


○樋山貴洋<sup>1</sup>, 小林吉行<sup>2</sup>, 松本吉央<sup>1</sup>, 村井昭彦<sup>1</sup>, 藤本雅大<sup>2</sup>, 小澤順<sup>2</sup>, 持丸正明<sup>1</sup> (1 東京大学/産総研, 2 産総研)

## 非接触・即時的な転倒リスク評価に向けた機械学習モデルの開発

### はじめに

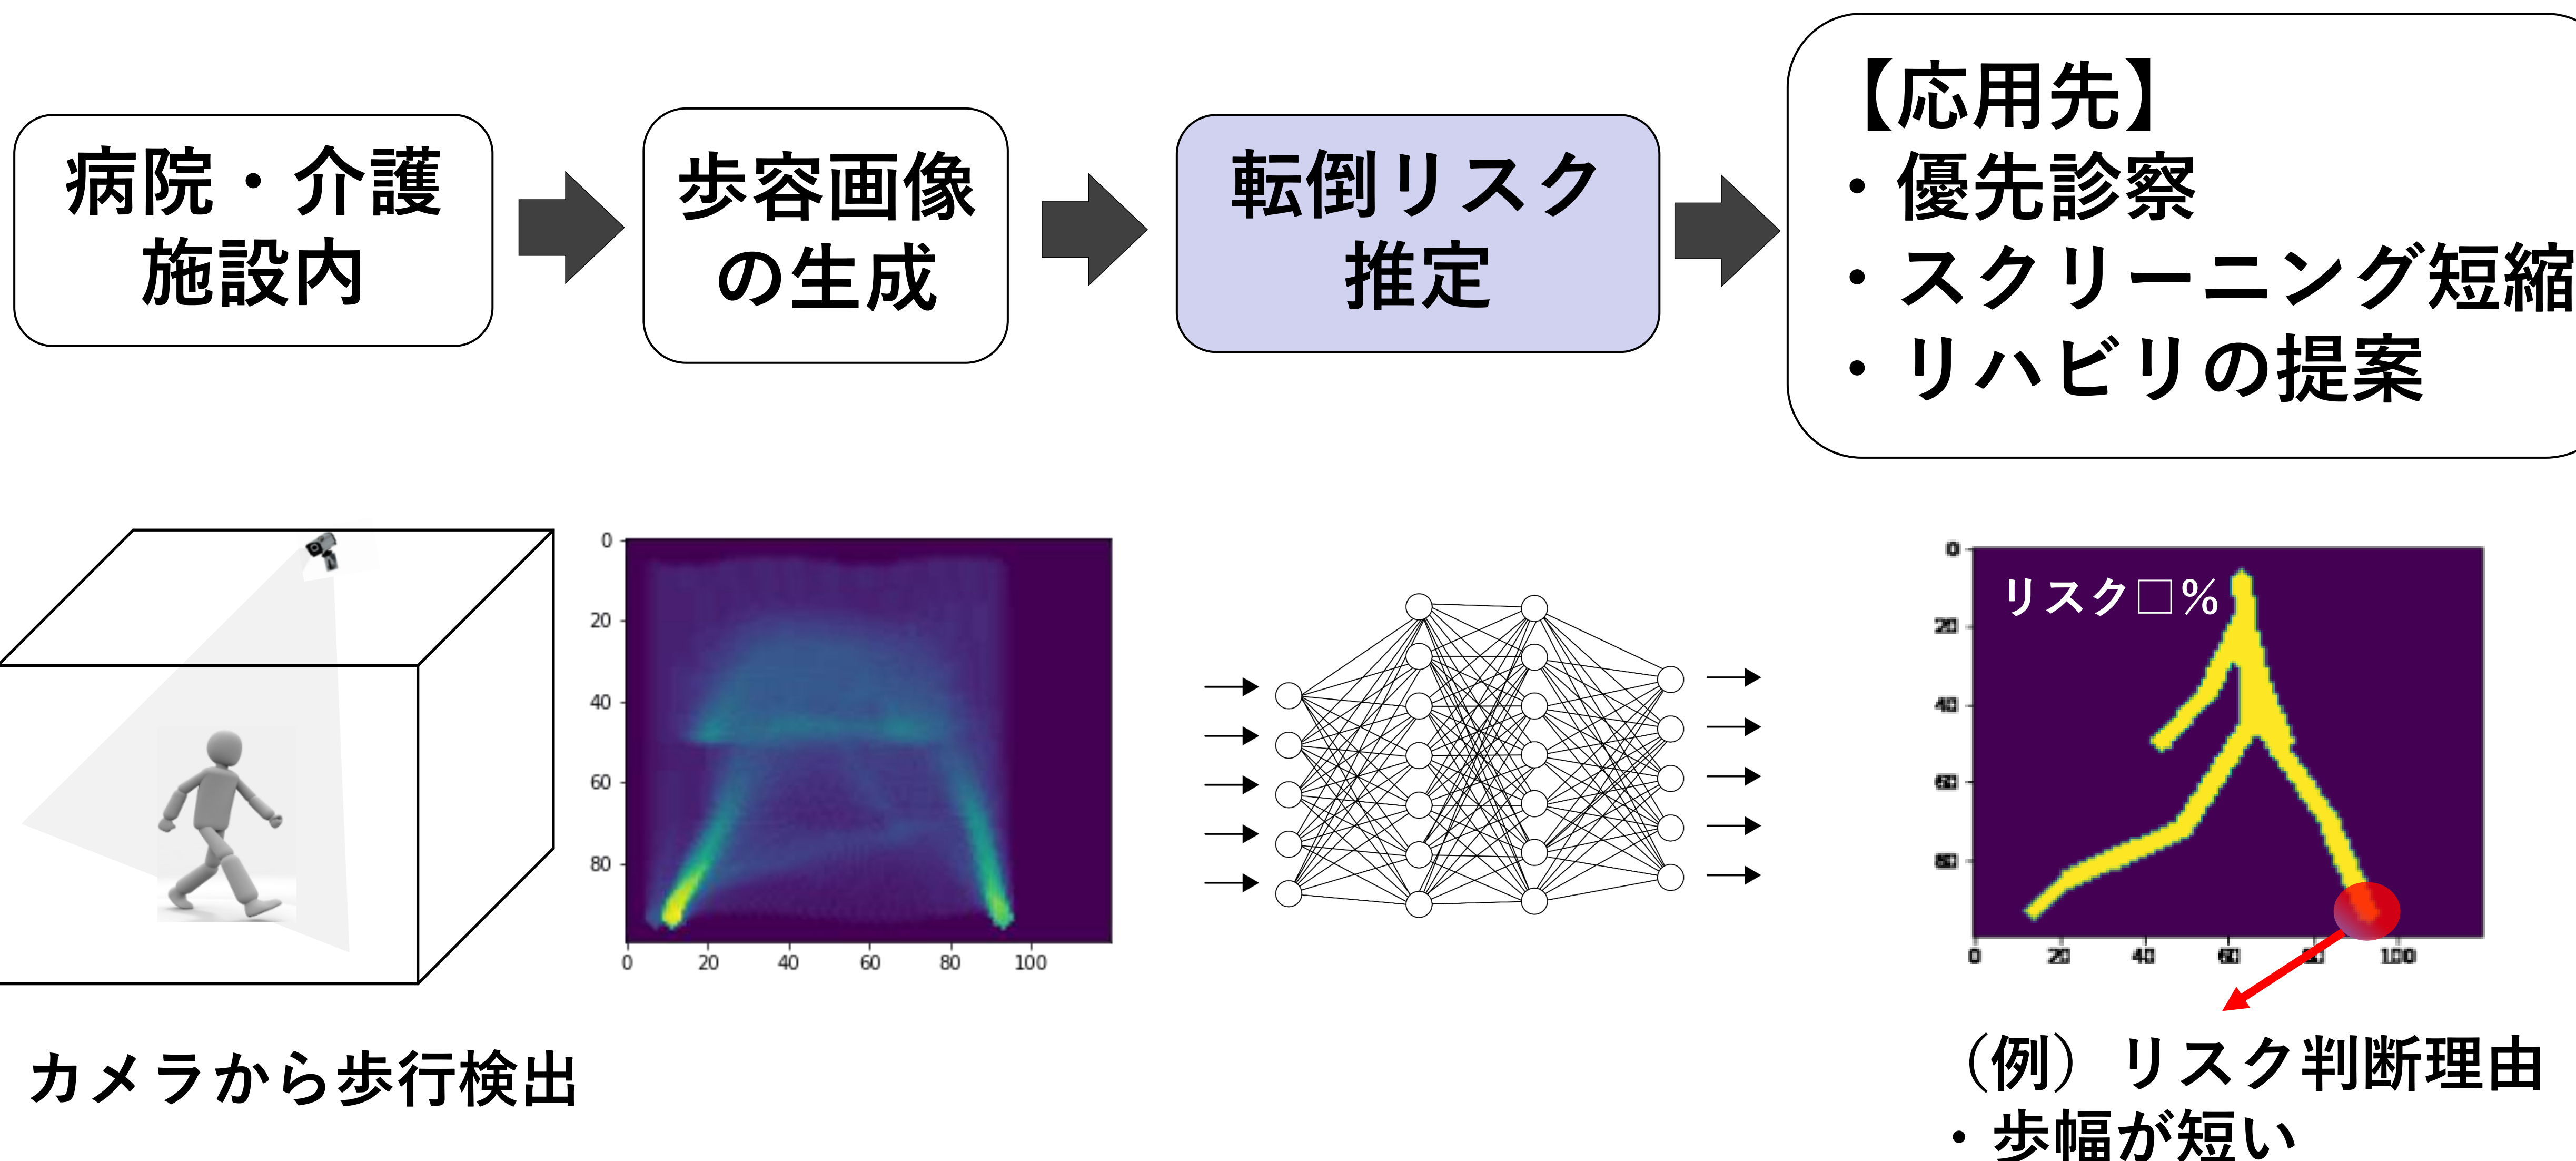
- ・65歳以上の約30%は転倒を経験しており, リスクの段階で検出し介入につなげることが必要
- ・センサ装着の煩わしさや医療・介護現場の人手不足から, 非接触で即時的な評価方法の検討が必要
- ・従来研究から歩容画像を入力とした機械学習技術により年齢や性別を高精度に推定可



1 歩行周期の歩容画像から転倒リスクが推定できる可能性

### アプリケーションイメージ

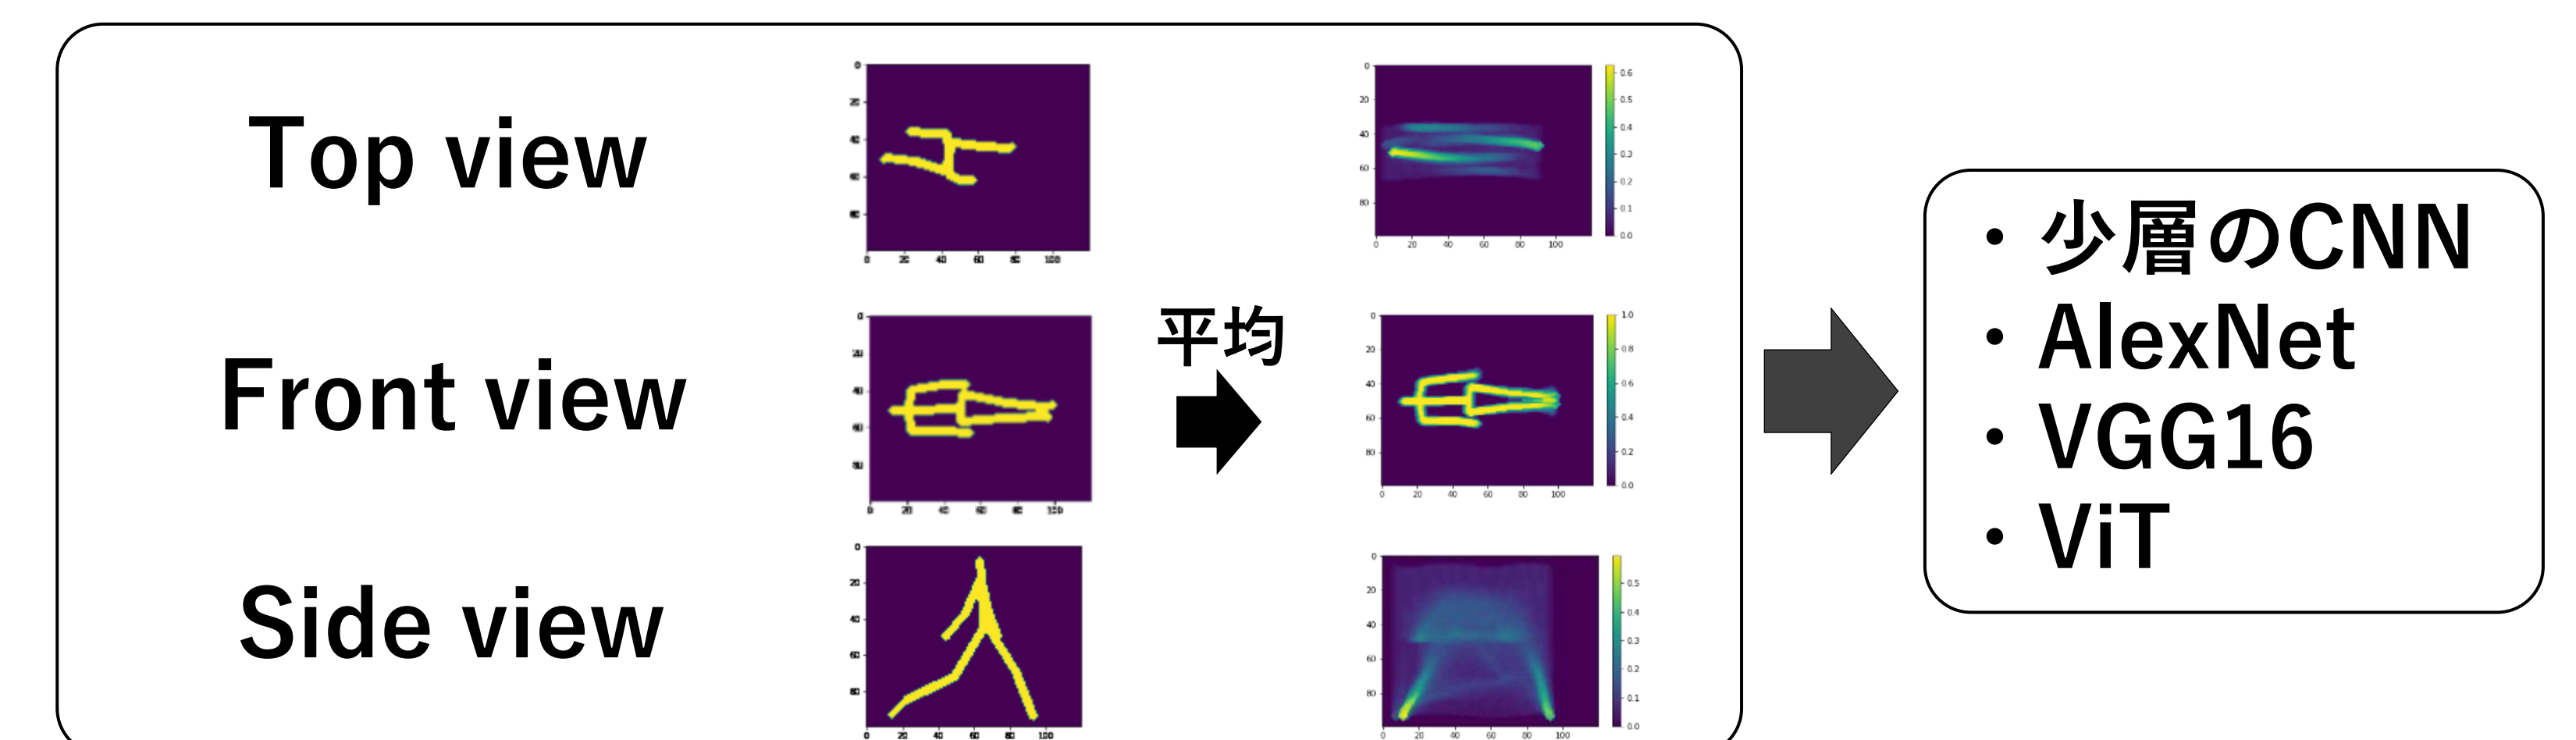
- ・単眼カメラを病院や介護施設に設置することを想定し, 歩容画像から転倒リスクを評価
- ・転倒リスクモデルの判断要因を可視化することで, 歩行機能の評価も可能



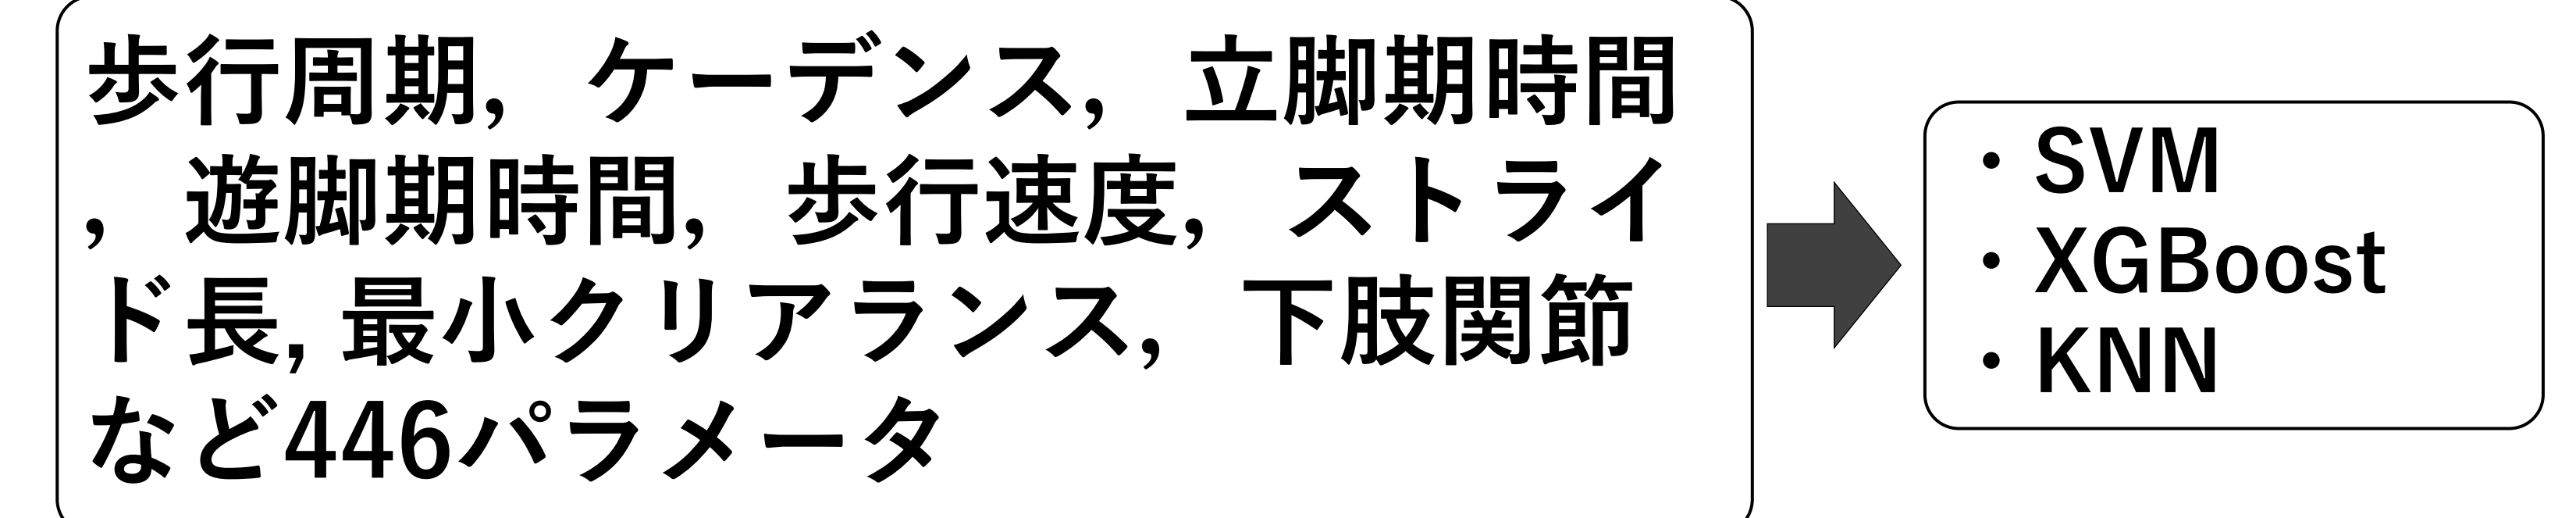
### 方法

- ・被験者80名 (うち転倒経験者45名)
- ・モーションキャプチャを利用し歩行データを計測
- ・3つの入力データを比較


#### 1. 平均歩容画像



#### 2. 歩行パラメータ



#### 3. 時系列データ



### 結果

- ・歩容画像を入力とした6層のCNNが最も精度が高い結果
- ・歩幅が転倒リスクの判断根拠になりうる

#### モデルの結果

Model	AUC
SVM	0.60 ± 0.12
KNN	0.54 ± 0.10
XGBoost	0.60 ± 0.10
LSTM	0.53 ± 0.08
5 layers	0.66 ± 0.12
<b>6 layers</b>	<b>0.67 ± 0.13</b>
7 layers	0.62 ± 0.13
AlexNet	0.61 ± 0.12
VGG16	0.66 ± 0.13
ViT	0.60 ± 0.11

#### 入力画像を変えた6層CNN結果

Input	AUC
Top view	0.59 ± 0.12
Front view	0.59 ± 0.12
Side view	0.67 ± 0.11
Side view of upper body	0.62 ± 0.01
<b>Side view of lower body</b>	<b>0.70 ± 0.11</b>

