

一般論文

# ニューラルネットワークを用いた 段ボール箱の圧縮強度予測

飯田 恭平 \*

## Prediction of the Compressive Strength of Cardboard Boxes using a Neural Network

Kyohei IIDA \*

本研究では、ニューラルネットワークを用いて段ボール箱の圧縮強度の予測モデルを作成し、予測精度の評価を行った。活性化関数は Swish 関数を用いて、隠れ層のノード数及び層数を変化させて予測精度が高くなる条件を検討した。その結果、RMSPE が 8.53%になる条件が得られた。この値はケリカットの簡易式よりも高い予測精度であった。また、予測モデルが中仕切り及び中仕切りを入れた段ボール箱にも活用できることが分かった。

In this study, we made a predictive model for the compressive strength of cardboard boxes using a neural network, and evaluated the prediction accuracy. The swish function was used as the activation function. We searched for conditions with high prediction accuracy by changing the number of nodes and layers in the hidden layer. As a result, a condition was obtained that result in the root mean squared percentage error of 8.53%. This value indicates better prediction accuracy than the simple kelicutt formula. Furthermore, the predictive model can predict the compressive strength of partitions and cardboard boxes containing partitions.

キーワード：段ボール箱、圧縮強度、機械学習、ニューラルネットワーク、中仕切り

Keywords：Cardboard box, Compressive strength, Machine learning, Neural network, Partition

### 1. 緒言

人工知能の定義は研究者ごとで異なるが、おおまかには「知的な機械、特に、知的なコンピュータプログラムを作る科学と技術」と言われる<sup>1)</sup>。人間の脳の働きをコンピュータで再現するために、Fig.1 で示す人工ニューロンが考え出された。入力層、隠れ層、出力層の 3 層構造でノードをつなぎ合わせたものが

Fig.2 で示すニューラルネットワークの一例である<sup>2)</sup>。




Fig.1 Artificial neuron

\* 連絡者(Corresponding author), あいち産業科学技術総合センター産業技術センター (〒448-0013 愛知県刈谷市恩田町 1 丁目 157 番地 1), Aichi Center for Industry and Science Technology Industrial Research Center 1-157-1 Onda-cho, Kariya-shi, Aichi-ken, 448-0013, Japan, TEL:0566-45-6902, FAX:0566-22-8033, Email:kioyuehi\_iida@pref.aichi.lg.jp




Fig.2 Neural network

2000 年代以降は第三次人工知能ブームと呼ばれており、このブームは「マシンラーニング(機械学習)」の実用化、「ディープラーニング(深層学習、特徴表現学習)」の登場により起きたとされている<sup>1)</sup>。ブームが起きた結果、現在では多くの人工知能が開発、販売されている。

これまで、我々は輸送包装分野で人工知能活用方法の模索を目的として、市販の AI 予測分析ツールを用いて、段ボール箱の強度予測モデルを作成してきた。強度予測モデルと従来の予測方法(ケリカットの簡易式)及び統計学(重回帰分析)の予測精度の比較<sup>3)4)5)</sup>、ケリカットの簡易式の適用範囲外である箱形式 0215、0300 の段ボール箱の強度予測結果<sup>5)6)</sup>、予測精度が高い説明変数の選定結果<sup>7)</sup>について報告している。

本研究では、学習のアルゴリズムをニューラルネットワークとし、隠れ層のノード数及び隠れ層の層数を変化させて段ボール箱の圧縮強度の予測精度が高くなる条件を検討した。

また、G.G.Maltenfort は「“中仕切り”の圧縮強度推定は、段ボール箱の圧縮強度推定と同じではなく、そんなに単純なものではない」と述べている<sup>8)</sup>。そこで、中仕切り及び中仕

切りを入れた段ボール箱を強度予測モデルの学習及び予測対象に加えた場合の予測精度を求めたので、その結果について報告する。

## 2. 実験方法

### 2.1 段ボール箱圧縮強度のデータ収集

強度予測モデルの訓練、検証及びテスト用として、段ボール箱のデータを合計 1480 種類収集した。段ボール箱の作製は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)を用いた。使用した段ボールシートの材質を **Table1**、作製した段ボール箱の種類内訳を **Table2**、段ボール箱の内側寸法及び圧縮強度の範囲を **Table3** に示す。中仕切りについては胴枠(a)、十字仕切り(b)、キ字仕切り(c)(長辺 1 枚、短辺 2 枚)、サ字仕切り(d)(長辺 2 枚、短辺 1 枚)、井桁仕切り(e)の 5 種類とした。中仕切りの外観の一例を **Fig.3** 及に示す。中仕切りの長さ、幅、高さは段ボー

Table1 Cardboard materials

No.	Flute / Liner / Corrugating Medium	The number of boxes
①	AF / C160 / S120	75
②	AF / K140 / S120	75
③	AF / K170 / S120	75
④	AF / K170 / PS120	75
⑤	AF / K170 / S160	75
⑥	AF / K210 / S120	225
⑦	AF / K210 / PS120	75
⑧	AF / K210 / S160	75
⑨	AF / K210 / PS180	225
⑩	AF / K280 / S120	75
⑪	BF / C160 / S120	40
⑫	BF / K140 / S120	40
⑬	BF / K170 / S120	40
⑭	BF / K210 / S120	40
⑮	WF / K140 / S120	40
⑯	WF / K170 / S120	40
⑰	WF / K210 / S120	150
⑱	WF / K280 / S120	40
Total(18types)		1480

ル箱の内側寸法と同じとした。中仕切りを入れた段ボール箱は中仕切りのみ及び段ボール箱のみの状態でも圧縮強度を測定した。圧縮強度の測定は 23℃/50%R.H.の環境下に 24 時

間以上静置したあと、箱圧縮試験機((株)島津製作所製、AG-10kNA)を用いて JISZ0212:1998(方法 B)の試験方法で行った。

Table2 Types of boxes





Types of boxes	Partitions	Flute	Material	The number of boxes	Subtotal
0201 	Not included	AF	①~⑤ ⑦,⑧,⑩	40 of each	500
			⑥,⑨	90 of each	
		BF	⑪~⑭	40 of each	160
		WF	⑮,⑯,⑰	40 of each	170
⑱			50		
0215 		AF	①~⑩	20 of each	200
0300 	①~⑩		15 of each	150	
0201 	a~e	AF	⑥,⑨	10 of each	100
		WF	⑱	10 of each	50
No box (Partition only)	a~e	AF	⑥, ⑨	10 of each	100
		WF	⑱	10 of each	50
Total					1480

Table3 Range of dimensions and compressive strength

Types of boxes	Partitions	Flute	Length [mm]	Width [mm]	Height [mm]	Perimeter [mm]	Compressive strength[N]
0201	Not included	AF	139~733	80~443	107~743	520~1932	1340~ 6650
		BF	67~397	53~251	53~397	256~1104	940~ 4060
		WF	157~739	100~461	101~727	516~1920	2340~12300
0215		AF	109~739	101~467	113~739	420~1928	1260~ 6470
0300		AF	179~701	101~647	53~199	612~2660	2850~16540
0201		a~e	AF	180~520	80~420	170~430	520~1880
	WF		200~500	100~400	200~400	600~1800	5660~15690
No box (Partition only)	a~e	AF	180~520	80~420	170~430	520~1880	830~10170
		WF	200~500	100~400	200~400	600~1800	1950~11130




Fig.3 Appearance of partitions

## 2.2 強度予測モデルの作成

Neural Network Console(ソニーネットワークコミュニケーションズ(株)製)を用いて強度予測モデルを作成した。Input(説明変数)はTable4に示し、Output(目的変数)は圧縮強度とした。Category(文字列)から Numeric(数値)への変換は One-Hot エンコーディング(文字列を0と1の数値に変換)の手法を用いた。最適化手法はミニバッチ勾配降下法を用いた。

Table4 Explanatory variables

Parameter	Types of data	The number of parameter
Material	Category	18
Length	Numeric	1
Width	Numeric	1
Height	Numeric	1
Perimeter	Numeric	1
Types of boxes	Category	4 (including none)
Partitions	Category	6 (including none)
Total		32

### 2.2.1 活性化関数の選定

活性化関数は入力値を別の形に変えて出力する関数である。活性化関数の選択肢は多く、よく使われる活性化関数は時代と共に変化している。本研究では、Fig.4に示す Swish 関数を用いることにした。

Swish 関数はディープラーニングの登場で注目されるようになった ReLU(Rectified Linear Unit)(Fig.5)の発展型であり、強化学習を用いて探索された活性化関数である。複数のモデルで他の活性化関数よりも良い精度が得られることが報告されている<sup>9)</sup>。Swish 関数は ReLU に非常によく似た曲線を描くが、曲線が滑らかで連続的かつ非単調な点が異なる。




Fig.4 Activation function (Swish)




Fig.5 Activation function (ReLU)

### 2.2.2 ニューラルネットワークの構成

Table5の構成でニューラルネットワークを構築した。学習の安定化及び収束を早めるため、Batch Normalization<sup>10)</sup>を affine(全結合層)の後に挿入した。隠れ層のノード数は3, 7, 17, 37, 73, 149, 307の7種類とした。Neural Network Consoleではロス関数はレイヤーで用意がされている。そこで、ロスレイヤーは

Squared Error(二乗誤差を最小化する出力層)を用いた。

Table5 の隠れ層を 1~5 層につなぎ合わせて予測精度を評価した。ノード数は全ての隠れ層で同じ値を用いた。

Table5 Layer structure

1Layer } 5Layers	Input Layer	Input	size:32
	Hidden Layer	Affine	Out Shape: 3,7,17,37,73,149,307
		Batch Normalization	—
		Activation Function	Swish
	Output Layer	Affine	Out Shape:1
		Batch Normalization	—
		Output (Squared Error)	size:1

2.2.3 強度予測モデルの選定方法

epoch(学習反復世代)数は 200 とした。隠れ層：2 層、ノード数：73 の条件の学習曲線を Fig.6 に示す。Validation Error (検証データを予測した時の誤差)を 10epoch 間隔で求め、Validation Error が最も小さくなった epoch の強度予測モデルを使用した。




Fig.6 Learning Curve

2.3 強度予測モデルの精度評価方法

2.3.1 データの分割方法

強度予測モデルの精度評価は Fig.7 で示すように、収集した全データを訓練データ(80%、1184 個)、検証データ(10%、148 個)及びテストデータ(10%、148 個)に分けて行った。データ分割は無作為に実施した。




Fig.7 How to divide training data, validation data and test data

2.3.2 予測精度の算出方法

強度予測モデルの予測精度はテストデータを用いて、Fig.8 に示す平均平方二乗誤差率(以下、「RMSPE」とする)で評価した。

$$RMSPE = \sqrt{\frac{1}{n} \sum_{i=1}^n \left( \frac{\hat{x}_i - x_i}{x_i} \right)^2}$$

x : Actual value  
 $\hat{x}$  : Predicted value

Fig.8 Root mean squared percentage error

3. 実験結果及び考察

3.1 ノード数及び層数と誤差率の関係

本節では、Fig.7 のデータ分割を 5 回行い、740 個のテストデータから RMSPE の平均値を求めた。隠れ層のノード数及び層数と RMSPE の関係を Fig.9 に示す。各層数での RMSPE の最小値を Table6 に示す。

隠れ層が 2 層、ノード数が 73 のときに RMSPE : 8.57% となり、予測精度が最も高くなった。隠れ層は 3 層以上に増やしても予測精度の向上はみられなかった。

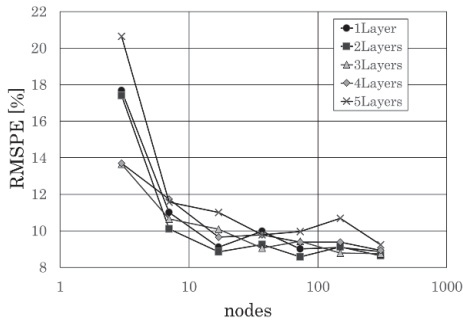


Fig.9 RMSPE each the number of layers

Table6 Minimum RMSPE each the number of layers

The number of Layers	RMSPE[%] (The number of nodes)
1Layer	8.86 (307)
2Layers	8.57 ( 73)
3Layers	8.76 (307)
4Layers	8.94 (307)
5Layers	9.24 (307)

3.2 強度予測モデルの予測精度評価

3.1 節で得られた、隠れ層：2 層、ノード数：73 の条件を用いて予測精度の評価を行っ

た。本節では、段ボール箱の種類及び材質ごとの予測精度について細かく比較を行うが、3.1 節で用いた 740 個のテストデータではデータ数の少ない材質があった。そのため、本節では Fig.7 のデータ分割を 20 回行い、2960 個のテストデータから予測精度を評価することにした。全データでの RMSPE の平均値は 8.57%から 8.53%になった。

3.2.1 ケリカットの簡易式との比較

Fig.10 に圧縮強度の実測値と予測値(ケリカットの簡易式)、Fig.11 に実測値と予測値(強度予測モデル)の関係を示す。ケリカットの簡易式を Fig.12 に示す。ケリカットの簡易式は箱形式 0201 に対してのみ予測を行った。

ケリカットの簡易式の RMSPE は 16.3%であり、強度予測モデルの予測精度の方が高いことが分かった。特に圧縮強度の実測値 6000N 以上の範囲では予測精度の差が大きく、ケリカットの簡易式の RMSPE は 21.3%、強度予測モデルの RMSPE は 7.91%であった。

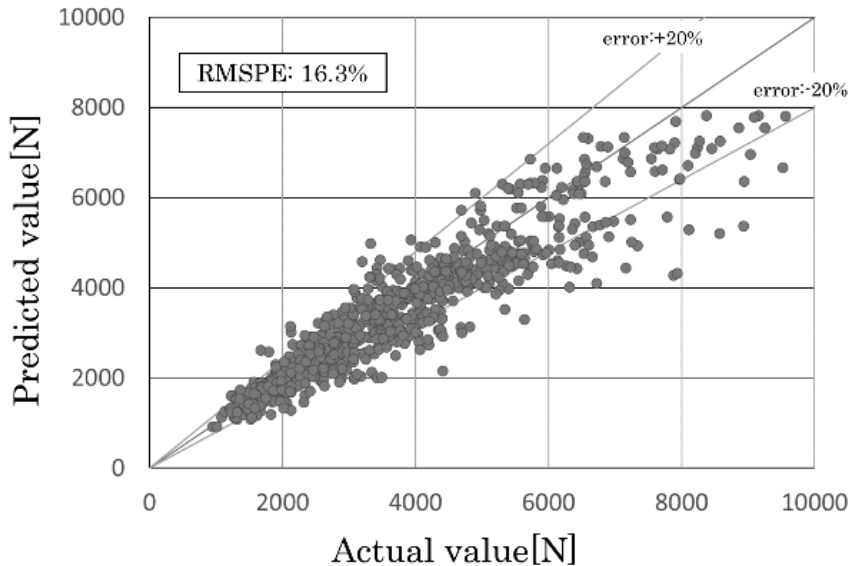


Fig.10 Relationship between Actual and predicted values (Kellicutt formula)

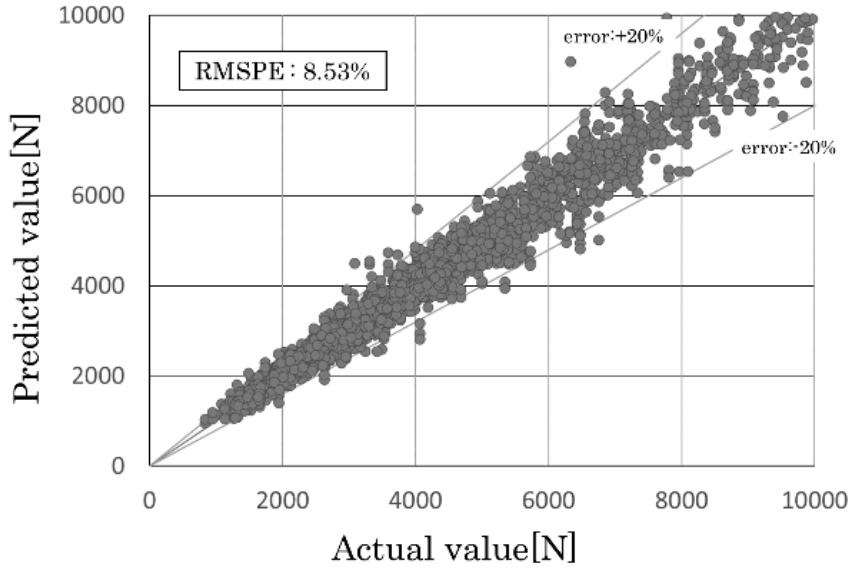


Fig.11 Relationship between Actual and predicted values (Strength predicted model)

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

$P_k$  :Compressive strength[kN]  
 $\beta$  :Constants for each flute  
 $R_x$  :Sum of ring crush resistance[kN/m]  
 $Z$  :Perimeter[cm]

Fig.12 Kellcutt formula (Simplified style)

段ボール箱の周辺長と圧縮強度の実測値及び予測値の関係の一例を示す。段ボール箱の周辺長(長さ×幅)以外の条件は固定した。

Fig.13 にケリカットの簡易式、Fig.14 に強度予測モデルの関係を示す。Fig.14 では長さ又は

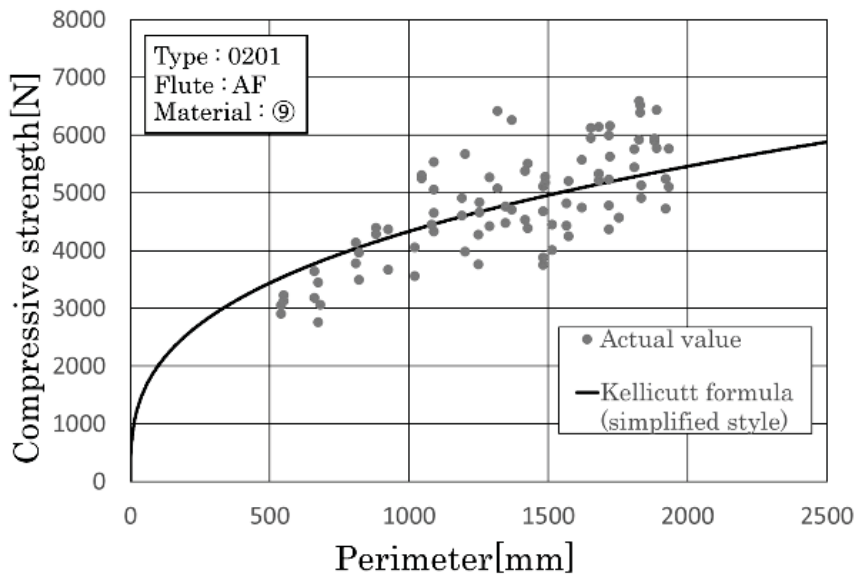


Fig.13 Relationship between Perimeter and compressive strength (Kellcutt formula)

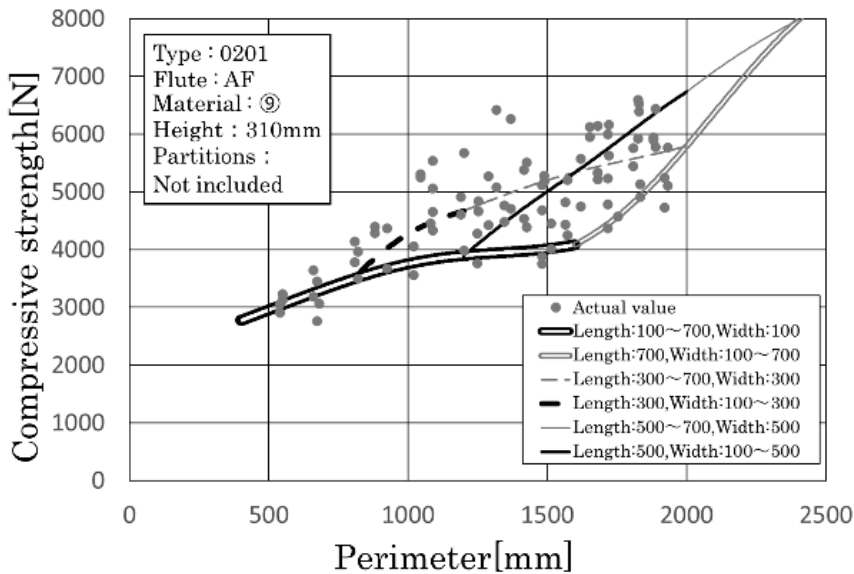


Fig.14 Relationship between perimeter and compressive strength (Strength predicted)

幅の片方を固定し、固定しなかった条件を 1mm 間隔で変化させて圧縮強度を予測させた。

ケリカットの簡易式では長さとの関係に関わらず予測値が 1 本の曲線で表されるのに対して、強度予測モデルでは複数の曲線を描くことが分かる。強度予測モデルでは周辺長が同じでも、長さとの関係に応じて複数の値を予測するため、ケリカットの簡易式よりも高い予測精度が得られたと考えられる。

強度予測モデルではさらに研究を深く進めることで、段ボール箱圧縮強度の挙動を細かく解析できる可能性を持つと考えられる。詳細な解析については今後の検討課題としたい。

### 3.2.2 予測精度の詳細

段ボール箱の種類ごとの予測精度を Table7 に示す。中仕切り及び中仕切り入り段ボール箱の RMSPE は 7.50~9.62%、4 種データの平均値は 8.66%であり、他の段ボール箱と大差

なく強度予測が出来ることが分かった。

段ボールシートの材質ごとの予測精度を Table8 に示す。圧縮強度(実測値)の一定範囲ごとの予測精度を Table9 に示す。段種 BF 及び圧縮強度 2000N 未満の範囲で RMSPE が 10%以上になり、他の条件と比べて予測精度が悪いことが分かった。圧縮強度 2000N 未満の条件で、BF のみ及び BF 以外の予測精度を Table10 に示す。両者の予測精度には大きな違いがなかった。

これらの結果から、本研究で作成した強度予測モデルは低い圧縮強度の予測精度が悪いことが分かった。BF は圧縮強度 2000N 未満のデータの割合が多い(160 個中 102 個)ため、予測精度が悪くなったと考えられる。1000N 未満のさらに低い圧縮強度の段ボール箱のデータを充実させることで、予測精度の改善に期待ができる。



Table7 RMSPE per type of boxes

Types of boxes	Partitions	Flute	Material	The number of test data	RMSPE[%]
0201	Not included	AF	①～⑩	1034	7.80
		BF	⑪～⑭	313	11.4
		WF	⑮～⑱	325	8.72
0215		AF	①～⑩	398	9.30
0300		AF	①～⑩	307	5.52
0201	a～e	AF	⑥, ⑨	181	9.11
		WF	⑰	95	9.62
No box (Partition only)	a～e	AF	⑥, ⑨	206	8.32
		WF	⑰	101	7.50

Table8 RMSPE per materials

No.	Flute / Liner / Corrugating Medium	The number of test data	RMSPE[%]
①	AF / C160 / S120	157	7.78
②	AF / K140 / S120	169	7.72
③	AF / K170 / S120	159	7.50
④	AF / K170 / PS120	160	6.70
⑤	AF / K170 / S160	180	7.61
⑥	AF / K210 / S120	439	8.36
⑦	AF / K210 / PS120	139	6.14
⑧	AF / K210 / S160	163	6.01
⑨	AF / K210 / PS180	418	9.76
⑩	AF / K280 / S120	142	7.59
⑪	BF / C160 / S120	83	10.3
⑫	BF / K140 / S120	71	11.3
⑬	BF / K170 / S120	79	11.5
⑭	BF / K210 / S120	80	12.3
⑮	WF / K140 / S120	74	9.68
⑯	WF / K170 / S120	78	7.14
⑰	WF / K210 / S120	298	8.55
⑱	WF / K280 / S120	71	9.57

Table9 RMSPE per compressive strength

Compressive strength [N]	The number of test data	RMSPE[%]
Under 2000	297	11.5
2000 ~ 2999	565	8.52
3000 ~ 3999	635	8.32
4000 ~ 4999	471	7.58
5000 ~ 5999	245	8.35
6000 ~ 6999	250	8.84
7000 ~ 7999	158	7.23
8000 ~ 8999	106	5.90
9000 ~ 9999	78	6.68
10000 ~ 10999	57	7.68
11000 ~ 11999	46	9.37
12000 or more	52	9.21

Table10 RMSPE per flute in the range of compressive strength under 2000N

Material		The number of test data	RMSPE[%]
Compressive strength under 2000N	Only BF	198	11.6
	Except for BF	99	11.4

#### 4. 結論

(1) 活性化関数を Swish 関数、隠れ層 2 層、ノード数 73 のニューラルネットワークを用いて強度予測モデルを作成した。段ボール箱の圧縮強度を RMSPE : 8.53% の精度で予測する強度予測モデルが作成できた。ケリカットの簡易式は RMSPE : 16.3% であり、強度予測モデルの方が高い予測精度が得られることを示した。

(2) 中仕切り及び中仕切りを入れた段ボール箱の RMSPE は 8.66% であり、他の段ボール箱の予測精度と大差ないことが分かった。中

仕切り及び中仕切りを入れた段ボール箱に対しても、強度予測モデルが活用できることを示した。

本研究は説明変数に文字列を含むため、データ収集を行っていない段種 CF の段ボール箱などの強度予測には対応することが難しい。今後は、説明変数を全て数値にして学習させることで、訓練データに含まない材質の段ボール箱の予測精度の評価を行いたいと考えている。また、圧縮強度以外の輸送包装分野での機械学習の活用方法についても検討をしていく。

＜参考文献＞

- 1) 総務省,平成 28 年度版情報通信白書, p.235,p.233(2016),<https://www.soumu.go.jp/johotsusintokei/whitepaper/ja/h28/pdf/index.html>(2022 年 9 月 13 日)
- 2) 柴田良一,“はじめての「SonyNNC」”(ソニー(株),ソニーネットワークコミュニケーションズ(株)監修),(株)工学社,p.17,p.245 (2021)
- 3) 飯田恭平,機械学習を活用した段ボール強度推定の新たな試み,日本包装学会,第 31 回年次大会予稿集,p.56 (2022)
- 4) 飯田恭平,機械学習による段ボール強度予測 - 統計学との比較 -, 日本包装学会誌,**31**(6),p.375 (2022)
- 5) 飯田恭平,人工知能による段ボール強度の新たな推定方法,あいち産業科学技術総合センター研究報告,11,p.42 (2022)
- 6) 飯田恭平,人工知能を用いた箱形式 0215、0300 の段ボール強度予測,第 60 回全日本包装技術研究大会大会予稿集,p.73 (2022)
- 7) 飯田恭平,人工知能を用いた段ボール強度予測,第 62 回包装技術研究大会中部大会,p.21 (2022)
- 8) 川端洋一,“よくわかる段ボール包装設計講座-合理化のための圧縮強度の考え方-”,日報企画販売(株),p.154(2000)
- 9) P. Ramachandran, B. Zoph, Q. V. Le, Searching for Activation Functions, arXiv:1710.05941v2 [cs.NE] (2017)
- 10) S. Ioffe, C. Szegedy, Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, arXiv:1502.03167v3 [cs.LG] (2015)

(原稿受付 2023 年 7 月 8 日)

(採録受理 2023 年 11 月 6 日)