データの価値の毀損を考慮した最適なデータ販売方法に関する研究

米岡 主税 † 野澤 拓磨 ‡ 小山田 昌史 ‡ 岡留 剛 †
Chikara Yoneoka Takuma Nozawa Masafumi Oyamada Takeshi Okadome

1. はじめに

近年，データに対する需要が大幅に増加しており，データの売買のためにデータマーケットの確立が求められている．データマーケットには，データを購入してビジネス等に利用することで利益を得ようとするデータ購入者と，保有するデータを販売して代金を受け取ることで利益を得ようとするデータ販売者が存在している．データ購入者は購入したデータを利用して予測モデルを作成し，その予測結果を基に行動を行うことで収益を得ることが最終目標である．そのため，データ購入者は通常データの品質が高いほどデータを利用することで得られる利益が大きくなると考える．しかし，実際に得られる利益は購入するデータの品質だけでなく，他のデータ購入者の行動にも依存する．そのため，データ販売者はデータ購入者の相互作用を考慮したデータ販売を行う必要がある．

本稿では複数のデータ購入者が存在する場合に，データ販売者が保有するデータセットから適切なデータを選択して構成したサブセットを販売することで，データ購入者の行動を制御してデータを販売することで得られる収益の最大化を実現する枠組みを提案する．

2. 関連研究

[1] や [2] で議論されているようにデータマーケットの設計において様々な形式のものが提案されている．その中で，データの価格設定問題は非常に関心の高い話題の１つである．データの価格設定方法は様々なものが考えられるが，データ購入者がデータを利用することで得られる価値を基準とするものが多く存在している．特にこのような議論では，[3] や [4] のように直接データ購入者がデータを使用することで得られる収益などを基準とするのではなく，データの予測モデルの性能に対する貢献度を基準とし，この貢献度を数値化するデータ評価指標を利用する研究が主流である．例えば，Shapley 値を基にしたデータ評価指標である Data Shapley[5] や，その後続研究として Beta Shapley[6] や Distributional Shapley[7] などが存在している．その他にも，強化学習を使用した Data valuation using reinforcement learning(DVRL)[8] などの様々なデータ評価指標が提案されている．

予測モデルの性能はデータ購入者の収益と密接な関係があるが，データを利用することで実際に収益を得るにはほとんどの場合でデータ購入者の行動の内容や周囲の環境が重要になる．特にデータ販売はデータ購入者が全員類似した情報を手に入れることとなるため，データ購入者同士の行動を類似させて新たな競争相手を生んでしまう可能性が非常に高い．そのため，各データ購入者のモデル性能を最大化するデータを販売するだけでは，データ購入者同士の競争を激化させてデータ購入者の収益を阻害してしまう可能性がある．一方で，予測モデルを基にデータ購入者が収益を得ようと行動したとき，実際にどれだけの収益が得られるのかということは先行研究では検討されていない．

† 関西学院大学, Kwansei Gakuin University
‡ 日本電気株式会社, NEC Corporation

このようなデータ利用の相互作用によるデータの価値の毀損を扱ったのは私たちの知る限り本研究が初めてである．本研究ではこのようなデータ価値の毀損について議論を進めるとともに，データの価値の毀損を防止するデータ販売に対してもデータ評価指標が有効に利用できることを示す．

3. 最適なデータマーケット

3.1 データ販売者の目標

データ販売者は保有する各データに価格付けを行い，各データ購入者が支払う代金の総和を最大化するように行動する．このとき，データを利用することで得られる収益よりもデータの価格が高い場合を考えると，データ購入者はデータを買わないという選択をとることとなる．そのため，データ販売者は各データに対してデータ購入者がデータを利用することで得られる収益を超えるような価格設定を行うことは難しい．このような条件での価格設定方法を考えると，例えばデータ販売者がデータ購入者の収益の期待値に一定の割引率を設定して定価をつけるといった状況が考えられ，この場合は「データ販売者が得られる総収益」と「データ購入者の収益の総和」は比例関係を満たす．このような状況を想定しつつより幅広い枠組みとして，本研究ではデータ販売者が得られる総収益はデータ購入者の収益の総和に対して単調増加な関数になっていると仮定する．例えば，比例のような線形関数のみならず，対数関数や指数関数などの非線形な関数も含むこととなる．このとき，データ販売者は自らの収益の最大化を達成しようとすると，データ購入者の収益の総和を最大化することを目指すことになる．

3.2 データ購入者の行動

データ購入者の目的は購入したデータを利用して収益を得ることである．そのため，データ購入者はデータを利用して得られた知見をもとに収益を得るための行動をとる．このとき，データマーケットにデータ購入者が一人しか存在しないのであれば，自らの行動選択によってのみ得られる収益が変化することとなる．一方で，複数のデータ購入者が存在する場合には，それぞれの行動が互いの行動の利益に影響を及ぼす可能性がある．

例えば，データ購入者が新規顧客開拓のためにターゲティングを行おうとしている状況を考える．つまり，データ購入者は細分化した市場から自分に有利な市場を選択してビジネスを開始する．このとき，他に競争相手がいないような市場を選択すれば，データ購入者はその市場のシェアを独占することができる．一方で，他に多くの競争相手が存在する市場を選択する場合はシェアを奪い合うこととなり，市場規模が大きい場合でも得られる収益は低下してしまう．このように，データ売買が独立に行われたとしてもデータ購入者間には相互作用が存在し，同じ行動を選択してしまうと互いの収益を毀損する結果となってしまう．

このような行動の相互作用によるデータの価値毀損をモデル化するために以下のような収益のモデルを仮定する．

$$r = \frac{v}{n}$$

この式では，行動において得られる総報酬 v を同じ行動をとるデータ購入者の数 n 人で等しく分けたものが一人当たりの収益 r であることを示している．つまり，行動をとるのが一人であれば得られる収益は最大の v であるが，同じ行動をとる人数に反比例して得られる収益が減衰していく．

3.3 最適なデータ販売方法

データ販売者がデータ購入者の収益の総和の最大化を目指すうえで，データ購入者の行動の相互作用によるデータの価値毀損は非常に大きな問題である．しかし，データ購入者同士は互いにどのようなデータを購入してどのような行動をとるのかを知ることはできない．そのた

め，データ購入者は購入したデータと行動の嗜好性に基づいて最適な行動を決定することになる．したがって，同一の行動をとるデータ購入者が複数存在する場合は 3.2 で述べたように互いの収益を毀損する結果となる．

上記のようなデータの価値毀損を回避するため，本研究では各データ購入者が異なる行動をとるようにデータ販売者が渡すデータを調整するアイデアを導入する．このようにすることで，同一の行動をとるデータ購入者の数を最小化し，データ購入者の収益の総和の最大化を目指すことができる．データ購入者の行動への介入のためにはデータ購入者の嗜好性を推定する必要があるが，簡単のためにデータ販売者が各データ購入者の行動の嗜好性をすべて把握している状況を考える．

4. 問題設定と提案手法

4.1 問題設定

データマーケットには N 人のデータ購入者が存在しており，M 種類の行動の中から一つの行動を選択するものとする．このとき，行動の集合を $A = \{1, \ldots, M\}$ とし，データ購入者の集合を $B = \{1, \ldots, N\}$ とする．また，データ販売者は自身が持つデータ $\mathcal{D}$ のサブセットを各データ購入者に販売するものとする．このとき，データ購入者 i が購入するデータを $\mathcal{D}_i \subseteq \mathcal{D}$ とし，行動 j を選択することによる総報酬を v_j とする．そして，データ購入者 i が行動 j を選択した場合の収益 r_i は同じ行動をとるデータ購入者の数 n_j に依存して $r_i = \frac{v_j}{n_j}$ となる．また，データ購入者 i は行動 j の選択を評価する関数 f_{ij} を持っており，データ $\mathcal{D}_i$ が与えられた場合に関数値が最も高い行動をとることとする．関数 f_{ij} は購入データ $\mathcal{D}_i$ にのみ依存する関数であり，例えば $\mathcal{D}_i$ を用いて予測モデルを作成した場合のテストデータに対する分類精度や予測精度に依存した関数として定義することができる．これらの情報をデータ販売者が事前に知ることができるとした上で，データ購入者の収益の総和 $R = \sum_{i \in B} r_i$ の最大化を実現するために二つの手続きを経る．

4.2 データによる行動の制御

4.2.1 販売データによる行動の制御方法

データ販売者は，渡すデータを制御することでデータ購入者の行動を制御しようとする．そのため，「任意の i, j に対して，データ購入者 i が行動 j を選択するようなデータ $\mathcal{D}_{ij}$ が存在するのか」という問題を解くことで，データ購入者 i に行動 j をとらせることが可能なのかを明らかにしたい．そのためには，すべての $j \in B$ について $j = \underset{j' \in B}{\operatorname{argmax}} f_{ij'}(\mathcal{D}_{ij})$ を満たす $\mathcal{D}_{ij}$ が存在するかどうかを，データ販売者が持つデータのすべてのサブセットについて検証を行う必要がある．もし，条件を満たす $\mathcal{D}_{ij}$ が存在するならデータ購入者 i に $\mathcal{D}_{ij}$ を販売することで行動 j を選択するように制御することが可能である．一方で，このような $\mathcal{D}_{ij}$ が存在しない場合にはデータ購入者 i が行動 j を選択することはないと考えられる．通常今回考える問題を解こうとする場合には，各 i, j の組み合わせごとにデータ販売者の持つデータ集合 $\mathcal{D}$ に対して $O(2^{|\mathcal{D}|})$ の計算量が必要となり，現実的な計算時間では解くことが難しい．そこでデータ評価指標である DVRL を利用することで現実的な計算時間でこの問題を解くことを試みることとする．

4.2.2 Data valuation using reinforcement learning(DVRL)

DVRL[8] は Yoon らによって提案された強化学習を使用したデータ評価指標である．この枠組みでは，まず評価したいデータ集合と予測モデル，目的関数（一般には学習における誤差関数とテストデータ）を用意する．次に，各データ点に割り振られた重みに基づいてサンプリングを行い，選ばれたデータ点を用いてモデルの学習を行う．そして，目的関数を増大さ

せるデータ点に関しては重みを大きく，逆に目的関数を減少させるデータ点に関しては重みを小さくするように学習がなされる．これらを繰り返すことで，重みの大小でデータの有効性が判断できるようになり，各データ点の重みが各データ点の評価値として得られることとなる．そして，このようにして得られたデータの評価値を基に，データに重みをつけて予測モデルの再学習を行うことで，すべてのデータを均等に扱うよりも高い予測性能を得ることが可能となる．本研究では，各 i, j について目的関数 f_{ij} を最大化するようにデータの重みを学習し，$j = \underset{j' \in B}{\operatorname{argmax}} f_{ij'}(\mathcal{D}_{ij})$ を満たす $\mathcal{D}_{ij}$ を得ることを目指す．

4.3 最大重みマッチング

データ購入者 i が行動 j を選択するようなデータ $\mathcal{D}_{ij}$ が存在する場合は，データ $\mathcal{D}_{ij}$ を販売することでデータ購入者の行動を制御できる．この関係性をグラフ G で表現することを考える．まず，任意のデータ購入者と行動を頂点 V とする．そして，任意のデータ購入者 i と行動 j に対して，$\mathcal{D}_{ij}$ が存在する場合に頂点 i, j 間に辺を張ることとし，このような辺の集合を E とする．このとき，グラフは二部グラフとなり，行動の頂点に関しては各行動をとった場合の総報酬 v_j が各頂点の重みとして表現されるとする．ここで，買い手の収益の総和を最大化することを考えれば，この問題は最大重みマッチング問題に帰着することができる．これは，今回考えている価値毀損モデルでは他のデータ購入者と同じ行動を選択したとしても全体の収益の総和を増加させることはできず，可能である限りだれも選択していない行動を選択させることで全体の収益の総和を最大化することができる．逆に，もし誰も選択していないような行動に割り当てることができないデータ購入者がいる場合は，どの行動に誘導してもそのデータ購入者が得られる収益は他のデータ購入者の収益を阻害することで得られるものであり，これ以上は全体の収益の総和を増加させられないため，どの行動にも割り当てないとみなしても結果に変わりはない．そのため，今回関心があるのはいずれかのデータ購入者によって選択された行動の収益の合計であり，各行動に最大 1 人のデータ購入者を割り当てる問題であるとみなすことが可能である．この場合，今回の問題設定は二部グラフの片側の頂点に重みが乗った状態での最大重みマッチングであるとみなすことができる．最大重みマッチング問題は単なる最大マッチング問題に比べて計算量が大きくなる場合も多い．しかし，今回の問題設定では重みの降順に行動の頂点を並び替えた上で，通常の最大マッチングのアルゴリズムを適用することで厳密解が得られることが知られている．上記の厳密解を求めるアルゴリズムの計算量は $O(|V||E|)$ や $O(\sqrt{|V|}|E|)$ であり，非常に小さな計算量で厳密解を得ることが可能である．

5. 実験

5.1 使用データと状況の想定

今回は Rossmann Store Sales データセットを使用した．このデータセットには 4 種類の店舗 (A,B,C,D) のデータが混在しており，データ購入者はこの 4 種類の店舗のどの市場にターゲッティングするのかを検討しているという場合を考える．つまり，今回は店舗の種類がデータ購入者の取るアクションの種類に対応している．また，f_{ij} は各データ購入者ごとに異なるテストデータを店舗の種類ごとに用意し，購入データ $\mathcal{D}_i$ を用いて学習したモデルを使用して売上を予測する回帰問題のテストデータに対する平均二乗和誤差の値であるとする．つまり，予測誤差が小さくなるほどデータ購入者はその行動をとりたいという気持ちが高まり，もっとも予測精度が高くなるような店舗にターゲッティングすることとなる．今回はデータマーケットに 4 人のデータ購入者 (1,2,3,4) が存在する場合を

考えて，全体の収益の総和が最大になるように各データ購入者にデータを割り当てる問題を解く．各データ購入者は事前に少量のデータを用いて学習した予測モデルを持っていると仮定し，このときの各店舗に対する予測精度を初期状態とする．また，単純化のために今回は各行動を選択した場合に得られる収益の総和はすべて等しく v とする．

今回の状況設定を構成するにあたって，まず Rossmann Store Sales データセットから各データ購入者に対して各店舗の種類ごとにデータをサンプリングしてそれぞれのテストデータ (データセット全体の 19% を使用) を作成する．次に，その残りのデータから各データ購入者について事前に持つ少量の学習用データ (データセット全体の 1% を使用) をランダムにサンプリングする．最後に，さらにその残りのデータを販売者の保有するデータ (データセット全体の 80% を使用) として扱うこととした．また，それぞれのデータ購入者が用いる予測モデルは勾配ブースティング木を使用している．

5.2　データの割り当て

まず，購入データを適切に割り当てることで買い手 i に行動 j を選択させることが可能かを考える必要がある．このとき，行動 j をデータ購入者 i に選択させたい場合には $j = \underset{j' \in A}{\mathrm{argmax}} f_{ij'}(\mathcal{D}_{ij})$ を満たすような $\mathcal{D}_{ij}$ の存在を検証する必要がある．そこで今回はデータ評価指標である DVRL[8] を使用することとした．DVRL では強化学習を使用することでデータセットの中から予測精度が最大となるサブセットのサンプリングを行うことにより，現実的な時間で解の探索が可能である．

その後，条件を満たす $\mathcal{D}_{ij}$ の構成が可能かどうかを基に二部グラフを作成して最大重みマッチング問題を解く．これによって，全員に同じデータを渡す場合と比較して結果がどのように変わるのか比較を行う．今回はすべての行動の収益が同じであることを仮定しているが，収益の大きさの順に頂点番号を並び替えることで行動の収益が異なる場合にも容易に拡張できるものである．

5.3　実験結果

初期状態として，データ購入者のもつテストデータや販売者の持つデータと区別された，各データ購入者ごとにランダムにサンプリングした少量のデータで学習した場合のモデル性能を図 1 に示す．

各店舗に対する予測精度（平均二乗和誤差）

データ購入者	A	B	C	D
1	0.186	0.488	0.186	0.165
2	0.191	0.485	0.194	0.164
3	0.187	0.473	0.188	0.169
4	0.185	0.496	0.187	0.165

図 1　データ購入者の初期状態

このとき，予測精度を見てみると店舗ごとにばらつきがあることがわかる．この状態ではどのデータ購入者についても予測精度が最大となる店舗（青く色づけした）は店舗 D に対するものであり，全員が行動 D を選択することになる．

次に，単純にデータセット全体を全員に渡した場合の結果を図 2 に示す．

各店舗に対する予測精度（平均二乗和誤差）

データ購入者	A	B	C	D
1	0.133	0.147	0.141	0.116
2	0.134	0.146	0.149	0.116
3	0.134	0.145	0.140	0.118
4	0.131	0.127	0.142	0.117

図 2　同じデータを渡した場合に選択される行動

この場合にも予測精度が最大となるのは，いずれの購入者の立場においても店舗 D であるから，全員が店舗 D を選択することとなり，データを渡す前と行動自体は変わらない．一方で，予測精度はデータを購入することにより増加していることからデータ販売自体は有効に機能すると考えられる．このとき，データ購入者全体の収益の総和は $\frac{v}{4} \cdot 4 = v$ となる．

次に提案手法を用いた結果を示す．まず DVRL を用いて各データ購入者に適切なデータを選択することで各行動を選択させることが可能か検証を行う．そのために，データ購入者 i と行動 j の組み合わせごとに，DVRL を用いてデータ購入者 i の店舗 j に対する予測精度 f_{ij} を最大化するデータセット $\mathcal{D}'_{ij}$ を作成する．このとき，DVRL を用いて作成したデータセット $\mathcal{D}'_{ij}$ が条件 $j = \underset{j' \in A}{\operatorname{argmax}} f_{ij'}(\mathcal{D}'_{ij})$ を満たすとは限らないため，データ購入者 i が $\mathcal{D}'_{ij}$ を購入した場合にどの店舗への予測精度が最大となるのか（どの行動を選ぶことになるのか）の確認を行う．例として，データ購入者 1 に関して結果を示したものが図 3 である．

各店舗に対する予測精度（平均二乗和誤差）

選択させたい行動	A	B	C	D
A	0.127	0.100	0.136	0.116
B	0.130	0.128	0.143	0.116
C	0.131	0.151	0.109	0.112
D	0.115	0.136	0.110	0.108

図 3　データ購入者 1 に選択させられる行動の種類

縦軸はどの行動を選択させる目的でデータを選択したかを表し，横軸はどの行動に対する予測結果かを表している．例えば，行動 C を選択させるために DVRL を用いた結果を見ると，店舗 C に対する予測精度が最大となっているためデータ購入者 1 に行動 C を選択させることが可能であることがわかる．逆に，行動 A を選択させるために DVRL を用いた結果を見ると，店舗 B に対する予測精度が最大となっているため作成したデータをデータ購入者 1 に渡しても行動 B を選択させることが可能であることがわかるが，データ購入者 1 に行動 A を選択させることはできない．このようにして，データを調整することによってデータ購入者 1 に B,C,D の行動のうち任意のものを選択させることが可能なことがわかる．逆に A の行動を選択させることは今回の探索では不可能であったことがわかる．

このような検証をすべてのデータ購入者に対して行い，その結果を図示したものが図 4 である．行動させることが可能なものには○を，行動させることが不可能なものには×をそれぞれ記載している．

行動を選択させられるか

データ購入者	A	B	C	D
1	×	○	○	○
2	×	×	×	○
3	×	○	○	×
4	×	○	×	○

図 4　各データ購入者に選択させられる行動の種類

この情報を基に二部グラフを構成し，最大重みマッチングを行った結果が図 5 である．赤線がマッチングを行った結果，対応することになるデータ購入者と行動の組である．結果として全体の収益の総和は $3v$ となり，図 2 のように，全てのデータ購入者に同一のデータを渡した場合の収益の総和 v よりも，大きく改善出来ている．

6.　今後の課題

今回の実験結果からデータ販売者が販売するデータを制御することでデータ購入者の行動を制御することができ，データ購入者全体の収

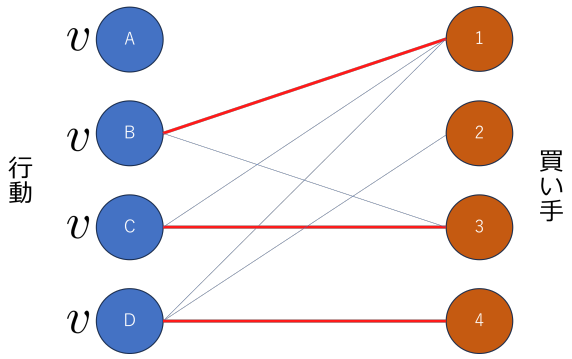

図 5　二部グラフと最大重みマッチングを行った結果

益の総和の最大化に貢献ができることが示された．特に，二部グラフ構成後は非常に小さな計算量でデータ購入者を各行動に最適に割り振ることが可能となる．

一方で，現実的な時間で解くためにはまだ課題が残っている．今回は DVRL を使用して解の探索を試みたが，データ購入者を任意の行動に誘導することはできなかった．そのため，将来的にはデータ加工によって選択できるデータの候補を増大させたり，他のデータ評価指標を利用したりすることでより幅広い行動をデータ購入者に選択させられることを目指していきたい．

参考文献

[1] Mengxiao Zhang, Fernando Beltrán, and Jiamou Liu. A survey of data pricing for data marketplaces. *ArXiv*, Vol. abs/2303.04810, , 2023.

[2] Jian Pei. A survey on data pricing: From economics to data science. *IEEE Transactions on Knowledge and Data Engineering*, Vol. 34, pp. 4586–4608, 2020.

[3] Yingjie Tian, Yurong Ding, Saiji Fu, and Dalian Liu. Data boundary and data pricing based on the shapley value. *IEEE Access*, Vol. 10, pp. 14288–14300, 2022.

[4] Olga Ohrimenko, Shruti Tople, and Sebastian Tschiatschek. Collaborative machine learning markets with data-replication-robust payments. *ArXiv*, Vol. abs/1911.09052, , 2019.

[5] Amirata Ghorbani and James Y. Zou. Data shapley: Equitable valuation of data for machine learning. *ArXiv*, Vol. abs/1904.02868, , 2019.

[6] Yongchan Kwon and James Y. Zou. Beta shapley: a unified and noise-reduced data valuation framework for machine learning. *ArXiv*, Vol. abs/2110.14049, , 2021.

[7] Amirata Ghorbani, Michael P. Kim, and James Y. Zou. A distributional framework for data valuation. *ArXiv*, Vol. abs/2002.12334, , 2020.

[8] Jinsung Yoon, Sercan Ö. Arik, and Tomas Pfister. Data valuation using reinforcement learning. *ArXiv*, Vol. abs/1909.11671, , 2019.