

**ファジィ理論に基づく臨床判断の定量化と
転倒・転落リスクの推定に関する研究**

2022年1月

磯 本 佳 助

目次

第1章 序論	1
1.1 背景	1
1.2 提案システムの概要	6
1.3 本論文の構成	9
第2章 関連研究	12
2.1 臨床判断のモデル化	12
2.2 離床センサの開発	13
2.3 本論文の独自性	14
第3章 研究の基礎知識	16
3.1 転倒・転落リスクの定義	16
3.2 ファジィ理論の基礎知識	18
3.2.1 ファジィ理論の起源	18
3.2.2 あいまいさの種類	19
3.2.3 生体情報とファジィ	21
3.3 ファジィ理論の数学的基礎	21
3.3.1 ファジィ集合とメンバーシップ関数	21
3.3.2 ファジィ集合の上下限	24
3.3.3 ファジィ数	25
3.3.4 ファジィ線形回帰式	27
3.3.5 ファジィ推論	28
3.4 主観評価の測定	30
3.4.1 評定尺度法	30
3.4.2 Visual analogue scale の利点	31
3.4.3 ファジィ評定法	32
3.5 数量化理論	33

3.6	三次元ビジョン	33
3.6.1	Depth カメラ	33
3.6.2	Point cloud	35
3.6.3	クォータニオン	36
第4章	あいまいさを含む臨床判断のモデル化～因果関係の分析～	38
4.1	本章の目的	38
4.2	ファジィ評定法に基づくアンケート	39
4.2.1	看護師の臨床判断を観測するアンケート	39
4.2.2	転倒・転落リスクの臨床判断プロセスの定義	42
4.2.3	説明変数と目的変数の定義	43
4.3	リスク判断の定量化手法	44
4.3.1	ファジィ線形回帰分析の概要	44
4.3.2	ファジィ線形回帰式の再定義	45
4.3.3	ファジィ線形計画問題による外れ値の探索	47
4.3.4	ファジィ最小二乗法による臨床判断の解析	49
4.4	ダミーデータによる検証	50
4.4.1	ダミーデータの生成	50
4.4.2	実験条件	51
4.4.3	解析結果	52
4.4.4	ファジィ係数の中心の相関に関する考察	53
4.4.5	ファジィ係数の幅の相関に関する考察	53
4.4.6	ハイパーパラメータ K の調整	54
4.5	看護師の回答データを用いた検証	55
4.5.1	アプリケーションの構築	55
4.5.2	実験条件	56
4.5.3	結果と考察	57
4.6	本章のまとめ	58
第5章	あいまいさを含む臨床判断のモデル化～過学習の軽減～	60
5.1	本章の目的	60
5.2	ファジィ理論に基づく臨床判断の解析	61
5.2.1	ファジィグラフ尺度法を用いたアンケート	61

5.2.2	L-L ファジィ数の演算規則	62
5.2.3	ファジィ最小二乗法によるモデル化	63
5.2.4	従来手法の問題点	64
5.3	過学習を軽減するモデル化手法	65
5.3.1	概要	65
5.3.2	クラメール連関係数による説明変数の選択	65
5.3.3	L-L ファジィ相関比の算出	67
5.3.4	可能性測度に基づく説明変数のソート	68
5.3.5	K-分割交差検証による項目数の決定	69
5.4	看護師の回答データを用いた検証	70
5.4.1	目的と方針	70
5.4.2	実験条件	71
5.4.3	検証手順	72
5.4.4	結果	73
5.5	考察	76
5.5.1	臥位の項目数と誤差が小さな理由	76
5.5.2	誤差の変化率と再現誤差との関係	77
5.5.3	説明変数の削減に伴う誤差の変化	77
5.6	本章のまとめ	79
第 6 章	物理的観点に基づく患者の転倒・転落リスク推定	81
6.1	本章の目的	81
6.2	Depth カメラを用いた推定手法	82
6.2.1	概要	82
6.2.2	PCD の補正	84
6.2.3	ロバスト性のためのベッド直上視点データの分割	87
6.2.4	人物位置推定	88
6.2.5	位置情報に基づく転倒・転落リスク推定	91
6.3	任意の設置条件下における検証	92
6.3.1	実験条件	92
6.3.2	PCD の補正結果	95
6.3.3	転倒・転落リスクの推定結果	95
6.4	Depth カメラの設置制約の検討	97

6.4.1	設置制約の対象パラメータ	97
6.4.2	実験条件	98
6.4.3	ピッチ角に応じたリスク推定結果	99
6.4.4	センサの設置に必要な条件	101
6.5	実際の入院患者を対象とした検証	102
6.5.1	実験条件	102
6.5.2	結果	104
6.5.3	転倒・転落リスクの誤判定に関する考察	110
6.5.4	人物位置と姿勢との関係	112
6.6	本章のまとめ	114
第7章	患者の特徴を多方面から鑑みた転倒・転落リスク推定	116
7.1	本章の目的	116
7.2	ファジィ推論に基づく転倒・転落リスク推定手法	117
7.2.1	システムの全体像	117
7.2.2	設計のためのデータセット定義	120
7.2.3	メンバーシップ関数と IF-THEN ルールの作成	122
7.2.4	ファジィ推論の実行手順	124
7.3	検証	126
7.3.1	メンバーシップ関数の設計	126
7.3.2	転倒・転落リスクの推定	129
7.4	考察	131
7.4.1	メンバーシップ関数の設計	131
7.4.2	転倒・転落リスクの推定	132
7.5	本章のまとめ	135
第8章	結論	136
8.1	本論文のまとめ	136
8.2	今後の展望	138
	謝辞	141
	参考文献	142
付録A	Kinectの外観と仕様	153

業績リスト

List of Figures

1.1	Concept of the proposed system	6
3.1	Examination of relatedness for the fall risk	16
3.2	Grayscale and various kinds of gray	22
3.3	Classic subset and fuzzy set in the grayscale	23
3.4	Definition of fuzzy numbers	26
3.5	Examples of the rating scale method	30
3.6	Fuzzy graphic rating scales	32
3.7	Examples of the depth map and point cloud dataset	34
3.8	Rotation quaternion	37
4.1	Sample questionnaire sheet. The nurse draws the fall risk that he/she perceives based on the Fall Assessment Score sheet (FAS).	41
4.2	A process of clinical judgment concerning the fall risk. x is the presence of a checkmark, y^- to y^+ is the response by a nurse, a is a mean of the potential importance, c is a spread (vagueness) of the potential importance, and w^- to w^+ is the temporary importance. The nurse concludes the fall risk y^- to y^+ based on the importance w^- to w^+ that temporarily occurs in his/her mind.	42
4.3	L-L fuzzy number Y_i . Attach a spread e_i to a usual value (a mean) y_i	43
4.4	Derivation procedure of the evaluation criteria used by a nurse based on the fuzzy linear regression	46

4.5	Concept of Bi-Objective Fuzzy Regression (BOFR). In the classic Fuzzy Linear Programming (FLP), the fuzzy coefficients that minimize $\check{\mathbf{c}}_{LP}^T \check{\mathbf{x}}_i$ are searched under the constraint that the estimated values $\check{\mathbf{a}}_{LP}^T \check{\mathbf{x}}_i - \check{\mathbf{c}}_{LP}^T \check{\mathbf{x}}_i$ to $\check{\mathbf{a}}_{LP}^T \check{\mathbf{x}}_i + \check{\mathbf{c}}_{LP}^T \check{\mathbf{x}}_i$ include the observed values $y_i - e_i$ to $y_i + e_i$. BOFR can deal with the outliers because a relaxation term ξ_i is added to the inequality constraints and the objective function in FLP.	48
4.6	Concept of Fuzzy Least Squares (FLS). The purpose of FLS is to find the fuzzy coefficients that minimize the difference between the center of the estimated value $\check{\mathbf{a}}_{LS}^T \check{\mathbf{x}}_i$ and the center of the observed value y_i , as well as the difference between the both-ends of the estimated value $\check{\mathbf{a}}_{LS}^T \check{\mathbf{x}}_i \pm \check{\mathbf{c}}_{LS}^T \check{\mathbf{x}}_i$ and the both-ends of the observed value $y_i \pm e_i$	49
4.7	Relationship among a hyperparameter K (or the number of used samples $\text{card}(I')$), the slope of the objective function $dJ_{LP}/d\text{card}(I')$, and the correlations $\text{Cor}(\check{\mathbf{a}}^t, \check{\mathbf{a}})$ and $\text{Cor}(\check{\mathbf{c}}^t, \check{\mathbf{c}})$. Condition P in Table 4.1 is utilized. The $\text{card}(I')$ turns smaller as the hyperparameter K increases, and the $dJ_{LP}/d\text{card}(I')$ becomes the highest at the point of $K = 0.1$ ($\text{card}(I') = 479$). In this point, the correlations $\text{Cor}(\check{\mathbf{a}}^t, \check{\mathbf{a}})$ and $\text{Cor}(\check{\mathbf{c}}^t, \check{\mathbf{c}})$ become larger.	55
4.8	Execution window in the application	56
5.1	L-L fuzzy number A that consists of the mean a and spread c . $\mu_A(z)$ is the degree to which a real number z ($\in \mathbb{R}$) belongs to A . The range of $\mu_A(z)$ is 0 to 1 (i.e., $0 \leq \mu_A(z) \leq 1$).	62
5.2	Concept of the proposed method. A selection method of explanatory variables in the quantification theory type-I is reformed based on the fuzzy theory.	66
5.3	Repeatable errors in a nurse for the three FASs that have the status of checkmarks all in common (i.e., $\mathbf{x}_{67} = \mathbf{x}_{150} = \mathbf{x}_{247}$ in Eq. (5.1)). Each of the errors was calculated by Eq. (5.26).	75

5.4	Relationship between the number of items and the error. The model of “Nurse 1 - Sitting sideways” is utilized. Error values are derived by Eq. (5.23). Describe only five folds ($l' = 1, 2, \dots, 5$). Black lines represent the averages of all folds ($l' = 1, 2, \dots, 12$).	78
6.1	Concept of the proposed method concerning depth camera	83
6.2	Concept behind the parameter derivation for the PCD correction	84
6.3	Definition of the inclination angle	86
6.4	Concept behind the division of the bed top view dataset for robustness	87
6.5	Relationship between the separation thresholds and the number of three-dimensional points for each section	88
6.6	Procedure for the human location estimation	89
6.7	Relationship between the center of gravity g^X and the fall risk r^X on the X-axis (Eq. (6.14))	92
6.8	Infrared image of the room used for the experiments, which was acquired using a depth camera (a Microsoft Kinect sensor). The two points A and B correspond to the coordinates on the long-side edge of the bed, which are defined for correction.	93
6.9	Results of the rotation and translation	96
6.10	Results of fall risk estimation. The upper-right value indicates the elapsed time, while the upper-left value indicates the fall risk. The fall risk follows the order: (a) lying down < (b) long sitting < (c) sitting sideways < (d) standing.	97
6.11	Position and orientation of the depth camera	98
6.12	Example of a side-view map used for the classification of the degrees of existence of the subject’s body part and layer in Table 6.4. The two dashed lines represent the AOV related to the pitch angle of the depth camera.	100
6.13	Depth maps showing the hospital environment. (a) and (b) represent the rooms for Subject A and B, respectively. There is an over chair table and a backrest in the room for Subject B.	103
6.14	Time-series data of fall risk for each subject	106

6.15	Fall risk results of Subject A. Enlarge a part of Fig. 6.14(a) and focus on several results.	107
6.16	Fall risk results of Subject B. Enlarge a part of Fig. 6.14(b) and focus on several results.	108
6.17	Adjustment of the bed height with a remote controller	111
6.18	Scatter diagrams of human locations on each posture (Subject A) . .	113
6.19	Scatter diagrams of human locations on each posture (Subject B) . .	113
7.1	Concept of the proposed system with the methods in sections 4 to 6 .	118
7.2	Procedure of fuzzy inference that derives the fall risk \hat{r} from the human location (center of gravity) g_{input}^X , g_{input}^Y , and g_{input}^Z	119
7.3	Collection of datasets to create the membership functions	120
7.4	Creation of membership functions and IF-THEN rules	122
7.5	Execution of fuzzy inference	124
7.6	Antecedent parts on each axis (1st fold)	128
7.7	Consequent part (common to all folds)	129
7.8	Frequency distributions of fall risk for each fold	130
7.9	Example of depth maps representing the diversity of the posture “Sitting sideways”	133
7.10	Frequency distributions concerning the posture “Sitting sideways” . .	134
A.1	Appearance of the Microsoft Kinect sensor	153

List of Tables

3.1	Definition of fall risks for each section	17
4.1	Conditions on the dataset generation and analysis	51
4.2	Analytical results for each dataset	52
4.3	Estimation models selected by each nurse. Three choices are recorded. A bold font represents the model that matches the nurse’s (respon- dent’s) ID.	57
5.1	Experimental conditions	71
5.2	List of the Number of items (Num) and Error (Err). The Subtraction (Sub) \bar{E}^- and Rate of change (Rate) $\bar{E}^{\%}$ were derived by Eq. (5.25).	74
6.1	Parameters of the proposed method	93
6.2	Thresholds for the PCD separation (unit is [m]). The coordinate origin is shown in Fig. 6.4.	94
6.3	Fall risk weights in this experiment	94
6.4	Relationship amongst the “Pitch,” “Fall risk,” “Degree of subject’s body part existence,” and “Degree of layer existence” factors	99
6.5	Parameter conditions of the proposed method	103
6.6	Thresholds for the PCD separation (unit is [m]). Each parameter was adjusted based on the bed and room of a hospital cooperated in this experiment.	103
6.7	Distribution of fall risk across the various states. “Unknown” is a state which cannot be classified into any state. For example, the depth map (F) showing in Fig. 6.16(b) is classified Unknown because another person is existing within the measurement range. Subject A did not turn into the “Long sitting” posture during the experiment.	109

7.1	Parameter conditions of the proposed method concerning the depth camera (a Microsoft Kinect sensor)	126
7.2	Thresholds for the PCD separation (unit is [m])	126
7.3	Averages and standard deviations for each fold	127
A.1	Specifications of the Microsoft Kinect sensor	153

第1章 序論

1.1 背景

「転倒」とは「自分の意思に反してバランスを崩してしまい、足底以外の身体の一部が地面または床面についた状態」である。また、「転落」とは「高低差のあるところから転がり落ちること」である。英語圏では、転倒と転落の区別語はなく、どちらも「Falls」と呼ばれる。一方、「事故」には「思いがけず生じた悪い出来事」、あるいは「物事の正常な活動・進行を妨げる不慮の事態」といった意味があるといわれている [1]。

転倒・転落事故は、医療現場において大きく問題視されており、深刻な事故の一つとされている [2-5]。高齢者など身体機能の衰えた人は、転倒・転落事故により足部や臀部の骨折、頭部の損傷など深刻な怪我に繋がる危険が高い [6]。入院患者の転倒・転落事故は医療事故全体の約30%を占めており [7]、対象をリハビリテーション科に限定すると発生率は46%にまで上昇する [8]。こうした事故は特に高齢者に多く、入院患者の転倒・転落事故の内、65歳以上の患者が占める割合は82.6%となっている [7]。また、高齢者のおよそ30%が年に少なくとも1回の転倒・転落を経験している [9]。

転倒・転落事故は日本国内でも深刻な問題とされており、日本の病院における転倒・転落事故の割合は入院患者全体の2.7%といわれている [10]。また、転倒・転落事故の発生件数は、医療事故全体の23.6%（リハビリテーション科は約50%）を占めている [11,12]。特筆すべきはこれらの事故の内、51.3%がベッド周辺で生じているということである [13]。また、転倒・転落事故の発生後に、患者に障害が残るケースは44.3%、患者が死亡するケースは1.9%を占めており [11]、転倒・転落によって患者の生活の質（QOL: Quality of Life）が著しく低下する危険性が非常に高い。

さらに、内閣府の調査によると、65歳以上の要介護者の内、介護が必要になった原因の12.2%が転倒・骨折によるものであった [14]。また、高齢者の不慮の事故による死亡者数について死因別に比較すると、転倒・転落が死因による死亡者数は交通事故よりも多く、死亡者数も年代が上がるにつれて増加傾向にあることが明らかに

なっている [15]. 比較的最近の 2016 年においては、高齢者の不慮の事故による人口 10 万人当たりの死亡者数は、交通事故の 8.9 人に対して転倒・転落は 20.7 人となっており、交通事故の 2 倍以上の高齢者が転倒・転落が原因で死亡していることが分かる。

こうした統計データが示す通り、転倒・転落は頻繁に起こる事故であり、大きく問題視されている。そのため、医療現場では転倒・転落事故を未然に防ぐため、転倒・転落の危険性がある入院患者に対し、ベッドから立ち上がる際にはナースコールを押し、看護師の介助を受けるよう指導を行っている。しかし、患者自身の認知機能の低下や転倒・転落の過少評価、および、看護師に対する遠慮により、ひとりで立ち上がろうとする患者が多く存在する。そのため医療現場では、クリップセンサやマットセンサ等の離床センサを使い、転倒・転落事故の予防や早期発見が行われている [1]. クリップセンサとは接触型センサの一種であり、患者とセンサ本体を繋ぐ特殊なひもを用いることで患者の動きを検知する。このひもは、両端にマグネットとクリップがそれぞれ装着されており、運用の際はマグネットをセンサ本体に、クリップを患者の衣類に取り付ける。平常時は、このひもはたるんだ状態にあるが、患者の上半身が起き上がった際はクリップを付けた方向に力が働くため、最終的にはひもが完全に伸びきり反対側のマグネットがセンサ本体から外れる。こうした物理的な作用によって、患者の起床動作を検知できる。一方、マットセンサでは、ベッドサイドの床上にマット型のセンサを設置する。患者がそのマットの上に乗ると、患者の体重に反応してアラームが鳴るため、本センサを用いることで患者の離床動作やベッドからの転落を検知できる。クリップセンサは危険度が高く、認知力の低下が見られる患者に、マットセンサは立ち上がり動作に問題がある患者に適している [1]. しかし、クリップセンサは装着による違和感を患者へ与えてしまう恐れがあるうえ、患者自身がクリップを取り外すことがある。また、マットセンサは視認可能であるため、患者がマットを避けて移動することが容易である。さらに、いずれの対策も危険な行動に至った後に検知されるため、転倒・転落事故の予防・予測へと繋げることが難しい。

一方、こうした離床センサのほかに、転倒・転落時の衝撃を緩和するため、緩衝材入り保護帽や衝撃吸収マットが使用されることがある [16]. これらの器具には、転倒・転落による重篤な外傷を回避する効果があるものの、転倒・転落事故が発生することを前提としたリスクマネジメントであり、事故そのものを防げる訳ではない。理想的な環境としては、看護師が転倒・転落する危険性の高い患者を常に見守ることであるが、看護師の業務負担を考えると現実的とはいえない。

ここまでの内容として、患者の行動を検知する離床センサについて述べたが、転倒・転落を防止するためのもう一つのアプローチとして、アセスメントツールの使用が挙げられる。アセスメントツールとは、入院時などに転倒・転落しやすい患者をスクリーニングして予防介入に繋げるためのものである [17]。転倒・転落に関するアセスメントツールは数多く開発されており、患者の転倒・転落を予測するために各国の医療現場で利用されている。その中でも、Morse Fall Scale (MFS) [18] や St. Thomas's Risk Assessment Tool in Falling Elderly Inpatients (STRATIFY) [19] は、特に信頼性が高いといわれている [20]。これらのアセスメントツールは、転倒・転落危険度の迅速な評価ができるといった長所がある。しかし、質問数とその分少ないため、患者の細かい病状までを考慮できず、転倒・転落に繋がる重要因子を見逃す可能性が高い。

一方、日本では日本看護協会 (Japanese Nursing Association) によって転倒・転落アセスメントスコアシート (FAS: Fall Assessment Score sheet) が推奨された 1999 年以降、様々なアセスメントツールが開発されてきた [21]。その結果、現在では日本の多くの病院で、様々な形式の FAS が利用されている。FAS は、転倒・転落に関するリスクをスコア化するためのチェックシートであり、多いものでは約 50 個のチェック項目を有する。看護師は FAS の記入後、スコア化された点数や病院で決められているルールに基づき、患者の転倒・転落予防策について立案および実施を行う [22, 23]。FAS は患者の状態を詳細に把握することが可能であり、より正確なアセスメントへと繋がれるといった利点がある。しかしながら、FAS は他のアセスメントツールより質問数が多いため、一部の看護師 (特に新人看護師) にとって非常に扱いにくいといった問題点を有する。そのため、FAS は MFS や STRATIFY と比べて、患者のアセスメントに多くの時間を必要とする。

一般的に、FAS の記入および評価は全ての入院患者に対して行う必要があり、通常は患者の入院時に実施される。日本は世界的に見ても患者の入院日数が多く、一人の患者が医療用ベッドを占有する期間が長い [24]、近年では入院日数が減少傾向にあり、FAS が推奨された 1999 年から比較的最近の 2014 年にかけて、病院における患者の平均滞在期間は約 21% 減少している [25]。これらの統計データは、入院患者が以前よりも頻繁に入れ替わり、より多くの患者に対してアセスメントを行わなければならないことを示唆している。さらに、入院患者の病状は刻一刻と変化するため、入院後も FAS の記入内容が変わることがある。つまり、看護師は FAS が追加・更新されるたびに転倒・転落リスクを評価する必要があり、看護師に対する負担が非常に大きいといえる。

さらに、患者の容体は病院や診療科ごとに異なり、転倒・転落事故の割合にも違いが見られることから [26,27]、汎用的な FAS では一部の患者に対して有効性を発揮できず、適切なアセスメントを行えない可能性が高い。そのため、脳外科などの特定の疾患を持つ患者に特化したアセスメントスコアシートを提案する研究者も存在する [28]。さらに、Perell らは既存の転倒・転落リスク評価尺度を要約し、その使用に関してより適切なインフォームド・チョイスを行えるよう、20種類のアセスメントツールについて5名のレビュアーによる調査を実施した。その結果、調査の対象となったアセスメントツールは診断精度や総合的な有用性に大きなばらつきがあるものの、転倒・転落予防プログラムの一環として使用できる尺度がいくつかあり、施設が独自に評価尺度を開発する必要性は低いと述べた。ただし、急性期、外来、長期療養などの環境では、有効な評価指標に相異があるため、異なるアセスメントツールを用いる必要があることを主張した [29]。

このように、実際の患者は様態が多様であることから、FAS を杓子定規に扱うことは難しい。そのため、医療現場では看護師の判断によって立案の変更やより適切な対処を行っている。こうした看護師の判断は、患者を担当する看護師が FAS や患者の様子を観察し、看護師個人が感じる患者の転倒・転落の危険性に基づいている。このような、看護師が患者の状態を熟考して看護ケアを行うための一連の意思決定のことを臨床判断 (Clinical judgment) という [30]。

様々なアセスメントツールが開発される一方で、看護師の臨床判断に着目した研究が進められている。看護師は、自身の知識や経験に基づいた転倒・転落予測ができるといわれており、その有用性は既に多くの研究で実証されている。泉らは、転倒経験、知的活動、視力障害、排泄介助、移動レベル、ナースの直感、トリガーの7項目から成るアセスメントツールを用いて、入院患者の転倒・転落予測に関する調査を行った。その結果、ナースの直感は相対危険比が最も高くなった [31]。また、Vassallo らは高齢者のリハビリテーション病棟に入院する 200 名の患者を対象として、2種類のアセスメントツール (Downton および STRATIFY) と臨床判断 (徘徊行動の観察) の予測精度について調査した。その結果、Downton と STRATIFY の予測精度はそれぞれ 50% と 46.5%、臨床判断の予測精度は 78% となり、看護師の臨床判断は 2種類のアセスメントツールよりも高い精度を持つことが示された [32]。さらに、Meyer らは従来のアセスメントツールと看護師の臨床判断との比較を行った結果、介護施設でのアセスメントツールの利用は、看護師の臨床判断のみに頼るよりも臨床的に良い結果にはならないと述べた [33]。また、Aranda-Gallardo らはアセスメントツールによるリスクアセスメントは、急性期病院に入院した成人患者

に対しては、ほとんど有用性を示さないことを明らかにした。この結果を受けて、Aranda-Gallardo らは看護師の臨床判断を聞き入れることが最善のアプローチに繋がることを主張した [34]。

前述した通り、患者の容体や事故の割合は施設ごとに異なるため [26,27]、一部の診療科では有効なアセスメントツールも、他の診療科では十分な効果を発揮できない場合がある。そのため、転倒・転落の危険性を推定する際は、その診療科に勤める看護師の臨床判断を取り入れることが必要不可欠であるといえる。なお、余談だが近年では看護師だけに留まらず経験を積んだ理学療法士においても、正確な臨床判断ができる可能性が示唆されている [35]。転倒・転落のアセスメントを行う際は、人間の主観を含む判断が重要となり、一部の研究者によってその調査が進められている。

臨床判断の有用性が注目される一方で、問題視される部分もまた存在する。転倒・転落に関する臨床判断は、看護師間で共通する訳ではない。藤井らは、転倒が予測される看護場面のリスク評価に影響する要因を明らかにするため、看護師 752 名を対象に自記式質問紙による調査を実施した。その結果、経験年数の少ない看護師は、看護場面の状況に含まれる危険にはっきり気付いていないせいで、却ってリスクを高く評価する可能性があることを主張した [36]。

さらに、看護師が持つ判断基準の違いや、判断の迷いも臨床判断の問題点といえる。平松らは独自に開発した FAS を用いて、高齢者の転倒予測に対する入院時の看護師間の一致について検討した。その結果、FAS のチェック項目が主観的な場合や、患者本人や家族からあいまいな情報が提示された場合は、看護師によって判断が分かかれやすく、信頼性に限界があることが示唆された [37]。その後、森田らは多重ロジスティック回帰分析によって改訂された FAS を用いて、看護師の評定者間一致性に関する検証を実施した結果、平松らと同様の見解を示した [38]。さらに、清水らは FAS を活用している看護師に半構造化インタビューを実施し、インタビュー内容を質的帰納的に分析した。その結果、FAS の表現があいまいであるため、看護師は自身の判断が正しいか迷ったり、迷いながら予防対策を講じていることが明らかになった [39]。以上のことから、看護師の臨床判断を扱う際は、こうした判断の相違や迷いについても留意する必要があるといえる。

ここまでで述べた通り、医療現場では入院患者の転倒・転落事故を防ぐため、離床センサやアセスメントツール、看護師の臨床判断などが活用されている。本論文の目的は、これらの事柄を統合した入院患者の見守りシステムを新たに提案することである。このとき、筆者のシステムは、最終的には看護師が担うアセスメントに

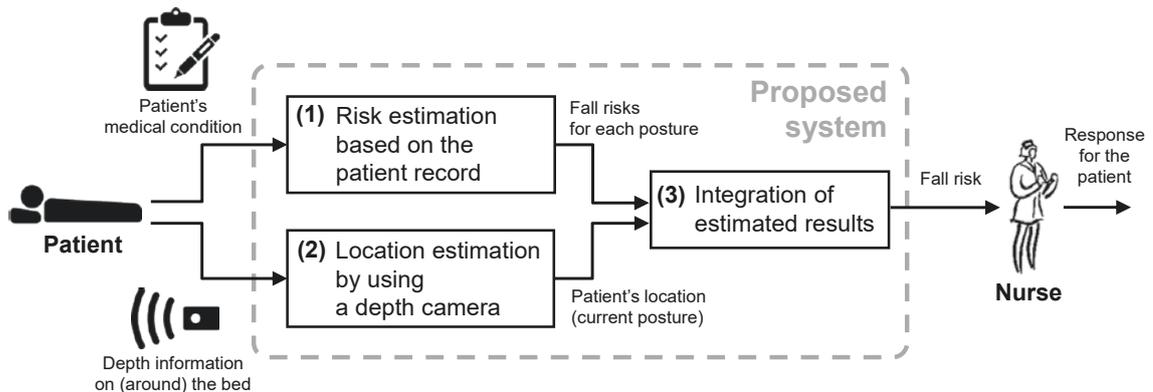


Fig. 1.1 : Concept of the proposed system

関する業務を代わりに行うことを想定していることから、本研究では看護師の臨床判断を定量化し、システムとして実現するための手法の確立を目指している。さらに、今回提案する手法は、離床センサやアセスメントツールの長所を活かしたものである。次節より、提案システムの概要について述べる。

1.2 提案システムの概要

Fig. 1.1 に提案システムの構成図を示す。本提案システムは、患者の病状とベッド上（またはベッド周辺）の距離情報を入力、転倒・転落リスクを出力としている（「転倒・転落リスク」という用語については3.1節で詳細を述べる）¹。このとき、本研究では患者の転倒・転落に着目することから、患者の病状は電子カルテの一種であるFASにより取得する。一方、ベッド上（またはベッド周辺）における距離情報の取得にはDepthカメラを用いる。FASとDepthカメラを併用することで、患者の「外見²」だけでなく、転倒の既往歴やしびれ感があるなどの「内実³」を考慮することが可能となるため、より正確なリスクアセスメントの実現が期待できる。さらに、システムの利用者である看護師は算出された転倒・転落リスクの値に基づき、患者への対応を決定することができる。これにより、現場経験の比較的浅い新人看護師でも適切なアセスメントを遂行することが可能となる。また、看護師はDepthカメラ

¹なお、既存の離床センサの多くは、システムの出力が「アラームの有無」であるが、提案システムでは出力を「転倒・転落リスクの値」としている。提案システムの出力をアラームの有無としないのは、病院や診療科によってアラームの鳴動閾値が異なると考えたためである。

²外から見た様子。

³内面の事情。

の映像を通して患者の様子をリアルタイムに把握することが可能であるため、ベッドから離れた場所からでも患者の見守りを行うことができる。

提案システムの内部は、(1)～(3)の3つのモジュールで構成される (Fig. 1.1)。 (1) は患者のカルテ情報に基づくリスク推定、(2) は Depth カメラを用いた患者の位置推定 (姿勢推定)、(3) は推定結果の統合である。

モジュール (1) では、FAS から患者の転倒・転落リスクを姿勢ごとに算出する。このとき、転倒・転落リスクを推定するためのモデル式の作成には、看護師の転倒・転落に関する知見 (看護師の経験則) を反映できるよう、看護師から取得したデータを用いる。なお、モデル式の作成方法としては、看護師から取得したデータではなく、実際の転倒・転落事例を用いた手法が考えられる。しかし、患者の容体は病院や診療科によって異なり、転倒・転落事故の割合にも違いが見受けられる [26, 27]。そのため、実際の事故データからリスク推定モデルを作成する場合は、病院や診療科ごとに転倒・転落事例を収集しなければならないが、これには多大な時間とコストを必要とする。また、個人情報であるため利用の敷居が高く、データに偏りも生じやすい。そのため、実際の事故データに基づいてモデル式を作成するのは実用的ではないといえる。さらに、アセスメントツールは臨床で看護師が簡便に使えて、かつ根拠のあるリスクをスコア化して基準を定めるべきだといわれている [17]。つまり、アセスメントツールは単に転倒・転落事故の要因を列挙するだけでは不十分であり、看護師にとって扱いやすい形式でなければならない。一方、日本国内の FAS は多いものでは約 50 個の項目を有しており⁴、転倒・転落事故の要因となり得るのは、その関連性の強さに関わらずチェック項目として採用される傾向にある。そのため、FAS は他のアセスメントツールと比べて、チェック項目が不足している可能性は低いと考えられる。ただし、項目数が多いことで、看護師にとっての簡便さが損なわれる可能性があることから、本論文では転倒・転落リスクの推定に不要な項目をモデル式から削除する手法についても検討する。このとき、本手法の主目的はモデルの次元数を削減することで、モデル構築に必要なデータ数を減らし、看護師の負担軽減に繋げることとしているが、将来的には泉ら [17] が提唱する看護師が簡便に使える FAS の実現にも応用できる可能性が高い。

モジュール (2) では、Depth カメラから患者の位置情報を推定する。Depth カメラは、赤外線光をカメラ本体から照射することでセンシングを行うため、患者が就

⁴ちなみに、MFS と STRATIFY の項目数はどちらも 6 個である。これらと比較すると、FAS の項目数がいかに多いかが分かる。

寝た後の暗所でも利用できる。さらに、三次元空間情報を取得できるため、患者とベッドとの相対的な位置関係を知ることが可能である。なお、6.5.4節で後述することになるが、本システムは病室のベッド周辺での使用を想定していること、ならびに入院患者のベッドには落下防止用の柵が付いていることが相まって、患者の行動が制限されやすい。そのため、患者の位置情報から臥位や立位などの姿勢を推定することが可能である。Fig. 1.1のモジュール(2)では、入力を「ベッド上(またはベッド周辺)の距離情報」、出力を「患者の位置情報」としているが、出力に関しては最終的には「姿勢情報」へと変換して利用される。一方、先ほど登場したモジュール(1)では、転倒・転落リスクを患者の姿勢ごとに求めている。そのため、モジュール(2)を通じて得られる患者の位置情報を姿勢情報へと変換することで、モジュール(1)と(2)の間に「姿勢」という共通点ができ、結果として両者を統合させることが可能となる。さらに、姿勢は患者の外見を表す概念であり、人間にとって理解が容易である。そのため、姿勢情報への変換は、看護師の判断をシステムに介入させるうえで、意義のあるプロセスだといえる。

モジュール(3)では、各姿勢における患者の転倒・転落リスクと現在の位置情報(姿勢情報へと変換して使用)を統合し、現在の転倒・転落リスクを算出する。FASを用いた手法(モジュール(1))は、患者の内実を扱えるという利点があるが、ベッド上における患者の様子までは把握できない。そのため、転倒・転落に直結する患者の行動をリアルタイムに観測できず、結果として転倒・転落事故を未然に防止したり早期に発見したりできないといった事態が生じ得る。一方、Depthカメラを用いた手法(モジュール(2))は、患者の外見に関する情報を取得できるが、我々の目に映らない部分までを捉えることはできない。そのため、一般的には軽症患者よりも重症患者の方が転倒・転落リスクが高くなるべきであるにも関わらず、外見の特徴が類似しているために両者を同等に扱ってしまい、結果として誤ったリスクを算出してしまうといった問題が起こり得る。これに対し、モジュール(3)ではFASとDepthカメラの情報をどちらも利用するため、互いの短所を補いつつ、長所を活かしたりリスク推定が可能である。なお、FASを用いた手法では看護師の臨床判断を利用するが、この判断には看護師個人の主観を含む。さらに、姿勢は、異なる姿勢同士を区別するための境界が不明瞭である。そのため、モジュール(1)の出力である転倒・転落リスクと、モジュール(2)の出力である姿勢は、両者ともにあいまいな概念だといえる。このような理由から、モジュール(3)ではファジィ推論を使用しており、あいまいな情報が混在する状況下においても、尤もらしい転倒・転落リスクの推論を目指している。

本論文の目的は、各モジュールを実現するための手法を確立することである。そのため、それぞれのモジュールに即した研究テーマを設定している。1つ目のテーマは看護師の転倒・転落に関する臨床判断のモデル化、2つ目のテーマはDepthカメラを用いた患者の位置推定、3つ目のテーマはあいまいさを含む推定結果の統合である。本論文では各々のテーマについて、方法論の提案ならびに検証結果の記載を行う。

1.3 本論文の構成

本論文は全8章で構成される。第1章では、本研究の背景および提案システムの全体像について述べている。このとき、本論文で提案するシステムは3つのモジュールを含有する点に加え、各モジュールが持つ役割やモジュール間の入出力関係を説明した。第2章では、提案システムに関連する先行研究を「臨床判断のモデル化」と「離床センサの開発」の2つのカテゴリに分けてそれぞれ紹介する。その後、先行研究の優位性や課題を踏まえながら、筆者の提案システムが持つ独自性について述べることで、本研究の立ち位置を明確化する。

第3章では、提案システムの構築に用いる各種理論の基礎知識について述べる。本論文では提案システムの実現にあたって、ファジィ理論や数量化理論、三次元ビジョンなど様々な分野の手法を用いている。そのため、第3章では各分野の概要を節ごとに分けて紹介する。ここでは基本的な事柄に加え、各々の分野が持つ理念について筆者の見解を交えつつ説明する。各分野の理念と提案システムとの関係性について述べることで、第4章以降に登場する解析手法（方法論）の意義を明確にすることができる。これは、読者が本論文の理解を深めるための一助となる。

第4～7章では、それぞれの研究テーマの詳細を記す。本論文では提案システムを構成するモジュールの個数に合わせて、研究テーマを3つに分割している。第4章および第5章ではモジュール(1)について述べる。このとき、第4章では看護師の臨床判断に関して、FASのチェック内容と看護師が感じる転倒・転落リスクとの因果関係の特定に焦点を当てている。ゆえに、本章ではモデルパラメータの正確さを重視した定量化手法を提案する。

一方、上記の手法を通じてモデルパラメータを導出する際は、看護師個人に多くのアンケートを課す必要があり、看護師の勤務状況によっては使用が難しい。そのため、第5章ではモデル構築の簡便さを追求しており、比較的少量のデータのみで

臨床判断の簡易モデルを作成する方法について研究を進めている。なお、第5章の手法は過学習問題に主眼を置いており、過学習はモデル化に用いるデータ数が少ないときに発生しやすいといわれている。ただし、出力データとの関連性が高い入力データの種類が元々少ないなど、データに内在する特徴によっては、十分なデータ数を確保できた場合においても過学習が生じ得る。そのため、将来的には第4, 5章でそれぞれ提案される手法を組み合わせることで、モデルパラメータの正確性を担保しつつ、過学習問題を回避することができ、より実用性の高いモデルの構築へと繋げられる。よって、モジュール(1)に関しては2つの章を設けており、異なる観点からその実現方法を追求している。

つづいて、第6章ではモジュール(2)について説明する。本章では、Depthカメラにより得られた距離情報から、ベッド上またはその周辺における患者の現在位置を推定する。また、推定された患者の位置座標を使い、物理的観点を考慮した転倒・転落リスクを算出する方法について述べる。さらに、患者の位置座標と姿勢との関係性について調査し、第6章の方法論が姿勢を推定する能力を有することを確認する。なお、モジュール(2)において、姿勢だけでなく位置座標や転倒・転落リスクの推定に関しても検討する理由は、患者の見守りシステムをモジュール(2)単体のみで実用化する余地を残すためである。本論文では、実際の看護師や病室での検証を通じて、提案システムの各モジュールが理論的に実現可能か否かを確認する。しかし、本研究は転倒・転落という患者の生命に直結する題材を扱っていることから、提案システムを実用段階まで到達させるためには、様々な環境下での試験を通じて、あらゆる例外やエラーの特定および対処を行わなければならない。ただし、こうした試験には多くの時間とコストを要する。そのため、筆者の提案システムは段階的な運用ができるよう、一部のモジュールが不足した状況下でも患者の転倒・転落リスクを推定可能な構成とした。さらに、モジュール(2)では提案手法が複雑化するのを防ぐため、患者の姿勢およびリスクの推定に深層学習を用いない。本モジュールでは患者の位置座標を重心計算に基づいて推定し、得られた位置座標を用いて現在の姿勢や物理的な転倒・転落リスクの導出を行う。

第7章ではモジュール(3)について記載する。第4, 5章ではモジュール(1)を作成し、患者の転倒・転落リスクを姿勢ごとに算出している。一方、第6章ではモジュール(2)を作成し、現在の姿勢を導出している。モジュール(3)ではこれらの結果を統合することで、現在の転倒・転落リスクを推定する。方法論としては、ファジィ推論を用いる。モジュール(1)で算出される転倒・転落リスクと、モジュール(2)で導出される姿勢は、両者ともにあいまいな概念であり、通常の実数との対応付けが困難

である。論理学で登場する一般的な推論は、こうしたあいまいな概念を扱うことが難しく、あいまいな情報が含まれた状態で結果を推論することは不可能に近い。そのため、第7章では一般的な推論ではなく、ファジィ推論と呼ばれる手法を使用する。ファジィ推論を用いることで、あいまいな情報がデータ内に混在する状況下においても、患者の転倒・転落リスクを推定することが可能となる。なお、人間は任意の数値情報のみを参照して特定の値を推論している訳ではなく、時には数値化が不可能なあいまいな情報から意思決定を行うことがある。そのため、ファジィ推論を用いた本モジュールは、人間が普段行う推論プロセスに即しているといえる。

最後に、第8章では本論文のまとめを述べる。このとき、本論文で達成できた事柄だけに留まらず、未達成の部分についても記載することで、次世代の研究へと繋げる。次章より各々の詳細を述べる。

第2章 関連研究

2.1 臨床判断のモデル化

転倒・転落のアセスメントツールに基づく看護師の臨床判断のモデル化については、研究事例がそれほど多くはない。安藤らは、患者のアセスメントスコアと複数の姿勢を看護師に提示し、それぞれの姿勢に対する転倒・転落の危険度を看護師に判断させるアンケートを実施した。その後、ある特定のアセスメントスコアに対し、実数値遺伝的アルゴリズム（RCGA: Real-Coded Genetic Algorithm）とファジィニューラルネットワーク（FNN: Fuzzy Neural Network）によるモデル構築を試みた [40]。しかし、遺伝的アルゴリズムは初期集団の違いや突然変異の発生タイミングによって最終的な結果が変化するため、最適解を安定して得ることが不可能である。また、ニューラルネットワークはモデルの表現力が高いものの、ネットワークの構造が複雑化しやすいため、算出されたパラメータの解釈が困難である。さらに、安藤らが構築したモデルは、特定のアセスメントスコアのみに特化したものであり、汎用性や利便性が高いとは言い難い。

山崎らは、100例のFASに対し転倒・転落リスクを各々評価するアンケートを看護師に実施した。その後、取得したデータにLasso回帰を適用することで、FASの項目と看護師の評価との関係性をモデル化した [41]。Lasso回帰は、正則化項によって不要なパラメータの値を0にするといった性質があるため、FASの余分な項目を削減することが可能である。また、モデル式が単純になりやすく、モデルパラメータの解釈も容易である。ただし、山崎らのアンケートでは転倒・転落リスクを回答する際、看護師は0～100%のいずれかの数値を記入する必要がある。そのため、回答の選択肢が多くなりやすく、分解能を1%としたときは101パターンもの回答が存在することになる。数値情報を回答させる際の選択肢の多さは、回答者に煩わしさや混乱を招く原因となる。さらに、看護師は臨床判断を下す過程において、自身が感じるリスクの大きさを数値情報として認識しているとは限らない。そのため、臨床判断を取得する際は、看護師に混乱を与える可能性が低く、なおかつ数値化が困難な感覚的な部分を回答中に反映可能なアンケート手法を採用すべきである。こ

のほかに、看護師は転倒・転落リスクの判断時に迷いを感じることもあるにも関わらず [39]、山崎らのアンケートでは迷いの部分を考慮していない。そのため、アンケート回答から看護師の心緒（例：自身の判断に確信を持って回答したか、あるいは漠然とした回答を行ったか）を把握することができない。これはモデル式の精度や信頼性に関わる部分であり、看護師の判断をより正確にモデル化するならば、迷いに関してもアンケートの際に取得すべきである。

臨床判断のモデル化については研究事例がいくつか存在するが、モデル式の明瞭性や利便性、およびアンケート手法の汎用性や妥当性において課題が残る。そのため、本論文では臨床判断を扱う際に、こうした問題を考慮したアンケートおよび解析手法の実現を目指す。

2.2 離床センサの開発

転倒・転落を防止するための離床センサについては、研究が比較的盛んに行われている。Rahmaniらは、距離画像の各フレームに対して畳み込みニューラルネットワーク（CNN: Convolutional Neural Network）を適用し、カメラの角度やポジションが変化しても、人間の行動内容を分類できるモデルを作成した [42]。しかし、本手法はCNNを用いているため、生成されたパラメータの解釈や誤判定が生じたときの対応が困難である。Inoueらは、入院患者をモニタリングするため、カラーカメラから取得した映像にホモグラフィ変換を適用し、映像の正規化およびベッドの位置検出を実現した [43]。しかし、カラーカメラを使用するため、夜間での使用に適さない。古橋らは、Depthマップに対してRANSAC法を適用することで、ベッド平面の推定と除去、ならびに人体骨格抽出を実現した [44]。しかし、センサをベッド中心部から約2.5mの高さに設置するため、患者に対する圧迫感とセンサ落下の危険が伴う。

入院患者をモニタリングする研究としては、枕内部に埋め込まれた加速度センサと、ベッドフレームに取り付けられたピエゾ振動センサを用いる方法が提案されている [45]。これは、各センサから得られた微小振動に対し機械学習を用いることで、患者の姿勢分類を実現するものである。しかしながら、センサが接触式であるため、使用中に患者が違和感を覚える恐れがある。Enayatiらは、油圧式トランスデューサ（Hydraulic transducer）から取得した圧力データに対し、主成分分析やフィードフォワード・ニューラルネットワークを適用することで患者の姿勢推定を実現した [46]。

しかし、敷布団の下にセンサを設置するため、患者に接触による不快感を与えてしまう。また、接触型であるため故障のリスクが高い。初雁らは、電動ベッドのアクチュエータ内部に力センサを内蔵させ、ベッド荷重の変動から患者の起居動作を検出することで、ベッド上の患者の動作推定を実現した [47]。しかし、本システムを利用するためには、ベッド本体の改造が必要であり、導入の敷居が高い。Ocuvera社は、深度センサから取得した患者の映像に基づき、転倒・転落リスクを推定する製品を開発している [48]。しかし、本システムはベッドに横たわる患者の足元から少し離れた位置にセンサを設置するため、別の入院患者のベッドがその位置に存在するときの使用が困難である。

このように、離床センサの研究については、様々なデバイスや解析手法を用いたアプローチが行われている。しかし、利用できる場面が少なかったり、内部パラメータが複雑だったりするなどの問題があり、利便性や実用性の面で課題が残る。

2.3 本論文の独自性

本論文で提案するシステムは、(1)~(3)の3つのモジュールで構成されており (Fig. 1.1)，モジュール(1)は「臨床判断のモデル化」、モジュール(2)は「離床センサの開発」に関する内容である。そのため、2.1節および2.2節では、本論文の関連研究を「臨床判断のモデル化」と「離床センサの開発」の2つに分けてそれぞれ紹介した。

関連研究について調査した結果、離床センサに関する研究は比較的多く、本論文と同じく Depth カメラによるリスク推定を行う研究テーマも散見された。そのため、提案システムはモジュール(2)だけで独自性を主張するのは難しい可能性がある。ただし、筆者の手法はより多くの環境下で利用できるよう、取得したデータの座標変換や圧縮を通じてロバスト性を担保しているといった特徴がある。また、患者の位置座標の推定も重心の計算式に基づいて行われることから、システムの挙動を把握しやすい。さらに、各種パラメータの役割も明確である。そのため、モジュール(2)は独自性が薄いものの、新規性、汎用性、および利便性は十分にあるといえる。

一方、看護師の臨床判断に関しては、有効性を調べた研究自体は複数存在するが [31–34]、FASに基づく臨床判断のモデル化を行った研究は前例が少ない。さらに、そうした先行研究においても、医療現場や看護師の実態を十分に考慮しているとはいえず、実用性の面で多くの課題が残る。一方、提案システムのモジュール(1)で

は、看護師からモデル構築に必要なデータを取得する際に、数値情報を記入させる形式ではなく、より直感的な回答が可能なアンケート手法を用いる。このとき、看護師が転倒・転落リスクを判断する際に感じる迷いも取得する。さらに、本研究では内部パラメータの解釈が容易、かつ、アンケートの際に取得した看護師の迷いを表現可能なモデル化手法を提案する。これにより、看護師に内在する判断基準を従来よりも忠実に表現できる可能性が高く、また、先行研究が抱える問題点の解消も期待できる。以上より、モジュール(1)は有用性や独自性が認められる可能性が高いといえる。

さらに、モジュール(3)ではファジィ推論により、モジュール(1)、(2)からそれぞれ得られた結果を踏まえた転倒・転落リスクを算出する。ファジィ推論を用いることで、看護師の臨床判断という明確な数値化が困難なデータに対しても分析を行うことが可能となり、結果として医療現場に従事する看護師が有する経験則を扱えるようになる。また、FASを通じて得られる患者の内実、および、Depthカメラを通じて観測される患者の外見を勘案することが可能となり、対象とする患者に即した転倒・転落リスク推定を実現できる。

以上、本研究テーマは看護師の臨床判断が持つ迷いを踏まえたアンケートおよび解析手法の提案に加え、患者の内実と外見を統合したリスク推定を実現するという点において独自性があると考えられる。このとき、内実と外見はそれぞれFASおよびDepthカメラにより取得されるが、これらをシステムの入力として同時に用いることで、各々の長所を活かしつつ、互いの短所を補完し合うことができる。さらに、モデル構築に実際の事故データを使用する必要がなく、看護師の臨床判断を用いるため、病院や診療科に合わせたシステムを実現することも比較的容易である。

筆者が提案する手法は、独自性以外にも様々な利点を兼ね備えており、社会的波及効果が十分にあるといえる。

第3章 研究の基礎知識

3.1 転倒・転落リスクの定義

転倒・転落リスクとは、転倒・転落の危険性を示す指標のことである。別名、転倒リスクとも呼ばれるが、英語ではどちらも Fall risk と表される。既存の研究では、歩行や認知機能との関連性を調べる際に用いられる (Fig. 3.1 左部)。金 [49] は歩行パラメータ (歩行速度や歩幅、両脚支持期など) と転倒および複数回転倒との関連性について調査し、複数回転倒者に歩行速度低下やケイデンス減少、歩幅短縮などといった特徴があることを明らかにしている。また、牧迫 [50] は認知機能や心理・精神的機能の影響を把握し、より効果的な転倒予防の展開を促すため、認知的フレイル (高齢化により不健康を引き起こしやすい状態) [51] と転倒リスクとの関連について検討している。

本論文では、入院患者の状態・様子と転倒・転落リスクとの関連付けを行う (Fig. 3.1 右部)。このとき、転倒・転落リスクは数値情報として扱われる。ただし、本研究では 1.2 節で述べた提案システムを実現するため、研究課題を複数に分け、各々検証を実施している。そのため、転倒・転落リスクの定義や尺度は、各章で異なる点に注意する必要がある。

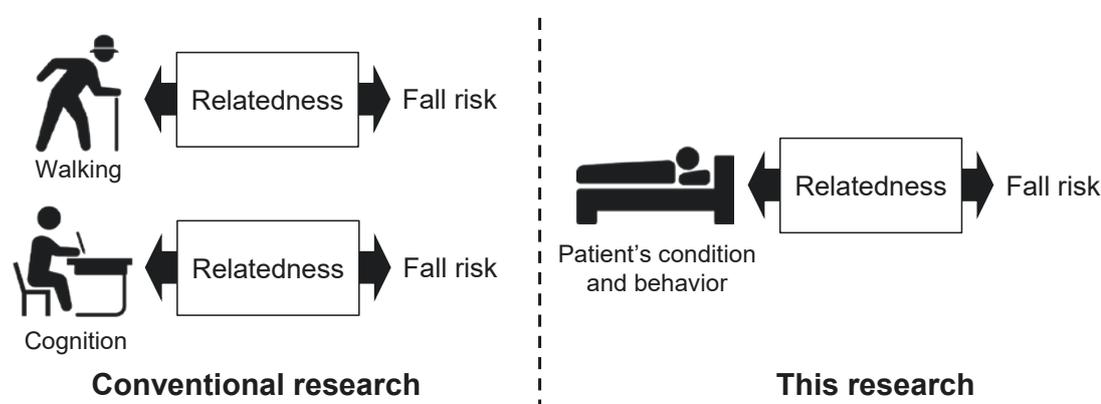


Fig. 3.1 : Examination of relatedness for the fall risk

Table 3.1 : Definition of fall risks for each section

Section No.	Fall risk	1st yardstick	2nd yardstick
4 & 5	A risk that a nurse feels from the patient condition	There is no danger and the patient need not be visited	Visit the patient as soon as possible
6	A patient risk based on a physical perspective	Patient on the bed has no danger	Patient is clearly dangerous in a physical perspective
7	A risk that is taken a patient's condition and behavior into consideration	Patient on the bed has no danger	Patient is clearly dangerous from a physical perspective so much that a nurse stops current duties and visits the patient

Table 3.1 に、本論文における転倒・転落リスクの定義を記す。本論文の第4, 5章では、FASに関する看護師の知見に基づいて転倒・転落リスクの推定モデルを構築する。そのため、これらの章では転倒・転落リスクの定義を「看護師個人が感じる患者の転倒・転落の危険性」とする。一方、転倒・転落リスクを数値化するための尺度を構成する基準点(3.3.2節参照)としては、「患者に危険がないと判断し訪問しない」および「可能な限り急いで訪問」と定めた。これらの基準点は、看護師の行動に直結する内容となっている。

つづいて、第6章ではDepthカメラを用いて人物位置を推定した後、求めた人物位置情報に基づいて物理的な観点を踏まえた転倒・転落リスクの計算を行うことから、転倒・転落リスクを「物理的観点に基づく患者の転倒・転落の危険性」と定義する。また、基準点については「患者がベッド上で全く危険がない状態」と「物理的観点において明らかに危険が伴う状態」とする。

最後に、第7章ではFASの内容、看護師の知見、およびDepthカメラの情報を全て使用し、患者の内実と外見を勘案したリスク推定を行うため、転倒・転落リスクの定義を「患者の内実と外見を考慮したときの転倒・転落の危険性」と定める。数値情報として表すための基準点については、「患者がベッド上で全く危険がない状態」および「看護師が現在の業務を中断しすぐに病室に向かうほど、物理的観点において明らかに転落・転落の危険が伴う状態」とした。

なお、転倒・転落リスクの値は必ずしも2つの基準点の内側に収まる訳ではなく、場合によっては基準点の範囲外となることも十分起こり得る。これは、転倒・転落リスクの推定に人間の判断を使用することや、基準点の定め方に起因している。詳細については、3.3.2節で述べることとする。

3.2 ファジィ理論の基礎知識

3.2.1 ファジィ理論の起源

ファジィ理論とは、人間の主観的な思考やあいまいさを定量的に扱うための数学的な理論のことである。本理論は、「ファジィ集合」と呼ばれる集合についての新しい考えが、1965年にLotfi Asker Zadehによって提唱されたことで生まれた[52]。ファジィ集合の登場後、論理や推論、測度へと発展したものがファジィ理論である[53]。

Zadehが提案した考え方は、0か1か(つまり、「偽」であるか「真」であるか)の二値的な情報だけでなく、「背が高い」、「色が白い」、「暑い」などのあいまいな情報

も扱えるといった特徴を持つ。しかし、発表当初は「そのようなあいまいさは確率論でも処理できる」や「あいまいさを排除すべき科学の世界にあいまいさを持ち込むべきではない」などの批判的意見が相次いだ。こういった批判があるにも関わらず、ファジィ理論に関する論文を発表し続けた Zadeh や、一部の研究者らの努力によって、ファジィ理論への理解が徐々に進んでいった [54]。ファジィ理論は、制御工学の分野において特に注目され、エアコンファジィ制御のような家庭用製品も登場した [55]。ファジィ理論には、人間独自のあいまいさを扱えるといった特徴があり、こうした特徴が「人間の感覚に近い温度管理」などを実現するうえで大きな貢献を果たしたといえる。

本論文では、提案システムを実現するうえで、看護師の臨床判断を扱う場面が生じる。こうした看護師の臨床判断は、看護師自身の感覚的な部分に依存しており、通常の数学や統計学だけでは説明（立式）が困難な事象である可能性が高いと考えられる。そのため、本研究ではファジィ理論を導入することとした。ファジィ理論を用いることで、看護師が臨床判断を行う際に生じるあいまいさを扱うことが可能となり、看護師の意思決定をより正確に反映したモデルの実現が期待できる。

3.2.2 あいまいさの種類

ファジィ理論はあいまいさを扱う学問であるが、一口にあいまいさと言っても様々な種類が存在する。鬼沢は、代表的なあいまいさを5種類述べた [54]。

1. 知識不足からくるあいまいさ (Incompleteness)

知らないことに起因するあいまいさ。必要な知識が得られれば解消。

2. 多義性からくるあいまいさ (Ambiguity)

ある対象が複数の意味で用いられ得ることで生じるあいまいさ。例えば、日本語で「はし」と言っても、「橋」なのか、「箸」なのか、それとも「端」のことを言っているのかは不明確で、何通りもの解釈が可能。

3. 確率論が対象とするあいまいさ (Randomness)

ランダムに生起する事象を対象にし、その事象が生起するかどうかに関するあいまいさ。

4. 不確かさからくるあいまいさ (Impreciseness)

情報に誤りが含まれていたり、雑音がのっていたりなど正確な情報がないこと

からくるあいまいさ。

5. 人間が日常使う言葉に含まれるあいまいさ (Fuzziness)

人間が日常使う言葉に含まれるあいまいさ、主観的なあいまいさ。例えば、「背の高い」人を1万人提示されたとしても「背の高さ」に伴うあいまいさを解消することは不可能。ファジィ理論が扱うあいまいさ。

本研究では、臨床判断を回答するアンケートを看護師へ実施するが、そのアンケートの回答には Fuzziness だけでなく、Randomness と Impreciseness が存在すると予想される。まず、Fuzziness に関しては 3.2.1 節で述べた通り、看護師が感じるリスクには人間独自のあいまいな部分が含まれると考えられる。本論文において、メインで扱うあいまいさである。

つぎに Randomness だが、今回看護師に実施するアンケートはファジィ評定法(3.4.3 節参照)を採用している。本アンケートでは、転倒・転落リスクの大きさを数値情報として回答させるのではなく、看護師はアンケート用紙内に記された2つの指標を基準として、線分上の任意の位置に回答を行う。このとき、看護師はコンピュータと異なり、常に全く同じ位置に回答を記入できる訳ではなく、同一のアンケートを実施したとしても、回答を行う位置が多少なりとも毎回異なるはずである。この位置ずれは、Fuzziness とは違いランダムに生起するため、本研究では Randomness によるあいまいさも扱う必要があるといえる。

最後に Impreciseness に関して、人間は常に正しい判断ができるとは限らず、外的または内的要因によって誤った判断を下すことがある。例として、看護師はアンケート用紙に回答を行う際に患者の FAS を確認する必要があるが、このとき FAS の内容を見間違える可能性がある。具体的には、「患者が認知症を患っていること」が FAS に記載されているにも関わらず、看護師がその部分を見落とした場合がこれにあたる。このような見間違いをしたとき、看護師は認知症がない前提で転倒・転落リスクを推定する。そのため、得られたアンケート回答を用いてモデル化を行う際に、辻褄が合わなかったり誤ったモデルが形成されたりする可能性が高い。こうした問題に対処できるよう、本論文では看護師の臨床判断に Impreciseness が存在すると仮定しており、看護師に生じた誤判断を外れ値として捉え、モデル化の際に排除することが可能な手法を採用している(4.3.3 節参照)。

3.2.3 生体情報とファジィ

ファジィ理論は生体情報にも応用されることがあるが、生体情報にファジィ処理を行う際の注意点として「たくさんの情報（量）を集めるだけでなく、質の高い情報を集める」が挙げられる [56]。これは、生体情報を多く収集するほど、質の低い情報を含む可能性が高くなるためである。また、次元数が増加するため、情報同士の組み合わせが複雑化するという問題が生じる。

本研究では、Depth カメラによって患者の外見、つまりは生体情報を取得している。さらに、取得した生体情報をファジィ推論によって処理している。よって、今回の研究はファジィ理論を生体情報に応用しているといえるため、田崎ら [56] の考えに則った解析を行うべきである。

以上の観点を踏まえ、本研究では患者の外見を Depth カメラから推定する際に、複数のフレームのデータを用いるのではなく、1 フレーム分のデータのみを使用する。使用するデータを限定することで、情報が複雑化する事態を回避できるため、比較的簡便なアルゴリズムでの推定が可能となる。さらに、質の低い（ノイズの多い）データや欠損データが生じたときに、前後のフレームを代替データとして使用したり、それらを用いて平滑化を行えたりするため、データの質も担保しやすい。

ファジィ理論において、解析に用いるデータ量を削減することは、提案システムを実用化するうえで、機能の実装や管理が容易になるほか、システムの信頼性向上へと繋がると考えられる。

3.3 ファジィ理論の数学的基礎

3.3.1 ファジィ集合とメンバーシップ関数

通常の場合は、ある部分集合 A の元 x が「属する」か「属さない」かの二値で表現される。このとき、 x が集合に属するときを1、属さないときを0とし、数式化したものを部分集合 A の特性関数 (Characteristic function) と呼ぶ。特性関数の返り値は1または0となる。

しかしながら、人間の判断は特性関数のように境界がはっきりとした数式で表現できる訳ではなく、判断に多かれ少なかれあいまいさが伴う。そのため、ファジィ集合では、メンバーシップ関数 (Membership function) と呼ばれる数式を導入することで、こうした判断のあいまいさを表現する。メンバーシップ関数では返り値を

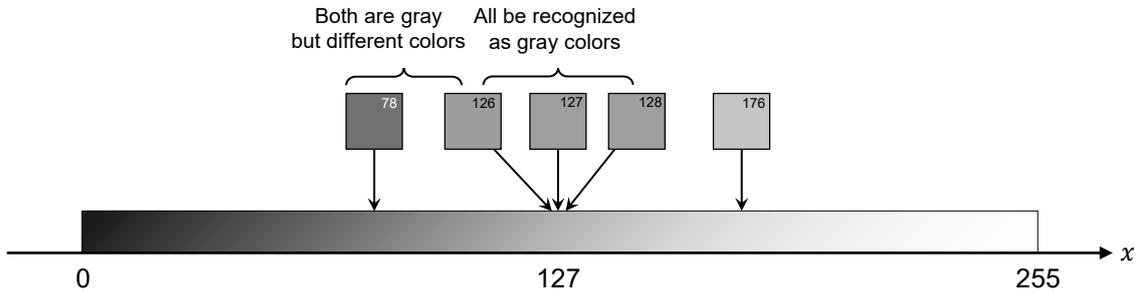


Fig. 3.2 : Grayscale and various kinds of gray

0~1の連続値とすることで、集合に属する度合いを数値化している。メンバーシップ関数の返り値が1に近いほど、元 x が集合に属する度合いが大きく、0に近いほど x が集合に属する度合いが小さいことを表す [57]。なお、この0~1の度合いは、「帰属度」や「Grade」、または単に「メンバーシップの値」など様々な呼称が存在するが、本論文では特別な理由がない限り、日本語では「帰属度」、英語では「Grade」と表記する。

上記のファジィ集合について理解を深めるため、「灰色である」という人間の感覚を例にさらなる説明を行う。色情報を数値として表現するための方法の一つとして「グレースケール」が挙げられる。Fig. 3.2に示すように、グレースケールでは数値0を「黒色」、255を「白色」として色の濃淡を表現する。一方、「灰色」とは、一般的に黒と白の中間色として認識される。そのため、0と255のおおよそ中間位置にあたる数値127は灰色に属するという考えには、大多数が納得できるものと思われる。しかし、「灰色である」という概念は、数値127のときのみ真になる訳ではなく、多くの人間は周辺の数値（例えば、数値127に隣接する数値126や128）もまた「灰色である」という感覚を有する。そのため、本感覚を数学的に扱う場合は $A = 127$ のような一般的な等式ではなく、部分集合を用いる方が適切である。例として、「灰色である」ことを表す部分集合 A は、

$$A = (78, 79, 80, \dots, 126, 127, 128, \dots, 174, 175, 176) \tag{3.1}$$

のように表現できる (Fig. 3.3(a))。

しかし、上記の数式は人間の感覚を十分に反映できていない。Eq. (3.1)では部分集合 A を78~176の範囲としたが、特別な事情がない限り、我々は部分集合の左端78の色と中心127の色に対し、全く同じ「灰色らしさ」を感じる訳ではない。恐らくは、数値127の方が灰色らしさを強く感じ、数値78においては「灰色ではあるものの、黒っぽさも含んでいる」といった感覚が生じるはずである。Eq. (3.1)

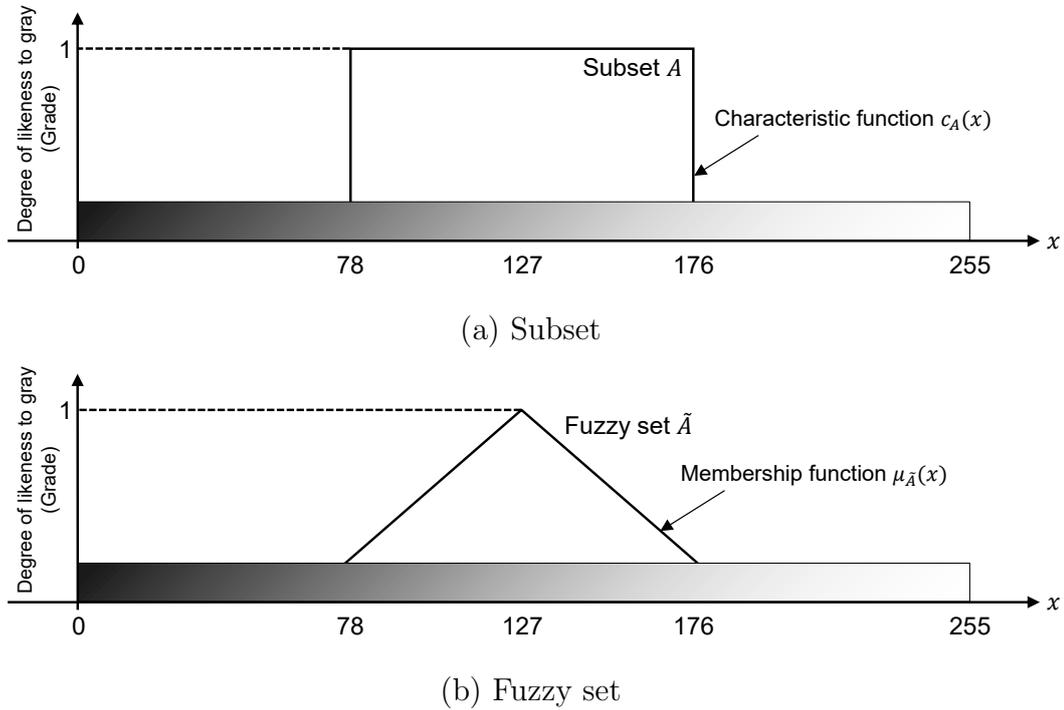


Fig. 3.3 : Classic subset and fuzzy set in the grayscale

の部分集合では、数値78と127をどちらも同じ灰色として扱うが、実際は両者に対して異なる感覚を抱いていると考えられる。

ファジィ集合は、こうした人間独自の感覚を表現する際に有用となる。ファジィ集合では、部分集合 A に属する元 x に帰属度 (Grade) を付与する。帰属度によって、各々の元がどの程度その集合に属するか (つまり、数値78の「灰色らしさ」と127の「灰色らしさ」の違い) を表現でき、より人間らしい感覚を扱うことが可能となる。Eq. (3.1) の部分集合 A をファジィ集合 \tilde{A} として改めると、

$$\begin{aligned} \tilde{A} = & (78/0.02, 79/0.04, 80/0.06, \dots, 126/0.98, 127/1.00, \\ & 128/0.98, \dots, 174/0.06, 175/0.04, 176/0.02) \end{aligned} \quad (3.2)$$

となる。ただし、帰属度0の元を省略せず、

$$\begin{aligned} \tilde{A} = & (0/0.00, 1/0.00, \dots, 77/0.00, 78/0.02, 79/0.04, 80/0.06, \dots, 126/0.98, 127/1.00, \\ & 128/0.98, \dots, 174/0.06, 175/0.04, 176/0.02, 177/0.00, \dots, 254/0.00, 255/0.00) \end{aligned} \quad (3.3)$$

などを書くこともある (Fig. 3.3(b)) .

上記のファジィ集合 \tilde{A} は、メンバーシップ関数によって表現される。通常の特
性関数は引数 x の返り値として、0（属さない）か1（属する）のいずれかを返すが、
メンバーシップ関数では0~1の範囲内の値を返す。そのため、Eq. (3.1), (3.2) を特
性関数またはメンバーシップ関数を用いて表すと、両者はそれぞれ

$$c_A(x) = \begin{cases} 1 & ; 78 \leq x \leq 176 \\ 0 & ; \text{otherwise} \end{cases} \quad (3.4)$$

$$\mu_{\tilde{A}}(x) = \begin{cases} 1 - \frac{127-x}{50} & ; 77 \leq x \leq 127 \\ 1 - \frac{x-127}{50} & ; 127 \leq x \leq 177 \\ 0 & ; \text{otherwise} \end{cases} \quad (3.5)$$

となる。ここで、全体集合を U と置くと、部分集合 A と特性関数 $c_A(x)$ 、または、
ファジィ集合 \tilde{A} とメンバーシップ関数 $\mu_{\tilde{A}}(x)$ の関係は、それぞれ Eq. (3.6), (3.7) と
表される。

$$A = \{x \in U \mid c_A(x) = 1\} \quad (3.6)$$

$$\tilde{A} = \{(x, \mu_{\tilde{A}}(x)) \mid x \in U\} \quad (3.7)$$

3.3.2 ファジィ集合の上下限

3.3.1 節では、グレースケールの一般的な定義に基づき、元 x の取り得る範囲を0
~255とした (Fig. 3.3)。しかし、現実世界では0~255の範囲外の色も存在し得る
と考えられる。3.3.1 節で述べたグレースケールは、色情報を数値化するための基準
値として、一般的な液晶ディスプレイが表現できる色の濃淡の最小値と最大値を用
いているだけに過ぎない。

ここで、色の濃淡を液晶ディスプレイのグレースケールではなく、素材の光反射
率で測定したとき、ベンタブラック (Vantablack) は吸収率 99.965%、2019 年にマ
サチューセッツ工科大学 (MIT: Massachusetts Institute of Technology) が発見し
た黒い素材は吸収率 99.995% と表される [58]。そして、MIT が発見した素材はベン
タブラックの 10 倍以上黒いとされる。これは、現実世界にグレースケールの数値 0
よりもさらに黒い色が存在すること、つまりは数値 0 未満に相当する色があること
を示唆している。

一般的に、ある概念を数値として表現する際は、尺度を構成するための基準点を2点定める必要がある。しかし、これは現実世界で起こる事象がその基準点の内側に全て収まることを意味するものではなく、観測された事象が基準点の範囲外に属することも十分に起こり得る。今回はグレースケールを用いて説明を行ったが、セルシウス度 (Degree Celsius) がその最たる例として挙げられ、尺度を構成する2つの基準点 (融点を 0°C 、沸点を 100°C とする) の範囲外 (例: -20°C) にも値を取ることが可能である。さらに、「欲に頂なし」ということわざがある通り、これが人間の感覚となれば、観測された事象に上下限がないのは尚更であり、尺度を構成するための基準点として、その事象の上下限と等価になる指標を採用できないのは至極当然だといえる。

本研究では、看護師にアンケートを実施する際に、尺度を構成するための基準点を2点定めている。これらの基準点は、看護師のアンケート回答を数値化し、モデル式を作成するために用いられるが、このとき作成されたモデル式によって推定された転倒・転落リスクの値は、基準点の範囲外となる位置に生じることがある。しかし、上述した内容を踏まえると、こうした結果が発生しても何ら不思議ではないといえる。

3.3.3 ファジィ数

我々は日常生活の中で「だいたい10個」や「約30分」などといったあいまいな数値表現を使うことがある。このようなあいまいな数はファジィ集合で表すことができ、ファジィ数と呼ばれている。ファジィ数とは、数値上のファジィ集合であり [59]、平たく言うとファジィ集合を「あいまいな数値」とみなす考え方である。

3.3.1 節では「灰色である」という概念を例に、ファジィ集合について説明した。このとき、Eq. (3.2) に示すファジィ集合は、127 を中心として78~176 の範囲を有しており、127 以外の元は帰属度が1未満となる。このような元は集合に完全に属している訳ではなく、あいまいさを含んでいるといえる。よって、Eq. (3.2) のファジィ集合はあいまいな数値としてみなすことができ、「だいたい127」のように言い換えることが可能である。

ファジィ数には様々な種類があるが、その中でもL-Rファジィ数 (L-R fuzzy number) は最も主流なファジィ数といえる。L-Rファジィ数とは、帰属度が1となる数値を基準として、基準となる値から離れるほど帰属度が低下するという特徴を有するファジィ数である。L-Rファジィ数は、基準となる値 m 、基準となる値の左側 (負

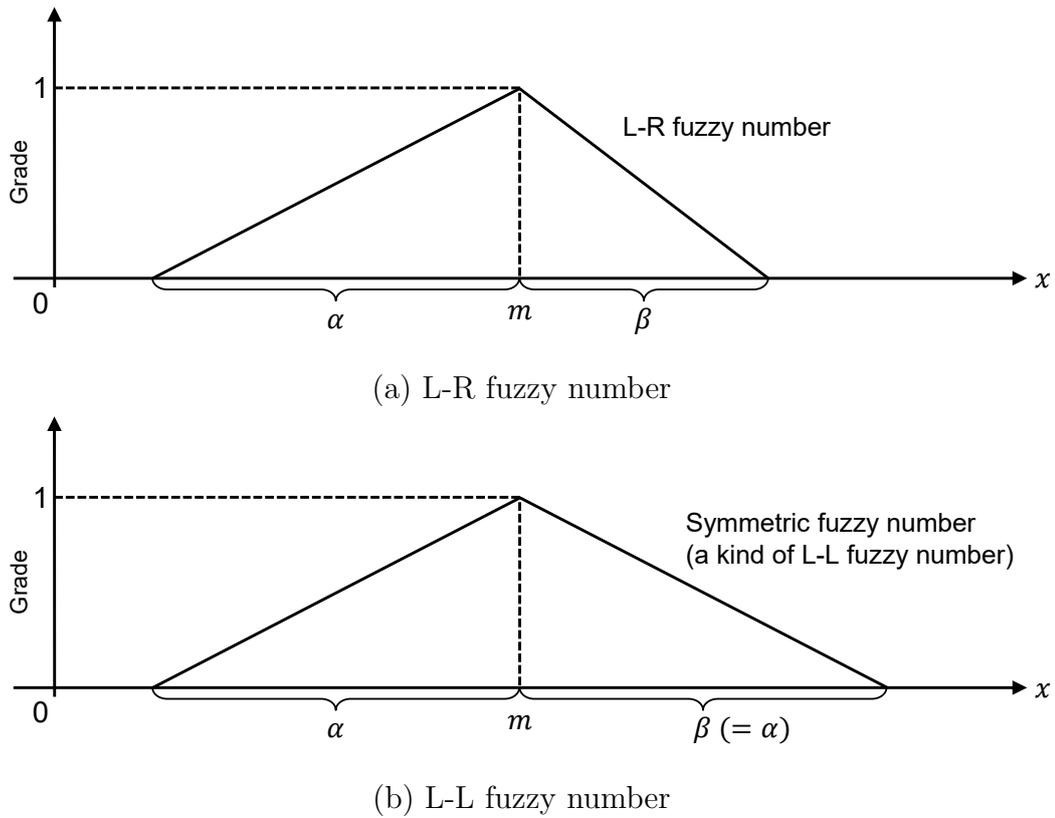


Fig. 3.4 : Definition of fuzzy numbers

の方向)において帰属度が0になる値までの距離 α 、基準となる値の右側(正の方向)において帰属度が0になる値までの距離 β の3要素で構成される (Fig. 3.4(a)).

一方、L-R ファジィ数において帰属度が0になるまでの距離が左右等しい ($\alpha = \beta$ を満たす) 場合、そのファジィ数はL-L ファジィ数 (L-L fuzzy number) [60] と呼ばれる (Fig. 3.4(b)). さらに、メンバーシップ関数の形状が左右対称となるファジィ数を左右対称型ファジィ数 (Symmetric fuzzy number) [61] と呼ぶ。左右対称型ファジィ数はL-L ファジィ数の一種であり、こちらも代表的なファジィ数として広く利用されている。

3.3.1節のファジィ集合 \tilde{A} は、左右対称型のL-L ファジィ数であり、Eq. (3.8) のように表される。

$$\tilde{A} = (127, 50)_L \tag{3.8}$$

このとき、メンバーシップ関数は Eq. (3.9) となる。

$$\mu_{\tilde{A}}(x) = \max\left(0, 1 - \frac{|x - 127|}{50}\right) \tag{3.9}$$

なお, Eq. (3.9) は三角型メンバーシップ関数 (Triangular membership function) と呼ばれる.

本論文では左右対称型の L-L ファジィ数を用いる. このとき, 三角型メンバーシップ関数によって帰属度の変化を表す.

3.3.4 ファジィ線形回帰式

「要因となる数値」と「結果となる数値」を調べ, 要因と結果の関係性を明らかにする解析手法を回帰分析と呼ぶ. ここで, 多くの場合, 要因となる数値は $\mathbf{x}_i = (x_{i,0} \ x_{i,1} \ x_{i,2} \ \cdots \ x_{i,n})^T$, 結果となる数値は y_i と表され (i はデータの識別番号, n はデータの次元数, T は行列の転置記号), \mathbf{x}_i は入力 (または説明変数), y_i は出力 (または目的変数) と呼ばれる.

回帰分析では, 係数 $\mathbf{a} = (a_0 \ a_1 \ a_2 \ \cdots \ a_n)^T$ によって入力と出力の関係を Eq. (3.10) と表す.

$$y_i = \mathbf{a}^T \mathbf{x}_i \quad (3.10)$$

回帰分析を用いることで, 入出力関係を表すモデル式を作成できる.

一方, 入力や出力がファジィ数となるときは, モデル式の作成にファジィ線形回帰分析 (FLR: Fuzzy Linear Regression) [62] が用いられる. FLR とはファジィ数を対象とした回帰分析のことであり, 本手法を適用する際はモデル自体にあいまいさが存在すると仮定される. そのため FLR では, 係数 \mathbf{a} はファジィ数 $\mathbf{A} = (A_0 \ A_1 \ A_2 \ \cdots \ A_n)^T$ へと変更され, 入出力を結ぶ回帰式は

$$Y_i = \mathbf{A}^T \mathbf{x}_i \quad (3.11)$$

と表される. ここで, Eq. (3.11) はファジィ線形回帰式と呼ばれる. Eq. (3.11) は出力 y_i をファジィ数 $Y_i = (y_i, e_i)_L$ としたときのファジィ線形回帰式であり, 式中の \mathbf{A} はファジィ係数と呼ばれる. \mathbf{A} の各要素 A_j ($j = 0, 1, 2, \dots, n$) はファジィ数 $A_j = (a_j, c_j)_L$ となり, a_j は係数の大きさ, c_j は係数のあいまいさを表す.

本研究では, FLR によって患者の FAS と転倒・転落リスクとの関係性をモデル化する.

3.3.5 ファジィ推論

我々の日常生活での推論には、通常人間としての判断のあいまいさが伴う。このようなあいまいさの存在する推論は、ファジィ推論（近似的推論）と呼ばれている [63].

一般的に、二値論理における推論の方法は「 A ならば B 」という含意を用いて行われ、特に modus ponens は広く知られる推論形式である。modus ponens は「 A ならば B が真」であるとき、「 A が真」ならば「 B は真」であることを推論するもので、

$$\frac{A \rightarrow B \quad A}{B}$$

と表すことができる。ここで、 A および B は明確に定められた命題である。

一方で、 A 、 B にファジィ概念を取り入れた命題では、modus ponens は

$$\frac{\begin{array}{l} \text{前提 1 } \text{If } x \text{ is } A \text{ then } y \text{ is } B \\ \text{前提 2 } x \text{ is } A' \end{array}}{\text{結論 } y \text{ is } B'}$$

と一般化される。ここで、 x 、 y は対象名、 A 、 A' 、 B 、 B' はファジィ集合であり、必ずしも $A = A'$ 、 $B = B'$ を満たす必要はない。上記の式は多重ファジィ推論形式¹へと拡張することが可能であり、

$$\frac{\begin{array}{l} \text{前提 1} \quad \text{If } x \text{ is } A_1 \text{ and } y \text{ is } B_1 \text{ then } z \text{ is } C_1 \text{ else} \\ \text{前提 2} \quad \text{If } x \text{ is } A_2 \text{ and } y \text{ is } B_2 \text{ then } z \text{ is } C_2 \text{ else} \\ \vdots \\ \text{前提 } n \quad \text{If } x \text{ is } A_n \text{ and } y \text{ is } B_n \text{ then } z \text{ is } C_n \\ \text{前提 } n+1 \quad x \text{ is } A' \text{ and } y \text{ is } B' \end{array}}{\text{結論 } z \text{ is } C'}$$

などと表すことができる。なお、前提1～前提 n において、thenより左側の部分（例： A_1 、 B_1 、 A_2 、 B_2 ）は前件部（Antecedent）、thenより右側の部分（例： C_1 、 C_2 ）は

¹別名、IF-THEN ルールと呼ばれる。

後件部 (Consequent) と呼ばれており、各々ファジィ集合を表すためのメンバーシップ関数が定義される。

本論文では、多重ファジィ推論形式に基づいて「患者の姿勢」から「転倒・転落リスク」を推論しており、

前提 1	If posture is	lying down	then fall risk is	very low	else
前提 2	If posture is	long sitting	then fall risk is	low	else
前提 3	If posture is	sitting sideways	then fall risk is	high	else
前提 4	If posture is	standing	then fall risk is	very high	
前提 5	posture is similar to sitting sideways				
結論	fall risk is approximately high				

といった条件文が定義される。ここで、前提5および結論は、患者の現在の姿勢に応じて内容が都度変化し、前提5にあいまいさ (例: similar to) が含まれると、それに伴って結論にもあいまいさ (例: approximately) が生じる。

なお、7.2 節に記す提案手法では、「患者の位置座標」に基づいて現在の姿勢を推定することから、上記の条件文は実際には、

前提 1	If x-coord is M_{p1}^X and y-coord is M_{p1}^Y and z-coord is M_{p1}^Z then fall risk is M_{p1}^R else				
前提 2	If x-coord is M_{p2}^X and y-coord is M_{p2}^Y and z-coord is M_{p2}^Z then fall risk is M_{p2}^R else				
前提 3	If x-coord is M_{p3}^X and y-coord is M_{p3}^Y and z-coord is M_{p3}^Z then fall risk is M_{p3}^R else				
前提 4	If x-coord is M_{p4}^X and y-coord is M_{p4}^Y and z-coord is M_{p4}^Z then fall risk is M_{p4}^R				
前提 5	x-coord is M^X and y-coord is M^Y and z-coord is M^Z				
結論	fall risk is M^R				

といった推論形式で利用される (coordinate を coord と略記)。ここで、前提1~前提4は各々の姿勢に対応しており、前提1が臥位 (Lying down)、前提2が長座位 (Long sitting)、前提3が端座位 (Sitting sideways)、前提4が立位 (Standing) に相当する。さらに、任意の姿勢を p としたとき、前件部は「ベッド上 (またはベッド周辺) において姿勢 p が存在する範囲」、後件部は「姿勢 p のときの転倒・転落リスク」となる。例として、前提1 (臥位) については、ファジィ集合 M_{p1}^X , M_{p1}^Y , M_{p1}^Z によって臥位の姿勢が存在する範囲を定めている。一方、 M_{p1}^R は、臥位の姿勢のときの転倒・転落リスクを表すファジィ集合である。

通常、「姿勢の分類基準」や「姿勢が存在する範囲」は境界が不明瞭なあいまいなものであり、これらの基準および範囲を厳格に定めることは困難である。また、転倒・転落リスクに関しても、看護師が常に迷いのない判断を行うのは難しいと考えられる。そのため、姿勢の範囲や転倒・転落リスクを表す際にファジィ集合を導入し、ファジィ推論によって患者の転倒・転落リスクを算出することは、現実に即した方法だといえる。

3.4 主観評価の測定

3.4.1 評価尺度法

本研究では、看護師に対して転倒・転落リスクに関するアンケート調査を行う。看護師が行う転倒・転落リスクの判断には、看護師自身の知識や経験を含む心理的な側面が影響していると考えられる。通常、こうした判断は心理量の測定法である評価尺度法 (Rating scale method) [64] によって観測される。

評価尺度法には Simple Descriptive Scale (SDS), Numerical Rating Scale (NRS), Visual Analogue Scale (VAS) などが存在する (Fig. 3.5)。SDS とは、言葉による記述に基づき作成した 4~5 点 (例：無 (Nil), 軽い (Mild), 並の (Moderate),

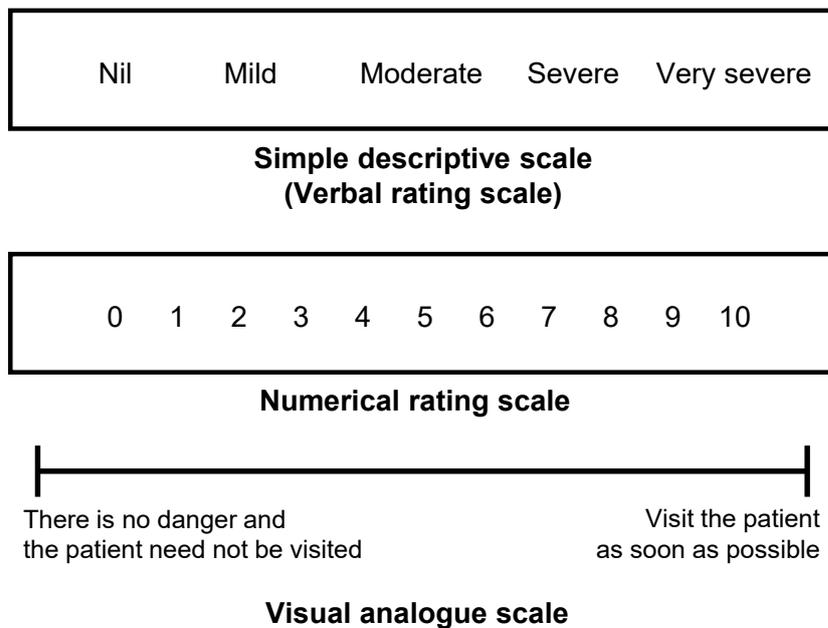


Fig. 3.5 : Examples of the rating scale method

酷い (Severe)、とても酷い (Very severe)) を選択肢とするアンケート手法である。別名, Verbal Rating Scale (VRS) とも呼ばれる。NRS とは, 選択肢を 0~10 の 11 段階に分け, いずれかの数字を回答させるアンケート手法である。VAS とは, 一定の長さの線分上の両端に記された内容を基準として, 回答者が感じる主観的な程度を記入するアンケート手法である。

VRS, NRS, VAS は信頼性, 妥当性ともに検証され, 臨床の場で用いられている [65]。

3.4.2 Visual analogue scale の利点

Downie らは, SDS は回答の選択肢があまりにも少なく, VAS はあまりにも多いため, 測定誤差を考慮すると評価手法としては NRS が最も推奨されると主張した [66]。一方で, 人間の判断, 注意ならびに記憶という能力に関し, 一度に正しく実行できる範囲はいずれの能力も 7 ± 2 であることが明らかになっており, この範囲のことをマジックナンバーと呼ぶ。マジックナンバーを超えると, 人間は判断に混乱が生じたり物体を正確に把握したりできなくなる。また, 正しい記憶ができなくなる [67,68]。以上より, マジックナンバーの観点から見ると, 回答の選択肢が 11 段階ある NRS はアンケート形式として相応しくないといえる。

しかしながら, 選択肢の少なさにより回答の制約が増すのは望ましくないため, 看護師へのアンケート形式としては回答欄に目盛りがない VAS を使用する。VAS は, アンケート回答者が選択肢の個数を気にすることなく回答できるため, マジックナンバーの影響を受けにくいと考えられる。なお, VAS は 1921 年に Hayes と Patterson によって発表され, Aitken と Zealley の研究以降, 精神物理学の分野で気分や感覚を量的に評価するために広く用いられるようになった [69]。VAS は特別な材料を必要とせず, 簡単にカルテに書けるため手軽に臨床で利用できるといった特徴がある。また, 主観的評価の中でも感度が良く, 簡便で再現性があり, 世界共通のものであるといわれている [70]。そのため, 現在では精神物理学に限らず, 様々な分野で VAS が利用されている [71]。

本研究でも, 看護師に対して VAS をベースとしたアンケートを実施する。

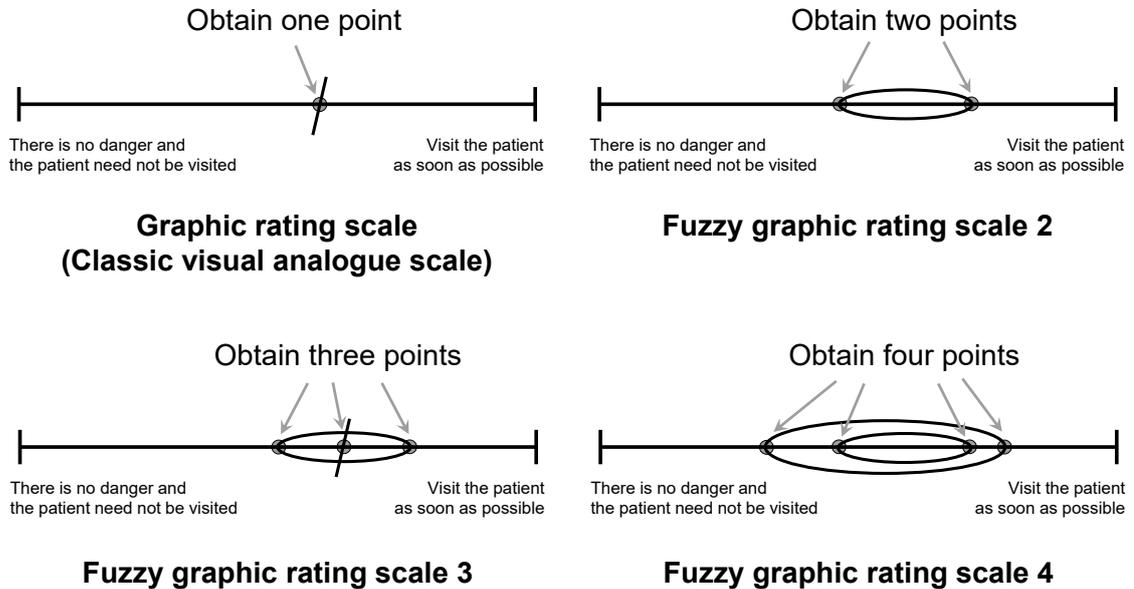


Fig. 3.6 : Fuzzy graphic rating scales

3.4.3 ファジィ評定法

通常の評定尺度法は、回答の際に迷いが生じ、回答する箇所を一意に決められない場合でも、必ず一ヶ所に回答しなければならない。そのため、回答者の判断を正確に取得できず、結果としてデータの質が低下するといった問題が生じ得る。こうした問題は、ファジィ評定法を導入することで解決できる可能性が高い。ファジィ評定法とは、ファジィ理論によって改良されたアンケート手法である [72]。ファジィ評定法を用いることで、評価における回答者のあいまいさや迷いを取得することが可能となる。

ファジィ評定法では、迷いの範囲を記入させる方法にいくつか種類があり、各々取得するデータ点の個数が異なる。その中でも、比較的現実的な手法としては、Fig. 3.6 に示す通り、線分上の2点を回答する方法、3点を回答する方法、4点を回答する方法の3つが挙げられる [73-76]。なお、通常のVASは線分上の1点を回答する方法とみなされ（つまり回答に迷いの範囲がない）、別名グラフ尺度法（GRS: Graphic Rating Scale）と呼ばれる。

これらの方法にはそれぞれ一長一短があるが、今回はアンケート回答者への負担を軽くすることに重きを置いたため、本論文では線分上の2点を回答する手法であるファジィグラフ尺度法2（FGRS2: Fuzzy Graphic Rating Scale 2） [73] を採用している。さらに、回答者が迷いを全く感じない場合も想定し、通常のVAS（線分上

の1点を回答)も併用している。

3.5 数量化理論

数量化理論とは、質的変数(カテゴリデータ)の分析のための4種、あるいは6種の記述的多変量データ解析の方法群である[77]。本理論は、主に林知己夫によって開発された。統計学において、観測されたデータは一般的に量的変数(数量データ)または質的変数(カテゴリデータ)のいずれかに分別することが可能である。量的変数とは、データ間の大小関係を比較したり、演算を行ったときに意味のある数値となるデータのことである。一方、質的変数とは、データ間の大小関係や演算をしても無意味なデータのことである。ここでの数値は単なる分類の意味しか持たない。

数量化理論にはI~VI類の手法が存在するが、数量化I類では説明変数が質的変数、目的変数が量的変数となるデータの回帰分析を行う。このとき、回帰分析の際に生じる問題に対処するため、クラメール連関係数や相関比が使用される[78]。本研究では、質的変数と量的変数の両方を扱っており、FASのチェックマークの有無を表す値は質的変数、転倒・転落リスクを表す値は量的変数に属する。そのため、看護師から取得したデータを分析する際は、ファジィ理論だけでなく数量化理論の手法も用いている。

3.6 三次元ビジョン

3.6.1 Depthカメラ

Depthカメラとは、実空間上の距離情報を取得するためのセンサである。本論文では、Depthカメラの一つであるMicrosoft社のKinect[79]を検証の際に用いる。Kinectとは、二次元平面上に三次元距離情報をマッピングできるセンサである[80]。Depthカメラによってマッピングされた画像はDepthマップ(Depth map)と呼ばれ、Kinectの場合は 512×424 ピクセルの解像度を有する(Fig. 3.7)。多くの場合、Depthマップはグレースケールの画像であり、計測対象がDepthカメラの原点に近づくほど画素の色が白くなる(ピクセルの値が増加)。逆に、計測対象が遠ざかるほど画素の色が黒くなる(ピクセルの値が減少)。

計測対象までの距離を測る方法として、KinectではTime of Flight(ToF)方式が採用されている。ToFとは、光の伝搬速度が秒当たり30万kmであることを利用し

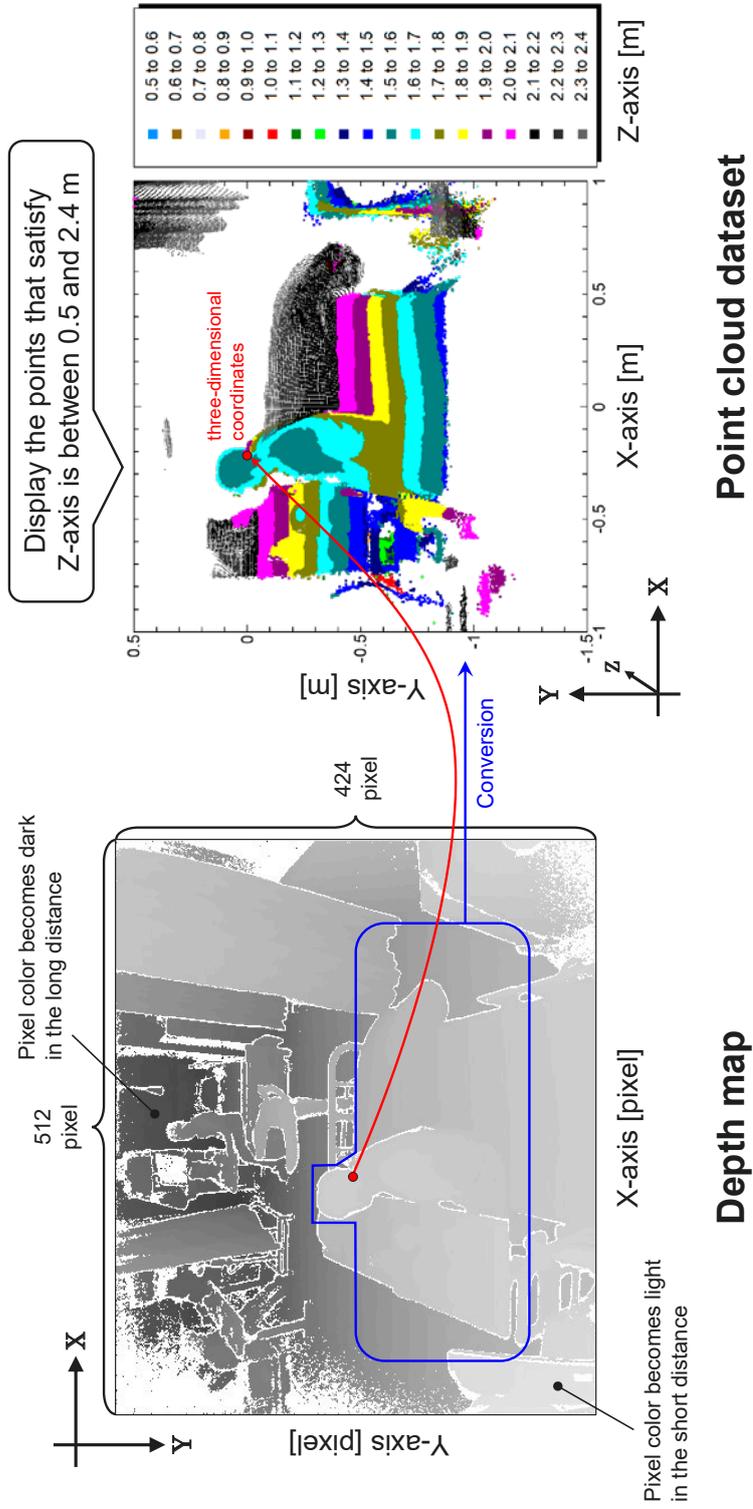


Fig. 3.7 : Examples of the depth map and point cloud dataset

て、赤外線光のパルスをカメラ側から照射し、その光パルスが対象物に反射して戻ってくるまでの飛行時間を計測する方法である。ただし、対象物までの距離を光パルスの飛行時間によって、1mm精度で取得しようとする、現在の民生用電子機器のデバイス技術では到底及ばない仕様となる。そのため、本研究で使用する Kinect では、光パルスの飛行時間を位相遅れとして測定するために、反射して戻ってきた光によって発生する光電流を電荷としてチャージして、その電荷量を測定する方法が用いられている [80]。

上述した通り、Kinect では赤外線光が利用されており、距離情報の取得にセンサ外部の光を必要としない。つまり、夜間や暗闇のような光のない場所でも使用することができる。そして、本研究で提案する転倒・転落リスク推定システムは、主に患者のベッド付近での使用を想定している。そのため、患者が就寝した後の暗闇の環境下での使用も当然起こり得ることから、こうした環境下でも距離情報を計測できる本センサは、筆者のシステムと相性が良いといえる。さらに、カラーカメラと異なり、Depth マップには患者の顔が鮮明に映らないため、プライバシーの面でも優れているといった利点がある。本論文では、Depth カメラから患者の位置情報や姿勢、ならびに転倒・転落リスクを推定する方法を提案する。

なお、提案手法は Kinect 独自の機能（例：Body トラッキング）を使用しないため、距離情報の計測に赤外線光が採用されているならば（つまり、暗闇の環境下でもデータ計測が可能ならば）、Kinect 以外の Depth カメラでも提案システムを実現することは十分可能である。

3.6.2 Point cloud

3.6.1 節では、Depth カメラおよび Depth マップについて述べた。このとき、Depth マップはグレースケールの画像であり、対象物までの距離に応じてピクセルの値が変化すると説明した。しかし、Depth マップはピクセルの値ではなく、元々はそのピクセルに映る対象物までの距離（単位は [m] または [mm]）が保管される。つまり、各ピクセルは、X 軸ピクセル [pixel]、Y 軸ピクセル [pixel]、対象物までの距離 [m] の3要素で構成される。このような形式のデータの集合は、Depth データと呼ばれる [80]。

Depth データは、三次元座標に変換することが可能である。三次元座標は、X 軸座標 [m]、Y 軸座標 [m]、Z 軸座標 [m] から成るデータである。このとき、座標原点は Depth カメラ本体であり、Depth データの「対象物までの距離」と三次元座標の「Z

軸座標」は同値となる。この三次元座標の集合を、一般的に点群データ (PCD: Point Cloud Dataset) と呼ぶ (Fig. 3.7)。Kinect の解像度は 512×424 であり, Depth マップの中に約 21.7 万個のピクセルが存在するため, Kinect の PCD は約 21.7 万個の三次元座標データで構成されているといえる²。

本研究では, 上記で述べた形式の PCD を処理することで, 患者の様子を推定する。

3.6.3 クォータニオン

PCD を処理するにあたり, 本研究ではクォータニオン (四元数) [81] と呼ばれる特殊な数を用いる。クォータニオンとは, 実数に $i^2 = j^2 = k^2 = -1$, $ij = k$, $jk = i$, $ki = j$ であるような 3 種類の想像上の数 i , j , k を付け加えて自然に四則演算ができるようにしたものである [80]。三次元物体の回転を表現する際に利用される。

本論文ではクォータニオンにより, ベクトル, 回転軸および回転量を表現することがある。クォータニオンは,

$$\begin{aligned}\tilde{q} &= q_0 + q_1i + q_2j + q_3k \\ &= (q_0; q_1, q_2, q_3) \\ &= \left(\cos \frac{\theta}{2}; v_x \sin \frac{\theta}{2}, v_y \sin \frac{\theta}{2}, v_z \sin \frac{\theta}{2}\right)\end{aligned}\tag{3.12}$$

と式変換することができ, v_x , v_y , v_z は回転軸, θ は回転角を表す (Fig. 3.8)。

また, i , j , k は以下の演算規則を満たす X, Y, Z 軸の基底ベクトルである。

$$\begin{aligned}i^2 &= j^2 = k^2 = ijk = -1 \\ ij &= -ji = k, \quad jk = -kj = i, \quad ki = -ik = j\end{aligned}\tag{3.13}$$

なお, \tilde{q} のノルム $\|\tilde{q}\|$ は, Eq. (3.14) を満たす。

$$\|\tilde{q}\| = \sqrt{q_0^2 + q_1^2 + q_2^2 + q_3^2} = 1\tag{3.14}$$

つづいて, 回転クォータニオン \tilde{q} によって, p を p' へと変換する式を Eq. (3.15) に示す³。

$$p' = \tilde{q}p\tilde{q}^*\tag{3.15}$$

²Fig. 3.7 の例では, Z 軸の値が 0.5~2.4m となる点のみを表示しており, 21.7 万個全ての点がこの図の中に存在する訳ではない。

³回転を表すクォータニオンには, 「位置ベクトルの回転」と「座標系の回転」の 2 種類が存在する。Eq. (3.15) は位置ベクトルの回転を表す。

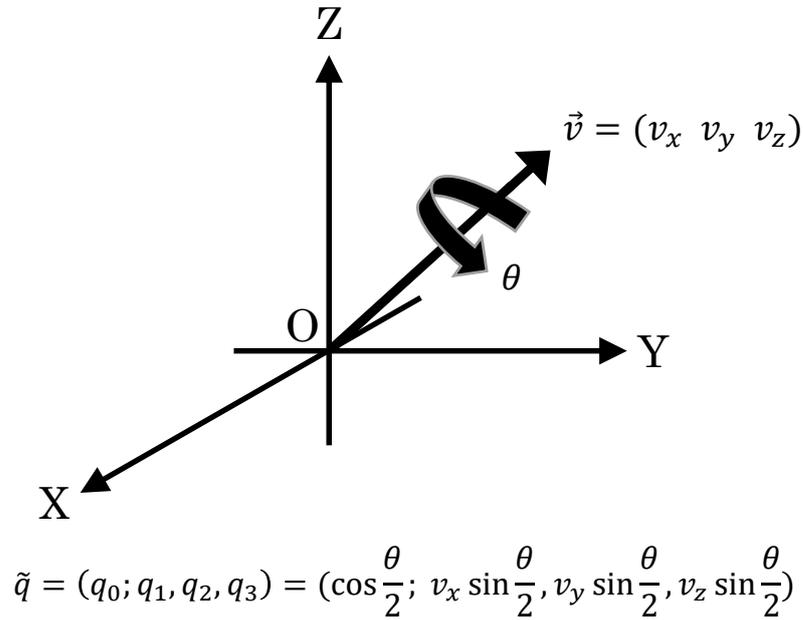


Fig. 3.8 : Rotation quaternion

ここで、 p および p' は、三次元座標（位置ベクトル）を表すクォータニオンであり、 $p = (0; x, y, z)$ 、 $p' = (0; x', y', z')$ と定義される。 p の各要素 x 、 y 、 z （または、 p' の各要素 x' 、 y' 、 z' ）は、それぞれ三次元座標の X、Y、Z 軸の値を表す（単位は [m]）。また、 \tilde{q}^* は、回転クォータニオン \tilde{q} の共役クォータニオンである (Eq. (3.16))。共役クォータニオン \tilde{q}^* は、 p の回転時に \tilde{q} と共に用いられる。

$$\tilde{q}^* = (q_0; -q_1, -q_2, -q_3) \tag{3.16}$$

なお、Fig. 3.8 では右手座標系について扱ったが、クォータニオンに関する変換式は、左手座標系の場合でも使用することが可能である。

以上、本研究で用いられる手法の基本的な原理について述べた。次章以降はこれらの原理を用いて、各々の研究課題の達成を目指す。

第4章 あいまいさを含む臨床判断の モデル化～因果関係の分析～

4.1 本章の目的

第4章では、看護師の臨床判断を定量的に表すモデル式を作成する方法を記す。臨床現場において、看護師は転倒・転落アセスメントスコアシート（FAS: Fall Assessment Score sheet）から患者の転倒・転落に関する危険性を判断し、その予防策の立案および実施を行っている。しかし、実際には患者の様態は多様であるため、杓子定規に扱うことは難しく、看護師の判断によって立案の変更やより適切な対処を行っている。この看護師の判断は、患者を担当する看護師がFASや患者の様子を観察し、看護師個人が感じる患者の転倒・転落の危険性に基づいており、こうした看護師の意思決定は臨床判断と呼ばれる。

一方、FASのチェック項目には主観に基づくあいまいな項目も多く、また、多数のチェック項目を総合的に勘案したうえで患者を観察し、転倒・転落の危険性を判断しなければならない。この臨床判断は看護師自身の知識や経験に大きく依存するため、看護師が変わるとその危険性の判断も変わることがある [21]。さらに、同じ看護師であっても危険性の判断には迷いが生じることもある。これらは、FASの各チェック項目が持つ転倒・転落の危険性に関する重みについて看護師間の統一が取れていないことや、一人の看護師の中においても、重みにゆらぎがあるためであると推察できる。臨床現場の質を保つうえで、看護師が行う転倒・転落の危険性に関する判断を定量化し、また、それを看護師間で共有することは重要な課題の一つである。

以上の背景に鑑み、第4章では看護師の判断基準を定量化する方法として、(1) 看護師の判断を取得するアンケート用紙、(2) アンケート回答データの解析手法、の2つを提案する。その際、看護師の判断に生じる迷いを正確に反映でき、かつ、現実的に実現可能な提案とするため、以下の3つの条件を満たすよう留意する。

【条件1】判断の迷いを考慮したアンケートおよび解析手法であること

【条件2】外れ値に対応した解析手法であること

【条件3】解析に用いる学習データ数が看護師個人から取得できる現実的な分量であること

第4章では、上記の条件を全て満たす看護師判断の定量化手法の実現可能性について検証を行う。

4.2 ファジィ評定法に基づくアンケート

4.2.1 看護師の臨床判断を観測するアンケート

本研究では、看護師に対して転倒・転落リスクに関するアンケート調査を行う必要がある。ここで、転倒・転落リスクとは、4.1節で述べた「看護師個人が感じる患者の転倒・転落の危険性」とする。看護師が転倒・転落リスクを判断する際は、看護師自身の知識や経験を含む心理的な側面も影響している。通常、こうした判断問題は心理量の測定法である評定尺度法により回答を収集する。しかし、従来の評定尺度法は、判断の際に迷いが生じた場合であっても、回答を必ず一箇所に定めなければならない。一般的に、アンケートを行う際は、回答者の自然な思考をそのまま回答に反映できる形式にすべきである。そのため、迷いの発生時は回答箇所を無理に一つに決めさせるのではなく、迷っている部分を回答させる方が、回答者の判断をより正確に取得できる。

Fig. 4.1に、提案するアンケート用紙の一例を記す。図の(a)はFAS、(b)および(c)は看護師の回答欄を表す。(b)は患者の姿勢を使用しないとき、(c)は使用したときの回答欄であり、アンケート実施時はいずれか一方が用いられる。アンケートは、評定尺度法的一种である Visual Analogue Scale (VAS) [66]をベースとする。ここで、VASとは一定の長さの線分上の両端に記された内容を基準として、回答者が感じる主観的な程度を記入するアンケート手法である。別名、グラフ尺度法とも呼ばれる。従来のVASは任意の一点に縦棒を記入することで回答を行うが、本研究では楕円を用いた回答によって判断の迷いを同時に取得する。なお、このようなアンケートはファジィ評定法 [72] と呼ばれる。本研究では、通常のVASとファジィ評定法を併用し、看護師の臨床判断を収集する。看護師は判断に迷いがなければ縦棒を記入し、迷いがあるときは楕円によって迷いの範囲を記す。これらの評価は、Fig. 4.1(b)では一つの線分上のみに、(c)では線分左側に記された患者の姿勢ごとに行う。

Based on the fall assessment score sheet, please fill in the degree of fall risk for the patient

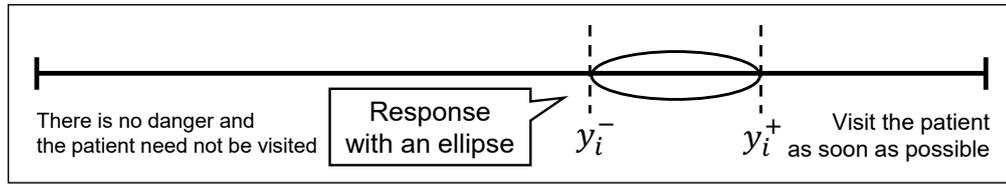
[Fall Assessment Score Sheet]

ID : 100 Creator : Date :

No.	Evaluation item	Evaluation contents	Value	Score
1	History of falls in hospitals	<input checked="" type="checkbox"/> Having <input type="checkbox"/> None	—	—
2	Date of fall	20 / /	—	—
3	Age	<input type="checkbox"/> 70 years old or older <input type="checkbox"/> 9 years old or younger	2	0
4	Sex	<input checked="" type="checkbox"/> Male <input type="checkbox"/> Female	If is a man; 1	1
5	Anamnesis of the fall	<input checked="" type="checkbox"/> Experience of the fall <input type="checkbox"/> Experience of the swoon	2	2
6	Sensory disturbance	<input checked="" type="checkbox"/> Visual disorder <input type="checkbox"/> Hearing disorder	1	1
7	Functional disorder	<input type="checkbox"/> Paralysis <input checked="" type="checkbox"/> Feeling numbness <input type="checkbox"/> Abnormality of bones or joints	3	3
8	Activity	<input type="checkbox"/> Weakness of legs, drop in muscular power <input type="checkbox"/> Bedridden <input type="checkbox"/> Feeling giddy <input checked="" type="checkbox"/> Assistance is necessary for movement <input type="checkbox"/> Using a wheelchair, stick or walker	3	3
9	Cognition	<input checked="" type="checkbox"/> Disorientation, muddiness, confusion <input checked="" type="checkbox"/> Loss of memory, and relearning is difficult <input type="checkbox"/> Loss of judgement and understanding <input checked="" type="checkbox"/> Threatening action <input type="checkbox"/> Dementia	4	4
10	Drug use x_i (Approximately 50 contents)	<input type="checkbox"/> Analgesics <input type="checkbox"/> Insulin, hypoglycemic agent <input type="checkbox"/> Chemotherapy <input type="checkbox"/> Antihypertensive diuretic <input type="checkbox"/> Antiparkinson drug <input type="checkbox"/> Sleep stabilizer <input checked="" type="checkbox"/> Medical narcotics <input checked="" type="checkbox"/> Purgative enema	For each 1	2
11	Excretion action	<input checked="" type="checkbox"/> Urine or fecal incontinence <input type="checkbox"/> Restrooms are far from a sickroom <input type="checkbox"/> Need to go to a restroom at night <input type="checkbox"/> Urethral catheterization <input checked="" type="checkbox"/> Assistance is necessary for excretion <input checked="" type="checkbox"/> Frequent miction	For each 2	6
12	Sitting balance (rising)	<input type="checkbox"/> Falling down after rising <input type="checkbox"/> Being unable to stand up without any support <input type="checkbox"/> Both legs leave each other and are not parallel	For each 1	0
13	Sitting balance (keep standing)	<input checked="" type="checkbox"/> Shakiness of the body <input type="checkbox"/> Staggering or falling down	For each 1	1
14	Sitting balance (walking)	<input type="checkbox"/> Short stride length <input type="checkbox"/> Staggering <input checked="" type="checkbox"/> Stumbling <input checked="" type="checkbox"/> Movement as if about to grab something	For each 1	2
15	Sitting balance (changing directions)	<input type="checkbox"/> Staggering <input type="checkbox"/> Stumbling <input type="checkbox"/> Movement as if about to grab something	For each 1	0
16	Sitting balance (sitting on a chair)	<input type="checkbox"/> Holding the elbow rest <input type="checkbox"/> Losing sight of the chair <input type="checkbox"/> Plopping down	For each 1	0
17	Sitting balance	<input type="checkbox"/> Sitting posture is unstable and the body is shaking	For each 1	0
Total Score				25

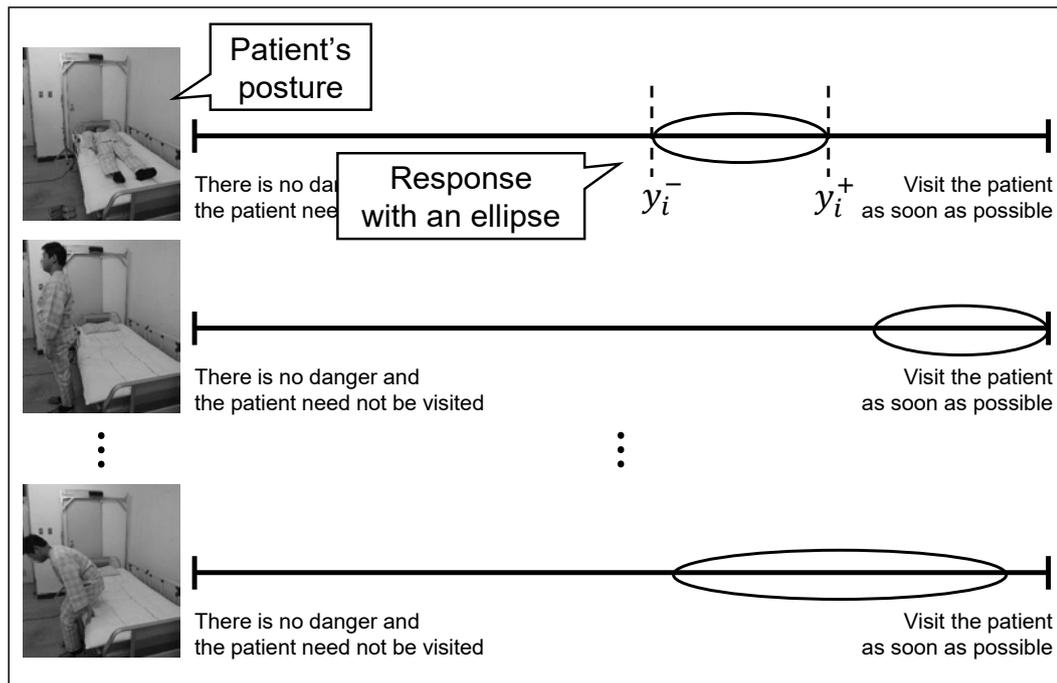
Bold font : More than one item Thin font : For each item

(a) Fall assessment score sheet



※ If any answer is vague, please indicate the range of vagueness using an ellipse

(b) Response area of the nurse



※ If any answer is vague, please indicate the range of vagueness using an ellipse

(c) Postures of the patient and the response area of the nurse

Fig. 4.1 : Sample questionnaire sheet. The nurse draws the fall risk that he/she perceives based on the Fall Assessment Score sheet (FAS).

Fig. 4.1 の i はデータ内の個々の FAS の識別番号, (a) の x_i は FAS のチェックマークの有無を表すベクトルである. また, (b) の y_i^- および y_i^+ は, それぞれファジィ評定法による回答の最小値および最大値である (看護師が通常の VAS で回答した場合は $y_i^- = y_i^+$ となる). 一方, アンケートの回答欄として (c) の方を採用した場合は, 解析の対象とする姿勢を任意に一つ定める ((c) の例では「臥位」を指定). (c) の y_i^- および y_i^+ は, 対象とする姿勢における回答の最小値および最大値である. (b) と (c) は, どちらの方式が採用されたとしても, FAS の内容を x_i , 看護師の回答を y_i^-, y_i^+ として分析が行われる.

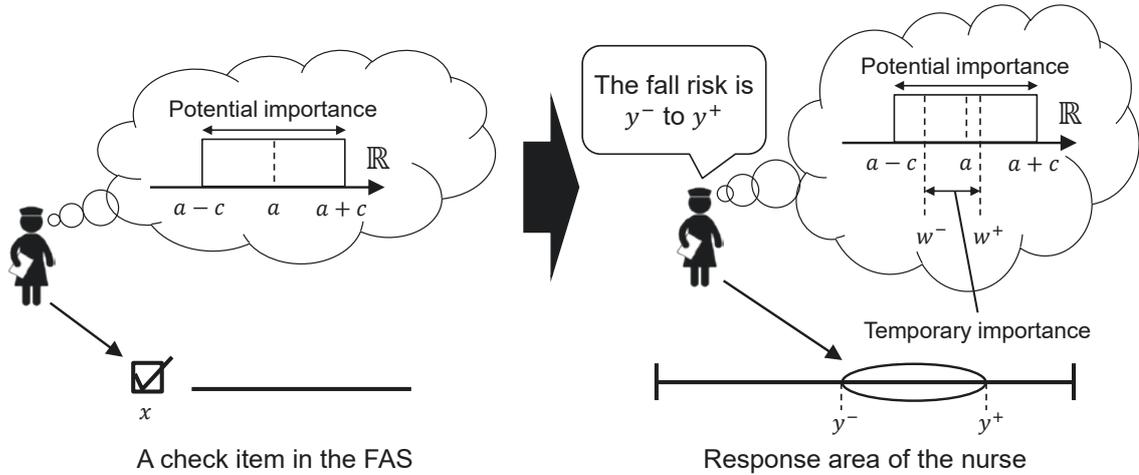


Fig. 4.2 : A process of clinical judgment concerning the fall risk. x is the presence of a checkmark, y^- to y^+ is the response by a nurse, a is a mean of the potential importance, c is a spread (vagueness) of the potential importance, and w^- to w^+ is the temporary importance. The nurse concludes the fall risk y^- to y^+ based on the importance w^- to w^+ that temporarily occurs in his/her mind.

4.2.2 転倒・転落リスクの臨床判断プロセスの定義

臨床現場において、看護師は一般的に FAS の内容に基づいて転倒・転落リスクを評価している [22,23]. これに関して、1.1 節でも述べた通り、平松や森田らは FAS のチェック項目が主観的な場合や、患者本人や家族からあいまいな情報が提示された場合は、看護師によって判断が分かれやすく、信頼性に限界があることを示した [37,38]. また、清水らは FAS の表現があいまいであるため、看護師は自身の判断が正しいか迷ったり、迷いながら予防対策を講じていることを明らかにした [39]. これらの報告は、看護師が臨床判断の際に感じる転倒・転落リスクの大きさや判断の迷いが、FAS のチェック項目に起因して変化することを示唆している. 以上のことから、想定される転倒・転落リスクの臨床判断プロセスを Fig. 4.2 のように定義し、その詳細を以下に記載する.

看護師は FAS のチェック項目を見たとき、そのチェック項目に対する重要度 $a-c \sim a+c$ ($c \geq 0$) を潜在的に感じる. ここで、 c は重要度に含まれるあいまいさである. 人間はコンピュータと違い、明確な数値として判断基準を持っていないため、ここでは c を付与することであいまいな重要度を表現する. 一方、看護師は転倒・転落リスクを一意に決められないことがあるが、これはあいまいさ c により生じるも

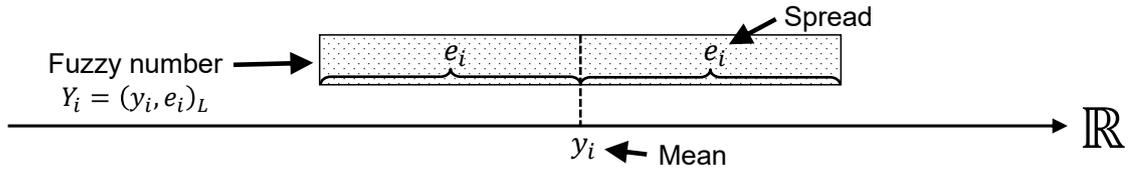


Fig. 4.3 : L-L fuzzy number Y_i . Attach a spread e_i to a usual value (a mean) y_i .

のである。転倒・転落リスクの回答時，看護師は臨床判断の中であいまいな重要度 $w^- \sim w^+$ ($a - c \leq w^- \leq w^+ \leq a + c$) が一時的に生じる。看護師は $w^- \sim w^+$ に基づき，転倒・転落リスク $y^- \sim y^+$ を回答する。ただし，重要度 w^- ， w^+ は常に一定の値ではなく，回答のたびに化する。

本研究では，看護師の迷いを含んだ回答 $y^- \sim y^+$ は，上記のプロセスを経て決定されると想定する。

4.2.3 説明変数と目的変数の定義

本研究において，看護師は FAS の内容から患者の転倒・転落リスクを判断する。そのため，第 i 番目の FAS において，チェックマークの有無を表すベクトル \mathbf{x}_i は説明変数，看護師の回答 Y_i は目的変数と定義でき，Eq. (4.1) のように表される。

$$\mathbf{x}_i = (x_{i,1} \ x_{i,2} \ \cdots \ x_{i,n_{all}}) \quad Y_i = (y_i, e_i)_L \quad (4.1)$$

ここで， \mathbf{x}_i は FAS の全項目数 n_{all} の要素から成り，各要素 $x_{i,j}$ は項目 j のチェックマークの有無を表す。一方， Y_i は L-L ファジィ数¹と呼ばれる (Fig. 4.3)。ファジィ数では，通常の数値 y_i に幅 e_i が設けられる。

なお， $x_{i,j}$ は数量化理論に基づきチェックマークなしを 0，ありを 1 の質的変数とする。一方， Y_i は線分の左端から回答までの長さとし，Eq. (4.2) により中心 y_i および幅 e_i のファジィ数へと変換する。

$$y_i = \frac{y_i^+ + y_i^-}{2} \quad e_i = \frac{y_i^+ - y_i^-}{2} \quad (4.2)$$

¹第4章の解析手法は帰属度の定義を必要としないため，Fig. 4.3 では帰属度を省略した。

4.3 リスク判断の定量化手法

4.3.1 ファジィ線形回帰分析の概要

つづいて、回答データから看護師の転倒・転落リスク判断を定量化する方法を示す。説明変数や目的変数にファジィ数を含むデータを解析する方法として、ファジィ線形回帰分析（FLR: Fuzzy Linear Regression）が挙げられる。FLRでは、説明変数 x_i と目的変数の推定値 $\hat{Y}_i = (\hat{y}_i, \hat{e}_i)_L$ との関係式（モデル式）を Eq. (4.3) のように表す。ここで、 \oplus と \otimes は、ファジィ数の加算、乗算記号である。

$$\hat{Y}_i = A_0 \oplus A_1 \otimes x_{i,1} \oplus A_2 \otimes x_{i,2} \oplus \cdots \oplus A_{n_{all}} \otimes x_{i,n_{all}} \quad (4.3)$$

$A_0, A_1, \dots, A_{n_{all}}$ はファジィ係数と呼ばれ、Eq. (4.4) で表される。

$$A_j = (a_j, c_j)_L \quad (4.4)$$

a_j はファジィ係数の中心、 c_j はファジィ係数の幅である。本研究では、 a_j は看護師がチェック項目 j を重視する程度、 c_j はチェック項目 j により生じるあいまいさの程度と解釈できる。

FLRでは、ファジィ係数の各値を導出する。FLRは、ファジィ線形計画問題（FLP: Fuzzy Linear Programming）とファジィ最小二乗法（FLS: Fuzzy Least Squares）の2種類に分類される。FLPは一般式が簡潔なため、実装および計算コストが低い [82]。しかし、Reddenらは、FLPは外れ値に対して非常に敏感であり、外れ値によってモデルの形状が歪みやすいと指摘した [83]。そのため、誤差データに頑強なファジィロバスト回帰分析が複数提案されている [84–86]。

ただし、浅野らはFLPにより算出されたファジィ係数の中心 a_j は、通常の重回帰分析と似通った値となるが、ファジィ係数の幅 c_j に関しては、その説明変数の変化の形状が、推定区間の中央値と目的変数との残差の絶対値の変化の形状と類似しているか否かによって決定されるものであり、目的変数を推定するときの説明変数が持つあいまいさを表すものではないと述べた [87]。そのため、FLPは従来手法が持つ問題点を解消したファジィロバスト回帰分析を用いることで、観測されたデータ内に潜む外れ値の影響を軽減させることが可能なものの、看護師がFASの中であいまいさを感じるチェック項目を抽出することはできない。

一方、FLSは推定値と観測値との隔たりが少なく、FLPより観測値に適合した結果が得られやすい [82, 88]。しかし、FLSは目的関数が二次となる制約付き最適化問題であるため、解の探索がFLPより難しく、計算コストも高い [89]。奥谷らは、FLS

の目的関数と制約条件がファジィ係数の中心と幅とで完全に分離できるという性質を利用することで、FLSの最適解を二次計画法によって求められると述べた [90]。そのため、FLSは、一般式については一意な解の探索が可能である。しかし、FLSは外れ値の影響を軽減するために一般式を改良することが困難である。もし、FLSの一般式に正則化項などを追加すると、従来の解法を利用できなくなる可能性が高い。仮に、従来の解法が利用可能であったとしても、問題（目的関数や制約条件）がさらに複雑化する事態は避けられない。

以上より、問題の単純さを保ちつつ、外れ値の影響を軽減可能な解析手法を実現するため、本研究では看護師の臨床判断を定量化する際、FLPにより外れ値を除去した後、FLSによりファジィ係数を求めることとする。解析手順の概要を Fig. 4.4 に、各々の詳細を次節より記す。

4.3.2 ファジィ線形回帰式の再定義

ファジィ線形回帰式の作成にあたり、区間増加問題 (SIP: Spreads Increasing Problem) [89] への対策が必要となる。SIPとは、説明変数 $x_{i,j}$ の増加につれ、目的変数 \hat{Y}_i の幅 \hat{e}_i が単調増加するという問題である。目的変数の推定値 \hat{Y}_i の幅 \hat{e}_i は、Eq. (4.3) より求められるが、ファジィ数の乗算結果は幅の部分が必ず非負になることから本問題が生じる。SIPでは、対象となる評価問題が単調増加しないとき、推定された回帰式の性能が大きく低下するといった問題が生じる。そのため、SIPの影響を軽減したモデルが多数提案されている。しかし、従来手法はファジィ係数の幅を切片項を除き全て0に固定したり [91]、ファジィ数の演算規則を変更したりしている [92]。そのため、従来のファジィ理論に則ったモデルを作成できない。さらに、SIPに対応した手法は、目的関数や制約条件が複雑化しやすく利便性に欠ける。

このように、FLRではSIPが重要な問題として挙げられる。そのため、本研究では $x_{i,j}$ がカテゴリ総数2の質的変数 ($x_{i,j}$ の値が0と1の二通り) であることを利用し、SIPの解消を図る。一般的なファジィ線形回帰式は Eq. (4.3) と表されるが、本研究では Eq. (4.5) へと改める。

$$\begin{aligned} \hat{Y}_i = & A_0 \oplus A_1 \otimes x_{i,1} \oplus A_2 \otimes x_{i,2} \oplus \cdots \oplus A_{n_{all}} \otimes x_{i,n_{all}} \\ & \oplus \bar{A}_1 \otimes \bar{x}_{i,1} \oplus \bar{A}_2 \otimes \bar{x}_{i,2} \oplus \cdots \oplus \bar{A}_{n_{all}} \otimes \bar{x}_{i,n_{all}} \end{aligned} \quad (4.5)$$

$\bar{x}_{i,j}$ は $x_{i,j}$ の否定 (NOT 演算) であり、Eq. (4.6) となる。また、 $\bar{A}_j = (\bar{a}_j, \bar{c}_j)_L$ は $\bar{x}_{i,j}$ のファジィ係数を表す。 $\bar{A}_j \otimes \bar{x}_{i,j}$ の項を追加することで、FASの項目にチェック

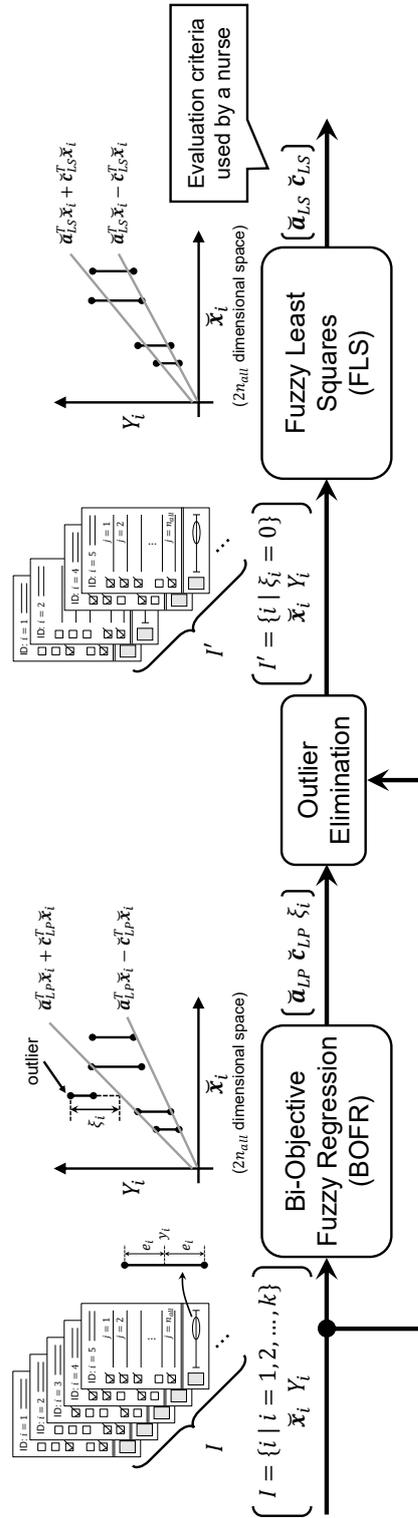


Fig. 4.4 : Derivation procedure of the evaluation criteria used by a nurse based on the fuzzy linear regression

マークがないときに生じるあいまいさを表現することが可能となり、SIPの影響を軽減できる。

$$\bar{x}_{i,j} = \begin{cases} 1 & ; x_{i,j} = 0 \\ 0 & ; x_{i,j} = 1 \end{cases} \quad (4.6)$$

なお、Eq. (4.5) のファジィ係数の中心と幅、ならびに説明変数をそれぞれ

$$\check{\mathbf{a}} = (a_0 \ \mathbf{a} \ \bar{\mathbf{a}})^T \quad (4.7)$$

$$= (a_0 \ a_1 \ a_2 \ \cdots \ a_{n_{all}} \ \bar{a}_1 \ \bar{a}_2 \ \cdots \ \bar{a}_{n_{all}})^T ; \forall \bar{a}_j = 0$$

$$\check{\mathbf{c}} = (c_0 \ \mathbf{c} \ \bar{\mathbf{c}})^T \quad (4.8)$$

$$= (c_0 \ c_1 \ c_2 \ \cdots \ c_{n_{all}} \ \bar{c}_1 \ \bar{c}_2 \ \cdots \ \bar{c}_{n_{all}})^T ; \forall c_j, \bar{c}_j \geq 0$$

$$\check{\mathbf{x}}_i = (x_{i,0} \ \mathbf{x}_i \ \bar{\mathbf{x}}_i)^T \quad (4.9)$$

$$= (1 \ x_{i,1} \ x_{i,2} \ \cdots \ x_{i,n_{all}} \ \bar{x}_{i,1} \ \bar{x}_{i,2} \ \cdots \ \bar{x}_{i,n_{all}})^T$$

$$; \forall x_{i,j} = 0 \text{ or } 1, \bar{x}_{i,j} = 1 - x_{i,j}$$

と置くと、目的変数 \hat{Y}_i の中心 \hat{y}_i および幅 \hat{e}_i は、Eq. (4.10) により求められる。

$$\hat{y}_i = \check{\mathbf{a}}^T \check{\mathbf{x}}_i \quad \hat{e}_i = \check{\mathbf{c}}^T \check{\mathbf{x}}_i \quad (4.10)$$

4.3.3 ファジィ線形計画問題による外れ値の探索

FLPとは目的変数の推定値 \hat{Y}_i が観測値 Y_i を包含するという制約の下、 \hat{Y}_i の幅の総和が最小となるファジィ係数を探索する最適化問題である [93]。しかし、全観測値を包含させる必要があるため、観測値の中に外れ値が存在すると回帰式の形状が大きく歪む。Petersは、外れ値を含むデータを対象とするときは、従来のFLPにファジィ区間 (Fuzzy interval) を設けることで、外れ値の影響を軽減し、推定精度を向上させられることを示した [85]。その後、ÖzelkanらはPetersのアイデアに基づき、二目的ファジィ回帰分析 (BOFR: Bi-Objective Fuzzy Regression) を提案した [86]。BOFRとは、推定値が持つあいまいさの最小化と外れ値の探索を同時に行う多目的最適化問題である。BOFRでは、推定値と観測値間の差異の大きさに基づいて、外れ値の特定を行っている。なお、差異の大きさから外れ値を除去するという考えは、非ファジィ数を対象としたロバスト回帰分析でも既に導入されていることから [94]、BOFRのコンセプトは外れ値の特定手段として妥当であるといえる。

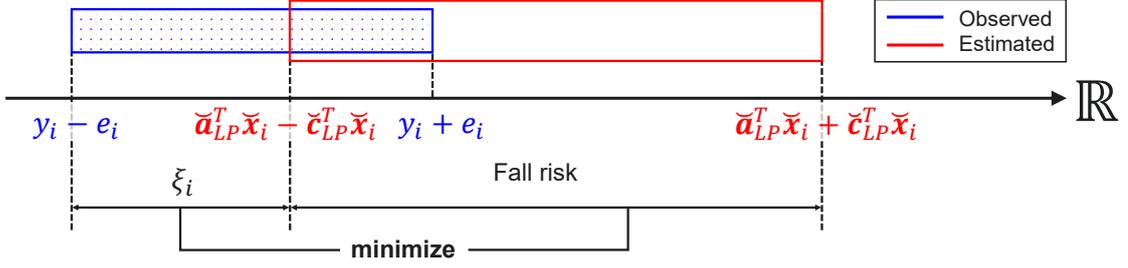


Fig. 4.5 : Concept of Bi-Objective Fuzzy Regression (BOFR). In the classic Fuzzy Linear Programming (FLP), the fuzzy coefficients that minimize $\check{c}_{LP}^T \check{x}_i$ are searched under the constraint that the estimated values $\check{a}_{LP}^T \check{x}_i - \check{c}_{LP}^T \check{x}_i$ to $\check{a}_{LP}^T \check{x}_i + \check{c}_{LP}^T \check{x}_i$ include the observed values $y_i - e_i$ to $y_i + e_i$. BOFR can deal with the outliers because a relaxation term ξ_i is added to the inequality constraints and the objective function in FLP.

本研究では、BOFRにより外れ値の影響を軽減する [86]. Fig. 4.5 に BOFR の概要を示すとともに、その一般式を Eq. (4.11) に記載する.

$$\text{minimize } J_{LP} = \sum_{i=1}^k (\check{c}_{LP}^T \check{x}_i + \frac{1}{K} \xi_i) \quad (4.11)$$

subject to

$$\check{a}_{LP}^T \check{x}_i - \check{c}_{LP}^T \check{x}_i - \xi_i \leq y_i - e_i \quad ; i = 1, 2, \dots, k$$

$$\check{a}_{LP}^T \check{x}_i + \check{c}_{LP}^T \check{x}_i + \xi_i \geq y_i + e_i \quad ; i = 1, 2, \dots, k$$

$$\bar{a}_{LP} = 0, \check{c}_{LP} \geq 0, \forall \xi_i \geq 0 \quad ; i = 1, 2, \dots, k$$

ここで、 \check{a}_{LP} 、 \check{c}_{LP} は、BOFR より求まるファジィ係数の中心と幅を表す. BOFR は通常の FLP に緩和制約項 ξ_i を追加し、観測値 $y_i - e_i \sim y_i + e_i$ が推定値 $\check{a}_{LP}^T \check{x}_i - \check{c}_{LP}^T \check{x}_i \sim \check{a}_{LP}^T \check{x}_i + \check{c}_{LP}^T \check{x}_i$ から外れた位置に存在する場合、 ξ_i によって回帰式の形状が歪むのを防ぐ. ξ_i の比重はハイパーパラメータ K ($0 < K < 1$) により調整され、1 に近づくほど比重が大きくなる.

さらに、BOFR は観測値が外れた位置に存在するとき、 ξ_i が増加するという性質を持つ. そのため、全データセットを I とすると、外れ値を除外した新たなデータセット I' は下記の条件を満たす集合となる.

$$I = \{i \mid i = 1, 2, \dots, k\} \quad I' = \{i \mid \xi_i = 0\} \quad (4.12)$$

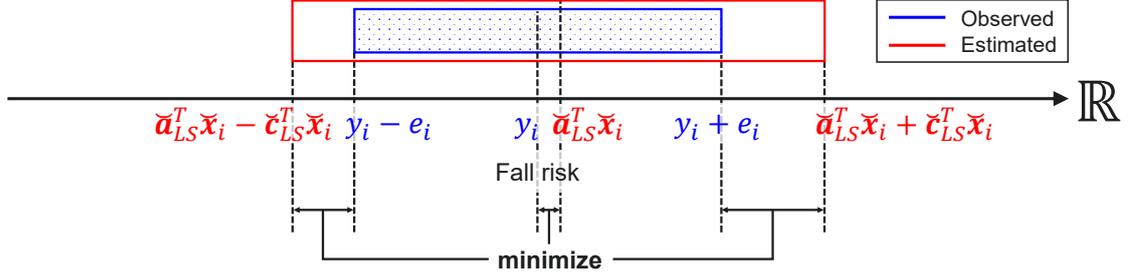


Fig. 4.6 : Concept of Fuzzy Least Squares (FLS). The purpose of FLS is to find the fuzzy coefficients that minimize the difference between the center of the estimated value $\check{\mathbf{a}}_{LS}^T \check{\mathbf{x}}_i$ and the center of the observed value y_i , as well as the difference between the both-ends of the estimated value $\check{\mathbf{a}}_{LS}^T \check{\mathbf{x}}_i \pm \check{\mathbf{c}}_{LS}^T \check{\mathbf{x}}_i$ and the both-ends of the observed value $y_i \pm e_i$.

4.3.4 ファジィ最小二乗法による臨床判断の解析

FLS とはファジィ数に距離概念を導入し、目的変数の推定値 \hat{Y}_i と観測値 Y_i との誤差の総和が最小となるファジィ係数を探索する最適化問題である [95]. Fig. 4.6 に概要を示す. $\check{\mathbf{a}}_{LS}$, $\check{\mathbf{c}}_{LS}$ は、FLS により求まるファジィ係数の中心と幅である.

FLS の一般式は、Eq. (4.13) と表される [90].

$$\begin{aligned} \text{minimize } J_{LSa} &= \sum_{i \in I'} (y_i - \check{\mathbf{a}}_{LS}^T \check{\mathbf{x}}_i)^2 & (4.13) \\ \text{minimize } J_{LSc} &= \sum_{i \in I'} (e_i - \check{\mathbf{c}}_{LS}^T \check{\mathbf{x}}_i)^2 \\ \text{subject to } & \bar{\mathbf{a}}_{LS} = 0, \check{\mathbf{c}}_{LS} \geq 0 \end{aligned}$$

以上、FLP の後に FLS を実行することで、看護師の誤判断と迷いを考慮した定量化を実現できる. $\check{\mathbf{a}}_{LS}$ および $\check{\mathbf{c}}_{LS}$ はモデル式 (Eq. (4.5)) を構成するパラメータであり、FAS の状態 \mathbf{x}_i を入力として与えると、転倒・転落リスクの推定値 \hat{Y}_i が出力される.

なお、Fig. 4.1 において、(b) ではなく (c) の様式を採用した場合は、FLS の実行後に対象とする姿勢を変更し、目的変数を改める. その後、FLP および FLS を再び行い、 $\check{\mathbf{a}}_{LS}$, $\check{\mathbf{c}}_{LS}$ を求める. 以上のプロセスを全姿勢に対して実施し、ファジィ係数を姿勢ごとに算出する. 例として、Fig. 4.1 のアンケートにおいて、看護師が7通りの姿勢に対して回答を記入した場合は、 $\check{\mathbf{a}}_{LS}$ および $\check{\mathbf{c}}_{LS}$ が7セット得られる (つまり、モデル式が7つ作成される).

4.4 ダミーデータによる検証

4.4.1 ダミーデータの生成

第4章の目的は、転倒・転落リスク判断を定量化するためのアンケート解析手法を提案することである。そのため、本検証では判断基準の真値 \check{a}^t , \check{c}^t と、提案手法によって得られる推定値 \hat{a} , \hat{c} とを比較する。ただし、実際の看護師の回答データを検証に用いた場合、 \check{a}^t , \check{c}^t が未知であるため、真値との比較によって提案手法の有効性を示すことができない。そのため、本節では判断基準の真値が既知なダミーデータを作成し、それを看護師の回答データとして使用する。

4.2.2節に示した臨床判断プロセスは、臨床現場の実情 [22,23] や転倒・転落アセスメントの迷いに関する先行研究の知見 [37-39] を踏まえていることから、本プロセスに基づいてダミーデータを生成する。そのため、生成されたダミーデータは、実際の看護師の回答データを十分に模倣できていると考える。

以下に生成手順の詳細を記す。なお、Fig. 4.1(c) を用いたアンケートを実施した場合においても、提案手法は患者の姿勢ごとに独立してFLRを行う（つまり、説明変数に「姿勢」を含まない）ことから、今回の検証では判断基準の真値を生成する際に姿勢に関する条件を定めない。

- 1) FASの各チェック項目に対して、ファジィ係数の中心および幅の真値 \check{a}^t , \check{c}^t を設定する。

$$\check{a}^t = (a_0^t \ a_1^t \ a_2^t \ \cdots \ a_{n_{all}}^t \ \bar{a}_1^t \ \bar{a}_2^t \ \cdots \ \bar{a}_{n_{all}}^t)^T \quad (4.14)$$

$$\check{c}^t = (c_0^t \ c_1^t \ c_2^t \ \cdots \ c_{n_{all}}^t \ \bar{c}_1^t \ \bar{c}_2^t \ \cdots \ \bar{c}_{n_{all}}^t)^T \quad (4.15)$$

- 2) チェック項目 j ($= 0, 1, 2, \dots, n_{all}$) ごとに、 $[a_j^t - c_j^t, a_j^t + c_j^t]$ (または $[\bar{a}_j^t - \bar{c}_j^t, \bar{a}_j^t + \bar{c}_j^t]$) の範囲で一時的な重要度 $w_{i,j}^-$, $w_{i,j}^+$ (または $\bar{w}_{i,j}^-$, $\bar{w}_{i,j}^+$) をランダムに生成する。これらの重要度は、FASの識別番号 i ($= 1, 2, \dots, k$) ごとに生成される。

- 3) Eq. (4.16) より、回答データ y_i^- を算出する。

$$y_i^- = (\check{w}_i^-)^T \check{x}_i + \varepsilon_i^- \quad y_i^+ = (\check{w}_i^+)^T \check{x}_i + \varepsilon_i^+ \quad (4.16)$$

ここで、 \check{w}_i^- は一時的な重要度 $w_{i,j}^-$, $\bar{w}_{i,j}^-$ のベクトルである。同様に、回答データ y_i^+ を算出する。このとき、一定確率で外れ値 ε_i^- , ε_i^+ を発生させる。

- 4) 回答データ y_i^- , y_i^+ より、Eq. (4.2) を用いて観測値 $Y_i = (y_i, e_i)_L$ を算出する。

Table 4.1 : Conditions on the dataset generation and analysis

Nurse	ID	Num. of samples k	Mean $[\bar{a}^t]$	Spread $[\bar{c}^t]$	Parameter K
1	A	250	[0.0, 3.0]	[0.0, 3.0]	0.01
	B	250	[0.0, 3.0]	[0.0, 3.0]	0.2
	C	500	[0.0, 3.0]	[0.0, 3.0]	0.01
	D	500	[0.0, 3.0]	[0.0, 3.0]	0.2
2	E	250	[0.0, 6.0]	[0.0, 3.0]	0.01
	F	250	[0.0, 6.0]	[0.0, 3.0]	0.2
	G	500	[0.0, 6.0]	[0.0, 3.0]	0.01
	H	500	[0.0, 6.0]	[0.0, 3.0]	0.2
3	I	250	[0.0, 3.0]	[-1.5, 1.5]	0.01
	J	250	[0.0, 3.0]	[-1.5, 1.5]	0.2
	K	500	[0.0, 3.0]	[-1.5, 1.5]	0.01
	L	500	[0.0, 3.0]	[-1.5, 1.5]	0.2
4	M	250	[0.0, 6.0]	[-1.5, 1.5]	0.01
	N	250	[0.0, 6.0]	[-1.5, 1.5]	0.2
	O	500	[0.0, 6.0]	[-1.5, 1.5]	0.01
	P	500	[0.0, 6.0]	[-1.5, 1.5]	0.2

4.4.2 実験条件

ダミーデータの生成条件を Table 4.1 に記す. 今回は, 全データ数, ファジィ係数の中心および幅の生成範囲, ハイパーパラメータが異なるデータセットを生成する. 本検証では, 中心や幅の生成範囲が異なる4名の看護師を想定し, 中心の生成範囲が幅の生成範囲と等しいデータ群(条件 A~D, I~L)と, 中心の生成範囲が幅の生成範囲より広いデータ群(条件 E~H, M~P)を用意する. このとき, 切片項のファジィ係数 A_0 の値が, 他のファジィ係数の中に混在しないよう, \bar{a}_j^t は常に0とする. また, \bar{c}_j^t と \underline{c}_j^t については, 0より大きな値となるのをいずれか一方のみとする(つまり, \bar{c}_j^t , \underline{c}_j^t は少なくとも一方が0となる). なお, 条件 I~P は $[\bar{c}^t]$ に負値が存在しているが, 負値は真値 \bar{c}_j^t の符号が反転されたものである.

一方, 全データ数 k は 4.1 節に示した【条件 3】に基づき, 看護師個人が回答できるであろう分量として, 少なくとも 250 例, 多くとも 500 例と設定した. また, ハイパーパラメータ K は, 外れ値処理を行わない条件と行う条件として, それぞれ $K = 0.01$ と $K = 0.2$ を定めた. さらに, 本検証では一般的な無作為性とあいまいさを区別するため, $w_{i,0}^-$, $w_{i,0}^+$ を定数とする. ただし, 発生率 5%, 大きさ $[-30, 30]$ と

Table 4.2 : Analytical results for each dataset

Nurse	ID	Correlation		Num. of used samples card(I')
		Cor($\check{\mathbf{a}}^t, \check{\mathbf{a}}$)	Cor($\check{\mathbf{c}}^t, \check{\mathbf{c}}$)	
1	A	0.840	0.622	250
	B	0.858	0.779	226
	C	0.854	0.819	500
	D	0.897	0.913	444
2	E	0.843	0.595	250
	F	0.929	0.829	232
	G	0.975	0.800	500
	H	0.973	0.905	438
3	I	0.703	0.258	250
	J	0.764	0.473	233
	K	0.902	0.426	500
	L	0.932	0.784	440
4	M	0.928	0.298	250
	N	0.964	0.658	230
	O	0.963	0.509	500
	P	0.988	0.834	445

して、外れ値 ε_i^- , ε_i^+ を生じさせる。また、チェック項目の個数 n_{all} (次元数) を 50, 回答データ y_i^- および y_i^+ の分解能を 1 とした。

なお、解を得るためのソルバーについては、FLP は lpSolve [96], FLS は CVX-OPT [97] を用いた。

4.4.3 解析結果

Table 4.1 の各条件に対し、提案手法を実施した結果を Table 4.2 に示す。表中の $\text{Cor}(\check{\mathbf{a}}^t, \check{\mathbf{a}})$ はファジィ係数の中心の真値と推定値との相関係数, $\text{Cor}(\check{\mathbf{c}}^t, \check{\mathbf{c}})$ は幅の真値と推定値との相関係数, $\text{card}(I')$ は FLS に使用したデータ数 (集合 I' の濃度) を表す。 $\text{Cor}(\check{\mathbf{a}}^t, \check{\mathbf{a}})$ および $\text{Cor}(\check{\mathbf{c}}^t, \check{\mathbf{c}})$ は、ファジィ係数の真値と推定値の一致度を表す指標であり、真値 $\check{\mathbf{a}}^t$ (または $\check{\mathbf{c}}^t$) の各要素 a_j^t , \bar{a}_j^t (または c_j^t , \bar{c}_j^t) の大小関係と、推定値 $\check{\mathbf{a}}$ (または $\check{\mathbf{c}}$) の各要素 a_j , \bar{a}_j (または c_j , \bar{c}_j) の大小関係が一致するほど値が 1 に近づく。つまり、判断基準の推定値が真値と類似するほど相関係数の値が高くなることから、相関係数は判断基準の推定精度と解釈できる。第 4 章では、判断基準の定量化を目的としており、相関係数をもって提案手法の有効性を示すことが可

能である。

4.4.4 ファジィ係数の中心の相関に関する考察

Table 4.2 より、中心の相関係数 $\text{Cor}(\check{a}^t, \check{a})$ については、いずれの条件でも値が 0.7 以上となることが分かる。ここで、ギルフォードの経験則 (Guilford's rule of thumb) [98] に従う場合、相関係数 0.7 以上は、両者の間に強い相関があると解釈される。本章において、 a_j はチェック項目 j を重視する程度と定義していた。そのため、Table 4.2 に示す $\text{Cor}(\check{a}^t, \check{a})$ の各結果はギルフォードが定めた基準値を超えており、 $[\check{a}^t]$ が $[\check{c}^t]$ より同等以上に広い場合、看護師が重視する FAS のチェック項目を高い精度で抽出できることを示唆するものである。

さらに、ハイパーパラメータ K の値のみが異なる条件同士 (条件 A と B, C と D, E と F, G と H, I と J, K と L, M と N, O と P) を比較すると、基本的に K が 0.2 となる方 (条件 B, D, F, J, L, N, P) が、相関係数 $\text{Cor}(\check{a}^t, \check{a})$ が大きくなることが確認できる。これより、提案手法は BOFR によって外れ値を除去し、重要なチェック項目の抽出精度を向上させることが可能といえる。

4.4.5 ファジィ係数の幅の相関に関する考察

今回は、重要度 a_j , \bar{a}_j にあいまいさ c_j , \bar{c}_j が内在するという想定の下で検証を行った。ここで、Table 4.2 を確認すると、全データ数 k を 500 個、かつ、ハイパーパラメータ K を 0.2 としたとき (条件 D, H, L, P)、幅の相関係数 $\text{Cor}(\check{c}^t, \check{c})$ が全て 0.7 以上となっており、真値との強い相関を示した。

一方、本検証で用意した条件 A～P のデータ群は、Table 4.1 に記した幅の生成範囲 $[\check{c}^t]$ に基づき、条件 A～H と条件 I～P とに大別できる。条件 A～H は観測値 Y_i の幅 e_i がチェックマークの付いた項目 ($x_{i,j} = 1$ のとき) のみに起因して生じ、条件 I～P はチェックマークの付いていない項目 ($x_{i,j} = 0$ のとき) にも起因して発生するという特徴を持つ。そのため、条件 A～H においては、チェックマークの付いた項目数に応じて観測値 Y_i の幅 e_i が単調に増加する。しかし、条件 I～P においては、 e_i が単調増加しないため、条件 A～H と比べて相関係数 $\text{Cor}(\check{c}^t, \check{c})$ が小さくなりやすく、Table 4.2 の各結果がそのことを裏付けている。特に、条件 I および M に関しては、条件 I～P の中でも学習データ数が 250 例と少なく、外れ値処理も行わないといった悪条件を重ねたため、 $\text{Cor}(\check{c}^t, \check{c})$ が 0.258 および 0.298 と他の条件に比べて大

幅に小さい値となった。ただし、条件 J～L, N～P の解析結果が示す通り、このような場合でも学習データ数の増加や外れ値処理の実施によって、推定精度を向上させることは十分可能である。

さらに、条件 I～P の判断基準を定量化する際、Eq. (4.3) のファジィ線形回帰式ではチェックマークの付いていない状態に対するファジィ係数の幅を適切に表現できないため、SIP が生じて定量化を行うことすら不可能であった。それに対し、今回用いた Eq. (4.5) は、SIP による影響を考慮しているため、推定精度に劣化はあるものの、判断基準の定量化を行うことが可能である。

なお、本検証では結果同士の比較を行うため、ハイパーパラメータ K を 0.01 または 0.2 として解析を行ったが、 K の最適値が常に 0.2 になるとは限らない。例として、条件 P は $K = 0.2$ のときより、 $K = 0.1$ の方が相関係数 $\text{Cor}(\check{c}^t, \check{c})$ が大きくなる。ハイパーパラメータ K の調節方法については、4.4.6 節に後述する。

4.4.6 ハイパーパラメータ K の調整

提案手法は、ハイパーパラメータ K の値によって結果に違いが生じる。そのため、より正確な結果を得るには、ハイパーパラメータ K の調整が必要不可欠である。FLR は、目的変数の幅を区間として考えたとき、区間回帰分析 (Interval regression analysis) と呼ばれることがある [99]。石渕らは、外れ値が区間回帰分析にもたらず影響について「外れ値が排除されたとき、区間回帰分析の近似最適解 (目的関数) が大きく減少する」と述べ、区間回帰式に包含されるデータ数と近似最適解の二次元グラフを作成することで、解の候補を視覚的に意思決定者に示すといった方法を提案した [100]。つまり、回帰式に包含されるデータ数の変化に対応する目的関数の変化量を見ることで、適切なデータ数を決定できる。一方、本研究で用いる BOFR は、ハイパーパラメータ K の増加に応じて、解析に用いられるデータ数 $\text{card}(I')$ が単調減少するという性質を持つ。そのため、石渕らの手法を提案手法へ応用することは十分可能である。

条件 P のデータ群 (Table 4.1 参照) に関して、ハイパーパラメータ K (または解析データ数 $\text{card}(I')$) と目的関数 J_{LP} の傾き $dJ_{LP}/d\text{card}(I')$ との関係、ならびに相関係数 $\text{Cor}(\check{a}^t, \check{a})$, $\text{Cor}(\check{c}^t, \check{c})$ との関係を Fig. 4.7 に示す。図より、 $K = 0.1$ のとき $\text{Cor}(\check{a}^t, \check{a})$ および $\text{Cor}(\check{c}^t, \check{c})$ が大きくなっていることが分かる。また、今回使用したダミーデータは正常なデータ数の期待値が 475 個となるが、条件 P は $K = 0.1$ とした際に 479 個のデータが使用されており、期待値に近い値となったことから、本

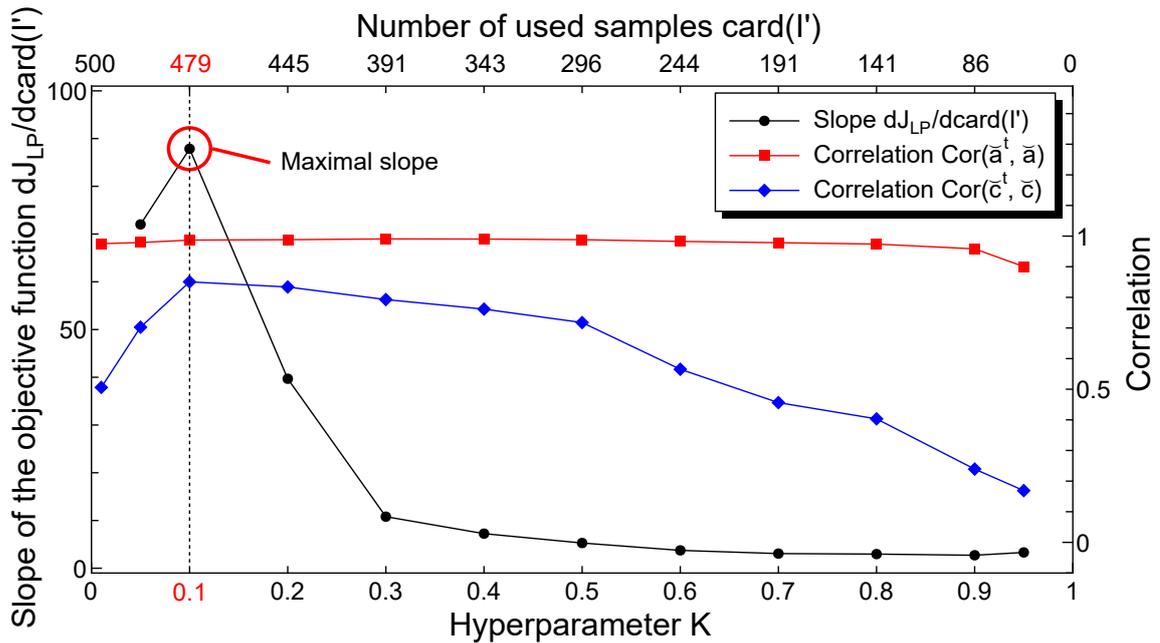


Fig. 4.7 : Relationship among a hyperparameter K (or the number of used samples $card(I')$), the slope of the objective function $dJ_{LP}/dcard(I')$, and the correlations $Cor(\vec{a}^t, \vec{a})$ and $Cor(\vec{c}^t, \vec{c})$. Condition P in Table 4.1 is utilized. The $card(I')$ turns smaller as the hyperparameter K increases, and the $dJ_{LP}/dcard(I')$ becomes the highest at the point of $K = 0.1$ ($card(I') = 479$). In this point, the correlations $Cor(\vec{a}^t, \vec{a})$ and $Cor(\vec{c}^t, \vec{c})$ become larger.

指標により正常値と外れ値を適切なバランスで分離できるといえる。

通常、提案手法による解析を行う際は、ファジィ係数の中心および幅の真値 \vec{a}^t , \vec{c}^t が未知であるため、相関係数の値からハイパーパラメータ K を調節することができない。しかし、 K を $0 < K < 1$ の範囲で任意に調整し、Fig. 4.7 のように目的関数の傾きが最大となる K の値を選択することで、より正確な解析結果を得ることが可能である。

4.5 看護師の回答データを用いた検証

4.5.1 アプリケーションの構築

つづいて、実際の看護師の回答データを用いた検証を行う（本検証は鳥取大学医学部附属病院の倫理審査委員会より承認を受けたものである（19A033））。本節で

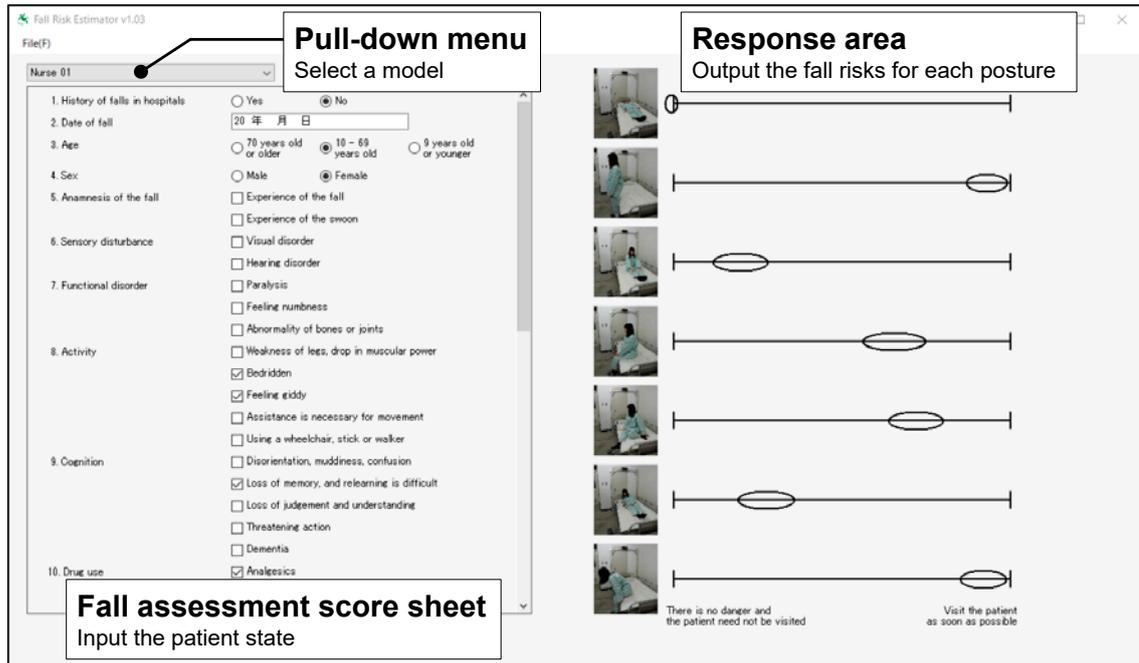


Fig. 4.8 : Execution window in the application

は、リスク判断の定量化手法を通じて得られたモデル式が、モデルとなった看護師本人の感性を反映しているか否かを確認するため、モデル式による推定結果と看護師による臨床判断との一致性について検証する。本実験では、複数の看護師からアンケート回答を収集し、看護師ごとに転倒・転落リスク推定モデルを構築する。その後、アンケートに協力した看護師に対し、自身の判断と似通った推定モデルを選択するよう依頼する。もし、看護師が自身のモデルを正しく選択することが可能ならば、そのモデルは看護師本人の判断基準が反映されている可能性が高く、提案手法の有効性が示唆される。

検証の際は、Fig. 4.8のアプリケーションを用いる。本アプリケーションは、画面左側のFASを記入すると、画面右側に転倒・転落リスクが自動的に算出される。また、画面左上のプルダウンメニューから、使用する看護師のモデルを選択できる。

4.5.2 実験条件

本実験では、看護師11名から回答データを取得した。このとき、看護師1名が回答するFASの個数は、4.4節の結果を鑑みると500例とするのが望ましいが、今回は看護師の実情を考慮して200例（つまり $k = 200$ ）とした。また、姿勢数は7通り

Table 4.3 : Estimation models selected by each nurse. Three choices are recorded. A bold font represents the model that matches the nurse's (respondent's) ID.

Nurse ID	First choice	Second choice	Third choice
01	05	03	01
02	02	11	05
03	03	11	06
04	04	05	01
05	10	05	01
08	11	01	03
10	02	09	08
11	02	06	08

とした（基本姿勢として「臥位」、「長座位」、「端座位」、「立位」の4通り、基本姿勢の中間として「臥位と長座位の中間姿勢」、「長座位と端座位の中間姿勢」、「端座位と立位の中間姿勢」の3通りを定めた）。その後、転倒・転落リスク推定モデルを看護師ごとに計11個作成し（ハイパーパラメータ K は全て0.2とした）、アプリケーション（Fig. 4.8）へと組み込んだ²。本検証では、各看護師にアプリケーションを操作してもらい、算出される転倒・転落リスクとして自身の判断に似通っていると考える推定モデルを第3候補まで回答する。

なお、推定モデルの評価指標の一つとして、観測値（看護師のアンケート回答）と推定値（モデル式の出力）との誤差率が挙げられる。しかし、本研究では看護師の回答をL-Lファジィ数として取得しているため、通常の数値データと同様の方法で誤差率を算出することが困難である。さらに、看護師の判断基準が推定モデルに反映されていることを決定づける誤差率の閾値が不明確である。こうした理由から、本検証では誤差率を使用しないこととした。

4.5.3 結果と考察

Table 4.3に結果を記す（回答が得られた8名のみを記載）。今回の調査では、11個の推定モデルの中から3個を選択するため、無作為に回答した場合はおよそ27.3%

²なお、提案手法は看護師および患者の姿勢ごとにFLSを行うことから、ファジィ係数 \check{a}_{LS} , \check{c}_{LS} 自体は77セット（看護師11名×姿勢数7通り）得られる。つまり、本実験を通じて作成される転倒・転落リスク推定モデルは、看護師1名当たり7セットのファジィ係数で構成されることになる。そのため、Fig. 4.8のアプリケーションでも回答欄を7つ設けている。

の看護師が自身のモデルを選択することになる。これに対し、Table 4.3を見ると、62.5%（8名中5名）の看護師が第3候補までに自身のモデルを選択しており、期待値である27.3%を大幅に上回っていることが分かる。本検証は、看護師個人に課すFASの個数を200例としており、ダミーデータを用いた検証（4.4節）と比べてモデル式の作成に使用するデータ数が少ない。しかし、データ数が少量の場合においても、提案手法は看護師が自身のモデルを識別できる程度には、臨床判断の定量化が可能である。

なお、今回の検証は、転倒・転落に関する判断基準が看護師間で異なるという前提で行われたが、一部の看護師の判断基準が類似する場合は、看護師08および11も適切な回答を行っている可能性がある。Table 4.3において看護師02、08、11の回答に着目すると、看護師02は看護師11を選択しており、看護師11も看護師02を選択している。さらに、看護師11は看護師08を選択しており、看護師08も看護師11を選択している。つまり、看護師02、08、11は互いのモデルを選択し合っている。今回の検証では、8名中5名の看護師が自身のモデルを識別できた。ただし、看護師02、08、11の判断基準が類似する場合、間接的ではあるものの8名中7名の看護師が適切なモデルを選択できたといえる。

これらの結果は、作成された推定モデルが看護師個人の判断基準を反映できており、提案手法が有効であることを示唆するものである。

4.6 本章のまとめ

第4章では、看護師の臨床判断を定量化するにあたり、臨床現場で実際に使われているFASに基づいて転倒・転落リスクを判断するアンケートを例にして、多次元チェック項目に対する意思決定の定量化（モデル化）手法について提案した。このとき、臨床判断の迷いを観測するアンケート用紙も新たに提案した。提案手法の有効性を確認するため、ダミーの回答データに対して提案手法を適用し、ファジィ係数の真値と推定値との相関を確認した。その結果、ファジィ係数の中心の生成範囲が幅の生成範囲より同等以上に広い場合、データ数が500個かつ外れ値処理を行うと、ファジィ係数の中心だけでなく、幅に関しても相関係数が全て0.7以上となり、いずれも強い相関を示した。これらの結果は、看護師がFASの中で重視するチェック項目の抽出のみならず、その項目に対する判断の迷いも高い精度で定量化できることを示唆している。つまり、判断の迷いがチェック項目に起因して発生する場合、

提案手法によって看護師の判断基準をより忠実に抽出できるといえる。

さらに、実際の看護師から回答データを収集し、提案手法によって転倒・転落リスク推定モデルを構築した。その後、看護師が自身の推定モデルを識別可能か検証した結果、8名中5名の看護師が第3候補までに自身のモデルを選択していた。本結果は、提案手法が6割以上の看護師の感性を反映しており、妥当性が十分にあることを示すものである。

以上より、提案手法はダミーデータと実際の回答データを用いた検証を通じて、理論的な部分だけでなく実用的な観点からも有効性があることが明らかになった。よって、将来的には熟練看護師の判断基準を実装したアプリケーションの実現が期待できる。新人看護師は本アプリケーションを利用することで、自身のトレーニングや質の高いアセスメントへと繋げられる。

第5章 あいまいさを含む臨床判断の モデル化～過学習の軽減～

5.1 本章の目的

第5章では、転倒・転落リスク推定モデルの作成時に看護師から十分なデータ数を確保できないケースに焦点を当て、少量のデータ数でモデル式を構築した際に生じる過学習の軽減を目的とした解析手法を提案する。

医療現場において、看護師は転倒・転落アセスメントスコアシート（FAS）に基づく臨床判断を行っている。一方、患者の病状や処方が変わるたびにFASのチェック内容に変化があることから、看護師は都度臨床判断を行う必要があり、大きな負担となっている。そのため、臨床判断の自動化が望まれるが、FASに基づいて看護師自身が臨床判断をする際に生じるあいまいさ（迷い）があることから [39]、その実現は難しいとされていた。そこで筆者は、看護師が臨床判断を行う際に生じる迷いをファジィ数として取得可能なアンケート用紙、ならびにファジィ線形回帰分析を用いたアンケート解析手法を第4章で提案した。また、看護師の判断を模したダミーデータによる検証の結果、看護師個人から500例以上のアンケート回答を得ることで、その看護師が持つあいまいさを含んだ臨床判断を正確にモデル係数として反映可能であることを見出した。しかし、一般的に看護師の業務は多岐にわたり多忙なものであるため、病院によっては500例ものアンケートを個人に課すのは現実的ではない。そのため、提案していたモデル化手法には実現場にて応用するにあたって、十分な学習データ数を確保するのが困難な場合がある。

一般論としてモデル化に用いる学習データ数が少ない場合は、モデル式が学習データに過剰に適合するため、適切なモデル係数を推定できず過学習が生じやすい。ただし、こうした過学習はモデル式の次元数を低くすることで軽減できるといわれている [101,102]。つまり、モデル化の前に目的変数との関係性（相関）が低い説明変数を削除し、次元を落とした簡易モデル（スパースモデル）へと変更することで、学習データの過剰適合が緩和される。その結果として過学習の軽減が期待される。さ

らに、次元数が低いほどモデル化に必要な学習データ数（今回はアンケート数）も少なくて済む。以上より、実現場への適用を視野に入れる際、データ数の不足に起因する問題は、説明変数の過多とそれに伴う過学習の発生と置き換えることができる。

そこで第5章では、モデル式に用いるFASの項目数をアンケートデータの特徴を踏まえて削減することで、過学習を軽減する解析手法を新たに提案する。これにより、目的変数を推定するにあたって少ないデータ数でもモデル構築が可能となり、アンケート回答時に看護師へ与える負担を軽減できる。さらに、FASのチェック項目を無作為に削減した結果や、提案する項目削減手順とは逆の順序を適用した結果と比較することで、提案手法の有効性を確認する。

5.2 ファジィ理論に基づく臨床判断の解析

5.2.1 ファジィグラフ尺度法を用いたアンケート

本章では第4章と同様、「看護師個人が感じる転倒・転落の危険性」を転倒・転落リスクと定め、看護師へアンケートを実施する。アンケート用紙としては、Fig. 4.1(a)および(c)を用いた。看護師は、(a)に示すFASのチェック項目を確認後、(c)の線分両端に記された内容を基準として、自身が感じる転倒・転落リスクを線分上に回答する。このとき、回答は患者の姿勢ごとに行う。

アンケートの収集後は、解析の対象とする姿勢を一つ選択する。そして、第*i*番目のFASにおいて、チェックマークの有無を表すベクトル \mathbf{x}_i を説明変数、看護師の回答 Y_i を目的変数と定める (Eq. (5.1))。

$$\mathbf{x}_i = (x_{i,1} \ x_{i,2} \ \cdots \ x_{i,n_{all}}) \quad Y_i = (y_i, e_i)_L \quad (5.1)$$

ここで、 \mathbf{x}_i の各要素はチェックマークなしを0、ありを1とする質的変数である。一方、 Y_i はL-Lファジィ数 (5.2.2節参照) であり、Eq. (5.2)により中心 y_i と幅 e_i に変換される。

$$y_i = \frac{y_i^+ + y_i^-}{2} \quad e_i = \frac{y_i^+ - y_i^-}{2} \quad (5.2)$$

本研究では、看護師の迷いを含む判断をファジィ数として扱う。

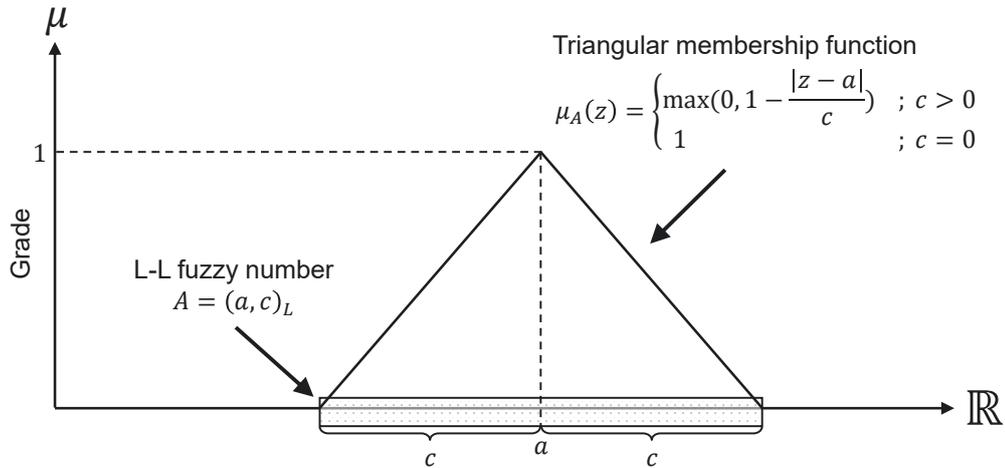


Fig. 5.1 : L-L fuzzy number A that consists of the mean a and spread c . $\mu_A(z)$ is the degree to which a real number $z (\in \mathbb{R})$ belongs to A . The range of $\mu_A(z)$ is 0 to 1 (i.e., $0 \leq \mu_A(z) \leq 1$).

5.2.2 L-L ファジィ数の演算規則

Fig. 5.1 に L-L ファジィ数の一例を記す. ファジィ数は「だいたい a ぐらいの数」のようなあいまいな事象に対して用いられ, Eq. (5.3) のように定義される [63]. 式中の c, d はあいまいさの大きさを表す.

$$A = (a, c)_L \quad B = (b, d)_L \tag{5.3}$$

一方, Fig. 5.1 の縦軸は帰属度であり, ファジィ数 A に帰属する度合い (A らしさ) を 0~1 で表す. 帰属度の変化は, Eq. (5.4) のように定義される. Eq. (5.4) は三角型メンバーシップ関数と呼ばれ, ファジィ理論の中で広く活用されている.

$$\mu_A(z) = \begin{cases} \max(0, 1 - \frac{|z - a|}{c}) & ; c > 0 \\ 1 & ; c = 0 \end{cases} \tag{5.4}$$

さらに, Eq. (5.5)~(5.8) に L-L ファジィ数の四則演算を示す. 坂和が自身の著書 [63] に記した式を用いる場合, Eq. (5.3) の A と B には以下の公式 (近似公式) が

成り立つ.

$$A \oplus B = (a + b, c + d)_L \quad (5.5)$$

$$A \ominus B = (a - b, c + d)_L \quad (5.6)$$

$$A \otimes B \simeq (ab, |ad| + |bc|)_L \quad (5.7)$$

$$A \oslash B \simeq \begin{cases} \left(\frac{a}{b}, \frac{|ad| + |bc|}{b^2} \right)_L & ; b \neq 0 \\ (0, 0)_L & ; b = 0 \end{cases} \quad (5.8)$$

ただし, Eq. (5.8) は $b = 0$ のとき $(0, 0)_L$ とした.

5.2.3 ファジィ最小二乗法によるモデル化

説明変数や目的変数にファジィ数を含むデータを解析する方法として, ファジィ最小二乗法 (FLS: Fuzzy Least Squares) [95] が挙げられる. FLS では, 説明変数と目的変数の回帰式 (モデル式) を Eq. (5.9) と定める.

$$\begin{aligned} \hat{Y}_i &= A_0 \oplus A_1 \otimes x_{i,1} \oplus A_2 \otimes x_{i,2} \oplus \cdots \oplus A_n \otimes x_{i,n} \\ &\oplus \bar{A}_1 \otimes \bar{x}_{i,1} \oplus \bar{A}_2 \otimes \bar{x}_{i,2} \oplus \cdots \oplus \bar{A}_n \otimes \bar{x}_{i,n} \end{aligned} \quad (5.9)$$

式中の A_j は, 中心 a_j と幅 c_j で構成されるファジィ係数である ($A_j = (a_j, c_j)_L$). 一方, \bar{A}_j は, $x_{i,j}$ の NOT 部 $\bar{x}_{i,j} (= 1 - x_{i,j})$ のファジィ係数であり ($\bar{A}_j = (\bar{a}_j, \bar{c}_j)_L$), 区間増加問題 [89] を緩和する役割を担う.

FLS ではファジィ数に距離概念を導入し, 目的変数の推定値 \hat{Y}_i と観測値 Y_i との誤差の総和が最小となるファジィ係数を探索する. Eq. (5.9) の各変数を

$$\check{\mathbf{a}} = (a_0 \ a_1 \ a_2 \ \cdots \ a_n \ \bar{a}_1 \ \bar{a}_2 \ \cdots \ \bar{a}_n)^T ; \forall \bar{a}_j = 0 \quad (5.10)$$

$$\check{\mathbf{c}} = (c_0 \ c_1 \ c_2 \ \cdots \ c_n \ \bar{c}_1 \ \bar{c}_2 \ \cdots \ \bar{c}_n)^T ; \forall c_j, \bar{c}_j \geq 0 \quad (5.11)$$

$$\check{\mathbf{x}}_i = (1 \ x_{i,1} \ x_{i,2} \ \cdots \ x_{i,n} \ \bar{x}_{i,1} \ \bar{x}_{i,2} \ \cdots \ \bar{x}_{i,n})^T \quad (5.12)$$

$$; \forall x_{i,j} = 0 \text{ or } 1, \bar{x}_{i,j} = 1 - x_{i,j}$$

とすると, FLS の一般式は Eq. (5.13) と表される.

$$\text{minimize } J_a = \sum_{i \in I} (y_i - \check{\mathbf{a}}^T \check{\mathbf{x}}_i)^2 \quad (5.13)$$

$$\text{minimize } J_c = \sum_{i \in I} (e_i - \check{\mathbf{c}}^T \check{\mathbf{x}}_i)^2$$

$$\text{subject to } \forall \bar{a}_j = 0, \forall c_j, \bar{c}_j \geq 0$$

なお, Eq. (5.10)～(5.13) の I , n はそれぞれ FLS に使用するアンケート回答の集合および FAS の項目数を表す¹.

5.2.1 節にて, 解析の対象とする姿勢を変更し, FLS を個々に適用する. FLS を用いた解析により, 看護師が FAS のチェック項目を重視する程度 α だけでなく, チェック項目により生じるあいまいさ ϵ を含むモデル式を患者の姿勢ごとに作成できる.

5.2.4 従来手法の問題点

5.2.1～5.2.3 節では, 目的変数をファジィ数とするアンケート解析手法を記した. しかし, 従来手法は FLS の際に全説明変数を用いており, モデル式の作成に多くの学習データを必要とする. 一般的に, 説明変数の次元数が多いと, 回帰分析の際に過学習が生じ, 未知のデータに対する目的変数の推定精度が低下する [101,102]. こうした過学習は, 説明変数の次元数に対して学習データの個数が少ない場合に深刻化しやすい. しかし, 看護師に FAS の項目数を削減させることは業務上許されることではなく, また, あまりにも多くのアンケートを依頼することは看護師の負担を増やす行為であり, 必ずしも最良の選択とはいえない. そのため, 本章では目的変数との関係性に基づいて説明変数を削減する. モデル式にほとんど寄与しない説明変数を事前に取り除くことで, FLS による解析が必要なファジィ係数の個数を減らすことができる. これにより, ファジィ係数の過剰適合を軽減でき, かつ, 学習データ数も少なく済む.

一方, 説明変数が質的変数, 目的変数が量的変数となるデータの回帰分析を数量化 I 類と呼ぶ. 数量化 I 類では, モデル式に用いる説明変数を選択する方法が既に存在する. 本章では, 数量化 I 類における説明変数の選択手法をファジィ理論に基づき改良する. 各々の詳細を 5.3 節に記す.

¹第4章の Eq. (4.3)～(4.13) では FLS に使用する FAS の項目数 (モデル式の次元数) を n_{all} と固定していた. 一方, 第5章の手法は扱うデータセットに応じてモデル式の次元数が変化する. そのため, 第5章では n_{all} (定数) ではなく n (変数) によって, モデル式の次元数を表すこととする.

5.3 過学習を軽減するモデル化手法

5.3.1 概要

Fig. 5.2 に提案手法の概要を示す. 本提案手法は (a)～(d) の4ステップで構成されるが, 説明変数の選択自体は (a) と (d) で行われる. (a) では説明変数の項目数を n_{all} から n_{crv} へ, (d) では n_{crv} から n_{opt} へと削減する. このとき, (d) ではモデル式から説明変数を1つずつ削除し, その都度 FLS を行うことでモデル式に用いる項目数 n_{opt} を決定している. (b) および (c) は, (d) で説明変数を削除するための前準備を行う (説明変数をソートすることで削除する順序を決定).

なお, 本提案手法は看護師から取得可能な学習データ数が少量の場合を想定しており, こうした状況下で全説明変数を用いて FLS を行うと, モデル式が学習データに過剰に適合し, 適切なファジィ係数を算出できない. そのため, 本章では一般的な方法論であるファジィ係数の値を利用した説明変数の削減は行わない.

一方, 昔は自身の著書 [78] で数量化I類の事例を扱う中で, 相関比によって目的変数に影響を及ぼしている説明変数を把握し, 相関比の低い項目はモデル式から削除するという方針を提案した. 相関比を用いることで, 目的変数の推定に不要な説明変数を削除できるため, モデル式の精度向上が期待される. また, 説明変数の次元数が低減されるため, 学習データの過剰適合が緩和される. さらに, 相関比は説明変数ごとに個別に算出されるといった特徴があるため, 説明変数の次元数による影響がなく, 次元数が多い場合でも常に一律した解を得ることが可能である (ファジィ係数と異なり, 解析に用いる説明変数の組み合わせによって結果が変化しない).

以上の理由から, Fig. 5.2(d) では相関比に基づいて説明変数の選択を行う. ただし, 今回は目的変数がファジィ数であることから, 本手法をそのまま適用できない. そのため, (b) ではファジィ数の演算規則 (5.2.2 節参照) に基づいて相関比を求める. また, (c) ではファジィ数の可能性測度に基づいて, 算出された相関比の並び替えを行う.

5.3.2 クラメール連関係数による説明変数の選択

数量化I類を適用する際に, 説明変数相互で相関の高い組み合わせがあるとモデル係数を上手く求められないことは理論的に証明されており, こうした現象を多重共線性と呼ぶ [78]. そのため, まずはクラメール連関係数 (CrV: Cramér's V) [103]

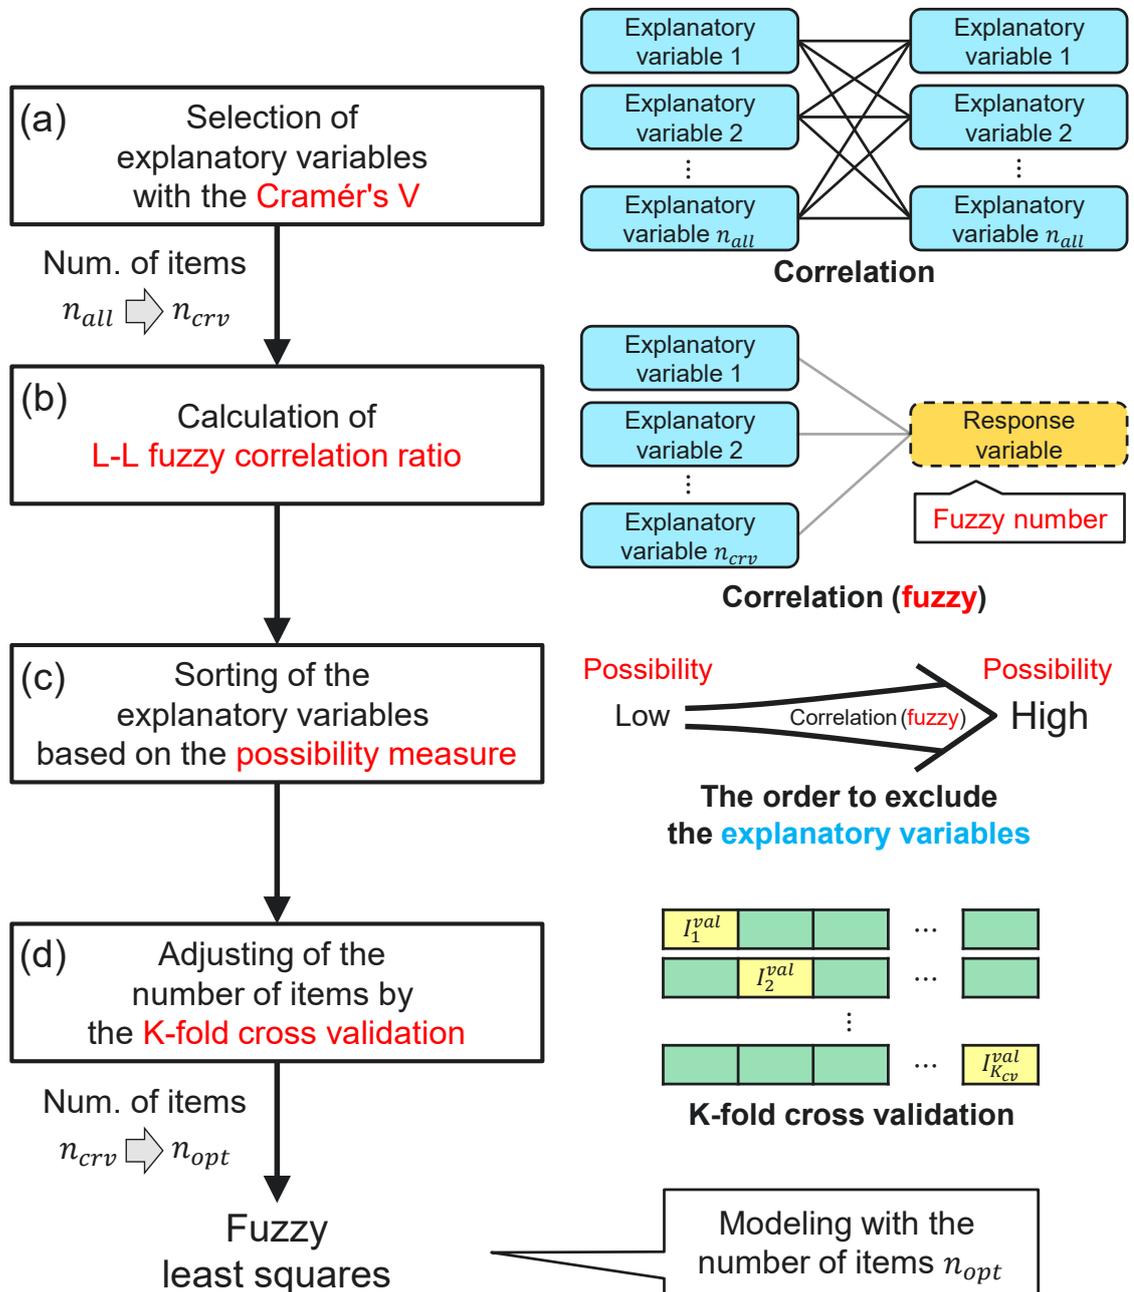


Fig. 5.2 : Concept of the proposed method. A selection method of explanatory variables in the quantification theory type-I is reformed based on the fuzzy theory.

によって説明変数間の相関を確認することで、多重共線性を防止する。説明変数のカテゴリ数が2のとき、CrVはEq. (5.14)により求まる。ここで、 $\chi^2(j, j')$ は項目 j と j' のカイ二乗値、 k は全データ数、 $r_{crv}(j, j')$ は項目 j と j' のCrVを表す。

$$r_{crv}(j, j') = \sqrt{\frac{\chi^2(j, j')}{k}} \quad (5.14)$$

$r_{crv}(j, j')$ がある閾値よりも高くなる組み合わせが生じたときは、説明変数の一方をモデル式から削除する。これにより、多重共線性を回避できる。

CrVにより、説明変数の項目数を n_{all} から n_{crv} へと削減する。

5.3.3 L-L ファジィ相関比の算出

つぎに、説明変数と目的変数の相関を確認する。両者の関係は、一般的に相関比 [78] で表されるが、本指標はそのままの状態ではファジィ数を扱えない。そのため、本節では従来の相関比をファジィ数の演算規則 (5.2.2節参照) により拡張したL-L ファジィ相関比を新たに定義する。

- 1) 説明変数の全カテゴリを含む集合を $U = \{u \mid u = 0, 1\}$ とする。項目 j の説明変数 $x_{i,j}$ において、識別番号 i の集合 $I^{(j)}$ と、 $x_{i,j} = u$ を満たす i の集合 $I_u^{(j)}$ をそれぞれ定める。

$$\begin{cases} I^{(j)} = \{i \mid i = 1, 2, \dots, k\} \\ I_u^{(j)} = \{i \mid x_{i,j} = u\} \end{cases} \quad (5.15)$$

- 2) 目的変数の観測値 Y_i の全体平均 $\bar{Y}^{I^{(j)}}$ と群別平均 $\bar{Y}^{I_u^{(j)}}$ を以下により求める。

$$\begin{cases} \bar{Y}^{I^{(j)}} = \left(\sum_{i \in I^{(j)}}^{\oplus} Y_i \right) \oslash \text{card}(I^{(j)}) \\ \bar{Y}^{I_u^{(j)}} = \left(\sum_{i \in I_u^{(j)}}^{\oplus} Y_i \right) \oslash \text{card}(I_u^{(j)}) \end{cases} \quad (5.16)$$

ここで、 \sum^{\oplus} はファジィ数の総和を表す。また、 $\text{card}(I^{(j)})$, $\text{card}(I_u^{(j)})$ は各集合の要素数 (濃度) であり、非ファジィ数となる。

3) 誤差変動（級内変動） S_j^W と群間変動（級間変動） S_j^B を以下よりそれぞれ求める．

$$\begin{cases} S_j^W = \sum_{u \in U}^{\oplus} \sum_{i \in I_u^{(j)}}^{\oplus} \{(Y_i \ominus \bar{Y}^{I_u^{(j)}}) \otimes (Y_i \ominus \bar{Y}^{I_u^{(j)}})\} \\ S_j^B = \sum_{u \in U}^{\oplus} \{\text{card}(I_u^{(j)}) \otimes (\bar{Y}^{I_u^{(j)}} \ominus \bar{Y}^{I^{(j)}}) \otimes (\bar{Y}^{I_u^{(j)}} \ominus \bar{Y}^{I^{(j)}})\} \end{cases} \quad (5.17)$$

4) S_j^W と S_j^B から，L-L ファジィ相関比 H_j^2 を算出する．

$$H_j^2 = S_j^B \otimes (S_j^W \oplus S_j^B) \quad (5.18)$$

全ての説明変数に対し，上記の解析を実施する．

5.3.4 可能性測度に基づく説明変数のソート

5.3.3節では，説明変数と目的変数のL-L ファジィ相関比を求めた．通常の数値化I類では，説明変数は相関比の低い方から優先的に削除される [78]．しかし，L-L ファジィ相関比はファジィ数であり，大小関係が一概には定まらない．そのため，ファジィ数の可能性測度 [104] によって，ファジィ数間の比較を行う．

1) 項目 j ， j' のL-L ファジィ相関比をそれぞれ H_j^2 ， $H_{j'}^2$ とする．

$$H_j^2 = (\eta_j^2, l_j^2)_L \quad H_{j'}^2 = (\eta_{j'}^2, l_{j'}^2)_L \quad (5.19)$$

ここで， H_j^2 および $H_{j'}^2$ はL-L ファジィ数であり， η_j^2 ， $\eta_{j'}^2$ はファジィ数の中心， l_j^2 ， $l_{j'}^2$ はファジィ数の幅を表す．

2) Dubois と Prade の大小関係の指標 [104] により， $H_j^2 > H_{j'}^2$ となる可能性 $\text{Pos}(H_j^2 > H_{j'}^2)$ を求める．ファジィ数の帰属度が Eq. (5.4) に従い変化する場合， $\text{Pos}(H_j^2 > H_{j'}^2)$ は Eq. (5.20) により算出される．

$$\text{Pos}(H_j^2 > H_{j'}^2) = \begin{cases} 1 & ; \eta_{j'}^2 + l_{j'}^2 \leq \eta_j^2 \\ 0 & ; \eta_j^2 + l_j^2 \leq \eta_{j'}^2 \\ 1 - \frac{z' - \eta_j^2}{l_j^2} & ; \text{otherwise} \end{cases} \quad (5.20)$$

ただし，

$$z' = \frac{l_j^2 l_{j'}^2 + \eta_j^2 l_{j'}^2 + \eta_{j'}^2 l_j^2}{l_j^2 + l_{j'}^2}$$

である。Pos($H_j^2 > H_{j'}^2$) は0～1の値であり、1に近いほど $H_j^2 > H_{j'}^2$ が真となる可能性が高い。全ての j' に対し、Pos($H_j^2 > H_{j'}^2$) を求める。

- 3) 項目 j の可能性測度平均 $\overline{\text{Pos}(H_j^2)}$ を求める。

$$\overline{\text{Pos}(H_j^2)} = \frac{1}{n_{crv}} \sum_{j'=1}^{n_{crv}} \text{Pos}(H_j^2 > H_{j'}^2) \quad (5.21)$$

全ての項目に対し、同様に平均を求める。 $\overline{\text{Pos}(H_j^2)}$ が小さい項目ほど目的変数との関係性が低く、モデル式から優先的に削除できる。

5.3.5 K-分割交差検証による項目数の決定

最後に、K-分割交差検証 (K-fold cross validation)²によりモデル式に使用する項目数を決定する。K-分割交差検証では、観測データを学習データと検証データに分け、汎化性能が高くなるパラメータを推定する。

- 1) 観測データ I を交差数 K_{cv} で分割する。 l ($= 1, 2, \dots, K_{cv}$) 回目の検証における、学習データの識別番号 i の集合を I_l^{train} 、検証データの識別番号 i の集合を I_l^{val} とする。
- 2) I_l^{train} において、モデル式に用いる項目数 n を $n_{crv}, n_{crv} - 1, n_{crv} - 2, \dots, 2, 1$ と変化させながら FLS を行う。このとき、項目 j は $\overline{\text{Pos}(H_j^2)}$ が小さいものから順に (昇順に) 削除する。
- 3) 項目数 n のときの目的変数の推定値を $\hat{Y}_{i,n}$ と置く。また、 $\hat{Y}_{i,n}$ の中心を $\hat{y}_{i,n}$ 、両端を $\hat{y}_{i,n}^-, \hat{y}_{i,n}^+$ とする。Eq. (5.22) より、検証データ I_l^{val} との誤差 $E^{val}(l, n)$ を求める。

$$E^{val}(l, n) = E_{sum}^{val}(l, n) / \text{card}(I_l^{val}) \quad (5.22)$$

²機械学習におけるモデル評価手法の一つ。K-分割交差検証では、学習プロセスにおいて、全データを学習データ (Training dataset) と検証データ (Validation dataset) (またはテストデータ (Test dataset)) に分割し、モデルの評価を行う。このとき、全データは K 個のサブセットへとランダムに分割されるが、サブセットは一般的にフォールド (Fold) と呼ばれる。これらのフォールドごとに、現在のフォールド以外 ($K - 1$ 個) のデータを使ってモデルのトレーニング (学習) を行い、その後残った1個のフォールドのデータを使って予測 (検証またはテスト) を行う [105]。

ただし,

$$E_{sum}^{val}(l, n) = \frac{1}{3} \sum_{i \in I_l^{val}} (|y_i - \hat{y}_{i,n}| + |y_i^- - \hat{y}_{i,n}^-| + |y_i^+ - \hat{y}_{i,n}^+|)$$

である. なお, ファジィ数間の距離を推定する際は, ファジィ数の中心 y_i , $\hat{y}_{i,n}$ と両端 y_i^- , y_i^+ , $\hat{y}_{i,n}^-$, $\hat{y}_{i,n}^+$ を代表点として選択することから [90], Eq. (5.22) の $E_{sum}^{val}(l, n)$ ではこれらの値を用いている.

- 4) K_{cv} 回目 ($l = K_{cv}$) の検証を終えた後, 全交差の平均 $\bar{E}^{val}(n)$ を Eq. (5.23) より求める.

$$\bar{E}^{val}(n) = \frac{1}{K_{cv}} \sum_{l=1}^{K_{cv}} E^{val}(l, n) \quad (5.23)$$

- 5) $\bar{E}^{val}(n)$ が最小となる n を, 最終的な項目数 n_{opt} とする.

$$n_{opt} = \operatorname{argmin}_n \bar{E}^{val}(n) \quad (5.24)$$

- 6) 全観測データ $I \in I_l^{train} + I_l^{val}$ を用いて, 項目数 n_{opt} で FLS を行う.

以上の方法により, 過学習を軽減したモデルを構築できる.

5.4 看護師の回答データを用いた検証

5.4.1 目的と方針

つづいて, 提案手法の過学習軽減効果の有無を確認する. 過学習という現象に関して, 神寫らは自身の著書 [101] にて「訓練誤差と汎化誤差にはギャップがあるが, このギャップのために訓練誤差が小さくとも汎化誤差が大きくなってしまいう問題」と述べた. ここで, 訓練誤差とは学習データに対する誤差, 汎化誤差とはテストデータ (未知のデータ) に対する誤差を表す. 神寫らの発言に従うならば, 過学習が持つ問題とは「テストデータに対する誤差が大きくなること」だといえる. そのため, 「過学習の軽減」とは「テストデータに対する誤差を小さくすること」と同義であり, 提案手法の適用前後において「テストデータに対する誤差が提案手法適用前より小さくなったこと」を示すことで, 提案手法に過学習軽減効果があることが裏付けられる.

Table 5.1 : Experimental conditions

Data collection	Affiliation of nurses	Tottori University Hospital
	Number of subjects (nurses)	3
	Number of FASs card($I_i^{train} + I_i^{val} + I_i^{test}$)	300 (per nurse)
	Number of postures	4
	Line length in the response area	152 mm
Data analysis	Number of division in a dataset	12
	Allocation of each divided dataset	Training 10, Validation 1, Test 1
	Number of all items in the FAS n_{all}	50
	Number of items after applying CrV n_{crv}	49

よって、本検証では提案手法適用前の誤差と適用後の誤差を比較する。ただし、提案手法の適用前後における誤差の変化量を単に確認するだけでは、その変化が偶然発生したという可能性を否定できない。そのため、今回は2標本t検定を用いて、テストデータに対する誤差の変化を検定する。2標本t検定とは、2つの標本の平均値の差を検定することであり、本検定を通じて有意差が確認された場合は、その差が統計的に意味のあるものだと（つまり偶然発生したものではないと）結論付けることが可能である。一方、筆者は先ほど「過学習の軽減」とは「テストデータに対する誤差を小さくすること」と同義であると述べた。そのため、「有意差が確認された」とは直接的には「テストデータに対する誤差が小さくなったこと」を表すが、間接的には「過学習が軽減されたこと」を示すことになる。よって、今回の検証では、2標本t検定の結果をもって過学習軽減効果の有無を判断する。

なお、転倒・転落に関する臨床判断が看護師間で共通せず個人差があることは、先行研究にて既に明らかになっている [21, 36, 37]。こうした個人差が存在する現状で、複数の看護師の回答を交えたとしても、統一的なモデルを作成できないのは明らかである。よって、本実験では先行研究の知見を踏まえ、個々の看護師に対してモデル構築および2標本t検定を行う。

5.4.2 実験条件

5.4.1 節に示す方針の下、実際の看護師の回答を用いた検証を行う（本検証は鳥取大学医学部附属病院の倫理審査委員会より承認を受けたものである（19A033））。Table 5.1 に実験条件を示す。今回は、鳥取大学医学部附属病院に勤める看護師3名から回答を取得しており、FASも同病院（Fig. 4.1(a)）のものを用いた。ただし、「年

齢 (Age)」については「9歳以下 (9 years old or younger)」のカテゴリを削除した³. また、患者の姿勢は臥位 (Lying down), 長座位 (Long sitting), 端座位 (Sitting sideways), 立位 (Standing) の4姿勢とした. さらに, K-分割交差検証の前に, CrV が唯一0.5以上となった説明変数の組み合わせ「入院中の転倒の有無 (History of falls in hospitals)」, 「転倒, 転落したことがある (Experience of the fall)」の内, 「入院中の転倒の有無」を削除する⁴. しかし, 削除する項目の決定には解析者の見解が介入する余地を含む. さらに, 非ファジィ数となる説明変数間に強い相関があると, 多重共線性が生じるのは既知の事実である [78]. そのため, 今回はCrV後 (項目数 n_{crv}) を基準として, 作成されたモデルの評価を行う.

なお, 通常のグラフ尺度法は線分の長さが100mmであるが, 今回のアンケートは楕円による回答が可能であり, より多くのスペースが必要になるため152mmまで拡張した. また, 看護師個人へ依頼するアンケート数は300例に留めており, その内学習データに250例 (4.4節の実験条件の一つ) を割り当てている.

5.4.3 検証手順

本実験では, $K = 12$ とする K-分割交差検証を行い, 説明変数を削減した際の誤差の変化を確認する. 検証の手順を以下に示す.

- 1) 全データを12個に分割し, その内の1個をテストデータに割り当てる.
- 2) $l' (= 1, 2, \dots, 12)$ 回目の検証において, $K_{cv} = 11$ として5.3.3～5.3.5節の手順に従い, 学習データと検証データから項目数 n_{opt} を求める.
- 3) 項目数 n_{opt} でFLSを行う (このときテストデータを使用しない). 作成したモデル式を使い, テストデータとの誤差 $E^{test}(l', n_{opt})$ を求める. また, 項目数 n_{crv} でFLSを行い, テストデータとの誤差 $E^{test}(l', n_{crv})$ を算出する.
- 4) テストデータの割り当てを変えながら2), 3)を計12回実施する.

³鳥取大学医学部附属病院のFASは, 「年齢 (Age)」の欄に「70歳以上 (70 years old or older)」と「9歳以下 (9 years old or younger)」の2つの評価内容が存在する. しかし, モデル式に両方とも使用すると, 「年齢」だけ説明変数のカテゴリ数が3となり, FLSの適用が困難となる. そのため, 入院患者数の少ない「9歳以下」を削除することで, カテゴリ数を2とした.

⁴「入院中の転倒の有無 (History of falls in hospitals)」は患者が入院した後, 実際に転倒・転落事故に遭うまでチェックマークの有無が確定しない. これは, 転倒・転落事故の防止という目的と相反することから本項目を削除した.

- 5) 各交差 l' の n_{opt} , $E^{test}(l', n_{opt})$, $E^{test}(l', n_{crv})$ から, 全交差の平均 \bar{n}_{opt} , $\bar{E}^{test}(n_{opt})$, $\bar{E}^{test}(n_{crv})$ をそれぞれ算出する.
- 6) Eq. (5.25) により, 差分 \bar{E}^- (Sub: Subtraction) および変化率 $\bar{E}^%$ (Rate: Rate of change) を求める.

$$\begin{cases} \bar{E}^- = \bar{E}^{test}(n_{opt}) - \bar{E}^{test}(n_{crv}) \\ \bar{E}^% = \frac{\bar{E}^{test}(n_{opt}) - \bar{E}^{test}(n_{crv})}{\bar{E}^{test}(n_{crv})} * 100 \end{cases} \quad (5.25)$$

\bar{E}^- および $\bar{E}^%$ は誤差が改善した程度を示す指標であり, 負値は誤差が改善したこと, 正値は誤差が悪化したことを表す.

5.4.4 結果

Table 5.2 に説明変数削減後の項目数 (Num: Number of items) と誤差 (Err: Error) を示す. 表中の $\bar{E}^{test}(n_{crv})$ は説明変数削減前 (項目数 n_{crv}) の誤差の平均, \bar{n}_{opt} は説明変数削減後の項目数の平均, $\bar{E}^{test}(n_{opt})$ は誤差の平均を表す. また, \bar{E}^- と $\bar{E}^%$ は, それぞれ誤差の差分および変化率である. さらに, 「昇順 (Ascending order)」は可能性測度平均の低い方から説明変数を削除したときの結果 (提案手法の結果), 「無作為 (Random order)」は説明変数をランダムな順に削除したときの結果, 「降順 (Descending order)」は可能性測度平均の高い方から削除したときの結果を表す.

一方, 表中の「平均 (Average)」は各結果の平均値であり, 看護師ごとに算出される. ただし, 5.5.1 節に後述する理由により, 「臥位 (Lying down)」の結果は平均を求める際に使用せず, 2 標本 t 検定の対象からも除外する. 「昇順」に関して, 差分 \bar{E}^- の平均を各々確認すると, 看護師 1 は -0.80mm , 看護師 2 は -0.73mm , 看護師 3 は 0.27mm であった. 本検証では, これらの差分に対して 2 標本 t 検定を各々適用することで, 有意差の有無を判断する.

説明変数削減前の誤差 $E^{test}(l', n_{crv})$ と削減後の誤差 $E^{test}(l', n_{opt})$ について, 両平均値の有意差を確認するため, サンプルサイズを 36 (看護師 1 名 \times 姿勢数 3 通り \times 交差数 12 個), 帰無仮説を「説明変数削減前と削減後の平均値は等しい», 対立仮説を「説明変数削減後の平均値は削減前より小さい», 有意水準を 1% (0.01), 5% (0.05), 10% (0.10) と定め, 2 標本 t 検定 (標本間の対応あり, 片側検定) を行い p 値を算出する. このとき, 提案手法である「昇順」だけでなく, 比較手法にあたる「無作為」および「降順」についても検定を行う. また, 有意水準についても複

Table 5.2 : List of the Number of items (Num) and Error (Err). The Subtraction (Sub) \bar{E}^- and Rate of change (Rate) $\bar{E}^{\%}$ were derived by Eq. (5.25).

Nurse and posture	Original			Ascending order (proposed)			Random order			Descending order			
	Err [mm] $\bar{E}^{test(n_{err})}$	Num \bar{n}_{opt}	Err [mm] $\bar{E}^{test(n_{opt})}$	Sub [mm] \bar{E}^-	Rate [%] $\bar{E}^{\%}$	Num \bar{n}_{opt}	Err [mm] $\bar{E}^{test(n_{opt})}$	Sub [mm] \bar{E}^-	Rate [%] $\bar{E}^{\%}$	Num \bar{n}_{opt}	Err [mm] $\bar{E}^{test(n_{opt})}$	Sub [mm] \bar{E}^-	Rate [%] $\bar{E}^{\%}$
1	Lying down*	3.16	4.25	2.33	-0.83	-26.27	12.50	3.05	-0.11	-3.48	49.00	3.16	0.00
	Long sitting	18.26	24.00	17.26	-1.00	-5.48	16.42	17.55	-0.71	-3.89	36.83	17.76	-2.74
	Sitting sideways	18.23	21.08	17.20	-1.03	-5.65	26.08	17.87	-0.36	-1.97	43.00	19.20	5.32
	Standing	17.03	31.67	16.67	-0.36	-2.11	30.42	17.02	-0.01	-0.06	45.08	17.6	3.35
	Average*	17.84	25.58	17.04	-0.80	-4.41	24.31	17.48	-0.36	-1.97	41.64	18.19	0.35
				$p = 0.0002 (< 0.01)$					$p = 0.1823 (> 0.10)$				
2	Lying down*	0.50	1.83	0.44	-0.06	-12.00	2.75	0.42	-0.08	-16.00	20.08	0.42	-16.00
	Long sitting	28.03	26.83	27.05	-0.98	-3.50	47.75	28.32	0.29	1.03	49.00	28.03	0.00
	Sitting sideways	35.11	27.67	33.64	-1.47	-4.19	46.00	36.12	1.01	2.88	49.00	35.11	0.00
	Standing	37.82	32.00	38.08	0.26	0.69	43.58	39.11	1.29	3.41	48.17	38.78	2.54
	Average*	33.65	28.83	32.92	-0.73	-2.33	45.78	34.52	0.86	2.44	48.72	33.97	0.32
				$p = 0.0408 (< 0.05)$					$p = 0.9891 (> 0.10)$				
3	Lying down*	0.55	1.08	0.50	-0.05	-9.09	2.50	0.49	-0.06	-10.91	12.08	0.49	-10.91
	Long sitting	22.31	37.00	23.07	0.76	3.41	49.00	22.31	0.00	0.00	49.00	22.31	0.00
	Sitting sideways	30.20	30.00	30.51	0.31	1.03	43.75	30.71	0.51	1.69	49.00	30.20	0.00
	Standing	34.85	20.58	34.58	-0.27	-0.77	46.67	35.15	0.30	0.86	49.00	34.85	0.00
	Average*	29.12	29.19	29.39	0.27	1.22	46.47	29.39	0.27	0.85	49.00	29.12	0.00
				$p = 0.8032 (> 0.10)$					$p = 0.9498 (> 0.10)$				$(p \text{ was undefined})$

Note: “Average” and “p-value” were calculated without the results of “Lying down.”

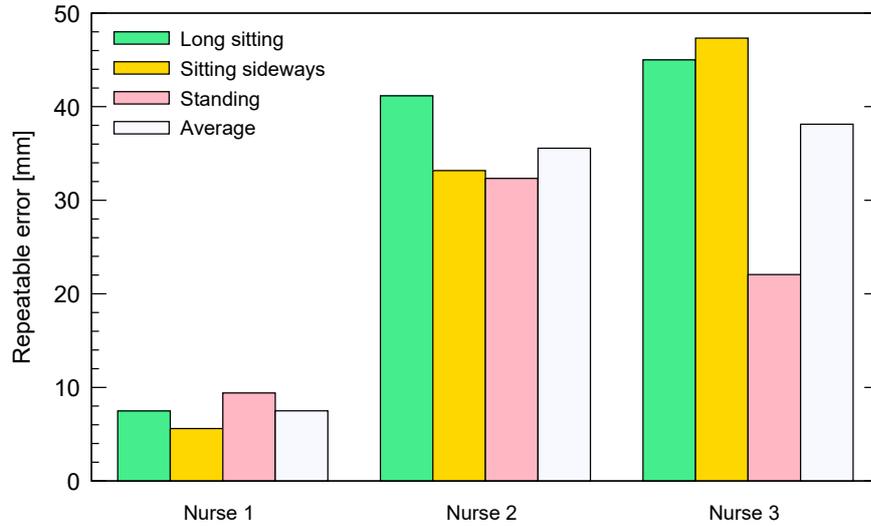


Fig. 5.3 : Repeatabe errors in a nurse for the three FASs that have the status of checkmarks all in common (i.e., $\mathbf{x}_{67} = \mathbf{x}_{150} = \mathbf{x}_{247}$ in Eq. (5.1)). Each of the errors was calculated by Eq. (5.26).

数の結果を確認することで、提案手法の効力を段階的に調べるができる。

Table 5.2の「p値 (p-value)」に検定結果を示す。「昇順」の結果に対してp値をそれぞれ求めた結果、看護師1は $p = 0.0002 (< 0.01)$ 、看護師2は $p = 0.0408 (< 0.05)$ 、看護師3は $p = 0.8032 (> 0.10)$ となり、有意水準1%のときは看護師1のみ、有意水準5%のときは看護師1, 2の帰無仮説が棄却された。一方、「無作為」および「降順」に関しては、いずれの看護師においても帰無仮説は保留され ($p > 0.10$)、誤差の変化が認められなかった。これらの結果は、提案手法が他の比較手法と比べて、テストデータに対する誤差の減少（過学習の軽減）に寄与することを示すものである。

なお、「昇順」において、看護師1の結果が最も良くなった理由、および、看護師3に有意差が現れなかった原因としては、回答の一貫性が影響していると考えられる。今回実施したアンケートには、看護師が記入する回答の一貫性を確認するため、 $i = 67, 150, 247$ に全く同じ内容のFASを用いた。Fig. 5.3は、これらFASに対する看護師の回答の再現誤差 E^{same} を Eq. (5.26) によって求めた結果である ($I^{same} = \{(67, 150), (67, 247), (150, 247)\}$) 。

$$E^{same} = \frac{1}{9} \sum_{(i,i') \in I^{same}} (|y_i - y_{i'}| + |y_i^- - y_{i'}^-| + |y_i^+ - y_{i'}^+|) \quad (5.26)$$

Fig. 5.3を見ると、看護師1は再現誤差が全て10mm以内に収まっており、回答の

一貫性が比較的高いことが分かる。一方、看護師3においては再現誤差が他の看護師より大きくなる傾向にあり、回答に一貫性が見られない。本手法は元々看護師に内在する意思決定の際のあいまいさを含んだルールを推定するものであることから（第4章）、看護師の回答に一貫性がない場合は誤差が悪化する。つまり、看護師3の回答データは元々モデル化が困難である可能性が高いため、提案手法が有効に機能せず誤差が改善しなかったと考えられる。一方、看護師1の回答には一貫性があることから、有意水準1%のときでも有意差を確認できた。

以上、提案手法は説明変数削減前後における誤差の変化に対して唯一有意差が現れたことから、過学習軽減効果があることが示唆された。このとき、アンケート回答に一貫性がある看護師については、特に有効性を発揮できる可能性が高いことが明らかになった。

5.5 考察

5.5.1 臥位の項目数と誤差が小さな理由

Table 5.2を見ると、臥位は他の姿勢と比べて、項目数 \bar{n}_{opt} および誤差 $\bar{E}^{test}(n_{opt})$ が大幅に小さくなっていることが分かる。一般的に、臥位は転倒・転落リスクの低い姿勢であり、看護師は患者が臥位るとき、転倒・転落事故が発生する可能性はほとんどないといった感覚を抱く。今回看護師から取得した回答を確認すると、患者の姿勢が臥位ときはFASの内容に依らず「危険がないと判断し訪問しない」（Fig. 4.1(c)の線分左端）の位置に回答を行う傾向にあった。本特徴はモデル式を作成する際に、FASのチェック項目（説明変数）を多く必要としないことを示唆している。また、回答の大部分が「危険がないと判断し訪問しない」の位置を占めており、回答間のバラつきが少ないことから、モデル式の誤差も小さくなりやすい。以上の理由により、臥位は項目数および誤差が小さくなったと考えられる。

なお、臥位は他の姿勢と異なり、モデル式に不要な説明変数が多いため、説明変数を任意に削減するだけでも過学習が軽減する可能性が高い。実際、Table 5.2を見ると、看護師2・臥位と看護師3・臥位に関しては、説明変数を「無作為」および「降順」に削減した場合においても、変化率 $\bar{E}^{\%}$ は負値となり誤差が改善していることが分かる。さらに、「昇順」の変化率に関して、看護師1は-26.27%、看護師2は-12.00%、看護師3は-9.09%であり、他の姿勢と比べて誤差が改善した程度が明らかに大きい。本姿勢を2標本t検定の対象とすると、良好な結果が得られやすい

のは自明であり，提案手法の正当な評価が不可能となる．5.4.4節では看護師個人ごとに2標本t検定を実施したが，回答の性質が明らかに異なる臥位に関しては，上記理由により検定対象から除外した．

5.5.2 誤差の変化率と再現誤差との関係

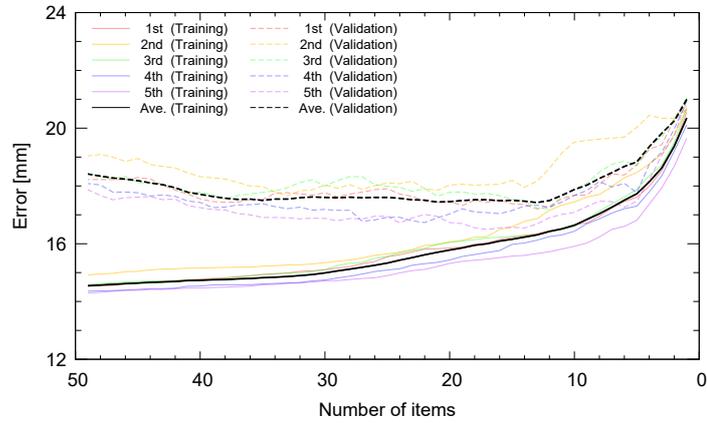
Table 5.2の「昇順」を見ると，看護師2・立位，看護師3・長座位，看護師3・端座位に関しては，変化率 $\bar{E}\%$ が正值であり，誤差が悪化していることが分かる．原因としては，2標本t検定のときと同様，回答の再現誤差 E^{same} が影響していると考えられる．

誤差の変化率 $\bar{E}\%$ (Table 5.2)において，結果が良好な順に並べると，長座位は看護師1 (-5.48%) →看護師2 (-3.50%) →看護師3 (3.41%) となる．一方，同姿勢の再現誤差 E^{same} (Fig. 5.3)についても，良い結果から順に並べると，看護師1 →看護師2 →看護師3 となり，誤差の変化率と同一の順序となることが分かる．また，端座位についても，誤差の変化率 $\bar{E}\%$ は看護師1 (-5.65%) →看護師2 (-4.19%) →看護師3 (1.03%)，再現誤差 E^{same} は看護師1 →看護師2 →看護師3 となった．さらに，立位に関しては，誤差の変化率 $\bar{E}\%$ は看護師1 (-2.11%) →看護師3 (-0.77%) →看護師2 (0.69%)，再現誤差 E^{same} は看護師1 →看護師3 →看護師2であった．これらが示す通り，長座位，端座位，立位においては，誤差の変化率 $\bar{E}\%$ と再現誤差 E^{same} との間に関係性が成り立ち，各姿勢において再現誤差が最も大きいものは誤差が悪化する（誤差の変化率が正值となる）ことが分かる．

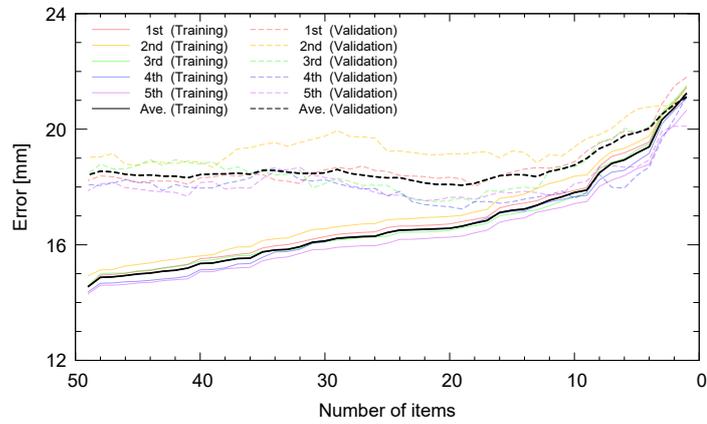
本提案手法の効果量は再現誤差の大きさに応じて変化する可能性が高く，看護師の回答に一貫性がない場合は有効性を発揮できない．一方，回答に一貫性がある場合は，過学習軽減効果が高く現れやすいと考えられる．

5.5.3 説明変数の削減に伴う誤差の変化

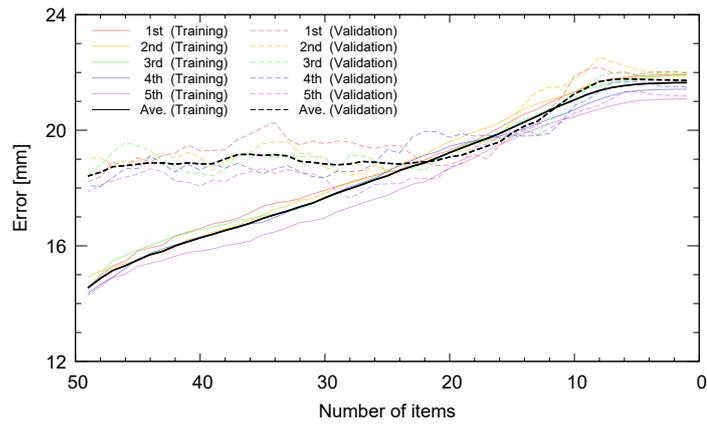
5.4節では，説明変数を削除する順序を3つ定め，誤差が改善する程度をそれぞれ検証した．Fig. 5.4は，看護師1・端座位のモデル式に用いる項目数 n と誤差 $\bar{E}^{val}(n)$ (Eq. (5.23)) の関係性を表すグラフである．図中の実線は学習データ，破線は検証データの変化を表す．学習データに対する誤差も，検証データと同様の方法で求めた．(a)は「昇順」，(b)は「無作為」，(c)は「降順」を表す（視認性を考慮して $l' = 1, 2, \dots, 5$ のみ記載）．また，各図の黒線は交差ごとの $\bar{E}^{val}(n)$ から，さらに全交



(a) Ascending order (proposed method)



(b) Random order



(c) Descending order

Fig. 5.4 : Relationship between the number of items and the error. The model of “Nurse 1 - Sitting sideways” is utilized. Error values are derived by Eq. (5.23). Describe only five folds ($l' = 1, 2, \dots, 5$). Black lines represent the averages of all folds ($l' = 1, 2, \dots, 12$).

差 ($l' = 1, 2, \dots, 12$) の平均を求めた結果である。

Fig. 5.4において、(a)は提案手法、(b)および(c)は比較手法に相当する。(a)を見ると、検証データに対する誤差は、項目数が10～15となる辺りまでは、項目数の削減に伴い減少する傾向にあることが分かる。また、学習データに対する誤差の増加も比較的緩やかである。一方、(b)、(c)においては、項目数が削減されても、検証データに対する誤差にほとんど変化が見られない。さらに、(a)と比べて、学習データに対する誤差が急激に増加している。

一般的に、モデル式を作成する際は、誤差が小さいほど優れたモデルとされる。そして、Fig. 5.4の各結果は、提案手法が説明変数の削減に伴う誤差の増加を最も抑制できていることを示唆するものである。5.4.4節では、テストデータに対する誤差が提案手法によって有意に低下することを示すことで、提案手法の有効性を裏付けた。提案手法はさらに、モデル化の際に用いられる学習データおよび検証データに対する誤差の増加を抑えられるという点に関して、他の比較手法よりも優位性があるといえる。

5.6 本章のまとめ

筆者は、転倒・転落に関する看護師の臨床判断をモデル化するにあたり、判断の際に生じる迷いを考慮するアンケート解析手法を提案している。第5章では、看護師個人から取得可能なアンケート回答数が基準値に満たないケースに焦点を当て、過学習を軽減する解析手法について提案と実データに基づく分析を行った。本章で提案した手法は、過学習を軽減かつ判断の迷いを含むファジィデータを扱えるよう、数量化I類における説明変数の選択手法をファジィ理論に基づき改良している。

看護師3名から回答データを300例ずつ取得し、提案手法によるモデル化を行った結果、看護師2名は説明変数削減前後において、モデル式の誤差が平均0.80mmおよび0.73mm減少した。その後、各々の結果に対して2標本t検定を実施した結果、p値はそれぞれ0.0002 (< 0.01)、0.0408 (< 0.05)となり、有意水準5%で誤差の改善が認められた。さらに、有意差が現れた2名は、残り1名の看護師よりも回答の一貫性が高く、提案手法はこうした傾向のデータに対して有効性を発揮できる可能性が高い。

以上、本検証を通じて「提案手法に過学習軽減効果があること」および「提案手法が有効に機能する看護師の条件」を明らかにできた。こうした知見は、今後シス

テムの実現に繋げていく過程において、モデル化を行う看護師のスクリーニングに寄与する可能性が高い。つまり、看護師にアンケートを依頼する前に、回答の一貫性を別途調査することでモデル化の可否を推察できるため、大勢の看護師に負担を強いることなく、モデル化に有効な回答データを得られる。さらに、今回の提案手法は回答データ数が少ない場合に生じる過学習を軽減可能なことから、将来的には先のスクリーニングを通じて選抜された看護師へ要求するアンケート数を削減できる可能性が高く、モデル化を行う際の利便性の向上および回答者本人の負担軽減へと繋がられる。

第6章 物理的観点に基づく患者の 転倒・転落リスク推定

6.1 本章の目的

第6章では、物理的観点に基づく転倒・転落リスク推定を行う。本研究の目的は、転倒・転落アセスメントスコアシート（FAS）と Depth カメラから患者の転倒・転落リスクを推定するシステムの構築であり、第4, 5章ではFASを用いた手法の提案および検証を行った。つづいては、Depth カメラを用いた手法について検討する。ただし、本章では提案手法の検証を行う際にFASを使用しない。本提案システムは3つのモジュールで構成されるが（Fig. 1.1）、各々に対して基礎研究をしないままシステムを作成すると、システムの運用中に誤判定などの問題が生じた際に、原因を特定することが困難となる。例として、システムに問題が生じる原因としては、Depth カメラから取得したデータ、看護師のアンケート回答、システム内部のアルゴリズムなどが挙げられるが、個々の特性を正確に把握していないと、原因の解明に時間がかかる可能性が高い。そのため、第6章では、第4, 5章の成果物に対しDepth カメラに関する機能を追加するのではなく、転倒・転落リスクの推定に使用する情報を一旦限定し、Fig. 1.1のモジュール(2)を独立して作成する。

本章で扱うデータは、Depth カメラに装着された加速度センサから得られた情報と、Depth カメラから取得された1フレーム分の点群データ（PCD: Point Cloud Dataset）、あるいは1フレーム分のDepth データのみとする。なお、転倒・転落リスクを推定する際は、一見すると数十フレームのPCD（またはDepth データ）を使い、患者の動的な情報も利用する方が適切であるように思われる。しかし、本システムに動的な要素を含めてしまうと、患者の移動速度や動きベクトルなどを計算する必要性が生じるため、静的な要素のみを利用した場合と比べて、システム全体の負荷が大きくなる。また、扱う情報を複雑化させる行為は、ファジィ理論の観点からも望ましくないとされるため（3.2.3節）、まずは静的な情報のみを用いることとする。第6章では、静的な情報から転倒・転落リスクを推定する方法について、そ

の実現可能性を明らかにする。

このほかにも、Depth カメラによって取得された PCD は、そのままの状態では看護師が理解不能なデータである可能性が高いため、本章では1 フレーム分の PCD から看護師が理解可能な情報（概念）を推定することができるかを別途検討する。今回実験に用いる Kinect は、0.5～4.5m の距離を PCD の Z 軸（3.6.2 節）として計測できるが¹、看護師は距離情報を見ただけで患者の転倒・転落リスクを推定できるとは到底考えられない。そのため、このままの状態では看護師の臨床判断と Depth カメラの距離情報を組み合わせることができず、入院患者の見守りシステムに看護師の感性を介入させられない。よって、看護師にとって理解可能な情報（概念）を PCD から抽出可能であるか、その可否について追加で検証を行う。

第6章では3種類の実験を通じて、6.2 節に示す提案手法の妥当性を確認する。最初に、6.3 節では任意の環境および設置条件に対して、提案システムが想定通りの挙動を示すかを検証する。つぎに、6.4 節では様々な設置条件下における検証を通じて、提案システムを適切に稼働させるために必要な Depth カメラの設置制約を特定する。最後に、6.5 節では実際の医療現場および入院患者を対象とした実験を行う。このとき、PCD を看護師が理解できる情報（概念）へと変換可能であるか否かを、実患者から取得したデータに基づいて考察する。

6.2 Depth カメラを用いた推定手法

6.2.1 概要

提案システムの構成概要図を Fig. 6.1 に示す。システム稼働時、Depth カメラの設置位置としてはベッド全体を見下ろせるベッド中心の直上が理想的であるが、カメラが患者へ落下する危険性があると同時に、常に患者の視界に入ることから不快感を与える可能性がある。そのため、患者の視界に入りにくいベッド頭部側や、不意にカメラが落下しても患者が怪我を負う可能性の低いベッドサイドに Depth カメラを設置し、ベッド面の斜め上方から PCD を得ることとする。

つぎに、Depth カメラから得られた PCD はベッド面が斜めから撮影されているため、ベッド中心の直上視点へと変換する。視点変換された PCD は、ベッド直上から測定したかのように補正される (Fig. 6.1(a))。その後、ベッド上の空間をいくつか

¹データの信頼性を考慮しない場合は 0.5～8.0m の距離を計測可能。

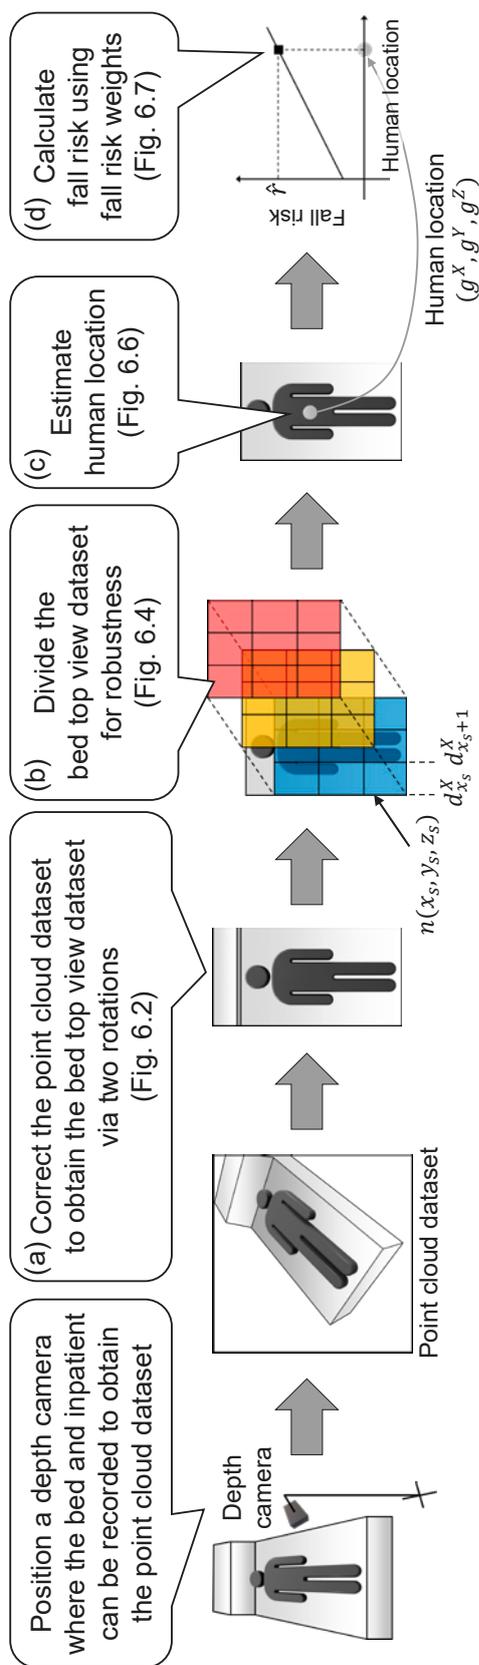


Fig. 6.1 : Concept of the proposed method concerning depth camera

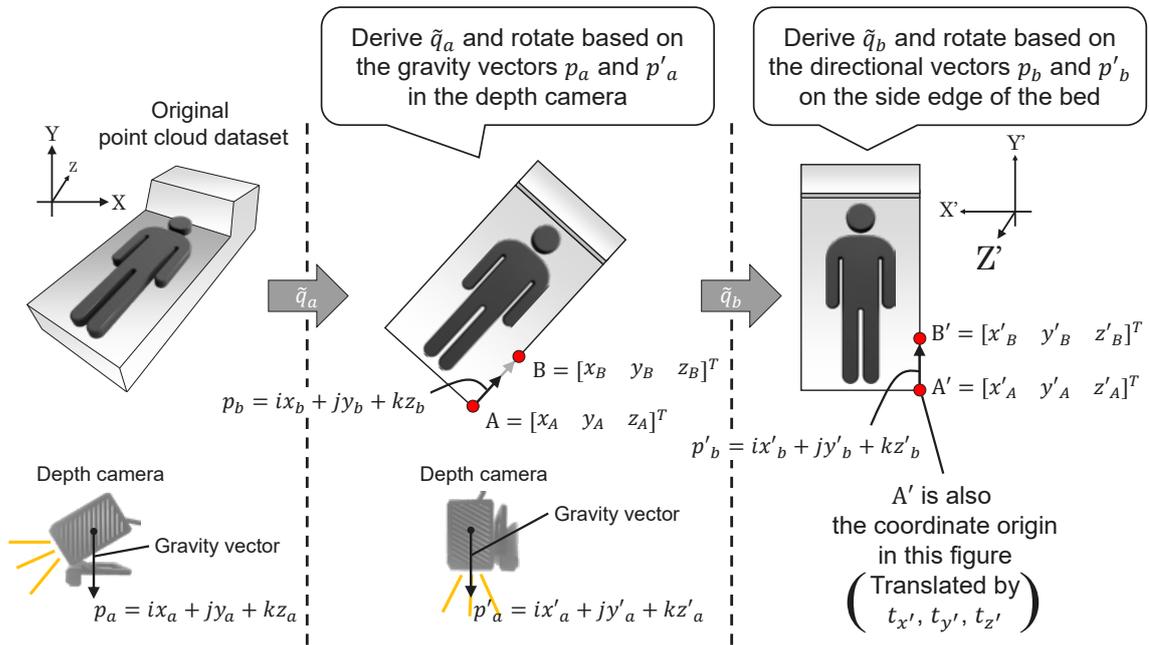


Fig. 6.2 : Concept behind the parameter derivation for the PCD correction

の区画に分割し (Fig. 6.1(b)), 各区画内に存在するデータ点の個数から, 身体の一部が存在する代表区画を求めて人物位置を算出する (Fig. 6.1(c)). 最後に, あらかじめ設定した転倒・転落リスクの重み係数を用いて, 人物位置から転倒・転落リスクを推定する (Fig. 6.1(d)). 6.2.2~6.2.5節では, (a)~(d)の詳細を述べる.

なお, 今回は Kinect を用いて提案手法の検証を行うため, 座標軸としては Kinect から得られる Depth マップに合わせて左手座標系を採用している. ただし, Kinect は Depth マップなどの映像を左右反転して取り込む性質があるため, データの見かけ上は左手座標系となるが, 現実空間上では右手座標系となる点に留意したい.

6.2.2 PCDの補正

PCDの補正に必要なパラメータの算出方法について, Fig. 6.2に概要を示す². 本手法は2回の回転を経て, 元のPCD (Original point cloud dataset) をベッド直上視点データ (Bed top view dataset) へと変換する. ステップ1)~3)は1度目の回転, ステップ4)~6)は2度目の回転に関する内容である.

²Fig. 6.2はX, Y, Z軸が左手座標系となっているが, 右手座標系を利用する場合は, 三次元ベクトルのX軸の符号を反転させる. 右手座標系から左手座標系へ変換する場合も同様である. なお, 座標系の違いによって転倒・転落リスクの推定精度が変化することはない.

- 1) Depth カメラに装着した加速度センサより重力ベクトル p_a を取得する。ここで、 p_a はクォータニオンであり、Eq. (6.1) の x_a, y_a, z_a はそれぞれ X, Y, Z 軸の方向量、 i, j, k はクォータニオンを表現するための虚数単位を表す記号である。

$$p_a = ix_a + jy_a + kz_a \quad (6.1)$$

- 2) Depth カメラが真下を向いた際に、Depth カメラにかかる重力ベクトル p'_a を設定する。
- 3) p_a の回転クォータニオンを \tilde{q}_a とする (Eq. (6.2))。

$$\tilde{q}_a = q_{a0} + iq_{a1} + jq_{a2} + kq_{a3} \quad (6.2)$$

\tilde{q}_a の共役クォータニオンを \tilde{q}_a^* とすると、 p_a から p'_a への回転変換を表す式は、Eq. (6.3) となる。

$$p'_a = \tilde{q}_a p_a \tilde{q}_a^* \quad (6.3)$$

\tilde{q}_a に、 $\|\tilde{q}_a\| = 1$ という制約を与え、 p_a と p'_a から Eq. (6.3) を満たす $q_{a0}, q_{a1}, q_{a2}, q_{a3}$ を一組算出する。

- 4) ベッド边上の点 $A = [x_A \ y_A \ z_A]^T$ および点 $B = [x_B \ y_B \ z_B]^T$ を目視で設定する。ベッドに転倒・転落防止柵が装着されている場合は、防止柵の上辺に点 A, B を設定する。点 A, B を通る方向ベクトルを p_b と定義する (Eq. (6.4))。 p_b もクォータニオンであり、 \tilde{q}_a によって座標変換が為されている。

$$p_b = ix_b + jy_b + kz_b \quad (6.4)$$

- 5) クォータニオン p'_b を方向ベクトルとして定義する。なお、 p'_b は補正後の PCD の X' 軸、または Y' 軸と平行になるよう設定する必要がある³ (Fig. 6.2)。例として、Y' 軸と平行にする場合は $p'_b = j$ となる。
- 6) p_b の回転クォータニオンを \tilde{q}_b とする。Eq. (6.3) 同様、 $\|\tilde{q}_b\| = 1$ という制約を与え、 p_b と p'_b から \tilde{q}_b の各項の値を算出する。

³ 今回の提案手法では、患者の位置情報に基づいて転倒・転落リスクの推定を行うが、このとき転倒・転落リスクの大きさはベッドとの相対的な位置関係によって変化する。例えば、転倒・転落リスクの値は、患者がベッド上に存在するときは低く、ベッド边上に存在するときは高くなると考えられる。また、ベッド外に存在するときは、転倒・転落リスクが最も高くなる。そのため、X', Y' 軸をベッドの各辺と平行になるよう定めることで、患者とベッドとの位置関係を把握しやすくした。

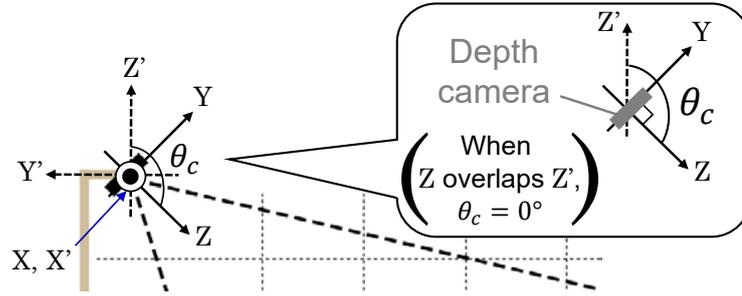


Fig. 6.3 : Definition of the inclination angle

以上の方法により、PCDを補正するための回転クォータニオン \tilde{q}_a および \tilde{q}_b が得られる。なお、ベッドの頂点の一つを座標原点とする場合は、変換後のPCDをEq. (6.5)により平行移動する。 $t_{x'}$, $t_{y'}$, $t_{z'}$ は各軸の平行移動の大きさ、 x'_c , y'_c , z'_c は平行移動後の三次元空間情報を表す。

$$\begin{bmatrix} x'_c \\ y'_c \\ z'_c \end{bmatrix} = \begin{bmatrix} x' \\ y' \\ z' \end{bmatrix} + \begin{bmatrix} t_{x'} \\ t_{y'} \\ t_{z'} \end{bmatrix} \quad (6.5)$$

一方、Depthカメラを枕元上方に設置した場合は (Fig. 6.5 に示す位置)、X軸周りの回転のみでPCDの変換を達成することが可能である。Eq. (6.6) に変換のための回転行列を記す。 x_c , y_c , z_c は射影前、 x'_c , y'_c , z'_c は射影後のデータである。 θ_c はカメラ本体の傾き角度を表す (Fig. 6.3)。

$$\begin{bmatrix} x'_c \\ y'_c \\ z'_c \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos \theta_c & -\sin \theta_c \\ 0 & \sin \theta_c & \cos \theta_c \end{bmatrix} \begin{bmatrix} x_c \\ y_c \\ z_c \end{bmatrix} + \begin{bmatrix} t_{x'} \\ t_{y'} \\ t_{z'} \end{bmatrix} \quad (6.6)$$

それぞれの変換手法に関して、クォータニオンによる回転はDepthカメラの設置時に行うことを想定している。つまり、回転クォータニオン \tilde{q}_a , \tilde{q}_b を算出する際、ベッド上に掛け布団や患者が存在しないことを前提とした手法である (ただし、 \tilde{q}_a , \tilde{q}_b を求めた後は、Depthカメラの設置条件が変化しない限り、ベッド上に掛け布団などがあってもPCDの変換を行うことが可能)。一方、Eq. (6.6)の回転行列を用いる場合は、Depthカメラを特定の位置に設置する必要がある。しかし、ベッド上に掛け布団や患者が存在する状況下であっても、回転行列を算出し、座標変換を適用することが可能である。

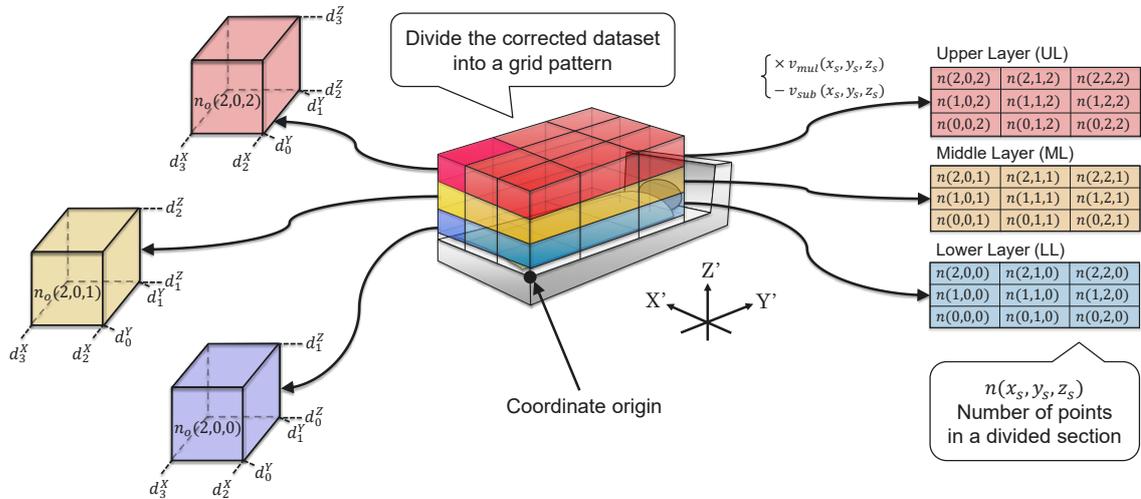


Fig. 6.4 : Concept behind the division of the bed top view dataset for robustness

PCDに含まれる全ての三次元座標点に対して、回転クォータニオンまたは回転行列による変換を実施する。

6.2.3 ロバスト性のためのベッド直上視点データの分割

回転クォータニオンまたは回転行列により補正されたベッド直上視点データは、変換前のPCDと同様、Kinectの場合は 512×424 ピクセルと多くの三次元座標点を持つことから処理コストが高く、転倒・転落リスク推定のリアルタイム性が損なわれる。また、患者の体型やベッド周辺環境の違いによる影響を受けやすい。そこで、補正後のPCDをいくつかの区画に分割することで、それらの影響を緩和し、ロバスト性の向上を図る。方法の概要を Fig. 6.4、詳細を以下に示す。

- 1) 補正後のPCDにおいて、ベッドの範囲内でデータを格子状に分割する（必要に応じてベッド外のデータを含める）。分割は座標変換後のX, Y, Z軸（Fig. 6.4におけるX', Y', Z'軸）全てに対して行う。なお、代表的な姿勢である臥位、座位、立位の判別を高さ（Z軸）によって可能にするようZ軸は3層に分割する（患者の転倒・転落事故を未然に防ぐためには、臥位と立位に加えて、立位に遷移する前の座位の姿勢判定が不可欠であるため）。X, Y軸は任意の分割数でも構わない。Z軸方向に3分割され、生成された層をそれぞれ上層（UL: Upper Layer）、中層（ML: Middle Layer）、下層（LL: Lower Layer）と定める。

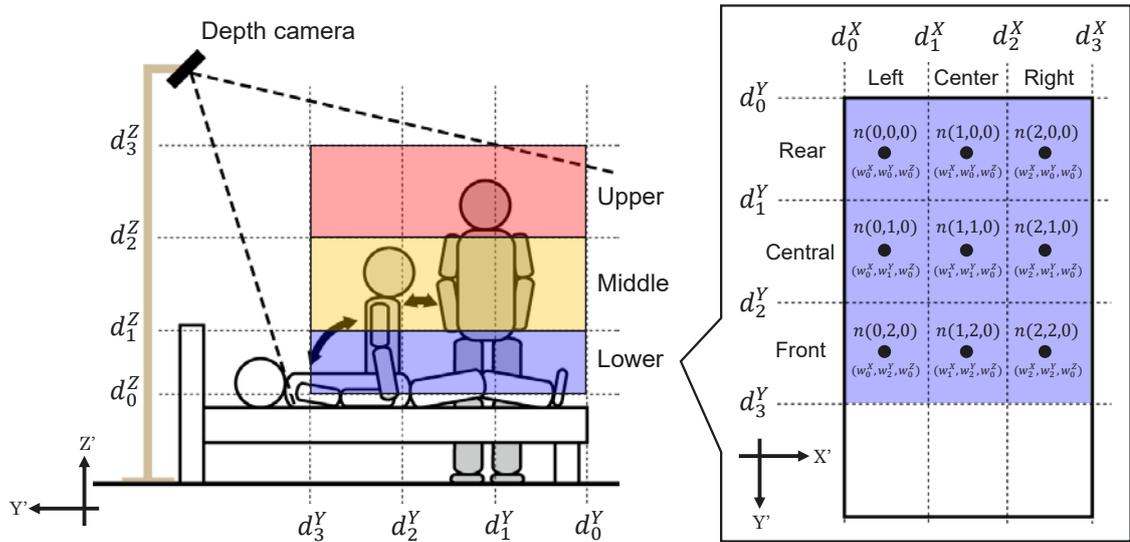


Fig. 6.5 : Relationship between the separation thresholds and the number of three-dimensional points for each section

- 2) 各区画を分割する際の閾値を $d_{x_s}^X, d_{y_s}^Y, d_{z_s}^Z$ [m] とする (x_s, y_s, z_s は区画番号). また, $d_{x_s}^X \leq x'_c \leq d_{x_{s+1}}^X, d_{y_s}^Y \leq y'_c \leq d_{y_{s+1}}^Y, d_{z_s}^Z \leq z'_c \leq d_{z_{s+1}}^Z$ の範囲内に存在する三次元座標点の数を $n_o(x_s, y_s, z_s)$ とする. 全区画の $n_o(x_s, y_s, z_s)$ を求める.
- 3) 各区画に存在する三次元座標点の数 $n_o(x_s, y_s, z_s)$ は, Depth カメラの設置位置や周辺環境による影響を受けやすい. そのため, $n_o(x_s, y_s, z_s)$ に対し, これらの影響を平滑化する補正係数 $v_{mul}(x_s, y_s, z_s), v_{sub}(x_s, y_s, z_s)$ をそれぞれ乗算, 減算し, $n(x_s, y_s, z_s)$ を求める (Eq. (6.7)).

$$n(x_s, y_s, z_s) = v_{mul}(x_s, y_s, z_s) \times n_o(x_s, y_s, z_s) - v_{sub}(x_s, y_s, z_s) \quad (6.7)$$

Fig. 6.5 は, X, Y, Z 軸をそれぞれ3分割したときの $d_{x_s}^X, d_{y_s}^Y, d_{z_s}^Z$ および $n(x_s, y_s, z_s)$ の関係を表す ($x_s = 0, 1, 2, y_s = 0, 1, 2, z_s = 0, 1, 2$). 本提案手法では, 計測範囲をベッド上に限定した後 (ベッド外の様子を取得する場合は計測範囲をベッド外まで拡張), 格子状の区画を作成している.

6.2.4 人物位置推定

6.2.3 節で作成した格子上の区画から, 人物位置を推定するアルゴリズムの概要を Fig. 6.6, 詳細を以下に述べる.

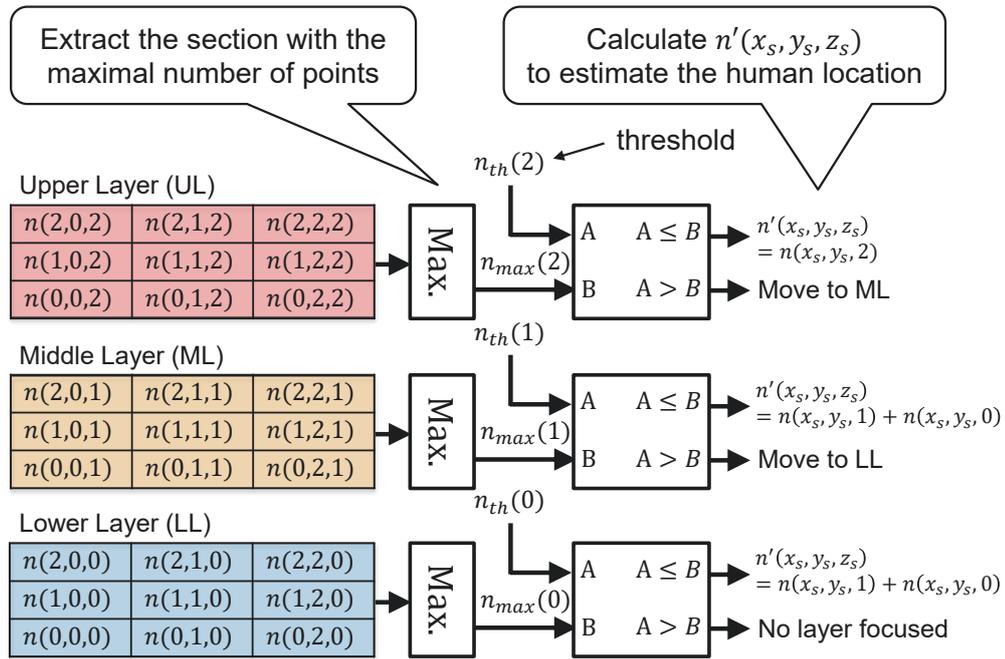


Fig. 6.6 : Procedure for the human location estimation

- 1) $n(x_s, y_s, z_s)$ の内, Z 軸 (上層, 中層, 下層) の各層ごとに最大値を持つ区画を抽出する. ここで, 上層, 中層, 下層の各最大値を $n_{max}(2)$, $n_{max}(1)$, $n_{max}(0)$ とする.
- 2) 人物が存在する層を判定するため, 各層の最大値 $n_{max}(*)$ (*は各層を意味する) があらかじめ定義した閾値を上回っているか比較する. ここで, 上層, 中層, 下層の各閾値を $n_{th}(2)$, $n_{th}(1)$, $n_{th}(0)$ とする.
- 3) 2) の結果から, 着目する層を Eq. (6.8)~(6.10) に従って決定する. 式中の「No layer focused」は, 人物と思しきオブジェクトが計測範囲内に存在しないため (つまり人物が不在), どの層にも着目しないことを表す.

$$\begin{cases} \text{Focus on UL} & ; n_{max}(2) \geq n_{th}(2) \\ \text{To equation (6.9)} & ; \text{otherwise} \end{cases} \quad (6.8)$$

$$\begin{cases} \text{Focus on ML \& LL} & ; n_{max}(1) \geq n_{th}(1) \\ \text{To equation (6.10)} & ; \text{otherwise} \end{cases} \quad (6.9)$$

$$\begin{cases} \text{Focus on ML \& LL} & ; n_{max}(0) \geq n_{th}(0) \\ \text{No layer focused} & ; \text{otherwise} \end{cases} \quad (6.10)$$

着目する層のデータは、4)以降の人物位置推定に使用する⁴。

- 4) 3)で中層および下層に着目する場合は、中層の三次元座標点の個数 $n(x_s, y_s, 1)$ と下層の三次元座標点の個数 $n(x_s, y_s, 0)$ を足し合わせる。ただし、上層に着目する場合は、立位の推定のため $n(x_s, y_s, 2)$ をそのまま使用する (Eq. (6.11) 参照)。

$$n'(x_s, y_s, z_s) = \begin{cases} n(x_s, y_s, 2) & ; \text{Focus on UL} \\ n(x_s, y_s, 1) + n(x_s, y_s, 0) & ; \text{Focus on ML \& LL} \end{cases} \quad (6.11)$$

- 5) 着目する層において、 $n'(x_s, y_s, z_s)$ が最大数となる区画の x_s, y_s, z_s をそれぞれ $x_{max}, y_{max}, z_{max}$ と置く。例として、最大数の区画が $n'(1, 1, 2)$ のとき、 $x_{max} = 1, y_{max} = 1, z_{max} = 2$ となる。
- 6) 最大数の区画 $n'(x_{max}, y_{max}, z_{max})$ を基準として、Eq. (6.12) より X 軸の重心座標 g^X を求める。例として、最大数の区画が $n'(1, 1, 2)$ であるならば、 g^X の導出には $n'(0, 1, 2), n'(1, 1, 2), n'(2, 1, 2)$ が用いられる。

$$\begin{cases} g^X = \frac{\sum_{x_s} \frac{d_{x_s}^X + d_{x_s+1}^X}{2} n'(x_s, y_{max}, z_{max})}{\sum_{x_s} n'(x_s, y_{max}, z_{max})} \\ g^Y = \frac{\sum_{y_s} \frac{d_{y_s}^Y + d_{y_s+1}^Y}{2} n'(x_{max}, y_s, z_{max})}{\sum_{y_s} n'(x_{max}, y_s, z_{max})} \\ g^Z = \frac{\sum_{z_s} \frac{d_{z_s}^Z + d_{z_s+1}^Z}{2} n(x_{max}, y_{max}, z_s)}{\sum_{z_s} n(x_{max}, y_{max}, z_s)} \end{cases} \quad (6.12)$$

Y 軸も同様に g^Y を求める。Z 軸に関しては、 $n'(x_s, y_s, z_s)$ ではなく $n(x_s, y_s, z_s)$ を用いて g^Z を求める。

求めた重心座標を人物位置と定義する。

⁴Eq. (6.9), (6.10) では、条件を満たすとき中層と下層を合わせて着目している。Eq. (6.9) で中層を、Eq. (6.10) で下層を別々に着目した際、両者の境界上に人物が居た場合には中層から下層、または、下層から中層へと着目する層が断続的に切り替わるといった現象が生じ、データの連続性が失われる。そのため、中層と下層を合わせて着目することとした。なお、上層と中層に関しては、転倒・転落リスクが最も高い姿勢である立位を正確に判定するため、別々に着目することとした。

6.2.5 位置情報に基づく転倒・転落リスク推定

6.2.4節で算出した重心座標 g^X , g^Y , g^Z を使い、人物の転倒・転落リスクを求める。転倒・転落リスクの推定手順を以下に示す。

- 1) 各分割区画の閾値 $d_{x_s}^X$, $d_{y_s}^Y$, $d_{z_s}^Z$ に、転倒・転落リスクの重み係数 (FRW: Fall Risk Weight) を各々設定する。各軸の FRW をそれぞれ $w_{x_s}^X$, $w_{y_s}^Y$, $w_{z_s}^Z$ とする。
- 2) 重心座標 g^X から、基準となる FRW $w_{x'_s}^X$ を定める。Eq. (6.13) は、X 軸の分割数が3のときの場合分けである。

$$w_{x'_s}^X = \begin{cases} w_0^X & ; d_0^X \leq g^X < d_1^X \\ w_1^X & ; d_1^X \leq g^X < d_2^X \\ w_2^X & ; d_2^X \leq g^X < d_3^X \end{cases} \quad (6.13)$$

Y, Z 軸に関しても、基準となる FRW $w_{y'_s}^Y$ および $w_{z'_s}^Z$ を同様に求める。

- 3) Eq. (6.14) により、X 軸方向の転倒・転落リスク r^X を求める。Eq. (6.14) は、 g^X と r^X を結ぶ一次方程式であり、図化すると Fig. 6.7 となる。なお、ベッド外（またはベッド出口）に近いほど、リスクが高まるという条件を満たすなら、二次方程式や指数関数を用いても構わない。Y, Z 軸の転倒・転落リスク r^Y , r^Z も同様に求める。

$$\begin{cases} r^X = \frac{w_{x'_s+1}^X - w_{x'_s}^X}{d_{x'_s+1}^X - d_{x'_s}^X} (g^X - d_{x'_s}^X) + w_{x'_s}^X \\ r^Y = \frac{w_{y'_s+1}^Y - w_{y'_s}^Y}{d_{y'_s+1}^Y - d_{y'_s}^Y} (g^Y - d_{y'_s}^Y) + w_{y'_s}^Y \\ r^Z = \frac{w_{z'_s+1}^Z - w_{z'_s}^Z}{d_{z'_s+1}^Z - d_{z'_s}^Z} (g^Z - d_{z'_s}^Z) + w_{z'_s}^Z \end{cases} \quad (6.14)$$

- 4) r^X , r^Y , r^Z の合計値 \hat{r} を最終的な転倒・転落リスクとする。

$$\hat{r} = r^X + r^Y + r^Z \quad (6.15)$$

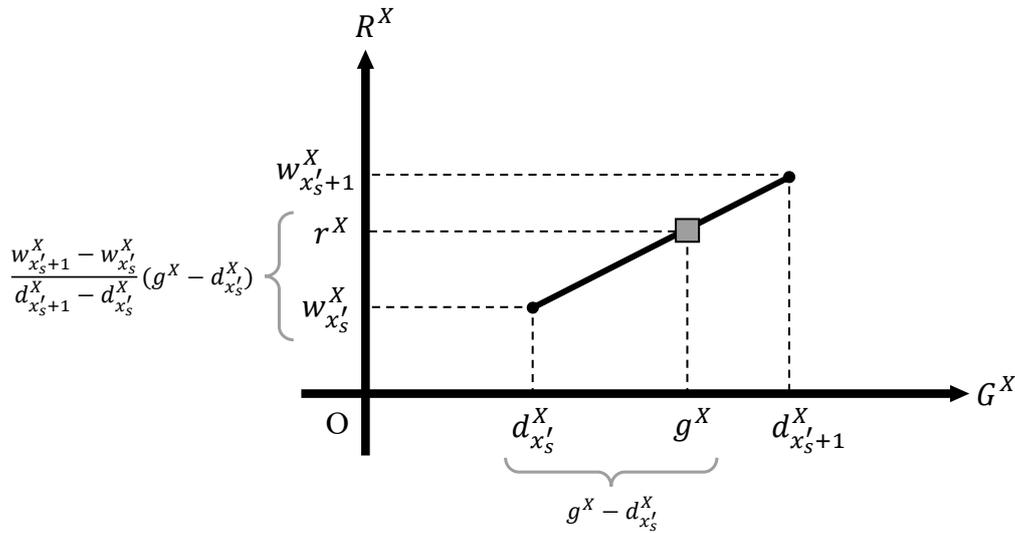


Fig. 6.7 : Relationship between the center of gravity g^X and the fall risk r^X on the X-axis (Eq. (6.14))

6.3 任意の設置条件下における検証

6.3.1 実験条件

提案手法の有用性を検証するため、医療用ベッドを使い健常者による検証を行う。今回は被験者として、25歳の健康な男性を選定した。ただし、提案手法はロバスト性を向上させるため、6.2.3節にて補正後のPCDを分割（つまり、いくつかの区画に圧縮）しており、このとき入院患者の体型に関する情報の大部分が除去される。そのため、提案手法は年齢や性別の違いによる影響がほとんどなく、被験者が1名でも検証を行うことは十分可能といえる。Table 6.1に実験条件を記す。今回は、重力ベクトルの計測にはLSM330 (STMicroelectronics Inc., Geneva, Switzerland)を、PCDの取得にはMicrosoft社のKinect [79]を使用する。

Fig. 6.8は、Depthカメラより撮影した実験環境の赤外線画像である。画像内の点A, Bはキャリブレーションに必要な点であり、本検証ではベッド長辺上に設定した。なお、今回試作したシステムはDepthカメラを設置すると、画面上にDepthマップを表示する機能を有する。本システムの利用者は、表示されたDepthマップを確認しながら、ベッド辺と重なる位置に点A, Bを配置する。ただし、これらの点は、Canny法によるエッジ推定やHough変換の組み合わせによるベッド辺の検出手法に基づいて設定することも充分可能である [106]。

Table 6.1 : Parameters of the proposed method

Bed size (W×D×H)	[m]	$1.0 \times 1.9 \times 0.5$
Height between Kinect and ground	[m]	1.8
Translation $t_{x'}, t_{y'}, t_{z'}$	[m]	-1.3, 0.0, 1.3
Gravity vector (X-, Y-, Z-axis)		-0.64, -0.32, 0.70
Bedside edge vector (X-, Y-, Z-axis)		0.99, 0.01, 0.00
Rotation quaternion \tilde{q}_a		$0.42 + 0.82i + 0.38j$
Rotation quaternion \tilde{q}_b		$0.71 + 0.70k$
Thresholds for determining the layers (UL, ML, LL)		1500, 1000, 1000
Coefficients for smoothing (Mul., Sub.)		all 1.0, all 0.0

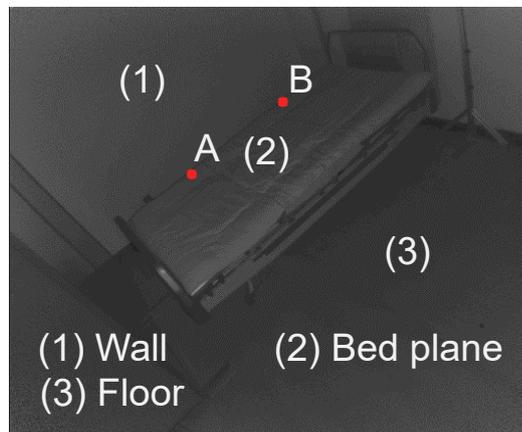


Fig. 6.8 : Infrared image of the room used for the experiments, which was acquired using a depth camera (a Microsoft Kinect sensor). The two points A and B correspond to the coordinates on the long-side edge of the bed, which are defined for correction.

Table 6.2 : Thresholds for the PCD separation (unit is [m]). The coordinate origin is shown in Fig. 6.4.

X-axis		Y-axis		Z-axis	
d_{-1}^X	-0.50				
d_0^X	0.00	d_0^Y	0.00	d_0^Z	0.10
d_1^X	0.33	d_1^Y	0.50	d_1^Z	0.40
d_2^X	0.67	d_2^Y	1.00	d_2^Z	0.70
d_3^X	1.00	d_3^Y	1.50	d_3^Z	1.00

Note: d_{-1}^X is a threshold added to the outside of the bed.

Table 6.3 : Fall risk weights in this experiment

X-axis		Y-axis		Z-axis	
w_{-1}^X	4				
w_0^X	3	w_0^Y	3	w_0^Z	0
w_1^X	2	w_1^Y	2	w_1^Z	1
w_2^X	1	w_2^Y	1	w_2^Z	2
w_3^X	0	w_3^Y	0	w_3^Z	3

Note: w_{-1}^X was used for the extended UL.

Table 6.2 に、PCD を分割する際の閾値 $d_{x_s}^X$, $d_{y_s}^Y$, $d_{z_s}^Z$ を記す. 各値は、実験用ベッドのサイズや周辺環境に基づいて設定しており、座標原点および座標軸については Fig. 6.4 の定義に則った. また、Table 6.3 に FRW $w_{x_s}^X$, $w_{y_s}^Y$, $w_{z_s}^Z$ を記載する. 今回は、 $d_{x_s}^X$, $d_{y_s}^Y$, $d_{z_s}^Z$ がベッド出口に近い、または、地面から遠いほど FRW の値を大きくした. これらの値は、転倒・転落リスクの算出に利用される (Eq. (6.14)). なお、 $w_{x_s}^X$, $w_{y_s}^Y$, $w_{z_s}^Z$ の最小値は全て 0, 最大値はそれぞれ 4, 3, 3 としたため、転倒・転落リスクの最小値は 0, 最大値は 10 となる. このとき、最小値 0 は「患者がベッド上で全く危険がない状態」、最大値 10 は「物理的観点において明らかに危険が伴う状態」を表す. さらに、本検証では立位の際の転倒・転落リスクをより正確に推定できるよう、上層の範囲をベッド外の方に 0.5m 拡張した. Table 6.3 の w_{-1}^X は、拡張後の上層に対して使用される.

実験は以下の手順で行う. 1) ベッド上に被験者が居ない状態で PCD の回転および平行移動を行う. 2) 座標変換後、被験者による姿勢の変化 (臥位 (Lying down), 長座位 (Long sitting), 端座位 (Sitting sideways), 立位 (Standing)) に対して、転倒・転落リスクを推定する.

6.3.2 PCDの補正結果

Fig. 6.9にPCDの変換結果を記す。Fig. 6.9(a)は変換前、(b)は変換後の結果である。なお、本検証ではベッドの4つの頂点の内、Depthカメラとの距離が最も近い頂点を座標変換後の原点とした。図中の色分けされた部分は、Z軸方向の距離を表す。各図の(1)～(3)は、実験時に撮影されたオブジェクトを示しており、Fig. 6.9の(1)～(3)と対応する。(1)は壁面、(2)はベッド面、(3)は床面である。

本検証では、ベッドを斜めから撮影したときのPCDを真上から見下ろす視点へと変換することを試みた。Fig. 6.9の(2)に着目すると、変換前はベッド面に対するZ軸の距離が一定ではないが、変換後はベッド面がほぼ全て0.0～0.1mの範囲内に収まっていることが分かる。さらに、変換後はベッド面が長方形に近い形状となり、各辺はX軸またはY軸とほぼ平行になっている。これらの結果が示すのは、Depthカメラを任意の位置に設置した場合であっても、適切な視点へと変換可能なことである。

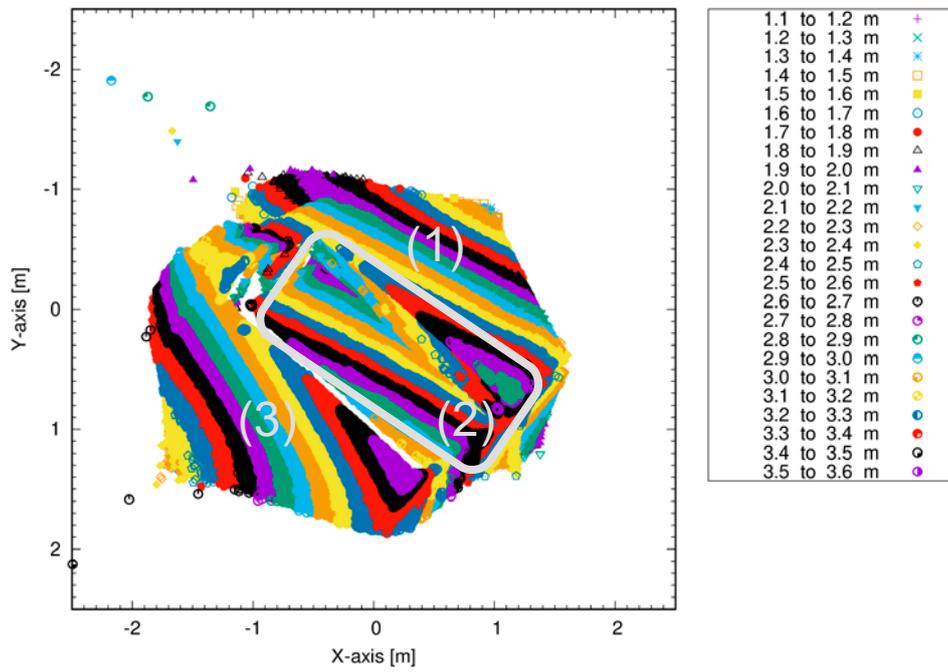
6.3.3 転倒・転落リスクの推定結果

座標変換されたPCDを用いて推定された転倒・転落リスクをFig. 6.10に記す。(a)は臥位、(b)は長座位、(c)は端座位、(d)は立位の結果である。各図の上部には2つの値が表示されているが、右上は経過時間、左上は転倒・転落リスクの値を表している。なお、経過時間の単位は[s]、転倒・転落リスクは無次元量(単位なし)となる。

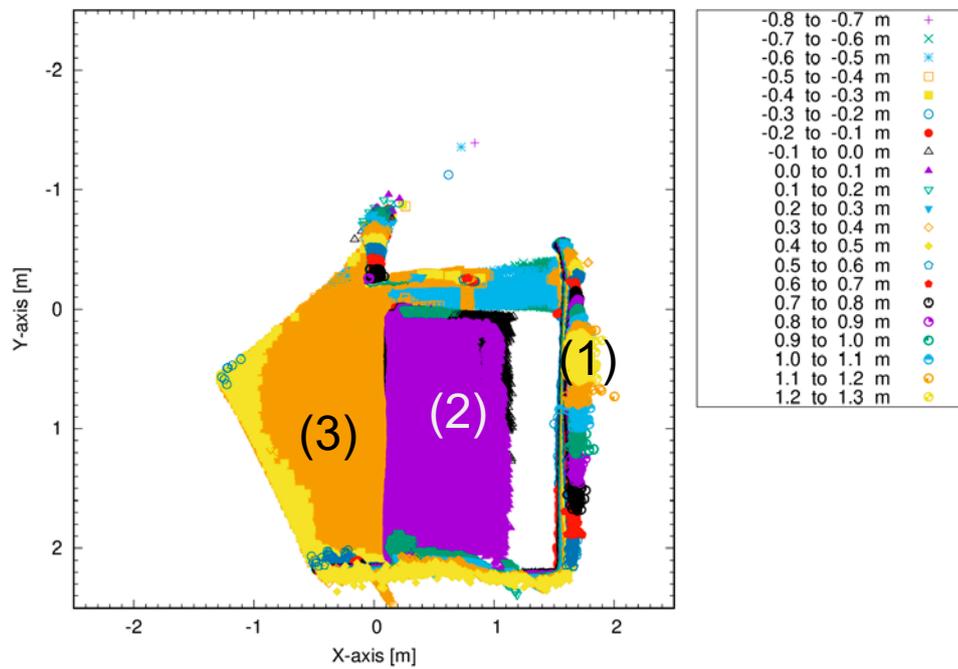
結果を見ると、各姿勢の転倒・転落リスクは臥位(3.0)、長座位(3.6)、端座位(5.1)、立位(7.5)の順に並んでいることが分かる。これは「患者が立ち上がっているときは転倒の危険性が高く、寝ているときは転倒の危険性が低い」という一般的な感覚と一致する。また、物理的観点から見ても「患者の重心位置が高いほど大怪我を負いやすい⁵⁾」という性質を満たしており、本結果が妥当なものであることを示唆している⁶⁾。

⁵⁾患者が高位置に存在するときは、位置エネルギーが大きくなるため、転倒・転落したときに大怪我を負う可能性が高い。また、重心位置が高いほどバランスを取りづらく、転倒する危険性が高くなると考えられる。

⁶⁾このほかにも、SA Healthの報告[107]によると、転倒・転落インシデントは入院患者がトイレに行く際に頻繁に発生する。また、患者がベッドから出る際にもインシデントが起こり得る。一方、ベッドから転がり落ちるインシデントは発生頻度が低い。これらのインシデントが生じる際、患者の姿勢はそれぞれ立位、端座位、臥位であることが多いと考えられる。ここで、Fig. 6.10を見ると、転倒・転落リスクの値も同様の順序となることから(立位(7.5)→端座位(5.1)→臥位(3.0))、今回の結果は転倒・転落インシデントの実態との相関があるといえる。



(a) Before



(b) After

Fig. 6.9 : Results of the rotation and translation

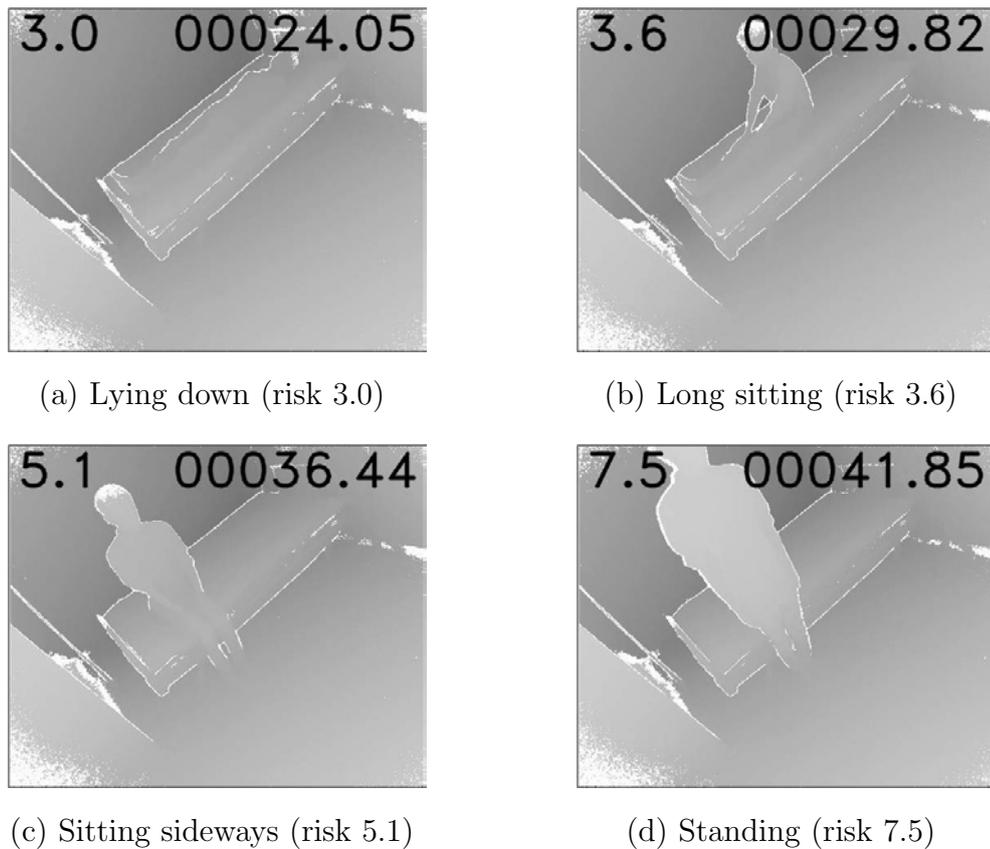


Fig. 6.10 : Results of fall risk estimation. The upper-right value indicates the elapsed time, while the upper-left value indicates the fall risk. The fall risk follows the order: (a) lying down < (b) long sitting < (c) sitting sideways < (d) standing.

なお、今回はベッド上に掛け布団がない状態で検証を行ったが、提案手法は患者が存在する層を上層、中層、下層の順に探索するため (Eq. (6.8)~(6.10))、上層や中層に相当する姿勢 (つまり、立位や座位) の患者を検出する際に、下層に存在する掛け布団は、患者が存在する層の検出精度に影響を与えない。さらに、人物が掛け布団に覆われていても、上記に述べた理由により、リスクの推定は十分可能である。

6.4 Depthカメラの設置制約の検討

6.4.1 設置制約の対象パラメータ

6.3節での検証を通じ、本提案システムはPCDを変換することで、Depthカメラとベッドとの位置関係を固定せずともリスク推定が可能であることを確認した。し

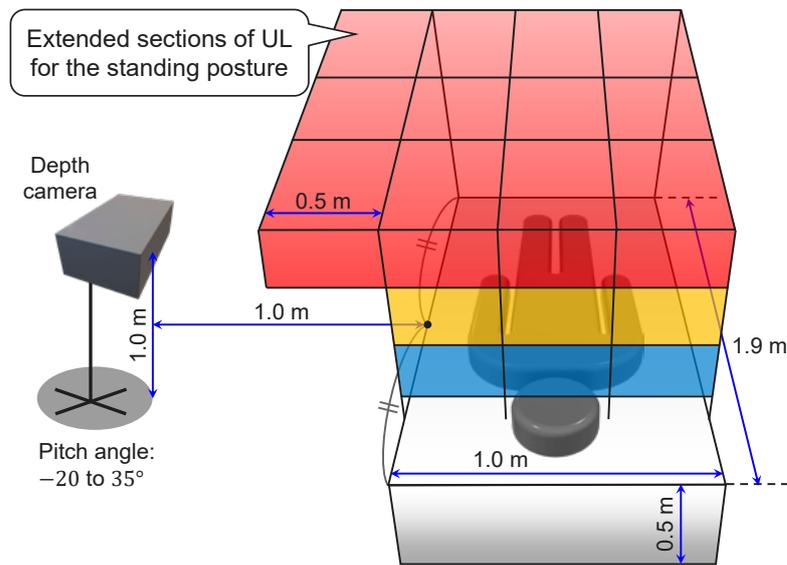


Fig. 6.11 : Position and orientation of the depth camera

かし、Depth カメラの設置制約については議論されておらず、設置位置によってはリスク推定に必要な情報を十分に得られない恐れがある。

Depth カメラの設置制約は、主に (1) ベッドからの距離や高さ、(2) カメラの向き (ロール角、ピッチ角、ヨー角)、(3) Depth カメラの測定仕様の3点関係する。ただし、(1) は (3) に依存する制約であり、今回使用する Depth カメラの測定仕様から、(1) の制約を求めることができる。例として、今回用いる Kinect は計測可能範囲が 0.5~4.5m であることから、設置距離の制約は必然的に計測対象から 0.5~4.5m 離れた位置となる。また、設置高さについては、ベッド上部より測定可能範囲を適用するため、今回対象のベッド高さが 0.5m であることから設置高さの制約は必然的に 1.0~5.0m となる。つぎに、(2) については Depth カメラの仕様上、ロール角は水平でなければならず、ヨー角は設置位置に関わらずベッド中心へと向けるため考慮する必要はない。結果として、設置制約を求めるにあたり、検証が必要なのはピッチ角のみとなる。そのため、6.4.3、6.4.4 節ではピッチ角の設置制約について検討する。

6.4.2 実験条件

Depth カメラは Fig. 6.11 に示す通り、上層からの水平距離 0.5m、地面からの高さ 1.0m の位置に設置する。これは、6.4.1 節で述べた制約を満たしつつ、計測を行う対象に最も近い位置である。そのため、ベッドおよびベッド周辺情報が Depth カ

Table 6.4 : Relationship amongst the “Pitch,” “Fall risk,” “Degree of subject’s body part existence,” and “Degree of layer existence” factors

Pitch [°]	Fall risk				Degree of subject’s body part existence				Degree of layer existence			
	Lying down	Long sitting	Sitting sideways	Standing	Lying down	Long sitting	Sitting sideways	Standing	LL	ML	ML	UL
-20	NLF	4.7	6.2	7.7	F	P	P	T	P	T	T	T
-10	3.1	4.3	5.9	7.6	T	T	P	T	P	T	T	P
0	3.0	4.7	6.1	7.6	T	T	T	P	T	T	T	P
10	3.5	3.9	5.8	6.8	T	T	P	P	T	T	T	P
20	3.0	4.2	5.9	NLF	T	P	P	F	T	P	P	P
30	3.4	4.2	5.7	NLF	T	P	P	F	T	P	P	F
35	3.2	4.0	5.4	NLF	T	P	P	F	P	P	P	F

Note: Here, NLF indicates that the system judged that there was no human. T, P, and F were determined based on the side-view maps presented in section 6.4.3. T: The complete body part or layer exists within the angle of view (AOV); P: Partly exists within the AOV; F: Does not exist within the AOV.

メラに映りにくく、特に厳しい条件だといえる。一方、ロール角はベッド面と平行になる角度、ヨー角はベッド中央を向いた角度とする。

6.4.3 ピッチ角に応じたリスク推定結果

Depth カメラのピッチ角を変更し、各姿勢の転倒・転落リスクを算出した結果を Table 6.4 に示す。ここで、第1カラムに示す「ピッチ角 (Pitch)」は、カメラが下を向くほど正の方向に大きくなり、ピッチ角 0° は地面と水平であることを表す。第2カラムに示す「転倒・転落リスク (Fall risk)」に記載の NLF は、人物が不在と判定されたことを意味する (Eq. (6.8)~(6.10) において、「No layer focused」が選択された状態)。つぎに、Table 6.4 の第3カラムには「被験者の体部の存在有無 (Degree of subject’s body part existence)」, 第4カラムには「各層の存在有無 (Degree of layer existence)」を記載している。表中の T (True) は被験者の体部 (または各層) を画角内に全て含む状態, P (Partly) は画角内に一部含む状態, F (False) は画角内に全く含まない状態を表す。なお、太字の項目は、誤った転倒・転落リスクを算出した結果を表す。さらに、各層の存在有無については、本章で対象とした4姿勢の内、長座位と端座位はどちらも中層に対応することから、姿勢と各層との対応関

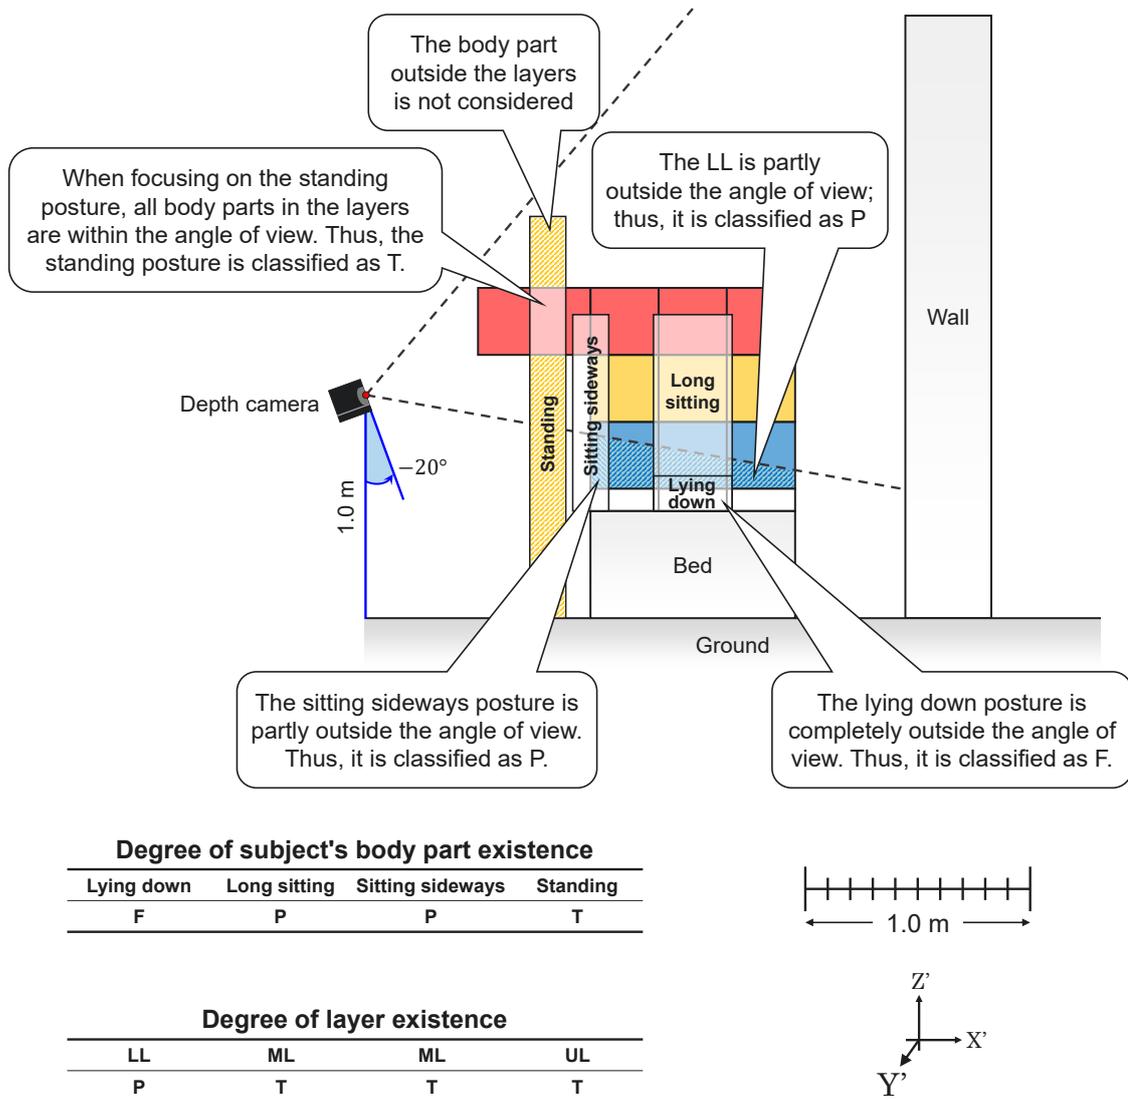


Fig. 6.12 : Example of a side-view map used for the classification of the degrees of existence of the subject's body part and layer in Table 6.4. The two dashed lines represent the AOV related to the pitch angle of the depth camera.

係を合わせるため、Table 6.4では中層を2列設けている⁷。

一方、上述した存在有無の分類は、実験環境の小縮尺図に基づき行われた。Fig. 6.12に、Depthカメラのピッチ角が -20° のときの小縮尺図を示す。今回は、各姿勢に対応する被験者の形状を直方体と近似して分類を行った。さらに、図中の2本の破線は、Depthカメラのピッチ角に関する画角を表しており、これら2本の破線の成す角度はDepthカメラの仕様に基づき 60° とした。これらの破線が示す画角の範囲は、被験者の体部や各層に関するT, P, Fの分類（Table 6.4）に利用される。なお、各層の範囲外にある被験者の体部（例：Fig. 6.12に示す立位のエリア内の斜線部）は、転倒・転落リスクの計算に使用されないため、T, P, Fの分類には利用しないこととする。

6.4.4 センサの設置に必要な条件

Table 6.4を見ると、ピッチ角が -10° , 0° , 10° のときは、臥位、長座位、端座位、立位の順に転倒・転落リスクが増加しており、6.3節の結果と同様の傾向を示していることが分かる。しかし、ピッチ角が 20° , 30° , 35° のときは、臥位、長座位、端座位に関しては同様の傾向となるが、立位はNLFとなり不適切な判定結果となった。さらに、ピッチ角が -20° の場合においても、被験者が臥位の姿勢であるにも関わらず、NLFと判定された。このような誤判定が第2カラムで生じたとき、被験者の体部の存在有無（第3カラム）は全てFと分類されており、被験者の体部が画角外にあることが分かる。

一方、6.4.3節でも述べた通り、本検証では各層の範囲内に存在する被験者の体部のみを考慮していることから、全ての層が画角内に存在する場合、被験者の体部もまた測定可能であることは自明である。そのため、Table 6.4の第4カラムのFについて検討する必要はなく、第3カラムのFのみに着目すれば良い（これは、被験者の体部がTまたはPのとき、転倒・転落リスクの結果は全て正しく、このとき第4カラムの各層がTもしくはPに分類されることに基づいている）。こうした理由から、ピッチ角に関する設置制約は「被験者の体部が画角内に収まる角度に設定する」だと考えられる。さらに、本制約は全ての層がTに分類されたときに確実に満たされる。そのため、設置制約は「Depthカメラの画角および測定可能な範囲内に全て

⁷本提案手法では、上層は立位、中層は座位、下層は臥位の推定に利用される。一方、今回の検証では、座位の姿勢に関しては長座位と端座位の2つに区分し、それぞれに対して転倒・転落リスクを確認した。そのため、Table 6.4では中層が2列存在することとなった。

の層を含む位置」と言い換えられる。本システムを実運用する際は、上記の制約を満たす位置に Depth カメラを設置すると良い。

6.5 実際の入院患者を対象とした検証

6.5.1 実験条件

最後に、提案手法の実用性について検討するため、実際の病院で実患者による検証を行う（本検証は鳥取大学医学部附属病院の倫理審査委員会より承認を受けたものである（1703A221））。被験者として、入院中の成人男性2名を選定した。検証時に使用したベッドは一般的な医療用ベッドである。実験条件を Table 6.5 に示す。本病院では Depth カメラを枕元上方に設置可能であったため、PCD の変換には Eq. (6.6) の回転行列を用いた。PCD の補正係数 $v_{mul}(x_s, y_s, z_s)$, $v_{sub}(x_s, y_s, z_s)$ は全て1および0とする⁸。本検証では取得される PCD や患者への影響を考慮し、至適基準による比較を行わないこととする⁹。

各区画を分割する際の閾値は、病院内のベッドサイズや周辺環境に合わせて Table 6.6 のように定めた。このとき、6.3, 6.4 節の検証と同様、最も危険な姿勢である立位を検出しやすくするため、上層の範囲をベッド外まで拡張した。なお、 d_0^Y (Fig. 6.5 参照) については、ベッド周辺のカーテンによる影響を考慮し、ベッド辺と重なる位置ではなく、ベッド辺から約 0.1m 内側の位置に設定した（座標原点が 0.1m 内側へ移動）。FRW は、Table 6.3 と同様の値を用いた。これら FRW は、ベッド出入口 (X, Y 軸) および高位置 (Z 軸) に近づくにつれ大きくなる。 d_{-1}^X はベッド外の空間を分割する閾値、 w_{-1}^X はベッド外の FRW である。

Fig. 6.13 は両被験者の入院環境である。被験者 A はベッド上に布団以外の生活用品が存在しない環境、被験者 B はベッド上にオーバーテーブルがあり、ベッドの背

⁸Depth カメラに映る物体の大きさは、カメラ本体から離れるにつれて小さくなるが、 $v_{mul}(x_s, y_s, z_s)$ および $v_{sub}(x_s, y_s, z_s)$ はこうした影響を平滑化するために使用される。ただし、距離の違いによる影響が大きくなるのは以下の3点のいずれかを満たすときである。(1) θ_c の値が小さい、(2) 分割区画数が多い、(3) ベッドサイズが大きい。今回の実験条件は、カメラ本体の傾き角度を病院環境が許す限り大きくしている。また、分割区画数も $3 \times 3 \times 3 + 3$ と必要最低限にしており（末尾の「+3」はベッド外に拡張された上層 (Fig. 6.11 参照) の区画数を表す）、ベッドも一般的なサイズである。そのため、距離の違いによる影響は小さいと考え、補正係数は全て1および0とした。

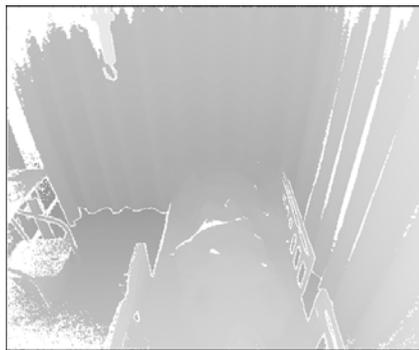
⁹本検証の至適基準としては、既存のセンサ（例：クリップセンサ）を装着した状態での実験が挙げられる。しかし、装着時の違和感に起因して体動が不自然となり、提案システムの正当な評価ができなくなるといった事態を避けるため、今回は至適基準による比較を実施しないこととする。

Table 6.5 : Parameter conditions of the proposed method

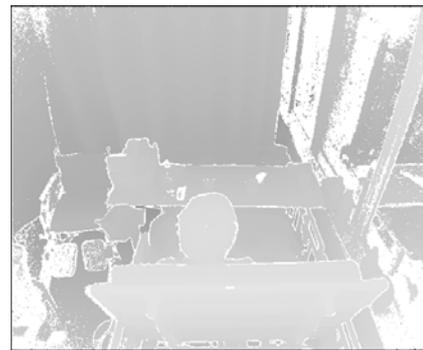
Bed size (W×D×H)	[m]	0.9 × 2.1 × 0.5
Degree of Kinect	[deg]	147.6
Height between Kinect and ground	[m]	1.95
Sample interval	[s]	1.0
Extended measure on X-axis upper layer	[m]	0.5
Thresholds for determining the layers (UL, ML, LL)		1500, 1500, 1500
Coefficients for smoothing (Mul., Sub.)		all 1.0, all 0.0

Table 6.6 : Thresholds for the PCD separation (unit is [m]). Each parameter was adjusted based on the bed and room of a hospital cooperated in this experiment.

X-axis		Y-axis		Z-axis	
d_{-1}^X	-0.50				
d_0^X	0.00	d_0^Y	0.00	d_0^Z	0.10
d_1^X	0.30	d_1^Y	0.50	d_1^Z	0.40
d_2^X	0.60	d_2^Y	1.00	d_2^Z	0.70
d_3^X	0.90	d_3^Y	1.50	d_3^Z	1.45



(a) Subject A



(b) Subject B

Fig. 6.13 : Depth maps showing the hospital environment. (a) and (b) represent the rooms for Subject A and B, respectively. There is an over chair table and a backrest in the room for Subject B.

もたれを起こした環境で検証が行われた。

6.5.2 結果

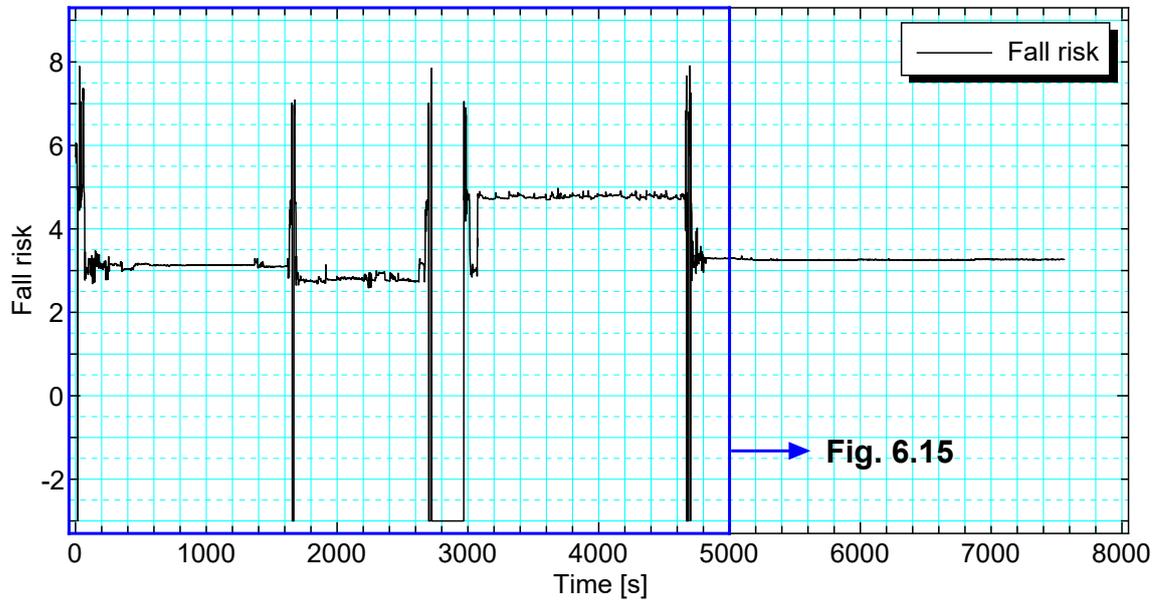
6.5.1 節の条件にて算出された転倒・転落リスクの時系列データを Fig. 6.14 に示す。転倒・転落リスクが負値 (-3.0) となる時間帯は、NLF (患者が不在) と判定されたことを表す。Fig. 6.14(a) の詳細を Fig. 6.15 に、Fig. 6.14(b) の詳細を Fig. 6.16 に示す。Fig. 6.15 は被験者 A, Fig. 6.16 は被験者 B の推定結果である。Fig. 6.15, 6.16 の (a) において、赤点 (A)~(N) の時間帯の Depth マップを転倒・転落リスクの高い方から順に並べた結果を同図の (b) に示す。さらに、Table 6.7 に各状態 (不在 (NLF), 臥位 (Lying down), 長座位 (Long sitting), 端座位 (Sttting sideways), 立位 (Standing), 不明 (Unknown)) における転倒・転落リスクの発生回数を示す。表中の「不明」は、被験者が計測範囲内に存在しているが (「不在」ではないが), 「臥位」, 「長座位」, 「端座位」, 「立位」のいずれにも属さない状態である (例: 「臥位」から「長座位」に遷移する中間の姿勢)。

Fig. 6.15 (被験者 A) を見ると、計測範囲内に患者のみが存在するとき (看護師や清掃員が存在しないとき) の転倒・転落リスクは「立位 (7.0~7.9)」→「端座位 (4.6~4.8)」→「臥位 (2.8~3.3)」の順になることが分かる。また、Table 6.7(a) を確認すると、転倒・転落リスクの値は、臥位は 3.0~4.0, 端座位は 4.0~5.0, 立位は 6.0~の範囲に多く分布していることが見て取れる (長座位は計測中に一度も生じなかった)。これは「患者が立ち上がっているときは転倒の危険性が高く、寝ているときは転倒の危険性が低い」という一般的な感覚や、「患者の重心位置が高いほど大怪我を負いやすい」という物理的観点と一致する。

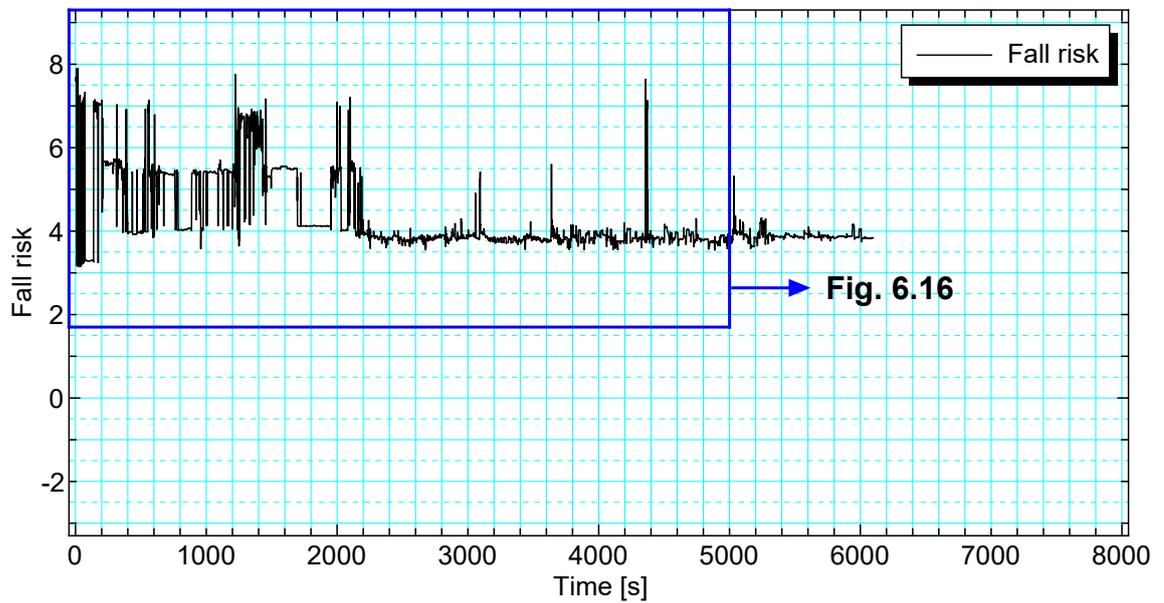
一方、Fig. 6.16 (被験者 B) に関しては、(L) のような例外 (6.5.3 節に後述) を除くと、患者がひとりで居るときは基本的に「立位 (7.1~7.2)」→「端座位 (4.1~5.5)」→「臥位 (4.0)」→「長座位 (3.9)」という関係が成り立つ。また、転倒・転落リスクの値に関しても、臥位は 4.0~5.0, 長座位は 3.0~4.0, 端座位は 5.0~6.0, 立位は 6.0~の範囲に最も多く分布している (Table 6.7(b))。被験者 B は、臥位の転倒・転落リスク (4.0~5.0) が長座位 (3.0~4.0) より大きくなり、転倒・転落リスクの大小関係が Fig. 6.10 とは異なる結果となった。原因としては、被験者 B はベッドの背もたれを起こしており、システムが背もたれを人物の体部と誤認してしまったためだと考えられる。つまり、背もたれを起こしたことで、中層に存在する三次元座標点の数 $n_o(x_s, y_s, 1)$ が大きくなったため、本来ならば $n_o(x_s, y_s, 1)$ が小さくな

るはずの臥位における転倒・転落リスクの推定精度が低下したのである。被験者Bは背もたれの影響により、不適切な結果を算出しやすい。しかし、最も危険な姿勢である立位と、立位に遷移する前の端座位のリスクは、依然として高い値を保っている。そのため、転倒・転落の予防および検知に関しては、運用上は大きな支障をきたさないと考えられる。

なお、6.3.1節でも述べたが、本提案システムはロバスト性を向上させるため、PCDを取得した際にベッド上の空間を分割し、いくつかの区画へと置き換えることで低次元化を達成しており、このとき体型による影響が除外される（小児と大人ほどの違いの場合はその限りではない）。そのため、今回は被験者が2名のみではあるものの、本システムは他の患者に対しても転倒・転落リスクを同様に推定できる可能性が高いといえる。さらに、PCDの分割によってノイズの影響を抑制しているため、多くの環境に適応できると考えられる。

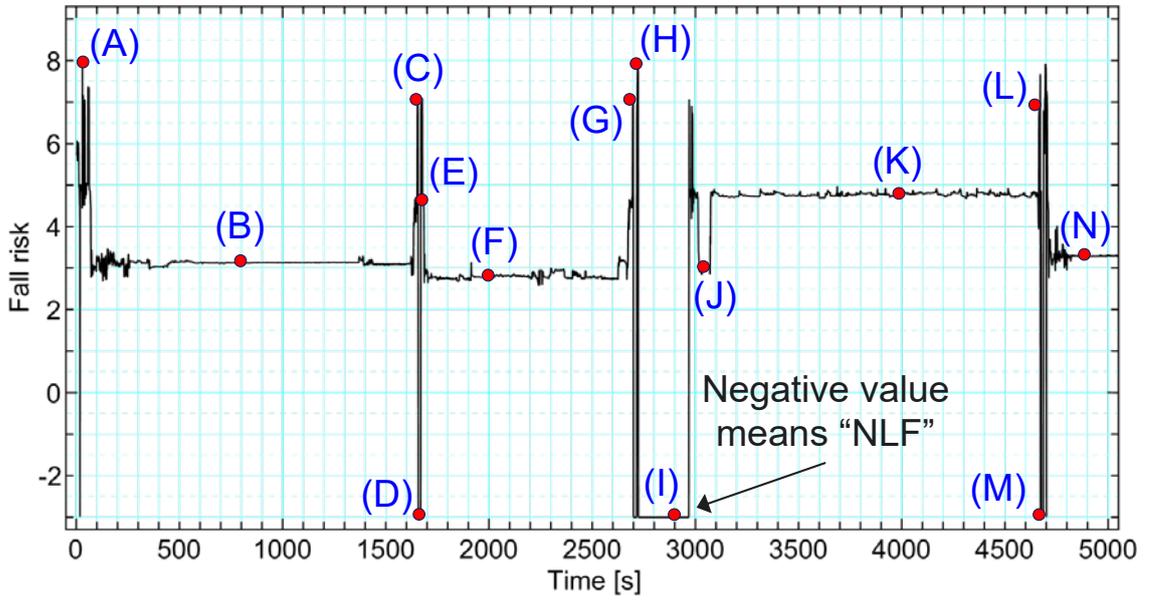


(a) Subject A

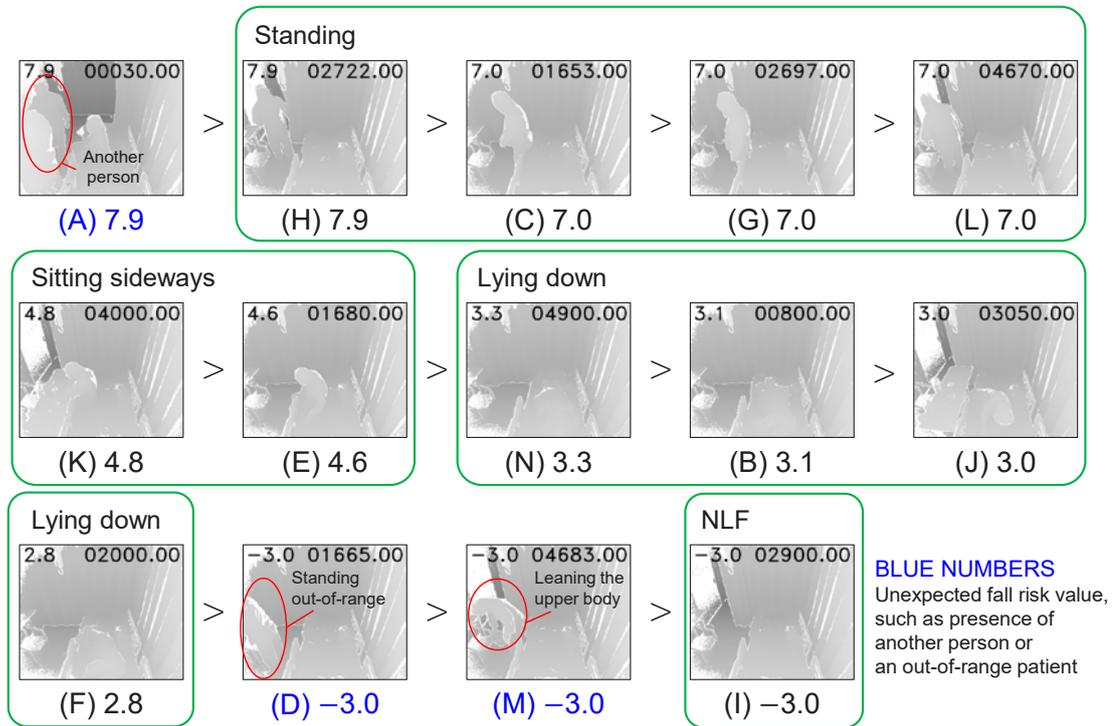


(b) Subject B

Fig. 6.14 : Time-series data of fall risk for each subject

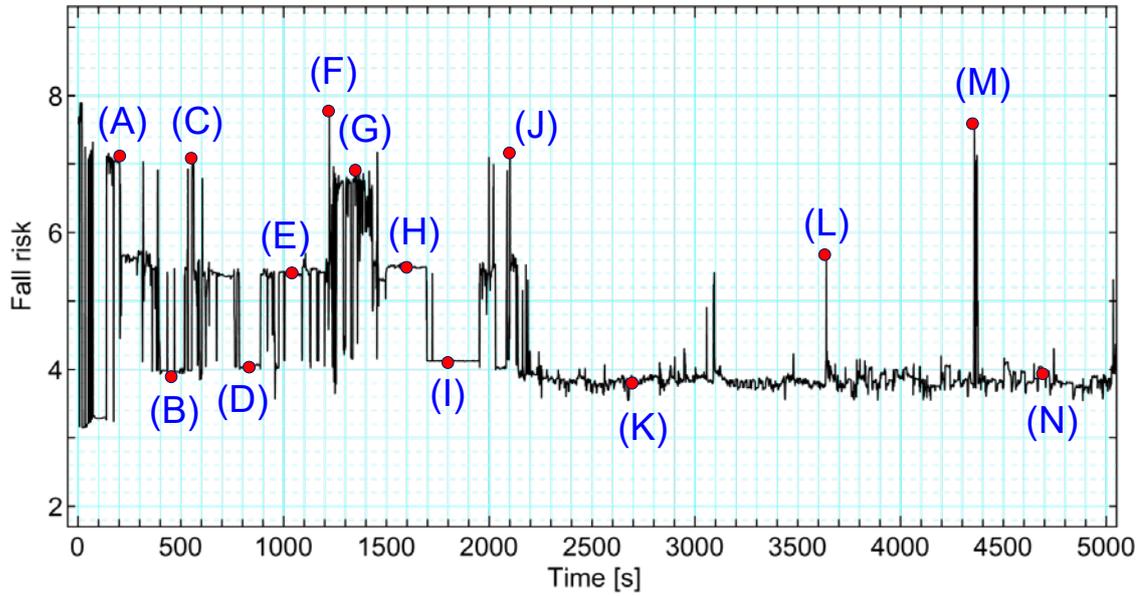


(a) Time-series data (14 red marks are the representative results)

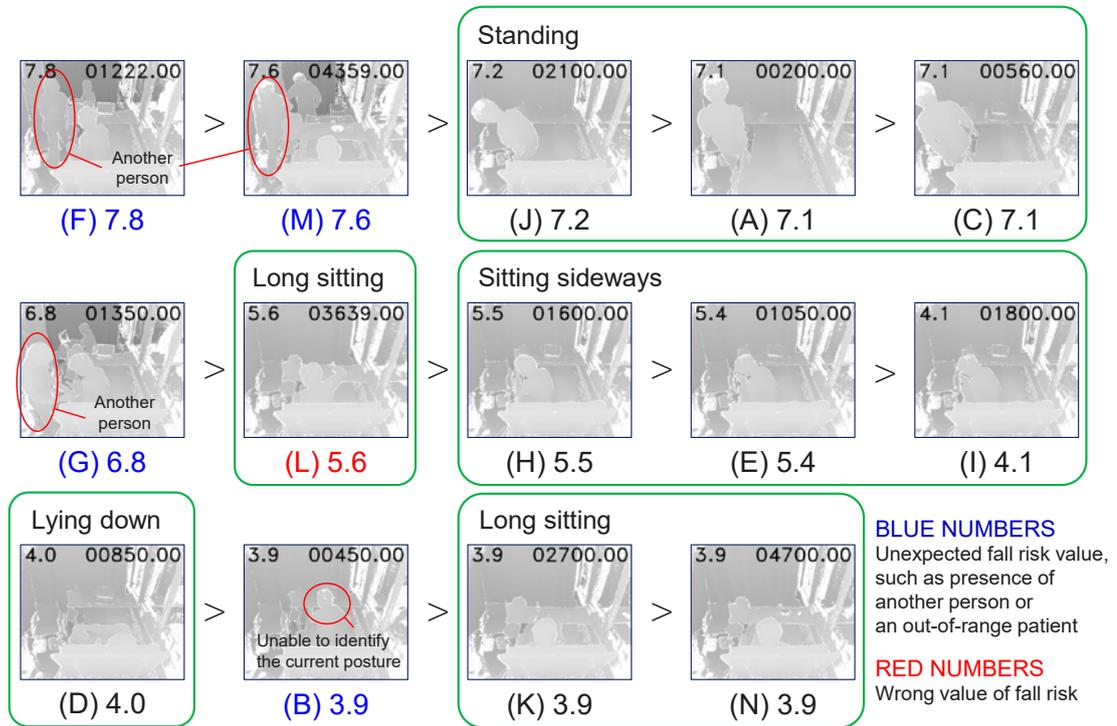


(b) Fall risk comparison of 14 red marks showing in (a)

Fig. 6.15 : Fall risk results of Subject A. Enlarge a part of Fig. 6.14(a) and focus on several results.



(a) Time-series data (14 red marks are the representative results)



(b) Fall risk comparison of 14 red marks showing in (a)

Fig. 6.16 : Fall risk results of Subject B. Enlarge a part of Fig. 6.14(b) and focus on several results.

Table 6.7 : Distribution of fall risk across the various states. “Unknown” is a state which cannot be classified into any state. For example, the depth map (F) showing in Fig. 6.16(b) is classified Unknown because another person is existing within the measurement range. Subject A did not turn into the “Long sitting” posture during the experiment.

(a) Subject A

State	-3.0	2.0 to 3.0	3.0 to 4.0	4.0 to 5.0	5.0 to 6.0	Over 6.0	Sum.
NLF	244	0	0	0	0	0	244
Lying down	0	1012	4414	2	0	0	5428
Long sitting	0	0	0	0	0	0	0
Sitting sideways	0	0	0	1654	0	0	1654
Standing	1	0	0	3	1	49	54
Unknown	45	13	23	59	20	19	179

(b) Subject B

State	-3.0	2.0 to 3.0	3.0 to 4.0	4.0 to 5.0	5.0 to 6.0	Over 6.0	Sum.
NLF	0	0	39	0	0	0	39
Lying down	0	0	10	114	0	0	124
Long sitting	0	0	3611	280	8	0	3899
Sitting sideways	0	0	3	288	935	4	1230
Standing	0	0	1	0	0	68	69
Unknown	0	0	242	177	104	215	738

6.5.3 転倒・転落リスクの誤判定に関する考察

6.5.2節の検証より、提案システムは患者が端座位または立位るとき、転倒・転落リスクが高く算出されることが明らかになった。しかし、一部の結果には誤判定や例外が発生している。本節では誤判定や例外の具体例を述べるとともに、その原因について考察する。

1) 立位を不在と誤判定する（被験者 A）

被験者 A (Fig. 6.15) は、(D) や (M) の Depth マップでは立位の姿勢であるにも関わらず、人物が不在（転倒・転落リスクの値が -3.0 ）と判定される。本検証では、患者がベッド外に存在するときは、転倒・転落リスクの推定に上層のデータのみが用いられる（6.5.1節参照）。一方、(M)を確認すると、患者は背中を曲げ、屈んだ姿勢となっていることが分かる。そのため、Depth カメラに患者の背丈が実際よりも低く映ったことから、不在と判定されたのである。(D)についても、患者が猫背の姿勢となったことで体部が計測範囲外へと移動したため、判定結果が不在となった。ただし、看護師が注意を払う必要のある患者を対象とした場合、一般的に不在は立位よりも危険な状態に位置付けられる。そのため、本提案システムは(D)および(M)のように、立位を不在と誤判定することがあるものの、リスク推定をするうえではより厳しい評価が為されたことから実用上の問題はないといえる。

2) 長座位の転倒・転落リスクが端座位よりも高くなる（被験者 B）

被験者 B (Fig. 6.16) は、(L)では長座位であるにも関わらず、転倒・転落リスクが5.6となっており、端座位((E), (H), (I))よりも高い値が算出された。しかし、一般的な感性に従うならば、端座位の転倒・転落リスクは長座位よりも高くなる方が望ましい。(L)の転倒・転落リスクが高くなった原因は、患者が検証中にベッドの高さを調節したためである。今回取得したDepth マップを確認すると、被験者 B は578~581秒の時間帯にベッドの高さを上昇させていた (Fig. 6.17)。本操作を行ったことで、患者の背丈が実験開始時よりも高く観測されやすくなり、それに伴って転倒・転落リスクの値も高くなったのである（提案手法は、患者が高位置にあるほど、転倒・転落リスクの値が高く算出されやすい）。本問題については、ベッドの高さの変化に合わせて、分割区画の生成位置を変えることで解決できると考えられる。今回被験者が使用したベッドは電動式であり、付属のリモコンを操作することでベッドの高さを調節できる。そのため、リモコンの操作

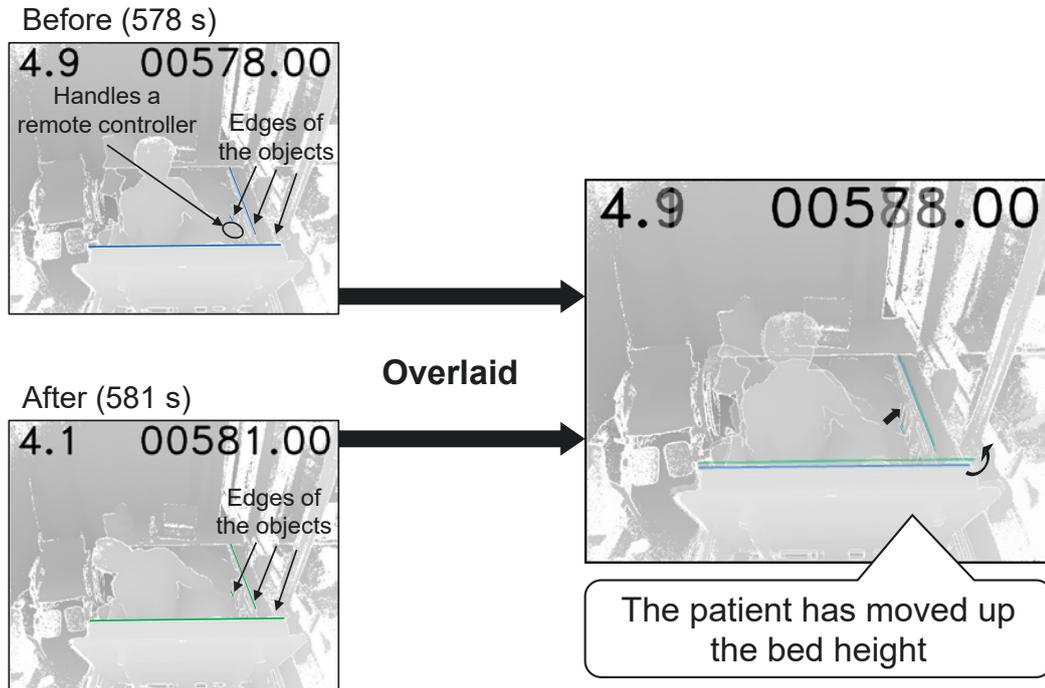


Fig. 6.17 : Adjustment of the bed height with a remote controller

履歴から高さの変化量を取得し、その値に基づいて提案システムのパラメータを更新することは充分可能であると思われる。例として、「ベッドの高さを0.1m上昇」という操作を受け取った際は、Z軸の閾値 $d_{z_s}^Z$ を全て0.1m上方へと移動させる。こうした処理をシステムに追加することで、ベッドと分割区画の位置関係を常に一定に保つことが可能になると考えられる。

3) 同じ端座位であるにも関わらず結果が大きく異なる（被験者 B）

被験者 B (Fig. 6.16) において、(E) と (I) の Depth マップはどちらも被験者が端座位の姿勢であるにも関わらず、転倒・転落リスクはそれぞれ5.4, 4.1となり、両者の間に大きな差異が生じている。本現象については2)と同様、患者がベッドの高さを変更したことが原因で生じたと考えられる。つまり、ベッドの高さが上昇したことで、身体の一部が上層の領域と重なるようになり、着目する層が「中層および下層」から「上層」へと移り変わったため (Eq. (6.8)~(6.10) による判定結果が「ML & LL」から「UL」へと変化)、転倒・転落リスクの推定結果に大きな違いが生じたのである。ただし、本誤判定についても、Z軸の閾値をベッドの高さの変化に応じて適宜調整する処理を追加することで、解決できる可能性が高い。

4) 臥位の転倒・転落リスクが長座位よりも高くなる（被験者 B）

被験者 B (Fig. 6.16) において, (D) の Depth マップは被験者が臥位の姿勢であるにも関わらず, 転倒・転落リスクが長座位よりも高い値となった. しかし, 一般的な感性に従うならば, 長座位の転倒・転落リスクの方が高くなるべきである. 被験者 B の実験環境は, 計測範囲内にベッドの背もたれが存在する. そのため, 中層に属する三次元座標点の数 $n_0(x_s, y_s, 1)$ が大きくなりやすく, 結果として臥位の転倒・転落リスクが通常よりも高く算出された. ただし, 臥位の姿勢は, 身体の向きがベッド長辺と平行 (つまり, 頭部と足部がベッド短辺付近に存在) になるのが一般的であり, 背もたれがあるときに発生することはほとんどない. そのため, 被験者の姿勢自体は臥位に属するものの, 身体の向きがベッド長辺に対してほぼ垂直となる (D) は, 特殊なケース (例外) であるといえる. さらに, 提案システムはベッドに転倒・転落防止柵が装着された状態での使用を想定しており, こうした状況下で (D) の姿勢となることはほぼ不可能である. そのため, 今回の誤判定がシステムの実運用時に発生することは稀であると考えられる. さらに, (D) は通常の臥位とは明らかに異なるため, 異常な姿勢として転倒・転落リスクが高く算出されても何ら問題はない.

6.5.4 人物位置と姿勢との関係

Table 6.7 の結果を見ると, 転倒・転落リスクは同一の姿勢においては類似した値となることが多い. 例として, 被験者 A の転倒・転落リスクは, 端座位では 4.0~5.0, 立位では 6.0~ の位置に多く分布している. 本特徴は, 転倒・転落リスクと姿勢間における相関関係の存在を示唆するものである.

転倒・転落リスクは, 人物位置 g^X, g^Y, g^Z を Eq. (6.14) へと代入し, 算出された r^X, r^Y, r^Z をさらに Eq. (6.15) へと代入することで求められる. つまり, 転倒・転落リスクは, 元々は人物位置であった. 「転倒・転落リスクは元々人物位置である」と「転倒・転落リスクと姿勢間には相関関係がある」という 2 つの前提は, 三段論法によって「人物位置と姿勢間には相関関係がある」という 1 つの結論へと導かれる. よって, 人物位置と姿勢は, 両者の間に関係性が見られる可能性が高いといえる.

Fig. 6.18, 6.19 は臥位, 長座位, 端座位, 立位における人物位置の散布図を表す. Fig. 6.18 は被験者 A, Fig. 6.19 は被験者 B の散布図であり, それぞれ Table 6.7(a), (b) で使用したデータをグラフ化したものである. Table 6.7 では転倒・転落リスクの値をまとめていたが, Fig. 6.18, 6.19 では転倒・転落リスクの値を求める前の人

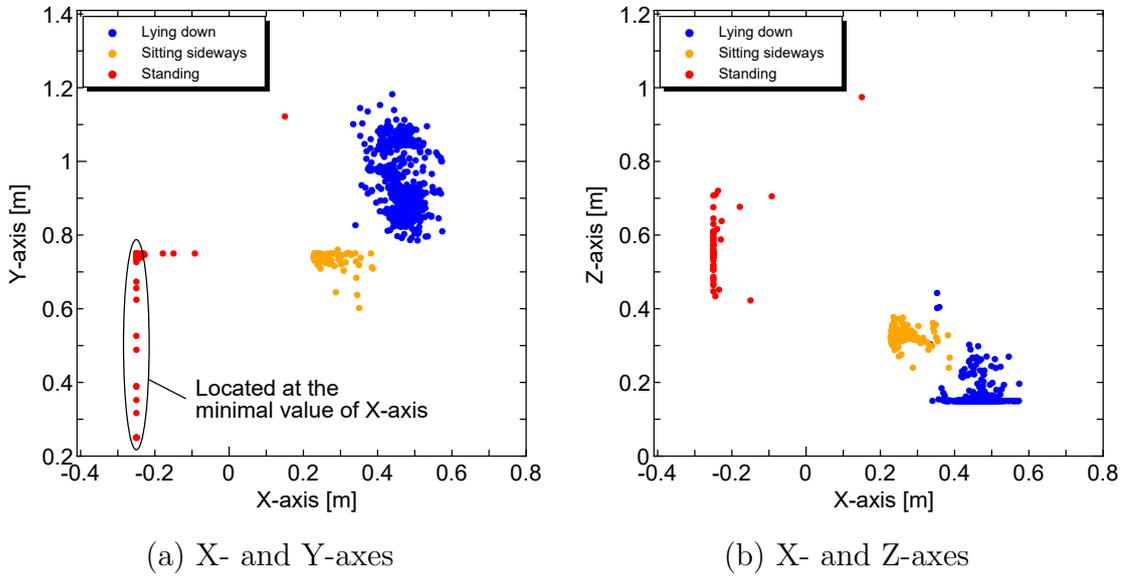


Fig. 6.18 : Scatter diagrams of human locations on each posture (Subject A)

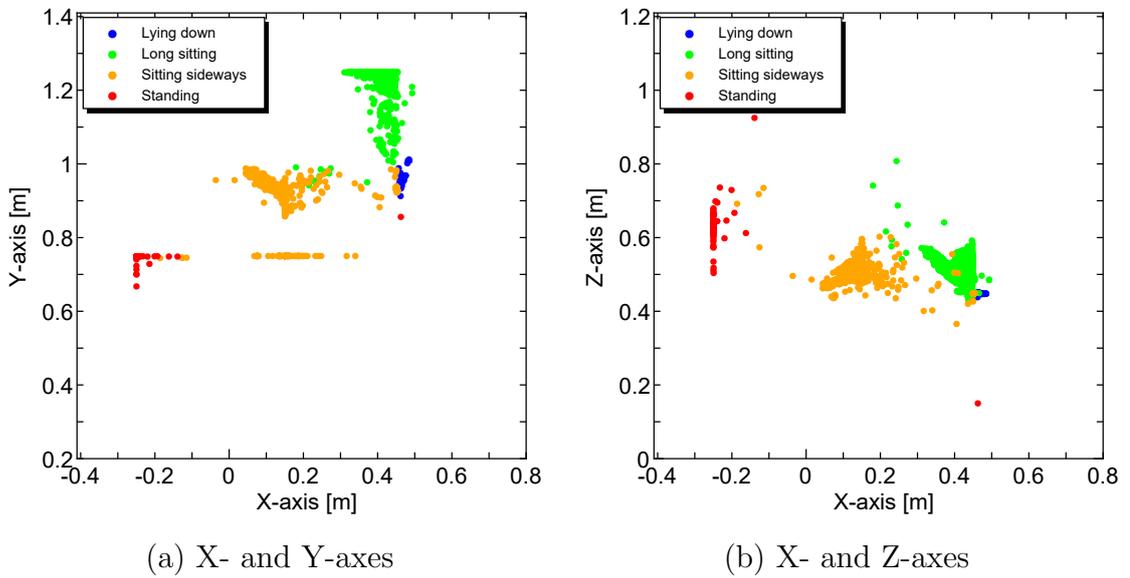


Fig. 6.19 : Scatter diagrams of human locations on each posture (Subject B)

物位置（重心座標）に着目している。各姿勢の分布を見ると、被験者Bの臥位（背もたれの影響により通常とは異なる位置に分布）を除いて、同一姿勢は密接した位置に、異なる姿勢は乖離した位置に点在することが分かる。本結果は、人物位置から姿勢を分類可能なことを示唆するものである¹⁰。

一般的に、人物位置から姿勢を特定することは不可能に近いと考えられる。しかし、本システムは「患者がベッド上またはベッド周辺に存在する」という制約条件（前提条件）が存在する。こうした条件下で患者が行う動作は限られる。例えば、入院患者は端座位の姿勢をベッド中央部やベッド外で行うとは考えづらい。ベッドに腰掛けることができるのは、当然ながらベッド端部だけである。さらに本システムは、基本的には転倒・転落防止柵の付いたベッドでの使用を想定している。ベッドに転倒・転落防止柵があることで制約がさらに強まり、姿勢をより分類しやすくなると考えられる。

我々人間にとって、「姿勢」は馴染み深い概念である。一方、「人物位置」は本章で新たに定義されたデータであり、三次元ベクトルで表されるため、そのデータだけを見て患者の状況を直感的に察知することは、多くの人々にとって困難であると考えられる。そのため、人間の感性をシステムに組み込むためには、人物位置から姿勢情報への変換が必要不可欠だといえる。

6.6 本章のまとめ

第6章では、Depthカメラによって計測されたPCDを用いて、物理的観点に基づく転倒・転落リスクの推定を試みた。提案システムは、PCDをベッド直上視点へと変換、ベッド上の空間情報の分割による低次元化、重心計算に基づく人物位置の推定、FRWを用いた転倒・転落リスクの算出の4ステップで構成される。

2名の実患者に対し、作成したシステムの検証を行った結果、一方は「患者が立ち上がっているときは転倒の危険性が高く、寝ているときは転倒の危険性が低い」という特徴と一致する推定結果が得られた。通常、人間は高位置にあるほど転倒する

¹⁰なお、Fig. 6.18(a)において、X軸の値が -0.25m となる位置に立位のデータ点（赤点）が並んでいるのは、X軸の最小値が -0.25m となるようパラメータが設定されたためである。Table 6.5, 6.6に示す通り、本検証ではX軸をベッド外に 0.50m 拡張している。また、Fig. 6.4に示された座標原点および座標軸に従うと、ベッド外は負値となる領域にあり、その範囲は $-0.50\sim 0.00\text{m}$ となる。そして、人物位置を求める際は重心の計算が行われるため、X軸の最小値は -0.50m の半分である -0.25m となる。以上の理由から、X軸が -0.25m の位置に複数のデータが分布した。

危険性が上昇し、なおかつ転倒・転落した際に大怪我を負う可能性が高くなるため、本結果は物理的観点から見て妥当であるといえる。

しかし、もう一方の患者については、最も転倒・転落の危険性が低い姿勢である臥位の際に、転倒・転落リスクの値が高くなるという結果になった。このような結果となった原因は、患者がベッドの背もたれを起こしたためであり、背もたれを患者の体部と誤判定してしまい、当初の予想とは異なる転倒・転落リスクを算出した。しかし、本提案システムは、基本的には転倒・転落の危険性が高い患者への使用を想定しており、こうした患者はベッドに転倒・転落防止用の柵が設置されることが多い。ベッドに背もたれと柵が存在する状況下で、患者が臥位の姿勢となることは不可能に近い。よって、臥位の姿勢に対する転倒・転落リスクが高くなることは、実用上は大きな問題にはなり得ない。

上記の検証に加え、人物位置の散布図を別途確認した結果、人物位置と姿勢の間には相関関係があることが示唆された。つまり、患者がベッド上またはその周辺に存在する場合、その患者の位置情報（重心座標）を見ることで、看護師にとって馴染み深い概念である「姿勢」を推定できる可能性が高い。

以上より、提案システムは実際の環境下でも使用できる可能性が高いこと、ならびに、患者の姿勢を推定する能力を有していることが明らかになった。

第7章 患者の特徴を多方面から鑑みた 転倒・転落リスク推定

7.1 本章の目的

第7章では、転倒・転落アセスメントスコアシート（FAS）を用いた推定結果と Depth カメラを用いた推定結果を統合する。第6章では、Depth カメラを用いて患者の位置情報を求め、その位置情報から物理的観点に基づく転倒・転落リスクを推定可能であることを示した。しかし、第6章では転倒・転落リスクを算出する際に、筆者が任意に定めた転倒・転落リスクの重み係数を使用する。これらの重み係数は、ベッドの位置関係に基づいて相対的に定めているだけに過ぎない。そのため、患者個人の病状に即した転倒・転落リスクの推定を行うことができない。

さらに、提案システムは、看護師の代わりに入院患者のモニタリングを行うことを使用目的の一つとすることから、看護師と同等の判断ロジックで転倒・転落リスクを推定する方が望ましい。仮に、転倒・転落リスクの推定をシステム独自の判断ロジックに基づいて行った場合、看護師とシステムの判断が乖離してしまい、看護師の業務を代行するという目的を達成できなくなる。さらに、提案システムを導入する医療現場の実情を考慮した転倒・転落リスク推定を行うことが難しくなるため、システムの信頼性を担保することが不可能となる。一方、看護師は長年の現場経験により、入院患者について豊富な知識を有していると考えられる。そのため、看護師の経験則をシステムに組み入れることで、提案システムの妥当性や信頼性を向上させられる可能性が高いといえる。また、看護師の業務を代わりに遂行することが可能となる。

第4章および第5章では、FASを用いた看護師の臨床判断をモデル化する方法について述べた。本モデルを使用することで、看護師の経験則に基づく患者の転倒・転落リスクを「姿勢ごと」に算出できる。一方、第6章では患者の位置情報を求め、物理的な転倒・転落リスクを推定した。このとき、患者がベッド上（またはベッド周辺）に存在するという条件を満たす場合、患者の位置情報と「姿勢」との間に相

関関係が見られることが明らかになった。そのため、第7章では「姿勢」を媒介として、FASを入力とする転倒・転落リスク推定モデル（第4, 5章）と、Depthカメラを用いた位置情報の推定手法（第6章）を組み合わせ、患者の現在の転倒・転落リスクを導出する方法について述べる。これにより、患者の内実（FASの内容）と外見（Depthカメラから得られる情報）の両者を踏まえることが可能となり、患者の特徴を多方面から鑑みた転倒・転落リスク推定を実現できる。また、看護師の経験則を利用することが可能となる。

第4, 5章では、VASの線分左端からの距離を転倒・転落リスクの値としており、単位が[mm]であった。一方、第6章では転倒・転落リスクが無次元量であった。第7章では、方法論の一般化のため、転倒・転落リスクの単位を[%]と定める。このとき、0%を「患者がベッド上で全く危険がない状態」、100%を「看護師が現在の業務を中断しすぐに病室に向かうほど、物理的観点において明らかに転落・転落の危険が伴う状態」とする。なお、本章では単位に[%]を用いるが、これは患者が転倒・転落する「確率」を示している訳ではない。今回は転倒・転落リスクの定義を「患者の内実と外見を考慮したときの転倒・転落の危険性」としており、本数値を求める際は看護師の臨床判断が用いられるため、実際は「看護師が感じる危険の程度」を表すことになる。

本章では転倒・転落リスクを推定するにあたり、患者の姿勢および看護師の臨床判断が用いられる。このとき、「姿勢」は境界が不明瞭なあいまいな概念である。また、人間は推論を行う際に、判断に迷いやゆらぎが生じやすい。提案手法では、こうしたあいまいさや迷いを数学的に表現するため、転倒・転落リスクの推定にファジィ推論を用いることとする。

7.2 ファジィ推論に基づく転倒・転落リスク推定手法

7.2.1 システムの全体像

6.2.2~6.2.4節では、人物位置（重心座標） g^X , g^Y , g^Z を求める方法を示した。その後、6.2.5節では各分割区画の閾値に対して重み係数を付与し、物理的観点に基づく転倒・転落リスクを算出した。第7章では、人物位置の推定後に重み係数を用いた計算を行うのではなく、ファジィ推論によって転倒・転落リスクを導出する。システム全体の構成概要図をFig. 7.1に示す。また、人物位置から転倒・転落リスクを求める推論の流れをFig. 7.2に示す。Fig. 7.2において、メンバーシップ関数

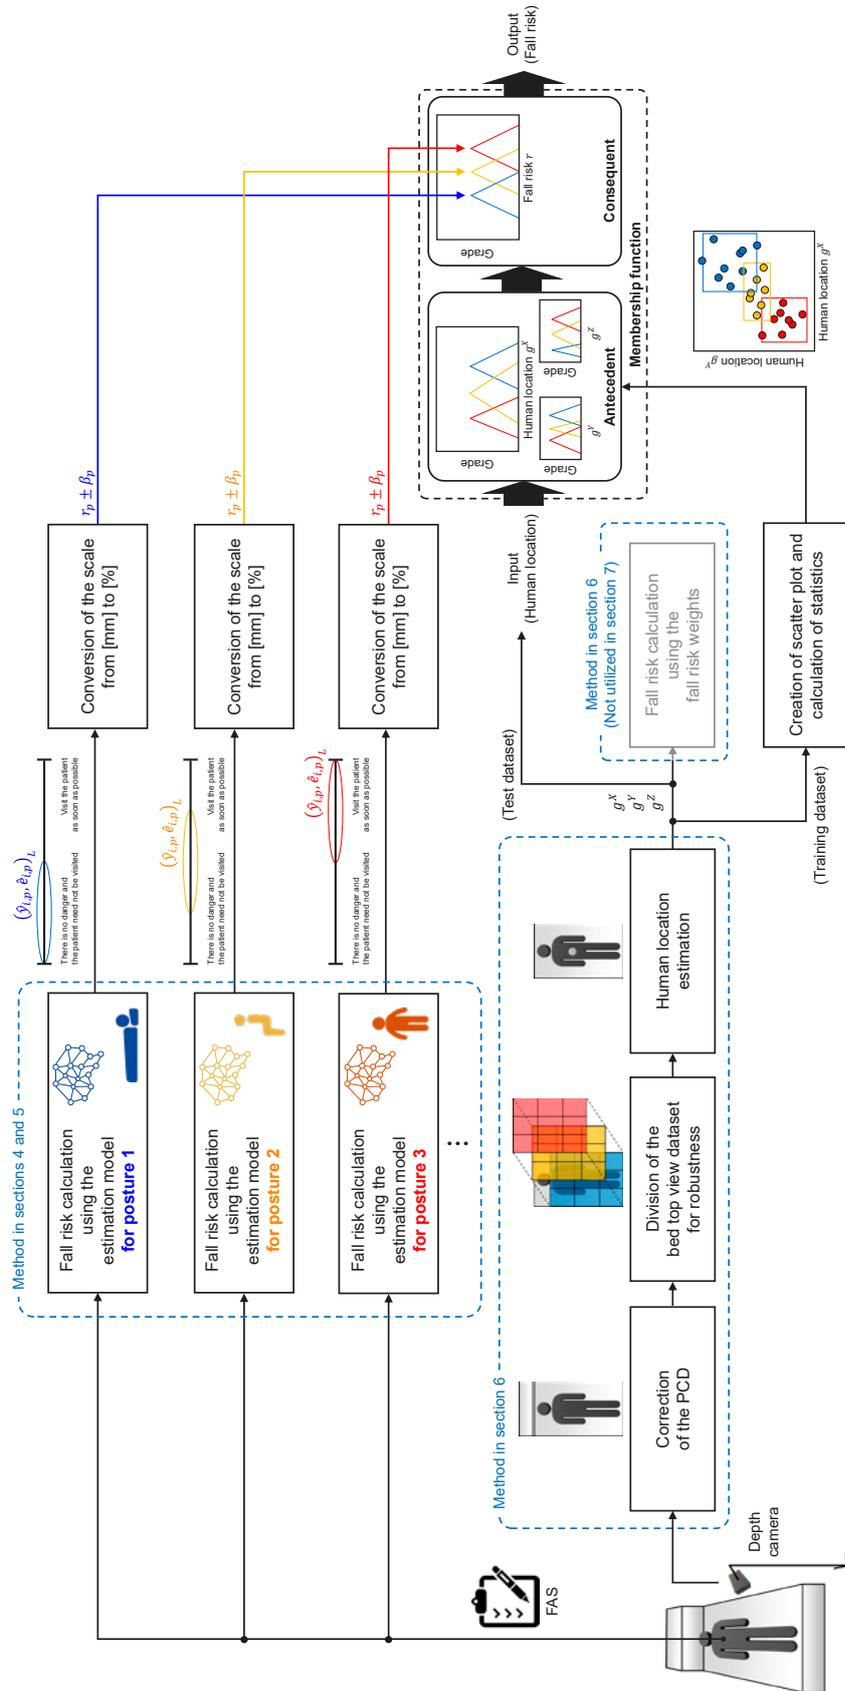


Fig. 7.1 : Concept of the proposed system with the methods in sections 4 to 6

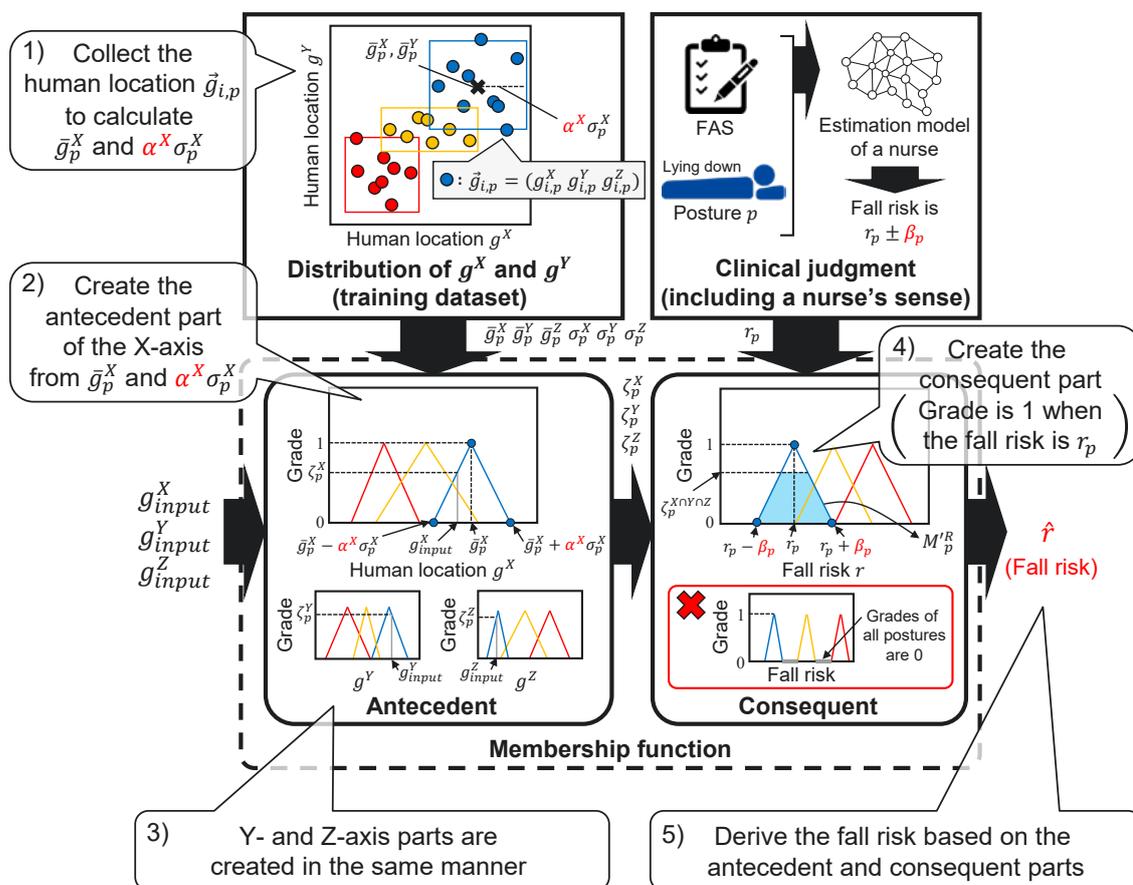


Fig. 7.2 : Procedure of fuzzy inference that derives the fall risk \hat{r} from the human location (center of gravity) g_{input}^X , g_{input}^Y , and g_{input}^Z

(Membership function) は前件部 (Antecedent) と後件部 (Consequent) で構成されており、前者は人物位置から姿勢、後者は姿勢から転倒・転落リスクの推論を行う。

前件部は、患者の重心座標と姿勢との関係性を表すデータセットに基づき作成される。本システムは、ベッド上またはベッド周辺において、身体機能の低下した患者を対象とした状況を想定している。これらは制約条件であり、患者の行動パターンを限定させる要因となる。そのため、重心座標と姿勢を結びつけることが可能となる。前件部のメンバーシップ関数は、上述した性質に基づき、各姿勢の重心座標データ (学習データ) および調整パラメータ α^X , α^Y , α^Z により設計される。

後件部の設計は、姿勢を媒介変数とすることで、患者の姿勢を考慮した看護師のリスク予測に関する感性を取り入れる (丸岡らの研究によると、看護師が転倒・転落リスクを考える際には患者の姿勢を考慮するため [30])。後件部のメンバーシップ関数は、看護師が患者の FAS と姿勢を見たときに感じる転倒・転落リスクに基づ

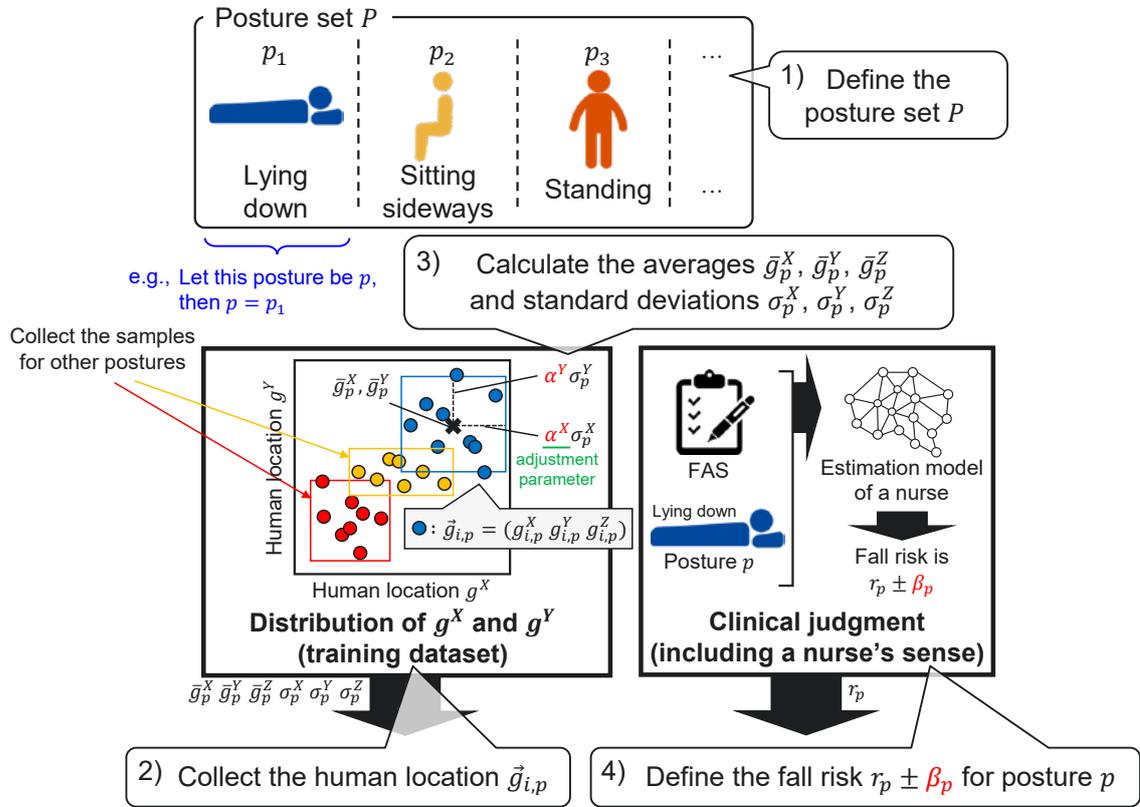


Fig. 7.3 : Collection of datasets to create the membership functions

き作成される。 β_p は、看護師が姿勢 p の転倒・転落リスクを決定する際に生じる判断のあいまいさや迷いの大きさを表す。なお、後件部は看護師が任意に設計可能であるが、本論文ではファジィ線形回帰分析によって構築された看護師の推定モデル(第4, 5章)を用いた設計についても想定している。

7.2.2~7.2.4節では、設計のためのデータセット定義、メンバーシップ関数(前件部・後件部)とIF-THEN ルールの作成、ファジィ推論の実行手順についてそれぞれ述べる。

7.2.2 設計のためのデータセット定義

まずは、メンバーシップ関数を作成するためのデータセットを定義する。概要図を Fig. 7.3, 詳細を以下に示す。

1) 姿勢の集合を P とする。姿勢の個数が N_p のとき、 P は Eq. (7.1) で表される。

$$P = \{p_1, p_2, \dots, p_{N_p}\} \tag{7.1}$$

ここで、ある任意の姿勢 p は P に帰属する (p は集合 P に属する)。つまり、 $p \in P$ である。

- 2) 姿勢 p における人物位置情報 (重心座標) を $\vec{g}_{i,p}$ とすると、 $\vec{g}_{i,p}$ はEq. (7.2)のベクトルで表される。 $g_{i,p}^X$, $g_{i,p}^Y$, $g_{i,p}^Z$ は i 番目のデータにおけるX, Y, Z軸の人物位置情報である。

$$\vec{g}_{i,p} = \begin{pmatrix} g_{i,p}^X & g_{i,p}^Y & g_{i,p}^Z \end{pmatrix} \quad (7.2)$$

これを前件部の学習データ $\vec{g}_{i,p}$ として、任意の人物 (可能ならば提案システムを使用する患者本人) から I_p 個取得する ($i = 1, 2, \dots, I_p$)。

- 3) 前件部学習データのX軸平均 \bar{g}_p^X , 標準偏差 σ_p^X をEq. (7.3), (7.4)より算出する¹。

$$\left\{ \begin{array}{l} \bar{g}_p^X = \frac{1}{I_p} \sum_{i=1}^{I_p} g_{i,p}^X \\ \bar{g}_p^Y = \frac{1}{I_p} \sum_{i=1}^{I_p} g_{i,p}^Y \\ \bar{g}_p^Z = \frac{1}{I_p} \sum_{i=1}^{I_p} g_{i,p}^Z \end{array} \right. \quad (7.3)$$

$$\left\{ \begin{array}{l} \sigma_p^X = \sqrt{\frac{1}{I_p - 1} \sum_{i=1}^{I_p} (g_{i,p}^X - \bar{g}_p^X)^2} \\ \sigma_p^Y = \sqrt{\frac{1}{I_p - 1} \sum_{i=1}^{I_p} (g_{i,p}^Y - \bar{g}_p^Y)^2} \\ \sigma_p^Z = \sqrt{\frac{1}{I_p - 1} \sum_{i=1}^{I_p} (g_{i,p}^Z - \bar{g}_p^Z)^2} \end{array} \right. \quad (7.4)$$

Y, Z軸も同様に平均 \bar{g}_p^Y , \bar{g}_p^Z , 標準偏差 σ_p^Y , σ_p^Z を算出する²。

¹今回は母集団の分布が不明であるため、標本分散の平方根により、標準偏差の不偏推定量を近似する。

²なお、学習データによっては、人物位置情報 (重心座標) が正規分布に従わないことも当然考えられる。しかし、統計量の種類を増やすと、方法論が複雑化して利便性が低下する恐れがあるため、今回は平均と標準偏差のみを用いて人物位置情報の分布を近似することとした。

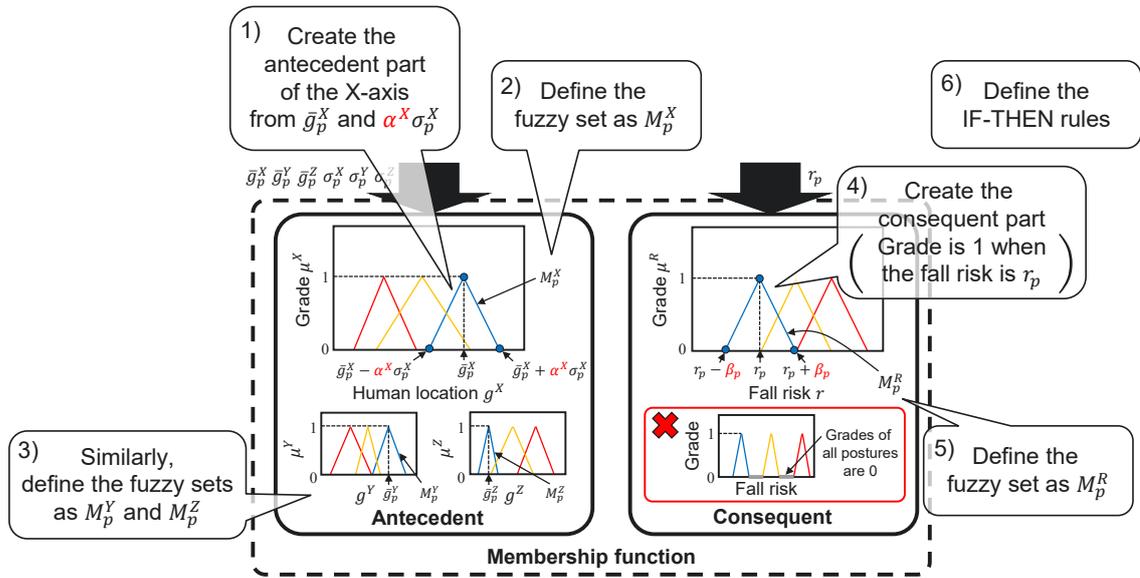


Fig. 7.4 : Creation of membership functions and IF-THEN rules

- 4) 患者が姿勢 p のときの転倒・転落リスク $r_p \pm \beta_p$ [%] を任意に設定し、後件部の学習データとする。ここで、 β_p は判断のあいまいさ（迷い）を表す。なお、学習データの作成に第 4, 5 章で求めたモデル式を用いる場合、 r_p および β_p は Eq. (7.5) より求められる。

$$\begin{cases} r_p = \hat{y}_{i,p} * \frac{100}{L} \\ \beta_p = \hat{e}_{i,p} * \frac{100}{L} \end{cases} \quad (7.5)$$

ここで、 $\hat{y}_{i,p}$ 、 $\hat{e}_{i,p}$ は識別番号 i の FAS (4.2.1 節参照)³における姿勢 p の転倒・転落リスク（推定値）を表す L-L ファジィ数の各要素であり、 $\hat{y}_{i,p}$ は L-L ファジィ数の中心、 $\hat{e}_{i,p}$ は L-L ファジィ数の幅を表す（単位は共に [mm]）。また、 L は VAS の線分の長さであり、第 5 章の検証では 152mm としていた。

7.2.3 メンバシップ関数と IF-THEN ルールの作成

7.2.2 節で定義したデータセットより、メンバシップ関数および IF-THEN ルールの作成を行う。概要図を Fig. 7.4、アルゴリズムを以下に示す。

³ $\hat{y}_{i,p}$ および $\hat{e}_{i,p}$ における i は、Eq. (7.3), (7.4) で用いられる i とは別物であり、前件部学習データの識別番号を表す訳ではない。Eq. (7.5) の i は、FAS の識別番号 (4.2.1 節で定義) を表す。

- 1) 学習データのX軸平均 \bar{g}_p^X , 標準偏差 σ_p^X から前件部のメンバーシップ関数 $\mu_p^X(g^X)$ を Eq. (7.6) と設定する. α^X は調整パラメータである.

$$\mu_p^X(g^X) = \begin{cases} \frac{g^X}{\alpha^X \sigma_p^X} - \frac{\bar{g}_p^X}{\alpha^X \sigma_p^X} + 1 & ; \bar{g}_p^X - \alpha^X \sigma_p^X \leq g^X \leq \bar{g}_p^X \\ -\frac{g^X}{\alpha^X \sigma_p^X} + \frac{\bar{g}_p^X}{\alpha^X \sigma_p^X} + 1 & ; \bar{g}_p^X < g^X \leq \bar{g}_p^X + \alpha^X \sigma_p^X \\ 0 & ; \text{otherwise} \end{cases} \quad (7.6)$$

- 2) $\mu_p^X(g^X)$ のファジィ集合 M_p^X を Eq. (7.7) のように設定する.

$$M_p^X = \{(g^X, \mu_p^X(g^X)) \mid g^X \in \mathbb{R}\} \quad (7.7)$$

- 3) Y, Z 軸についても 1), 2) の手順に従いメンバーシップ関数 $\mu_p^Y(g^Y)$, $\mu_p^Z(g^Z)$ およびファジィ集合 M_p^Y , M_p^Z を設定する.

- 4) つづいて, 転倒・転落リスクの学習データ $r_p \pm \beta_p$ から後件部のメンバーシップ関数 $\mu_p^R(r)$ を Eq. (7.8) のように設定する.

$$\mu_p^R(r) = \begin{cases} \frac{r}{\beta_p} - \frac{r_p}{\beta_p} + 1 & ; r_p - \beta_p \leq r \leq r_p \\ -\frac{r}{\beta_p} + \frac{r_p}{\beta_p} + 1 & ; r_p < r \leq r_p + \beta_p \\ 0 & ; \text{otherwise} \end{cases} \quad (7.8)$$

- 5) $\mu_p^R(r)$ のファジィ集合 M_p^R を

$$M_p^R = \{(r, \mu_p^R(r)) \mid -\beta_p \leq r \leq 100 + \beta_p\} \quad (7.9)$$

とする.

- 6) 多重ファジィ推論形式 (IF-THEN ルール) を Eq. (7.10) のように設定する. 前提1~前提 N_p はそれぞれ「else if (OR)」で結ばれている.

前提 1	If g^X is M_{p1}^X and g^Y is M_{p1}^Y and g^Z is M_{p1}^Z then r is M_{p1}^R else
前提 2	If g^X is M_{p2}^X and g^Y is M_{p2}^Y and g^Z is M_{p2}^Z then r is M_{p2}^R else
⋮	⋮
前提 N_p	If g^X is $M_{pN_p}^X$ and g^Y is $M_{pN_p}^Y$ and g^Z is $M_{pN_p}^Z$ then r is $M_{pN_p}^R$
前提 $N_p + 1$	g^X is M^X and g^Y is M^Y and g^Z is M^Z
結論	r is M^R

(7.10)

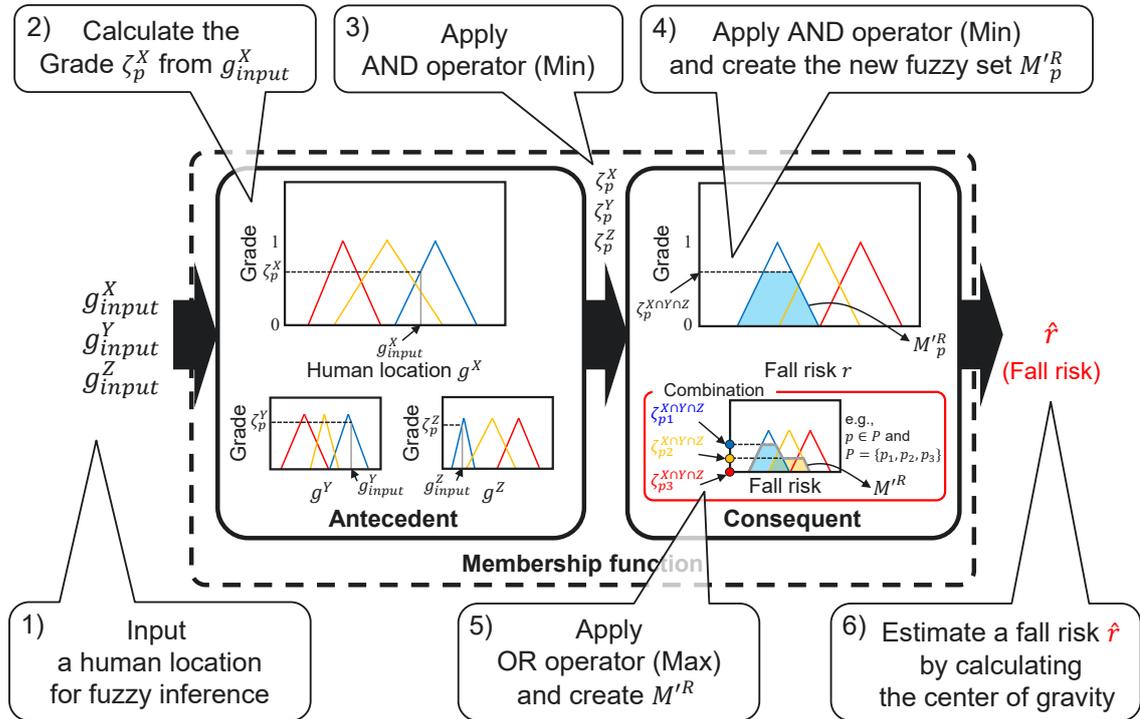


Fig. 7.5 : Execution of fuzzy inference

ここで、 M^X, M^Y, M^Z は入力データ $g_{input}^X, g_{input}^Y, g_{input}^Z$ のファジィ集合、 M^R は M^X, M^Y, M^Z より推定された転倒・転落リスクのファジィ集合である⁴。

7.2.4 ファジィ推論の実行手順

作成されたメンバーシップ関数と入力データ $g_{input}^X, g_{input}^Y, g_{input}^Z$ よりファジィ推論を実行する。概要を Fig. 7.5 に示すとともに、実行手順 [63] を以下に述べる。

- 1) 6.2.2～6.2.4 節に示した方法により、人物位置（重心座標） $g_{input}^X, g_{input}^Y, g_{input}^Z$ を取得し、ファジィ推論の入力データとする。
- 2) 前件部のファジィ集合 M_p^X, M_p^Y, M_p^Z から、入力データの帰属度（Grade） $\zeta_p^X, \zeta_p^Y, \zeta_p^Z$ を求める。Eq. (7.11) は帰属度 ζ_p^X の推定式である。式中の $\mu^X(g^X)$ は、 M^X を設定するためのメンバーシップ関数を表す。また、 \vee は論理和（max）、 \wedge

⁴Eq. (7.10) に示す多重ファジィ推論形式の基本概念については、3.3.5 節に記載を行っている。このとき、各種前提条件についても説明を記している。

は論理積 (min) を表す⁵。

$$\begin{aligned}\zeta_p^X &= \bigvee_{g^X} \{\mu_p^X(g^X) \wedge \mu'^X(g^X)\} \\ &= \max_{g^X} [\min\{\mu_p^X(g^X), \mu'^X(g^X)\}]\end{aligned}\tag{7.11}$$

ζ_p^X は姿勢 p の確からしさを表しており、人物位置から転倒・転落リスクを推定するときの媒介変数の役割を果たす。

- 3) $\zeta_p^X, \zeta_p^Y, \zeta_p^Z$ を AND 演算で結び⁶、新たな帰属度 $\zeta_p^{X \cap Y \cap Z}$ を作成する。

$$\begin{aligned}\zeta_p^{X \cap Y \cap Z} &= \zeta_p^X \wedge \zeta_p^Y \wedge \zeta_p^Z \\ &= \min(\zeta_p^X, \zeta_p^Y, \zeta_p^Z)\end{aligned}\tag{7.12}$$

- 4) 前件部の帰属度 $\zeta_p^{X \cap Y \cap Z}$ から、後件部のファジィ集合 M_p^R の頭切りを行い、後件部の新たなファジィ集合 $M_p'^R$ を作成する。頭切りは Eq. (7.13) によって行われ、 $\mu_p^R(r)$ は M_p^R のメンバーシップ関数、 $\mu_p'^R(r)$ は $M_p'^R$ のメンバーシップ関数を表す。

$$\mu_p'^R(r) = \zeta_p^{X \cap Y \cap Z} \wedge \mu_p^R(r)\tag{7.13}$$

- 5) 全姿勢 $P (p_1 \sim p_{N_p})$ に対し 2)～4) を行う。その後、後件部のファジィ集合全てを OR 演算で結んだ⁷ファジィ集合 M'^R を作成する。

$$\mu'^R(r) = \mu'_{p1}{}^R(r) \vee \mu'_{p2}{}^R(r) \vee \dots \vee \mu'_{p_{N_p}}{}^R(r)\tag{7.14}$$

$$M'^R = \{(r, \mu'^R(r)) \mid -\beta_p \leq r \leq 100 + \beta_p\}\tag{7.15}$$

Eq. (7.14) の $\mu'^R(r)$ は M'^R のメンバーシップ関数であり、 M'^R は Eq. (7.15) より表される。 $\mu'_{p1}{}^R(r), \mu'_{p2}{}^R(r), \dots, \mu'_{p_{N_p}}{}^R(r)$ は、頭切り後のファジィ集合 $M'_{p1}{}^R, M'_{p2}{}^R, \dots, M'_{p_{N_p}}{}^R$ のメンバーシップ関数である。

- 6) M'^R のメンバーシップ関数 $\mu'^R(r)$ に対して重心法を行い、最終的な転倒・転落リスク \hat{r} を算出する。

$$\hat{r} = \frac{\int_{-\beta_p}^{100+\beta_p} \{r \times \mu'^R(r)\} dr}{\int_{-\beta_p}^{100+\beta_p} \mu'^R(r) dr}\tag{7.16}$$

⁵論理和，論理積はそれぞれ OR 演算，AND 演算とも呼ばれる。

⁶Eq. (7.10) において， g^X, g^Y, g^Z は「AND」で結ばれるため。

⁷Eq. (7.10) において，前提 1～前提 N_p は「OR」で結ばれるため。

Table 7.1 : Parameter conditions of the proposed method concerning the depth camera (a Microsoft Kinect sensor)

Bed size (W×D×H)	[m]	0.9 × 2.1 × 0.5
Degree of Kinect	[deg]	147.6
Height between Kinect and ground	[m]	1.95
Sample interval	[s]	1.0
Extended measure on X-axis upper layer	[m]	0.5
Thresholds for determining the layers (UL, ML, LL)		1000, 1500, 1500
Coefficients for smoothing (Mul., Sub.)		all 1.0, all 0.0

Table 7.2 : Thresholds for the PCD separation (unit is [m])

X-axis		Y-axis		Z-axis	
d_{-1}^X	-0.50				
d_0^X	0.00	d_0^Y	0.00	d_0^Z	0.10
d_1^X	0.30	d_1^Y	0.50	d_1^Z	0.40
d_2^X	0.60	d_2^Y	1.00	d_2^Z	0.70
d_3^X	0.90	d_3^Y	1.50	d_3^Z	1.55

7.3 検証

7.3.1 メンバーシップ関数の設計

提案手法の有用性を示すため、実際の病院で検証を行う。実験条件を Table 7.1, 7.2 に示す。今回は 6.5 節とは異なる病室を使用するため、パラメータの値をいくつか変更している。被験者としては、実際の入院患者 2 名を選定した (6.5 節の被験者 2 名とは別人)。検証時に使用したベッドは一般的な医療用ベッドである。今回は、ベッド上に布団以外の生活用品は存在せず、ベッドの背もたれを起こさない条件下で実験を行う。

本検証では、患者 1 名当たり約 2 時間の人物位置データを連続して取得し、その中から姿勢が臥位 (Lying down)、長座位 (Long sitting)、端座位 (Sitting sideways)、立位 (Standing) であるものを計 8830 個選択した ($P = \{ \text{臥位, 長座位, 端座位, 立位} \}$)。各姿勢のデータ個数は、臥位 5337 個、長座位 576 個、端座位 2620 個、立位 297 個である。ここから、K-分割交差検証によって、提案手法の有効性を確認する。今回は $K = 4$ として、8830 個の人物位置データを 4 分割し、その内 3 つを学習デー

Table 7.3 : Averages and standard deviations for each fold

(a) 1st fold

Posture p	Num. I_p	Average			Standard deviation		
		\bar{g}_p^X	\bar{g}_p^Y	\bar{g}_p^Z	σ_p^X	σ_p^Y	σ_p^Z
Lying down	4003	0.463	0.899	0.153	0.047	0.088	0.016
Long sitting	432	0.398	0.994	0.424	0.084	0.281	0.104
Sitting sideways	1965	0.143	0.736	0.408	0.097	0.055	0.061
Standing	223	-0.244	0.565	0.594	0.028	0.208	0.083

(b) 2nd fold

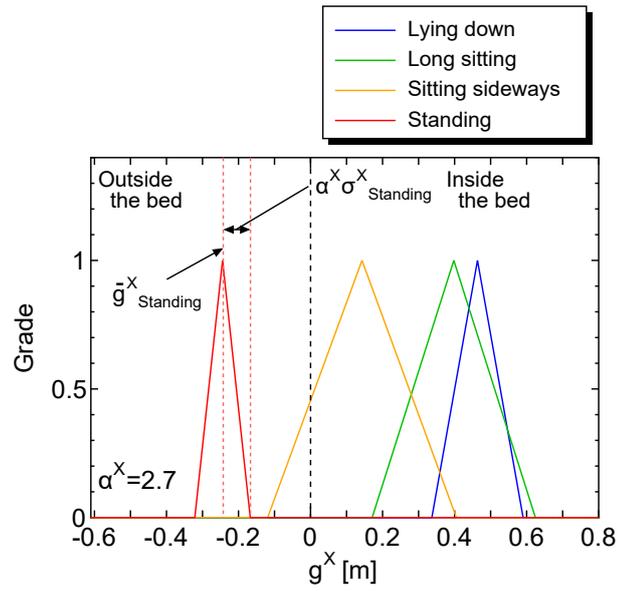
Posture p	Num. I_p	Average			Standard deviation		
		\bar{g}_p^X	\bar{g}_p^Y	\bar{g}_p^Z	σ_p^X	σ_p^Y	σ_p^Z
Lying down	4002	0.462	0.900	0.153	0.047	0.088	0.017
Long sitting	432	0.397	0.988	0.420	0.085	0.281	0.105
Sitting sideways	1965	0.144	0.735	0.406	0.098	0.058	0.063
Standing	222	-0.243	0.570	0.594	0.033	0.208	0.083

(c) 3rd fold

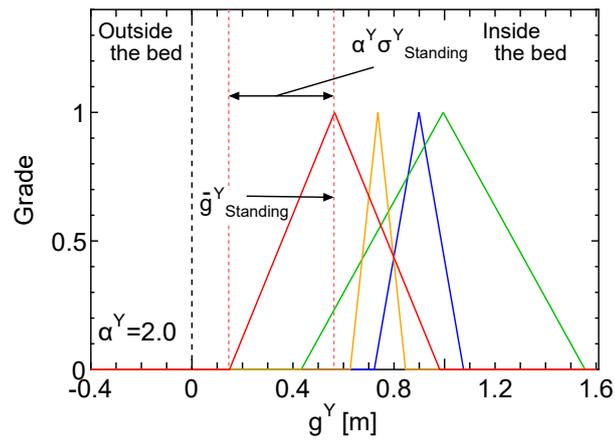
Posture p	Num. I_p	Average			Standard deviation		
		\bar{g}_p^X	\bar{g}_p^Y	\bar{g}_p^Z	σ_p^X	σ_p^Y	σ_p^Z
Lying down	4003	0.463	0.899	0.153	0.047	0.088	0.017
Long sitting	432	0.396	0.996	0.417	0.084	0.279	0.101
Sitting sideways	1965	0.142	0.736	0.409	0.100	0.057	0.061
Standing	223	-0.245	0.586	0.595	0.022	0.201	0.087

(d) 4th fold

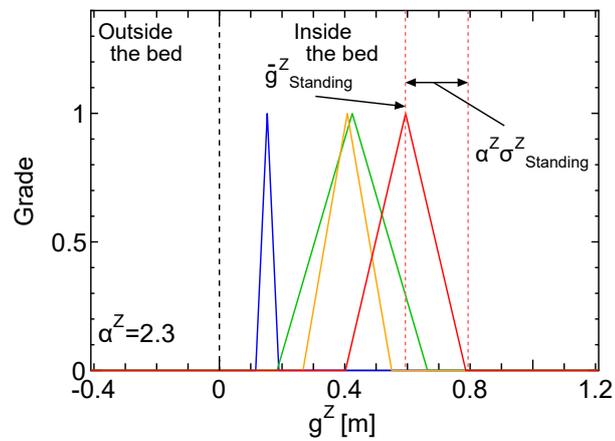
Posture p	Num. I_p	Average			Standard deviation		
		\bar{g}_p^X	\bar{g}_p^Y	\bar{g}_p^Z	σ_p^X	σ_p^Y	σ_p^Z
Lying down	4003	0.462	0.899	0.153	0.047	0.088	0.016
Long sitting	432	0.398	0.989	0.420	0.084	0.279	0.105
Sitting sideways	1965	0.145	0.735	0.407	0.099	0.058	0.062
Standing	223	-0.243	0.564	0.588	0.033	0.208	0.085



(a) X-axis



(b) Y-axis



(c) Z-axis

Fig. 7.6 : Antecedent parts on each axis (1st fold)

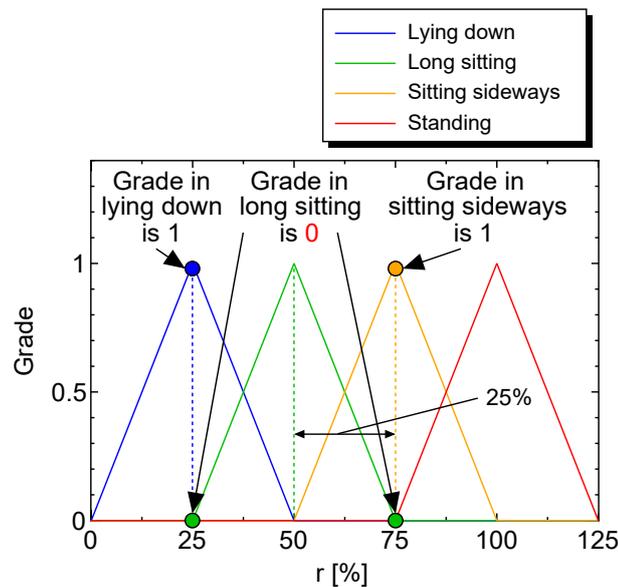


Fig. 7.7 : Consequent part (common to all folds)

た、残りの1つをテストデータに割り当てる。Table 7.3は、1~4回目の交差において各姿勢の平均および標準偏差を求めた結果である。今回は、 $\alpha^X = 2.7$, $\alpha^Y = 2.0$, $\alpha^Z = 2.3$ として、7.2.3節に基づき前件部を設定した (α^X , α^Y , α^Z の調整については、7.4.1節で考察する)。Fig. 7.6は、1回目の交差における前件部を表す。

後件部は、本来ならば看護師の臨床判断や転倒・転落リスクの推定モデルに基づいて決定するものであるが、提案手法の有効性を検証しやすくするため、今回はFig. 7.7に示すように、検証のために一般論的に臥位を25%、長座位を50%、端座位を75%、立位を100%とする。パラメータ β_p については、隣接した姿勢（例：長座位の場合、臥位と端座位が隣接）の帰属度が1のとき、自身の帰属度が0となるよう全て25%とした。

7.3.2 転倒・転落リスクの推定

Fig. 7.2に示す提案手法により患者の転倒・転落リスクを推定する。データセットとしては、前件部の作成に使用されなかった残りの人物位置データを利用する。今回は臥位1334個（1335個）、長座位144個、端座位655個、立位74個（75個）をテストデータとした。

各交差における転倒・転落リスクの度数分布をFig. 7.8に示す。今回検証に使用するデータセットは先ほどと同様、臥位、長座位、端座位、立位の4姿勢に限定し

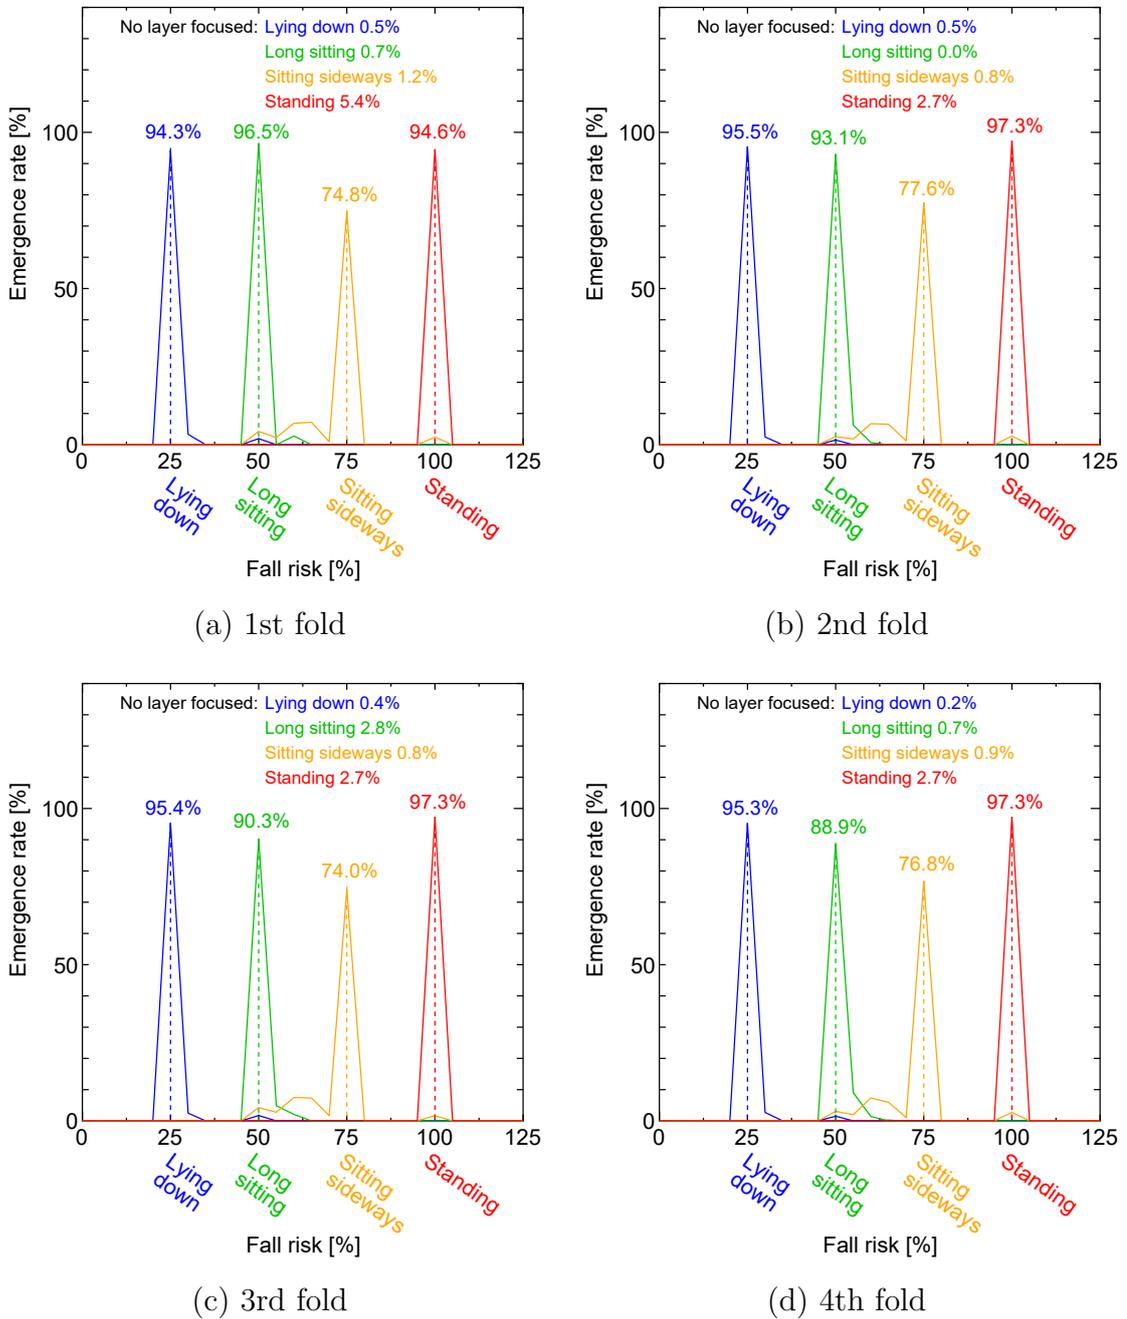


Fig. 7.8 : Frequency distributions of fall risk for each fold

ているため、算出される転倒・転落リスクは25, 50, 75, 100%のいずれかになることが望ましい。図より、算出された転倒・転落リスクの度数分布を姿勢ごとに見ると、平均89.9%は算出されるべき値となった。

本章で提案する転倒・転落リスク推定手法は、任意に設定した後件部のメンバーシップ関数通りに推論結果が得られることを期待したものであり、結果として約90%の精度で期待通りの結果が得られた。これは臨床現場において、FASを入力としたモデル式を用いて後件部を設定することで、そのモデル式の出力と同等な転倒・転落リスクを推定できることを示唆している。つまり、モニタリング対象患者の様子（外見）だけでなく、その患者の状態や病状（内実）を考慮した推定システムの実現に繋がるものである。さらに、後件部は看護師が任意に調整できることから、将来的には患者に対して専属の看護師を配置することと同等な安全対策に繋げることも十分可能である。以上より、ファジィ推論を用いた転倒・転落リスク推定手法の有効性を示すことができた。

7.4 考察

7.4.1 メンバーシップ関数の設計

本検証では、平均と標準偏差に基づいて前件部のメンバーシップ関数を設計しているが、このとき調整パラメータ $\vec{\alpha} = (\alpha^X \ \alpha^Y \ \alpha^Z)$ を設定する必要がある。この $\vec{\alpha}$ は、適切な前件部作成のために重要なパラメータとなる。

この $\vec{\alpha}$ は以下の2点を考慮して決定する。

- (1) ベッドの範囲内において、前件部の帰属度 ζ_p^X , ζ_p^Y , ζ_p^Z が0となる区間を少なくする。
- (2) 姿勢 P の内、ある任意の姿勢を p 、その他の姿勢を q とする。また、姿勢 q の集合を Q とする（例えば、 $P = \{\text{臥位, 長座位, 端座位, 立位}\}$, $p = \text{長座位}$ のとき、 $Q = \{\text{臥位, 端座位, 立位}\}$ ）。

$$\begin{aligned} p \in P \quad q \in Q \\ Q = P - p \end{aligned} \tag{7.17}$$

前件部はX, Y, Z軸の3つあるが、その内少なくとも1つが、姿勢 p の帰属度が1のとき、その他の姿勢 q の帰属度が0となる。式にすると Eq. (7.18) と

なる。

$$\begin{aligned} & [\exists g^X \{ \mu_p^X(g^X) = 1 \cap \mu_q^X(g^X) = 0 \}] \\ \cup & [\exists g^Y \{ \mu_p^Y(g^Y) = 1 \cap \mu_q^Y(g^Y) = 0 \}] \\ \cup & [\exists g^Z \{ \mu_p^Z(g^Z) = 1 \cap \mu_q^Z(g^Z) = 0 \}] \end{aligned} \quad (7.18)$$

(1) は α を大きくする処理である。前件部では人物位置から姿勢の帰属度を求めるが、ベッドの範囲内に全姿勢の帰属度が0となる部分が存在すると、転倒・転落リスクに解なしが存在することになる。そのため、範囲内を可能な限り網羅するよう α を大きくする。

一方、(2) は α を小さくする処理である。 α が大きくなりすぎると、姿勢 p とその他の姿勢 q の区別ができなくなり、正確な転倒・転落リスクを算出できない可能性が高くなる。そのため、 Q に属する全ての姿勢 q に対し、Eq. (7.18) を満たすよう α を調整する必要がある。

Fig. 7.6 に示す前件部は、上記の条件を満たすよう作成した。

7.4.2 転倒・転落リスクの推定

Fig. 7.8 より本提案システムは、平均約9割の精度で期待通りの結果が得られることが分かった。しかし、端座位の推定精度は平均75.8%であり、望ましい結果となったものが他姿勢より少ない。そこで、端座位の推定精度が低くなった原因を探るべく、被験者の上体の特徴に基づき、端座位のデータ2620個を3つのクラスタに分類する。分類するクラスタは「前傾または正常 (Bend forward or straighten)」, 「後傾 (Bend back)」, 「横傾 (Bend aside)」の3つとした。Fig. 7.9 は各クラスタに属するデータの一例である⁸。(a) は前傾または正常、(b) は後傾、(c) は横傾のクラスタに属する。

Fig. 7.10 は各クラスタにおける転倒・転落リスクの度数分布である。結果を見ると、いずれのデータセットも前傾または正常姿勢については、転倒・転落リスク75%の部分に約8割のデータが集中している。一方、後傾、横傾のデータは、全体的に転倒・転落リスク50%の部分が高くなっている。本検証では、あらかじめ設定した後件部より (Fig. 7.7), 転倒・転落リスク50%は長座位のときのみ生じることを期待

⁸各 Depth マップの右上の数字は経過時間 (単位は [s]), 左上の数字は転倒・転落リスクの値 (単位は [%]) を表す。

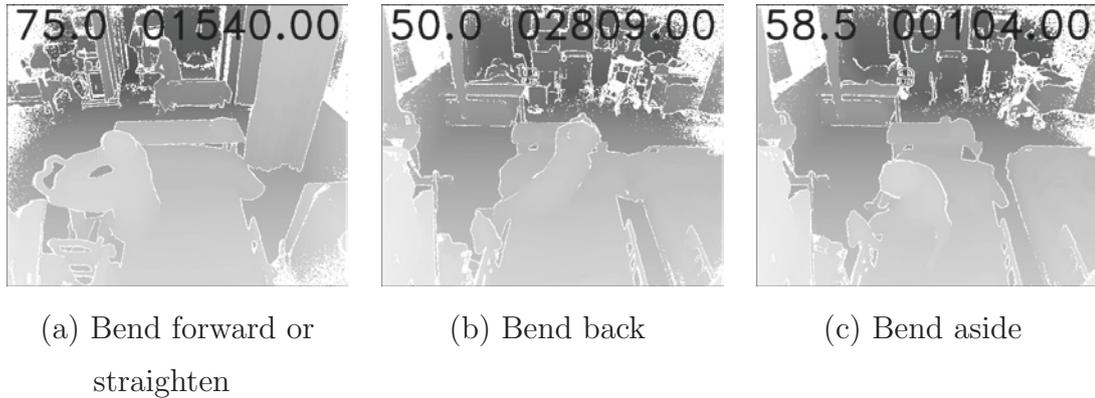


Fig. 7.9 : Example of depth maps representing the diversity of the posture “Sitting sideways”

していた。しかし上体の状態によっては、人物位置が長座位の属する領域へと移動し、結果として端座位を長座位と誤判定してしまう。人物が後傾または横傾のとき、上体の重心は多くの場合ベッド中央側へと傾く。そして、ベッド中央は長座位の帰属度が高い区域であるため、後傾、横傾に関しては長座位の帰属度が高くなり、転倒・転落リスク50%が算出された。ただし、後傾または横傾においては、転倒・転落リスクが低く算出されることがあっても大きな問題にはなり得ない。なぜなら、一般的に人間は上体が後ろに傾いた状態では立ち上がることができず、立ち上がるためには上体を前方へ傾ける必要があるからである。つまり、後傾姿勢の直後に、転倒の危険性が高い立位の姿勢に直接遷移することはない。これは、横傾姿勢に関しても同様である。本システムは、立位に遷移する前の「上体が前傾または正常な端座位」を平均81.1%の精度で推定できることから、実用上の問題はない。

なお、Fig. 7.10を見ると、前傾または正常な姿勢は、転倒・転落リスク50%における出現率が明らかに低くなっている（つまり、転倒・転落リスクが50%となることがほとんどない）ことから、長座位との分別ができているものの、55~70%の部分には1~2割程度出現している。本現象については、臀部の位置が影響している可能性が高い。つまり、人物がベッドに深く腰掛けると、臀部がベッド中央側へ寄り、人物位置も同様に中央寄りとなることから、結果として転倒・転落リスクが低く算出されたと考えられる。しかし、深く腰掛けた姿勢は身体のバランスが安定しやすく、ベッドに浅く座ったときよりも転倒・転落の危険性が低い。そのため、深く座ったときに転倒・転落リスクが低くなることについては、何ら問題はないといえる。

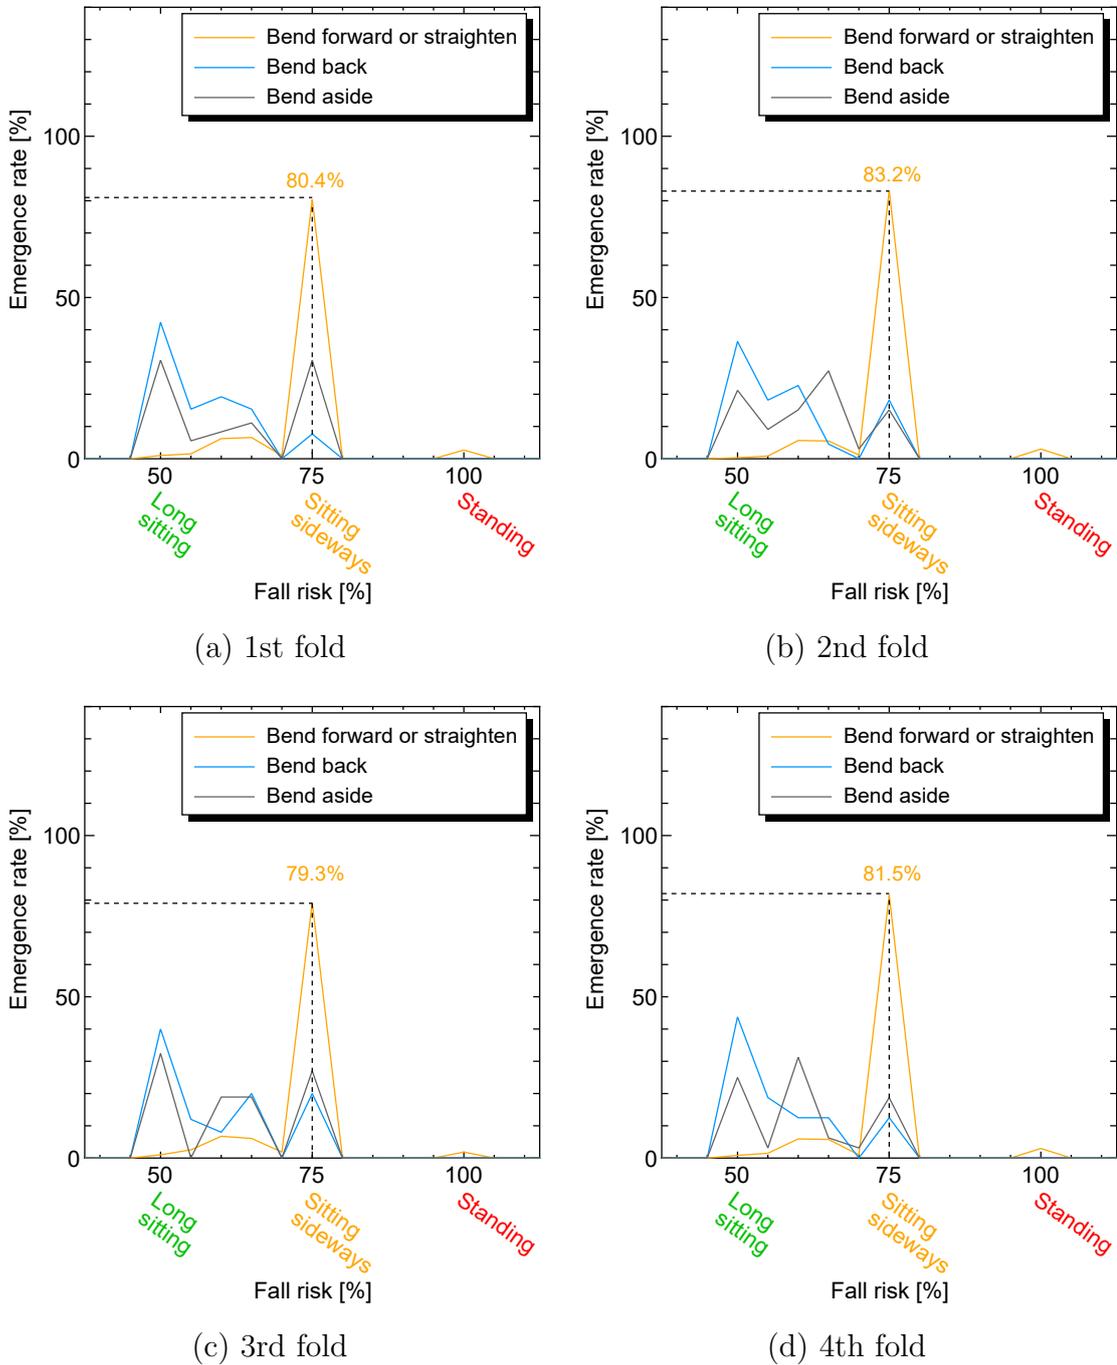


Fig. 7.10 : Frequency distributions concerning the posture “Sitting sideways”

7.5 本章のまとめ

第7章では、患者の外見から得られる情報だけでなく、病状や疾患の有無などの内実を考慮した転倒・転落リスクの推定手法を確立することを目的として、ファジィ推論を用いたシステムの試作を行った。ファジィ推論では、あらかじめ設定された前件部および後件部に基づく推論結果を算出する。今回は、前件部を第6章で求めた患者の位置情報、後件部を第4, 5章で求めたFASに基づく転倒・転落リスクとする多重ファジィ推論形式を定めた。このとき、各々の条件を結ぶ媒介変数として、患者の姿勢を用いた。

その後、対象とする姿勢を臥位、長座位、端座位、立位の4姿勢として、各姿勢の後件部を任意に定め、K-分割交差検証を行った結果 ($K = 4$)、平均89.9%が期待通りの転倒・転落リスクとなった。また、各姿勢の推定精度を確認すると、臥位95.1%、長座位92.2%、立位96.6%であり、4姿勢の内3姿勢においては9割以上が算出されるべき値となった。しかし、端座位の推定精度は平均75.8%であり、他姿勢よりも2割程度低い値となった。これは、端座位という同一の枠組みにおいても、患者の上体の傾きが異なると、推定される位置情報に違いが生じるためである。そこで、上体の傾きに基づき、端座位をさらに「前傾または正常」、「後傾」、「横傾」のクラスタに分類し、再度集計を行った結果、「前傾または正常」については平均81.1%が想定通りの転倒・転落リスクとなった。本結果は、端座位の状態を限定することで、推定精度を向上可能なことを示唆するものである。

以上より、ファジィ推論を用いた本モジュールは、任意に設定された後件部に従った推論を高い精度で実現できていることから、FASを入力とした転倒・転落リスク推定モデル（または看護師の臨床判断）をシステムに組み込むことができる可能性が非常に高いといえる。

第8章 結論

8.1 本論文のまとめ

医療現場における転倒・転落事故は深刻な問題であり、本研究では看護師の代わりに入院患者の見守りを行うシステムの構築を試みた。本システムは、転倒・転落アセスメントスコアシート（FAS）と Depth カメラにより取得された情報に基づき、患者の転倒・転落リスクを推定するものである。提案システムが実現することで、患者の内実と外見を勘案することが可能となるため、患者個人の状態により適合したリスク推定結果が期待できる。

本論文では、提案システムを(1)～(3)の3つのモジュールに分割し、それぞれのモジュールについて解析手法の提案およびその検証を実施した。モジュール(1)では、FASに記された内容から患者の転倒・転落リスクを推定する。そのため、第4、5章では、転倒・転落リスクをVASまたはファジィ評定法で回答するアンケートを看護師に対して実施した後、得られた回答データに対してファジィ線形回帰分析（FLR）を適用することで、FASを入力、転倒・転落リスクを出力とする推定モデルを作成した。本手法は、看護師が判断の際に感じる人間特有のあいまいさ（迷い）を取得・解析できるといった特徴を持つ。さらに、看護師は臨床判断の際に患者の姿勢も考慮すること、ならびに、モジュール(1)を他のモジュールと組み合わせられるよう、アンケートデータの集計および転倒・転落リスク推定モデルの作成は、患者の姿勢ごとに行った。

モジュール(1)に関して、本論文では第4章と第5章の2つの章を設け、異なる観点からその実現方法について検討した。第4章では、筆者が設計したアンケート用紙およびその解析手法に関して、まずは理論的な側面から有効性を確かめるべく、モデルパラメータの真値が既知である回答データを複数用意し、FLRによるモデル化、およびモデルパラメータの真値と推定値の比較を行った。その結果、看護師から回答データを500例以上収集し、なおかつ外れ値処理を行うことで、提案手法は看護師に内在するあいまいさを含んだ判断基準を高い精度で定量化できることが示唆された。さらに、実際の看護師から1名当たり200例の回答データを取得し、提

案手法によるモデル化を行った。その後、アンケートに協力した看護師に対し、自身の判断と類似した結果を出力するモデルを選択するよう依頼した。その結果、6割以上の看護師が自身のモデルを回答中に含んでいた。提案手法は、看護師の判断基準を定量化する際に、通常ならば500例以上の回答データを必要とする。しかし、回答データを200例しか確保できない場合においても、自身のモデルを識別できる程度には、回答者本人の判断基準をモデル式へと反映させることが可能といえる。

つづいて、第5章では看護師から取得可能な回答データ数が少量の場合に生じる過学習問題に主眼を置き、過学習を軽減するモデル化手法について提案した。本手法は、FLRによるモデル化の前にクラメール連関係数と相関比をそれぞれ算出し、これらの指標に基づいてモデル式に用いる説明変数を選択することで、モデル構築の際の過学習軽減を試みている。看護師3名を対象として臨床判断に関するアンケートを実施し、各看護師から300例ずつ回答データを収集した。その後、交差検証および2標本t検定によって提案手法の有効性を検証した。これと同時に、アンケートの回答内容を分析し、回答の一貫性についても確認を行った。その結果、提案手法は回答に一貫性のある看護師のデータに対して、過学習軽減効果が有意に現れることが認められた。以上、第4章では理論的な観点から、第5章では実用的な観点から看護師の臨床判断をモデル化する手法を提案しており、モジュール(1)の実現可能性を複数の側面から示すことができたといえる。

つぎに、モジュール(2)(第6章)ではDepthカメラより計測されたPCDを用いて、ベッド上またはその周辺における入院患者の位置情報を推定した。このとき、PCDの座標変換や分割を行うことでロバスト性を高め、より多くの環境下で提案システムを利用できるようにした。その後、得られた位置情報から患者の物理的な転倒・転落リスクを導出した。また、患者の位置情報と姿勢との関係性について調査し、位置情報から姿勢を特定できる可能性が高いことを示した。物理的な転倒・転落リスクはモジュール(2)を単体で利用する際に、患者の姿勢はモジュール(1)と(2)を紐付ける際に用いられる。提案手法に関して、医療関係者および入院患者による協力の下、実際の病室にて検証を行った。その結果、入院患者の転倒・転落リスクは、最も危険な姿勢である立位の高くなり、物理的観点から見ても違和感のない傾向にあった。さらに、入院患者の姿勢を臥位、長座位、端座位、立位に分類した後、その患者の位置情報を散布図として視覚化し、データの分布を確認した結果、位置情報を表す三次元座標点は同一の姿勢においては類似した箇所に密集し、逆に異なる姿勢同士は離れた位置に分布していた。本傾向は、患者の位置情報と姿勢との間に関係性があることを示唆するものである。

最後に、モジュール(3) (第7章) では患者の姿勢を媒介としてモジュール(1)と(2)の結果を統合し、患者の特徴を多方面から鑑みた転倒・転落リスクを推定した。このとき、看護師の臨床判断や患者の姿勢はあいまいな概念に属するため、モジュール(1)、(2)の結果を統合する際は、ファジィ推論を利用することとした。ファジィ推論では、推論結果を得るにあたり前件部および後件部をそれぞれ定める必要があるが、本研究では前件部をDepthカメラより推定された位置情報(モジュール(2))、後件部をFASにより推定された転倒・転落リスクの値(モジュール(1))に基づいて作成している。その後、姿勢を臥位、長座位、端座位、立位の4通り定め、実際の入院患者から取得したPCDを用いて、K-分割交差検証による評価を行った。その結果、転倒・転落リスクの推定値は約9割が期待通りの結果となった。なお、先ほど定義された4姿勢の内、端座位だけは推定精度がやや低くなったが、これは端座位が他の姿勢よりも、患者の上体の傾きに違いが生じやすいためであると考えられる。そのため、端座位を上体の傾きに基づいてさらに細分化し、再度検証を実施した。その結果、上体が前傾または正常な端座位の推定精度は、細分化を行う前の端座位より5%以上高くなることが確認された。

以上、本論文では提案システムを構成する各種モジュールについて全4章にわたって検証した。その結果、いずれのモジュールも理論的に妥当であり、有効性を十分に担保できた。よって、提案システムは実現可能性が非常に高く、将来的には転倒・転落防止への貢献が期待される。

8.2 今後の展望

本論文では、様々な検証を通じて提案システムの実現可能性を示した。しかし、未達成の課題も数多く存在する。まず、モジュール(1)においては、本来ならば看護師1名当たり500例の回答データを収集し、提案手法の妥当性を検証すべきである。しかし、今回は看護師の実情を考慮し、回答データ数を最大300例に留めた。そのため、今後は回答データ数を500例以上確保した状態でモデル式を作成し、筆者が設計したアンケート用紙および解析手法について、有効性を改めて確認する必要がある。また、今回はアンケートの協力者を単一の病院から募っており、提案手法の適用可能範囲に関する検証が十分に為されていない。よって、今後は複数の病院を対象として、同形式のアンケートを実施する必要がある。

つづいて、モジュール(2)においては、検証数をさらに増やし十分なエビデンス

を確保する必要があると考える。今回実施した検証は、被験者の人数が比較的少なく、病室の種類にも多様性がない。理論的な側面から考えると、本モジュールは取得したデータの平滑化を事前に行っているため¹、体型や病室の違いが推定結果に大きな影響を及ぼす可能性は低く、検証数が少なくても提案手法の妥当性を述べることは可能である。しかし、提案システムの実用性および汎用性を明確にするためには、理論的な根拠だけでなく、実際の検証結果も併せて示すことが必要不可欠である。そのため、今後はより多くの入院患者および病院に協力を募り、十分な検証数を担保する必要がある。なお、様々な条件下での実験を続ける中で、提案システムが想定外の挙動をすることも当然起こり得る。こうした例外の洗い出しとその対処を行うためにも、実験を積み重ねることは非常に重要であるといえる。

最後に、モジュール(3)については、実際のFASや看護師の臨床判断を用いた検証も実施すべきである。本モジュールは、ファジィ推論を実行するために前件部と後件部をそれぞれ設定する必要があるが、本論文の検証では実際の入院患者から取得したPCDに基づいて前件部を定めた。しかし、後件部については筆者が任意に設定しており、モジュール(1)の結果が利用されていない。ファジィ推論という方法自体は、数学的観点からその有効性が十分に実証されていることから、後件部を任意に定めたとしても、提案手法の妥当性を検証するうえで大きな問題にはなり得ない。また、後件部を任意に設定することで推定結果の真値が明確になり、提案手法の評価が容易となる。そのため、モジュール(3)単体の検証を行うだけなら、モジュール(1)の利用は必須ではない。しかし、システム全体の評価を行うにあたっては、全てのモジュールを用いた検証が必要となる。本論文は、基本的にはモジュール単体での検証を主としており、いずれのモジュールにも妥当性があることを示すことで提案システムの実現可能性を主張した。ただし、提案システムは最終的にはモジュール単体ではなく、各モジュールの結果を勘案することで、モニタリング対象患者の転倒・転落リスクを算出する。そのため、今後は(1)～(3)の全モジュールを用いた条件下における検証を改めて実施する必要があると考える。このとき、当然ながら後件部は任意に定めるのではなく、実際の患者のFASに基づいて算出された転倒・転落リスクの値を用いて設定する。その後、提案システムの出力と看護師の判断（または実際の事故データ）を比較することで、筆者が提案したシステムの信頼性を明らかにできる。

¹モジュール(2)では、ロバスト性を向上させるために取得したデータの圧縮を行っており、このとき患者の体型や病室の環境に関する情報が大幅に削除される。

以上, 本節では現状の課題と今後の展望について述べた. これらの課題を達成することで, 患者の内実と外見を考慮した転倒・転落リスク推定システムを実現できる.

謝辞

本研究は、鳥取大学大学院工学研究科知能システム制御研究室（旧 知能制御工学講座 A 研究室）において行われたものである。このとき、被験者に対して実験主旨およびデータ用途や、個人情報の管理に関するインフォームド・コンセントを事前に実施している。

本研究を遂行するにあたり、主指導教員として終始懇切丁寧にご指導いただいた鳥取大学 櫛田大輔准教授に感謝申し上げます。また、日頃よりご助言をくださり、なおかつ本論文をまとめるに際して懇切なご鞭撻をくださった鳥取大学 横田孝義教授に感謝申し上げます。そして、本研究を実現するにあたり、データ収集に多大なるご協力をいただき、なおかつ研究方針について多くのご意見をくださった鳥取大学 深田美香教授に厚く御礼申し上げます。さらに、博士学位審査委員の立場から、大変意義のあるご意見をくださった鳥取大学 岩井儀雄教授に感謝申し上げます。また、本研究について日頃よりご助言をくださった鳥取大学 竹森史暁准教授に厚く御礼申し上げます。

本研究は、株式会社ケイズとの共同研究によって実施されたものである。病院環境ならびに社会ニーズに対する情報提供をいただいた同社の神庭公祐氏、小谷悠太氏、村田大輔氏に感謝の意を表す。また、本研究を遂行するにあたり、被験者としてご協力いただいた鳥取大学医学部附属病院の看護師ならびに患者の方々に感謝申し上げます。

最後に、本論文の完成に至るまで、長きにわたって支えていただいた両親に感謝の意を表す。

参考文献

- [1] 杉山良子, 転倒・転落防止パーフェクトマニュアル, 学研メディカル秀潤社, 2012.
- [2] D. Oliver, J.B. Connelly, C.R. Victor, F.E. Shaw, A. Whitehead, Y. Genc, A. Vanoli, F.C. Martin, and M.A. Gosney, “Strategies to prevent falls and fractures in hospitals and care homes and effect of cognitive impairment: systematic review and meta-analyses”, *BMJ*, Vol. 334, No. 7584, pp. 82–85, 2007.
- [3] D. Oliver, F. Healey, and T.P. Haines, “Preventing falls and fall-related injuries in hospitals”, *Clinics in Geriatric Medicine*, Vol. 26, No. 4, pp. 645–692, 2010.
- [4] K.A. Järvinen and P.H. Järvinen, “Falling from bed as a complication of hospital treatment”, *Journal of Chronic Diseases*, Vol. 21, No. 5, pp. 375–378, 1968.
- [5] L.Y. Tsai, S.L. Tsay, R.K. Hsieh, S. Yu, J.M. Tsai, H.H. Chien, and S.J. Liu, “Fall injuries and related factors of elderly patients at a medical center in Taiwan”, *International Journal of Gerontology*, Vol. 8, No. 4, pp. 203–208, 2014.
- [6] Centers for Disease Control and Prevention, “Important facts about falls”, <https://www.cdc.gov/homeandrecreationalsafety/falls/adultfalls.html> [accessed Sep. 30, 2017].
- [7] F. Healey, S. Scobie, D. Oliver, A. Pryce, R. Thomson, and B. Glampson, “Falls in English and Welsh hospitals: a national observational study based on retrospective analysis of 12 months of patient safety incident reports”, *Quality and Safety in Health Care*, Vol. 17, No. 6, pp. 424–430, 2008.
- [8] J. Coussement, L.D. Paepe, R. Schwendimann, K. Denhaerynck, E. Dejaeger, and K. Milisen, “Interventions for preventing falls in acute- and chronic-care

- hospitals: a systematic review and meta-analysis”, *Journal of the American Geriatrics Society*, Vol. 56, No. 1, pp. 29–36, 2008.
- [9] World Health Organization, “WHO global report on falls prevention in older age”, 2007.
- [10] 日本病院会, “QI プロジェクト 結果報告”, 2016.
- [11] 公益財団法人日本医療機能評価機構, “医療事故情報収集等事業 第48回報告書”, <http://www.med-safe.jp/contents/report/index.html> [accessed Feb. 4, 2021].
- [12] 鈴木亨, 園田茂, 才藤栄一, 村田元徳, 清水康裕, 三沢佳代, “回復期リハビリテーション目的の入院脳卒中患者における転倒, 転落事故とADL”, *リハビリテーション医学*, Vol. 43, No. 3, pp. 180–185, 2006.
- [13] 田代和也, 岡部武史, 太田秀臣, 上出正之, 三森教雄, 石原扶美丈, “院内転倒事故の検討—より安全な医療のために—”, *東京慈恵会医科大学雑誌*, Vol. 117, No. 2, pp. 91–95, 2002.
- [14] 内閣府, “高齢社会白書”, 2015.
- [15] 消費者庁, “高齢者の事故の状況について”, 2018.
- [16] 武藤芳照, 原田敦, 鈴木みずえ, 認知症者の転倒予防とリスクマネジメント < 第3版 > 病院・施設・在宅でのケア, 日本医事新報社, 2017.
- [17] 泉キヨ子, エビデンスに基づく転倒・転落予防, 中山書店, 2005.
- [18] J.M. Morse, R.M. Morse, and S.J. Tylko, “Development of a scale to identify the fall-prone patient”, *Canadian Journal on Aging / La Revue canadienne du vieillissement*, Vol. 8, No. 4, pp. 366–377, 1989.
- [19] D. Oliver, M. Britton, P. Seed, F.C. Martin, and A.H. Hopper, “Development and evaluation of evidence based risk assessment tool (STRATIFY) to predict which elderly inpatients will fall: case-control and cohort studies”, *British Medical Journal*, Vol. 315, No. 7115, pp. 1049–1053, 1997.

- [20] D. Oliver, F. Daly, F. Martin, and M. McMurdo, “Risk factors and risk assessment tools for falls in hospital in-patients: a systematic review”, *Age and Ageing*, Vol. 33, No. 2, pp. 122–130, 2004.
- [21] 檜山明子, 中村恵子, “入院患者の転倒リスクアセスメントツールの予測精度—国内データベースを用いた文献検討—”, *日本医療・病院管理学会誌*, Vol. 53, No. 1, pp. 31–39, 2016.
- [22] 東京都病院経営本部, “転倒・転落防止対策マニュアル（予防から対応まで）”, <http://www.byouin.metro.tokyo.jp/about/hokoku/anzen/manual/index.html> [accessed Feb. 4, 2021].
- [23] 日本医師会, “医療従事者のための医療安全対策マニュアル”, <http://www.med.or.jp/anzen/manual/menu.html> [accessed Feb. 4, 2021].
- [24] A. Shirakabe, K. Asai, T. Otsuka, N. Kobayashi, H. Okazaki, M. Matsushita, Y. Shibata, H. Goda, S. Shigihara, K. Asano, K. Kiuchi, K. Tani, T. Nishiwaki, N. Hata, and W. Shimizu, “Clinical approach to shortening length of hospital stay in elderly patients with acute heart failure requiring intensive care”, *Circulation Reports*, Vol. 2, No. 2, pp. 95–103, 2020.
- [25] Ministry of Health, Labour and Welfare, “2014 summary of patient survey”, https://www.mhlw.go.jp/english/database/db-hss/sps_2014.html [accessed Apr. 23, 2021].
- [26] NHS Improvement, “The incidence and costs of inpatient falls in hospitals”, 2017.
- [27] 壇美津代, 武井真由美, 金井優宜, 橋本健一郎, 浅野聡, “急性期病院における転倒・転落の現状と診療科ごとの特徴：インシデント報告から”, *日本転倒予防学会誌*, Vol. 2, No. 1, pp. 45–52, 2015.
- [28] 渡辺明子, 太田尚, 青木春実, 櫻井利江, 柿沼健一, “脳外科患者に対する転倒転落アセスメントスコアシートと危険防止対策の有用性”, *日本看護技術学会誌*, Vol. 3, No. 1, pp. 41–50, 2004.
- [29] K.L. Perell, A. Nelson, R.L. Goldman, S.L. Luther, N. Prieto-Lewis, and L.Z. Rubenstein, “Fall risk assessment measures: an analytic review”, *The Journals*

- of Gerontology, Series A: Biological Sciences and Medical Sciences*, Vol. 56, No. 12, pp. M761–M766, 2001.
- [30] 丸岡直子, 泉キヨ子, 平松知子, “看護師が転倒防止策を決定するまでの臨床判断の構造”, *日本看護管理学会誌*, Vol. 9, No. 1, pp. 22–29, 2005.
- [31] 泉キヨ子, 平松知子, 加藤真由美, 牧本清子, 正源寺美穂, 西山久美子, 中島ゆかり, “入院高齢者の転倒予測に関する改訂版アセスメントツールの評価”, *金沢大学つるま保健学会誌*, Vol. 27, No. 1, pp. 95–103, 2003.
- [32] M. Vassallo, L. Poynter, J.C. Sharma, J. Kwan, and S.C. Allen, “Fall risk-assessment tools compared with clinical judgment: an evaluation in a rehabilitation ward”, *Age and Ageing*, Vol. 37, No. 3, pp. 277–281, 2008.
- [33] G. Meyer, S. Köpke, B. Haastert, and I. Mühlhauser, “Comparison of a fall risk assessment tool with nurses’ judgement alone: a cluster-randomised controlled trial”, *Age and ageing*, Vol. 38, No. 4, pp. 417–423, 2009.
- [34] M. Aranda-Gallardo, M.E. de Luna-Rodriguez, M.J. Vazquez-Blanco, J.C. Canca-Sanchez, A.B. Moya-Suarez, and J.M. Morales-Asencio, “Diagnostic validity of the STRATIFY and Downton instruments for evaluating the risk of falls by hospitalised acute-care patients: a multicentre longitudinal study”, *BMC Health Services Research*, Vol. 17, No. 1, pp. 1–9, 2017.
- [35] 松田徹, 吉田晋, 井上美幸, 村永信吾, 大嶋幸一郎, 川間健之介, “臨床判断を基盤とした転倒危険性の感じ方は理学療法士経験年数で異なるか?—Timed “Up & Go” Test 遂行時の高齢者映像観察による検証—”, *理学療法科学*, Vol. 33, No. 1, pp. 69–75, 2018.
- [36] 藤井真砂子, 米澤弘恵, 長谷川智子, 上木礼子, 大久保清子, 大口二美, “転倒が予測される看護場面のリスク評価に影響する要因”, *日本看護管理学会誌*, Vol. 12, No. 2, pp. 32–41, 2009.
- [37] 平松知子, 泉キヨ子, 加藤真由美, 正源寺美穂, 西山久美子, “施設高齢者の転倒予測に対する入院時の看護師間の一致”, *金沢大学つるま保健学会誌*, Vol. 27, No. 1, pp. 147–150, 2003.

- [38] 森田恵美子, 飯島佐知子, 平井さよ子, 賀沢弥貴, 安西由美子, “転倒アセスメントスコアシートの改訂と看護師の評定者間一致性の検討”, 日本看護管理学会誌, Vol. 14, No. 1, pp. 51–58, 2010.
- [39] 清水昌美, 細見明代, 長野淑恵, 柴田しおり, 兵頭静恵, 藤本和美, 大西麻実, 池田沙央里, 岡本夏美, 沼本教子, “急性期病院における転倒・転落リスクアセスメントツール活用に関する看護師の認識と活用上の課題”, 神戸市看護大学紀要, Vol. 17, pp. 17–25, 2013.
- [40] 安藤泰正, 櫛田大輔, 北村章, 深田美香, “入院患者のベッド上における姿勢危険度の推定—転倒アセスメントスコアと看護師の経験則のモデル化—”, 第14回計測自動制御学会システムインテグレーション部門講演会 (SI2013), pp. 1807–1812, 2013.
- [41] 山崎慎治, 櫛田大輔, 北村章, 深田美香, “入院患者の転倒危険度推定のための看護師判断モデルに基づく知識抽出—転倒アセスメントスコア評価のデータマイニング—”, 第16回計測自動制御学会システムインテグレーション部門講演会 (SI2015), pp. 1099–1103, 2015.
- [42] H. Rahmani and A. Mian, “3D action recognition from novel viewpoints”, In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2016)*, pp. 1506–1515, 2016.
- [43] M. Inoue, R. Taguchi, and T. Umezaki, “Vision-based bed detection for hospital patient monitoring system”, In *40th International Engineering in Medicine and Biology Conference (EMBC 2018)*, pp. 5006–5009, 2018.
- [44] 古橋知大, 大村廉, “KINECT を用いたベッド上の人体認識”, マルチメディア, 分散, 協調とモバイルシンポジウム 2014 (DICOMO2014), pp. 138–143, 2014.
- [45] 中正和久, 齋藤俊哉, 間所洋和, 下井信浩, “複合センサを用いた高齢者向けベッドモニタリングシステムの改良—システムの現状と将来構想について—”, 秋田県立大学ウェブジャーナル B (研究成果部門), Vol. 4, pp. 101–106, 2017.
- [46] M. Enayati, M. Skubic, J.M. Keller, M. Popescu, and N.Z. Farahani, “Sleep posture classification using bed sensor data and neural networks”, In *40th*

International Engineering in Medicine and Biology Conference (EMBC 2018), pp. 461–465, 2018.

- [47] 初雁卓郎, 椎野俊秀, 村井真也, “ベッド上の患者行動を推定・通知するシステム「離床 catch」の提案”, *労働科学*, Vol. 88, No. 3, pp. 94–102, 2012.
- [48] Ocuvera, “Home”, <http://ocuvera.com/> [accessed Feb. 3, 2020].
- [49] 金憲経, “転倒リスクと歩行との関連”, *バイオメカニズム学会誌*, Vol. 38, No. 4, pp. 233–239, 2014.
- [50] 牧迫飛雄馬, “高齢者の認知・精神機能と転倒リスク”, *日本転倒予防学会誌*, Vol. 3, No. 3, pp. 5–10, 2017.
- [51] L.P. Fried, C.M. Tangen, J. Walston, A.B. Newman, C. Hirsch, J. Gottdiener, T. Seeman, R. Tracy, W.J. Kop, G. Burke, and M.A. McBurnie, “Frailty in older adults: evidence for a phenotype”, *The Journals of Gerontology, Series A: Biological Sciences and Medical Sciences*, Vol. 56, No. 3, pp. M146–M156, 2001.
- [52] L.A. Zadeh, “Fuzzy sets”, *Information and Control*, Vol. 8, No. 3, pp. 338–353, 1965.
- [53] 水本雅晴, 石渕久生, 乾口雅弘, 大里有生, 坂和正敏, 中島信之, 講座ファジィ <第2巻> ファジィ集合, 日刊工業新聞社, 1992.
- [54] 鬼沢 武久, “電子情報通信学会『知識の森』(S3群4編2章)”, http://www.ieice-hbkb.org/portal/doc_573.html [accessed Feb. 4, 2021].
- [55] 日本知能情報ファジィ学会, “エアコンファジィ制御 (三菱重工)”, <http://www.j-soft.org/example-database/2000-03-16-58> [accessed May. 11, 2021].
- [56] 田崎栄一郎, 吉田勝美, 有田清三郎, 井上裕二, 神辺眞之, 斉藤泰一, 出口敏雄, 西村治彦, 吉川仁育, 講座ファジィ <第11巻> ファジィ医療診断, 日刊工業新聞社, 1994.
- [57] L.A. Zadeh, 菅野道夫, 向殿政男, ザデー・ファジィ理論, 日刊工業新聞社, 1992.

- [58] MIT News, “MIT engineers develop “blackest black” material to date”, <https://news.mit.edu/2019/blackest-black-material-cnt-0913> [accessed May. 11, 2021].
- [59] 水本雅晴, “最近のファジー理論”, 情報処理, Vol. 29, No. 1, pp. 11–22, 1988.
- [60] S. Charfeddine, F. Mora-Camino, and M. de Coligny, “Fuzzy linear regression: application to the estimation of air transport demand”, In *International Conference on Fuzzy Sets and Soft Computing in Economics and Finance (FSSCEF 2004)*, pp. 350–359, 2004.
- [61] M.M. Nasrabadi, E. Nasrabadi, and A.R. Nasrabad, “Fuzzy linear regression analysis: a multi-objective programming approach”, *Applied Mathematics and Computation*, Vol. 163, No. 1, pp. 245–251, 2005.
- [62] 田中英夫, 和多田淳三, 林勲, “ファジィ線形回帰分析の三つの定式化”, 計測自動制御学会論文集, Vol. 22, No. 10, pp. 1051–1057, 1986.
- [63] 坂和正敏, ファジィ理論の基礎と応用 (POD版), 森北出版, 2008.
- [64] 吉川歩, “ファジィ評定とメンバーシップ関数同定法 (<特集> ファジィ評価の最近の展開)”, 日本ファジィ学会誌, Vol. 10, No. 2, pp. 4–12, 1998.
- [65] 日本緩和医療学会, “がん疼痛の薬物療法に関するガイドライン (2014年版)”, <https://www.jspm.ne.jp/guidelines/pain/2014/> [accessed Feb. 18, 2021].
- [66] W.W. Downie, P.A. Leatham, V.M. Rhind, V. Wright, J.A. Branco, and J.A. Anderson, “Studies with pain rating scales”, *Annals of the Rheumatic Diseases*, Vol. 37, No. 4, pp. 378–381, 1978.
- [67] 岡田直之, 脳に宿る心—認知科学・人工知能から神秘の世界に迫る—, オーム社, 2009.
- [68] G.A. Miller, “The magical number seven, plus or minus two: some limits on our capacity for processing information”, *The Psychological Review*, Vol. 63, pp. 81–97, 1956.
- [69] 長南達也, “Visual analog scale”, 呼吸, Vol. 11, No. 1, pp. 28–31, 1992.

- [70] S. Jenny, U. Anita, W. Tony, B.G. David, 熊沢孝朗, 痛み学—臨床のためのテキスト—, 名古屋大学出版会, 2010.
- [71] A.W.K. Yeung and N.S.M. Wong, “The historical roots of visual analog scale in psychology as revealed by reference publication year spectroscopy”, *Frontiers in Human Neuroscience*, Vol. 13, No. 86, pp. 1–5, 2019.
- [72] 若山大樹, 竹村和久, “態度と社会的規範の曖昧性を考慮した消費者の行動意図予測”, 感性工学研究論文集, Vol. 2, No. 1, pp. 65–72, 2002.
- [73] 寺下裕美, 大須賀美恵子, 下野太海, 戸田真美子, “作業者の感情評価への Fuzzy 評価法の導入”, 日本ファジィ学会誌, Vol. 10, No. 2, pp. 366–374, 1998.
- [74] T. Hesketh, R. Pryor, and B. Hesketh, “An application of a computerized fuzzy graphic rating scale to the psychological measurement of individual differences”, *International Journal of Man-Machine Studies*, Vol. 29, No. 1, pp. 21–35, 1988.
- [75] S. de la Rosa de Sáa, M.A. Gil, G. González-Rodríguez, M.T. Lopez, and M.A. Lubiano, “Fuzzy rating scale-based questionnaires and their statistical analysis”, *IEEE Transactions on Fuzzy Systems*, Vol. 23, No. 1, pp. 111–126, 2015.
- [76] 竹村和久, 若山大樹, 堀内圭子, “広告受容の数理心理モデルとデータ解析法の開発—消費者の判断と意思決定の心理実験と調査研究を通じて—”, 広告科学, Vol. 45, pp. 153–172, 2004.
- [77] 森本栄一, 高橋正樹, 林文, 吉野諒三, 阿部貴人, 村上隆, 社会と調査 第9号 特集: 数量化理論の現在, 社会調査協会, 2012.
- [78] 菅民郎, 例題と Excel 演習で学ぶ多変量解析 回帰分析・判別分析・コンジョイント分析編, オーム社, 2016.
- [79] Microsoft, “Kinect hardware”, <https://developer.microsoft.com/en-us/windows/kinect/hardware> [accessed Sep. 30, 2017].
- [80] 中村薫, 杉浦司, 高田智広, 上田智章, KINECT for Windows SDK プログラミング Kinect for Windows v2 センサー対応版, 秀和システム, 2015.

- [81] Trinity College Dublin, “On quaternions; or on a new system of imaginaries in algebra by William R. Hamilton”, <https://www.maths.tcd.ie/pub/HistMath/People/Hamilton/OnQuat/> [accessed Feb. 3, 2020].
- [82] H.F. Wang and R.C. Tsaur, “Resolution of fuzzy regression model”, *European Journal of Operational Research*, Vol. 126, No. 3, pp. 637–650, 2000.
- [83] D.T. Redden and W.H. Woodall, “Properties of certain fuzzy linear regression methods”, *Fuzzy Sets and Systems*, Vol. 64, No. 3, pp. 361–375, 1994.
- [84] 藪内賢之, 和多田淳三, 辰巳憲一, “誤差データのファジィ回帰分析”, 日本ファジィ学会誌, Vol. 6, No. 6, pp. 1161–1170, 1994.
- [85] G. Peters, “Fuzzy linear regression with fuzzy intervals”, *Fuzzy Sets and Systems*, Vol. 63, No. 1, pp. 45–55, 1994.
- [86] E.C. Özelkana and L. Duckstein, “Multi-objective fuzzy regression: a general framework”, *Computers & Operations Research*, Vol. 27, No. 7-8, pp. 635–652, 2000.
- [87] 浅野真, 土方一彦, 小山健, “ファジィ可能性回帰分析のファジィ係数の幅について”, 日本ファジィ学会誌, Vol. 9, No. 3, pp. 395–401, 1997.
- [88] 竹村和久, “ファジィ重回帰分析による広告コミュニケーション効果の研究”, 広告科学, Vol. 37, pp. 119–124, 1998.
- [89] J. Lu and R. Wang, “An enhanced fuzzy linear regression model with more flexible spreads”, *Fuzzy Sets and Systems*, Vol. 160, No. 17, pp. 2505–2523, 2009.
- [90] 奥谷巖, 高瀬達夫, “最小二乗法によるファジィ線形回帰モデル”, 日本計算工学会論文集, Vol. 2002, p. 20020007, 2002.
- [91] C. Kao and C.L. Chyu, “A fuzzy linear regression model with better explanatory power”, *Fuzzy Sets and Systems*, Vol. 126, No. 3, pp. 401–409, 2002.
- [92] M.M. Nasrabadi and E. Nasrabadi, “A mathematical-programming approach to fuzzy linear regression analysis”, *Applied Mathematics and Computation*, Vol. 155, No. 3, pp. 873–881, 2004.

- [93] H. Tanaka, S. Uejima, and K. Asai, “Linear regression analysis with fuzzy model”, *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. 12, No. 6, pp. 903–907, 1982.
- [94] P.J. Huber, “Robust estimation of a location parameter”, *The Annals of Mathematical Statistics*, Vol. 35, No. 1, pp. 73–101, 1964.
- [95] P. Diamond, “Fuzzy least squares”, *Information Sciences*, Vol. 46, No. 3, pp. 141–157, 1988.
- [96] M. Berkelaar, et al., “CRAN — package lpSolve”, <https://cran.r-project.org/web/packages/lpSolve/> [accessed Sep. 17, 2021].
- [97] M. Andersen, J. Dahl, and L. Vandenberghe, “CVXOPT”, <https://cvxopt.org/> [accessed Sep. 17, 2021].
- [98] J.P. Guilford, *Fundamental statistics in psychology and education (3rd ed.)*, McGraw-Hill, 1956.
- [99] 田中英夫, 林勲, 長坂一徳, “可能性測度による区間回帰分析”, 行動計量学, Vol. 16, No. 1, pp. 1–7, 1988.
- [100] 石淵久生, 田中英夫, “混合 0-1 整数計画問題による区間回帰分析”, 日本経営工学会誌, Vol. 40, No. 5, pp. 312–319, 1989.
- [101] 神寫敏弘, 麻生英樹, 安田宗樹, 前田新一, 岡野原大輔, 岡谷貴之, 久保陽太郎, ボレガラ・ダヌシカ, 深層学習—Deep Learning—, 近代科学社, 2015.
- [102] W. Richert, L.P. Coelho, 斎藤康毅, 実践 機械学習システム, オライリー・ジャパン, 2014.
- [103] H. Cramér, *Mathematical Methods of Statistics*, Princeton University Press, 1946.
- [104] D. Dubois and H. Prade, “Ranking fuzzy numbers in the setting of possibility theory”, *Information Sciences*, Vol. 30, No. 3, pp. 183–224, 1983.
- [105] H. Brink, J.W. Richards, and M. Fetherolf, *Machine Learning 実践の極意—機械学習システム構築の勘所をつかむ!—*, インプレスビジネスメディア, 2017.

- [106] P. Kittipanya-Ngam, O.S. Guat, and E.H. Lung, “Computer vision applications for patients monitoring system”, In *15th International Conference on Information Fusion (FUSION 2012)*, pp. 2201–2208, 2012.
- [107] SA Health, “Falls prevention policy directive and toolkit”, <https://www.sahealth.sa.gov.au/wps/wcm/connect/public+content/sa+health+internet/clinical+resources/clinical+programs+and+practice+guidelines/older+people/falls+prevention/falls+prevention+policy+directive+and+toolkit> [accessed Feb. 3, 2020].

付録A Kinectの外観と仕様

本研究で使用した Kinect の外観を Fig. A.1 に、本体の仕様を Table A.1 に示す。



Fig. A.1 : Appearance of the Microsoft Kinect sensor

Table A.1 : Specifications of the Microsoft Kinect sensor

Color	Resolution	[pixel]	1920 × 1080
	Frame rate	[fps]	30
Depth	Resolution	[pixel]	512 × 424
	Frame rate	[fps]	30
	Measurable range	[m]	0.5 to 8.0
	Measurable range (reliable)	[m]	0.5 to 4.5
	Horizontal angle of view	[deg]	70
	Vertical angle of view	[deg]	60
Body index	Number of trackable people		6
	Measurable range	[m]	0.5 to 4.5
Joint	Number of trackable people		6
	Number of joints		25
Size	Width (W)	[mm]	249
	Depth (D)	[mm]	66
	Height (H)	[mm]	67

業績リスト

主論文（査読付き論文）

1. 磯本佳助, 櫛田大輔, “3D 距離画像センサを用いたベッド上における患者の転倒・転落リスク推定”, 電気学会論文誌C (電子・情報・システム部門誌), Vol. 139, No. 8, pp. 919–926, 2019.
2. 磯本佳助, 櫛田大輔, 深田美香, “あいまいさを含む転倒・転落リスク判断の定量化に関する研究—ファジー理論に基づくアンケート解析手法の提案—”, 電子情報通信学会論文誌D, Vol. J104-D, No. 3, pp. 164–171, 2021.
3. Keisuke Isomoto and Daisuke Kushida, “Improvement of a depth camera installation for fall risk estimation”, *SICE Journal of Control, Measurement, and System Integration*, Vol. 14, No. 2, pp. 128–137, 2021.
4. 磯本佳助, 櫛田大輔, 深田美香, “過学習を考慮した説明変数の選択を伴う転倒・転落リスク判断のモデル化手法”, 電子情報通信学会論文誌D, Vol. J105-D, No. 5, 2022 (早期公開済).

主論文（国際会議）

1. Keisuke Isomoto and Daisuke Kushida, “Modeling the vagueness-included decision-making process of nurses using fuzzy linear regression”, In *2020 IEEE 2nd Global Conference on Life Sciences and Technologies (LifeTech 2020)*, pp. 207–211, 2020.
2. Keisuke Isomoto and Daisuke Kushida, “Fall risk estimation with relaxation of the strong constraint on depth camera location”, In *SICE Annual Conference 2020 (SICE 2020)*, pp. 397–402, 2020.

3. Keisuke Isomoto, Daisuke Kushida, and Mika Fukada, “Fall risk estimation modeling based on clinical judgment and its evaluation by nurses”, In *2021 IEEE 10th Global Conference on Consumer Electronics (GCCE 2021)*, pp. 473–476, 2021.

学術講演

1. 磯本佳助, 櫛田大輔, “Depth データの座標変換を伴う転倒・転落リスク推定”, 第 21 回 IEEE 広島支部学生シンポジウム (HISS 21st), pp. 409–412, 2019.

表彰

1. Keisuke Isomoto and Daisuke Kushida, IEEE LifeTech 2020 Excellent Student Paper Award 3rd Prize, In *2020 IEEE 2nd Global Conference on Life Sciences and Technologies (LifeTech 2020)*, 2020.

参考論文

1. 磯本佳助, 櫛田大輔, “三次元ビジョンセンサを用いた人物検出と呼吸推定”, 電気学会論文誌 C (電子・情報・システム部門誌), Vol. 138, No. 7, pp. 927–933, 2018.
2. Keisuke Isomoto and Daisuke Kushida, “Fall risk estimation for inpatients on beds using 3D vision sensor”, In *40th International Engineering in Medicine and Biology Conference (EMBC 2018)*, pp. 925–928, 2018.
3. 中島浩輔, 磯本佳助, 櫛田大輔, “EMG を用いた筋線維タイプに基づく筋疲労推定モデルの構築”, 電気学会論文誌 C (電子・情報・システム部門誌), Vol. 140, No. 7, pp. 697–704, 2020.

その他

1. 磯本佳助, 櫛田大輔, “3次元ビジョンセンサを用いた生体検出と呼吸推定”, 動的画像処理実利用化ワークショップ2017 (DIA2017), pp. 285–291, 2017.
2. 磯本佳助, 櫛田大輔, “ファジィ推論によるベッド上患者の転倒リスク推定手法の提案”, 第20回IEEE広島支部学生シンポジウム (HISS 20th), pp. 311–314, 2018.
3. 磯本佳助, 櫛田大輔, “Kinectを用いたベッド上における患者の転倒リスク推定”, 第27回計測自動制御学会中国支部学術講演会, pp. 151–152, 2018.
4. 服部夏実, 磯本佳助, 櫛田大輔, 深田美香, “Lasso回帰を用いた転倒アセスメントスコアシートの最適化”, 第29回計測自動制御学会中国支部学術講演会, pp. 85–86, 2020.