

マルチタスク学習に基づく疾病コンテキストを考慮した ICU入室患者の死亡リスク予測

Disease-Dependent Mortality Prediction in ICU by Multi-Task Learning

則のぞみ^{*1} 鹿島久嗣^{*2} 山下和人^{*3} 猪飼宏^{*4} 今中雄一^{*5}
 Nozomi Nori Hisashi Kashima Kazuto Yamashita Hiroshi Ikai Yuichi Imanaka

^{*1*}^{*2} 京都大学大学院情報学研究科 知能情報学専攻

^{*3*}^{*4*}^{*5} 京都大学大学院医学研究科 医療経済学分野

We integrate disease-specific contexts into mortality modeling by formulating the mortality prediction problem as a multi-task learning problem in which a task corresponds to a disease. Our method effectively incorporates medical domain knowledge relating to the similarity among diseases and the similarity among Electronic Health Records into a data-driven approach by incorporating graph Laplacians into the regularization term. The experimental results on a real dataset from a hospital support the effectiveness of our proposed method by outperforming several baselines, including logistic regression without multi-task learning and several multi-task learning methods without the domain knowledge. Besides, we illustrate an interesting result pertaining to disease-specific predictive features, suggesting a hypothesis that could be validated by further investigations in the medical domain.

1. はじめに

1.1 ICU入室患者の死亡リスク予測問題

集中治療室 (ICU) における医療行為は、重篤な症状を呈する患者に対して短期間に行われる頻繁な介入によって特徴付けられる。医師は限られた時間で複数の患者を同時に治療する必要があるため、特に重篤な状態にある患者を正確に予測することは医師の注意をより必要とする患者にアラートを出すといった診療支援に繋がることが期待できる。実際、いくつかの研究では ICU 入室患者の死亡事例の一定割合は“防ぎ得た死”であったという考察がなされており、死亡リスクの早期検知及び適切な介入の必要性が指摘されている [McGloin 99, Zeggwagh 14].

ICU においては患者の死亡リスクが患者の重症度の代替物としてしばしば用いられており、これまでも死亡リスク予測のための様々なモデルが探求されてきた [Hug 09, Ghassemi 14, Ghassemi 15]. しかし、従来の研究では疾病ごとではなく ICU 入室患者全体を対象としたモデリングが行われることが一般的であり、“疾病によって死亡リスクを説明するルールが異なる”というような“疾病コンテキスト”は十分に考慮されてこなかった。例えば、人工呼吸を受けた患者は胃潰瘍になりやすいため胃潰瘍の予防のために胃薬が用いられるが、既に出血しているような胃潰瘍の治療にも同じ胃薬が用いられるといったようなことがあり、それぞれのケースで同一の胃薬が患者の死亡リスクをどう説明するかのルールは異なると考えられる。このような疾病コンテキストは、特定の診察・診療科における患者の再入院予測や疾病の進行予測などのタスクにおいては暗黙の前提であり、それらのタスクでは、事前に指定された疾病のみを対象とした予測モデリングが行われるのが一般的である。しかし、ICU では様々な疾病の患者が対象となるため、疾病ごとに異なるコンテキストを考慮した予測モデル、すなわち、疾病ごとに個別化した予測モデルが効果的であると期待できる。

1.2 課題

疾病ごとに個別化した予測モデルの構築にあたっては (1) 疾病ごとのモデルの個別化に伴うデータの不足と (2) 電子健康記録 (Electronic Health Record: EHR) に特徴的なデータの疎性に対処する必要がある。以下でこの二点について説明する。

(1) 疾病ごとのモデルの個別化に伴うデータの不足:

多くの疾病では少数の患者に関するデータしか得られないために、個々の疾病で個別にモデルを構築しようとした際には十分なデータが得られないという問題が生じる。この点を説明するために、図 1 で QIP プロジェクト^{*1} 内の ICU データセットにおける各疾病の患者数を図示した。このデータセットは日本国内の約 170 病院において 2010 年 4 月から 2013 年 3 月までに退院した約 20 万人の ICU 入室患者集合から成る。横軸は疾病及び関連保健問題の国際統計分類 (ICD) 10 の四階層目までを用いたコーディングに基づく疾病のインデックスを、縦軸は対応する患者数を表す。図から、ほとんどの疾病は少数の患者しか含まないことが分かる。具体的に述べると、約 8 割の疾病で患者数が 30 人以下となっていた。従って、疾病ごとにモデルを個別化する際には対象の疾病のデータ以外の情報を何らかの方法で活用する必要があると考えられる。

(2) EHR に特徴的なデータの疎性:

死亡リスク予測モデリングにおいては、患者は年齢や性別などのデモグラフィックな情報の他、過去の病歴、入院中の治療内容などを含む EHR によって表現されるが、EHR は非常に疎であることが指摘されており [Zhou 14]、これは今回対象とするような ICU のデータにも当てはまる。そのような疎性の一つの要因として、EHR の多くが医療上の要請から複数の観点に基づき細かく分類されていることが考えられる。例えば、薬品は薬効、成分、形状、医薬品メーカーなど複数の観点から分類されており、その中の何らかの性質、例えば成分が異なれば違う薬品コードが振られている。しかし、成分が異なっても薬効が同じグループが存在し、それらの薬品は患者の死亡リスク予測において似たような役割を果たすことが期待できる。

連絡先: 則のぞみ, 京都大学情報学研究科

*1 <http://med-econ.umin.ac.jp/QIP/>

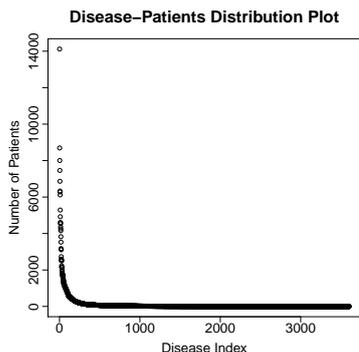


図 1: ICU データセットにおける各疾病の患者数。横軸は疾病のインデックス (ICD10 における四階層目までの情報を用いたコーディング), 縦軸は対応する患者数を示している。多くの疾病は少数の患者しか含まないことが確認できる。

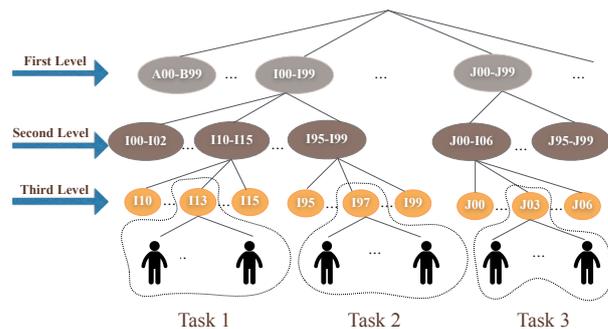


図 2: ICD10 の階層情報を活用したマルチタスク学習の一例。患者は ICD10 の三階層目までの情報を用いたコーディングで定義される疾病によってグルーピングされる。疾病の階層情報を元に疾病間の類似度を定義し, その類似度を用いて複数の疾病に対する予測モデルを同時に学習する。

従って, 予測モデルの構築に際してはこれら EHR 間の類似度を考慮することが効果的であると期待できる。

1.3 解決策

上記の課題に対処するために, 本論文では疾病の分類と EHR の分類に関する二つのドメイン知識を取り込むマルチタスク学習手法を提案する。提案手法では一つの疾病に対する予測が一つのタスクに対応し, 疾病間で情報を共有することで複数の疾病に対する予測モデルを同時に学習する。疾病を適切に関連付け情報を共有させるために, 本論文では医学分野における疾病間の類似度がドメイン知識として与えられることを仮定する。実験では世界保健機関が管理する ICD10 の分類を用いた。図 2 に, ICD10 の階層情報を活用したマルチタスク学習の一例を示した。ICD においては, 疾病は原因, 症状, 部位など複数の観点から階層的に分類されており, 患者の死亡リスクに影響するであろう情報を反映した疾病間の類似度を得ることができる。提案手法では, ICU 入室患者の死亡リスク予測問題を最適化問題として定式化する際に, 医学的な分類上類似した疾病間でモデルパラメータが類似するような正則化項を加える。EHR に特徴的なデータの疎性に関するも同様に, EHR の医療分類上類似した特徴量間でモデルパラメータが類似するような正則化項を加える。提案手法ではモデルパラメータ行列が行方向, 縦方向の両方向に正則化されるため, 提案手法を“クロス正則化”によるマルチタスク学習と呼ぶ。

2. 提案手法

2.1 問題設定

ICU 入室患者の死亡リスク予測における疾病コンテキストを考慮するために, 各疾病で個別化された予測モデルを学習する問題を考える。疾病が T 個あり, 各疾病で一つの予測モデルを構築することを考える。 t 番目の疾病を有する患者は N_t 人おり, t 番目の疾病の n 番目の患者は EHR から抽出された M 次元の特徴ベクトル $\phi_n^{(t)}$ で表されるとする。 t 番目の疾病に対して $N_t \times M$ の計画行列 $\Phi^{(t)} \equiv [\phi_1^{(t)}, \phi_2^{(t)}, \dots, \phi_{N_t}^{(t)}]^\top$ を構築する。 t 番目の疾病の n 番目の患者には二値のクラスラベルとして $y_{t,n} \in \{0, 1\}$ が割り当てられており, 患者のアウトカムが死亡である場合 $y_{t,n} = 1$, そうでない場合 $y_{t,n} = 0$ であるとする。これらをまとめて, t 番目の疾病に対して N_t 次元のベクトル $\mathbf{y}^{(t)} \equiv (y_{t,1}, y_{t,2}, \dots, y_{t,N_t})^\top$ を割り当てる。

我々は患者の死亡リスクをモデル化するためにロジスティック回帰を採用し, n 番目の患者のアウトカムが死亡である事後確率を $Pr[y_{t,n} = 1 | \phi_n^{(t)}] = \sigma(\mathbf{w}^{(t)\top} \phi_n^{(t)})$ によって表現する。ここで, $\sigma(a)$ はシグモイド関数 $\sigma(a) \equiv (1 + \exp(-a))^{-1}$ である。 $\mathbf{w}^{(t)}$ は t 番目の疾病に対応する M 次元のモデルパラメータである。各疾病で予測モデルを個別化の際に生じるデータの不足に対処するために, 全疾病の予測モデルを同時に学習する。全体のモデルパラメータを $M \times T$ 行列 $\mathbf{W} \equiv [\mathbf{w}^{(1)}, \mathbf{w}^{(2)}, \dots, \mathbf{w}^{(T)}]$ で表現し, 対数損失と正則化項を含む目的関数を最小化することで \mathbf{W} を推定する。正則化項により, 医学的分類に基づく疾病の類似度などのドメイン知識を取り込む。疾病間の類似度および EHR から抽出される特徴量間の類似度がそれぞれ行列 $\mathbf{S}^{\text{dz}}, \mathbf{S}^{\text{feat}}$ で与えられているとする。 $\mathbf{S}^{\text{dz}}(i, j)$ は i 番目と j 番目の疾病の類似度を表し, $\mathbf{S}^{\text{feat}}(i', j')$ は i' 番目と j' 番目の特徴量間の類似度を表す。我々のゴールは, M 次元ベクトル $\phi_{n'}^{(t')}$ ($t' \in \{1, \dots, T\}$) で表現された未知の患者の死亡リスクを, 訓練データ $\{(\Phi^{(t)}, \mathbf{y}^{(t)})\}_{t=1, \dots, T}$ と, 二つの類似度行列 $\mathbf{S}^{\text{dz}}, \mathbf{S}^{\text{feat}}$ を元に予測することである。

2.2 クロス正則化によるマルチタスク学習

我々は, 損失関数 $\mathcal{L}(\mathbf{W})$ を以下で定義する対数損失として定義する:

$$\mathcal{L}(\mathbf{W}) \equiv - \sum_t^T \sum_n^{N_t} \{y_{t,n} \log \sigma(\mathbf{w}^{(t)\top} \phi_n^{(t)}) + (1 - y_{t,n}) \log(1 - \sigma(\mathbf{w}^{(t)\top} \phi_n^{(t)}))\}. \quad (1)$$

ここで $\sigma(a)$ はシグモイド関数である。目的関数には損失関数の他, 過学習の防止とドメイン知識の取り込みのための正則化項 Ω を加え, 全体として以下のような最適化問題を考える:

$$\min_{\mathbf{W}} \mathcal{L}(\mathbf{W}) + \Omega(\mathbf{W}). \quad (2)$$

ここで, 疾病間の類似度と特徴量間の類似度に関するドメイン知識を以下の正則化項によって活用する:

$$\begin{aligned} \Omega^{\text{dz}}(\mathbf{W}) & \equiv \frac{1}{4} \sum_{i=1}^T \sum_{j=1}^T \mathbf{S}_{i,j}^{\text{dz}} \left\| \frac{\mathbf{W}_{*,i}}{\sqrt{\mathbf{D}_{i,i}^{\text{dz}}}} - \frac{\mathbf{W}_{*,j}}{\sqrt{\mathbf{D}_{j,j}^{\text{dz}}}} \right\|^2 = \frac{1}{2} \text{Tr}(\mathbf{W} \mathbf{L}^{\text{dz}} \mathbf{W}^\top), \end{aligned} \quad (3)$$

$$\begin{aligned} \Omega^{\text{feat}}(\mathbf{W}) & \\ \equiv \frac{1}{4} \sum_{i=1}^M \sum_{j=1}^M S_{i,j}^{\text{feat}} & \left\| \frac{\mathbf{W}_{i,*}}{\sqrt{D_{i,i}^{\text{feat}}}} - \frac{\mathbf{W}_{j,*}}{\sqrt{D_{j,j}^{\text{feat}}}} \right\|^2 = \frac{1}{2} \text{Tr}(\mathbf{W}^\top \mathcal{L}^{\text{feat}} \mathbf{W}). \end{aligned} \quad (4)$$

ここで、 D^{dz} は $D_{i,i}^{\text{dz}} \equiv \sum_j S_{i,j}^{\text{dz}}$ によって定義される対角行列であり、 D^{feat} も同様に定義される。また、 \mathcal{L}^{dz} 、 $\mathcal{L}^{\text{feat}}$ はそれぞれ S^{dz} 、 S^{feat} の正規化された対称ラプラシアン行列（以降では単にラプラシアン行列と記載）である。隣接行列 A によって表現される無方向グラフのラプラシアン行列は $D^{-1/2}(D-A)D^{-1/2}$ である。ここで、 D は $D_{i,i} \equiv \sum_j A_{i,j}$ によって定義される対角行列である。正則化項 $\Omega^{\text{dz}}(\mathbf{W})$ は、もし i 番目の疾病と j 番目の疾病が医学的分類上類似している場合二つのモデルパラメータ $\mathbf{W}_{*,i}$ と $\mathbf{W}_{*,j}$ を類似させる機構として機能する。 $\Omega^{\text{feat}}(\mathbf{W})$ についても同様である。モデルパラメータ行列 \mathbf{W} は二つのラプラシアン行列 \mathcal{L}^{dz} と $\mathcal{L}^{\text{feat}}$ を用いて縦方向、横方向の両方に正則化されるので、この正則化をクロス正則化と命名する。全体として、我々は以下の正則化項を採用する：

$$\Omega(\mathbf{W}) \equiv \lambda^{\text{dz}} \Omega^{\text{dz}}(\mathbf{W}) + \lambda^{\text{feat}} \Omega^{\text{feat}}(\mathbf{W}) + \lambda^{\text{rid}} \Omega^{\text{rid}}(\mathbf{W}). \quad (5)$$

ここで、 $\Omega^{\text{rid}}(\mathbf{W}) \equiv \frac{1}{2} \text{Tr}(\mathbf{W} \mathbf{W}^\top)$ は過学習を防ぐために用いられるリッジ正則化であり、 $\lambda^{\text{dz}} \geq 0$ 、 $\lambda^{\text{feat}} \geq 0$ 、 $\lambda^{\text{rid}} \geq 0$ はそれぞれ Ω^{dz} 、 Ω^{feat} 、 Ω^{rid} の重みを調整するためのハイパーパラメータである。ラプラシアン行列は半正定であるので、正則化項は損失関数と同様に凸であり、最適解は標準的な勾配法を用いて求めることができる。我々は以下の導関数と L-BFGS 法を用いてパラメータ行列を推定した。

$$\begin{aligned} \left[\frac{\partial \mathcal{L}(\mathbf{W})}{\partial \mathbf{W}} \right]_{*,t} &= \Phi^{(t)\top} (\mathbf{p}^{(t)} - \mathbf{y}^{(t)}), \\ \frac{\partial \Omega^{\text{dz}}(\mathbf{W})}{\partial \mathbf{W}} &= \mathbf{W} \mathcal{L}^{\text{dz}}, \quad \frac{\partial \Omega^{\text{feat}}(\mathbf{W})}{\partial \mathbf{W}} = \mathcal{L}^{\text{feat}} \mathbf{W}, \quad \frac{\partial \Omega^{\text{rid}}(\mathbf{W})}{\partial \mathbf{W}} = \mathbf{W}, \end{aligned} \quad (6)$$

ここで $\mathbf{p}^{(t)} = (\sigma(\mathbf{w}^{(t)\top} \phi_1^{(t)}), \sigma(\mathbf{w}^{(t)\top} \phi_2^{(t)}), \dots, \sigma(\mathbf{w}^{(t)\top} \phi_{N_t}^{(t)}))^\top$ 、 $\mathbf{y}^{(t)} = (y_{t,1}, y_{t,2}, \dots, y_{t,N_t})^\top$ であり、 $\left[\frac{\partial \mathcal{L}(\mathbf{W})}{\partial \mathbf{W}} \right]_{*,t}$ は t 番目の列ベクトル $\frac{\partial \mathcal{L}(\mathbf{W})}{\partial \mathbf{W}}$ を表す。

3. 実験

3.1 実験条件

3.1.1 データの前処理

データセットには、QIP プロジェクトで収集された一病院のデータを用いた。患者の疾病は、患者の入院の契機となった疾病を ICD の三階層目までの情報を用いた疾病コードによって定義した。前処理として、18 歳未満の患者と、患者数が 10 名未満の疾病を有する患者を除き、結果として 701 人の患者集合、20 疾病を得た。20 疾病の ICD コードと疾病名は以下である：A41(その他の敗血症)、C15(食道の悪性新生物)、C16(胃の悪性新生物)、C18(結腸の悪性新生物)、C20(直腸の悪性新生物)、C22(肝及び肝内胆管の悪性新生物)、C34(気管支及び肺の悪性新生物)、G93(脳のその他の障害)、I20(狭心症)、I21(急性心筋梗塞)、I35(非リウマチ性大動脈弁障害)、I50(心不全)、I70(アテローム性動脈硬化症)、I71(大動脈瘤及び解離、

K52(その他の非感染性胃腸炎及び非感染性大腸炎)、K56(麻痺性イレウス及び腸閉塞、ヘルニアを伴わないもの)、K65(腹膜炎)、K76(その他の肝疾病)、K91(消化器系の処置後障害、他に分類されないもの)、N18(慢性腎不全)。患者が入院期間中に死亡した場合患者のアウトカムを死亡とし、それ以外の場合は生存とした。患者を表現する特徴量は以下のように構成した。まず、各患者について年齢と性別を抽出し、年齢については“65 歳以下”と“65 歳より高齢”の二つの特徴量を構成した。また、患者の入院の契機となった疾病について、ICD の四階層目までの情報を用いた疾病コードも特徴量に加えた。最後に、入院期間中に患者に行われた医療費を伴う全ての介入行為も特徴量に加えた。これらは投薬、手術、検査など患者に対して行われた介入行為であり、DPC システムによってコーディングされている。DPC データは医事データで診療報酬請求に関わる検査、処置、投薬、手術等が記録されており、医療上の要請から複数の観点に基づき細かく分類されている。特徴量間の類似度 S^{feat} については、介入行為が投薬である場合、薬効が共通していれば類似度を 1 としそうでない場合 0 とした。介入行為が投薬以外である場合、医療分類において三階層目までの分類が共通していれば類似度 1 としそうでない場合 0 とした。疾病間の類似度 S^{dz} については、ICD10 の階層分類において共通する階層の数によって類似度を定義した。

3.1.2 予測設定

全データセットのうち 60% の患者を訓練データとして抽出し、残りの 40% を評価データとして用いた。各手法におけるハイパーパラメータは交差確認 ($k = 5$) を用いて以下の中から決定された： $\{0, 10^{-4}, 10^{-3}, 10^{-2}, 10^{-1}, 10^0\}$ 。サンプリング、予測、評価の一連のプロセスを 10 回繰り返し、Wilcoxon の符号順位検定で予測精度を比較した。予測設定としては (1) ICU 退室日前日までの情報を用いた予測と (2) 退院日前日までの情報を用いた予測の二通りを用意し、予測精度の評価指標としては AUC (Area Under the ROC Curve) を用いた。

3.1.3 比較手法

実験で用いた様々な手法の比較を表 1 に示した。疾病の分類と EHR の分類に関するドメイン知識を取り込む効果を評価するために以下の三つの比較手法を用意した。*Proposed-feat* は式 5 で $\lambda^{\text{dz}} = 0$ 、*Proposed-dz* は式 5 で $\lambda^{\text{feat}} = 0$ 、*non-MTL-1 (separate)* は式 5 で $\lambda^{\text{dz}} = \lambda^{\text{feat}} = 0$ とした場合に相当する。また、我々はマルチタスク学習をせず全体で一つのモデルを学習する手法 *non-MTL-2 (common)* も用意した。マルチタスク学習のベースラインとしては以下の二つを用意した。*MTL-1 ($\ell_{2,1}$)* [Argyriou 06] は、 $\ell_{2,1}$ ノルムを正則化項に取り込んだものであり、*MTL-2 (Trace)* [Ji 09] はトレースノルムを正則化項に取り込んだものである。二つのマルチタスク学習手法は提案手法と同様にロジスティック回帰に基づく。

3.2 結果

3.2.1 予測精度

表 2 に各手法の AUC 平均値を示した。太字で示されている結果は各設定において太字表記以外の結果に対して Wilcoxon の符号順位検定で有意 ($p < 0.05$) であった結果である。ICU 退室前の予測設定では、提案手法が他の全手法に対して有意に精度向上していることが確認できる。一方、退院前の予測設定では、提案手法と提案手法の変形である *Proposed-dz* はほぼ同精度となっており、その他の手法に対しては有意に精度向上している。ICU 退室前予測設定の方が退院前予測設定よりも患者に関して得られる特徴量が少ないことから、特に特徴量が疎であるような場合に、特徴量に関するドメイン知識が有効であ

表 1: 実験で用いた様々な手法の比較

手法	正則化	ドメイン知識			
		タスク	特徴量	マルチタスク学習	疾病ごとのモデルの個別化
Proposed	Task, Feature, l_2	✓	✓	✓	✓
Proposed-feat	Feature, l_2		✓	✓	✓
Proposed-dz	Task, l_2	✓		✓	✓
non-MTL-1 (separate)	l_2				✓
non-MTL-2 (common)	l_2				
MTL-1 ($l_{2,1}$) [Argyriou 06]	$l_{2,1}, l_2$			✓	✓
MTL-2 (Trace) [Ji 09]	Trace			✓	✓

表 2: 様々な手法の AUC 平均値の比較．太字で示されている結果は各設定において太字表記以外の結果に対して Wilcoxon の符号順位検定で有意 ($p < 0.05$) であった結果である．

手法	AUC 平均	
	ICU 退室前の 予測	退院前の 予測
Proposed	0.776	0.911
Proposed-feat	0.703	0.840
Proposed-dz	0.768	0.908
non-MTL-1 (separate)	0.709	0.836
non-MTL-2 (common)	0.755	0.878
MTL-1 ($l_{2,1}$) [Argyriou 06]	0.732	0.809
MTL-2 (Trace) [Ji 09]	0.741	0.863

ることが示唆された．また，ベースラインとして比較した既存のマルチタスク学習手法と，マルチタスク学習せず全疾病で一つのモデルを学習する *non-MTL-2 (common)* を比較すると，マルチタスク学習により予測精度が低下している一方，医学分類に基づく疾病の類似度を取り込んだマルチタスク学習手法である提案手法と *Proposed-dz* についてはマルチタスク学習により予測精度が向上していることが確認できる．以上から，疾病を単位としたマルチタスク学習は必ずしも予測精度を向上させるわけではないが，疾病間の関連を適切に取り込んだマルチタスク学習により予測精度の向上が可能であることが示唆された．

3.2.2 疾病ごとの予測モデル

続いて，各疾病についてモデルパラメータの値が大きい上位 10 個の特徴量を列挙し，“疾病ごとの予測ルール”に関する考察を行った．紙面の都合上全ての考察については割愛するが，以下で一点だけ取り上げる．疾病 *G93*(脳のその他の障害)における“65 歳以下”：これは疾病に固有の予測ルールの典型例と考えられる．他の疾病 (*K52, K56, K65, K76, K91*) では特徴量“65 歳以下”は，負の値を取る絶対値の大きい上位 10 個の特徴量に含まれており，高齢ではないことが死亡リスクを高めるか否かが疾病によって異なることが示唆された．この仮説は医学分野での研究により今後検証可能なものである．以上のような“疾病ごとの予測ルール”に関する分析は，疾病を単位としたマルチタスク学習を行う提案手法によって初めて可能になったことは特筆すべきである．

4. おわりに

本研究では，ICU 入室患者の死亡リスク予測問題を疾病を単位としたマルチタスク学習として定式化することで，“疾病によって死亡リスクを説明するルールが異なる”というような

疾病コンテキストを考慮した．疾病ごとのモデルの個別化に際して課題となるデータの疎性に対処するために，医学的分類に基づく疾病の類似度と，医療分類に基づく特徴量の類似度を正則化項に取り入れた手法を提案した．実データを用いた実験により，提案手法がマルチタスク学習を行わない手法や上記のドメイン知識を取り込まない既存のマルチタスク学習手法を上回る予測精度を持つことを示した．更に，疾病ごとに異なる予測ルールに関する考察を行うことで今後検証の対象となりうる仮説を得た．提案手法により，疾病ごとに異なる予測ルールに関する仮説の構築が可能になることが期待された．

参考文献

- [Argyriou 06] Argyriou, A., Evgeniou, T., and Pontil, M.: Multi-task Feature Learning, in *NIPS*, pp. 41–48 (2006)
- [Ghassemi 14] Ghassemi, M., Naumann, T., Doshi-Velez, F., Brimmer, N., Joshi, R., Rumshisky, A., and Szolovits, P.: Unfolding Physiological State: Mortality Modelling in Intensive Care Units, in *KDD*, pp. 75–84 (2014)
- [Ghassemi 15] Ghassemi, M., Marco, A. P., Naumann, T., Thomas, B., David, A. C., Peter, S., and Mengling, F.: A Multivariate Timeseries Modeling Approach to Severity of Illness Assessment and Forecasting in ICU with Sparse, Heterogeneous Clinical Data, in *AAAI* (2015)
- [Hug 09] Hug, C. W. and Szolovits, P.: ICU Acuity: Real-time Models versus Daily Models, in *AMIA Annual Symposium Proceedings*, Vol. 2009, pp. 260–264 (2009)
- [Ji 09] Ji, S. and Ye, J.: An Accelerated Gradient Method for Trace Norm Minimization, in *ICML*, pp. 457–464 (2009)
- [McGloin 99] McGloin, H., Adam, S., and Singer, M.: Unexpected Deaths and Referrals to Intensive Care of Patients on General Wards. Are Some Cases Potentially Avoidable?, *Journal of the Royal College of Physicians of London*, Vol. 33, No. 3, pp. 255–259 (1999)
- [Zeggwagh 14] Zeggwagh, A. A., Mouad, H., Dendane, T., Abidi, K., Belayachi, J., Madani, N., and Abouqal, R.: Preventability of Death in a Medical Intensive Care Unit at a University Hospital in a Developing Country, *Indian Journal of Critical Care Medicine*, Vol. 18, No. 2, pp. 88–94 (2014)
- [Zhou 14] Zhou, J., Wang, F., Hu, J., and Ye, J.: From Micro to Macro: Data Driven Phenotyping by Densification of Longitudinal Electronic Medical Records, in *KDD*, pp. 135–144 (2014)