

平成 29 年度厚生労働行政推進調査事業補助金
政策科学総合研究事業(政策科学推進事業)

「診断群分類を用いた病院機能評価手法とデータベース利活用手法の開発に関する研究」
分担研究報告書

DPC 分析用データセットの作成・開発について

研究分担者 堀口 裕正 国立病院機構本部総合研究センター 診療情報分析部 副部長

研究要旨

本研究班において、収集した DPC データは、データセットの量が大きく、一般的な研究者が保有する分析環境（コンピュータの能力やデータを保管するストレージの量等）では処理が行えない状況となっている。また、その膨大なデータのうち、矛盾するレコードや、研究で使用するには留意が必要なデータも混じっている。

そこで、いくつかのデータ処理を行うことによって、データを分析可能なものに絞り込み、さらに分析に必要な様々な処理を加えてデータセットを作成し、さまざまな研究が実施しやすい環境を構築することを行った。

本年度、平成 22 年～28 年のデータについては新たに利用承諾がとれた医療機関のデータを加えて、分析用データセットの再作成を行うとともに、平成 29 年のデータについて分析用のデータセットの作成を行い、分析に供することができた。その際、キー情報の重複や必要なデータの欠損のある症例などは、分析に影響度が大きいので、それらの症例情報については確実に除去を行った。

このデータセットの完成で、DPC データの精度を向上させ、より高度な分析を実施することが可能となると考えられる。

A.目的

本研究班において、収集した DPC データは、まず基本調査として入院情報の D/E/F ファイル・様式 1・3・4 ファイル（以下それぞれ FF1/FF3/FF4 ファイルと表記）と多岐にわたっている。また各病院のデータ収集が通年化され収集時期の範囲も広く、多数の医療機関が参加している。さらに、付随する調査として ICU/ER・リハビリ・CP・外来機能といった各種調査が付随し、それぞれが、基本調査の集計データを分析にあたって必要としている。

平成 28 年 3 月現在、本研究班では平成 15 年度調査から平成 28 年度調査までの 14 年度の調査データを医療機関との契約の元で保有し、分析に活用しているが、平成 29 年調査データの分量はすべてテキストのデータで、1TB を超えた量

となっており、一般的な研究者が保有する分析環境（コンピュータの能力やデータを保管するストレージの量等）では処理が行えない状況となっている。

そこで、本研究では、平成 21 年度より本研究班の保有する DPC 調査データから、

- 1、利用できるデータを選択し、
- 2、その 1 つ 1 つのデータが研究に利用する際に留意すべきポイントがあるかをチェックして情報を付加し
- 3、分析に必要な情報を容易にとりだせるよう用途別に分割し、

さまざまな統計処理を行うための数値を計算しやすいよう整理して共通分析用データセットとして作成し、本研究班においてより精度の高い、高度な分析を行うための環境を整備することを試みている。本年度は平成 28 年度

から平成 29 年度(24 ヶ月)分のデータを通年で 1 つのデータセットとして取り扱い、各種の分析処理を行うことが出来る基盤作成を目的とした。

B.方法

以下の処理を、研究班保有の DPC データに対して行い、分析用データセットを作成することとした。

1、データの取り込み

参加医療機関から提供された DPC データ (FF1/3/4/D/E/F/外来ファイル) を DB に取り込む。その際、平成 26 年度データからの様式 1 ファイル縦持ち化に対応した処理を追加した。また、平成 28 年度のフォーマット改正および H ファイルの追加に伴う処理を追加した。

2、エラーチェック

提出されたデータのエラーチェックを行い、エラーデータをデータセット内から除外する。また研究に使用する際留意する項目に対してチェックしフラグを付与する。

どのような条件についてエラー・留意とするかについては本年の研究として検討を行う。

3、DPC コード情報の一体的保有

平成 20 年度「DPC 松田研究班版 DPC コーダーの開発について」で作成した DPC コーディングツールを利用した DPC コードを分析用データセット内に取り込み、他のデータと一体的に保有する

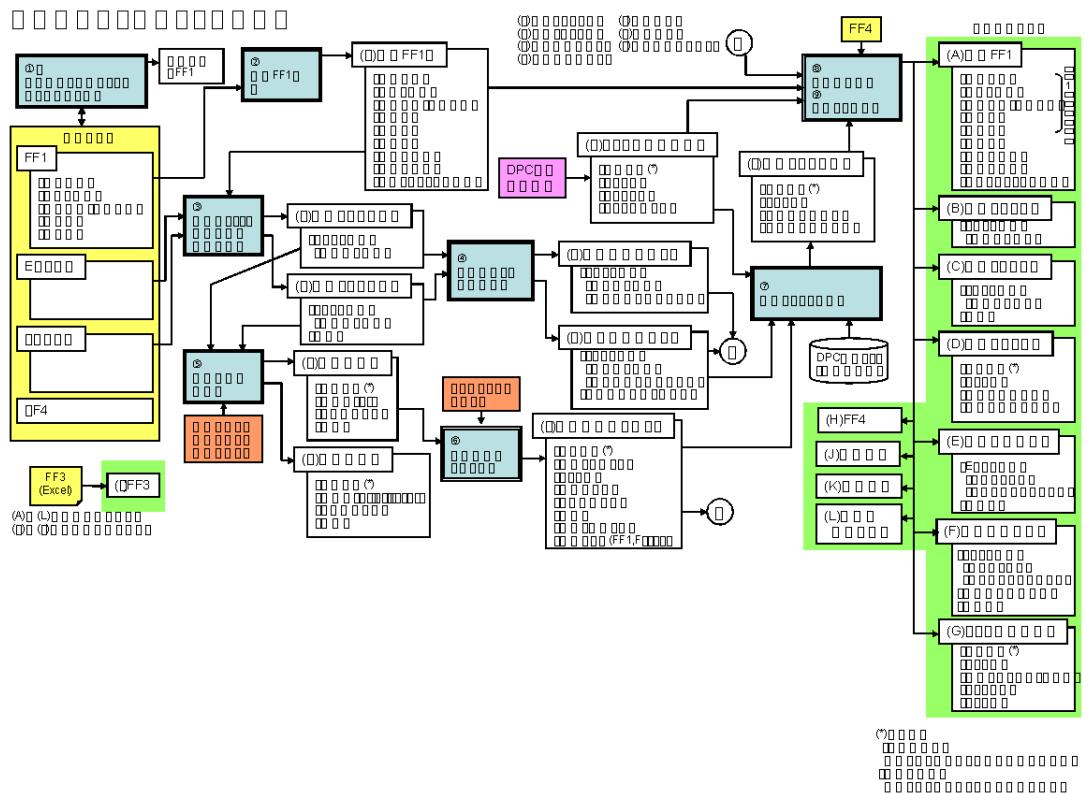
以上の処理を行い、分析用データセットを作成する。

分析用データセットには次のファイルが

含まれる

- (A) 拡張 FF1 様式 1
(FF1) 情報に留意フラグ等の情報をお加したもの
- (B) 統合 E ファイル E ファイルに退院日及び期間内入院回数を付加したもの
- (C) 統合 F ファイル F ファイルに退院日・実施日等を付加したもの
- (D) 疑似 D ファイル D ファイル作成ルールに基づいて擬似的に D ファイルを生成
- (E) 診療明細データ 統合 E ファイルの点数部分を金額に置き換えたもの
- (F) 行為明細データ 統合 F ファイルの点数部分を金額に置き換えたもの
- (G) DPC 年度毎情報 運用時期別に生成された DPC コード情報
- (H) FF4 様式 4
- (J) 実施手術 F ファイルから手術関係のレコードのみを抽出したもの
- (K) 実施処置 F ファイルから処置・薬剤関係のレコードのみを抽出したもの
- (L) 年度別手術コード 手術コードを診療報酬の運用年度別に変換したもの

尚、データ処理のフローは下に示す図のとおりである。



C.結果

本年度の研究期間においては平成 26 年度時点で伏見班保有のデータに対して B. 方法で示した処理を行った。

以下特記すべき事項に関して記載する。

1. エラーチェックについて

本研究データセット作成については、以下のルールの下で、データエラーチェックおよび留意フラグ付与を行った。

表1 エラーチェック仕様

No	エラー番号	チェック内容	チェック論理(NG条件)	対象データ	種別	備考	フラグ内容等
1	ERR010	FF1 のキーが重複している	FF1 縱にて「施設コード+データ識別番号+入院年月日+回数管理番号+診療情報番号+コード+バージョン+連番」が重複 (過去の FF1 との重複もチェックする。)	FF1 FF1T	キー重複	<ul style="list-style-type: none"> ・重複データは FF1 データを除外データ FF1 テーブルに、エラー情報と共に格納し、以降の処理には使用しない。 ・親様式1(診療情報番号=0)がエラーの場合、子様式1(診療情報番号≥ 1)のレコードも一緒に除外する。 ・子様式1の重複は該当の子様式1のみ除外とし、親様式1および他の子様式1には影響を及ぼさない。 ・「日帰り入退院+同一日再入院」および「日帰り入退院+日帰り入退院」の場合は、同一日再入院および最初の日帰り入院を採用する(回数管理番号が最小のもののみ採用する)。この場合は ERR010 ではなく、ERR220 として、非採用の様式1情報のみ除外とする。 	

2	ERR020	FF4 のキーが重複している	FF4 にて「施設コード+データ識別番号+入院年月日」が重複	FF4	キー重複	<ul style="list-style-type: none"> ・重複データは FF1 データを除外データ FF1 テーブルに、エラー情報と共に格納し、以降の処理には使用しない。 ・親様式1と子様式1の両方を除外する。(過去に仮確定した子様式1も除外する。) 	
3	ERR030	E ファイルのキーが重複している	E ファイルの「施設コード+データ識別番号+入院年月日+データ区分+順序番号+該当月」が重複	E ファイル	キー重複	<ul style="list-style-type: none"> ・重複データは FF1 データを除外データ FF1 テーブルに、エラー情報と共に格納し、以降の処理には使用しない。 ・親様式1と子様式1の両方を除外する。(過去に仮確定した子様式1も除外する。) 	
4	ERR040	F ファイルのキーが重複している	F ファイルの「施設コード+データ識別番号+入院年月日+データ区分+順序番号+行為明細番号+該当月」が重複	F ファイル	キー重複	<ul style="list-style-type: none"> ・重複データは FF1 データを除外データ FF1 テーブルに、エラー情報と共に格納し、以降の処理には使用しない。 ・親様式1と子様式1の両方を除外する。(過去に仮確定した子様式1も除外する。) 	
5	ERR050	EF 統合ファイルのキーが重複している	EF 統合ファイルの「施設コード+データ識別番号+入院年月日+データ区分+順序番号+行為明細番号+該当月」が重複	EF 統合	キー重複	<ul style="list-style-type: none"> ・重複データは FF1 データを除外データ FF1 テーブルに、エラー情報と共に格納し、以降の処理には使用しない。 ・親様式1と子様式1の両方を除外する。(過去に仮確定した子様式1も除外する。) 	

6	ERR060	外来 E ファイルのキーが重複している	外来 E ファイルの「施設コード+データ識別番号+入院年月日+データ区分+順序番号+該当月」が重複	外来 E	キー重複	<ul style="list-style-type: none"> 重複データは FF1 データを除外データ FF1 テーブルに、エラー情報と共に格納し、以降の処理には使用しない。 親様式1と子様式1の両方を除外する。(過去に仮確定した子様式1も除外する。) 	
7	ERR070	外来 F ファイルのキーが重複している	外来 F ファイルの「施設コード+データ識別番号+入院年月日+データ区分+順序番号+行為明細番号+該当月」が重複	外来 F	キー重複	<ul style="list-style-type: none"> 重複データは FF1 データを除外データ FF1 テーブルに、エラー情報と共に格納し、以降の処理には使用しない。 親様式1と子様式1の両方を除外する。(過去に仮確定した子様式1も除外する。) 	
	ERR080	D ファイルのキーが重複している	D ファイルの「施設コード+データ識別番号+入院年月日+データ区分+順序番号」が重複	D ファイル	キー重複	<ul style="list-style-type: none"> 重複データは FF1 データを除外データ FF1 テーブルに、エラー情報と共に格納し、以降の処理には使用しない。 親様式1と子様式1の両方を除外する。(過去に仮確定した子様式1も除外する。) 	
	ERR090	H ファイルのキーが重複している	H ファイルの「施設コード+病棟コード+データ識別番号+退院年月日+入院年月日+実施年月日+コード+バージョン+連番」が重複	H ファイル	キー重複	<ul style="list-style-type: none"> 重複データは FF1 データを除外データ FF1 テーブルに、エラー情報と共に格納し、以降の処理には使用しない。 親様式1と子様式1の両方を除外する。(過去に仮確定した子様式1も除外する。) 	

		在院日数が1 日未満である	入院日>退院日	FF1 FF1T	除外	<ul style="list-style-type: none"> ・エラーデータは FF1 データを除外データ FF1 テーブルに、エラー情報と共に格納し、以降の処理には使用しない。 ・親様式1(診療情報番号=0)がエラーの場合、子様式1(診療情報番号≥ 1)のレコードも一緒に除外する。 ・子様式1のエラーの場合は、該当子様式1は除外するが、親様式1および他の子様式1は除外しない。 ・子様式1で退院日が'00000000'である場合は、許容する。親様式1はこのエラーとなる。 	
8	ERR110						
9	ERR120	入院時年齢が 0歳未満であ る	生年月日>入院日	FF1 FF1T	除外	<ul style="list-style-type: none"> ・エラーデータは FF1 データを除外データ FF1 テーブルに、エラー情報と共に格納し、以降の処理には使用しない。 ・親様式1(診療情報番号=0)がエラーの場合、子様式1(診療情報番号≥ 1)のレコードも一緒に除外する。(過去に仮確定した子様式1も除外する。) ・子様式1のエラーの場合は、該当子様式1は除外するが、親様式1および他の子様式1は除外しない。 	

		年月日が誤っている	実在しない年月日 (13月1日、7月 32日など)、および SQLserver の datetime 型で扱え ない日付(1753年 1月1日以前)	ALL (FF1T も)	除外	<ul style="list-style-type: none"> エラーデータは FF1 データを除外データ FF1 テーブルに、エラー情報と共に格納し、以降の処理には使用しない。 対象は全ての日付情報をする あくまで実在しない年月日のチェックのみであり、手術日が入院日と退院日の間にあ るか、などの相関チェックは行なわない。 '00000000'は許容する。 親様式1(診療情報番号=0)がエラーの場合、子様式1(診療情報番号≥1)のレコ ードも一緒に除外する。(過去に仮確定した子様式1も除外する。) 子様式1のエラーの場合は、該当子様式1は除外するが、親様式1および他の子様 式1は除外しない。 様式1開始日、様式1終了日をチェック対象に追加。 前回退院年月日は日を 00 にする表記を共用しているため、本チェックの対象外とす る。 	
10	ERR130						
11	ERR140	(欠番)					
12	ERR150	(欠番)					
13	ERR160	統括診療情報 番号が異常で ある (3日以内再入 院集約レコー ド)	統括診療情報番号 が0以上の数字で ない	FF1 FF1T	除外	<ul style="list-style-type: none"> 他のエラーデータ除外より最初に判定する。 エラーデータは FF1 データを除外データ FF1 テーブルに、エラー情報と共に格納し、以降の処理には使用しない。 	

14	ERR170	様式1対象期間が1日未満である	様式1開始日 > 様式1終了日	FF1 FF1T	除外	<ul style="list-style-type: none"> ・エラーデータは FF1 データを除外データ FF1 テーブルに、エラー情報と共に格納し、以降の処理には使用しない。 ・親様式1(診療情報番号=0)がエラーの場合、子様式1(診療情報番号≥ 1)のレコードも一緒に除外する。 ・子様式1のエラーの場合は、該当子様式1は除外するが、親様式1および他の子様式1は除外しない。
15	ERR180	親様式1において様式1開始日、様式1終了日が入院日、退院日に一致していない	統括診療情報番号 =0かつ(様式1開始日が入院年月日と一致しないまたは 様式1終了日が退院年月日と一致しない)	FF1 FF1T	除外	<ul style="list-style-type: none"> ・エラーデータは FF1 データを除外データ FF1 テーブルに、エラー情報と共に格納し、以降の処理には使用しない。 ・親様式1(診療情報番号=0)がエラーの場合、子様式1(診療情報番号≥ 1)のレコードも一緒に除外する。(過去に仮確定した子様式1も除外する。) ・子様式1のエラーの場合は、該当子様式1は除外するが、親様式1および他の子様式1は除外しない。

16	ERR190	様式1開始日 が入院と退院 の範囲外である	様式1開始日<入 院年月日 または 様式1開始日 > 退院年月日	FF1 FF1T	除外	<ul style="list-style-type: none"> ・エラーデータは FF1 データを除外データ FF1 テーブルに、エラー情報と共に格納し、以降の処理には使用しない。 ・親様式1(診療情報番号=0)がエラーの場合、子様式1(診療情報番号≥ 1)のレコードも一緒に除外する。 ・子様式1のエラーの場合は、該当子様式1は除外するが、親様式1および他の子様式1は除外しない。
17	ERR200	様式1終了日 が入院と退院 の範囲外である	様式1終了日<入 院年月日 または 様式1終了日 > 退院年月日	FF1 FF1T	除外	<ul style="list-style-type: none"> ・エラーデータは FF1 データを除外データ FF1 テーブルに、エラー情報と共に格納し、以降の処理には使用しない。 ・親様式1(診療情報番号=0)がエラーの場合、子様式1(診療情報番号≥ 1)のレコードも一緒に除外する。 ・子様式1のエラーの場合は、該当子様式1は除外するが、親様式1および他の子様式1は除外しない。
	ERR210	回数管理番号 が異常である	回数管理番号が0 以上の数字でない	FF1T	除外	<ul style="list-style-type: none"> ・他のエラーデータ除外より最初に判定する。 ・エラーデータは FF1 データを除外データ FF1 テーブルに、エラー情報と共に格納し、以降の処理には使用しない。

	ERR220	同じ入院日の入院が複数存在する	回数管理番号が複数存在する。 最小の回数管理番号のみの様式1情報のみを探用し、他の回数管理番号の様式1情報はERR220として除外する。	FF1T	除外	<ul style="list-style-type: none"> エラーデータは FF1 データを除外データ FF1 テーブルに、エラー情報と共に格納し、以降の処理には使用しない。 <p>20_FF1_キー重複チェックでチェック実施。</p>	
18	ERR510	E ファイルと F ファイルが不整合である(F ファイルデータが非存在である)	E ファイルの各レコードに対して、同じ月の F ファイルに同じ「施設コード+データ識別番号+入院年月日+データ区分+順序番号」を持つレコードが存在しない。	E ファイル、F ファイル	フラグ	<ul style="list-style-type: none"> 親様式1(診療情報番号=0)のみチェック対象。 子様式1(診療情報番号≥1)はチェック対象外。フラグは 0 を設定する。 	0:エラー無し 1:F ファイルデータ欠落有り
19	ERR520	E ファイルと F ファイルが不整合である(E ファイルデータ非存在である)	F ファイルの各レコードに対して、同じ月の E ファイルに同じ「施設コード+データ識別番号+入院年月日+データ区分+順序番号」を持つレコードが存在しない。	E ファイル、F ファイル	フラグ	<ul style="list-style-type: none"> 親様式1(診療情報番号=0)のみチェック対象。 子様式1(診療情報番号≥1)はチェック対象外。フラグは 0 を設定する。 	0:エラー無し 1:E ファイルデータ欠落有り
20	ERR530	入院期間外の EF ファイルレコードが存在する	E ファイルの実施日 < FF1 の入院日または FF1 の退院日 < E ファイルの実施日	FF1,E ファイル、統合 E ファイル	フラグ	<ul style="list-style-type: none"> 親様式1(診療情報番号=0)のみチェック対象。 子様式1(診療情報番号≥1)はチェック対象外。フラグは 0 を設定する。 	0:エラー無し 1:入院期間外 E ファイルデータ有り

21	ERR540	E ファイル、F ファイルの退院日が FF1 と異なる	「施設コード+データ識別番号+入院年月日」が FF1 と E ファイル、F ファイルで同一であるが、退院日が異なる。	FF1,FF1 T,E ファイル、F ファイル EF 統合ファイル	フラグ	・親様式1(診療情報番号=0)のみチェック対象。 ・子様式1(診療情報番号≥1)はチェック対象外。フラグは 0 を設定する。	0:エラー無し 1:E ファイルの退院日が FF1 と異なる 2:F ファイルの退院日が FF1 と異なる 3:E ファイルとFファイルの両方の退院日が FF1 と異なる 4:EF 統合ファイルの退院日が FF1 と異なる
22	ERR541	D ファイルの退院日が FF1 と異なる	「施設コード+データ識別番号+入院年月日」が FF1 と D ファイルで同一であるが、退院日が異なる。	FF1,FF1 T,D ファイル	フラグ	・親様式1(診療情報番号=0)のみチェック対象。 ・子様式1(診療情報番号≥1)はチェック対象外。フラグは 0 を設定する。	0:エラー無し 1:D ファイルの退院日が FF1 と異なる
22	ERR542	H ファイルの退院日が FF1 と異なる	「施設コード+データ識別番号+入院年月日」が FF1 と H ファイルで同一であるが、退院日が異なる。	FF1,FF1 T,H ファイル	フラグ	・親様式1(診療情報番号=0)のみチェック対象。 ・子様式1(診療情報番号≥1)はチェック対象外。フラグは 0 を設定する。	0:エラー無し 1:H ファイルの退院日が FF1 と異なる

23	ERR550	入院基本料または特定入院料を算定しない日がある	F ファイルでデータ区分 90(入院基本料)または 92(特定入院料)の点数がない日がある。	E ファイル	フラグ	<ul style="list-style-type: none"> ・親様式1(診療情報番号=0)のみチェック対象。 ・子様式1(診療情報番号≥1)はチェック対象外。フラグは0を設定する。
24	ERR610	医科レセプトのみでない	FF4 で「1.医科レセプトのみ」以外	FF4	フラグ	<ul style="list-style-type: none"> ・FF4 にレコードがない場合もフラグ設定する。 ・親様式1(診療情報番号=0)のみチェック対象。 ・子様式1(診療情報番号≥1)はチェック対象外。フラグは0を設定する。

25	ERR710	24時間以内の死亡である	FF1で「24時間以内死亡の有無」が「24時間以内死亡の有り」または「救急患者として搬送され、入院前に処置室、手術室等で死亡有り」	FF1 FF1T	フラグ		0:エラー無し(24時間以内死亡無し) 1:24時間以内死亡有り 2:救急患者として搬送され、入院前に処置室、手術室等で死亡有り
26	ERR720	生後7日以内の死亡である	退院時転帰が死亡、かつ退院日が生年月日から7日以内(生年月日当日は1日とカウント)	FF1 FF1T	フラグ		0:エラー無し(生後7日以内の死亡無し) 1:生後7日以内の死亡有り
27	ERR730	治験対象である	FF1で「治験実施の有無」が「有り」	FF1 FF1T	フラグ		0:エラー無し(治験実施無し) 1 治験実施有り
28	ERR740	移植手術を実施している	Fファイルに移植手術に該当するKコードに該当するレセ電算コードを持つ。移植手術のKコードは厚労省告示に基づく。(H15第75号、H18第138号、H20第93号、H22第93号、H24第93号、H26第93号)	Fファイル	フラグ	・親様式1(診療情報番号=0)のみチェック対象。 ・子様式1(診療情報番号≥1)はチェック対象外。フラグは0を設定する。	0:エラー無し(移植手術無し) 1:移植手術有り

		厚生労働大臣 が定める者で ある	Fファイルに厚労省 告示に該当する医 科点数表コードを 持つ。(H16 第 107 号、H18 第 139 号、H22 第 94 号、 H22 第 94 号、第 96 号、第 197 号、H24 第 140 号、H26 第 140 号)	F ファイ ル	フラグ	・親様式1(診療情報番号=0)のみチェック対象。 ・子様式1(診療情報番号≥1)はチェック対象外。フラグは 0 を設定する。	0:エラー無し(厚生労働大臣が定 める者でない) 1:H16 年度の厚生労働大臣が定 める者である 2:H18 年度の厚生労働大臣が定 める者である 3:H20 年度の厚生労働大臣が定 める者である 4:H22 年度の厚生労働大臣が定 める者である 5:H24 年度の厚生労働大臣が定 める者である 6:H26 年度の厚生労働大臣が定 める者である 7:H28 年度の厚生労働大臣が定 める者である
29	ERR750	一般病棟外へ の移動がある	FF1 で「一般病棟 外への移動あり」 がある(~H16)。 「精神病棟への入 院あり」または「そ の他の病棟への入 院有り」がある (H17~)。	FF1 FF1T	フラグ		0:エラー無し 1:一般病棟外への移動あり
30	ERR760	年齢が 120 歳 以上である	入院時年齢が 120 歳以上	FF1 FF1T	フラグ		0:エラー無し(入院時年齢 120 歳 未満) 1:入院時年齢 120 歳以上
31	ERR770						

32	ERR780	手術が輸血のみである	FF1 の手術1~5に輸血だけしか存在しない (輸血管理料は含まないこと)	FF1 FF1T	フラグ		0:エラー無し(手術なし、または、輸血以外の手術あり) 1:手術が輸血のみ
33	ERR790	短期滞在手術基本料を算定している	E ファイルに短期滞在手術基本料に該当するレセ電コードがある。	E ファイル	フラグ		0:エラー無し(短期滞在手術基本料なし) 1:短期滞在手術基本料あり
34	ERR800 (旧 ERR140)	診療報酬制度変更跨り (2010 年度からの調査通年化により、条件変更)	様式1開始日・終了日が診療報酬年度を跨っている。 (2016 年度データでは、様式1開始日が 2016/4/1 以前である。)	FF1T	フラグ	H23 新規追加、H24 変更、H26 変更、H28 変更	0:エラー無し エラー有りの場合は、跨った診療報酬年度を設定(2009 年度 →2010 年度跨りなら 2010 を設定)

D. 考察

本研究の結果から、提出されているデータについて、一定数のエラーが含まれていることがわかった。特にキー情報の重複や必要なデータが欠損している症例などは、分析に影響度が大きいので、それを確実に除去できるようになったことは成果である。

また、分析の方向性によって、使用の可否が決まる入院患者レコードがあるということが本研究の過程で判明した。たとえば、入院の途中で保険適応になる患者について、それを分析に含めるか否か、その場合の在院日数はどの範囲を指すべきなのか、などといった点は、研究の目的に応じて、それを研究者が容易に判断できる環境にあることは結果の妥当性を維持するためにも重要である。今回の研究で、留意が必要な入院レコードに対してそのフラグメント化ができたことは大きな成果であったといえる。今後の

開発においてもさらなる留意コードが必要かについてその使い勝手とともに検討していきたい。

現時点ではいまだにいくつかのテーブルについては一般的な研究者の持つ環境ではハンドルが難しいサイズのレコード数を持っている状況にある。今後、このデータセットを使って、研究者が共通して使える集計データを作成し、より容易に研究ができるデータ環境を構築していく必要がある。

E. 結論

本年度、平成 28 年度分までの分析用データセットの作成が完了し、運用することもできた。また、平成 29 年度以降のデータについても同様に処理が出来るシステムの稼働を行うことが出来た。

次年度以降、より容易に研究ができるデータ環境を構築していく研究を行っていきたい。

