

イジングマシンを用いたコンビニシミュレーションの商品配置最適化

齊藤玲奈 (指導教員：工藤和恵)

1 はじめに

近年、急速な社会変化やライフスタイルの多様化に伴い、コンビニエンスストアはますます重要な役割を果たしている。生活必需品を手軽に購入できる場所として、多くの消費者に親しまれ、その利用頻度、店舗数や売上高は右肩上がりです。このため、限られた店舗スペースの中でいかに商品を配置し売上を最大化するかが小売業界の重要課題となっている。しかしながら、商品数や配置パターンの組み合わせは膨大で最適解を導出することは容易ではない。

そこで本研究では、イジングマシンを用いたブラックボックス最適化手法をコンビニの商品配置最適化問題に適用した。商品配置最適化研究は多数行われているが、イジングマシンを用いた研究はまだ少なく、高い実用性が期待できるのではないかと考える。

2 問題設定

本研究ではコンビニシミュレーションの商品配置最適化問題を解く。しかしこの問題はイジングモデルのエネルギー関数による定式化が困難である。そこで本研究ではシミュレーションをブラックボックス関数としてとらえ、ブラックボックス最適化問題に置き換えて考える。このブラックボックス関数は、商品の配置を入力として受け取り、平均移動回数を出力する。

2.1 店内の設定

本研究で使用するシミュレーション [2] では、図1のように格子状に区画分けした店内を考える。店内は 10×10 のマスに区画分けした。灰色のマスは壁、ピンクのマスはレジ、緑のマスは出入口を表している。白と水色のマスは通路であるが、水色のマスは通路の中で商品を配置できる部分である。灰色・ピンクのマスは通行不可、白・水色・緑のマスは通行可能である。出入口は1つ、レジは1つ、商品は日配食品・加工食品・ファストフード・非食品の4つを配置する。出入口とレジの位置は固定である。4つの商品は水色の部分から場所を選択して配置することができる。

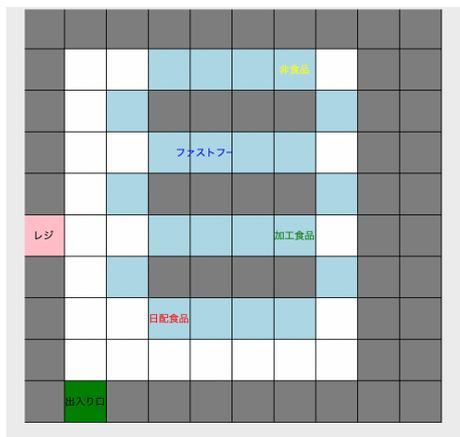


図 1: 店内の配置

2.2 シミュレーションの設定

一回のシミュレーションで客は10人とする。客は商品を1つ購入する。それぞれの客の購入品は4つの商品の中でランダムに決まる。すべての客は出入口から入る。入店したら客は上下左右ランダムに動く。目的の商品の配置されたマスの上を通過すると商品を獲得したことになる。商品を獲得したらレジに向かい、出入口に到着して買い物は終了である。シミュレーション自体はすべての客が店内から退出した時点で終了する。

3 定式化

ブラックボックス最適化とは目的関数が不明の問題に対して最適化する方法である。ブラックボックス関数は中身がわからないので、直接最適化することはできない。代わりに、獲得関数でブラックボックス関数を近似して、獲得関数を最適化する。大まかな流れとしては、

1. ブラックボックス関数 $B(x)$ のデータに合う獲得関数 $g(x)$ を作る
2. 獲得関数 $g(x)$ を最適化して x を得る
3. 得た x でブラックボックス関数から、新たなデータ $y = B(x)$ を得る

この手順を繰り返してブラックボックス関数の最適解を見つける。ここで手順2で最適化する獲得関数をどのように設定するのが重要である。

本研究ではイジングマシンと機械学習を融合して行うブラックボックス最適化手法の FMQA を実行した。FMQA とは Factorization Machines (FM) と呼ばれる機械学習と、量子アニーリング・イジングマシン (QA) による最適化を組み合わせたブラックボックス最適化の一種である [3]。FMQA の実行手順は2段階に分かれている。はじめに、初期教師データとして、 n 個の入力サンプル $\{x_1, x_2, \dots, x_n\}$ と、対応する n 個の出力 $\{f(x_1), f(x_2), \dots, f(x_n)\}$ を得る。次に FMQA による最適化サイクル (以下の手順) を繰り返す。

1. 教師データに基づき FM を機械学習し FM パラメータを取得する。
2. 獲得関数 $g(x)$ を最小とする入力 \hat{x} をイジングマシンを用いて推定する。
3. 目的関数 $f(x)$ を \hat{x} で評価することで、 $\hat{y} = f(\hat{x})$ を求める。
4. 教師データに (\hat{x}, \hat{y}) を追加する。

このサイクルを繰り返すことで FM の予測精度が向上し、イジングマシンによるより良い解の推定が期待できる。本研究ではイジングマシンとして Fixstars Amplify を使用した [4]。

初期教師データを作成するために、ランダムな商品配置を作成して目的関数であるコンビニシミュレーション

ンに入力して実行することを 20 回繰り返した。獲得関数 $g(\mathbf{x})$ は、次式のような機械学習モデルの一種である Factorization Machine (FM) を用いた [3]。

$$g(\mathbf{x}) = w_0 + \langle \mathbf{w}, \mathbf{x} \rangle + \sum_{i=1}^D \sum_{j=i+1}^D \langle \mathbf{v}_i, \mathbf{v}_j \rangle x_i x_j$$

$$= w_0 + \sum_{i=1}^D w_i x_i + \sum_{i=1}^D \sum_{j=i+1}^D \sum_{f=1}^k v_{i,f} v_{j,f} x_i x_j$$

(1)

ここで、式中の \mathbf{x} はバイナリ変数の組である。位置 i は商品が置かれていれば $x_i = 1$ 置かれていなければ $x_i = 0$ である。 \mathbf{w} 、 \mathbf{v} は上式のモデルを機械学習した後には得られる FM パラメータである。FM パラメータの学習と推論は PyTorch で行った。 D はバイナリ変数の全体のサイズである。 k はパラメータ数を決めるハイパーパラメータである。FM の獲得関数は \mathbf{x} の 2 次式であるため、QUBO の形式に書き直すことができ、イジングマシンで最小化ができる。次式が QUBO 形式で表されたハミルトニアン形式である。

$$H(\mathbf{x}) = \sum_{i=1}^D \sum_{j=i}^D Q_{i,j} x_i x_j + \sum_{i=1}^N \left(\sum_{j=M(i-1)+1}^{M_i} x_j - 1 \right)^2$$

$$Q_{i,j} = \begin{cases} w_i & (i = j) \\ \sum_{f=1}^k v_{i,f} v_{j,f} & (i \neq j) \end{cases}$$

(2)

ここで、 N は商品数、 M は配置の候補数、 $D = NM$ である。それぞれの商品が店内に一つずつ配置されるようにするための one-hot 制約をつけた。目的関数 $B(\mathbf{x})$ として、入力された商品配置 \mathbf{x} に対してシミュレーションを 300 回行いシミュレーション結果のばらつきを少なくして客の平均移動回数を出力する。

4 結果

図 2 は全体の評価回数を 100 回、初期教師データの作成を 20 回、FMQA サイクルを 80 回に設定した時の全体の結果である。初期教師データ作成時にランダムに生成した入力値に対して得られた目的関数値を青色、FMQA 最適化過程における目的関数値を赤色で示している。最小化された平均移動回数は 75.45 であり、ブラックボックス最適化過程において客の平均移動回数の最小値が徐々に更新される様子がわかる。

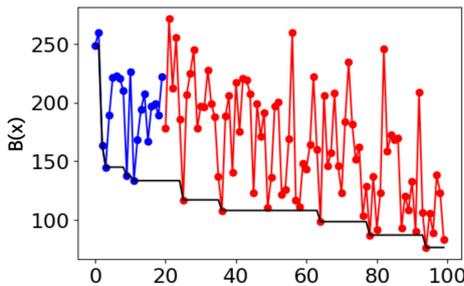


図 2: FMQA 最適化過程における目的関数値の推移

またこの最小値が観測された店内配置は図 3 のよう

であった。この最適化された商品配置では、すべての商品がレジと出入り口の付近に配置されている。このことから入店して商品を獲得してレジに行き退店するという流れの移動回数が少なくなるように商品が配置されていることがわかる。

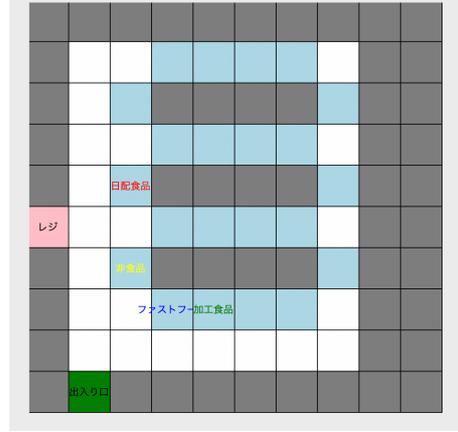


図 3: 最適化された商品配置

5 まとめ

本研究ではイジングマシンを用いたブラックボックス最適化のアルゴリズムを実装し、コンビニシミュレーションの客の平均移動回数の最小化をすることで、店内配置の最適化を行った。研究の結果、商品は出入り口の付近に配置され客の平均移動回数が少なくなるような配置を導くことができた。

現状ではそれぞれの商品が店内に一つずつ配置されるようにするために one-hot 制約をつけたが、このままでは複数の商品が同じ場所に配置されてしまう場合がある。そのため、イジングマシンで解を出すときに商品の配置が被らないようにするために二重の one-hot 制約をつけることが今後の課題である。

参考文献

- [1] 一般社団法人日本フランチャイズチェーン協会 コンビニエンスストア統計時系列データ (2017 年～2023 年) <https://www.jfa-fc.or.jp/particle/320.html> (2024 年 1 月 24 日アクセス).
- [2] エージェントシミュレーションやってみた 1 (コンビニ) https://qiita.com/chutake_exe/items/7906fa90f8272f326895 (2024 年 1 月 24 日アクセス).
- [3] 田中 宗, 山下 将司, 関 優也, アニーリングマシンによるブラックボックス最適化, 日本神経回路学会誌, 2022, 29 巻, 4 号, p. 164-173
- [4] Fixstars, 量子アニーリングと共に進化するクラウド Fixstars Amplify, <https://amplify.fixstars.com/> (2024 年 1 月 24 日アクセス).