

# 平面骨組への分解とマルチエージェント強化学習による 不均等スパン鋼構造立体骨組の最適設計

Multi-agent Reinforcement Learning for Optimal Design of 3D Nonuniform-Span  
Steel Frames as Assemblies of 2D Frames

竹中虎太郎<sup>1)</sup>, 大崎 純<sup>2)</sup>

Kotaro Takenaka and Makoto Ohsaki

1) 修(工) 京都大学 大学院生 (〒615-8540 京都府京都市西京区桂京都大学, E-mail: takenaka.kotaro.68x@st.kyoto-u.ac.jp)

2) 博(工) 京都大学 工学研究科 教授 (〒615-8540 京都府京都市西京区桂京都大学, E-mail: ohsaki@archi.kyoto-u.ac.jp)

Our previous research introduced multi-agent reinforcement learning into discrete optimization of regular 3D frames and streamlined design modifications. This study extends the approach to enhance the generalization performance for 3D steel frames with nonuniform spans. The proposed method (LS+MRL) effectively optimizes cross-sectional dimensions and is superior to simulated annealing in terms of computational time and constraint satisfaction. Additionally, by increasing the layers of the neural network, the method achieves greater efficiency while reducing the number of parameters.

**Key Words :** Structural Optimization, Multi-agent Reinforcement Learning, Discrete Optimization, Building Frame

## 1. はじめに

建築物の立体骨組は、多くの部材から構成される高次の不静定構造物である。実務設計では、一貫構造計算ソフトウェアなどのツールを用いて設計荷重に対する応答を評価するが、断面仮定時の応答が望ましくない場合、断面等の更新による設計変更と構造解析を繰り返す必要がある。本研究では、不均等なスパンをもつ立体骨組を対象に、機械学習を用いて設計変更を効率化するための最適化手法を提案する。

著者らの既往研究[1]では、整形な立体骨組を対象とした離散最適化手法を提案した。既往手法では、1) 鋼構造立体骨組の構面を平面骨組に分解して部材断面を最適化(分解過程)し、2) 平面骨組から立体骨組へ2つの強化学習(RL)エージェントを用いて再構築する(再構築過程)という二段階のプロセスを導入した。その際、平面骨組に分解したときと立体骨組として解析したときの層せん断力の分布や変形の差、および複数の平面骨組を組み合わせて立体骨組へ再構築する際に共有される柱部材の断面の相違などの不整合がある。再構築過程では、部材選択および断面選択タスクを行う異種RLエージェントを活用し、エージェントが局所的な情報に基づいて設計変更を行うことで、再構築に伴う不整合を修正する。

本研究では、既往手法の汎化性能を向上させるため、不均等なスパンをもつ立体骨組を学習対象として強化学習

を実行する。具体的には、不均等スパンの骨組構造に対応するため、ニューラルネットワーク(NN)の層数を増やし、モデルの表現力を高めつつ、NNのパラメータ数を削減することで、より効率的なネットワーク構成を実現する。

数値解析では、学習対象骨組と節点数および部材数が異なる骨組に学習済みエージェントを適用し、既往の離散最適化手法との比較から、本手法の計算時間の短縮と汎化性能の向上を示す。これにより、不均等なスパンをもつ立体骨組への適用可能性を明らかにする。

## 2. 最適化問題の定式化

本研究で対象とする鋼構造骨組は、不均等スパンを含む純ラーメン立体骨組とする。骨組形状は、層数 $n_f$ 、X方向スパン数 $n_x$ 、Y方向スパン数 $n_y$ 、X方向スパン長ベクトル $\mathbf{l}_x \in \mathcal{L}^{n_x}$ およびY方向スパン長ベクトル $\mathbf{l}_y \in \mathcal{L}^{n_y}$ を選択して決定し、部材断面寸法を離散設計変数とする最適化問題を考える。ただし、 $\mathcal{L}$ はとりうる梁部材長を集めた集合とし、上付き文字によって任意の次元の直積空間を表す。

梁にH形鋼のBH材(Built-up H)、柱に角形鋼管のBB材(Built-up Box)を用いる。部材 $i$ がH形鋼のとき、せい $H_i$ 、幅 $B_i$ 、フランジ厚 $t_f^i$ を用いて設計変数を $\mathbf{y}_i = \{H_i, B_i, t_f^i\}$ とし、角形鋼管のとき、せい $D_i$ 、柱板厚 $t_i$ から同様に $\mathbf{y}_i = \{D_i, t_i\}$ と表す。骨組の対称性を考慮して部材をグルーピングし、

梁柱の順に並べたベクトルを設計変数として

$$\mathbf{x} = \{\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_m\} \in \mathcal{X} \quad (1)$$

と表す．ここで， $m$ は部材数， $\mathcal{X}$ は設計変数 $\mathbf{x}$ のとりうる集合を示す．連続変数最適化問題と離散変数最適化問題では， $\mathcal{X}$ は以下に示す異なる集合 $\mathcal{X}_C$ ， $\mathcal{X}_D$ とする（単位はmm）．H形鋼のウェブ厚 $t_i^w$ はフランジ厚に比例するものとし，連続変数のとき $t_i^w = \max\{9, t_i^f/2\}$ ，離散変数のとき下記のリスト $\mathcal{T}_w$ のなかで $t_i^f/2$ との差が最も小さい値とする．

$$\begin{aligned} \mathcal{X}_C &= \{\mathbf{x} | 450 \leq H_i \leq 1000, 200 \leq B_i \leq 400, \\ &12 \leq t_i^f \leq 40, 350 \leq D_i \leq 1000, 12 \leq t_i \leq 40 \\ \mathcal{X}_D &= \{\mathbf{x} | H_i \in \mathcal{H}, B_i \in \mathcal{B}, t_i^f \in \mathcal{T}_f, D_i \in \mathcal{D}, t_i \in \mathcal{T}\} \\ \mathcal{H} &= \{450, 500, \dots, 1000\}, \mathcal{B} = \{200, 250, \dots, 400\}, \\ \mathcal{T}_w &= \{9, 12, 14, 16, 19, 22\}, \\ \mathcal{T}_f &= \{12, 16, 19, 22, 25, 28, 32, 40\}, \\ \mathcal{D} &\in \{350, 400, \dots, 1000\}, \\ \mathcal{T} &= \{12, 16, 19, 22, 25, 28, 32, 36, 38, 40\} \end{aligned}$$

最適化問題の目的関数は総鋼材量（体積） $V(\mathbf{x})$ とする．文献[1]の通り，骨組には鉛直および水平方向の荷重を与える．各節点の拘束条件についても文献[1]と同じとする．梁材，柱材にはSN400 ( $F = 235 \text{ N/mm}^2$ ) およびBCP325 ( $F = 325 \text{ N/mm}^2$ )をそれぞれ用い，許容応力度設計に基づき部材の性能指標として次式で定められる許容応力度比を検定値1.0以下とする．最下階および最上階を除く柱梁接合部には梁の降伏が先行する崩壊系となるような指標として柱梁耐力比制約を制限値1.5以上で与える．建物変形指標として層間変形角を1/200以下とする．部材 $i$ ，層 $i$ あるいは接合部 $i$ に関する量を下添え字 $i$ で表すと，制約条件とパラメータは以下のとおりである．

$$\begin{aligned} &\text{許容応力度比:} \\ \sigma_i &= \begin{cases} \frac{M_i}{Z_i f_{b,i}} + \frac{|N_i|}{A_i f_i} \leq 1.0, (i = 1, 2, \dots, n_c) & \text{柱} \\ \frac{M_i}{Z_i f_{b,i}} \leq 1.0, (i = 1, n_g) & \text{梁} \end{cases} \\ f_i &= \begin{cases} f_t & N_i \geq 0 \\ f_c & N_i < 0 \end{cases} \\ f_t &= F, f_c = \begin{cases} \frac{1 - 0.4(\lambda_i/\Lambda_i)^2}{3/2 + (2/3)(\lambda_i/\Lambda_i)^2} \cdot 1.5F & \lambda_i \leq \Lambda_i \\ \frac{18}{65(\lambda_i/\Lambda_i)^2} \cdot 1.5F & \lambda_i > \Lambda_i \end{cases} \\ f_{b,i} &= \max\{f_b^1, f_b^2\} \\ f_b^1 &= \left[ 1 - \frac{0.4(l_{b,i}/\rho_i)^2}{\Lambda_i^2} \right] \cdot F \\ f_b^2 &= \frac{8900}{l_{b,i} H_i / A_{f,i}} \cdot F \\ &\text{柱梁耐力比:} \\ \beta_i &= M_{pc,i} / M_{pb,i} \geq 1.5, (i = 1, 2, \dots, n_j) \end{aligned}$$

層間変形角:

$$d_i = \delta_i / h_i \leq 1/200, (i = 1, 2, \dots, n_f)$$

$n_c$	: 柱断面の種類数	$n_g$	: 梁断面の種類数
$A_i$	: 断面積	$l_i$	: 部材長
$n$	: 構造制約の数	$l_{b,i}$	: 座屈長さ
$\rho_i$	: 断面二次半径	$\lambda_i$	: 有効細長比
$\Lambda_i$	: 限界細長比	$A_{f,i}$	: フランジ断面積
$f_{b,i}$	: 許容曲げ応力度	$Z_i$	: 断面係数
$M_i$	: 曲げモーメントの絶対値の最大値		
$N_i$	: 軸力	$f_i$	: 許容軸応力度
$M_{pc,i}$	: 節点 $i$ の柱全塑性モーメント総和		
$M_{pb,i}$	: 節点 $i$ の梁全塑性モーメント総和		
$\beta_i$	: 柱梁耐力比	$n_j$	: 節点数
$\delta_i$	: 層間変位	$h_i$	: 階高
$n_f$	: 層数	$d_i$	: 層間変形角

制約条件をまとめて $g_i(\mathbf{x}) \leq \varphi_i$ , ( $i = 1, 2, \dots, n$ )と表し，鋼材量最小化問題を以下のように定式化する．

$$\text{Find } \{\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_m\} \in \mathcal{X} \quad (2a)$$

$$\text{minimize } V(\mathbf{x}) = \sum_{k=1}^m A_k l_k \quad (2b)$$

$$\text{subject to } g_i(\mathbf{x}) \leq \varphi_i, (i = 1, 2, \dots, n) \quad (2c)$$

$$\mathbf{x} \in \mathcal{X}$$

### 3. 強化学習による最適化手法

本手法は，既往研究[1]で提案された平面骨組への分解過程と立体骨組への再構築過程の二段階アプローチを基本として，離散断面最適化を行う．以下では，本研究で使用する最適化手法とエージェントの学習方法を示す．さらに，不均等スパンの骨組への拡張のために使用したNN構成についても示す．

#### (1) 分解過程

分解過程では，Algorithm 1 [1]に示すように，すべてのとりうる平面骨組の構面に対して式(2)に示す最適化問題による連続最適化を行う．最適化手法には非線形性の強い問題に適用でき計算効率の良い内点法[2]を用いる．その後，得られた連続変数を集合 $\mathcal{X}_D$ に基づいて離散化することで立体骨組最適化の初期解を得る．

#### (2) 再構築過程

Algorithm 2 [1]に示すLS+MRL (Local Search with Multi-agent Reinforcement Learning)手法が再構築過程での強化学習エージェントに基づく再構築手法である．LS+MRLでは，部材選択タスクを担当するAGENT1と断面選択タスクを担当するAGENT2の2つのRLエージェントを活用する．断面を変更する部材の選択や部材断面選択など複数のタスクが存在するため，異種エージェントのMRLの導入により，単純なエージェントによって部材更新の過程を分担して実行する．タスクを分担することによってそれぞれのタスクごとに特化した価値評価と更新における計算負荷の低減が可能となる．また，局所的な情報に基づく設計変更を行うことで，再構築に伴う不整合を修正する．

### (3) 強化学習ワークフロー

RLのフレームワークでエージェントを学習するために、状態量、行動、報酬を定義したマルコフ決定過程(MDP: Markov Decision Process)を導入する必要がある。MDPはそれまでの状態と行動に依存することなく次の状態を決定することができる。MDPに基づいてRLでは価値概念を利用し、現在の状態から価値を最大化するような最適な行動をエージェントに選択させる学習を行う。

状態量を、構造性能指標、対象部材の形状指標、および柱梁識別値の局所的な指標から定義する。構造性能指標には、最適化問題の構造に関する制約条件(2c)を参照し、部材情報である許容応力度比、節点情報である柱梁耐力比、構面情報である層間変形角の値を検定値によって正規化して用いる。部材断面の形状指標には、断面寸法値をとりうる寸法の最大値により正規化して用いる。柱梁識別値は2成分のベクトルで表現する。ただし、柱梁耐力比および層間変形角はX, Y方向それぞれの値を考慮する。AGENT1およびAGENT2が行動選択に用いる状態量をベクトル

$$\mathbf{s} = \{s_\sigma, s_\beta, s_d, s_y, s_m\} \quad (3)$$

と表す。詳細は表1の通りである。

表-1 状態量の詳細

- 部材の許容応力度比 $\sigma$ に関する状態量

$$s_\sigma = 1 - \sigma \in \mathbb{R}^1$$

- 部材端部の柱梁耐力比 $\beta_1, \beta_2, \beta_3, \beta_4$ に関する状態量

$$s_\beta = \{1 - 1.5/\beta_1, 1 - 1.5/\beta_2, 1 - 1.5/\beta_3, 1 - 1.5/\beta_4\} \in \mathbb{R}^4$$

- 構面の層間変形角 $d_1, d_2$ に関する状態量

$$s_d = \{1 - 200 \cdot d_1, 1 - 200 \cdot d_2\} \in \mathbb{R}^2$$

- 断面寸法値に関する状態量

$$s_y = \begin{cases} \{D/\bar{D}, D/\bar{D}, t/\bar{t}\} \in \mathbb{R}^3 & \text{柱} \\ \{H/\bar{H}, B/\bar{B}, t^f/\bar{t}^f\} \in \mathbb{R}^3 & \text{梁} \end{cases}$$

$\bar{D}, \bar{t}, \bar{H}, \bar{B}, \bar{t}^f$ : 各寸法値の最大値

- 柱梁識別に関する状態量

$$s_m = \begin{cases} \{1, 0\} \in \mathbb{R}^2 & \text{柱} \\ \{0, 1\} \in \mathbb{R}^2 & \text{梁} \end{cases}$$

2種類のエージェントの行動を定義する。 $m$ 種類の部材から $i$ 番目の部材グループを選択するとき、エージェントのとりうる行動は以下で定義される。

$$\mathcal{A}_1 = i \in \{1, 2, \dots, m\} \quad (4)$$

一方、部材グループ $i$ において離散断面集合の中で近傍断面寸法を選択するとき、行動は

$$\begin{aligned} \mathcal{A}_2 &= \begin{cases} a_k^g & (1 \leq k \leq n_g) \\ a_k^c & (n_g < k \leq n_g + n_c) \end{cases} \\ a_k^g &= \begin{cases} H_k \text{増加}, B_k \text{増加}, t_k^f \text{増加}, \\ H_k \text{減少}, B_k \text{減少}, t_k^f \text{減少} \end{cases} \\ a_k^c &= \begin{cases} D_{k-n_g}^1 \text{増加}, D_{k-n_g}^2 \text{増加}, t_{k-n_g} \text{増加}, \\ D_{k-n_g}^1 \text{減少}, D_{k-n_g}^2 \text{減少}, t_{k-n_g} \text{減少} \end{cases} \end{aligned} \quad (5)$$

と定義される。ただし、 $D_{k-n_g}^2$ は柱梁において同じNNを使用するために定義する。柱断面選択時に $D_{k-n_g}^2$ は行動として選択されないようにマスク処理を行う。

報酬は、既往手法[1]と同様に、鋼材量および制約違反量の減少量に基づいて決めることで、制約違反を改善しながら鋼材量を下げの方策をとるように与える。

立体骨組最適化のためのAGENT1とAGENT2による学習手順として、1) Algorithm 1 [1]を用いて構面分解から立体骨組の初期解を得る、2) 立体骨組の離散最適化を行うことによる探索を繰り返し、探索中の更新履歴からエージェントのパラメータを更新する。学習全体のワークフローは図3 [1]に従う。具体的には、エージェントのパラメータ $\theta$ をランダムに初期化する。各エピソードでは、学習骨組の形状を対象骨組の集合からランダムに選択し、Algorithm 1 [1]により断面寸法を初期化する。第 $t$ ステップにおいて有効な行動をするために $\epsilon$ -greedy法[3]を用いてランダムな確率で部材や断面を選択し、多様な解の探索を行う。ただし、AGENT1およびAGENT2の学習を交互に行うことで、エージェント間の相互作用から最適方策が得られるようにする。そのため、学習対象でないエージェントについては $\epsilon = 0$ として行動価値が最大の行動を選択する。この操作を、制約違反が増加する、あるいは最大ステップ数に達するまで繰り返す。部材更新の後、次のステップの状態量 $\mathbf{s}_{t+1}$ 、報酬 $r_{t+1}$ 、終了状態 $\mathbf{e}$ を学習データ $\{\mathbf{s}_t, \mathbf{a}_t, \mathbf{s}_{t+1}, r_{t+1}\}$ として保存する。エージェントは保存された学習データからパラメータ $\theta$ の更新を毎ステップ行う。学習中、10エピソードごとに、2つのエージェントともに $\epsilon = 0$ とした検証用骨組に対して断面更新を行うテストエピソードを実行し、累積報酬を記録して学習モデルの性能を確認する。




図-1 NNの構成

### (4) ニューラルネットワーク構成

既往研究[1]では、計算負荷を小さくするために単層のNNを採用していた。しかし、本研究では不均等スパンの

骨組を扱うため、部材ごとの状態量の種類が多様になると考えられる。そのため、多層のニューラルネットワークを構築し、非線形な表現力を得られる構成とする。具体的には、図1に示すように、入力層から出力層に向けて徐々にパーセプトロンの数を減少させる構造とする。さらに、各層では活性化関数としてtanh関数を用いる。これにより、パラメータ数を従来の約半分に抑えつつ、部材ごとの複雑な状態量を適切に表現できるようにする。

4. 数値解析例

以下では、まず学習に使用した骨組を学習済みマルチエージェント（以下、LS+MRL）によって最適化し、鋼材量および計算時間、構造性能を確認する。その後、スパンおよび層方向に異なる特徴をもつ立体骨組を対象として、LS+MRLの最適化性能を鋼材量および計算時間、制約の充足状況により検証する。性能の比較には確率的アルゴリズムである焼きなまし法[4] (SA: Simulated Annealing)の結果を用いる。ただし、一度の試行における構造解析回数を揃えるため、LS+MRLおよびSAにおける最大断面更新回数を1000回とする。さらに、検証する骨組においてSAのパラメータは試行錯誤により決定し、ランダム性を有する手法であるため10回試行する。

(1) 学習設定

学習には、層数 $n_f = 1, 2, \dots, 5$ 、X、Y方向スパン数 $n_x, n_y = 1, 2, \dots, 5$ の骨組に対して、部材長の集合 $\mathcal{L} = \{5.0, 5.2, \dots, 10.0\}$ としてランダムに得られる不均等スパンを含む立体骨組を用いる。床荷重 $w = 7.0, 7.2, \dots, 10.0$  kN/m<sup>2</sup>をランダムに与えて学習対象骨組とする。Algorithm 1 [1]による初期解の生成は強化学習とは非同期に行い、強化学習では保存された初期解をランダムに選び部材更新を行う。この初期解は、内点法により、とりうる構面ごとの最適化から得られ、構面を立体に組み合わせるとき重複する柱の断面には大きい寸法値を採用する。学習の総エピソード数を $n_{ep} = 20000$ 、学習率 $\alpha = 1.0 \times 10^{-4}$ 、割引率 $\gamma = 0.99$ とする。Experience Replay [5]によって保存する学習データ $\{s_t, a_t, s_{t+1}, r_{t+1}\}$ の数は20000とし、20000を超える場合、古い学習データと置き換える。NNパラメータ更新のための学習の際にはランダムに200個のデータを取り出す。エージェントのNNパラメータの初期値はランダムに設定して学習を開始する。

構造解析および強化学習には、Intel(R) Core(TM) i7-14700K およびGeForce RTX 4060Tiを備える計算機を用い、Python 3.10、MATLAB R2024bによりプログラムを実装した。強化学習エージェントは機械学習のフレームワークであるPyTorch2.3.1によって構成する。さらに、連続変数最適化にはmatlab2024bのOptimization Tool-boxの内点法(IPM)を用いる。

(2) 学習結果

20000エピソードの学習を約93.1時間行った。表3(a)の検証用骨組において累積報酬が最大となるときのエージェント

表-2 初期解と最適解の構造性能

初期解

LS+MRL

構面 X の最大許容応力度比

Diagram showing the maximum allowable stress ratios for Frame X in the initial solution. The ratios are distributed across the frame members, with red values indicating areas of high stress concentration.

0.96	1.04	0.86
1.16	1.27	0.79
0.86	1.04	0.88
0.85	1.03	0.67
0.99	1.05	0.90
1.11	1.34	0.90
0.98	1.10	0.92
0.92	1.18	0.79
		0.53

Diagram showing the maximum allowable stress ratios for Frame X in the optimized solution. The ratios are distributed across the frame members, with red values indicating areas of high stress concentration.

0.94	0.88	0.88
0.98	0.93	0.74
0.90	0.96	0.88
0.70	0.64	0.46
0.91	0.96	0.89
0.86	0.88	0.77
0.86	0.86	0.90
0.76	0.99	0.71
		0.53

構面 Y の最大許容応力度比

Diagram showing the maximum allowable stress ratios for Frame Y in the initial solution. The ratios are distributed across the frame members, with red values indicating areas of high stress concentration.

0.91	1.01	0.33
0.94	1.27	0.92
0.79	1.02	1.03
1.13	1.34	0.38
1.05	0.98	
0.97	1.18	0.43

Diagram showing the maximum allowable stress ratios for Frame Y in the optimized solution. The ratios are distributed across the frame members, with red values indicating areas of high stress concentration.

0.99	0.86	0.34
0.95	0.93	0.79
0.66	0.64	0.31
0.94	0.77	
0.75	0.88	0.37
1.00	0.85	
0.76	0.99	0.41

構面 X の柱梁耐力比の逆数を検定値で除した値

Diagram showing the inverse of the column-beam capacity ratio normalized by the design value for Frame X in the initial solution. The ratios are distributed across the frame members, with red values indicating areas of high stress concentration.

1.13	1.46	0.65	0.33
1.03	1.36	0.65	0.33
0.98	1.31	0.65	0.39

Diagram showing the inverse of the column-beam capacity ratio normalized by the design value for Frame X in the optimized solution. The ratios are distributed across the frame members, with red values indicating areas of high stress concentration.

0.98	0.85	0.52	0.33
0.91	0.84	0.46	0.33
0.82	0.99	0.55	0.33

構面 Y の柱梁耐力比の逆数を検定値で除した値

Diagram showing the inverse of the column-beam capacity ratio normalized by the design value for Frame Y in the initial solution. The ratios are distributed across the frame members, with red values indicating areas of high stress concentration.

0.84	1.44	0.32
0.95	1.43	0.28
1.01	1.34	0.29

Diagram showing the inverse of the column-beam capacity ratio normalized by the design value for Frame Y in the optimized solution. The ratios are distributed across the frame members, with red values indicating areas of high stress concentration.

0.84	0.84	0.33
0.74	0.87	0.28
0.70	0.96	0.25

X 方向層間変形角を検定値で除した値

Diagram showing the normalized inter-story drift angle for Frame X in the initial solution. The ratios are distributed across the frame members, with red values indicating areas of high stress concentration.

0.21
0.35
0.44
0.36

Diagram showing the normalized inter-story drift angle for Frame X in the optimized solution. The ratios are distributed across the frame members, with red values indicating areas of high stress concentration.

0.19
0.29
0.35
0.31

Y 方向層間変形角を検定値で除した値

Diagram showing the normalized inter-story drift angle for Frame Y in the initial solution. The ratios are distributed across the frame members, with red values indicating areas of high stress concentration.

0.03
0.16
0.24
0.21

Diagram showing the normalized inter-story drift angle for Frame Y in the optimized solution. The ratios are distributed across the frame members, with red values indicating areas of high stress concentration.

0.10
0.18
0.23
0.19

を最適エージェントとして以降の検証に用いる。

Algorithm 1 [1]の連続変数の緩和による最適解を離散化近似した初期解と、LS+MRLによる最適解の構造性能を表2に示す。部材の許容応力度比、柱梁耐力比および層間変形角をそれぞれ1.0、1.5、1/200によって除した値を制約充足率の指標(以降、充足率)として示している。ここで、全ての充足率が1.0以下で制約を満たすようにするため、柱梁耐力比は逆数を用いて $(1/\beta_i)/1.5 \leq 1.0$ としている。

初期解では、196の制約のうち40の制約違反が確認された。違反している制約の平均充足率は1.15であった。許容応力度比において内側構面の柱梁で制約違反（1.0を超える値をとる）している。特に柱では、充足率が最大1.46であり大きく制約違反している。さらに、柱梁耐力比では、各構面において2つの梁が接続する節点周りで制約違反

が多くみられる。この初期解に対して、LS+MRLで最適化したところ全ての制約条件が満たされ、制約充足率を高めていることが確認される。とくに、梁では許容応力度比の平均充足率が0.90であり、許容応力度比制約が有効な制約となっている。

(3) 汎化性能の検証

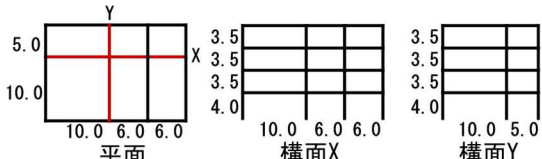
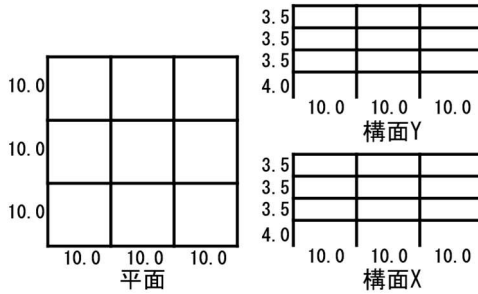
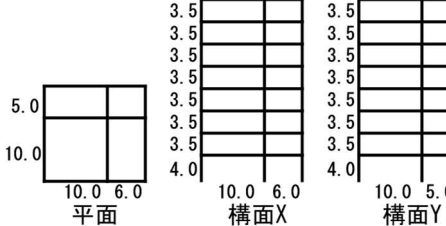
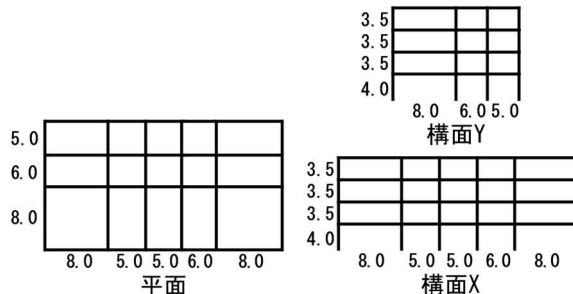
表3(b)～(d)では、学習に使用していない骨組モデルに対してLS+MRLを適用し、鋼材量、計算時間および最適解の最大充足率により性能を検証する。それぞれ既往手法[1]が対象とする正方形平面をもつ骨組、層数、スパン数に関して未学習の骨組である。正方形平面の場合、異なる断面分布をもつ構面は対称性から最大2種類であるが、不均等スパン骨組では荷重分布の異なる2種類以上の構面を考慮する必要がある。以降では、不均等スパンをもつ骨組に対しても正方形平面の場合と同様の最適化手法で立体骨組最適化が可能であることを確認する。ただし、SAでは単一の試行で最適解が得られるとは限らないため、全ての骨組について10回の試行の中から最良の解の鋼材量を比較に使用する。さらに、本研究における最適化計算時間は、各手法が最良解を得るために行った計算の合計として定義する。

- 骨組(a)は部材数116、構造性能に関する制約条件の数は196である。初期解における制約違反数は40である。最適解の鋼材量では、LS+MRLはSAに比べて約8%小さい。計算時間については約95%短縮された。最大充足率はLS+MRLが0.98と制約を満足しているのに対し、SAは1.05と僅かに制約を超過した。
- 骨組(b)は、正方形平面をもつ単純な骨組である。対称性を考慮したとき部材数28、構造性能に関する制約条件の数は60である。初期解における制約違反数は18である。最適解の鋼材量では、LS+MRLはSAに比べて約6%小さい。計算時間については約90%短縮された。最大充足率はLS+MRLが0.99、SAは0.98と制約を満足した。
- 骨組(c)は部材数168、構造性能に関する制約条件の数は310である。初期解における制約違反数は96である。最適解の鋼材量では、LS+MRLはSAに比べて約11%小さい。計算時間については約92%短縮された。最大充足率はLS+MRLが0.97と制約を満足しているのに対し、SAは1.26と大きく制約を超過した。
- 骨組(d)は部材数248、構造性能に関する制約条件の数は328である。初期解における制約違反数は29である。最適解の鋼材量では、LS+MRLはSAに比べて約2%大きい。計算時間については約94%短縮された。最大充足率はLS+MRLが0.97と制約を満足しているのに対し、SAは1.03と僅かに制約を超過した。

5. 結論

本研究では、既往研究[1]で提案された整形な立体骨組

表-3 鋼材量と計算時間の比較

Algorithm	鋼材量	計算時間	最大充足率
(a) 3×2 スパン 4 層			
			
LS+MRL	8.45	13.98	0.98
SA	9.19	330.65	1.01
SA 比	0.92	$4.22 \times 10^{-2}$	—
(b) 3×3 スパン 4 層			
			
LS+MRL	19.01	22.99	0.99
SA	20.03	233.68	0.98
SA 比	0.94	$9.83 \times 10^{-2}$	—
(c) 2×2 スパン 8 層			
			
LS+MRL	14.17	26.98	0.97
SA	15.92	355.08	1.26
SA 比	0.89	$7.59 \times 10^{-2}$	—
(d) 5×3 スパン 4 層			
			
LS+MRL	14.44	36.05	0.96
SA	14.14	627.32	1.03
SA 比	1.02	$5.74 \times 10^{-2}$	—

を対象とした離散最適化手法を発展させ、不均等スパンを含む立体骨組を対象とした学習済みマルチエージェント最適化手法(LS+MRL)を提案し、その汎化性能を数値解析により検証した。得られた知見は以下の通りである。

- ① 不均等スパン骨組を対象とした20000エピソード(約93.1時間)の強化学習により、断面を変更する部材を選



択するエージェントと断面を変更するエージェントの異種エージェントが構造に関する制約を満たす最適解を得た。さらに、NN構成を多層にしてパーセプトロンの数を漸減するすることで、少ないNNのパラメータで精度の良い解が得られた。

- ② 正方形平面をもつ骨組，層数，スパン数に関して未学習の骨組に学習済みLS+MRLを用いて最適化を行った。LS+MRLはすべての検証骨組において1000ステップで制約を満たしたが，SAでは完全に満たすことはできなかった。計算時間に関しては，1回の試行で最適解が得られるためSAと比較して最大で95%短縮することができ効率よく最適解が得られた。本研究によって，不均等スパン骨組においても既往研究を用いてLS+MRLによる最適性能が示された。

本研究の結果から，提案手法LS+MRLが不均等スパン骨組の最適設計に対して高い汎化性能を発揮し，実設計への適用が期待できる手法であることが明らかになった。今後は，大規模な骨組への適用可能性について検討する必要がある。また，より実務設計への適用に向けた設計要件の検討が必要である。

謝辞: 本研究はJSPS科研費JP23K04104の助成を受けた。

#### 参考文献

- [1] 竹中 虎太郎, 大崎 純, 山川 誠, 林 和希: 平面骨組への分解とマルチエージェント強化学習による鋼構造立体骨組の最適設計, 日本建築学会構造系論文集, 第90巻, 第829号, 334-343, 2025.
- [2] R. H. Byrd, Mary E. Hribar and Jorge Nocedal: An interior point algorithm for large-scale nonlinear programming, SIAM Journal on Optimization, Vol 9(4), pp. 877–900, 1999.
- [3] R. S. Sutton and A. G. Barto: Reinforcement Learning: An Introduction, Robotica, Vol. 17(2): pp. 229–235, 1999. (DOI: 10.1017/S0263574799271172)
- [4] S. Kirkpatrick, C. D. Gelatt. and M. P. Vecchi: Optimization by simulated annealing, Science, Vol. 220(4598), pp. 671–680, 1983. (DOI: 10.1126/science.220.4598.671)
- [5] L. J. Lin: Self-improving reactive agents based on reinforcement learning, planning and teaching. Machine Learning, Vol. 8, pp. 293–321, 1992. (DOI: 10.1007/BF009926