

博士論文

穿刺業務の観察によるスタッフ教育の  
ための機械学習利用に関する研究  
～臨床データを用いた人間工学的アプローチ～

A Study on the Use of Machine Learning for Staff  
Education through Observation of Puncture Task  
～Ergonomic approach using clinical data～

神奈川工科大学

2023 年度  
川崎 路浩

# 目次

<b>第 1 章 序論</b>	<b>1</b>
1.1 研究の背景	1
1.2 目的	5
1.3 論文の構成	10
<b>第 2 章 先行研究と本研究の位置づけ</b>	<b>11</b>
2.1 バスキュラーアクセスに関する研究	11
2.2 エコー下穿刺の研究	11
2.3 機械学習と人間工学について	12
2.4 医療タスクにおける認知負荷に関する研究	12
2.5 研究課題	13
<b>第 3 章 エコープローブ操作に着目した操作技術の顕在化</b>	<b>15</b>
3.1 背景	15
3.2 超音波画像診断装置	15
3.3 モーションキャプチャ	16
3.4 方法	16
3.4.1 被験者	17
3.4.2 エコーガイド下穿刺方法	17
3.4.3 観察装置	17
3.4.4 位置座標と加速度の抽出	18
3.4.5 変位量の算出	19
3.4.6 データ分析（散布図行列）	19
3.4.7 データ分析（主成分分析）	20
3.5 分析結果	22
3.4.1 散布図行列	22
3.4.2 主成分分析	27
3.6 考察	33
3.7 研究の限界	34
3.8 結論	34
<b>第 4 章 機械学習を使った穿刺手技の評価</b>	<b>35</b>
4.1 背景・目的	35
4.2 バスキュラーアクセス	35

4.3	穿刺部位の観察 .....	36
4.4	機械学習と評価 .....	37
4.4.1	線形回帰 (Linear Regression) .....	37
4.4.2	Autoencoder .....	37
4.4.3	評価 .....	38
4.5	方法 .....	39
4.5.1	被験者 .....	39
4.5.2	データ採取 .....	39
4.5.3	動画データの準備 .....	39
4.5.4	動画データから座標データへ変換 (Open Pose) .....	40
4.5.5	位置座標の抽出 .....	40
4.5.6	散布図行列 .....	42
4.5.7	Autoencoder を使った機械学習 .....	43
4.6	結果 .....	47
4.6.1	散布図行列 .....	47
4.6.2	機械学習 .....	48
4.7	考察 .....	51
4.8	研究の限界 .....	52
4.9	結論 .....	52

## 第5章 認知負荷の軽減と機械学習を用いた支援システムの実現性 ...53

5.1	背景・目的 .....	53
5.2	視線追跡装置 .....	54
5.3	認知負荷とアイトラッキング技術 .....	54
5.4	CatBoost (Categorical Boosting) .....	55
5.5	方法 .....	55
5.5.1	被験者 .....	55
5.5.2	データ採取 .....	55
5.5.3	視線データの抽出 .....	56
5.5.4	タスクイベントと注視時間 .....	56
5.5.5	機械学習による分類 .....	57
5.5.6	SHAP による予測貢献度 .....	59
5.6	結果 .....	61
5.6.1	タスクイベントと注視時間 .....	61
5.6.2	座標位置とタスクイベント・注視タイプ .....	65

5.6.5	機械学習による分類 .....	74
5.6.6	特徴量の重要性和 SHAP による予測貢献度 .....	76
5.7	考察 .....	82
5.7.1	タスクイベントと注視時間 .....	82
5.7.2	機械学習による分類と貢献度 .....	83
5.8	研究の限界 .....	84
5.9	結論 .....	85
第 6 章	総合考察 .....	86
第 7 章	結論 .....	88
参考文献	.....	89
付録	.....	94
謝辞	.....	95

# 第 1 章 序論

## 1.1 研究の背景

血液透析は、腎臓の機能が不十分な場合に体外で血液を浄化する治療法である。治療に使う回路図を図 1.1 に示す。治療では、拡散と限外濾過の原理により透析器（ダイアライザ）を使用して血液中の不要な物質や余分な水分を取り除くことで、体内の電解質や水分のバランスを保つ。

ダイアライザは半透膜となっており、膜には小さな穴が無数に開いており、不要物質（尿素窒素やクレアチニンなど）、余分な塩分、水分を透過させる一方で、血球や他の重要な成分は体内に留まるように設計されている。つまりダイアライザは血液と透析液を物理的に分離するが、不要物質と水分は移動でき、透析液は不要物が入っていないため、濃度差により不要物質を血液から引き出し、必要な物質（重炭酸ナトリウムなど）を血液に戻す役割を果たしている。このダイアライザでの拡散、限外濾過を効率的におこなうためには、高い流量の血液がダイアライザを流れる必要がある。




図 1.1 血液透析回路図

透析治療を受ける際には，患者の血液を透析器に導くためのアクセスが必要であり，一般的にバスキュラーアクセス（Vascular Access：VA）と呼ばれる．透析治療のため手術により手首付近にある動脈と静脈をつないだ，「シャント」もしくは「Arterio Venous Fistula：AVF」と呼ばれる（図 1.2）バスキュラーアクセスが第 1 選択として推奨されており最もよく使われている[1]．それよりシャントに代表されるバスキュラーアクセスを通して血液が取り出され，浄化された後，再び体内に戻される．実際に針を刺す位置（穿刺部）は血管をつないだ吻合部ではなく，動脈血が流れ込んだ中枢側（肘に使い側）にある静脈になる（図 1.3，図 1.4）．




図 1.2 シャント吻合部




図 1.3 針の穿刺位置（イメージ）



図 1.4 実際の穿刺部位の一例

血液透析を実施している患者は日本に約 36 万人おり、1 週間に通常 3 回の血液透析をおこなっている[2]。一度、血液透析が導入されるとすると腹膜透析に移行もしくは、腎臓移植をおこなうか、死亡するまで血液透析を継続することになる。透析治療のたびに、「シャント」に対して、2 本の針を刺して（穿刺して）治療をおこなう。穿刺が失敗すればその分、針を刺される回数は多くなる。治療の為とはいえ単純に考えても年間で 300 回以上、針を刺されることになる。適切な穿刺技術は、治療の効果や患者の安全性に直結しており、透析看護師や医師には高い技術と経験が求められる。穿刺時の痛みに限らず、透析治療における痛みは患者に睡眠障害、血液透析治療へのアドヒアランスの低下など大きな影響を与えていると言われている[3]。つまり、血液透析における穿刺技能の向上は患者満足度に影響する可能性がある。また、「シャント」においては、基礎疾患や血液透析の影響、及び繰り返しの穿刺により血管石灰化や内膜肥厚が起こりやすく[4]、経年的に狭窄したりするなどの問題が起こりやすい。

シャント血管の狭窄・変形・蛇行を併発した場合は穿刺部位が限定され、留置すべき針先の位置を制限せざるを得なくなることがある。このことが更に穿刺の難易度を上げ、失敗する頻度が増え、さらなる血管の荒廃を引き起こす可能性がある。このように血液透析における穿刺技能は非常に重要なものであるが、医療における技能習得の多くは、OJT（On the Job Training）により行われる。穿刺は穿刺ごとに対象となる患者が違い、また対象の血管も異なることから画一的な教育は難しく、視覚化もできず、触覚（「固い」、「柔らかい」など）や経験則などを非常に抽象的な言語（「やさしく」、「あたってる」、「血管に入った感じ」など）による指導に依存せざるをえず、指導者にとっても追随者にとっても的確な伝承という点において、難しさがある。

近年、超音波画像診断装置（以下、エコー）の画像高精細化や小型化[5]によって、エコ

一のアクセシビリティが格段に向上してきた。医療従事者でもエコーガイド下穿刺（以下，エコー下穿刺）[6]が行われるようになり，VA の走行や径の変化・石灰化及び内膜肥厚の可視化が可能となってきた（図 1.5）。触覚と前回までの経験則に頼ってきた血管内評価が，視覚情報で他者と共有可能となるという飛躍的な発展を遂げた。エコー下穿刺を利用すると，視覚を共有でき，指導者や追随者（その中でも特に初学者）に新たな門戸が開かれた。また，見えていることにより比較的安心・安全に穿刺をおこなうことが可能となった。



図 1.5 エコー下穿刺の実際

しかし，新たな問題点が生じた。従来の穿刺では穿刺時の視線移動は基本的に穿刺部位を見るので視点の移動が少なく済む。一方，エコー下穿刺は現実の針先や針の動きを見つつ，エコー画面上のいわばバーチャル世界内で再現された画像を現実の操作にフィードバックするという複雑な行為が生じる。

注意を向けるべき事柄の増加や，両手で別の目的の操作（穿刺とプローブ操作）をそれぞれおこなうことになり，医療スタッフの負荷は増加することになる。特に通常の穿刺に慣れた状態からエコー下穿刺を初めておこなったときには顕著にギャップを感じると考えられる。このように医療者の作業には，便利になるはずの医用デバイスが逆に認知的ならびに身体的負荷を増やすことがあり，機器の取り扱いが難しくなったり，取り扱いに慣れるまでの期間が長くなったりすることによる，技能習得までの時間が延びる可能性がある。

エコー下穿刺の教育においても穿刺と同様に OJT により行われ，プローブ操作（動かし方）についても職人技と言われる熟練技能として扱われ，見て学び，実行，指摘され復習といった流れになると思われる。猪木によると OJT のエッセンスは「例示と模倣作業の反



復」と述べられている[7].「まず、経験豊かな年長者が例を示し、学ぶ者が例示を見て模倣する. 教えるものはその不完全なところ, 改良すべきところを指摘しながら, 同じ作業を繰り返してやらせ, それを観察して問題点を再び指摘する」とある. 言い換えると穿刺やプローブ操作を口頭指導によって教えることは, 「それ自体が訓練」となっており, どのような操作が最適か, 操作をする上で何が難しいのか, それらを効率的に学ぶエッセンスとなる部分(特徴)は何かといった医療タスクに対する客観的な分析を基に教育がおこなわれているわけではない.

## 1.2 目的

医療タスクにおける経験と勘に頼る部分においての客観的な先行研究は多くはない. 例えば, 認知的部分に対しては, ある医療タスクに関しての視覚情報獲得について眼球運動データを取得できる視線追跡装置を用いた検討[8]や医学生における組織学教育で視線追跡装置を用いた研究[9]などがある. 医療タスクにおける身体的負荷(操作)に対する定量的な評価については, モーションキャプチャを利用した穿刺動作における施設間の差異についての検討[10]やモーションキャプチャによる超音波検査教育システムに関する予備的研究[11], などが散見される. しかし, モーションキャプチャには大きな利点がある一方で, 例えば, マーカーベースのモーションキャプチャは, 管理された環境を必要とし, 操作に高度な訓練を受けた人員が必要なため, 臨床用途では利用できない可能性がある. 一方, マーカーレスモーションキャプチャは, 標準的なビデオを使用してマーカーなしで動きを記録し, 多くの場合, ディープラーニングベースのアルゴリズム(**OpenPose**と**DeepLabCut**)を活用して体節の位置と向きを特定する[12]. この方法は, 時間がかからず, 専門家を必要とせず, マーカーベースの方法に関連するエラーの影響を受けにくい. いくつかの先行研究はあるが, 透析治療における穿刺を再現可能な数値で表現しようという先行研究は多くない.

本研究では透析治療における「穿刺タスク」に着目して, 臨床データを取得して解析をおこなう. また, 解析には「意思決定過程」という人間工学的な概念を利用する. 「意志決定過程」は **Endsley** ら[13]により提案されている意思決定過程モデルの 1 つである. このモデルでは, 意思決定過程が, **Situation Awareness**(状況認識), **Decision**(意思決定), **Performance of Action**(行動)の 3 つの段階によって構成され, 再びその結果がフィードバックされる. 人間の行動においてこの意思決定過程は日常的に行われていることであり, 穿刺タスクにおいても例外ではなく, 針を刺すために状況認識をおこない実際に針を動かす行動につながる(図 1.6).

しかし, 1.1 で述べたように, 穿刺タスクの教育方法は経験と勘に頼る部分が主となっており, かつ, 状況認識をするための客観的な材料が少ない. つまり, 専門家であっても主

観的な情報のみで、状況を誤って解釈すると、間違った判断を下す可能性があることが考えられる。関連要素を認識し、それらの意味を理解し、将来の状態を予測することが意思決定に重要となる。これは、正確な判断に基づいて行動を決定することが非常に重要な医療のような複雑な環境において特に重要である。

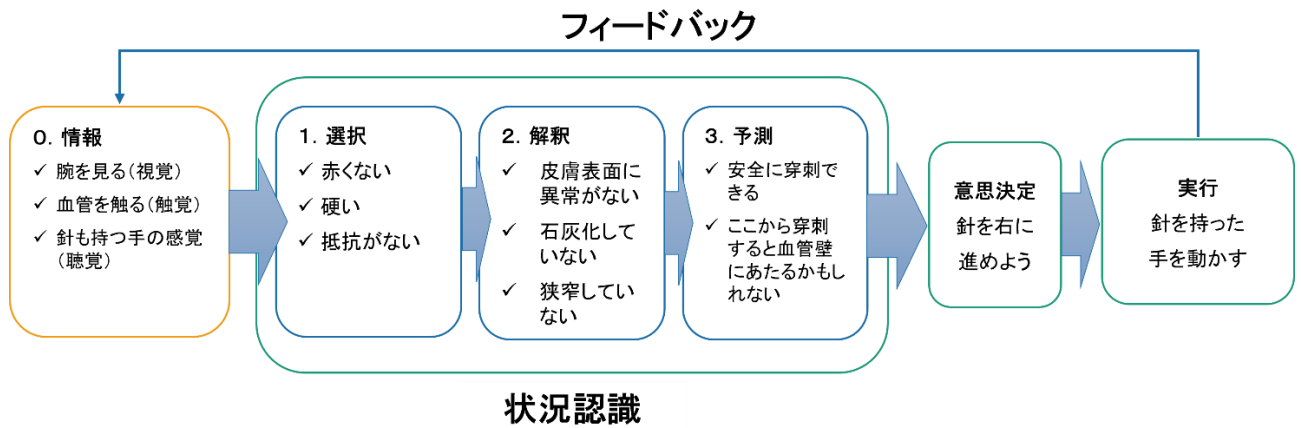


図 1.6 穿刺タスクにおける意思決定過程の一例

穿刺タスクに絞っても，エコー下穿刺は現実の針先や針の動きを見つつ，エコー画面上のいわばバーチャル世界内で再現された画像を現実の操作にフィードバックするという複雑な行為が生じている（図 1.7）．

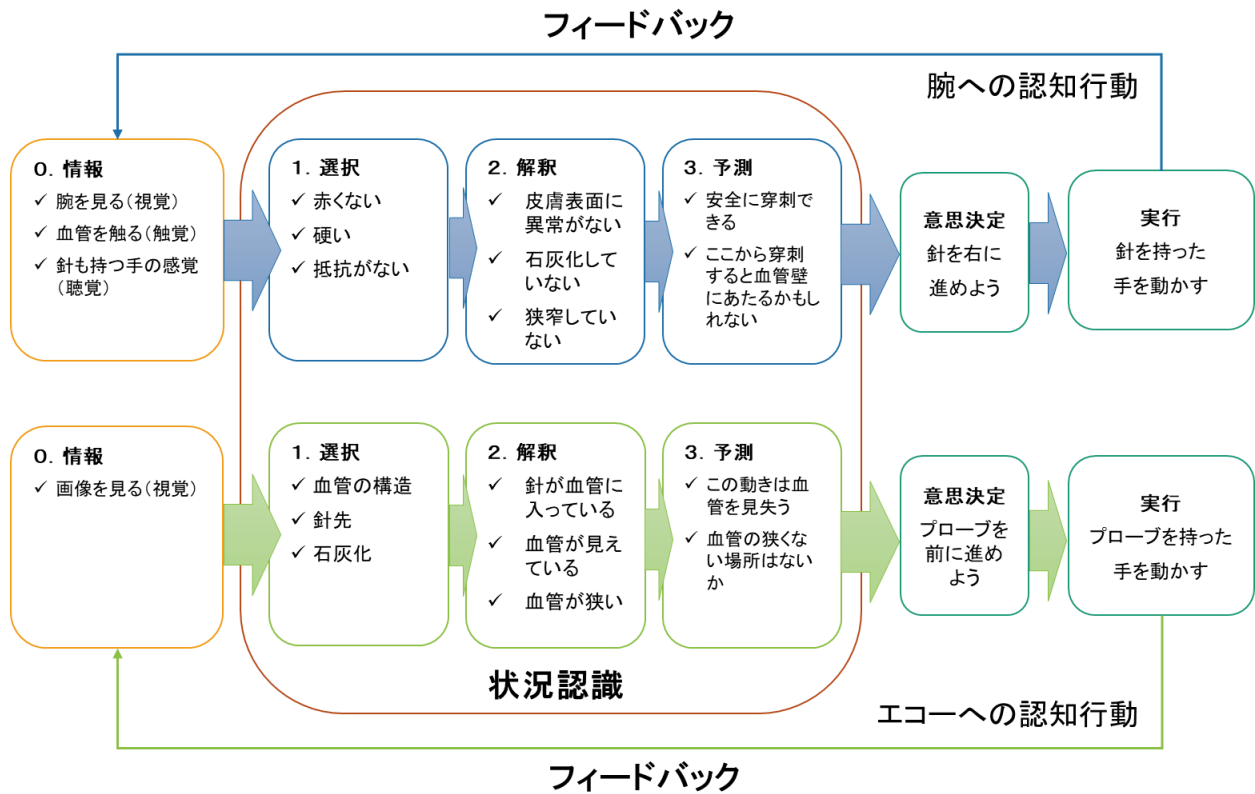


図 1.7 エコー下穿刺における意思決定過程の一例

しかし、これらの状況認識には経験による影響も大きい。穿刺においても、繰り返すことにより、必要な知識が内在化され、作業の自動化が進むことで時間が短縮され、穿刺の精度が向上する。初めは視覚や聴覚など外部からの情報、マニュアル等への依存が高いが、習熟すると内在知識を利用して、作業を効率的にこなす。つまり、動きが自動化され、必要な情報のみが意識されるようになり、それによって作業時間の短縮が実現する。このような現象は、Rasmussen[14]の SRK モデル（図 1.8）により表現されている。

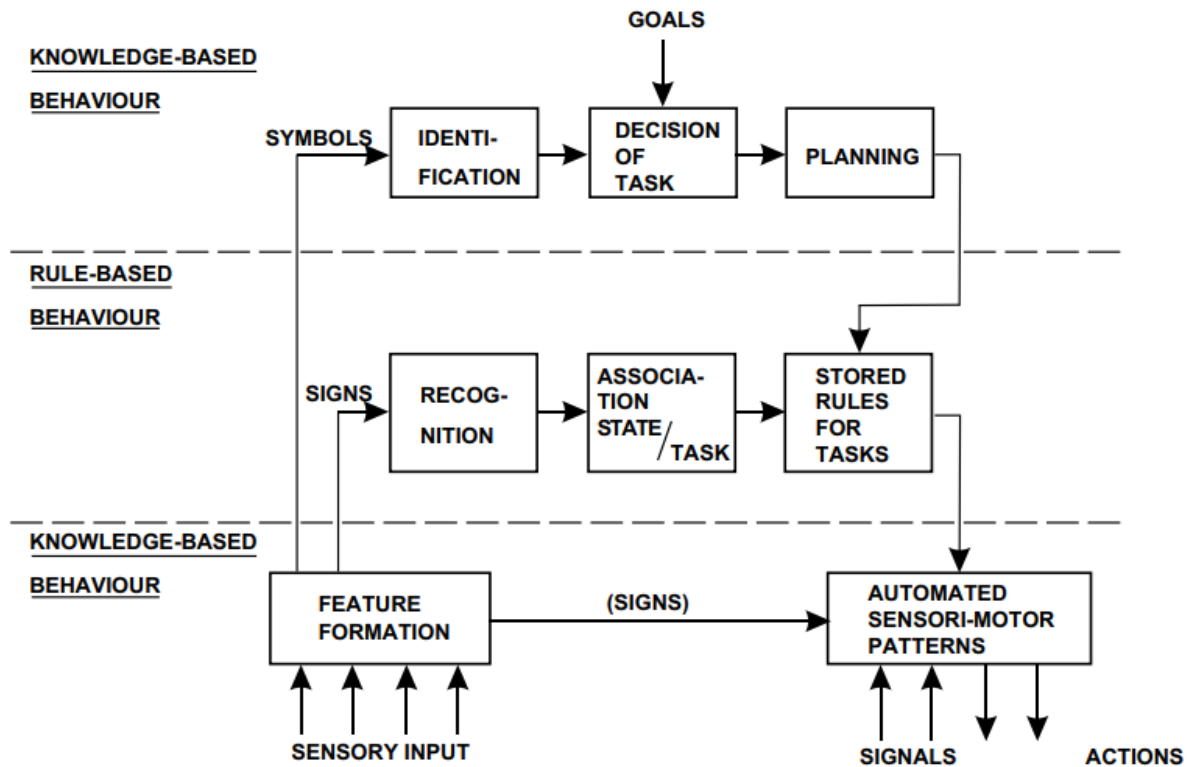


図 1.8 SRK モデル（文献[14]より引用）

そこで本研究では、モーションキャプチャ技術を使って、エコーガイド下穿刺技術の視覚化を試み、穿刺者の動作を数値化する。これにより、経験に基づいた技術を客観的に理解することを目指す。また、穿刺動作を数値化しオートエンコーダ（機械学習アルゴリズム）を使用してデータを学習し穿刺手技の評価が可能な機械学習モデルの検討をおこなう。これにより、穿刺時の客観的な評価をおこない、指導や実際の穿刺動作にフィードバックできる可能性がある。最後に視線追跡技術を用いて穿刺者の眼球運動を分析し、認知負荷と穿刺タスクの関係を明らかにする。また、機械学習を用いて認知負荷軽減が可能な支援システムの実現性を検討する。

本研究では、これらの内容を組み合わせて検討し、医療従事者の穿刺やエコーガイド下穿刺における手技の習得や改善につなげるため、穿刺業務の観察によるスタッフ教育のための機械学習利用に関する検討をおこなうことを目的とする。

### 1.3 論文の構成

第 1 章では本研究の背景として血液透析の説明, エコー下穿刺に関する説明と医療タスクにおける教育方法の問題点について概説し, 本研究の目的を論じた.

第 2 章では, 先行研究と本研究の位置づけとして, 第 2 章 1 節ではバスキュラーアクセスに関する研究, 第 2 章 2 節ではエコー下穿刺の研究, 第 2 章 3 節では機械学習について, 第 2 章 4 節では医療タスクにおける認知負荷に関する研究について述べ, 第 2 章 5 節ではそれらを踏まえた研究課題について述べた.

第 3 章ではエコーガイド下穿刺中の特にエコープローブ操作に着目し, 操作技術 (動かし方) を構成する要素の顕在化を目指し, モーションキャプチャなどの計測機器を使った測定結果を解析し, 経験に基づいた技術を客観的に理解する検討をおこなった.

第 4 章では穿刺タスクを撮影した動画から, 穿刺針を持つ指の位置座標を抽出し, 位置座標と動きの大きさを定義したデータセットを作成し, 機械学習を用いて穿刺タスクにおける穿刺手技の評価手法として有用か検討をおこなった.

第 5 章では認知負荷と穿刺タスクの関係を明らかにし, 認知負荷の軽減と機械学習を用いた支援システムの実現性の検討をおこなった.

第 6 章では第 3 章から第 5 章までの内容をまとめた考察を述べる.

最後に第 7 章で結論を述べる.

## 第2章 先行研究と本研究の位置づけ

### 2.1 バスキュラーアクセスに関する研究

2006年の米国におけるバスキュラーアクセスに関する臨床診療ガイドラインでは、中心静脈カテーテル依存を減少させるために、血液透析治療が必要となる前の進行した慢性腎臓病患者に AVF (arteriovenous fistula) を造設することを推奨している[15]。2016年 J Vasc Surg で発表されたバスキュラーアクセスの転帰に関する、システマティックレビューとメタアナリシスでは、長期透析を必要とする成人におけるバスキュラーアクセスの開存性、死亡率、バスキュラーアクセスの感染などが評価され、2年後の開存率は AVF が最も高かった。また、日本においては 91% が AVF であり、米国の 1.3 倍程度多い[16]。

血液透析患者の長期予後に及ぼす影響として、バスキュラーアクセスの合併症が起こることにより血液透析の質を低下させる可能性があり、その結果、時間依存的な影響を及ぼすという報告がされている[17]。

韓国での 2008 年から 2016 年までの韓国国民健康保険データベースに基づく、バスキュラーアクセスの転帰として血液透析患者の全死亡率と開存率を分析した研究では AVF は全年齢群で AVG (arteriovenous graft) より開存率が高かった。

これらの先行研究からバスキュラーアクセスにおける AVF は、多くの国の研究で推奨されており、開存率が高く長期の利用ができるということが分かる。特に日本ではその利用率が高いこと、そしてバスキュラーアクセスの合併症は透析の質に影響を及ぼす可能性があることから、AVF に対する穿刺はその機能を損なわないように、適切に実施する必要がある。

### 2.2 エコー下穿刺の研究

バスキュラーアクセス、特に AVF に対する穿刺を適切におこなう必要性は先に述べた通りである。しかし、通常の穿刺は血管の内部構造や状態を視覚的に確認することはできない。近年では超音波画像診断装置（以下、エコー）が小型化され、価格が安価になったことを背景に、エコーを用いて、穿刺部位を視覚的に確認しながら穿刺をおこなう、エコーガイド下穿刺が増加している。

エコーガイド下穿刺は、困難な AVF の穿刺に有効である。また、適切にバスキュラーアクセスを穿刺するために極めて重要である。エコーガイド下穿刺により正確な血管穿刺が可能となり、その結果、患者と経済的に大きなプラスの影響を与えると複数の論文で報告

されている[18][19][20].

一方、エコーガイド下穿刺が血液透析治療における困難なバスキュラーアクセスの標準として認められるためには、さらなる報告が必要であるとされ、エコーガイド下穿刺には、専門意識、理論、OFF/OJT による訓練、シミュレータの使用などにより、エコーガイド下穿刺技術に関するトレーニングが重要であると言われている[21]. 加えて、エコーを使用すると、血管のマッピングや針挿入に最適な部位の特定が可能になる. エコーガイド下穿刺では、プローブの操作と穿刺針の挿入が同時に行われるため、視覚化され挿入経路の自由度が高まり、穿刺針挿入中に針の軌跡（方向）を調整できる. しかし、エコーガイド下穿刺における最善の方法は、穿刺者の経験と技術に関する知識によって異なると言われている[22].

## 2.3 機械学習と人間工学について

機械学習（machine learning : ML）技術の急速な発展は、製造業における人間工学研究に大きな影響を及ぼしている[23]. 人間工学研究における ML の利用を評価するために、多くの研究が行われてきた[23][24][25].

2014 年から 2021 年までの人間工学分野における機械学習手法に関連する 1141 件の論文を Web of Science で検索し、機械学習手法と人間工学の知識構造を分析する研究では、「検証」と「予測」がよく使われるキーワードとして挙げられており、人間工学分野での機械学習手法の応用は年々増加すると結論づけられている[26].

人間工学においてウェアラブルセンサと機械学習アルゴリズムを組み合わせることで、人間工学に基づく分析方法の改善や作業者の生体力学的リスク（活動を実行する人に作用するすべての外部要素）のモニタリングが可能になる可能性が示されていた[27]. また、別の研究では機械学習アルゴリズムを使用すると、標準化された動きにおける機械的およびストレス関連の筋肉活動を予測できるとされ、実験データのモデル化には、XGBoost と TensorFlow という 2 つの異なるアルゴリズムが使用されていた[28].

## 2.4 医療タスクにおける認知負荷に関する研究

認知的負荷理論（Cognitive Load Theory : CLT）は、最近の医学教育研究で注目されている学習の枠組みである[29][30][31]. Manu らによると、CLT は、感覚記憶や長期記憶の帯域幅が著しく広いのに比べ、ワーキングメモリの容量が限られていることに着目している



[30]. しかし, CLT については, 認知負荷が低い方が常に学習に有益であるなどの誤解がある. 認知負荷の別々のタイプについて複数の指標を使用することで, より正確な測定が可能になり, それぞれについて単一の指標を使用するよりも, 認知負荷のタイプをより明確に分けることができるかもしれないと言われている. Jimmie Leppink らは認知的負荷理論を医学教育に適用するためのさらなる研究の必要性を強調し, 将来の研究の潜在的な方向性を示唆している[32].

別の研究では CLT を医学教育に適用することは, 感情が認知的負荷に与える影響は無関係な負荷だけにとどまらず, 負荷のサブタイプ (感覚記憶, 作業記憶, 長期記憶) を指定する必要があると提案している[33]. 医療環境における医療者の意思決定を補助することで, 認知的負荷の軽減が優先されるべきと期待されているが, まだ十分に実現されていないのは, 機械学習アルゴリズムがどのように臨床現場に反映されるかという点においてギャップがあるからである. このギャップの要因は多数あり, 中心的な課題は, 複雑な意思決定プロセスや臨床ワークフローに関するものである. 人間と ML の結果を軽減する方法を正確に特定するには至っていない[34].

## 2.5 研究課題

バスキュラーアクセスは, 血液透析治療において重要である. 2006 年の米国臨床診療ガイドラインでは, 血液透析治療を開始する前の進行した慢性腎臓病患者に対して, 中心静脈カテーテルの依存を減少させるために, AVF の造設を推奨している[15]. 日本の場合, 91%の患者が AVF を利用しており, これは米国の 1.3 倍である[16]. しかし, バスキュラーアクセスの合併症は透析の質を低下させ, 生命予後に影響を及ぼす[16].

近年, バスキュラーアクセス, 特に AVF に対する穿刺を効果的におこなうための技術として, エコーガイド下穿刺が注目を浴びている. これは, 超音波画像診断装置の発展により, 穿刺部位を視覚的に確認しながらおこなうことが可能になったためである. 実際, エコーガイド下穿刺は, 困難な AVF の穿刺に有効であると報告されている[18][19][20]. しかしこの技術の普及のためには, 継続的な研究とトレーニングが必要とされている[20].

一方, 機械学習技術の発展は, 人間工学の分野で注目されている[23]. 特に, 人間の行動やリスクをモニタリングするためにウェアラブルセンサと機械学習アルゴリズムを組み合わせる研究が進められている[27].

さらに, 医学教育における CLT は, 学習の効果的な枠組みとして重視されている[29][30][31]. しかし, 医療環境における意思決定の補助としての機械学習の適用は, まだ十分に実現されていない[34].

以上のことから下記 3 点を研究課題として検討をおこなう．

- 1．エコープローブ操作に着目したエコーガイド下穿刺技術の顕在化
- 2．医療従事者の穿刺タスクと機械学習の組み合わせによる，穿刺手技の評価方法の検討
- 3．穿刺における認知負荷の軽減と，機械学習を用いた支援システムの実現性（実現性検証）に関する検討

これらの研究を通じて，バスキュラーアクセスへの穿刺の質の向上と，医療タスクにおける負担の軽減，穿刺やエコーガイド下穿刺における新しい手技評価の確立による，早期の手技習得や手技の改善につなげるため，穿刺業務の観察によるスタッフ教育のための機械学習利用の可能性を探求する．

## 第3章 エコープローブ操作に着目した操作技術の顕在化

### 3.1 背景

近年、超音波画像診断装置（以下、エコー）の画像高精細化や小型化[5]によって、エコーのアクセシビリティが格段に向上してきた。医療従事者でもエコーガイド下穿刺（以下、エコー下穿刺）[6]が行われるようになり、VAの走行や径の変化・石灰化および内膜肥厚の可視化が可能となってきた。触覚と前回までの経験則に頼ってきた血管内評価が、視覚情報で他者と共有可能となるという飛躍的な発展を遂げた。一方、エコーガイド下穿刺が血液透析治療における困難なバスキュラーアクセスの標準として認められるためには、さらなる報告が必要であるとされ、エコーガイド下穿刺には、専門意識、理論、OFF/OJTによる訓練、シミュレータの使用などによる、エコーガイド下穿刺技術に関するトレーニングが重要であると言われている[15]。また、エコーガイド下穿刺における最善の方法は、穿刺者の経験と技術に関する知識によって異なると言われている[22]。

そこで、本章の研究ではモーションキャプチャを使い、エコープローブ操作に着目したエコーガイド下穿刺技術の顕在化により、穿刺者のエコープローブ操作の特徴をとらえ、経験に頼った部分を数値的に表現できるか検討することを目的とする。

### 3.2 超音波画像診断装置

超音波画像診断装置は、医療分野での非侵襲的な診断ツールとして広く採用されている。この装置は人体の内部の組織や流体に向けて超音波を放射し、反射を利用して内部の詳細なイメージを捉えるものである。心臓の動きや血液の流れ、胎児の成長や位置、腹部の臓器の状態など、さまざまな体の部分を評価するのに用いられる。超音波は、放射線を使用しないため、患者へのリスクが低いとされており、その非侵襲性から手術や他の侵襲的な手段を必要とせず、診断を得ることができる。しかし、脂肪組織や骨など、超音波の伝播を妨げる体組織が存在するため、適切な画像が得られない場合がある。そのため、知識や技術、経験が不可欠である。技術の進化とともに、近年の超音波装置は3Dや4Dの画像を提供する能力を持ち、更に詳細な視覚的情報を提供することが可能である。

エコーガイド下穿刺（図3.1）や正確な血管の評価には、専門のトレーニングや経験が不可欠である。シミュレータを用いたトレーニングや、実際の患者でのハンズオントレーニングが行われている。




図 3.1 エコーガイド下穿刺で血管内に針を進めている様子（長軸像）

### 3.3 モーションキャプチャ

モーションキャプチャは人間の動きをデジタル的に記録し再現する技術である．この技術は，映画，ビデオゲーム，スポーツ，医療，ロボティクスなど多岐にわたる分野で利用されている．

モーションキャプチャは通常，動きを記録するために，人や物にセンサや反射マークを取り付ける．これらは特殊なカメラやセンサによって追跡する．マークを配置した人や物が動くと，マークの位置と動きがリアルタイムでキャプチャされ，3D 空間内の動きとして記録される．

本研究では，アキュイティ株式会社製モーションキャプチャシステム (OptiTrack V120:Duo, 付録 A) )を使用した．

### 3.4 方法

本研究は，神奈川工科大学ヒト倫理審査委員会によって承認されている（承認番号：20191223-02）．

### 3.4.1 被験者

透析専門のクリニックに勤務する臨床工学技士の男性 5 名を被験者としている。被験者の詳細は表 3.1 に示す。被験者の年齢は比較的近い年齢層にある。しかし、透析業務歴、エコー下穿刺歴は倍以上の年数差がある。

表 3.1 被験者のプロフィール

被験者	1	2	3	4	5
年齢（年）	39	35	35	35	35
透析業務歴（年）	16	12	9	8	8
エコーガイド下穿刺歴（年）	10	6	6	4	4

### 3.4.2 エコーガイド下穿刺方法

被験者は穿刺針として有効長 38mm、外径 17G もしくは 16G の太さの針を利用して穿刺を行なった。エコーは FC1-X VA（FUJIFILM）、プローブは HFL38xp（FUJIFILM）を使用して動脈側（A 側）と静脈側（V 側）の穿刺時に血管を描画した。プローブの操作方法は被験者が日常的に行なっている単軸法を利用した。



図 3.2 短軸法による穿刺針の見え方

### 3.4.3 観察装置

本研究で用いるモーションキャプチャは光学式と呼ばれるタイプで、評価したい部位に

マーカを装着し，3次元座標を記録するものである．

マーカ撮影用のカメラには OptiTrack V120: Duo (OptiTrack)，計測ソフトには Motive: Body (OptiTrack) を使用し，マーカは直径 9.5mm 反射マーカ (OptiTrack) を専用の高さ 20mm のマーカベース (OptiTrack) に取り付け，それをプローブ上部のプローブ把持に影響の無い場所へ 3 個装着して空間座標上の位置を記録した．被験者から見てプローブを穿刺部位から中枢側方向（前後）が X，持ち上げる上下方向が Y，左右方向が Z 軸としてデータ収集をおこなった．その他に穿刺動作全体とエコー画像をハンディカメラ (SONY FDR-AXP35) でそれぞれ同時に撮影した．図 3.3 は観察装置の実際の配置である．

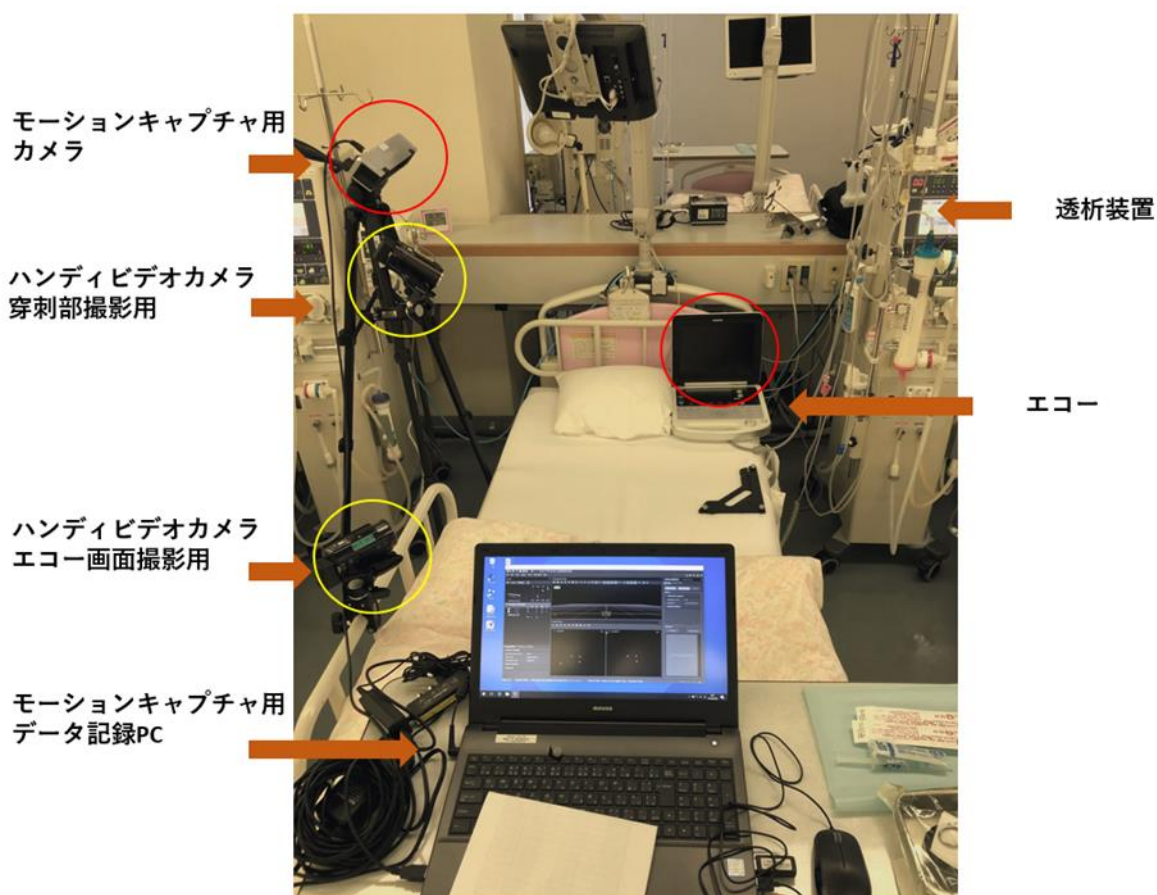


図 3.3 観察装置の配置

#### 3.4.4 位置座標と加速度の抽出

モーションキャプチャにより記録されたデータの分析は SKYCOM, (OptiTrack) を使用した．SKYCOM に Motive: Body の測定データを読み込むことにより，観察時のプローブ座標位置における動作の再現（動画）による確認やマーカごとの位置座標や加速度を抽出し

た．抽出する際に，ビデオカメラで撮影したエコー画像と時間軸で同期をおこない，穿刺開始からエコー画面に針先が最初に見えるまでを「視認前」，針が見えてから穿刺終了までを「視認後」として時間軸に合わせてデータを追加した．抽出により定量化された一連の動作で得られた，X, Y, Z 軸の経時的な位置座標，加速度などの数値データを 0.01 秒間隔で CSV 形式で出力した．

ただし，データ収集は被験者 1 名につき 12 回の穿刺をおこなったので 60 症例分のデータが収集できたが，モーションキャプチャによりエコーの動きが適切に捉えられていなかった 26 症例分については除外データとした．

### 3.4.5 変位量の算出

Python (3.8) 言語とフレームワークである pandas (2.0) を使い，3.3.4 で出力された CSV ファイルを 1 症例ごとに読み込み，difflib モジュールを使って，X, Y, Z それぞれの変位量を算出し，1 症例ごとに CSV 形式で保存した（図 3.4）．

ファイルは，時間，位置座標（X, Y, Z），変位量（deltaX, deltaY, deltaZ）と X 軸方向の加速度（ACC），タイプ（視認前・視認後）の 9 項目で構成した．




図 3.4 変位量算出のフローチャート

### 3.4.6 データ分析（散布図行列）

散布図行列は，多変量データセットの中の各変数ペア間の関係を示す散布図 (scatter plots) を行列形式で配置したものである．データ分析の初期段階で広く使用される探索的データ分析 (EDA: Exploratory Data Analysis) のツールの一つである．本研究では，変数間（変位量 X, Y, Z）の相関関係を視覚的に理解（顕在化）するために利用した．

#### I. ディレクトリの読み込み

os.listdir() 関数を使用して，指定されたパスにあるファイルのリストを取得した．ファイルリストは 3.3.5 で作成したファイルである．

## II. ファイルのループ処理（図 3.5）

`pandas.read_csv()` 関数を用いて CSV ファイルを読み込み、データフレームに格納する。`dropna()` メソッドで、データフレームから欠損値（NaN）を含む行を削除した。変位量である `deltaX`, `deltaY`, `deltaZ` 列だけを抽出し、値を小数点以下 3 桁までとした。

`scatter_matrix()` 関数を使用して、選択された列のペア間で散布図行列を作成した。`diagonal='hist'` で対角線上にヒストグラムを表示した。

`plt.savefig()` を使用して、生成された図を画像ファイルとして保存した。`plt.close()` で現在の図をクローズし、次のループのための描画をクリアした。

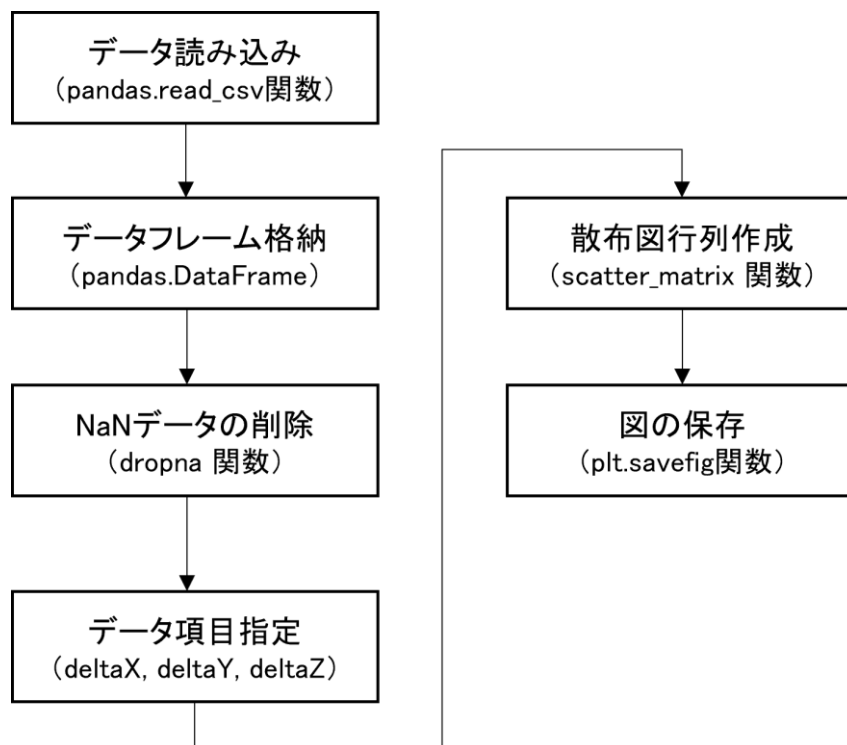


図 3.5 散布図行列作成のフローチャート

### 3.4.7 データ分析（主成分分析）

位置座標データでの分析は静的特性の分析であり、座標データは物体や観測点が空間内でどのように配置されているかを示す。エコープローブの空間内での位置座標についてある時点（穿刺開始時など）を決めて分析をおこなえば、主成分分析（principal component analysis : PCA）によってそのような静的特性を抽出できる可能性がある。また、異なる時点での物体の位置を比較することにより、PCA を使ってデータの基本的なパターンを見つけ出し、これらのパターンに基づいて物体間または時間点間での違いを分析することがで



きる．しかし，本研究でのエコープローブの動きは，被験者だけではなく患者や患者の穿刺部位より，条件が大きく異なる．これらの事情により条件を揃えて比較することが困難である．これは，臨床データを取り扱う際には常に考えなければいけない．

そのため，本研究では位置座標の変化を変位量データとして動的特性の分析をおこなうことにした．一般的に変位量データは物体の運動や時間経過に伴う位置の変化を反映する．時間に依存するデータに対して PCA をおこなう場合，変位量データが運動のパターンや，時間に伴う変化の主要なモードを抽出するのに適している[35][36]．

## I. データの読み込みと前処理

`pandas` ライブラリの `read_csv()` 関数を用いて，CSV ファイルからデータフレームを作成し，欠損値を含む行を削除した．次に `deltaX`，`deltaY`，`deltaZ`，`ACC` のデータのみを選択して値を小数点以下 3 桁までにした．

## II. PCA の実行

`PCA()` クラスを用いて PCA を初期化し，Iで作成したデータフレームにフィットさせ，元のデータを主成分空間に写像（変換）した．

## III. 主成分得点の保存

PCA によって変換された特徴量（主成分得点）を新しいデータフレームとして作成し，CSV ファイルに保存した．各主成分の寄与率（`explained_variance_ratio_`）を計算し，それを別の CSV ファイルとして保存した．

PCA による各変数の主成分に対する貢献度（成分行列）を図にした．

## IV. 寄与率

寄与率を格納するための `Pandas DataFrame ExplainedVariance` を初期化する．`deltaX`，`deltaY`，`deltaZ` の列を特徴量として選択し，`Type` 列を目的変数として使用した．`Type` 列は「Before visibility : BV」を 0，「Visual recognition : VR」を 1 とカテゴリを数値に変換した．

散布図を 3D でプロットし，「Before visibility : BV」と「Visual recognition : VR」の 2 つの条件で異なる色を使ってデータを可視化した．

作成したプロットを画像ファイルとして保存した．

### 3.5 分析結果

データ収集によって有効であった 34 症例分のデータを分析した.

#### 3.4.1 散布図行列

散布図行列は, 3 つの変数 ( $\text{deltaX}$ ,  $\text{deltaY}$ ,  $\text{deltaZ}$ ) 間の関係を可視化した. モーションキャプチャのマーカから得られた位置座標 3 次元の動きのデータを表している. 各行列は, 2 変数間の相関関係と, 各変数の分布を示すヒストグラムを含んでいる.

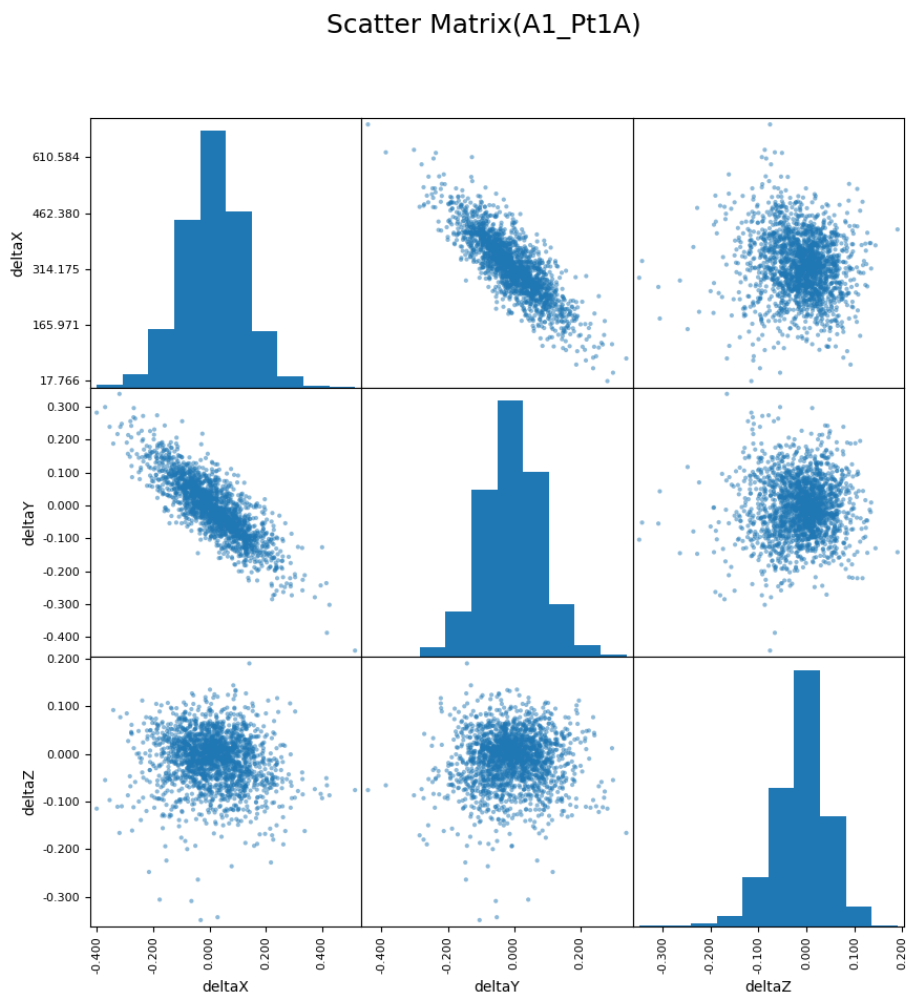


図 3.6 被験者 1 (散布図行列)

Scatter Matrix(A2\_Pt1A)




図 3.7 被験者 2 (散布図行列)

Scatter Matrix(A3\_Pt1A)

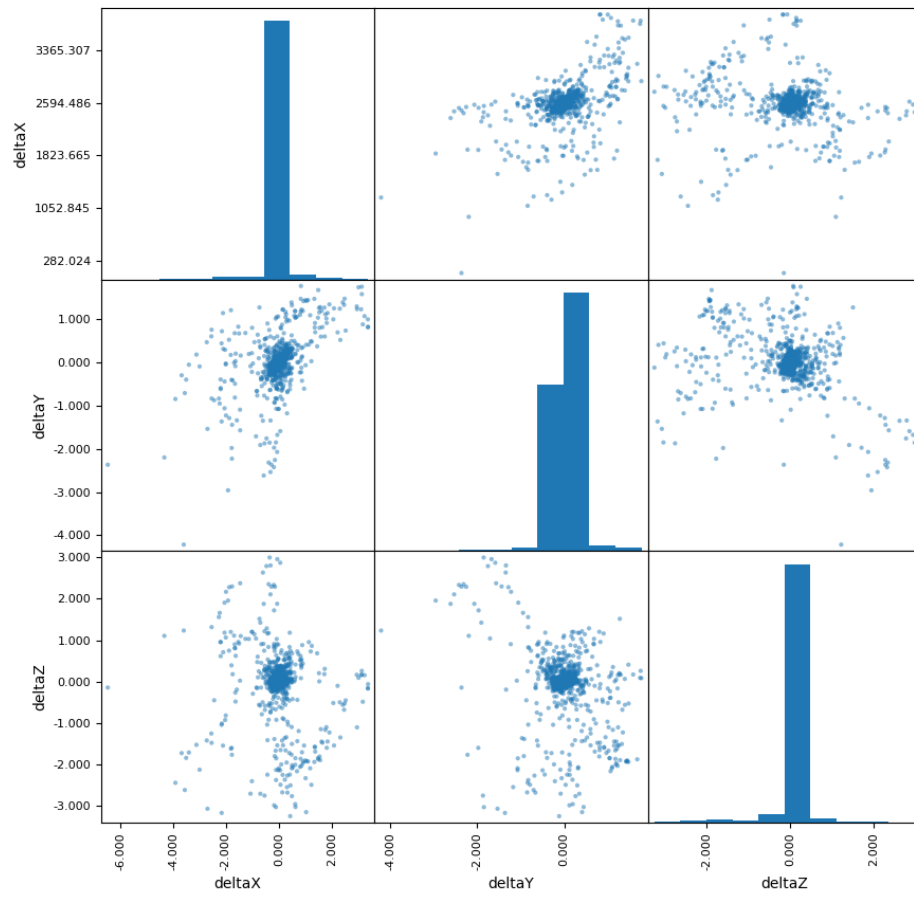


図 3.8 被験者 3 (散布図行列)

Scatter Matrix(A4\_Pt4A)




図 3.9 被験者 4 (散布図行列)

Scatter Matrix(A5\_Pt1A)




図 3.10 被験者 5 (散布図行列)

## 変数の分布

対角線上にあるヒストグラムは、各変数の分布を示している。これらは変数の値がどの程度分散しているか、多くのデータポイントがどの値の周りに集中しているかを示している。deltaX, deltaY, deltaZ のヒストグラムは、データが特定の範囲内に集中していることを示しており、特に deltaY と deltaZ は正規分布に近い形をしている。deltaX は比較的分散が広がっている傾向がある。

## 変数間の相関関係

対角線以外のプロットは、2 つの変数間の散布図を示しており、それぞれの関係を可視化している。特に、deltaX と deltaY, deltaX と deltaZ のプロットは、これらの変数間に強い正または負の相関関係がある。

deltaX と deltaY のプロットは明らかな線形関係を示しており、一方の変数が増加すると他方の変数も増加する傾向にある。

## 被験者の比較

被験者ごとに変数の分布と相関関係が異なることが観察できる。被験者 3 では deltaZ の分散が比較的小さいのに対して、他の被験者では広範囲にわたっている。



また、被験者 3 のデータでは、deltaY と deltaZ の散布図が他の散布図とは異なるパターンを示している。穿刺対象患者が変わった場合、別の被験者でも被験者 3 と同様の分散が小さくなっている場合があった。

### 3.4.2 主成分分析



3D 散布図は、主成分分析 (PCA) を用いて次元削減されたデータセットを可視化して示す。ここでの主成分は、元のデータセットにおける変数間の相関関係を最大に捉える軸である。

## データの分類

散布図は、データポイントがどのようにクラスターを形成しているかを示している。特に被験者 4 (図 3.11) では、「Before visibility」の状態におけるデータポイントが広い範囲に分布しているのに対し、「Visual recognition」の状態ではより密集したクラスターを形成している。





被験者 1





被験者 2

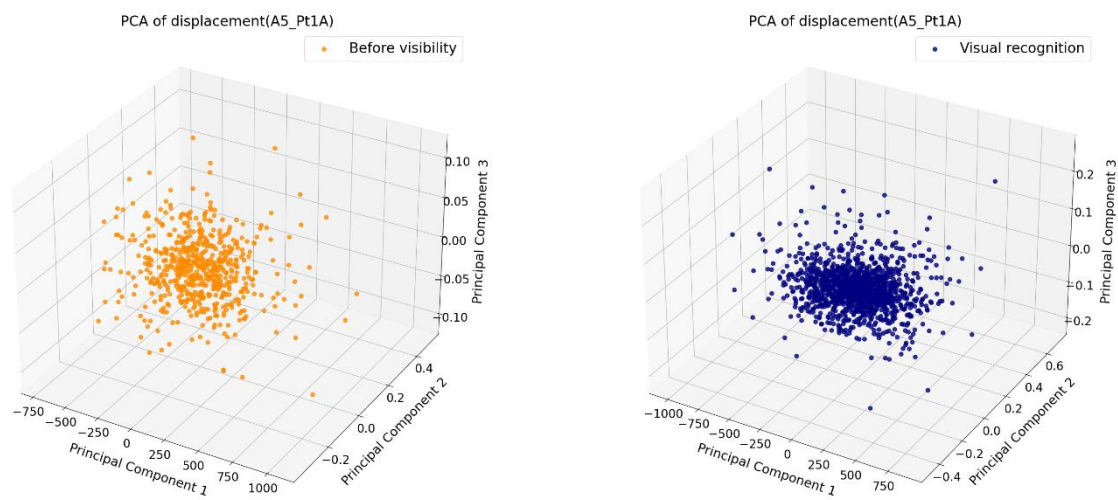




被験者 3



被験者 4



被験者 5

図 3.11 被験者ごとの 3 次元 PCA

## 主成分の分散

3 軸（主成分 1, 主成分 2, 主成分 3）を通じて、データの分散がどのように表現されているかが分かる。各主成分は、データの分散のある割合を捉えており、一般に第一主成分が最も多くの分散を捉え、次に第二、第三と続く。

## 条件の違いによる分布の変化

「Before visibility」と「Visual recognition」の状態でデータポイントの分布がどのように異なるかが見て取れる。これは、被験者が穿刺針を視認する前後で動きがどのように変化するかを示している可能性がある。

## 外れ値の識別

被験者 2, 被験者 3（図 3.11）では、主クラスタから離れた場所にポイントが存在する。これらは外れ値であり、他と違う動きやエラー、あるいは大きく動いた状態を表している可能性がある。

被験者 1 では  $\Delta X$ ,  $\Delta Y$ ,  $\Delta Z$  にラベル付けされたデータ点は、互いに比較的近く、これらの成分によって捕捉された分散が類似している。ACC は、第 1 主成分に沿って原点から離れており、その成分と強い正または負の相関があることを示している。

被験者 2 の  $\Delta X$  と  $\Delta Y$  は互いに近く、第 1 主成分に沿って原点から遠く、 $\Delta Z$  は原点に近い位置にある。ACC は第 2 主成分に沿って離れており、これは、他の成分と比較して、この成分で捕捉された分散と異なる相関がある。

被験者 3 の  $\Delta X$  は第 1 主成分に沿って原点から離れており、有意な分散を示している。 $\Delta Y$  と  $\Delta Z$  は互いに近いが、 $\Delta X$  から比較的離れており、分散の様子は似ているが、 $\Delta X$  とは異なる。ACC は、第 2 主成分に沿って原点から離れており、分散の点で異常値である。

被験者 4 では  $\Delta X$  と  $\Delta Y$  は第 2 主成分上で原点から遠く離れており、分散の点で有意である。 $\Delta Z$  は第 1 主成分に沿って原点から遠く、それとの強い正または負の相関を示している。ACC データポイントは原点に近く、被験者 3 のプロットほど主成分と強い相関がない。

被験者 5 では  $\Delta X$  と  $\Delta Y$  は第一主成分における寄与は低いものの、第二主成分においてはより大きな寄与をしている。 $\Delta Z$  はどちらの主成分においても低い値を持っており、分散にはほとんど寄与していない。ACC は第一主成分において原点から遠く、この成分において最も分散を引き起こしている。








図 3.12 PCA と寄与項目

### 3.6 考察

エコープローブの操作は、エコーガイド下穿刺の成功に重要な役割を果たす。散布図行列は、3次元の動きを表すモーションキャプチャマーカでとらえた3つの変数（ $\Delta X$ ,  $\Delta Y$ ,  $\Delta Z$ ）の関係を視覚化することができた。変数の  $\Delta X$ ,  $\Delta Y$ ,  $\Delta Z$  の分布が特定の範囲内に集中していることが示され、これらの変数のヒストグラムが正規分布に近い形をしていることから、穿刺時のプローブの操作が一定のパターンに従っている可能性が示唆される。これは、特に  $\Delta Y$  と  $\Delta Z$  において顕著であり、エコー下穿刺におけるプローブ動作の標準化に対する理解を深めるのに役立つ情報であることが示唆される。

エコープローブ操作に焦点を当てたエコーガイド下穿刺技術の研究[6]は、臨床現場での穿刺成功率を向上させる重要な技術的進歩となる。先行研究では超音波診断装置を用いて血管のリアルタイム観察をおこなう。その方法はプローブ固定装置を用いてプローブ動作を固定し、その状態で穿刺を実施することで確実な穿刺を可能にしている[37]。

また、PCAによる分析（図 3.12）からは、主成分がデータの分散をどの程度捉えているかが明らかになり、データポイントのクラスタリングが可視化された。特に、「Before visibility」と「Visual recognition」の状態での分布の違いから、穿刺針を視認する前後での操作の変化を推察できる。一方で、被験者ごとに異なるパターンが存在することが確認され、個々の操作技術や患者の解剖学的特徴に基づいた別アプローチでの検討が必要であることを示唆している。被験者3のデータは他の被験者と異なるパターンを示し、 $\Delta Z$  の分散が比較的小さかったことは、特定の技術や条件下での安定性を示唆している。また、すべてにおいて無相関であった。これはプローブを長軸・短軸に切り替える動作があったためであると推察される。しかし、これらのデータ分析はプローブ操作の被験者の技術的側面だけでなく、患者の解剖学的変異や臨床環境の違いといった複数の要因を考慮する必要があるという課題を提起している。

散布図行列とPCAは、被験者間の分布と相関のばらつきを浮き彫りにした。観察されたばらつきは、プローブ操作技術が個人の背景や状況に応じて異なる可能性を示唆し、おそらく異なる技能を表したものであると考えられる。PCAは、データセットの次元削減をし、エコーガイド下穿刺における複雑な動きの理解や、トレーニング手順の改善に役立つ可能性がある。また、外れ値の特定からは、不規則な動きや操作上のエラーによる影響も考慮されるべきであり、これはトレーニングの改善やプロトコルの最適化に有用な情報を提供すると考えられる。

穿刺におけるプローブの動きを、散布図行列と主成分分析（PCA）を用いて分析することで、プローブ操作のパターンを顕在化し、教育や臨床へのフィードバックができる可能性が示唆された。

### 3.7 研究の限界

本研究では症例数が 34 症例と比較的小さく、統計的な有意性を確立するには不十分であった。少ない症例数では、偶発的な偏りや個別の症例（被験者）の特異性が結果に過大な影響を及ぼすリスクがある。次に、散布図行列と主成分分析によるデータの解釈は、穿刺時のプローブ操作の複雑さを完全には捉え切れていない可能性がある。3 次元の動きデータを 2 次元のプロットで表現する際には、ある程度の情報が失われる。また、穿刺技術の教育や実践において、実際の手技の微妙なニュアンスをデータ化し、可視化することは困難であることを考慮する必要がある。さらに、被験者間での変数の分布と相関関係の違いが観察されたが、これらの違いが単に個人差によるものなのか、それとも技術的な違いや他の要因によるものなのかを区別することは難しい。特に、被験者ごとの手法の習熟度や患者の解剖学的特徴による影響を詳細に分析するには、さらなる研究が必要である。加えて、エコーガイド下穿刺技術は多様な臨床環境で応用されるが、この研究が行われた特定の環境や条件が他の環境にそのまま適用できるとは限らない。異なる機器や異なる患者での結果がこの研究の結果と同様である保証はない。最後に、穿刺技術に関する研究では、プローブの操作性だけでなく、医療従事者の負担、患者の安全性、医療の経済性など、多角的な評価が求められる。しかし、これらの要素は現状の研究では十分に評価されていない可能性がある。

これらの限界は、今後の研究での考慮事項となる。穿刺技術のさらなる改善と医療の質の向上を目指し、より大規模な研究や多様な臨床環境での検証が期待される。

### 3.8 結論

プローブ操作の被験者によるパターンを顕在化することにより、エコープローブ操作技術を教育や臨床へフィードバックできる可能性が示された。エコーガイド下穿刺の有効性を高める上で、変数の相互作用とプローブ操作の役割を理解することの重要性が浮き彫りになった。

## 第4章 機械学習を使った穿刺手技の評価

### 4.1 背景・目的

シャント血管の狭窄・変形・蛇行を併発した場合は穿刺部位が限定され、留置すべき針先の位置を制限せざるを得なくなることがある。このことが更に穿刺の難易度を上げ、失敗する頻度が増え、さらなる血管の荒廃を引き起こす可能性がある。このように血液透析における穿刺技能は非常に重要なものであるが、医療における技能習得の多くは、OJTにより行われる。穿刺は穿刺ごとに対象となる患者が違い、また対象の血管も異なることから画一的な教育は難しく、視覚化もできず、触覚や経験則などを非常に抽象的な言語による指導に依存せざるをえず、指導者にとっても追随者にとっても的確な伝承という点において、難しさがある。

本研究では穿刺タスクにおける動きを数値化し、機械学習の一種であるオートエンコーダを使用する。オートエンコーダは、表現学習手法の中でも汎用性の高いツールであり、生体信号のような複雑なデータ構造を、より解釈しやすくコンパクトな形で表現（圧縮）することを学習することができると言われている[38]。先行研究として、睡眠時無呼吸解析においてオートエンコーダは生体信号から特徴を圧縮して学習するために使用し、元の信号をより小さく管理しやすい潜在空間表現に変換する。これらの表現を畳み込みニューラルネットワーク分類器と組み合わせて、睡眠時無呼吸症候群を効果的に分析する[39]とされている。

そこで本研究では、穿刺動作から座標位置を取得し、医療従事者の穿刺タスクと機械学習の組み合わせによる、穿刺手技の評価手法の検討をおこなうことを目的とする。

### 4.2 バスキュラーアクセス

透析医療におけるバスキュラーアクセス（Vascular Access：VA）は、血液を体外の機器へと導く、また血液を体内に戻すためのデバイスもしくは、その部位（方法）を指す。血液透析が開始された頃は、深大腿動脈や大伏在静脈を露出して、直接カテーテルを挿入していた。1960年 Quinton と Scribner が、カニューレを橈骨動脈と前腕の静脈に留置し、両者を連結する「外シャント」を開発してから血液透析が反復して行えるようになった。また、1961年 Shaldon は、経皮的に大腿動静脈にカテーテルを留置して VA として使用する方法を考案した。1966年に Brescia と Cimino によって編み出された内シャントは画期的な

ものであり、現在でも VA の主流となっている。

VA には大きく分けて三種類ある。中心静脈カテーテル (Central Venous Catheter : CVC) は、大きな静脈に直接挿入される長いチューブで、緊急や短期間のアクセスとして使用される。次に一般的に「内シャント (シャント)」と呼ばれているのは AVF のことであり、手関節の 3~4cm 中枢側の橈骨動脈と橈側皮静脈を吻合する。一番、多く使われているアクセスである。最後に AVG は AVF を作成するのに適した動静脈をもたない場合に使用され、人工的なチューブを用いて血管の代わりとする。これらの VA はいずれも、適切な流量を確保し、効果的な治療が行えるようにするために重要である。しかし、感染や血栓形成などのリスクも伴うため、管理は慎重におこなう必要がある。定期的な検査や日常の穿刺時に、問題が発生した場合には速やかに対応することが不可欠である。

VA (特にシャント) への穿刺を適切におこなわなければ、患者の治療の成否に直結するため、より慎重な対応が求められる。

### 4.3 穿刺部位の観察

シャントの観察は、長期シャントの開存を左右することにつながる重要な情報となる。一般的に穿刺前・中・後に行い、とくに穿刺前の観察は異常の早期発見につなげるためにも大切である。穿刺する部位はまず視診で血管の怒張の程度、シャント音が大きいこと、拍動が強いことを確認し、感染兆候がない部位を選定する。皮膚の癒痕化や薄くなっている部位は避ける。動脈側は十分な血流がみとめられ、できるだけ太く直線的な血管を選択する。静脈側は内腔に狭窄がなく、穿刺しやすい部位であればシャントの本管以外でもよい。とくに注意すべきことは、静脈側に戻ってきた血液を、そのまますぐ動脈側で吸引となる再循環を起こさないことである。また、同一部位の穿刺は、反復穿刺することでその部分が動脈瘤様に拡張し、その場所から中枢側が急に細くなるなどの問題が生じてくる [40]。

吻合部近くの穿刺は避け、5~7cm 上部から使用する。シャントの寿命を長持ちさせるためにも、なるべく広範囲にまんべんなく穿刺することを心がけるなど、視覚、聴覚、触覚で獲得した情報を実際の穿刺に役立てるが、それらのことを学習して知っているか否かという内在的知識も重要である。



## 4.4 機械学習と評価

機械学習とは与えられた問題や課題または環境に応じてコンピューター自身が学習し、学習結果を生かした問題解決や課題解決などをおこなう仕組み全体のことをいう[41]。大きく、「分類」と「回帰」に分けることができる。

### 4.4.1 線形回帰 (Linear Regression)

「ある説明変数が大きくなるにつれて、もつ変数も大きく（または小さく）なっていく」という関係性をモデル化する手法[42]である。

線形回帰を使った分類は、通常線形回帰モデルを変更して分類問題に適用する手法である。しかし、線形回帰は本来、回帰問題（連続的な値を予測する）に使用されるため、分類問題（離散的なカテゴリを予測）に、そのまま適用するのは理想的ではない。線形回帰は、入力特徴（ $X$ ）と目標値（ $Y$ ）の間に線形関係（式 4.1）を見つけようとするモデルである。

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon \quad [\text{式 4.1}]$$

$\beta$  : モデルの係数

$\varepsilon$  : 誤差

### 4.4.2 Autoencoder

オートエンコーダは教師なし学習用に設計されたニューラルネットワークの一種であり、学習中に明示的な出力信号を与えられることなくデータを表現することを学習すると言われている[42]。つまり、オートエンコーダの機能は、入力データをエンコード（圧縮）し、それを元の入力にできるだけ近い形にデコード（復元）して戻すことあり、効率的にデータを再構築[43]する特徴を学習することである。

### 4.4.3 評価

- True Positives (真陽性) : モデルが正しく陽性と予測した数
- False Positives (偽陽性) : モデルが誤って陽性と予測した数
- False Negatives (偽陰性) : モデルが誤って陰性と予測したが, 実際には陽性である数
- True Negatives (真陰性) : モデルが正しく陰性と予測した数
- Total Samples (総サンプル数) : すべてのサンプルの数

Accuracy (正解率) :

正解率は, モデルが正しく予測したサンプルの割合を示します. すべてのサンプルのうち, 正しく予測したサンプルの割合である.

Precision (適合率) :

適合率 (式 4.2) は, モデルが陽性と予測したサンプルのうち, 実際に陽性である割合を示す. モデルが正確に陽性と予測できた割合である.

$$\text{Precision} = \frac{TP}{TP + FP} \quad [\text{式 4.2}]$$

Recall (再現率) :

再現率 (式 4.3) は, 実際に陽性であるサンプルのうち, モデルが正確に陽性と予測できた割合を示す. モデルが実際の陽性サンプルをどれだけ捉えることができるかを示す.

$$\text{Recall} = \frac{TP}{TP + FN} \quad [\text{式 4.3}]$$

F1-Score :

F1 スコア (式 4.4) は, 適合率と再現率のバランスを示す指標である. 適合率と再現率はトレードオフの関係にあり, 適合率を上げると再現率が下がり, 逆もまた同様である. F1 スコアは, このトレードオフを調和させた指標である.

$$\text{F1 Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad [\text{式 4.4}]$$

## 4.5 方法

本研究は，神奈川県立大学ヒト倫理審査委員会によって承認されている（承認番号：20191223-02）。

### 4.5.1 被験者

被験者(臨床工学技士 6 名)を表 4.1 に示す。

表 4.1 被験者のプロフィール

被験者	A1	A2	A3	A4	A5	A6
年齢 (年)	52	33	26	36	43	42
透析業務歴 (年)	29	5	1	5	17	6
エコーガイド下穿刺歴 (年)	15	4	0.5	4	10	4

### 4.5.2 データ採取

被験者は穿刺針として有効長 38mm，外径 17G もしくは 16G の太さの針を利用して穿刺を行なった。患者の腕（穿刺位置）を中心に，手元を撮影するビデオカメラ（Sony 社製・FDR-AXP35）を配置した。記録画素数とフレームレートは 1920×1080／30p とした。

### 4.5.3 動画データの準備

撮影した動画データをパソコンに取り込み，動画編集ソフト（Adobe 社製・Adobe Premiere Pro v15.4）を使い，被験者が患者のバスキュラーアクセスの皮膚に針を接触させたところを開始，針を留置して内筒針を引いたところを終了としてデータのトリミングをおこなった。トリミング後，OpenPose がサポートする mp4 形式（1980×1280／30p）で動画ファイルを出力，保存した。

#### 4.5.4 動画データから座標データへ変換（Open Pose）

Open Pose は、姿勢推定や人物のポーズ推定などのタスクを実行するためのオープンソースのライブラリである。Open Pose を使うと、画像やビデオから人の姿勢やポーズを推定することができる。本研究では穿刺をおこなう右手の動作を、Open Pose を用いて座標データに変換する手法を使った。OpenPose のセットアップとして OpenPose (v1.7.0) のソースコードを GitHub からダウンロードした。Open Pose は C++で書かれており、CMake と OpenCV などの関係ソフトウェアと共にインストールをおこなった。

Open Pose は、学習済みのモデルファイルをベースに動作する。これらのモデルは Open Pose の公式ウェブサイト

(<https://cmu-perceptual-computing-lab.github.io/openpose/web/html/doc/index.html>) からダウンロードおこなった。モデルには、姿勢推定用のモデルと、ポーズ推定用のモデルが含まれる。

姿勢推定の実行として 4.3.3 で作成した動画ファイルごとに、コマンドラインから下記のコードを入力し姿勢推定を実行した（実行ディレクトリは下記とは異なる）。

```
./build/examples/openpose/openpose.bin  
--video input_video.mp4 --write_json output_directory --hand
```

推定結果には、各関節の位置番号、位置座標 (X,Y) や信頼度などが含まれた JSON 形式のファイルが動画 1 フレームに 1 つの JSON ファイルという形で出力される。

コマンド実行後、Open Pose からの推定結果の保存をおこなった（図 4.1）。




図 4.1 動画データから座標データへの変換フローチャート

#### 4.5.5 位置座標の抽出

本研究では穿刺する「手」に着目しているので、JSON 形式のファイルから手の位置情報を抽出し、それらのデータを CSV ファイルに一括に変換するプロセスを実行する Python

スクリプトを作成し処理をおこなった（図 4.2）.

`json_to_csv(json_file, writer)` 関数で、指定された JSON ファイルを読み込み、その中からポイント（手の関節位置情報）を抽出した．手のポイントは全部で 20 個抽出できるが、本検討では穿刺針を持つ、親指と人差し指のうち、カメラから常に見えていて動きが捉えられる、6・7・8 番のポイントを利用した（図 4.3）．重複する `person_id` をチェックして、複数の人物データが含まれているかどうかを確認した．左手（`left_hand_keypoints`）と右手（`right_hand_keypoints`）の情報をそれぞれ処理し、ポイントは、`person_id`, `hand_type`（`left` または `right`）, `x` 座標, `y` 座標, および信頼度（`confidence`）の列で構成される CSV 行に変換する．

`merge_json_to_csv(input_dir, output_csv)` 関数では先述の 2 つの関数を含み、指定されたディレクトリ内の複数の JSON ファイルからデータを読み込み、それらを単一の CSV ファイルに結合し 1 つの CSV ファイルとして出力した．出力 CSV ファイルには、ヘッダー情報として `person_id`, `keypoint_type`, `X`, `Y`, `confidence` としている．

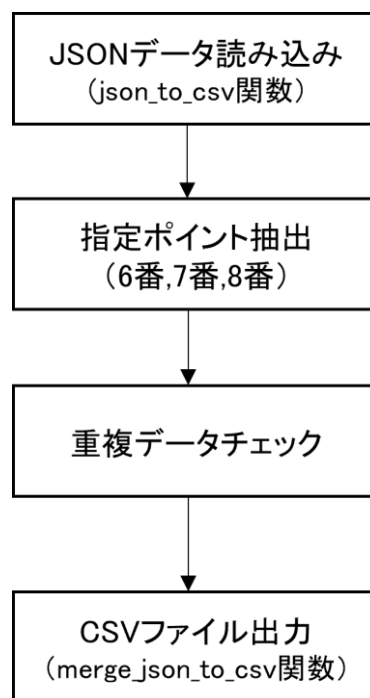


図 4.2 JSON ファイルから指定ポイントの位置座標抽出フローチャート



図 4.3 手のポイント

#### 4.5.6 散布図行列

Python (3.8) 言語とフレームワークである pandas (2.0) を使い, 4.5.5 で出力された CSV ファイルを 1 症例ごとに読み込み, difflib モジュールを使って, 3 つのポイントの X, Y, それぞれの変位量 (`x6_diff`, `y6_diff`, `x7_diff`, `y7_diff`, `x8_diff`, `y8_diff`) を算出し, 穿刺部位 (A 側もしくは V 側) を `pt` カラム, 被験者番号を `subject` カラムにそれぞれ追加して, 全症例を 1 つのファイルにまとめた.

`x6_diff`, `y6_diff`, `x7_diff`, `y7_diff`, `x8_diff`, `y8_diff` の値を使い, `scatter_matrix_plot` 関数を使い, 散布図行列を作成した.

#### 4.5.7 Autoencoder を使った機械学習

4.5.6 でまとめたデータセットのポイント 6 番の変位量 (x6\_diff) 数値から $\pm 10\text{mm}$ を超える値であった場合を「1」、それ以外を「0」として、基準値以内であった場合とそうで無かった場合はエラーとして定義した。

0 もしくは 1 は Err カラムに情報を追加した。この Err カラムの「1 (クラス 1)」と「0 (クラス 0)」を目的変数、説明変数はポイント 6, 7, 8 番の X と Y の変位量としたデータセットを準備した。

エンコーダ定義：

```
input_layer = Input(shape=(input_dim,))
encoded = Dense(128, activation='relu')(input_layer)
encoded = Dense(64, activation='relu')(encoded)
```

Input レイヤーは入力データの形状を指定し、それに続いて 2 つの Dense 層（全結合層）を指定。Dense 層は、128 個および 64 個のユニットを持ち、活性化関数として ReLU (Rectified Linear Unit) 関数を適用した。これにより、入力データが低次元にエンコードされる。

デコーダ定義：

```
decoded = Dense(128, activation='relu')(encoded)
decoded = Dense(input_dim, activation='sigmoid')(decoded)
```

エンコーダで得られた低次元の表現を元の次元にデコードする。2 つの Dense 層を使用し、最終的に input\_dim の次元数を持つ出力が得られる。最終の Dense 層では sigmoid 活性化関数を使用した。これにより出力値が 0 から 1 の範囲に制約される。

オートエンコーダモデル定義（図 4.4）：

```
autoencoder = Model(input_layer, decoded)
encoder = Model(input_layer, encoded)
```

エンコードとデコードを結合したオートエンコーダモデルを定義した。

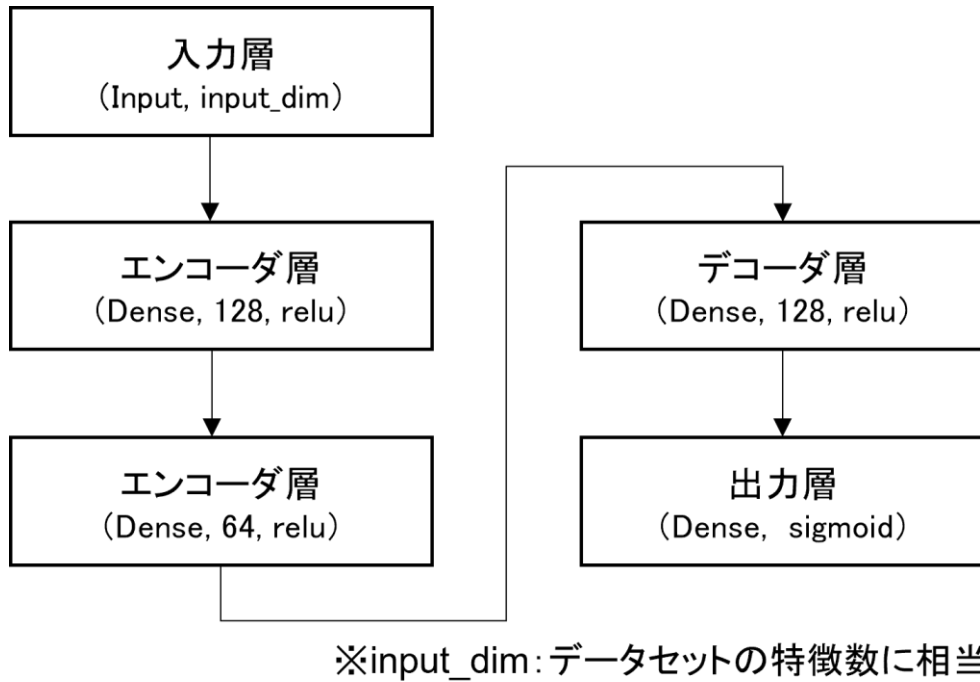


図 4.4 オートエンコーダモデル

分類器モデル定義（図 4.5）：

```
encoded_input = Input(shape=(64,))
classifier_layer = Dense(32, activation='relu')(encoded_input)
classifier_output = Dense(1, activation='sigmoid')(classifier_layer)
classifier = Model(encoded_input, classifier_output)
```

分類器の入力は、エンコーダの出力に合わせて 64 個の入力ユニットとした。全結合層で 32 個のユニットを持ち、ReLU（Rectified Linear Unit）活性化関数を適用した。出力層には 1 つのユニットをもち、活性化関数として sigmoid 関数を適用した。これは、二値分類をおこなうための出力層とするためで、sigmoid 関数により、出力は 0 から 1 の範囲に制約され、確率的な出力が得られる。



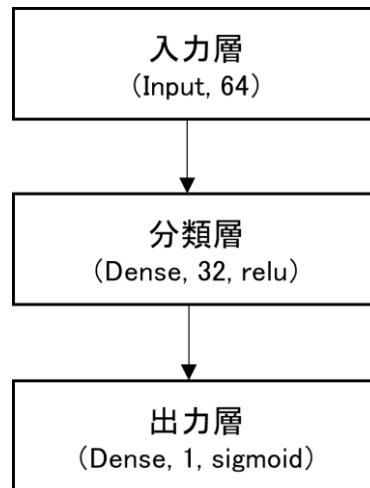


図 4.5 分類器モデル

コンパイルと学習:

```
autoencoder.compile(optimizer='adam', loss='mean_squared_error')
```

オートエンコーダモデルをコンパイルした。最適化関数として `adam` を使用し、損失関数として平均二乗誤差 (Mean Squared Error, MSE) を指定した。

```
autoencoder.fit(train_data, train_data, epochs=50,  
batch_size=64, shuffle=True, validation_split=0.2, verbose=0)
```

`train_data` は入力データであり、ターゲットデータも同じである。(入力データを再現するように学習)。`epochs` は学習数、`batch_size` はミニバッチのサイズを指定した。`shuffle=True` はデータをエポックごとにシャッフルすることを示す。`validation_split=0.2` はトレーニングデータの 20% を検証セットとして使用することを示す。`verbose=0` によりトレーニング中のログの詳細を非表示とした。

```
classifier.compile(optimizer=Adam(learning_rate=0.001),  
loss='binary_crossentropy', metrics=['accuracy'])
```

分類器モデルをコンパイルした。最適化関数として `Adam` を使用し、損失関数として `Binary Cross-Entropy` を指定した。また、トレーニング中の精度を算出するため `metrics` として `accuracy` を指定した。

```
encoded_datas = encoder.predict(train_data)
```

エンコーダモデルを使用して、訓練データ `train_data` を低次元表現に変換し、`encoded_datas` に格納した。

```
History = classifier.fit(encoded_datas, train_labels, epochs=50, batch_size=64, shuffle=True, validation_split=0.2, verbose=1)
```

エンコーダの出力 `encoded_datas` と訓練ラベル `train_labels` を使用して分類器モデルをトレーニングした。エポック数、バッチサイズ、シャッフル、検証セットの使用、ログの表示などの訓練パラメータを指定した。分類器の訓練により、エンコーダの低次元表現を使用して、与えられた入力データに対する二値分類をおこなった（図 4.5）。

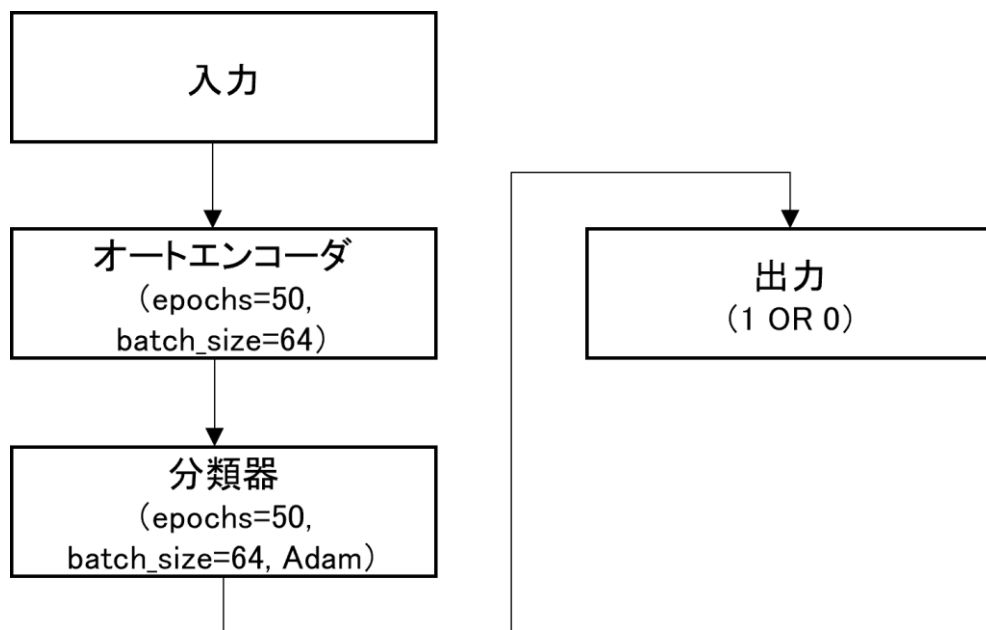


図 4.5 学習モデル

## 4.6 結果

### 4.6.1 散布図行列

各散布図（図 4.6）は、二つの項目間の関係性を示している．散布図に直線的なパターンが見られる場合、二つの変数間には正または負の相関があることを意味する．例えば `x6_diff` と `x7_diff` と `x8_diff` では、明らかに正の相関が見られる．

また、データポイントが特定の領域に集まっている（クラスタリング）が見られる場合、データにはクラスタが存在することを示す（`y6_diff`, `y7_diff`）．一方、特定のパターンから逸脱するデータポイントは、異常値や外れ値と見なすことができる．




図 4.6 各ポイント変位量の散布図行列

## 4.6.2 機械学習

図 4.7 は、分類器モデルの学習中に記録された損失値と正解率を示している。左側のグラフは「損失関数」を、右側のグラフは「正解率」をそれぞれ表している。学習損失 (Training loss) はトレーニングデータに対するモデルの予測誤差を示す。学習 (エポック) が進むにつれて、この値は減少する傾向にある。つまり、モデルがトレーニングデータに対して予測を行えるようになっていくことを意味する。検証損失 (Validation Loss) は検証データに対する予測誤差を示す。この値も学習損失同様に減少しているが、学習損失よりも高い値を示すエポックもいくつかある。これは、モデルが見たことのないデータに対しては、やや劣る予測をすることを意味する。




図 4.7 分類器モデルの学習における損失値と正解率

図 4.8 にエンコーダモデル内での入力特徴量の重要度を示す。特徴量の重要度は、その特徴量がエンコーダによって生成される圧縮表現にどれだけ寄与しているかを測定するものである。グラフには説明変数である 6 つの入力特徴量を示しており、中でも `y6_diff`, `x7_diff` の重要度が他の特徴量に比べて顕著に高い。これは、モデルがデータの圧縮表現を生成する際にこれらの特徴量により多く影響を受けていることを示す。




図 4.8 エンコーダにおける特徴重要度

表 4.2 よりモデルの全体的な精度は 99.4%であり，非常に高い性能を示している．クラス 0 に対する精度は 98.9%，再現率は 99.8%，F1 スコアは 99.4%であった．クラス 1 に対する精度は 99.8%，再現率は 99.0%，F1 スコアは 99.4%であった．

表 4.2 分類結果

	precision	recall	f1-score	accuracy
0	0.989	0.998	0.994	0.994
1	0.998	0.990	0.994	

図 4.9 よりモデルはクラス 1 の予測において，16 件の誤識別（誤ってクラス 0 として識

別された)をしているが、全体としては非常に高い真陽性率を達成している。クラス 0 の予測は、2 件を誤ってクラス 1 とした識別があるのみで、実際のクラス 0 をほとんど正しく識別できている。




図 4.9 分類結果の混同行列

## 4.7 考察

結果 4.6.1 より, `x6_diff` と `x7_diff` と `x8_diff` では, 明らかに正の相関が見られる. `x6_diff`, `x7_diff`, `x8_diff` の間に正の相関があることは, これらの変数が互いに関連して動くことを示している. これは穿刺タスクにおける指の関節の動き (ポイント) が互いにリンクしている可能性がある. `y6_diff`, `y7_diff` のクラスタリングは, 特定の状態や条件と一緒に発生することを示しており, これらの条件が今回定義したエラー ( $\pm 10\text{mm}$  以上の動き) の有無と関連している可能性がある. つまり, このクラスタリングのデータポイントから離れた位置にある点については, 異常値または外れ値として解釈できる可能性がある.

図 4.3 より, 今回の分類器モデルでは学習損失が下がり続ける一方で, 検証損失が一定のポイントで停滞するか上昇する場合があり, 過学習 (overfitting) の兆候がある. これは, モデルがトレーニングデータに対しては非常に良い性能を示すが, 新しいデータにはうまく一般化できないことを意味している. 損失, 正解率のグラフもエポックの終わりに向けて安定しているように見えるため, モデルが収束に近づいている可能性がある. 全体として良好な性能を示しているが, 学習と検証の精度や損失の間にあるギャップを最小限に抑え, より汎用型にするためには, 正則化やハイパーパラメータのチューニングをする必要がある.

図 4.4 より `y6_diff` と `x7_diff` が他の特徴量よりも重要であることは, これらの特徴がエラーの識別において特に有効であることを示唆している. これらの変数は, 穿刺ミスの予測において大きな役割を果たす可能性がある. さらにモデルの精度向上のために, 低重要度の特徴量を排除することでモデルの複雑さを減らす, またはより多くの情報をもたらす新しい特徴量を追加することが考えられる. エンコーダの特徴量重要度を解析することは, モデルの解釈性を高め, データの理解を深めるために重要である. しかし, データセット特有のコンテキストや, エンコーダが使用される特定のタスクに対して, これらの結果を適切に解釈する必要がある.

表 4.2 より, モデルが両クラスに対して均等に優れたパフォーマンスを持ち, 低い偽陽性率と偽陰性率を示していることを示している. また, サンプル数は 0 と 1 が同じぐらいであり, 検証データのバランスが取れたデータセットに対して行われた評価であることが言える. つまり, この分類モデルは非常に信頼性が高いと言える.

図 4.5 より, クラス 1 の予測において 16 件の誤識別があるものの, 真陽性率は高い. これは, エラーが発生したときにそれを検出する能力が高いことを示しているが, 少しのエラーは見逃されている可能性がある.

クラス 0 に関しては, ほぼ完璧に正しい識別をしていて, エラーがないときにそれを正確に検出できることが示された.

以上のことから、穿刺時の画像から手（指）の動きを位置座標として抽出し、オートエンコーダにより特徴を圧縮して学習させて、それを利用した分類器でエラーを検出するという、穿刺手技の評価手法の有用性が示された。

#### 4.8 研究の限界

重要な特徴量（y6\_diffと x7\_diff）が明らかにされているものの、他の特徴量の貢献度が低いことが示されている。これは、特徴量の選択やモデルの複雑さの削減において改善の余地があることを示している。

モデルの評価はバランスの取れたデータセットに基づいておこなったが、実際の臨床ではデータは必ずしも均等に分布していない可能性がある。バランスの取れていないデータセットにモデルを適用すると、性能が大幅に変わる可能性がある。

クラスタリングから離れた位置にあるデータポイントは異常値または外れ値として解釈される可能性があるが、これらの点をどのように取り扱うかについての明確な答えを示す必要がある。

モデルが良好な性能を示しているものの、臨床現場でのデータに対する検証が行われない限り、その有用性は完全には確認できない。研究結果は穿刺時のエラー検出におけるオートエンコーダと分類器の有用性を示唆しているが、上記の限界点は今後の研究方向性を指し示すものであり、これらを改善するためのさらなる研究が必要である。

#### 4.9 結論

本検討では穿刺時の手技の評価手法として機械学習モデルを用いることの有効性を評価した。特に、オートエンコーダを利用して、穿刺時の指の動きを捉えた座標データを基に、圧縮された特徴を抽出し、分類器を通じてエラーの有無を識別した。特徴量の重要度を評価することで、特に y6\_diffと x7\_diffが本検討において重要な役割を果たしていることが明らかになった。これにより、特徴量の選択とモデルの複雑さを最適化することで、精度の向上が期待できる。穿刺時における機械学習を使った穿刺手技の評価は教育への応用が期待できるが、実践への適用にはさらなる改善と検証が必要である。



## 第5章 認知負荷の軽減と機械学習を用いた支援システムの 実現性

### 5.1 背景・目的

視線追跡装置は、使用者の眼球運動を追跡しそのデータを分析するために使用される。穿刺のような精密な医療手技では穿刺者の視線が手技の成功に大きく影響する可能性がある。エコーガイド下穿刺では、主な視線は手元とエコー画面で通常の穿刺より視覚情報獲得が増えている（領域増加）。画面からの情報をフィードバックさせる形でプローブ操作をするというタスクが追加され触覚情報はプローブと針先を通したものとなり間接的なものとなった。注意を向けるべき領域の増加や、両手で別の目的の操作をそれぞれおこなう（1人法の場合）ことになり、穿刺者への認知負担は変容するが、結果的には増加することになる。

van Merriënboer JJ ら[44]によると、「手技の複雑さが増すと認知負荷も増加する」また、「初学者向けの教育指針と経験豊富な学習者向けの教育指針は異なる」と言われている。また、Venkat MV ら[45]によると「CLT は、作業記憶（ワーキングメモリ）が学習におけるボトルネックであり、ワーキングメモリは限られた容量であるため、一度に多くの情報を処理しようとする、オーバーロード（過負荷）になる。教育方法は、このワーキングメモリの容量を考慮して設計されるべきである」と言われている。

医療手技は穿刺に限らず、複雑なものが多い。つまり本来であれば、人間に侵襲を加える行為で複雑なことであれば、画一的な手技や教育を十分におこなうことが必要であるが、医療手技の対象者が人間であり、その状況、状態を画一的にして教育することが難しい。そのような複雑な状況でも教育効果を最大限とするためには、学習者の行動形成要因や認知的負荷理論といったものに着目し、効果的に伝わる方法、学習の効率化を目指すことが、医療従事者の負担軽減、医療の質の向上につながると考える。それらに関連する先行研究は少なく、特に穿刺と認知負荷に着目した先行研究は見つけられなかった。

本検討では、穿刺タスク時の視線追跡装置から得られるデータを分析し、穿刺者の認知負荷と注視時間の関係に着目し、認知負荷の軽減と機械学習を用いた支援システムの実現性に関する検討をおこなうことを目的とした。

## 5.2 視線追跡装置

視線追跡装置とは視線追跡 (Eye Tracking) 技術を用いた装置である。この技術は、人の目の動きや注視点を追跡し記録することで、その人が何を見ているか、どれぐらいの時間、注視しているかを分析するために用いられる。

原理は、近赤外 LED によって角膜上に光の反射点を生じさせ、その画像をアイトラッキングカメラで撮影しアイイメージを取得する。撮影した画像から、角膜上の光の反射点と瞳孔を識別し、目と光の反射パターンを画像処理アルゴリズムが検出する。アイマークレコーダーデルを使用し、空間中の目の位置と視点を高精度で推定する[46]。

人間の視野は人の視野は外方  $100^\circ$ 、下方  $70^\circ$ 、内方・上方  $60^\circ$  の範囲であり[47]、このうちの視軸から半径視角  $2.5^\circ$ 、 $4.2^\circ$ 、 $9.2^\circ$  に対応する 3 つの範囲のことを中心視野といい、この範囲で注視を行っていることを中心視と言う。また、 $14^\circ$ 、 $24.2^\circ$ 、 $45\sim 53^\circ$ 、 $53^\circ\sim$  鋸状縁に対応する 4 つの範囲を周辺視野という。この周辺視野で注視をおこなうことを周辺視と言う[48]。

単眼視野の中で、全視野に対する中心視野の割合は、2.5%程度であり、97.5%は周辺視野であると言われている[48]。このことより、人間は視覚から情報を獲得しようとするとき中心視と周辺視という 2 種類の方法で情報を獲得している。

## 5.3 認知負荷とアイトラッキング技術

認知負荷とは、「ワーキングメモリで使用されている精神的努力の総量のこと、学習やタスクのパフォーマンスを発揮するためには、この負荷を理解することが極めて重要である」[49]と言われており、アイトラッキング技術は、認知負荷をリアルタイムで測定する非侵襲的な方法であり、「人間の認知負荷の研究分野で有益である」と言われている[49]。

認知負荷の推定には、固視時間、固視回数、瞳孔径などの視線追跡パラメータを用いることができる。Sevcenko N らの研究[50]では、フローチャートの解釈は、ナッシュ・シュナイダーマン図の解釈に比べ、より長い固視時間、より多くの固視回数、より大きな瞳孔径をもたらし、より高い認知負荷を示すことがわかった。Katona J の研究[51]では、視線追跡技術を使用して、時間的に重要なリソースを管理する人間とコンピューターの相互作用中の認知負荷を推定している。

瞳孔の大きさは、認知負荷のもう 1 つ指標であり、「認知負荷の変化は、瞳孔の小さな拡張を引き起こし、管理された環境では、高精度の瞳孔測定は、1 秒よりも短い時間スケールで認知負荷の小さな違いを検出するために使用することができる[52]」と言われている。

## 5.4 CatBoost (Categorical Boosting)

CatBoost はカテゴリカル変数を効果的に処理し，高い予測性能を持つ勾配ブースティングライブラリであり，2017 年に Yandex 社から発表された機械学習アルゴリズムである[53]. 特にカテゴリカル変数を数値に変換する必要がなく，カテゴリカルデータを直接扱うことができるのが大きな利点であり，データの前処理が簡略化でき，モデルのトレーニングが容易になる．分類，回帰の問題に適している．

## 5.5 方法

本研究は，神奈川工科大学ヒト倫理審査委員会によって承認されている（承認番号：20191223-02）．

### 5.5.1 被験者

被験者（臨床工学技士 6 名）を表 4.1 に示す．本研究の被験者は第 4 章の被験者と同一である．

表 5.1 被験者のプロフィール

被験者	A1	A2	A3	A4	A5	A6
年齢（年）	52	33	26	36	43	42
透析業務歴（年）	29	5	1	5	17	6
エコーガイド下穿刺歴（年）	15	4	0.5	4	10	4

### 5.5.2 データ採取

眼球運動測定に，メガネ型の視線追跡装置（Tobii Pro Glasses 3，Tobii 社製）を用いた．測定中は頭部を動かすと眼球運動データに影響が出てしまう可能性があるため被験者には，頭部を大きく動かさないよう説明した．

視線追跡装置を装着した状態で，被験者は穿刺針として有効長 38mm，外径 17G もしくは 16G の太さの針を利用して穿刺を行なった．その際の眼球運動を記録した．データ採取は 52 回，のべ 104 回の穿刺であった．

### 5.5.3 視線データの抽出

記録されたデータを専用の解析ソフト（Tobii Lab Pro, Tobii 社製）を利用して、1 症例ごとに、被験者が患者のバスキュラーアクセスの皮膚に針を接触させたところを開始（S）、針を留置して内筒針を引いたところを終了（E）としてデータにフラグを付けた。また、穿刺部位を見ている間を「S0,S1,S2」、エコー画面を見ている間を「M1,M2,M3」としてフラグをつけた。

ソフトに付属する、DataExport 機能を使って、1 症例ごとの解析データを Excel 形式として出力した。データが適切に記録されていなかった 2 回分のデータは除外して 102 件となった。

Python 言語と pandas フレームワークを利用して、Excel ファイルから必要項目のみ抽出した。項目は下記 11 項目とした。

- Recording timestamp
- Sensor
- Participant name
- Recording name
- Recording date
- Event
- Gaze point X
- Gaze point Y
- Gaze event duration
- Eye movement type
- Eye movement type index

to\_csv()関数を利用して、データフレームを CSV ファイルとして保存した。

### 5.5.4 タスクイベントと注視時間

Python 言語で os.listdir を使って、ディレクトリ内にある 4.2.3 で作成した 102 件の CSV ファイル名を被験者ごとにリストとして読み込んだ。

被験者ごとにファイルリストをループ処理して、ファイルからデータを読み込み、pd.concat を使って一つのデータフレームに結合した。

Eye movement type 列のセルに「EyesNotFound」を含む場合は、データが適切に記録され

ていなものとして、行をデータフレームから除外した。Event 列に格納された、タスクを表すタグ (S,M など) をわかりやすい名前 (Puncture site1st , Monitor 1st など) に置換し、Gaze event duration の時間単位をミリ秒から秒に変換した。各項目のデータ内容を下記に示す。

Event : 5.5.3 でつけたフラグ名 (本研究ではタスクイベントとして定義)

Gaze point X : 画面上の視線 X 座標位置

Gaze point Y : 画面上の視線 Y 座標位置

Gaze event duration : 注視時間 (Gaze duration)

Eye movement type : 注視タイプ

(視線が静止を「Fixation」、瞬時的な視線移動を「Saccade」と定義)

Eye movement type index : 視線の移動順

変換されたデータを CSV ファイルとして保存した。Event 列のタスクごとに平均視線持続時間を算出した。算出された結果を、イベントを横軸、平均時間を縦軸とした棒グラフで作成した。また、タスクイベントと Fixation, Saccade の関係を散布図で作成した。結果を画像ファイルとして保存した。

### 5.5.5 機械学習による分類

前処理 :

5.4.3 で作成した CSV ファイルを Pandas の DataFrame として読み込み、特定の列 (Gaze point X, Gaze point Y, Gaze event duration, Event, Eye movement type) を抽出した。Gaze point X と Gaze point Y カラムから差分を計算し、それぞれ X\_diff と Y\_diff カラムに格納した。欠損値 (NaN) を削除した。

各イベントに対する注視時間の平均を基準値とし、Gaze event duration カラムの時間を比較し、基準より高ければ「2」、基準より低ければ「1」、基準と同じであれば「0」として新しいカラム「Comparison」に結果を格納した。また、被験者 A1, A5 を熟達者「3」、被験者 A2, A4, A6 を中堅者「2」、被験者 A3 を初心者「1」として、新しいカラム「level」を作成し、データを格納した。

すべての結合されたデータ（データセット）を CSV ファイルとして保存した（図 5.1）. データセットの Event と Eye movement type カラムのカテゴリカル変数を数値に変換するために, LabelEncoder 関数を利用した. 変換後の数値は Event\_encoded および Eye\_movement\_type\_encoded カラムに格納した.

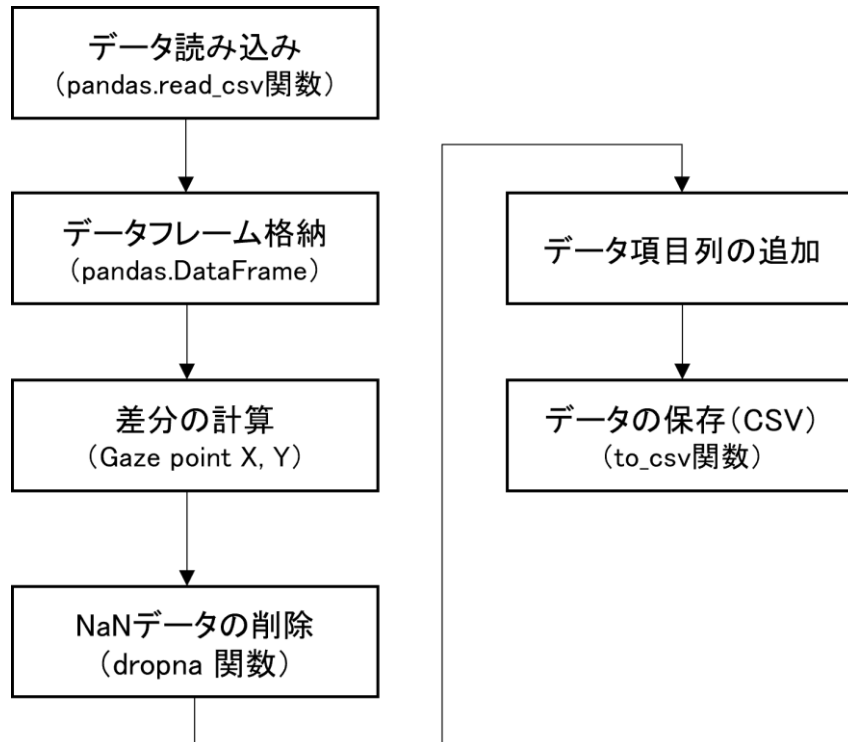


図 5.1 前処理のフローチャート

特微量とターゲット変数の設定:

モデルのトレーニングに使用する説明変数(特微量(X))と目的変数(Y)を設定した. 特微量は Event\_encoded, Eye\_movement\_type\_encoded, Gaze event duration, X\_diff, Y\_diff, Comparison の 6 項目, 目的変数は熟達者, 中堅者, 初心者を数値データとして格納した level カラムとした.

データセットをトレーニングセットとテストセットに train\_test\_split 関数を使用し分割した. トレーニングセット 80%, テストセット 20%とした.

モデルのトレーニング:

機械学習のモデルには CatBoost (Categorical Boosting) を使用した. CatBoost モデルを CatBoostClassifier として, iterations パラメータを 80 に, loss\_function パラメータは MultiClass に設定し, 多クラス分類ができる仕様とした. トレーニングデータ (train\_data) を使用してモデルをトレーニングした.

学習曲線の可視として cv 関数を使用してクロスバリデーションを実行し, 学習曲線を可視化した. 学習曲線はトレーニングセットとテストセットの精度 (train-MultiClass-mean と test-MultiClass-mean) をプロットし, モデルの学習状況評価に使用した. また, 予測結果の評価として以下の項目とモデルの特微量の重要性を算出するために「Feature Importance」を利用した.

「Feature Importance」は, CatBoost モデルの特微量の重要性を評価するための一つの方法である. 特定の特微量は, その特微量を含む列 (カテゴリーカル特微量の場合, 各カテゴリに対して) が, モデルの予測に与える影響を評価する. これにより, どの特微量がモデルの予測に対して重要であるかを理解し, モデルのトレーニングや特徴選択に役立つ.

#### 5.5.6 SHAP による予測貢献度

SHAP 値は shapley additive explanations の略である. 機械学習のモデルにそれぞれの特微量がその予想にどれだけ影響を与えているのか算出するものである. これにより, ある特徴変数の値の増減が与える影響を可視化することができる.

SHAP 値は解釈手法である additive feature attribution methods に協力ゲーム理論の shapley value を導入したもの[54]である. additive feature attribution methods は特微量の線形関数を用いて機械学習モデルにおいて, 各データに対して特微量と予測結果の線形モデルを作ることにより, 特微量が予測に与える影響を評価する手法である. shapley value は各プレイヤーの貢献度に応じて利益を分配する指標であり, 機械学習モデルの各特微量をプレイヤーに見立て計算をおこなうことで貢献度合いを評価するものである.

SHAP 値には説明対象のモデル予測結果と特徴量の貢献度の合計値は一致することを示す local accuracy, 存在しない特徴量は影響しない missingness, 任意の特徴量がモデルに与える影響が大きくなるようにモデルを変更した際にその特徴量の貢献度が減少しないことを示す consistency[54]の3つの性質を持っている。

SHAP を使用するため, `shap.initjs()`関数により初期化をおこなった。 `shap.TreeExplainer`により, 貢献度を算出する関数を準備した。モデルは決定木ベースのモデル (CatBoostClassifier) であるため, `shap.TreeExplainer` を使用している。また, `feature_perturbation` パラメータは `tree_path_dependent` に設定し, 特徴量の重要度 (貢献度) を計算する。 `model_output` パラメータは `raw` に設定し, モデルの raw データ出力を解釈するようにした。

`shap.summary_plot` 関数により SHAP Summary Plot を描画する。これにより, 予測における各特徴量の SHAP 値 (貢献度) の分布が可視化され, それらの特徴量が予測にどのように寄与しているか評価する。

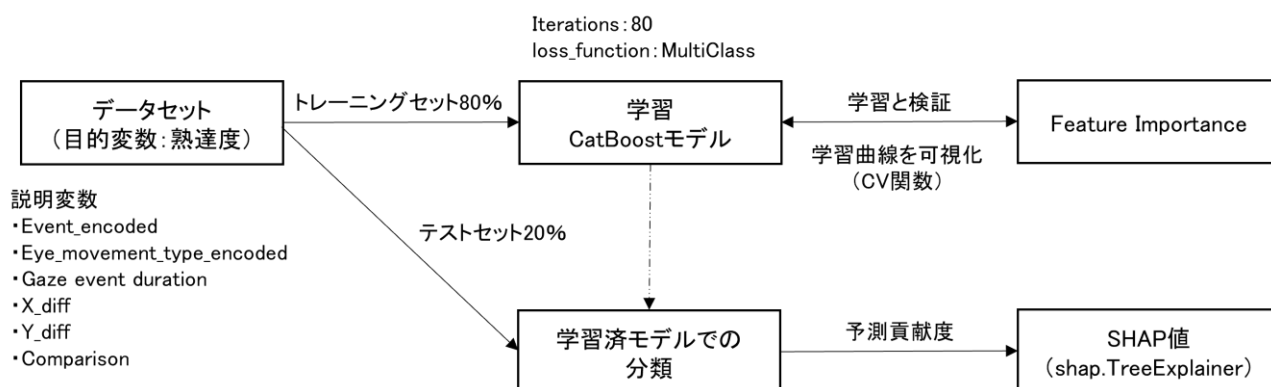


図 5.2 CatBoost による学習フローチャート



## 5.6 結果

### 5.6.1 タスクイベントと注視時間

被験者ごとの動脈側(A)と静脈側(V)の穿刺におけるタスクイベントの注視時間(Fixation)を示す(図 5.3～図 5.8, 表 5.1). 穿刺回数が被験者ごとに異なるので, 注視時間は平均値で評価した.

Monitor 1st : エコー画面を最初に見てから視線を外すまでの時間

Monitor 2nd : 2 回目にエコー画面を見てから視線を外すまでの時間

Puncture site 1st : 穿刺部位を最初に見て視線を外すまでの時間

Puncture site 2nd : 2 回目に穿刺部位を見て視線を外すまでの時間

A 側穿刺「Monitor 1st」では, 被験者 A3 が最も注視時間が長く(図 5.5), A5 が最も短かった(図 5.7).

A 側穿刺の「Monitor 2nd」イベントでは, 被験者 A3 が最長で, A1 が最短であった(図 5.3). V 側穿刺は「Monitor 1st」イベントで比較的均等な分布を見せており, 被験者間での差は少なかった. 「Monitor 2nd」では A1 の注視時間が顕著に長かった.

Puncture site 1st, Puncture site 2nd での A 側穿刺「Puncture site 1st」では, 被験者 A6 が最も長い注視時間(図 5.8)であり, A5 が最も短かった. 特に, A6 は他のタスクイベントに比べて長い時間を要していた. 「Puncture site 2nd」では全体的に注視時間が短くなっていた. 特に, A1, A4, A5 は大きく時間が短縮されていた.

V 側穿刺では「Puncture site 1st」で比較的均等な注視時間が見られるが, 「Puncture site 2nd」では A2 の持続時間が突出して長くなっていた(図 5.4).

A 側と V 側の穿刺で比較すると, タスクイベントごとに平均注視時間にはいくつかの差を認めた. 各被験者の注視時間には明確な違いを認めた.




図 5.3 被験者 A1 のタスクイベントと注視時間




図 5.4 被験者 A2 のタスクイベントと注視時間




図 5.5 被験者 A3 のタスクイベントと注視時間




図 5.6 被験者 A4 のタスクイベントと注視時間




図 5.7 被験者 A5 のタスクイベントと注視時間




図 5.8 被験者 A6 のタスクイベントと注視時間

表 5.1 タスクイベントと注視時間

Event	Mean Gaze duration (S)						
A	A1	A2	A3	A4	A5	A6	ave
Monitor 1st	5.38	3.37	3.96	5.85	2.02	1.53	3.70
Monitor 2nd	2.00	3.47	4.78	5.53	3.54	2.09	2.77
Puncture site 1st	5.43	4.50	3.80	3.92	5.17	2.33	5.30
Puncture site 2nd	1.00	2.02	2.14	1.55	0.89	0.99	0.94
V	A1	A2	A3	A4	A5	A6	ave
Monitor 1st	3.70	3.78	3.29	3.69	2.12	2.23	2.91
Monitor 2nd	6.21	2.82	3.80	5.11	1.59	2.82	3.90
Puncture site 1st	4.33	3.90	4.20	3.85	4.13	3.47	4.23
Puncture site 2nd	2.45	1.47	4.59	1.37	1.87	0.66	2.16

### 5.6.2 座標位置とタスクイベント・注視タイプ

被験者ごとの視線 X・Y 座標と注視タイプ (Fixation, Saccade) とタスクイベント (Monitor 1st, Monitor 2nd, Puncture site 1st, Puncture site 2nd) によって分類した散布図を示す (図 5.9～図 5.14)。また, Fixation と Saccade のカウント数と時間を示した表 (表 5.2) と散布図 (図 5.15, 図 5.16) を示す。

注視点の広がりが多い場合, 被験者の注意が視野の広い範囲に分散していることが分かる。広がりが多い場合は, 特定の領域に注意が集中していることを示す。被験者 A2 (図 5.10), 被験者 A5 (図 5.13) は比較的広く分布している。

また, 注視点の密度が高ければ, 何らかの理由で被験者の視線が集中していることを示す。被験者 A2, 被験者 A3 (図 5.11) ではその傾向がみられる。

Fixation 回数と平均時間 (表 5.2) では「Fixation」の回数は, 被験者とタスクイベントによって大きく変動している。Saccade 回数と平均時間は「Fixation」よりも回数が少なく, 時間も短い。各被験者の「Fixation」と「Saccade」を比較すると, モニターと穿刺で差を認めた。図 5.15 より被験者 A2 のタスクイベントすべてにおいて高い Fixation 回数を示している。また, 被験者 A1, A4 は「Monitor 1st」のタスクイベントで Fixation 回数が高い。一方で, 被験者 A1, A5, A6 の「2nd」タスクイベントでは Fixation 回数が低い。Saccade 回数は, A 側穿刺, V 側穿刺ともに被験者 A5 の「Monitor 1st」タスクイベントで高い回数を示している点が目立っている。他のほとんどのポイントは, 回数が 100 から 200 の間に分布しているのに対し, このポイントは 230 近くにある。

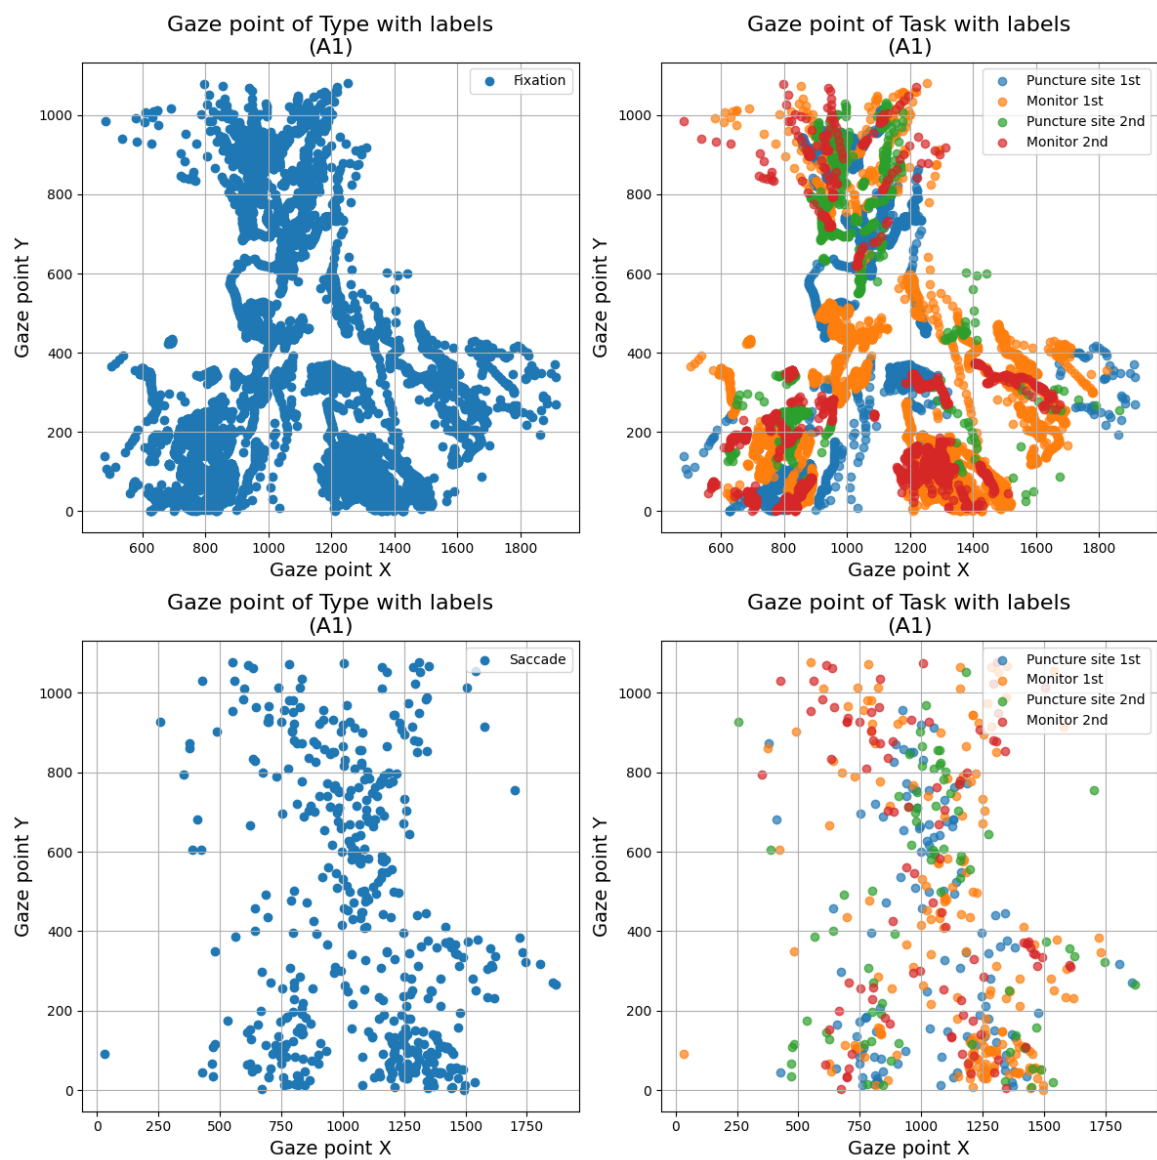


図 5.9 被験者 A1 の位置座標とタスクイベント

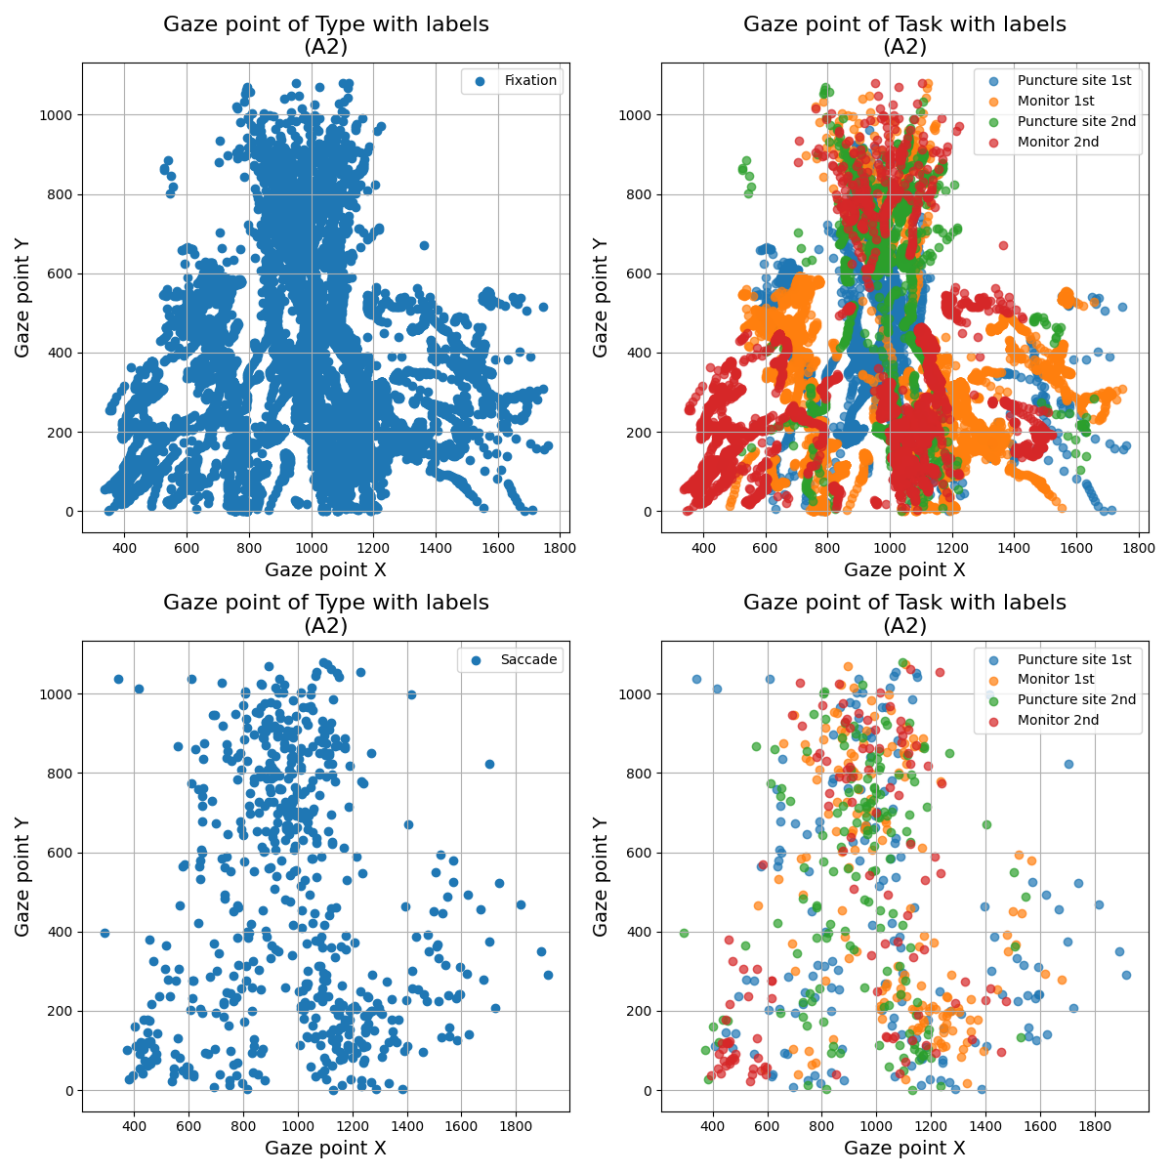


図 5.10 被験者 A2 の位置座標とタスクイベント

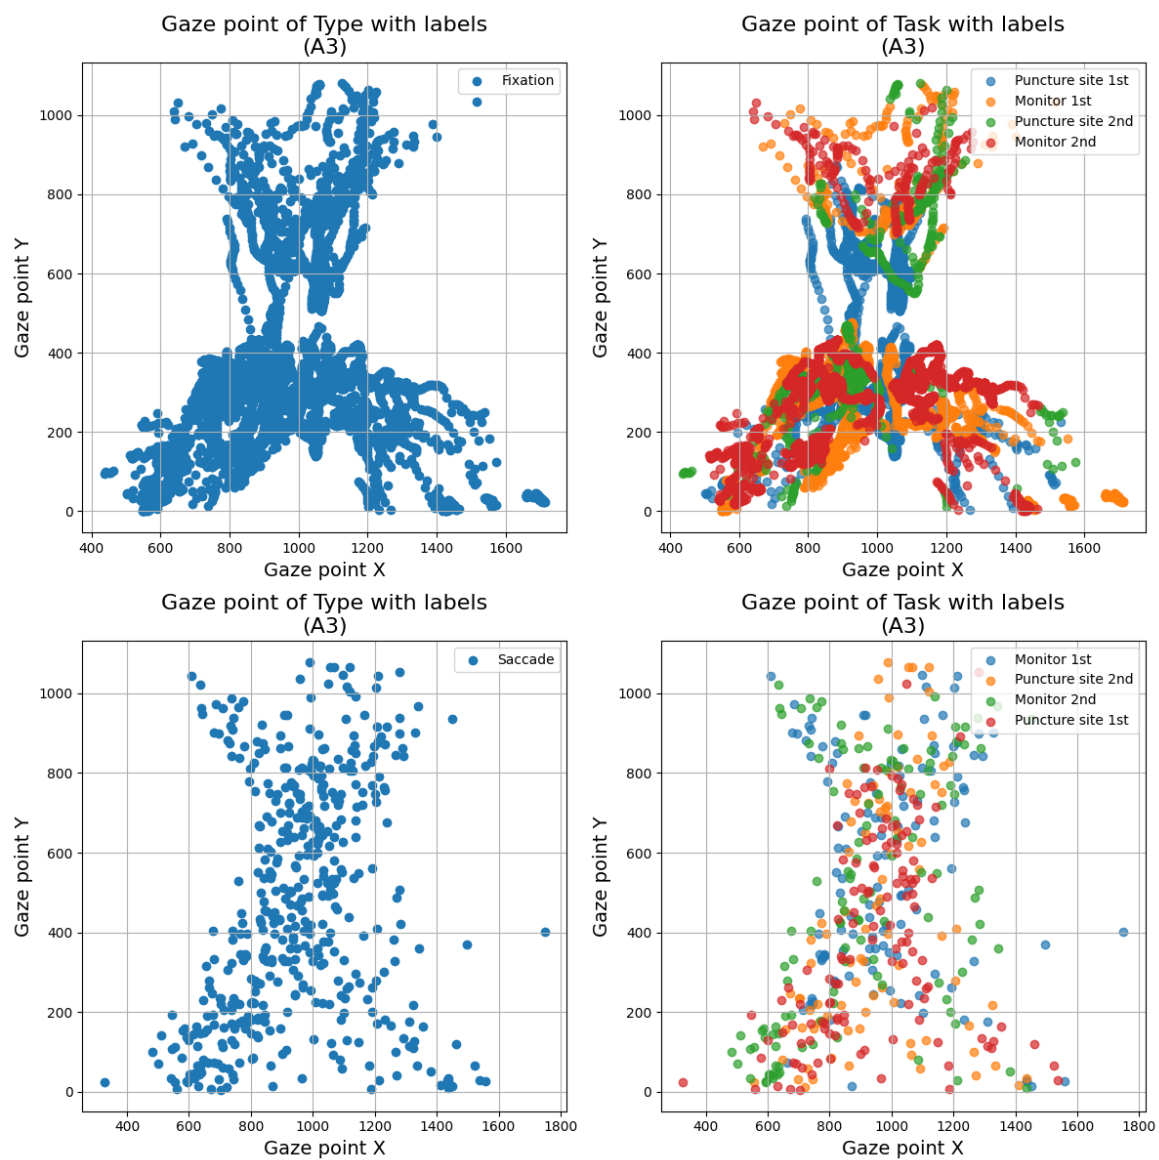


図 5.11 被験者 A3 の位置座標とタスクイベント





図 5.12 被験者 A4 の位置座標とタスクイベント

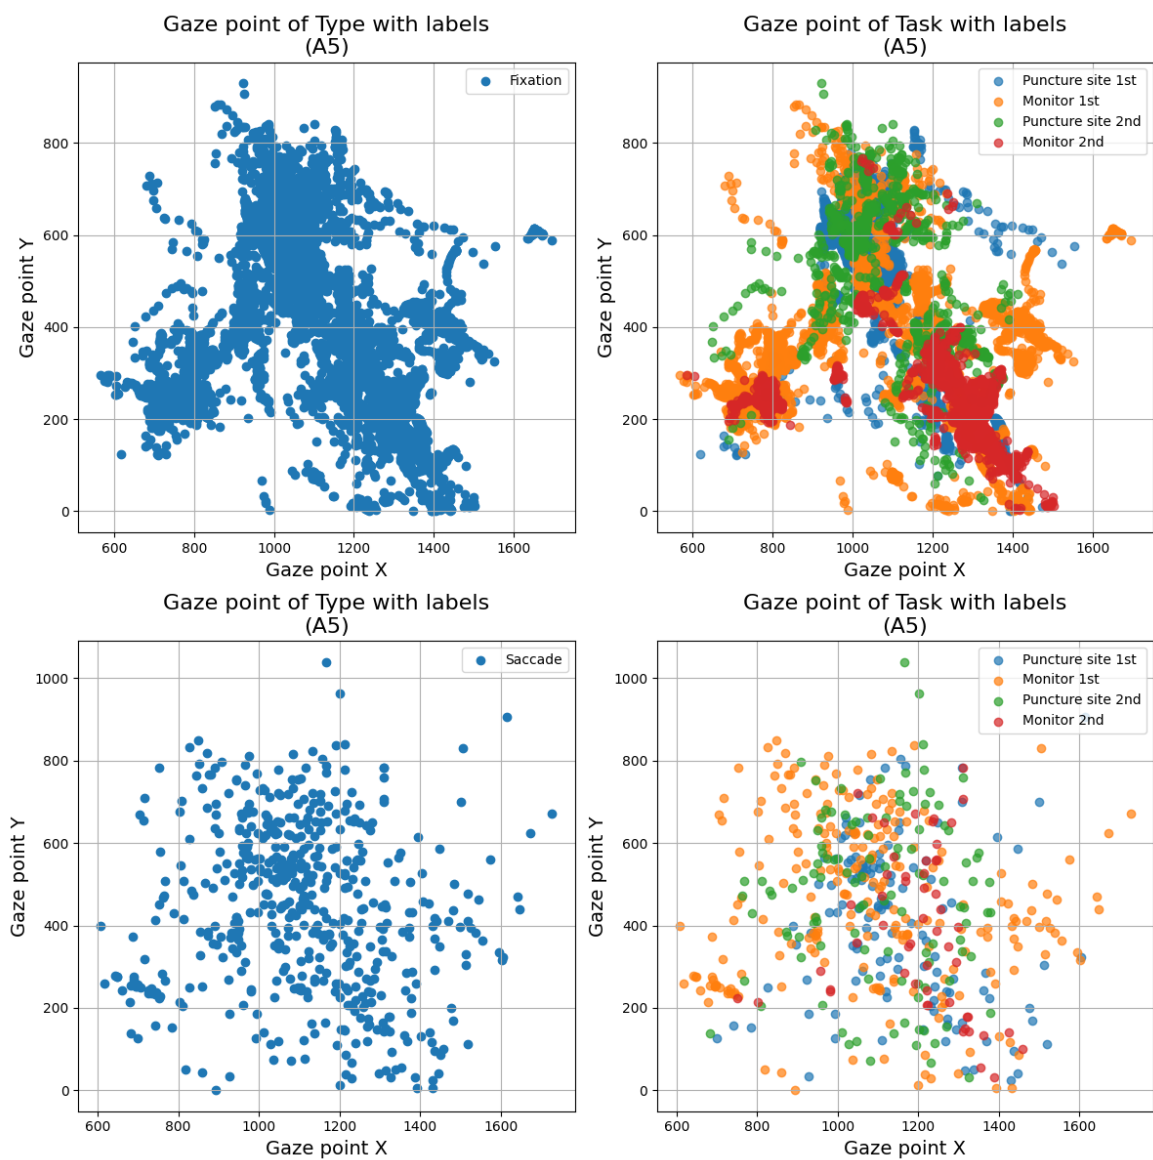


図 5.13 被験者 A5 の位置座標とタスクイベント

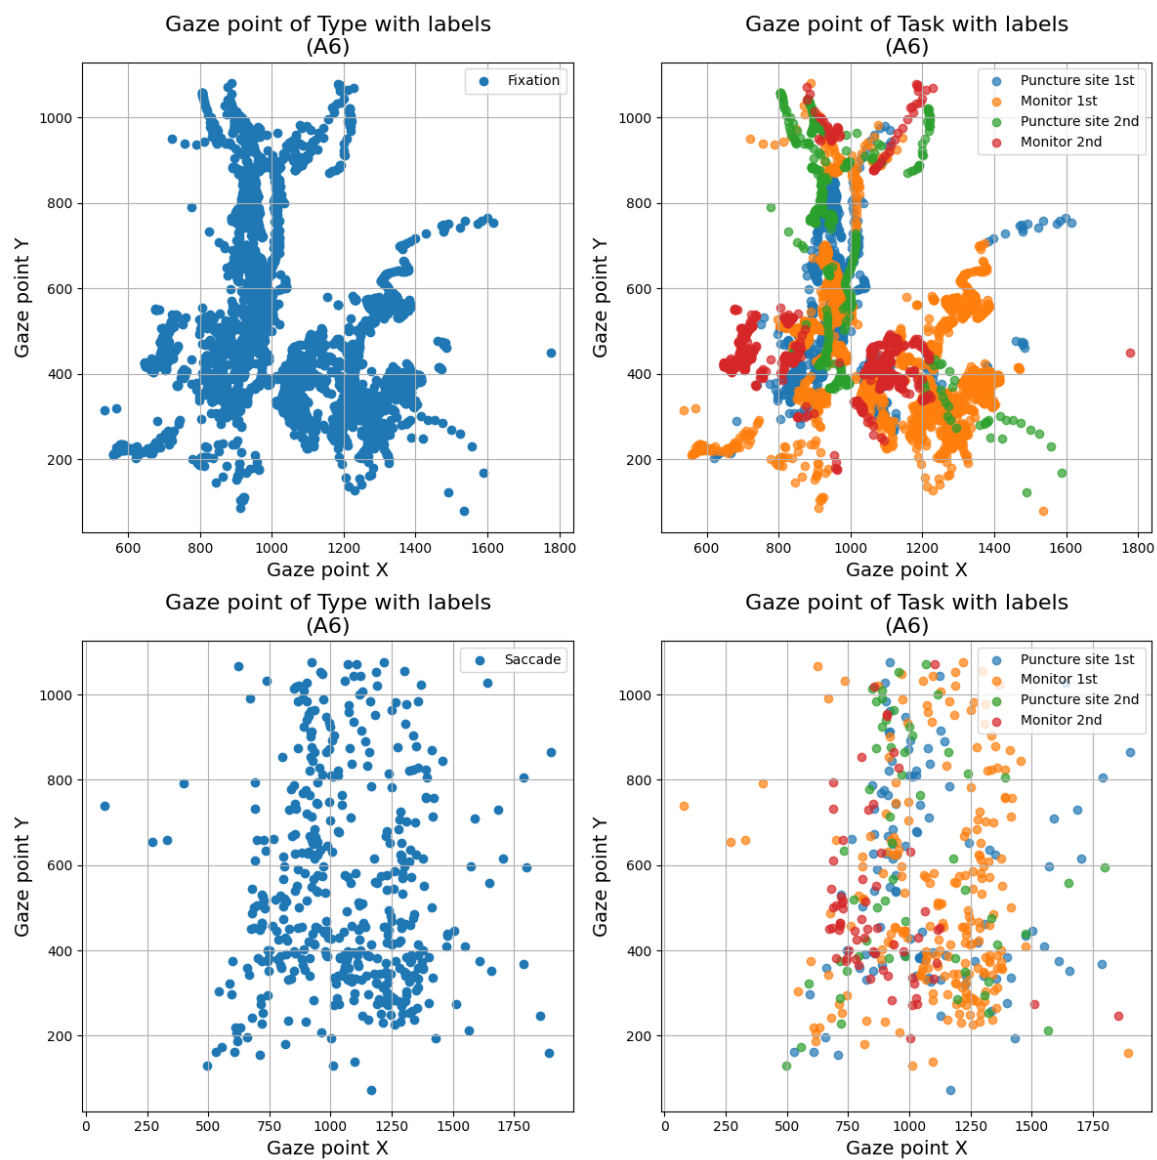


図 5.14 被験者 A6 の位置座標とタスクイベント

表 5.2 Fixation と Saccade のカウント数と時間

Event	A				V			
	Fixation		Saccade		Fixation		Saccade	
	Count	Mean Gaze Duration[S]	Count	Mean Gaze Duration[S]	Count	Mean Gaze Duration[S]	Count	Mean Gaze Duration[S]
Monitor 1st	5604	5.56	190	0.05	2769	3.86	117	0.07
Monitor 2nd	1745	2.11	93	0.05	3618	6.46	148	0.05
Puncture site 1st	5679	5.54	115	0.04	5094	4.47	160	0.04
Puncture site 2nd	1042	1.07	77	0.04	1476	2.59	84	0.05
Monitor 1st	4817	3.48	161	0.04	5500	3.89	161	0.04
Monitor 2nd	4101	3.57	116	0.04	4457	2.89	113	0.03
Puncture site 1st	5552	4.63	162	0.05	4994	4.04	176	0.03
Puncture site 2nd	1916	2.17	151	0.05	1495	1.59	123	0.05
Monitor 1st	3926	4.08	126	0.06	3130	3.40	105	0.05
Monitor 2nd	3473	4.95	124	0.06	2109	3.94	83	0.06
Puncture site 1st	3043	3.96	129	0.05	3381	4.32	98	0.05
Puncture site 2nd	724	2.40	90	0.05	3967	4.79	173	0.05
Monitor 1st	5407	5.99	138	0.07	4424	3.82	160	0.08
Monitor 2nd	3060	5.82	162	0.07	2558	5.38	136	0.08
Puncture site 1st	5241	4.10	232	0.07	5013	4.00	190	0.05
Puncture site 2nd	456	1.76	62	0.05	934	1.52	106	0.06
Monitor 1st	3234	2.17	238	0.06	4002	2.23	227	0.06
Monitor 2nd	1844	3.64	54	0.05	659	1.69	43	0.07
Puncture site 1st	4553	5.31	127	0.05	4904	4.34	248	0.05
Puncture site 2nd	922	1.00	113	0.05	1842	1.95	80	0.04
Monitor 1st	2516	1.66	218	0.05	2629	2.37	163	0.05
Monitor 2nd	928	2.24	65	0.05	812	3.01	58	0.04
Puncture site 1st	1299	2.52	108	0.04	1076	3.70	71	0.04
Puncture site 2nd	428	1.11	54	0.05	241	0.79	53	0.05




図 5.15 Fixation と Saccade のカウント数 (A)




図 5.16 Fixation と Saccade のカウント数 (V)

### 5.6.5 機械学習による分類

訓練曲線とテスト曲線の両方が同じような値に向かって収束しており，これはモデルがうまく汎化していることを示している（図 5.17）．テストデータに対するモデルの性能は，時間の経過とともにトレーニングデータに対する性能に近づいている．学習経過に伴い，あまり変動がないことから，学習プロセスが安定していることが推測できる．訓練曲線とテスト曲線が近いので，オーバーフィッティングが起きていないことが分かる．




図 5.17 学習経過（左：A，右：V）

レベル 1 の適合率（Precision）は 0.94 で非常に高く，モデルが陽性と予測したサンプルのうち，実際に陽性である割合が高いことを示す（表 5.3）．

レベル 1 の再現率（Recall）は 0.69 で，実際に陽性であるサンプルのうち，モデルが正確に陽性と予測できた割合が比較的低いことを示す．つまり，モデルが陽性サンプルを一部見逃している可能性がある．

レベル 2 の適合率（Precision）は 0.81 で，高い適合率を示している．モデルが陽性と予測したサンプルのうち，実際に陽性である割合が高い．レベル 2 の再現率（Recall）は 0.93 で，高い再現率を示した．実際に陽性であるサンプルのうち，モデルが正確に陽性と予測できた割合が高い．

レベル 3 の適合率（Precision）は 0.85 で，高い適合率を示している．モデルが陽性と予測したサンプルのうち，実際に陽性である割合が高い．レベル 3 の再現率（Recall）は 0.76 で，実際に陽性であるサンプルのうち，モデルが正確に陽性と予測できた割合が比較的低い値であった．レベル 3 の F1 スコアは 0.80 であり，F1 スコアが 1 に近いほど，モデルの性能は良いとされ，0 に近いほど性能は低いとされている．したがって、F1 スコアが 0.80 であることは，モデルが陽性（正と判断されるべきクラス）の予測において，良好なバランスを持っていることを示す．

表 5.3 予測結果

	level	precision	recall	f1-score	accuracy
A	1	0.94	0.69	0.80	0.83
	2	0.81	0.93	0.86	
	3	0.85	0.76	0.80	
V	1	0.93	0.68	0.79	0.82
	2	0.79	0.92	0.85	
	3	0.83	0.76	0.79	

予測結果の混同行列（図 5.18）より正しくレベル 1 と予測した数（True Positive : TP）は 1600 個．レベル 1 と予測するべきでないレベルに誤って予測した数（False Positive : FP）は 703 個．レベル 1 であるべきサンプルを誤って予測した数（False Negative, : FN）は 103 個であった．

正しくレベル 2 と予測した数（TP）は 6994 個．レベル 2 と予測するべきでないクラスに誤って予測した数 (FP) は 66 個．レベル 2 であるべきサンプルを誤って予測した数 (FN) は 547 個であった．

クラス 3 に属するサンプルに関して：

正しくレベル 3 と予測した数（TP）は 3625 個．レベル 3 と予測するべきでないクラスに誤って予測した数（FP）は 1400 個．レベル 3 であるべきサンプルを誤って予測した数（FN）は 24 個であった．




図 5.18 予測・結果の混同行列（左：A，右：V）

### 5.6.6 特徴量の重要性と SHAP による予測貢献度

注視時間の重要度が最も高く、モデルに最も影響のある特徴であった(図 5.19, 図 5.20). タスクイベント、注視時間が平均より高いか低いかを表した「Comparison」の特徴は、注視時間に比べて重要度スコアが低い、モデルの予測に寄与している。座標位置の変位量である X\_diff と Y\_diff の特徴量は、ある程度の重要度を持つが注視時間よりもかなり影響力が低かった。注視タイプ (Fixation, Saccade) は特徴の中で最も重要度が低かった。




図 5.19 モデルの学習における重要特徴量 (A)






図 5.20 モデルの学習における重要特徴量 (V)

図 5.21, 図 5.22 は縦軸に特徴 (説明変数), 横軸は SHAP 値の平均 (予測出力に対する影響の大きさ) を表しており, バーの長さが影響の大きさを示す. 色分けされたバーは, level (Class 0, Class 1, Class 2 は被験者 A1, A5 を熟達者「3」, 被験者 A2, A4, A6 を中堅者「2」, 被験者 A3 を初心者「1」) に対する特徴の影響を表しており, 縦軸の上部に位置する特徴ほど予測に対する平均的な影響が大きいことを意味している. 注視時間が最も影響力の強い特徴であった.




図 5.21 予測結果に対する SHAP 値 (A)




図 5.22 予測結果に対する SHAP 値 (V)

SHAP 値を violin プロットで示す（図 5.23, 図 5.24, 図 5.25）。SHAP 値は正または負の値を取り，モデル予測に対して正の影響を与える特徴はバーの右側に，負の影響を与える特徴はバーの左側に表示される。




図 5.23 各レベルにおける SHAP 値の violin プロット（レベル 1）




図 5.24 各レベルにおける SHAP 値の violin プロット (レベル 2)




図 5.25 各レベルにおける SHAP 値の violin プロット (レベル 3)

## 5.7 考察

### 5.7.1 タスクイベントと注視時間

A 側穿刺の「Monitor 1st」イベントでは、被験者 A3 が最も長い注視時間を持ち、被験者 A5 が最も短い。これは、被験者 A3 がこのタスクイベントに最も時間を要したことを示唆している。「Monitor 2nd」でも被験者 A3 が最長である。V 側穿刺は「Monitor 1st」イベントで比較的均等な分布であり、差は少ない。「Monitor 2nd」では被験者 A1 の注視時間が顕著に長く、注意力、習熟度の違いが考えられる。

A 側穿刺の「Puncture site 1st」イベントでは、被験者 A6 が最も長い注視時間であり、被験者 A5 が最も短い。特に被験者 A6 は他のタスクイベントに比べて長い時間を要しており、A6 が特に注意を払っていた可能性がある。「Puncture site 2nd」では全体的に注視時間が短くなっており、これは繰り返しによる慣れを示している可能性がある。特に、被験者 A1, A4, A5 は大きく時間が短縮されている。V 側穿刺では、「Puncture site 1st」で比較的均等な持続時間が見られるが、「Puncture site 2nd」では被験者 A2 の注視時間が突出して長くなっている。これは、被験者 A2 が注意を向けていた可能性がある。各被験者の注視時間には明確な違いがあり、これは個々の認知負荷の違い、タスクに対する熟知度、注意の配分に関連している可能性がある。また、A 側と V 側の穿刺を比較すると、タスクイベントごとに注視時間にはいくつかの違いがある。これらの違いは、穿刺部位によると捉え方の違い、習熟度、あるいは認知負荷の違いを反映している可能性がある。

これらのデータは穿刺のタスクイベントにおける学習者の認知負荷を評価し、その情報を使用して教育やトレーニングの方法を最適化するために有用だと考える。

注視タイプ（Fixation, Saccade）とタスク（Monitor 1st, Monitor 2nd, Puncture site 1st, Puncture site 2nd）の分布から注視点の広がりが多い場合、被験者の注意が視野の広い範囲に分散していることを表し、広がりが狭い場合は、特定の領域に注意が集中していることを表す。注視点の密度が高ければ、興味や難易度が高く、被験者が情報の処理に多くの時間を費やした領域を示している可能性がある。

Saccade によって示されるように、注視点の移動が頻繁な場合、被験者が異なる視覚情報に注意を向けている可能性がある。注視対タイプにおける被験者間の違いは、認知における個人の能力を反映している可能性がある。

1st と 2nd に着目した注視タイプの変化は、穿刺タスク全体における注意配分が下がっている可能性を示唆している。例えば、2nd での注視（Fixation）が少ないということは、被験者が意識を集中させているよりは、確認している可能性がある。

視覚的注意がタスクの効率や効果にどのような影響を与えるかを理解することにより、眼球運動データをタスクのパフォーマンス指標と相関させることができる。

異なる被験者間でこれらのパターンを比較することで、視覚的注意と認知的負荷がタスクの複雑さ、個人差、潜在的にはトレーニングや指導設計の効果によってどのように変化するかについての洞察を得ることができる可能性がある。また、CLTに基づく教育プランの有効性を推定するために使用することができる可能性がある。認知的負荷を確認することを目的とすれば、被験者間で一貫して長い注視時間を示すタスクについては、指導方法を考える余地があるかもしれない。教育やトレーニングでは、視線データは教育方法や教材の難易度を確認するためのフィードバックとして活用でき、認知負荷を軽減するための重要な指標になり得る可能性がある。

### 5.7.2 機械学習による分類と貢献度

訓練曲線とテスト曲線の収束は、実用的な機械学習モデルにとって重要であると言われており[55]、本検討でのモデルはオーバーフィッティングを起こすことなく、収束しており、モデルがうまく汎化していることを示唆している。

レベル 1 の適合率での高い精度 (0.94) は、陽性を正しく識別するモデルの能力を示すが、低い再現率 (0.69) は、モデルが真の陽性をいくつか見逃していることを示唆する。これは、データセットにおけるサンプル数が他のレベルに比べ少なく、モデルが偽陰性のほうが偽陽性よりもいいと判断した可能性がある。つまり、潜在的なデータセットの不均衡の表れである可能性がある。適合率と再現率はトレードオフの関係にある評価項目であり、一方を最適化すると他方が低下することがある。

混同行列は、異なるクラスにおけるモデルの能力を表している。例えば、レベル 2 とレベル 3 での真陽性 (True Positives) の多さは、これらのカテゴリの陽性を正しく分類するモデルの能力を裏付けている。しかし、レベル 3 でのかなりの数の偽陽性 (False Positives) は、モデルがこのクラスを過剰に予測している可能性を示唆しており、これはクラスの不均衡やクラス間の特徴分布の重複が原因[55]である可能性がある。

SHAP 値はモデル内の各特徴に重要度を割り当てる、ゲーム理論に基づいたロバストな手法[56]であり、注視時間が最も影響のある特徴であることがわかる。これは、生体・生存に関する予測モデル、特に時系列またはイベントデータに関連する予測モデルにおいて、イベント継続時間が予測に影響を与えていると言われている[57][58]先行研究に合致する。

各レベルにおける SHAP 値の violin プロットから視線の注視時間がモデル予測に最も大きな影響を与えることが分かり、穿刺者が注視する時間がそのタスクイベントの理解度や

認知負荷の高さを示唆している可能性がある。しかし、タスクイベントの影響が中立的であることは、イベントの種類が一概に認知負荷に関連していないことを示唆している。平均値より高い、低い、を表す **Comparison** の影響が比較的小さいことは、認知負荷に対して決定的ではないことを示している。座標位置の変化量が少ない影響を与えていることから、穿刺者の視覚的な追跡行動は認知負荷を直接的に反映しないかもしれないが、視覚的な探索行動と組み合わせることでより深い洞察を得る可能性がある。注視タイプは最も少ない影響を与えていることから、眼球運動の種類自体は認知負荷の直接的な指標ではないことが示唆される。

機械学習は、穿刺教育での個々の学習ニーズに合わせたカスタマイズされた指導を可能にする可能性がある。モデルの汎化能力は、異なる状況に適用可能な教育ツールの開発に不可欠である。適合率の高さはモデルが正確な予測をおこなう能力を示し、再現率の低さは見逃されがちな要素があることを示す。これは教育において、特定の学習内容が学習者によって見落とされがちなことを意味する可能性がある。SHAP 値の分析から、どの特徴が学習成果に最も大きな影響を与えるかを理解することができる。この情報を活用して、穿刺者に焦点を当てた指導や教育計画を立てることができる。

この方法は、指導者が穿刺者の学習過程を個別化し、認知負荷を軽減するのに役立つ可能性がある。また、データセットの均衡をとることや、重要な特徴量を適切に評価することによって、教育モデルの精度と効果を最大化できると考える。

## 5.8 研究の限界

サンプル数が不足しているため、データセットの不均衡と特徴分布の重複がモデルの予測精度に影響を与えること、特定のクラスや事象に対する予測が偏っている可能性があり、これは特に再現率が低いことから示唆される。さらに、注視タイプや注視時間などの眼球運動データの解釈には個人差が大きく、これが認知負荷やタスクパフォーマンスにどう影響するかの一貫性のあるパターンを見出すことは困難である。また、注視データの収集や解析には高度な技術が必要であり、これには専門知識と機材が必要である。これらの要因は、研究結果の一般化や教育へのフィードバックにおいての直接的な適用を制限する可能性がある。



## 5.9 結論

本検討で扱った、注視時間を含む眼球運動データは穿刺教育において、学習者の認知負荷を評価し、個別化された指導を提供するための重要な指標として機能すると考えられる。CLTに基づくと、教材の複雑さや学習活動は、学習者の認知資源の限界内で軽減されるべきであると言われている[59]。機械学習モデルを用いて個々の学習者のパフォーマンスと認知負荷を評価することで、教育者はより効果的な教育アプローチを開発できる可能性がある。データセットの不均衡と特徴分布の重複は、モデルの予測精度に影響を与えるため、これらの課題を解決することにより、教育の質を高め、学習者の理解度と能力の向上が期待できる。

## 第 6 章 総合考察

エコーガイド下穿刺は、血管の可視化を通じて穿刺の精度と安全性を高める技術である。この技術の効果的な実施には、適切なエコープローブの操作が不可欠である。散布図行列や PCA 分析を用いてエコープローブの操作パターンを顕在化することは、技術的な標準化と訓練の方法論に大きく貢献できる可能性があることが第 3 章で示された。エコープローブ操作のパターンを定量化することで、指導者は初学者に対してより具体的かつ構造的なフィードバックをすることが可能になる。また、経験に基づいた技術を客観的に理解することができることにより、状況認識に影響を及ぼす情報獲得において、熟達者は客観的なデータを基に経験を伝えることが可能となる。さらに、穿刺時のプローブの操作パターンの理解は、プローブ操作の効果的な訓練方法の開発につながり、穿刺技術の全体的な向上を促進することが期待できる。

第 2 章 3 節でも述べたが、人間工学に機械学習を組み合わせた手法の検討により、従来とは違う評価手法を得る可能性を大きく広げている。Sanchez ら[60]は、一般就労者の筋骨格系障害（WMSD）の予測に K-nearest neighbor（KNN）を用い、この方法は従来の予測方法の限界を克服し、より優れた精度と妥当性を示した。あるいは、機械学習法は、その後の研究のためのモデル構築に使用される。Mudiyanselag ら[61]は、表面筋電位（SEMG）データとリスクレベルを用いて訓練した 4 つの機械学習分類モデル（SVM, KNN, 決定木, ランダムフォレスト）を構築した。人間工学分野・医療分野における機械学習の発展は加速しており、自然言語処理[62]、画像解析[63]など、新しい手法での検討がおこなわれている。

穿刺タスクにおける、機械学習の応用は穿刺手技の評価にも変化をもたらす。第 3 章に述べたエコープローブの顕在化に加え、第 4 章では手（指）の動きや、針の動きなどの動作データを分析することで、穿刺の成功率を高めるための重要な洞察を得ることができることが分かった。特にオートエンコーダなどのアルゴリズムを用いて特徴を抽出し、分類モデルを構築することで、穿刺の手技の大きな逸脱を予測し、失敗に至る要因を事前に推定することが可能になる。この方法は、医療従事者が実際の臨床現場で穿刺技術を実践する際に役立つ。また、トレーニングプロセスにおいても、機械学習に基づくフィードバックは、穿刺技術の早期習得と精度の向上を支援することが期待できる。

意思決定過程は、Situation Awareness（状況認識）、Decision（意思決定）、Performance of Action（行動）の 3 つの段階であり、特に状況認識においては、得られた情報を選択し、解釈して、意思決定、行動へと移る。第 3 章ではエコーガイド下穿刺のプローブの動きを明らかにし、第 4 章では針を持つ手の動きを明らかにした。意思決定過程に当てはめると、

本研究では状況認識で利用する情報について、客観的な数値データとして与えることが出来る。さらにその数値データを解析することにより、個人の動きの特徴を捉えることができる。加えて、機械学習を利用したことにより、意思決定過程の一部を模擬することが可能となった。機械学習ではデータに基づき、学習（解釈）をおこない、結果を予測（意思決定）することが可能であるので、各種測定装置から得られた数値データを、機械学習でおこなう意思決定過程をシミュレーションとして利用すれば、穿刺手技の新たな評価手法として活用することが可能となり、また、医療における新たな教育手法として本研究が利用できる可能性がある。

しかし、穿刺タスクは高い認知負荷を伴う。特にエコーガイド下穿刺においては穿刺対象の情報が画像として、視覚からたくさん得られる機会が増える。第5章では機械学習モデルによって、穿刺タスク時の視線データを分析し、注視時間や注視タイプから認知負荷を推測することができる可能性が示唆された。これにより、穿刺タスクの難易度や教育方法の検討を行い、学習者の認知負荷を適切に管理することが出来る可能性ある。

認知負荷理論に基づく教育プランの開発と機械学習を組み合わせることで、効果的な学習プロセスを設計することが可能であると考えられる。

一方で、意思決定過程や認知負荷理論を今回の検討で利用したデータのみで、すべて議論することはできない。第1章2節で述べたように、意思決定過程に影響を及ぼす要素として、内在化された知識がある。あらかじめ獲得している知識の量や経験が、どれほど意思決定過程に影響を与えているか本研究では踏み込んでいない。今後の課題として、アンケート調査や被験者の背景情報などに関するデータ追加をおこない、より多角的な検討を実施する必要があると考える。

臨床データを用いた人間工学的アプローチによる本研究は穿刺タスクにおける、個々の学習者に合わせたカスタマイズされた教育を実現し、従来からの経験と勘に頼る指導・習得ではなく、客観的な数値データや評価手法により、穿刺技術の習得をより効率的かつ効果的にすることが期待できる。

## 第 7 章 結論

本研究は、血液透析における穿刺業務の質の向上と医療スタッフの教育において重要な意義を持つ。透析治療における穿刺は患者の安全と満足度に直接的な影響を与えるため、この業務における技術の向上は非常に重要である。特に、シャントの狭窄や変形が生じると穿刺の難易度が高まり、失敗が重なることでさらなる問題を引き起こす可能性がある。このような背景の中で、エコーガイド下穿刺技術の発展は、血管の可視化を通じて穿刺の精度を高める有効な手段となっている。しかし、エコープローブの操作には高度な技能が求められ、これに対する効果的な教育方法の開発が課題となっている。本研究では、エコープローブ操作に着目し、散布図行列や PCA 分析を用いて操作パターンを顕在化することで、教育と訓練の方法を改善することを目指した。また、機械学習を用いた穿刺手技の評価の導入により、穿刺タスクの成功率を向上させ、医療従事者への認知のおよび身体的負荷を軽減することが期待される。さらに、機械学習を用いた支援システムの開発によって、穿刺タスクにおける認知負荷の軽減が実現される可能性がある。穿刺時の視線データから得られる情報を分析することで、教育や学習プロセスの設計に役立てることができる。これにより、個々の学習者のニーズに合わせたカスタマイズされた教育が可能となり、穿刺技術の習得をより効率的かつ効果的におこなうことができる。

本研究は、医療スタッフの技術向上、患者ケアの質の向上、そして医療教育の改善に貢献するものと考えられる。穿刺技術の向上は患者の治療に直接的な影響を与え、医療スタッフの技能向上と教育方法の改善は長期的な医療サービスの質向上に寄与すると考えられる。

## 参考文献

- [1] Santoro A, Canova C, Freyrie A, Mancini E. Vascular access for hemodialysis. *J Nephrol.* 2006;19: 259-264.
- [2] 花房 規男, 阿部 雅紀, 常喜 信彦, 星野 純一, 和田 篤志, 菊地 勘, 後藤 俊介, 小川 哲也, 神田 英一郎, 谷口 正智, 中井 滋, 長沼 俊秀, 長谷川 毅, 三浦 健一郎, 武本 佳昭. わが国の慢性透析療法の現況 (2021 年 12 月 31 日現在). *日本透析医学会雑誌.* 2022;55: 665-723.
- [3] Gerogianni G. Factors Affecting Pain in Hemodialysis and Non-pharmacological Management. *Cureus.* 2023;15: e35448.
- [4] 整爾大平, 憲司阿部, 透蓮実, 忠正今. 慢性血液透析用内シャント血管の組織像. *日本透析療法学会雑誌.* 1990;23: 1099-1107.
- [5] Mondillo S, Giannotti G, Innelli P, Ballo PC, Galderisi M. Hand-held echocardiography: its use and usefulness. *Int J Cardiol.* 2006 Jul 28;111(1):1-5.
- [6] 花房 規男, 近藤 靖司, 金子 知代, 丹羽 拓馬, 山本 裕子, 渡邊 恭通, 榎本 裕, 野入 英世, 藤田 敏郎. エコーガイド下バスキュラーアクセス穿刺法. *日本透析医学会雑誌.* 2007;40(6): 517-521.
- [7] 猪木武徳. 学校と工場－日本の人的資源. 東京:読売新聞社, 224-234, 1996
- [8] 川淵 愛子, 青木 洋貴, 鈴木 聡, 透析装置の不具合対処における診断プロセスのタスク記述と潜在的な改善点抽出のための試験的適用. *日本経営工学会論文誌.* 2019-2020;70(1): 35-52.
- [9] Darici D, Reissner C, Missler M. Webcam-based eye-tracking to measure visual expertise of medical students during online histology training. *GMS J Med Educ.* 2023 Sep 15;40(5).
- [10] 伊藤駿, 西村健桃, 鈴木聡. 穿刺針の角度変化から見た施設間の穿刺パフォーマンスの特徴. *日本血液浄化技術学会誌.* 2019;27(2): 268-269.
- [11] 大淵康弘, 青木悠祐, 橋本賢一, 他. モーションキャプチャを用いた超音波教育システム構築に向けての予備的研究. 第 52 回日本医学教育学会大会予稿集. 2020; 107
- [12] Wade L, Needham L, McGuigan P, Bilzon J. Applications and limitations of current markerless motion capture methods for clinical gait biomechanics. *PeerJ.* 2022 Feb 25;10:e12995.
- [13] Endsley, M.R. Toward a Theory of Situation Awareness in Dynamic Systems , *Human Factors.* 1995;37(1): 32-64.
- [14] J.Rasmussen. Skills, rules, and knowledge; signals, signs, and symbols, and other distinctions in human performance models. *IEEE Transactions on Systems, Man, and Cybernetics.* 1983;13(3): 257-266.

- [15] Allon M, Zhang Y, Thamer M, Crews DC, Lee T. Trends in Vascular Access Among Patients Initiating Hemodialysis in the US. *JAMA Netw Open*. 2023;6(8)
- [16] Almasri J, Alsawas M, Mainou M, Mustafa RA, Wang Z, Woo K, Cull DL, Murad MH. Outcomes of vascular access for hemodialysis: A systematic review and meta-analysis. *J Vasc Surg*. 2016 Jul;64(1):236-43.
- [17] Yeh LM, Chiu SY, Lai PC. The Impact of Vascular Access Types on Hemodialysis Patient Long-term Survival. *Sci Rep*. 2019 Jul 24;9(1):10708.
- [18] Lui KW, Yeow KM, Wan YL, Cheung YC, Ng KK, Tseng JH. Ultrasound guided puncture of the brachial artery for haemodialysis fistula angiography. *Nephrol Dial Transplant*. 2001 Jan;16(1):98-101.
- [19] Schoch M, Bennett PN, Currey J, Hutchinson AM. Point-of-care ultrasound use for vascular access assessment and cannulation in hemodialysis: A scoping review. *Semin Dial*. 2020 Sep;33(5):355-368.
- [20] Kar-Wai Lui, Kee-Min Yeow, Yung-Liang Wan, Yun-Chung Cheung, Koon-Kwan Ng, Jeng-Hwei Tseng, Ultrasound guided puncture of the brachial artery for haemodialysis fistula angiography, *Nephrology Dialysis Transplantation*. 2001;16(1): 98-101.
- [21] Tadashi Kamata, Mayumi Tomita & Noriyuki Iehara. Ultrasound-guided cannulation of hemodialysis access. *Renal Replacement Therapy*. 2016; 2(7).
- [22] Iglesias R, Lodi M, Rubiella C, Teresa Parisotto M, Ibeas J. Ultrasound guided cannulation of dialysis access. *J Vasc Access*. 2021; 22: 106-112.
- [23] S. Lee, L. Liu, R. Radwin and J. Li, "Machine Learning in Manufacturing Ergonomics: Recent Advances, Challenges, and Opportunities," in *IEEE Robotics and Automation Letters*. 2021; 6(3). 5745-5752.
- [24] Donisi L, Cesarelli G, Coccia A, Panigazzi M, Capodaglio EM, D'Addio G. Work-Related Risk Assessment According to the Revised NIOSH Lifting Equation: A Preliminary Study Using a Wearable Inertial Sensor and Machine Learning. *Sensors*. 2021;21.
- [25] Chan VCH, Ross GB, Clouthier AL, Fischer SL, Graham RB. The role of machine learning in the primary prevention of work-related musculoskeletal disorders: A scoping review. *Appl Ergon*. 2022;98: 103574.
- [26] Mengjiao Zhang, Hongxia Li, Shuicheng Tian, Visual analysis of machine learning methods in the field of ergonomics — Based on Cite Space V, *International Journal of Industrial Ergonomics*. 2023;93.
- [27] Donisi L, Cesarelli G, Pisani N, Ponsiglione AM, Ricciardi C, Capodaglio E. Wearable Sensors and Artificial Intelligence for Physical Ergonomics: A Systematic Review of

Literature.Diagnostics. 2022; 12(12):3048.

- [28] Suess F, Melzner M, Dendorfer S. Towards ergonomics working - machine learning algorithms and musculoskeletal modeling. IOP Conf Ser: Mater Sci Eng. 2021;1208: 012001.
- [29] Young JQ, Sewell JL. Applying cognitive load theory to medical education: construct and measurement challenges. Perspect Med Educ. 2015 Jun;4(3):107-9.
- [30] Venkat MV, O'Sullivan PS, Young JQ, Sewell JL. Using Cognitive Load Theory to Improve Teaching in the Clinical Workplace. MedEdPORTAL. 2020;16: 10983.
- [31] Ghanbari S, Haghani F, Barekatain M, Jamali A. A systematized review of cognitive load theory in health sciences education and a perspective from cognitive neuroscience. J Educ Health Promot. 2020 Jul 28;9:176.
- [32] Leppink J, van den Heuvel A. The evolution of cognitive load theory and its application to medical education. Perspect Med Educ. 2015;4: 119-127.
- [33] Young JQ, Sewell JL. Applying cognitive load theory to medical education: construct and measurement challenges. Perspect Med Educ. 2015 Jun;4(3):107-9.
- [34] Ehrmann DE, Gallant SN, Nagaraj S, Goodfellow SD, Eytan D, Goldenberg A, et al. Evaluating and reducing cognitive load should be a priority for machine learning in healthcare. Nat Med. 2022;28: 1331-1333.
- [35] David CC, Jacobs DJ. Principal component analysis: a method for determining the essential dynamics of proteins. Methods Mol Biol. 2014;1084:193-226.
- [36] Morishita T. Time-dependent principal component analysis: A unified approach to high-dimensional data reduction using adiabatic dynamics. J Chem Phys. 2021;155: 134114.
- [37] 巻野雄介, プローブ固定装置を用いたエコーガイド下末梢静脈穿刺法の開発, 大分県立看護科学大学大学院博士論文, 2020 年度
- [38] Charte D, Charte F, del Jesus MJ, Herrera F. An analysis on the use of autoencoders for representation learning: fundamentals, learning task case studies, explainability and challenges. arXiv [cs.LG]. 2020.
- [39] Haidar R, Koprinska I, Jeffries B. Feature Learning and Data Compression of Biosignals Using Convolutional Autoencoders for Sleep Apnea Detection. Neural Information Processing: 26th International Conference, ICONIP 2019, Sydney, NSW, Australia, December 12–15, 2019, Proceedings, Part I. Berlin, Heidelberg: Springer-Verlag; 2019. pp. 162–174.
- [40] 中村三夫. 血液浄化療法の治療指標. 透析療法合委員同専門会編. 0 血液浄化療法ハンドブック. 東京:協同医書, 152-154: 2019.
- [41] 伸也秋庭, 阿聖杉山, 学寺田. 見て試してわかる機械学習アルゴリズムの仕組み 機械学習図鑑. 東京:翔泳社, 38,80-81: 2019.

- [42] Umberto Michelucci. An Introduction to Autoencoders. arXiv:2201.03898v1 [cs.LG] 11 Jan 2022.
- [43] Bank D, Koenigstein N, Giryas R. Autoencoders. arXiv [cs.LG]. 2020.
- [44] van Merriënboer JJ, Sweller J. Cognitive load theory in health professional education: design principles and strategies. *Med Educ*. 2010 Jan;44(1):85-93.
- [45] Venkat MV, O'Sullivan PS, Young JQ, Sewell JL. Using Cognitive Load Theory to Improve Teaching in the Clinical Workplace. *MedEdPORTAL*. 2020;16:10983.
- [46] 康仁佐藤, 拓生松延. 非固定視野映像による注視点分析法. *パナソニック電工技報*. 2010;58: 68-73.
- [47] 若倉雅登 監修. 病気を見きわめる 目のしくみ辞典. 東京都: 株式会社技術評論社, 172: 2017.
- [48] 苧阪直行. 周辺視機能の精神物理学的研究. 東京都: 株式会社風間書房, 1~3: 1983.
- [49] Krejtz K, Duchowski AT, Niedzielska A, Biele C, Krejtz I. Eye tracking cognitive load using pupil diameter and microsaccades with fixed gaze. *PLoS One*. 2018;13.
- [50] Sevcenko N, Appel T, Ninaus M, Moeller K, Gerjets P. Theory-based approach for assessing cognitive load during time-critical resource-managing human–computer interactions: an eye-tracking study. *Journal on Multimodal User Interfaces*. 2023;17: 1-19.
- [51] Katona J. Measuring Cognition Load Using Eye-Tracking Parameters Based on Algorithm Description Tools. *Sensors*. 2022; 22.
- [52] Measuring cognitive load during visual tasks by combining pupillometry and eye tracking. [cited 8 Jan 2024]. Available: <https://graphics.stanford.edu/papers/klingner-dissertation/>
- [53] Dorogush AV, Ershov V, Gulin A. CatBoost: gradient boosting with categorical features support. arXiv [cs.LG]. 2018.
- [54] Lundberg S, Lee S-I. A Unified Approach to Interpreting Model Predictions. arXiv [cs.AI]. 2017.
- [55] Erickson BJ, Kitamura F. Magician’s Corner: 9. Performance Metrics for Machine Learning Models. *Radiol Artif Intell*. 2021;3.
- [56] Scott Lundberg, Su-In Lee. A Unified Approach to Interpreting Model Predictions. arXiv:1705.07874v2 [cs.AI]. 2017.
- [57] Wen Y, Rahman MF, Zhuang Y, Pokojovy M, Xu H, McCaffrey P, Vo A, Walser E, Moen S, Tseng TB. Time-to-event modeling for hospital length of stay prediction for COVID-19 patients. *Mach Learn Appl*. 2022 Sep 15;9.
- [58] Suresh K, Severn C, Ghosh D. Survival prediction models: an introduction to discrete-time modeling. *BMC Med Res Methodol*. 2022;22: 207.



- [59] John Sweller & Paul Chandler (1994) Why Some Material Is Difficult to Learn, *Cognition and Instruction*, 12:3, 185-233.
- [60] Suárez Sánchez A, Iglesias-Rodríguez FJ, Riesgo Fernández P, de Cos Juez FJ. Applying the K-nearest neighbor technique to the classification of workers according to their risk of suffering musculoskeletal disorders. *Int J Ind Ergon*. 2016;52: 92-99.
- [61] Mudiyansele SE, Nguyen PHD, Rajabi MS, Akhavan R. Automated Workers Ergonomic Risk Assessment in Manual Material Handling using sEMG Wearable Sensors and Machine Learning. *arXiv [cs.LG]*. 2021.
- [62] Imai T. Application of Artificial Intelligence Technology in the Field of Medical Natural Language Processing. *人工知能*. 2020;35: 474-479.
- [63] Michihiro K, Toshiki S, Satoshi S. Study on Deep Learning-Based Detection of Viable Cell Count in Dialysis Fluid Images. *Renal Replacement Therapy*. 2024.

## 付録

A) OptiTrack V120: Duo 仕様書 ([https://www.optitrack.jp/dcms\\_media/other/v120duo.pdf](https://www.optitrack.jp/dcms_media/other/v120duo.pdf))

## 謝辞

本論文の執筆にあたり，多くの方々にご支援いただいた．終始熱心なご指導を頂いた鈴木聡教授に感謝の意を表す．

データ採取施設選定にあたり山家敏彦特任教授よりご指導とご助言を賜り，感謝申し上げます．

データ採取においては，昭島腎クリニック院長，栗本義直先生，臨床工学技士主任の渡辺徹氏，さとうクリニック院長，佐藤純彦先生，臨床工学部部長の佐久間宏治氏はじめスタッフの皆様にはひとかたならぬお世話になり感謝申し上げます．

最後に，所属する CIM 研究室のみなさまには多くのご支援をいただき，お礼申し上げます．

令和 5 年 11 月

川崎路浩