

# AutoEncoderを導入したRegression Forestsによるノイズ発見

日比野真也<sup>†</sup> 木村 昭悟<sup>††</sup> 山下 隆義<sup>†</sup> 山内 悠嗣<sup>†</sup> 藤吉 弘亘<sup>†</sup>

<sup>†</sup> 中部大学 〒487-8501 愛知県春日井市松本町 1200

<sup>††</sup> 日本電信電話株式会社 コミュニケーション科学基礎研究所 〒243-0198 神奈川県厚木市森の里若宮 3-1

E-mail: <sup>†</sup>h\_msy@mprg.cs.chubu.ac.jp, <sup>††</sup>akisato@ieee.org, <sup>†††</sup>{yamashita,hf}@cs.chubu.ac.jp,

<sup>††††</sup>yuu@isc.chubu.ac.jp

あらまし 本研究では、Regression Forests の回帰過程において発生するテストサンプルのノイズによるノードの分岐反転を発見する手法を提案する。Regression Forests の回帰推定の際に、入力特徴ベクトルのある次元にノイズが付与されると、その次元を参照した分岐ノードが反転し、異なる子ノードへ分岐することがある。分岐が反転すると到達する末端ノードが変化するため正しい回帰推定が困難となり、精度が低下するという問題が生じる。そこで、本研究では Regression Forests の各回帰木の末端ノードに相関があることに着目し、学習済みの各回帰木に学習サンプルを入力し、到達したノードを表現した特徴パターンを入力して AutoEncoder を学習する。これにより、ノイズを含む特徴ベクトルを入力した際の各回帰木の正しい出力パターンを想起し、分岐が反転したノードを発見できる。分岐が反転したノードに対して複数パスを考慮することで、ノイズの影響を低減した回帰推定を行う。評価実験より、提案手法は4つのデータセットに対して回帰精度を向上させることができた。

キーワード Random Forests, Regression Forests, AutoEncoder, 回帰分析, ノイズ発見

## 1. はじめに

機械学習法の一つである Random Forests [1] は、複数の決定木を用いたアンサンブル学習法である。Random Forests は 2001 年に Breiman により提案され、分類問題だけでなく、回帰、密度推定、半教師学習、多様体学習に利用されている。コンピュータビジョンの分野では、文字認識 [2] や物体認識 [3]、セマンティックセグメンテーション [4]、人体姿勢推定 [5] 等の様々なタスクに Random Forests が用いられている。Random Forests の学習は、各分岐ノードにおいて、情報利得を最大化するように分岐ルールを決定する。しかし、特徴ベクトルにノイズが付与されると、トラバース時に分岐が反転し精度が低下する。特に回帰問題を扱う Regression Forests [6] では、各回帰木の出力の平均値を回帰の推定結果とするため、精度が低下しやすいという問題がある。ノイズの影響を低減する手法として、若山らは複数パスを考慮した Regression Forests を提案した [7]。本手法は、分岐ノードがノイズを参照した場合に、左右両方の子ノードへ分岐し、それぞれ到達する末端ノードを求める。末端ノードの出力は、各回帰木において複数パスに分岐した回数で出力を重みづけする。複数パスを用いて重みづけすることで、ノイズによる回帰推定への影響を低減している。しかし、特徴ベクトルに付与されたノイズの位置が既知でないと、複数パスを考慮したトラバースを利用できない。そのため、若山らの手法は特徴ベクトルに含まれるノイズの位置が既知の場合において有効となる。

そこで本研究では、Regression Forests にノイズが含まれる

データが入力された場合に、ノイズを参照したノードを発見する手法を提案する。まず、ノイズを含まない特徴ベクトルを入力して回帰を行い、トラバース時にサンプルが到達したノードを用いてノイズを含まない正解パターンを作成する。そして、正解パターンを AutoEncoder [8] に入力して学習する。推定時は学習した AutoEncoder にテストサンプルを入力し、ノイズが含まれた場合に、正解パターンを想起する。正解パターンを想起することで、想起前後のパターンを比較してノイズを参照したノードを発見できる。ノイズを参照したノードは、複数パスを考慮した Regression Forests により推定し、ノイズの影響を低減し、高精度な回帰推定を実現する。

## 2. Regression Forests

本研究では、ノイズの影響を受けやすい回帰問題を対象とする。本章では、回帰タスクを扱う Regression Forests のアルゴリズムと、複数パスを考慮した Regression Forests による回帰法について述べる。

### 2.1 学習

Regression Forests は、Random Forests と同様に回帰木を構築することにより学習を行う。Regression Forests の学習アルゴリズムをアルゴリズム 1 に示す。まず、学習サンプルから  $T$  個のサブセットを作成し、サブセットごとに回帰木を学習する。回帰木の各ノードは、ランダムに特徴次元を選び、目的関数  $I_j$  が最大となる特徴次元と閾値で分岐する。目的関数  $I_j$  は式 (1) のように定義される。

- Require:** 学習サンプル :  $I$   
**Require:** 木の数 :  $T$   
**Require:** 木の深さ :  $D$   
**Require:**  $T$  個のサブセット :  $I = (I_1, I_2, \dots, I_T)$ .  
**Require:** 特徴選択回数 :  $F$   
**Require:** しきい値選択回数 :  $TH$
- 1: For  $k = 1, \dots$ , 木の数  $T$  まで
  - 2: サブセット  $I_k$  を用いて決定木を作成
  - 3: For  $l = 1, \dots$ , 特徴量選択数  $F$  まで
  - 4: For  $m = 1, \dots$ , しきい値選択数  $TH$  まで
  - 5: しきい値  $t$  と特徴次元をランダムに選択
  - 6: 目的関数  $I_j$  で分岐
  - 7: 
$$I_j = \sum_{v \in S_j} (y - \hat{y})^2 - \sum_{i \in L, R} \left\{ \sum_{v \in S_j^i} (y - \hat{y}_j)^2 \right\}$$
  - 8: if  $I_j > I_{j_{old}}$   $t$ , 特徴次元番号を保存
  - 9: end for
  - 10: end for
  - 11: if gain = 0 または  $D$  に達した → 末端ノードを作成
  - 12: 到達したサンプルを用いて回帰分析
  - 13: else  $I_l, I_r$  を用いて再帰処理
  - 14: end for

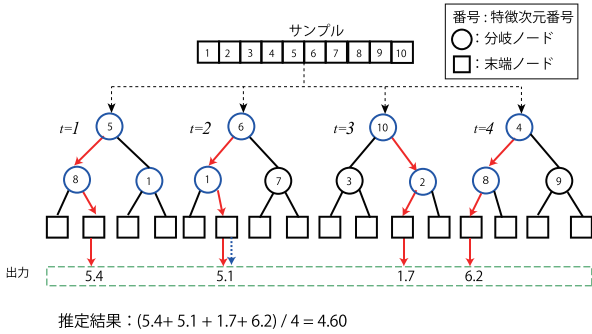


図 1 Regression Forests による回帰推定

$$I_j = \sum_{v \in S_j} (y - \hat{y})^2 - \sum_{i \in L, R} \left\{ \sum_{v \in S_j^i} (y - \hat{y}_j)^2 \right\} \quad (1)$$

ここで,  $S_j$  は特徴次元,  $v$  は選択された特徴次元,  $y$  は各ノードの出力を,  $\hat{y}$  は  $y$  の平均を示す.  $j$  は選択したノード番号,  $L, R$  はそれぞれ左と右の子ノード番号を示す.

## 2.2 回帰推定とノイズの影響

図 1 に Regression Forests による回帰推定を示す. テストサンプルを各回帰木へ入力し, 分岐ノードの分岐関数に従い末端ノードまで分岐する. 末端ノードには学習で得られた回帰係数が保存されており, この回帰係数とサンプルの特徴量を基に連続値の出力  $\hat{Y}_t$  を得る. 複数の回帰木の出力  $\hat{Y}_t$  の平均を式 (2) で求め, 最終的な出力  $\hat{Y}$  とする.

$$\hat{Y} = \frac{1}{T} \sum_{t=1}^T \hat{Y}_t \quad (2)$$

ここで,  $T$  は木の数を示す.

Regression Forests では, 入力サンプルのある特徴次元にノイズが含まれた場合, 図 2 に示すようにトラバーサルにおいてノイズを含む特徴次元を参照すると, 分岐ノードのしきい値処理により好しくない子ノードへ分岐することがある. その結果, 式 (2) より平均を求める際にアウトライアが含まれると,

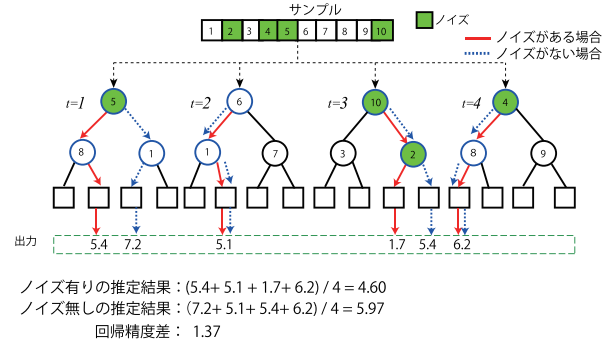


図 2 ノイズを参照した Regression Forests

表 1 ノイズの影響

ノイズ割合 [%]	0	12.5	25	37.5	50	62.5	75	87.5
回帰推定による誤差 [%]	15.2	16.3	22.4	23.7	26.9	29.1	30.9	32.7

その回帰精度は大きく低下する.

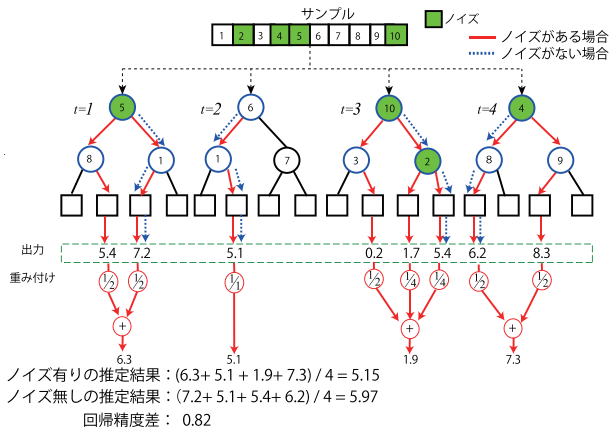
表 1 に, UCI Machine Learning Repository データセットの Concrete Compressive Strength (8 次元特徴ベクトル) を用いたノイズの割合に対する回帰による推定誤差を示す. 表 1 より, ノイズの割合が増加すると, 回帰による推定誤差も大きくなるのがわかる.

## 2.3 複数パスを考慮した回帰推定と問題点

若山らはノイズを参照した際の回帰の推定精度を向上するアプローチとして, 複数パスを考慮したトラバーサル手法を提案している. 図 3 に, 複数パスを考慮した Regression Forests の概要を示す. 本手法は, サンプルに含まれるノイズを参照してノードを分岐した場合に, 両方の子ノードへ分岐することで, ノイズによる分岐の反転の影響を低減している. 複数パスを考慮した Regression Forests は, 末端ノードに達するまでにノイズを含む特徴次元を参照した回数により末端ノードの出力に重み付けを行い, 出力された全ての末端ノードの値の和を各回帰木の出力とする. 各回帰木の出力  $\hat{Y}_t$  は, 式 (3) のように求める.

$$\hat{Y}_t = \sum_{k=1}^K \frac{1}{2^{n_k}} \cdot \hat{y}_k \cdot \delta[f_k, 1] \quad (3)$$

ここで  $\hat{y}_k$  は末端ノードの出力,  $f_k$  は末端ノードにたどり着いた場合に 1 を出力し, 末端ノードではない場合に 0 を出力する.  $n_k$  は末端ノードにたどり着くまでにノイズの特徴次元を参照した回数を示している.  $K$  は末端ノードの数を示す.  $\delta$  はクロネッカーのデルタ関数を示しており, 2 つの引数が一致する場合に 1 を出力し, それ以外の場合に 0 を出力する関数である. トラバーサル時に, ノイズを含む特徴次元を参照した際に, 分岐ノードは左右両方のノードに分岐する. ノイズを多く参照すると出力の信頼が低くなるため,  $n$  回ノイズを含む特徴次元を参照した場合に, 出力に  $\frac{1}{2^n}$  の重みを付与する. これにより, ノイズを参照して間違った末端ノードにたどり着いた場合に, ノイズによる影響を低減することができる. しかし, 実問題において, ノイズが既知である場合は少ないため, 複数パスを考慮したトラバーサルを利用できないという問題がある.



### 3. 提案手法

本研究では、Regression Forests のトラバースした際に得られた末端ノードのパターンを学習した AutoEncoder を用いることで、ノイズが付与された特徴次元を発見する手法を提案する。

#### 3.1 回帰木の末端ノード間における相関

Regression Forests は、学習データからランダムにサンプルを選択して作成したサブセットごとに学習する。このとき、サブセット間には学習サンプルの重複を許すため、各回帰木には相関がある。Regression Forests は、サンプルを入力した際に特定の末端ノードに到達する。特定の末端ノードに到達したサンプルを、他の回帰木に入力すると特定の末端ノードに到達する可能性が高い。本研究では、各回帰木の相関性を確認するために交差エントロピーを算出する。

まず、図4に示すように、全学習サンプルを入力し、回帰木の末端ノード  $n$  に到達した学習サンプルの集合  $S^n$  を求める。 $S^n$  を他の回帰木  $t$  に入力し、到達した末端ノードの分布から交差エントロピー  $H(S^n)$  を求める。交差エントロピーは式(4)により算出する。

$$H_t(S) = - \sum_{i=1}^N P_t^i(S) \log P_t^i(S), \quad (4)$$

$$P_t^n(S) = \frac{|S^n|}{|S|}$$

ここで、 $P_t^n(S)$  は  $t$  番目の回帰木の末端ノード  $i$  に到達した学習サンプル集合  $S^i$  から求めた生起確率、 $N$  は回帰木  $t$  の末端ノード数である。次に、全てのノードに対して交差エントロピーを求め、式(5)を用いて  $H_t(S)$  の平均  $\hat{H}_t$  を求める。

$$\hat{H}_t = \frac{1}{N} \sum_n H_t(S^n) \quad (5)$$

交差エントロピーの平均値が小さい場合にサンプルが到達するノードが偏るため相関が強くなる。予備実験として、提案手法の前提条件である回帰木の末端ノードの相関性の有無を交差エントロピーにより評価する。Regression Forests の学習時にサブセットの重複割合を変更させた場合の交差エントロピー


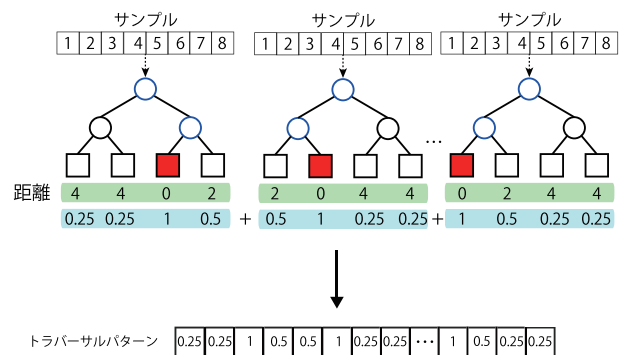
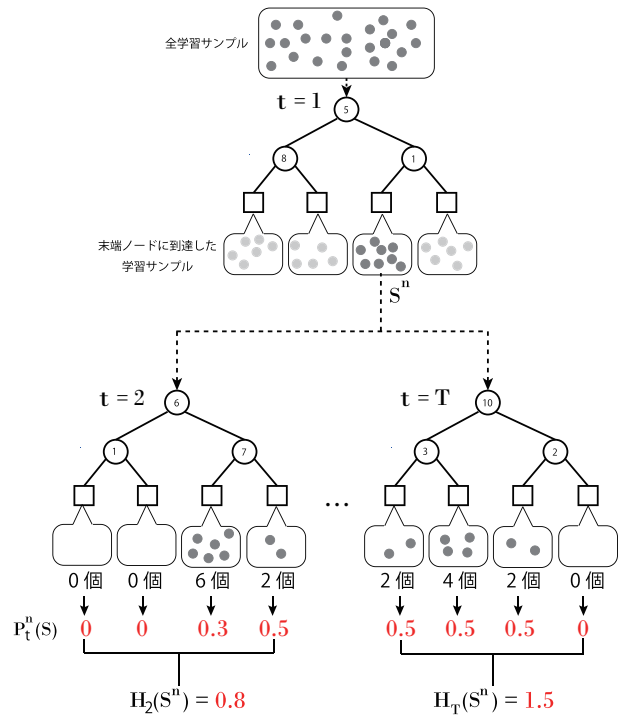


図6 サブセットの重複割合における交差エントロピー

を図6に示す。図6より、サブセットの重複割合が高くなると交差エントロピーが小さくなるのがわかる。交差エントロピーが小さいということは、到達した末端ノード間の対応がとれていることを示しており、各回帰木の出力間に相関があるといえる。

### 3.2 AutoEncoder によるノイズ発見

提案手法は、回帰木間の相関を利用して、トラバーサル結果を AutoEncoder により想起してノイズの発見を行う。図 7 に、処理の流れを示し、提案手法の学習と回帰推定の詳細について述べる。

#### 3.3 提案手法の学習

##### 3.3.1 Regression Forests の学習

Regression Forests の学習には、ノイズが含まれないサンプルを用いて回帰木を構築する。回帰木を構築する際に、学習サンプルの集合からサブセットを作成する。その際に、サブセット間のサンプルの重複を許しているため、サブセットのサンプルの重複度が大きい場合に回帰木のノード間の相関が強くなる。本研究では、100 個のサブセットから 100 本の回帰木を学習により構築する。

##### 3.3.2 交差エントロピーによる回帰木の選択

学習により構築した全ての回帰木に対し、式 (5) により交差エントロピーを求める。ノイズ発見の精度を向上させるために、相関の高い回帰木、すなわち交差エントロピーの小さい木を選択する。このようにして選択した回帰木群を提案手法における Regression Forests とする。

##### 3.3.3 AutoEncoder の学習

AutoEncoder の学習方法について述べる。ノイズが含まれないサンプルを用いて構築した回帰木に、ノイズを含まないサンプルを入力しトラバーサルする。トラバーサルした際に辿り着いた末端ノードからトラバーサルパターンを作成する。トラバーサルパターンの作成方法は、図 5 に示すようにサンプルが到達したノードを 1 とし、サンプルが到達していないノードは式 (6) により求める到達したノードからの距離  $D$  の逆数を算出する。

$$D = t_u + t_d \quad (6)$$

ここで、 $t_u$  は子ノードから親ノードへ、 $t_d$  は親ノードから子ノードへ移動した回数である。各回帰木の末端ノードの値をつなげたものをトラバーサルパターンとする。トラバーサルパターンは回帰木の各階層で作成し、それぞれ AutoEncoder を学習する。各 AutoEncoder は、各階層ごとに入力トラバーサルパターンを想起するように学習する。本研究で用いる AutoEncoder は、入力層 1、中間層 1、出力層 1 とする。

#### 3.4 回帰による推定

##### 3.4.1 回帰木のトラバーサル

3.3.2 節により選択した回帰木に識別サンプルを入力してトラバーサルする。各回帰木において、辿り着いた末端ノードから式 (6) により求めた距離を用いてトラバーサルパターンに変換する。

##### 3.4.2 AutoEncoder によるノイズ発見

AutoEncoder によるノイズ発見手順を図 8 に示す。ノイズを含むトラバーサルパターンから、学習した AutoEncoder を用いて正しいトラバーサルパターンを想起する。

各回帰木において最大値となるトラバーサルパターンの位置を比較し、想起前後で最大値の位置が変化した場合、ノイズと

判定する。ノイズ判定は、Regression Forests の末端ノードから順番にノイズ判定を行う。ノイズと判定されたら、一つ浅い階層のノイズ判定を行う。末端ノード以外のノードでノイズと判定されない場合に、そのノードでノイズを参照し分岐が反転したと考えられる。

##### 3.4.3 複数パスを考慮した回帰による推定

3.4.2 節によりノイズを参照した分岐ノードに対して複数パスのトラバーサルを行う。ノイズを参照した分岐ノードから、両方の子ノードへ分岐する。このとき、末端ノードに達するまでにノイズを含む特徴次元を参照した回数により末端ノードの出力に重み付けを行い、出力された全ての末端ノードの値の和を回帰木の出力とする。最終的な出力は、式 (2) より求める。

## 4. 評価実験

提案手法の有効性を評価するために評価実験を行う。

### 4.1 データセットと実験概要

本実験では、UCI Machine Learning Repository で公開されているデータセットの Concrete Compressive Strength [9], Geographical Original of Music [10], Energy Efficiency [11], Airfoil Self-Noise [12] を用いる。各データセットの詳細を表 2 に示す。本実験では、各データセットに意図的にノイズを付与したテストサンプルを作成する。また、サンプルに付与するノイズの値は全サンプルにおける各特徴次元の平均値を用いる。

### 4.2 実験 1: AutoEncoder によるパターン想起の評価

本実験では、AutoEncoder による正しいトラバーサルパターンを想起した際のノイズ発見率を評価する。ノイズ発見率は、ノイズを含むサンプルから得られたトラバーサルパターンと AutoEncoder を用いて想起されたトラバーサルパターンを比較し、式 (7) により求める。

$$\text{ノイズ発見率} = \frac{\text{正しいパターンに変化した総数}}{\text{ノイズの総数}} \quad (7)$$

各データセットにおける、評価実験の結果を表 3 に示す。サブセットの重複割合が高くなるほど、交差エントロピーが小さく、ノイズ発見率が高くなるのがわかる。平均して約 70% のノイズを発見できた。特に、データセット 2 においては、平均して 72% のノイズを発見することができた。

### 4.3 実験 2: ノイズに対する回帰推定精度の評価

本実験では、AutoEncoder により想起されたパターンからノイズを参照した可能性が高いノードを発見し、複数パスを考慮した回帰を行う。比較手法として、ノイズを含んだサンプルを入力した複数パスを考慮した Regression Forests、ノイズを含んだサンプルを入力した Regression Forests、ノイズを含まないサンプルを入力した Regression Forests、提案手法を比較する。回帰誤差は式 (8) により求める。

$$\text{回帰誤差} = \frac{\text{正解値} - \text{Regression Forests の出力}}{\text{正解値}} \quad (8)$$

表 4 に、各データセットの回帰誤差を示す。実験結果から、ノイズを含まないサンプルで回帰した場合と比較し、ノイズを含むと回帰精度が平均して約 5.4% 低下した。しかし、提案手

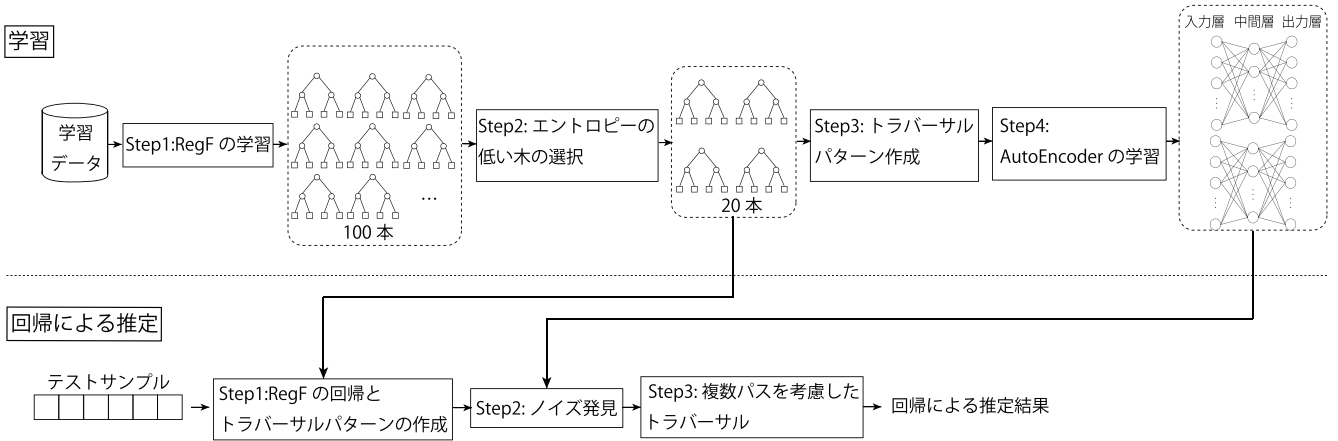


図 7 提案手法の流れ

表 2 実験パラメータ

	データセットの詳細			Regression Forests のパラメータ			
	名称	サンプル数	特徴次元数	木の数	深さ	特徴量選択回数	しきい値選択回数
データセット 1	Concrete Compressive Strength	1030	8	13	4	3	20
データセット 2	Geographical Original of Music	1059	68	35	4	8	50
データセット 3	Energy Efficiency	768	8	20	4	3	30
データセット 4	Airfoil Self-Noise	1503	5	20	4	2	25

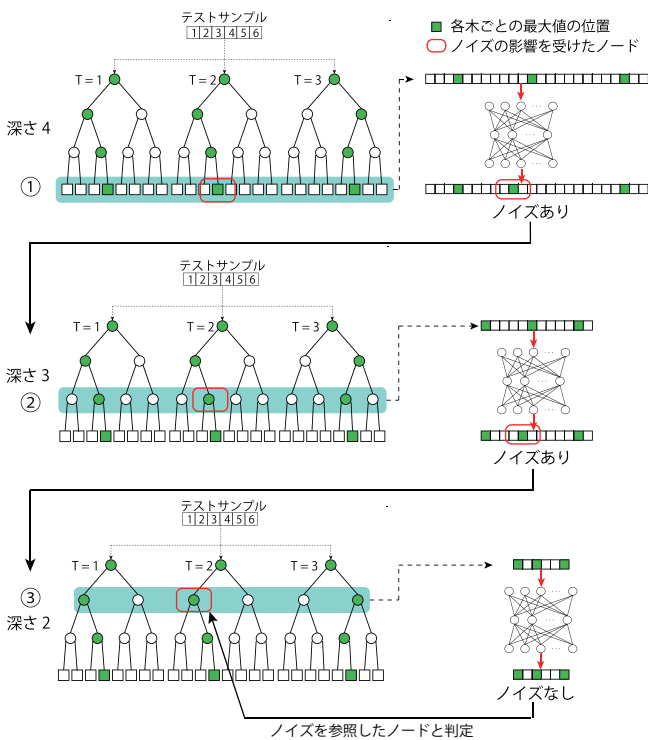


図 8 ノイズ発見手順

法はノイズありの回帰精度より、平均して約 4.0%回帰精度が向上した。特に、データセット 1 では約 4.7%回帰精度が向上した。以上から、ノイズパターンを AutoEncoder を用いて正解パターンに想起することによりノイズの影響を低減できた。

#### 4.4 実験 3: 交差エントロピーによる回帰木選択の効果

本実験では、交差エントロピーによる回帰木の選択の有効性を評価する。交差エントロピーによる選択の有無による回帰推定精度を比較する。表 5 に、交差エントロピーによる回帰木の選択の有無による交差エントロピー、ノイズ発見率、回帰誤差を示す。表 5 より、交差エントロピーを用いた選択を導入することで、ノイズ発見率を約 2.5%、回帰精度を約 2.0%向上させることができた。特に、データセット 3 では、ノイズ発見率が 4.1%、回帰精度が 3.2%向上した。以上より、交差エントロピーの小さな回帰木を選択し、Regression Forests を構築することにより、末端ノード間の相関が強まり、AutoEncoder の想起精度を向上させることができた。想起精度が向上することで、ノイズ発見率が高くなり、回帰による推定精度が向上したといえる。

#### 5. おわりに

本稿では、AutoEncoder を導入した Regression Forests によるノイズ発見と回帰について述べた。提案手法は、Regression Forests の各回帰木の末端ノード間に相関が存在することを利用し、AutoEncoder を用いて正しいトラバースルパターンの想起することにより、サンプルに含まれるノイズにより分岐が反転したノードを発見する。分岐が反転したノードから複数パスを考慮してトラバースルして回帰推定することで、ノイズの影響を低減することを示した。また、交差エントロピーの低い回帰木を選択する有効性を確認した。今後の課題は、AutoEncoder の想起精度の向上である。また、回帰タスクだけでなく識別タスクに応用する予定である。

#### 文 献

[1] L. Breiman, "Random forests", Machine learning, vol.45,

表 3 実験 1: パターンの想起結果

サブセット重複割合 [%]	データセット 1		データセット 2		データセット 3		データセット 4	
	交差エントロピー	ノイズ発見率	交差エントロピー	ノイズ発見率	交差エントロピー	ノイズ発見率	交差エントロピー	ノイズ発見率
10	0.92	66.2	1.02	68.9	1.19	61.3	0.94	60.4
20	0.73	67.9	0.93	69.2	0.83	62.5	0.89	61.9
30	0.75	67.5	0.84	69.6	0.91	62.9	0.71	62.3
40	0.68	69.1	0.68	70.2	0.88	64.1	0.69	64.0
50	0.66	69.7	0.67	71.7	0.62	65.9	0.66	67.1
60	0.64	71.2	0.62	72.9	0.68	67.2	0.55	68.9
70	0.52	72.8	0.54	73.1	0.58	68.7	0.48	70.5
80	0.42	73.9	0.57	75.3	0.53	71.9	0.42	72.3
90	0.39	75.1	0.51	76.1	0.42	72.6	0.52	73.9
100	0.34	76.6	0.49	76.9	0.35	73.5	0.47	75.5
平均	0.61	<b>71.0</b>	0.69	<b>72.4</b>	0.70	<b>67.1</b>	0.63	<b>67.7</b>

表 4 実験 2: 回帰結果

サブセット重複割合 [%]	データセット 1				データセット 2				データセット 3				データセット 4			
	ノイズなし	ノイズあり	複数パス	提案手法	ノイズなし	ノイズあり	複数パス	提案手法	ノイズなし	ノイズあり	複数パス	提案手法	ノイズなし	ノイズあり	複数パス	提案手法
10	19.4	25.1	22.1	23.9	14.1	16.2	15.5	15.9	7.2	12.8	10.4	11.8	10.7	18.5	16.4	17.3
20	19.1	24.5	22.7	23.1	14.6	17.1	14.8	16.3	6.4	13.7	10.9	12.3	10.4	18.9	15.8	16.2
30	18.7	24.8	21.5	22.8	13.8	16.5	15.8	15.7	6.8	12.4	9.6	11.5	10.9	17.5	14.2	15.9
40	18.8	23.6	21.8	22.6	13.2	15.8	14.3	14.9	6.3	12.0	10.8	10.2	11.2	17.9	14.9	15.2
50	17.1	22.9	20.4	21.2	14.2	15.9	14.2	15.2	6.5	14.6	12.6	11.2	9.7	16.0	14.3	14.8
60	16.2	23.1	20.1	20.4	13.4	14.5	13.6	14.2	6.1	13.5	10.0	9.7	9.7	17.3	14.2	14.9
70	16.4	24.5	19.7	20.1	12.5	14.7	13.1	13.6	6.2	13.3	11.2	9.5	10.6	16.9	13.4	13.5
80	15.3	22.0	18.9	18.3	12.3	14.1	13.6	13.1	6.7	12.9	10.3	10.3	10.3	16.5	13.7	13.1
90	16.1	21.4	18.5	18.5	12.1	15.3	14.3	13.6	6.0	11.7	9.8	9.1	9.2	15.2	12.6	12.0
100	15.8	21.9	18.6	17.2	11.5	14.9	12.1	12.3	5.8	11.4	10.1	8.2	9.5	15.7	13.1	11.7
平均	17.3	23.4	20.4	<b>20.8</b>	13.2	15.5	14.1	<b>14.5</b>	6.4	12.8	10.6	<b>10.4</b>	10.2	17.0	14.3	<b>14.5</b>

表 5 実験 3: 交差エントロピーによる回帰木選択の効果

	交差エントロピー		ノイズ発見率 [%]		回帰誤差 [%]	
	選択あり	選択なし	選択あり	選択なし	選択あり	選択なし
データセット 1	0.64	0.82	71.2	68.1	20.4	22.4
データセット 2	0.62	0.74	72.9	71.4	14.2	15.7
データセット 3	0.68	0.91	67.2	63.1	9.7	12.9
データセット 4	0.55	0.66	68.9	67.7	14.9	16.3
平均	<b>0.62</b>	0.78	<b>70.0</b>	67.6	<b>14.8</b>	16.8

- no.1, pp.5-32, 2001.
- [2] Y. Amit, and D. Geman, "Shape quantization and recognition with randomized trees", Neural computation, vol.9, no.7, pp.1545-1588, 1997.
- [3] J. Gall, A. Yao, N. Razavi, L. Van Gool, and V. Lempitsky, "Hough forests for object detection, tracking, and action recognition", Pattern Analysis and Machine Intelligence, vol.33, no.11, pp.2188-2202, 2011.
- [4] J. Shotton, M. Johnson, and R. Cipolla, "Semantic texton forests for image categorization and segmentation", Computer vision and pattern recognition, 2008.
- [5] J. Shotton, T. Sharp, A. Kipman, A. Fitzgibbon, M. Finocchio, A. Blake, M. Cook, and R. Moore, "Real-time human pose recognition in parts from single depth images", Communications of the ACM, vol.56, no.1, pp.116-124, 2013.
- [6] A. Criminisi, J. Shotton, and E. Konukoglu, "Decision forests: A unified framework for classification, regression, density estimation, manifold learning and semisupervised learning", Foundations and Trends in Computer Graphics and Vision vol.7, no.2-3, pp.81-227, 2012.
- [7] 若山涼至, 藤吉弘巨, "複数パスを考慮した Regression Forests によるカメラのヨー角の推定", パターン認識・メディア理解研究会, 2013.
- [8] G. E. Hinton, and R. R. Salakhutdinov, "Reducing the dimensionality of data with neural networks", Science, vol.313, no.5786, pp.504-507, 2006.
- [9] I-Cheng. Y, "Modeling of strength of high performance concrete using artificial neural networks", Cement and Concrete Research, vol.28, no.12, pp. 1797-1808, 1998.
- [10] F. Zhong, Claire. Q. and Ross. D. King, "Predicting the Geographical Origin of Music", International Conference on Data Mining, 2014.
- [11] A. Tsanas, and A. Xifara, "Accurate quantitative estimation of energy performance of residential buildings using statistical machine learning tools", Energy and Buildings, vol. 49, pp. 560-567, 2012.
- [12] T.F. Brooks, D.S. Pope, and A.M. Marcolini. "Airfoil self-noise and prediction", NASA Reference Publication 1218, 1989.