

医師不在地域における機械学習を用いた遠隔医療相談のプロセス改善に関する研究

谷口 敦¹ 甲斐 瑛子² 井上 創造¹ 野原 康伸³ Ashir Ahmed² 中島 直樹³

概要：現在，バングラデシュで遠隔医療を取り入れた大規模集約的健康診断，Portable Health Clinic を行っている。通信付き検査機器を使用し健診を行い，その健診結果を基に患者の選別を行った後，医師との遠隔医療を受けてもらう生活習慣病の予防，または医師との遠隔相談を通じた治療をするプロジェクトである。しかしながら，そういったプロジェクトの中でもリスクの高い患者が多く，以前として遠隔地の医師の時間はとても貴重であることが分かった。本研究ではそのような Portable Health Clinic の問診プロセスを改善する為に，医師が自然言語で書く患者の訴えなどを言語処理し，活用し健康診断および遠隔医療のプロセスを改善することを目的とする。

Evolving Health Consultancy Process in Doctor-absent Area by Machine Learning

TANIGUCHI ATSUSHI¹ KAI EIKO² INOUE SOZO¹ NOHARA YASUNOBU³ ASHIR AHMED² NAKASHIMA NAOKI³

1. 背景

発展途上国では栄養失調，子供の低体重，栄養失調や感染症といった伝統的な疾患などが人々の健康を脅かす最も大きな要因であった。しかし近年では高血圧や糖尿病といった生活習慣病が蔓延している。またその多くの国で医師が不足しており，問題を深刻化させている要因の一つになっている [1]。また近年，発展途上国においても，糖尿病や高血圧症をはじめとする生活習慣病が急激に増加している一方で，その多くの国が深刻な医師不足にあえいでいる。その上，医師や医療施設が都市に集中し，農村部では十分な医療サービスが行われていない。そのため遠隔医療のニーズが高く，実際に携帯電話網を用いた電話医療相談サービスが実際に導入されている [2]。しかし，携帯電話のみの遠隔診療では医療診療の質の確保は困難である。このような状況においては，遠隔医療が必要か否かの患者選別（トリアージ）方法および，それと効率よく連携する遠

隔医療のプロセス構築が必要となる。

現在我々は，バングラデシュのグラミンググループと共同で，健診・遠隔医療サービス実証実験（Portable Health Clinic）を行っている [3,4,5]。Portable Health Clinic のプロセスは

- 問診：まず患者が問診を受ける
- 健康診断：持ち運び可能なアタッチケース型の診断パッケージによる診断を受ける，また測定結果をタブレット PC に集約させるその結果を用いて国際的診断基準をもとに受診者を4段階に自動分類（トリアージ）する
- 遠隔医療，処方箋の発行：首都ダッカのコールセンターには，医師が駐在しており，トリアージの際にオレンジ色の注意マーカー，赤の危険マーカーをされた患者を，Skype ソフトウェアを用いて医師が問診・健診結果を見ながら遠隔診療する

という仕組みになっている。

この Portable Health Clinic は医師不在地域の患者の健康改善に役立っているが，遠隔医療に依然として時間がかかっていることが課題である。そこで，自然言語で記録される患者の訴え（主訴情報）が活用されていない点に注目した。遠隔診断の際のアドバイスを問診，健診結果から，

¹ 九州工業大学
1-1 Sensuicho, Tobata-ku, Kitakyushu, Fukuoka, 804-8550, Japan

² 九州大学
W2-726, Ito Campus, 744 Moto'oka, Nishi-ku, Fukuoka, 819-0395, Japan

³ 九州大病院
3-1-1, Maidashi, Higashi-ku, Fukuoka, 812-8582, Japan

機械学習によって予測する事によって、問診の時点で予測されるアドバイスを現地のヘルスワーカーに自動的に提示することにでき、ヘルスワーカーが医師に変わってアドバイスをすることができるようにすることを目指す。

また、現在手書きで行っている問診を電子化するための Web システムを作成した。さらに Portable Health Clinic の既存データである問診データ健診データを機械学習し、医師が出すアドバイスを予測しその予測精度 76.24% を得た。さらにそこに主訴情報のデータを加えることによってアドバイスの予測精度が 82.55% に上がった。また時間の消費をモデリングし推定されたパラメータに基づきシミュレーションを行った。現在医師にかかっている 211.86 時間に対し、119.38(56.33%) 時間まで短縮できた。

今後、すでに実装済の問診内容の Web 入力システムに問診プロセスを改善する手法を組み込み、実際に現地に導入する予定である。

本稿の構成は以下のとおりである。2 章では関連研究と現在バングラデシュで行っている Portable Health Clinic の説明、3 章で Portable Health Clinic のプロセス改善のための提案手法、4 章ではその実装とその評価を述べる、最後に 5 章で本稿をまとめる。

2. 関連研究

発展途上国での健康診断サービスは、医師が少ない地域の患者の健康改善に大きく役に立っている。バングラデシュは患者へのサービスのマルチ化 [6]、より多くの人に医療サービスを受けてもらうためのコミュニティー生成 [7]、また国民保険への試み [8]、子供のための医療提供 [9]、さらには自然災害による健康被害の軽減のための公衆衛生活動 [10] などここ 10 年で大きく進歩をしている [11]。

近年このような途上国においても、モバイルコンピューティングの技術がヘルスケアの現場に置いて拡大している。バングラデシュの隣、インドにおいて携帯電話の携帯電話のメッセージング機能を使用し、生活習慣病の改善を目的とした研究 [12] が行われた。35 歳から 55 歳までの働いている男性 8741 人をランダムに選び、通常の労働集約的介入群と携帯電話のメッセージ機能による介入群の 2 グループに分け、無作為化比較試験を行っている。この研究ではモバイルコンピューティングの技術が発展途上国で役に立つ点、また健診データのような実際のデータを使用すればより良い結果が見出される可能性が示されている。

一方、近年の医療現場において Clinical Decision Support System(CDSS)が発達してきた [13]。CDSS とはヘルスワーカーが、健診や治療、または処方などの指示をするなどの意思決定を行う際に、判断ミスを抑制して医療の安全の向上や臨床上の判断根拠の共有を図るシステムである。CDSS の課題は自動的に患者の病気を診断することである。静的ではあるが、電子カルテから糖尿病を認識するためのルー

ル設計の開発 [14]、また退院情報から疾患を予測するルールを提案 [15] するような論文も出ており、そのうちいくつかは予防治療の研究もある [16]。

加えて近年、機械学習や、データマイニングによる自動化ルールモデルの研究が多く出ている。[17,18,19]。薬物療法と患者との問題の相関ルールの論文 [20] や、複数の医師の判断情報から患者の薬を予測するものもある。

さらに、自然言語処理技術は、臨床データのために利用されることが期待されている [20,21,22,23,24,25,26]。

2.1 Portable Health Clinic について

グラミンググループは、主として女性によって運営される医療ビジネスを創設することを検討していた。そこで上記で述べた農村部での医師不足という理由も含め、「Portable Health Clinic」(PHC)を構築している。アタッシュケースに医療機器、通信機器などを適切に接続し、パッケージ化する。それを看護師などのヘルスワーカーが農村部や企業事業所へ持ち込む。この機材により収集された対象者の生体情報や病歴情報は、携帯電話網を活用して、首都ダッカにあるコールセンターに集約される。この健診で生活習慣病発症者や予備軍を抽出し、リスクに応じて現地での保健指導（リスク種別のベンガル語パンフレットを渡すなど）やコールセンターの医師からの遠隔診療を行う。これを定期的に繰り返し、社会システムとしての「Portable Health Clinic」の効果を検証するとともに、データを蓄積している。

システムの稼働は、2012 年 7 月からで、2012 年度は、8527 名が初回健診を受診し、1 日当たりの最大受診者数は 307 名であった。初回健診受診者のうち 1635 名が橙・赤と判定されて遠隔診療を受診した。

2.1.1 業務の流れ

問診 問診では生活習慣・病歴など 30 項目をヘルスワーカーが患者に聞く。Portable Health Clinic ではアタッシュケース型医療キット 1 台を複数人に対して使うため、バーコードなどを用いてユーザー ID を読み込み、別の ID が読み込まれるまでその個人の情報を識別する。

健診 次に健康診断を行う。持ち運び可能なアタッシュケース型の診断パッケージによる診断を受ける健康診断では、身体情報・健診情報（血圧 / 動脈酸素飽和度 (SpO₂), 血糖値等）など 15 項目を血圧計などの測定機器を使い測定する。

トリアージ 測定結果に基づき、患者の選別を行う。国際診断基準を基に生活習慣病の専門医が定めた B-logic と呼ぶ判断基準に基づき、リスクが低い受診者から順番に「健康 (緑)」「要注意 (黄)」「要治療 (橙)」「要緊急治療 (赤)」の 4 段階 (色) に分類する。「要治療」「要緊急治療」の人は首都ダッカにいる医師と遠隔医療相談

をおこなう。また、「要注意」の人は、生活習慣改善のための保健指導パンフレットを配布される。

遠隔医療 首都ダッカのコールセンターには、医師が駐在しており、既に生活習慣病に罹患していることが健診で判明した患者を、遠隔医療は、農村の患者と都市にいる医師をインターネットでつなぎ、Skype ソフトウェアでの遠隔医療相談が行われる。医師は、基本的な問診・健診データと相談内容の中の患者からの訴えを元に遠隔処方箋を出し、生活習慣に関するアドバイスを与える。

処方箋 アドバイス リスクを項目ごとに4段階で示した健診結果と、医師からの処方箋とアドバイスは、現地でプリントアウトされる。患者はそれに従って、現地に多く存在する薬局で処方された薬を手に入れる。また、1回目の健康診断で遠隔医療相談を受けた、すなわち「要治療」「要緊急治療」の人たちは、約2ヶ月後に再健診を受診するよう求められる。再健診を済ませた後、再び遠隔医療による相談を受ける。

図 1

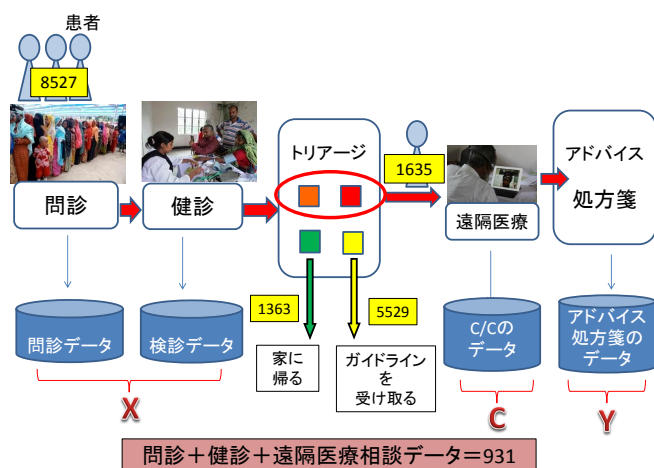


図 1 Portable Health Clinic の過程

2.1.2 データの収集

PHC では持ち運び可能なアタッチケース型の診断パッケージによる健康診断を受ける。身体情報・健診情報（血圧/動脈酸素飽和度 (SpO₂), 血糖値等) など 15 項目を血圧計などの測定機器を使い測定する。

パッケージは、6 種の通信機能付き検査機器

- 血圧計 (収縮期血圧/拡張期血圧/脈拍数/不整脈)
- 体重計 (体重/[BMI])
- 体温計 (体温)
- 血糖計 (血糖値)
- パルスオキシメータ (SpO₂)
- 電子メジャー (ウエスト/ヒップ/[ウエストヒップ比])

と 2 種の手動測定器具 (尿検査紙 [糖・蛋白・ウロビリノー

ゲン], メジャー), 携帯プリンタとタブレット, ノート PC, モバイル WiFi ルータから構成される。各機器は、手動計測器具を除き、携帯プリンタを含めて全て電池を搭載しており、停電時でも業務を継続することができる。この健診パッケージは、日本において訪問看護や在宅診療に活用することも想定して、日本の薬事法承認済の医療機器で構成されている。計測機器とデータ端末間の通信規格には、既存の Bluetooth に変わり、Body Area Network (IEEE802.15.6) が採用されている。BAN は 2012 年 2 月に、世界で初めて医療用途向け短距離無線通信技術として成立した国際規格であり、より安全に低消費電力で医療データを収集することができる。

既存の Bluetooth 等と比べて、より安全に低消費電力で医療データを収集することができる。BAN にネイティブに対応した医療機器は現在のところ市販されていないため、市販の医療機器に外付けする形で BAN の通信モジュールを搭載し、対応させることとした。

3. 提案手法

2.1 章のような健診と遠隔医療を組み合わせた実証実験においても、リスクの高い患者が多すぎて遠隔医療をこなせず、また生活習慣病リスクが低くとも医師との面談を希望する患者が出てきて、依然として医師の時間リソースが貴重であることが分かった。また現在問診の際、手書きで内容を聞き取り紙に書き、パンチングした後で手打ちでデータを手入力してデータベースに入力している。そこで健診の時同様、問診内容もデータを打ち込むシステム、打ち込まれたデータをデータベースに送信することができるシステムを実装した。

3.1 データ収集システム

ここでの要求はまず入力しやすいかつ解析しやすい Web システムを実装する必要がある。現地のスタッフは ICT の知識があまりないので、よりシンプルにした。

また健診同様、集団に使うため、バーコード等を用いて個人を識別し (ユーザー ID を読み込み), 別の ID が読取られるまでをその個人の情報として取り扱う必要がある。また患者の取り違えが発生しないように、名前や ID 等を画面に表示する必要がある。

また現地スタッフが使用するため、使用言語はベンガル語、もしくは英語で作成する必要がある。現時点で健診のデータ入力の際は英語で行われており、医師が遠隔医療の際に書き留める主訴情報はベンガル語が使われている。今回、すでに開発の自由度を考慮して Android のタブレットで行っている。Web システムは Android のタブレット用に実装を行い、かつヘルスワーカーがデータを入力しやすいように 1 ページに収まるように実装した。

まず現在手書きで書き込んでいる問診内容を、HTML

フォーム化し、サーバに送られたデータを PHP 言語でデータベースシステムに格納するようにした。その際フレームワークである jQuery mobile を使用した。管理をしやすくするために jQuery mobile の大きな特徴であるページが遷移できる点を活かし、質問毎にページ内遷移をし、最後にまとめてデータ送信を行った。なお 2013 年度用の問診内容では計 9 ページに至った。

3.2 機械学習

我々はヘルスワーカーが情報システムの補助によりあらかじめ、医師が入力している主訴情報、さらに医師が患者に対して出すアドバイスを得ることができれば、医師の仕事を減らすことができ、貴重な時間を節約できると考えた。

ここで提案するのは、ヘルスワーカーが患者から得た問診データを入力し、健診データを計測機器から取得したら、予め機械学習をした主訴情報を重要度順に表示し、患者に選択させ、それをもとに関連のあるアドバイスを予測し、許された範囲内で患者に尋ねるシステムである。また仮にヘルスワーカーがアドバイスに至らなくとも、問診結果や健康診断結果に加えて、本システムで得られる主訴情報を医師が遠隔で確認することにより、医師は問診漏れを防ぐことができ、また必要な情報が揃った上で遠隔医療相談ができるため、短時間でアドバイス、薬の処方ができると考えられる。

そこで医師が出すアドバイスを今回のプロジェクトより得られる問診データ、健診データそして主訴情報から予測するために機械学習を取り入れた。(図 2)

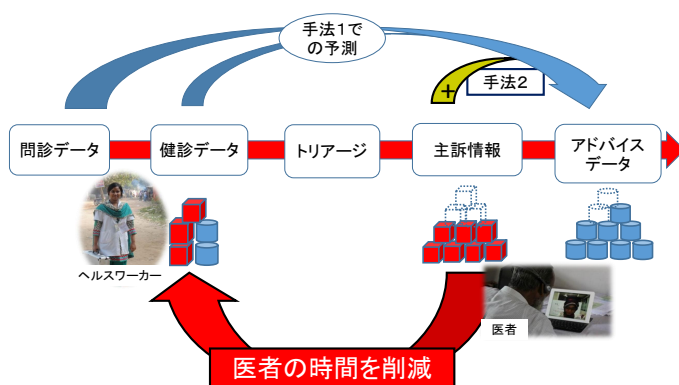


図 2 提案手法

(1) まずヘルスワーカーは患者から主訴情報、加えて問診データ、健診データを集める。その主訴情報データは単語レベルであるので、文章化し準備しておく。例えばもし”pain”を言う単語が出てきた際には”Do you have any pain in your body?”と言った形で表示させる。このようにすればヘルスワーカーが予め機械学習しておいた予測システムを使い、患者にアドバイスを与えることができる。

- (2) 次に過去の問診、健診、主訴情報のデータセットより学習されたモデルを元に、患者に対してアドバイスが必要かどうかを予測する。
- (3) ヘルスワーカーは、システムの予測により患者にアドバイスを与えるようにする
- (4) 医師はシステムまたはヘルスワーカーが正しい予測をすれば、アドバイスをスキップすることができる。アドバイスが正しければ保証をし、もし予想が正しくなければ正しく訂正しなおす。

3.3 データセット

問診データ、健診データ、主訴情報データ、さらにアドバイスデータがある。

システムの稼働は、2012 年 7 月からで、2012 年度は、8527 名が初回健診を受診した。1635 名が危険なカテゴリーと判定されて遠隔診療を受診した。そのうち完全なデータを入手できた 931 人分のデータを今回の分析対象とした。

3.3.1 データの種類

我々は 4 タイプものデータを記録した。

- (1) 問診データ: 生活習慣や過去の病気の情報を含む基本的な 32 個の質問を患者に対して行う。カテゴリーデータを含む。例として”あなたは定期的に服用している薬はありますか? 降圧剤ですか?”という質問に対して”はい”または”いいえ”で回答してもらう。(表 2)
- (2) 健診データ: 19 個の測定機器を使い、機器と同期されたタブレット端末によって集められる。血圧のような連続データ、また尿検査のようなカテゴリーデータがある。国際診断基準を基に生活習慣病の専門医が定めた B-logic と呼ぶ判断基準に基づき測定していく(表 3)。

表 3 健診のデータセット

	最小値	平均	中央値	M 最大値	標準偏差
Age	19	43	45.5	106	13.9
BMI	12.29	22.52	22.09	39.78	4.08
縮小期血圧 [mmHg]	76	127.85	122	290	23.87
拡張期血圧 [mmHg]	52	81.17	80	155	12.41
血糖値 [mg/dl]	36	109	97.5	600*	4.08
SpO2	87	98.16	98	100*	0.99
UrineProtein	-*	NA	NA	+++*	NA
UrineSugar	-*	NA	NA	+++*	NA
UrineUrobilinogen	±*	NA	NA	+++*	NA
PlusRatio	50	84.02	83	130	12.85
Body Temperature	91.08	97.19	97.47	100.67	1.331

(3) 主訴情報データ: 患者と医師との間で行われ、自由記述で書き込まれる主訴情報データで、テキストなので複雑である。そこでそのテキストデータを単語レベルに区切り、解析している。例えば”pain in the right hypochondriac for 3 years”という記述があった際は”pain”, ”in”, ”the”, ”hypochondriac”, ”for”, ”3”, ”yeaes”に分割してい

表1 データセット

データの名前	データの種類	# データの変数	データの型
(1) 問診データ	カテゴリデータ	32	Boolean
(2) 健診データ	連続データ or カテゴリデータ	19	-
(3) 主訴情報	自由記述	137	Word vectors
(4) アドバイスデータ	選択式 or 自由記述	21	Boolean

表2 問診リスト

	Question
Q1	What is the elapsed time from your last meal?
Q2	Do you have any symptom or trouble in your body?
Q3-Q5	Do you take any of the following medicines periodically? (Anti hypertensive?, Insulin injection?, Cholesterol reducer?)
Q6-Q9	Have you ever been diagnosed as (stroke, heart disease, chronic kidney failure or got treatment of it, anemia) by a doctor?
Q10	Are you a regular smoker?
Q11	Have you gained 10kg weight since the age of 20?
Q12	Have you engaged in at least 30 minutes of exercises with sweating twice or more a week for over a year?
Q13	Do you walk or do any equivalent activity at least an hour a day in your daily life?
Q14	Do you walk faster than other people of the same sex and similar age?
Q15	Have you gained or lost over 3 kg weight for the past year?
Q16	Do you eat faster than others?
Q17	Do you eat dinner within 2 hours before bedtime three or more times a week?
Q18	Do you eat after dinner snacks three or more times a week?
Q19	Do you skip breakfast three or more times a week?
20	Do you get refreshing sleep?
Q21	Do you want to improve your habits of eating and exercise?
Q22	Do you have any drug allergy?
23	Have you ever gone under operation?
Q24	Do you consult with medical doctor or drug shop periodically?

る。全体の単語の中で5回以上出てきている単語を抽出すると131単語となった。(表4)

'after', 'ho', 'with'と言った意味が伝わりにくい単語があるが、これらの単語はシステムのパフォーマンスを改善する可能性があるので、わざと除外しなかった。

- (4) アドバイスデータ: 医師から患者に対して提案されるもので、遠隔地の医師がベンガル語で書かれた選択式のアドバイスを患者側に提供する。遠隔地の医師は一般的なアドバイスを選択することによってより簡単にアドバイスを提供できる。これにより、選択式のアドバイスをアドバイスデータとして扱うようにした。また医師は時折自由記述によるアドバイスを付け加える。"Go through the following checkup/test and if needed see the nearest specialist doctor —Fasting Blood Sugar". 下線部がフリーテキスト、下線のついていない部分が選択式のアドバイスである。

3.4 提案手法1: 問診, 健診からアドバイスの予測

まず問診データ, 健診データを入力データとして, アドバイスデータを出力データとして機械学習を行い, アドバイスを予測した。

- (1) データセットを準備する。そのデータセットは問診の

変数32個, 健診の変数19個を入力として, アドバイスの変数を21個を出力とした。

- (2) すべてのアドバイスに対して

- (a) SVMモデルでアドバイスを予測する。その際線形カーネル, クロスバリデーション($k=2$)で行う。その際, ネガティブデータとのバランスをとるためにポジティブデータを倍増させた。
- (b) その後, 元の正のデータの数を減らした後, 正解率を以下のように算出する。

$$Accuracy = \left(\frac{TN}{TN + FP} + \frac{TP}{TP + FN} \right) \times \frac{1}{2} \times 100(1)$$

ただし TP, TN, FP, FN はそれぞれ True Positive, True Negative, False Positive, False Negative となった健診の数である。

問診データと健診データを入力変数とし学習モデルを作成した21個のアドバイスそれぞれに対し予測精度を出した。

3.5 提案手法2: 問診, 健診, 主訴情報からアドバイスを予測

問診データ, 健診データに加え, 主訴情報データを加え手法1の予測精度を上げていく。

表 4 主訴情報単語リスト

words
abdomen, abdominal, acidity, after, allergy, allergic, anorexia, antihtn, antihypertensive, anxiety, appetite, asthma, back, bleeding, blood, body, bodyache, both, bp, burningsensation, case, chest, cold, complaints, constipation, cough, days, decrease, discharge, discomfort, distress, dm, drug, drugs, duration, during, easy, epigastric, eye, feet, fever, feverish, frequency, from, g, gastritis, generalized, glucose, grade, hand, headache, headache, heart, high, hip, ho, hot, htn, hypertension, increase, increased, insomnia, insulin, irregular, is, itching, joint, joints, knee, known, lbp, left, leg, leucorrhoea, level, limb, loss, low, lower, medication, menstrual, micturation, micturition, mild, month, months, multiple, n, nausea, neck, nocomplain, nocomplaints, noho, nospecific, not, obesity, occasional, occasionally, oha, or, oral, over, pain, palpitation, pattern, per, pressure, problem, pt, pud, pv, region, respiratory, right, same, several, side, skin, sleep, sometimes, sweating, swelling, taking, times, to, uncontrolled, upper, urine, uti, vertigo, weakness, weight, which, whitish, whole, with, work, year

表 5 アドバイスリスト

Advice No.	Advice
Ad1	Walk or do physical exercise regularly
Ad2	Check blood pressure every week regularly. If pressure is not normal for few weeks, see the nearest doctor.
Ad3	Check diabetes every month and if not normal see the nearest specialist doctor.
Ad4	Drink lots of water
Ad5	Continue current medicine as usual
Ad6	Walk 30 minutes regularly
Ad7	Take medicine regularly as per instruction
Ad8	Go through the following checkup/test and if needed see the nearest specialist doctor.
Ad9	Do not bend down to work
Ad10	Do not smoke
Ad11	Avoid tension and live easy
Ad12	Avoid oily food; eat less fat and less spicy foods
Ad13	Take FBS (Fasting Blood Sugar) test to confirm diabetes. If needed see the nearest specialist doctor.
Ad14	Comply with the diabetes diet plan.
Ad15	Do not take raw salt with meal.
Ad16	Use high commode in toilet
Ad17	Eat more vegetables
Ad18	Avoid soft bed and prefer hard mattress
Ad19	Check your pressure after 7 days. If the pressure is not normal, see the nearest doctor.
Ad20	Do not eat sweets.
Ad21	Do not lift heavy weight

3.5.1 オッズ比の計算と主訴情報の単語のランク付け

- (1) 前の章で紹介した単語抽出する方法で主訴情報を準備する
- (2) さらに主訴情報の単語を手法 1 で使われているデータセットに 1 単語ずつ追加していく。ここでは主訴情報データ以外に問診データの変数が 32 個、健診データの変数が 19 個、加えアドバイスデータ変数が 21 個使われた。
- (3) 各アドバイスの変数に対して、
 - (a) ロジスティック回帰によって見積もり、オッズ比を各主訴情報変数 137 個ごとに以下の式で計算した。

$$\text{オッズ比} = \frac{TP/FN}{FP/TN} \quad (2)$$

- (4) の正の値が出た 21 個の主訴情報変数のオッズ比の平均を計算する。

- (5) 平均を出した主訴情報を降順に並べる。

3.5.2 問診データ健診データ主訴情報よりアドバイスを予測

- (1) k の値を 1 から主訴情報の単語数まで
 - (a) 主訴情報の単語でオッズ比 k が最も高いものを抽出
 - (b) 手法 1 に、選んだ主訴情報の単語を加えていき同じ手順を行う。
 主訴情報の単語を加えていき、21 個のアドバイスごとそれぞれに予測精度を出した。アドバイス予測の際、問診、健診、主訴情報の変数を使用し、アドバイスそれぞれに対し学習モデルを作成した。

4. 評価

この章では、医師の主訴情報、またはアドバイスを与え

る時間を減らすシミュレーションによる評価を行う。今回我々はPHCのプロセス改善への結果が得られた。

評価のポイントは

- (1) 問診データ、健診データより、アドバイスの予測が可能か
- (2) 主訴情報を入力データとして加えることによる予測精度の向上が見られるか
- (3) 遠隔地医師の時間を減らすことができるかである。

4.1 精度の評価




図3 各アドバイスの予測精度

図.3 (w.o.CC) は手法1の問診データ健診データからアドバイス(以下Ad)を予測した際の予測精度である。主訴情報は扱っていない。ここでの予測精度の平均は76.24%、最低で56.80%、最高で94.41%であった。

またアドバイスごとに見ると予測精度の傾向を見ることができた。問診データ、健診データのみで予測すると、Ad2, Ad3, Ad5, Ad16, Ad19, Ad20が80%以上という高いスコアを出した。Ad16とAd20以外は高血圧に関するアドバイスであった。これらのタイプのアドバイスは問診データ健診データのみで容易に予測することができる。

図.3 (with CC) は問診データ健診データさらに主訴情報を加え、そこからアドバイスを予測した際の予測精度である。この予測精度の平均は82.65%、最低で61.72%、最高で95.44%であった。図.4はそれぞれのアドバイスに対して主訴情報を加えて行くことによる予測精度の改善を表している。図よりいくつかのアドバイスは予測精度が60%程度の低精度のままであるが、いくつかのアドバイスは大体20単語の主訴情報を加えたあたりから精度が上がった。平均すると80%に達した。

予測精度の詳細を見ていくと、手法2での予測では、Ad9, Ad18, Ad21が手法1に比べ5%以上改善された。その全てが“痛み”に関するアドバイスであった。




図4 主訴情報を加えた際の予測精度

4.2 時間の短縮

ここで、医師の時間の短縮を評価するために、我々はまず、提案サービスに基づいて、時間消費モデルを定式化した。その後、実際のデータレコードからモデルのパラメータを推定する。特に医療従事者と医師の各活動の実際の時間を用いた。最後に、時間消費は通常時および推定したパラメータのシミュレーションに基づいた提案手法との間で比較する。時間消費を推定するための方法は我々の独自の方法であるが、そのパラメータを実データから導かれるいくつかの仮定を元に設定することでできる限り現実性を確保する。

4.2.1 時間のモデリング

時間短縮のモデリングをするために、医師もしくはヘルスワーカーが患者に対して主訴情報を出す時間とアドバイスを出す時間の合計時間に目をつける。もちろん実際の健康診断では並列化、もしくはパイプライン化がなされている。しかしながらそれは医師のコストに直接影響するため、いずれにしても合計時間が重要になる。

ここで $Y = (y_1, y_2, y_3, \dots, y_L)$ をアドバイスの項目の集合とし、 y_i は i 番目のアドバイスの項目とし、全部で L 項目あるとする。1つの主訴情報を聞く時間を t_{CC} と1つのアドバイスを与えるための時間を t_{Vi} と定義できる。また、アドバイス y_i に対し、 n 人に、実際に医師がアドバイスをあげる件数を q_i 件と定義する。

通常時では、医師は一人の患者に対して平均で T_c の時間だけかけると定義した。最終的に n 人に対して全 L 項目のアドバイスを与える時間の総和としては、

$$T_{Doc} = n \cdot t_{CC} + \sum_{i=1}^L t_{Ad,i} \cdot q_i \quad (3)$$

と表すことができ、現状では、これはすべて医師がかけている時間となる。

提案手法の機械学習中での、アドバイスの正解、不正解、また有無の4つの場合に基づき、ヘルスワーカーと医師の両方のコストを時間として計算する。現在医師は T_c 時間をかけている。次のステップとして、医師、もしくはヘルス

ワーカーが一つの主訴情報を聞く時間を t_{CC} と定め m 個の主訴情報を平均して聞くと仮定すると $T_C (= m \cdot t_{CC})$ と表せる。それぞれの患者は $m' (< m)$ 個の主訴情報を質問される。予測が正解だった場合、ヘルスワーカーはそのアドバイスが必要か必要でないかを決定することができる。もし不正解だった場合、医師は必ず主訴情報を聞くことによってその不正解を補わなければならない。この時間はアドバイス y_i に比例しているため $T'_{C,i}$ と定義できる。提案手法を用いて、 $m' (< m)$ 種類の主訴情報を聞くとする。1つのアドバイス l_i について、予測(有・無)と実測(有・無)を組み合わせた4つの場合についてそれぞれの件数 $q_{TN,i}, q_{FN,i}, q_{FP,i}, q_{TP,i}$ に基づいて計算する。

以下に変数を定義する。

- l : 患者がもらったアドバイスの個数
 - T_{doc} : 医師が遠隔医療にかかった時間
 - m : 主訴情報の数
 - t_{CC} : 1つの主訴情報を聞く時間
 - t_V : アドバイス1つあたりにかける平均の時間
 - $t_{V,i}$: 1つのアドバイス l_i を与えるための時間
 - $t_{Ad,i}$: 医師が l_i 個のアドバイスを与える時間
 - \bar{t}_{Ad} : 医師がアドバイスを与える時間の平均オーバーラインのついたパラメーターは元のパラメーターの平均を意味することとする。
 - $t_{Check,i}$: 医師が予測されたアドバイスの真偽をチェックする時間
 - $t_{Rev,FN,i}$: 医師が必要であればアドバイスをする時間
 - $t_{Rev,FP,i}$: 医師が不必要なアドバイスを訂正する時間
- (1) True Negative (TN): 分類器により、アドバイスが不要と予測し、実際にアドバイスが与えられていなかった。ヘルスワーカーが主訴情報を聞き、アドバイスが不要と判断し与えない場合で、医師は与えられたアドバイスをチェックする。
- ヘルスワーカーの時間: $q_{TN,i} \cdot m' \cdot t_{CC}$
 - 医師の時間: $t_{Check,i}$
- (2) True Positive (TP): 分類器により、アドバイスが必要と予測し、実際にアドバイスが与えられる。ヘルスワーカーが主訴情報を聞き、アドバイスが必要と判断しアドバイスを与える。医師は与えられたアドバイスをチェックする。
- ヘルスワーカーの時間: $q_{TP,i} \cdot (m' \cdot t_{CC} + t_{Ad,i})$
 - 医師の時間: $t_{Check,i}$
- (3) False Negative (FN): この場合は分類器により、アドバイスが不要と予測されたが、実際にはアドバイスが必要であった場合。ヘルスワーカーが主訴情報のみを聞き、アドバイスが不要と判断し、与えない。実際にはアドバイスが必要なため、医師がさらなる問診をし、アドバイスを与える。
- ヘルスワーカーの時間: $q_{FN,i} \cdot m' \cdot t_{CC}$

- 医師の時間: $q_{FN,i} \cdot t_{Rev,FN,i} + t_{Check,i}$

(4) False Positive (FP):

分類器により、アドバイスが必要と予測したが、実際にアドバイスが与えられていなかった場合。ヘルスワーカーが主訴情報のみを聞き、アドバイスが必要と判断し与える。実際にはアドバイスが不要なため、医師がさらなる問診をし、アドバイスを訂正する。

- ヘルスワーカーの時間: $q_{FP,i} \cdot (m' \cdot t_{CC} + t_{Ad,i})$
- 医師の時間: $q_{FP,i} \cdot t_{Rev,FP,i} + t_{Check,i}$

この4つの場合分けを、表にまとめると以下(表6)のようになる。

このすべての場合について総和を取ると、ヘルスワーカーの時間は、

$$T'_{HW} = n \cdot m' \cdot t_{CC} + \sum_{i=1}^L (q_{FP,i} + q_{TP,i}) \cdot t_{Ad,i} \quad (4)$$

このすべての場合について総和を取ると、医師の時間は、

$$T'_{Doc} = \sum_{i=1}^L \{(q_{FP,i} \cdot t_{Rev,FP,i} + q_{FN,i} \cdot t_{Rev,FP,i}) + n \cdot t_{Check,i}\} \quad (5)$$

と表すことができる。

4.2.2 モデルのパラメーター推定

t_{CC} , t_c , $t_{Ad,i}$, および T'_C の時間パラメータを、サーバー側のシステムのタイムスタンプからの直線回帰によって、これらの値を推定する。

- (1) 931人を遠隔医療診断を行ったタイムラインごとに並び替える
- (2) 遠隔医療は、2012年7月8日～2013年1月24日までの、のべ54日間行われた。
- (3) まず、日付をまたいでいない、最初と終わりが確認できる877人(=931-54)を時間計算の対象とする。
- (4) また、上下70人、合計140人を対象外とする。要するに約50分以下、約1.75分以上の範囲を対象とする。
- (5) 最終的に残った、対象とできる737人を解析対象のデータとする。1患者当たり、平均13.61分の診療時間がかかっていた。
予測変数を T_{doc} , 説明変数を患者がもらったアドバイスの個数をとった直線回帰式は $T_{Doc} = 703.97 + 33.95 \cdot l$ と表すことができる。ここで、切片:703.97[秒]は、医師が主訴情報を患者に聞く固定の時間 $m \cdot t_{CC}$ と考える事ができ、傾き:33.95秒は、医師がアドバイス1つあたりにかける平均の時間 t_V と考えることができる。
- (6) また、この固定した703.97秒以上にかかった遠隔医療の時間を、医師が患者にアドバイスをするために使った時間と考えた。この時間を、一人の患者が貰ったアドバイス数 l で平均を取り、各アドバイス1つあたりの時間 $t_{V,i}$ がかかっているかを示した。

表6 アドバイスに対する消費時間のモデル

Prediction \ Truth	Negative	Positive
Negative	Health Worker : $q_{TN,i} \cdot m' \cdot t_{CC}$ Doctor : $t_{Check,i}$	Health Worker : $q_{FN,i} \cdot m' \cdot t_{CC}$ Doctor : $q_{FN,i} \cdot t_{Rev,FN,i} + t_{Check,i}$
Positive	Health Worker : $q_{FP,i} \cdot (m' \cdot t_{CC} + t_{Ad,i})$ Doctor : $q_{FP,i} \cdot t_{Rev,FP,i} + t_{Check,i}$	Health Worker : $q_{TP,i} \cdot (m' \cdot t_{CC} + t_{Ad,i})$ Doctor : $t_{Check,i}$

4.3 パラメータの定義

ここにパラメータ ($t_{Rev,FN,i}$, $t_{Rev,FP,i}$, $t_{Check,i}$) を, チャンスレベルつまり推定器が当てずっぽうに答える場合, および完璧に当てることができる場合を想定し定義する. すべてのアドバイス数を q とすると, $q = L \cdot n = 19551 (= q_{TN} + q_{TP} + q_{FP} + q_{FN})$ と表せる.

4.3.1 条件 1: 各場合

- 完璧なシステム (予測率 100%) の場合, 医師がアドバイスを与える時間は現状の 1/10 に短縮できる. この場合, それぞれの人数は: $q_{TN} = 16390$, $q_{TP} = 3161$, $q_{FP} = 0$, $q_{FN} = 0$ となり, 条件式は以下の通りになる.

$$\begin{aligned} T_{Doc} \cdot 0.1 &= T'_{Doc,Perfect} \\ &= \left\{ n \cdot t_{CC} + \sum_{i=1}^L t_{Ad,i} \cdot q_i \right\} \cdot 0.1 \\ &= \sum_{i=1}^L \{ (q_{FP,i} \cdot t_{Rev,FP,i} + q_{FN,i} \cdot t_{Rev,FN,i}) + n \cdot t_{Check,i} \} \\ &= \left\{ n \cdot t_{CC} + (q_{FN} + q_{TP}) \cdot \overline{t_{Ad}} \right\} \cdot 0.1 \\ &= q_{FP} \cdot \overline{t_{Rev,FP}} + q_{FN} \cdot \overline{t_{Rev,FN}} + q \cdot \overline{t_{Check}} \\ (n \cdot t_{CC} + q_{TP} \cdot \overline{t_{Ad}}) \cdot 0.1 &= q \cdot \overline{t_{Check}} \\ \text{where } q_{FP} = 0 \text{ and } q_{FN} = 0 \\ (931 \cdot t_{CC} + 3161 \cdot \overline{t_{Ad}}) \cdot 0.1 &= 19551 \cdot \overline{t_{Check}} \\ \overline{t_{Check}} &= \frac{(931 \cdot 703.97 + 3161 \cdot 33.95) \cdot 0.1}{19551} = 3.9[s] \end{aligned}$$

- システムの答えがすべて”Negative” の場合, 医師の仕事の時間は現在のものと同じになる.

この場合の人数の割り振りは $q_{TN} = 16390$, $q_{TP} = 0$, $q_{FP} = 0$, $q_{FN} = 3161$ となり, 条件式は以下のとおりになる. $T_{Doc} \leq T'_{Doc,Negative}$

$$\begin{aligned} n \cdot t_{CC} + \sum_{i=1}^L t_{Ad,i} \cdot q_i \\ &= \sum_{i=1}^L \{ (q_{FP,i} \cdot t_{Rev,FP,i} + q_{FN,i} \cdot t_{Rev,FN,i}) + n \cdot t_{Check,i} \} \\ n \cdot t_{CC} + (q_{FN} + q_{TP}) \cdot \overline{t_{Ad}} \\ &= q_{FP} \cdot \overline{t_{Rev,FP}} + q_{FN} \cdot \overline{t_{Rev,FN}} + q \cdot \overline{t_{Check}} \\ n \cdot t_{CC} + q_{FN} \cdot \overline{t_{Ad}} &= q_{FN} \cdot \overline{t_{Rev,FN}} + n \cdot \overline{t_{Check}} \end{aligned}$$

where $q_{TP} = 0$ and $q_{FP} = 0$

$$931 \cdot t_{CC} + 3161 \cdot \overline{t_{Ad}} = 3161 \cdot \overline{t_{Rev,FN}} + 931 \cdot \overline{t_{Check}}$$

where $q_{TN} = 16390$ and $q_{FN} = 3161$

$$\overline{t_{Rev,FN}} = \frac{(931 \cdot 703.97 + 3161 \cdot 33.95) - 19551 \cdot 3.9}{3161} = 217.16[s]$$

- また, システムの答えがすべて”Positive” の場合, それぞれの人数は: $q_{TN} = 0$, $q_{TP} = 3161$, $q_{FP} = 16390$, $q_{FN} = 0$ となる. その場合の条件式は以下の通りになる.

$$\begin{aligned} T_{Doc} \leq T'_{Doc,Positive} \\ n \cdot t_{CC} + (q_{FN} + q_{TP}) \cdot \overline{t_{Ad}} \\ &= q_{FP} \cdot \overline{t_{Rev,FP}} + q_{FN} \cdot \overline{t_{Rev,FN}} + q \cdot \overline{t_{Check}} \\ n \cdot t_{CC} + q_{TP} \cdot \overline{t_{Ad}} &= q_{FP} \cdot \overline{t_{Rev,FP}} + q \cdot \overline{t_{Check}} \end{aligned}$$

where $q_{TN} = 0$ and $q_{FN} = 0$

$$931 \cdot t_{CC} + 3161 \cdot \overline{t_{Ad}} = 16390 \cdot \overline{t_{Rev,FP}} + q \cdot \overline{t_{Check}}$$

where $q_{TP} = 3161$, $q_{FP} = 16390$

$$\overline{t_{Rev,FP}} = \frac{(931 \cdot 703.97 + 3161 \cdot 33.95) - 19551 \cdot 3.9}{16390} = 41.88[s]$$

4.3.2 条件 2: 現状を元に定義する場合

- ここでは医師が予測されたアドバイスを訂正し直す時間 $t_{Rev,i} = 33.95[s]$ とアドバイスを与える時間 ($t_{Ad,i}$) と同じであると単純に仮定する. 加えて医師が予測されたアドバイスをチェックする時間 $t_{Rev,i} = 3.40$ がアドバイスを与える時間の 1/10 であると仮定する.

この 4 つの場合分けを表 7 にまとめた.

結果より, パラメータを定義した条件 1 を採用した. システムを利用するとすべての場合において, 医師の仕事の時間が短縮された. 一方, 条件 2 では条件 1 に比べ医師の仕事の時間が多く短縮された. しかしながら条件 2 での問題はアドバイスが不必要である際に時間が減少してしまうところである. システムがエラーを示した場合のために $t_{Rev,FN,i}$ と $t_{Rev,FP,i}$ を定義したので, 少なくともチャンスレベルのシステムを導入した際は医師の時間が増えるべきである. 条件 1 によるパラメータの定義は以下のとおりになる.

- $\overline{t_{Check}} = 3.9[s]$
- $\overline{t_{Rev,FN}} = 217.16[s]$
- $\overline{t_{Rev,FP}} = 41.88[s]$

4.4 時間削減のシミュレーション




図5 時間の見積もり

上記で採用した条件 1 において定義されたパラメータを用いて, 合計で 931 人分のデータを使い医師の時間と

表7 医師の時間 [hours] と 2つの条件のシミュレーション時間の比較

	現状	Positive chance	Negative chance	Perfect system	手法 1 (76%)	手法 2 (82%)
条件 1	211.86	211.86	211.86	21.19	114.72	92.48
条件 2	211.86	173.03	48.27	18.46	69.34	58.62

ヘルスワーカーの時間シミュレーションを行った。常時の 211.86 時間と比べると、手法 1 では 114.72 時間まで医師の消費時間を減らすことができ、また手法 2 においては、92.48 時間に減らすことができた。ヘルスワーカーの時間に関しては、手法 1 では 68.76 時間であり、ヘルスワーカーが聞く主訴情報の数に比例して 200.4 時間まで増加する。しかしながらその増加分は、ヘルスワーカーが医師に比べより低いスキルで、低コストで簡単に雇える点を考慮すると、十分実現可能であるといえる。また患者に尋ねるべき主訴情報の数は、医師とヘルスワーカーとの相対的なコストに依存する。

4.5 議論

ここまでに、

- 4.1 節において、アドバイスの種類を予測し、
- 4.2-4.5 節でそれらにかかる合計の時間短縮についてシミュレーションをした。

この研究の中で、主訴情報を処理する抽出方法における、3つの欠点について議論する必要がある。

4.5.1 意味の持たない単語について

主訴情報は自由記述によって書かれるためどう扱っていいか大変難しい。主訴情報リスト 4 を見てわかるように、“after”、“both”、や“case”といった、いくつかの意味の持たない単語が見受けられる。一方で医師が書き記した、“bp(blood pressure)”、“dm(Diabetes mellitus)”、“htn(hypertension)”といった単語を省略したものも存在する。今後我々はこのようにこれらの単語に対し、フィルタリングをしていくこと、また質問者にとって扱いやすい新しいリストをどう作成していくかが鍵となる。

4.5.2 質問者用の単語

現在主訴情報より抽出した単語に基づき解析しているが、実際に質問者が使用する形の主訴情報に戻さなくてはならない。例を挙げると、抽出された単語が、“low”だった場合、考えられる主訴情報が、“low grade fever”、“pain in lower back”、“numbness on lower limb”があり、いくつかの使用事例が存在する。

4.5.3 否定的な単語について

我々は“no”、“not”といった否定的な単語についてあまり気にしていなかった。否定的な単語は逆の状態を示すため、患者の状態を表すことにおいてとても重要な単語である。例えば、主訴情報が“no htn”(高血圧ではない)であるとき、解析時は“no”、“htp”に分かれてしまう。その結果、我々のアルゴリズムにより患者が“htp”であるとなされてしまう。

これらの問題を解決するために、我々はより多くの技術的な自然言語処理を導入したり、選択システムなどの新しい主訴情報入力システムを開発する必要がある。

またモデルの計算の定数を仮定するときに注意しなければならない点がある。現在、理論的に過去のデータで幾つかの定数を計算しているが、本来は実際の実験において測定することが好ましい。加えて医師のコストとヘルスワーカーのコストを同じ比率で計算しているが、これも実際のコストを踏まえると違うはずである。またアドバイスの内容によって、医師にできてヘルスワーカーにできないものについても、専門医と十分検討していく必要がある。

5. 結論

本論文では、現在行われている Portable Health Clinic の問題点である医師の仕事にかかる時間が貴重であることに目をつけ、その仕事のうちいくつかを医師よりスキルがないヘルスワーカーが代わりにして医師の時間を削減するという、健康診断と遠隔診療のプロセス改善方法を述べ、その解析結果を示した。我々は医師から患者に対して出されるアドバイスを問診データ、健診データ、主訴情報より予測することを目的とし、ヘルスワーカーが患者から得たデータより予め機械学習をした主訴情報を重要度順に表示し、患者に選択させ、それをもとに関連のあるアドバイスを予測し、患者に尋ねるシステムを提案した。問診データ、健診データからアドバイスを予測する手法 1 における予測精度は 76.24% に達し、問診データ、健診データに主訴情報を加えたものから、アドバイスを予測する手法 2 での予測精度は 82.55% に達した。この結果は医師の仕事を許される範囲内でヘルスワーカーに任せられることができる可能性を表している。また医師から患者に対して出される主訴情報を変数に用いることによって予測精度が向上した。さらに時間の消費モデル、推定されたパラメーターに基づき、総時間の消費をシミュレートし、合計 114.72 時間の医師の時間を削減することができた。

謝辞

本研究の一部は、最先端研究開発支援プログラム「超巨大データベース時代に向けた最高速データベースエンジンの開発と当該エンジンを核とする戦略的サービスの実証・評価(中心研究者:喜連川優)」および NEDO IT 融合による新社会システムの開発・実証プロジェクト「IT 融合によるバーチャルクリニック構築事業」による。

参考文献

- [1] Organization, WHO.: Health Transition, available from <http://www.who.int/trade/glossary/story050/en/index.html>.
- [2] Ahmed, A. and Osugi, T.: ICT to change BOP: Case Study: Bangladesh, *Shukosha, Fukuoka*, pp. 139–155 (2009).
- [3] Kai, E. and Ahmed, A.: Remote health consultancy service for unreached community: amazing facts and technical challenges, *Proceedings of the First MJIT-JUC Joint Symposium, MJIT, UTM, Kulalumpur, Malaysia* (2012).
- [4] Kai, E. and Ahmed, A.: Technical Challenges in Providing Remote Health Consultancy Services for the Unreached Community, *Advanced Information Networking and Applications Workshops (WAINA), 2013 27th International Conference on*, IEEE, pp. 1016–1020 (2013).
- [5] Nakashima, N., Nohara, Y., Ahmed, A., Kuroda, M., Inoue, S., Ghosh, P. P., Islam, R., Hiramatsu, T., Kobayashi, K., Inoguchi, T. and Kitsuregawa, M.: An Affordable, Usable and Sustainable Preventive Healthcare System for Unreached People in Bangladesh, *Proceedings of the 14th World Congress on Medical and Health Informatics (MedInfo2013)*, p. 1051 (2013).
- [6] Ahmed, S. M., Evans, T. G., Standing, H. and Mahmud, S.: Harnessing pluralism for better health in Bangladesh, *The Lancet*, Vol. 382, No. 9906, pp. 1746–1755 (2013).
- [7] El Arifeen, S., Christou, A., Reichenbach, L., Osman, F. A., Azad, K., Islam, K. S., Ahmed, F., Perry, H. B. and Peters, D. H.: Community-based approaches and partnerships: innovations in health-service delivery in Bangladesh, *The Lancet*, Vol. 382, No. 9909, pp. 2012–2026 (2013).
- [8] Adams, A. M., Ahmed, T., El Arifeen, S., Evans, T. G., Huda, T. and Reichenbach, L.: Innovation for universal health coverage in Bangladesh: a call to action, *The Lancet*, Vol. 382, No. 9910, pp. 2104–2111 (2014).
- [9] Adams, A. M., Rabbani, A., Ahmed, S., Mahmood, S. S., Al-Sabir, A., Rashid, S. F. and Evans, T. G.: Explaining equity gains in child survival in Bangladesh: scale, speed, and selectivity in health and development, *The Lancet*, Vol. 382, No. 9909, pp. 2027–2037 (2013).
- [10] Neumayer, E. and Plümper, T.: The gendered nature of natural disasters: The impact of catastrophic events on the gender gap in life expectancy, 1981–2002, *Annals of the Association of American Geographers*, Vol. 97, No. 3, pp. 551–566 (2007).
- [11] Chowdhury, A. M. R., Bhuiya, A., Chowdhury, M. E., Rasheed, S., Hussain, Z. and Chen, L. C.: The Bangladesh paradox: exceptional health achievement despite economic poverty, *The Lancet*, Vol. 382, No. 9906, pp. 1734–1745 (2013).
- [12] Ramachandran, A., Snehalatha, C., Ram, J., Selvam, S., Simon, M., Nanditha, A., Shetty, A. S., Godsland, I. F., Chaturvedi, N., Majeed, A. et al.: Effectiveness of mobile phone messaging in prevention of type 2 diabetes by lifestyle modification in men in India: a prospective, parallel-group, randomised controlled trial, *The Lancet Diabetes & Endocrinology*, Vol. 1, No. 3, pp. 191–198 (2013).
- [13] Greenes, R. A.: *Clinical decision support: the road ahead*, Academic Press (2011).
- [14] Makam, A. N., Nguyen, O. K., Moore, B., Ma, Y. and Amarsingham, R.: Identifying patients with diabetes and the earliest date of diagnosis in real time: an electronic health record case-finding algorithm, *BMC medical informatics and decision making*, Vol. 13, No. 1 (2013).
- [15] Solt, I., Tikk, D., Gál, V. and Kardkovács, Z. T.: Semantic classification of diseases in discharge summaries using a context-aware rule-based classifier, *Journal of the American Medical Informatics Association*, Vol. 16, No. 4, pp. 580–584 (2009).
- [16] Souza, N. M., Sebaldt, R. J., Mackay, J. A., Prorok, J. C., Weise-Kelly, L., Navarro, T., Wilczynski, N. L., Haynes, R. B. et al.: Computerized clinical decision support systems for primary preventive care: a decision-maker-researcher partnership systematic review of effects on process of care and patient outcomes, *Implement Sci*, Vol. 6, No. 1, pp. 87–99 (2011).
- [17] Zhou, X., Chen, S., Liu, B., Zhang, R., Wang, Y., Li, P., Guo, Y., Zhang, H., Gao, Z. and Yan, X.: Development of Traditional Chinese Medicine Clinical Data Warehouse for Medical Knowledge Discovery and Decision Support, *Artif. Intell. Med.*, Vol. 48, No. 2-3, pp. 139–152 (online), DOI: 10.1016/j.artmed.2009.07.012 (2010).
- [18] Obenshain, M. K.: Application of data mining techniques to healthcare data, *Infection Control and Hospital Epidemiology*, Vol. 25, No. 8, pp. 690–695 (2004).
- [19] Koh, H. C., Tan, G. et al.: Data mining applications in healthcare, *Journal of Healthcare Information Management*, Vol. 19, No. 2, p. 65 (2011).
- [20] Wright, A., McCoy, A., Henkin, S., Flaherty, M. and Sittig, D.: Validation of an association rule mining-based method to infer associations between medications and problems, *PTT-Persönlichkeitsstörungen: Theorie und Therapie*, Vol. 12, No. 1, pp. 3–11 (2008).
- [21] Zhou, L. and Hripesak, G.: Temporal reasoning with medical data - a review with emphasis on medical natural language processing, *Journal of biomedical informatics*, Vol. 40, No. 2, pp. 183–202 (2007).
- [22] Demner-Fushman, D., Chapman, W. W. and McDonald, C. J.: What can natural language processing do for clinical decision support?, *Journal of biomedical informatics*, Vol. 42, No. 5, pp. 760–772 (2009).
- [23] Denny, J. C., Peterson, J. F., Choma, N. N., Xu, H., Miller, R. A., Bastarache, L. and Peterson, N. B.: Development of a natural language processing system to identify timing and status of colonoscopy testing in electronic medical records, *AMIA Annual Symposium Proceedings*, Vol. 2009, American Medical Informatics Association, p. 141 (2009).
- [24] Li, D., Kipper-Schuler, K. and Savova, G.: Conditional random fields and support vector machines for disorder named entity recognition in clinical texts, *Proceedings of the workshop on current trends in biomedical natural language processing*, Association for Computational Linguistics, pp. 94–95 (2008).
- [25] Ogren, P. V., Savova, G. K. and Chute, C. G.: Constructing evaluation corpora for automated clinical named entity recognition, *Medinfo 2007: Proceedings of the 12th World Congress on Health (Medical) Informatics; Building Sustainable Health Systems*, IOS Press, p. 2325 (2007).
- [26] Roberts, A., Gaizauskas, R. and Hepple, M.: Extracting clinical relationships from patient narratives, *Proceedings of the Workshop on Current Trends in Biomedical Natural Language Processing*, Association for Computational Linguistics, pp. 10–18 (2008).