

PERCLOSと車両の操作情報に基づく ドライバ眠気推定における Optunaと時系列解析を用いた 推論モデルの精度比較

日本大学文理学部情報科学科 卒業演習発表(令和6年2月7日)

谷聖一研究室 青木拓海 安齋陸

1. はじめに

- 1.1 動機
- 1.2 先行研究
- 1.3 演習目的

2. 準備

- 2.1 機械学習とは
- 2.2 学習方法とモデル
- 2.3 学習アルゴリズム
- 2.4 Optunaとは
- 2.5 時系列解析とは

3. 演習

- 3.1 演習環境
- 3.2 演習方法
- 3.3 演習結果

4. まとめ

- 4.1 考察
- 4.2 今後の課題

1. はじめに

- 1.1 動機
- 1.2 先行研究
- 1.3 演習目的

2. 準備

- 2.1 機械学習とは
- 2.2 学習方法とモデル
- 2.3 学習アルゴリズム
- 2.4 Optunaとは
- 2.5 時系列解析とは

3. 演習

- 3.1 演習環境
- 3.2 演習方法
- 3.3 演習結果

4. まとめ

- 4.1 考察
- 4.2 今後の課題

1.1 動機

社会背景

漫然運転(睡眠不足や疲労)が原因の死亡事故が最多

↳原付以上運転者の事故類型別・法令違反別死亡事故件数¹



ドライバの眠気状態の認識や注意喚起を行う研究が行われている

1.2 先行研究

簡易なドライビングシミュレータを用いたPERCLOSと車両の操作情報によるドライバ眠気推定 [2021]

村上 雅彦*, 北村 翼*, 松原 大*, 南 基大*, 鈴木 隆元* *エイチアイ

PERCLOSと車両の操作情報を用いたドライバ眠気推定における推論モデルとデータ分割方法による推論精度の比較 [2023]

宮本 亨紀, 谷 聖一, 村上 雅彦

Subjective and objective sleepiness in the active individual [1990]

Torbjörn Åkerstedt, Mats Gillberg

自動車運転時の眠気の予測手法についての研究：第1報, 眠気表情の評定法と眠気変動の予測に有効な指標について [1997]

北島 洋樹, 沼田 仲穂, 山本 恵一, 五井 美博

1.2 先行研究

簡易なドライビングシミュレータを用いたPERCLOSと車両の操作情報によるドライバ眠気推定 [2021]

村上 雅彦*, 北村 翼*, 松原 大*, 南 基大*, 鈴木 隆元* *エイチアイ

PERCLOSと車両の操作情報を用いたドライバ眠気推定における推論モデルとデータ分割方法による推論精度の比較 [2023]

宮本 亨紀, 谷 聖一, 村上 雅彦

Subjective and objective sleepiness in the active individual [1990]

Torbjörn Åkerstedt, Mats Gillberg

自動車運転時の眠気の予測手法についての研究：第1報,
眠気表情の評定法と眠気変動の予測に有効な指標について [1997]

北島 洋樹, 沼田 仲穂, 山本 恵一, 五井 美博

1.2 先行研究

先行研究との比較

		先行研究[2021]	先行研究[2023]	今回の演習
モデル		線形回帰 ニューラルネットワーク	LightGBM 線形回帰 ニューラルネットワーク	LightGBM ニューラルネットワーク LSTM ARIMA
分割方法	α	✓	✓	
	β		✓	
	γ		✓	
	δ			✓
	ε			✓
ハイパーパラメータ		デフォルト	デフォルト	最適化

1.2 先行研究

先行研究との比較

		先行研究[2021]	先行研究[2023]	今回の演習
モデル		線形回帰 ニューラルネットワーク	LightGBM 線形回帰 ニューラルネットワーク	LightGBM ニューラルネットワーク LSTM ARIMA
分割方法	α	✓	✓	
	β		✓	
	γ		✓	
	δ			✓
	ε			✓
ハイパーパラメータ		デフォルト	デフォルト	最適化

1.3 演習目的

ハイパーパラメータ最適化

↳機械学習アルゴリズムの挙動を制御するパラメータを指し
学習性能に大きく関係する

時系列解析

↳時間の経過順に並んだデータを元に長期的傾向や周期的変動に対し
将来の値を予測するもの



予測精度向上を目指す

1. はじめに

- 1.1 動機
- 1.2 先行研究
- 1.3 演習目的

2. 準備

- 2.1 機械学習とは
- 2.2 学習方法とモデル
- 2.3 学習アルゴリズム
- 2.4 Optunaとは
- 2.5 時系列解析とは

3. 演習

- 3.1 演習環境
- 3.2 演習方法
- 3.3 演習結果

4. まとめ

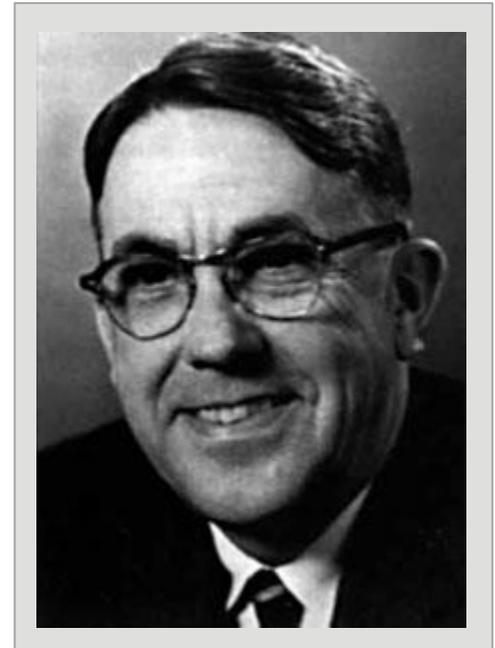
- 4.1 考察
- 4.2 今後の課題

2.1 機械学習とは

機械学習

↳ 明示的にプログラムしなくても学習する能力を
コンピュータに与える研究分野

Arthur Samuel (1959)



2.2 学習方法とモデル

教師あり学習

↳ 入力データに正解を加えた状態で学習させ
新たな入力データに対し出力データを得るためのもの

教師なし学習

↳ 入力データに正解を加えない状態で学習させ
データの背景にある隠れたパターンや構造を見つけ出すもの

強化学習

↳ どのような行動を取れば
最大限の利益が得られるかを学習する（囲碁やチェスなど）

2.2 学習方法とモデル

教師あり学習

↳ 入力データに正解を加えた状態で学習させ
新たな入力データに対し出力データを得るためのもの

教師なし学習

↳ 入力データに正解を加えない状態で学習させ
データの背景にある隠れたパターンや構造を見つけ出すもの

強化学習

↳ どのような行動を取れば
最大限の利益が得られるかを学習する（囲碁やチェスなど）

2.2 学習方法とモデル

教師あり学習

↳ 入力データに正解を加えた状態で学習させ
新たな入力データに対し出力データを得るためのもの

教師なし学習

↳ 入力データに正解を加えない状態で学習させ
データの背景にある隠れたパターンや構造を見つけ出すもの

強化学習

↳ どのような行動を取れば
最大限の利益が得られるかを学習する（囲碁やチェスなど）

2.2 学習方法とモデル

教師あり学習

↳ 入力データに正解を加えた状態で学習させ
新たな入力データに対し出力データを得るためのもの

教師なし学習

↳ 入力データに正解を加えない状態で学習させ
データの背景にある隠れたパターンや構造を見つけ出すもの

強化学習

↳ どのような行動を取れば
最大限の利益が得られるかを学習する（囲碁やチェスなど）

2.2 学習方法とモデル

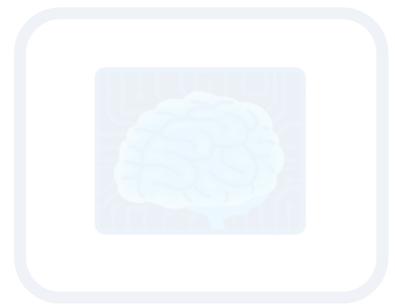
教師あり学習

↳ 入力データに**正解**を加えた状態で学習させ
新たな入力データに対し出力データを得るためのもの

学習データ



モデル

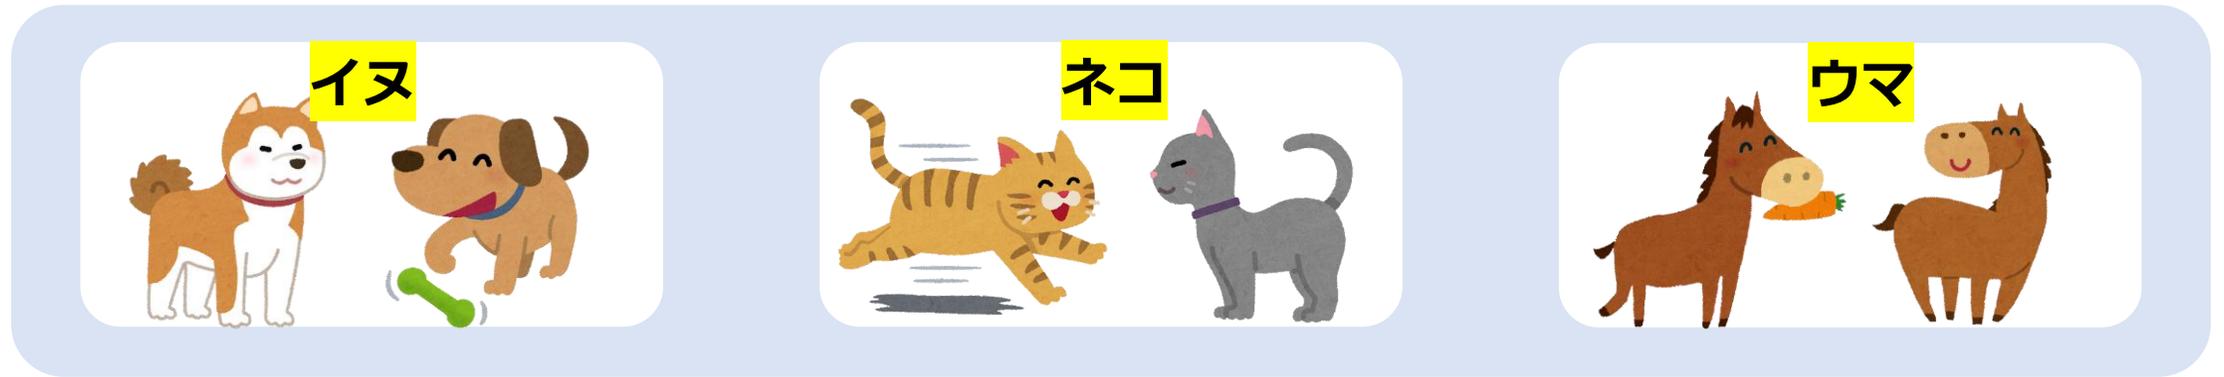


2.2 学習方法とモデル

教師あり学習

↳ 入力データに**正解**を加えた状態で学習させ
新たな入力データに対し出力データを得るためのもの

学習データ



モデル

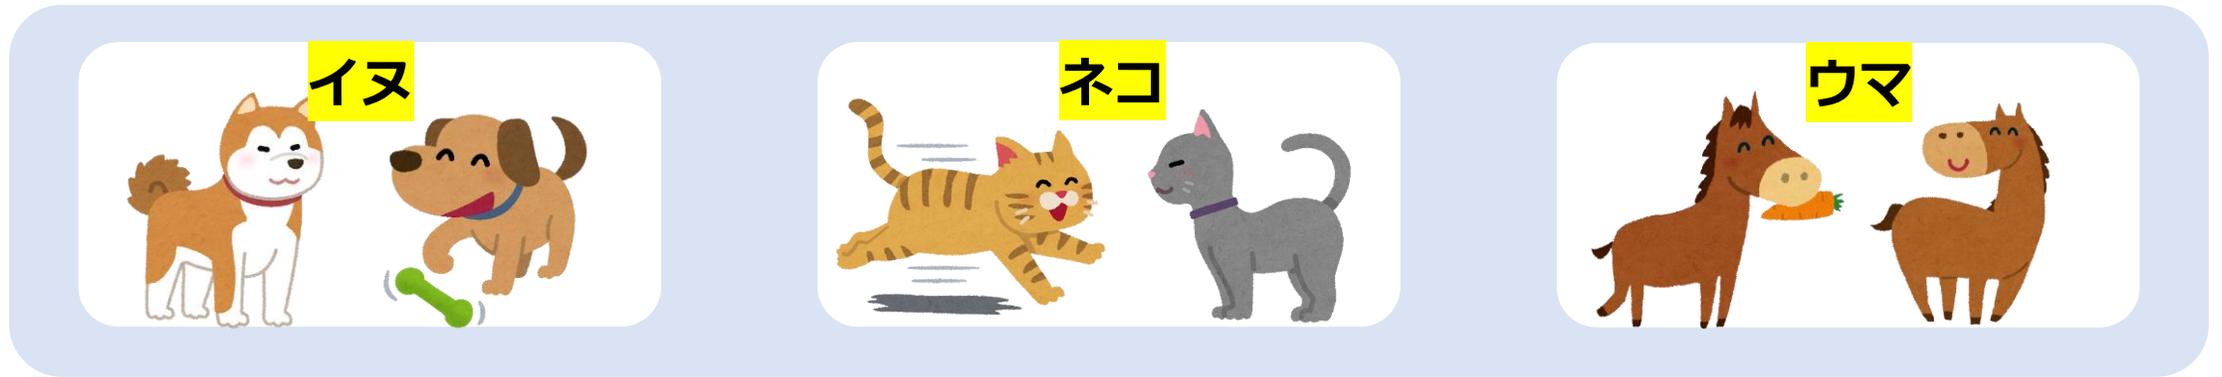


2.2 学習方法とモデル

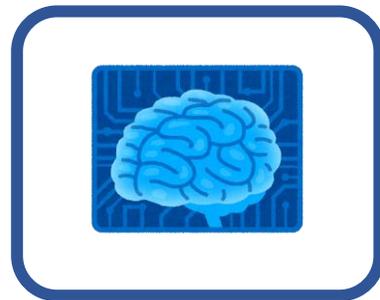
モデルとは

↳ 入力したデータに対する出力（回答）を導き出す仕組みのこと

学習データ



モデル



2.2 学習方法とモデル

教師あり学習

↳ 入力データに**正解**を加えた状態で学習させ
新たな入力データに対し出力データを得るためのもの

学習データ



入力



モデル



出力



2.3 学習アルゴリズム

LightGBM

↳ 勾配ブースティングを用いた決定木による機械学習の手法

誤差逆伝播法

↳ 出力と正解の誤差から出力が正解に近づくようにパラメータ調整するニューラルネットワークのアルゴリズム

LSTM(Long Short-Term Memory)

↳ 長期的な依存関係を学習することのできるRNNの一種

ARIMA(Auto Regressive Integrated Moving Average)

↳ 統計的特性が時間的に変動する時系列に有効な手法の一つ

2.3 学習アルゴリズム

LightGBM

↳勾配ブースティングを用いた決定木による機械学習の手法

誤差逆伝播法

↳出力と正解の誤差から出力が正解に近づくようにパラメータ調整するニューラルネットワークのアルゴリズム

LSTM(Long Short-Term Memory)

↳長期的な依存関係を学習することのできるRNNの一種

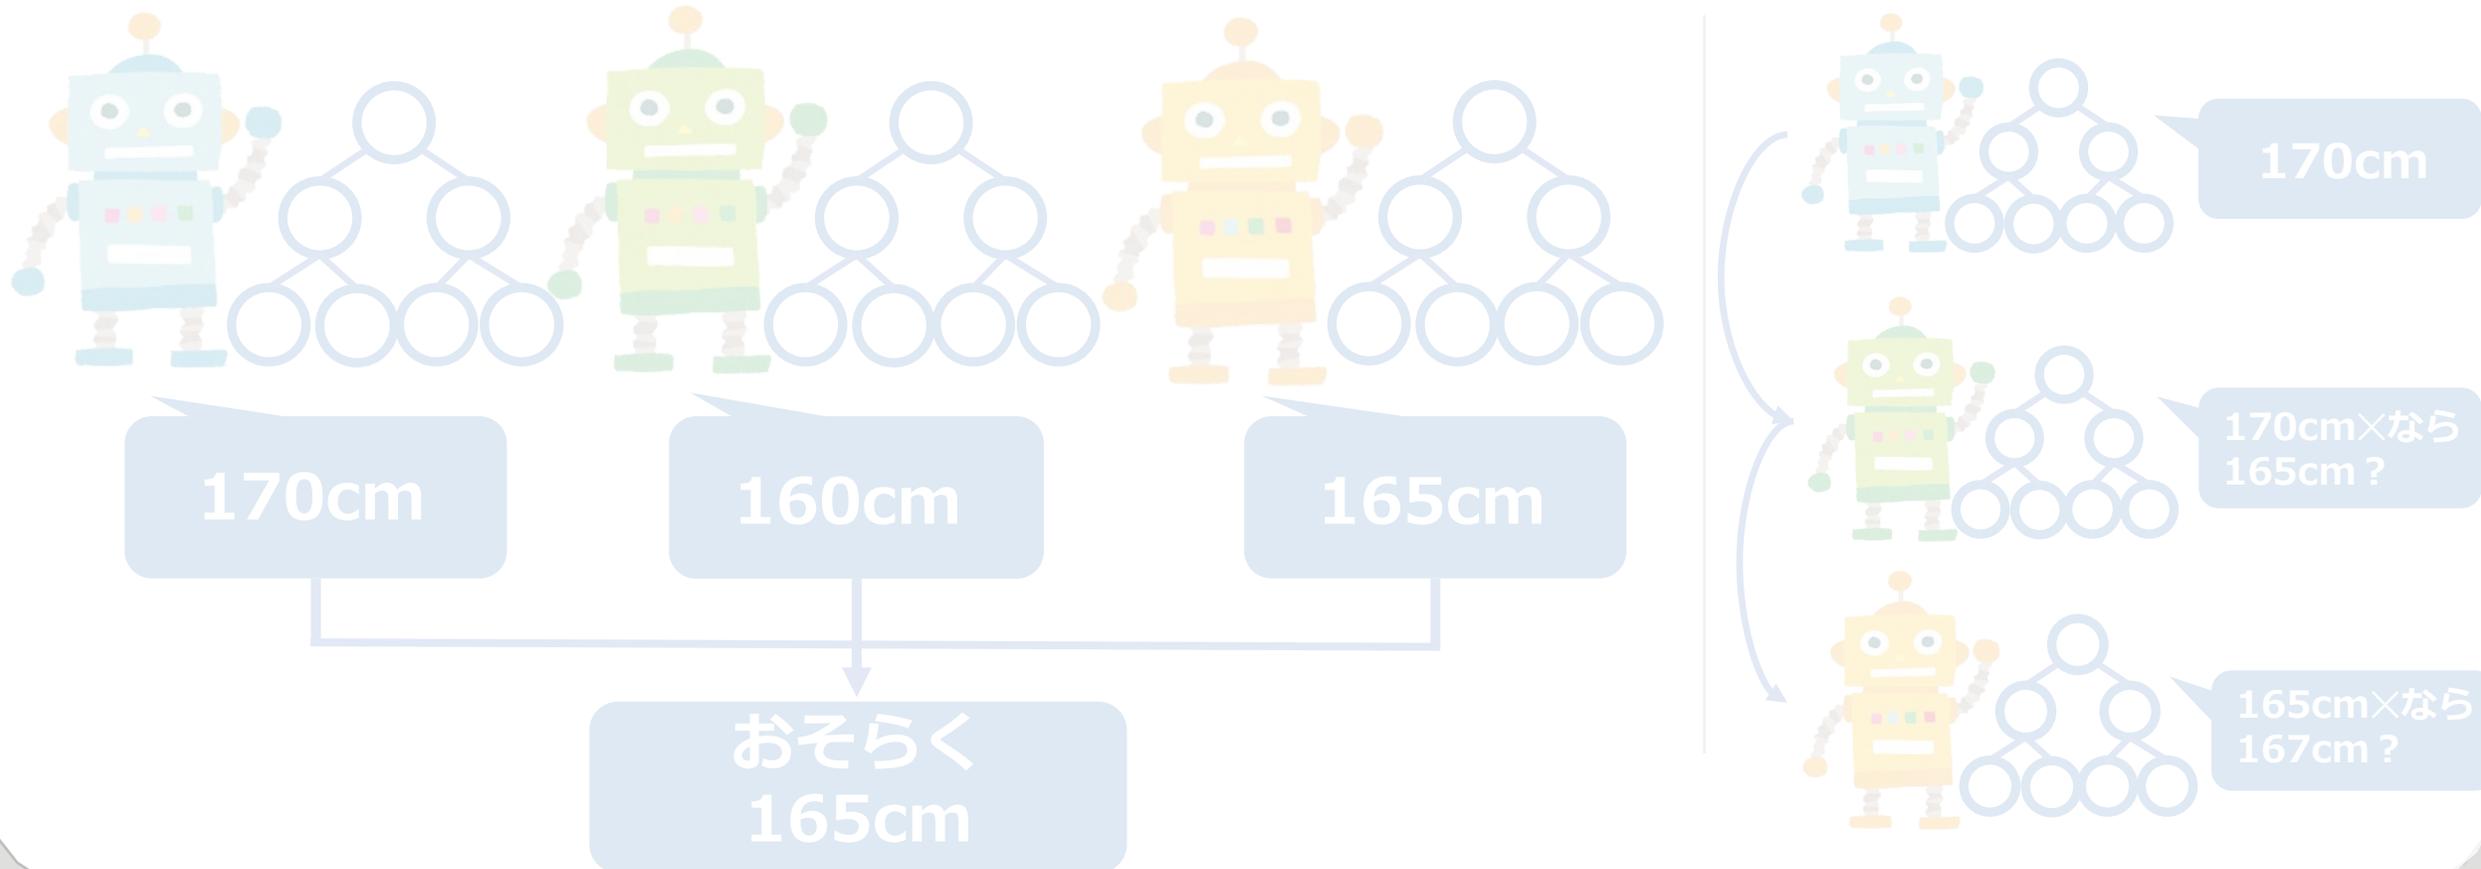
ARIMA(Auto Regressive Integrated Moving Average)

↳統計的特性が時間的に変動する時系列に有効な手法の一つ

2.3 学習アルゴリズム

LightGBM

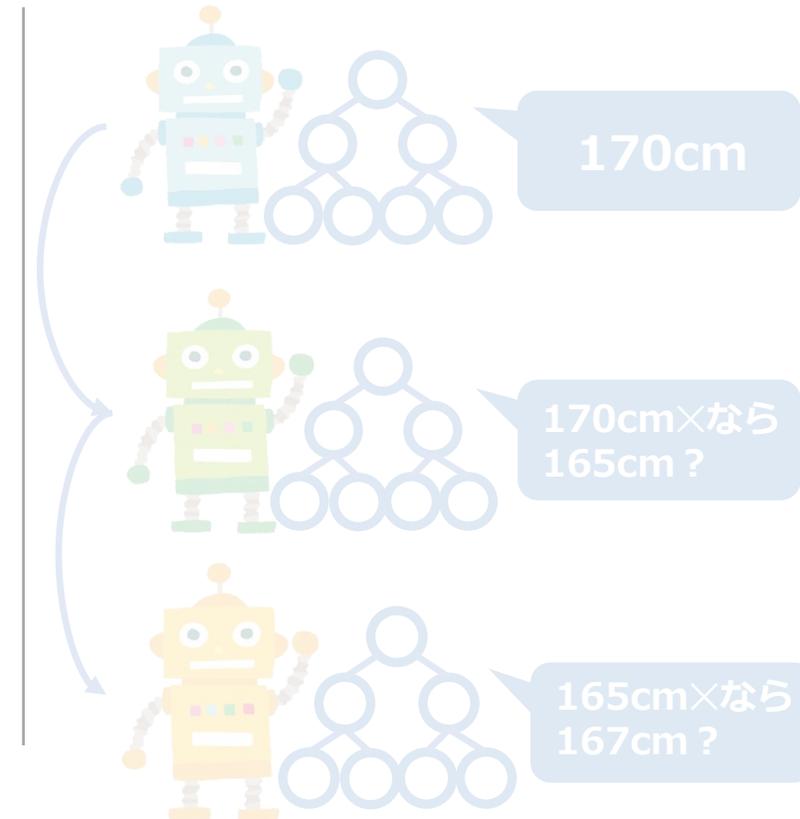
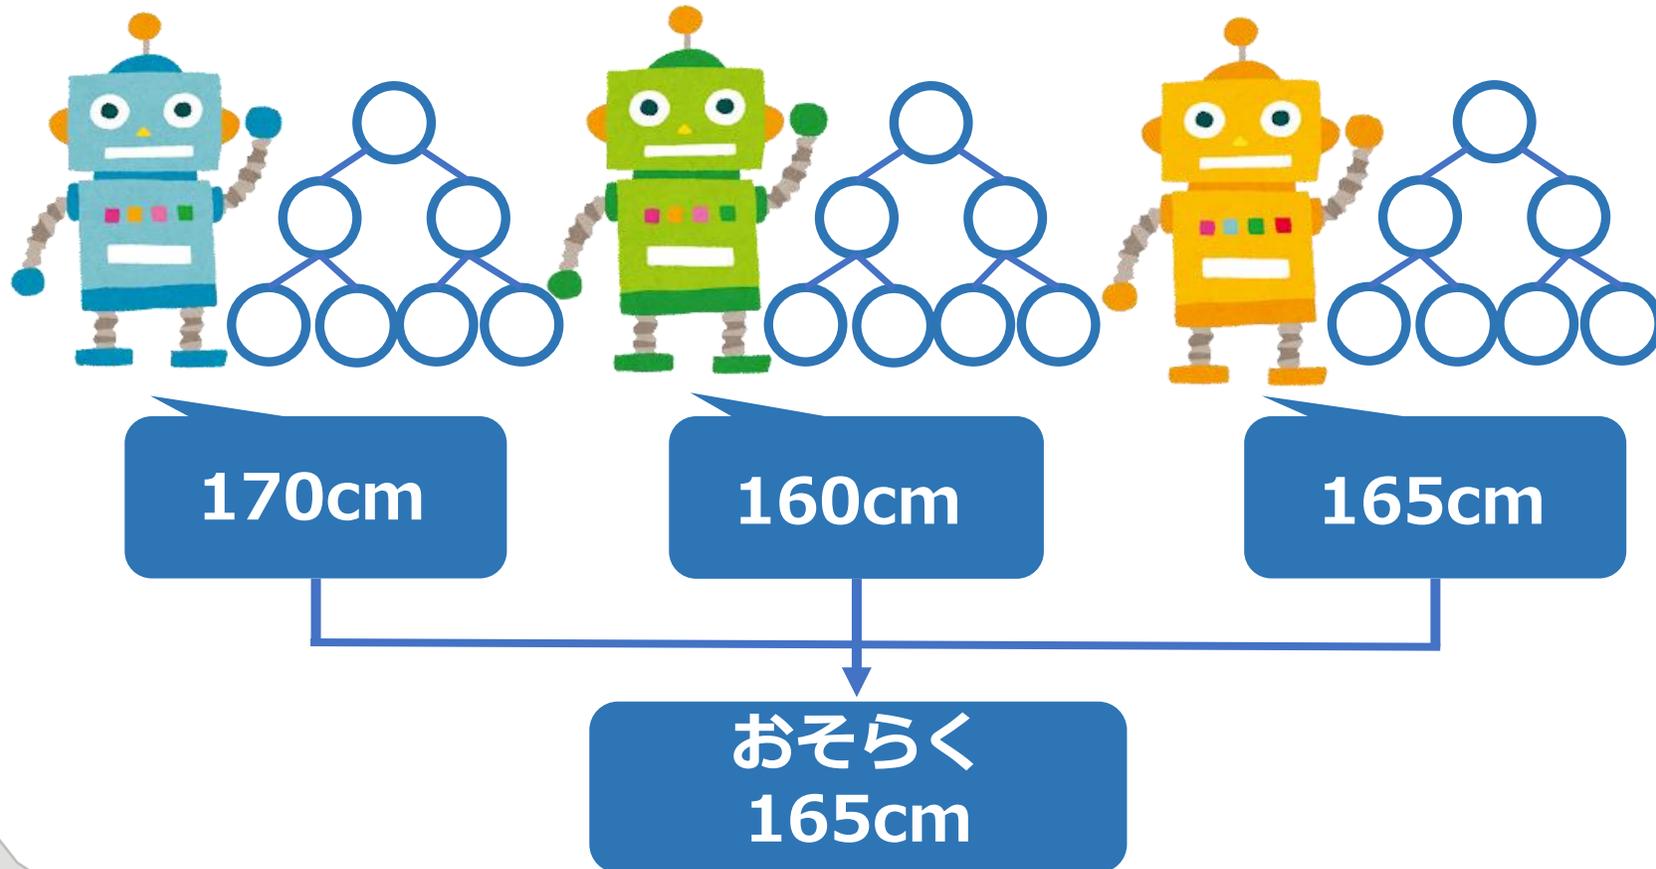
↳ マイクロソフトによって2016年頃に開発
勾配ブースティングを用いた決定木による機械学習の手法



2.3 学習アルゴリズム

LightGBM

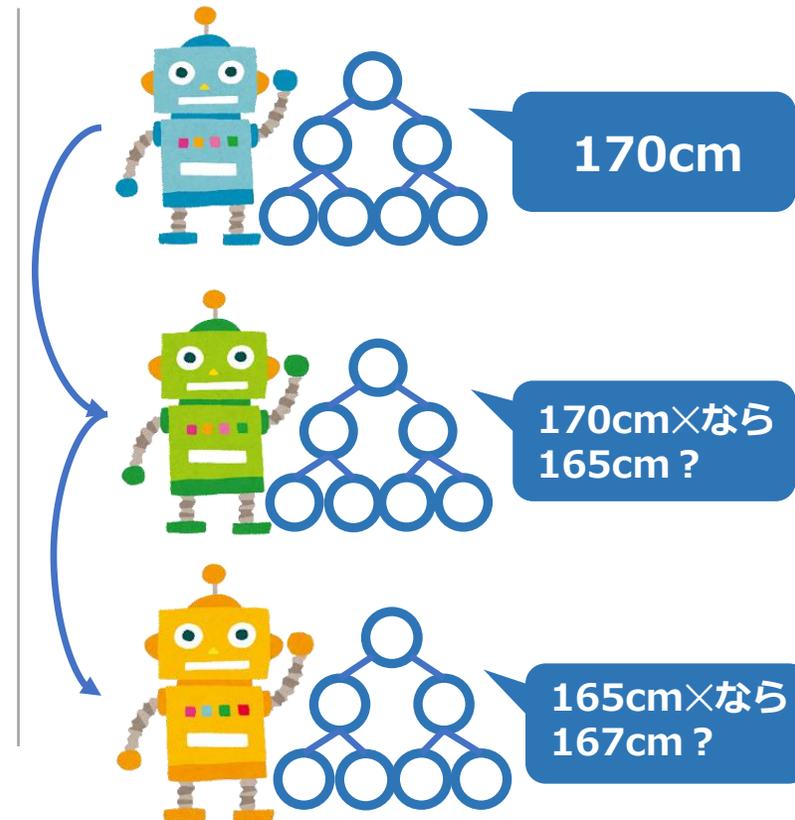
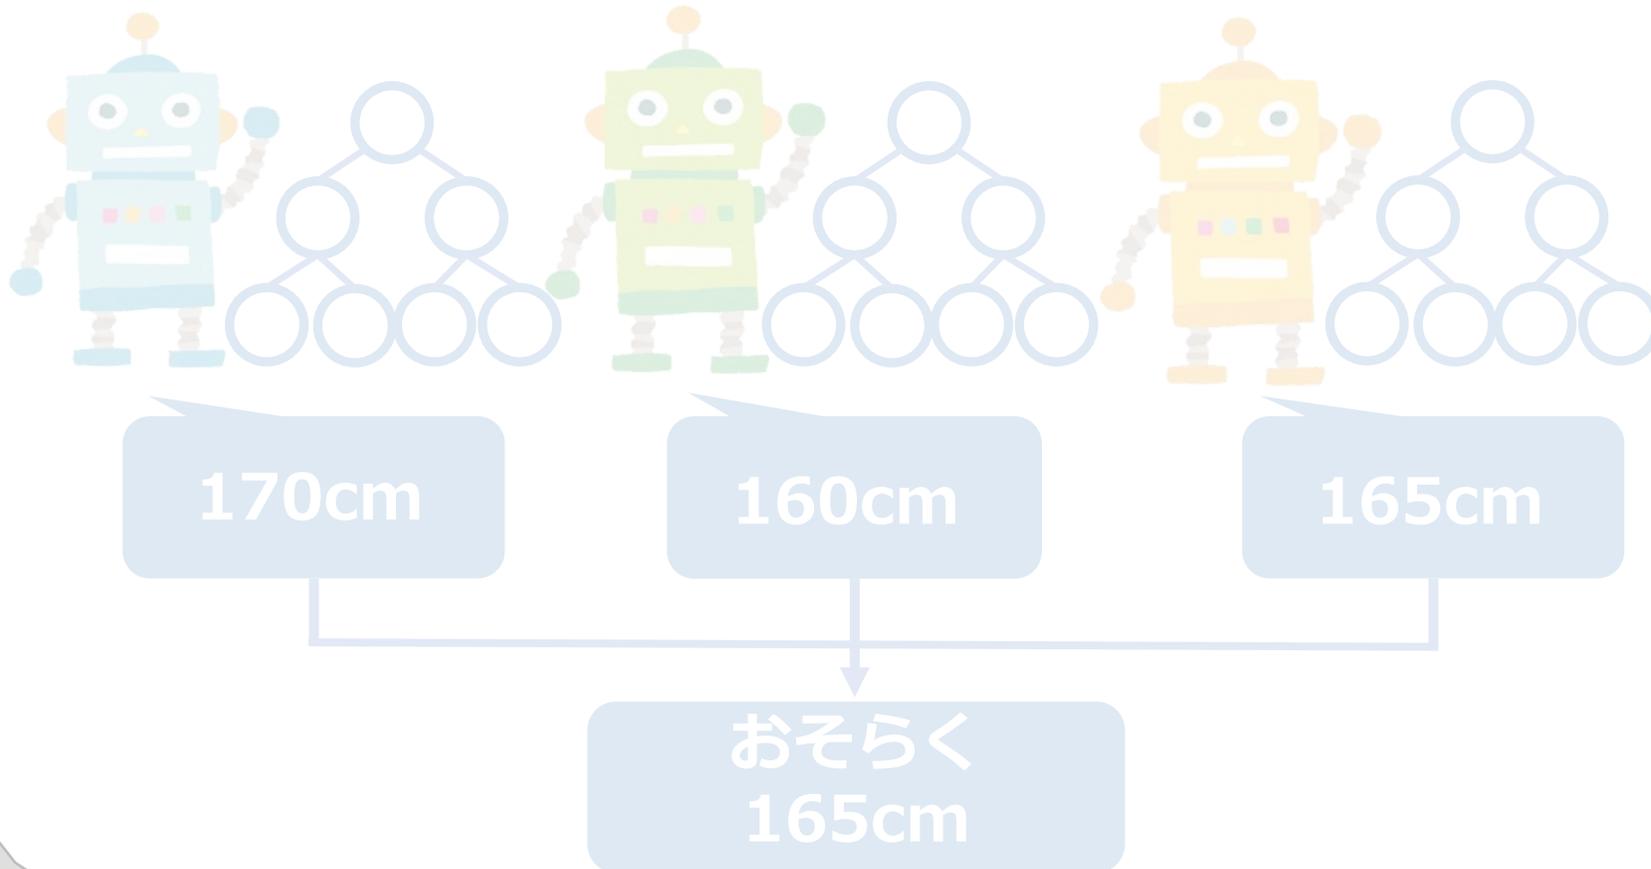
↳ マイクロソフトによって2016年頃に開発
勾配ブースティングを用いた決定木による機械学習の手法



2.3 学習アルゴリズム

LightGBM

↳ マイクロソフトによって2016年頃に開発
勾配ブースティングを用いた決定木による機械学習の手法



2.3 学習アルゴリズム

LightGBM

↳勾配ブースティングを用いた決定木による機械学習の手法

誤差逆伝播法

↳出力と正解の誤差から出力が正解に近づくようにハイパーパラメータを調整するニューラルネットワークのアルゴリズム

LSTM(Long Short-Term Memory)

↳長期的な依存関係を学習することのできるRNNの一種

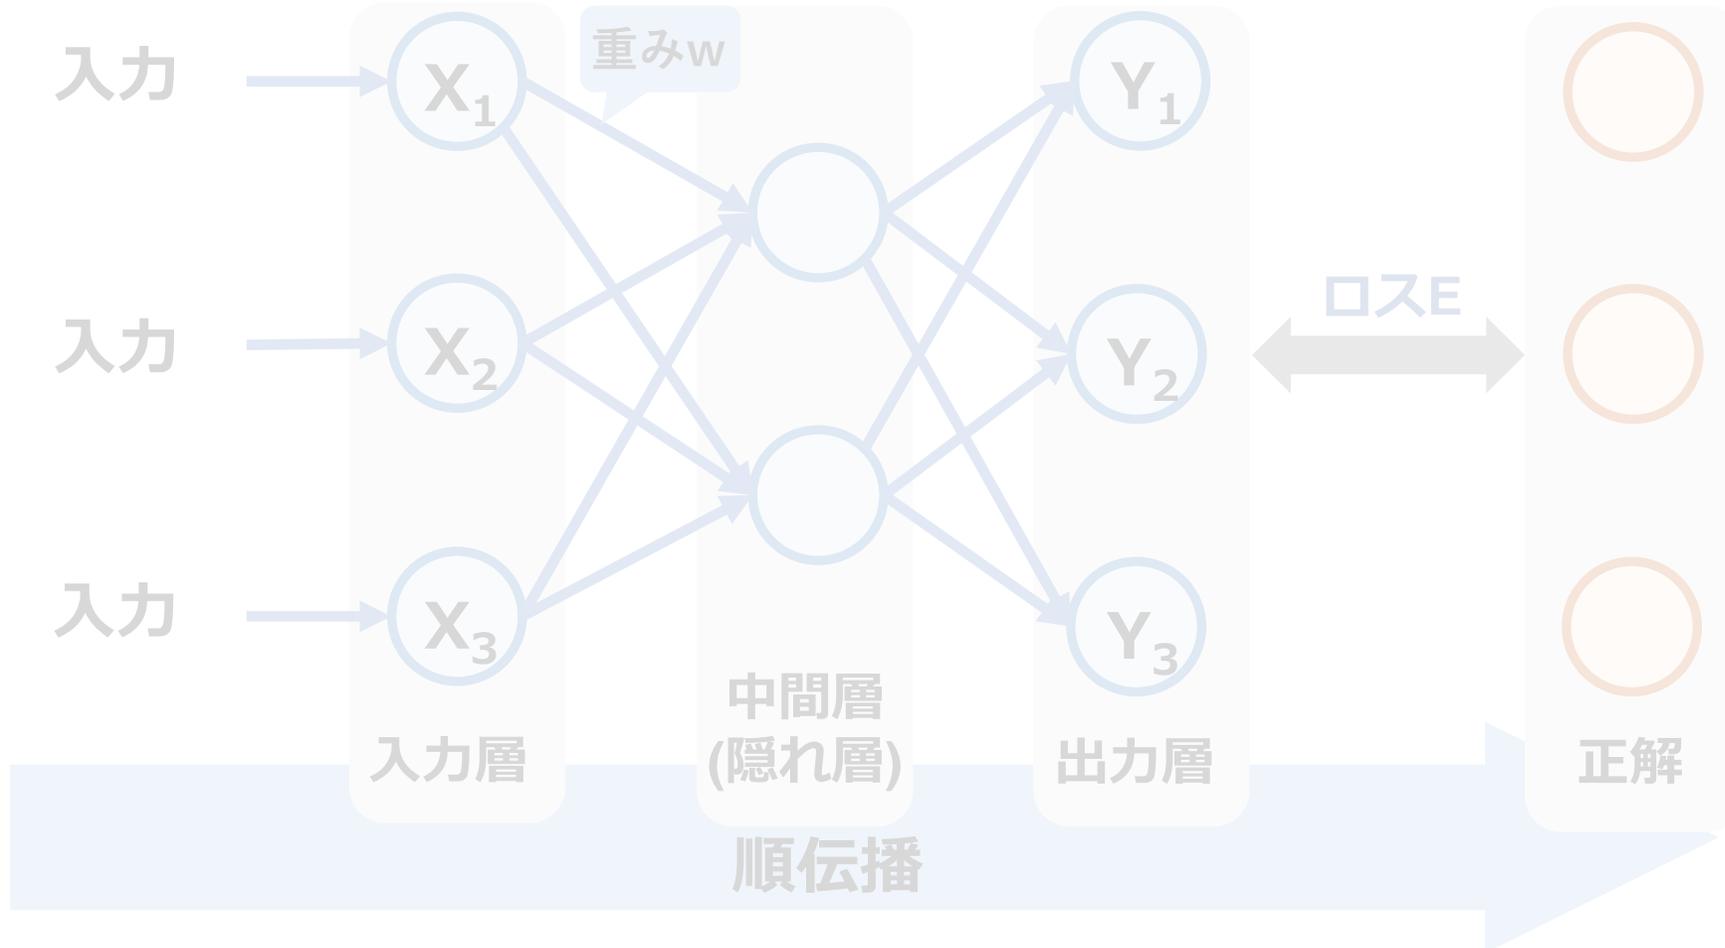
ARIMA(Auto Regressive Integrated Moving Average)

↳統計的特性が時間的に変動する時系列に有効な手法の一つ

2.3 学習アルゴリズム

誤差逆伝播法

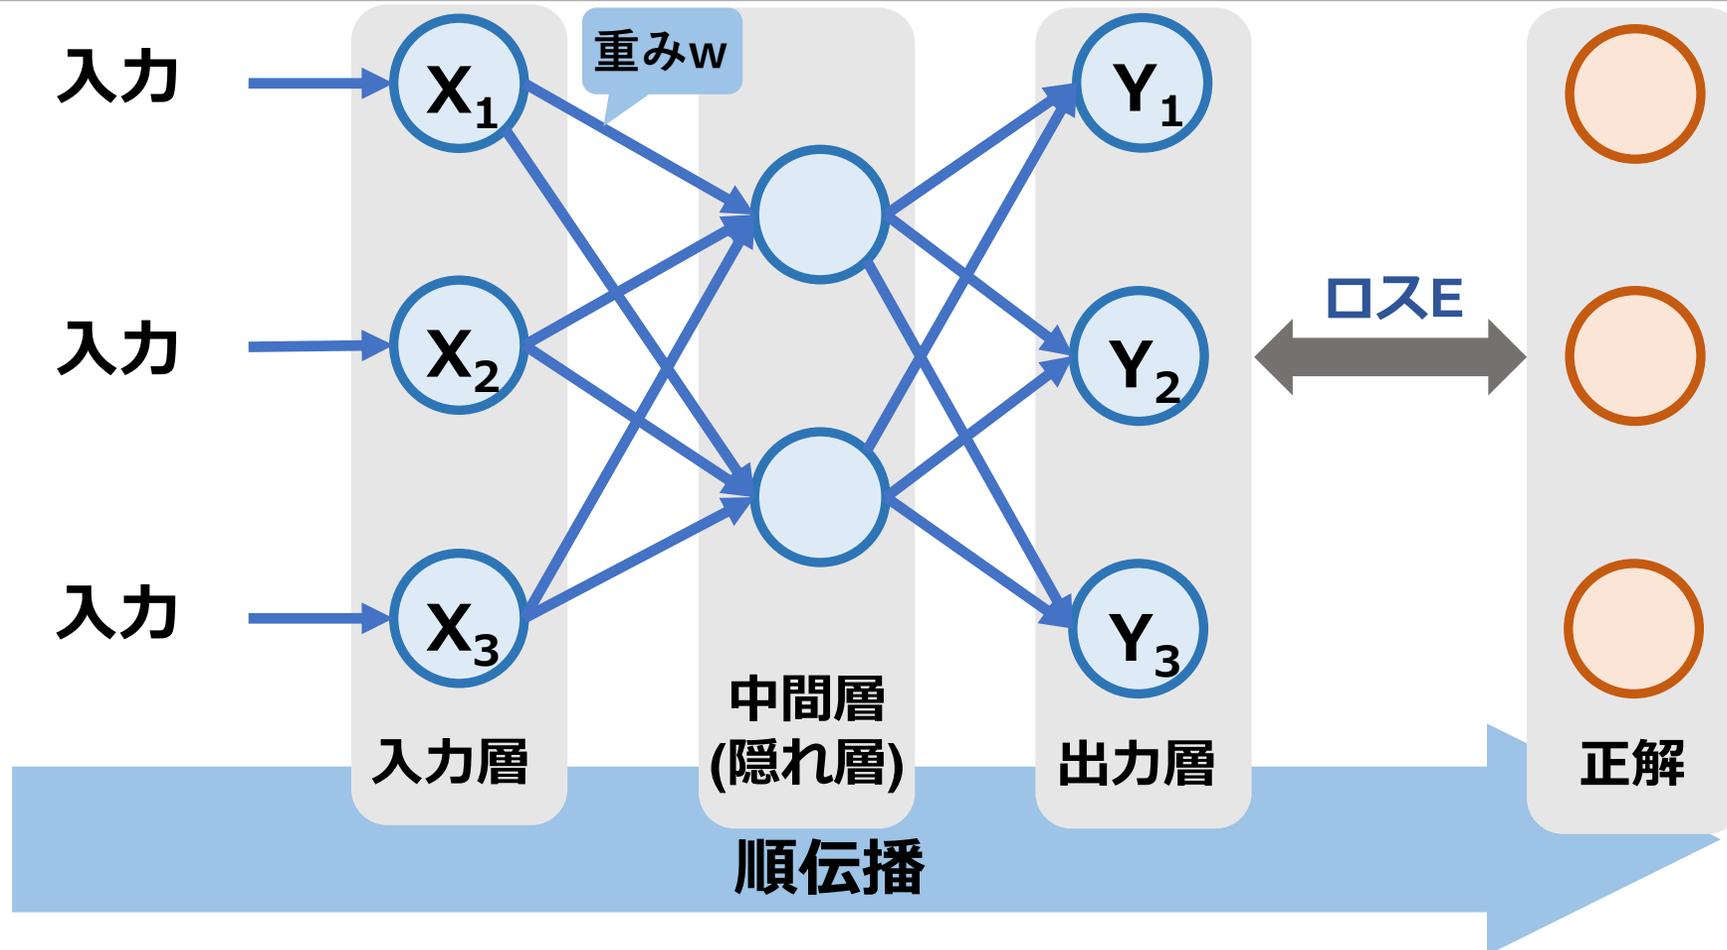
↳出力と正解の誤差から出力が正解に近づくようにハイパーパラメータを調整するニューラルネットワークのアルゴリズム



2.3 学習アルゴリズム

誤差逆伝播法

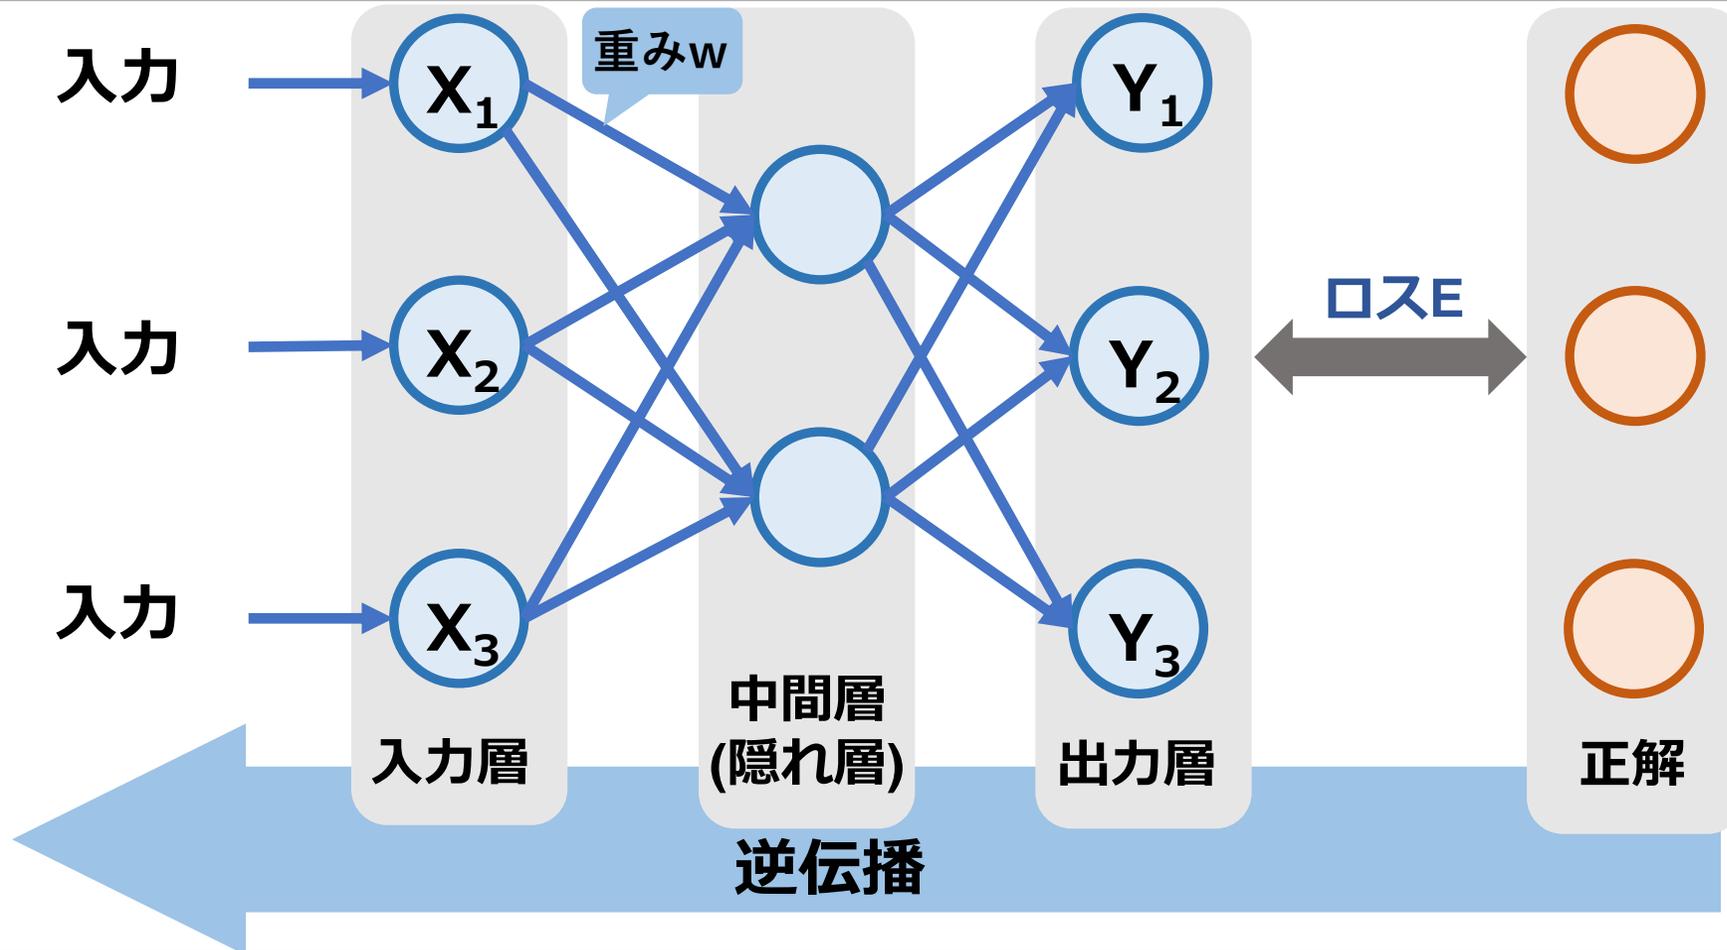
↳出力と正解の誤差から出力が正解に近づくようにパラメータ調整するニューラルネットワークのアルゴリズム



2.3 アルゴリズム

誤差逆伝播法

↳出力と正解の誤差から出力が正解に近づくようにパラメータ調整する
ニューラルネットワークのアルゴリズム



2.3 学習アルゴリズム

LightGBM

↳勾配ブースティングを用いた決定木による機械学習の手法

誤差逆伝播法

↳出力と正解の誤差から出力が正解に近づくようにパラメータ調整するニューラルネットワークのアルゴリズム

LSTM(Long Short-Term Memory)

↳長期的な依存関係を学習することのできるRNNの一種

ARIMA(Auto Regressive Integrated Moving Average)

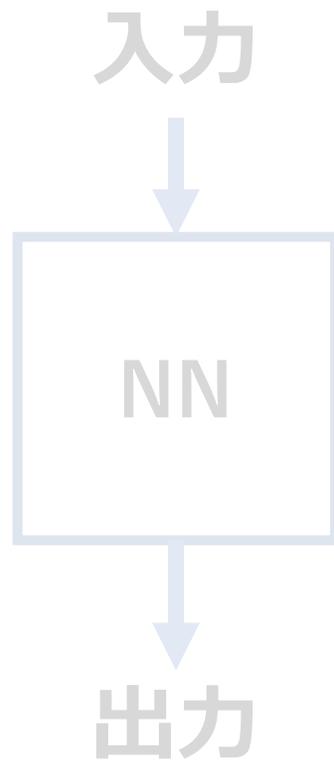
↳統計的特性が時間的に変動する時系列に有効な手法の一つ

2.3 学習アルゴリズム

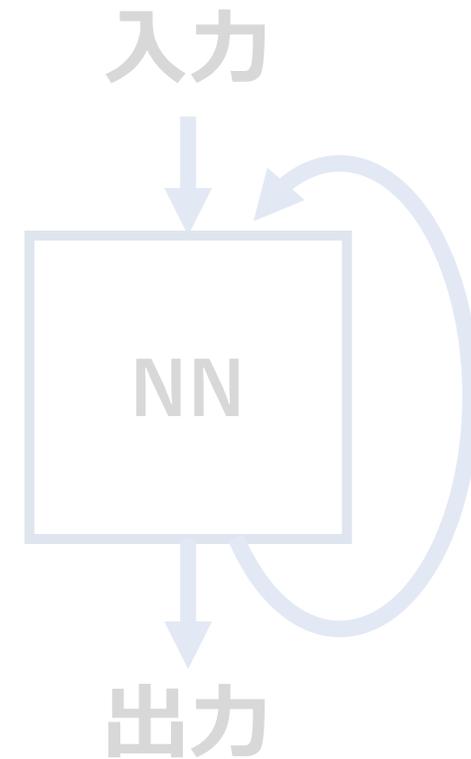
リカレントニューラルネットワーク

↳出力側から入力側へのフィードバックを持つニューラルネットワーク

FNN



RNN

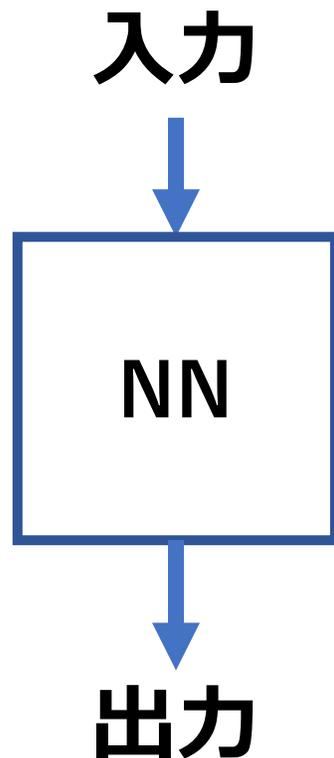


2.3 学習アルゴリズム

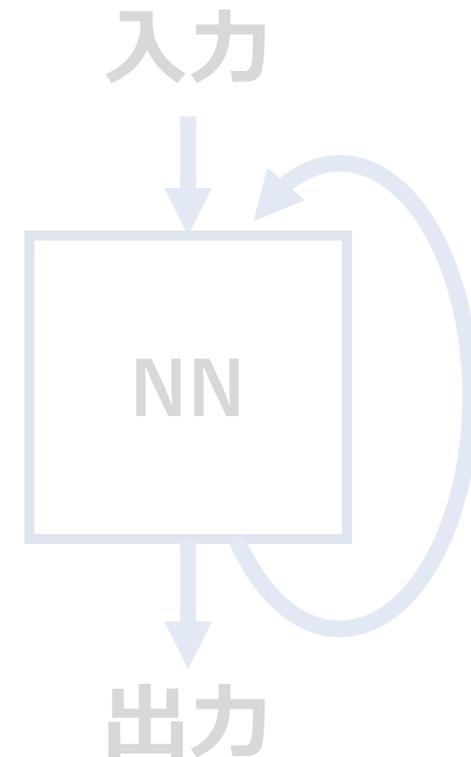
リカレントニューラルネットワーク

↳出力側から入力側へのフィードバックを持つニューラルネットワーク

FNN



RNN

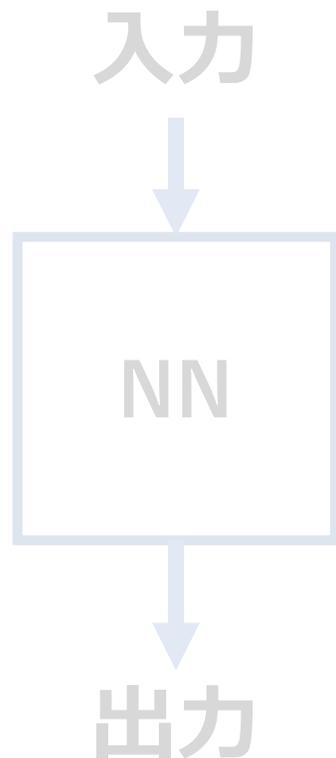


2.3 学習アルゴリズム

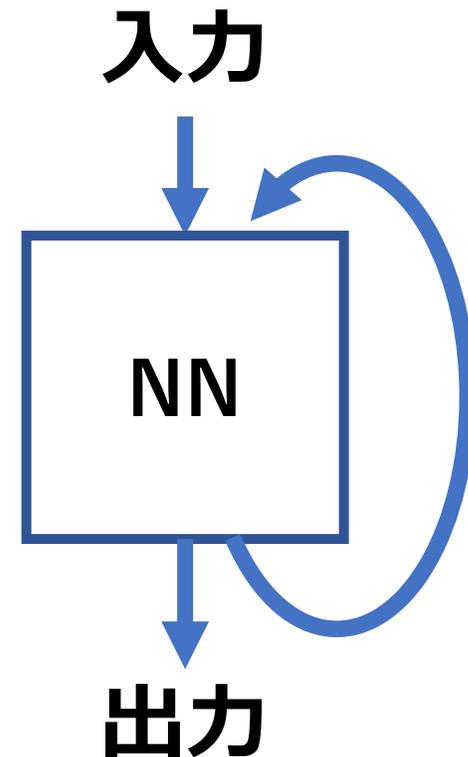
リカレントニューラルネットワーク

↳出力側から入力側へのフィードバックを持つニューラルネットワーク

FNN



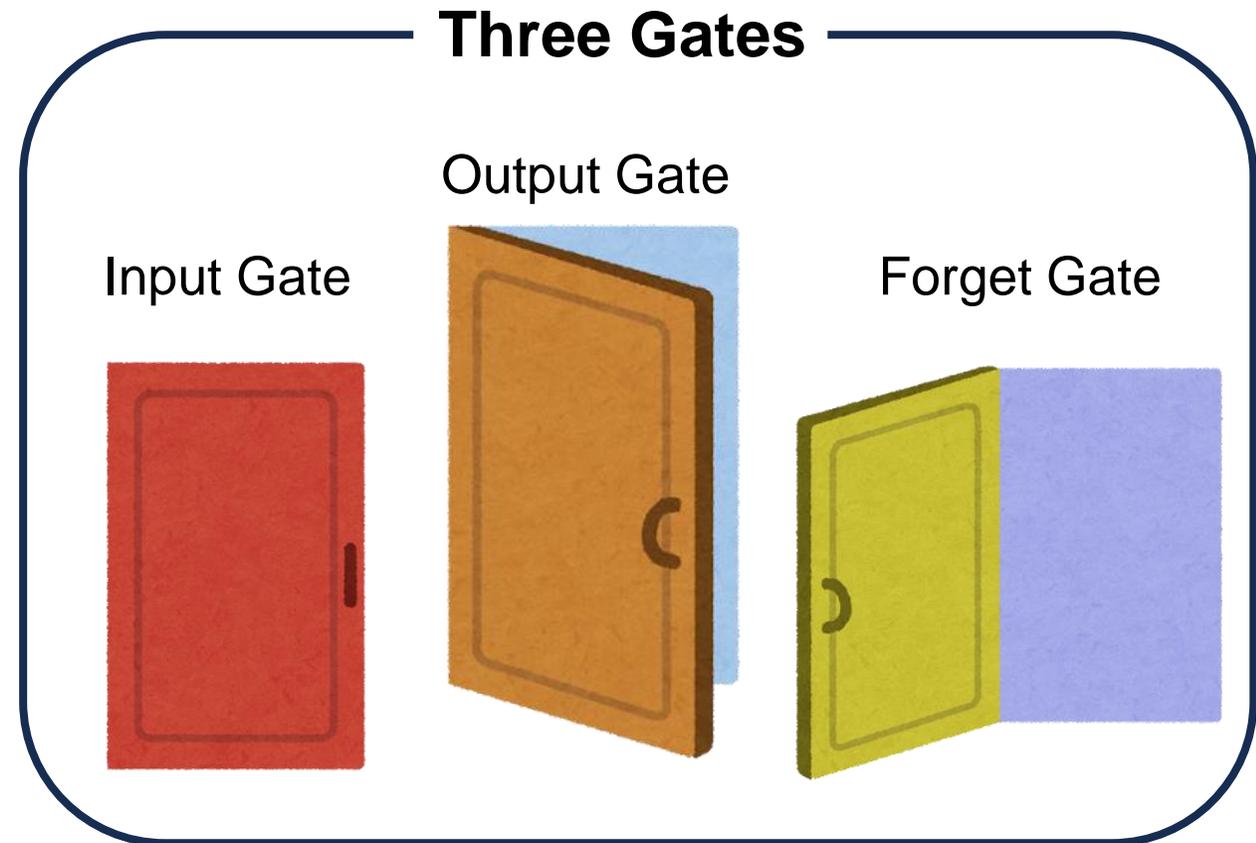
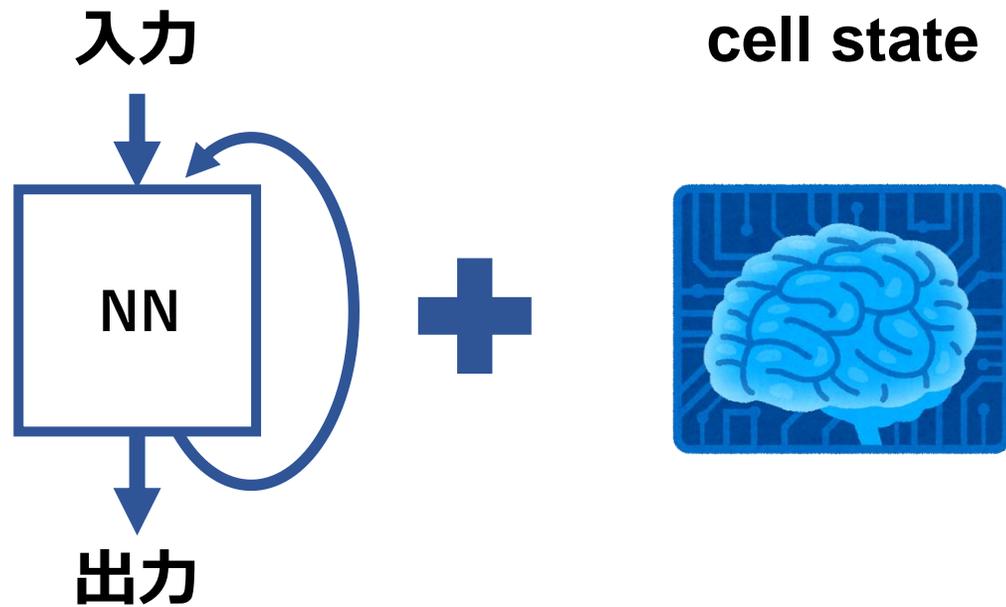
RNN



2.3 学習アルゴリズム

LSTM(Long Short-Term Memory)

↳ 長期的な依存関係を学習することのできるRNNの一種



2.3 学習アルゴリズム

LightGBM

↳勾配ブースティングを用いた決定木による機械学習の手法

誤差逆伝播法

↳出力と正解の誤差から出力が正解に近づくようにパラメータ調整するニューラルネットワークのアルゴリズム

LSTM(Long Short-Term Memory)

↳長期的な依存関係を学習することのできるRNNの一種

ARIMA(Auto Regressive Integrated Moving Average)

↳統計的特性が時間的に変動する時系列に有効な手法の一つ

2.3 学習アルゴリズム

ARIMA(Auto Regressive Integrated Moving Average)

↳統計的特性が時間的に変動する時系列に有効な手法の一つ

ARIMAモデル

ARMAモデル

ARモデル



MRモデル



I (和分過程)

2.3 学習アルゴリズム

ARIMA(Auto Regressive Integrated Moving Average)

↳ 平均値が時間的に変動するような時系列に有効な手法の一つ

AR(Auto Regression : 自己回帰)

↳ 過去の値を用いて予測

MA(Moving Average: 移動平均)

↳ 過去の予測値の誤差を用いて予測

I(Integrated : 和分・積分)

↳ 差分化などを用いて非定常データを定常データに変換
和分過程

2.4 Optunaとは

Optuna²

↳ハイパーパラメータの最適化を自動化するためのソフトウェアフレームワーク

ハイパーパラメータ

↳機械学習アルゴリズムの挙動を制御するパラメータのこと

例:学習率

正則化項

決定木の葉の最大数

ニューラルネットワークの層数

ニューラルネットワークのユニット数

2.4 Optunaとは

Optuna²

↳ハイパーパラメータの最適化を自動化するためのソフトウェアフレームワーク

ハイパーパラメータ

↳学習アルゴリズムの挙動を制御するパラメータのこと

例:学習率

正則化項

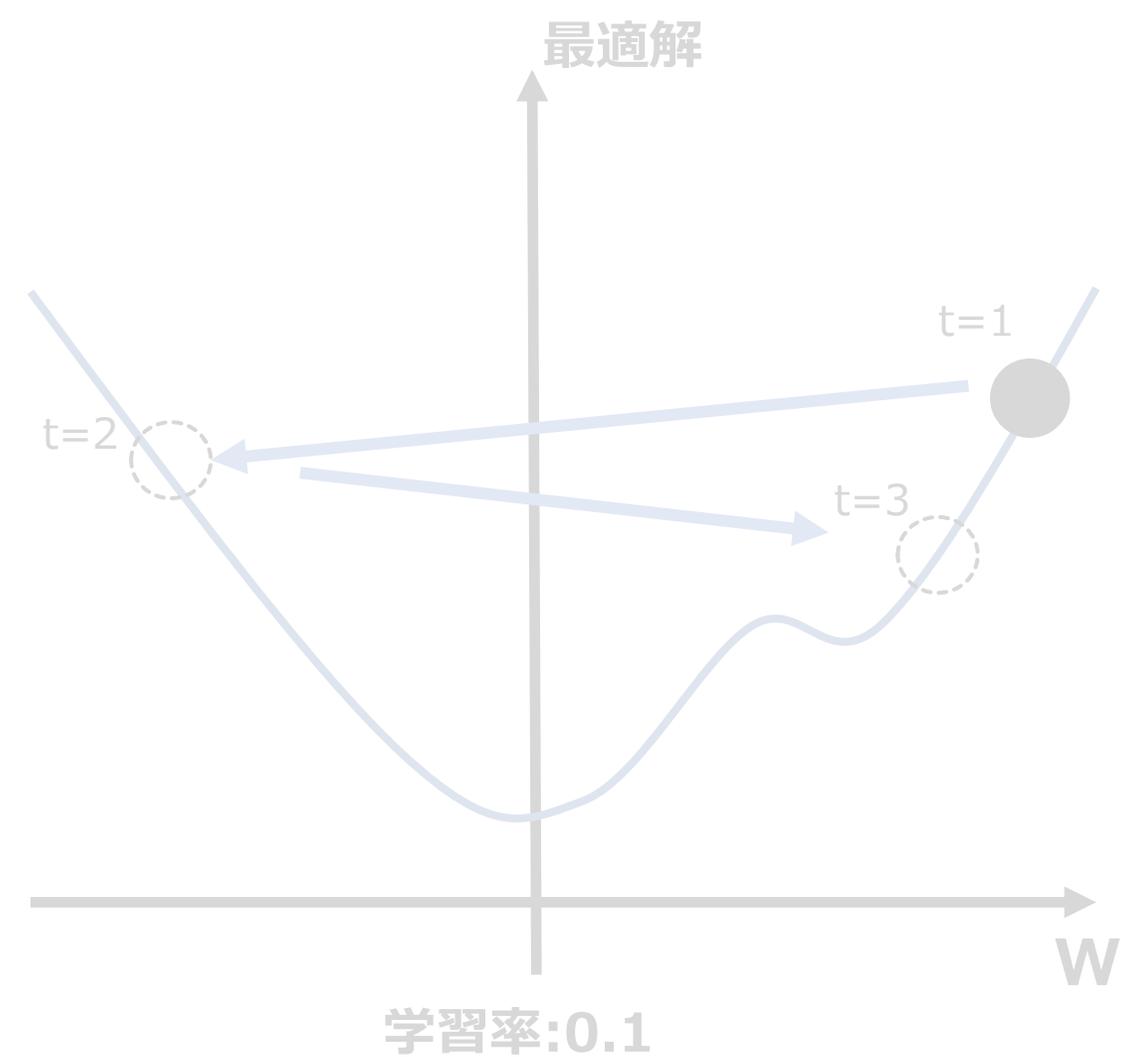
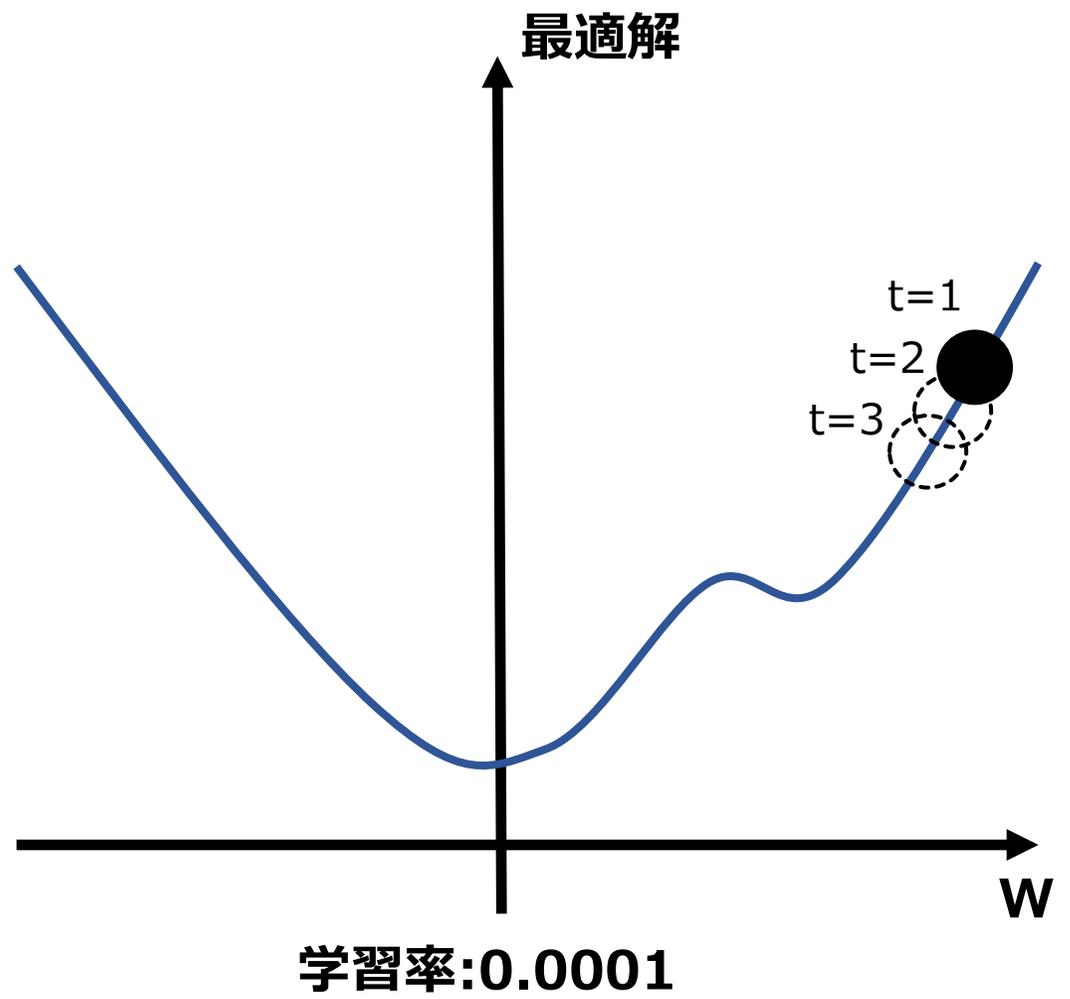
決定木の葉の最大数

ニューラルネットワークの層数

ニューラルネットワークのユニット数

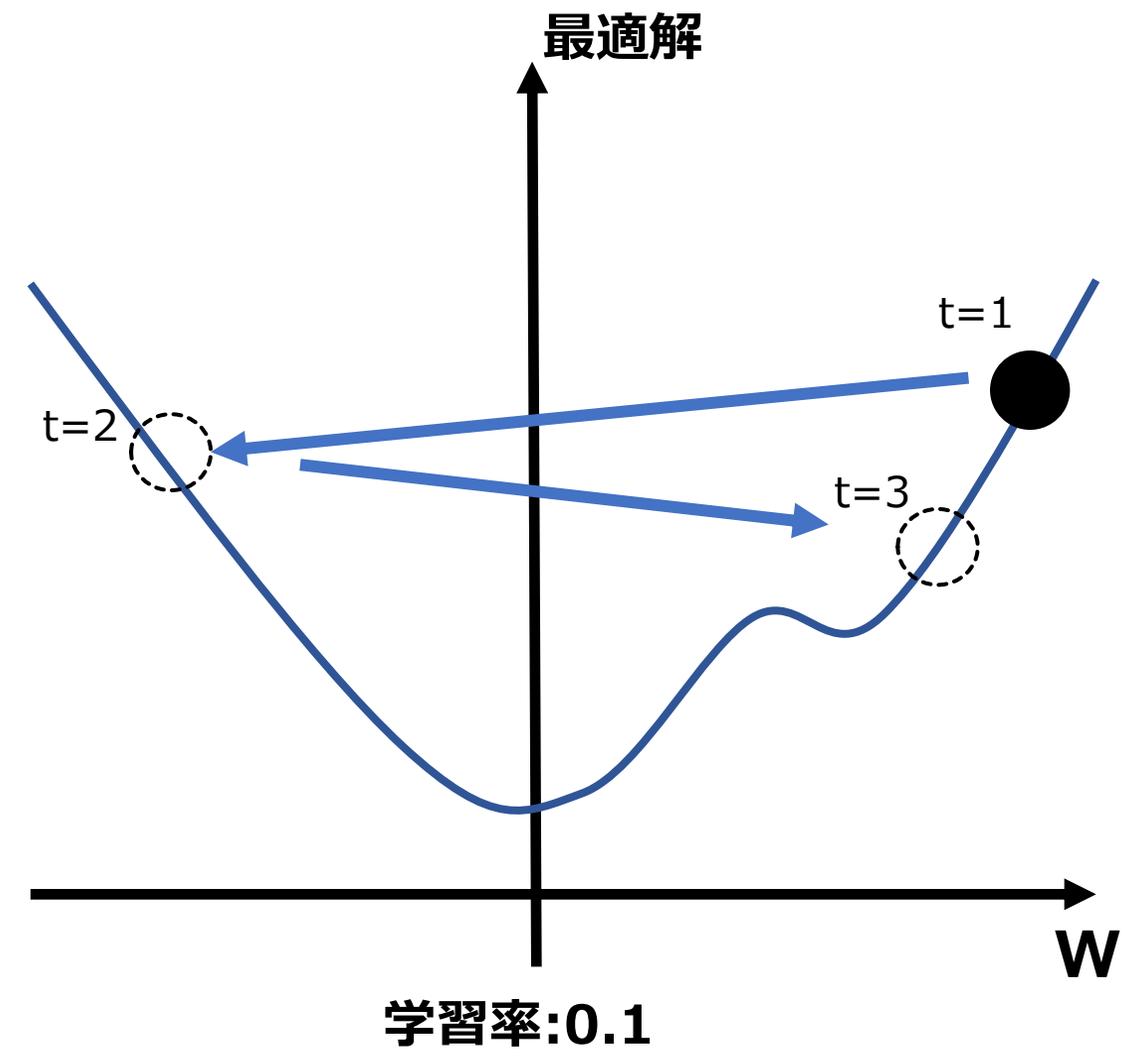
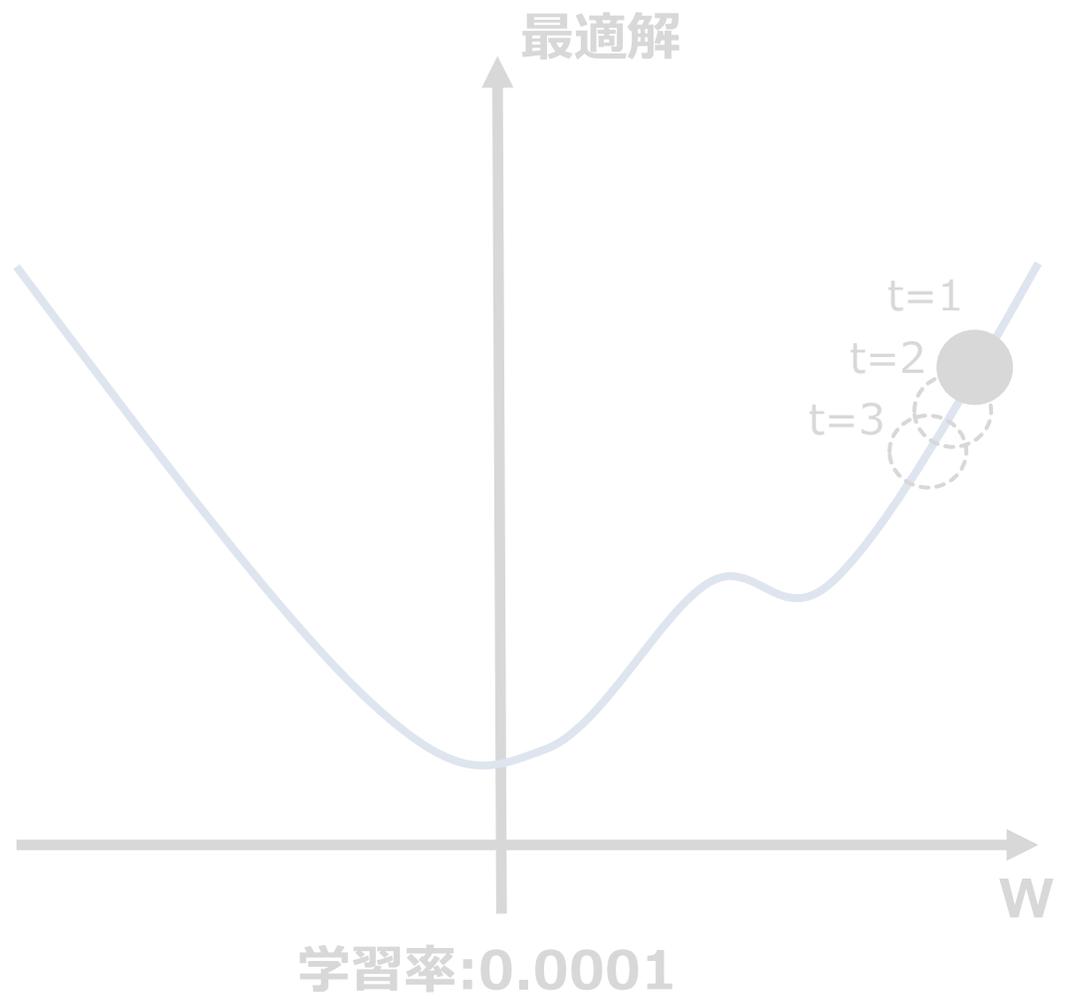
2.4 Optunaとは

例: 学習率



2.4 Optunaとは

例: 学習率

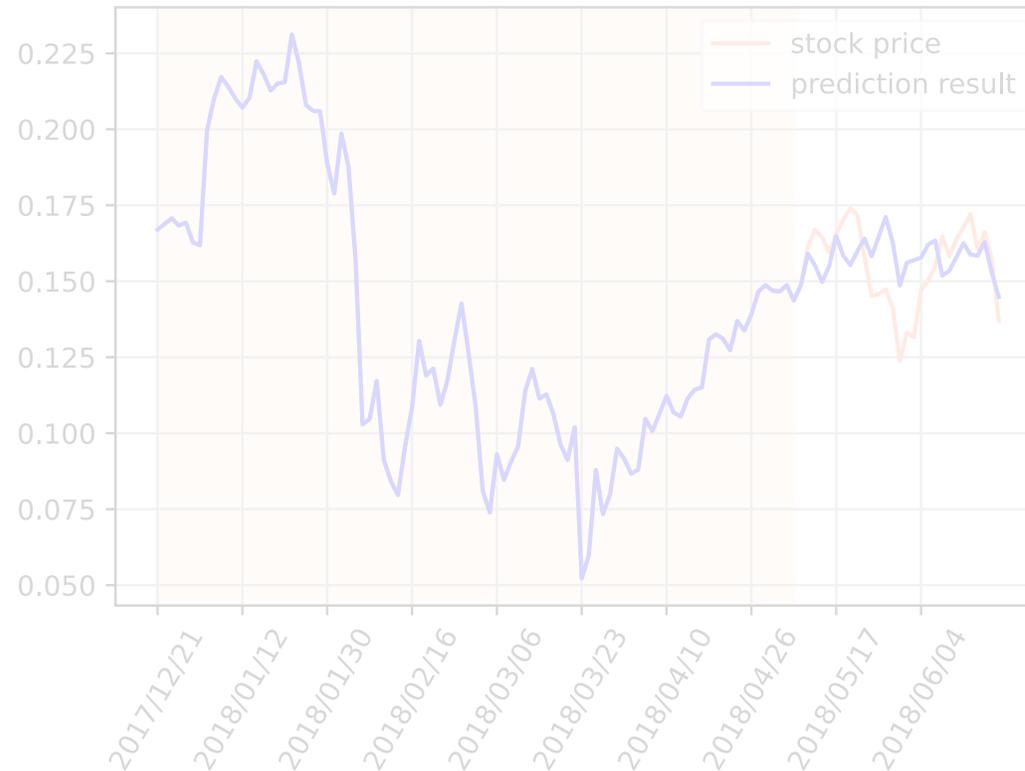


2.5 時系列解析とは

時系列解析

└時間の経過順に並んだデータを元に長期的傾向や周期的変動に対し将来の値を予測するもの

株価予測

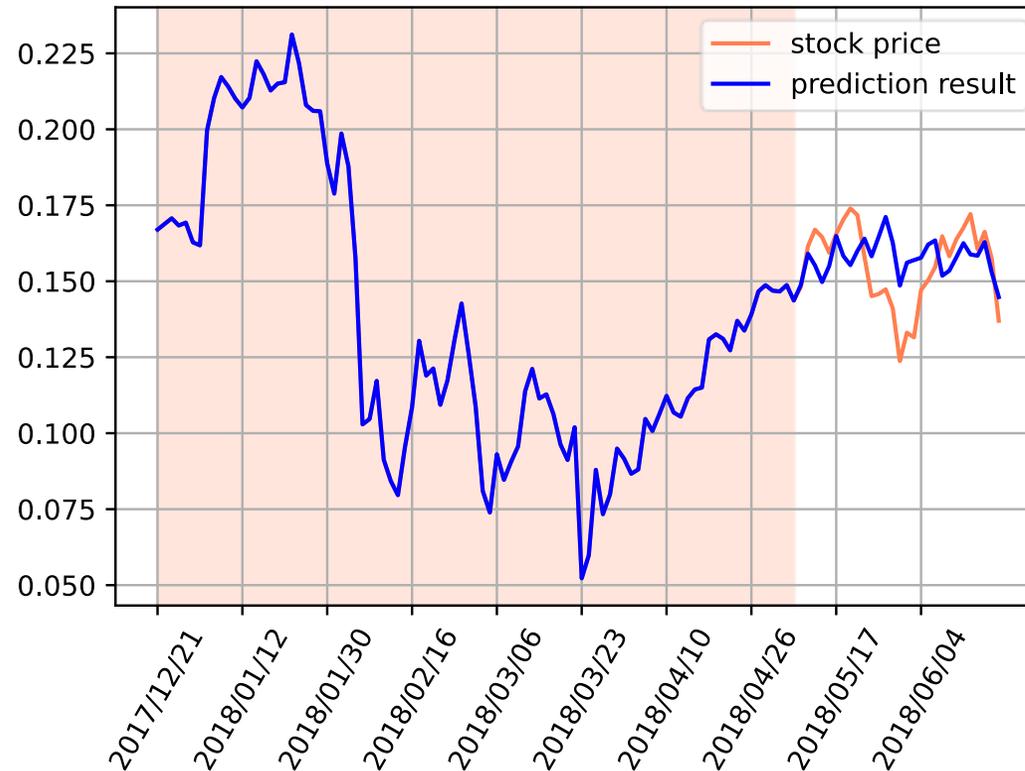


2.5 時系列解析とは

時系列解析

└時間の経過順に並んだデータを元に長期的傾向や周期的変動に対し将来の値を予測するもの

株価予測



1. はじめに

- 1.1 動機
- 1.2 先行研究
- 1.3 演習目的

2. 準備

- 2.1 機械学習とは
- 2.2 学習方法とモデル
- 2.3 学習アルゴリズム
- 2.4 Optunaとは
- 2.5 時系列解析とは

3. 演習

- 3.1 演習環境
- 3.2 演習方法
- 3.3 演習結果

4. まとめ

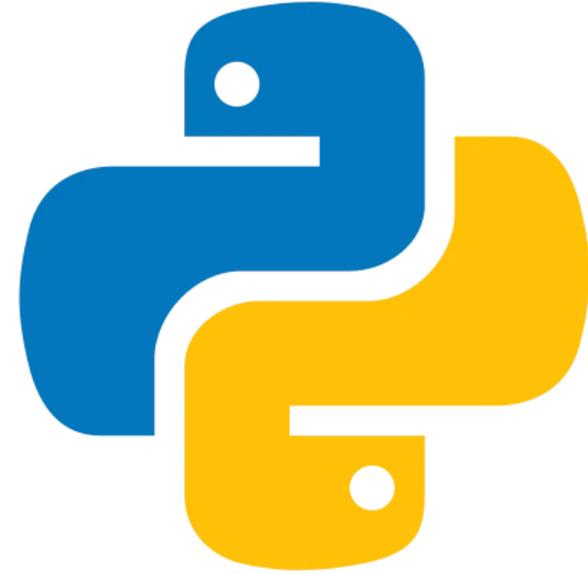
- 4.1 考察
- 4.2 今後の課題

3.1 演習環境



Google Colaboratory

- 環境構築が不要
- GPU に料金なしでアクセス
- 簡単に共有



Python

- 可読性が高い
- ライブラリが豊富
- Google Colabの主要言語

3.2 演習方法

1. ドライビングシミュレータで60分間先導車両を追跡する



提供：株式会社エイチアイ

3.2 演習方法

1. ドライビングシミュレータで60分間先導車両を追跡する

- Unity で作成
- ハンドルとフットペダル型のコントローラにより自車両を操作
- 高速道路を模した平坦かつ直線的なコースを走行
- 60km/h~80km/h でランダムに速度が変化する先行車両が存在
- 自車両の進行方向がランダムで1°程度変化(風, 路面の凹凸など)

3.2 演習方法

1. ドライビングシミュレータで60分間先導車両を追跡する

- 被験者 1 人につき 1 時間の実験を 3 ~ 4 回ずつ実施
- 22 歳から 40 歳までの男性 5 名
- ディスプレイ上部のカメラで顔周辺を撮影
- カロリンスカ眠気尺度による眠気評定値を適宜変更

3.2 演習方法

2. 走行実験中に取得したデータを説明変数とする

1. 生体情報

1. PERCLOS[P]

2. 車両情報

1. 速度の標準偏差[SpS]

2. 加速度の標準偏差[AS]

3. 躍度の標準偏差[JS]

4. ステアリング角の標準偏差[StS]

5. アクセルペダル踏込量の標準偏差[APS]

6. ブレーキペダル踏込量の標準偏差[BPS]

7. リアルタイム・ステアリングエントロピー³[RSE]

8. リアルタイム・ステアリングエントロピーの標準偏差[RSES]

3.2 演習方法

3. 走行実験中に取得したデータを目的変数とする

1. カロリンスカ眠気尺度(Sleepiness)

↳ 被験者が今どれくらい眠いのかを評価するための眠気の自己評価尺度

数値	説明(英語)	説明(日本語)
1	Extremely alert	非常にはっきり目覚めている
2		
3	Alert	目覚めている
4		
5	Neither alert nor sleepy	どちらでもない
6		
7	Sleepy, but no difficulty remaining awake	眠い
8		
9	Extremely sleepy, fighting sleep	とても眠い

3.2 演習方法

3. 走行実験中に取得したデータを目的変数とする

2. 北島らの顔表情に基づく眠気尺度(oss)

↳ 第三者が被験者の顔表情から眠そうであるかを評価するための尺度

数値	評価	説明
1	全く眠くなさそう	視線の移動が速く、頻繁である。瞬きの周期は安定している。動きが活発で体の動きを伴う。
2	やや眠そう	視線移動の動きが遅い、唇が開いている。
3	眠そう	瞬きはゆっくりと頻発。口の動きがある。座り直し有り。顔に手をやる。
4	かなり眠そう	意図的と思われる瞬きがある。頭を振る、肩の上下動など無用な体全体の動きあり、あくびは頻発し、深呼吸も見られる。瞬きも視線の動きも遅い。
5	非常に眠そう	瞼を閉じる。頭が前に傾く。頭が後ろに倒れる。

RMSE, Root Mean Square Error

予測値 \hat{y} と真値 y に対し 以下のように計算される

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2}$$

3.2 演習方法

分割方法

- A:**各実験データを結合しランダムにシャッフル
訓練データ:8割, テストデータ:2割

- B:**各実験データを時系列順に結合
各 i ($\in \{1, 2, 3, 4, 5\}$) に対して
訓練データ: i 人目以外, テストデータ: i 人目

3.2 演習方法

分割方法

A:各実験データを結合しランダムにシャッフル
訓練データ:8割, テストデータ:2割

B:各実験データを時系列順に結合
各 i ($\in \{1, 2, 3, 4, 5\}$) に対して
訓練データ: i 人目以外, テストデータ: i 人目

3.3 演習結果

ハイパーパラメータ最適化:分割方法A

OSS(北島ら):RMSEが0.25のとき5段階中1段階分の誤差

Sleepiness(カロリンスカ眠気尺度):RMSEが0.25のとき9段階中2段階分の誤差

LightGBM_oss

変数の数	平均	1	2	3	4	5	6	7	8	9
Optuna無し	0.082	0.132	0.107	0.082	0.074	0.073	0.068	0.067	0.066	0.067
n_trials=1000 onPruner	0.076*	0.132*	0.101*	0.074*	0.067*	0.065*	0.063*	0.062*	0.059*	0.062*

LightGBM_sleepiness

変数の数	平均	1	2	3	4	5	6	7	8	9
Optuna無し	0.092	0.171*	0.133	0.100	0.082	0.072	0.070	0.069	0.068	0.067
n_trials=1000 onPruner	0.082*	0.173	0.130*	0.087*	0.070*	0.059*	0.057*	0.052*	0.052*	0.054*

LightGBM(oss): RMSEは概ね**0.00577**減少

LightGBM(sleepiness):RMSEは概ね**0.01067**減少

3.3 演習結果

ハイパーパラメータ最適化:分割方法A

OSS(北島ら):RMSEが0.25のとき5段階中1段階分の誤差

Sleepiness(カロリンスカ眠気尺度):RMSEが0.25のとき9段階中2段階分の誤差

NN_oss

変数の数	平均	1	2	3	4	5	6	7	8	9
Optuna無し	0.280	0.354	0.372	0.376	0.26	0.235	0.225	0.234	0.206	0.254
n_trials=1000 onPruner	0.137*	0.152*	0.151*	0.149*	0.133*	0.129*	0.128*	0.129*	0.127*	0.133*

NN_sleepiness

変数の数	平均	1	2	3	4	5	6	7	8	9
Optuna無し	0.318	0.302	0.533	0.407	0.303	0.302	0.290	0.247	0.253	0.224
n_trials=1000 onPruner	0.173*	0.189*	0.190*	0.192*	0.163*	0.172*	0.167*	0.164*	0.160*	0.162*

NN(oss): RMSEは概ね**0.14275**減少

NN(sleepiness):RMSEは概ね**0.14463**減少

3.3 演習結果

分割方法

A: 各実験データを結合しランダムにシャッフル
訓練データ: 8割, テストデータ: 2割

B: 各実験データを時系列順に結合
各 i ($\in \{1, 2, 3, 4, 5\}$) に対して
訓練データ: i 人目以外, テストデータ: i 人目

3.3 演習結果

ハイパーパラメータ最適化:分割方法B,テストデータ:1人目

OSS(北島ら):RMSEが0.25のとき5段階中1段階分の誤差

Sleepiness(カロリンスカ眠気尺度):RMSEが0.25のとき9段階中2段階分の誤差

LightGBM_oss

変数の数	平均	1	2	3	4	5	6	7	8	9
Optuna無し	0.186	0.164	0.154	0.161	0.166	0.168	0.180	0.186*	0.199	0.293
n_trials=1000 onPruner	0.168*	0.162*	0.151*	0.151*	0.164*	0.145*	0.169*	0.187	0.172*	0.209*

LightGBM_sleepiness

変数の数	平均	1	2	3	4	5	6	7	8	9
Optuna無し	0.209	0.198	0.196	0.205*	0.192	0.190	0.195	0.201	0.206	0.297
n_trials=1000 onPruner	0.201*	0.196*	0.190*	0.207	0.185*	0.186*	0.187*	0.199*	0.198*	0.264*

LightGBM(oss): RMSEは概ね**0.01790**減少

LightGBM(sleepiness):RMSEは概ね**0.00751**減少

3.3 演習結果

ハイパーパラメータ最適化:分割方法B,テストデータ:1人目

OSS(北島ら):RMSEが0.25のとき5段階中1段階分の誤差

Sleepiness(カロリンスカ眠気尺度):RMSEが0.25のとき9段階中2段階分の誤差

NN_oss

変数の数	平均	1	2	3	4	5	6	7	8	9
Optuna無し	0.118	0.112*	0.111	0.111	0.104	0.105	0.107	0.107*	0.111	0.196
n_trials=1000 onPruner	0.107*	0.112	0.111*	0.101*	0.102*	0.102*	0.104*	0.108	0.109*	0.110*

NN_sleepiness

変数の数	平均	1	2	3	4	5	6	7	8	9
Optuna無し	0.152	0.156	0.155	0.153	0.150	0.148	0.142	0.152	0.154	0.160
n_trials=1000 onPruner	0.140*	0.156*	0.153*	0.132*	0.128*	0.128*	0.130*	0.130*	0.151*	0.151*

NN(oss): RMSEは概ね**0.01143**減少

NN(sleepiness):RMSEは概ね**0.01250**減少

3.3 演習結果

ハイパーパラメータ最適化

- 実験データの分割方法によらずハイパーパラメータ最適化による精度の向上はあまり期待できない傾向
- 分割方法AのNNのみハイパーパラメータ最適化を行うことで精度が向上した

3.3 演習結果

分割方法

A: 各実験データを結合しランダムにシャッフル
訓練データ:8割, テストデータ:2割

B: 各実験データを時系列順に結合
各 i ($\in \{1, 2, 3, 4, 5\}$) に対して
訓練データ: i 人目以外, テストデータ: i 人目

3.3 演習結果

時系列解析:LSTM,分割方法B,テストデータ:1人目

OSS(北島ら):RMSEが0.25のとき5段階中1段階分の誤差

Sleepiness(カロリンスカ眠気尺度):RMSEが0.25のとき9段階中2段階分の誤差

NN_oss

変数の数	平均	1	2	3	4	5	6	7	8	9
NN	0.118*	0.112	0.111*	0.111*	0.104*	0.105*	0.107*	0.107*	0.111*	0.196*
LSTM	0.130	0.111*	0.111	0.111	0.110	0.111	0.111	0.110	0.111	0.288

NN_sleepiness

変数の数	平均	1	2	3	4	5	6	7	8	9
NN	0.152*	0.156	0.155*	0.153*	0.150*	0.148*	0.142*	0.152*	0.154*	0.160
LSTM	0.155	0.155*	0.156	0.154	0.155	0.155	0.155	0.156	0.155	0.156*

LSTM(oss): RMSEは概ね**0.01249**増加

LSTM(sleepiness):RMSEは概ね**0.00280**増加

3.3 演習結果

時系列解析:ARIMA,分割方法B,テストデータ:1人目

OSS(北島ら):RMSEが0.25のとき5段階中1段階分の誤差

Sleepiness(カロリンスカ眠気尺度):RMSEが0.25のとき9段階中2段階分の誤差

ARIMA_oss

変数の数	平均	1	2	3	4	5	6	7	8	9
ARIMA	0.267	0.267	0.267	0.267	0.267	0.267	0.267	0.267	0.267	0.267*
LSTM	0.130*	0.111*	0.111*	0.111*	0.110*	0.111*	0.111*	0.110*	0.111*	0.288

ARIMA_Sleepiness

変数の数	平均	1	2	3	4	5	6	7	8	9
ARIMA	0.307	0.308	0.308	0.308	0.308	0.308	0.308	0.308	0.308	0.308
LSTM	0.155*	0.155*	0.156*	0.154*	0.155*	0.155*	0.155*	0.156*	0.155*	0.156*

ARIMA(oss): RMSEは概ね**0.13701**増加

ARIMA(sleepiness):RMSEは概ね**0.15450**増加

時系列解析

- RMSEが安定的に小さくならなかった
LSTMはニューラルネットワークに比べてRMSEが僅かに増加した
ARIMAはRMSEが大きく増加した

1. はじめに

- 1.1 動機
- 1.2 先行研究
- 1.3 演習目的

2. 準備

- 2.1 機械学習とは
- 2.2 学習方法とモデル
- 2.3 学習アルゴリズム
- 2.4 Optunaとは
- 2.5 時系列解析とは

3. 演習

- 3.1 演習環境
- 3.2 演習方法
- 3.3 演習結果

4. まとめ

- 4.1 考察
- 4.2 今後の課題

4.1 考察

ハイパーパラメータ最適化

✕ LightGBM

決定木という仕組みから
パラメータの影響が少なかった
可能性がある

○ ニューラルネットワーク

層数等のモデルを構築する上で
重要なパラメータが多いため
パラメータの影響が大きかった
可能性がある



データの改善がより大きな差別化要因になる

4.1 考察

時系列解析



LSTM

時系列解析による精度向上は期待できなかった
NNと同じ特性を合わせ持つため一定の精度が出た可能性がある



ARIMA

時系列解析による精度向上は期待できなかった
非定常性を持たなかった可能性がある



実験データに時系列的特性がない可能性
実験データの事前条件が時系列的特性を決める可能性

4.2 今後の課題

新たな特徴量を追加

└ 今回の実験では生体情報としてPERCLOSのみを使用
目を閉じている割合以外に眉や口などの生体情報を追加する

実路走行データで実験

└ 他交通参加者からの影響を受けたデータで
時系列的特性が存在するかを確認する