The 32nd Annual Conference of the Japanese Society for Artificial Intelligence, 2018

強化学習による構造解析の高速化
High-Speed Calculation in Structural Analysis by Reinforcement Learning

中村　壮志[*1]
Soshi Nakamura

鈴木　琢也[*2]
Takuya Suzuki

[*1] マギル大学
McGill University

[*2] 竹中工務店
Takenaka Corporation

By improvement of computer’s performance, it has become to enable to simulate the behavior of structure, soil and so on using the nonlinear structural analysis of large and complex models. However, these simulations require lots number of convergent calculation to search a convergent solution. Although there are several convergent methods such as Newton’s method, there is no almighty method that fits all situations. Hence, it is up to the person carrying out the analysis to select one of these methods. Considering this situation, in this paper, we propose a method to choose and combine the appropriate convergent method using the concept of Q-learning from reinforcement learning. First, using simple analysis model, we train an action value table to choose the appropriate convergent method with Q-learning. Then, we carried out an analysis using obtained action value table and show that our method can make the convergence time shorter than conventional ones.

1. はじめに

近年の計算機能力の発達に伴い，構造解析分野における要素数･節点数の多い大規模な解析モデル（図 1）を用いたより高精度な数値シミュレーション解析が現実的になりつつある（例えば[Shigeno　2014]）。この大規模解析は，対象とする構造物が線形モデルに留まる場合においては，既に実用化レベルに達している。しかし，構造物に線形性を仮定することは限界があり，今後は，非線形状態に至るまでの解析が求められるようになっていくと考えられる。現状では，大規模モデルの非線形解析を陰解法によって行う場合，非常に大きな計算時間が必要となり，実用化に向けた大きな課題のひとつとなっている。

一般に陰解法に基づく非線形構造解析における解は，外力等の時々刻々の条件から，Try & Error の収束計算によって求められる。収束計算には，初期剛性法（修正 Newton 法），接線剛性法（Newton 法），BFGS 法，ラインサーチ法など様々なものがある[野口　1995]が，それぞれの手法には長所，短所があり解こうとする問題に応じて適切な手法は異なるため，どの問題に対しても有効な収斂手法は明示されていない。そのため，実際にどの収斂方法を選択するかは，解析実施者の経験（あるいは勘）に委ねられているのが現状である。

このような課題に対し，著者らは，これら既往の収斂手法を問題や収斂状況に応じて適切に組み合わせることを考えている。それぞれの手法を最もふさわしい場面で選択することができれば，これまでの単一の収斂手法のみを用いる場合に比べて，効率よく収斂解が探索できる可能性がある。一方，計算を早期に終了するための，適切な組み合わせ方法は，モデルの規模，計算機のスペック等にも依存し，人が設定することは非常に困難であると考えられる。そこで，本研究においては，この適切な収斂方法の選択を，強化学習における Q 学習の枠組みで行う手法を提案する。まず，行動価値テーブルを用いて適切な収斂手法を選択する提案手法を説明する。つづいて，簡単な例題を使って，Q 学習を用いて行動価値テーブルの更新を行う。最後に，学習の結果を用いて数値計算を実施し，従来手法と比較して高速化が可能になっているかを検証する。

連絡先：鈴木琢也，竹中工務店，千葉県印西市大塚 1-5-1，
0476-47-1700，0476-47-6460，suzuki.takuya@takenaka.co.jp

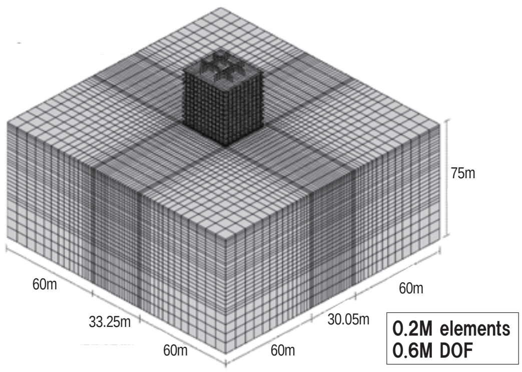

図 1　大規模解析モデルの一例[Shigeno　2014]

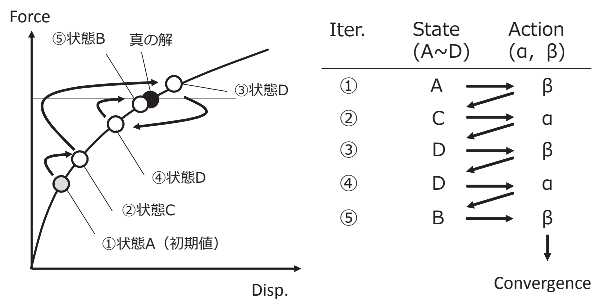

図 2　提案法による収斂計算のイメージ

2. ハイブリッド収斂手法の概要

図 2 には提案する収斂計算のイメージを示す。

ここでは簡単のため，2 種類の収斂法（α,β）を組み合わせて収斂計算を行う場合を考える。図に示すように，ある解析ステップにおいて収斂解を得ようとする場合，まず，現時点の状態（A~D）に基づいて行動価値テーブルを参照し，最も価値の高い収斂手法を選択する。つづいて，選択された収斂手法を用いて予測解を算出する。さらに，その予測解の許容誤差を確認し，

許容範囲内であれば，次のステップへ，範囲外であれば，更新された状態に基づいて再度行動価値テーブルの参照，収斂手法の選択を繰り返す。具体的な行動価値テーブルの構成や，個々の収斂解析手法については後述する。

3. 検討対象例題

提案手法の検証に用いる例題解析について説明する。

解析モデルは，図 3 に示す地盤を模擬した要素数 7452，節点数 8664 のモデルとする。地盤のせん断剛性は 18MPa，ポアソン比は 0.3，単位体積質量は 1.8t/m^{3}とする。非線形特性には，VonMises の降伏条件を用い，降伏応力度は 50kPa，降伏後の二次剛性は 2.0MPa とし，地盤の拘束圧による剛性上昇を考慮する。境界条件は，底面固定，側面繰り返し境界とし，上部地盤の剛体を鉛直下向きに 2000kN の荷重を 200kN ずつ 10Step に分けて載荷し，変形解析を実施する。

本研究では，この例題解析の収斂計算を接線剛性法（ニュートン法）と初期剛性法（準ニュートン法）とを組み合わせることで高速化が可能であるかどうかを検証する。両者の収斂方法の違いを図 4 に示す。

ここで，接線剛性法は，毎回接線勾配を更新するため予測解の精度が高く比較的少ない収斂回数で収斂解を得られることを特徴とする。しかしながら，接線勾配の更新や逆行列の算定に時間を要するため，大規模なモデルでは 1 回の接線勾配の更新に多くの時間を要する場合がある。一方，初期剛性法は接線勾配を更新せず，常に同じ勾配を用いる手法である。そのため 1 回の予測解の計算に必要な時間は接線剛性法よりも短いが，予測解の精度が低く，収斂回数は増えてしまう。

なお，本検討例題を全て接線剛性法によって行った場合の解析時間は 210 秒，全て初期剛性法によって行った場合は 35 秒であった。今回のモデルは要素数・節点数が比較的大きいため接線勾配法においては，収斂回数を低減できるメリットよりも 1 回の更新に時間がかかるデメリットの方が大きかったものと推察される。

4. 学習計画

学習には Q 学習[Watkins 92]を用いる。行動価値テーブルの構成を図 5 に示す。図に示すように，状態は，「前回までに初期剛性法を繰り返したか」，すなわち「最後に接線剛性法を選択したのは何回前か」で分ける。ただし，最初の3回分については，別の状態として認識する。この表中の網掛けした部分の行動価値を Q 学習によって算定する。

学習は，前述の解析モデルを用いて，様々な収斂手法選択条件下で 10000 回（10STEP×1000 回）実施する。学習時の収斂手法選択は，更新回数を 30 回までに，1 回ないし 2 回接線剛性法を選択するものとして，モンテカルロ手法によってランダムに変化させる。このように，接線剛性法の選択回数を絞ったのは，前章の結果より，接線剛性は計算時間的に不利であり，より少なくする方が有効であると考えたためである。

報酬 R は，各ステップの収斂に要した時間 t から下記の報酬関数を用いて，行動価値テーブルの各行動に分配する。収斂に要した時間が少ないほど，大きな報酬が得られるようにしている。

$$R = 1/t \tag{1}$$

なお，割引率は考慮せず，(1)式で得られた値を選択した行動に単純に加算していく。

学習のフローを図 6 に示す。

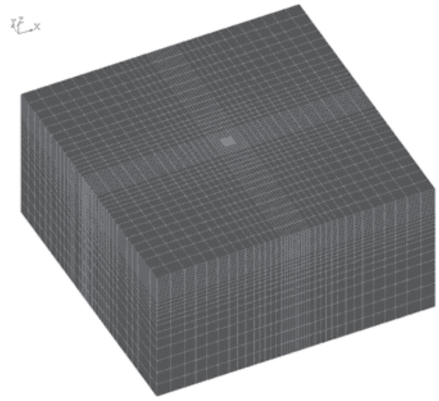

図 3　解析モデル（100m×100m×50m）

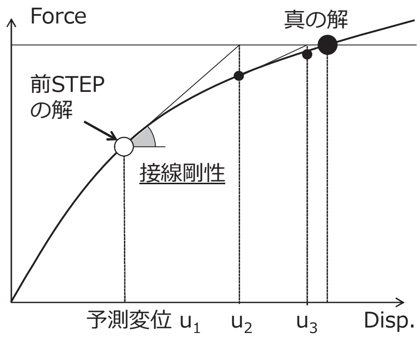

(a)接線剛性法

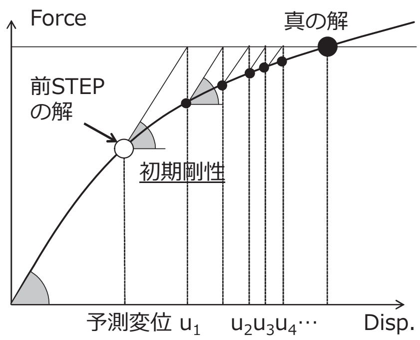

(b)初期剛性法

図 4　接線剛性法と初期剛性法の違い

State		Action 初期剛性法	Action 接線剛性法
Iter.　1回目			
Iter.　2回目			
Iter.　3回目			
Iter. 4回目以降	前回に接線剛性法を選択(before1)		
	前回まで初期剛性法を連続1回選択(before2)		
	前回まで初期剛性法を連続2回選択(before3)		
	・・・		
	前回まで初期剛性法を連続28回選択before29)		

図 5　行動価値テーブルの構成

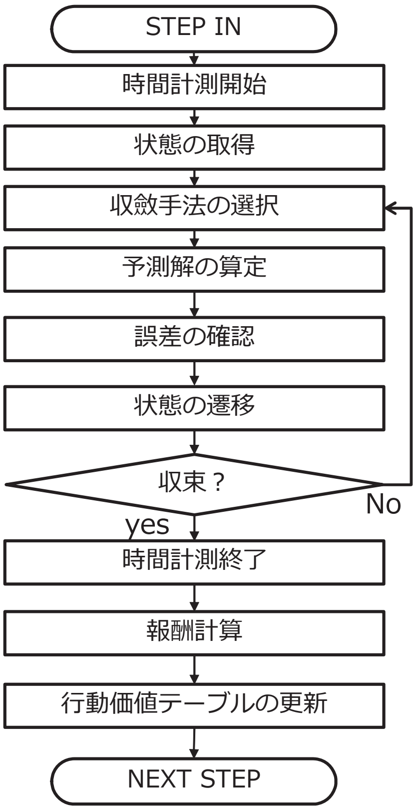

図 6　学習フロー図

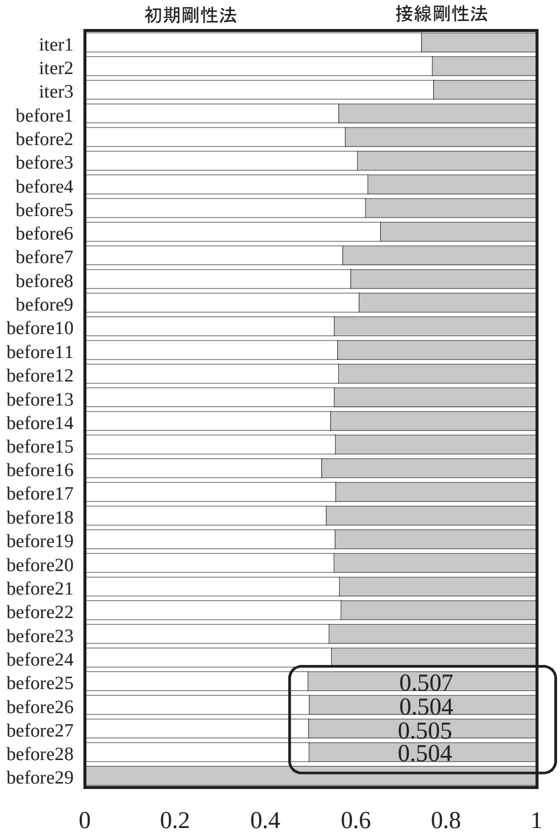

図 7　学習後の行動価値テーブル

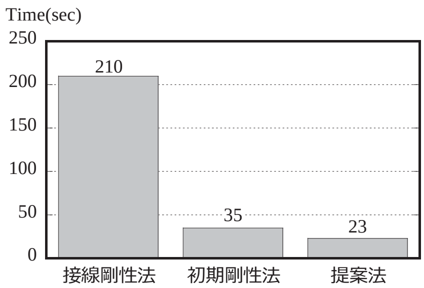

図 8　計算時間の比較

5. 学習結果

図 7 には，学習によって得られた行動価値テーブルの値を示す。なお，今回はモンテカルロ的に収斂手法を決め打ちで実施しているため，各状態に対して，それぞれの手法の効果を等確率で検討できていない可能性を考慮し，最終的に得られた Q 値を頻度で除算するとともに，両方の手法の和が 1 となるように正規化して表示している。

図より，初期剛性法を連続して選択した回数が少ない場合には初期剛性を選択する価値が高く，連続選択の回数が多くなるにつれて徐々に，接線剛性法を選択する価値が高くなる傾向があることがわかる。特に初めのイテレーション 3 回においては，いずれも初期剛性法を選択する価値の方が高い結果となった。今回のテストモデルは比較的大規模であり，1 回の接線剛性更新にかかる計算コストが大きいため，短いスパンで何度も接線剛性法を選択する価値は低くなったものと考えられる。

算定した行動価値の中で，初期剛性法よりも接線剛性法を選択する価値が高くなる状態は，連続で初期剛性法を選択した回数が 24～28(before25-29)回のときであった。ただし，このうち before29 の価値は今回のモンテカルロ探索で，初期剛性法を選択する機会がなかったために生じた特異値であるため，有意な値ではない。これらの結果より，今回のモデルは 25 回おきに接線剛性法を選択することが，計算時間削減に有効であると推察される。

そこで，25 回目のみに接線剛性法を選択して計算時間を計測した結果を図 8 に示す。図に示すように 25 回目のみを接線剛性法を選択した場合の計算時間は 23 秒となり，接線剛性法のみを選択した場合の 210 秒，初期剛性法のみを選択した場合の 35 秒よりも計算時間を短縮できることが確認できた。

6. まとめ

本研究においては，行動価値テーブルを用いて複数の収斂計算方法を適切に選択して収斂を行う手法を提案した。さらに，簡単な例題を使って，強化学習を用いて行動価値テーブルの更新を行い，その結果得られる行動価値テーブルを用いて数値計算を実施し，従来手法と比較して高速化が可能になっていることを確認した。

参考文献

[Shigeno 2014] Shigeno, Y., Hamada, J., Nakamura, N.: Hybrid parallelization of earthquake response analysis using K computer, Proceeding of 14thIACMAG, 2014.

[野口 1995] 野口裕久，久田俊明:非線形有限要素法の基礎と応用，丸善，1995.

[Watkins 92] Watkin, C. J. C. H. and Dayan, P.: Technical note Q-learning. Machine Learning 8(3):279-292, 1992