

# 機械学習を用いた糖尿病患者の治療行動予測

くらすわ ひさし†1 ふじの あきのり†2

倉沢 央 / 藤野 昭典

はやし かつよし†3

林 勝義

NTT未来ねっと研究所<sup>†1</sup>NTTコミュニケーション科学基礎研究所<sup>†2</sup>NTT先端集積デバイス研究所<sup>†3</sup>

近年、AIを活用して医療情報を分析し、医師の診断や治療を支援する取り組みがさかんに行われています。NTTでは東京大学医学部附属病院と共同で、糖尿病患者さんの治療支援のためのAIの構築に取り組んでいます。本稿では、糖尿病治療の課題の1つである患者の「受診中断」という治療行動に着目し、治療をやめてしまいそうな患者を事前に予測する技術について紹介します。

## 糖尿病治療の課題～受診中断～

近年、糖尿病の患者数は増加傾向にあり、2014年には316万人に達しています〔平成26年患者調査（厚生労働省）〕。糖尿病は進行すると腎症等の合併症等を引き起こし、患者自身のQOL（Quality of Life）の低下や医療費の増大につながるため、糖尿病患者には治療の継続が求められています。しかし、糖尿病患者の約1割が受診を中断し、合併症の発症後、病態が悪化してから受診を再開するというケースが多いことが問題となっています。

この問題を解決するために、従来より受診中断の要因を明らかにするため、属性や検査値から受診中断者の特徴に関する調査が行われています。年齢が低いことや男性の有職者などの特徴が報告されており、『糖尿病受診中断対策包括ガイド』<sup>(1)</sup>として糖尿病治療にかかわる医療従事者に周知・活用されています。しかし、受診中断にはさまざまな要因が考えられるため、医師がここからさらに積極的に支援すべき患者を個人にまで絞り込み、支援することが難しい状況でした。そこでNTTは東京大学医学部附属病院（東大病院）と共同で、電子カルテデータ

を基に受診中断を個人レベルで予測するモデルの構築をめざしました。予測精度を高めるため、NTTがこれまで培ってきた機械学習に関する知見と東大の医療データ分析や臨床での患者への指導に関する知見を参考にして生成した特徴量を基にモデルを構築しました<sup>(2),(3)</sup>（図1）。

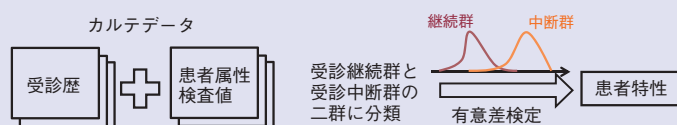
## 受診中断予測モデルの設計

積極的に支援すべき患者さんの絞り込みに向けて、受診中断の引き金となり得る外来予約（予定されていた受診が履行されず、それ以後の受診が中断に至る可能性が高い予約）の不受診の予測に取り組むことにしました。具体的には、外来予約日（予約が登録され、

受診することを予定した日）までの電子カルテデータから抽出した特徴量ベクトル $x$ （説明変数）を用いて、受診が中断された外来を+1、受診が継続された外来を-1と定義されたクラス $y$ （従属変数）を予測するロジスティック回帰モデル<sup>\*1</sup>を設計しました。これにより次の外来予約日に患者が来るのか、来ないのかを予測することができます。特徴量ベクトルが $x$ であるデータがクラス $y$ に帰属する確率を、重みベクトル $w$ を用いて、以下のようなモデル式で表すことができます。

\*1 ロジスティック回帰モデル：はい、いいえのように2値しか取り得ない従属変数のデータを用いてその発生確率を予測するモデル。

(a) 従来：受診中断と関連する患者特性を明らかにする取り組み



(b) 本研究：受診中断の引き金となり得る不受診外来を予測する取り組み




図1 糖尿病患者の受診中断、関連研究に関する状況と本研究の取り組み

$$P(y|\mathbf{x};\mathbf{w}) = \frac{1}{1 + \exp(-y\mathbf{w} \cdot \mathbf{x})}$$

帰属するクラスが既知のデータ集合  $\{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n), \dots, (\mathbf{x}_N, y_N)\}$  を用いて  $\mathbf{w}$  の値を推定することで、モデルを学習させました。ただし、特徴量の種類（特徴量ベクトルの次元）が学習に用いるデータ数と比較して多い場合、モデルを過学習<sup>\*2</sup>させる危険性が高まるため、L2正則化<sup>\*3</sup>を用いて過学習を抑制し、モデルの汎化性能を高めています。

## 特徴量の設計

次に、特徴量の設計を行いました。単純に電子カルテデータに含まれるさまざまなデータを学習させるだけではなく、予測精度を高めるために糖尿病専門医の知見や患者の意見、人の行動分析の知見を活用して特徴量の設計に取り組みました。すなわち、電子カルテからそのまま機械的に出力した患者の病状に関連する特徴量（X1群：29025種類）と私たちが独自に検討した受診中断との関連性が高いと考えられる特徴量（X2群：97種類）の2種類を設計しました。

まず、X1群の特徴量を表1に示します。これらは、外来予約日より過去

表1 X1群の特徴量の例

| 項目   | 特徴量           |
|------|---------------|
| 受診歴  | 診療科           |
| 病歴   | 確定した病名・疑われた病名 |
| 処方薬歴 | 処方薬剤、服薬タイミング  |

表2 X2群の特徴量の例

| 項目    | 特徴量                                                                           |
|-------|-------------------------------------------------------------------------------|
| 属性    | 性別・外来予約日の年齢<br>自宅から病院までの距離・時間                                                 |
| 受診歴   | 累積外来受診回数<br>受診した曜日                                                            |
| 外来予約歴 | 予約登録日と外来予約日の間隔<br>予約登録日と外来予約日の曜日一致<br>予約登録曜日<br>予約登録日の糖尿病代謝内科受診有無<br>外来予約日の天気 |
| 処方薬歴  | 同時に処方された処方薬の種類<br>錠剤処方薬のサイズ                                                   |
| 検査歴   | HbA1c, HDL-C, LDL-C, 中性脂肪, 総コレステロール                                           |

に受診していた診療科、診断された病名、処方された薬剤の名前および処方時期、実施された手術および検査に関するものです。該当すれば1、そうでなければ0とする二値で構成されます。また、症状については発症した時期として外来予約日直近と外来予定日より前（直近かどうかは問わず過去のいずれかの時期）を区別するため、外来予約日からさかのぼって90日以内を対象にしたものと外来予約日よりも過去を対象にしたものの2種類を用意しました。

次に、X2群の特徴量を表2に示します。これらは患者の「行動」に着目

して設計しました。これは、予約不受診という行動が患者自身の行動特性や置かれている環境に左右されやすいのではないかと考えたためです。例えば、行動特性や環境要因を示唆するものとして外来予約日の曜日や外来予約当日の天気や錠剤処方薬のサイズなどが挙げられます。また、糖尿病専門医の「薬の飲み忘れが多いような受診中断の可能性が考えられる患者への対策として処方日数や服用タイミングを変更し、通院周期を短くするような対応を取る」といった話を参考に薬の処方に関する項目を選びました。糖尿病患者への聞き取り調査では「治療の必要性が

\*2 過学習：訓練データに合わせすぎて、汎用的に成り立たないモデルを得てしまうこと。

\*3 L2正則化：過学習を抑制するため、特徴量の重みの大きさにペナルティを与える手法。

理解できると治療を継続しようと思う」といった意見を参考にこれまでの通院や病気の経験にかかわる項目を選びました。外来予約日の天気や錠剤処方薬の形状については、それぞれ気象庁や独立行政法人医薬品医療機器総合機構が管理するデータベースを参照しました。また、先行研究からは受診中断の関連因子とされる性別や年齢、交通の便などを利用しました。

### 予測モデルの評価

対象外来レコードは、その外来に対応する患者が以下の3つの条件を満たすこととしました。


- ① 2004年1月1日以降、東大病院の糖尿病・代謝内科の外来に初診で来院
- ② 初診日から3カ月以内に糖尿病の病名コード（ICD10 E10からE14）が電子カルテに入力
- ③ HbA1cの検査オーダーが初診日から3カ月以内に発行

また、対象とする外来予約の期間は、2011年4月1日から2014年6月30日までとしました。予約行動判定の結果を表3に示します。継続外来群は15104件（869人）、中断外来群は922件（285人）でした。

X1群、X2群の特徴量を学習させた予測モデルはROC（Receiver Operating Curve）曲線を用いて評価を行いました。結果を図2に示します。モデルに

表3 予約行動の判定結果

| 予約行動             | 件数（患者数）      |
|------------------|--------------|
| 新規の予約登録          | 32962件（879人） |
| 予約日程変更           | 4680件（619人）  |
| 外来予約を伴う受診（継続外来群） | 15104件（869人） |
| 外来予約を伴わない受診      | 228件（116人）   |
| 他に予約を伴う外来不受診     | 493件（232人）   |



ROC曲線下の面積（AUC値）が大きいほど（曲線が左上に近づくほど）予測性能が高いことを表す（完全にランダムな場合は0.5）

図2 ROC曲線

用いる特徴量の違いが予測精度に与える影響をAUC（Area Under the Curve）値によって調べてみると、X1群単独では0.912であったのに対し、X2群単独では0.943とX1群単独と比較して予測精度を上げることができました（表4）。

X1とX2の両群を用いると、X2群単独と比較して予測精度はさらに改善することも分かりました（AUC=0.958）。AUC値に基づく性能評価では、一般に0.9以上はExcellent discrimination（優れた予測性能）と位置付けられて

表 4 AUC値, 適合率, 再現率, F値

| 特徴量               | AUC値  | 適合率   | 再現率   | F値    |
|-------------------|-------|-------|-------|-------|
| X1群 <sup>※1</sup> | 0.912 | 0.466 | 0.438 | 0.449 |
| X2群 <sup>※2</sup> | 0.943 | 0.750 | 0.577 | 0.652 |
| X1+X2群            | 0.958 | 0.757 | 0.659 | 0.704 |

※1 電子カルテに格納されているデータ

※2 電子カルテデータを整形して得たデータ

いることから、本予測モデルは中断の引き金となり得る不受診外来を精度良く検出し、積極的な治療継続支援が必要な患者に支援を提供する時期を絞り込むのに役立つと期待できます。また、用いた特徴量別に予測の正確性と網羅性を同じく表4に示しています。X1とX2の両群を用いたモデルの適合率は0.751、再現率は0.654、F値は0.698という結果が得られました。これらは、それぞれすべてのデータのうち予約不履行の正解データが約7割含まれていたこと（適合率）、正解データの約7割を見つけることができること（再現率）を示しています。同様にX1群の特徴量だけで分析した場合を考えますと、4割程度しか見つけられないので、図3に示すとおり、特徴量の工夫により大きく予測性能を高めることができましたといえます。

### 寄与度の高い特徴量

高い予測精度に寄与した特徴量が何かを調べるために、個々の特徴量について、重みの大きさを用いてそれぞれの予測精度への影響を比較しました。その結果を表5に示しています（上位3件と下位3件を表示）。重みは、X1+X2群の特徴量を用いたロジスティック回帰モデルを学習して得られました。重みが大きい特徴量ほど受診中断の予測に大きく影響しています。重みが大きい特徴量から明らかなよう




図 3 特徴量の工夫

表 5 寄与度の高い特徴量

| 特徴量                  | 継続外来群   | 中断外来群  | 重み   |
|----------------------|---------|--------|------|
| 質：予約登録日の曜日：日         | 91件     | 73件    | 2.4  |
| 質：外来予約日の曜日：金         | 2338件   | 493件   | 1.9  |
| 量：予約登録日と外来予約日の間隔     | 平均45.8日 | 平均8.0日 | 1.4  |
| 質：バセドウ病（過去に疑いが晴れた病名） | 445件    | 2件     | -1.3 |
| 質：外来予約日の曜日：月         | 2386件   | 83件    | -1.3 |
| 質：フェノフィブラート（過去の処方薬剤） | 163件    | 0件     | -1.1 |



に、患者の病態よりも外来予約行動に関する特徴量が予測に大きく影響を与えるように予測モデルが学習されていました。予約登録日の曜日、外来予約日の曜日、予約登録日から外来予約日までの日数がモデルの予測精度に影響しており、特定の条件下（日曜日に予約登録が行われ、外来予約日が金曜日であり、登録日から予約日の期間が短いなど）では不受診が起りやすいことが示されました。これらは、これまで医師が気付かなかった患者の予約行動を今回の分析技術が見つけたとして、共同研究者である糖尿病専門医の先生から評価いただいています。このような不受診、それに続く受診中断リスクの高い患者を絞り込み、不受診と関連する因子を修正する（予約登録日から外来予約日までの日数を長くするなど）方策の検討の一助となると考えています。このように予測結果を基に受診中断を避けるために積極的に支援すべき患者の絞り込みや支援時期の見極め、リスクの高さに合わせた支援の度合いの調整が可能となることから、医師の診療支援、ひいては患者の病態の維持、改善につながることを期待されます。

## 今後の展開

機械学習を用いた初の試みとして、外来予約日までの電子カルテデータから患者の行動特性を示唆する特徴量の


生成に工夫を凝らし、糖尿病外来患者の受診が中断するきっかけとなり得る外来予約の不受診を予測するモデルを設計し、高い予測精度を示すことができました。機械学習分野では人に適切な手段や情報を提示する技術としてリコmend技術が提案されており、患者の不受診回避に適切な受診中断対策を選択する技術として適用することも検討していきたいと考えています。また、telemedicine領域の研究結果からは患者の登録データ（生体情報や生活習慣）に基づいて患者に生活習慣に関するフィードバックを行うと特に食事内容に関連した患者の行動が患者自身によって修正されることが明らかになっており<sup>(4)</sup>、これに類似して患者が次の外来予約を登録すると、予約日近くに予約確認のフィードバックがなされ受診への動機付けを行うなども1つの解決策となり得ると考えています。現在、電子カルテデータの標準規格が普及し大量の診療データを扱える環境が整いつつあることから、これを活用しながら本予測モデルの改善に取り組んでいきます。

## 参考文献

- (1) 野田・山崎・林野・泉・後藤：“糖尿病受診中断対策包括ガイド”，2014。
- (2) H. Kurasawa, K. Hayashi, A. Fujino, K. Takasugi, T. Haga, K. Waki, T. Noguchi, and K. Ohe : “Machine-Learning -Based Prediction of a Missed Scheduled Clinical Appointment by Patients With Diabetes,” J. Diabetes Sci. Technol., Vol.10, No.3, pp.730-736, 2016.
- (3) 倉沢・林・藤野・高杉・芳賀・脇・野口・大

江：“機械学習を用いた糖尿病外来受診中断予測,” 第19回日本医療情報学会春季学術大会, 2015.

- (4) K. Waki, H. Fujita, Y. Uchimura, K. Omae, E. Aramaki, S. Kato, H. Lee, H. Kobayashi, T. Kadowaki, and K. Ohe : “DialBetics: A Novel Smartphone-based Self-management Support System for Type 2 Diabetes Patients,” J. Diabetes Sci. Technol., Vol.8, No.2, pp.209-215, 2014.



(左から) 藤野 昭典/ 倉沢 央/  
林 勝義

病態悪化など健康状態の変化の予兆をとらえる技術の研究開発に継続して取り組み、さまざまなICTサービスと連携しながら、人間のQOLの向上や医療費増加の抑制など社会課題の解決に貢献していきたいと考えています。

## ◆問い合わせ先

NTT未来ねっと研究所  
ユビキタスサービスシステム研究部  
TEL 0422-59-4316  
FAX 0422-59-4810  
E-mail kurasawa.hisashi@lab.ntt.co.jp