



人工知能を使った先進的な認知症介護

BPSD 予測・予防により介護負担を軽減する認知症対応型 AI・IoT サービスの開発と実装



- 1 データ収集
様々な情報源から、例えばバイタルデータ(脈拍・体動など)、環境情報(温度・湿度等)介護記録を収集し、AIの「栄養」としてクラウドに送信します。
- 2 データ前処理
データを整理し欠損値を補い、AIが正しく分析できる状態に整えます。
- 3 モデル選択
最適なアルゴリズム(例: LSTMやTransformer)を選び、学習を支える「脳」を形成します。
- 4 データ分析とBPSD予測
AIがリアルタイムでデータを解析し、BPSDの発生可能性を予測して、具体的なケア方法をスタッフに提案します。
- 5 学習と改善
ケア結果のフィードバックをもとにAIは再学習を行い、さらに予測精度を高めていきます。

(Supportive.)

BPSD 予測・予防により介護負担を軽減する認知症対応型 AI・IoT サービス「DeCaAI」研究開発について説明します。

DeCaAI は、認知症ケアをサポートするために開発された人工知能システムです。BPSD(認知症による行動・心理症状)の発症リスクを予測し、その対応方法を提案することで、認知症の方や家族、介護・看護に役立つ情報を提供します。

1. データの収集・・・まず、DeCaAI は認知症患者の日常の行動や健康情報を収集します。睡眠時間、食事のパターン、活動量などが含まれます。こうした情報は患者さん自身や家族、介護士、看護師などのスタッフが入力したものです。
2. 情報の整理(前処理)・・・収集された情報は AI によって整理されます。この段階では、誤ったデータを除去したり、情報を使いやすい形に整える作業が行われます。
3. 重要なポイントの選択・・・AI は収集された情報の中から、認知症の方の状態に関わる重要なポイントを抽出します。これにより、ケアの質を向上させるために必要な情報だけが使われます。
4. データの分析・・・重要な情報を基に、AI が過去のデータや研究成果を活用して分析を行います。この分析は、患者さん認知症の方がどのような状況にあるのかをより深く理解するためのものです。
5. 予測と提案 最終的に、AI は BPSD (認知症による行動・心理症状)の発症リスクを予測します。そして、家族や看護師に向けて、予防や対応方法の具体的なアドバイスを提案します。

人工知能への理解を深めてください。人工知能は、これまでの経験や研究を基に分析を行い、データを補助するためのツールです。「人間の判断を完全に置き換えるもの」ではなく、「補助してくれる存在」と考えてください。

このセミナーでは、AI (DeCaAI) の仕組みや活用方法、そして実際の介護現場でどのように役立つのかを具体的に解説します。参加される皆様には、AI や IoT が認知症ケアにどのような変革をもたらすのかを体感していただきながら、実際の運用例や事例紹介を通して理解を深めていただきます。AI の理論だけでなく、現場でどのように活かせるのかを意識しながら、積極的にご参加ください。

【認知症】

時間・空間・場所・状況・目的・関係などの「つながりとその意味」が頭からすぐに消えてしまったり、寸断されたり、つながらないために起こる

【認知症】

時間・空間・場所・状況・目的・関係などの「つながりとその意味」が頭からすぐに消えてしまったり、寸断されたり、つながらないために起こる“脳機能障害”



認知症の介護において大きな問題となるのは、ひとつは、高度な物忘れの状態、すなわち健忘症であり、もうひとつは、といわれるBPSD(認知症の行動・心理症状)であり、認知症介護の最大の難問となっている。

BPSD:行動・心理症状:Behavioral and Psychological Symptoms of Dementia

無断
外出

徘徊
不穏

うつ

不安

閉じ
こもり

幻視
幻聴

脱抑制

妄想



無反応
無関心

認知症患者の心の声を AI が捉え、行動の変化や環境の影響を深く理解する『プロアクティブケア』


プロアクティブケアでは、病気や健康上の問題が発生する前に予防と管理を行い、BPSD が現れる前に状況を検知して対処するケアを導出します。

IoT センサーや AI 技術を用いて、身体的、心理的、環境的、社会的要因に基づくデータを収集します。

BPSD の兆候を早期に発見し、スタッフに迅速に通知することで予防と対応を実現することが可能です。




バイタルセンサーで測定された脈拍（回/分）、介護記録システムの情報、そして画像解析に基づき、BPSD が発生した時間帯を可視化しています。また、テキストデータには BPSD の発症に関連するタグ付け（tagging）が施され、これをもとに学習が進められています。





Valence & Arousal マッピングテーブルは感情の評価を二次元座標で表現します。心理学者 James A. Russell が提案したモデルを基に構築されていて、Valence（快・不快）と Arousal（覚醒度）の2軸を使います。

これにより、喜怒哀楽の感情を視覚化してマッピングすることが可能になります。



FACS 詳細と感情評価



顔の特徴点抽出



ランドマーク検出

FACS（Facial Action Coding System）は、顔の筋肉の動きを分析し、感情を理解するための手法で、その基本となるのが AU（Action Unit）です。AU は、特定の顔の筋肉の動きを示す最小単位であり、たとえば、眉を上げる動作は AU1、口角を上げる動作は AU12 として分類されています。

FACS は、これらの AU の組み合わせを解析することで、表情から感情を正確に読み取ることが可能です。

次に、AU1～AU7 の例を示します。

検索



検索

多様なデータをもとに、ケア現場で役立つ情報をリアルタイムに検索・提示し、AI が最適なケア方法やリスク

予測を提案します。

プルチックの感情の輪



プルチックの感情の輪（Plutchik's Wheel of Emotions）は、アメリカの心理学者ロバート・プルチックによって提唱された、感情の分類理論。円すいを逆さまにしたようなモデルで、8つの基本感情（喜び、信頼、恐れ、驚き、悲しみ、嫌悪、怒り、期待）を中心に、その強弱や混合感情まで表現している。

外側になるほど感情が弱くなり、内側ではより強い感情が表されている。隣接する感情同士が混ざり合うことで、新しい感情が生まれること！例えば「喜び」と「信頼」が合わさると「愛」の感情が生まれる。

番号	動作名称	顔の動き	関連する主な感情（英語）
AU1	内側眉上げ (Inner Brow Raiser)	眉の内側が上がる	悲しみ (Sadness), 困惑 (Confusion)
AU2	外側眉上げ (Outer Brow Raiser)	眉の外側が上がる	驚き (Surprise), 関心 (Interest)
AU3	上まぶた引き上げ (Upper Lid Raiser)	まぶたを開き、目を強調	驚き (Surprise), 恐れ (Fear)
AU4	眉下げ (Brow Lowerer)	眉を中央に寄せて下げる	怒り (Anger), 集中 (Concentration)
AU5	まぶた大きく開く (Upper Lid Opener)	目がしっかりと開く	恐れ (Fear), 警戒 (Alertness)
AU6	頬上げ (Cheek Raiser)	頬が上がり目尻にしわ	喜び (Joy), 本物の笑顔 (Duchenne Smile)
AU7	まぶた締め (Lid Tightener)	下まぶたが引き上げられる	緊張 (Tension), 不信 (Distrust)
AU8	唇引き寄せ (Lip Corner Puller)	唇を中央に引き寄せる	嫌悪 (Disgust), 不満 (Dissatisfaction)
AU9	鼻しわ寄せ (Nose Wrinkler)	鼻にしわが寄る	嫌悪 (Disgust), 軽蔑 (Contempt)
AU10	上唇引き上げ (Upper Lip Raiser)	唇が上がる	嫌悪 (Disgust), 軽蔑 (Contempt)
AU11	鼻唇溝深め (Nasolabial Deepener)	鼻唇溝が深くなる	喜び (Joy), 満足 (Satisfaction)
AU12	唇角引き上げ (Lip Corner Puller)	唇の角が上がる	喜び (Joy), 安心 (Relief)



分析

1. 行動データとの連携：顔の表情だけでなく、体の動きや声のトーンを AI で分析することで、感情だけでなく全体的な心理状態をより正確に把握できるようになるんだ。
2. バイタルサインとの統合：心拍数や体温などの生理的データと顔の感情分析を組み合わせることで、患者のストレスや体調の変化を早期に検知できる。
3. ケア効果のリアルタイム評価：顔の表情変化をリハビリやレクリエーション活動中に記録して、どの活動がポジティブな感情を引き出すかを把握できる。
4. 環境との相互作用：環境センサーと連携して、特定の環境（照明や音楽など）が感情に与える影響を測定することも可能だよ！

7つの感情カテゴリー(悲しみ・幸福・怒り・軽蔑・嫌悪・恐怖・驚き)に区分し、さらに(快⇔不快)(注目:接近⇔拒否:回避)(休止:恐れ⇔緊張:怒り)という関係を対比しながらデータを収集し、画像認識技術を用いて感情評価を行い学習させます。(46種類)

楽しみ/ENJOYMENT:13種

- ① ECSTASY狂喜:非常に大きな幸福の状態
- ② EXCITEMENT興奮:強力な熱意
- ③ WONDER驚嘆:非常に大きな驚きや、信じ難い経験
- ④ NACHESナチェス:自分の子供や教え子が成長した時の誇らしい喜び
- ⑤ FIEROフィエロ:困難な挑戦を乗り越えた時の喜び
- ⑥ PRIDE高慢:自分自身の成果や、仲間の成果から得た深い喜び
- ⑦ PEACE平穏:穏やかであることの喜び
- ⑧ RELIFE安心:不快であることがなくなった時の心の落ち着き
- ⑨ SCHADENFREUDEシャデンフロイデ:他人やライバルの不幸を楽しみ気持
- ⑩ AMUSEMENT面白い:遊び心のある、明るく楽しい気持
- ⑪ COMPASSION/JOY同情:他人の苦しみを和らげることで得られる気持
- ⑫ REJOICING喜び:優しさや思いやりを見た時に経験する暖かく爽やかな気持
- ⑬ SENSORY PLEASURE感覚的快楽:視覚・聴覚・触覚・味覚・嗅覚の5つの感覚

恐れ/FEAR:8種

- ① TERROR震駭:激しい恐怖
- ② HORROR恐怖:嫌悪感とショックの混在
- ③ PANICパニック:コントロールが出来ない突然の恐怖
- ④ DESPERATION自暴自棄:危険を減らすことができない、やけくそな感情
- ⑤ DREAD恐れる:重大な危険を予期した感情
- ⑥ ANXIETY不安:訪れるかもしれない脅威への恐怖
- ⑦ NERVOUSNESS緊張感:危険があるかどうかわからない不確実な感情
- ⑧ TREPIDATION狼狽:危険の可能性を予期した、うろたえる感情

嫌気/DISGUST:7種

- ① LOATHING強い嫌悪:他人に向けた激しい嫌悪感、または自分自身に向けた自己嫌悪
- ② ABHORRENCE憎悪:強い嫌悪と憎しみが混ざり合った気持
- ③ REVULSION反感:嫌悪感と憎しみが混ざり合った気持
- ④ REPUGNANCE嫌気:コンセプトやアイデアに対する強い嫌悪感
- ⑤ DISTASTE嫌悪:悪い味、匂い、物質、またはアイデアへの嫌悪感
- ⑥ AVERSION嫌い:嫌いなことを避けるための衝動
- ⑦ DISLIKE苦手:自分にとって得意ではな趣好


悲しみ/SADNESS:11種

- ① ANGUISH苦悩:激しい悲しみや苦しみ
- ② SORROW悲嘆:苦痛と苦しさの感覚、多くの場合は喪失が原因
- ③ GRIEF悲哀:深い喪失の悲しみ
- ④ DESPAIR絶望:悪い状況が変わるという希望の喪失
- ⑤ MISERY悲惨:強い苦しみや不幸の気持
- ⑥ HOPELESSNESS落胆:良いことは何も起こらないという信念
- ⑦ HELPLESSNESS無力:状況が改善できないという認識
- ⑧ RESIGNATION諦め:何もできないという信念
- ⑨ DISTRUGHTNESS逸脱:考えることを避けなくなる悲しみ
- ⑩ DISCOURAGEMENT挫折:失敗を繰り返して、できないと感じる信念
- ⑪ DISAPPOINTMENT残念:期待が満たされていない感情

怒り/ANGER:7種類

- ① FURY憤激:制御できない暴力的な怒り
- ② VENGEFULNESS執念:傷つけられたことに対して復讐したいと考える欲望
- ③ BITTERNESS怨み:不当な扱いを受けた時の怒り
- ④ ARGUMENTATIVENESS論争性:違う意見に対して反抗する気持
- ⑤ EXASPERATIO激昂:繰り返されるか強い迷惑によって惹き起こされる怒り
- ⑥ FRUSTRATIONフラストレーション:欲求が満たされないときの苛立ち
- ⑦ ANNOYANCE苛立ち:ちょっとした迷惑や不便さに対する軽い怒り

AIと脳の機能の共通点と特異性の比較



感情分析や分類における重要なプロセスを示します。顔画像を処理するために畳み込みニューラルネットワーク（CNN）を活用し、左側の顔画像から特徴を抽出し、中央の全結合ネットワークに入力して感情を理解する流れを描写しています

抽出された特徴は全結合ネットワークに渡され感情が分類されることで、人間の視覚情報処に似たプロセスが再現されます。一方コネクトロームは、人間の脳がニューロン間で特徴の抽出情報を処理し、側頭葉と海馬で記憶形成を担う準備を脳全体で支えている。

AIでは、ニューラルネットワーク（CNN）が顔画像から特徴を解析し、視覚データを通じて顔の構造を認識します。

一方で、脳もニューロンを駆使して視覚情報を処理し、顔の特徴や構造を把握しています。

ニューロンはおよそ 860 億個、その接続数（シナプス）は約 100 兆個生成 AI の回路は「パラメータ数」で数兆規模
人間の脳は、生成 AI の約 100 倍の能力があることになる。

感情の座標軸モデルを活用し、7つの基本的な感情を


快・不快（感情の質）と覚醒（感情の活性度）の 2 軸で分類、AI で学習させて認識します。

この手法を通じて感情を定量的に分析するだけでなく、AU 構成によりクラス分類を行い感情の理解を深めます。

例えば、喜びは「快」で「高覚醒」、哀しみは「不快」で「低覚醒」に分類し AU 同志を組合わせて評価しています。

クラス	感情 (Emotion)	主なAU構成 (Main AU Composition)	・ 説明 (Explanation)
クラス0	喜び (Joy)	AU1, AU12, AU25	デュシェンヌ・スマイル(本物の笑顔)
クラス1	怒り (Anger)	AU4, AU15, AU20	対立・攻撃的な感情
クラス2	悲しみ (Sadness)	AU1, AU4, AU15, AU41	淡々とした感情、目がたれ気味
クラス3	驚き (Surprise)	AU1, AU2, AU5, AU26	瞳孔の開きや口の開きが特徴的
クラス4	恐怖 (Fear)	AU1, AU2, AU4, AU20, AU25	防衛的反応や緊張した表情が見られる
クラス5	嫌悪 (Disgust)	AU9, AU10, AU17	鼻のしわ寄せや唇の縮みがポイント
クラス6	軽蔑 (Contempt)	AU12, AU14, AU16	唇片側の引き上げや無表情を含む
クラス7	興奮 (Excitement)	AU1, AU6, AU12, AU25	明るい目つきと活気ある表情が特徴
クラス8	緊張 (Tension)	AU4, AU5, AU20	硬い表情、目元の緊張感が見られる
クラス9	安心 (Relief)	AU6, AU12, AU15	穏やかで落ち着いた表情
クラス10	疑い (Doubt)	AU4, AU7, AU15	側頭や眉の微妙な動きが特徴
クラス11	中立 (Neutral)	—	感情の揺れや特異な表情がない

画像処理は CNN、時系列では RNN や LSTM、分類は Randomforest や LightGBM、高度な処理は Transformer を
使い、目的に合わせた最適なアルゴリズムから学習モデルを選択




高齢者の行動や心理状態を理解し、適切なケアにつなげるために、心拍変動（HRV）が重要視されます。

HRV(Heart Rate Variability)は心拍と心拍の間隔の変化を表し、自律神経のバランスを示します。食事・排泄・入浴・就寝などの日常イベントごとに HRV を分析し、認知症の行動・心理症状（BPSD）発症前の異常を AI で自動検出、早期発見を行います。

BPSD の予測は AI でバイタルや環境データを解析し、症状の 30～60 分前に兆候を捉え、介護者の早期対応と安全なケアを支援します。

Behavior	HRVパターンの特徴
排泄(特に失禁時)	HRV急低下・心拍数急上昇(羞恥・不快)
食事	食前後でHRV変動:摂取中は上昇、食後は副交感支配で安定化
入浴	湯温刺激で一時的にHRV低下し心拍上昇
就寝	概日リズムに沿ってHRV上昇、心拍低下
散歩	軽い有酸素運動は、心拍数が少し上昇する一方で、HRVは通常の安静時に比べてやや低下
ノンレム睡眠	副交感神経が優位になり、HRVが最も高くなる
レム睡眠	自律神経活動は変動しやすく、HRVはノンレム睡眠時ほど高くないが、覚醒時よりは安定している
BPSD直前	HRVが著しく低下し、心拍数の変動が不規則になる



【分析】B P S Dが発症した時刻と一致して、心拍数の変動が確認されました。

初動から約 40 分後、一過性の徐脈から回復し、頻脈に至った時点で B P S D の発症が見られた。

このような一過性の徐脈と頻脈のパターンは、他の症例でも B P S D 発症時に確認されています。

【結果】脈拍の経時的推移と遅速幅の心拍変動(HRV) の変化を、B P S D 発症の特徴的なパターンとして A I に学習させました。

HRV による BPSD 予兆の科学的根拠 BPSD 発生前には、以下のような特徴的な HRV 異常が顕在化します。

- a) SDNN (標準偏差) や RMSSD (短期変動) 指標の低下
- b) LF/HF 比の極端な変動 (交感・副交感神経の不均衡)
- c) 周囲環境に対する反応性の過敏化 (心拍反応が誇張される)

これらは、自律神経の調整障害が先行して起きている証拠であり、

BPSD の引き金となる心理的ストレスや混乱、不快刺激に対する過敏反応として考察できる。




分析

右の図は、ウェアラブルデバイスを使用して得られた継続的な脈拍データを示しており、BPSD が現れる前に観察される生理的な兆候を特定し、その特徴的なパターンをプロセス分析を通じて明らかにしています。

BPSD はしばしば突然現れ、徘徊や興奮、暴言や暴力、不安、妄想といった多様な症状が

見られ、これが認知症ケアに深刻な影響を及ぼしているわけです。このため、発症の兆候を可視化し、客観的な指標として捉えるための技術開発が急務とされていた。

本フォーラムでは、ウェアラブルデバイスを用いて 1 秒ごとに測定される脈波 (PPG) から心拍間隔 (IBI) を算出し、さまざまな心拍変動 (HRV) 指標を導出します。HRV は自律神経系の活動を反映する生理的指標であり、特に副交感神経の活性を示す RMSSD や自律神経のバランスを表す LF/HF 比が、心理的ストレスや覚醒状態との関連で注目されている。



これらの指標を移動平均やスライディングウィンドウ手法で時系列的に分析することで、BPSD 発症前後の HRV の変動パターンを特定することが可能になります。

さらに、周波数領域の解析を実施し、心拍変動の時系列信号に高速フーリエ変換（FFT）を適用し、特定の周波数帯における変動の強度 $|B(f)|$ を抽出します。

ここでの $|B(f)|$ は周波数 f における HRV 成分の振幅を示し、自律神経の活性度を定量化しています。これにより、BPSD の発症に関連して顕著に増減する周波数成分を特定のパターンとして定義できます。

さらに、これらの HRV 指標を組み合わせて Z スコア化し、異常値としての閾値を超えるタイミングを統計的に特定することで、BPSD の前兆となる異常な心拍変動を捉えるアルゴリズムの構築を目指した。

最終的には、得られたパターンを活用し、介護現場でリアルタイムに BPSD リスクを通知する予測モデルを開発することで、事前に適切な介護が可能となります。このように、非侵襲的かつ継続的に取得可能な生体信号から、認知症に特有の行動変容の前兆を抽出し、科学に基づいた BPSD 予測支援システムの戦果報告になります。

データの収集と解析方法

- 1) ウェアラブル端末の心拍センサーを使って、HRV のデータを取得します。
- 2) ウェアラブルデバイスは光電容積脈波 (PPG) センサーを用いたデバイスを使用して、RR 間隔を測定します。
- 3) データ収集では PPG センサーで心拍間データを記録し、バンドパスフィルターでノイズを除去します。
- 4) ピーク検出により心拍タイミングを特定し、RR 間隔を計算。
- 5) 時間領域では Mean RR や SDNN 周波数領域では FFT で LF と HF のパワースペクトルを分析します。
- 6) HRV は、心拍間のわずかな変動を意味し、自律神経系 (交感神経と副交感神経) の活動状態を示します。
- 7) 指標を測定することでストレスレベルや身体の回復状況、健康全般の状態を把握することができます。AI (DeCaAI) が自動的に SDNN や RMSSD を計算します。

8) SDNN (NN 間隔の標準偏差) は、心拍変動の全体的な状態を示します。

【計算式】

$$SDNN = \sqrt{\frac{1}{N} \sum_{i=1}^N (NN_i - \overline{NN})^2}$$

① NN_i は、 i 番目の隣接 RR 間隔 (R-R 間隔) ② NN は NN 間隔の平均

③ N はデータ数 (心拍間隔の数)

ここで NN は隣接する心拍間隔 (通常はミリ秒単位) を指します。

臨床的には、SDNN が低い場合は慢性的なストレスや加齢により自律神経のバランスの乱れを示唆します。

9) RMSSD (隣接差の二乗平均平方根) は短期的な心拍変動を反映し、副交感神経の活動を特に評価する指標です。

【計算式】

$$RMSSD = \sqrt{\frac{\sum_{i=1}^{N-1} (NN_{i+1} - NN_i)^2}{N-1}}$$


臨床的意義として、RMSSD の低下はストレスや不規則な生活習慣と関連していることがあります。

認知症の BPSD は、SDNN や RMSSD の低下が自律神経の不均衡を示し、徘徊や不安、興奮などの症状の発症につながります

大量なデータに基づく処理と、認知症についての知識の体系に基づく処理とを、組み合わせて統合します。

認知症の機能障害における BPSD 発症を紐解く、学習時に起こり得る想定外の状態へも対応する仕組みと、認知症患者と介護者と AI が、より深く意思疎通できるように ChatGTP 等で会話を可能にしました。

判別分析




収集したデータを統計的手法で解析 BPSD の評価に基づいてクラス分類する前段階で、生活自立度と中核症状の関連を紐づけて判別します。

主成分分析（AI 分析）からデータを分析、BPSD を予測します。

日本医療研究開発機構「認知症対応型 AI・IoT システム推進事業」で開発された「人工知能 DeCaAI」

- ◆認知症対応型 AI（DeCaAI）は、大量のケア情報を確実に収集・統合し迅速に活用できるようにデータの見える化を実現しています。
- ◆ケア情報は効率よく圧縮して蓄積させ、生体データは長期間の大量データになってもデータの精度が損なうことは無く数年前のデータを即時に参照してプロセス解析に使用しています。
- ◆業務内容（BPSD 対応・直接介護・間接介護等）や対人援助に応じて、医療・介護スタッフ自身によって独自の管理をしたり、分析したりして、適切なケア情報を把握できるよう統合化しています



非監督型機械学習手法である k-means クラスタリングと主成分分析,異常検知のアルゴリズムを用いて症状の分類とクラスタリングを行っています。

- 活動性の高い外向的の症状（例：徘徊や攻撃動）
- 活動性の低い内向的の症状（例：アパシー、不安、抑うつ）

高活動性と低活動性を明確に区別し、それぞれに関連する特徴を抽出します。

また、地理統計学的アプローチを用いて、寒冷地や温暖地といった地域特性が症状に及ぼす影響を検証しました。

さらに、高精度なベイズ推論と SHAP 値による説明可能な AI 技術を導入し、予測モデルの解釈を高めることで、介護現場での実用的な活用を目指したモデルの構築に成功しました。



◇BPSD発生精度

Model	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC
Stacking Classifier	0.9407	0.9558	0.9611	0.9505	0.9558	0.8659	0.866

◇種別判定精度

Model	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC
Stacking Classifier	0.834	0.9762	0.834	0.8037	0.8153	0.821	0.8218

◇採用モデルの予測確率を組合せ

Model	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC
Extra Trees Classifier	0.9185	0.9608	0.9833	0.9031	0.9415	0.8081	0.8161
Random Forest Classifier	0.8963	0.9643	0.9778	0.88	0.9263	0.7529	0.7649
CatBoost Classifier	0.9148	0.9535	0.9778	0.9026	0.9387	0.8	0.8069



Model	Accuracy	AUC	Recall	Prec.	F1	Kappa	MCC	TT (Sec)
Extra Trees Classifier	0.946	0.9835	0.993	0.931	0.9608	0.8722	0.8778	0.17
Random Forest Classifier	0.9079	0.9663	0.9885	0.8873	0.9347	0.7769	0.7917	0.292
CatBoost Classifier	0.9048	0.9598	0.9955	0.8791	0.9328	0.7671	0.7895	22.568
Decision Tree Classifier	0.8762	0.8438	0.9504	0.8754	0.91	0.7113	0.7219	0.062
Light Gradient Boosting Machine	0.8873	0.9396	0.9814	0.8674	0.9203	0.727	0.7458	0.44
Naive Bayes	0.4016	0.5738	0.1138	0.8598	0.199	0.0591	0.1351	0.039
Gradient Boosting Classifier	0.8635	0.9106	0.9763	0.8441	0.9045	0.6641	0.6907	1.013
Ada Boost Classifier	0.7873	0.7973	0.9165	0.7927	0.8491	0.4825	0.5065	0.307
K Neighbors Classifier	0.773	0.8128	0.9547	0.7636	0.8477	0.415	0.4616	0.058
Linear Discriminant Analysis	0.6698	0.6624	0.8055	0.7279	0.7632	0.2152	0.2193	0.102
Ridge Classifier	0.6746	0	0.8354	0.7227	0.7724	0.2055	0.2154	0.116
Logistic Regression	0.654	0.6289	0.8472	0.6977	0.7642	0.133	0.1422	0.512
Quadratic Discriminant Analysis	0.519	0.566	0.4936	0.6976	0.5761	0.0523	0.0602	0.099
Dummy Classifier	0.6651	0.5	1	0.6651	0.798	0	0	0.033
SVM - Linear Kernel	0.5556	0	0.6279	0.6098	0.5991	0.0496	0.0519	0.094


Gradient Boosting(XGBoost)	推論確率を向上させるのに適しているブースティング技術。勾配情報を使ってエラーを徐々に減少させるモデル 認知症の早期診断、認知症患者データの複雑なパターンを見つけ出し、分類と予測の精度を向上させる
Networks:	発症病態種のような複雑なパターンを学ぶ深層学習 大量の高次元データを解析して、認知症の進行やリスクの高い状態を特定する
Voting Classifier	複数のモデルを組み合わせて、弱点を補強しつつ全体の精度を高める 複数のモデルの結果を組み合わせて、より安定した精度の高い分類を可能にする。認知症か非認知症か二分類
Extra Trees Classifier	決定木を大量に使うことでランダム性を増やし、安定した結果を得る 複雑なデータの解析、それによって、認知症の早期発見や症状のパターン解析を効率化
Bagging Classifier	データのサブセットを利用して結果をまとめる 複数のモデルを組み合わせて結果の安定性や精度を高め、認知症の特定や進行度合いの予測をサポート
Random Forest	多くの決定木を使って、投票によって結果を決める方法。 認知症やアルツハイマー病のリスクや症状の進行を高精度で予測
Naive Bayes	確率を使った手法で、特にテキスト分類に使用 データの確率的関係を基に、認知症患者の症状やリスクの分類を行い、早期診断を支援
Gradient Boosting	エラーを少しずつ改善していく方法 複数のモデルを組み合わせて予測する方法。アルツハイマー病や認知症の非侵襲的なデータから予測
Decision Tree	データを「はい/いいえ」で分けながら結果を予測 認知症患者の症状データをもとにリスクを分類し、ケアプランを個別に調整
AdaBoost	弱いモデルを組み合わせ、より強力なモデルを作る手法 多くのデータから正確な分類を行う、認知症の早期発見や進行状況の評価、リスク予測
Linear Discriminant Analysis	クラス間の分離を最大化するために特徴を変換する方法 高次元データの次元を減らして、重要な特徴を抽出、健康な高齢者と認知症患者を区別
Neural Networks	人間の脳を模倣して情報を処理する強力な方法で、大規模データで優秀 データを分析して、認知症の進行状況を予測、認知症患者の行動データを活用して、個別のケアプランを設計
Voting Classifier	複数のアルゴリズムの結果を組み合わせて予測精度を向 高次元データを効率的に処理、新しい洞察を提供する
Stochastic Gradient Descent	勾配をランダムに更新しながら、スピーディーに学習する手法 大量のデータを扱う機械学習や深層学習で、認知症の進行を予測するモデルをトレーニングする。
Bagging Classifier	サブセットデータを用いて複数のモデルを学習、結果を統合することで安定性を上げる技術 データを活用して、認知症患者の状態を分類、進行の正確性を向上させる
Extra Trees Classifier	決定木を作って、ランダム性を追加することで正確さを高めるアルゴリズム。 データを基に認知症患者の認知症リスクを分類する場面で使われる
Logistic Regression	分類問題でよく使われる手法で、2つのクラス間の確率を予測 データの二値分類に強く、認知症患者の特徴を基に認知症のリスクや進行状況を予測
XGBoost	勾配ブースティングの進化版。速くて正確なモデル 「予測」のアルゴリズム、臨床データを分析して、早期診断の精度向上、認知症リスクを予測するんだ[8]。
K-Nearest Neighbors	一番近いデータのパターンを参考にして分類や回帰を行う。 遅発性アルツハイマー病のリスク予測。認知症患者の多様なデータを統合して、早期診断をサポート
Support Vector Machine	データを分けるための最適な「超平面」を探し出す方法 アルツハイマー病や軽度認知障害(MCI)を正確に分類

BPSD 予測評価


評価には Precision-Recall 曲線（PR 曲線）を使用した。

この手法は不均衡データに対して効果的で再現率と適合率のバランスを可視化し、臨床現場での実用性を考慮した評価が可能である


◇Extra Trees Classifier




◇Random Forest Classifier



◇CatBoost Classifier



◇Scikit-Learn+GRU



2024 年 3 月 11 日の段階では、30 分後と 60 分後の

19 種類 BPSD 発生を予測した。


- 30 分後の適合率は平均= 98%再現率は 74%
- 60 分後の適合率は平均 99%再現率は 73%

適合率(Precision)予測通りに出現した確率、真陽性(True Positive)

再現率(Recall)予測した中で正解した確率

学習方法の検討だけでなく、個人ごとの介護記録に対して…


自然言語解析を用いて形態素解析を行い学習データに加えることで、最終的には予測精度が実用レベルまで向上しました。



BPSD 予測モデル(無断外出) XGBoost : Gradient Boost LightGBM : Gredient boosting machine
LightGBM を用いて Feature-Importance の概要

Feature Importance とは、決定木(RandomForest)をアンサンブルする学習手法において、その学習モデルが持つ特徴量の重要性(影響力)を定量化する指標です。

種別 5 (無断外出) 30 分後の予測に対する「BPSD25」の影響力



センサーデータの種類	
temperature	温度
humidity	湿度
pressure	気圧
light	照度
co2	CO2濃度
sound	騒音
heartrate	心拍数

BPSD25Q

BPSD25Q	BPSD25Q
1 実際にはないものが見えたり、聞こえたりする(幻視・幻聴)	14 悲観的で気分が落ち込んでいる(うつ)
2 盗られたという、嫉妬する、別人という(盗害、嫉妬、誤認、他)(妄想)	15 やる気がない、自分からは動かない(アパシー)
3 他者を傷つけるような乱暴な言葉を発する(暴言)	16 声かけに反応しない、興味を示さない(無反応・無関心)
4 他者に乱暴な行いをする(暴行)	17 心配ばかりする(不安)
5 うろろろする、不安そうに動き回る(徘徊・不穏)	18 日中うとうとする(傾眠傾向)
6 家/施設から出たがる(無断外出)	19 部屋・家から出たがらない(閉じこもり)
7 他者への性的に不適切な行為(性的不適切行動)	20 夜間寝ないで活動する、人を起こす行動がある(昼夜逆転)
8 こたわって同じ行為を何度も繰り返す(常同行動)	21 異食や過食、拒絶(食行動異常(異食))
9 我慢ができない、衝動的に行動する(脱抑制)	22 介護されることを拒否する(更衣、整容、入浴、食事、他)(介護への抵抗)
10 怒りっぽい(易怒性)	23 尿や便で汚す、何日も入浴しない(風呂、異所排泄、弄便、他)(不潔行為)
11 忘れて同じことを何度も尋ねる(繰り返し質問)	24 タバコ、ガスコンロ等の火元不適切管理(火の不始末)
12 ものをためこむ(収集)	25 隠す、別な場所に置く、探し回る(物をなくす)
13 大声・鳴声が続く、さけぶ(大声)	

クラス分類は「BPSD25Q に添って分類（属性）」した教師あり学習データで、与えられるデータには BPSD 症状の種別ごとの情報を含んでいる。

【種別 5（無断外出）30 分後の予測表の構造】

縦軸（Y 軸）特徴（要因）

各バーが示すのは特定の要因（特徴）の名前だね。例えば、「BPSD250(相陽-不知)」や「年齢」、「湿度」などがリストされているよ。

特徴名には、説明やデータ収集時の条件が含まれているため、それぞれの要因が何を表すのかを把握するのが重要。

横軸（X 軸）特徴の重要性


横軸は「Feature importance」、つまりどれだけその特徴が重要かを数値で表している。数値が大きければ、その要因が分析モデルや予測に大きな影響を与えたということになります。

バーの長さ、特徴の重要度

バーの長さが直接、特徴の重要度を表しています。

一番長いバーは「BPSD250(徘徊-不穏)」で、これが分析において最も影響力があることを示しているね。

グラフは、認知症ケアに関連するデータを分析した結果で。例えば、「BPSD250(介護者の感情)」や「物忘れ」は、認知症の行動や心理症状（BPSD）に関連する重要な特徴。



一方、環境データ（湿度や気圧など）も含まれていて、これらがどの程度影響するかを確認できる。意外かもしれないけど、環境要因は認知症ケアの研究で注目されている。

leaf の予測値の合計数値指標に対する数値が高いほど予測する BPSD 項目に影響を及ぼしている。

応用の可能性

Temperature15

予測導出時間から 15×10[分]前の環境データの正規化された測定値を示す。



センサーの種別・どのくらい前のデータが該当の BPSD 発生に影響しているかを判断した指標モデルの重みづけで XX 分前のデータで判断している。

これらの結果を使うことで、より効果的な介入や予測ができるかもしれないね。例えば、重要度の高い特徴を特に注目して、ケアのプログラムを改善したりするアイデアに繋がるかも。

センサーデータの種類	
temperature	温度
humidity	湿度
pressure	気圧
light	照度
co2	CO2濃度
sound	騒音
heartrate	心拍数

学習時には、学習データを元に決定木を追加し、検証データを元に精度を測定していく、学習回数により精度が上がるように決定木を追加していく。

Leaf とは、「予測値」を割り振った特徴量の重要性(影響力)を



定量化した指


標

Yes


- leaf1:0.060
- leaf9:-0.107
- leaf15:-0.036
- leaf5:-0.022
- leaf20:0.080
- leaf21:-0.071
- 合計:-0.096

No

- leaf3:-0.090
- leaf18:-0.001
- leaf6:-0.082
- leaf16:0.060
- 合計:-0.113



補足:Co2_XX・light_XX/sound_XX・Pressure_XX・temperature_XX→とのセンサーの種別・どのくらい前のデータが該当のBPSD発生に影響しているという重み付け(XXは何分前のデータであるか示す例・Co2_96であれば960分前≒16時間前のCo2データであることを示す。



BPSD 病態種毎の指標モデル(無断外出:徘徊・不穏)環境因子…環境データ2 4/3/11

BPSD 予測をするために必要な指標モデル(特徴量のヒストグラム化)【「無断外出・夕暮れ症候群」の30分後の予測のモデルの場合】

指標に対する数値が高いほどそのモデル(予測するBPSD項目に影響を及ぼす)

BPSD 予測（病態種）

BPSD予測確率	BPSD発祥の予測時間	BPSD発祥の種類
0.89598927	2025-04-08 01:37(67分後)に10001323がBPSD1	(幻視・幻聴)を発生させる可能性があります。
0.85391945	2025-04-08 01:19(49分後)に10001362がBPSD2	(妄想)を発生させる可能性があります。
0.66515446	2025-04-08 01:38(68分後)に10001332がBPSD3	(暴言)を発生させる可能性があります。
0.92722136	2025-04-08 01:37(67分後)に10001365がBPSD4	(暴行)を発生させる可能性があります。
0.9059882	2025-04-08 01:35(65分後)に10001311がBPSD5	(徘徊・不穏)を発生させる可能性があります。
0.87541926	2025-04-08 01:24(54分後)に10001387がBPSD6	(無断外出)を発生させる可能性があります。
0.8536459	2025-04-08 01:39(69分後)に10001288がBPSD7	(性的不適切行動)を発生させる可能性があります。
0.9206373	2025-04-08 01:33(63分後)に10001318がBPSD8	(常同行動)を発生させる可能性があります。
0.89441506	2025-04-08 01:34(64分後)に10001299がBPSD10	(易怒性)を発生させる可能性があります。
0.8880727	2025-04-08 01:19(49分後)に10001218がBPSD11	(繰り返し質問)を発生させる可能性があります。
0.783879	2025-04-08 01:37(67分後)に10001362がBPSD13	(大声)を発生させる可能性があります。
0.92015165	2025-04-08 01:23(53分後)に10001354がBPSD15	(アパシー)を発生させる可能性があります。
0.76449955	2025-04-08 01:08(38分後)に10001286がBPSD16	(無反応・無関心)を発生させる可能性があります。
0.69330525	2025-04-08 01:40(70分後)に10001258がBPSD17	(不安)を発生させる可能性があります。

データを基に異常の兆候や重要なサインの解析

（AI によるリアルタイム解析）

各種センサーで収集された情報は、AI（人工知能）によってリアルタイムに解析されます。

認知症ケアに役立つ非監督型（教師無しデータ）の成果

検出される兆候

【表情・声の変化】

不安・困惑・苦痛を示す表情、うめき声、ため息、声のトーンの変化など

【言葉・行動からの兆候】

助けを求める発言、意味のない繰り返し発話、不穏な言動

【身体の動き】

立ち上がり・徘徊前の挙動、転倒リスクの高い体重移動、不自然な動作の繰り返し

【排泄や脱衣の前兆】

排泄前の落ち着かない様子、排泄前の視線の動き、脱衣を始める動作



1. 感情推定に使われるデータ

データ項目	使用技術	検出される感情指標
顔表情の筋肉パターン	顔面筋解析（FACS）	苛立ち・痛み・驚き・喜びなど
声のトーン・速度・音圧	音声感情解析	怒り・悲しみ・恐怖・安心感など
心拍変動（HRV）	バイタルセンサー	ストレス・興奮・安定状態
発汗・皮膚温	GSR（皮膚電気反応）	緊張・不快・混乱など

2. 感情変化のリアクション

- i) 苛立ちを検知 → 看護師、介護士に「言葉かけ変更」通知（例：「今は静かに寄り添いましょう」）
- ii) 悲しみを検知 → 音楽療法やぬくもりケアの推奨
- iii) 落ち着きの兆候 → ケア継続可能性の通知、次ステップを提案

これにより、心理的ケアも「見える化」「介入の適正化」が可能となります。

3. スマートアラート機能— 介護の判断負担を軽減し、重要なケアに集中できる通知制御

コールやモニターアラートの氾濫により、看護師の“アラート疲れ”や“見落とし”が生じやすい現状があります。

本システムは、緊急性や重要性を AI が自動評価し、優先順位に基づいて通知するスマートアラート機能を搭載しています。

優先レベル	対応例	通知方法
緊急(赤)	転倒・失神・急激な SpO ₂ 低下	即時バイブ＋音声通知＋アプリ通知
重要(黄)	体温上昇傾向・徘徊前兆	看護記録画面へのポップアップ提示
参考(緑)	睡眠変化・食欲減退傾向	シフト交代時レポートに自動追加

AI 介護がもたらす影響と具体的メリット


AI の導入背景

- ① 高齢化社会において、認知症患者の増加とともに、介護業界では人材の不足が深刻化しています。
- ② 認知症の BPSD（行動・心理症状）は予測が困難であり、対応する介護者に大きな負担を与える要因となっています。
- ③ AI を活用した科学的介護は、このような課題を解決する重要な手段となり得ます。

介護者の負担軽減






AI は BPSD 発症のリスクを早期に予測し、適切な介入方法を提示することで介護者が状況に余裕を持って対応できるよう支援します。

これによりストレス軽減や労働環境の改善が見込まれます。



QOL（生活の質）の向上

根拠に基づくAIケアで認知症患者に適切な対応ができ、安定した生活・環境が増えます。その結果、患者の精神的・身体的満足度が向上します。



業務効率が向上

センサーやAIの自動データ管理で介護者の負担が減り、対人ケアに専念できる時間が増えます。特に記録作業の負担軽減が重要です。


施設運営への貢献

AI が移動支援や記録管理、生活環境の監視を支援し、人手不足でも質の高い介護を実現します。

被検者と病態						生活自立度と認知症生活自立度								科
	AD	DLB	FTD	VaD	その他	認知症自立生活自立度	I	II-a	II-b	III-a	III-b	IV	M	
要支援						J-1	8	10	16	26	31	15	2	
要介護1						J-2	46	11	16	18	18	6	1	
要介護2	154	32	5	21	45	A-1	34	14	28	36	23	14	3	
要介護3	136	20	5	28	62	A-2	8	21	42	15	8			
要介護4	80	11				B-1	11	5	8	1	4			
要介護5	82	1				B-2	13	8	11	6	8			
						C-1			14					
						C-2								

学的根拠に基づくケア

AI がバイタルデータや行動ログを解析してケアプランを作成し、施設やスタッフの信頼性の高いケアを支援します。



【おわりに】

2017 年(平成 29 年)度および 2018 年(平成 30 年)度の総務省採択事業「認知症対応型 I o T サービス」の実証事業において、認知症に伴う行動・心理症状 B P S D (叫声、拒絶、徘徊等)について、I o T センサーで得たデータと従前のケア方法を A I が解析して介護者に通知することで、B P S D の発症を 7 4 % 予防し、介護負担を軽減する効果があるという新たな知見が得られており、該成果の可及的速やかな実用化と普及が望まれ 2022 年から 2025 年まで日本医療研究開発機構より実用化支援事業として認知症対応型 A I の開発に継続着手しています。

- (1) I o T センサーで得たデータと A I 解析の精度向上について、研究の加速・充実に努めました。
- (2) 複数の研究者により専門分野毎に 7 つの研究項目に分けてデータ基盤を構築し I o T データ等を収集し、B P S D 予測に関する A I 解析及び B P S D 予防ケア及び対処ケアの導出を行いました。

研究分担

産学連携企業