販売量予測モデル構築のための作業手順書

株式会社フュージョンシス

目次

作業手順のフローチャート

解析の手順をフローチャートを使って説明する。

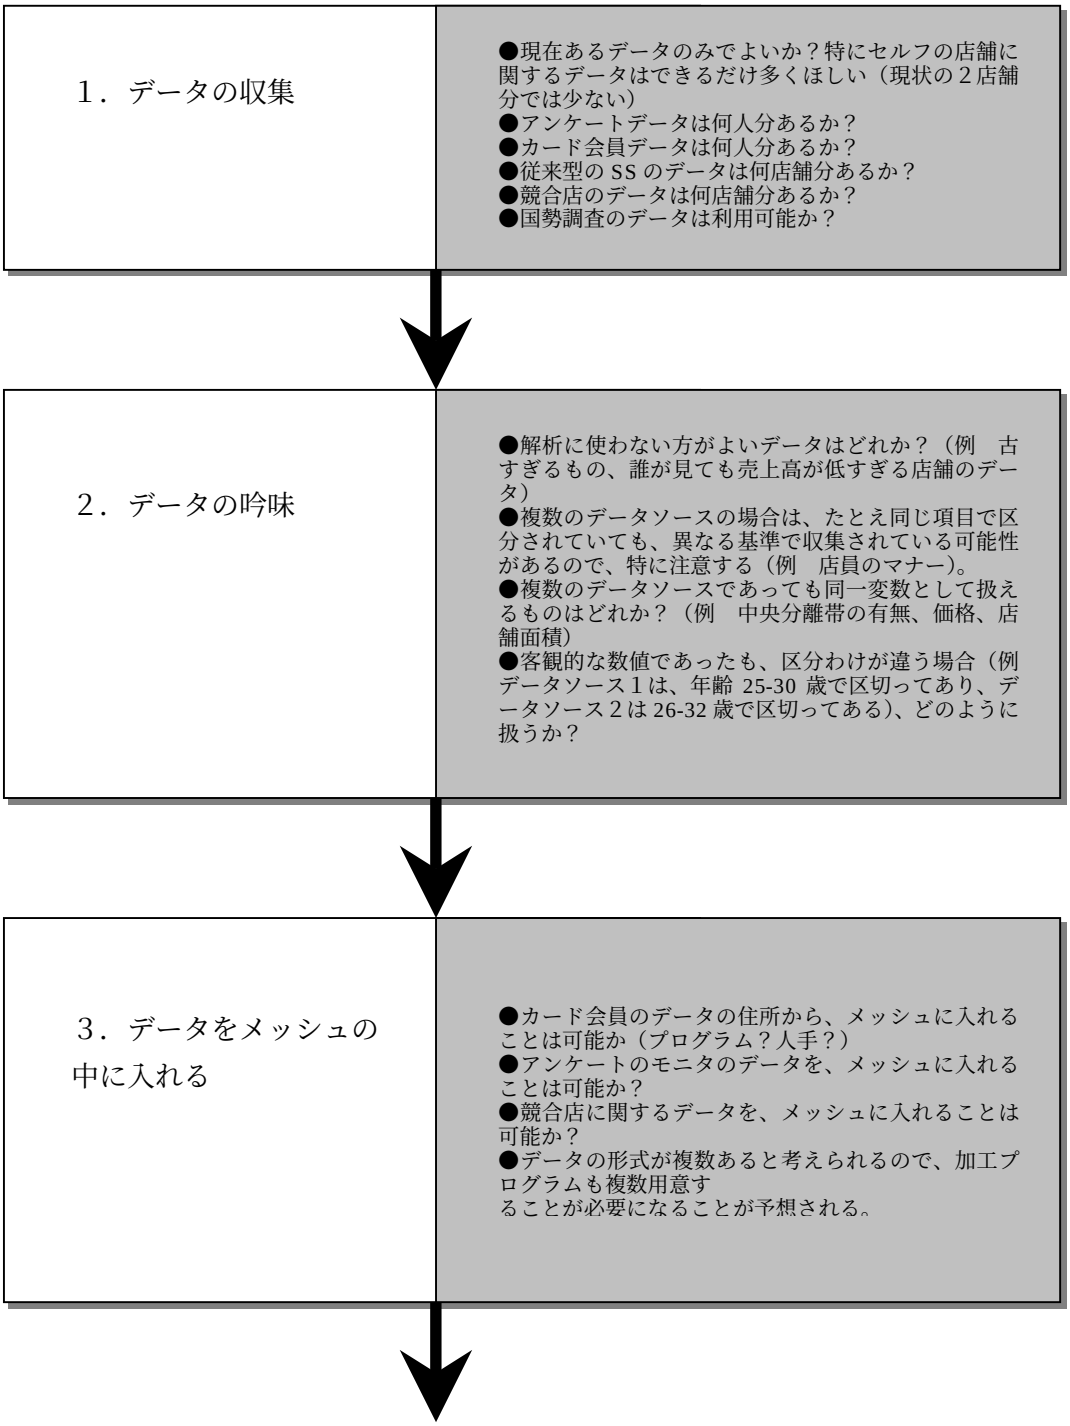

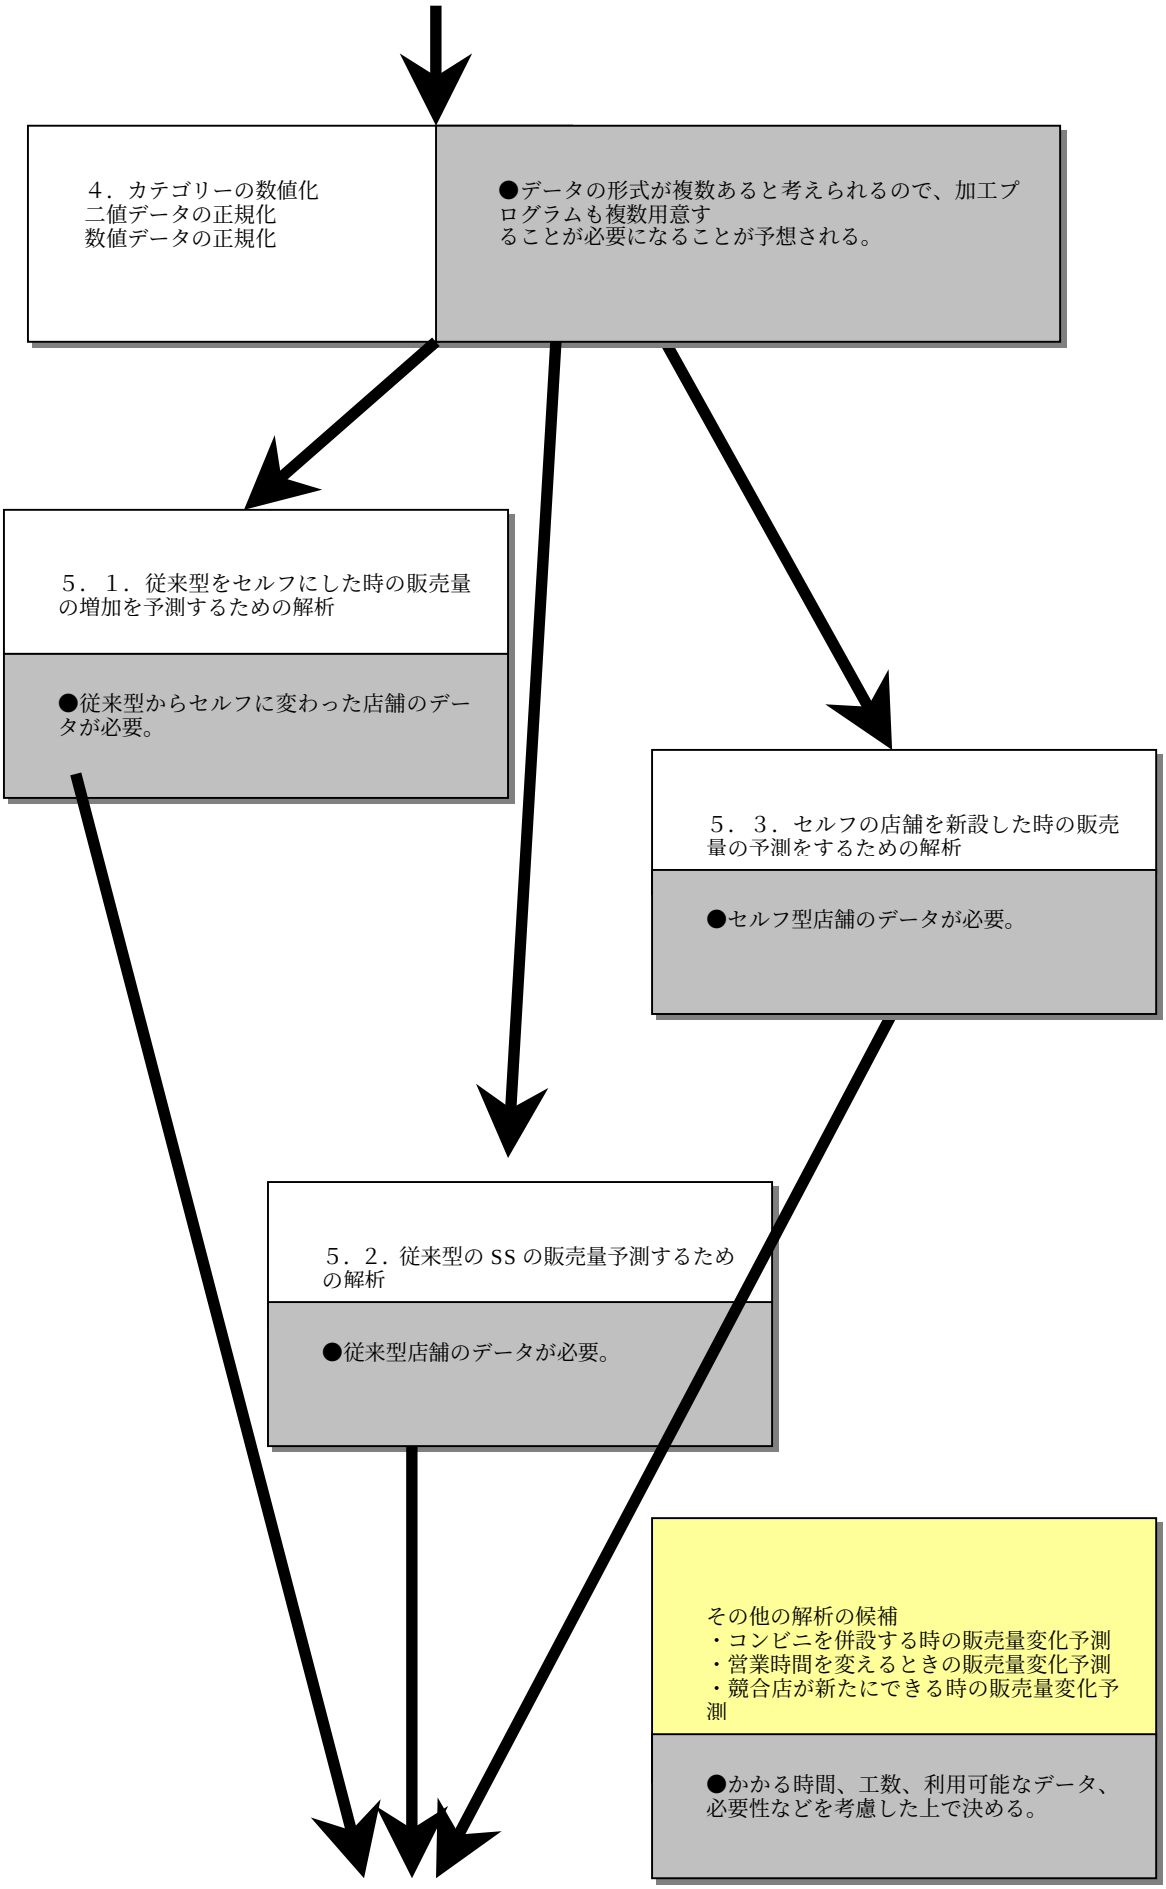
４．カテゴリーの数値化
二値データの正規化
数値データの正規化
●データの形式が複数あると考えられるので、加工プログラムも複数用意することが必要になることが予想される。
５．１．従来型をセルフにした時の販売量の増加を予測するための解析
●従来型からセルフに変わった店舗のデータが必要。
５．３．セルフの店舗を新設した時の販売量の予測をするための解析
●セルフ型店舗のデータが必要。
５．２．従来型の SS の販売量予測するための解析
●従来型店舗のデータが必要。
その他の解析の候補
・コンビニを併設する時の販売量変化予測
・営業時間を変えるときの販売量変化予測
・競合店が新たにできる時の販売量変化予測
●かかる時間、工数、利用可能なデータ、必要性などを考慮した上で決める。

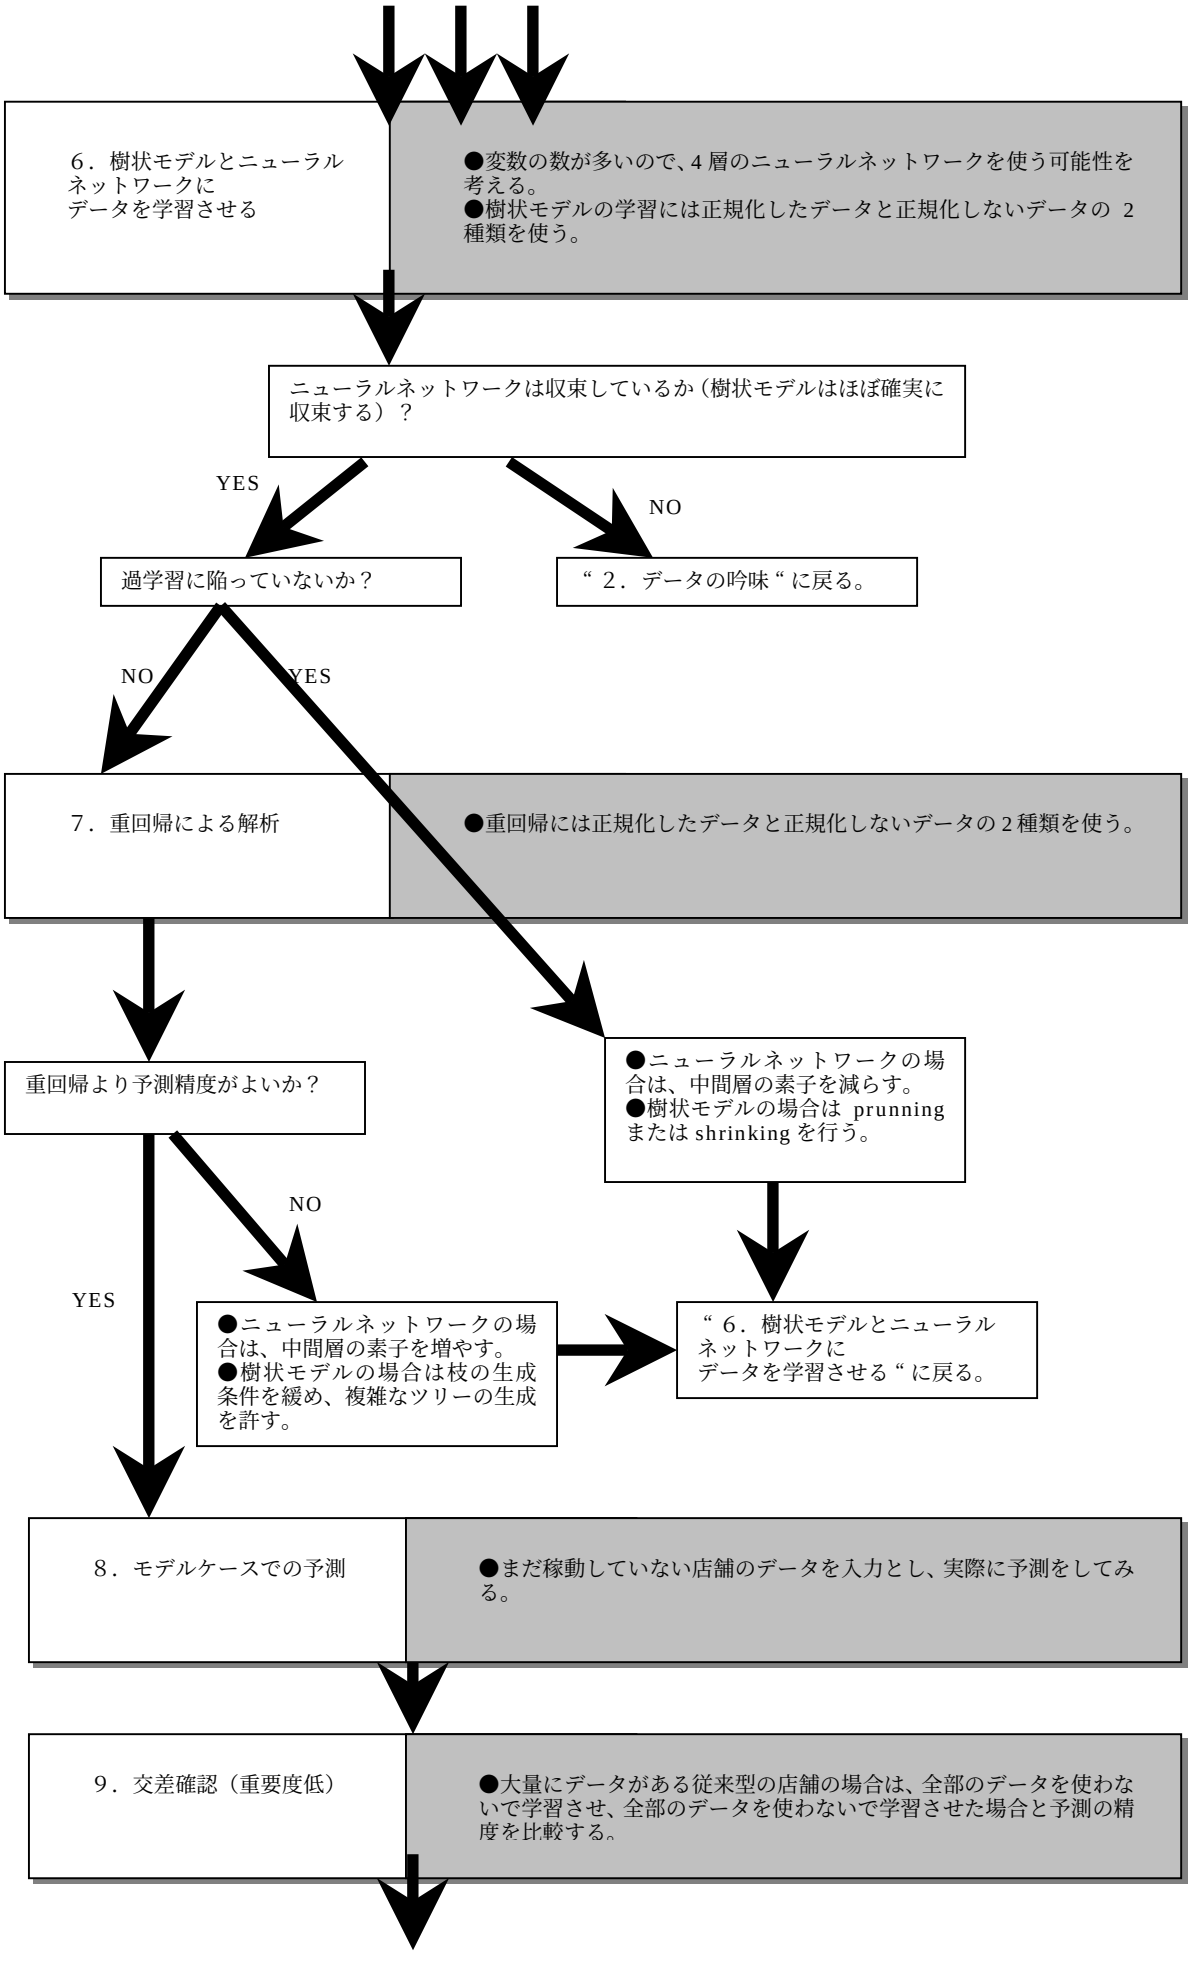
6．樹状モデルとニューラルネットワークにデータを学習させる
●変数の数が多いので、4 層のニューラルネットワークを使う可能性を考える。
●樹状モデルの学習には正規化したデータと正規化しないデータの 2 種類を使う。
ニューラルネットワークは収束しているか（樹状モデルはほぼ確実に収束する）？
YES
NO
過学習に陥っていないか？
“ 2．データの吟味 “ に戻る。
NO
YES
7．重回帰による解析
●重回帰には正規化したデータと正規化しないデータの 2 種類を使う。
重回帰より予測精度がよいか？
●ニューラルネットワークの場合は、中間層の素子を減らす。
●樹状モデルの場合は prunning または shrinking を行う。
NO
YES
●ニューラルネットワークの場合は、中間層の素子を増やす。
●樹状モデルの場合は枝の生成条件を緩め、複雑なツリーの生成を許す。
“ 6．樹状モデルとニューラルネットワークにデータを学習させる “ に戻る。
8．モデルケースでの予測
●まだ稼動していない店舗のデータを入力とし、実際に予測をしてみる。
9．交差確認（重要度低）
●大量にデータがある従来型の店舗の場合は、全部のデータを使わないで学習させ、全部のデータを使わないで学習させた場合と予測の精度を比較する。

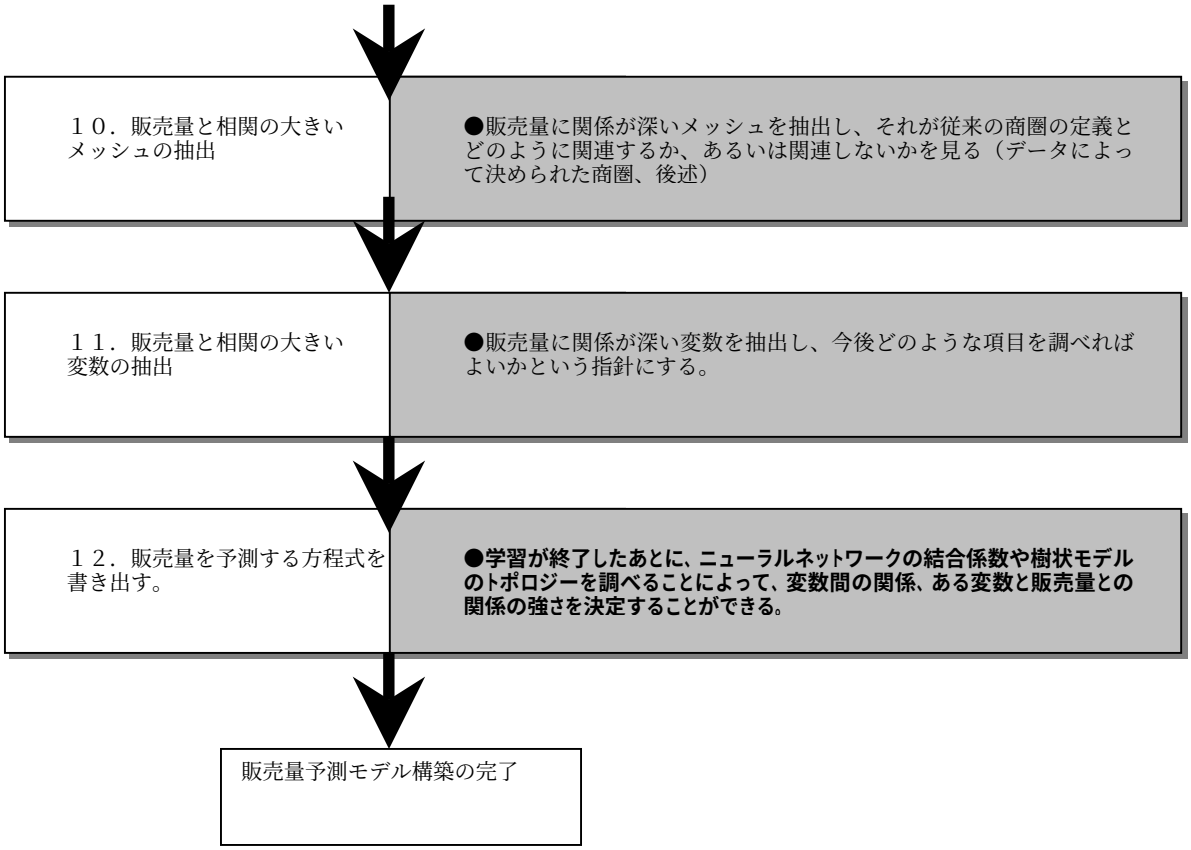
１０．販売量と相関の大きいメッシュの抽出
●販売量に関係が深いメッシュを抽出し、それが従来の商圏の定義とどのように関連するか、あるいは関連しないかを見る（データによって決められた商圏、後述）
１１．販売量と相関の大きい変数の抽出
●販売量に関係が深い変数を抽出し、今後どのような項目を調べればよいかという指針にする。
１２．販売量を予測する方程式を書き出す。
●学習が終了したあとに、ニューラルネットワークの結合係数や樹状モデルのトポロジーを調べることによって、変数間の関係、ある変数と販売量との関係の強さを決定することができる。
販売量予測モデル構築の完了

構成的に商圏を設定していく方法の問題点

世帯数、交通量、昼間人口、商業統計、競合 SS の影響度によって、商圏を構成的に設定していく方法は、

・比較的単純にモデルを構築できる。
・モデルの構成が直感的で、理解しやすい。

といった長所がある一方、

・カード顧客やアンケートに答えてもらったモニターなどの情報を設定した商圏の情報とどのように結びつけるか明らかではない。
・補足率や競合 SS などの影響度を正確に評価しにくく、人間が評価すると、恣意性が入りやすい。

といった短所がある。従来のライリーの法則やハフモデルも、市場ポテンシャル、買い物出向比率、距離抵抗係数といった客観的に決めるのが困難なパラメータを含んでおり、そこがこれらのモデルの限界である。ただし有効な考え方も多く含まれており、前向きに考慮する。

商圏を設定しない方法（構成的でないモデルの構築法、あるいはデータを学習させることによってモデルを構築する方法）

今回ご提案するのは、商圏を初めからは設定しない方法である。この方法の主眼は、解析者による恣意的な判断を可能な限り除いた形で解析を行うということである。

★長所
・恣意性が入りにくい。
★短所
・必ずしも直感的ではないので、理解が難しい。
・データ解析で扱わなければならないの変数が多い。

という特徴がある。各 SS について御社様が持っているデータ、MPSI から購入する競合 SS のデータとアンケートに答えてもらったモニターのデータ、カード会員などの特定の顧客のデータをすべて組み合わせて解析および予測を行う。変数としては次のようなものを考慮する。

メッシュごとに分けられているデータ

メッシュごとに利用可能なデータはメッシュ毎に1変数として扱う。下図のように解析をするすべての SS に対して相対的な位置ができるだけ同じになるようにメッシュをきることが望ましい。

		御社1		

		御社2		

潜在的な需要に関するデータ

・メッシュの中心と SS との距離（もし利用可能であれば来店時間、帰店時間、走行時間を使う。不明な場合は直線距離で代用）

・メッシュ内の昼間人口

・メッシュ内に登録されている車の台数

・メッシュ内の累積交通量

・メッシュ内の世帯数

など

メッシュ内の競合 SS

・競合 SS と御社 SS との距離（もし利用可能であれば走行時間を使う。不明な場合は直線距離で代用）

・競合 SS の規模

・競合 SS の売上

など

メッシュ内の他の商業施設

・他の商業施設と御社 SS との距離（もし利用可能であれば走行時間を使う。不明な場合は直線距離で代用）

・他の商業施設の規模
・他の商業施設の売上
など

対象となる SS そのものの属性
・前面中央分離帯の有無
・側面中央分離帯の有無
・前面交通量
・ガソリンフル軽量機数
など

顧客に関するデータ
もともと地図情報に入ってはいないが、プログラム的に地図に埋め込めるものであれば、顧客に関する情報もメッシュ内の変数として扱うことも考慮する（ただし、顧客データの形式がどのようなものであるか現時点では不明なので工数の評価が難しい）。

カード顧客関連
カード顧客は特にロイヤリティが高いと考えられるので、解析に用いる。

・カード顧客の住所と SS との直線距離（理想的には、来店時間、帰店時間、走行時間を使うべきだが、不明な場合は直線距離で代用）
・カード顧客の利用頻度
など

アンケートに答えてもらったモニターに関するデータ
・モニタがきた位置と SS との直線距離（理想的には、来店時間、帰店時間、走行時間を使うべきだが、不明な場合は直線距離で代用）
・モニタの利用頻度
など

留意点

データの区別に関して

基本的に MPSI のデータと御社様の持っているデータは 2 種類のソースと考えられるので、たとえ同じ名前を持つ項目があったとしても、その内容は整合的であるとは限らない。その時は重複のない 2 つの項目として扱う。

解析時に新たに付け加えるべき変数

競合店か否かを区別するフラグ、商業施設か否かを区別するフラグ、カード顧客であるか否かを区別するフラグ、アンケートに答えてもらったモニタであるかを示すフラグなど。

データのプレシーズニング（前処理）

データの形式を揃える

すべての SS に関するデータを一律なフォーマットにする（この部分で PERL を用いたデータの整形作業が大量に発生する）。

数値データの正規化

すべての変数は 0.1 から 0.9 までの実数値（二値データの場合、0,1 を使うとニューラルネットワークが収束しない場合があることがわかっている）をとるようにデータを正規化する。これによってすべての変数の相対的な寄与率を同じにすることができる。数値データは最大値、最小値を検出したあと、それぞれが、0.9,0.1 にマッピングするような正規化を行う（この部分で PERL を用いたデータの整形作業が大量に発生する）。

二値データの正規化

中央分離帯有無のようなニ値データは、0.9,0.1 にマッピングするような正規化を行う。

カテゴリカルデータの正規化

カテゴリカルデータ（文字列によるデータ）はデータに現れるすべてのカテゴリを列挙して、正の整数値にアサインする。次に[0.1,0.9]の間に等間隔にマッピングするような正規化を行う。なおオープンアンサーなどの回答は解析に含めない（この部分で PERL を用いたデータの整形作業が大量に発生する）。

データの数を増やす
次のような方法によって、学習に用いるデータの数を増やすことが可能である。

データの直積によって大量のサンプルデータを作る
SS1 に関してメッシュによって分けられている情報（データ M と呼ぶ）と顧客データのようにメッシュの形で入っていないデータ（データ N と呼ぶ）があるとする。MxN を次のように定義することによって、顧客の人数分のサンプルデータを生成することができる。

サンプルデータ1
＝（
前面中央分離帯有無、側面中央分離帯有無、前面交通量、.....
メッシュ1登録車両台数、メッシュ2登録車両台数、メッシュ3登録車両台数,....、メッシュ100登録車両台数、
メッシュ1昼間人口、メッシュ2昼間人口、メッシュ3昼間人口,....、メッシュ100昼間人口、
メッシュ1SS までの走行時間、メッシュ2SS までの走行時間、メッシュ3SS までの走行時間,....、メッシュ100SS までの走行時間、
.....
カード会員1自宅から SS までの走行時間、カード会員1利用頻度、カード会員1週末外出頻度,....、カード会員1自家用車保有台数
）

サンプルデータ2
＝（
前面中央分離帯有無、側面中央分離帯有無、前面交通量、.....
メッシュ1登録車両台数、メッシュ2登録車両台数、メッシュ3登録車両台数,....、メッシュ100登録車両台数、
メッシュ1昼間人口、メッシュ2昼間人口、メッシュ3昼間人口,....、メッシュ100昼間人口、
メッシュ1SS までの走行時間、メッシュ2SS までの走行時間、メッシュ3SS までの走行時間,....、メッシュ100SS までの走行時間、
.....
カード会員2自宅から SS までの走行時間、カード会員2利用頻度、カード会員2週末外出頻度,....、カード会員2自家用車保有台数
）

ただしカード会員1、カード会員2は SS1 を利用する顧客である。同様に SS2 についても直積を定

義し、SS2 を利用するカード会員分のデータを作ることができる。

ブートストラップによって大量のサンプルデータを作る

元のデータ
＝(
前面中央分離帯有無、側面中央分離帯有無、前面交通量、.....
メッシュ1登録車両台数、メッシュ2登録車両台数、メッシュ3登録車両台数,....、メッシュ100登録車両台数、
メッシュ1昼間人口、メッシュ2昼間人口、メッシュ3昼間人口,....、メッシュ100昼間人口、
メッシュ1SS までの走行時間、メッシュ2SS までの走行時間、メッシュ3SS までの走行時間,....、メッシュ100SS までの走行時間、
.....
メッシュ1カード会員人数、メッシュ2カード会員人数、メッシュ3カード会員人数,....、メッシュ100カード会員人数
)

とすると、 [0.1,0.9]上で一様乱数を発生させ、1 番目の変数を発生させた乱数で置き換える。すなわち

サンプルデータ1
＝(
乱数、側面中央分離帯有無、前面交通量、.....
メッシュ1登録車両台数、メッシュ2登録車両台数、メッシュ3登録車両台数,....、メッシュ100登録車両台数、
メッシュ1昼間人口、メッシュ2昼間人口、メッシュ3昼間人口,....、メッシュ100昼間人口、
メッシュ1SS までの走行時間、メッシュ2SS までの走行時間、メッシュ3SS までの走行時間,....、メッシュ100SS までの走行時間、
.....
メッシュ1カード会員人数、メッシュ2カード会員人数、メッシュ3カード会員人数,....、メッシュ100カード会員人数
)

サンプルデータ2

＝(

前面中央分離帯有無、乱数、前面交通量、……

メッシュ1登録車両台数、メッシュ2登録車両台数、メッシュ3登録車両台数,….、メッシュ100登録車両台数、

メッシュ1昼間人口、メッシュ2昼間人口、メッシュ3昼間人口,….、メッシュ100昼間人口、

メッシュ1SSまでの走行時間、メッシュ2SSまでの走行時間、メッシュ3SSまでの走行時間,….、メッシュ100SSまでの走行時間、

…….

メッシュ1カード会員人数、メッシュ2カード会員人数、メッシュ3カード会員人数,….、メッシュ100カード会員人数

)

変数の個数分の学習データができる。

直積とブートストラップを組み合わせて大量のサンプルデータを作る

上記2つの方法を組み合わせることも可能である。

解析法およびデータ

三つの解析法

今回用いるのは、重回帰モデル、樹状モデル、ニューラルネットワークの3つである。重回帰は線形データに適用可能、他の2つは非線形なデータに関しても適用可能である。

データの形式

1(0,0)	2(0,1)	3(0,2)	4(0,3)	5(0,4)
6(1,0)	7(1,1)	8(1,2)	9(1,3)	10(1,4)
11(2,0)	12(2,1)	御社 13(2,2)	14(2,3)	15(2,4)
16(3,0)	17(3,1)	18(3,2)	19(3,3)	20(3,4)
21(4,0)	22(4,1)	23(4,2)	24(4,3)	25(4,4)

メッシュごとのデータを次のようなCSVファイルに落とす。

メッシュ	メッシュ	メッシュ	…	昼間人口	SSまでの	登録車両	登録車両	…	…	正規化さ	正規化さ	正規化さ	正規化さ	…	…

通し番号	x 座標	y 座礁			走行時間	台数	台数			れた昼間人口	れたSSまでの走行時間	れた登録車両台数	れた登録車両台数		
1	0	0													
2	0	1													
3	0	2													
4	0	3													
5	0	4													

アンケートのモニタやカード会員のデータは次のような CSV ファイルに落とす。

サンプル番号	御社 SS に一意につけられた ID	当該 SS に対する位置	当該 SS に対する x 座標	当該 SS に対する y 座標			性別	年齢					
1	ide45628	4	0	3									
2	ide45679	5	0	4									
3	ide31890	10	1	4									
4	ide40231	3											
5	ide45012	13											

3 つの解析法の内容と特徴

この節では重回帰、ニューラルネットワーク、樹状モデルについてその共通点と相違点などを述べる。

重回帰モデル

いまあるサービスステーションの売上高 O、交通量 T、ガソリン価格 P の関係を知りたいとする（これをシステム S と記す）。

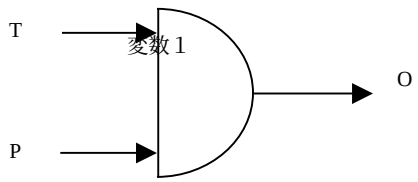

現実の中のシステムにはさまざまな因果関係や影響があり、O,T,P の間の関係を表現する厳密な数式を書き下すことはもちろん不可能である。重回帰モデルを使うということは O,T,P の間にとりあえず、線形関係が成り立つと仮定することである（非常に乱暴な仮定ではある）。

O＝aT＋bP+c

実測値と予測値の間の誤差（最小二乗誤差）が小さくなるように a,b,c を決めてやるのが重回帰の本質である。

ところが重回帰は次のような単純なデータ（この例は XOR と呼ばれる）さえ、回帰させることができない（このような例は無数にある）。

	T	P	O
データ1	0	0	0
データ2	1	0	1
データ3	0	1	1
データ4	1	1	0

このようなデータは現実世界にはいくらでもあり、そこに重回帰の限界がある。

ニューラルネットワーク

ニューラルネットワークや樹状モデルはいずれも machine learning と呼ばれるカテゴリーに属する方法であり、重回帰が線形モデルの存在をアプリオリに仮定しているのに対し、ニューラルネットワークや樹状モデルでは、アプリオリに特定の形のモデルの存在を仮定せず、アルゴリズムによってシステム S と非常に近い振る舞いをする擬似システム S'を作り出すことを主眼としている。

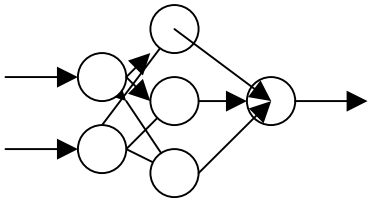

ニューラルネットワークは上のような構成をする素子の集まりである。1 層目は入力層、2 層目は中間層、3 層目は出力層である。素子の数はそれぞれいくつにとってもよい（上の T,P,O の例ならば入力層の素子の数は 2 にとり、出力層の素子の数は1にとる）。

1 層目と 2 層目は

$$I_i^2=F(\sum_j^N w_{ij}O_j^1)$$

の関係で結ばれている。ここで I_i^2 は 2 層目の i-番目の素子への入力、O_j^1 は 1 層目の j-番目の素子からの出力、w_{ij} は 2 層目の i-番目の素子と 1 層目の j-番目の素子との間の結合係数、F はシグモイド関数である。2層目と3層目の素子の間にも同様な関係が成立する。すなわち

$$I_i^3=F'\left(\sum_j^N v_{ij}O_j^2\right)$$

ここで I_i^3 は 3 層目の i-番目の素子への入力、O_j^2 は 2 層目の j-番目の素子からの出力、w_{ij} は 2 層目の i-番目の素子と 1 層目の j-番目の素子との間の結合係数、F' はシグモイド関数である。

ニューラルネットワークの学習は、出力がデータ1からデータnまでを順次入力層に与えたとき、出力素子がそれぞれ O1,O2、・・・・On に近づくように w_{ij} の値を調節することと定義される。

	入力1	入力2	出力
データ1	T1	P1	O1
データ2	T2	P2	O2
データ3	T3	P3	O3
データ4	T4	P4	O4
・・・・・・			
データn	Tn	Pn	On

ニューラルネットワークは重回帰が失敗する XOR のようなデータであっても問題なく学習できる。どのように w_{ij} を変えていくかというアルゴリズムは多数あるが、逆誤差伝播法 (BACK-PROPAGATION) がよく使われる (これについては説明を省略させていただきます)

樹状モデル（または樹形モデル）

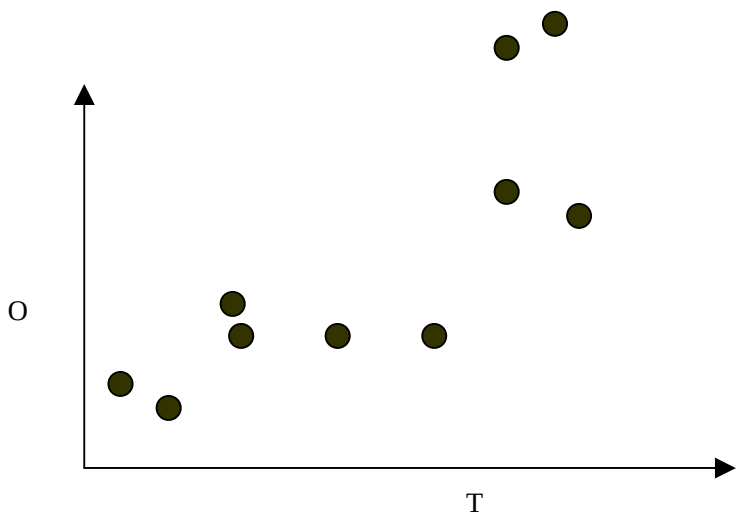

今売上と交通量の間に図のような関係があるとする。1個の●は 1 つのサービスステーションからのデータを表す。回帰モデルの場合は

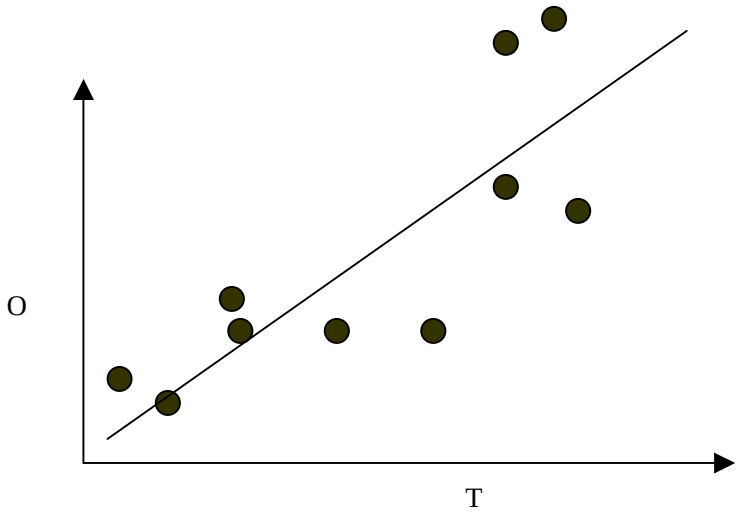

のようなモデルを選択することになるが、明らかに中央部や右半分でデータをうまく反映していない。一方樹状モデルでは

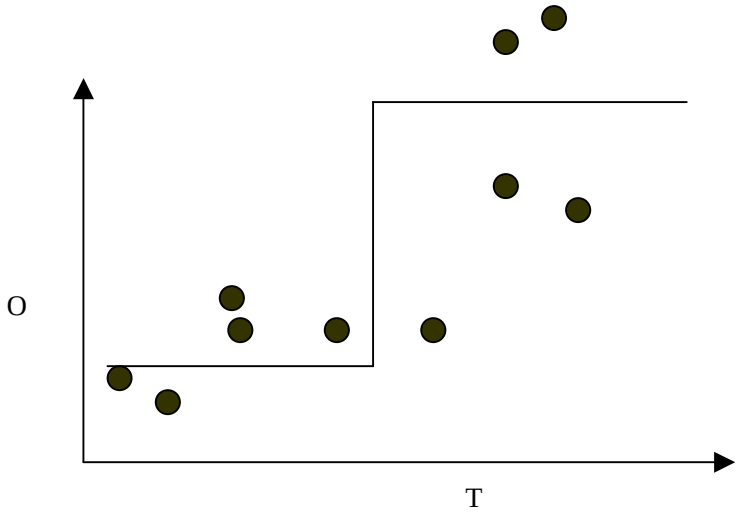

といったモデルや

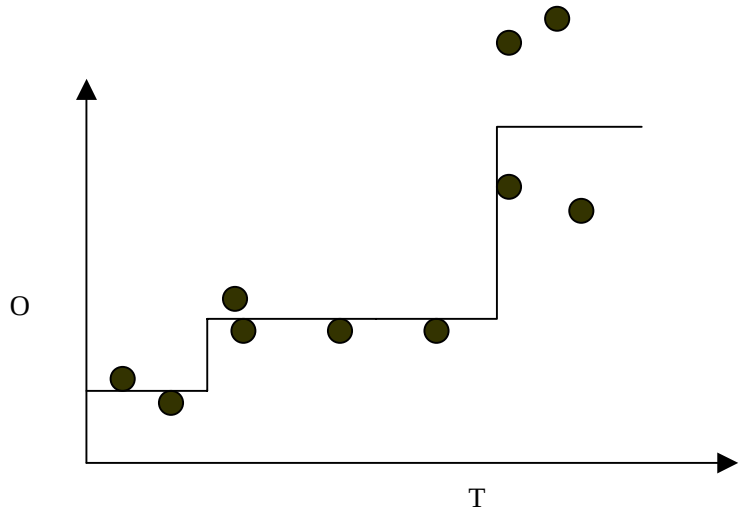

といったモデルが構成される（モデルを構成するためのアルゴリズムについての説明は省略させていただきます）。明らかに回帰より正確にデータを反映している。T、P、O の場合は3次元空間内に散らばった（T1,P1,O1）,（T2,P2,O2）,（T3,P3,O3）・・・・・（Tn,Pn,On）をうまく近似するようなカクカクした平面が生成される。

なぜ樹状モデルやニューラルネットワークは重回帰よりも優れているか？
現実のデータでは変数間にさまざまな相互作用が起こる。たとえば売上は一般に交通量が大きければ高くなるが、交通量が大きくなってもたとえば近隣に競合店があれば、競合店がない場合に比べて売上は伸びない。このような変数間の相互作用を回帰モデルは反映できない。変数間に相互作用がある場合、特にニューラルネットワークは優れている。

	重回帰	ニューラルネットワーク	樹状モデル
目的	回帰、予測、分類、判別	回帰、予測、分類、判別	回帰、予測、分類、判別
計算時間	短い	長い	やや長い
非線型データへの適用	不可	可能	可能
理解しやすさ	しやすい	やや難しい	やや難しい

学習データとテストデータ

データが100個ある場合、学習に99個を使い、1 個をテストに使うことができる。このような方法を交差確認法（CROSS－VALIDATION）という。交差確認法によって実際の売上とニューラルネットワークや樹状モデルが予測した値との差が小さければ、ニューラルネットワークや樹状モデルは現実のシステム S を十分によく近似している擬似システム S‘を構成したと考えられる。

今101番目の新規店舗については売上高のデータはないが、その他のデータはすべてそろっているとする。101番目の売上を学習の終了したニューラルネットワークや樹状モデルで予測することが、このプロジェクトの 1 つの主題である。

実際の解析にあたって

欠損値（missing value）の扱い
データがすべての変数に対して存在するわけではないので、欠損値をうまく処理することが必要である。販売量や他の変数と相関を持たないように、一様乱数を[0.1,0.9]で発生させ、データとして用いる。

外れ値（outlier）の扱い
初めは外れ値を除外しないで解析を行う。正規化を行っているので、外れ値の寄与は他の正常なデータに比較して、大きくなる。結果が著しく不合理な場合には、外れ値を除外する必要が出る可能性がある。

学習の回数
変数が多いので、ニューラルネットワークの学習は回数を増やすことが必要であることが予測される（樹状モデルの場合収束は一般に早い）。学習するデータ数を SS20店舗分で10000個とすると、1 回のループでその10000個のデータを学習させる。収束させるために多数回のループを回す。

交差確認法（cross-validation）
樹状モデルについては n-重の交差確認を行うことを考慮する（S-plus ではビルトインで交差確認

法機能が使える）。ニューラルネットワークではプログラミングが複雑になりすぎるので、特に交差確認法は用いない。

過学習（over-learning）に対する対策
学習によってできたモデルが過学習に陥ると、データに対するエラーは小さくなるが、予測能力が落ちる場合がある。その場合、いくつかの方法でモデルを単純化する。

・AIC(Akaike Information Criteria) を使う。
・樹状モデルの場合は prunning または shrinking によってモデルを単純化する。
・中間層の素子の数を減らす。

などを使うことを考慮する。

変数の間引き
解析が進むと販売量に寄与している変数とそうでない変数が区別できると考えられるので、寄与度の小さい変数は間引く。これによって計算時間の短縮が図れる。

データから決定される商圏の設定
商圏は従来、走行時間 3 分、5 分、10 分、15 分といったもので決められてきたが、この中で解析のなかで、販売量と相関が強いメッシュの位置を決定できる。従来の商圏とどのように関係するか、あるいはしないかを見ることができる。

変数間の関係の調査

方程式の構築
学習が終了した樹状モデルやニューラルネットワークは、変数に値を入力することによって販売量を出力する。この方程式を書き下すために、ニューラルネットワークの結合係数や樹状モデルのトポロジーを調べることによって、変数間の関係、ある変数と販売量との関係の強さを決定する。

計算可能性
上述の計算式は実際に計算可能な関数から構成される。計算式自体は複雑だが、段階を追えば必ず計算のできる関数である。

■