


クラスター分析：空間的アプローチによる 数理モデリング





Milliman, whose corporate offices are in Seattle, serves the full spectrum of business, financial, government, and union organizations. Founded in 1947 as Milliman & Robertson, the company has 48 offices in principal cities in the United States and worldwide. Milliman employs more than 2,100 people, including a professional staff of more than 1,000 qualified consultants and actuaries. The firm has consulting practices in employee benefits, healthcare, life insurance/financial services, and property and casualty insurance. For further information visit milliman.com.

目次

エグゼクティブ・サマリー	2
はじめに	3
背景	4
モデリングのための伝統的アプローチ	5
代替的アプローチ	6
グラフによる表示	8
潜在的利用法	9
伝統的な生命・医療保険モデルへの応用	10
定期保険モデルへの応用	12
変額年金モデルへの応用	14
モデルの検証	18
次のステップ	19

エグゼクティブ・サマリー

コンピュータ・ソフトウェアおよびハードウェアの進歩により、単一シナリオであれば、ほとんどの会社で保険契約を集約せず、一件毎にモデルしたベースでプロジェクションができるようになっていきます。また、中規模の保険会社であれば、適切なハードウェアとソフトウェアを備えることにより、シナリオ数にもよりますが、複数シナリオによる一件別プロジェクションも可能でしょう。

しかしながら、1990年代に決定論的シナリオ手法に代わり確率論的シナリオを用いる方法がより一般的となったように、今まさに（確率論的シナリオの将来の各時点ですらにその時点での確率論的シナリオを発生させプロジェクションを行う）ネスティッド・ストキャスティック・シナリオ手法への移行が始まりつつあります。

ネスティッド・ストキャスティック手法（あるいは、決定論的プロジェクションの中で確率論的プロジェクションを行う手法）は、責任準備金や資本を確率論的手法で設定しなければならない場合、複数シナリオにおける利益や剰余の分布を考察する際に有用です。しかしながら、ネスティッド・ストキャスティック計算を行うと、数理モデルのランタイムが大幅に増加してしまいます。相当な規模の保有契約について、契約一件毎のネスティッド・ストキャスティック計算を行うのは非現実的でしょう。計算負荷がそこまで高くない場合でも、計算時間を短縮したり、ファイル・サイズを抑制したりしたい場合には、小型モデルの開発が非常に有用です。

ミリマンは、このプロセスを効率よく迅速に行えるようにするため、**クラスター・モデリングと呼ぶ新型の自動モデル圧縮プロセスを開発・実用化しました。クラスター・モデリングは、社会科学などの分野で頻繁に利用されるクラスター分析手法に基づいた手法で、数百万件の契約を数千件、あるいは数百件のモデルポイントに、効率的にモデル化することができます。**

ミリマンは、このプロセスを効率よく迅速に行えるようにするため、**クラスター・モデリングと呼ぶ新型の自動モデル圧縮プロセスを開発・実用化しました。クラスター・モデリングは、社会科学などの分野で頻繁に利用されるクラスター分析手法に基づいた手法で、数百万件の契約を数千件、あるいは数百件のモデルポイントに、効率的にモデル化することができます。このプロセスは、元の一件別モデルの結果を複数の経済シナリオ・経験シナリオにわたって精緻に再現できます。**

クラスター・モデリングは、一件別保有ファイル内の全契約を、少数の代表的モデルポイントに自動的に割り振ります。¹ 代表的モデルポイント数はユーザーが指定します。概念的には、各契約について他のすべての契約との距離を計算し、各契約の重要度を、その契約の規模と最も近い他の契約までの距離の積として定義します。その後、最も重要性の低い契約をその契約から最も近い他の契約に割り当て、割当先の契約の保有金額をグロスアップします。モデルの規模がユーザーの指定した大きくなるまで、このプロセスを繰り返します。

多くの会社では、適切なハードウェアを使用すれば今やこうした技術を使用しなくとも確率論的シナリオのプロジェクションができます。しかしながら、その一方でモデルポイントを高度に圧縮する手法も今後ますます重要になるでしょう。ネスティッド・ストキャスティック分析等の確率論的分析のニーズが高まるにつれて、数理モデルの担当者にとってこのツールが非常に役立つものになると確信しています。

1 ここでは「契約」という用語を使用していますが、既にある程度のモデルセルにマッピングされた保有ファイルを元ファイルとして使用することもあるでしょう。また、負債の代わりに資産のモデルポイント削減に適用する場合もあるでしょう。

はじめに

事実上、世界中のあらゆる生命保険会社が数理モデルを採用し、財務予測、商品のプライシング、エンベディッド・バリュー、リスク管理、責任準備金評価などに利用しています。会社により、あるいは目的に応じて、モデルは一件別かもしれませんし、ある程度圧縮しているかもしれません。一件別データからセル・モデルを構築する従来の手法は、科学的にできることはありますが、芸術的に行う部分もあります。

対照的に、社会科学などの分野で頻繁に利用されるクラスター分析手法に基づいた**クラスター・モデリング**は、ミリマンが開発・実用化した新型の自動モデル圧縮プロセスです。

クラスター・モデリングは、全契約を少数の代表的モデルポイントに自動的に割り振ります。代表的モデルポイント数はユーザーが指定します。概念的には、各契約について他のすべての契約との距離を計算し、各契約の重要度を、その契約の規模と最も近い他の契約までの距離の積として定義します。その後、最も重要性の低い契約をその契約から最も近い他の契約に割り当て、割当先の契約の保有金額をグロスアップします。モデルの規模がユーザーの指定した大きさになるまで、このプロセスを繰り返します。

MG-ALFA® リリース 6.7 では、このアルゴリズムを使用することができるようになりました。このレポートでは、クラスター・モデリングがどのように機能するか概説し、いくつかのクライアント・モデルに対する適用例を紹介します。この新しい手法を用いることで、確率論的モデリングやネスティッド・ストキャスティック・モデリングを実務化するプロセスを飛躍的に加速できるものと確信しています。

このレポートでは、**クラスター・モデリング**がどのように機能するか概説し、いくつかの**クライアント・モデル**に対する適用例を紹介します。

背景

目的によっては、モデルは一件別、あるいはそれに近くなる傾向があります。

- 法定または税基準の財務報告
- C-3 フェーズ 2 基準シナリオ

他の分野では、「伝統的」モデリング手法と呼んでいる数理モデリング手法により、類似の負債セルを圧縮します。これは、歴史的な理由によって、あるいは計算効率を上げようとして行われたのかもしれませんが、これが一般的であると思われる分野として、以下の分野などがあります。

- キャッシュフロー・テスト
- 資産負債モデリング
- 確率論的モデリング
- 一般会計原則（GAAP）評価と予測

こうしたモデルは、一般に予測や責任準備金評価の用途で用いるセルの数を 1 から 2 オーダー減らします。

コンピュータ・ソフトウェアおよびハードウェアの進歩により、単一シナリオであれば、ほとんどの会社で保険契約を集約せず、一件毎にモデルしたベースでプロジェクションができるようになっていました。また、中規模の保険会社であれば、適切なハードウェアとソフトウェアを備えることにより、シナリオ数にもよりますが、複数シナリオによる一件別プロジェクションも可能でしょう。

しかしながら、1990 年代に決定論的シナリオ手法に代わり確率論的シナリオを用いる方法がより一般的となったように、今まさにネスティッド・ストキャスティック・シナリオ手法への移行が始まりつつあります。

ネスティッド・ストキャスティック手法（あるいは、決定論的プロジェクションの中で確率論的プロジェクションを行う手法）は、責任準備金や資本を確率論的手法で設定しなければならない場合、複数シナリオにおける利益や剰余の分布を考察する際に有用です。これらは、国際財務報告基準（IFRS）、原則ベースのアプローチ（PBA）による責任準備金や資本、エコノミック・キャピタル、VA CARVM、SOP 03-1、FAS 133、公正価値、ダイナミック・ヘッジ、C-3 フェーズ 2 などがあります。

ネスティッド・ストキャスティック計算を行うと、数理モデルのランタイムが大幅に増加してしまいます。相当な規模の保有契約について、契約一件毎のネスティッド・ストキャスティック計算を行うのは非現実的でしょう。例えば、ダイナミック・ヘッジの分析に求められると思われる以下の計算を想像してみます。

- 年次報告サイクルの 30 年間のプロジェクション
- 1 百万負債モデル・ポイント
- 1000 シナリオ
- 各年末にダイナミック・ヘッジのリバランスを行い、各リバランスでは以下の要件で満期までのパス・プロジェクション
 - 30 年間のプロジェクション
 - ベースケースについて 100 パス、その各々に 20 ショック（上昇 10 と下降 10）、結果として各プロジェクション・ノードについて 2100 パス

この負債ポートフォリオに対する負債セルのプロジェクション総数は、以下の通りです。

$$\begin{aligned} & (30 \text{ 年間}) \times (1 \text{ 百万セル}) \times (100 \text{ パス}) \times (1 + 2 \times 10 \text{ ショック}) \times (1000 \text{ シナリオ}) \\ & = 63 \text{ 兆セル} \cdot \text{パス} \cdot \text{プロジェクション} \end{aligned}$$

一秒間に 1 万セル・パスのプロジェクションができる超高速システムを持っていると仮定します。それでも、約 63 億秒、つまり 200 年がかかります。これでは明らかに非実用的です。別のオプションを検討せざるを得ません。

モデリングのための伝統的アプローチ

上記の問題を解決する際、ランタイムを減らすことのできる方法は非常に限られています。

- ハードウェアとソフトウェアをより高速にする
- コンピュータの台数を増やす
- シナリオ数を減らす
- パスやショックの数を減らす
- リバランスの頻度を減らす
- セルを減らす

これらオプションのいずれもがランタイムを改善できるものの、一つの方法で全ての問題が解決できるものではありません。ここでは、最も効果が大きいと考えられるセルの削減に焦点を当てます。一般的に、数理モデルを構築する際には、いくつかのオプションが選択可能です。

- (1) 一件別
- (2) 契約月、プランコード、特性の似た保険契約者を集約
- (3) (2)に加えて、5歳または10歳さみの契約年齢、契約年、保険料払い込み方式を集約
- (4) (3)に加えて、リスク区分の統合やマイナーなプランの主要プランへのマッピングなどのモデリングを実施

アクチュアリーが、最初の3つのオプションを採用し、SAS、Access、プロジェクション用ソフトのモデリング・ツール、その他モデリング用ソフトを使用して、自動的にモデリングを行うことは容易です。しかし、これらのオプションは有用ではありますが、1/10に圧縮することも難しいでしょう。そして、次にアクチュアリーは、オプション(4)へと進みます。しかし、(4)を行う場合には下記のような欠点があります。

- マイナーなプランを主要なプランにマッピングするためには、モデリング担当者が各マイナーなプランについての知識を持っている必要があります
- マッピングのルールが主観的に決定され、自動化が難しい
- 新しいプランが作られたり、保有契約の特性が変わったりするたびに、マッピングのルールを見直して拡張する必要があります
- 伝統的なモデルの検証手法（基準日時点の責任準備金、保険料、キャッシュバリュー、保有契約高の実際値とモデル値の比較）は、モデルが複数のシナリオにわたってうまく機能することを必ずしも確認するわけではありません。単一のシナリオであっても、基準日のバランスシートの厳格な適合が、将来プロジェクションの良好なフィットを保証するものではありません
- 連生契約や、最低保証（GMB）があるためイン・ザ・マネーの度合いや過去の経歴によりモデルセルを分別する必要のある特定の商品種類については、モデリングのルールを決めて適用することは困難です

代替的アプローチ

クラスター・モデリングは、伝統的な数理モデリングの手法に比べて多くの長所があります。以下に例を挙げます。

- あらゆる商品種類に適用でき、負債だけではなく資産にまで拡張可能
- 所与のモデル対実績のフィットに対し、非常に高い圧縮比率が達成可能
- 容易に自動化が可能
- その後の評価日においても、モデリング手法は維持可能で、同じ方法で適用可能
- モデルフィットの評価基準や優先順位を変えるカスタマイズが可能
- 一件別保有契約や、モデル化した保有契約に適用し、更にモデル化した保有契約を作成可能
- 目的に応じて、モデルの詳細度を上げたり下げたりするため、モデルポイントの数を容易に調整可能
- モデルをリランセずに、モデル圧縮の水準を様々なレベルに変化させながらモデルフィットの分析が容易に可能

クラスター・モデリングは、元になる理論としてクラスター分析（多くの観察値をはるかに少数のクラスターに減少させる多くの分野で用いられる様々な手法）を利用して、各観察を n 次元空間の点に位置づけ、次に各次元における距離の平方和の平方根としての距離をみつけることで、距離測度を決定します。

クラスター・モデリングは、元になる理論としてクラスター分析（多くの観察値をはるかに少数のクラスターに減少させる多くの分野で用いられる様々な手法）を利用して、各観察を n 次元空間の点に位置づけ、次に各次元における距離の平方和の平方根としての距離をみつけることで、距離測度を決定します。

簡単に言うと、このプロセスは以下のように働きます。

1. ユーザーは、各契約に対する任意の数のロケーション変数を定義します。ロケーション変数とは、圧縮後のモデルがその値と近い値を再現できるようにしたいと希望する変数です。シナリオによって変動する項目については、単一シナリオによる値、もしくは少数のキャリアレーション・シナリオによる値を用いることもできます。
 - a. プロジェクション日現在の単位当たりの責任準備金、キャッシュバリュー、アカウントバリュー、保険料
 - b. 単位当たり GMB 保険金の現在価値
 - c. 当初 5 年間のプロジェクションでの単位当たり払い込み保険料総額
 - d. 単位当たり初年度負債キャッシュフロー
 - e. 単位当たり利益の現在価値 (PVP)
2. 所与の契約の重要性を示すための規模の変数を定義します。これは、他の条件が同じ場合に、大型契約が小型契約のように簡単にマップされないようにするために必要です。例えば、伝統的な規模の変数として、生命保険の額面金額や据置年金のアカウントバリューが挙げられます。
3. 契約を区分に分けて、プログラムが区分の境を越えてマッピングしないようにします。区分は、プランコード、契約年、GAAP 世代、その他必要と考えられるキー項目となるでしょう。区分を用いる理由は、以下の通りです。
 - おおよそ各区分の件数の平方和に比例するクラスター・モデリング実行のための計算時間を削減(グループ全体を区分しない場合の実行時間は、10 個の同じ規模の区分に分離した場合のほぼ 10 倍となります。仮に、いかなる場合にも一緒にマッピングできそうにない別個の契約に対応する複数の区分を想定すると、その結果は本質的に同じになります)

2 2002年のNorth American Actuarial Journalの記事に、Yvonne Chuehが、金利シナリオのサンプルを選択するために距離測度を用いた例を挙げています。この論文では、測定対象は契約ではなく任意の2つのシナリオ間の距離で、規模や区分といった概念は関係していませんでした。クラスター手法を何らかの形で用いている会社があるかもしれないと思いますが、公開された資料においては確認されていません。

- 報告、検証等の用途に応じて、一つの区分の契約を別の区分にマッピングせずにおきたい場合
- ロケーション変数だけでは、異なる区分にある契約を十分に区別できないと判断される場合

4. 圧縮後のモデルにあるべきセルの数を指定します。

5. プロセスは、n 個のロケーション変数により n 次元空間内での場所が特定できたものとして、任意の 2 つの契約の距離を n 次元平方和のアプローチを用いて定義します。このようにして、例えば、3 つのロケーション変数、Var1、Var2、Var3 を用いて、契約 1 と契約 2 の距離を以下のように測定することができます。

$$\sqrt{(\text{Var1}_1 - \text{Var1}_2)^2 + (\text{Var2}_1 - \text{Var2}_2)^2 + (\text{Var3}_1 - \text{Var3}_2)^2}$$

この定義では、ロケーション変数が適切に大きさを表さなくてはなりません。各ロケーション変数を関連する変数の大きさで加重した標準偏差によって除し、「標準化する」と便利でしょう。また、異なる距離変数を合わせて異なる優先順位がつけられるようウエイトを導入することもできます。

コンピュータの容量制限があるため、全ての距離がメモリーに残せるわけではありません。しかし実際には、最初に距離計算をした後は、再計算はそれほど必要ありません。

6. クラスタ・モデリングのプロセスにより、契約規模と最も近い契約までの距離の積算として、各契約の重要性を定義します。このようにして、小型の契約や他と非常に近い契約は他所にマッピングされる一方、大型の契約で他と離れているものは他所にはマッピングされないようになります。
7. このプロセスでは、各ステップで、重要性が低い契約を見極め、それに近い他所（マップ先契約）にマッピングをし、マップ先契約の大きさを調整します。ユーザーは、求めるモデルポイントの数になるまで、このステップを繰り返します。

この時点で、ユーザーが指定した目標数のクラスターだけが残ります。最後のプロセスでは、クラスター内の全てのセルの平均ロケーションに最も近い各クラスターの契約、すなわち、各クラスターの最も代表的な契約が特定されます。一般に、圧縮された保有ファイルにある各契約は、スケール・アップされた元の保有ファイルの契約で構成されています。（すなわち、論理的に合算すべき変数は元のセルの値をグロスアップしてセルグループ全体の値に合うようにし、その他の変数については元の契約からそのまま取得します。）³

3 クラスタ内のセルの値をスケールアップするよりも合計した方が好ましい場合があるかもしれません。例えば、モデル後の契約件数を実際の件数に合致させたい場合が考えられます。

グラフによる表示

下の 3 つの図が、クラスター・モデリング・プロセスを例示するのに役立ちます。これらの図では、2 次元で 2 つのロケーション変数だけを想定します。図 1 の散布図は、2 次元グラフの配置点により、各ロケーション変数の値を表します。それぞれの点の大きさは、契約の規模を表します。図 2 では、各契約がクラスターに割り振られています。最後に、図 3 では、適切にグロスアップされた大きさの 4 つのモデルポイントから成る 4 点モデルの結果を示しています。

図 1




図 2




図 3



潜在的利用法

上述したクラスター・モデリング・プロセスを用いて様々なモデルが生成できます。

- **中規模モデル**：モデルを一件別にランした場合に想定される結果を非常に忠実に追跡する、本質的には伝統的モデルの代わりのモデル。この場合、一区分当たり、かなり多数の区分やセルを使用します。ロケーション変数は、モデル作成に用いられる伝統的な変数（契約年齢、契約年、イン・ザ・マネーの度合い等）、あるいは上述された財務変数、またはその組み合わせとなるでしょう。この利用法は、伝統的モデリングに最も似ています。しかし、伝統的モデルでは、ユーザーが特定のセル数に照らしてモデルを評価し、その目標を達成するために様々な微調整（「このモデルプランはそれほど大きくないので、年齢幅とイン・ザ・マネーの幅をもう少し広げたらどうなるか・・・」）を試行錯誤しなくてはなりません。一方、クラスター・モデリング・プロセスでは、そういったトレードオフは、距離関数の設定を行う際に一度指定する必要があるだけで、後はプログラムが作業します。
- **小型モデル**：例えば、CTE などを見積もるのに十分な程度に、一件別の結果で想定される結果に近い結果を再現するよう設計されたモデル。しかし、あらゆるモデリング（特にオプション性の高い商品の場合）に歪みが出ます。また、その結果は、特にテイル・シナリオにおいて、大型モデルで可能なほど忠実な結果は期待できません。
- **超小型モデル**：例えば、非常に多くのシナリオをランして、その中から小型モデルでランさせる一連のサンプルシナリオを選択するために用いるモデル。同様に、主要な前提条件に対する感応度テスト結果から「デルタ」を測定する場合、通常は多数のシナリオを使用しなくてはなりませんが、その代わりに超小型モデルを使用することが考えられるでしょう。

比較的大型のモデルでは、様々な距離関数が比較的問題なく機能するでしょう。小型のモデルの場合には、距離関数の選択は自明の作業ではありません。何らかの工夫が必要ですし、関心のある変数がどの程度良好にフィットするかを確認するため、より大型のモデルに対する比較テストが必要です。適切な関数が見つかるまでには、こうした作業を繰り返す必要があるかもしれません。

伝統的な生命・医療保険モデルへの応用

まず、少数の変数のマッチングが、いかにプロジェクション全体のキャッシュフローの忠実なマッチングに影響するかを示す事例を検討してみましょう。

最初に、伝統的な日本の生命・医療保険契約の約 12 万セルのモデルから始めます。モデルには、伝統的商品の枠組みにある死亡保険金、災害疾病給付金、年金が含まれます。次に、以下の要素で構成される距離関数を用いて、より小型（200 セル）のモデルを作ります。

- 開始時責任準備金（ウエイト 1）
- プロジェクション初年度保険料（ウエイト 1）
- プロジェクション初年度保険金（ウエイト 1）
- 利益相当の現在価値（ウエイト 8）
- プロジェクション 10 年間の利益相当の現在価値（ウエイト 6）
- プロジェクション 20 年間の利益相当の現在価値（ウエイト 6）

モデリング・プロセスの確認として、元の 12 万セルの負債モデルと新しい 200 セルのクラスター・モデルの複数のロケーション変数の値を比較します。

図 4

200セルのクラスター・モデル対12万セルの伝統的モデル 生命・医療保険モデル (単位：百万円)				
	元	新	差	比率
開始時責任準備金	372,911	371,605	(1,306)	99.65%
初年度保険料	85,708	81,645	(4,063)	95.26%
初年度保険金	36,485	35,162	(1,322)	96.38%
利益の現在価値	154,467	154,444	(23)	99.99%
10年間の利益の現在価値	77,808	77,634	(174)	99.78%
20年間の利益の現在価値	119,924	120,001	77	100.06%


これらの変数が効果的にマッチしていることが、この図で確認できます。また予想通り、ウエイトの高い変数の方がよりよいフィットを示す傾向があることも記しておきます。

一方、クラスター・モデル対伝統的モデルの年ごとのキャッシュフローの結果をグラフに表すことは興味深いものです。いくつかのキャッシュフロー項目と分配可能利益の結果を図 5 に示しています。ここでは、全体のキャッシュフローだけではなく、年ごとのキャッシュフローも、クラスター・モデルは忠実に再現しています。（経過の浅いところで満期について多少のタイミングのずれがありますが、ネットすればほぼゼロになります。）

言い換えると、比較的単純な距離関数であっても、キャッシュフローおよびその他項目はかなり良好に再現できるのです。（しかし、小さな項目は、特にコントロールをしない場合、100%からは大きく異なる比率になります。）もちろん、モデルによっては、他のものよりも「うまく作用する」ものもありますので、テストが必要です。

図 5

5組の値を示しています。太線の組は分配可能利益で、それ以外は（初年度に大きい方から順に）保険料、解約返戻金、その他給付金、コミッションおよび経費です。



定期保険モデルへの応用

このプロセスのより具体的な例として、約 110 万件を保有する定期保険のブロックについて以下の例を考えてみましょう。このブロックについて、ロケーション変数とウエイトを以下のように定義しました。

- 開始時責任準備金（ウエイト 10）
- 1-5、6-10、11-15、16-20、21-25、26-30 年のキャッシュフロー相当の現在価値を、それぞれウエイト 4、全体をウエイト 10（キャッシュフロー相当は、保険料からコミッション、経費、死亡保険金を減算した値に等しい）
- 保険料（5 年毎の 6 グループに対して）および死亡給付金（5 年毎の 6 グループに対して）に、それぞれ逓減ウエイト 1、0.7、0.5、0.3、0.2、0.1

この会社が、契約世代ごとの保有価値を分析できるようにすべく、定期的に商品設計・構造を変更していたため、このブロックの区分の定義に契約年を用いました。また、主に時間の節約のため、保険金が一定である期間によっても区分しました。（保険期間が一定である期間が異なる契約へのマッピングはほとんど行われな

いと思われる。）

各ロケーション変数の一件別の値をファイルに残すため、完全に一件別のモデルを一度リランさせました。次に、10000 件と 300 件を目標モデル規模とする圧縮プロセスを実行しました。図 6 では、それぞれのモデル規模における特定の主要なロケーション変数のフィットを比較しています。

図 6

定期保険モデルフィットの分析 (単位: \$ 百万)					
変数	一件別 実績	10,000 モデル	10,000 差	300 モデル	300 差
開始時責任準備金	4,097	4,089	-9	4,076	-22
キャッシュフローの現在価値 (PVCF) 累計	2,156	2,156	0	2,163	6
保険金 1-5	2,378	2,321	-56	2,322	-56
保険金 6-10	2,749	2,701	-48	2,675	-74
保険金 11-15	2,455	2,417	-38	2,404	-51
保険金 16-20	1,573	1,553	-21	1,538	-35
保険金 21-25	997	983	-15	985	-12
保険金 26-30	547	537	-10	532	-15
保険料 1-5	3,255	3,187	-69	3,233	-22
保険料 6-10	3,318	3,271	-47	3,269	-49
保険料 11-15	3,309	3,270	-39	3,273	-36
保険料 16-20	3,313	3,290	-23	3,295	-18
保険料 21-25	2,706	2,689	-17	2,707	1
保険料 26-30	2,047	2,033	-14	2,077	29
PVCF 1-5	481	477	-4	482	1
PVCF 6-10	190	195	4	191	0
PVCF 11-15	278	280	2	276	-2
PVCF 16-20	537	536	0	539	2
PVCF 21-25	399	398	-1	397	-2
PVCF 26-30	271	271	-1	278	7

より高速かつより小型のモデルを作るためのデータを得るために、一件別にモデルをランしなければならないのでは、まるで意味がないように見えます。しかし、このモデルが確定したので、エコノミック・キャピタルの計算や ERM に、大型のモデルでは非実用的であったと思われる多数のシナリオをランすることができます。

この例として、図 7 では、5 つの異なるシナリオ（ロケーション変数の基準となっているベースシナリオを含む）下での税引き後利益の割引率 5% による現在価値を、両方のモデルの詳細度で比較しています。

図 7

定期保険モデル現在価値（税引き後利益） （単位：\$百万）					
シナリオ	一件別	10,000 モデル	10,000 差	300 モデル	300 差
ベースケース	4,309	4,304	5	4,295	14
死亡率×115%	3,649	3,656	-7	3,651	-3
死亡率×85%	4,978	4,960	18	4,945	33
失効率×115%	3,714	3,709	5	3,685	29
失効率×85%	5,251	5,246	5	5,266	-15

明らかに、モデルフィットは、いずれのモデルも非常に良好です。このことから、確率論的死亡率のシミュレーション、流行病分析、一連の経済シナリオのような、他の種類のシナリオ下でもモデルが上手く機能するであろうというある程度の自信が与えられます。しかしながら、モデルのセル数が減るに従ってフィットが幾分悪化するため、ランタイムの削減と引き換えにどの程度の変動が受け入れ可能かをユーザーが決定しなくてはならないでしょう。同様に、目的に応じて、保険料と保険金のウエイトを別々に増加させること、あるいは、責任準備金のランオフのパターンを反映したロケーション変数を含めることが考えられるでしょう。

変額年金モデルへの応用

このクラスター手法を変額年金（VA）モデルにも応用し、1000本の経済シナリオによるランを行いました。伝統的なマッピング手法をこの商品ラインに採用するのは、以下を含む多くの理由で手腕が問われます。

- 似たような属性の契約同士であっても、イン・ザ・マネーの率が明らかに異なるでしょう。
- 将来パフォーマンスを決定づける保険契約者の投資配分は、非常に細かくかつ柔軟に設定できます。

これらおよびその他類似の要因により、10対1あるいは20対1以上の圧縮率でフィットの良好な変額年金モデルを伝統的な手法を使って作成するのは困難です。しかし、ここでクラスター手法により21万件の保有ブロックから作った250セルのモデルは、840対1の比率です。

会社が使用するプランのグループに対応する7つの区分を使用しました。規模の変数は、開始時アカウントバリューです。

変額年金モデルは、多様な経済シナリオの下でうまく機能する場合にのみ有用です。多くの会社にとって、完全な一件別モデルを1000シナリオ、あるいはVA CARVMやC-3フェーズ2の目的で多くのシナリオにわたってランさせることは困難でしょう。しかし、適切なロケーション変数を設定するために、いくつかの代表的なシナリオを用いて一件別モデルをランさせることは可能です。今回は、以下の2つのシナリオを使用しました。

- 金利は横ばいとし、全ての株式のトータル・リターンは、将来にわたって年間15%とする
- 金利は横ばいとし、全ての株式のトータル・リターンは、将来にわたって年間マイナス5%とする

いくつかのシナリオでどのシナリオを用いてキャリブレーションするかは、ユーザーがフレキシブルに選択できます。ここでは、保険契約のパフォーマンスの限界を例示するため、この2つにしました。今回使用したロケーション変数とウエイトは、以下の通りです。

- 一般勘定のアカウントバリュー（AV）（ウエイト3）
- AG34に対応するため、株式以外（すなわち、債券やバランスファンド）の3つの異なるアカウント・ファンドにおけるAV（このモデルでは、10種類の特別勘定ファンドを使用しますが、その他の可能性としては、各ファンドをロケーション変数として入れることです。ウエイト6）
- 2つのキャリブレーション・シナリオそれぞれにおける死亡給付金、解約返戻金、一部引き出し、年金の現在価値（ウエイト1、ただし、年金は0.5）
- 2つのシナリオそれぞれにおける利益相当の現在価値（試行錯誤に基づき、+15にはウエイト10、-5にはウエイト15。後者の方がマッチさせるのが難しく、伝統的な使用法として悪いシナリオこそ懸念対象であるため）
- 2つのシナリオそれぞれにおける10年後と20年後のAV（ウエイト3）

特定の変数のフィットを図8に示しました。なお、ファンド間でシャッフルがあることにご注意ください。各ファンドに対するロケーション変数を分けて使用することで減らせるかもしれませんが、その代償として他の変数のフィットを悪化させる可能性があります。

図 8

シナリオ変数	一件別	VAモデルフィット (単位: \$百万)	
		250セルのモデル	差
開始時一般勘定AV	766	734	-33
開始時 SA1 AV	742	439	-303
開始時 SA2 AV	2,982	3,034	53
開始時 SA3 AV	2,165	2,537	371
開始時 SA4 AV	2,000	2,056	56
開始時 SA5 AV	1,938	1,881	-57
開始時 SA6 AV	2,119	2,131	12
開始時 SA7 AV	1,821	1,900	79
開始時 SA8 AV	1,532	1,304	-228
開始時 SA9 AV	1,240	1,192	-49
開始時 SA10 AV	284	354	70
+15 死亡保険金現在価値	3,463	3,406	-57
+15 解約返戻金現在価値	17,050	17,052	2
+15 一部引き出し現在価値	5,179	5,211	32
+15 年金給付金現在価値	559	462	-97
+15 利益の現在価値	1,256	1,240	-16
+15 10年後AV	5,305	5,360	56
+15 20年後AV	2,101	2,062	-39
-5 死亡保険金現在価値	1,846	1,758	-88
-5 解約返戻金現在価値	7,772	7,843	71
-5 一部引き出し現在価値	3,104	3,134	29
-5 年金給付金現在価値	273	202	-71
-5 利益の現在価値	-544	-540	4
-5 10年後AV	1,224	1,228	4
-5 20年後AV	40	38	-2

250 セルのクラスター・モデル、および、この会社の 9000 セルの伝統的モデル（更に上記にない 50 セルのクラスター・モデル）両方を 1000 本のシナリオでランさせてテストしました。この結果は、30 年後の最終サージの金額（百万ドル）を示しています。（30 年間の割引係数を考慮すると、最終サージの \$42M は、開始時 AV の 10bp の現在価値に相当します。）

図 9 では、9000 セルのモデルによる結果のサージの順に、3 つのシナリオによる結果（グラフのスケールを考慮し、添付の表からは最良の 20 シナリオを除く）を示しています。9000 セルのモデルを表す曲線は、このモデルの結果の基準として並べているためスムーズになっています。

250 セルのモデルよりもボラティリティーが高いものの、50 セルのモデルでさえ、9000 セルのモデルに近い結果を生成することが分かります。250 セルのモデルでも顕著な偏差があります。おそらく、(モデルフィットが良くない) 特定のファンドが異常に良好な、または貧弱なパフォーマンスをするシナリオによるものでしょう。しかしながら、このような偏差は、多数のシナリオで平均するとスムーズになります。




図 10 では、250 セルのモデルと 9000 セルのモデルによる様々な水準の CTE を比較しています。

図 10


VAモデル最終サンプラスのCTE
250セルのクラスター・モデルと9000セルの伝統的モデルとの比較
(単位: \$ 百万)

CTE 水準	250セル	9000セル	差
0%	\$965	\$1,058	\$93
50%	359	427	67
65%	159	218	59
75%	-28	21	49
90%	-548	-515	32
95%	-981	-939	42
99%	-1,909	-1,879	30

この場合、図 9 や図 10 から分かるように、250 セルのモデルは、9000 セルのモデルよりも体系的に平均 \$ 93M 低い結果になっています。(\$ 42M が 10bp に相当することを思い出してください。) このエラーのほとんどは、9000 セルの伝統的モデルにあります。元の一件別モデルとのテストにより、9000 セル・モデルの方が一件別モデルよりも平均約 \$ 70M 高いことが明らかになっています。

多くの場合、テイル部分が着目されると思われます。図 11 では、最悪ケース 100 シナリオ（9000 セル・モデルで評価）における 4 つのモデル（50 セル、250 セル、9000 セル、一件別）の結果を比較したものです。テイルの分析に利用するためには、50 セル・モデルでは明らかに一件別モデルからは大きく乖離しているものの、250 セルのモデルでは、9000 セルの伝統的モデルよりも実際に改善された結果になっています。

図 11



モデルの検証

どのようなモデル化であっても何らかの方法での検証が必要です。伝統的手法を用いたモデル化は、静的検証（バランスシート項目が実際の保有と近いことの検証）と、動的検証（損益計算書項目が実際の経験に妥当に近いことの検証）を用いて確認することが多くあります。伝統的なモデリング手法に対しては、複数のシナリオによるフィットのテスト（モデルを利用して得た異なる項目の結果を一件別の計算で求めた結果と比較すること）が相対的に少ないまま、その場その場の対応で利用されることが多いようです。これは、比較的件数の多いモデルなら、それほど大きくは外れないであろうという気安さがあるためです。

はるかに件数の少ないモデルの場合には、もっと多くのテストをすることが適切でしょう。こうしたテストの性質は、目的にもよりますが、いくつか一般的なガイドラインをお伝えします。ここでは、一件別モデルがテストに利用できるものの、全てのシナリオに対してランさせるのは非実用的であるものと仮定します。

まず、静的ベースでは、ロケーション変数のフィットを確認します。こうしたレビューをすることで、異なる変数をマッチさせることのトレードオフが見えてくるでしょう。結果的に、ロケーション変数に適用するウェイトを調整することになるかもしれませんし、圧縮したモデルで使用するセル数を変えることになるかもしれません。さらに、別のシナリオに対する利益の現在価値相当など（必ずしもキャリブレーションに用いるわけではない）他の変数の静的検証結果を導入してもよいでしょう。こうした変数を導入することで、より多くのシナリオを適用する場合にもモデルが正確であろうということが裏付けされます。

静的ベースで示されたフィットが十分であれば、そのモデルをランさせて、元のモデルから得た結果と比較します。

元のモデルの代わりに一般目的の新しいモデルを構築する場合、損益計算書およびバランスシートの全ての項目を全年度について比較すべきです。良好なマッチングを確実にするためには、利益の現在価値相当が不適切で修正が必要ではないか、あるいは開始時の値ではなくむしろ責任準備金のランオフのパターンの方にもっと注目した方がよいのではないかといったことを確認すべきでしょう。

多数のシナリオでランすることを目的としたモデルの正当性を確認するためには、少数のシナリオに対して一件別モデルをランさせます。（これらのシナリオは、目的に応じて、例えば、一件別モデルの計算結果に基づいて、分布全体からランダムにシナリオを抽出するのではなく、テイル・シナリオからサンプルを取得することが考えられます。）

どの程度テストと検証が必要かは、個々の目的、および、監査人、監督当局、その他モデルの正確性を立証すべき相手に対して証拠として何が必要とされるかによりますが、我々の予想は、初めてモデルをランさせた後に複数シナリオによるテストが必要になるのは、毎月とか毎四半期ではなく、必要に応じ適宜実施するというものです。静的テストは、新しいモデルを構築するたびに実施が必要になるものと思われます。

次のステップ

このアプローチには大きな可能性があると考えています。実例を積むことで、ロケーション変数とそれに結び付けられたウエイトの定義、そしてキャリブレーション・シナリオに必要な数がわかってくるでしょう。「正しい」選択は、もちろん個別の保有ブロックや目的によりますが、この手法が伝統的な数理モデリング手法に対して有利な点を有することは明らかです。

このアプローチは、負債以外にも利用できます。MG-ALFA のインターフェースは、適切なロケーション変数とシナリオを選択すると、この同じテクニックが資産モデリングにも利用できます。同じ手法を用いてシナリオを圧縮するための同様のインターフェースは、現在開発中です。

多くの会社では、適切なハードウェアがあれば今やこうした技術なしに確率論的シナリオのランができます。しかし、高度に圧縮したモデル開発のための手法は、今後ますます重要になるでしょう。ネスティッド・ストキャスティックの分析を含め、確率論的分析のニーズが高まるにつれ、このツールが数理モデルの担当者にとって非常に役立つようになると確信しています。

実例を積むことで、ロケーション変数とそれに結び付けられたウエイトの定義、そしてキャリブレーション・シナリオに必要な数がわかってくるでしょう。「正しい」選択は、もちろん個別の保有ブロックや目的によりますが、この手法が伝統的な数理モデリング手法に対して有利な点を有することは明らかです。



1301 Fifth Avenue, Suite 3800
Seattle, WA 98101
(206) 624-7940

www.milliman.com