失関数の種類、重み係数に設定する初期値、その最適解を求めるための手法、そこで扱われる各種係数の値、エポック数(全データに対する学習回数)、ミニバッチサイズ(全データをバッチに分けて学習させる時のサイズ)及び過学習対策等、様々な項目の組み合わせをトライアンドエラーしながら調整するチューニングと呼ばれる作業が必要となり、労力が大きいという側面もある。教育には手間暇がかかるということである。

4 学習方針

蓄積された工事費データを基にして、工事費を予測する試みは古くからある。例えば、石原³⁾は事務所及び住宅に関して、それぞれ多変量解析を採用している。具等⁴⁾は同一発注者による同種の施設に関して、重回帰分析及びニューラルネットワークを採用している。これらの既往の研究に見られる特徴は、対象施設の用途を一つに限定していることである。

用途を限定することで、学習データ群は同質のものとなり、予測精度を高めることはできるが、予測ツールとして利便性は高いとは言えない。建設プロジェクト初期段階において、種々の用途または複合施設に対して、それぞれ工事費を検討したい場合がある。そこで、用途種別を限定しない予測ツールの開発を目指した。

ただし、これを実現させるためには、種々の条件を抱合する多くの学習データを集める必要がある。また、扱う工事費のバラツキは必然的に大きくなり予測が難しくなるため、何らかの対策を講じる必要がある。

まず、学習データ量を確保する件を考える。工事費の予測を困難にする要因として、物価変動がある。この影響を小さくするためには、比較的直近で地域間の物価格差が小さいデータを使用することになる。しかし、一組織内で収集できるデータ量には限りがある上に、建設時期と建設地を限定することで、データ収集量は更に減少してしまう。そこで、比較的長い過去及び全地域のデータを対象にすることを考える。これらのデータは、時点補正や地域間補正をして用いるのではなく、建設時期と建設地を何らかの方法で数量データ化し(6参照)、入力データとして位置づけ、工事費とともに学習させるものとする。

次に、扱う工事費のバラツキが大きくなる件について考える。このバラツキは個々の施設の特殊要因や用途種別に負うところは大きいですが、まだそれらが明確には定まっていないプロジェクト初期段階における予測ツールの運用を考えている。そ

ここで、工事費の予測範囲を限定するという意味で、延床面積当たりの工事費を5段階程度に分類して、それを建物のグレードと見なし、学習データに加えるという方法を考える。5段階というのは人間が直感的に分類できるレベルである。また、後述（5参照）するが、施設用途別に見ると、このグレードは更に1から4段階に減ることになる。

5 データ概要

収集したデータは、建設地は国内各地域、着工が2000年から2019年の計233件である。種々の規模、用途種別、グレード、構造種別を含んでいる。用途種別とグレードの関係下における各データ件数を表1に示す。

全データにおける延床面積当たりの工事費の平均をA、標準偏差を σ とした場合、グレードIは $A-1.5\sigma$ 未満、IIは $A-1.5\sigma$ 以上 $A-0.5\sigma$ 未満、IIIは $A-0.5\sigma$ 以上 $A+0.5\sigma$ 未満、IVは $A+0.5\sigma$ 以上 $A+1.5\sigma$ 未満、Vは $A+1.5\sigma$ 以上 $A+2.5\sigma$ 未満、V強は $A+2.5\sigma$ 以上と機械的に設定している。正規分布の場合、 $\pm 2.5\sigma$ の範囲に入るデータ量は全体の約98.76%であり、本設定はほぼすべてのデータをカバーできる。

なお、平均と標準偏差を計算する際には、2018年の東京に補正した金額を採用した。補正には、国土交通省の建設工事費デフレータ及び地域別工事費指数を用いた。本補正はグレードを便宜的に設定するためにのみ使用している。工事費を学習させる時には補正をしていない金額を用いる。

同表内の施設用途01、07、08、09は再開発でよく見られる用途であり、02から06はそれらの用途の複合施設である。用途別にグレードの件数を見ると、1件のものを除けば概ね1から4段階に入る分布になっており、人間が直感的に設定できる範囲である。更に、本ツールの使用者に、自分が携わった過去の案件がどのグレードに属するかを提示することで、初期段階においてグレードを想定することは十分に可能であると考えている。

表1 用途種別とグレードの関係下における各データ件数

用途種別	グレード						合計	構成比
	I	II	III	IV	V	V強		
01事務所		13	19	4	1		37	15.9%
02事務所・商業		4	6	6			16	6.9%
03事務所・住宅		1	5	1			7	3.0%
04事務所・商業・住宅		2	2	1	1		6	2.6%
05事務所・宿泊			3	1			4	1.7%
06商業・住宅	1	5	2				8	3.4%
07住宅		9	5	2	1		17	7.3%
08宿泊		3	2	2			7	3.0%
09商業	2	6	1				9	3.9%
10庁舎		1	12	2			15	6.4%
11文化		1	3	3	2	5	14	6.0%
12スポーツ	1	1	2	3			7	3.0%
13教育・研究		20	27	5	5	1	58	24.9%
14医療		3	8	2			13	5.6%
15福祉				3			3	1.3%
16生産	1		2	3	1	2	9	3.9%
17倉庫・物流	2	1					3	1.3%
合計	7	70	99	38	11	8	233	100.0%
構成比	3.0%	30.0%	42.5%	16.3%	4.7%	3.4%	100%	—

6 ニューラルネットワークの入出力データ項目

ニューラルネットワークの入出力データの各項目の内容について以下に示す。なお、各入力データはプロジェクト初期段階において想定できるという考えの下に設定している。

6.1 入力データ項目

(1) 延床面積、地上階数、地下階数

建物の規模と概略の形状を表す数量データとして採用した。

(2) 用途種別

用途種別はカテゴリーデータであり、各用途種別に対し、該当すれば1、そうでなければ0を入力する。ただし、複合施設の場合は最大3用途までとし、該当する用途の数値を合計すると1になるように按分して設定するものとした。按分率は施設の専有面積比等を参考にする。

(3) グレード

グレードは本来カテゴリーデータであるが、Iは1、IIは2、IIIは3、IVは4、Vは5、V強は6と数量データ化した。グレードは延床面積当たりの工事費を一定金額幅に割り当てているので、グレードを表す数値とほぼ比例関係になると考えた。

(4) 構造種別

構造種別はRC（鉄筋コンクリート造）、S（鉄骨造）、SRC（鉄骨鉄筋コンクリート造）の3種類のカテゴリーデータとした。構造種別の複合は最大2までとし、用途種別と同様の扱いとした。

(5) 建設地

建設地は本来カテゴリーデータであるが、種類が多くなるため、数量データ化する方法を検討した。そこで、建設地における平均地価及び地域別工事費指数を使用するものとした。場所の範囲は原則都道府県単位とし、政令指定都市がある場合はそれを別途考慮した。東京都の場合は特別区内と特別区外に分けた。

平均地価は国土交通省土地・建設産業局の土地総合情報システムより、2018年における商業地の土地面積当たりの平均取引額を使用した。

地域別工事費指数は国土交通省の平成30年度新営予算単価より、県別の鉄骨鉄筋コンクリート造の地域別工事費指数を用いた。

(6) 着工年

着工年は本来カテゴリーデータであるが、種類が多くなるため、建設地と同様に数量データ化する方法を検討した。ここでは着工年の西暦の数値及び建設工事費デフレタの過去2年の勾配を用いた。

西暦の数値と物価変動は線形な関係にあるわけではないが、物価変動を表す指数とセットで学習させる方法を採用した。

建設工事費デフレタは国土交通省の建築総合指数を参照し、該当年の同指数を2年前の同指数で除した値を用いた。即ち、物価トレンドを表すデータとして採用した。

6.2 出力データ項目

出力データは一つであり、延床面積当たりの工事費である。工事費については、時点補正、地域間補正は行わずに使用する。

6.3 データの前処理

ニューラルネットワークの入出力データに実際値をそのまま使うとデータ項目毎に桁数が違うため、膨大な重み係数を算出するには、数値計算が安定せず適さない。そこで、入力データとしてカ

テゴリーデータを除く数量データは、使用する活性化関数の特徴を考慮して、すべて標準化（平均0、標準偏差1）し、出力データは基準化（最大値1、スケールなし）して用いた。カテゴリーデータはそのままの値（最大値1）を用いた。

7 学習結果及び考察

ニューラルネットワークの計算はプログラミング言語Pythonを用い、深層学習ライブラリKeras⁵⁾を利用した。中間層は3層とし、各中間層の活性化関数には双曲線関数（tanh）、出力層はシグモイド関数を用いた。損失関数は二乗和誤差を使用し、学習の最適化アルゴリズムはadam²⁾とした。また、過学習を抑えるため、損失関数にL2正則化項²⁾を考慮した。

学習結果は次の3ケースについて示す（用途番号は表1参照）。

Case1：再開発系事務所（用途01）

Case2：再開発系4用途（用途01から09）

Case3：全件（用途01から17）

Case1は再開発系の事務所という単一用途を対象とした場合である。多くの既往の研究がこれに該当する。Case2は再開発系の事務所・商業・住宅・宿泊の4用途、及びそれらの複合施設を対象としている。Case3は全用途全件のデータを対象としている。Case1からCase3にかけて、データ量は増えることになり、工事費のバラツキも大きくなる傾向がある。

学習に対する検証方法は、各ケース、全データの15%程度を無作為抽出し、検証データとして使用する。この検証データの80%以上が、予測誤差±15%以内に入れば合格とした。

Case1からCase3の学習結果をそれぞれ図4から図6に示す。各図、縦軸及び横軸が共に0から1の値となっているが、予測値及び実績値である延床面積当たりの工事費の最大値を1に基準化しているためである。図中、「学習データ」とは学習させたデータを使って予測した結果であり、再現性を評価している。「検証データ」は学習させていないデータを入力しているので、本予測ツ

ルをまさに検証するものである。

過学習の場合、「学習データ」の方は45度のライン上にほぼ並び、「検証データ」の方は大きく外れるという結果になる。本学習ではL2正則化項を考慮している効果が出て、再現性の精度はやや落ちているが「検証データ」の予測結果は比較的良好である。

予測精度という観点からは、検証データの合格率がCase1は83.3%、Case2は100%、Case3は82.4%と、Case2が最も良い結果となった。Case3は元々バラツキの大きいデータを扱っているが、より詳細なチューニングの効果で検証条件をクリアできている。

以上の結果より、単一用途のみならず、複数用途を対象とした予測ツールの開発の可能性を示すことができたと考えている。

8 開発ツールの概要

予測ツールの開発は、利便性の高さを考慮してマイクロソフト社のExcelを利用した。当画面を図7に示す。操作手順はシンプルで、入力データ項目（延床面積、地上階数、地下階数、用途、グレード、構造、着工年、建設地）を設定し、「AI予測実行」ボタンを押すのみである。瞬時に工事費及び延床面積当たりの工事費（㎡当たり、坪当たり）の各予測値が得られる仕組みとなっている。

学習はPythonのプログラムを通じて行い、検証に合格した時の重み係数をExcelに取り込み、Excelサイドで工事費の予測計算をする方式としている。

本ツールの特徴として、パラメトリックスタディが容易であることが挙げられる。例えば、延床面積、地上階数、地下階数、用途、グレード、構造、建設地を一定にし、着工年だけを変化させて工事費の変化を観察することができる。その一例を建設工事費デフレータ（国土交通省）と合わせて図8に示す。

予測値はデフレータよりも後半やや高めとなっている。当社の設計者の多くは、このデフレータ

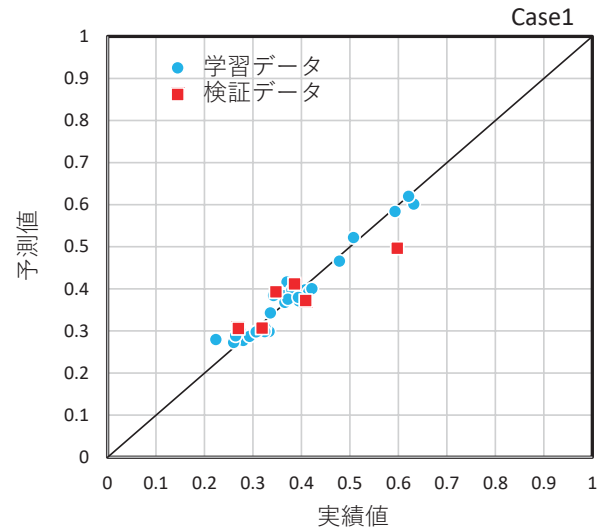


図4 Case1における実績値と予測値の比較




図5 Case2における実績値と予測値の比較

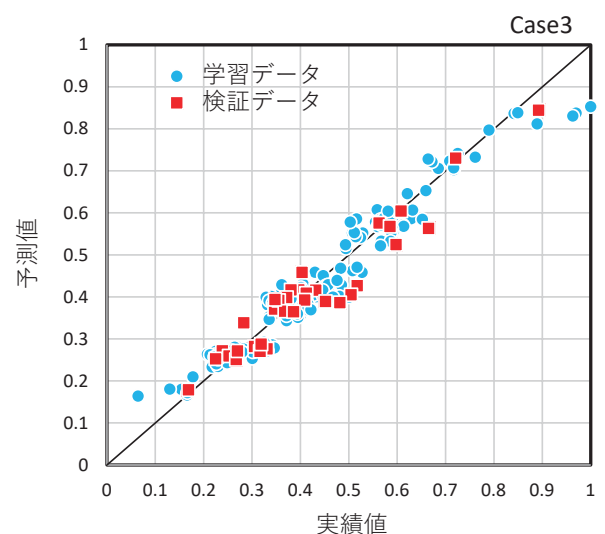


図6 Case3における実績値と予測値の比較

建設プロジェクト初期段階における目標工事費予測システム

過去実績をニューラルネットワークで学習して予測しています

※ 青太枠内を入力し、[AI予測実行]ボタンをクリックして下さい

入力項目名	入力	比率合計 1
延床面積 (㎡)	20,000	
地上階数 (階)	10	
地下階数 (階)	2	
用途1 (主)	事務所	1.000
用途2	-	0.000
用途3	-	0.000
グレード*	III	
構造1 (主)	SRC	1.000
構造2	-	0.000
着工年	2019	
建設地 (地域指数考慮)	東京都23区内	

* グレード V：高い、I：低い

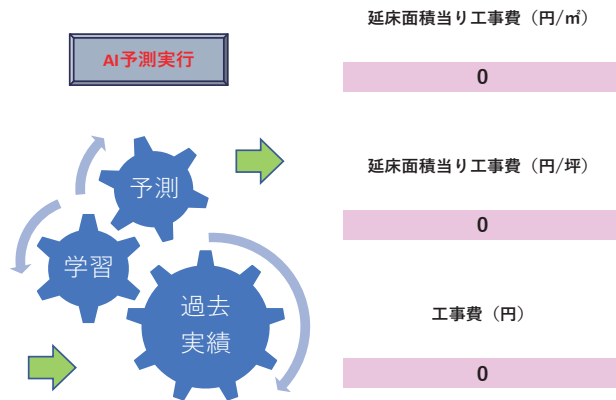


図7 建設プロジェクト初期段階における目標工事費予測システムの画面例

よりも物価上昇率が高いと感じており、それが裏づけられた結果となっている。理由の一つとして、デフレータを算出する時に想定された建物モデルに比べて、当社で扱った案件は社会的要求水準が全般的に高かったためと推察される。

このようなパラメトリックスタディを行うことで、各入力データ項目がコストに与える影響度を知ることができ、コスト特性に対する知見を深めることができる。

9 今後の課題

ニューラルネットワークによる建設プロジェクト初期段階における工事費予測の有効性を示した。また、複数の施設用途や複合施設を単一の予測ツールで対応できる可能性も示した。しかし、予測精度を高めるための課題はいくつかあると考えており、それらの内容を以下にまとめる。

(1) 学習データ量の増大

入力データ項目が複数ある中で、それらの組み合わせによっては学習データ量が少なくなる領域があった。それらを補うデータが必要であり、学習データは多いほどよいと考える。

(2) 一部施設用途の細分化

教育・研究という施設用途を設けたが、学校校舎、屋内運動場、大学講堂、研究施設等、コスト特性が違うと思われる建物が混在する状況であっ




図8 予測工事費の推移例

た。ただし、細分化し過ぎると学習データ量が不足するので、注意は必要である。

(3) 入力データとして特殊要因の追加検討

工事費への影響度が高い特殊要因はいくつか考えられるので、データ化を工夫して取り入れることが有効と考えられる。グレードで表現できない部分を補完するような位置づけになると考えている。

(4) 着工年におけるデータ化の見直し

時点による物価変動の要因は各種経済指標、金利動向等多くあり、工事費と相関性の高いものがある程度であれば取り入れる必要がある。ある程度の年代をまとめて、カテゴリーデータとして扱うことも考えられる。

(5) 建設地におけるデータ化の見直し

時点に応じた地域間の物価変動を数量データ化

することが考えられる。ある程度の場所をまとめてカテゴリーデータとして扱うことも考えられる。

10 AI手法の更なる展開の可能性

今回は建築の特徴を表すいくつかの数値データから目標工事費の予測を試み、AI手法の有効性を示した。AIは特に画像認識の分野において成功例が多いことから、次の(1)から(3)のステップによる工事費予測の展開も考えられる。

- (1) 建物の竣工写真から延床面積当たりの工事費を予測する仕組みを確立する。
- (2) 建物のラフなスケッチから疑似的な竣工写真を生成する。
- (3) 上記(1)の仕組みを使い、疑似的な竣工写真から延床面積当たりの工事費を予測する。

以上のステップにより、建物のラフなスケッチから工事費を予測できることになる。

上記(2)については、敵対的生成ネットワークGAN (Generative Adversarial Networks) と呼ばれる手法が広く研究されている。将来的には、建物のラフなスケッチから工事費を予測できるのではないか。

11 おわりに

基本構想、基本計画等の初期段階に算出する目標工事費は、建設プロジェクトを円滑に進める上ではより多くのデータを基に算出することが望ましい。この観点から、従来の類似案件データを利用する方法に加え、より多くのデータを活用できる第二の方法として、AI手法を用いた目標工事費予測ツールを開発した。

AIが予測した工事費には「この工事費の精度はどのくらいですか」と質問が投げかけられることが予想される。工事費の精度(図9)には三つの意味があると言われている⁶⁾。

- (1) 設計のコスト管理の精度

設計の川上段階に設定した「①設計の目標工事費」と実施設計完了時に算出した「②概算工

事費」を比較した場合の精度

- (2) 工事費概算法の精度

実施設計完了時に算出した「②概算工事費」と「③精算工事費」を比較した場合の精度

- (3) 積算行為自体の精度

建設工事の実施前に「④積算により算出した工事費」と建設工事完了後に「⑤実際にかかった費用の清算により確定した工事費」を比較した場合の精度

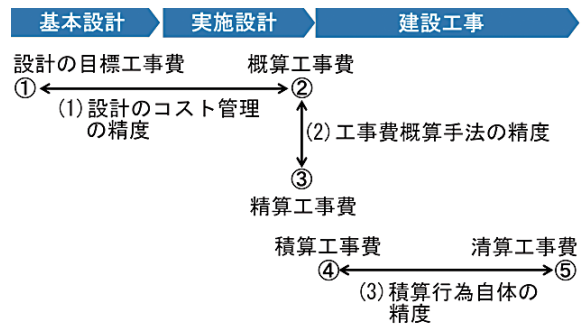


図9 工事費の精度

AIが予想した工事費は設計の目標工事費になるため、AIが予想した工事費の精度に関する質問は「設計のコスト管理の精度」に該当する。精度に関する質問に答えるため、また、その精度を高めるためにも、AIによる工事費予測に連携した設計段階のコストマネジメント手法の構築・整備が必要となる。

今後、本ツールの実用性を更に高めることで、コストマネジメント初期段階における情報量を増やし、建設プロジェクトの円滑な進行に寄与したいと考えている。

(参考文献)

- 1) 加藤泰正, 伊藤一義, 村瀬弘幸「ニューラルネットワークを用いた建設プロジェクト初期段階における概算工事費の予測方法に関する検討」『第42回情報・システム・利用・技術シンポジウム論文集』pp.334-337, 2019.12
- 2) 例えば, Ian Goodfellow他『深層学習』KADOKAWA, 2018.2
- 3) 石原徹也「多変量解析による企画段階での建築コストの予測に関する研究」『日本建築学会関東支部研究報告書』pp.421-424, 1986
- 4) 具源龍, 加藤直樹「データマイニング手法を用いた建築プロジェクトの工事費予測モデルの提案」『日本建築学会環境系論文集』第598号, pp.79-85, 2005.12
- 5) <https://keras.io/>
- 6) 日本建築学会社会システム委員会建築コスト小委員会「建築コスト・ワークショップV「建築コストのタテマエ・ホンネを語る。」『建築コスト七不思議Q&A(第1版)』2012.2.24