

# 米国のディジーズ・マネジメントにおける予測モデルの活用

## 目 次

- |                                  |                         |
|----------------------------------|-------------------------|
| I. はじめに                          | III. 予測モデルの例—ACG-PM の概要 |
| II. ディジーズ・マネジメントにおける<br>予測モデルの役割 | IV. 活用事例                |
|                                  | V. 実践上の課題と予測モデル活用の意義    |

主任研究員 矢倉 尚典

## 要 約

### I. はじめに

米国では、ディジーズ・マネジメントの取り組みを効率的に運用する際に生ずる諸課題に対して、様々な対応策の試みを経て、実用的な解決が図られている。本稿では、それらの諸課題のうち、対象者の特定と階層化という課題に対する一つの解決策として米国で実務の用に供されている予測モデルの活用事例を取り上げ、実践上の課題と予測モデル活用の意義を明らかにする。

### II. ディジーズ・マネジメントにおける予測モデルの役割

ディジーズ・マネジメントにおける対象者の特定・階層化の重要性と、対象者の特定・階層化プロセスにおける予測モデルの役割を明らかにする。併せて予測モデルの類型についても簡単に説明する。

### III. 予測モデルの例—ACG-PM の概要

予測モデルの実例として、米国ジョーンズ・ホプキンス大学が開発した予測モデル（ACG-PM）の概要を述べ、その予測精度について考察する。

### IV. 活用事例

前章で紹介した ACG-PM をディジーズ・マネジメントのサービス提供の実務の用に供している Johns Hopkins HealthCare 社の導入経緯・運用体制を、活用事例として紹介する。

### V. 実践上の課題と予測モデル活用の意義

予測モデル導入に際して考慮すべき実践上の課題を整理し、予測モデル活用の意義を明らかにする。

## I. はじめに

損保ジャパン総合研究所では、ディジーズ・マネジメントについての調査・研究を継続して行っている<sup>1</sup>。ディジーズ・マネジメントは「糖尿病、喘息、心臓病等の慢性疾患の患者集団と、彼らを担当する医師その他の医療従事者の双方を主たる対象者として、それぞれの疾病に固有の手法で働きかけを行い、質の高いヘルスケアを低コストで提供できるようにする」取り組みである。この取り組みを効率的に進めるにあたり、いくつもの課題が存在する。例えば、誰に働きかけるのか（対象者の選定）、どのように働きかけるのか（対象者に合わせた働きかけ手法の選択および実施）、誰が働きかけるのか（人材の確保）、効果の測定（評価）等である。ディジーズ・マネジメントのサービス提供が事業化されている米国では、産業として確立していく過程のなかで、これらの諸課題について、様々な対応策の試みを経て、実用的な解決を図りつつ今日に至っている。

本稿では、これらの諸課題のうち、大きな母集団の中から合理的・合目的に働きかけの対象者をいかに選定するか（対象者の特定と階層化）という課題に焦点を当て、この課題に対する実用的な解決として、米国のディジーズ・マネジメントにおいて実務の用に供されている予測モデルの具体的活用事例を取り上げる。本稿の目的は、予測モデルの具体的活用事例を理解することを通じて、予測モデルをどのように活用すべきか、予測モデル活用における実践上の課題を明らかにし、予測モデル活用の意義を明確にすることである。

本稿第II章では、ディジーズ・マネジメントにおける対象者の特定・階層化の重要性および予測モデルの役割を、第III章で予測モデルの実例を簡単に解説した上で、第IV章で米国における予測モデルの具体的活用事例を紹介する。最後に、第V章で実践上の課題を整理し、予測モデル活用の意義を明らかにする。

なお、予測モデルの具体的活用事例を理解するにあたって、予測モデルの役割・実例から解説することがわかりやすいと考え、第II章、第III章を配したが、この部分は参考文献1に第2章第3節として掲載された拙稿「ヘルスサポートプログラムと予測モデル」をベースとしていることをお断りしておく。

## II. ディジーズ・マネジメントにおける予測モデルの役割

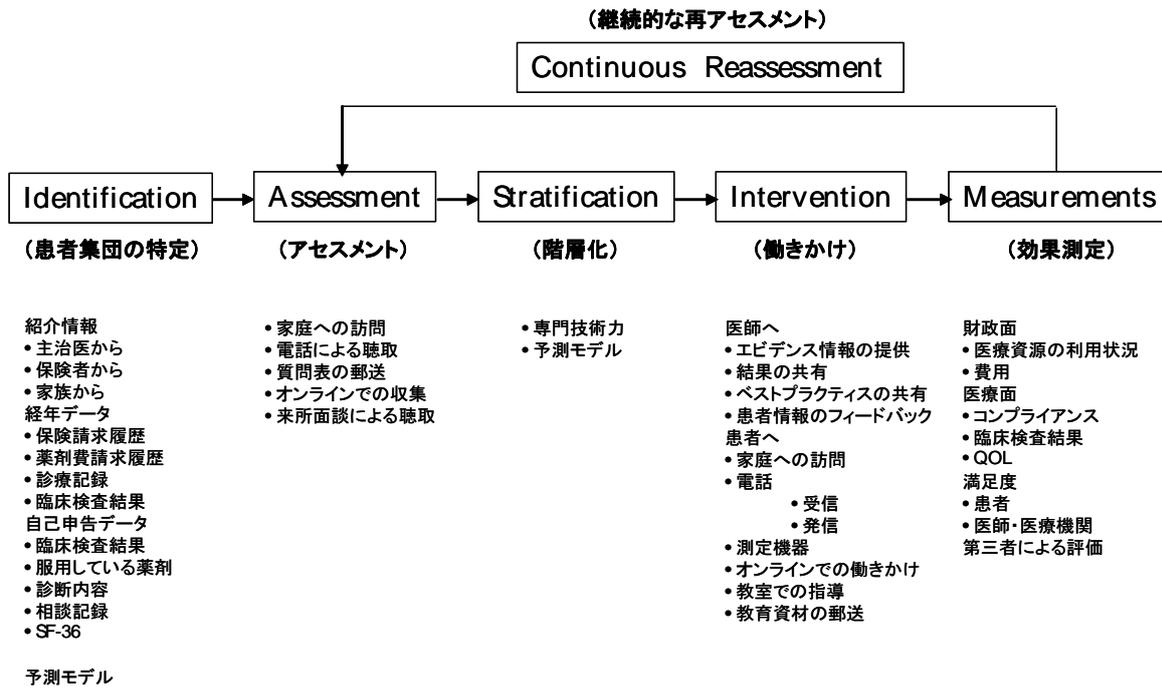
### 1. ディジーズ・マネジメントにおける対象者の特定・階層化の重要性

ディジーズ・マネジメントを実際に取り組むプログラム（以下、「DMプログラム」とする）の基本プロセスと主な活動は《図表1》のとおりであるが、その特徴は、全員に同じ働きかけを一律に行うのではなく、対象者の特定（Identification）、階層化（Stratification）というプロセスを経て、働きかけ方の強度・頻度を調整していることである。

ディジーズ・マネジメントにおいて働きかけの強度・頻度を調整していることは、人数的には比較的小さな集団が医療費の大部分を費消しているという知見（パレートの法則）に基づき、有限で高価なヘルスケア資源を効果的・効率的

<sup>1</sup> これまで、機関誌「損保ジャパン総研クォーターリー」第41号で「米国ヘルスケアにおける新たな潮流—米国における Disease Management の発生と展開—」（2002年10月）を公表したほか、損保ジャパン記念財団主催「欧米のヘルスケアビジネスおよびディジーズ・マネジメント研究会」の事務局を務め、損保ジャパン記念財団叢書で研究成果およびシンポジウム講演討議録を公表してきた。損保ジャパン記念財団叢書第65号「米国におけるディジーズ・マネジメントの発展」（2003年6月）、第67号講演討議録「ディジーズ・マネジメント発展の可能性と課題」（2004年1月）、第72号講演討議録「これからの生活習慣病対策のあり方を探る」（2006年7月）。また、ニュースレター「ディジーズ・マネジメント・レポーター」を2004年3月に創刊し、わが国におけるディジーズ・マネジメントの取組事例を紹介してきた。

《図表 1》 デイジーズ・マネジメントの基本プロセスと主な活動



(出典) 損保ジャパン総合研究所作成

に投入しようとする意図していることのためである。パレートの法則は、一国の富の80%が20%の人口に集中していることを観察した20世紀初頭のイタリアの経済学者 Vilfredo Pareto が起源であるが、経済学以外の分野にも一般化され、米国においてはヘルスケアコストの構造に関する理解においても適用されて、人口のおおよそ20%が直接的な医療費のおおよそ80%を消費すると考えられている。この認識に基づき、DMプログラムでは、働きかけるべき比較的小人数の集団を特定し、階層化して投入する資源を調整することにより効果的・効率的な運営を実現しようとしているのである。

働きかけるべき比較的小人数の集団の特定・階層化においては、働きかけるべき対象者を適切に選び出して階層分けができているかが、重要なポイントとなる。すなわち、選び出し方が粗く、働きかけるべき対象者以外の人も含めて選び出してしまうと、働きかけるべき対象者以外

の人にも働きかけを実施することになり、資源を不効率に投入することになる。また、逆の意味で選び出し方が粗く、働きかけるべき対象者の選び出し漏れが多いと、働きかけて効果を出すべき機会をみすみす逃していることになる。

例を挙げて説明する。例えば、上記のように比較的少人数の集団が医療費の大半を費消していることから、働きかけの対象者として、翌年の医療費が高額となる上位10%の人を選び出す、すなわち、母集団が1,000人で構成されているとして、翌年の医療費の高い順に並べたときの1番から100番までになるであろう人を選び出すことを想定しよう。今仮に使える情報が何もないとすればどうするだろうか。何も情報がない、すなわち、どの人についても翌年上位10%に入るかどうかについて同じ情報しかないため、無作為に(ランダムに)100人を選んだとする。この場合の選び出し結果にどの程度期待できるだろうか。全員に同じ情報

しかないのだから、誰についても翌年上位 10% に入る確率は 0.1 である。選んだ 100 人のうち平均的には 10 人しか翌年上位 10% の人が含まれず、90 人は翌年上位 10% でない人が含まれる。この 100 人に資源投入しても効果が期待できるのは 10 人で、90 人は資源投入しなくてもよかった人である。また、これは、逆に翌年上位 10% の人の平均的には 9 割、90 人が選ばれずに残ることを意味しており、効果が期待できたはずの人に資源投入できなかつたことになる。無作為に選んだ 100 人がすべて翌年上位 10% の人である確率は、 $(100/1,000) \times (99/999) \times (98/998) \times \dots \times (1/901)$  となり、0.1 の 100 乗よりさらに小さな値で、もうほとんど期待できない。

上記の例で、DM プログラムを効果的・効率的に運営するために、対象者の特定・階層化がいかに重要であるが理解していただけたらと思う。次に、この課題に対して、ディジーズ・マネジメントが先行発展した米国ではどのような実用的な解決が図られたのかについて述べる。

## 2. 対象者の特定・階層化における予測モデルの役割

前節で例に挙げた無作為に選ぶという方式は理解を進めるための極端な例であるが、もう少し精度のよい選び出し方はないものかということに誰しもが考え、正確な予測は不可能だとしても、翌年医療費が高額になりそうな人とそうでない人を見分けるために使えそうな情報を少しでも集めようとするだろう。例えば、各人の前年の医療費データが利用可能であったとすると、前年医療費上位 10% の人を働きかけ対象とするという方式を取ることも考えられる。人工透析の必要な腎臓機能障害のように慢性疾患を持っている人は翌年も高額な医療費がかかるだ

ろうから、前年の医療費を基準に選び出せば、まったく無作為に選び出すよりは確からしいだろうという考え方である。しかし、前年は医療費が高額であったが翌年はそうではなくなる人、前年は医療費が高額ではなかったが翌年は医療費が高額となる人が多く見られ、前年医療費上位 10% の人と翌年医療費上位 10% の人を比較すると相当な入れ替わりがあることは想像に難くない。当研究所が日本国内のいくつかの集団について調査した結果(未公表)でも、約 35,000 名の集団で医療費上位 20% の人約 7,000 名のうち 45% が入れ替わった事実が確認されている。

判断材料となる情報をもっとたくさんあれば、より確からしい結果が得られる可能性は高くなるだろう。例えば、母集団全員に対して詳細な調査(検査)を実施し、その結果を判断材料とすれば、より確からしい結果が得られるだろう。しかし、母集団全員に対して詳細な調査(検査)を実施することは実用的な解決であろうか。母集団全員に対して詳細な調査(検査)を実施するには多大な費用の投下が必要となる。ディジーズ・マネジメントのサービス提供を事業化する前提で考えれば、費用対効果の側面も踏まえ、実用的な解決を図ることが必要とされる。

米国の DM プログラム運営において、効果的・効率的な対象者の特定・階層化という課題に対する実用的な解決として使用されているツールが Predictive Model と呼ばれている予測モデルである。米国では、様々な実践的な試行錯誤を経て、また、数理統計理論とコンピュータ科学の進展を受けて、単に前年の医療費だけでなく、母集団構成員の管理データ(年齢・性別等)や医療費請求データ、処方薬剤給付データといったすでに収集済みで利用可能なその他の各種情報も含めた大量のデータに対してデータ・マイニングや各種の数理統計解析等を行っ

た結果を活用した予測のための数理モデルが各種開発され、DMプログラムにおける対象者の特定・階層化というプロセスの効果的・効率的な運営に活用されている。

この予測モデルは、一般的には、各個人の過去もしくは現在の状態を表す数値を入力し、各個人の将来の状態を予測した指標を計算する数理モデルである。各個人の状態を示す情報を予測モデルに入力することにより計算された予測指標の数値の大きさに着目して、働きかけの対象とするかどうか、どの階層に分類するか等を決定していくという形で活用される。効果的・効率的な対象者の特定と階層化という課題に対して、すでに収集済みのデータを用いて予測指標を算出し、算出された予測指標に着目して、ある程度対象者の絞り込んだ上で詳細な情報収集を実施するという実用的な解決を図っているのである。

### 3. 予測モデルの類型

多くの試行錯誤の結果、様々な予測モデルが開発されている。それらの予測モデルは次の視点で分類整理することができる。

#### (1) 何を予測するか

将来の状態として何を予測するか、すなわち、予測指標を何にするかは、DMプログラムの内容によって異なる。例えば、翌年の医療費の実額もしくは要する医療資源の大きさの相対値を予測指標とするモデルもあれば、翌年に入院が発生する確率を予測指標とするモデルもある。

#### (2) 説明変数

予測の基となる説明変数として、傷病名や治療内容を主として用いているモデルもあれば、処方されている薬剤を主として用いているモデ

ルもある。どのようなデータがすでに収集されており利用可能かの環境がDMプログラムの実施主体により異なることもその要因である。また、使用できるデータの精度、信頼度も問題とされている。例えば、傷病名については医師によりどの傷病名コードとするか判断が分かれることも考えられる。処方薬剤については処方された薬剤の標準コードを記録するので、コーディングの揺らぎが少ないと考えられる。

#### (3) モデル作成の技法

伝統的には、多変量解析の諸手法、例えば、線形の重回帰分析やロジスティック回帰分析といった手法を使用して作成したモデルが中心であったが、近年発展の著しい計算機科学・ニューラルネットワーク技術を駆使したモデルを開発している事業者もある。モデルの開発主体がそれぞれの創意工夫を凝らして果敢に挑戦している状況である。モデルによる予測の精度や検証の度合いにおいて、どれか一つの技法が他を凌駕しているという情報は無い。

### Ⅲ. 予測モデルの例－ACG-PMの概要

本章では、予測モデルの実例としてACG-PMの概要を紹介する。ACG-PMは、米国ジョンズ・ホプキンス大学が開発したACG (Adjusted Clinical Groups) とよばれる健康状態の分類カテゴリーをベースとしたモデルで、前章で述べた予測モデルの類型で整理すると、翌年どれくらいの医療資源を要するようになるかの相対指標および翌年ハイリスク・グループとなる確率を予測するモデルで、説明変数としては傷病名や治療内容を主として用いており、モデル作成技法としては伝統的な回帰分析を使用したモデルである。モデルの内容および予測精度の評価結果について、比較的豊富に情報が公開されて

いることから、本稿では ACG-PM を取り上げることとした。

## 1. ACG の概要

ACG とは、米国ジョンズ・ホプキンス大学が開発した「病気の状態・年齢・性別で定義された健康状態に関する分類カテゴリー」である<sup>2</sup>。ACG を利用して医療費推計を行うソフトウェア “The Johns Hopkins ACG® Case-Mix System” がジョンズ・ホプキンス大学ブルームバーグ公衆衛生大学院からリリースされている。従来、このソフトウェアには予測モデルに特化した機能は組み込まれておらず、ACG にグルーピングするアルゴリズムを活用してユーザーが予測モデルをカスタマイズしていたが、2003 年 4 月にリリースされた Version 6.0 から “The acgPM” と呼ばれる予測モデル（以下、「ACG-PM」とする）の機能が追加されている。

ACG による分類は以下のように行われる。まず集団の各人の医療費請求データに記録された ICD9-CM のすべてのコードに対して 32 個の ADG（診断名グループ分類 Adjusted Diagnosis Groups の略）のどれかひとつを割り振り、次に各人に割り振られた ADG の組み合わせおよび年齢・性別を基にその人が 93 の ACG の分類カテゴリーのどれに属するかを決定する。ACG はカテゴリー間相互に排他的である（各人は 93 個のカテゴリーのいずれか 1 つに分類され、同時に 2 つ以上のカテゴリーに分類されることはない）という特徴を持っている。

## 2. ACG-PM の概要<sup>3</sup>

予測モデル ACG-PM では 2 種類のリスク予測指標 (probability score と predicted resource index) が算出される。probability score はその人が翌年ハイリスク・グループとなる確率であり、predicted resource index はその人が翌年どれくらいの医療資源を要するようになるかを相対値で表わしたものである。

ここで言う「ハイリスク」とは、各人別に予測された翌年の医療費がその集団における上位 5%以内に入ると予想される人と定義されている<sup>4</sup>。疾病別に（あるいは、ある特定の疾病について）ハイリスクとなるアルゴリズムを設定しているのではない。もちろん、ACG をベースにしているので、ハイリスクと分類されたグループの疾病を見ていけば、例えばハイリスクで糖尿病を持っている人という識別は可能である。

このモデルにリスクファクターとして組み込まれている変数は次の 7 つである。

- (1) 年齢（新生児から 64 歳までの 7 つの年齢区分）
- (2) 性別
- (3) ACG (各人個別に判定された ACG の分類カテゴリーに加え、罹患率の大きさによる 3 区分)
- (4) “hospital dominant” マーカー（ケアは様々な形態で提供されうるが病院でのケアが主要である診断名を示すマーカー）
- (5) 妊娠の有無
- (6) 薬剤費水準（過去の薬剤費履歴に基づく 5 区分）

<sup>2</sup> ACG の概要については、ジョンズ・ホプキンス大学のサイト<<http://www.acg.jhsph.edu/what/what.html>> visited May 29, 2003 の情報を中心にまとめた。

<sup>3</sup> The Johns Hopkins ACG® Case-Mix System Version 6.0 Release Notes <[http://www.acg.jhsph.edu/library/pdf\\_docs/Doc60/releasenotes60.pdf](http://www.acg.jhsph.edu/library/pdf_docs/Doc60/releasenotes60.pdf)> visited July 10, 2003.

<sup>4</sup> この 5%という水準は、各種の水準でテストを重ねた結果、モデル開発目的で設定したものであり、ユーザーがハイリスクの定義として他の水準（例えば、上位 1%等）を採用することを妨げるものではないとリリースノートでは説明されている。

(7) EDC (Expanded Diagnosis Clusters : 影響の大きな慢性症状を示す区分)

モデルの開発に際しては、米国の複数の健康保険プランの 200 万人以上のデータを split half approach<sup>5</sup>で使用し、統計手法としては、probability score にはロジスティック回帰モデルを、predicted resource index には通常の最小二乗法による重回帰モデルを適用した。

現在のモデルの予測対象は非高齢者 (65 歳未満) であり、probability score と predicted resource index は、総医療費を対象にしたものと薬剤費のみを対象にしたものの 2 セットが用意されている。

Probability score で各人が翌年ハイリスク・グループとなる確率が算出されるから、probability score が例えば 0.4 以上の人は誰か、何人いるか、また、0.6 以上とすればどうかといったシミュレーションを行い、そのときの該当者の疾病による分類集計や医療費の相対指数

の集計ができる。具体的な集計例として Version 6.0 Release Note に《図表 2》に示した表が掲載されている。

3. ACG-PM の予測精度

ACG-PM の予測精度に関し、Version 6.0 Release Note では次のように説明されている。

ACG-PM は疾病ごとにハイリスクを予測しているのではないが、ハイリスク予測により抽出された者を疾病ごとに分類集計して、それぞれの疾病の患者全体に対してハイリスクと予測された者の割合として《図表 3》を示し、ACG-PM で抽出した場合の方が、前年度ハイコストであったという条件で抽出した場合 (以下、Prior Cost を略して PC 方式という) に比べ、DM プログラム対象疾病の者 (言い替えると、DM プログラムにより介入効果の期待できる疾病の患者) が多く含まれるので、DM プログラム対象者特定の精度が PC 方式より優れている

《図表 2》 ACG-PM による予測結果集計例(1) :

疾病分類・予測確率の大きさによる分類ごとの人数および医療費相対指数の分布

Disease Category	Total	Number of Cases			Mean Predicted Relative Resource Use			
		Probability Score Category			Probability Score Category			
		≥0.4	≥0.6	≥0.8	<0.4	≥0.4	≥0.6	≥0.8
Arthritis	17,679	940	463	172	2.18	6.82	9.31	15.71
Asthma	27,863	764	386	136	1.43	6.75	9.29	14.85
Diabetes	16,991	1,307	716	345	2.67	7.59	10.62	17.36
Hypertension	50,122	2,064	1,011	457	2.06	7.25	10.27	17.57
Ischemic Heart Disease	9,330	971	514	242	3.27	7.40	10.35	17.33
Congestive Heart Failure	1,634	460	292	184	5.17	8.81	12.26	19.61
Hyperlipidemia	31,240	1,170	529	186	1.97	7.13	9.49	15.46
Low Back Pain	61,980	1,493	723	279	1.76	6.53	8.77	14.27
Depression	10,190	599	298	113	2.09	6.63	9.03	14.30
Chronic Renal Failure	742	308	253	183	13.11	16.48	19.40	25.21
COPD	6,204	545	301	147	2.58	7.71	10.24	16.68

(出典) The Johns Hopkins ACG Case-Mix System Version 6.0 Release Note, Table 5

<sup>5</sup> 対象データをランダムに 2 グループに分け、一方をモデルの作成に使用し、他方を作成したモデルの検証に使用する方式。

《図表 3》ACG-PM による予測結果集計例(2) :  
 ハイコスト集団と特定された者の割合の比較 (疾病別)

Condition	Percentage of High-risk Cohort		比率
	acgPM	Prior Cost	
Hypertension	37.91	26.96	<b>1.41</b>
Low Back Pain	27.42	17.19	<b>1.60</b>
Diabetes	24.00	13.39	<b>1.79</b>
Ischemic Heart Disease	17.83	22.72	<b>0.78</b>
Arthritis	17.26	13.33	<b>1.29</b>
Lipoid Metabolism	21.49	13.30	<b>1.62</b>
Congestive Heart Failure	8.45	7.42	<b>1.14</b>
Asthma	14.03	6.87	<b>2.04</b>
COPD	10.01	7.05	<b>1.42</b>
Depression	11.00	4.85	<b>2.27</b>
Chronic Renal Failure	5.66	5.40	<b>1.05</b>

(出典) The Johns Hopkins ACG Case-Mix System Version 6.0 Release Note, Table 3  
 ただし、比率欄は損保ジャパン総合研究所が試算し追加した。

《図表 4》ACG-PM による予測結果集計例(3) : 感度・陽性的中率の比較

Probability Score Threshold	Percentage of Population	acgPM		Prior Cost*	
		Sensitivity	PPV	Sensitivity	PPV
.4	1.33%	0.16	0.59	0.12	0.46
.5	0.89%	0.12	0.66	0.09	0.50
.6	0.63%	0.09	0.72	0.07	0.54
.7	0.42%	0.06	0.76	0.05	0.57
.8	0.25%	0.04	0.80	0.03	0.62
.9	0.10%	0.02	0.84	0.01	0.69

\* Based on a validation sample of approximately 410,000 covered lives.

\* Prior cost cohorts were chosen to the same size as acgPM high-cost cohorts, i.e., if selecting cases with an acgPM probability score of .7 or higher yielded 100 predicted high-risk patients, the prior cost comparison would be the 100 cases at the highest Year 1 cost.

(出典) The Johns Hopkins ACG Case-Mix System Version 6.0 Release Note, Table 2

とリリースノートは主張している。

また、《図表 4》を示し、Sensitivity (感度 : 真の人全体のうち真として抽出された人の割合)、Positive Predictive Value (陽性的中率 : 真として抽出された人のうち事実真であった人の割合。以下、「PPV」とする)とも、ACG-PMの方が PC 方式より優れているとリリースノートは主張している。

上記が Version 6.0 Release Note で公表されている内容であるが、この内容をよりビビッドに理解できるよう、示された数値を基に、人数規模 1 万人の集団の場合、予測結果はどのような人数分布になるのかを当研究所で試算した。以下、その結果を示して、予測精度について考察する。《図表 4》の確率閾値 0.4 の場合の諸数値を当てはめて、人数規模 1 万人の集団におけ

《図表 5》 ACG-PM のパフォーマンスのイメージ

確率閾値=0.4 の場合		翌年のActual		
		High Risk	Others	Total
Predicted	High Risk	②×0.59 78	55	②=①×0.0133 133
	Others	422	9,445	9,867
	Total	①×0.05 500	9,500	① 10,000

検算 : Sensitivity = 78/500 = 0.16

(出典) 損保ジャパン総合研究所作成

る人数分布を試算した結果は《図表 5》のとおりである。

すなわち、ハイリスクの定義は上位 5%だから、1 万人に対してハイリスク者は 500 人である。《図表 4》によれば、例えば、確率閾値=0.4 の場合、抽出される人数比率は 1.33%だから、ACG-PM による抽出結果は 133 人であり、また、その PPV は 0.59 だから、抽出された 133 人のうち真にハイリスクである者は 78 人ということである。つまり、抽出された者 133 人のうちハイリスクでない者が 55 人含まれており、また、ハイリスク者 500 人のうち 422 人は抽出されていないということである。

ここで留意すべき点は、PPV の値をどう理解するかである。すなわち、PPV=0.59 でハイリスクでない者が 41% (55 人) も含まれているからモデルの予測精度が悪いと考えるべきなのかどうかという点について補足しておく。数理統計解析に基づく予測モデルでは、基本的に「誰々はハイリスクになる、誰々はハイリスクにならない」と決定論的に予測できるものとは考えておらず、「誰がハイリスクになるかは不確実 (各人ともハイリスクになる確率を持っており、その大きさは各人によって異なる)」と考えている。モデルにより各人のハイリスク確率を

算出するわけであるが、モデルの確率予測が正しい場合でも、仮に、ハイリスク確率 0.8 の人が 63 人、ハイリスク確率 0.4 の人が 70 人、他の 9,867 人はハイリスク確率が 0.4 未満であったとする。予測確率 0.4 以上の 133 人について期待値通りに実現した場合、133 人に対するハイリスク発生数の期待値は  $63 \times 0.8 + 70 \times 0.4 = 78$  で、PPV=0.59 は期待値が実現しただけということになり、予測精度の問題ではなく、もともとの確率分布の問題ということにもなる。また、ハイリスクでないと言われた集団 9,867 人についても、ハイリスク者が 422 人発生しているが、発生率の標本平均は 0.0428、有意水準 5%の信頼区間は[0.0388, 0.0468]であり、ハイリスク確率が 0.4 未満と予測されている分布にもよるが、予測精度の問題は見られないかもしれない。ただし、PPV を比較する場合、すなわち、同じ集団に対して A 方式を適用した場合と B 方式を適用した場合を比較するならば、PPV の大きい方が優れていると判断することができる。

なお、一般的に、確率閾値を高く設定するほど PPV は高くなり、抽出した人が真にハイリスクである割合は向上するが、抽出される人数が小さくなるので、Sensitivity は小さくなり、真にハイリスクでも抽出されない割合が高くな

るというトレード・オフの関係が存在する。《図表 4》を見ればその状況が示されているので確認されたい。

さて、PC 方式の場合にはどのような人数分布となるのだろうか。《図表 4》で示された PC 方式の場合の数値を用いて、同様に人数規模 1 万人の集団における人数分布を試算してみると《図表 6》のとおりとなる。

PC 方式で、すなわち、前年度医療費の高かった人から順に 133 人を抽出した場合、 $PPV=0.46$  であるから、そのうち翌年ハイリスクである者は 61 人となり、平均的にはハイリスクでない者が 72 人含まれることになる。

翌年ハイリスクとなるものを選び出すことについて、ACG-PM では 78 人であるのに対して、PC 方式では 61 人であり、ACG-PM の方が 17 人多くハイリスク者を抽出できている勘定で、それが ACG-PM の方が予測精度が優れているとの主張の根拠である。この結果をもって十分な予測精度と見るかどうかについてはいろいろな判断があろう。Version 6.0 Release Note には、「リスク・ファクター・データが限られているから、モデルの予測能力にも限界がある。」との記述もあり、今後さらにモデルの改良の余地

があるとの見解が示されている。

#### IV. 活用事例

本章では、米国の DM プログラムにおける予測モデルの導入・活用事例として、Johns Hopkins HealthCare 社（以下、JHHC と略す）の例を紹介する<sup>6</sup>。JHHC は前章で概説した予測モデル ACG-PM を実務運用しており、その導入経緯・運用体制に関する情報が論文、セミナー資料等で比較的詳細に公表されていることから取り上げることとした。

##### 1. JHHC とは

JHHC は、ジョンズ・ホプキンス大学とジョンズ・ホプキンス・ヘルス・システム社により設立された、患者管理およびヘルスケア情報システムサービスを提供する会社である。JHHC の主たる顧客である健康保険プラン<sup>7</sup>には、Johns Hopkins Employer Health Program（ジョンズ・ホプキンス大学職員のための健康保険プラン：被保険者数 56,000 人）、Priority Partners（メリーランド州から指定を受けメディケイド対象者に医療サービスを提供しているマネージドケア型の健康保険プラン：被保険

《図表 6》PC 方式のパフォーマンスのイメージ

		翌年のActual		
		High Risk	Others	Total
Predicted	High Risk	$② \times 0.46$ 61	72	$② = ① \times 0.0133$ 133
	Others	439	9,428	9,867
	Total	$① \times 0.05$ 500	9,500	① 10,000

検算：Sensitivity =  $61/500 = 0.12$

(出典) 損保ジャパン総合研究所作成

<sup>6</sup> Innovative Strategies in Predictive Modeling セミナー（2007年2月、米国フロリダ州オーランドで開催）における、Linda Dunbar 氏のプレゼンテーション“Enhance Predictive Modeling by Improving Current Models that Create Better Solutions”の資料による。

者数 116,000 人)、および Uniformed Services Family Health Plan (メリーランド州周辺に居住する陸海空軍退役者・家族等を対象に国防省所定の医療サービスを提供しているマネージドケア型の健康保険プラン：被保険者数 23,000 人)がある。JHHC が提供しているマネジメント・プログラムは、End Stage Renal Disease (末期腎不全)、Behavioral Health (行動衛生、行動障害)、Substance Use (薬物乱用)、End of Life Care (終末期ケア)、リハビリテーション、Complex Medical Needs (複合医療ニーズ)、Children with Special Needs (特殊なニーズを持った子供のケア)、HIV/AIDS、Guided Care (ガイド役を付けたケア)、Partners with Mom (妊産婦ケア)、Cardiovascular/Diabetes TeleWatch (心血管疾患／糖尿病の遠隔モニター)といった各種のものがある。

## 2. 背景

従来、JHHC におけるディジーズ・マネジメントの対象者の選定は、前年の医療費額および utilization (医療資源利用) 管理部門、医療サービス提供者、州政府の健康部局等からの依頼情報をもとに進めてきた。その結果、個々の事案を担当する働きかけの担当者が担当件数をコントロールするために慎重な姿勢で対応し、急性発症事案のフォローはされたが、継続的な働きかけを要するニーズは明確に把握されないきらいがあった。

前章で触れた PC 方式のような、観測された実績値に対して閾値を設定して振り分けるモデル (以下、「閾値モデル」とする) は対象者選定には不適當で、資源の誤った配分、不効率、改

善機会の喪失に繋がり得るとする論文や ACG-PM を始めとする予測モデルは閾値モデルより優れたパフォーマンスを示すとする論文が多数発表されるようになってきた。それに伴い、ディジーズ・マネジメントの対象者とすべきハイリスク者を (特に高額医療費が発生する前に) 特定する手段として予測モデルは、単に概念的な理想という認識から脱し、実用に供することが検討されつつあったが、最良の予測モデルと雖もまだかなりの量の偽陽性 (ハイリスクと予測されたが、実際にはハイリスクではなかったケース) を含むものとの懸念も大きかった。偽陽性は、実際にはハイリスクとならないケースをハイリスクとして選び出してしまうため、不必要な介入に資源等を投入してしまう潜在的な可能性が懸念された。そこで、JHHC では、予測モデルの導入に先立って、予測モデルによりハイリスク者と分類された者の臨床的特徴を自社の被保険者集団で確認するための予備的研究を行った。

## 3. 導入に先立って行われた検討

JHHC のネットワーク医療機関である Wyman Park Medical Center (地域の一般内科診療所) に 2002 年 4 月から 2003 年 3 月までの 12 か月間継続して登録していた 65 歳以上の高齢被保険者 826 名を対象として、その 12 か月間の医療費の給付データをもとに、ACG-PM を用いて各人の翌年の医療費が上位 5% になる確率を算出し、そのスコアの高い方から 18% (150 人) をハイリスク群、残り 82% (676 人) をローリスク群と分類し、同期間の医療費データ等を両群で比較した<sup>8</sup>。

<sup>7</sup>参考文献 1 の巻末用語集では、健康保険プラン (Health Plan) とは、「特定のプランまたはプログラムが対象とする加入者に対して給付される、ヘルスケアのサービスのパッケージのこと。そのパッケージを提供するプログラム、プランまたは供給組織を指すこともある。」とされているが、ここでは、供給組織の意で用いている。

<sup>8</sup> Martha L. Sylvia, et al., "Clinical Features of High-Risk Older Persons Identified by Predictive Modeling", Disease Management 9(1), 56-62, 2006.

《図表 7》のとおり、ローリスク群と比較すると、ハイリスク群の方が年齢が高く、白人割合が高い。女性割合については有意差は認められない。比較的罹患率が高く、臨床的にも重要で、医療費が高く、ディジーズ・マネジメントによる介入になじみ易いと考えられる 9 疾患（虚血性心疾患、鬱血性心不全、高血圧症、糖尿病、変形性関節症、慢性閉塞性肺疾患、うつ病、認知症、パーキンソン病）の罹患率を両群で比較すると、9 疾患のうち、パーキンソン病を除く 8 疾患についてはハイリスク群の方が有意に罹患率が高く、9 疾患の合併数は 2 倍高いことが示された。

この予備的研究では、ハイリスクに分類された 150 人に対して郵送方式によるアンケート調

査を実施している。調査項目は、社会人口学的特徴、一般的健康状態、過去 6 ヶ月間の傷病による病床日数および日常動作に差し支えの生じた日数、ADL（日常生活動作：Activities of Daily Living の略）、IADL（手段的日常生活動作：Instrumental Activity of Daily Living の略）で構成されている。回答率は 80%（120 人）であった。《図表 8》のとおり、ハイリスク群は、半分弱（42.8%）の人が自分の健康状態は良いとはいえないと自己評価しており、ADL に困難のある人は 36.3%、過去 6 か月間に病床に臥したことがある人は 38.7%、IADL に困難のある人、過去 6 か月間に傷病により日常動作に差し支えの生じた人はいずれも 50%を超えていることが示された。

《図表 7》 研究対象集団間の特徴の比較

基本属性	ローリスク (676人)	ハイリスク (150人)	p値
年齢 平均値(標準偏差)	74.4 (6.0)	76.0 (6.3)	0.015
年齢構成			
65-74歳	56.8%	48.6%	
75-84歳	36.2%	40.7%	
85歳以上	7.0%	10.7%	
女性割合	57.4%	54.7%	0.541
白人割合	43.0%	54.7%	0.038
疾病罹患率	ローリスク (645人)	ハイリスク (150人)	p値
虚血性心疾患	15.3%	51.3%	<0.001
鬱血性心不全	2.2%	29.3%	<0.001
高血圧症	74.6%	88.0%	<0.001
糖尿病	7.1%	26.0%	<0.001
変形性関節症	30.4%	44.7%	<0.001
慢性閉塞性肺疾患	7.0%	22.0%	<0.001
うつ病	4.8%	15.3%	<0.001
認知症	4.7%	12.0%	<0.001
パーキンソン病	1.9%	4.0%	0.113
上記9疾患の合併数 平均値(標準偏差)	1.48 (0.97)	2.93 (1.46)	<0.001
医療サービスの利用	ローリスク (676人)	ハイリスク (150人)	p値
年間入院回数 平均値(標準偏差)	0.13 (0.49)	1.13 (2.38)	<0.001
年間入院日数 平均値(標準偏差)	0.51 (2.29)	7.34(22.02)	<0.001
年間合計医療費 平均値(標準偏差)	\$3,726 (\$5,038)	\$22,185 (\$41,506)	<0.001

(出典) Martha L. Sylvia, et al., "Clinical Features of High-Risk Older Persons Identified by Predictive Modeling", Disease Management 9(1), 56-62, 2006 の Table 1 および Table 2 より損保ジャパン総合研究所が訳出して作成。

《図表 8》ハイリスク群に対するアンケート調査の結果

	ハイリスク (120人)
教育年数	
第8学年以下	10.0%
高校	40.8%
大学	47.5%
家計年間所得	
\$20,000未満	21.0%
\$20,000-\$50,000	60.5%
\$50,000以上	18.5%
一人住まい	20.8%
既婚	61.7%
一般的健康状態の自己評価	
すこぶる良い (Excellent)	2.5%
とても良い (Very good)	20.2%
良い (Good)	34.5%
普通 (Fair)	36.1%
悪い (Poor)	6.7%
機能的能力	
ADL5項目のうち一つ以上が困難	36.6%
IADL7項目のうち一つ以上が困難	58.1%
過去6か月間に病床日数有	38.7%
過去6か月間に傷病により日常動作に差し支えの生じた日数有	52.3%

(出典) Martha L. Sylvia, et al., “Clinical Features of High-Risk Older Persons Identified by Predictive Modeling”, Disease Management 9(1), 56-62, 2006 の Table 1 および Table 2 より損保ジャパン総合研究所が訳出して作成。

さらに、ハイリスク群に分類されたが、アンケート調査に回答しなかった 30 人の特徴を把握するため、ハイリスク群に分類された人をアンケート調査に回答した人 (120 人) と回答しなかった人 (30 人) に分け、基本属性、9 疾患の罹患状況を比較している。《図表 9》のとおり、非回答者群は、回答者群と比べると、罹患率も総じて高く、入院回数、入院日数、年間医療費とも高いことが示された。このことは、上記で回答者に関して示した一般的健康状態の自己評価や機能的能力の状態が、ハイリスク群全体で評価すると、さらに悪い傾向となっていることが示唆される。

上記の分析結果から、JHHC は、ACG-PM による予測モデルを使用することは医療費請求データが存在する高齢者集団のスクリーニングには有効で効率的なアプローチであると結論し、ACG-PM を実務運用に組み込むこととした。

#### 4. 導入後の運用体制

JHHC では、ACG-PM を実務運用に組み込むこととしたが、ACG-PM により算出されたりリスクスコアのみを唯一の指標として、特定・階層化を実施しているわけではない。

JHHC は、ハイリスク者の必要とする支援ニーズを明らかにし、ディジーズ・マネジメントの有効性を確からしいものとするためには、機能上の障害や社会的な属性に関する補足情報の収集が必要であると考えている。この情報収集は、臨床的な内容の評価ができ、どのようなディジーズ・マネジメントによる介入が利用可能であるかを知っており、予測モデルにより算出されたリスクスコアとハイリスク者からの自己申告情報とを総合して判断できる登録正看護師のような医療関係者により行われることが望ましく、また、こうした情報を一箇所に集約し、この統合プロセスを手助けする情報技術 (IT) シ

《図表 9》アンケート調査の回答者と非回答者の特徴の比較

	回答者 (120人)	非回答者 (30人)	p値
<b>基本属性</b>			
年齢 平均値(標準偏差)	75 (6.1)	76.0 (6.3)	0.269
年齢構成			0.089
65-74歳	51.7%	48.6%	
75-84歳	40.0%	40.7%	
85歳以上	8.3%	10.7%	
女性割合	58.3%	54.7%	0.071
白人割合	56.7%	54.7%	0.517
<b>疾病罹患率</b>			
虚血性心疾患	50.0%	51.3%	0.513
鬱血性心不全	23.3%	29.3%	0.001
高血圧症	90.0%	88.0%	0.132
糖尿病	25.8%	26.0%	0.926
変形性関節症	49.2%	44.7%	0.027
慢性閉塞性肺疾患	19.2%	22.0%	0.094
うつ病	15.0%	15.3%	0.821
認知症	10.0%	12.0%	0.132
パーキンソン病	3.3%	4.0%	0.405
上記9疾患の合併数 平均値(標準偏差)	2.86 (1.38)	2.93 (1.46)	0.250
<b>医療サービスの利用</b>			
年間入院回数 平均値(標準偏差)	0.66 (1.04)	1.13 (2.38)	0.002
年間入院日数 平均値(標準偏差)	2.98 (6.24)	7.34(22.02)	<0.001
年間合計医療費 平均値(標準偏差)	\$15,204 (\$16,980)	\$50,111 (\$81,608)	<0.001

(出典) Martha L. Sylvia, et al., "Clinical Features of High-Risk Older Persons Identified by Predictive Modeling", Disease Management 9(1), 56-62, 2006 の Table 3 より損保ジャパン総合研究所が訳出して作成。

システムが必要であると考えた。また、利用可能なディジーズ・マネジメントの各種プログラムから最もベネフィットを受け易いと考えられる人を選び出すためには、医療費請求データから拾い集められた診断名に関する情報を有効活用する必要があり、例えば、ハイリスク群のうち、糖尿病を持っている人には糖尿病の理解と自己管理の方法等に関する知識を提供する支援が有効であろうし、4 つ以上の慢性症状を持っているハイリスク者には複合的なケアもコーディネートし、モニターする継続的な支援が有効であろうと考えられた。

そこで、JHHC は、次のような運用体制を構築した。

- ①スタッフを集中的に教育訓練し、
- ②教育訓練を受けたスタッフ全員が ACG 情報を利用可能とし、
- ③Clinical Screener という役割を新設し、
- ④IT システムを強化し、Clinical Screener toolkit を整備した。

Clinical Screener は JHHC が導入した看護職の新しい役割で、マネジドケアと臨床の経験を持った登録正看護師が担当し、従来からのルートで依頼のあったディジーズ・マネジメントの対象候補者のスクリーニングを受動的に行うだけでなく、ACG-PM のリスクスコアにより特定された潜在的ハイリスク者のスクリーニングを能動的に実施し、ディジーズ・マネジメント

に関するアセスメントを完了させ、その対象者に最も適切なプログラムを判断する体制とした。現在は3名体制で計20万人規模の被保険者集団を担当している。Clinical Screener Toolkitとして、ACG-PMによる予測情報、診断名情報、利用した医療サービスの情報、臨床指標（検査結果、X線）情報、対象者との電話によるコンタクトで収集された臨床評価情報、ディジーズ・マネジメントへの受容性・快諾性の評価情報が用意されている。Clinical Screenerから、対象者への実際の働きかけを担当するケース担当者への依頼手続きも、各種の情報を有機的に活用し、IT化されている。

ディジーズ・マネジメントが有益と考えられる対象者を抽出する指標として、下記の指標も併用されている。

- ①過剰需要（ACG-PMスコアが下位25%に属しているが、合計医療費額が上位25%に属するまたは受診回数が上位25%に属する）
- ②多剤服用（服用している薬剤の薬効分類数が、当該対象者の属するACG分類における平均値+標準偏差の2倍以上の水準（または上位25%）に属する）
- ③専門医の過剰受診その1（専門医への受診料が、当該対象者の属するACG分類における平均値+標準偏差の2倍以上の水準（または上位25%）に属する）
- ④専門医の過剰受診その2（受診した専門医の種類数が、当該対象者の属するACG分類における平均値+標準偏差の2倍以上の水準（または上位25%）に属する）
- ⑤救急治療室の過剰利用（救急治療室の利用料が、当該対象者の属するACG分類における平均値+標準偏差の2倍以上の水準（または上位25%）に属する）
- ⑥X線・画像検査の多用（画像診断料が、当該対象者の属するACG分類における平均値+標準偏差の2倍以上の水準（または上位25%）に属する）
- ⑦主治医なし（1年間主治医に一度も受診していない）
- ⑧プライマリーケア過少（主治医への受診回数が、当該対象者の属するACG分類における下位25%に属する）
- ⑨治療の継続不足（Modified-Modified Continuity Index<sup>9</sup>が下位25%に属する）
- ⑩専門医による治療が主体
- ⑪回避可能な入院（プライマリーケアが適切に提供されていたら回避できたであろう入院が1回以上ある）
- ⑫ケアコーディネーションのニーズが高い（3つ以上の慢性症状+（薬物乱用、統合失調症、もしくは双極性障害））
- ⑬受診障害の可能性（当該対象者の属するACG分類において、ACG-PMスコアが上位25%であるにも関わらず、医療資源利用は下位25%である）

ACG-PMにより算出されたリスクスコアを軸に様々な指標を駆使してディジーズ・マネジメント対象者の特定・階層化が行われていることが見てとれる。

## V. 実践上の課題と予測モデル活用の意義

前章で述べたように、米国では、予測モデルは単に概念的な理想という認識から脱し、DMプログラムの対象者を効果的・効率的に特定し階層化するための手段の1つとして実務の用に供されている。開発者も多数存在し、各種の予測モデルが開発・販売されていることから、こ

<sup>9</sup>  $[1 - \{ \text{受診医療機関数} / (\text{受診回数} + 0.1) \}] / [1 - \{ 1 / (\text{受診回数} + 0.1) \}]$  で計算される指標で治療の継続性を表すとされている。

うした予測モデルをどのように使いこなしていくのかが実践上の課題となっている。予測モデルを使いこなす上では、提供しようとする介入プログラムの内容に即した予測モデルを選択することや、予測モデルをより有効に活用するために、対象者の特定・階層化における **impactibility**（「介入効果度」）という概念が重要視されてきている。

米国におけるディジーズ・マネジメント分野のすべての利害関係者を代表する非営利組織として 1999 年に設立された **Disease Management Association of America** は年次総会の開催を始め、学術誌・用語集・各種ガイドラインの発刊等、様々な活動を展開しているが、予測モデルに関しては、2006 年 12 月、“**Predictive Modeling Buyer’s Guide**”と題する小冊子を公開し、予測モデルの利用者・購入者を対象とした啓蒙を図っている。本章では、このガイドブックにおける説明を参考に、予測モデルの導入に際しての考慮すべき実践上の課題を整理し、予測モデル活用の意義を明らかにして、本稿のまとめとする。

### 1. 使用目的により異なる予測モデルの機能

「介入効果度」の高い人とは、当該介入による影響を受け易い、効果を得やすい人のことである。例えば、急激で重篤な事態に陥った人を対象とし、状況を評価し、療養の計画を立案し、必要なサービスを調和よく組み合わせる協力的なプロセスで支援する介入プログラムの場合には、高額で重篤な事案を扱うので、医療費額の大きい上位 0.5%、1.0%といった超ハイコスト事案を予測するモデルが非常に有用である。一方、ディジーズ・マネジメントのプログラムの場合は、集団をベースとして、対象となる人数規模も大きく、主治医の治療計画にきちんと従い、

健康的な生活スタイルを選択するよう対象者をエンパワーすることを目的としている。現在ハイコストである、あるいはハイコストになると予測される人が必ずしも、主治医の治療計画にきちんと従わない人や自分の病態についての教育の必要な人、悪い生活スタイルを選択する人とは限らない。したがって、例えば、心不全既往症者について利尿剤をきちんと服薬することによって不必要な入院や救急治療室の利用、主治医の診察受診を減少させることを目指したプログラムの場合には、現在利尿薬の服薬不良の人もしくは将来服薬不良となる人が特定できるならモデルは有用である。

### 2. ケーススタディ

《図表 10》に掲げた例示で説明する。《図表 10》の上半分に 3 人の対象者について予測モデルにより算出されたリスクスコアが表示されている（リスクスコアの数値は例示のための仮想のものである）。3 人とも鬱血性心不全の既往がある。算出されたリスクスコアの大きさにより階層化し介入の強度を決めるとすると、D 氏は中等度の介入、E 氏、F 氏は最強度の介入と分類されるだろう。E 氏と F 氏に関して予測モデルは同等のリスクを見ている点に留意されたい。《図表 10》の下半分はその他のリスクファクターの状況を示している。D 氏は中等度の介入に分類されているが、D 氏には心血管疾患を悪化させるリスクファクターで修正（改善）可能なものが数多くある。慢性腎臓病のマーカーであるクレアチニンが高値であるし、心不全既往症者の心機能を改善し余命を伸ばすことが示されているベータブロッカーを服用していないし、服薬の遵守状況も悪い。したがって、D 氏は予測モデルで算出されたスコアが示唆する以上に大きなリスクを持っていると考えられる。一方、

《図表 10》 ケーススタディ D 氏、E 氏、F 氏の特徴

リスク要因	リスクスコア	D氏	E氏	F氏	負の影響
年齢:47歳	0.21	0.21			
年齢:62歳	0.35		0.35	0.35	
性別:男性	0.21		0.21	0.21	
性別:女性	0.17	0.17			
鬱血性心不全の既往	2.16	2.16	2.16	2.16	
糖尿病の既往	1.55		1.55	1.55	
急性心筋梗塞の既往	0.85		0.85	0.85	
胃食道逆流疾患の既往	0.40		0.40	0.40	
高血圧症の既往	0.38	0.38	0.38	0.38	
慢性閉塞性肺疾患の既往	1.25		1.25	1.25	
＜その他のリスク要因＞					
喫煙		○		○	冠動脈疾患、肺疾患
揚げ物を多く食べる				○	冠動脈疾患;胃食道逆流疾患のコントロール
LDLコレステロールが160mg/dl		○		○	冠動脈疾患
ACE阻害薬の処方なし				○	急性心筋梗塞、糖尿病の悪化;腎症、心不全、脳血管発作
ベータブロッカーの処方なし		○	○		心不全の悪化
メトホルミンを服用			○	○	
クレアチンが2.5mg/dl		○		○	乳酸アシドーシス
服薬遵守不良		○	○		
長時間作動型ベータ刺激薬の処方なし				○	慢性閉塞性肺疾患の悪化

(注) 上記のリスクスコアは例示目的で表示したものであり、実在の予測モデルでの算出結果を示したものではない。

(出典)DMAA, “Predictive Modeling Buyer’s Guide” p.17 Table 3 より損保ジャパン総合研究所が訳出して作成。

E 氏、F 氏については予測モデルによるスコアでは同等のハイリスクのように見えるが、F 氏のリスクの方が格段に大きいと考えられる。何故なら、F 氏は、ACE 阻害薬もベータブロッカーも服用しておらず、慢性腎臓病と心不全の既往があるにもかかわらず乳酸アシドーシスのリスクがあるメトホルミンを服用しており、合併している慢性閉塞性肺疾患の悪化を防止する長時間作動型ベータ刺激薬も服用していないからである。

ここに示したような臨床上の介入効果が大きいと期待される対象者は管理データに対して一連の注意喚起ルールを適用することによって発見することが可能である。予測モデルによるアウトプットに対してこのような一連のルールを適用するプロセスを追加することによって、DM プログラムにおける対象者の様々なプログラムへの階層化をより効率的かつ効果的に行うことができるようになる。また、その他の効果の期待できるいくつかのリスクファクターが《図表 10》の下半分に示されている。D 氏、F 氏は喫煙者で、F 氏は揚げ物を良く食べる。こ

のような効果の期待できるリスクファクターは自己申告により明らかにされるものである。

上記の例で示したように、多くのデータソースが有用であるが、予測モデルにおけるデータソースの有用性に影響を与える要素がいくつかある。信頼性と適時性は介入効果度の判断に特に関連が深い。不正確なデータ、データの欠損があると、効果の期待できる状況を誤って認識したり、見逃したりすることに繋がりうる。同様に、介入効果度の情報には適時性も必要である。すなわち、データのレビューが済んだ頃には、もう必要な薬を調剤してもらっているかもしれない。データの収集コスト、収集の容易さという側面では、年齢・性別等の属性データ、医療費請求データ、処方薬剤データといった管理データは収集コストも低く収集が容易であるが、自己申告で収集するデータは収集コストが高く、データ・フォーマットの標準化も進んでいない現状がある。データソースごとの比較は《図表 11》の通りである。

《図表 11》データ・ソースによる特徴の比較

基準	データソース			
	医療費請求データ	処方薬剤データ	検査データ	自己申告データ
収集の容易さ	+++	++	+	+
収集コスト	+	+	++	+++
適時性	+	++	+++	+++
信頼性	+	+++	+++	++(?)
標準化	+++	+++	+++	+
効果度による階層化 における有用性	++	+++	++	+++
Ease of "gaming"	++	+	+	?

(出典) DMAA, "Predictive Modeling Buyer's Guide" p.18 Table 4 より損保ジャパン総合研究所が訳出して作成。

### 3. まとめ

ディジーズ・マネジメントの特徴は集団ベースの視点にある。すなわち、依頼を受けた個別の事案に対応する戦略と異なり、集団全体を能動的に見渡した上で、DMプログラムの対象者を特定・階層化して働きかけを実施する戦略であり、それを通じて、有限で高価なヘルスケア資源の効果的・効率的な投入の実現を目指している。この戦略の成功の鍵として、働きかけの技術とともに、集団全体の中から働きかけの対象者を特定・階層化する技術が重要となる。さらに、DMプログラムの運用のコストという視点に立てば、この対象者の特定・階層化というプロセスを効率的に実施する必要がある。DMプログラムのサービス提供を事業化し、産業として確立してきた米国においては、特にこの必要性が強く認識され、実用的な解決が図られてきた。

対象者の特定・階層化の判断材料となるデータソースの収集の容易さ、収集コストを考慮した上で、米国の実務が導き出した一つの解決が、予測モデルの活用である。働きかけの効果を左右すると考えられるリスク要因は多様であるので、事前にすべての要因を調査し判断材料とすることは収集の容易さ、収集コストの点からも現実的でない。そこで、すでに収集済みの医療

費請求データや処方薬剤給付データ等を用いた予測モデルを活用して、集団全体の中から働きかけの対象候補者を絞り込んだ上で、多少のコストをかけて、各候補者について働きかけの効果が期待できるリスク要因の有り様を確認し、最終的に対象者の特定・階層化を実施するという実務が取られている。このように予測モデルは、DMプログラム実施のコスト負担者を明確に意識し、その中で要請される効率的な運用を実現するという課題に対する一つの解決として大きな役割を果たしている。

予測モデルは、集団ベースの視点に立ったディジーズ・マネジメントに必要とされる基本的な技術である。米国において、予測モデルは実務的に実用化され、多くの課題に対して取り組んだ経験が蓄積されている。わが国においてディジーズ・マネジメントが今後本格的に取り組まれ、定着・普及していくなかで、予測モデルの開発と実践上の課題に即した活用は、米国と同様に重要となると考えられる。

#### 参考文献：

- 1 田中滋 他編 「ヘルスサポートの方法と実践」(東大出版会、2007年)
- 2 「米国におけるディジーズ・マネジメントの発展」(損保ジャパン記念財団叢書 No.65、

2003年)

- 3 Martha L. Sylvia, et al. “*Clinical Features of High-Risk Older Persons Identified by Predictive Modeling*”, *Disease Management* 9(1), 56-62, 2006.
- 4 “*Predictive Modeling in Disease Management: Trends, Tools, and Strategies*”, National Health Information, LLC, 2004.
- 5 Cousins, et al., “*An Introduction to Predictive Modeling for Disease Management Risk Stratification*” *Disease Management* 5(3):157-167, 2002.
- 6 DMAA, “*Predictive Modeling Buyer’s Guide*”, 2006.
- 7 DMAA, “*Dictionary of Disease Management Terminology*”, Second edition, 2006.