

研究論文

人工知能による段ボール強度の新たな推定方法

飯田 恭平^{*1}

New Attempt to Estimate the Compressive Strength of the Cardboard Box using Artificial Intelligence

Kyohei IIDA^{*1}Industrial Research Center^{*1}

本研究では、輸送包装分野における人工知能の活用取組として、機械学習を用いた段ボール箱の圧縮強度の推定を行った。1150 種類の段ボール箱のデータを人工知能に学習させて正確度及び精度の評価を行った結果、既存推定方法のケリカット簡易式よりも人工知能の方が高い正確度及び精度が得られることを確認した。従来ケリカット簡易式では推定することが出来なかった箱形式 0215、0300 の段ボール箱についても、人工知能に学習をさせることで強度推定が可能になることを示した。一方、推定可能な段ボール箱の種類が増えると精度が低下する傾向がみられた。

1. はじめに

2000 年代以降は第三次人工知能ブームと呼ばれている¹⁾。このブームは、大量のデータ(ビッグデータ)を用いることで人工知能自身が知識を獲得する「マシンラーニング(機械学習)」が実用化され、次いで知識を定義する要素を人工知能が自ら習得する「ディープラーニング(深層学習、特徴表現学習)」が登場したことで起きたとされている¹⁾。ブームが起きた結果、現在では多くの人工知能や人工知能作成支援ツールが開発、販売されている。そこで、輸送包装分野において人工知能を活用する方法について模索することにした。

人工知能活用の取り組みとして、機械学習を用いて段ボール箱の圧縮強度を推定した。国内での圧縮強度推定方法の主流は、1951 年に Kellicutt らが提案した強度推定式を SI 単位系に換算し、簡略化して作られた「ケリカットの簡易式²⁾」である。この推定式は段の種類(以下、「段種」とする)、原紙強さ及び箱の周辺長から箱の圧縮強度を推定する方法であり、人工知能への置き換えが可能だと考えた。本研究では、市販の人工知能作成支援ツールを用いて人工知能を作成して段ボール箱の圧縮強度を推定したので、その結果について報告する。

2. 実験方法

2.1 段ボール箱の作製手順

マルチカッティングマシン((株)エスコグラフィックス製、KongsbergX22)を用いて段ボール箱を作製した。段ボールの材質を表 1、作製した段ボール箱の段種、箱

形式及び内側寸法の範囲を表 2 に示す。段ボール箱の内側寸法は以下の手順で無作為に選定した。

1. 長さ、幅、高さの組み合わせを表 2 の範囲の素数からそれぞれ無作為(重複可)に 100 種類選定。
2. 2000mm(流れ方向)×1500mm(幅方向)(AF 及び ABF)、1200mm(流れ方向)×1000mm(幅方向)(BF)の段ボールシートで作製できない寸法組み合わせを除外。
3. 残った組み合わせ(64~84 種類)から無作為(重複不可)に 40 種類(箱形式 0201)、20 種類(箱形式 0215)、15 種類(箱形式 0300)の内側寸法を選定。
4. 1、2 の手順を段種、箱形式ごとで別々に行う。3 の手順を段ボールシートの材質ごとで別々に行う。




箱形式 0201 は 800 箱(AF:材質 12 種類、BF:材質 4 種類、ABF:材質 4 種類)、箱形式 0215 は 200 箱(AF:材質 10 種類)、箱形式 300 は 150 箱(AF:材質 10 種類)の合計 1150 種類の段ボール箱を作製した。

表 1 段ボールの材質

段種	ライナ材質	中しん材質	製造会社
AF	C160 K140 K170 K210 K280	S120 PS120 S160 PS180	3社
BF	C160 K140 K170 K210	S120	2社
ABF	K140 K170 K210 K280	S120	2社

^{*1} 産業技術センター 環境材料室

表 2 段ボール箱の段種、箱形式及び内側寸法範囲[mm]

		箱形式		
		0201  (抜粋)JISZ1507	0215  (抜粋)JISZ1507	0300  (抜粋)JISZ1507
段 種	AF (5mm)	計480箱(寸法40種×材質12種)	計200箱(寸法20種×材質10種)	計150箱(寸法15種×材質10種)
		長さ:101~743(106種類) 幅:101~743(106種類) 高さ:101~743(106種類)	長さ:101~743(106種類) 幅:101~743(106種類) 高さ:101~743(106種類)	長さ:101~743(106種類) 幅:101~743(106種類) 高さ:53~199(31種類)
	BF (3mm)	計160箱(寸法40種×材質4種)		
		長さ:53~397(63種類) 幅:53~397(63種類) 高さ:53~397(63種類)		
	ABF (8mm)	計160箱(寸法40種×材質4種)		
		長さ:101~743(106種類) 幅:101~743(106種類) 高さ:101~743(106種類)		

合計1150箱(箱形式0201のみ800箱)

2.2 圧縮強度の測定方法

圧縮強度の測定は段ボール箱を 23℃/50%R.H.の環境下に 24 時間以上静置した後、箱圧縮試験機((株)島津製作所製、AG-10kNA)を用いて JIS Z 0212(方法 B)の試験方法で行った。

2.3 人工知能の作成方法

人工知能の作成は人工知能作成支援ツール(ソニーネットワークコミュニケーションズ(株)製、Prediction One、<https://predictionone.sony.biz/>)を用いて行った。人工知能に学習させるデータは表 3 に示すケリカットの簡易式で用いる物性値に近づけた特徴量 A とデータを細かく分けた特徴量 B の 2 条件とした。ケリカットの簡易式の詳細は図 1 に示す。

表 3 学習させるデータ項目

	特徴量
A	段種、ライナ材質、中しん材質、周辺長、圧縮強度
B	段種、ライナ等級、ライナ坪量、中しん等級、中しん坪量、長さ、幅、高さ、箱形式、製造会社、含水率、圧縮強度

ケリカットの簡易式

$$P_k = \beta \times R_x \times Z^{\frac{1}{3}}$$

 P_k :段ボール箱の強度[kN] β :段種ごとの定数 R_x :ライナ(表、裏)、中しん強度の和[kN/m] Z :周辺長[cm]

図 1 ケリカットの簡易式

2.4 ケリカットの簡易式との比較方法

既存推定式であるケリカットの簡易式は箱形式 0201 の段ボール箱の圧縮強度を推定する方法である。段ボール箱の箱形式は 0201 に限定して、ケリカットの簡易式と人工知能による推定の正確度及び精度を比較した。比較に用いた段ボール箱は材質を表 4 に示す 3 種類(AF のみ)に限定した 120 箱(寸法 40 種×3 種)と箱形式 0201 全データ 800 箱(寸法 40 種×20 種)の 2 条件とした。

表 4 限定した段ボールの材質

ライナ材質/中しん材質
C160/S120
K170/S120
K210/S120

2.5 人工知能の正確度及び精度の評価方法

人工知能は図 2 で示すように、収集したデータを無作為に並べて a~e に 5 等分し、一部のデータ(b~e)を使用して人工知能を作成し、残りのデータ(a)を用いて正確度及び精度を評価した。評価は学習用データと評価用データの組み合わせを変え、すべての組み合わせ(5 種類)の平均値で行った。正確度を平均誤差率(MPE)、推定精度を平均絶対誤差率(MAPE)及び平均平方二乗誤差率(RMSPE)の値で評価した。計算式の詳細は図 3 で示す。




図 2 学習用及び評価用データの分け方

$$\begin{aligned}
 & \text{(正確度)} \\
 & MPE = \frac{1}{n} \sum_{i=1}^n \frac{\hat{x}_i - x_i}{x_i} \\
 & \text{(精度)} \\
 & MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{x}_i - x_i}{x_i} \right| \\
 & RMSPE = \sqrt{\frac{1}{n} \sum_{i=1}^n \left(\frac{\hat{x}_i - x_i}{x_i} \right)^2} \\
 & \hat{x}: \text{推測値} \\
 & x: \text{実測値}
 \end{aligned}$$

図3 正確度及び精度の計算方法

3. 実験結果及び考察

3.1 ケリカットの簡易式と人工知能の正確度及び精度比較

特徴量Aでの、ケリカットの簡易式及び人工知能の正確度及び精度の評価結果を表5に示す。120箱では、人工知能の方がMPEの値が0に近づき、正確度は高くなったが、MAPE、RMSPEの値から精度はほぼ同等であった。800箱では、人工知能の方がケリカットの簡易式より正確度及び精度が高くなった。人工知能に学習させる段ボールの材質及び段種を120箱(AF:材質3種類)から800箱(AF:材質12種類、BF:材質4種類、ABF:材質4種類)に増やすと、正確度及び精度は若干低下した。正確度及び精度の低下はケリカットの簡易式でも見られる傾向であったため、測定データ自体のパラツキの影響を受けていることも懸念される。

表5 ケリカットの簡易式と人工知能の
正確度及び精度

	平均誤差率 (MPE)	平均絶対誤差率 (MAPE)	平均平方二乗誤差率 (RMSPE)
ケリカット (120箱)	-3.5%	10.0%	13.0%
ケリカット (800箱)	-6.7%	12.9%	16.2%
人工知能 (120箱)	0.4%	10.0%	12.9%
人工知能 (800箱)	1.5%	10.2%	13.5%

3.2 人工知能が推定する周辺長と圧縮強度の関係

人工知能に段ボール箱の周辺長と圧縮強度の関係を推定させ、ケリカットの簡易式との比較を行った。本節(3.2節)では正確度及び精度の評価を行わないため、図2のように学習用データと評価用データを分けることはせず、全てを学習用データとして人工知能を作成した。人工知能は材質を3種類に限定した120箱(表4)と箱形式0201全データ800箱の2条件で、特徴量Aを用いて作

成した。強度推定をする段ボール箱は段種:AF、材質:K170(ライナ)/S120(中しん)の条件とし、段ボール箱の周辺長を1~2500mmの範囲で1mm間隔に強度推定を行った。

図4に周辺長と圧縮強度の推定値の関係を示す。120箱の場合ではジグザグな曲線となったのに対し、800箱に学習用データの数を増やすと曲線が比較的滑らかになることが分かった。また、今回人工知能の学習に用いた段ボール箱の周辺長は120箱では540~1952mm、800箱では256~1952mmの範囲であった。学習していない範囲では圧縮強度の値が一定となり、強度推定が正確に行えないことが分かった。




図4 学習用データ数による比較

図5に、ケリカットの簡易式と人工知能(800箱)の強度推定結果及び実測値(40箱)を示す。周辺長が256~1527mmの範囲ではケリカットの簡易式と人工知能の差が±10%以内であり、近い推定値を示した。周辺長が1528~1932mmの範囲では、人工知能の方がケリカットの簡易式より5~18%高い強度を推定した。




図5 ケリカットの簡易式と人工知能の比較

3.3 学習させるデータ項目による正確度及び精度への影響

人工知能に学習させるデータ項目を変えた場合の影響について検討した。特徴量Bで作成した人工知能の評価結果を表6に示す。評価は箱形式0201全データ(800箱)

で行った。特徴量 A の結果(表 5)と比較をすると、特徴量 B の方が高い正確度及び精度が得られることが分かった。人工知能に学習させるデータ項目は推定結果に大きな影響を与えることが分かった。

表 6 特徴量 B の場合の正確度及び精度

	平均誤差率 (MPE)	平均絶対誤差率 (MAPE)	平均平方二乗誤差率 (RMSPE)
人工知能 (学習項目B) (0201のみ) (800箱)	1.0%	6.7%	8.7%

3.4 全データ(1150 箱)での評価

本研究で収集した全データ(1150 箱)で作成した人工知能の評価結果を表 7 に示す。人工知能は特徴量 B を用いて作成した。また、段種及び箱形式ごとの評価結果も併せて示す。

表 7 全データ(1150 箱)での正確度及び精度

	平均誤差率 (MPE)	平均絶対誤差率 (MAPE)	平均平方二乗誤差率 (RMSPE)
人工知能 (全データ) (1150箱)	0.6%	7.5%	9.7%
人工知能 (AF, 0201)	0.4%	6.6%	8.5%
人工知能 (AF, 0215)	1.8%	8.6%	11.2%
人工知能 (AF, 0300)	-1.4%	6.1%	7.4%
人工知能 (BF, 0201)	2.3%	9.4%	11.9%
人工知能 (ABF, 0201)	-0.2%	8.1%	10.5%

全データでの評価結果を箱形式 0201 のみ(800 箱)(表 6)と比較すると、精度が若干低下した。精度の低下は 3.1 節で収集データの数 120 箱から 800 箱に増やした際にも同様の傾向がみられており、推定可能な段ボール箱の種類が増えると精度が低下することが考えられる。また、ケリカットの簡易式(800 箱)(表 5)よりは高い正確度及び精度が得られた。

段種及び箱形式ごとの評価結果に注目する。全ての条件でケリカットの簡易式(800 箱)(表 5)よりも高い正確度及び精度が得られていることが分かった。ケリカットの簡易式では強度推定不可能な 0201 以外の箱形式に対しても、人工知能に学習をさせることで強度推定が可能になることを示した。

4. 結び

本研究の結果は、以下のとおりである。

- (1) 人工知能に学習させることで段ボール箱の圧縮強度が推定できることを示した。ただし、学習していない範囲では強度推定が正確に行えなかった。
- (2) 周辺長 256~1527mm の範囲で、人工知能(特徴量 A)とケリカットの簡易式に近い推定値を示した。
- (3) 人工知能に学習させるデータを細かく分けた特徴量 B ではケリカットの簡易式よりも高い正確度及び精度が得られた。
- (4) ケリカットの簡易式では強度推定不可能な箱形式 0215、0300 に対しても、人工知能に学習させることで強度推定が可能になることを示した。
- (5) 推定可能な段ボール箱の種類を増やすと精度は低下する傾向がみられた。

本研究では輸送包装の分野での人工知能を活用した事例を示した。今後は更なる人工知能の輸送包装の分野における活用の可能性を模索していく。

付記

本研究は、公益財団法人内藤科学技術振興財団の 2021 年度研究助成を受けて実施した。

文献

- 1) 総務省: 平成 28 年度版情報通信白書, 235(2016)
- 2) 公益社団法人日本包装技術協会: 第 56 期包装管理士講座, §8-15(2021)