

# 量子アニーリングとブラックボックス最適化を用いた 倉庫内業務最適化

高木 魁利<sup>1,a)</sup> 瀧上 昂希<sup>1</sup> 片山 晋<sup>1</sup> 浦野 健太<sup>1</sup> 米澤 拓郎<sup>1</sup> 河口 信夫<sup>1,2</sup>

**概要:** サプライチェーンの拡大に伴い、モノの中継地点である物流倉庫のさらなる効率化が求められている。しかし物流倉庫は休みなく運用されるため、現実空間における運用方法・環境の変更と、その定量的な評価は容易ではなく、センシングによる倉庫環境デジタル化と仮想環境の最適化が不可欠である。最適化の一種に物流・経済・交通などの多様な分野で応用されている組合せ最適化がある。近年、組合せ最適化問題に特化した量子アニーリングマシンと呼ばれるハードウェアが登場し、現実存在する多様な組合せ最適化問題を高速に解く手段として注目を集めている。一般に組合せ最適化問題を解くためには、対象とするドメインの専門知識に基づいた独自の数理モデルを構築し、最適化を行う。しかし、数理モデルの構築は容易ではなく、独自の数理モデルに基づいた最適解は、実環境やシミュレータで評価を行うまで有効性が保証されない。そのため、実環境やシミュレータに基づいた最適化を行う必要がある。本研究では量子アニーリングとシミュレータを用いた実在する物流倉庫の入荷場を対象とした業務とシフトを割り当てる組合せ最適化を行う。具体的には倉庫内シミュレータと Factorization Machine の学習による数理モデル化、そして量子アニーリングによる最適化を相互に繰り返し、最適化を行う。本手法の最適化の結果、実際の倉庫での業務とシフトと比較してリードタイムを最大 37.37%、残留荷物数を最大 95.47%、合計労働時間を最大 14.29%削減した。

## 1. はじめに

サプライチェーンの拡大に伴い、モノの中継地点である物流倉庫のさらなる効率化が求められている。しかし物流倉庫は休みなく運用されるため、現実空間における運用方法・環境の変更と、その定量的な評価は容易ではなく、センシングによる倉庫環境デジタル化と仮想環境の最適化が不可欠である。物理空間のデジタル化はユビキタスコンピューティングの発展により進展しており、デジタル化された大規模な実空間データは可視化、分析、予測などに用いられ、研究が多数行われている。

一方、最適化については、計算量の問題から大規模なデータを扱った研究が十分に行われていなかった。問題サイズが大きくなると計算量が指数関数的に増加するためである。巡回セールスマン問題やポートフォリオ最適化など、一部の有名な問題に対しては、専用のアルゴリズムによって大規模な問題を高速に解く手法が存在する。しかし、現実世界に存在する多様な問題はこれら有名な問題の枠組みに収まらないものが多く、従来は小規模な問題に限定して解かざるを得ない状況が多かった。

この背景の中、近年量子アニーリング [1] という手法が現実存在する多様な組合せ最適化問題を高速に解く手段として注目を集めている。量子アニーリングマシンは組合せ最適化問題に特化したハードウェアであるイジングマシンの一種であり、代表的な例としては 2011 年に商用化された D-Wave[2] が挙げられる。組合せ最適化問題は、物流、交通、経済、医療など多様な分野での実応用が研究されており [3],[4],[5]、現実空間のセンシングデータを活用した最適化もこの問題形式に適用が可能である。

一般に最適化環境を対象とした組合せ最適化問題を解くためには、専門知識に基づいた独自の数理モデルを構築し最適化を行う必要がある。しかし、この手法では導出された最適解を実環境やシミュレータで評価する必要があり、比較的多くのコストが必要となる。また独自の数理モデルの構築は容易ではない。さらに独自の数理モデルに基づいた最適解は、実環境やシミュレータでの評価を行うまで解の有効性が保証されない。

この課題を解決するためのアプローチとして FMQA という手法 [6] が存在する。FMQA は Factorization Machine[7] という学習モデルと量子アニーリングを用いたブラックボックス最適化手法の一手法である。ブラックボックス最適化とは、入力と出力は観測可能であるが、内部の現象

<sup>1</sup> 名古屋大学大学院 工学研究科  
Graduate School of Engineering, Nagoya University

<sup>2</sup> 名古屋大学 未来社会創造機構  
Institutes of Innovation for Future Society Nagoya University

<sup>a)</sup> kairi@ucl.nuee.nagoya-u.ac.jp

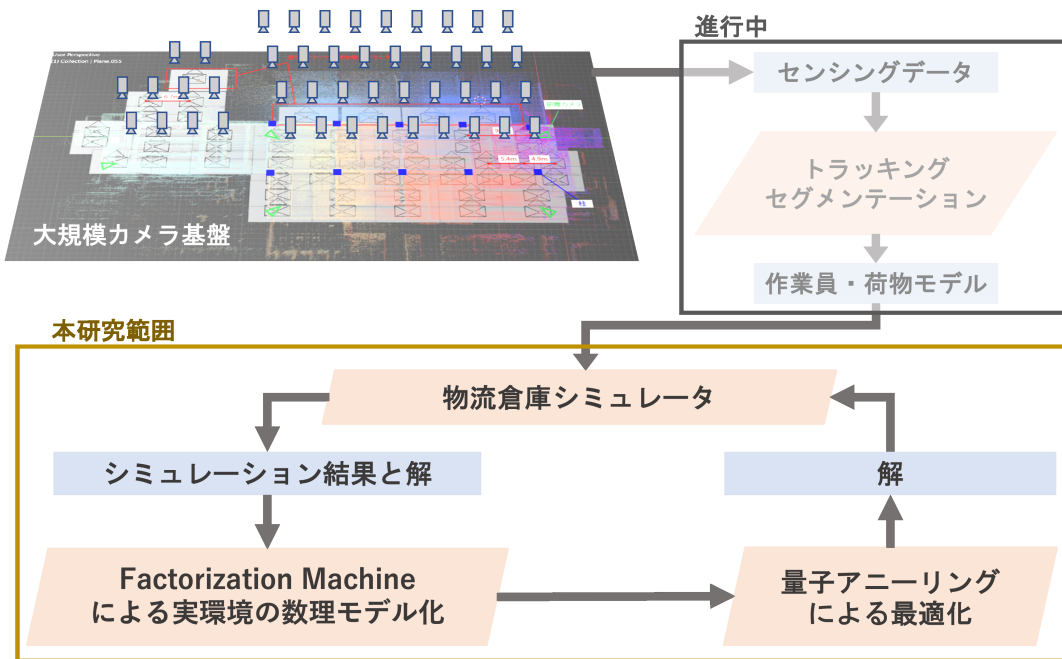


図 1 現実の問題に対する FMQA の応用の流れと本研究の対象

が複雑で明示的なモデル化が困難なシステムに対して、所望の出力を得るための最適な入力を探索する手法である。FMQA は、実環境での検証値やシミュレータの出力値に基づいた Factorization Machine による数理モデルを構築し、量子アニーリングによる最適化を行う。学習により数理モデルを構築するため、実環境に直接基づいた最適化を実現し、少ない評価回数で効率的な最適化が可能となる。

FMQA は材料情報学の応用例は存在するが [6],[8], 実空間への応用例は筆者が調べた限り存在しない。また、実空間は多くのプロセスが相互作用し、直接的な観測や解析による最適化は困難である。そこで、本研究では FMQA を用いた繰り返し最適化を実空間である物流倉庫に応用する。具体的には、以下の流れで行う。

- (1) 倉庫内シミュレータを Factorization Machine で学習し、数理モデルを構築する。
- (2) 構築した数理モデルをもとに量子アニーリングによる最適化を行う。
- (3) 最適解を倉庫内シミュレータで検証する。
- (4) (1)-(3) を繰り返す。

本研究の対象である物流倉庫の最適化問題は以下の 3 つに分割されている [9]。

- (a) 経営計画に基づいた倉庫の技術構造、運営最適化
- (b) 倉庫運営における作業計画の最適化
- (c) 倉庫内情報に基づく作業の管理・実行の最適化

本研究は本稿の (b) に密接に関連する物流倉庫入荷場の各従業員に対するシフト時間と業務の最適化を行う。

本研究における FMQA の実空間応用の流れと本研究対象を図 1 に示す。我々は現在、倉庫に大規模なカメラ基盤を

敷設し、得られる映像のオブジェクトトラッキングやセグメンテーションによるデータ化を行っている。そしてデータに基づき、実環境に対応する倉庫内シミュレータの構築を目指している。本研究は簡易的な倉庫内シミュレータの構築を先行して行い、作成したシミュレータに対し FMQA を応用する。

本研究の貢献は以下のようにまとめられる。

- 現実倉庫内の業務・シフト割り当てと最適化後の業務・シフト割り当てをマルチエージェントシミュレーションによって評価し、リードタイムを最大 37.37%、残留荷物数を最大 95.47%、合計労働時間を最大 14.29%削減した点
- 各従業員のシフト時間と業務の組合せが  $2^{1300}$  通り存在する状況において、500 の初期データセットと 100 回の繰り返し最適化で有効性を示した点
- 実空間である物流倉庫に FMQA を応用し、その流れを示した点

## 2. 関連研究

### 2.1 量子アニーリングの実世界応用

量子アニーリングおよびその関連技術の進展に伴い、物流 [5],[10],[11]、金融 [3],[4]、医療 [12],[13] などの多岐にわたる分野において応用研究が行われている。物流分野における研究としては、配送計画問題 (VRP: Vehicle Routing Problem) に関する取り組みが活発である。VRP は巡回セールスマン問題を実世界へ応用したものであり、複数のトラックが各拠点を一度ずつ訪れる最短移動距離を求める問題と言える。Kitai ら [5] は、量子アニーリングを用いた

複数のトラックのルーティング問題に対する解法を提案している。我々も入荷作業最適化は既存研究では行われていないため、量子アニーリングを実環境へ応用し、最適化を行った [11]。我々は物流倉庫入荷場をグリッドに分割し、各グリッドに異なる業務用途を割り当てる組合せ最適化を行い、各指標値の削減・向上を示した。

多くの研究では、量子アニーリングからの出力値と理論的最適解との比較による評価を行っている。しかし、TSP などの高速な探索アルゴリズムが存在する一部の有名問題を除き、理論的最適解を短時間で得ることは困難である。そこで、我々の研究 [11] やその他一部の研究 [5],[13] では、量子アニーリングからの出力値をシミュレータに入力し、実空間における量子アニーリングの解の有効性を示している。

一方、複雑なシステムに対する独自の数理モデルの構築は困難な場合がある。また、実空間における独自の数理モデルに基づいた最適解は、実空間やシミュレータでの評価を行うまで解が保証されない点がある。

## 2.2 量子アニーリングを用いたブラックボックス最適化

量子アニーリングを用いたブラックボックス最適化に関する研究はメタマテリアルの自動設計 [6]、プリント回路基板の自動設計 [8]、ノイズフィルターの形状設計 [14] などモノの設計を対象に活発に行われている。そのため、実空間への応用例は少なく、研究の余地がある。実空間への応用を行った研究 [15] では、量子アニーリングとスパース性を利用したベイズ線形回帰を用いてブラックボックス最適化を行い、物流倉庫内におけるピッキング順序と注文データを考慮したパーツの保管割り当ての最適化を行っている。本研究はブラックボックス関数の獲得に [6],[8] で使用された Factorization Machine を用いた。Factorization Machine は最適化要素である業務やシフトの相互関係に重きを置いて数理モデル化を行い、多様な業務やプロセスが絡み合う倉庫入荷場のモデル化を可能にする。

## 2.3 倉庫内シフト・業務最適化

倉庫内業務やシフトを効率化する研究は多数存在する [16],[17],[18],[19]。Ganbol ら [16] は、ランダム近傍探索法を用いてシミュレーションベースの最適化を行っている。この手法ではランダム性による解探索が特徴であり、最適解に到達するまでの検証コストが高いという課題がある。Popović ら [17] は、従業員のシフトと業務の割り当てを最適化するために線形計画法を用いており、理論的な最適化がなされているが、実環境またはシミュレーションでの検証をしていない。一方、Zhao ら [18] は、ピッキング作業員の休憩時間を考慮したシフト最適化を行い、遺伝的アルゴリズムを用いてシミュレーションによる評価をしている。シミュレーションを基にした最適化は行われていないため、最適解は実環境やシミュレータでの評価を行うまで有

効性が保証されない。Derkindere ら [19] は反復局所探索法 (ILS) を採用しており、ILS はその汎用性により大規模問題に適用可能であるが、固定かつ独自の数理モデル化による最適化を行う。

本研究ではこれらの課題と制約を踏まえ、FMQA を実世界に適用し最適化を行う。FMQA を用いた繰り返し最適化は、過去の解から得られるデータを基にして数理モデルを逐次構築し、現実存在する多様な組合せ最適化問題を高速に解く量子アニーリングによる最適化が可能である。

## 3. FMQA を用いた組合せ最適化

本章では一般的な FMQA の概要と、それを構成する Factorization Machine と量子アニーリングの概要について詳述する。

### 3.1 FMQA

FMQA は、Factorization Machine (FM) による機械学習と、量子アニーリング (QA) による最適化を組合せたブラックボックス最適化の一手法である。この手法は、観測された入力と出力データを基にブラックボックス関数を構築し、その関数を通じて所望の出力を生み出す最適な入力を探索する。FMQA の一般的な流れは以下の通りである。

- (1) 初期教師データとして、 $N_0$  個の入力値  $\{x_1, x_2, \dots, x_{N_0}\}$  と、 $N_0$  個のシミュレータや実環境で検証した出力値  $\{y_1, y_2, \dots, y_{N_0}\}$  を用意する。
- (2) 初期教師データを用いて Factorization Machine により数理モデルを構築する。
- (3) 構築した数理モデルを量子アニーリングマシンで最適化し、最小値を与える入力  $\hat{x}$  を得る。
- (4) 入力  $\hat{x}$  をシミュレータや実環境で検証し、得られた出力値  $\hat{y}$  を用いて初期教師データに  $(\hat{x}, \hat{y})$  を追加する。
- (5) 上記 (2) - (4) を  $N$  回繰り返す。

本研究では、上記のプロセスに従って最適化を実施する。

### 3.2 Factorization Machine

Factorization Machine は回帰モデルの一種であり、以下の式によって表される。

$$\hat{y}(x) = w_0 + \sum_{i=1}^n w_i x_i + \sum_{i=1}^n \sum_{j=i+1}^n \langle v_i, v_j \rangle x_i x_j \quad (1)$$

本モデルは各特徴量間の二次の相互作用を考慮したモデルである。 $w_0, w_i, v_i$  は学習によって得られるパラメータであり、ベクトル  $v_i$  の次元  $k$  はハイパーパラメータである。 $\langle \cdot, \cdot \rangle$  はベクトルの内積を示す。

Factorization Machine は二次式であり、変数が  $x_i \in \{0, 1\}$  である場合、量子アニーリングで扱う QUBO 式と同じ形式であるため、イジングマシンを用いた最小化が適用可能である。またモデルの推論の計算量はベクトル  $v_i$  の長

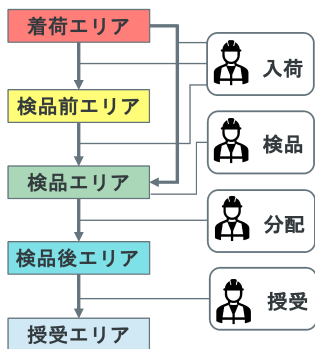


図 2 荷物のエリア遷移と各業務

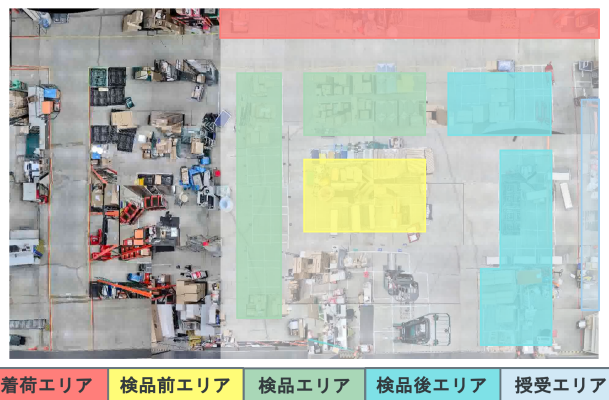


図 3 実際の倉庫レイアウトに基づいた業務エリア

さ  $k$  によって設定できる。

### 3.3 量子アニーリング

量子アニーリングマシンはイジングマシンと呼ばれるハードウェアの一種である。イジングマシンは QUBO (Quadratic Unconstrained Binary Optimization), あるいは Ising Model と呼ばれる形式で表現された組合せ最適化問題を解くことに特化したマシンである。ここでは、量子アニーリングを組合せ最適化問題に活用するにあたっての基本的な概念を説明する。

まず組合せ最適化問題は、与えた離散値の決定変数の中から、制約条件を満たし、目的関数を最小化する変数値の組合せを求める問題である。簡単な問題を例に量子アニーリングにおける数理モデル化を説明する。

$q_1 + q_2 \leq 1$  を満たし、 $f(x) = -q_1 q_2 - q_1$  を最小化する組合せ最適化を解くとする。この時決定変数は  $q_1, q_2 \in \{0, 1\}$  であり、QUBO は次のように表現される。

$$H_{QUBO} = \alpha H_A + \beta H_B \quad (2)$$

$$H_A = -q_1 q_2 - q_1 \quad (3)$$

$$H_B = q_1 + q_2 \leq 1 \quad (4)$$

$H_A$  は目的関数で  $H_B$  は制約条件である。QUBO では式 (2) のように制約条件と目的関数を一つの式で表現するため、制約条件を満たす解を得るには、各項の重み  $\alpha, \beta$  について、 $0 < \alpha < \beta$  としなければならない。

## 4. 提案手法

図 1 の本研究の対象範囲の流れをもとに、FMQA を実世界に応用する。提案手法は物流倉庫シミュレータと Factorization Machine による数理モデル化、そして量子アニーリングによる最適化を相互に接続し、繰り返し最適化を可能にする。そこで本章では倉庫内シミュレータの構築から始まり、数理モデルの構築、そして量子アニーリングを用いた最適化について詳述する。

## 4.1 マルチエージェントシミュレータの設計

### 4.1.1 対象倉庫の概念

本研究の対象となる倉庫の入荷エリアでは、業務を円滑に進行させるため、倉庫内では床面にラインを引いて、各業務エリアを区切るためのエリア分けを行っている。各業務エリアやエリア間を荷物が遷移するにあたり大まかに四種類の業務が存在しており、以下のように定義する。

- (1) 入荷：外部から着荷した荷物を検品前エリアや検品エリアに運ぶ業務
- (2) 検品：検品エリアで荷物を検品する業務
- (3) 分配：検品後エリアに荷物のサイズに応じて分けて運ぶ業務
- (4) 授受：検品後エリアから次のプロセスに荷物を運ぶ業務

荷物が各エリアを図 2 のように遷移する時、入荷、検品、分配、授受の業務が遂行される。本研究の対象となる入荷場のエリアはカメラ映像から得られた実際の庫内レイアウトを示した図 3 のように分けられる。

### 4.1.2 マルチエージェントシミュレータ

倉庫環境に基づいたマルチエージェントシミュレータを開発した。開発には Mesa[20] という Python ベースの Agent-Based Modeling Framework を使用した。このフレームワークは多数のシミュレーション研究で活用されている [21],[22],[23]。またエージェントモデリングから可視化・分析までを過不足なく行える仕組みになっている。シミュレータの入力を表 1 に示し、これを用いてシミュレーションの大まかな流れを説明する。

- (1)  $W$  人の各従業員がシフト時間  $S$  に当てはまる場合、業務  $T$  を担当しランダムに初期配置される。
- (2) シミュレーションステップが進むと、平均  $T_{IN}$  秒の指数分布関数に従った間隔で  $N_{IN}$  個の荷物が着荷エリアに生成される。またシフト時間に応じて作業員は出勤、休憩、退勤をする。
- (3) 作業員は与えられたシフト時間と業務に応じて作業を遂行し、荷物を入荷、検品、分配、授受して授受エリアま

表 1 シミュレーション入力

$x_{S,W,T}$	各作業員のシフト時間と業務
MAP	現実倉庫の床面を示す MAP
STEPS	シミュレーション最大ステップ数 (1step = 1[s])
$T_{INS}$	平均検品時間 [s]
$T_{IN}$	平均入荷待ち時間 [s]
$N_{IN}$	一度に入荷される荷物数
$T_{OUT}$	平均授受待ち時間 [s]
$N_{OUT}$	一度に授受される荷物数

表 2 シミュレーション出力

$LEADTIME_{mean}$	各荷物のリードタイムの平均値 [s]
$LEADTIME_{std}$	各荷物のリードタイムの標準偏差
$COUNT_{mean}$	残留荷物数の平均値
$COUNT_{std}$	残留荷物数の標準偏差
$SHIFT_{total}$	合計労働時間

で運ぶ。各荷物の検品時間は  $T_{INS}$  を平均とした正規分布によって決まる。

(4) 授受エリアに置かれた荷物のうちから、平均  $T_{OUT}$  秒の指数分布関数に従った間隔で  $N_{OUT}$  個の荷物が消失する。(次のプロセスへの荷物の受け渡し)

次に出力値を表 2 に示す。リードタイムは着荷エリアで荷物が到着してから、次のプロセスへ受け渡すまでの時間を意味する。残留荷物数はシミュレーション終了時にフロアに残った荷物の合計数を意味する。合計労働時間は各作業員のシフト時間の合計値である。

また作業員エージェントモデルについておおまかに説明する。各業務の従業員の遷移は“待機”している作業員が荷物のある場所まで“移動”し、荷物を“運搬”もしくは“検品”を行う。業務が完了すると、再び“待機”の状態に戻る。

## 4.2 倉庫内シフト・業務数理モデル化

倉庫内の各従業員  $W$  人に対して、シフトパターン  $S$  種類と業務  $T$  種類から一種類を割り当てる最適化問題として組合せ最適化問題の数理モデル化を行う。一般に、ブラックボックス最適化はブラックボックス関数のみの最適化を行う。本研究では、倉庫内の最適化の他に従業員の労働時間の削減も目的とした多目的最適化を行う。多目的最適化とは、2つ以上の目的関数を用いた最適化を示す。決定変数  $q_{i,j,k}$  は、シフトパターン  $i$  で従業員  $j$  が業務  $k$  を担当する場合に 1、それ以外で 0 をとる。次に、表 3 を踏まえ目的関数を定める。

$$H_s = w_0 + \sum_{i=1}^{|S||W||T|} w_i x_i + \sum_{i=1}^{|S||W||T|} \sum_{j=i+1}^{|S||W||T|} \langle v_i, v_j \rangle x_i x_j \quad (5)$$

表 3 文字定義

$q_{i,j,k}$	決定変数
$S$	事前に設定したシフト時間の集合
$W$	従業員の集合
$T$	業務の集合
$x_i$	決定変数を 1 次元に変更した特徴量ベクトル
$h_i$	シフト $i$ の合計労働時間
$w_0$	バイアス項
$w_i$	特徴 $x_i$ の線形重み
$\langle v_i, v_j \rangle$	特徴間の相互作用を捉えるための潜在ベクトル
$\alpha$	目的関数 $H_s$ の重み
$\beta$	目的関数 $H_t$ の重み
$\gamma$	制約条件 $H_c$ の重み
$N_0$	初期データ数
$N$	FMQA サイクル回数

$$H_t = \sum_i^S \sum_j^W \sum_k^T q_{i,j,k} \cdot h_i \quad (6)$$

$$H_c = \sum_{i \in S} \sum_{k \in T} q_{i,j,k} = 1 \quad (\forall j \in W) \quad (7)$$

$$H = \alpha H_s + \beta H_t + \gamma H_c \quad (8)$$

$H_s$  はシミュレータの評価値を最適化する目的関数である。各作業員のシフトと業務の組合せを入力とし、シミュレーション評価値を教師データとし FM を用いて学習を行う。学習の後  $w_0, w_i, \langle v_i, v_j \rangle$  の値から目的関数を構築する。FM で学習する場合、決定変数  $q_{i,j,k}$  の三次元ベクトルを一次元ベクトル  $x_i$  に変換している。しかし、どちらの変数も要素数は変わらないため、得られる目的関数に影響はない。 $H_t$  は従業員の労働時間を下げる目的関数である。 $h_i$  はシフト時間の index が  $i$  の時の合計労働時間を示している。そのため目的関数  $H_t$  は実際に働く全従業員の合計労働時間を示しており、この目的関数の値を最小化し、労働時間の削減が可能である。 $H_c$  は各従業員が 1 つのシフト時間に、1 つの業務を担当するための制約を示している。この制約条件を、そのままの形で実装すると、ミドルウェアが自動的に目的関数と罰則項をまとめた QUBO を構築する。

## 4.3 量子アニーリングによる最適化

作成した数理モデルを量子アニーリングにより最適化する。数理モデルを解くイジングマシンは多数あるが、本研究では様々なイジングマシンを一貫したプログラミング表現で操作するためのミドルウェアである Fixstars Amplify を利用する [24]。このミドルウェアは多数のイジングマシンをサポートしており、メジャーな量子アニーリングマシンである D-wave や、GPU 等の伝統的なハードウェア上に実装されたイジングマシン等を簡単に切り替えて利用できる。

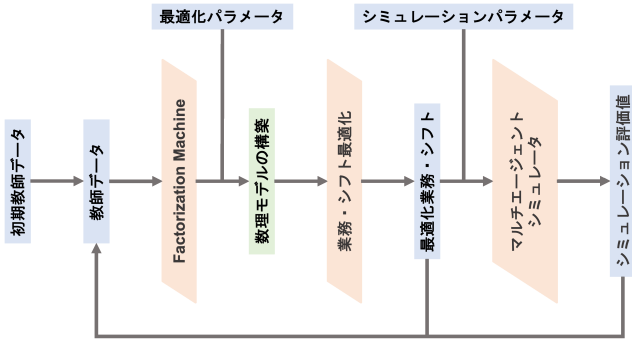


図 4 FMQA を用いた倉庫内最適化の流れ

STEPS	$T_{INS}$	$T_{IN}$	$T_{OUT}$	$N_{OUT}$
43200	180	300	120	5

量子アニーリングマシンは現在のところ扱える決定変数が 2000 程度しかない。対して、GPU などのハードウェア上に実装されるイジングマシンは数十万規模の変数で問題を解くことが可能である。本研究では近い将来の実用を見越して、最大で 262,144 個の決定変数を扱える GPU イジングマシンの Amplify Annealing Engine を利用する。

## 5. 評価実験

本章では提案手法を用いた業務とシフトの繰り返し最適化を行う。ベースラインと比較し、荷物のリードタイムや残留数、労働コストを削減できることを示す。

### 5.1 実験内容

実験は 3.1 節のプロセスを参考に図 4 の流れで行う。初めに作業員のシフトと業務の組合せ： $\{x_1, x_2, \dots, x_{N_0}\}$  とシミュレーション評価値： $\{y_1, y_2, \dots, y_{N_0}\}$  を用意する。本実験では初期データ  $N_0$  を 500 とし、ランダムに作成する。シミュレーション評価値は表 1,2 から以下の設定をする。リードタイムと残留荷物数を評価値に組み込むことで、2 つの評価値に対して最適化が可能となる。

$$y = LEADTIME + PENALTY \quad (9)$$

$$RATE = \frac{COUNT}{\sum_{t \in \mathcal{T}} (N_{IN})} \quad (10)$$

$$PENALTY = \left( \left\lfloor \frac{RATE - sc_{rate}}{st_{rate}} \right\rfloor + 1 \right) \times const \quad (11)$$

式 (10) は残留荷物数の比率  $RATE$  を示す。式 (11) の  $sc_{rate}$  は成功率の閾値、 $st_{rate}$  はペナルティ比率、 $const$  はペナルティ定数を示す。式 (11) は  $RATE$  が  $sc_{rate}$  を超える場合にのみ適応し、 $st_{rate}$  ごとに  $const$  が追加されることを意味する。本実験では  $sc_{rate}, st_{rate}, const$  はそれぞれ 0.02, 0.1, 1000 と設定した。

シミュレーションは各入力のシフト・業務の組合せに対

STEPS	$N_{in}$
0-7200	2
7200-14400	10
14400-21600	8
21600-28800	5
28800-39600	2

Index	Shift	$h_i$ [h]
0	6:00-10:00, 11:00-15:00	8
1	7:00-11:00, 12:00-16:00	8
2	8:00-12:00, 13:00-17:00	8
3	9:00-13:00, 14:00-18:00	8
4	6:00-10:00	4
5	7:00-11:00	4
6	8:00-12:00	4
7	9:00-13:00	4
8	10:00-14:00	4
9	11:00-15:00	4
10	12:00-16:00	4
11	13:00-17:00	4
12	14:00-18:00	4

し、10 回行い平均値や標準偏差を算出する。次にシミュレーションの入力値の説明をする。表 4 にシミュレーションの入力値を示す。STEPS は 1STEP1 秒とし、1 日の倉庫の稼働時間 6:00-18:00 の 12 時間 (43200 秒) シミュレーションを行うため、STEPS を 43200 に設定した。また  $T_{INS}, T_{IN}, T_{OUT}, N_{OUT}$  は倉庫内での映像を基に、値を想定し設定した。シフト時間は現実の倉庫のシフト時間を参考に長シフトと短シフトを作成した (表 6)。荷物の入荷数を表 5 に示す。現実倉庫の荷物の入荷数は一定ではなく、時刻によって変化する。本実験では現実倉庫の入荷数を想定し、午前中の時間である STEPS が 0-21600 に荷物が多く入荷するように設定をした。

次に Factorization Machine の学習による数理モデルの構築を行い、学習で獲得したブラックボックス関数を基に、アニーリングによる最適化を行う。実際の倉庫内の各従業員  $|W|25$  人に対して、シフトパターン  $|S|13$  種類と業務  $|T|4$  種類から一種類を割り当てる組合せ最適化を行う。最適化対象は  $25 \times 13 \times 4 = 1300$  であるため、 $2^{1300}$  通り存在する。アニーリングによる最適化では計算のタイムアウト時間を事前に与える必要がある。イジングマシンはタイムアウトまで探索を続け、タイムアウト時に探索期間中に得た最良の解を出力する。今回のタイムアウト時間は、使用したイジングマシンの最長タイムアウト時間である 600 秒とした。

最適化されたシフト・業務割り当てをシミュレータに入力し、検証を行う。出力されたシミュレーション評価値と最適化シフト・業務割り当てを、初期教師データに追加する。以後はこのサイクルを繰り返す。実験ではサイクル数  $N$  を 100 とし、繰り返し最適化を行う。

表 7 各評価指標結果と最適化パラメータ

SHIFT	$LEADTIME_{mean}$	$LEADTIME_{std}$	$COUNT_{mean}$	$COUNT_{std}$	$SHIFT_{total}$	$\alpha$	$\beta$	$\gamma$
BASE SHIFT	1430.412	1518.39	55.2	40.483	184			
FMQA <sub>1</sub> SHIFT <sub>78</sub>	997.931	700.428	35.6	11.983	156	1	10	1000
FMQA <sub>2</sub> SHIFT <sub>90</sub>	942.817	751.710	24.3	6.840	164	1	5	1000
FMQA <sub>3</sub> SHIFT <sub>94</sub>	<b>895.840</b>	705.925	<b>2.5</b>	0.5	184	1	1	1000




図 5 各指標値に対するシフト業務割り当て

## 5.2 実験結果

実倉庫のシフト・業務割り当てをベースラインに、得られたシフト・業務割り当てを比較し、各シミュレーション出力値で評価を行う。ベースラインである BASE SHIFT と得られた最適化シフト・業務割り当てに対するシミュレーション出力値を表 7 に示す。各最適化シフト・業務割り当ての番号は 100 サイクル中の 78 サイクル目, 90 サイクル目, 94 サイクル目に得られたことを意味する。

FM の学習で得られた目的関数である式 (5) により、各最適シフト・業務割り当てはベースラインに比べ、リードタイムの平均値と荷物残留数の平均値の削減を可能にした。FMQA<sub>3</sub> の SHIFT<sub>94</sub> において、リードタイムを 37.37%、残留荷物数を 95.47%、大幅に削減した。

また式 (6) における重み  $\beta$  が大きいほど、勤務時間を減少させる目的が働き、合計労働時間の削減を可能にした。FMQA<sub>1</sub> の SHIFT<sub>78</sub> において、ベースラインと比較して、リードタイムを 30.23%、荷物残留数を 35.50%、合計労働時間を 14.29%削減した。

残留荷物数の標準偏差は FMQA<sub>3</sub> の SHIFT<sub>94</sub> が最も低い。これはシミュレータの出力に散乱がなく、業務を遂行す

るのに安定し、最適化されたシフト・業務であると言える。

## 5.3 最適化結果分析

図 5 に実倉庫のシフト・業務割り当てと最適化されたシフト・業務割り当てを示す。横軸はシフト時間を、縦軸はシフト時間に対する業務ごとの人数の合計を示している。実倉庫のシフト・業務割り当てに比べて、最適シフト・業務割り当てでは、6:00-10:00 のシフト時間に業務人数が多い。表 5 より荷物の多い早朝の時間帯に、従業員を割り当てることで、早朝の荷物の滞留を減らし、各評価指標の向上に繋がったと考えられる。また荷物の少ない夕方時間帯の割り当てを減らすことで、合計労働時間の削減につながったと考えられる。

## 6. まとめ

本研究では、実倉庫の入荷場をモデルケースに量子アニーリングと Factorization Machine を用いたブラックボックス最適化を行った。倉庫内シフト・業務割り当て最適化では、倉庫内の各従業員  $W$  人に対して、シフトパターン  $S$  種類と業務  $T$  種類から一種類を割り当てる最適化問題を扱っ

た.  $2^{1300}$  通りの組合せ最適化問題を 500 の初期データと 100 回 FMQA による繰り返し最適化を行い, リードタイムを最大 37.37%, 残留荷物数を最大 95.47%, 合計労働時間を最大 14.29%削減した. 今後の課題としては, 大規模カメラ基盤からのデータ化を完了し, そのデータに基づいたシミュレータの開発と, 実環境での検証が必要である. また本研究では制約条件である式 (7) の重み  $\gamma$  を固定して最適化を行った. 本来最適解を得るために,  $\gamma$  は小さいほど, 制約条件が緩みより最適な解が得られる. よって制約条件の重みの最適化が必要である.

## 謝辞

この成果は, 国立研究開発法人新エネルギー・産業技術総合開発機構 (NEDO) の委託業務 (JPNP23003) の結果得られたものです. 本研究の一部は科研費 挑戦的研究 (開拓) 22K18422, トラスコ中山株式会社 に支援いただいています.

## 参考文献

- [1] Tadashi Kadowaki and Hidetoshi Nishimori. Quantum annealing in the transverse ising model. *Phys. Rev. E*, Vol. 58, pp. 5355–5363, Nov 1998.
- [2] D-Wave Systems. The D-Wave Advantage System: An Overview. Technical report, D-Wave Technical Report Series, 2020.
- [3] Michael Marzec. Portfolio optimization: Applications in quantum computing. *Handbook of High-Frequency Trading and Modeling in Finance*, pp. 73–106, 2016.
- [4] Kotaro Tanahashi, Shinichi Takayanagi, Tomomitsu Motohashi, and Shu Tanaka. Application of ising machines and a software development for ising machines. *Journal of the Physical Society of Japan*, Vol. 88, No. 6, p. 061010, 2019.
- [5] Sean J Weinberg, Fabio Sanches, Takanori Ide, Kazumitsu Kamiya, and Randall Correll. Supply chain logistics with quantum and classical annealing algorithms. *Scientific Reports*, Vol. 13, No. 1, p. 4770, 2023.
- [6] Koki Kitai, Jiang Guo, Shenghong Ju, Shu Tanaka, Koji Tsuda, Junichiro Shiomi, and Ryo Tamura. Designing metamaterials with quantum annealing and factorization machines. *Physical Review Research*, Vol. 2, No. 1, p. 013319, 2020.
- [7] Steffen Rendle. Factorization machines. In *2010 IEEE International conference on data mining*, pp. 995–1000. IEEE, 2010.
- [8] T. Matsumori, M. Taki, and T. Kadowaki. Application of qubo solver using black-box optimization to structural design for resonance avoidance. *Scientific Reports*, Vol. 12, p. 12143, 2022.
- [9] Jan Karásek. An overview of warehouse optimization. *International journal of advances in telecommunications, electrotechnics, signals and systems*, Vol. 2, No. 3, pp. 111–117, 2013.
- [10] 齋藤和広, 大山重樹, 梅木智光, 黒川茂莉, 小野智弘ほか. 配送計画問題における量子アニーリングの評価. 情報処理学会論文誌データベース (TOD), Vol. 14, No. 1, pp. 8–17, 2021.
- [11] 瀧上昂希, 福島悠人, 浅井悠佑, 片山晋, 浦野健太, 米澤拓郎, 河口信夫ほか. 倉庫内業務の量子アニーリングによる最適化とシミュレーションによる評価. 研究報告モバイルコンピューティングと新社会システム (MBL), Vol. 2024, No. 28, pp. 1–8, 2024.
- [12] Kazuki Ikeda, Yuma Nakamura, and Travis S Humble. Application of quantum annealing to nurse scheduling problem. *Scientific reports*, Vol. 9, No. 1, p. 12837, 2019.
- [13] 川口英明ほか. 量子アニーリングを用いた医師配置最適化シミュレーション. 研究報告量子ソフトウェア (QS), Vol. 2020, No. 23, pp. 1–7, 2020.
- [14] Akihisa Okada, Hiroaki Yoshida, Kiyosumi Kidono, Tadayoshi Matsumori, Takanori Takeno, and Tadashi Kadowaki. Design optimization of noise filter using quantum annealer. *IEEE Access*, Vol. 11, pp. 44343–44349, 2023.
- [15] 木暮宏光, 馬場健, 谷口真ほか. アニーリングアルゴリズムを用いたブラックボックス最適化による物流センターの保管割り当て問題の解法. 研究報告量子ソフトウェア (QS), Vol. 2024, No. 34, pp. 1–6, 2024.
- [16] Odkhishig Ganbold, Kaustav Kundu, Haobin Li, and Wei Zhang. A simulation-based optimization method for warehouse worker assignment. *Algorithms*, Vol. 13, p. 326, 12 2020.
- [17] Vlado Popović, Milorad Kilibarda, Milan Andrejić, Borut Jereb, and Dejan Dragan. A new sustainable warehouse management approach for workforce and activities scheduling. *Sustainability*, Vol. 13, No. 4, 2021.
- [18] Xiaosong Zhao, Na Liu, Shumeng Zhao, Jinhui Wu, Kun Zhang, and Rui Zhang. Research on the work-rest scheduling in the manual order picking systems to consider human factors. *Journal of Systems Science and Systems Engineering*, Vol. 28, No. 3, pp. 344–355, Jun 2019.
- [19] Vincent Derkinderen, Jessa Bekker, and Pieter Smet. Optimizing workforce allocation under uncertain activity duration. *Computers Industrial Engineering*, Vol. 179, p. 109228, 2023.
- [20] David Masad and Jacqueline Kazil. Mesa: An agent-based modeling framework. pp. 51–58, 01 2015.
- [21] Sarah Namany, Rajesh Govindan, Luluwah Alfagih, Gordon McKay, and Tareq Al-Ansari. Sustainable food security decision-making: An agent-based modelling approach. *Journal of Cleaner Production*, Vol. 255, p. 120296, 2020.
- [22] Jingran Sun and Zhanmin Zhang. A post-disaster resource allocation framework for improving resilience of interdependent infrastructure networks. *Transportation Research Part D: Transport and Environment*, Vol. 85, p. 102455, 2020.
- [23] Vasilios Anatalitis and Marijke Welisch. Putting renewable energy auctions into action—an agent-based model of onshore wind power auctions in germany. *Energy Policy*, Vol. 110, pp. 394–402, 2017.
- [24] The quantum computing cloud - fixstars amplify. <https://amplify.fixstars.com/en/>. Accessed on 04/10/2024.