

東京電機大学

博士論文

ディープラーニングプロトタイプ開発手法の研究と
DX 推進及びデジタルツイン応用への展開

Research on deep learning prototype development
methods and deployment to DX promotion and digital
twin applications

2024年3月

大高 謙二

目次

1. 序章	5
1.1. 研究の背景	5
1.2. 研究の目的	8
1.3. 論文の構成	10
2. 関連研究と課題	12
2.1. DL システム構築に関する関連研究と課題	12
2.1.1 AI におけるディープラーニングの位置付け	12
2.1.2. ディープニューラルネットワーク (DNN) の構造と DL の仕組み	15
2.1.3. DL の代表的アルゴリズムの概要	18
2.1.4. DL システム構築の技術育成に関する関連研究	24
2.1.5. DL システム構築および技術者育成における課題	25
2.2. DX 推進技術者育成の関連研究と課題	26
2.2.1. DX 推進の概要	26
2.2.2. DX 推進の技術者育成に関する関連研究	27
2.2.3. DX 推進における技術者育成の課題	28
2.3. デジタルツイン技術者育成の関連研究と課題	29
2.3.1. デジタルツインの概要	29
2.3.2. デジタルツインの関連研究	29
2.3.3. デジタルツインの特徴と技術者育成上の課題	31
3. DL 応用プロトタイプ開発手法の研究	33
3.1. DL システム構築および技術者育成における課題	33
3.2. DL システム構築の課題対策に関する提案	37
3.2.1. データ準備の手法の提案 (課題 1)	37
3.2.2. DL システム構築におけるチューニング手法の提案 (課題 2)	38
3.2.3. DL モデルの評価手法の提案 (課題 3)	42
3.2.4. 課題対策を踏まえたプロトタイプの開発	42
3.2.5. 技術者育成手法に関する提案 (課題 4)	46
3.3. 提案内容の実践	50
3.3.1. CNN チューニング手法の提案内容に関する検証	50
3.4.2. CNN モデルの性能検証とデータ準備手法の検証	55
3.4.3. LSTM のチューニング手法の提案内容に関する評価	63
3.3.4. 技術者育成提案に関する講座での実践と評価	69
3.4. 宿題実習結果の評価	76
3.4.1. DL システム構築の課題解決の提案に関する評価	76

3.4.2.	技術者育成に関するカリキュラム内容の評価.....	76
3.4.3.	実践講座の宿題結果から見た受講生の理解度評価.....	76
3.5.	宿題実習結果の考察.....	80
3.6.	まとめ.....	82
4.	DX 推進プロトタイプ開発と技術者育成手法の研究.....	83
4.1.	DX 推進技術者育成手法の提案.....	83
4.1.1.	DX 教育の体系.....	84
4.1.2.	教育内容.....	85
4.1.3.	理解促進のための実習推進上の工夫点.....	86
4.1.4.	評価手法.....	87
4.2.	システム構築実習の実践.....	88
4.2.1.	受講生の概要.....	88
4.2.2.	実施形態.....	88
4.2.3.	教材の体系.....	88
4.2.4.	実習の内容.....	89
4.2.5.	実習実施手順の工夫点.....	91
4.2.6.	受講生の評価方法.....	92
4.2.7.	宿題結果の評価に関する実習での達成目標.....	92
4.3.	宿題実習結果の評価.....	93
4.4.	宿題実習結果の考察.....	96
4.5.	まとめ.....	99
5.	デジタルツインプロトタイプ開発と技術者育成手法の研究.....	100
5.1.	デジタルツインプロトタイプ開発と教育手法の提案.....	100
5.2.	プロトタイプ構築教育の実践内容.....	105
5.2.1.	実習の実施形態.....	105
5.2.2.	プロトタイプ構築教育での実践内容.....	105
5.2.3.	評価方法.....	108
5.2.4.	宿題結果の評価に関する実習での達成目標.....	109
5.3.	宿題実習結果の評価.....	110
5.3.1.	実習における宿題の提出内容と理解度評価.....	110
5.3.2.	受講生による理解度の自己評価.....	111
5.4.	宿題実習結果の考察.....	113
5.4.1.	実践による教育手法の考察.....	113
5.4.2.	実践における課題への対策.....	113
5.5.	まとめ.....	115
6.	結言.....	116

謝辭	119
参考文献	120
1 章分	120
2 章分	121

1. 序章

1.1. 研究の背景

近年において、コンピューティングパワーの向上、ネットワークの高速化、ビッグデータの出現など、情報通信技術の発展により社会生活の革新が促進されてきた。この動向に呼応して発展したのが AI であり、特にこれらの技術革新によって従来の統計的手法による機械学習に加え、ディープラーニング（以下 DL）の技術が急速に進歩し普及が進んでいる。この DL の最大の特徴は、機械学習機能を活用して大量のデータを学習することで、日常の発生データから現在発生している事象や将来起こり得る事象について知見を得る機能を提供できることである。この機能によって、発生したデータから迅速に企業経営に資する知見を得る、現状の状態を監視する、将来の発生事象を予測するなどの機能が提供可能となり、これらによって社会に変革をもたらすことが現実的になってきている。(1) (2) (3)

さらにこの DL の技術進歩は、経産省が提唱した「2025 年の崖」の中で指摘された IT システムの課題解決手段として推進されているデジタルトランスフォーメーション（以下 DX）推進のキーテクノロジーとしても位置付けられる。DX 推進は AI に代表されるデジタル技術を活用して企業経営の構造改革を目指すものであるが、DL は日常で発生する大量のデータを分析し、経営判断の迅速化、状態監視、将来予測を可能とすることから DX 推進を支える中心的な技術の一つと位置付けられる。(4) (5)

また、昨今の重要な技術革新の一つにデジタルツインがある。デジタルツインは物理システムを仮想空間上に再構築し、物理システムからの情報を受信して物理システムを仮想空間上に再現することで物理システムを効率的に運用することを目指すシステムとなる。この機能の実現には各種データの分析により将来を予測する機能が必須であり、この機能実現の代表的な技術も DL の技術となる。(6) (7)

これらの技術革新と活用の広がりが AI の中から DL を研究対象とした背景となる。

一方、ここで DL の利用形態という観点で DL 活用方法の分類を試みると、以下の 3 つの利用方法に分類できる。

(1) DL ベンダーのサービスの利用

DL ベンダーのクラウドサービスや製品に付属する DL 機能を活用する形態

(2) DL システム構築または開発を伴う利用方法

自社の利用において、何らかのシステム構築または開発を行って利用する形態

(3) DL 機能を組み込んでユーザーに提供

自社のサービス、製品に対して DL 機能を組み込み、エンドユーザーに提供する形態。

上記の中で(2)の会社経営の根幹に関わるようなシステムや(3)の商品においては、特にシステムの機能開発や運用保守における当事者能力の保持と迅速な対応が求められる。この利用形態においては DL のシステム構築とシステム運用において、その手法が曖昧でシステム構築上の課題になる事項として、以下の 3 点を指摘することができる。

- ① DL の学習データの準備方法
- ② DL モデルの精度向上のためのチューニング作業
- ③ システムの要件も踏まえた DL モデルの評価

これらの作業は DL システムを構築する際の各種条件により最適解が異なり、システム構築上の標準化や手順化という観点で課題と捉えることができる。また、このような課題が DL システムを広く身近なものにするための障害にもなり得る。DL 活用促進のためには、これらの課題を解決し、システム構築の難易度を下げてシステム構築をより容易にすることが重要となる。この命題を解決していくためには、DL のシステム構築上の課題対策を織り込んだプロトタイプの開発とその活用が効果的な対策となる。(8)

また、DL の技術革新によって企業活動の付加価値向上を図るためには、技術者の育成が必須となるが、その育成対象は研究者や AI 専門技術者のみでなく、製品・サービスの営業、企画、開発者における人材育成も重要となる。このため、プロトタイプの成果を IT 技術者や AI 技術者以外の事業部門技術者に如何に解り易く教育していくかという観点も DL 活用促進のための重要なテーマとなる(9)(10)。

これらの観点での研究は、先に述べた DX 推進にも大きな効果をもたらすものとなる。DX 推進は企業がデジタル技術の活用により従来のビジネスモデルを変革して企業価値を向上することを目的としており、DL 応用の場合と同様に業務に即した実践的な技術者育成が重要となり、その手法としてプロトタイプによる教育が有効な手段となる。また、DX 推進のためには、事業部門の技術者がデジタル技術を習得することが効果的であり、教育対象者に IT や AI の専門技術者以外の技術者を含むことも DL の応用促進と共通している。さらに、先に述べた通り、DX 推進のキーテクノロジーは DL の技術となる。以上から、DX 推進の技術者育成について DL 応用の研究内容を有効に活用することが可能となる。

デジタルツインについては、物理システムを仮想空間上で再現するモデリング技術が重要な技術要素になり、この技術の習得が課題の一つになるが、デジタルツインの共通基盤である DL のデータ分析による将来予測の技術についても、物理システムの将来予測という観点から DL 応用や DX 推進と同様に実践的な教育を行うためのプロトタイプが重要な位置付けとなる。また、普及促進のための技術者育成についても、事業部門の技術者が重要な教育対象者となる点は DL 応用や DX 推進と共通している。

以上の背景から DL のシステム構築をより容易とする手法の研究とプロトタイプの開発、その成果を活用して事業部門技術者も対象とした理解しやすい教育手法の提案、これらの提案内容の DX 推進プロトタイプ開発と技術者育成への展開、さらに同様にデジタルツインへの展開を研究することとした。

1.2. 研究の目的

本研究の目的は、DL システム構築の課題であるデータ準備方法、DL モデルチューニング作業、DL モデル評価について、効率的にシステム構築を行う手法を研究し、企業における DL 活用促進、DX 推進、デジタルツイン活用促進を図り、企業価値向上に貢献することである。

上記の目的に対応した研究テーマとして、下記 3 件について研究する。

- 1) DL 応用プロトタイプ開発手法の研究
- 2) DX 推進プロトタイプ開発と技術者育成手法の研究
- 3) デジタルツインプロトタイプ開発と技術者育成手法の研究

各研究テーマの概要を以下に述べる。

(1)DL 応用プロトタイプ開発手法の研究

本研究では、DL のシステム構築の課題であるデータの準備手法、DL モデルのチューニング作業、DL モデルの評価について、効率的なシステム構築手法を研究し、その手法を反映したプロトタイプを開発することでシステム構築を容易にする手法を提案する。また、本手法は最終的に技術者育成に貢献する必要がある、プロトタイプの成果を活用し、DL 応用の実践経験がない技術者にも理解促進を図るための技術者育成手法を提案する。

DL システム構築の課題対策に関する提案については、プログラムでの検証を行って、その有効性を確認する。開発したプロトタイプを活用した技術者育成手法については、提案内容を反映した教育講座を企画し、受講生の理解度評価によって、プロトタイプと技術者育成手法の有用性を確認する。

(2)DX 推進プロトタイプ開発と技術者育成手法の研究

本研究では、企業活動における実践的な DX 推進プロトタイプの開発とその成果を活用した技術者育成手法の研究を行う。

本研究においては、DX 推進の中心技術である DL 応用プロトタイプの開発成果を活用して、DX 推進に関連した実践的応用例を強化することで DX 推進プロトタイプの開発を研究する。また、その成果物である DX 推進プロトタイプを活用し、DX 推進の実践経験がない技術者にも理解促進を図るための技術者育成手法を提案する。

本研究成果は、プロトタイプを活用した教育講座を企画し、受講生の理解度評価によって DX 推進プロトタイプと技術者育成手法の有効性を確認する。

(3)デジタルツインプロトタイプ開発と技術者育成手法の研究

本研究では、デジタルツインシステム構築上の課題を踏まえたプロトタイプ開発とデ

デジタルツインシステム構築の技術者育成手法を研究する。

本研究においても、デジタルツインの中心的技術である DL 応用プロトタイプの研究成果を活用し、デジタルツインのシステム構築上の課題を踏まえ、そのシステム特性を反映したデジタルツインのプロトタイプ開発を研究する。また、そのプロトタイプを活用し、デジタルツインの特徴を踏まえた技術者育成手法を提案する。

本研究成果は、プロトタイプを活用した教育講座を企画し、受講生の理解度評価によってシステム構築上の課題対策を織り込んだデジタルツインプロトタイプと技術者育成手法の有効性を確認する。

デジタル技術の進展によってデジタル技術を活用して企業価値を高める必要性が高まり、大企業中心に DL や DX 推進、デジタルツインの導入が進みつつあるが、IT のアウトソースが進行した企業や中小企業を中心として対応の遅れが指摘されている。これらの企業ではデジタル技術の専門家が不足している傾向があり、かつ事業部門の技術者育成が必要であるためシステム構築の難易度を下げることが普及の重要なポイントとなる (1) (2) (4)。

この現状を踏まえて、より幅広い企業層へのデジタル技術の普及と企業の付加価値向上に寄与することを目的として本研究を行う。

1.3. 論文の構成

本論文は6章から構成される。図1.1に各章と学術論文の対応を示す。

1章では研究の背景・目的と、論文の構成について述べる。

2章ではDLのシステム構築、及びDL、DX推進、デジタルツインの技術者育成に関する関連研究と課題について述べる。具体的にはAI全般動向、DLの位置付け、DLの概要、DLのシステム構築上の課題及び技術者育成上の課題、DX推進及びデジタルツインの概要、技術者育成上の課題について述べる。

3章ではDLシステム構築上の課題について、その対策手法を論じ、当該手法を具体化したプロトタイプの開発について論じる。また、その成果を活用した教育手法の提案内容について論じる。システム構築上の課題対策については、プログラムでの評価により、また、教育手法については、講座の実践によって提案内容の有効性を確認する。

4章ではDL応用プロトタイプの成果を活用し、DX推進に対応した実践的なDX推進プロトタイプの開発手法、技術者育成手法について論じる。また、これらの提案内容を講座で実践することで提案内容の有効性を確認する。

5章ではDL応用プロトタイプの成果を活用し、デジタルツインのシステム構築上の課題に対応したデジタルツインプロトタイプの開発手法を論じる。また、その成果を活用した教育手法の提案を行う。これらの提案内容を講座で実践することで提案内容の有効性を確認する。

6章では本研究の成果をまとめると共に今後の対応について論じる。

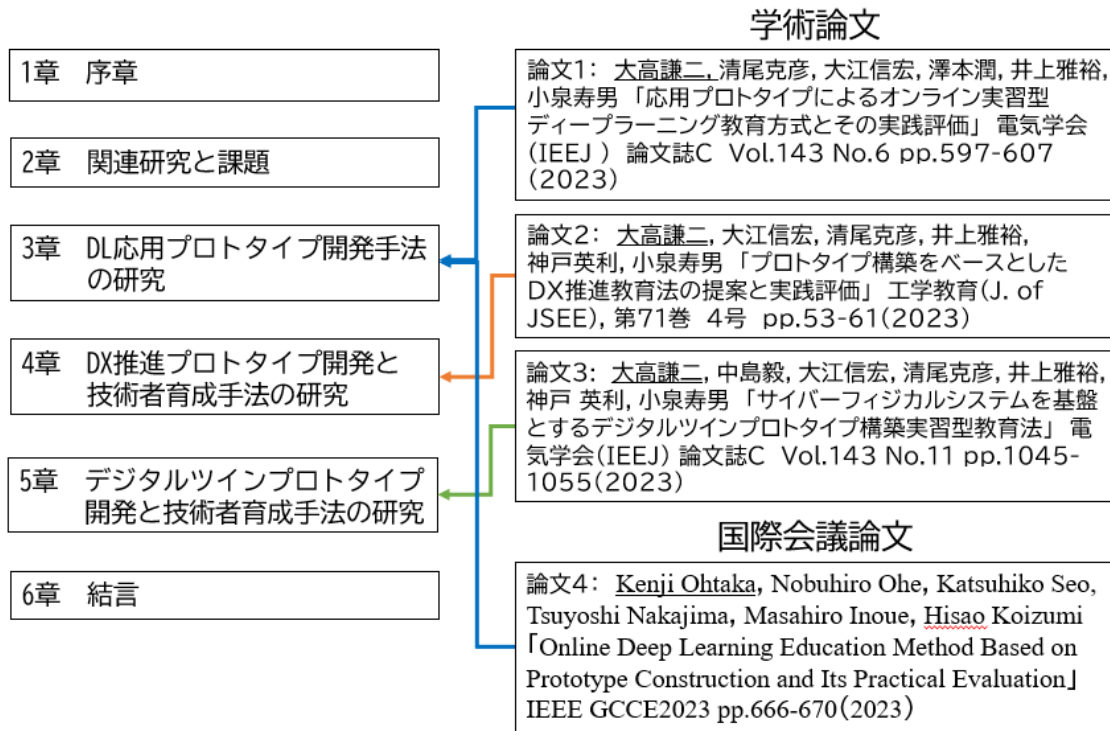


図 1.1 各章と学術論文との対応

2. 関連研究と課題

次に前述した3つの研究テーマに関する関連研究と課題について論じる。

2.1. DL システム構築に関する関連研究と課題

2.1.1 AIにおけるディープラーニングの位置付け

AIを論じる場合、用語の使用について明確にしておくことが重要であり、最初に本論文で使用する用語の整理を行う。AIは非常に単純化して表現すると、一般のシステムと同様にデータを入力し、システムで処理を行い、結果を出力するシステムとなる。ここで、システムの部分を総称してモデルと称する。またモデルの構造は数式モデルであるが、この数式についてはアルゴリズムと称する。このアルゴリズムの例が本論文で中心的に論じるConvolutional Neural Network(以下、CNN)となる。AIでよく使用される機械学習は目的に沿った形でAIモデルの出力値の正確性を向上する仕組みを指す。また、本論文での中心的議論の対象となるチューニングは機械学習で自動的に最適化されないパラメータ(これをハイパーパラメータと称する)の調整作業を示すものとする。

以上を踏まえて、AIの体系を図2.1に示す。AIの分類においては、まず機械学習における特徴量の把握方式によって分類することができ、大きく従来の統計的手法による機械学習とディープラーニング(DL)に分類される。

特徴量抽出手法		機械学習の手法	アルゴリズム	タスク	得意分野
機械学習	特徴抽出方法は人間が指定	教師あり	線形回帰 ロジスティック回帰 サポートベクタマシン 決定木	回帰 回帰分類、回帰分類	数値データ 表形式データの分析
		教師なし	k-means法	クラスタリング	
		強化学習	Q学習 モンテカルロ法	予測(報酬最大化)	ゲーム
ディープラーニング (機械学習の一部)	機械学習において特徴量を自動抽出	教師あり	CNN系 RNN系	分類 予測、分類	画像認識 時系列データ
		教師なし	(※)GAN AutoEncoder	生成 生成次元削減	画像 画像

(※) GAN: Generative Adversarial Networks

図 2.1 AI の体系

(1)機械学習

統計的手法による機械学習は、学習を行う際に学習すべき特徴を人間が設計する方式が基本となる。これが DL と比較した場合の大きな違いとなる。また機械学習はその方式によって学習時に正解データを示す「教師あり学習」と正解値を与えない「教師なし学習」、将来の報酬の最大化を図る「強化学習」に大別される。「教師あり学習」には、線形回帰、ロジスティック回帰、サポートベクマシン (SVM)、決定木などがあり、「教師なし学習」には K-means 法などのアルゴリズムがある。また強化学習の代表例には Q 学習などがある。さらに機械学習を完了したモデルがどのようなタスクを行うか、という観点の分類もあり、線形回帰、ロジスティック回帰、SVM は発生する数値の予測である回帰をサポートしており、SVM、決定木は分類のタスクをサポートし、Q 学習は報酬最大となる予測のタスクをサポートしている。

これらの機械学習に含まれるアルゴリズムは DL に比べると計算量が少なく、学習用のデータも少なくても機能する特徴があり、DL が注目される 2012 年以前は AI の中心的なアルゴリズムとなっていた。なお、AI における学習データは大別して、画像系、時系列に意味を持つ文章などに代表される時系列データ、さらに表形式の数値データに分類できるが、統計的手法の機械学習は表形式の数値データの分析では現在でもよく利用されている。

(2) DL

DL は機械学習の一方式であるが、従来の機械学習とは違い学習すべきデータの特徴量を機械学習の処理において自動的に把握する仕組みになっている点が大きな特徴となる。DL において「教師あり学習」の手法を採用しているアルゴリズムとしては、映像系の分析を得意とする CNN とその派生形のアルゴリズム、時系列データの分析を得意とする Recurrent Neural Network(以下 RNN)とその派生形のアルゴリズムがある。「教師なし学習」の手法に分類されるアルゴリズムとしては画像生成や次元削減をサポートする AutoEncoder 系が挙げられる。学習済みモデルのタスクとしては、CNN 系は「分類」、RNN 系は主に「予測」であるが、「分類」での使用例もある。AutoEncoder 系は主に画像の「生成」となる。なお、生成の観点では画像生成をサポートする GAN があり、学習の手法としては「教師なし学習」に分類される。

DL は人間が学習するデータの特徴を指定する必要がない点が他のアルゴリズムから大きく進歩した点であるが、その分、計算量が多く学習データも多く必要とする傾向がある。このため、2012 年までは現状のような注目は集めていなかった。しかし、2012 年の画像認識のコンテストで、従来年間で数%程度の改善しかできなかった認識性能を DL のアルゴリズムによって 10%以上の改善を図って 1 位となって注目を浴び、コンピューティングパワーの向上もあって現状の発展を遂げている。

以上の通り AI の体系を述べてきたが、今後の AI の発展は DL の発展に依存するところが大きいと判断している。DL は大量のデータが発生し保管された状況下で予め人

間がデータの特徴となるルールを与えることなく、大量データを機械学習することで様々な有効な **Output** を出力するシステムを構築することができる。これまでは簡単に得ることが出来なかった現状分析、将来予想、昨今では学習した知識を活用した生成機能までを可能としていきしており、今後の技術革新と社会変革への貢献が期待される。

2.1.2. ディープニューラルネットワーク (DNN) の構造と DL の仕組み

(1)DNN の構造

DL のアルゴリズムは脳細胞を模して数値モデル化したニューロンモデルと呼ばれる数値モデルを基本構成としている。この構成概念を図 2.2 に示す。このニューロンモデルには、入力データ、入力データと積を取る重み、積の総和に付加するバイアスと呼ばれる数値、この計算結果を入力としてニューロンモデルの出力値を計算するノードという構成になっている。このニューロンモデルを基本要素として、入力層、中間層、出力層を形成したネットワークがニューラルネットワーク (以下、NN) となる。この NN の中間層を複数構成とし、層を増やしたネットワークをディープニューラルネットワーク (以下、DNN) と呼ぶ。この DNN を活用して機械学習を行うことがディープラーニング (DL) となる。

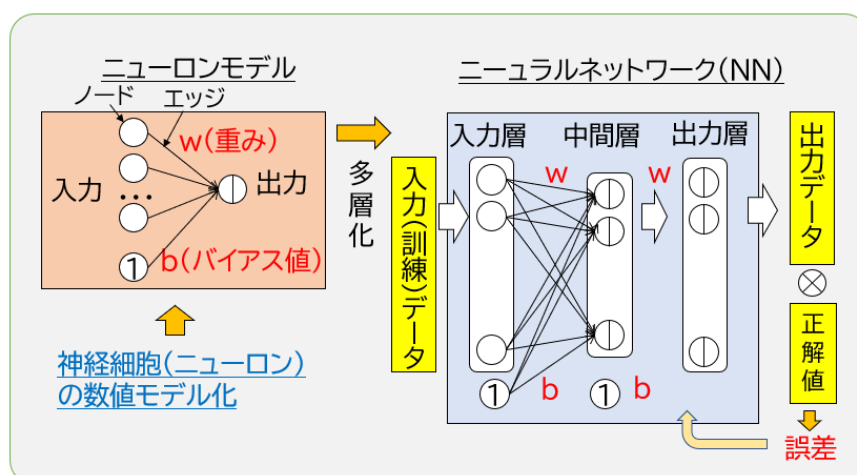


図 2.2 ニューロンモデルとニューラルネットワークの構成図

DNN の構造と DL の学習の仕組みを図 2.3 に記載する。DNN の構造は、データを入力する入力層、複数の中間層、出力層からなる。各層の間には重みとバイアスがあり、ニューロンモデルの構造を形成し、各層の数値とこれに固別設定された重みとの積を取り、その積の総和にバイアスを加算して、次の層の 1 個のノードに入力する。このノードに活性化関数と呼ばれる数式が定義されており、前層からの入力値をこの関数に入力し、その出力を次の層への出力する値 (次の層へ出力するために重みと積を取る数値) を求める。これを各層間で繰り返して、最終的に出力層から出力される数値が決まる。

この一連の動作を順伝搬と呼ぶが、ここで DNN の中間層を何層にするかは人間が指定する必要があり、この中間層の数は機械学習では自動的に決定できないため人間が指定するハイパーパラメータとなる。また、各層は複数のノードと呼ばれる単位で構成される。入力層のノード数は入力するデータのスカラ値の数に合わせ、出力層は予測数値や分類数に合わせて個数を決める。しかし、中間層のノード数は、モデルの仕

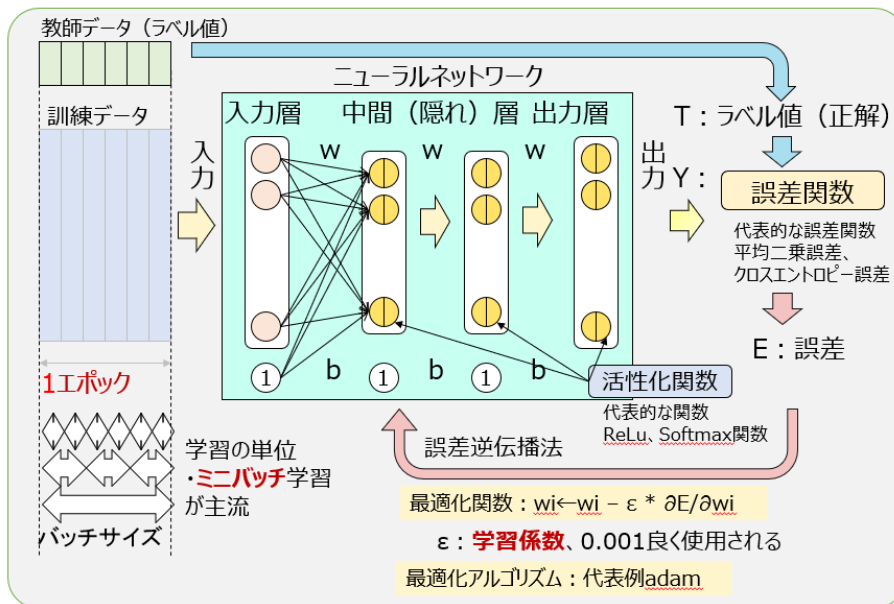


図 2.3 DNN の構成図

様や応用例の仕様では一意には決まらず、人間が規定しなければならないハイパーパラメータとなる。また、中間層で使用される活性化関数、出力層で使用される活性化関数、正解値との誤差を求める誤差関数も人間の指定が必要となり、この活性化関数と誤差関数もハイパーパラメータになる。しかし、中間層の活性化関数は研究が進んで進化してきており、現状では ReLU 関数がよく使用されている。また、出力層の活性化関数も多クラス分類であれば、Softmax 関数が使用される。誤差関数もクラス分類であればクロスエントロピー誤差が使用される。このように用途によって使用関数がほぼ決まってくるので、チューニングすべきハイパーパラメータという観点では活性化関数は原則として除外することができる。

(2)DL の学習の仕組

DL の学習は DL のアルゴリズムにデータを入力し、その結果、出力されたデータと正解値との誤差を求めて、その誤差をゼロに近づけていく作業となる。具体的には、まず誤差はニューロンモデルで解説した重みを変数とした誤差関数として定義できる。この誤差関数の重みを変数として誤差関数を偏微分すると重みに対する勾配という数値を求めることできる。この勾配はその数値の特性として誤差関数の値を最小とするために重みを小さく変化させるべきか、大きくすべきかを示してくれる。この特性を利用して誤差が最小となる重みの数値を特定していく。またこの変化させる数値として勾配の値をそのまま使用すると振動という弊害が発生し、最適な重みの検索が収束し難くなるため、小さい数字で変化させて、誤差が最小になる重みの組み合わせを特定していく。これらの一連の機械学習の手法を誤差逆伝搬法と呼ぶ。

本手法において、勾配の何%の数値で重みを変化させるかを示すのが学習率という数値であり、この数値をどう設定するかが機械学習における重要なハイパーパラメータの一つになる。この学習率には初期値の設定、さらにその後の学習率の調整をどういうアルゴリズムで実施するかを決定する最適化アルゴリズムの指定が必要となる。しかし、最適化アルゴリズムはその研究成果により現状でよく使用されるのが Adam というアルゴリズムであり、最適化アルゴリズムはチューニングという観点では対象外と考える問題はない。Adam は学習率の数値を学習の初期段階では大きく、学習が進むと小さくし、効率的に学習を進行させる工夫がされている。一方、初期値の設定については、チューニングにおいて重要なハイパーパラメータの一つとなる。

(3)学習データの入力手法と学習回数

機械学習におけるデータの AI モデルへの入力方法には 3 つの考え方がある。一つはバッチ方式で学習データを全てモデルに入力した後にその出力の誤差を求めて、誤差逆伝搬法で 1 度のみ重みを調整する方法となる。もう一つの方法は学習データの各々 1 データ毎に重みを調整するオンライン方式である。しかし、最初のバッチ方式は重みを調整する学習回数が少なすぎて効率が悪く、後者のオンライン方式も逆に学習回数が多過ぎて効率が悪いという欠点があり、現状では両者とも殆ど使用されていない。

現状で利用されている手法はミニバッチ方式と呼ばれる手法で、これは学習データを幾つかのグループに分けて、このグループの単位で学習、つまり重みを修正する方式となる。この場合、1 回の学習で何個のデータを利用するかを示すミニバッチサイズというハイパーパラメータの規定が重要となる。また、あるミニバッチサイズによって全学習データで 1 回学習を実施した場合、ミニバッチの単位で何回学習が実行されるかが決まるが、この学習回数をイテレーション数と呼ぶ。このイテレーション数はハイパーパラメータとして指定するものではないが、このイテレーション数がどういう値であるかは認識が必要となる。例として、1000 個のデータでミニバッチサイズ 50 の場合、イテレーション数は 20 となる。データが 500 個となった場合、ミニバッチサイズ 50 の場合、イテレーション数は 10 に減少する。このためデータ数に依存してミニバッチ単位での学習回数が増えるため、ミニバッチサイズの最適な数値がデータ数に依存して変化する可能性があることを認識しておく必要がある。

一方、全学習データをミニバッチ方式で 1 回学習を行えば、最良の重みの組み合わせを見つけられる訳ではなく、全学習データを使用した複数回の学習を行うことで、最適な重みをもったモデルを作ることができる。この全学習データを使って何回学習を行うかを指定するのがエポック数となる。本数値も機械学習の処理で自動的に決まる訳ではなく、人間が指定するハイパーパラメータとなる。

(4) DNN のアルゴリズムにおけるハイパーパラメータのまとめ

機械学習に付随して、重要な作業となるのが、対象モデルの認識性能を向上するためハイパーパラメータの調整を行うチューニング作業となる。機械学習を実施した場合、学習データとは異なるデータでその学習済みモデルがどの程度の正解を出すことができるかを確認し、運用時の要件を満たす性能であるかどうかを確認する。ここで要件を満たすことが出来ない場合はチューニング作業が必要となる。

ここで先に述べた DNN におけるハイパーパラメータを整理する。

- ① 中間層の数、中間層のノード数
- ② 中間層、出力層の活性化関数、誤差関数（但し、これらの関数はチューニングすべきパラメータとしては除外する）
- ③ 学習率の初期値、最適化アルゴリズム（最適化アルゴリズムはチューニングするパラメータとしては除外する）
- ④ エポック数、ミニバッチサイズ

2.1.3. DL の代表的アルゴリズムの概要

(1) 画像解析における代表的アルゴリズム CNN の概要

CNN は動物の脳の視覚野の構造を模して考案されたアルゴリズムで、DL における画像解析の基礎となるアルゴリズムである。CNN の構造を図 2.4 に示す。

CNN のコンセプトの詳細説明は割愛するが、脳の視覚を形成する仕組みは網膜から入った光の情報を電気信号に変換して脳へ伝達し、脳の中では単純型細胞と複雑型細胞と呼ばれる二種類の細胞によって画像を認識することが解っている。単純型細胞が小さい領域の光のエッジを認識する機能を果たし、これらの細胞の集合体で映像を認識していく。一方、複雑型細胞は単純型細胞で認識された映像がどこの位置にあっても同じものと認識する移動不変性の機能を果たす。

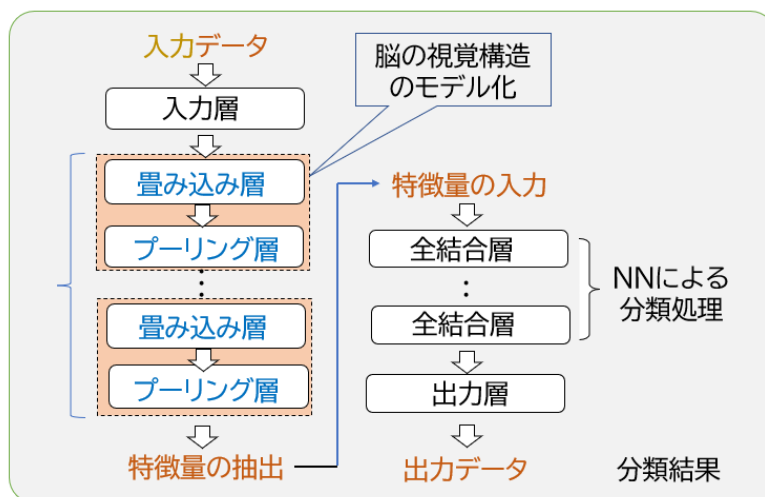


図 2.4 CNN の基本構成

CNNはこの脳の視覚細胞の仕組みを模して単純型細胞の役割を果たす畳み込み層というアルゴリズムと複雑型細胞の役割を果たすプーリング層というアルゴリズムを実装している。この2つの層の処理によって、入力画像の特徴を抽出することになる。さらにこの特徴量を NN の構造に入力し、分類処理を行って入力画像がなんであるかを識別する仕組みとなる。CNN の一般的なモデルでは、畳み込み層とプーリング層が1対1の対を形成し、この対を複数回繰り返す、その後 NN を接続する形態をとる。なお、この NN の層を総称して全結合層と呼ぶことが一般的であり、本論文でも NN 部分を全結合層と称する。以上が一般的な構造であるが、CNN の発展形としては、畳み込み層を複数連続させて、その後プーリング層を置く形態もあり、その他様々な発展形のアルゴリズムがある。本論文では、初学者の教育的観点を踏まえて基本系の CNN の構造をベースに論じていくこととする。

次に畳み込み層やプーリング層の動作も踏まえた CNN の構造図を図 2.5 に示す。ここで機械学習において、人間が指定しなければならないハイパーパラメータは何かという観点を中心に、その構造を概説する。まず、CNN には画像を入力する入力層があり、このノード数は入力する画像のピクセル数で決まる。例えば、縦横のピクセル数が 128×128 であれば、そのピクセル数は 16,384 個となり、入力層のノード数も 16,384 個となる。この場合、画像のサイズをどうするかは人間が規定する必要がある、その数値は CNN モデルの認識性能にも影響する。この観点から CNN に入力する画像サイズは重要なハイパーパラメータの一つとなる。

次に畳み込み層の数、プーリング層の数も CNN の性能に影響を与える。一般的には層数が多い方が認識性能はよいとされる。このため、畳み込み層の数、プーリング層の

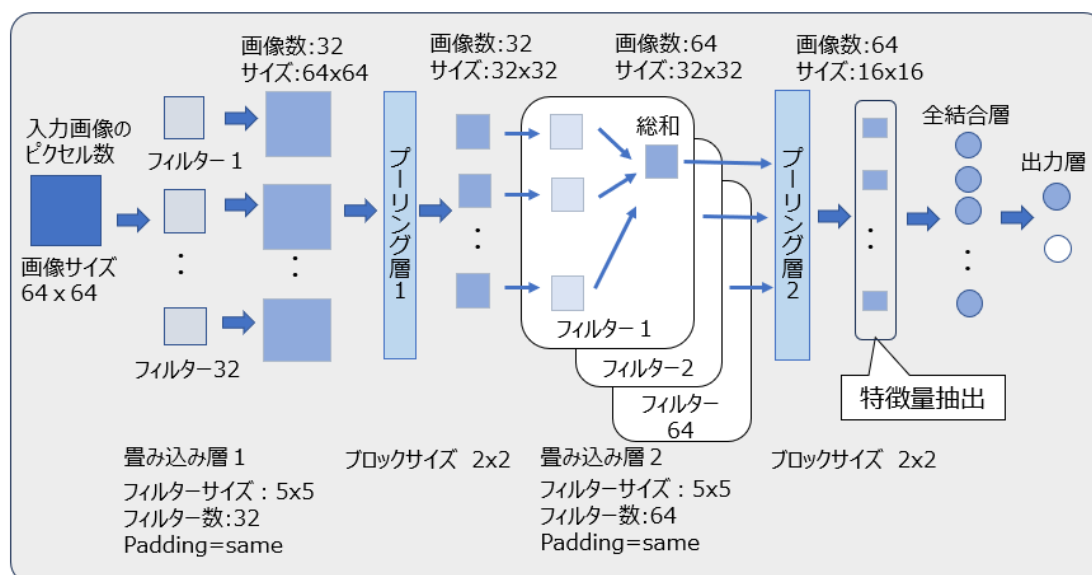


図 2.5 CNN の構造

数もハイパーパラメータの一つになる。さらに全結合層の層数、出力層を除く中間の層のノード数も CNN の分類性能に影響を与える。このため、全結合層の中間層の数、ノード数もハイパーパラメータとなる。

畳み込み層の処理概要を図 2.6 に示す。畳み込みの処理はフィルタと呼ばれる配列構造のデータと画像データとの間で配列の位置が一致するデータの積とその総和を求める計算を行う。また、この計算は通常、フィルタを画像に対して 1 ピクセルずつ右へシフトして、同じ計算を繰り返し、一行の計算を終了すると次行の処理を行い最終行まで処理を繰り返す。また、フィルタは複数枚指定することが可能で、上記処理をそれぞれのフィルタで繰り返す。この場合、フィルタ内の数値は機械学習で調整される数値であり、NN の重みと同様に自動調整される。しかし、フィルタのサイズとフィルタ数は人間が指定する必要があり、これらもハイパーパラメータとなる。

プーリング層の処理概要を図 2.7 に示す。プーリング処理は、通常、画像データを 2×2 の配列構造に分割し、その分割されたデータの平均値を求めるアベレージプーリングまたは最大値を抽出する MAX プーリングを行って画像の特徴量を求める処理となる。この場合、アベレージプーリングとするか、MAX プーリングを選択するかどうかは、人

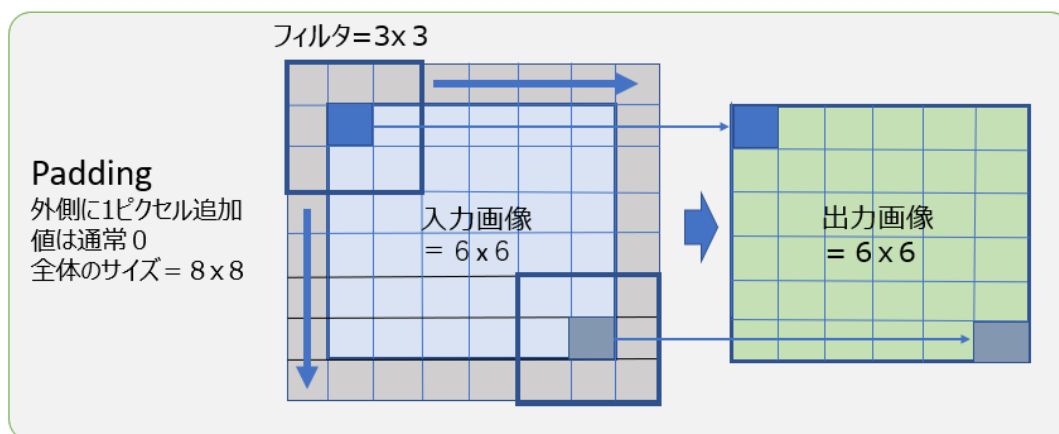


図 2.6 畳み込み層の処理

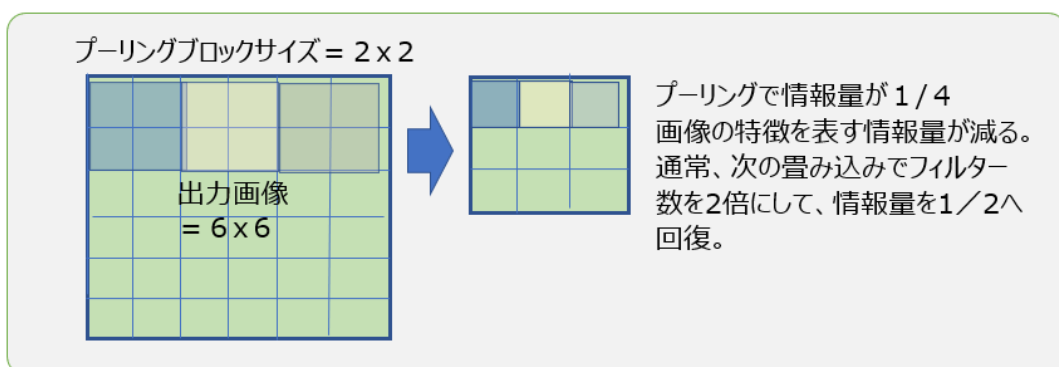


図 2.7 プーリング層の処理

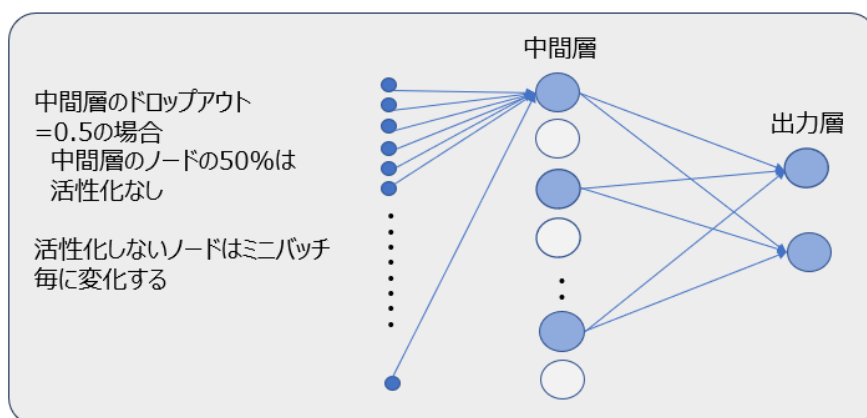


図 2.8 ドロップアウトの構成図

間を選択することになり、この選択もハイパーパラメータの一つとなるが、CNN 系では特徴をより強調することになる MAX プーリングがよく利用される。このため、チューニングの対象からは除外して問題はない。

以上がハイパーパラメータという観点も踏まえた CNN の概要となるが、もう一件、ハイパーパラメータとして、ドロップアウトについて、補足しておく。図 2.8 にドロップアウトの概念図を示す。ドロップアウトは DL における過学習を抑制する手法として考案されたものである。過学習とは学習データに偏った認識性能を示す学習済みモデルの状態を指し、検証データや実運用時のデータに対する認識性能が低くなる現象を言う。ドロップアウトはこの現象を回避するため、活性化するノード数を減らす手法で、パラメータとしては何%のノードを活性化させないかを示す数値を指定することになる。

最後に CNN のハイパーパラメータをまとめると以下の通りとなる。

- ① CNN に入力する画像サイズ
- ② 畳み込み層、プーリング層の層数
- ③ 畳み込み層のフィルタのサイズ、フィルタ数
- ④ プーリング層の処理方法 (MAX プーリングを使用し、チューニング対象からは除外する)
- ⑤ 全結合層の中間層の層数とノード数
- ⑥ ドロップアウト率

なお、上記以外に DNN で示したエポック数、ミニバッチサイズ、学習率の初期値、も CNN のチューニング対象のハイパーパラメータとなる。

(2) DL の時系列データ解析における代表的アルゴリズム LSTM の概要

LSTM (Long Short-Term Memory) は DL における時系列データの解析を可能とする代表的なアルゴリズムである。このアルゴリズムは Recurrent Neural Network (以下 RNN) の欠点を改良したアルゴリズムとなる。RNN の概念図を図 2.9 に示す。RNN

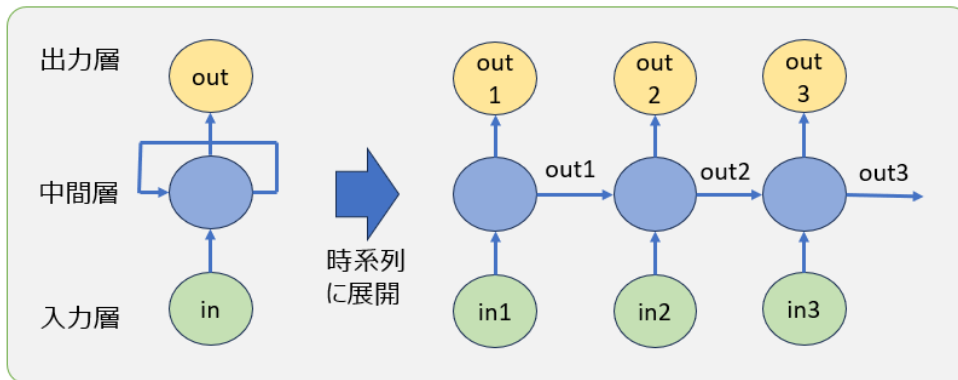


図 2.9 RNN の概念図

は入力層と中間層、出力層という単純な構成であるが、中間層の出力を出力層のみではなく、中間層に再入力させる方式で過去のデータとの時系列の関係性を含めて出力値を求める機能を実現している。しかし、この RNN は時系列の記憶数が限られ、記憶すべき時系列が長くなると時系列を考慮した出力値を求められない欠点があった。LSTM はこの欠点を改良したアルゴリズムとなる。

LSTM の概念図を図 2.10 に示す。LSTM は RNN の欠点を改良するために記憶セルという考え方を導入している。中間層からの出力を出力層、及び再帰的に中間層 (LSTM では LSTM ブロックと称する) に出力する考え方は RNN と同じであるが、これに加えて記憶セルが時系列のブロック間で伝達されていく仕組みになる。LSTM ブロックでは、時系列の観点で一つ前のブロックから出力されたデータと新しく入力されたデータを活性化関数に入力して変換し、記憶セルの絶対値を縮小する処理を行う。この作業は従来の記憶を小さくする作業で、余分な記憶を削除する役目を果たす。さらに前のブロックから出力されたデータと入力データを活性化関数に入力して変換し、縮減された記憶セルの値に加算する処理を行う。この処理は新たなデータで記憶を改訂する機能を持つ。この処理結果を次の LSTM ブロックへ記憶セルとして伝達する。

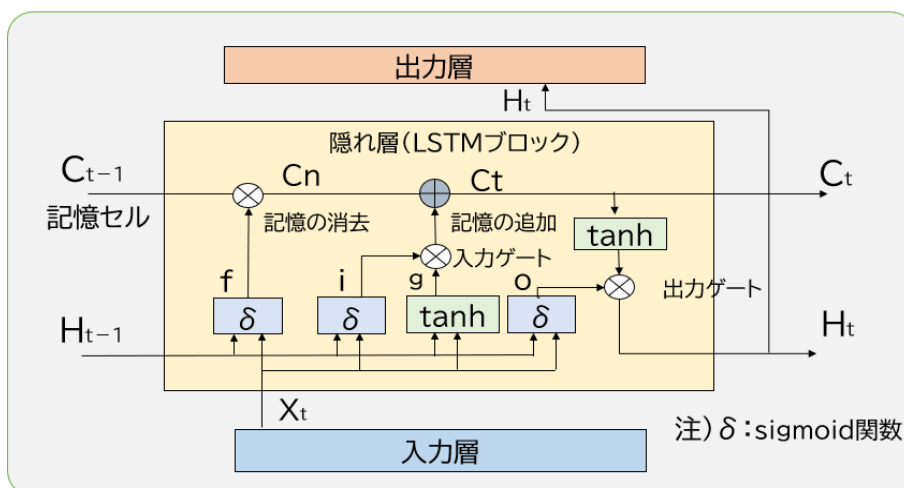


図 2.10 LSTM の概念図

一方、出力層への出力値と次の LSTM ブロックへの出力値は新しい入力データと前ブロックからの出力値を活性化関数に入力して変換し、さらに更新された記憶セルを活性化関数に入力して数値を変換し、その両者の積を求めることで算出する。この処理は新規の入力、前ブロックからの出力、記憶セルの値を総合して新しい出力値を求める処理となる。このような手法で、新しい入力を考慮して記憶を更新し、その記憶も考慮して、出力値と次のブロックへの出力値を求めるという手法で、長い時系列データを分析して結果を出力する機能を強化している。

次に LSTM へのデータの入力と LSTM からの出力結果という観点で LSTM の動作概要を図 2.11 に示す。LSTM には大別して 3 つの動作形態がある。1 番目は入力データ数 n 個に対して出力データ数が 1 個になる形態、2 番目が入力 1 個に対して出力が n 個となる形態、3 番目が入力 n 個に対して出力が m 個の形態となる。 n 対 1 の形態は感情分析などが応用例となる。これは文章を形成する複数の単語を入力し、その文章の批判、賛同などの感情を出力する形態など、何らかの時系列データから何らかの予測数値を求める形態となる。 1 対 n の形態は画像認識のクラス分類結果を入力し画面キャプションの文章を出力する例などが挙げられる。 n 対 m の形態は翻訳システムなどが該当する。ここで、出力のスカラ値の個数については、どのような応用を行うかで決まるものであり、チューニングの対象とはならない。

一方、入力側で n 個のスカラ値を入力する形態の場合、何個のスカラ値に対して、一つの答えを出すかを指定する必要がある。この数値を時系列の長さと呼ぶ。この時系列の長さは人間が指定するもので、LSTM の学習におけるハイパーパラメータとなる。もう 1 件、LSTM の特徴的なハイパーパラメータとなるのが LSTM ブロックの数である。これは先に示した LSTM の中間層に当たる LSTM ブロックへの再入力の回数+1

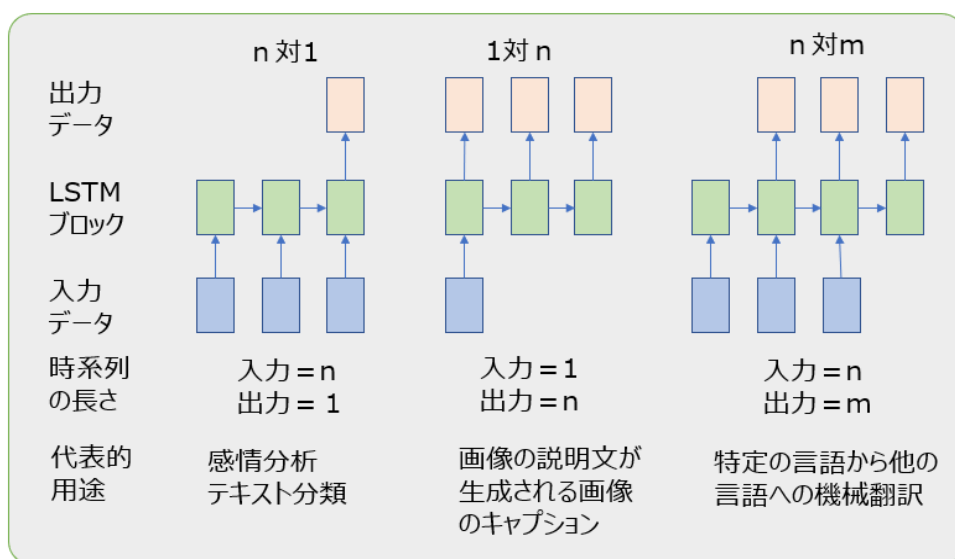


図 2.11 LSTM の動作概要

の数字を指定することとなる。

LSTM では、以上で解説した LSTM 構造をさらに重ね合わせて、多層構造にすることでモデルの解析能力を向上する手法がある。この手法も考慮すると LSTM の階層構造を何層にするかを検討する必要がある、この層数もハイパーパラメータとなる。また、この形態の場合は層と層の間に過学習を防止するドロップアウトを設定する必要がある。この場合のドロップアウト率もハイパーパラメータとなる。

以上が LSTM の概要であるが、DNN で示したハイパーパラメータも含めてチューニングに関連した LSTM のハイパーパラメータを整理すると以下の通りとなる。

- ① エポック数、ミニバッチサイズ
- ② 学習率の初期値
- ③ 時系列の長さ
- ④ LSTM ブロックの数
- ⑤ LSTM の層数
- ⑥ ドロップアウト率

2.1.4. DL システム構築の技術育成に関する関連研究

AI 技術の進展に伴い、その利活用による競争力の強化が国家的な課題になっており⁽¹⁾⁽²⁾⁽³⁾、国の方針も踏まえて、DL システム構築に関する研究としては、特定の応用分野に関する画像サイズの最適化の研究⁽⁴⁾や従来の手法と DL のアルゴリズムとの認識性能比較⁽⁵⁾などの論文が見られる。しかし、システム構築全般の手法を研究するような論文はあまり報告されていない。また、研究者育成などの観点では、高度な大学数学も含めた研究者育成の教育論文⁽⁶⁾は認められるが、システム構築の技術者育成を論じる論文はあまり報告されていない。

一方、大学教育の実践においては、データサイエンティストのカリキュラムから文系学生の教育まで幅広く検討されている。また、企業においては、大企業や IT 系企業を中心に独自のノウハウの習得と自社内での教育を推進し、DL 活用を推進している⁽⁷⁾⁽⁸⁾⁽⁹⁾⁽¹⁰⁾。しかし、中小企業や IT 系に十分な技術力を有しない企業では、応用実践を目標とした教育の充実や DL 応用の推進という観点では課題が残る⁽²⁾。これらの教育推進、課題解消の対応も含めて、DL の普及を目的に JDLA（日本ディープラーニング協会）により E 資格認定プログラムが規定され、本プログラムの認定事業者 18 団体（2023 年 9 月現在）より DL の教育講座が準備されている。これらの講座における DL の関連した教育では、NN、DL の基礎、画像解析分野での CNN の仕組み、その活用における技術的課題、応用事例の実習課題など、JDLA 認定のカリキュラムを踏襲した講義と実習が実施されている⁽¹¹⁾。

また、筆者らにおいても、DL の教育に関し、応用プロトタイプによるオンライン実習型の教育方式の研究を行ってきた⁽¹²⁾。

2.1.5. DL システム構築および技術者育成における課題

(1)最適な推論モデル特定のための技術的課題

①学習データの適切な準備

DL のモデル確定に重要となる第一のポイントとしてデータの準備がある。学習データは人間の教育に例えれば教材テキストに相当し、その内容は応用力を含む学習効果に大きな影響を与える。運用時も含めて、ほぼ網羅的に学習データを準備できれば、問題なく正常に稼働するモデルを作成できる。しかし、実際の実運用を考慮した場合、運用で発生するデータを学習時に全て準備することは通常困難であり、認識性能が高いモデルを生成するための効率的な学習データの準備が課題となる。

②機械学習モデルの最適なチューニング

モデル確定で次に重要なポイントは機械学習と検証作業によりハイパーパラメータをチューニングし、DL モデルの精度を向上する作業となる。前述のとおりこの作業にはモデルの精度に関わる多数のハイパーパラメータがあり、これらの特性を理解して効率的な調整を実施することが重要となる。

③応用システムの要件を踏まえたモデル評価

次に重要なポイントは DL システムの要件を踏まえたモデルの評価である。DL モデルの評価は一般的には検証時の正解率などで判断するが、システムの要件によっては単純に正解率のみで、モデルの成否を判断できない場合もある。システム要件をよく把握した上で、モデルの性能を見極める必要があり、この観点は特に実務経験が少ない技術者には理解し難い要素となる。

以上、推論モデルの特定のための技術的課題を述べたが、このような課題を実践的により効率的に改善していくシステム構築を提言している講座例などは少なく、特に実務経験が少ない技術者の育成法としては、これらの課題を効率的に解決する DL システム構築手法の確立が課題となる。

(2)技術者育成手法の観点での課題

技術者の育成という観点では、育成対象者が事業部門の技術者であることを前提とする必要があり、IT 技術者ではない対象者、或いは DL に関する実務経験が少ない技術者を対象とした育成法という観点での工夫が必要となる。そのためには DL の基礎教育の実施、応用システム構築の講座における理解度向上のための教育手順の工夫などが課題となる。

2.2. DX 推進技術者育成の関連研究と課題

2.2.1. DX 推進の概要

DX 推進とは、デジタル技術の活用により従来のビジネスモデルを変革して企業価値を向上する取り組みとなる⁽¹³⁾。2018年に経済産業省が2025年の崖⁽¹⁴⁾の問題を提唱して、レガシーシステムの改革を促すと共にDX推進ガイドライン⁽¹⁵⁾を作成するなど、国の方針としてDX推進の取組を続けてきている。このような方針を踏まえて、近年においては企業におけるDX推進事例が多く出てきている。一例として、知財(特許)ビッグデータを解析して各社の市場ポジショニングや戦略をあぶりだし、自社の事業戦略の強化を図る事例、工場の製造ラインのデータを収集して生産金額やロス金額などに換算し、製造ライン全体の改善、効率化を図る事例などが報告されている⁽¹³⁾。

DX推進は非常に幅広い企業活動の改革を包含する概念と捉えることができるが、これらの事例における技術的な特徴は大量のデータから経営判断に資する知見を得るところにある。本研究では、DX推進としての研究対象を本事例のように大量のデータから知見を得て企業活動に変革をもたらすシステムと位置付ける。本システムのプロット図を図2.12に示す。本システムを実現可能とする技術としては、IoTによる情報収集、インターネットで提供されるオープンデータなどのビッグデータ活用、大量データを解析するAI技術、大量データ処理を可能としたクラウドサービスなどの技術が挙げられる。このような背景からDX推進の人材育成には、IoT、AI、クラウド、ビッグデータの利用技術教育が重要となってくる。また、教育手法の観点では業務改革というDX推進の目的から教育はより実践的であることが望まれる。さらに教育対象者の観点では、DX推進が新しいデジタル技術を活用して企業の業務変革を行う趣旨

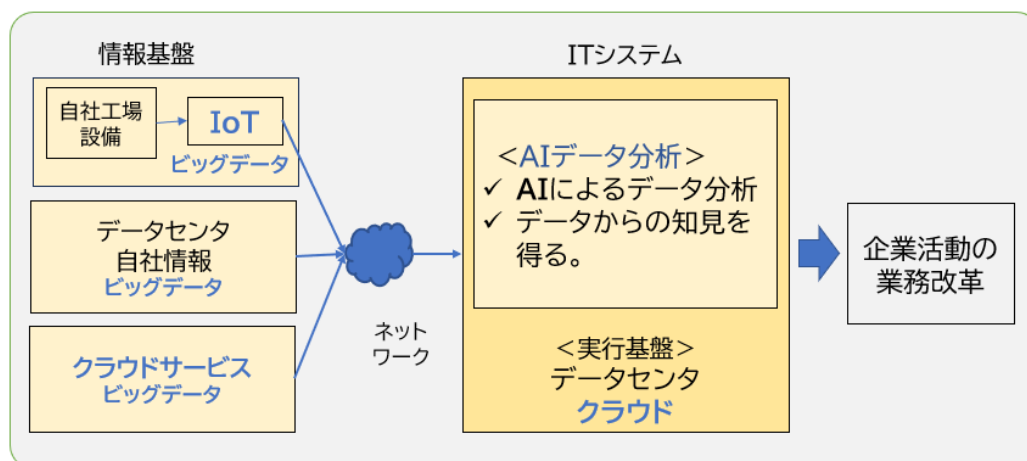


図 2.12 DX 推進システムの概念図

から業務革新を推進するマインドを持ち、アイデアを創出できる人が最新のデジタル技術を理解することが重要となる。このため企業においては社内人材のリカレント教育が人材育成の重要なテーマの一つとなる。

以上の背景から DX 推進の技術者育成においては、IoT、AI、クラウド、ビッグデータを活用して業務改革を行う実践的なプロトタイプシステムの構築実習を行うことが有効な手法となる。さらに教育対象者という観点では、受講生が IT 技術者ではないという前提に立ち、特に AI 技術について実務経験が少ない技術者も対象とする実習の進め方が重要となる。

2.2.2. DX 推進の技術者育成に関する関連研究

(1)関連研究

「Society5.0」⁽¹⁶⁾などを踏まえた中央教育審議会による「2040年に向けた高度な教育のグランドデザイン（答申）」（平成30年）で AI 人材育成の必要性が強く提示されたが、その後の政府指針なども踏まえて、大学教育における「数理・データサイエンス・AI 教育」の具体的内容が研究され、既にその研究結果を踏まえた教育が開始されている⁽¹⁷⁾。しかし、その内容は DX の業務改革ソリューションという実践教育としては課題が残る。また、DX 推進の人材育成をテーマにした書籍も多く出版されている。これらの書籍により DX 人材育成の考え方や教育形態を学ぶことは出来るが、書籍の内容のみでは実践的なシステム構築ができる技術者の育成法を確立することは難しい⁽¹⁸⁾。DX の技術基盤に関し、社会人を含めた技術者教育として、IoT や AI に関するプロトタイプを活用したシステム構築実習による教育の研究例⁽¹⁹⁾⁽²⁰⁾もあるが、単体の技術教育を中心としたものであり、4つの技術を統合した DX 教育の観点ではまだ課題が残る。さらに、DX 推進の上流工程の推進者の育成論文⁽²¹⁾は見られるが、システム構築全般の技術者育成に関する論文はあまり報告されていない。

(2)技術者育成に関する業界団体の現状

DX 推進が経済産業省を中心に国策として推進されていることを踏まえて、一般社団法人データサイエンティスト協会により、データサイエンティストのスキル定義や DS 検定試験が開始されている⁽²²⁾。一般社団法人日本ディープラーニング協会では AI の産業活用推進や技術者認定制度が推進されている⁽²³⁾。さらに情報処理推進機構が参加して、デジタルリテラシー協議会を設立し、デジタルリテラシーの向上を目指している⁽²⁴⁾。これらの活動によって、特に検定試験による技術者の育成が推進されている。

(3)企業における技術者育成の促進

企業においては、大企業を中心に DX 推進の人材育成の事例が報告されるようにな

ってきている。その共通的な取り組みとしては、レベルと目標設定、テキスト作成、自社内講師育成などによる社内教育の推進、IT 技術者のみではなく事業部門の人材教育に力を入れている点、などが挙げられる⁽¹³⁾。一方、DX 白書における DX 推進技術者の育成状況を見ると、事業戦略上、変革を担う人材の「量」の確保の調査では、大幅に不足している 30.8%、やや不足している 45.2%、過不足はない 15.6%となっている。同様に人材の「質」の確保では、大幅に不足している 30.5%、やや不足している 47.4%、過不足はない 14.8%となっている。やや不足しているという回答が一番高い比率を示しており、徐々に技術者育成が進んでいると想定できるものの、企業全体としては、未だ人材の育成には課題が残っていると考えられる⁽¹³⁾。

2.2.3. DX 推進における技術者育成の課題

(1) プロトタイプ構築による実践教育の促進

企業の現状において、自社で DX 技術者や教育内容の定義、テキストの作成、講師の育成などが特に大企業において進展しつつあるものの、IT 部門のアウトソース化が進展している場合や中小企業では自力での教育体制を作れないケースも少なくないと考えられる。また、社外の講座では実践的な応用例という観点では、事例の紹介レベルの講座が多く、実践的な教育が重要となる DX 推進の技術者教育にはそぐわない場合も多い。以上の状況から企業の業務改革を具体化するプロトタイプ教育による実践的な人材育成支援が重要となってくる。また、その内容については、DX 推進の基盤技術である IoT、AI、ビッグデータ、クラウドを活用したプロトタイプの構築体験が重要となる。

(2) AI 基礎教育の推進

DX 推進には事業部門のリカレント教育が重要であるという背景から IT を十分に理解した技術者ではない社会人が教育対象となることも多い。このため IT 技術との関連が強く DX で中心的役割を果たす AI の基礎的な学習の実施も重要となる。

(3) データ準備と DL モデルチューニング技術の育成

DX 技術の中心をなすのが、データの分析であり、その技術の中心となるのが DL 技術となる。このため、事業変革を担う基盤である DL の保守運用技術の向上が重要なテーマとなる。この為には、DL モデルの機械学習時のデータ準備の重要性、そのデータを活用した DL モデルのチューニング、その評価方法のノウハウを確保しておくことが重要となる。

2.3. デジタルツイン技術者育成の関連研究と課題

2.3.1. デジタルツインの概要

サイバーフィジカルシステム（CPS）は、フィジカル空間にある多様なデータをセンサーネットワーク等で収集し、サイバー空間で大規模データ処理技術等を駆使して分析／知識化を行い、そこで創出した情報／価値によって、産業の活性化や社会問題の解決を図っていくものとされている。また、デジタルツインは CPS の一つの形態であり、高度な計測・観測により現実世界の中から収集されたデジタルデータを基に物理的な製品やサービスをサイバー空間上で仮想的に複製し、将来起こり得る様々な事象を予測可能にするシミュレーション技術とされている。

日本においては、2021年3月に閣議決定された第6期科学技術・イノベーション基本計画（2021～2025年度）で、Society 5.0 実現のための「サイバー空間とフィジカル空間の融合」の手段としてデジタルツインが位置付けられた。以上の背景からデジタルツインは今後の産業において、革新的なイノベーション創出の可能性を持っている。現状では、欧米が先行しているものの日本においても製造業、建設業、都市計画などにおいて、デジタルツインの普及が加速しつつある。特に製造業の設計、開発の効率化、サプライチェーン全般における企業活動の効率化、保守運用の最適化、都市計画のシミュレーションなどで実績が出てきている⁽²⁵⁾⁽²⁶⁾⁽²⁷⁾。

このような動向を踏まえて、教育の現場においてもデジタルツインへの対応が必要となるが、デジタルツインの実現にはその対象とする物理システムをデジタルツインの仮想空間上でモデリングする技術が必要となる。そのモデリング技術には大別して、物理システムに特化したモデリング技術、モデル化のために収集すべきデータの特定、さらに物理システムの共通基盤となる DL による将来予測の技術がある⁽²⁶⁾。

2.3.2. デジタルツインの関連研究

(1)関連研究

デジタルツイン関連の研究は工学分野や計算科学分野を中心として、米国、ドイツ、中国などでの研究開発が活発である。製造プロセスの効率化⁽²⁸⁾、建築物のエネルギーマネジメント、自然災害等のモデリングに関する研究、また共通基盤としては、AI の活用、セキュリティの確保などに係る研究開発が推進されている⁽²⁶⁾。また日本国内でも製造、建設などのデジタルツイン研究⁽²⁹⁾が進んでいるが、デジタルツインの実現手法やデジタルツインを教育のツールとする研究が多く⁽³⁰⁾、デジタルツイン自身の教育を研究した例は少ない。

一方、産業界においては、デジタルツイン活用の研究開発が進み前述の通り製造業、

建設業、都市計画を中心に活用事例が出始めている⁽³¹⁾。

(2) デジタルツインの重要性と日本での普及状況

図 2.13 にデジタルツインの概念図を示す。デジタルツインは物理システムをサイバー空間上に再現し、物理システムのシミュレーションによって非常に効率的に物理システムの運用を行う手段を提供する。この新しいデジタル技術は、今後さらに普及が加速すると共に企業の競争力に大きな影響を及ぼす技術になっていくと考えられる。近年、日本においても、その普及が促進されており、運用保守のデジタルツイン化による予知保全の実現で保守の効率化やダウンタイムの縮小を図る事例、生産計画、製造、配送までのワンストップでのデジタルツイン化による柔軟で効率的な生産計画の実現、3D 地図と人流などの情報の融合による都市のシミュレーションによって都市計画の効率化を図る事例などが出てきている⁽²⁷⁾。

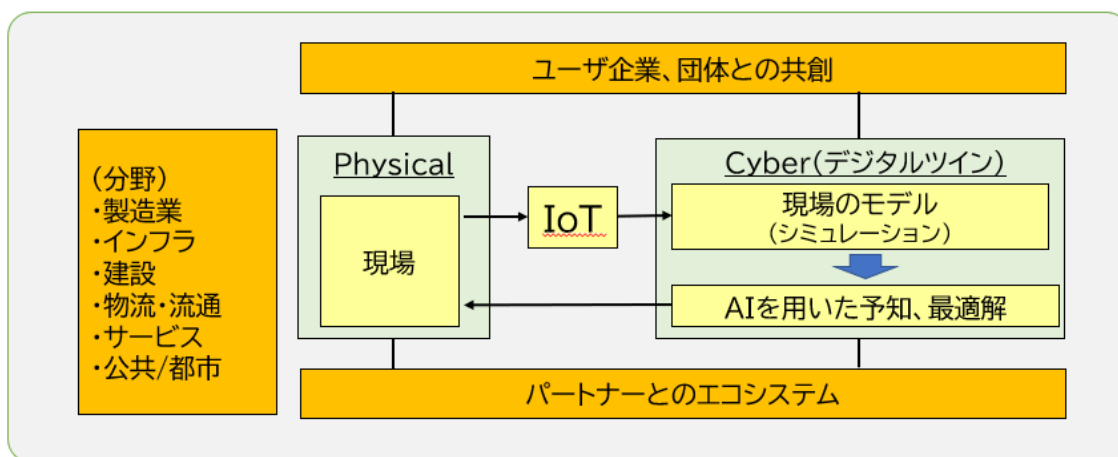
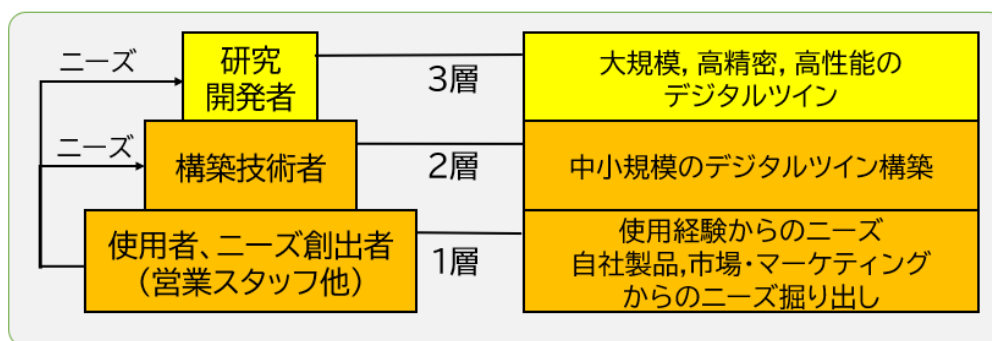


図 2.13 デジタルツインの概念図

(3) 人材育成支援の必要性

図 2.14 にデジタルツインの人材育成の構成図を示す。デジタルツインの活用促進のためには、人材育成が重要となり、その対象者は図 2.14 に示す 3 つの層に分類することができる。まず 1 層として利用者層があり、この 1 層の拡大とそれに伴うニーズの喚



起が重要となる。さらにこれらのニーズを踏まえて、2層の中小規模デジタルツインの構築技術者育成が重要となる。3層の大規模デジタルツインについては、大企業の業務ノウハウと人材育成への依存度が高いと考えており、本論文で最も重要と考えているのが、2層の技術者育成となる。一方、現状の教育動向においては、経済産業省のDX推進の方針に沿って、企業におけるデジタル技術者の育成が進んでいるもののDX白書によると依然として、量、質の不足も指摘されており、企業における業務ノウハウを持つ技術者のリスクリングの重要性が指摘されている⁽³²⁾⁽³³⁾。

2.3.3. デジタルツインの特徴と技術者育成上の課題

(1) デジタルツインの特徴

図 2.15 にデジタルツインの構成要素図を示す。デジタルツインはリアルな物理システムから提供されるセンサー情報などを入力し、物理システムと同等の仮想システムをサイバー空間上に構築する。このデジタルツインシステムの構築に必要な技術には、物理システムを仮想空間上に再現するための物理システムに特化したモデリング技術と再現のために収集するデータの特化が必要となる。物理システムに特化したモデリングの例としては製品、材料などを含む製造プロセス、建築・建設プロセス、製品、プラントの運用保守プロセスのモデリングなどがある。さらに固有の物理システムには依存しない共通のモデリング技術があり、その中心的な技術としてAI、特にDLのデータ分析による将来予測がある⁽²⁶⁾⁽²⁷⁾。

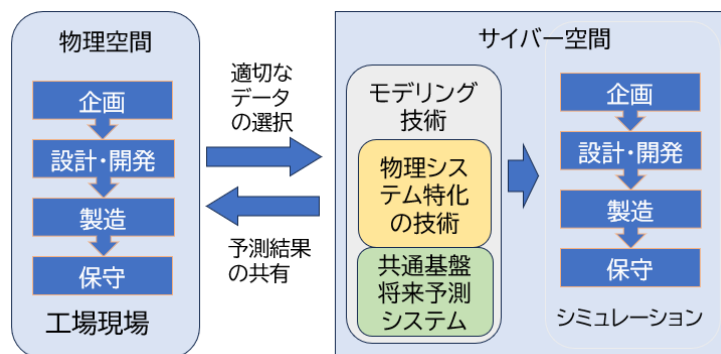


図 2.15 デジタルツインの構成要素図

(2) デジタルツインの特徴を踏まえた技術者育成上の課題

デジタルツインは実際の物理システムを対象とすることから実践的な教育が重要であり、システム構築力の育成にはプロトタイプによる構築実習が有効な教育手法となる。しかし、教育の現場ではデジタルツインシステムの特徴である物理システムに特化したモデリング技術が専門的で高度な技術となるため、システム構築に必要な正確なノウハウが不足している場合も想定される。本研究では、この課題を考慮した上で、物理システムに特化したモデリング技術とそのために必要となるデータについて、仮定を設定す

ることで、プロトタイプ構築を可能とし、デジタルツインの共通基盤技術である AI による将来予測のシステム構築力の育成を図ることを目標とする。

(3)物理システムに特化したモデリング技術の一例

本論文ではデジタルツインで物理システムを仮想空間上に再現するための物理システムに特化したモデリング技術とそのために必要となる収集すべきデータに仮定を置く。例えば、工場設備の予知保全を行うデジタルツインでは、工場設備の振動情報、温度情報、圧力情報など多様な情報からデータをどのような組み合わせで分析することによって障害を予知できるかというノウハウが必要となる。これらのノウハウによって、障害予見を行う DL モデルの入力データとして何を準備し、正解データとして何を準備すべきかを特定することが可能となる。

(4)デジタルツインのシステム構築力育成の要件

デジタルツインの構築力育成の要件はデジタルツインで再現する物理システム固有のモデリング技術とそのために収集すべきデータの特定、収集データを活用した DL による将来予測、さらにその結果を物理システムへフィードバックするシステムの構築力となる。一方、前述の通り本論文では上記の物理システム固有のモデリング技術とデータの特定には仮定を置くことで、DL による将来予測のシステム構築力の育成を図る。その教育要件は、仮定に基づくデータの生成、生成データによる DL モデルの機械学習と検証による学習済みモデルの確定、学習済みモデルのデジタルツインへの実装、物理システムの運用データによる DL 推論（予測）処理、予測結果の物理システムへのフィードバック、これらを実行するシステムの構築力育成となる。これらの教育のためには、実践力の育成が重要であり、プロトタイプの実装が有効な教育手段となる。

以上の現状を踏まえて、デジタルツインの技術者育成が重要であり、DL に加えてデジタルツインの教育法について研究を行ってきた⁽³⁴⁾。

3. DL 応用プロトタイプ開発手法の研究

本章では、2.1 節で述べた DL システム構築の 3 つの技術的課題の対策を研究し、DL のシステム構築をより容易とするための提案を行い、その提案に基づいてデータ準備支援、チューニング支援、モデル検証支援に関するプロトタイプへの実装方法を述べる。また、その成果を活用した技術者育成手法についても提案を行う。技術的課題の提案については、プログラムでの検証による有効性の確認について述べる。また、技術者育成手法の提案については、プロトタイプを活用した講座の実践による効果の確認について述べる。

3.1. DL システム構築および技術者育成における課題

図 3.1 に DL 応用のシステム構築の流れとその課題を示す。DL のシステム構築では DL システムの機能を設定し (図 3.1①)、AI モデル生成、AI モデルの機械学習、検証、推論 (応用例の実行処理) を実行するためのプログラム (図 3.1②) と応用例を実行するための学習用データ (図 3.1③) を準備する。このデータに対してクラス分けなどの処理 (図 3.1④) を実施し、この学習データとプログラムを活用して機械学習 (図 3.1⑤)、検証 (図 3.1⑥)、モデルのチューニング (図 3.1⑦) を行って学習済みモデルを確定する。その学習済みモデルを活用して推論処理 (図 3.1⑧) を実行し、設定した機能を実現する。上記のシステム構築において、特に重要となるのが推論処理に最適な DL モデルの確定と維持になる。

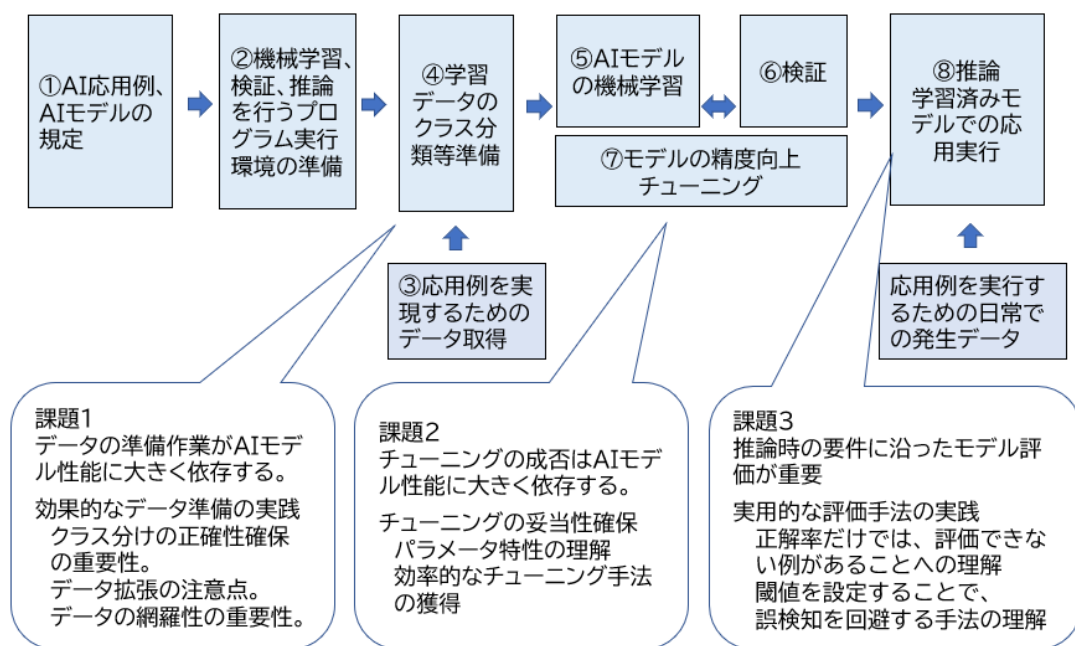


図 3.1 DL 応用システム構築の流れ

(1)最適な推論モデル特定のための技術的課題

①学習データの適切な準備（課題1）

DLのモデル確定に重要となる第一のポイントは学習データの準備となる。データ準備に関する課題の概念図を図3.2に示す。DLの機械学習では教師あり学習が主に行われるが、データが入力され、その際に出力すべき正解データが示され、その誤差を小さくするために機械学習の作業が繰り返し行われることになる。この場合、運用時も含めて、ほぼ網羅的に学習データを準備できれば、問題なく正常に稼働するモデルを作成できる。しかし、実際の実運用を考慮した場合、運用で発生するデータを学習時に全て準備することは通常困難であり、運用で発生し得るデータを学習時に全て準備することは通常困難であり、運用で発生し得るデータを考慮しながら、認識性能が高いモデルを生成するための効率的な学習データの準備が重要となる。

また、DLのモデルにおいては、学習していないデータであっても正解値を導き出す特性として汎化性能という特性がある。この機能を効果的に活用するためにどのようにデータを準備すべきかを考察することは、運用において良い性能を実現するために重要な要素となる。

しかし、このようなノウハウには決まった定型的な手法がないことからデータの準備がシステム構築上の課題の一つとなっている。

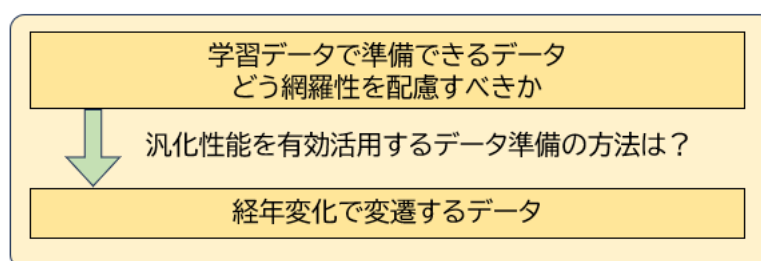


図 3.2 データ準備に関する課題の概念図

②機械学習モデルの最適なチューニング（課題2）

モデル確定で次に重要なポイントは機械学習と検証作業によりハイパーパラメータをチューニングし、DLモデルの精度を向上する作業である。チューニング作業の課題

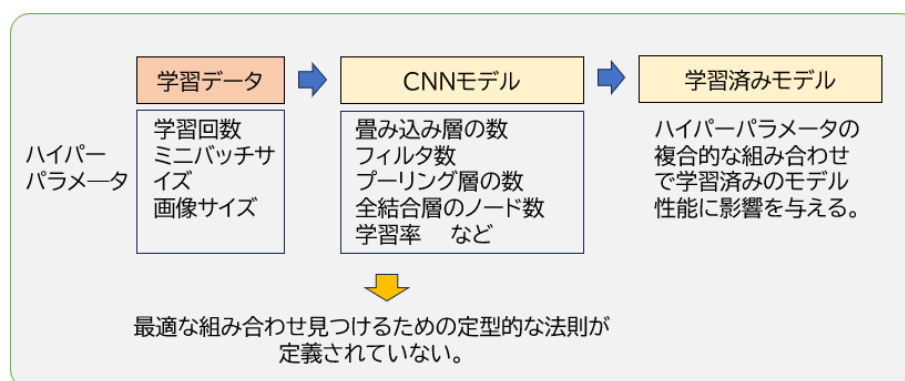


図 3.3 チューニングに関する課題の概念図

に関する概念図を図 3.3 に示す。このチューニングノウハウの習得は最適なモデルの生成は勿論、その後のシステム運用、保守、微妙な発生データの変化に対応した改善においても重要な要素となる。しかし、前述のとおりこの作業にはモデルの精度に関わる多数のハイパーパラメータがあり、これらの特性を理解して効率的な調整をすることが重要となるが、汎用的な決まった手順が存在する訳ではなく、効率的にチューニング作業を実施できるかどうかシステム構築における課題となる。

③ 応用システムの要件を踏まえたモデル評価（課題 3）

次に重要なポイントは DL システムの要件を踏まえたモデルの評価である。モデル評価の課題に関する概念図を図 3.4 に示す。DL モデルの評価は一般的には検証時（図 3.1 ⑥）に正解率などで判断する。しかし、システムの要件によっては単純に正解率のみで、モデルの成否を判断できない場合もある。例えば、モデルが一番難しい判断をしなければならないデータについての性能が重要な意味を持つ場合もあり、この場合は正解率のみでは要件を満足しているかどうかを判断できない。このため、正解率だけではなく、システム要件をよく把握した上で、モデルの性能を見極める必要があり、この観点は特に実践経験が少ない技術者には理解し難い要素となる。

以上、推論モデルの特定のための技術的課題を述べたが、このような課題を実践的により効率的に改善していくシステム構築を提言している講座例などは少なく、これらの課題を効率的に解決する DL システム構築手法の確立が課題となる。

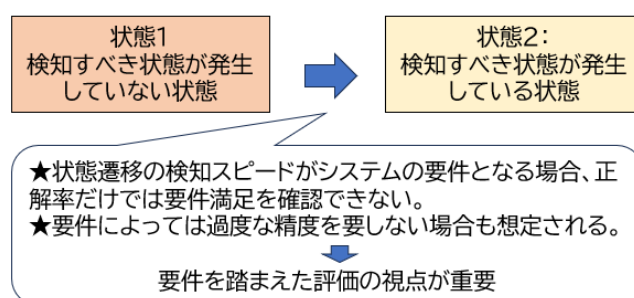


図 3.4 モデル評価に関する課題の概念図

(2) 技術者育成の観点での課題

技術者の育成という観点では、既に述べたとおり育成対象者が事業部門の技術者であることを前提とする必要があり、DL に関する実務経験が少ない技術者を対象とした構築技術の育成という観点での工夫が必要となる。そのためには体系的な DL の基礎教育の実施、システム構築の講座における教育手順の工夫などが必要となる。

① NN、DL の基礎講座の実施例

既に概説のとおり NN の構成、NN の中間層を複数構成にしたものが DNN のネットワークであること、DNN で機械学習を実施することを DL と総称すること、誤差逆伝

搬法など DNN の機械学習の仕組み、機械学習においては多くのハイパーパラメータがあることなどを解説する。また DL の活用においては、データ収集、データ加工、AI モデルの構成、機械学習、検証、推論、運用保守というステップがあることの説明を行う。

さらに DL の代表的なアルゴリズムである CNN などのネットワーク構成、機械学習の仕組み、ハイパーパラメータなどの解説を実施する。最後に比較的簡単な DL 応用例を実行し、DL モデルの実際の動作を体験するなどの内容とする。

② 理解しやすい講座進行の工夫

DL 教育を必要とする対象が大学、研究所や大企業、中小企業など広範囲に渡り、企業では IT や AI の専門技術部門のみではなく、多様な業種の技術部門が対象となる。このため特に企業において、教育対象の技術者が IT、AI の専門知識を有する前提とはならない。このため、講座の進め方も如何に解り易い構成を検討するかが課題となってくる。

3.2. DL システム構築の課題対策に関する提案

本節での提案内容を図 3.5 に示す。本節では、DL システム構築の 3 つの課題であるデータ準備手法、チューニング手法、モデル評価に関して、効率的にシステム構築を行う手法を提案する。その提案内容を実践的なプロトタイプの開発に展開する。本プロトタイプにおいては、データの準備では、実践的なデータ準備手段を提供し、データ準備手法を体験できる基盤を提供する。チューニングではチューニングすべきハイパーパラメータの個別評価や組み合わせ検証の基盤を提供し、モデルの評価では標準的な評価指標に加えて推論における要件確認のための基盤を提供する。

また、その成果を活用して技術者育成をする場合、IT 関係の専門技術者ではなく、事業部門の技術者など DL の実践経験が少ない技術者であっても理解を促進するための教育手法を提案する。

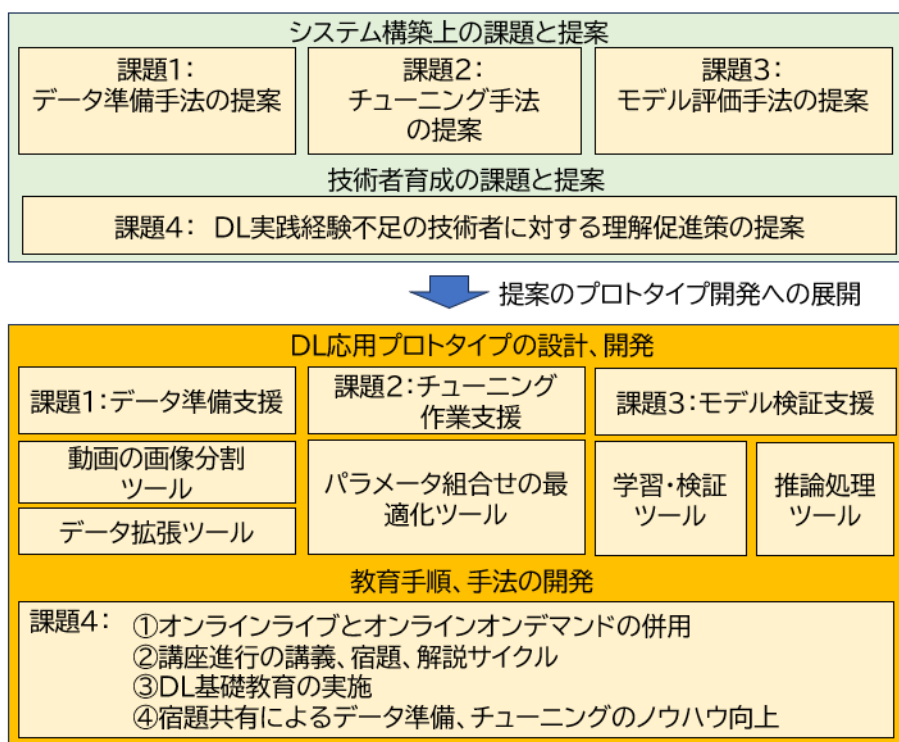


図 3.5 提案内容の概要

3.2.1. データ準備の手法の提案（課題 1）

一般論としてのデータの準備手法は、例えばクラス分類や回帰において、実運用に近いデータが準備できるのが最善の手法である。しかし、この手法は実運用では現実的ではなく、対応可能であっても膨大な時間、データ数となる可能性があるなど、効率的なアプローチではない。このため特に十分準備しなければならないデータの特徴、汎化性能の特性を考慮したデータの準備が重要となる。

クラス分類において準備すべきデータを考察すると、クラス分類の境界に相当する部

分、あるクラスから他のクラスへ遷移する周辺のデータ、明示的に判断が難しいと認識できる部分などのデータを重点的に準備する必要がある。

また、汎化性能により同一クラス内の物体の画像内での位置や間隔に関する中間的な特徴については、データ数を抑えることが可能になる。同一の物体については、画像中の位置を網羅したデータの準備は抑制することができる。更に形状については、その形状に変化がある場合でも、特徴的な部分が十分判別できれば、物体形状の変化をデータとして網羅的に準備する必要はないと考えられる。

データ準備において、上記のような考え方を踏まえて実施することは作業の効率化とモデルの性能向上の両立という観点で非常に重要となる。一方、上記のような考え方で準備したデータ数が他の同様な事例に対して不足している場合は、上記の考え方で準備したデータを増やす必要があり、そのためのデータ拡張も重要な対応策となる。なお、時系列データによる回帰処置については、クラスや形状、位置という概念がないため同じ考え方は適用できない。この場合は、原則としては、予測可能な発生し得るデータパターンを可能な限り網羅して行くことが重要となる。

3.2.2. DL システム構築におけるチューニング手法の提案（課題 2）

各モデルにおいて、どのハイパーパラメータを調整すべきか、その数値の絶対値をどうすべきかについて、共通的、固定的に確定することは困難なため、全体的なチューニング手法の考え方や流れを整理し、チューニングの効率化を図ることが重要となる。具体的には CNN と LSTM を例として取り上げ、汎用的な考え方、手順を示す。

以下に CNN と LSTM の方式について提案を述べる。

(1)CNN モデルのチューニング手法の提案

(a)ハイパーパラメータの初期値設定とチューニングの要否

2.1 章で述べたとおり、CNN のハイパーパラメータは非常に多様性があるが、最初に、これまでの事例などから良い評価結果が得られると想定されるハイパーパラメータの初期値を決める。この数値は最終的にはチューニングで決定していくため、最良の数値であることの確実性は問わない。参考となる事例や実績がある場合はその内容を初期値とし、良い事例や実績値がない場合は、以下の考え方を基本として初期値とチューニングすべきハイパーパラメータを決める。

(i) CNN に入力する画像サイズ

画像サイズは大きい方が、情報量が多く、モデルの認識性能向上に寄与する。しかし、情報量が多すぎると処理量が増える。このため適切はサイズを探す必要があるが、初期値としては、128x128 前後のサイズを初期値候補とする。

(ii)エポック数

本数値も数字は大きい方がよい結果が出る。しかし、大きすぎると学習時間が無駄

に発生し、過学習も発生し易い。このため、50 から 100 程度で設定することを推奨する。

(iii)学習率

初期値は多くの事例でよく利用される 0.001 とする。

(iv)ミニバッチサイズ

イテレーション数 20 以上になる範囲で、絶対数は 100 以内で任意に決定することを推奨する。

(v)畳み込み層の層、プーリング層の層数

10 クラス分類以下であれば、2 層を初期値とする。それ以上の場合は 3 層から 5 層で任意に選択する。なお、入力画像とプーリング層数との関係で最終のプーリング層からの 1 つの特徴量の情報量が 10x10 以下になる場合は、それ以上、層数を増やさないことを原則とする。

なお、プーリング層から出力される特徴量サイズは入力情報の 1/4 に減少する。基本的に次の畳み込み層でフィルタ数を 2 倍にすることで情報量を 1/2 まで回復する仕組みとする。

(vi)フィルタ数

事例でよく活用されている内容に従い 1 層目を 32 とし、その後は(v)で記載の通り情報量の減少を防ぐため、プーリング層を通過する毎に 2 倍の数字とする。フィルタ数はこの方式が多く使用されているため、この考え方で固定することを基本とするが、最初の値はチューニングの対象とする。

(vii)フィルタサイズ

事例で良く使用される 3 または 5 を初期値とする。本数値の何れかが採用されることが多数であり、どちらかを選定し、チューニング対象とはしない。

(viii)プーリング層の処理方法

事例で良く使用される MAX プーリングを使用とし、実績があるのでチューニング対象とはしない。

(ix)全結合層の数

10 クラス分類以下の場合は、中間層 1 層+出力層とする。

(x)全結合層のノード数

2 値分類であれば 600 前後、10 クラス分類は 1000 程度を仮設定する。

(x i)ドロップアウト率

非常に良く使用される 0.5 を初期値とする。本パラメータは過学習が起きない範囲のエポック数における認識性能では要件を見たさない場合に調整を検討する。

(b)チューニングすべきハイパーパラメータの選定と手順

上記 (a) に従い、各種ハイパーパラメータの初期値を検討する。次にその初期値か

ら数値を変更して、ハイパーパラメータの特性を見るべきパラメータを示す。

アルゴリズム共通：エポック数、ミニバッチサイズ、学習率、ドロップアウト率
CNN：画像サイズ、畳み込み層、プーリング層、全結合層の各層数
1層目のフィルタ数、全結合層のノード数

最初に初期値の条件で学習を実施し、正解率、誤差を確認し、指定したエポック数の範囲で性能向上の傾向が止まっており、過学習の傾向がないことを確認する。性能が上限に達してからプラス10回程度のエポック数で原則固定して以後の評価を行う。ただし、この時点でシステムの要件を満たす性能が達成されていれば、チューニング作業は不要となる。

上記で要件を満たさない場合は、ミニバッチサイズ、学習率、フィルタ数、全結合層のノード数はその特性を確認するため、数値を変更してその傾向を確認する。その結果から良い性能を示すパラメータ数値を幾つかピックアップし、それらの最適な組み合わせを確認する。この最適な組み合わせで、実現すべき要件を満たしていれば、チューニングは完了する。

この調整結果においても要件を満たさない場合は、正解グラフなどで過学習が起きていないか、起きている場合はエポック数を減らすか、ドロップアウト率の変更を試みる。また、正解グラフなどで性能が上限に達していない可能性があればエポック数を増やすことを試行する。

以上でも要件を満たせない場合はモデルの骨格に関する変更を試みる。この対象は画像サイズ、畳み込み層、プーリング層、全結合層の各層数となる。先に記載したとおり、最終のプーリング層から出力される1つの特徴量の情報量に余裕があれば、畳み込み層、プーリング層の追加の余地があり、追加した場合の性能を確認する。また、情報量に余裕が無い場合は、画像サイズを拡大して検証し、必要に応じて層数も増やして検証する。以上の対応でも要件を満たさない場合は全結合層の層数の増加も検討する。

なお、モデルの認識性能がでないのは学習データの不備も要因として考えられるため、モデルの骨格の変更に関する検証を行う前にデータの網羅性やクラス分類の不正確さなどが発生していないか再確認する。

(2)LSTMモデルのチューニング手法の提案

(a)初期値ハイパーパラメータの選定

CNNの場合と同様にLSTMのハイパーパラメータについて、これまでの事例などから良い評価結果が得られると想定されるハイパーパラメータの初期値を決める。参考となる事例や実績がない場合は、原則、以下の初期値設定を推奨する。

(i) エポック数

CNNと同様に数字は大きい方がよい結果が出る。しかし、大きすぎると学習時間が無駄に発生するため、初期値は50から100程度で設定することを推奨する。

(ii) 学習率

初期値は多くの事例でよく利用される 0.001 とする。

(iii) ミニバッチサイズ

イテレーション 20 以上になる範囲で、絶対数は 100 以内で任意に決定することを推奨する。

(iv) 時系列の長さ

データや分析内容から LSTM が分析する時系列のデータ長として適切と思われる数値を想定して仮設定する。

(v) LSTM ブロックの数

LSTM ブロック数は大きい方が良い結果が出るという傾向があるため、30 から 70 で仮設定を行う。

(vi) LSTM 自身を階層構造の数

参考となる事例などが無い場合は、原則、初期設定では階層構造を取らない。

(vii) ドロップアウト率

LSTM については、LSTM 自身を階層構造とする場合に使用されるが、階層構造の場合は、0.2 が使用されることが多いため本数値を初期値とする。

(b) チューニングすべきハイパーパラメータの選定と手順

以下のハイパーパラメータは初期値では確定が難しく、チューニング対象とする。
アルゴリズム共通：エポック数、ミニバッチサイズ、学習率、ドロップアウト率

LSTM ：入力データの時系列の長さ、LSTM ブロック数

CNN の場合と同様に最初に初期値の条件で学習を実施し、誤差を確認し、指定したエポック数の範囲で性能向上の傾向が止まっていることを確認する。性能が上限に達してからプラス 10 回程度のエポック数で原則固定して以後の評価を行う。ただし、この時点でシステムの要件を満たさず性能が達成されていれば、チューニング作業は不要となる。

上記で要件を満たさない場合は、ミニバッチサイズ、学習率、入力データの時系列の長さ、LSTM ブロック数はその特性を確認するため、数値を変更してその傾向を確認する。その結果から良い性能を示すパラメータ数値を幾つかピックアップし、それらの最適な組み合わせを確認する。この最適な組み合わせで、実現すべき要件を満たしていれば、チューニングは完了する。

この調整結果でも、要件を満たさない場合は、誤差グラフで過学習が起きていないか、起きている場合はエポック数を減らすか、ドロップアウト率の変更を試みる。また、誤差グラフで性能が上限に達していない可能性があればエポック数を増やすことを試行する。

以上でも要件を満たせない場合はモデルの骨格に関する変更を試みる。この対象は LSTM 自身の階層構造の変更となる。なお、モデルの認識性能がでないのは学習データの不備も要因として考えられるため、モデルの骨格の変更を検討するタイミングで学習データの網羅性が十分か再確認する。

3.2.3. DL モデルの評価手法の提案（課題 3）

(1) 通常の正解率では評価できない場合の考察と対応

学習結果の検証評価においては、通常以下の指標でモデルの認識性能を把握する。

分類：正解率、誤差、システムの要件によっては再現率、適合率を活用。

再現率は、あるクラスの全データに対して正しく当該クラスと認識できた割合

適合率は、あるクラスと判定された全データに対する当該クラスのデータの割合

回帰：R2 または RSME、誤差

しかし、例えば、異常検知の例では、その異常状態へ遷移した場合の検出スピードがシステム要件となる場合などは、その状態遷移時の検知性能を確認して要件を満足しているか確認が必要になる。このケースでは、正解率のみでは要件を満たすかどうかの確認は困難であり、状態遷移時の認識性能を確認する必要がある。この場合は学習時の検証データや推論処理において、要件を確認できるデータを準備し、そのデータの認識性能を確認して要件を満足するかどうかの確認作業を要する。

(2) 閾値設定の提案

上記に加えて、推論処理における閾値設定の手法を提案する。例として、異常検知において、一旦、異常状態に変化した場合、そのまま放置した状態では、正常に戻らない場合を想定する。この場合に例として連続 10 回の推論において、3 回異常を検知した場合に異常発生と判断する、という閾値設定を行う。これによって、10 件中 2 件以下の異常の誤検知については、システム全体としては異常誤検知を回避できる（異常検知の感度が推論処理 2 回以下を要求される場合を除く）。このような閾値設定が可能であれば、異常への状態遷移において、2 回程度の誤判定も許容しない過剰なチューニング作業を回避することもできる。

3.2.4. 課題対策を踏まえたプロトタイプの開発

図 3.6 にプロトタイプを構成するプログラムの開発環境を示す。プログラムは Python で開発し、ソースコードは Google Colaboratory の Notebook で作成、デバックを実施している。DL のフレームワークは TensorFlow、Keras を活用、関連するライブラリとしては、AI 全般をサポートする scikit-learn、配列他の数計算を行う Numpy、表形式で可視化する Pandas、グラフ描画の

Matplotlib、画像処理関係の OpenCV を使用している。

これらの環境で開発した DL 応用プロトタイプのプログラム構成図を図 3.7 に示す。前節で示した DL システム構築の課題解決を踏まえたプログラムの開発内容は以下のとおりとなる。なお、本節では、CNN 関係で開発したプロトタイプを記載する。LSTM に関するプロトタイプ開発については、5 章にて、詳細を記載する。

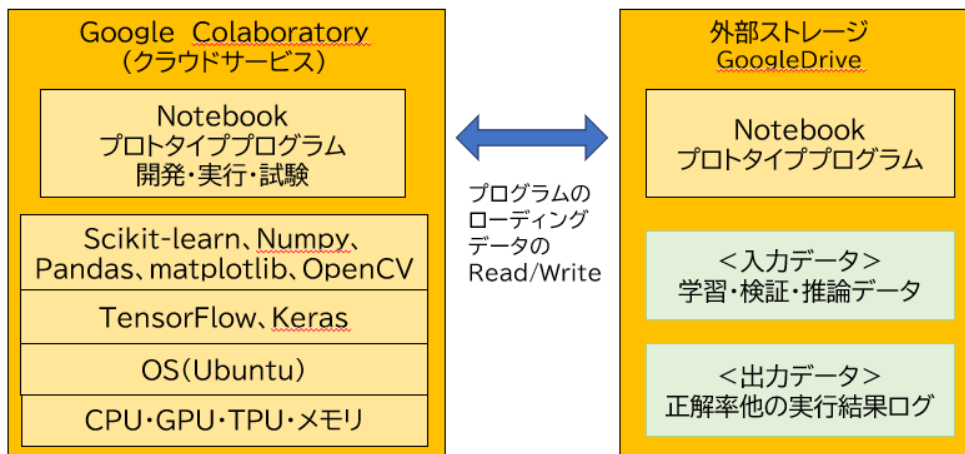


図 3.6 DL 応用プロトタイプのプログラム開発環境

(1) 静止画分割プログラム

システム構築の学習データの準備には、既に静止画が存在する場合も想定されるが、実践的なシステム構築においては、動画を撮って、その動画から画像データを準備するケースが発生する。このため、動画から静止画へ分割するツールを準備した。

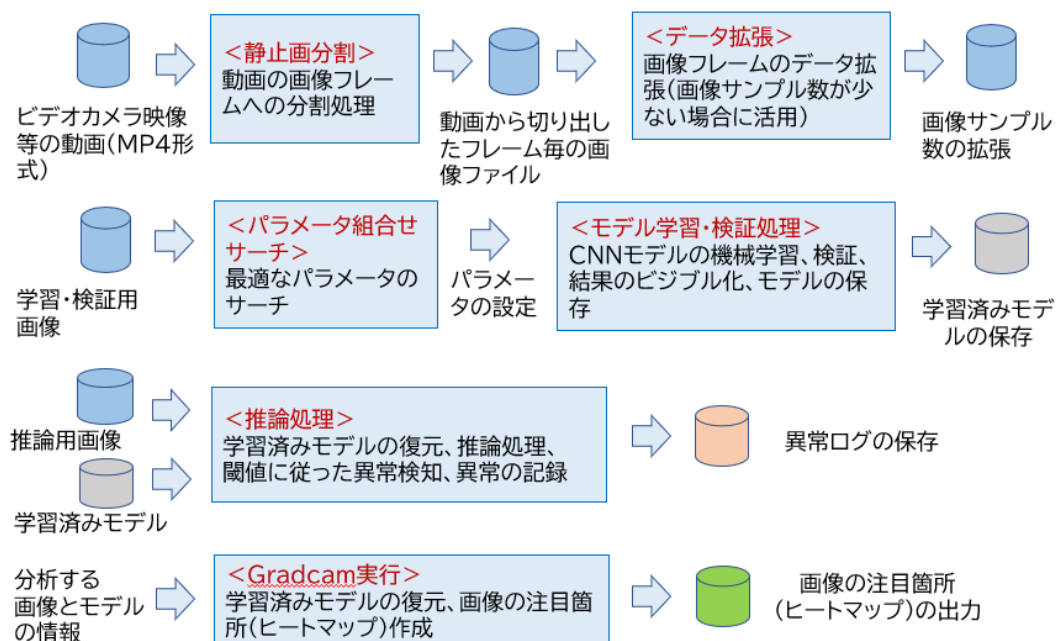


図 3.7 DL 応用プロトタイプのプログラム構成図

(2)画像データのデータ拡張プログラム

データの準備においては、既に存在するデータや動画取得によるデータ準備を行うが、そのデータ数が他の同等事例に対して不足することが考えられる。データを十分用意する手段として、一つのデータに回転、反転、拡大縮小、画像の平行移動などを組み合わせてデータ拡張を行い、データ数を増加するプログラムを開発した。

(3)パラメータ組み合わせサーチプログラム

本プログラムは前節で示したハイパーパラメータである画像サイズ、エポック数、ミニバッチサイズ、学習率、畳み込み層の層数、フィルタ数、フィルタサイズ、プーリング層の層数、プーリング方式 (MAX またはアベレージ)、全結合層の層数、ノード数、活性化関数、誤差関数、最適化アルゴリズムを指定可能とし、更にミニバッチサイズ、学習率、フィルタ数、フィルタサイズ、全結合層のノード数について、グリッドサーチ、ランダムサーチを実行できるものとした。

グリッドサーチは指定したハイパーパラメータの数値の全ての組み合わせを評価して、誤差によるランク付けをする機能であり、ランダムサーチはグリッドサーチと同様であるが、何パターンを検証対象とするかをパラメータで指定する手法になる。前者は検証パターン数のノウハウは不要であるが、検証時間を要する。後者は検証時間を節約できるが、何パターンを検証すれば最適或いはそれに近い組み合わせを見つけることができるかを予測できるノウハウが必要となる。

以上の機能により本プログラムによって前節で述べたチューニング手法の実行を可能とした。

(4)モデル学習・検証処理プログラム

画像を入力情報として、その画像のリサイズ、画像データの正規化、正解ラベルの付加、CNN モデルの構成、機械学習、検証、正解率、誤差のグラフ表示、学習済みモデルの保存を実行するプログラムを開発した。このプログラムでハイパーパラメータの最適な組み合わせを確定後、そのパラメータ構成で学習・検証を行い、正解率 (必要に応じて再現率、適合率へ変更)、誤差の観点でモデルの妥当性を確認できるようにしたものである。具体的には、要件を踏まえた正解率の絶対値の妥当性、過学習が発生していないかどうかの確認となる。

(5)推論処理プログラム

推論処理は学習済みモデルによって、その出力値を利活用する段階の処理となる。学習済みモデルの応用を実体験するため、学習済みモデルを復元し、推論用画像の正規化、推論結果の出力 (CNN の出力情報のグラフ表示用データの出力)、画像単位の異常、正

常の判断結果のログ出力、閾値にしたがった異常検知の表示などを行うプログラムを開発した。

CNN の出力値をビジュアル化するのは、CNN の判定がどれだけマージンを持って余裕をもった判定ができているかを確認する目的で用意した。チューニングとは直接の関係はないが、運用後のモデルの確からしさを確認できる。画像単位の判定結果のログは運用時の動作履歴となるが、このログを見ることで具体的にどの画像で誤りが発生しているかを確認可能であり、実運用における状態遷移時の画像認識の正確性を確認、監視することができる。最後に閾値の設定は前述のとおり、モデルの画像 1 枚の誤判定が全体の誤判定に繋がらないようにするための工夫である。また、評価時には要件に応じて過度の精度向上を求めず、効率化を優先する手法となる。

(6) GradCam 実行プログラム

GradCam は CNN が画像のどの部分を見ることで画像の分類をしているかについて、ヒートマップという手法を使ってビジュアル化する機能となる。本機能をサポートすることで人間が見て欲しい箇所を CNN が見ているかどうかを確認したい場合などに有効活用ができる。特に人間が見て欲しい箇所を見ていない場合は、人間が意図しないところに特徴がある画像になっていることを示しており、データの準備方法の改善のためのヒントに活用できる。

(7) 動画の準備

プロトタイプをベースに各種検証を実施する場合、実写の動画を使用すると画像間の特徴の微妙な差異を生成することが困難な面もあり、アニメーションツールで動画を作成し、微妙な差を有した画像を準備できるようにした。これにより学習するデータの選択によって特に汎化性能の評価に有効活用ができる動画準備を可能とした。

3.2.5 技術者育成手法に関する提案（課題4）

次に技術者育成に関する提案内容を述べる。研究の目標はシステム構築の効率化を目指すことであるが、最終的には、その手法を技術者に伝え実践して貰う必要があり、この観点で DL の実践経験が少ない技術者でもシステム構築を理解できるようにするための育成手法を提案する。

(1) オンラインライブ、オンデマンド併用型教育手法の提案

図 3.8 に教育実施形態の工夫点を示す。教育の実施は遠隔地からでも出席し易くするなどの理由でオンライン形式を基本とする。その実施形態はオンラインライブ講義、その後の宿題の実施、その際にはオンデマンドでの講義の復習を可能とする形態を基本とする。本方式により、受講生の参加しやすさの向上、宿題とオンデマンドの講義受講によって受講生の復習を促し理解の向上を図る。

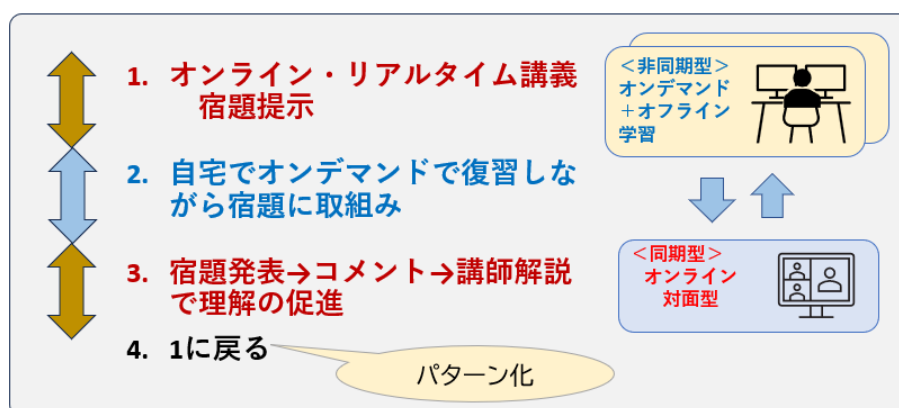


図 3.8 講座実施形態の工夫点

(2) 教育実施サイクルの提案

講座の実施回毎に前回の復習、宿題の解説、講義、宿題の出題を繰り返すことで同一の学習事項に講義と実習で何度も触れる機会を作り、受講生の理解促進を図る。

- ① 講座のアンケートも活用した前回講義の復習実施
- ② 宿題結果の受講生間の共有
- ③ 宿題に関する講師による評価と解説
- ④ 今回講座の講義
- ⑤ 次回の宿題説明
- ⑥ 今回講義のアンケート回収
- ⑦ 受講生の宿題実施と結果提出

(3) DL 基礎教育の事前実施

本技術者育成は DL の初学者も対象とすることから、DL 応用プロトタイプに基づく

教育の前に DL 基礎の事前講座を実施する。その教育内容の概要を以下に示す。

(a) NN の基本要素の概念と基本構成の理解促進

NN は人間の脳の細胞であるニューロンを参考とした技術である。既に図 2.2 で概念図を示したとおり、このニューロンを数値モデル化したものをニューロンモデルと呼び、ニューロンモデルのノードを縦に整列させた集合体を層と呼ぶ。その層が入力層、中間層、出力層を構成し、各層はニューロンモデルのネットワークで結合される。以上のような NN の基本構造の理解を促進する。

(b) NN を基礎とした DL の定義

DL の定義として、NN の中間層を複数構成にしたものが DNN のネットワークとなり、そのネットワークで機械学習を実施することを DL と総称していることを受講生に解説する。

(c) DNN 機械学習の仕組み

DNN の機械学習の仕組みとして、DNN にデータを入力し、DNN の出力結果と正解値の誤差を求め、この誤差を誤差逆伝搬法という仕組みにより最小化する作業が DNN における教師データありの機械学習であることを解説する。また、具体的な DNN 機械学習の動作としては、ニューロンモデルの構成要素である重みを最適化する動作であることを解説する。

(d) DL モデル活用の全工程の理解促進

DL モデルの活用においては、データ収集、データ加工、DL モデルの構成、機械学習、検証、推論、運用保守というステップがあることの説明を行う。またデータ加工の基本的な手法、モデル構成、機械学習における多くのハイパーパラメータ（重み、バイアス以外に人間が指定するパラメータ）の概要を解説する。

(e) 代表的な DL モデルの紹介

現状の代表的な DL モデルは中間層を複数そなえた基本的な DNN の構成に対して、さらに特徴的なアルゴリズムへ進化している。これらの代表的な DL モデルである CNN などのネットワーク構成、機械学習の仕組み、ハイパーパラメータなどの解説を実施する。

(f) DL モデル活用の基礎的実習

インターネットからプログラムと正解ラベル付きデータをダウンロードするような比較的簡単なアプローチで何らかの応用例を実行し、その DL モデルの実際の動作を体験することで理解を深める。

(4) 応用プロトタイプを基本とした講座の実施内容

3.2.4 節で示したプログラムやその解説書、サンプルの学習データ用の動画から構成される DL 活用のプロトタイプを準備し、その構築を通して DL の応用教育を実施する。図 3.9 に応用プロトタイプ構築による DL 教育手法の概要を示す。この手法によっ

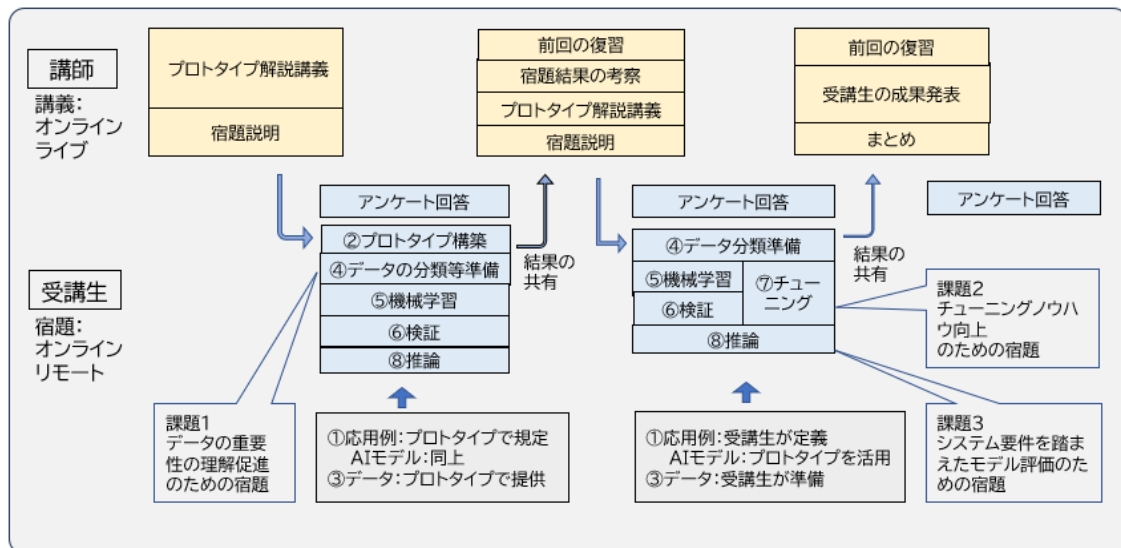


図 3.9 応用プロトタイプ構築による DL 教育手法

て実践的な技術育成を行うと共に 3.1 節で示した 3 つの課題の教育効果の向上を図る。

(a) 応用プロトタイプの講義 (オンラインライブ)

基礎教育の実施を受けてプロトタイプにおけるデータの準備、機械学習、検証、推論の実施方法、プロトタイプの構築方法などを講義する。

(b) 応用プロトタイプの構築と実行 (オンラインオンデマンド)

受講生がプロトタイプを構築し、プロトタイプで準備するデータから学習データ、推論データを準備し、応用例を実行する。プロトタイプのデータでは難易度の高いチューニングは必須の宿題とせず、DL 応用の一連の処理方式を経験させることに主眼をおく。

一方、データ準備の教育効果向上策として、受講生の実施結果を共有することで DL モデルと元データが同一でも DL モデルに入力する学習データの質や量の差によって推論時の性能に差がでることを確認し、データの重要性の理解を促進する。

(c) 受講生立案による応用事例の体験

次のステップとして受講生により応用事例の仕様を検討し、そのためのデータ準備を行って、応用システムの実現を図る。この場合、応用事例の仕様とデータの内容によってプロトタイプの DL モデルでは良好な結果が得られない可能性がある。ここで受講生に DL モデルのチューニングを実習させて、そのノウハウ向上を図る。また、受講生のチューニングの経緯と結果を受講生間で共有することで受講生のチューニングに関する理解の向上を図る。

(d) チューニングに関する補足説明の実施

チューニングの理解促進のため講師がプロトタイプとそのデータで実施した内容を開示し、受講生の理解促進を図る。

- ① 正解率に加えて誤検知のデータ、AI モデル出力値の見える化を図る。これにより難易度が高い部分でのモデル特性を開示する。

- ②ハイパーパラメータはチューニング対象とするハイパーパラメータについて、1個ずつパラメータ値を変化させ、当該モデルにおけるハイパーパラメータの特性を示すと共に、これによってハイパーパラメータの候補範囲を特定し、グリッドサーチやランダムサーチなどの手法による最適なハイパーパラメータの組み合わせ検索結果を示す。
- ③推論処理では、推論データでの認識性能を示す。具体的には画像データ毎の推論結果をログから確認し、誤りの発生状況を示す。また、同様に特に未学習のデータに関する汎化性能の確認を実施して開示し、要件を満たすかどうかを示す。これらの確認手段は該当画像毎の CNN の判定結果とデータを目視確認との比較を基本とする。その結果、改善を要する場合は、上記②で決定したパラメータの組合せ検証時の数値の妥当性、学習データの改善の余地、モデルの骨格への変更余地などを再確認する必要があることを示す。

(e)システム要件を踏まえた評価の重要性の理解

推論処理ではシステム要件を踏まえた閾値設定の考え方を導入して、システム要件を踏まえたモデル評価が重要であることの理解を促進する。

<動画による異常検出の閾値の例>

1秒間に何フレームの異常検知をした場合に異常発生とするかを閾値として設定する。この閾値設定によって判断が難しい状態におけるモデル性能の要件規定が可能となること、またモデルのフレーム毎の異常検出率は必ずしも100%に近い検出率を目指す必要がないこと、フレーム単位の検知精度に依存して正常を異常、異常を正常とする誤検知の発生防止に役立つこと、などの理解促進を図る。

3.3. 提案内容の実践

3.3.1. CNN チューニング手法の提案内容に関する検証

(1) 検証モデルの概要

図 3.10 に検証に使用した CNN の構造を示す。本検証は処理を単純化するため、2 値分類の基礎的なクラス分類問題を例とした。その検証モデルは畳み込み層、プーリング層のペアの 2 層構造とした。

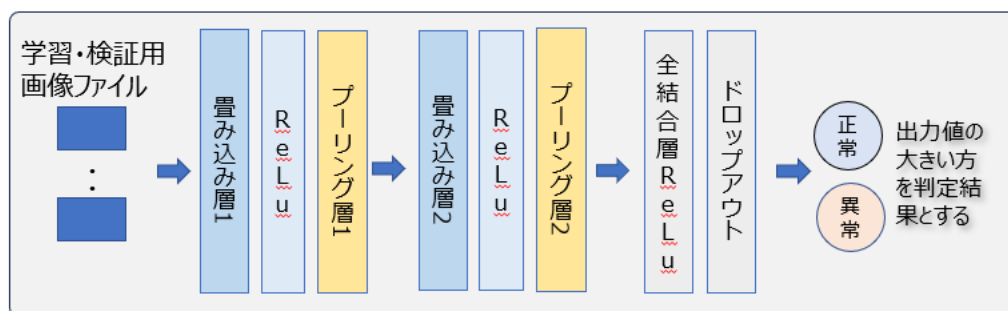


図 3.10 検証用 CNN の構造

(2) クラス分けの仕様と準備データ

図 3.11 に検証で使用した動画の概要を示す。実写の動画を使用した場合、画像間の特徴の微妙な差異を生成することが困難な面もあり、アニメーションツールで動画を作成し、微妙な差を有した画像を準備できるようにした。具体的には下図に示した動画から画像を抽出し学習用のデータとした。本動画は 3 つの Cube が画面上を左から右へ移動する動画であり、クラス分類は Cube の間隔が等間隔の場合を正常クラス、Cube の間隔が等しくなく、中間の Cube が片方に接近している場合を異常クラスとした。

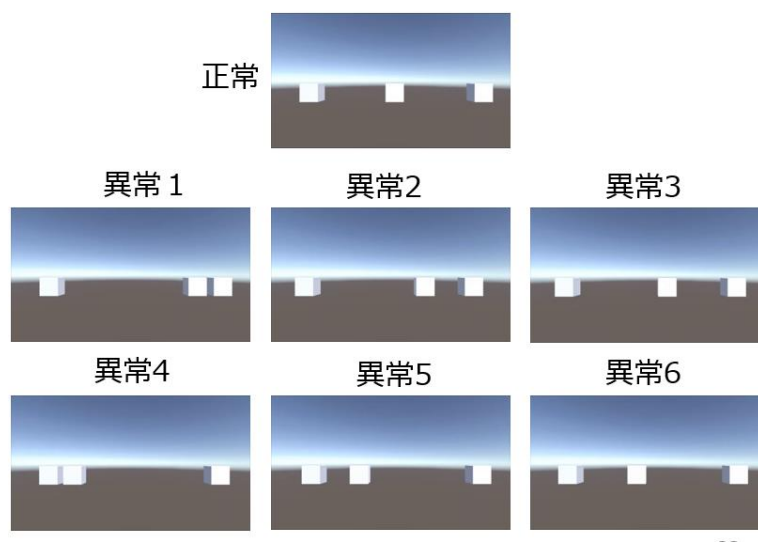


図 3.11 検証で使用した動画の概要

(3)CNN モデルの確定手順

(a)検証パラメータの選定と個別検証

3.1 章で述べた提案内容に沿って、これまでの評価実績や事例から良い評価結果が得られると考えられるハイパーパラメータの初期値を決める。まず、本検証では、以下の数値を初期値とした。

CNN に入力する画像サイズ : 128x128

エポック数 : 50

学習率 : 0.002、0.0015、0.001、0.0005、0.0001

初期値は事例でよく利用される 0.001 を初期値とした。

本パラメータは、0.001 を中心に複数の数値をピックアップし、最良のハイパーパラメータをサーチする。

ミニバッチサイズ : 16、32、64、96、128

過去の実績も踏まえて 64 を初期値とし、その周辺の数値を検証する。

畳み込み層の層数 : 2

1 層フィルタ数 : 32、64

2 層フィルタ数 : 64、128

デフォルトは 1 層 32、2 層 64、第二の候補として、1 層 64 も検証する。

フィルタサイズ : 3、5

デフォルトは 5、検証として 3 との差を確認する。

プーリング層の層数 ; 2

プーリング層の処理方法 : MAX プーリング

全結合層の数 : 1+出力層

全結合層のノード数 : 200、400、600、800、1000

600 をデフォルトにその周辺を検証する。

ドロップアウト率 : 0.5

最初の検証方法は一つのパラメータを選択し、そのパラメータの値を上記の数値で変化させ、その検証結果により各パラメータの特性を確認し、最終的に他のハイパーパラメータとの組み合わせ検証を行う数値を検討した。その検証結果は以下の通りとなった。

尚、表の数値に関する補足は以下のとおりである。検証では交差検証を実施している。交差検証は例として、学習データを 5 つに分割し、その内の 4 つを学習データ、一つを検証データとし、5 分割の全てを検証データとして使用する手法で、5 分割の場合は準備した学習データを使用して 5 回学習処理を行う。あるハイパーパラメータでの検証結果はこの 5 回の検証結果の平均値とする。表中「平均」の欄はこの交差検

証における平均値を示している。この手法は学習データを有効に活用し、認識性能を正確に把握できる手法となる。また、この平均値や交差検証 1 などで示される数値は交差エントロピーという誤差関数の値となる。交差エントロピーは、以下のような数値となる。

3 クラス分類における正解値と CNN の予想値における交差エントロピー

正解 (1、0、0)、学習或いは推論での予測値 (0.9、0.05、0.05) の場合
交差エントロピーの式

$$H = - (1 * \log(0.9) + 0 * \log(0.05) + 0 * \log(0.05)) = 0.045757$$

予測値が (0.5、0.25、0.25) の場合、

$$H = - 1 * \log(0.5) = 0.301030$$

学習は誤差が大きく変化した方が早く進む効果がある。交差エントロピーはこの観点で、単純な絶対値の差を誤差とするよりも誤差の変化が大きくなり学習の収束が早いとされている。

(i) ミニバッチサイズ

表 3.1 にミニバッチサイズの評価結果を示す。中間値の 32、64、96 が良い結果で、その精度には殆ど差が無い。順位付けをすると 96 が 1 位、32 が 2 位、64 が 3 位となるが、全体の傾向としては、大きすぎても小さすぎても良い結果がでない傾向を示している。組み合わせ評価用の選択肢としては、3 つ選択の場合は、32、64、96。2 値を選択の場合は、96 が 1 位を尊重し、その連続数値である 64 を評価候補とした。

表 3.1 ミニバッチ検証結果

ミニバッチ	学習時間	検証時間	交差検証 1	交差検証 2	交差検証 3	交差検証 4	交差検証 5	平均	ランク
16	31.1402906	0.15895209	-0.6913535	-0.0218014	-0.6935761	-0.6928154	-0.0091157	-0.4217324	5
32	20.7911055	0.15718465	-0.0154645	-0.0201725	-0.0125464	-0.0268404	-0.018807	-0.0187662	2
64	16.0098286	0.15715671	-0.0134208	-0.01233	-0.02046	-0.0180027	-0.0301295	-0.0188686	3
96	13.4259644	0.15780349	-0.0091445	-0.0232706	-0.0158683	-0.0277133	-0.0168086	-0.018561	1
128	12.6947736	0.22833424	-0.0364088	-0.0335539	-0.0337786	-0.0210258	-0.0328921	-0.0315318	4

(ii) 全結合層のノード数

表 3.2 に全結合層のノード数の評価結果を示す。この数値も中間値が良い結果を示しており、ミニバッチサイズと同様に大きすぎても小さすぎても良い結果がでない傾向を示している。組み合わせ検証の候補値は 3 値選択であれば、400、600、800 であり、2 値選択であれば、600、800 と判断できる。

表 3.2 全結合層ノード数の検証結果

全結合層ノード数	学習時間	検証時間	交差検証 1	交差検証 2	交差検証 3	交差検証 4	交差検証 5	平均	ランク
200	76.61282	0.283939	-0.05765	-0.02798	-0.0422	-0.03401	-0.04408	-0.04118	4
400	72.38186	0.307473	-0.0147	-0.03015	-0.01213	-0.02819	-0.03134	-0.0233	3
600	69.61229	0.286636	-0.00801	-0.02106	-0.00896	-0.02628	-0.01887	-0.01664	1
800	79.22917	0.363249	-0.02929	-0.01177	-0.0079	-0.02166	-0.02104	-0.01833	2
1000	76.07051	0.379908	-0.69142	-0.69183	-0.00677	-0.69294	-0.01698	-0.41999	5

(iii) 学習率

表 3.3 に学習率の評価結果を示す。学習率も他と同様に中間値がよい性能となる傾向を示している。組み合わせ検証の候補値としては、3 値選択であれば、0.0001、0.0005、0.001、2 値選択の場合は 0.0005、0.001 が妥当と判断できる。

表 3.3 学習率の検証結果

学習率	学習時間	検証時間	交差検証 1	交差検証 2	交差検証 3	交差検証 4	交差検証 5	平均	ランク
0.002	15.9437	0.15776	-0.6914	-0.03232	-0.04514	-0.03553	-0.01947	-0.16477	5
0.0015	15.93495	0.15792	-0.04432	-0.03192	-0.6938	-0.01661	-0.0341	-0.16415	4
0.001	15.92415	0.224286	-0.00869	-0.02297	-0.01504	-0.01887	-0.01647	-0.01641	2
0.0005	16.04123	0.159337	-0.01232	-0.00995	-0.00924	-0.01631	-0.01426	-0.01242	1
0.0001	15.99812	0.160632	-0.07363	-0.06629	-0.06377	-0.05627	-0.06126	-0.06424	3

(iv) 畳み込み層 1 層、2 層のフィルタ数

表 3.4 に評価結果を示す。傾向としてフィルタ数は 1 層 x 2 = 2 層の形態がランク上位になっている。32、64 のパターンと 64、128 のパターンの何れを選択するかという観点では、その差が小さく、CNN 系のモデルで 32 からスタートする例が多いため、32、64 のパターンの選択を基本とし、組み合わせ検証は不要と判断した。

表 3.4 畳み込み層のフィルタ数の検証結果

1層フィルタ	2層フィルタ	学習時間	検証時間	交差検証 1	交差検証 2	交差検証 3	交差検証 4	交差検証 5	平均	ランク
32	64	16.03507	0.158254	-0.01475	-0.02045	-0.0047	-0.01268	-0.02922	-0.01636	1
32	128	21.10663	0.161799	-0.02825	-0.00614	-0.01454	-0.02031	-0.04318	-0.02248	3
64	64	18.52326	0.228799	-0.00714	-0.69157	-0.69378	-0.69316	-0.69011	-0.55515	4
64	128	23.43496	0.168196	-0.03664	-0.02588	-0.00886	-0.02371	-0.00431	-0.01988	2

(v) フィルタサイズ

表 3.5 に評価結果を示す。全体的に微妙な差しかないが、傾向としてフィルタはサイズを揃える方がランク上位になっている。本ハイパーパラメータは 3x3 と 5x5 でその性能差が過小でありチューニングをより単純化するため、筆者の実績が多い 5x5 を採用し、組み合わせ検証は不要と判断した。

表 3.5 フィルタサイズの検証結果

1層フィルタ	2層フィルタ	学習時間	検証時間	交差検証 1	交差検証 2	交差検証 3	交差検証 4	交差検証 5	平均	ランク
3	3	13.40432	0.157945	-0.00891	-0.01495	-0.01077	-0.02077	-0.0184	-0.01476	1
3	5	16.04551	0.15996	-0.02962	-0.01119	-0.01903	-0.0255	-0.02043	-0.02115	4
5	3	13.46324	0.15658	-0.01771	-0.01023	-0.00989	-0.02283	-0.02899	-0.01793	3
5	5	16.05464	0.158621	-0.01813	-0.02124	-0.00654	-0.02053	-0.01545	-0.01638	2

(b)組み合わせ検証結果

上記の個別検証を踏まえて、学習率と全結合層のノード数における 2 位、3 位の差が大きいことから、組み合わせ検証は、上位 2 つの数値を選定して実施した。その結果を表 3.6 に示す。

グリッドサーチでのハイパーパラメータの組み合わせ

学習率 : 0.001、0.0005

ミニバッチサイズ : 64、96

全結合層の数 : 600、800

固定したハイパーパラメータ

ドロップアウト : 0.5

1 層フィルタ数 : 32

2 層フィルタ数 : 64

フィルタサイズ : 5

画像サイズ : 128x128

エポック数 : 50

表 3.6 組み合わせ検証結果

バッチサイズ	全結合層ノード数	学習率	学習時間	検証時間	交差検証 1	交差検証 2	交差検証 3	交差検証 4	交差検証 5	平均	ランク
64	800	0.0005	16.71324	0.158852	-0.0103	-0.01008	-0.00453	-0.01963	-0.01	-0.01091	1
64	600	0.0005	16.06546	0.157743	-0.02116	-0.02357	-0.00443	-0.0211	-0.00608	-0.01527	2
96	600	0.0005	13.50041	0.161548	-0.01766	-0.01792	-0.01393	-0.01881	-0.02323	-0.01831	3
96	800	0.0005	13.88497	0.161338	-0.0142	-0.01455	-0.00677	-0.02293	-0.03633	-0.01896	4
64	600	0.001	15.98361	0.161603	-0.01659	-0.00977	-0.03231	-0.03415	-0.00364	-0.01929	5
64	800	0.001	16.63658	0.162399	-0.06226	-0.02991	-0.01378	-0.02085	-0.02313	-0.02999	6
96	600	0.001	13.38937	0.157434	-0.01081	-0.02687	-0.00922	-0.02204	-0.68986	-0.15176	7
96	800	0.001	13.90318	0.158679	-0.0373	-0.69122	-0.0084	-0.03202	-0.01793	-0.15737	8

- i) 上記の結果をまとめるとミニバッチ、全結合層のノード数、学習率は、大き過ぎず、小さ過ぎない値を見つける必要がある。
- ii) 組み合わせの 1 位は以下となる。
ミニバッチ 64、全結合層のノード数 800、学習率 0.0005
- iii) 上位 5 ランクは非常に僅差、学習時の正解率 99.5%以上の 0.数%の範囲。

- iv) 学習率は、このケースでは 0.0005 の方が優位な傾向を示す。
- v) ミニバッチは、64 の方がやや優位な結果になっている。
- vi) 全結合層のノード数は、400 から 800 の範囲では顕著な傾向は見えない。

チューニングによるモデル確定の検証は以上のとおりであるが、3.2 章でのチューニングに関する提案内容の手順に沿った形で実施し、特性を見る必要があるハイパーパラメータの特徴を確認し、最適なハイパーパラメータの組み合わせを確認した。その結果としてのモデルの認識性能も 99%以上の正解率であり、提案内容の妥当性が検証できたと判断している。

3.4.2. CNN モデルの性能検証とデータ準備手法の検証

確定したモデルの認識性能を分析することで、データ準備手法の検証を行う。その結果を以下に示す。

(1)エポック数 100 (Early Stopping) での性能

以下の本検証におけるハイパーパラメータの構成を示す。

画像サイズ	: 128x128
カラー	: グレースケール
エポック数	: 100(early stopping)
ミニバッチサイズ	: 64
全結合層の数	: 800
ドロップアウト	: 0.5
1 層フィルタ数	: 32
2 層フィルタ数	: 64
フィルタサイズ	: 5
中間層活性化関数	: Relu
出力層活性化関数	: Softmax
誤差関数	: 交差エントロピー
学習率	: 0.0005
最適化アルゴリズム	: adam

性能を検証すべきモデルのハイパーパラメータが確定したことで、このモデルにおいて過学習が発生しない範囲のエポック数の最大値を確認する目的も兼ねて、個別検証時のエポック数 50 を 100 とし、終了条件を Early Stopping で示す形態とした。具体的には、連続 10 回のエポック実行で誤差の改善が見られない場合に、その時点で学習を終了する設定とした。この結果の正解率グラフを図 3.12 に示す。

結果としては、個別ハイパーパラメータの検証時とほぼ同じエポック数 50 程度で終了する結果を得た。このケースにおける誤認識の箇所を以下に示す。




図 3.12 確定したハイパーパラメータでの正解率グラフ

a) 推論における判定結果

表 3.7 推理における判定結果

No	画像サイズ	カラー	エポック	誤り総数	正解率	正常→異常 1		異常 1→正常		正常→異常 2		異常 2→正常	
						最初の異常フレームNo.	960	最初の正常フレームNo.	1382	最初の異常フレームNo.	1753	最初の正常フレームNo.	2142
1	128x128	L	ES100	7	99.86%	最初の異常	962	最初の正常	1382	最初の異常	1753	最初の正常	2142
						誤り数	-2	誤り数	0	誤り数	0	誤り数	0
2	128x128	L	10	71	98.58%	最初の異常	962	最初の正常	1382	最初の異常	1754	最初の正常	2140
						誤り数	-2	誤り数	0	誤り数	-1	誤り数	2
正常→異常 3		異常 3→正常		正常→異常 4		異常 4→正常		正常→異常 5		異常 5→正常			
最初の異常フレームNo.	2546	最初の正常フレームNo.	2908	最初の異常フレームNo.	4177	最初の正常フレームNo.	4592	最初の異常フレームNo.	4941	最初の正常フレームNo.	5329		
最初の異常	2547	最初の正常	2908	最初の異常	4177	最初の正常	4591	最初の異常	4941	最初の正常	5329		
誤り数	-1	誤り数	0	誤り数	0	誤り数	1	誤り数	0	誤り数	0		
最初の異常	2548	最初の正常	2906	最初の異常	4177	最初の正常	4582	最初の異常	4941	最初の正常	5325		
誤り数	-2	誤り数	2	誤り数	0	誤り数	10	誤り数	0	誤り数	4		
正常→異常 6		異常 6→正常		その他の誤り									
最初の異常フレームNo.	5718	最初の正常フレームNo.	6075	異常を正常と判断				正常を異常と判断					
最初の異常	5718	最初の正常	6074	なし				f=611,3688					
誤り数	0	誤り数	1					0					
最初の異常	5718	最初の正常	6057	f = 5311,5320-5322				f=274,598-609,3351, 3675-3686					
誤り数	0	誤り数	18					4					

b) 誤認識箇所




図 3.13 誤認識箇所

c) エポック数 10 での性能

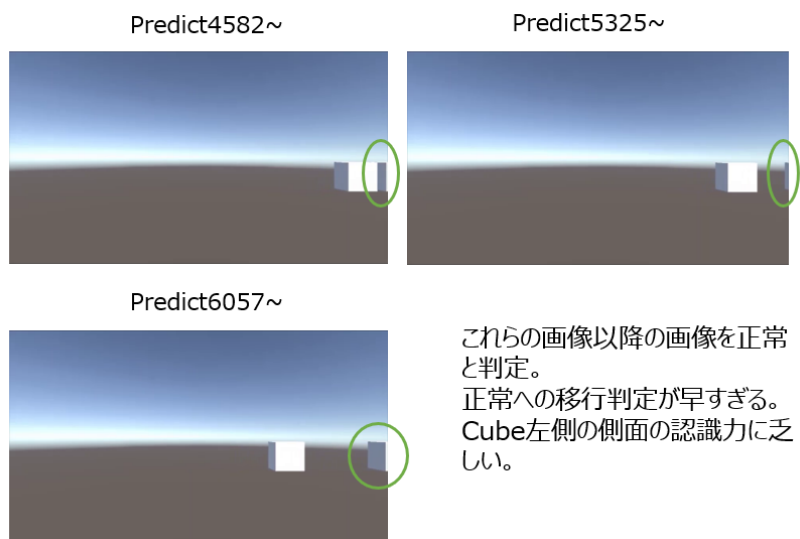


図 3.14 エポック 10 での追加誤認識箇所

エポックが 10 までしか進行しない段階での誤認識箇所を確認し、エポックが進むにつれて、認識性能がどう進むのかを確認した。

d) 確定モデルの性能分析まとめ

- ・エポック 100 の **Eary Stopping** ではエポック 50 程度で終了し、状態変化時の誤認識が 4 カ所で、間違いは 2 枚から 1 枚という精度を確保できている。
- ・正常状態を異常と検知するケースも 2 カ所、各 1 画像に留まる。
誤りの要因は、2 つ目の **Cube** の側面の出現時、或いは画面から消失時の細かい

画像の検知ミスで起こる。

- エポック 10 でも正解率は 98%を超えるが、Cube の側面の認識率が低下して、状態遷移で最大 18 枚、正常時を異常と判断する箇所が最大 11 枚連続で発生する。さらに 1 個の Cube の画像端までの距離の判断誤りが発生する。
- 学習回数を増やすと、CNN の判定結果が大きく改善する。

(2)モデルの汎化性能の確認

汎化性能を確認するため、学習データから一部を削除し、推論時にその削除部分はどう変化するかを確認して、汎化性能の特性を検証した。以下にその結果を示す。

a) Cube 間の距離が一番短い異常画像を学習データから削除した場合

以下の図 3.15 に示す画像データを学習データから削除した。




図 3.15 学習データから削除した画像

推論処理の誤り確認結果を以下に示す。

表 3.8 推論処理の認識結果

No	画像サイズ	カラー	エポック	誤り総数	正解率	学習・検証時未使用画像	未使用画像枚数	未使用画像での誤り件数	未知データの誤り率	未使用データ以外での誤り数	正常→異常 1 最初の異常フレームNo.	960	異常 1→正常 最初の正常フレームNo.	1382	
画像 1	128x128	L	ES100	347	93.06%	f=960-1381, 4177-4591	837	346	41.3%	1	最初の異常 誤り数	1044 -84	最初の正常 誤り数	1382 0	
正常→異常 2		異常 2→正常		正常→異常 3		異常 3→正常		正常→異常 4		異常 4→正常		正常→異常 5		異常 5→正常	
最初の異常フレームNo.	1753	最初の正常フレームNo.	2142	最初の異常フレームNo.	2546	最初の正常フレームNo.	2908	最初の異常フレームNo.	4177	最初の正常フレームNo.	4592	最初の異常フレームNo.	4941	最初の正常フレームNo.	5329
最初の異常	1753	最初の正常	2142	最初の異常	2546	最初の正常	2908	最初の異常	4178	最初の正常	4483	最初の異常	4942	最初の正常	5329
誤り数	0	誤り数	0	誤り数	0	誤り数	0	誤り数	-1	誤り数	109	誤り数	-1	誤り数	0
正常→異常 6		異常 6→正常		その他の誤り											
最初の異常フレームNo.	5718	最初の正常フレームNo.	6075	異常を正常と判断								正常を異常と判断			
最初の異常	5718	最初の正常	6075	f=1176-1250 f=4288-4292,4309-4360,4366-4371.								なし			
誤り数	0	誤り数	0	4373-4386								152			

b) Cube 間の距離が一番長い異常画像を学習データから削除した場合
 図 3.16 に示す以下のデータを学習データから削除した。




図 3.16 学習データから削除した画像

推論処理の誤り確認結果を以下に示す。

表 3.9 推論処理の認識結果

No	画像サイズ	カラー	エポック	誤り総数	正解率	学習・検証時未使用画像	未使用画像枚数	未使用画像での誤件数	未知データの誤り率	未使用データ以外での誤り数	正常→異常 1		異常 1→正常		
											最初の異常フレームNo.	960	最初の正常フレームNo.	1382	
画像 3	128x128	L	ES100	504	89.92%	f=2546-2909, 5718-6074	721	502	69.6%	2	最初の異常	960	最初の正常	1382	
											誤り数	0	誤り数	0	
正常→異常 2		異常 2→正常		正常→異常 3		異常 3→正常		正常→異常 4		異常 4→正常		正常→異常 5		異常 5→正常	
最初の異常フレームNo.	1753	最初の正常フレームNo.	2142	最初の異常フレームNo.	2546	最初の正常フレームNo.	2908	最初の異常フレームNo.	4177	最初の正常フレームNo.	4592	最初の異常フレームNo.	4941	最初の正常フレームNo.	5329
最初の異常	1753	最初の正常	2142	最初の異常	2591	最初の正常	2908	最初の異常	4177	最初の正常	4591	最初の異常	4942	最初の正常	5329
誤り数	0	誤り数	0	誤り数	-45	誤り数	0	誤り数	0	誤り数	1	誤り数	-1	誤り数	0
正常→異常 6		異常 6→正常		その他の誤り											
最初の異常フレームNo.	5718	最初の正常フレームNo.	6075	異常を正常と判断						正常を異常と判断					
最初の異常	5718	最初の正常	6070	f=2607,2608,2614-2641,2645-2651,2654-2655,2679-2695,2698,2704-2760,2765-2784,2802,2805-2810,2814-2838,2852-2869						f=611,3688 (学習画像を削減しない場合に発生している誤認識が復活している)					
誤り数	0	誤り数	5	f=5740-5766,5768-5774,5778-5823,5834-5860,5863-5927,5929-5931,5971-6011,6014-6019,6021-6027,6031-6066						450					

以上の 2 パターンの検証結果をまとめると境界部分のデータ、この場合は Cube の距離が最短の異常データと最長の異常データは充分用意すべきであることが解る。この部分のデータがないと学習が不十分になり、モデルチューニングも実効性が向上しない。データが少ない場合、或いはない場合、データ拡張の手法も検討し、データの準備が必要となることが解る。準備できない場合は試使用段階などでデータ

を集めて、モデルの再学習が必要になる。

- c) Cube 間の距離が 2 番目に短い異常画像を学習データから削除した場合
以下の図 3.17 に学習データから削除した画像を示す。




図 3.17 学習データから削除した画像

推論処理の誤り確認結果を以下に示す。

表 3.10 推論処理の認識結果

No	画像サイズ	カラー	エポック	誤り総数	正解率	学習・検証時未使用画像	未使用画像枚数	未使用画像での誤件数	未知データの誤り率	未使用データ以外での誤り数	正常→異常1 最初の異常フレームNo.	960 最初の異常誤り数	異常1→正常 最初の正常フレームNo.	1382 最初の正常誤り数	
画像2	128x128	L	ES100	33	99.34%	f=1753-2141, 4941-5328	776	32	4.1%	1	960	0	1382	0	
正常→異常2		異常2→正常		正常→異常3		異常3→正常		正常→異常4		異常4→正常		正常→異常5		異常5→正常	
最初の異常フレームNo.	1753	最初の正常フレームNo.	2142	最初の異常フレームNo.	2546	最初の正常フレームNo.	2908	最初の異常フレームNo.	4177	最初の正常フレームNo.	4592	最初の異常フレームNo.	4941	最初の正常フレームNo.	5329
最初の異常誤り数	-6	最初の正常誤り数	0	最初の異常誤り数	0	最初の正常誤り数	0	最初の異常誤り数	-1	最初の正常誤り数	1	最初の異常誤り数	-1	最初の正常誤り数	24
正常→異常6		異常6→正常		その他の誤り											
最初の異常フレームNo.	5718	最初の正常フレームNo.	6075	異常を正常と判断										正常を異常と判断	
最初の異常誤り数	0	最初の正常誤り数	0	なし										なし	

異常データの中で中間の距離を持つデータは、学習時の学習データとして存在していなくても汎化性能によって異常検知性能が大きく低下しない。これらの中間的な特徴を持つデータは少数でも検知性能に大きな影響は与えない。

d) 間隔が一番短い 2 つの Cube の画像中の中間的な位置のデータを削除
 以下の図 3.18 に学習データから削除した画像を示す。




図 3.18 学習データから削除した画像

推論処理の誤り確認結果を以下に示す。

表 3.11 推論処理の認識結果

No	画像サイズ	カラー	エポック	誤り総数	正解率	学習・検証時未使用画像	未使用画像枚数	未使用画像での誤件数	未知データの誤り率	未使用データ以外での誤り数	正常→異常 1		異常 1→正常	
											最初の異常フレームNo.	960	最初の正常フレームNo.	1382
画像 4	128x128	L	ES100	46	99.08%	f=1014-1138, 4416-4531	241	31	12.9%	15	最初の異常フレームNo.	962	最初の正常フレームNo.	1383
											誤り数	-2	誤り数	-1

正常→異常 2		異常 2→正常		正常→異常 3		異常 3→正常		正常→異常 4		異常 4→正常		正常→異常 5		異常 5→正常	
最初の異常フレームNo.	1753	最初の正常フレームNo.	2142	最初の異常フレームNo.	2546	最初の正常フレームNo.	2908	最初の異常フレームNo.	4177	最初の正常フレームNo.	4592	最初の異常フレームNo.	4941	最初の正常フレームNo.	5329
最初の異常誤り数	1753	最初の正常誤り数	2142	最初の異常誤り数	2547	最初の正常誤り数	2908	最初の異常誤り数	4177	最初の正常誤り数	4591	最初の異常誤り数	4941	最初の正常誤り数	5329
	0		0		-1		0		0		1		0		0

正常→異常 6		異常 6→正常		その他の誤り	
最初の異常フレームNo.	5718	最初の正常フレームNo.	6075	異常を正常と判断	
最初の異常誤り数	5717	最初の正常誤り数	6075	f=1020-1041,4517-4525 (cubeと画面の端までの距離が正常画像の距離以下になったタイミングで発生)	
	1		0		31
					f=273,274,610-612,3351,3687-3689
					9

以下に図示する接近した Cube の中間ポジションでは、汎化性能による異常検知性能が充分確保される。

しかし、下記の図 3.19 で示す両端の部分では、多数の 1 個の Cube の正常画像を学習しているため、接近した 2Cube に重きが置かれず、正常と判断してしまう画像

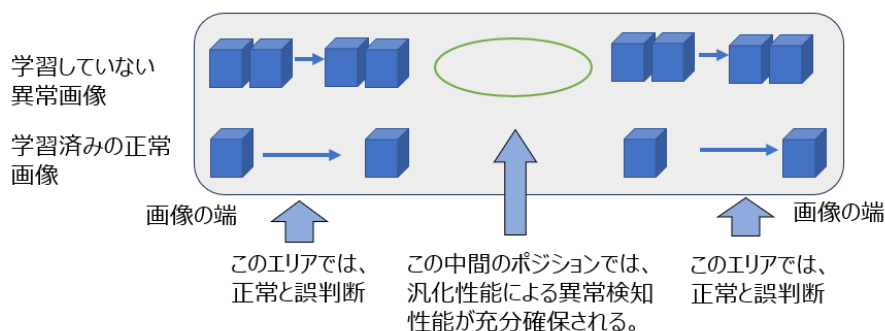


図 3.19 汎化性能が十分に有効な箇所

が発生する。

以上から同じ形状のものは、画像の位置が違って同じものと判断するので、データの準備は少なくとも良いことが解るが、同一ポジションに類似のデータが多数あり、これらと区別して識別したい場合などは、識別したいデータを充分準備した方が良いことが解る。

e) 接近した 2Cube が画面から欠ける画像の一部を除外した場合
以下の図 3.20 に学習データから削除した画像を示す。




図 3.20 学習データから削除した画像

推論処理の誤り確認結果を以下に示す。

表 3.12 推論時の認識結果

No	画像サイズ	カラー	エポック	誤り総数	正解率	学習・検証時未使用画像	未使用画像枚数	未使用画像での誤り件数	未知データの誤り率	未使用データ以外での誤り数	正常→異常 1 最初の異常フレームNo.	異常 1→正常 最初の正常フレームNo.	1382
画像 5	128x128	L	ES100	14	99.72%	f=974-1004. 4551-4577	58	0	0.0%	14	最初の異常 フレームNo. 960	最初の正常 フレームNo. 963	1380
											誤り数 -3	誤り数	2
正常→異常 2		異常 2→正常		正常→異常 3		異常 3→正常		正常→異常 4		異常 4→正常		正常→異常 5	
最初の異常フレームNo.	1753	最初の正常フレームNo.	2142	最初の異常フレームNo.	2546	最初の正常フレームNo.	2908	最初の異常フレームNo.	4177	最初の正常フレームNo.	4592	最初の異常フレームNo.	4941
最初の異常誤り数	1753	最初の正常誤り数	2140	最初の異常誤り数	2546	最初の正常誤り数	2906	最初の異常誤り数	4177	最初の正常誤り数	4590	最初の異常誤り数	4942
	0		2		0		2		0		2		-1
													1
正常→異常 6		異常 6→正常		その他の誤り									
最初の異常フレームNo.	5718	最初の正常フレームNo.	6075	異常を正常と判断				正常を異常と判断					
最初の異常誤り数	5718	最初の正常誤り数	6074	なし				なし					
	0		1					0					

学習データから削除したことは判定に全く影響していない。これは Cube 間の近接部分の特徴がしっかり認識できているためと思われる。したがって、形状の変化はあっても、他に判別可能な特徴を持っていれば、形状の差によるデータ準備は一部省略できることを示している。

以上の検証結果を踏まえて汎化性能について、以下にまとめる。

- ・クラス分けの境界に関連した画像は充分準備が必要となる。
- ・中間的な特徴を持つ部分はデータ数が少なくとも認識性能への影響は小さい。
- ・同じ形状のものは、画像内の位置がどこでも同じものと認識するので、データ数

が少なくても性能への影響は小さい。ただし、類似画像が多数あるポジションがあり、この類似画像とは別クラスで識別したい場合は十分なデータ準備が必要となる。

- ・検知すべき物体の形状は、多少変形していても特徴的な部分が学習されていれば、認識性能への影響は小さい。

以上が確定したモデルの評価内容となる。この結果から、クラス分類の境界に相当する部分、あるクラスから他のクラスへ遷移する周辺データを重点的に準備する必要があることが解る。また、汎化性能により同一クラス内の物体の特徴や物体間距離などの特徴については、動画中の位置を網羅したデータの準備は抑制することができる。更に形状については、その形状に変化がある場合でも、特徴的な部分が十分判別できれば、物体形状の変化をデータとして網羅的に準備する必要はないことも解る。この内容から 3.2 節の提案内容の妥当性を確認できたと判断している。

3.4.3. LSTM のチューニング手法の提案内容に関する評価

(1)LSTM の構成

LSTM の構造は、図 2.11、図 2.12 に示した通りであるが、評価では、入力が n 個のスカラー値、出力が 1 個のスカラー値、LSTM の構造を複数連結する形態は取らない形態とした。

(2)学習データと予測値

学習データは、分布の範囲を示す数値を漸次的に小さい値にししながら、その範囲で一樣分布での乱数を発生させ、そのデータを時系列の学習データとした。時系列データはある時刻から発生するものと仮定し、予測する数値はある事象発生までの時間数とした。データ生成における数値のイメージを以下の図 3.21 に示す。

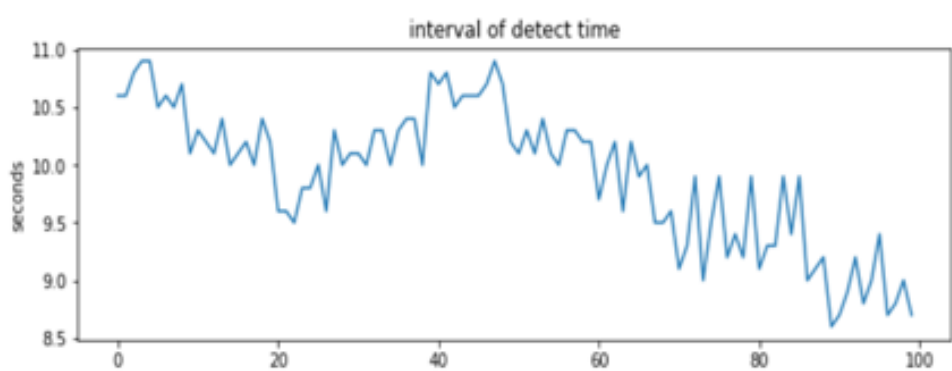


図 3.21 学習する時系列データの例

(3)評価指標

回帰の場合、モデル出力の予測値が、正解値をどの程度再現できているかを評価する

指標として Root Mean Squared Error (RMSE)、R2 (決定係数)などを使用する。その概要は以下のとおりである。

RMSE は、Mean Squared Error (MSE : 平均二乗誤差) の平方根となる。なお、誤差関数では偏微分との相性がよいことから通常 MSE を使用する。RMSE はモデルの精度評価などで誤差の絶対値を見る場合に有効となる。計算式は以下の通りとなる。

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad \begin{array}{l} \text{(正解値-予測値) の2乗の平均値} \\ \text{の平方根} \end{array}$$

R2 は 正解値と予想値が完全に一致する場合に 1 となり、R2 が 1 に近いほど、精度の高い予測であることを示す。計算式は以下の通りとなる。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad \text{(正解値-予測値) の2乗の総和}}{\sum_{i=1}^n (y_i - \bar{y})^2 \quad \text{(正解値-正解の平均値) の2乗の総和}}$$

(4)評価するハイパーパラメータとエポック数の決定

3.2 節で示した内容に従い特性を確認してチューニングするハイパーパラメータはエポック数、LSTM ブロック数、時系列の長さ、ミニバッチサイズ、学習率とした。

最初に以下に示すパラメータ構成で、エポック数を決定するための評価を実施した。エポック数以外の数値は適切かどうかこの時点では不明であるが、暫定値として、実績などから予測して設定している。

検証するエポック数 = 50、80、100、150 で実施
 LSTM のブロック数 = 64
 時系列の長さ = 20
 ミニバッチサイズ = 32
 学習率 = 0.001

検証結果を表 3.13 に示す。一般的にエポック数は多い方が、精度が高いが、その傾向はエポック 100 までであるため、エポック数は 100 と設定して評価を行った。

表 3.13 エポック数の評価

エポック数	LSTM ブロック数	時系列 の長さ	ミニバッチ サイズ	学習率	RMSE	R2	ランク
50	64	20	32	0.001	0.1594	0.7111	4
80	64	20	32	0.001	0.1555	0.7251	2
100	64	20	32	0.001	0.1549	0.7272	1
150	64	20	32	0.001	0.1578	0.7168	3

(5)ハイパーパラメータの個別検証

次にチューニングすべきハイパーパラメータの特性を確認する検証を実施した。その結果を以下に示す。

a) LSTM ブロック数

検証したパラメータは、これまでの評価実績も踏まえて以下のパラメータ構成とした。

エポック数 = 100
LSTM ブロック数 = 16、32、64、96
時系列の長さ = 20
ミニバッチサイズ = 32
学習率 = 0.001

検証結果を表 3.14 に示す。

表 3.14 LSTM ブロック数の評価

エポック数	LSTM ブロック数	時系列 の長さ	ミニバッチ サイズ	学習率	RMSE	R2	ランク
100	16	20	32	0.001	0.1546	0.7281	3
100	32	20	32	0.001	0.1537	0.7313	1
100	64	20	32	0.001	0.1549	0.7272	4
100	96	20	32	0.001	0.1545	0.7285	2

LSTM ブロックの長さはその数値による評価数値の大きな差はなく、大きな傾向は認められなかった。通常では、ブロック数が多い方ほど精度が上がり、ある時点で性能向上が限界に達するという傾向を示すことから、本ケースでは、ブロック長 32 が性能のピークになったものと判断した。

b) 時系列の長さの変更による精度の変動確認

検証したハイパーパラメータの数値を以下に示す。時系列の長さは、これまでの評価経験も踏まえて、以下の数値とした。

エポック数 = 100
LSTM ブロック数 = 32
時系列の長さ = 5、10、20、30
ミニバッチサイズ = 32
学習率 = 0.001

検証結果を以下の図 3.15 に示す。

表 3.15 時系列の長さの評価

エポック数	LSTM ブロック数	時系列 の長さ	ミニバッチ サイズ	学習率	RMSE	R2	ランク
100	32	5	32	0.001	0.1482	0.7421	2
100	32	10	32	0.001	0.1085	0.8372	1
100	32	20	32	0.001	0.1537	0.7313	3
100	32	30	32	0.001	0.1760	0.6122	4

時系列の長さは時系列データの発生パターンなどから、何が最適であるかを探す必要があるが、今回の結果では中間に位置する時系列の長さ 10 が良い結果を示した。

c) ミニバッチサイズ

検証したハイパーパラメータの数値を以下に示す。ミニバッチサイズはこれまでの評価経験も踏まえて、以下の数値とした。

エポック数 = 100
 LSTM ブロック数 = 32
 時系列の長さ = 10
 ミニバッチサイズ = 16、32、64、128
 学習率 = 0.001

検証結果を以下の表 3.16 に示す。

表 3.16 ミニバッチサイズの評価

エポック数	LSTM ブロック数	時系列 の長さ	ミニバッチ サイズ	学習率	RMSE	R2	ランク
100	32	10	16	0.001	0.1220	0.7944	4
100	32	10	32	0.001	0.1085	0.8372	3
100	32	10	64	0.001	0.1009	0.8593	1
100	32	10	128	0.001	0.1019	0.8564	2

ミニバッチサイズは、大きすぎても小さすぎても良い結果にならない傾向があるが、本検証でもその傾向があり、最良値はミニバッチ 64 となった。

d) 学習率

検証したハイパーパラメータの数値を以下に示す。

エポック数 = 100
 LSTM ブロック数 = 32
 時系列の長さ = 10
 ミニバッチサイズ = 64
 学習率 = 0.0005、0.001、0.002

検証結果を以下の表 3.17 に示す。

表 3.17 学習率の評価

エポック数	LSTM ブロック数	時系列 の長さ	ミニバッチ サイズ	学習率	RMSE	R2	ランク
100	32	10	64	0.002	0.1184	0.8064	3
100	32	10	64	0.001	0.1009	0.8593	1
100	32	10	64	0.0005	0.1096	0.8340	2

検証した数値の中間値が最良の結果を示しており、0.001 が最良値となった。

(6)最適な組み合わせの確認評価

最適な組み合わせを確認するため、グリッドサーチなどを使用することも可能であるが、パラメータ数が限られているため、ここではハイパーパラメータの特性を考慮しながら組み合わせ検証を実施する手法をとった。

a) 学習率とイテレーション変動の相関性の確認

個別評価において、ミニバッチサイズは 64、学習率は 0.001 が最適という結果となった。つまり、ミニバッチサイズ 64 の条件で、学習率 0.001 が最良という結果であるが、通常は学習率が小さくなった場合、重みの調整幅が小さくなるため学習が進み難くなる傾向がある。このためミニバッチサイズを小さくするとイテレーション数が増えるため、ミニバッチサイズの変動によって結果が変化するかどうかを確認する余地が出てくる。このため、以下の組み合わせを確認した。

エポック数 = 100
 LSTM ブロック数 = 32
 時系列の長さ = 10
 ミニバッチサイズ = 64、32
 学習率 = 0.0005、0.001

検証結果は以下の表 3.18 とおりであった。

表 3.18 学習率とミニバッチサイズの組み合わせ評価

エポック数	LSTM ブロック数	時系列 の長さ	ミニバッチ サイズ	学習率	RMSE	R2	ランク
100	32	10	32	0.0005	0.1062	0.8440	2
100	32	10	32	0.001	0.1085	0.8372	3
100	32	10	64	0.002	0.1184	0.8064	5
100	32	10	64	0.001	0.1009	0.8593	1
100	32	10	64	0.0005	0.1096	0.8340	4

学習率 0.0005 でミニバッチ 32 とし、イテレーション数を増加させると微増ではあるが、精度は向上している。しかし、学習率 0.001、ミニバッチサイズ 64 で一番

精度が良いという結果には変化はなしとなった。

b) 時系列の長さ と LSTM ブロック数の相関を確認

個別の検証では時系列の長さは 10、LSTM ブロック数は 32 がそれぞれ最良の結果となった。しかし、LSTM ブロック数 32 が最良となったケースの時系列の長さは 20 であったが、最終的に時系列の長さは 10 が最適な結果へ変化している。時系列の長さの条件が変化した場合、解析するデータ量が少なくなるため、計算量に大きく影響する LSTM ブロック数の最適な数値が変化していないか確認の余地がある。

この観点での評価パラメータと結果を以下に示す。

エポック数 = 100
LSTM ブロック数 = 16、32、64
時系列の長さ = 10
ミニバッチサイズ = 64
学習率 = 0.001

検証結果は以下の表 3.19 の通りである。

表 3.19 時系列の長さ と LSTM ブロック数との組み合わせ評

エポック数	LSTM ブロック数	時系列 の長さ	ミニバッチ サイズ	学習率	RMSE	R2	ランク
100	16	10	64	0.001	0.1050	0.8478	2
100	32	10	64	0.001	0.1009	0.8593	1
100	64	10	64	0.001	0.1093	0.8348	3

検証結果としては、評価数値に大きな差はなく、時系列の長さ 10、LSTM ブロック数 32 が最良であるという結果に変化はなしとなった。

(7)まとめ

ハイパーパラメータの調整結果は以下のとおりである。

エポック数 = 100
LSTM ブロック数 = 32
時系列の長さ = 10
ミニバッチサイズ = 64
学習率 = 0.001

この場合の正解値と推論結果との数値比較を図 3.22 に示す。また、本評価から考察できる LSTM 固有のハイパーパラメータの特性は以下のとおりとなる。

LSTM ブロックの数は多い方が、精度が上がる傾向があるが、ある時点で精度の向上が止まる傾向にあるので、必要最小限の数字を探す必要がある。時系列の長さは、解析するデータに依存する傾向があるので、データの特徴を踏まえて、適切な数値を探す必要がある。

以上の通り 3.2 節の提案内容に従い検証を行い、LSTM の初期値の設定、調整が必要なパラメータの特定、これらのパラメータの特性の確認、その内容に基づいて、最適なパラメータの組み合わせの確認を実践した。これによって最適な組み合わせを確認する手法として、提案手法が妥当であることを確認した。




図 3.22 LSTM モデルの推論と正解値の比較

3.3.4. 技術者育成提案に関する講座での実践と評価

(1)受講対象者

受講生は中小企業 8 社から 20 名が参加した。事業推進部門の受講生も 2 名程度いるが、基本的に製品、システムの開発部門、或いは保守部門などの技術者となっている。会社の業種は製造業やソフトウェアの開発会社が多いが、受講生には IT 技術者ではない方も含まれる。DL については、以前に勉強した受講生が 2 名いるが、業務で DL システムの構築経験がある受講生はおらず、DL の経験豊富な技術者はいない。

(2)基礎講座の実施内容

基礎講座をオンラインライブで 2 回、計 4 時間実施し、基礎実習の宿題はオンラインリモートで実施した。

表 3.20 に基礎講座の概要を示す。特に基礎の実習としては、CNN のアルゴリズムを活用した数字の手書き文字認識を題材とし、文字認識の実行、パラメータの変更による文字の認識精度の変化を確認した。この講座によって応用講座の宿題実施に必要な基礎知識の習得を図った。

表 3.20 基礎講座の概要

No	項目	主な内容
1	ディープラーニングの基礎	ディープラーニングの定義
		ニューラルネットワークの構造
		ニューラルネットワークの学習の仕組み
2	ディープラーニングの流れ	データの前処理
		ニューラルネットワークのモデル構成
		機械学習・検証・推論処理概要
3	代表的なディープラーニングアルゴリズムの概要	畳み込み型ニューラルネットワーク (CNN) の解説
4	CNNを活用した基礎実習	CNNを活用した手書き文字認識

(3) プロトタイプの応用例

プロトタイプで採用する応用事例は DL の代表的なアルゴリズムである CNN の画像解析を活用した異常検出とした。なお、異常検出の応用講座に先立ち、基礎講座において異常検出には正常データ、異常データがある場合の異常検出手法、異常データがない、或いは少ない場合の異常データを必要としない異常検出手法（例えば、オートエンコーダによる手法）があることを示し、適材適所で異常検出のアルゴリズムを選択すべきであることを講義した。その上で、応用課題としては、CNN によって、より正確な画像解析を行う異常検出の応用例とした。

受講生が動画から準備する宿題においては、日常で取得可能な動画を前提とし、異常検出の仕様は受講生が自由に設定することとした。その結果、データが少ない場合にはデータ拡張を行ってデータ数を増加させる宿題設定とした。また、受講生に対する課題の難易度が段階的に向上していくように、基礎講座において、CNN による手書き文字認識の実習を行った上で、応用講座の宿題を実施した。さらに応用講座の宿題においては、プロトタイプのデータとモデルでの異常検出、次に受講生の自由な発想でのデータ準備による異常検出という段階を踏んで、問題設定の難易度が段階的に上がっていくように工夫を行った。

図 3.23 にプロトタイプの応用例である工場ライン稼働監視の概念図を示す。具体的な応用例としては、工場ラインの模擬アニメーションを準備し、その動画を活用して CNN モデルによる工場ラインの異常検出を取り上げた。異常の定義はライン上の物体間の距離とし、その間隔が接近、又は離れすぎの場合を異常とした。

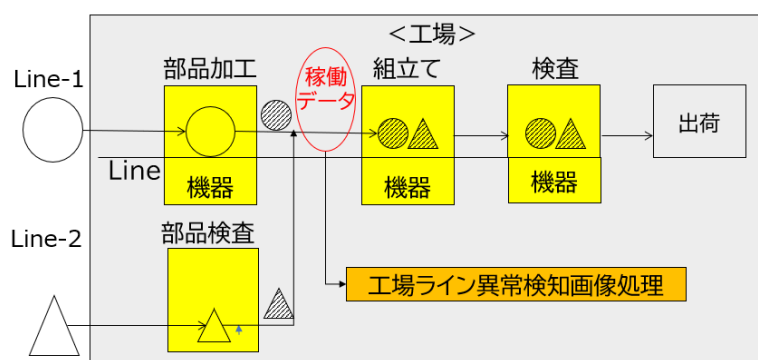


図 3.23 プロトタイプの応用例

(4) DL 応用講座の実行形態

図 3.24 に DL 応用講座の実行環境を示す。講義は、オンライン講義とし、オンライン会議システム ZOOM を活用し、講師、受講生間の連絡事項伝達、宿題提出、質問受付などはチャットツール Discord を活用した。また、プロトタイプの実行環境は Google Colaboratory、ストレージは Google Drive の各クラウドサービスを活用し、受講生の

PC 環境に依存しない IT リソースの環境を確保した。

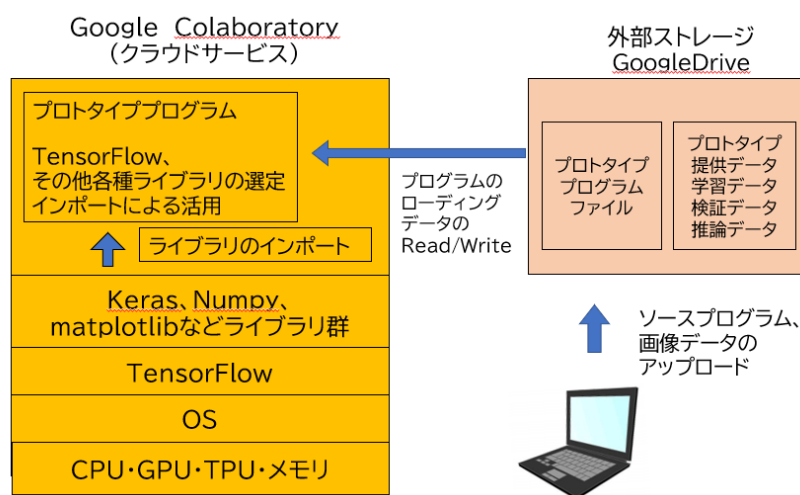


図 3.24 プロトタイプの実行環境

(5)DL 応用講座の実施内容

DL 応用教育の実施例を図 3.25 に示す。DL 応用講座は 3 回の講座で実施し、3 回の講義時間合計は 14 時間としている。

(a)応用講座での提供物

プロトタイプ解説書に加え、3.2 節で示した以下のツールを提供した。

① 静止画分割プログラム、データ拡張プログラム

受講生が自ら動画を取り学習用、推論用のデータを準備できるように、動画の静止画分割、さらに静止画のデータ拡張によってデータ数を増やすプログラム。

② パラメータサーチプログラム

ミニバッチサイズ、学習率、フィルタ数、全結合層のノード数などのグリッドサーチ、ランダムサーチをサポートしたプログラム。

③ 学習・検証プログラム

画像を CNN モデルに入力し、学習、検証、正解率、誤差のグラフ表示、学習済みモデルの保存などを実行するプログラム。

④ GradCam プログラム

CNN モデルが画像のどの部分に注目しているかを可視化する GradCam 機能を実装したプログラムを提供した。これによって、チューニング済みのモデルが意図どおりの動作をしているかどうかをより確実に確認する手段を提供した。

⑤ 推論処理ツール

推論処理によって学習済みモデルの応用方法を体験するため、学習済みモデルを復元し、推論結果の出力 (CNN の出力情報のグラフ表示用データの出力)、画像単位の異常、正常の判断結果のログ出力、閾値にしたがった異常検知の表示などを行うプロ

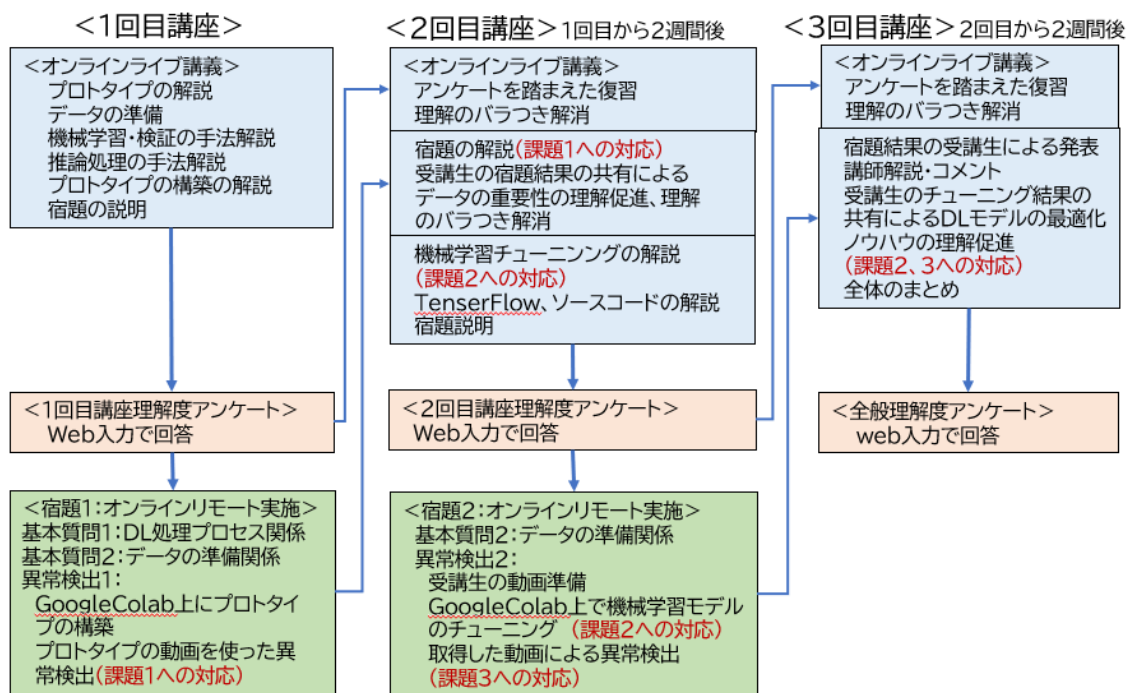


図 3.25 DL 応用教育の実施例

グラムを提供した。

さらに工場ラインを模したアニメーションにより、正常動画、異常動画（正常状態の画像も含まれる）、推論処理用の動画を提供した。

(b)第 1 回目の講座内容

基礎教育の実施を受けて、プロトタイプにおける動画の内容、データの準備、機械学習、検証、推論の実施方法、プロトタイプの構築方法などを講義する。

(c)第 2 回講座までの宿題

次回までの宿題は、大きく 3 つの構成とした。宿題 1-1（基本質問 1）は機械学習、検証、推論の役割と機能は何かという質問、宿題 1-2（基本質問 2）は推論時のデータの内、学習時に存在しないデータはどの部分かという質問、宿題 1-3（異常検出 1）は図 3.24 に示したプロトタイプの実行環境の構築、及びプロトタイプのツールとデータで異常検出を行い、結果報告を行うこととした。

(d)第 2 回目講座（1 回目講座の 2 週間後に実施）

1 回目講座の復習、宿題解説、機械学習時のチューニング手法、ツールのプログラムソースコードの解説を行う。

(e)第 3 回目講座に向けた宿題

次回までの宿題は宿題 1-2 同様に、宿題 2-1（基本質問 2）は推論時のデータの内、学習時に存在しないデータはどの部分かという質問、宿題 2-2（異常検出 2）は受講生が異常検出の仕様を立案し、その異常検出を実現する動画を準備してデータの仕分けを行い、異常検出を実現するものとした。

(f)第3回目講座（2回目講座の2週間後に実施）

受講生による宿題 2-2 の成果発表と全体の纏めを実施した。

(6)DL 応用の技術的課題の理解促進

上記の講座の流れにおいて、以下の工夫を行うことで DL 応用の技術的課題の理解促進を図った。

(a)データの重要性の理解促進

プロトタイププログラム（DL モデル）と動画による異常検出の宿題について、その結果を第2回講座内で共有することで、同じ動画で同じモデルの条件でも受講生の学習用の異常、正常データの準備方法、推論時のデータの準備方法によって結果が変わることを示し、学習データ準備の重要性に関する教育効果の向上を図った。

(b)機械学習モデルのチューニングノウハウ向上

第2回講座では、プロトタイプの動画による異常検出のチューニングについて、その適切な実施手順と結果を準備して、その実施結果を説明した。これにより理解の促進を図った。具体的な内容は、まずチューニングにおいて重要なハイパーパラメータを選定し、その内の一つのパラメータの値を変更してその結果を示し、それを繰り返して各ハイパーパラメータの特性と検証すべき数値の範囲を示した。

次にグリッドサーチとランダムサーチの概要を示した。グリッドサーチはチューニング対象のハイパーパラメータについて適切な検証範囲を設定し、その全ての組合せを検証する手法で、最適な組合せを確実に発見できるが、結果を得るのに時間が掛かることを解説した。

ランダムサーチはパラメータ数値の検証組合せ数を技術者が指定するため、その成否が技術者のノウハウに依存するが、より短時間で実施できる特徴があることを解説した。一方、今回のプロトタイプの DL モデルとデータにおいては、ハイパーパラメータの特性を正しく評価していけば、チューニングに重要なハイパーパラメータで設定数値が想定し難いパラメータが、ミニバッチサイズ、学習率、全結合層のノード数に集約されていくことを解説した。このことからパラメータの特性を確認することで、これをノウハウとして習得し、併せて多くのパターンを検証する必要がなくなっていくことも解かるため、宿題での対応は本手順に従ったグリッドサーチの手法を推奨した。

また、推論におけるパラメータ改良が必要な場合には、一般論としては、各ハイパーパラメータの範囲を広げて、ベイズ最適化の手法を採用することが有効であることを示した。ベイズ最適化は一定のパラメータの範囲内において、次のパラメータ変更の候補をアルゴリズムで決定していくもので、何回パラメータ変更による検証を行うかのノウハウは必要になるが、どのようにパラメータの変更をすべきかの知見に乏しい場合に、より効果的な手法となることを解説した。

一方、本プロトタイプにおいては、前記の通り学習で得られたハイパーパラメータの

特性に基づき、少数のパラメータの小規模な組み合わせでチューニングすることが可能であり、推論時の改良においてもグリッドサーチの方法を推奨した。

次に第3回講座では、受講生が自分で定義した異常検出の仕様と各自準備した動画によるチューニング作業、異常検出結果の発表会を実施した。これにより多様な画像でのチューニング結果を受講生間で共有し、ハイパーパラメータの特性をより明確化し、DLモデルのチューニング方法の理解向上を図った。

(c) 応用システムの要件を踏まえたモデル評価

プロトタイプで、推論処理プログラムを提供し、そのプログラム内で異常検出の閾値を設定することで、DLモデルの上位利用者の要件に沿ったモデル評価の重要性について理解の促進を図った。具体的には、異常検出するフレームの幅（例 30 フレーム）において、何フレームの異常検知で異常と判断するかを設定できるソースコードを提供し、特に2回目の宿題実施時に活用し、要件を踏まえた評価の重要性について理解を促進した。

(7) 講座実施手順の工夫

(a) 講座毎の実施サイクル

各講座における進行は、「前回の復習」→「宿題の解説」→「当該講座の講義・実習」→「次回講座までの宿題説明」→「アンケート回答」→「受講生による宿題実施」というサイクルを回し、より理解しやすい講座の進行とした。

(b) 講座進行の工夫点

復習はアンケートで解らなかつたと回答された内容について補足を実施した。宿題の解説は宿題結果で成果が出ていない受講生の内容について、課題や問題点を解説した。宿題1では期待通りの結果が出ている4件を選択し、その内容を受講生間で共有し、宿題2については、第3回目の講座で受講生による成果発表を行い、個々の受講生の成果を受講生全体で共有した。

実習、自習の内容については、プロトタイプのシステム構築と応用例の実行につき、その全体の流れを切れ目なく実施するように設定した。

(8) 受講生の評価方法と達成目標

理解度の把握は宿題結果の評価で実施した。

(a) 基本事項の質問

基本事項について、3.3.4(5)に示した通り、宿題1-1（機械学習、検証、推論への質問）、宿題1-2、2-1（データに関する質問事項）の質問を実施し、この解答内容から理解度把握の向上を図った。

(b) 宿題結果の評価

宿題の評価については、5段階のレベルを設定し、受講生の理解度把握の指標とした。

レベルの内容を以下に示す。

S：期待を超えるレベル

(宿題で課していないことまで自ら調査し解答等)

A：内容を期待通りに理解し解答できているレベル

B：十分とは言えないが理解できているレベル

C：提出していれば可というレベル

(一部の問題の不解答や明らかに間違った理解を含む)

D：未提出

(c) 宿題結果の評価に関する講座での達成目標

受講生は DL システム構築経験がない受講生であり、課題提出内容の誤りや過不足がないことが条件となる評価 A を平均的な達成目標とするのは難しいと判断している。このため、受講生評価の平均値が、宿題結果に一部不適切な内容が見られても全般的に理解ができている場合の評価である B 以上となることを講座の成果達成目標とする。

尚、評価時は評価 S:5 点、評価 A:4 点、評価 B:3 点、評価 C:2 点、評価 D:1 点と換算し、平均 3 以上を達成目標とする。

3.4. 宿題実習結果の評価

3.4.1. DL システム構築の課題解決の提案に関する評価

DL システム構築の課題であるモデルのチューニング、データ準備、モデル評価について、システム構築を簡易化する目的で課題解消手法を提案し、その検証を実施した。チューニングについては、CNN、LSTM について、そのハイパーパラメータを示し、その初期設定の考え方、チューニングすべきハイパーパラメータの特定、その個別評価手法とハイパーパラメータの最適な組み合わせの特定手法について、提案と評価を行い、提案内容の有効性を確認した。

データの準備については、クラス分類において、クラス遷移や状態変化を捉えたデータの準備や汎化性能を考慮した効率的なデータ準備の考え方を提案し、CNN の画像認識で CNN の評価を行い、クラス遷移のデータ準備が重要であること、画像の特徴における物体間距離や形状の認識性能では移動同一性が有効であることの確認、形状の変換は他に有力な特徴があれば、変化の全データを網羅する必要はないことなどを確認でき、提案が有効であることを評価できた。

モデルの評価においては、閾値の設定でモデルの誤検知によりシステムとしての最終的な誤検知を防止すること、また、状態遷移などの判断が難しい箇所においても、システムの要件と閾値によって、過度な性能の追求を回避できることを提案した。本件については、社会人技術者の教育講座の中でその検証を行っている。その評価は次節以降で論じる。

3.4.2. 技術者育成に関するカリキュラム内容の評価

本教育手法の主な特徴は、システム構築の課題を踏まえて、その課題解決に向けた仕組みをプロトタイプに織り込むこと、および受講生自らのデータ準備や宿題結果の全受講生での共有による教育効果の向上、さらにオンラインライブ、オンラインオンデマンドの併用による理解促進、①前回講義の復習と前回宿題の解説、②講義の実施、③次回宿題の設定というサイクルでの教育手順などによる DL 応用の理解促進となる。一方、JDLA の E 資格認定プログラムとの比較においては、上記特徴を生かしながら NN、DL の基礎、その基礎的応用事例の学習、CNN の仕組み、その活用における技術的課題、応用事例の実習課題などの DL に関するカリキュラムを踏襲している。

3.4.3. 実践講座の宿題結果から見た受講生の理解度評価

表 3.21 に宿題の内容から見た理解度評価を示す。

(1) 基本質問の解答から見た達成度

基本質問の解答実績は以下の通りとなった。

表 3.21 宿題内容から見た受講生の理解度評価

受講生	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	合計
宿題1 総合評価	C	C	B	B	C	B	A	B	C	A	A	未	S	C	S	A	C	C	S	B	
宿題1-1 基本質問1																					0
宿題1-2 基本質問2	✓	✓			✓									✓				✓		✓	6
宿題1-3 異常検出1	データ仕分けに課題	✓	✓		✓	✓		✓	✓					✓				✓	✓		9
	操作ミス			✓					✓										✓		3
	全般に理解不足				✓									✓				✓			3
宿題2 総合評価	B	B	B	B	C	A	B	A	A	A	S	C	S	C	S	B	B	A	S	B	合計
宿題2-1 基本質問2																					0
宿題2-2 異常検出2	応用の定義に課題あり或いは難易度が高い	✓	✓		✓																3
	データ仕分けに課題あり				✓									✓		✓	✓			✓	5
	チューニング不足、不適切等課題あり	✓			✓		✓						✓	✓						✓	6
	全般に理解不足				✓								✓	✓							3

宿題 1-1 の基本質問 1 は解答者 19 名が大きな間違いや誤解はなく解答しており、DL 応用のプロセスの基本は理解ができている。宿題 1-2 の質問事項 2 はデータの準備に関するものであるが、6 名に誤解答があった。一方、宿題の解説や宿題 2 の説明で再度質問主旨を説明することで、宿題 2-1 での同様の基本質問 2 には全員が質問主旨を正しく理解して解答できている。

(2)宿題 1-3 の異常検出 1 から見た達成度評価

報告者 19 名全員が 2 回目講座の実習、その後の宿題実施の基礎となる課題（画像データ分割、仕分け、学習・検証プログラム、推論プログラムを実行）を完了している。なお、1 名が未提出であった。

宿題の評価は 3.4.4 節(8)に示した 5 段階の評価指標で実施し、その評価結果は以下の通りとなった。

S:3 名、A:4 名、B:5 名、C:7 名、D:1 名 計 20 名。

平均評価点は 3.05 となる。1 回目であり 2 回目の宿題の最終評価ではないが、成果目標は 1 回目単独で達成している。

上記 19 名の補足事項は以下の通りである。

- ① 結果に対する考察など期待以上の成果：3 名
- ② データの仕分けに課題あり：9 名（④の 3 名含む）
- ③ 操作ミス：3 名（④の 1 名含む）
- ④ 全般的な理解不足：3 名

以上、宿題の提出者については、講座を継続するのに支障を来すレベルではないが、スキル、理解度には相当なばらつきがある。

(3)宿題 2-2 の異常検出 2 から見た達成度、理解度

報告者全員 20 名が自分で動画を準備し、異常検出の結果を報告できている。宿題の 5 段階評価は以下の通りである。

S:4 名、A:5 名、B:8 名、C:3 名、D:0 名 計 20 名。

平均評価点は3.5であり、1回目よりも高評価であり講座の成果目標を達成している。上記の補足事項は以下の通りである。

- ① チューニングその他期待以上成果あり：4名
- ② 特に問題なく成果が出ている：5名
- ③ 応用の定義に課題あり又は難易度が高すぎる：3名
- ④ データの仕分けに課題あり：5名
- ⑤ チューニングに課題あり：6名
- ⑥ 全般的に理解不足：3名

上記③から⑥は同一受講生の重複がある。その詳細を表2に示す。一方、宿題1との総合評価の比較は以下の通りとなる。

(対象19名、宿題1の未提出者は比較の対象外とした。)

宿題1から評価が向上(総合評価欄 青塗り潰し)：8名

宿題2では評価が低下(総合評価欄 橙塗り潰し)：2名

変化なし：9名

(4) 受講生による自己理解度評価

表3.22に受講生の自己理解度評価を示す。評価5「理解できた」、評価4「ほぼ理解できた」の比率が約85%となっており、受講生の理解度の満足度が高いことが解る。

表 3.22 受講生による理解度自己評価結果

アンケート項目(受講生自己評価)	評価2	評価3	評価4	評価5	平均
異常検出の流れ、実現方法	0	1	7	7	4.40
学習データの準備(データの仕分け方法、データ拡張の必要性)	0	2	5	8	4.40
CNNモデルの学習・チューニング	0	1	7	7	4.40
学習済みモデルの評価方法	0	4	7	4	4.00
異常検出の閾値設定の考え方	2	1	9	3	3.87

(5) 受講生の理解度に関するアンケート回答

受講生には、5段階の自己理解度評価に加え、具体的に理解できたこと、難しかったことを確認している。その回答結果を表3.23に示す。データ準備手法、チューニング手順、評価方法について、理解が進んでいることが解る。一方、主な難しかった点はデータ拡張の手法、チューニングにおける層数の考え方、閾値の考え方となる。これらの説明について、ドキュメントや説明方法の改善を図っていく。

表 3.23 受講生の理解度に関するアンケート回答

アンケート項目		番号	回答内容
学習データの準備作業の理解度について	理解できたこと	①	異常データと正常データを正確に分ける必要性、重要性を理解できた。
		②	正常と異常のデータは同数程度必要というきことを理解できた。
		③	未知のデータを検出するための仕分けの工夫が必要なことを理解した。
		④	仕分けの基準がかなり結果に影響するため、よく考えて実施する必要があるなと感じた。
	難しかったこと	⑤	仕分けはあらかじめ要件を明確に規定する必要があり、想像より難しかった。
		⑥	データ拡張で何を変更するか、判断するのが難しい。
CNNモデルのチューニングの理解度について	理解できたこと	①	各ハイパーパラメータの種類、特徴、効果が理解できました。
		②	典型的な設定の例について理解できた
		③	チューニングのパラメータの変化と実施結果（誤判定の変化の仕方）が複数紹介され、具体的なチューニングの進めかたがイメージできました。画像サイズを選択によって精度がかなり大きく変わることが理解できました。
	難しかったこと	④	特に層数、骨組みの決定について、経験や知識が必要と思ひ難しいと感じました。
		⑤	時間が足りなかったというもありますが、性能向上のための試行や深い考察を行うまでには至らず、これらは今後も様々に試行を繰り返して理解していくものかと感じました。
CNNモデルの検証、評価の理解度について	理解できたこと	①	実際のシステムの要件や特性に合わせて、異常判定の方式を変えたり、評価の仕方も変わったりというところが、実際に適用するうえで重要になりそうで、この内容が役立ちそうだと感じました。
		②	要件に応じて異常とする閾値を決定する必要があることを理解しました。
		③	異常 = 即エラーではなく、システムにあった設定が必要ということ
	難しかったこと	④	色々な検証方法をどのように決めていくか難しかった
		⑤	閾値について、考えかたを理解するのが難しかった
		⑥	要件に応じた閾値をどのように設定していくかが難しいと感じました。実際のクライアントとの相談のような気はしていますが…。

3.5. 宿題実習結果の考察

(1)データの重要性に関する成果

宿題1ではデータの準備、仕分け作業に課題があった受講生が9名いるが、宿題2では6名に減少している。宿題1ではデータはプロトタイプで準備し、仕分けの例も講義で示している。一方、宿題2では受講生が応用例を決定し、データを準備することから手本はなく難易度が上がる。その上でデータの仕分けに課題がある受講生が3名減少したことは教育手法の成果と考える。

(2)チューニングノウハウに関する成果

宿題1ではチューニングを必須課題としていないので、宿題2との比較はできないが、宿題2において、チューニングにおいても十分な成果を出した受講生が9名おり、AI経験が豊富ではない受講生が対象であることを考えれば十分な成果があったと考える。

(3)システム要件に即したDLモデル性能の評価

講義ではシステム要件に即したDLモデル性能の評価の考え方を説明しているが、異常、正常の定義に加えて、その異常検出性能のシステム要件を厳密に定義する作業が不足しており、閾値の設定による誤検知回避などの有効性の検証、考察するまでには至らなかった。この観点での宿題2のより明確な設定方法について、改善の余地があると考えている。

(4)初学者を想定した講座実施方法の効果

今回の受講生の宿題1をみると、積極的にチューニングまで先行して実施できる受講生から宿題の報告主旨を十分に理解できない受講生や操作ミスをする受講生もおり、技術の理解力にはばらつきがあると判断できる。これに対し、宿題2では宿題の報告主旨の理解不足や操作ミスがなくなり、宿題の難易度が上がっている状況でも8名が宿題の評価を上げている。

また、全体の評価の分布も宿題2では、宿題1の総合評価に対して、S、Aが2名増加、B評価が3名増、さらにC評価は4名減少し、D評価は1から0に減少している。これらの結果から講座の進行により経験の少ない受講生のスキルアップに効果があったものと考ええる。

(5)宿題評価における課題と対策

最終的に基本事項の理解不足3名、データ仕分けなどに課題がある受講生5名、チューニングに課題がある受講生6名、上記に重複があるため計8名に課題が残る。また、システム要件に即した評価については、まだ目標設定の徹底が不十分になっている。

データ仕分けについては、プロトタイプで準備した画像に対し、解説書によって異常、正常の仕分けの考え方を説明しているが、具体的な手法は目視による判断になっており、受講生の根気などの要因で正確性が確保できなかった受講生が出てしまったと考えて

いる。この観点で作業の正確性、効率性をどう確保するが今後の課題と考えている。

チューニングが正確にできなかった要因は、講師の実施結果を EXCEL で解説しているが、チューニングの実施手順を完全な手順書とはしておらず、講義内容、解説書、プログラムを参照しながら実施する形態としていた。このためハイパーパラメータの数値の特定、チューニングすべき数値範囲の特定において、正確性を欠いた受講生が出てしまったと考えている。操作は基本的に手順化すべきであったと考えている。

次に基本事項の理解不足と評価できる受講生が 3 名おり、その中の 2 名は宿題 1、宿題 2 共に最低ランクの評価で、他の 1 名は宿題 1 が未提出となっている。これらについては、1 回目の宿題で C、D ランクとなった段階で、その要因について受講生と対話を行い、その要因把握と対策が必要であったものと考えている。また、受講におけるスキル条件、受講後の達成レベルの周知徹底を図ることも重要と考えている。

システム要件に即した DL モデルの評価については、講義での解説に加えて、宿題説明時に応用例におけるシステム要件の明確化、それを踏まえた閾値のサンプルソースコードへの反映、これをベースとしたモデルチューニングへの影響と考察の実施を徹底するように改善を図りたい。

3.6. まとめ

本研究では、DL システム構築における課題であるデータ準備、DL モデルチューニング手法、要件に沿ったモデル評価について、その課題対策を研究し、その成果をプロトタイプ開発に反映し、システム構築を容易とする手法を提案した。また、その成果の技術者育成への展開手法も提案した。これらの提案内容の有効性検証を実施すると共に、プロトタイプを活用した技術者育成の講座を実践し、提案内容の評価について論じてきた。

システム構築の課題対策として、データ準備の考え方の整理、チューニングの実施手順の定型化を提案し、その実験評価を行って、データ準備の効率化、チューニング効率化に関する有効性を確認した。また、システム要件に沿ったモデル評価の提案については、技術者育成の実践の中で評価を行った。受講生の宿題評価では閾値とチューニングへの効果に関する実習には課題があるが、その考え方と効果について、受講生への周知を図った。

技術者育成手法の提案については、プロトタイプを基盤とした教育で宿題の出し方や講座の実施サイクル進行の工夫などで DL システム構築の理解度向上を図るものであり、講座開催の実践によって手法の評価を実施した。講座における宿題結果の評価が 5 段階評価で平均 3 以上を成果達成目標としたが、難易度の高い 2 回目宿題において、平均評価が 3.5 であり、講座の成果目標を達成できている。また宿題 2 の S、A 評価の 9 名の受講生について、本講座の経験をベースにさらに推論時のデータの入力処理、推論処理の結果とこれを活用する上位システムとの連携処理などを設計、開発する経験を積むことで CNN を活用できる技術者に育成できると評価している。

B 評価の受講生については、より丁寧な実習の実施、モデルチューニングの解説の工夫などを要すると考えており、さらに C 評価の 3 名については、早期の状況把握とその対策実施や受講前のスキル条件の周知徹底が重要と考えている。

以上の通り提案手法の実践により、DL システム構築における課題対策によるシステム構築の難易度の軽減、その成果を活用した講座実践による DL システム構築の基礎技術の向上、データ準備、チューニング手法の育成、受講生全体の理解度の底上げに成果があったものとする。

一方で教育成果には課題も残っており、これらの対策によって教育手法の改善を図ると共に、さらに教育の有効性を向上するため DL 推論処理の応用例の拡大を図り、DL 応用の技術者育成と DL 応用の普及に寄与できるよう努力していく。

4. DX 推進プロトタイプ開発と技術者育成手法の研究

本研究では、2.2 節で述べた DX 推進の課題を踏まえて、DL 応用プロトタイプの研究成果も活用し、AI、IoT、クラウド、ビッグデータを活用した DX 推進のためのソリューションを強化したプロトタイプを開発する。また、その成果を活用した技術者育成手法を提案する。提案内容は講座の実施によって評価し、提案内容の効果を確認する。

4.1. DX 推進技術者育成手法の提案

図 4.1 に DX 推進の技術基盤である AI、IoT、ビッグデータ、クラウドの 4 技術の関係図を示す。IoT やビッグデータによって大量の分析データ生成の基盤が整備され、AI

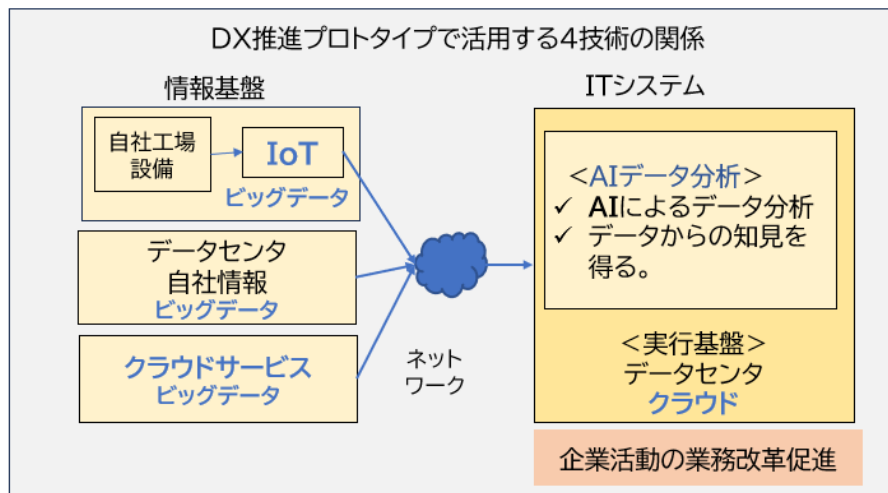


図 4.1 4 技術基盤の関連図

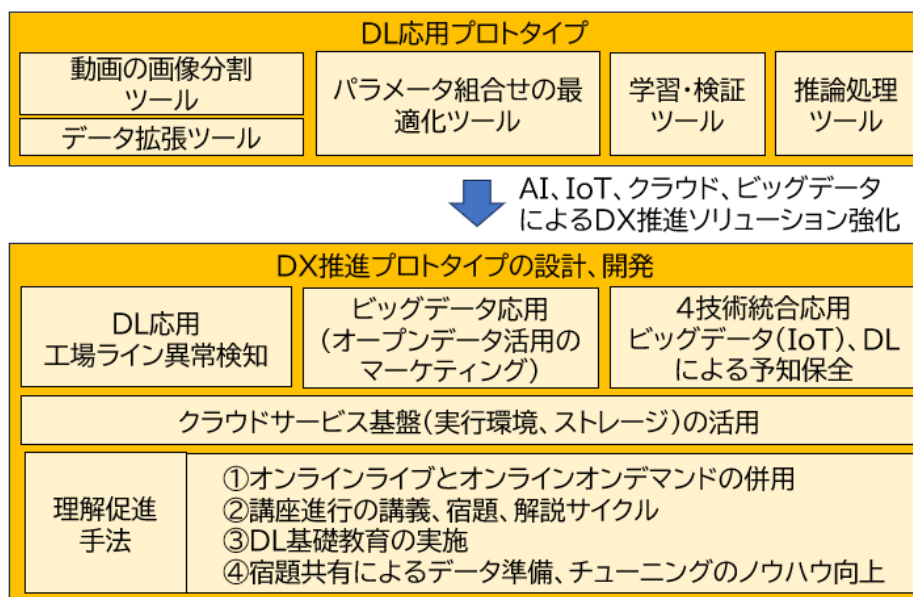


図 4.2 本提案の概要

によりその効果的な分析技術が発展し、クラウドによってこれらの IT 処理システムを容易に構築できる基盤が揃ったことで、DX 推進が加速されている。一方、2.2 節で述べた DX 推進の課題はこれら 4 技術を活用した DX 推進に則した実践的な技術者育成を推進することであった。本課題を踏まえた本節の提案内容の概要を図 4.2 に示す。3 章に述べた DL 応用プロトタイプの結果も活用し、これに IoT 活用、ビッグデータ活用、これらに AI とクラウド基盤の活用を加えた 4 技術統合のプロトタイプを開発する。その成果を活用した技術者育成手法として、これらの 4 技術の実践経験が少ない技術者であっても、効果的な理解促進に繋がる教育手法を提案する。

4.1.1 DX 教育の体系

IoT、AI、ビッグデータ、クラウドの技術基盤に対応した DX 教育内容の体系を図 4.3 に示す。その体系は AI、IoT、ビッグデータ、クラウドの 4 技術を活用して業務改革を行うプロトタイプ構築実習とこれらの 4 技術を総合的に活用したプロトタイプの構築実習で構成する。これらの実習によって、DX 推進の実践力を育成する。

これら 4 技術基盤の関連は図 4.1 に示した通りである。DX 推進はデータを発生させる仕組みとその分析、実行、管理に関わる技術革新があったことで推進が加速したと考えられる。データ発生技術の技術進歩としては、IoT によってあらゆる機器の情報収集が可能になったこと、インターネットの進展による大量のアクセスログやオープンデータなどのビッグデータの出現が挙げられる。また、これらのビッグデータや社内の膨大な文書情報を保管するデータセンタやクラウドサービスの充実、大規模で変動も大きいビッグデータを柔軟に処理できるクラウドサービスの出現も DX を推進する上での重要な技術進展となる。さらに AI 技術とコンピュータ処理能力の進展によって大量のデータを効率的に分析することが可能となってきた。

DX の推進はこのような技術革新によって可能になってきており、IoT、AI、クラウ

プロトタイプ	DX推進応用例
AI プロトタイプ構築での実践教育 (AI基礎教育を含む)	企業活動で発生するデータ全般を活用した業務改革に寄与するAIを活用したプロトタイプ
IoT プロトタイプ構築での実践教育	IoTデータを活用した製造業などにおける生産活動改善プロトタイプ
ビッグデータ プロトタイプでのビッグデータ活用の実践教育	ビッグデータを活用してデータからの知見を得て、マーケティングに活用するプロトタイプ
クラウド プロトタイプでのクラウドサービス活用の実践教育	クラウドサービスを活用したプロトタイプのシステム構築
4技術要素の統合システム AI, IoT, ビッグデータ, クラウド活用の4技術基盤を活用した応用プロトタイプ	4技術を複合的に活用し生産活動やマーケティングの改革を推進するプロトタイプ

図 4.3 DX 推進教育体系

ド、ビッグデータはDX推進の教育における重要な教育対象となる。DX推進の実践的な教育では、これらの技術を活用したデータ分析から新たな知見を発見し、マーケティング、研究開発、資材調達、製造、品質管理、出荷、保守に渡る業務改革のアイデア創出とシステム化を図る技術の育成が重要となる。

4.1.2. 教育内容

4 技術基盤に対する本教育法の提案内容について、以下に述べる。

(1)AIの基礎教育

本基礎教育を実施することで2.2.3(2)の課題解決を図る。教育内容としてはAIの機能である分類、回帰、クラスタリングやこれを実現するサポートベクタマシン（以下、SVM）、ディープラーニング（以下DL）のConvolutional Neural Network（以下CNN）など代表的なアルゴリズムの基礎実習とする。データの準備、加工、学習、検証、推論の処理段階の解説、特に学習時におけるハイパーパラメータと呼ばれるAIモデルの性能向上策などの基本を学ぶ。

(2)プロトタイプ構築による実習教育

本実習によって2.2.3(1)で示したプロトタイプ構築による実践教育の促進に関する課題解決を図る。

(a)AI活用の実習教育

プロトタイプによる実践的な教育を行う。プロトタイプにおいては何らかの業種を特定して、マーケティングから製造、品質管理、出荷など、これらの業務に対応した応用例を実現するプロトタイプシステムを開発、或いはオープンソースを活用して実現する。受講生にこれらのシステム構築、データの準備、システム実行を実践させることで教育効果の向上を図る。

(b)IoT活用の実習教育

データ収集方法として工場ラインのセンサーなどのIoTを活用したプロトタイプを開発し、収集したデータをAIで分析し、これを業務改革に繋げるシステムを実現する。受講生には自らデータを準備しプロトタイプを構築、実行することでIoT活用の教育を行う。

(c)ビッグデータ活用の実習教育

大量のデータ分析を行い、そのデータからある知見を得るためのプロトタイプを開発する。企業においてビッグデータに相当するようなデータを保持していて教育に活用可能であれば、当該データを活用したプロトタイプを準備して教育を行う。その準備が難しい場合は、インターネット上の公的なオープンデータなどを活用する。本プロトタイプを受講生によってシステム構築し、データから知見を得ることで、ビッグデータ或いは社外のデータ活用の技術を習得する。

(d)クラウド活用の実習教育

クラウドの活用についてはクラウドの利用法を解説の上、プロトタイプの実行においてプログラムの実行環境、データの格納環境としてクラウドサービスを活用する。各プロトタイプの実行においては、受講生がクラウドサービスを活用してシステム構築を行うことでクラウド活用の技術習得を図る。

(e) 4 技術を活用した実習教育

IoT、AI、ビッグデータ、クラウドの各技術要素を組み合わせたプロトタイプシステムを開発し、これを教材とする。プロトタイプでは、IoT から収集するデータ（疑似的な生成データを含む）を活用するものとする。IoT からのデータをビッグデータと捉えるか、またはクラウド上のオープンデータなどをビッグデータと位置付けて活用する。これらのデータ分析技術に AI を活用してデータから何らかの知見を検出し、業務改革に寄与できるソリューションとする。さらに実行環境やデータ管理をクラウドで実行するプロトタイプとする。このプロトタイプシステムによって 4 技術を総合的に活用した DX 推進の技術を学ぶ。受講生はプロトタイプのためのデータを準備し、システムの構築と実行によって DX 技術の理解を促進する。

4.1.3. 理解促進のための実習推進上の工夫点

実習推進上の工夫点を以下に示す。これらの工夫によって 2.2.3(3)の課題解決を図る。

(1)実習の実施サイクル

図 4.4 に本実習の実施サイクルを示す。本実習の実施に当たっては IT 系技術者だけが対象ではないことに留意し、理解し易い実習の進行を心がける必要がある。具体的には図 4.4 に示した通り、講義による解説の実施、宿題の設定、次回講義までの受講生による宿題の実施、次回講義における受講生の宿題結果の共有、講師による宿題の解説によって理解の促進を図る。

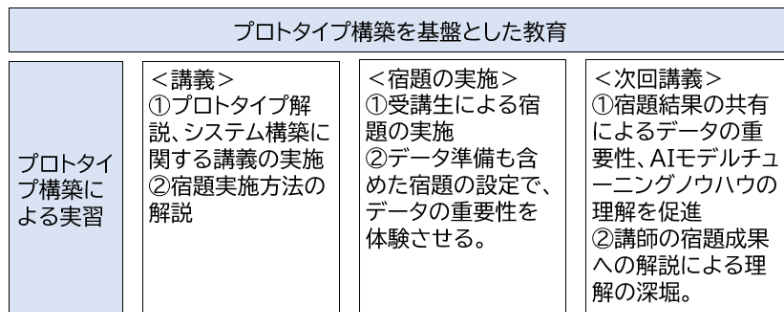


図 4.4 講座の実行サイクル

(2)データ準備ノウハウの育成

DX のシステムにおけるデータの重要性の教育はプロトタイプのシステム構築の宿題の実施において、データの準備や AI 機械学習における正解データのアノテーションも経験させることで技術力を強化する。また、次回講義において、受講生による宿題の共

有を行い準備したデータの良し悪しでシステムの性能に差が出ることを体験することでデータの重要性の理解を促進する。

(3)AI モデルチューニングのノウハウ育成

プロトタイプ構築の宿題の実施では自らのデータ準備によって AI モデルのチューニングの必要性が増し、その解決を図ることでチューニングノウハウの向上を図る。このノウハウ向上も次回講義の受講生間の宿題共有によって効果を向上させる。各受講生のデータと AI モデルのチューニング結果を共有することでチューニングにおけるデータとハイパーパラメータとの関係をより豊富に体験することができ、AI モデルの確定、維持の技術を効率的に向上できる。

4.1.4. 評価手法

本教育手法では、応用プロトタイプのシステム構築が教育の中心的な役割を果たしているが、システム構築の結果は受講生の仕様検討やデータ準備の内容などに依存して難易度が変化し、且つ予め正解を設定することが難しい性格がある。このためプロトタイプシステムによる実践的な宿題を課して、その実施結果を分析して、評価を行う手法とする。宿題結果の評価は、5階評価などの評価基準を設定し、定量的な評価を実施する。

4.2. システム構築実習の実践

本節では、提案内容に関する実践内容を述べる。尚、提案内容における AI 基礎教育の一部とビッグデータの個別活用については、統計的手法による機械学習をベースして実践が行われており、これらの実践は筆者が担当していないため、実践内容に関する記述対象からは除外する。

4.2.1. 受講生の概要

(1) 4 技術の個別実習

受講生は中小企業 10 社から 16 名が参加。参加企業の業種は IT 企業も含むが、製造業の受講者が中心となっている。受講生は課長以上の管理者が約 4 名を占めるが、各会社の技術担当者が主体の構成となる。受講生の所属は製品、ソリューションなどの企画、開発部門が中心であり、IT を専門としない技術者が含まれる。DX 関連については、DX の導入による業務改善の推進、利用を経験した受講生は参加していない。

(2) 4 技術の統合実習

IoT、AI、ビッグデータ、クラウドの 4 技術を統合したプロトタイプシステムは他のシステムに比べて、システム構成と宿題のレベルを高く設定したことから、今回は受講対象者を情報系学部の学生 3 名とした。

4.2.2. 実施形態

実習の実行形態は、講義はオンライン講義とし、オンライン会議システム ZOOM を活用し、講師、受講生間の連絡事項伝達、宿題提出、質問受付などは、チャットツール Discord を活用した。また、プロトタイプの実行環境は Google Colaboratory、ストレージは Google Drive の各クラウドサービスを活用する環境とした。

4.2.3. 教材の体系

基本的に各実習の解説書、プロトタイプを構成するプログラム、アンケートとなる。アンケートは講義の理解度に関する自己評価、不明だった点、感想などの記載を基本としている。

図 4.5 にプロトタイプにおけるプログラムの開発環境と開発したプログラム構成を示す。プログラムは Python で開発し、ソースコードは Google Colaboratory の Notebook で作成、デバックを実施している。DL のフレームワークは TensorFlow、Keras を活用、関連するライブラリとしては、AI 全般をサポートする scikit-learn、配列他の数計算を行う Numpy、表形式で可視化する Pandas、グラフ描画の Matplotlib を使用している。プロトタイプで開発したプログラムは、自製で開発を行っているが、AI 基礎

講座で活用の手書き文字認識はオープンソースをベースとして開発を行っている。

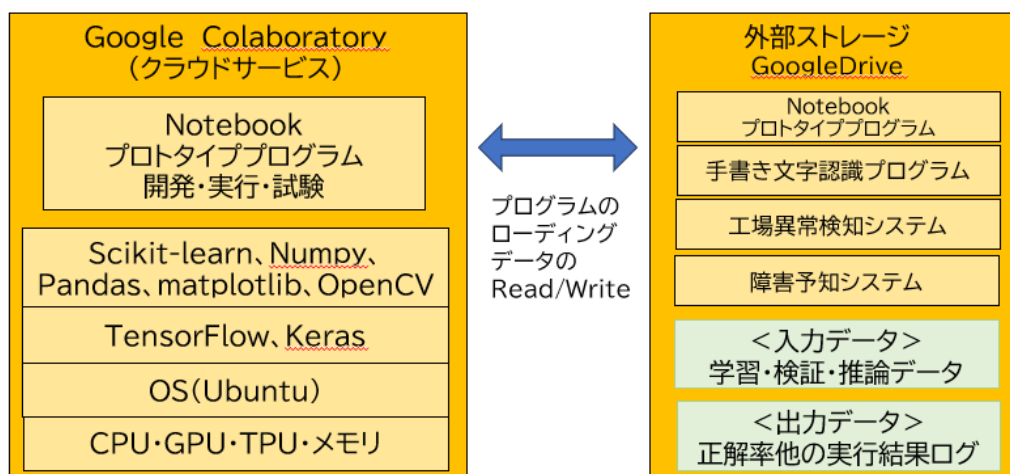


図 4.5 プロトタイププログラムの開発環境

4.2.4. 実習の内容

表 4.1 に実施した実習内容を示す。実習内容は DL 基礎を含む DL 実習及び DL、IoT、ビッグデータ、クラウドの 4 つの技術要素を統合的に活用したプロトタイプシステムの実習であり、クラウドについては、これらの実習の実行基盤、データ管理基盤として活用することで技術習得を行った。尚、IoT の個別実習については、4 技術の統合実習に含める形で実施した。

表 4.1 講座の実施内容

講座種別	教育項目	講義内容	宿題事項
AI (DL) 基礎実習 講義：4時間 宿題結果の共有と解説：2時間	—	ディープラーニング (DL) の CNN、RNN などのアルゴリズムの基礎 各種ハイパーパラメータの解説	手書き数字認識の演習 上記における各種ハイパーパラメータの変更による結果の考察
AI (DL) 応用の実習講義：6時間 宿題結果の共有と解説：2時間	工場ライン異常検出	プロトタイプの機能解説 プログラムの機能、仕様解説 構築、実行方法解説 チューニング手法の解説 ソースコード解説	受講生が自分で動画を取ってモデルチューニングと異常検出の実施。
クラウドの実習	活用方法解説	各プロトタイプの実行、分析データの集積場所として活用	個別宿題はなし。プロトタイプの実行で活用。
4技術の総合実習 (IoT教育を含む) 講義：6時間 宿題結果の共有と解説：2時間	工場ラインの異常発生予知	プロトタイプの機能解説 データの仕様解説 データの解析による予知方法の解説 プログラムの機能、仕様解説 チューニング手法の解説 ソースコード解説 プロトタイプの構築、実行方法の解説	受講生による仕様検討、学習データの準備、モデル選定、チューニングによる予知保全の実現

(1)AI(DL)基礎実習

講義での解説内容、宿題内容は表 4.1 に示す通りである。講義は1回目が4時間、2回目が宿題の共有、解説で2時間の講義を実施している。

(2)AI 応用の実習

図 4.6 に工場ラインの異常検知システムの構成図を示す。工場ラインの異常をライン上に流れる製品または部品間の距離によって検知する例を取り上げた。部品間の距離が短すぎる、或いは長すぎる場合をエラーと検知する応用例となる。実現方式は CNN による画像解析機能によって実現する。主な講義内容と宿題は表 1 に示した通りである。

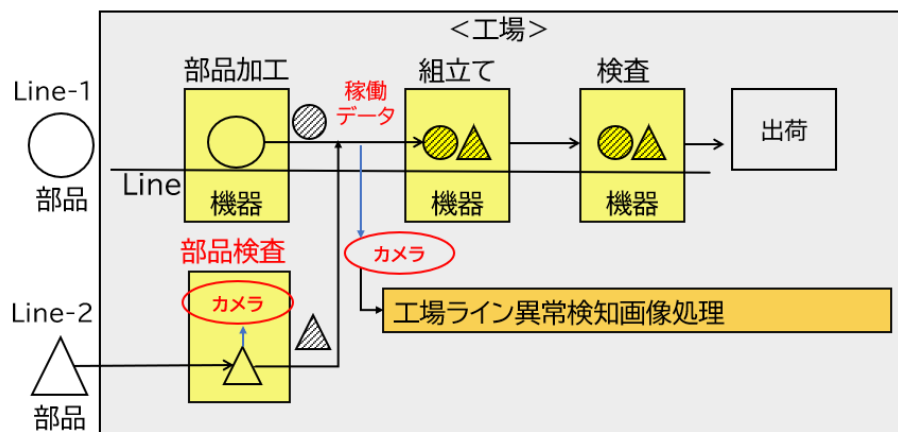


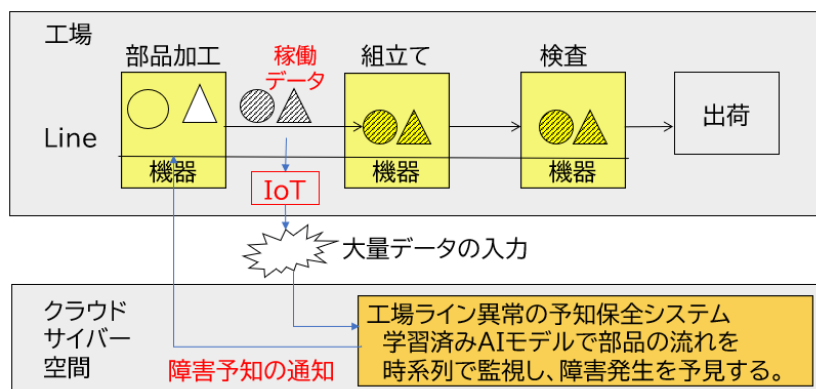
図 4.6 工場ラインの異常検知システムの構成図

(3)クラウドの実習

クラウドについては、活用方法を解説すると共に各プロトタイプの実行、データの管理について、クラウドサービスを活用することで、受講生のクラウド利用のノウハウ向上を図った。

(4)4 技術の総合実習

図 4.7 に4 技術の総合のプロトタイプシステムの構成図を示す。本プロトタイプは工



場ラインの異常発生を予測する予測保全のプロトタイプとして開発した。AI 実習の工場ラインの異常検知システムと同様に、ライン上の異常の定義はライン上を流れる部品または製品間の距離とした。異常を予測するデータは物体検知のセンサー情報の受信時間の間隔からなる時系列データとした。

プロトタイプにおいては、時系列データを扱うことからアルゴリズムは時系列データの特徴抽出が可能となるディープラーニングの Long short term memory(以下 LSTM)とし、学習データは物体検知の時間間隔の時系列データで、正解データは故障発生までの時間数として学習を実施した。発生させる学習データはシミュレータの開発で生成しデータ数は約 30 万件とした。推論処理では物体の検知時間の間隔の推移から障害発生時期を予測するシステムとした。本プロトタイプによって、IoT からのデータ受信処理、ビッグデータに相当する大量のデータ発生、AI によるデータ分析、クラウドでのシステム実行を実習することとした。主な講義内容と宿題については、表 4.1 に示した通りである。

4.2.5. 実習実施手順の工夫点

(1)実習の実行サイクルにおける工夫点

実習の実施手順は講義の実施、宿題の設定、アンケートの提出、受講生による宿題の実施、次回講義でのアンケートの内容も踏まえた復習、宿題結果の発表又は講師による紹介、宿題全般の解説という流れで実施した。

この流れによって、習得すべきポイントを講義、宿題実施、次回講義での復習、宿題結果共有、解説という形で何度も体験し、理解が進むように工夫を行った。

(2)データの重要性に関する教育

データの重要性は各実習の応用プロトタイプ構築の宿題において、原則は各受講者が自分でデータを準備し、実習によっては学習データのクラス毎の仕分け作業やアノテーションも体験させることで、データの重要性の理解向上を図った。また、宿題結果の共有によって、学習データの良し悪しがモデル性能に影響を与えることを実体験させることで、データの重要性の理解を促進した。

(3)チューニングノウハウの向上

各実習では基本的に宿題結果の受講生による発表、或いは講師による紹介を実施している。その結果、多様なデータによる各受講生のチューニング結果が共有できる。この共有によって、データ、モデル、そのハイパーパラメータの構成が多くのパターンで確認することができ、これらの関係性を体験させることでチューニングに関するノウハウの向上を図った。

4.2.6. 受講生の評価方法

理解度の把握は宿題結果の評価で実施した。

宿題については、実習毎に原則 2 件の宿題設定とした。これらの宿題の実施結果のレポートを確認することで、各受講生の理解度を評価した。評価は以下の 5 段階評価を設定して実施し、できるだけ定量的な評価になるように努めた。

5：期待を超えるレベル

(宿題で課していないことまで自ら調査し解答など)

4：内容を期待通りに理解し解答できているレベル

3：十分とは言えないが理解できているレベル

2：提出していれば可というレベル

(一部の問題の不解答や間違った理解を含む)

1：未提出、或いは実質的に未提出に相当する内容

4.2.7. 宿題結果の評価に関する実習での達成目標

受講生は各課題のシステム構築経験がない受講生であり、宿題提出内容の誤りや過不足がないことが条件となる評価 4 を平均的な達成目標とするのは難しいと判断している。このため、受講生評価の平均値が、宿題結果に一部不適切な内容が見られても全般的に理解ができている場合の評価点 3 以上となることを実習の成果達成目標とした。

4.3. 宿題実習結果の評価

(1)宿題の評価結果

表 4.2 に各実習の宿題評価結果を示す。

(a)AI(DL)基礎及び応用実習の実施結果

表 4.2 に示す通り、AI(DL)基礎実習の DL 関係宿題提出は 10 件であり、全体平均の評価点は 3.9 で実習の成果目標を達成できている。評価 4 以上で目的を達成している評価が全体の 60%となっている。また、提出はあったものの実質的成果が出ていない 2 評価は 1 件となった。

DL 応用の実習で応用システムの構築を伴う宿題では、全 11 件の内、4 評価以上が約 64%となっている。全体平均の評価点も約 3.6 で実習の成果目標を達成できている。

(b)クラウド実習の実施結果

クラウドについては、各プロトタイプの実行環境としてクラウドサービスを活用し、利用技術の習得を図った。自宅からのリモート参加が多いため、ファイルのアップロード、ダウンロードに時間が掛かり過ぎるという指摘があったが、特に大きな問題はなく、受講生の利用技術の育成に寄与できているものと判断している。

(c)4 技術の総合実習の実施結果

本実習における宿題は各受講生から計 3 件が提出され、その評価は 4 評価 1 件、3 評価 2 件となった。全体平均の評価点も約 3.3 で実習の成果目標を達成できている。プロトタイプをベースに受講生の考案による予知保全システムの構築を行う宿題において、目標をほぼ達成した宿題成果は 1 件であった。3 評価の 2 件は受講生の発想に基づく予知保全について、有意義な機能、データ仕様、分析手法を検討できているが、プロトタイプへの反映と実行までは完了していない結果となった。

表 4.2 各実習の宿題評価結果

宿題の出題講座	評価件数	5評価	4評価	3評価	2評価	1評価
AI基礎実習	10	4	2	3	1	0
		40.0%	20.0%	30.0%	10.0%	0.0%
AI応用の実習	11	1	6	3	1	0
		9.1%	54.5%	27.3%	9.1%	0.0%
4技術の総合実習	3		1	2		0
		0.0%	33.3%	66.7%	0.0%	0.0%

(2)受講生による自己の理解度評価

表 4.3 に AI(DL)応用実習に関する受講生の自己理解度評価、表 4.4 に総合実習の受講生の自己理解度評価を示す。AI 応用講座では若干チューニングに関する理解が他に比べて低い傾向を示している。総合実習では、宿題の難易度が高いという評価になっている。

表 4.3 DL 応用実習の受講生自己理解度評価

アンケート項目	受講生理解度自己評価 (単位:人数)				平均評価点
	2評価	3評価	4評価	5評価	
DL活用の大きな流れ		4	4	3	3.91
画像の準備方法 (静止画分割、仕分け、データ拡張など)		3	5	3	4.00
チューニング関係	1	3	6	1	3.64
機械学習結果の評価の考え方		4	6	1	3.73
推論処理における異常検出と閾値設定		4	3	4	4.00

表 4.4 総合実習の受講生自己理解度評価

アンケート項目	受講生理解度自己評価 (単位:人数)				平均評価点
	2評価	3評価	4評価	5評価	
プロトタイプ機能、仕様解説	0	2	1	0	3.33
プログラム解説		2	1	0	3.33
	容易	普通	難しい	非常に難しい	
宿題の難易度	0	0	2	1	4.33

(3) アンケート回答の主な内容

アンケートによって実習の進め方と理解度について、受講生の意見、感想を聞いているが、アンケート回答の主な内容を表 4.5 に示す。

表 4.5 アンケート回答の主な内容

講座	進め方に関する好評価のコメント
4技術 の個別 講座	① 理論、実践（宿題実施）、解説という形でフィードバックがあったため、一方的に受講するよりも理解が深まったと感じている。
	② テキストとオンライン講義内容の録画が残っているので、復習もしやすい状態で良かったと感じている。
	進め方の課題となるコメント
	① 質問の時間もあまりとれない印象であった。休み時間にちょっと聞くような感覚で話せる時間があるとよいかと思う。
	② 宿題のまとめ方が分からず、実行結果を提出できなかった。期間がやはり実質1週間ぐらいしかないのでは、途中までで終わってしまうのが残念と思う。
	③ 1週間後の土曜日等に課題に関する質疑応答等の時間が1時間等あればよかったですと思います。
	理解度に関する好評価のコメント
	① 実際に手を動かして復習するような応用プロトタイプの問題があり受講前と比べて、概要を理解・整理することができ、またAIの実装・運用方法が具体的になったと思う。
	② 以前に本などを買って多少勉強しようとしたディープラーニングですが、まったく理解できませんでした。それが今回の講義で幾つかの手法について理解できた。またデータの用意が重要ということも理解・実感できた。
理解度に関する実習の課題とすべきコメント	
① 全体的にレベルが高く、結構大変でした。ただ、内容的にはとても面白く録画の復習でなんとかした。	
② 内容が濃く、ついていくのが大変でしたが講義録画の見返しを行ったこともあり、各実習の最低限の理解はできたかと思っています。	
4技術 の統合 講座	理解度に関する好評価のコメント
	① リアルタイムで分析を行い、モデルを更新できるという点が予知保全システムの強みの1つだと感じた。実際の現場での使用例などをもっと多く知り自分の研究と紐づけたテーマを作ったらどうなのかと興味が湧いた。
	理解度に関する実習の課題とすべきコメント
① 予知保全技術の知識がなかったので、宿題の難易度はかなり高かった。	

4.4. 宿題実習結果の考察

(1)理解の達成度に関する教育法の評価

本教育手法の目標は、プロトタイプシステムの構築によって AI 技術の基礎と応用力、IoT の応用、クラウドの活用、ビッグデータの活用、データの重要性の体験、AI モデルのチューニングを実践することで DX 推進の技術者を育成することであった。これらの手法を検証するための実習では、AI (DL)の基礎、DL 活用プロトタイプ、**ビッグデータ**、IoT も含む 4 技術を総合したプロトタイプの構築実習を行い実践力の育成を図った。また実習の進め方では、受講生による学習データの準備、AI モデルのチューニング体験などを実施させて技術育成の課題解決を図った。

その結果、AI の実習では、基礎実習では 4 評価以上が 60%、システム構築・実行を伴う宿題でも約 63.6%がほぼ目的を達成しており、経験豊富な受講生が対象ではないことを考慮すると実習実施による成果はあったと考えている。4 技術の総合実習では、全員が予知保全の有意義な仕様検討ができており、その仕様をプロトタイプに実装して実行し、結果の検証まで完了した受講生がいたことは評価できる。

これらの全応用システムの宿題評価（基礎実習を除く）においても全体で約 57%が実習目的に沿った 4 評価以上の結果を出しており、DX 推進の実践的な技術者教育に成果があったと判断している。

(2)アンケートを踏まえた改善すべき事項

(a)質問の活性化

質問が出にくい傾向があり、この改善が課題となるが、頻繁に質問の時間を取る、逆に指名する、アンケートに質問を書かせる、チャットツールの併用など、さらに質問活性化への施策強化が必要と考えている。

(b)宿題説明の理解度向上と余裕を持った期間設定

宿題の説明では、実施方法、手順、実演など、宿題の内容、難易度に合わせて丁寧な説明を強化する必要があると考えている。また、余裕を持った宿題の実施期間を設定する必要があると考えている。

(c)受講生スキルに合わせた事前実習の準備

受講生の募集ではできるだけ、実習の主旨、受講生のスキル条件を明示すべきであるが、特に社会人教育の裾野を広くしていくことに配慮し、経験が浅いという前提で基礎実習の充実を図る努力も必要と考えている。

(3)他業種への展開

今回のプロトタイプの開発は主に製造業を中心としているが、他業種への展開も重要な課題となる。今回の実践評価の成果と課題への対策も含めて他業種を想定したプロトタイプを開発を行い、業種の拡大による教育効果の向上が今後の課題と考えている。

(4)AI 応用実習における課題と対策

システム構築を伴う宿題評価において、約 36%の受講生の理解度に課題がある結果となっている。DL については個別の基礎実習を実施し、プロトタイプ of 講義でも何度も同じテーマに触れるようにするなど、工夫を実施している。しかし、30%以上に課題が残った原因として、講義での実演などの観点で丁寧さが欠けた部分があったことなどによるものと考えている。これらの点は今後の改善事項と認識している。

(5)4 技術の統合実習の課題と対策

本実習の宿題では、プロトタイプで実装したモデルのチューニングに加えて受講生独自の仕様に基づくプロトタイプ of 構築も宿題として設定を行った。その結果、プロトタイプ of 構築、プログラムへの実装まで完結できた受講生が 1 名、他の受講生は有効な構想は検討できたが、アイデアのプログラムへの実装までは完結できなかった。

この改善対策としては、DL モデルの技術レベルや DL プログラミング経験を事前に確認し、その結果により事前講義を行うこと、また経験が浅い DL 初学者などの場合はプログラムに実装されたアルゴリズムの範囲内で宿題を設定するなどの配慮が必要であると考えている。特に今後、IT 技術者とは限らない社会人実習へ展開する場合は、DL で実施した基礎実習の事前実施が必須になると考えている。

(6)企業活動に即したビッグデータ活用への展開

複数企業を対象とした実習では、IoT から収集する企業設備の大量な情報、医療などの機微な情報、各企業の膨大な文書データなどのビッグデータを実習で活用することには限界がある。この課題を実習内で完全に解消するのは難しいため、実習で得たノウハウを踏まえて、これらのビッグデータ活用について社内の実証実験への展開などを期待したいと考えている。

(7)クラウド実習のプライベートクラウドへの展開

クラウドはプロトタイプ of 実行やデータの管理において、クラウドサービスを活用して利用技術の強化を図った。今回の利用サービスは所謂パブリッククラウドの利用になるが、クラウドのシステム形態にはプライベートクラウド、パブリックとプライベートを併用したハイブリッドクラウドの利用形態がある。社外実習においては実習の中でプライベートクラウドを構成することは難しく、プライベートクラウドの教育には課題が残る。このためプライベートクラウドの活用体験に関しては、社内での検討に委ね、その検討結果を踏まえて適宜プライベートクラウドの実体験をしていくことを期待している。

(8)AI モデルの進化への対応

DL における CNN、LSTM、CNN 系のより大規模なアルゴリズムについての解説を行い、CNN による実習を行っているが、特に DL のアルゴリズムは進化し続けている。これらの活用、特に新しいアルゴリズムにおける運用保守の技術力を確保するためには、これらを積極的にプロトタイプなどのシステムで活用し、そのキーとなるパラメータや実行性能などを見極める必要がある。これらへの対応は実習の受講者が会社に戻

って自らの取り組みとして、自主的に取り組むことを期待している。その一方で、実習の内容も継続して改良していくことを検討していきたい。

4.5. まとめ

本論文では、プロトタイプをベースとした DX 推進技術者の育成法について提案し、その実践評価を述べてきた。

本手法の骨子は DX 推進に有効な IoT、AI、ビッグデータ利活用、クラウド活用に関連したプロトタイプの開発と構築を通して DX 推進技術者の育成を図ることである。この手法について、プロトタイプをベースとした実習を企画し、複数企業の技術者や学生を対象に実践して評価を行った。その結果、DL 応用プロトタイプの実習では、宿題評価の平均が約 3.6、総合実習プロトタイプでの宿題評価平均が約 3.3 で実習の成果目標（評価平均 3 以上）を達成できている。また、プロトタイプのシステム構築を伴う宿題成果で約 57%の受講生が実習の教育目標をクリアしている。DL などの実践経験がない受講生が対象であったことを考慮すると、この結果から本実習、教育手法による成果があったと評価している。

一方、DL の技術教育では宿題実施に関する実演による講義という観点で課題があった。IoT を含む 4 技術の総合的な実習に関しては、今後、宿題の平易化や事前実習などによって、特に IT 経験の浅い社会人への適用検討が課題となる。ビッグデータやクラウドにおいては、受講生の社内での継続した検討、検証も求められる。またプロトタイプの開発においては、応用例の製造業以外の業種への展開、AI の技術進展に対応した最新技術のキャッチアップが重要となる。これらの課題も踏まえて、引き続き DX 推進の技術者育成の研究を行い、DX 推進による企業の競争力強化に寄与していく予定である。

5. デジタルツインプロトタイプ開発と技術者育成手法の研究

本研究では、2.3 節に記載のデジタルツインシステム構築の課題を踏まえて、物理システム固有のモデリング技術やデータの収集ノウハウに関する特性を踏まえたプロトタイプの開発について研究する。また、本プロトタイプを活用した人材育成手法の提案を行う。提案内容は講座の実践により検証し、提案内容の効果を確認する。

5.1. デジタルツインプロトタイプ開発と教育手法の提案

5.1.1. 提案内容

図 5.1 に提案内容の概要を示す。2.3 節で述べた課題のとおり、デジタルツインを構築するためには、物理システムを仮想空間上に再現するための物理システム特化のモデリング技術とモデリングするために収集すべきデータの特定ノウハウが必要になる。

本提案では、そこに仮定を置いてプロトタイプを開発する手法を提案する。本手法に基づいて、データを生成するツールや将来予測モデルの作成ツール、これを活用したデジタルツインのプロトタイプを開発する。その開発成果を活用して、DL 応用プロトタイプでの理解度向上手法に加えて、受講生が仮定を設定してデジタルツインを検証し、これを受講生間で共有して理解度向上を図る手法を提案する。

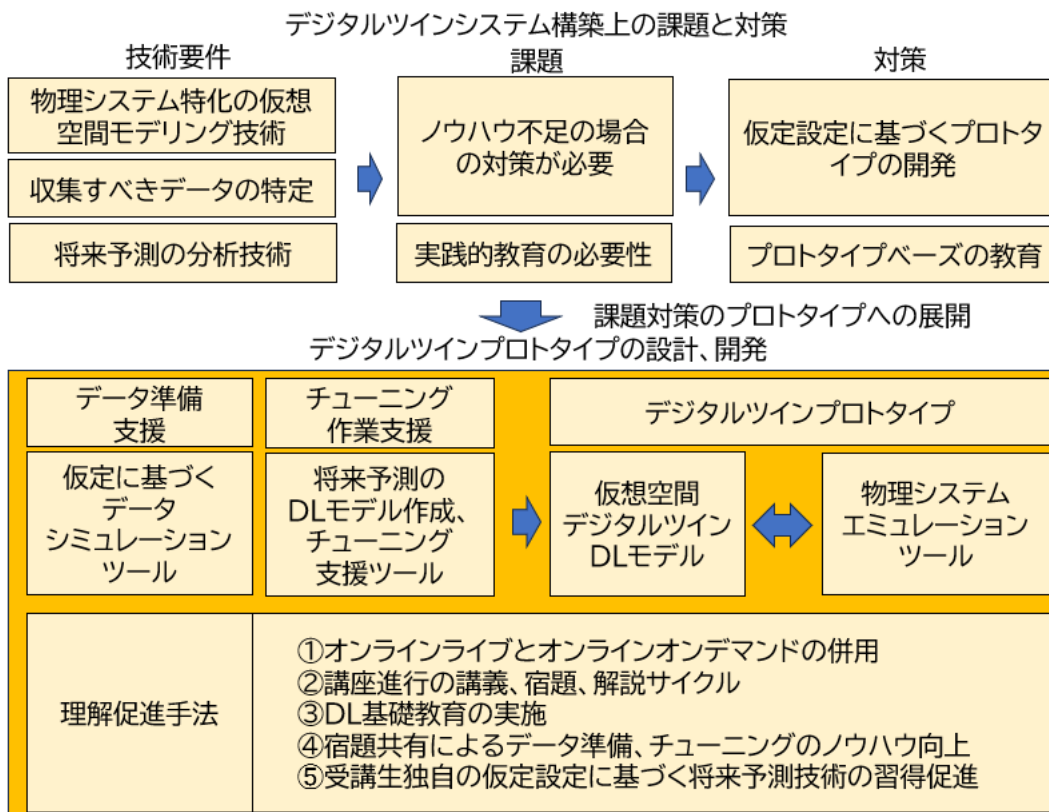


図 5.1 提案内容の概要

(1) プロトタイプシステム構築教材の提供

図 5.2 にプロトタイプシステムの構成図を示す。2.3 節で記述した通りデジタルツインは物理システムの効率的な運用を目指すシステムであることから実践的な教育が重要であり、プロトタイプの構築実習による教育を行う。プロトタイプで実現する機能例は将来事象を予測して物理システムを円滑に運用する機能とする。このシステムの代表的な事例として予知保全がある。以下に本プロトタイプの骨子を示す。

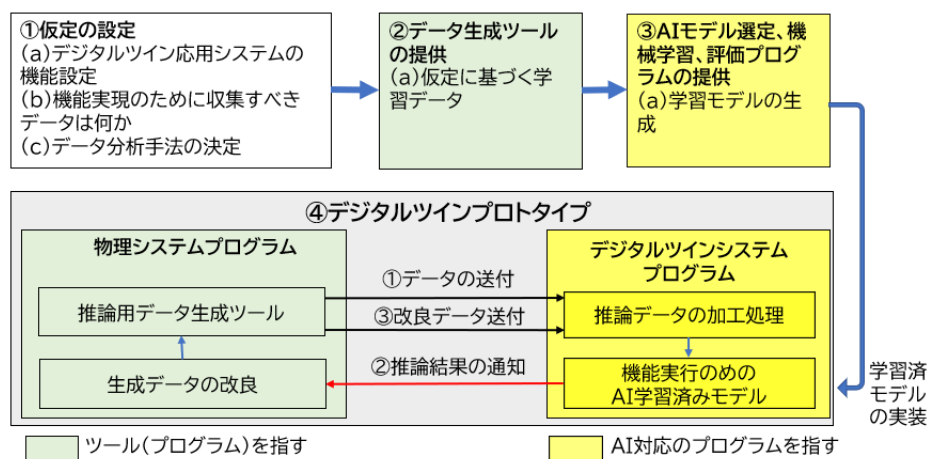


図 5.2 プロトタイプシステムの構成図

① 実現機能と収集データに関する仮定の設定

デジタルツインで再現する物理システムのモデリング技術や収集すべきデータの特長に関する業務ノウハウについて、システム構築可能な正確なノウハウがない場合でも、これらに対して仮定の設定を行う。例えば、予知保全において、工場設備の振動、圧力、温度などに関する時系列データと障害発生時刻を取得し、設備情報の時系列データをディープラーニング（以下 DL）の学習データとし、障害発生までの時間数を正解データとするなどの仮定を設定する。

② データ生成プログラムの提供

設定した仮定に基づいて学習データを作成するデータ生成プログラムを開発し、教材として提供する。学習データの生成は設定した仮定に基づいて、各種乱数生成（一様分布、正規分布、二項分布、ガンマ分布など）や正弦波の合成による波形データの生成などのプログラミング機能を活用して、プログラムによるデータ生成を行う。なお、活用できる実データがある場合は、当該時系列データを活用することを検討する。

③ AIモデルの学習・評価プログラムの提供

以下に示す処理を実行するためのプログラムを開発し、学習・評価プログラムの一例として提供する。AI モデルのアルゴリズムはデータの時系列の順序性を学習することが可能な DL の Long Short-Term Memory (以下 LSTM) を原則として採用する。構築作業としては、上記②で生成したデータを LSTM に入力して、学習、検証を行う。この検証作業において、デジタルツインで実現する機能のシステム要件(例: 障害発生までの時間予測の誤差は 12 時間以内など)を満足する予測精度になるように、LSTM のハイパーパラメータを調整して LSTM モデルを確定する。

尚、プログラムへの LSTM モデルの実装方法については、実現する将来予測の要件に依存して変化するが、原則的には、時系列の長さを指定可能な 1 次元配列のデータを入力データとし、出力はスカラ値として、スカラ値を予測する構造を基本とする。チューニング可能とするハイパーパラメータは学習回数を示すエポック数、学習におけるミニバッチサイズ、学習率、入力データの時系列の長さ、LSTM の中間ブロック数を必須とし、これらの数値を調整してチューニング可能な構造とする。また、ハイパーパラメータの組合せによる性能比較の手段として、R squared (以下 R²)、Root Mean Squared Error (以下 RMSE) を算出し履歴を残すことができる構造とする。さらに確定した LSTM モデルの構造と重みを格納し、デジタルツインプロトタイプで、学習済みモデルを再現できる仕組みとする。

④ デジタルツインプロトタイプの提供

上記で学習済みとなったモデルを実装するデジタルツインプログラムを開発し、プロトタイプとして提供する。本プログラムは物理システムからの発生データを受信し、学習済みの DL モデルにデータを入力して推論処理を行い、障害発生の予知などを行う。また、推論処理の結果により運用改善や品質改善のために物理システムへのフィードバックが必要であるかどうかの判断を行う。フィードバック要否の判断基準は特に定めないが、障害発生予測が 24 時間以内に達したなど、任意に設定を行う。

さらに実際に物理システムを構築することが難しい場合を想定して、仮定に基づく推論データを生成し、物理システムをエミュレーションする物理システムプログラムを提供する。本プログラムは上記②のデータ生成プログラムと同様の手法で運用時のデータをランダムに生成して、デジタルツインプログラムに送信する。また、デジタルツインプログラムからの改善を必要とする事象発生の通知を受けた場合、生成データの正常化或いは初期化を実施し、物理システム改善のエミュレーションを行う。

上記 2 つのプログラムの通信インターフェースは、特に定めないが、ソケットによるプログラム通信やキューによるスレッド間通信などを候補として通信を行う。

(2) 受講生によるプロトタイプの構築実習

受講生によるプロトタイプの構築作業においては、最初にプロトタイプのデフォルト

の仮定設定に基づき、各種プログラムは変更することなく実行する。データ生成プログラムによってデータを生成し、学習・評価プログラムによって生成したデータで DL モデルを学習し、評価指標によってその予測精度を確認する。次にデジタルツインプログラムにより運用データの推論処理を行い、運用改善の動作確認を実施する。さらに、学習・評価プログラムにおける DL モデルのチューニング作業を行って、精度向上を図る。これらの実習によってデジタルツインの仕組みの理解や DL モデルのチューニングの実践力を育成する。

DL モデルの予測精度の調整においては、本節(1)③で示した各ハイパーパラメータの調整を受講生が行い、評価指標に従って最適と考えられるハイパーパラメータの組合せを確認する。なお、講師は受講生の調整作業の前に以下に示すハイパーパラメータの特性を解説する。エポックス数は大きい程精度が上がるが、過剰に実施すると過学習の弊害があり、且つ学習の実行時間に悪影響を与えること、ミニバッチはケースバイケースで最適な値を探す必要があること、時系列の長さは学習すべき特徴を十分に反映した適切な長さを見極める必要があること、LSTM 中間層のブロック数は大きい程、精度が向上する傾向があるが、精度の限界点もあり、大き過ぎると学習の実行効率が落ちること、学習率はデフォルト値を 0.001 として、その前後での変化を確認すべきであることなどを解説する。なお、LSTM の熟練者ではない場合には、各ハイパーパラメータにおける適切と想定される範囲を指定して、それらの最適な組み合わせをプログラミングによって探すグリッドサーチやランダムサーチなどの手法によるチューニングはなしとし、マニュアルでハイパーパラメータの調整を行って、受講生自身が最適と考えられる範囲や特性の確認を実施することを優先する。以上の実習により実践的な構築力の育成を図る。

(3) 受講生の仮定設定によるプロトタイプシステム構築

受講生は自分の発想で、デジタルツインで再現する物理システムとモデリングに必要なデータの仕様に仮定を設定する。次に仮定に基づいたデータ生成が可能となるようにプロトタイプのデータ生成プログラムと物理システムプログラムを改定する。さらに AI モデルのハイパーパラメータの選定と学習・評価プログラムへの反映、AI モデルのチューニング作業を行う。本作業で学習済みとなったモデルをデジタルツインプログラムに実装し、仮定した機能の実現可能性を確認することでデジタルツインの構築力強化を図る。さらに各受講生の仮定設定のバリエーションの共有によって一層の教育効果の向上を図る。

(4) Python、LSTM の基礎教育の設定

受講生が Python でのコーディング実績や DL のプログラミングに慣れていない場合、また、ディープラーニング全般や LSTM の学習経験が少ない場合は、プロトタイプの構築を促進するため、事前の基礎講座を設定する。講座内容は、Python の言語仕

様を学ぶ基礎学習教材、DLで重要になる NumPy、Matplotlib、Pandas の各ライブラリの学習教材、各種乱数発生のコーディング例の学習教材、DL (CNN、LSTM) の基礎講座とする。

以上の(1)から(4)の提案内容により、プロトタイプの構築実習を可能とすることで、デジタルツインのAIによる将来予測のシステム構築力を育成する。

5.1.2. 評価方法

本教育手法では、プロトタイプのシステム構築が教育の中心的な役割を果たしているため、プロトタイプによる実践的なシステム構築の宿題を課した上で、その実施結果の評価を行う手法とする。評価においては、定量的な評価になるように、5段階評価などの基準を設定して評価する。また、具体的な評価の指標は、将来予測の精度が定量的な評価指標になるが、その実施過程も重要であり、業務ノウハウに設定した仮定の内容、これに基づき生成したデータの妥当性、学習・評価プログラムへの実装と LSTM ハイパーパラメータのチューニング内容の妥当性の各項目も考慮して、総合的に5段階などの基準にしたがい評価を行う。

さらに、実習の設定においては、受講生の仮定に基づきプログラムの修正を伴うシステム構築の実施に加えて、プロトタイプのデフォルトの状態での DL モデルのチューニングを行うなどの実習を設けて、重要な基本事項の理解度確認も可能な実習の設定とする。

5.2. プロトタイプ構築教育の実践内容

上記 5.1 項の提案内容を踏まえたプロトタイプの実例と実践した実習内容を示す。

5.2.1 実習の実施形態

(1)受講生

実習は理工系大学の情報系学部 4 年生 3 名、同院 1 年生 2 名（電気工学系学部出身）を対象とした。なお、これらの受講生は予知保全、障害予見などの業務に関する学習経験はなく、時系列データの分析を行う LSTM モデルの学習経験はない受講生となっている。

(2)実施時間

実習は 2 回の講義とし、1 回目は 4 時間の講義、次回までに実施する宿題の設定、2 回目はこの宿題の結果の共有、講師コメント、全体の総括を実施した。なお、1 回目と 2 回目の講義には 2 週間の間隔を設定した。

(3)実習の実行環境

実習の実行環境は、講義はオンライン講義とし、オンライン会議システム ZOOM を活用し、講師、受講生間の連絡事項伝達、宿題提出、質問受付などは、チャットツール Slack を活用した。また、プロトタイプの実行環境は Google Colaboratory、ストレージは Google Drive の各クラウドサービスを活用する環境とし、受講生の PC 環境に依存しない均一の環境とした。

(4)講義時間以外における受講生への対応

1 回目講義の前に 1 時間のオリエンテーションを行い、事前課題を設定した。事前課題は Python の基礎学習教材、NumPy、Matplotlib、Pandas の学習教材、各種乱数発生のコーディング教材、ディープラーニング (CNN、LSTM) の基礎講座資料による事前学習、これらの学習を踏まえた質問事項の提出を課題とし、講座前の知識の強化を図った。質問事項は 1 回目の講座で回答内容を紹介し、質問内容の受講生間での共有を図った。また、実習では、2 回の講義の間でのメールや Slack での Q&A は実施可能として講座を実施したが、結果として講義間での質問などの実績はなしであった。

5.2.2. プロトタイプ構築教育での実践内容

(1)プロトタイプ構築の教材内容

図 5.3 にプロトタイプにおけるプログラムの開発環境と開発したプログラム構成を示す。プログラムは Python で開発し、ソースコードは Google Colaboratory の Notebook で作成、デバックを実施している。

DL のフレームワークは TensorFlow、Keras を活用、関連するライブラリとしては、

AI 全般をサポートする scikit-learn、配列他の数計算を行う Numpy、表形式で可視化する Pandas、グラフ描画の Matplotlib を使用している。

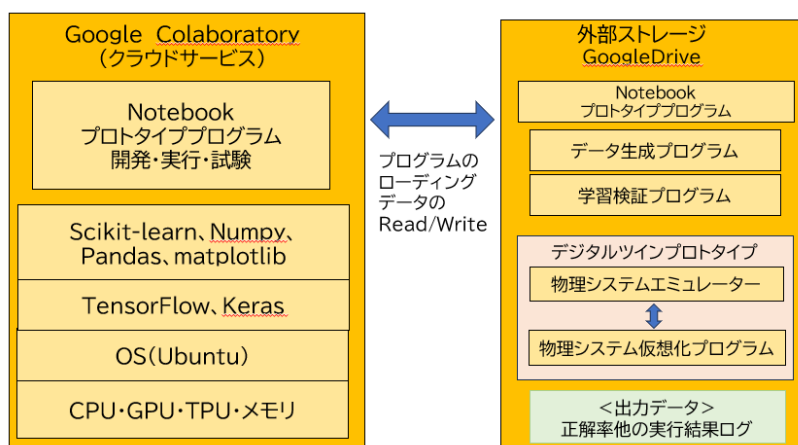


図 5.3 プログラムの開発環境

① デジタルツインの実現機能

本プロトタイプにおけるデジタルツインのシステム例は、工場ラインの異常検知を題材とした。現実の工場ラインの異常においては、当該ラインの異常の種別、その異常を予測するための仕組み、仕組みに基づく学習データの作成が必要となるが、本プロトタイプではこれらの業務ノウハウに対して以下の仮定を設定した。

② プロトタイプにおける仮定の設定

ライン異常の定義はライン上を流れる物体間の距離とし、ある一定の距離範囲に収まっていない場合が異常であるという仮定を設定した。この仮定はラインのメカニカルな異常や部品供給の異常などから発生し得る異常であることから仮定として選択した。この異常を予測する手法としては、時系列での距離の変化を特徴量とすることで故障発生までの時間を予測できるものと仮定した。この仮定はラインの異常においては時間経過と共に異常検知の指標である部品間距離が類似的なパターンで悪化するケースがあることから部品間距離の時系列データを分析することで障害予見が可能になると仮定した。

上記の前提に基づき、工場ラインからは近接センサーによるライン上を流れる物体の通過時間が通知されるシステムをデジタルツインの物理システムとして仮定した。

③ 仮定に基づくデータ生成ツールの提供

物体の通過時間間隔の範囲を変化させながら、その範囲内で一様分布によるランダムなデータ生成を行うプログラムを開発して提供した。このプログラムによって通過時間の間隔を数値化して DL モデルの学習データとし、正解データは仮定した障害発生時刻までの期間とした。

④学習・評価プログラムの提供

学習・評価プログラムで使用するアルゴリズムは機械学習において、時系列の並びを特徴量として機械学習が可能な LSTM とした。本学習・評価プログラムによって、上記③で生成したデータの学習を行い、DL モデルを確定する機能を提供した。DL モデルの確定においては、回帰（AI 全般における予測機能）の精度指標である R2、RMSE の算出機能をプログラムに実装して精度を評価する方法とした。要件に合わせるために調整可能としたハイパーパラメータはエポック数、ミニバッチサイズ、学習率、時系列の長さ、中間の LSTM のブロック数とした。

⑤ デジタルツインプロトタイプを提供

デジタルツインプロトタイプのプログラム構成を図 5.4 に示す。図左側のプログラムは仮定に基づいてデータを生成し、物理システムをエミュレーションする物理システムプログラムとなる。図右側のプログラムは学習済みモデルを組み込んで物理システムプログラムからの受信データによって物理システムを再現するデジタルツインプログラムとなる。図 5.4 において、①デジタルツインプログラムは物理システムプログラムからのデータを受信し、②学習済みモデルへのデータ入力を行って DL モデルの推論処理による障害発生の予測を行う。③障害発生までの期間について何らかの閾値を設定し、閾値を超えた場合に異常予見と判断して、その情報を物理システムプログラムに通知する。④障害予見を受信した物理システムプログラムは生成データに改善を与えて、⑤デジタルツインプログラムに通知するデータの正常化を図る。この仕組みによって疑似的に物理システムの予知保全とシステムの連続稼働を実現するプロトタイプを提供した。

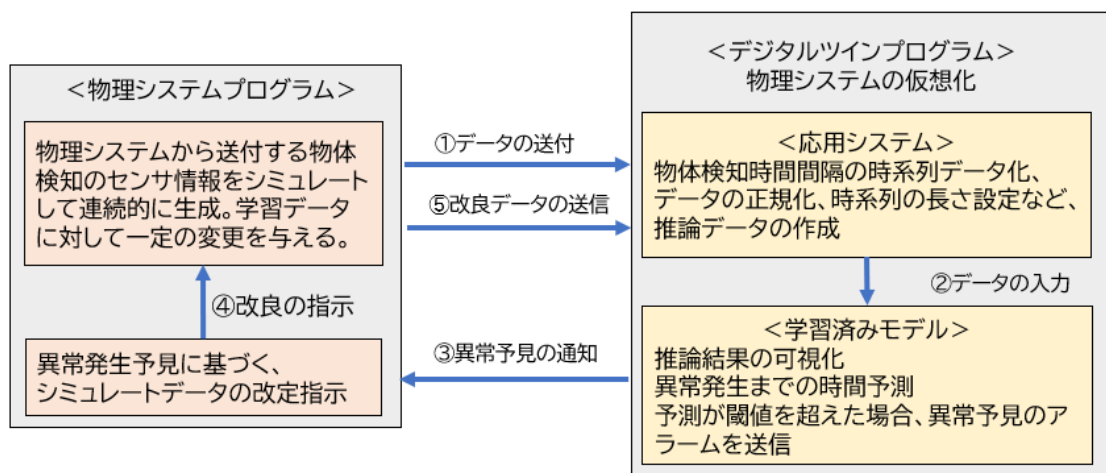


図 5.4 プロトタイプシステムの構成図

(2)1 回目の講義内容

1 回目の講義では、デジタルツインの概要、効果、基盤技術を解説、また現状での

事例の特徴や仕組みを解説した。事例の解説では、海外事例から飛行機エンジンのデジタルツイン化による運用保守効率化の事例を解説した。日本における事例では、海洋プラント設備のデジタルツイン化による運用でのダウンタイム縮減の事例、事業計画から生産、出荷配送までのワンストップのデジタルツイン化による生産調整の最適化を行う事例を解説した。さらにシンガポール、東京都における都市のデジタルツイン化による都市計画のシミュレーション事例を解説し、デジタルツインの応用イメージのヒントとした。

次に提供した各プログラムの機能と構成、ソースコードの解説、DLモデル(LSTM)の機能や仕組みの解説、DLモデルチューニングに必要なハイパーパラメータの概要とその特性、ソースコードでのパラメータ修正方法を解説した。

(3) プロトタイプ構築の宿題内容

宿題内容はその難易度から2段階で設定している。一つ目の宿題1は、提供したプロトタイプの構築と提供時の仮定に基づくシステムの実行とした。また重要な基礎事項の宿題として、プロトタイプで準備したLSTMモデルにおいて、各種ハイパーパラメータとLSTM認識性能との関係を把握し、よりよいハイパーパラメータの組み合わせを確認することとした。

2つ目の宿題2は受講生による仮定設定に基づいてデジタルツインの構築と仮定したモデルの検証を行うものとした。本宿題により受講生は、デジタルツインで実現する機能の設定、それを実現するためのデータ生成、将来予測のためのAIモデルのチューニングの実施、デジタルツインプログラムへのAIモデル実装とデジタルツインの実行によって仮定した機能の検証を行う。

(4) 2回目の講義内容

2回目講義は、各受講生による宿題結果の発表を行い、各自の結果を受講生間で共有した。この共有によりDLモデルのチューニング結果やデジタルツインの仮定に関する発想や検証結果などを共有し、教育効果の向上を図った。

また、1回目講義のアンケートを実施し、講義における不明点、難しかった点の確認を実施した。その結果を踏まえてLSTMの構造の復習、チューニングの理解の更なる促進のために講師による実施結果の解説、プログラミングによりハイパーパラメータの組合せをサーチするグリッドサーチ、ランダムサーチの手法などの補足説明を実施した。

5.2.3. 評価方法

2つの宿題の提出内容について、以下の5段階評価を設定して、講師による宿題提出内容の定量的な評価を行った。

S：期待を超えるレベル

(宿題で課していないことまで自ら調査し解答等)

A：内容を期待通りに理解し解答できているレベル

B：十分とは言えないが理解できているレベル

C：提出していれば可というレベル

(一部の問題の不解答や間違った理解を含む)

D：未提出、或いは実質的に未提出に相当する内容

なお、上記評価基準とした背景、補足は以下の通りとなる。Sランクは宿題の実施において講義で解説していない手法での深堀や改善を行う成果を上げた例があったことから設定した。Aランクは講義の内容を正しく理解し、宿題の手順や考察も適切である受講生を対象とした、評価 B は理解不足があるが宿題の成果や理解の促進が見られる講生を評価対象とした。ランク C は理解不足や誤りが目立つ場合の評価段階とした。ランク D は本来発生させない工夫が必要であるが、社会人も対象とした講座を想定しており、社会人の場合は仕事の都合などで宿題が提出できない場合が発生し得るため、本評価ランクを設定した。

5.2.4. 宿題結果の評価に関する実習での達成目標

受講生はデジタルツインのシステム構築経験がない受講生であり、宿題提出内容に誤りや過不足がないことが条件となる評価 A を全体の達成目標とするのは難しいと判断している。このため実習の成果達成目標は、宿題評価の平均値が、宿題内容に一部不適切な内容が見られても全般的に理解ができている場合の評価点となるB以上とした。

尚、評価時は評価S:5点、評価A:4点、評価B:3点、評価C:2点、評価D:1点と換算し、平均3以上を達成目標とした。

5.3. 宿題実習結果の評価

5.3.1. 実習における宿題の提出内容と理解度評価

(1)宿題1 LSTM ハイパーパラメータの調整

受講生全員が宿題を提出しており、その評価はS評価1名、A評価3名、B評価1名とした。全員の評価平均点は4となり、実習の成果目標を達成できている。S評価の1名は5つのハイパーパラメータを個別に調整し、一番良いハイパーパラメータを順次選択し、最後に相関関係のあるパラメータの組合せも再確認しており十分に理解した対応が実施されている。A評価の3名はハイパーパラメータの数値の範囲が十分でない部分も見られるが、全てのハイパーパラメータの調整を行い、その中で最適なパターンを選択しており、宿題の主旨を理解した対応ができている。B評価の1名は全てのハイパーパラメータの調整ができていないためB評価とした。

(2) 宿題2 仮定設定に基づくデジタルツイン作成

5名が仮定設定を行い、評価はA評価3名、B評価2名とした。全員の評価平均点は3.6となり、実習の成果目標を達成できている。A評価の3名はプロトタイプへの実装、評価まで完結している。他のB評価2名はソースコード実装が完結できず、仮定設定の検証までは完了できていない。

A評価の3つの仮定の設定と実施内容の概要は以下の通りとなる。第1の仮定は田植え機の欠株発生の監視による田植え機の故障予測と点検の効率化であった。学習データは、センサーや画像認識などによって欠株を検知し、この情報と故障情報が管理センターなどで管理されている前提で、故障発生情報を正解データとして、欠株の発生間隔の時系列データを学習するという設定であった。予測精度はプロトタイプのデフォルトの仮定設定でのチューニング結果に及ばないが、データ生成方法を変化させて、精度の違いを考察しており、DLにおけるデータの重要性を理解した内容になっている。

第2の仮定は、自動車のタイヤ交換の警告予想を行うものであった。学習データとして、自動車の走行距離と一定間隔における速度をペアとした一次元の時系列データがあり、正解データとしては交換実績によるタイヤ摩耗の限界時期のデータがある前提であった。予測精度はプロトタイプのデフォルトの仮定と同等となっている。

第3の仮定は、一定の間隔での血圧測定値による疾患発症警告、予防を行うものであった。スマホアプリなどで学習データとする日々の血圧測定値と正解データとする疾患発症時期のデータがある前提での提案であった。予測精度も第2の例と同様の結果であった。

一方、プロトタイプへの実装が完結せず、B評価とした受講生の内容は以下の通りであった。第1の仮定設定は自転車のチェーン故障の予見であった。本件はペダル踏み込みの圧力情報と故障情報が管理センターなどで蓄積されている前提で、ペダルへの圧力

の時系列データと故障情報を活用してチェーン故障を予測するものであった。この仮定においては、ペダルに圧力が掛かるタイミングが一定ではないため、時間間隔と圧力という 2 系統のスカラ値の学習要素が発生し、プロトタイプへの反映の難易度が上がり、実装は完了しなかった。

第 2 の仮定は、道路の渋滞予測に関するものであった。データとしては、一定の時間間隔における車の通過台数と平均速度、自動車の走行速度の低下に基づいた渋滞の発生時刻が管理されている前提であった。本件では管理データの時間間隔は一定であるが、不規則に上下変化する速度と台数の 2 値の学習要素が発生することがソースコードの反映を完了できない要因となった。

5.3.2. 受講生による理解度の自己評価

表 5.1 に受講生による自己の理解度評価結果を示す。特徴的な点は宿題の難易度が高いと感じている点となる。

表 5.1 受講生による理解度の自己評価結果

アンケート項目	受講生理解度自己評価 (単位: 人数)				平均評価点
	2評価	3評価	4評価	5評価	
デジタルツイン解説	0	2	2	1	3.80
プロトタイプの機能、仕様解説	0	2	3	0	3.60
プログラム解説	0	3	2	0	3.40
	容易	普通	難しい	非常に難しい	
宿題の難易度	0	1	4	0	3.80

アンケートでは、自己評価に関連して、理解できたこと、難しかったこと、今後の興味について聞いており、その回答を表 5.2 に示す。

本回答では、受講生の理解度向上、今後の取り組み姿勢や興味の向上という観点で十分な成果が見える。一方、特にプログラムについて、詳細な理解までは到達できなかった、データ生成の関数が難しかった、などの感想があり、今後、プログラムの理解を助ける工夫が重要となる。

表 5.2 受講生による理解度の自己評価結果

アンケート内容		番号	受講生回答
デジタルツイン解説の理解度について	理解できたこと	①	資料も沢山あり、じっくりとご説明していただき、大変参考になりました。
		②	応用事例を混ぜての解説だったためわかりやすかった。
		③	デジタルツインの機能であるシミュレーションを行うために、ディープラーニング等のAI技術を利用して解析を行う必要があることが分かりました。
	難しかったこと	④	前提の知識が薄いため、理解するために調べて、それをまた理解するには…というような作業が膨大で、追いつくことが出来ませんでした。
		⑤	どのようなフィードバックを現実世界に行っているのか、それを行うことでどのようなメリットがあるのか難しかったです。
プロトタイププログラム解説の理解度について	理解できたこと	①	今回用意して頂いた、3つのプログラムの機能は理解できました。
	難しかったこと	②	各機能をどのようにして、実装しているのか細部まで理解することができませんでした。
		③	仮説の設定や学習データの準備のところが、どのように予想を立て準備すればいいのかという所が少し難しかったです。
		④	ランダム関数が難しかった。
		⑤	何のためのプログラムかはわかって、詳細までは理解が出来ずそれを改良することはできませんでした。
デジタルツインの興味がどのように深まりましたか。	①	理解するためにはまだ学習が足りないことを痛感し、今後の学習への意欲を高めることが出来ました。	
	②	講座内で聞いた応用事例以外にもどんな利用をされているのかに興味が出た	
	③	自動車の運転支援などにデジタルツインを活かそうと考えているが、何を入力として学習をさせて何を分析するかを明確にしてから、分析の精度、速度を考えてどのようなデジタルツインを動かすかを改めて考え直す必要があることがわかった。	
	④	現実世界を仮想にもっていき、様々なシミュレーションを行うことができ、大変勉強になりましたし、もっとデジタルツインを使った利用方法があるのではないかと興味を持つことができた。	
	⑤	今後、デジタルツインの考え方は、日本国内の特有の課題に対してとても有効であると考えようになりました。まずは、AI技術を身に付け、デジタルツインの業務ノウハウ取得に再度チャレンジしてみたいと思います。	

5.4. 宿題実習結果の考察

5.4.1. 実践による教育手法の考察

(1)宿題 1 の実習における成果と課題

実習における宿題 1 の評価内容は 5 名全員が各ハイパーパラメータの変更結果を個別に確認し、個々の特性を理解できる手法でチューニング結果を開示している。また、プロトタイプのリソース設定から LSTM 固有のハイパーパラメータを変更することで、性能を改善するハイパーパラメータの組合せの検出も 5 名中 4 名が実施できている。LSTM やデジタルツインの初学者が対象であるが、実習でチューニングの理解向上が見られた要因は、プロトタイプの構築、講座の進めた方に加え、事前課題（録画形式による解説など）と 1 回目の講義で、LSTM の基礎やハイパーパラメータ解説を 2 回実施する手法などの効果によるものと判断している。

(2)宿題 2 の実習における成果と課題

実習における宿題 2 の評価内容は、A 評価 3 名、B 評価 2 名であった。実習の宿題 2 についても 5 名から宿題が提出され、内 3 名が仮定に基づくプロトタイプへの実装、検証まで完了した。この結果、5 つの仮定設定と生成すべきデータの検討結果を受講生間で共有できたこと、また、内 2 名はプロトタイプに仮定を実装してプロトタイプのリソース設定の仮定設定と同等の精度を実現し、これらの結果を受講生間で共有できたこと、もう 1 名はプロトタイプのリソース設定の精度までは到達していないが、学習データと検証データの乖離などデータ生成方法の精度に対する影響、データの重要性を指摘できおり、これを受講生間で共有できたことなどの成果を得ることができた。以上の通り、実習で仮定した内容のプログラムへの実装、検証が促進された要因は、プロトタイプの構築、講座の進めた方に加え、Python の事前課題の設定であったと判断している。この結果から Python での本格的な DL 経験がなくても、今回実施したような Python の事前講座などの手法によって教育効果が上がることを確認できた。一方、2 名が設定した仮定の検証完了に至っておらず、その要因を踏まえた対策の実施が必要となる。

(3)アンケート回答に関する課題

アンケート内容からはプロトタイプのプログラムソースコードの詳細な理解や応用には、まだ課題があることが解る。

5.4.2. 実践における課題への対策

宿題 2 について、自分の仮定設定は検討できているが、プロトタイプへ反映して動作検証をするまでに至っていない受講生が、5 名中 2 名となった。実習では乱数の発生方

法や各種ライブラリも含めた Python の事前課題を実施の上、講義での各プログラム解説を行った。その結果、5 名中 3 名が検証まで実施できており、成果が向上しているが、2 名の受講生は仮定の実証を完了するまでには至らなかった課題が残る。この要因は仮定の設定内容から 2 つの分析要素が発生することから、データ生成や機械学習のためのコード修正の難易度が上がり対応しきれなかったことが理由となっている。この対策としては、これまで提出された 5 つの仮定におけるデータ生成方法を典型的な例に分類して、各プログラムのソースコードに織り込み、これをサンプルコードとすることで設定した仮定のソースコードへの実装が促進されるものと判断している。

5.5. まとめ

デジタルツインの実現において物理システムに特化した業務ノウハウを必要とする部分に仮定を置き、その仮定に基づいたデータの生成、DLモデルの学習、チューニング、デジタルツインへの学習済みDLモデルの実装、設定した仮定の検証というシステム構築を行うためのプロトタイプの開発とそのシステム構築実習によって、デジタルツインの将来予測システムの構築力育成手法を提案し、その実践と評価について論じてきた。

本提案内容にしたがって、業務ノウハウへの仮定の設定、設定に基づくデータの生成、チューニングによる学習済みモデルの確定、プロトタイプへの学習済みモデルの実装、設定した仮定の検証などのシステム構築を講座の宿題として実践し、これらの成果を受講生間で共有することで、デジタルツインのDLによる将来予測システムの構築力育成を図った。その結果、LSTMハイパーパラメータの調整では評価平均4、仮定設定に基づくデジタルツイン構築、検証では評価平均3.6となり、実習の成果目標（評価平均3点以上）を達成しており、技術者育成に成果があったと判断している。しかし、受講生全員が設定した仮定に基づいたプロトタイプへの実装と検証を完了する、という結果には到達できていない。この課題解決のためには、受講生のPythonスキル、ディープラーニング知識を見極めた基礎教育の事前実施が重要であると共に、既に提出された5つの仮定設定の基本的パターンをプロトタイプに織り込み、サンプルコードとすることが有効な対策になると認識している。

今後、これらの課題解決を図ることでデジタルツインのシステム構築力の教育法を強化すると共に、さらにプロトタイプの有効性向上のために仮定設定の応用例拡大を図り、デジタルツインの活用促進に寄与できるよう、研究を進めていく予定である。

6. 結言

本研究の目的は、DL システム構築の課題であるデータ準備方法、DL モデルチューニング作業、DL モデル評価について、効率的にシステム構築を行う手法を研究し、企業における DL 活用促進、DX 推進、デジタルツイン活用促進を図り、企業価値向上に貢献することであった。

そのために、以下の 3 つのテーマについて研究を行った。

- 1) 研究 1 : DL 応用プロトタイプ開発手法の研究
- 2) 研究 2 : DX 推進プロトタイプ開発と技術者育成手法の研究
- 3) 研究 3 : デジタルツインプロトタイプ開発と技術者育成手法の研究

本研究の全体像を図 6.1 に示し、各研究の成果を以下にまとめる。

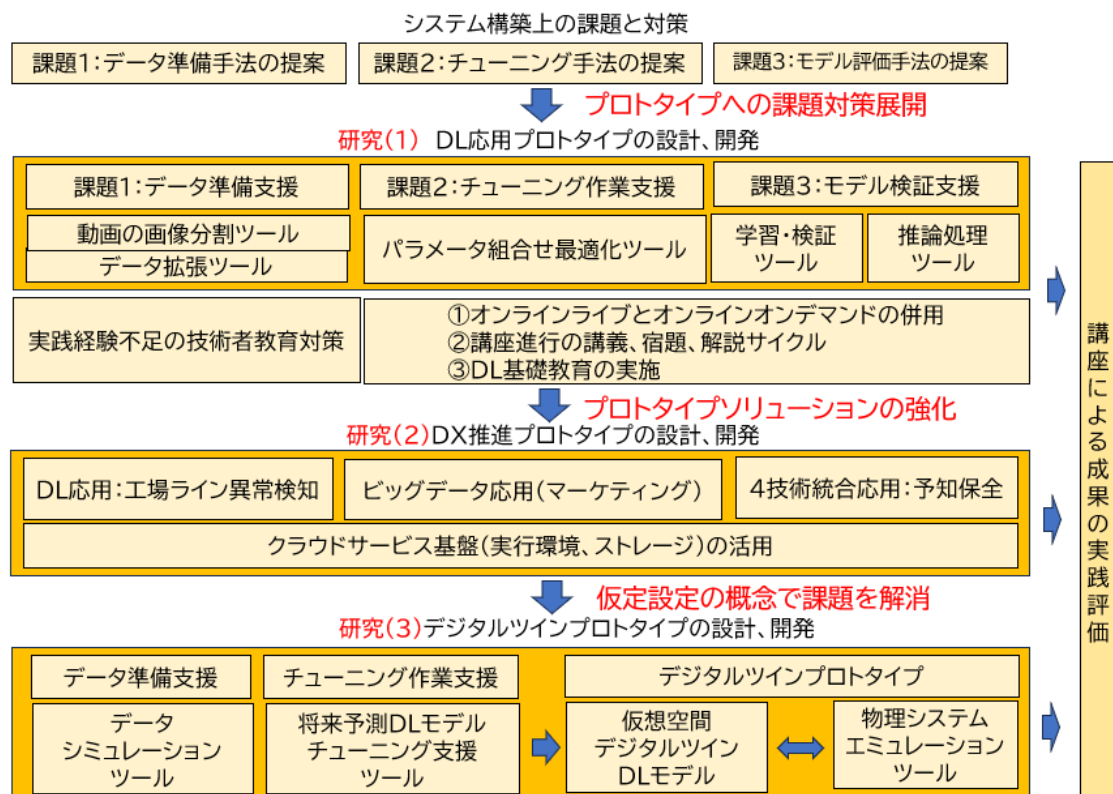


図 6.1 本論文の研究成果の構成図

(1)DL 応用プロトタイプ開発手法の研究

本研究では、データ準備においては、クラス分類におけるクラス内のデータ網羅性の考え方や汎化性能の特性を踏まえた効率的なデータ準備手法を研究した。チューニングでは定型的な手法として、初期値の設定、特性を確認するハイパーパラメータの特定、その結果を踏まえたグリッドサーチなどによる最適なハイパーパラメータの組み合わせ

せの確定、その結果でも要件を満たさない場合はデータの再確認とモデルの層数などの構造を再評価するという手順を提案した。モデルの評価については、要件に基づいた評価が重要であることを提案した。

これらの3つの課題に対する提案に基づいたプロトタイプを開発し、その成果を DL 応用講座で検証した。受講生には、実運用でのデータ入力に関する開発や DL モデルの認識結果を上位システムに伝達して、システムとして利活用するための開発などの経験を積む必要はあるが、実務での実践経験がない受講生が対象であっても DL 応用のシステムを構築できる技術者育成に成果を上げることができた。

一方、システム構築時の課題であったデータ準備やチューニングについて、十分な理解や宿題成果に結びつかなかった受講生も存在する。これらの対策については、更なる解説の充実、手順化の促進が必要であることを確認した。

(2)DX 推進プロトタイプ開発と技術者育成手法の研究

本研究では、DL 応用プロトタイプの成果とその考え方を活用して、DX 推進の主旨に沿った実践的な業務改革を想定した IoT、AI、ビッグデータ、クラウド、その統合的な DX 推進プロトタイプを開発した。その成果を実習講座に展開し、受講生の宿題の実施成果を確認することで提案手法の評価を行った。その結果、実践的なプロトタイプ構築の宿題を通して、DX 推進に実務経験がない技術者であってもシステム構築を期待通りに実行できることを確認した。

一方、宿題の完成度について、十分な成果が得られない受講生が残っている。これらについては、宿題実施の実演の充実、受講生のスキルに応じた Python 基礎講座の事前実施が必要であることを確認できた。

(3)デジタルツインプロトタイプ開発と技術者育成手法の研究

本研究では、DL 応用プロトタイプ開発手法の考え方を活用し、デジタルツインの物理システムに特化したモデリング技術や収集データに仮定をおく手法で、デジタルツインプロトタイプの開発を行った。また、受講生自ら仮定設定を行い、その仮定をプロトタイプに実装し、検証する教育手法や受講生のスキルに応じて Python の基礎講座や DL 基礎講座の事前実施を行う手法などを提案した。これらの成果について、講座の実践で検証を実施した。その結果、デジタルツインの実務経験がない技術者であっても、多様な仮定に基づく時系列データの生成とデジタルツインのシステム構築を実現しており、提案内容の有効性を確認できた。

一方、仮定に基づく時系列データの生成やプロトタイプへの実装、検証を完結できない受講生が残った。本件については、これまでの仮定内容を類型化し、そのコーディング例をプロトタイプ内で示すことが必要であることを確認した。

以上の研究成果により、DL システム構築の課題であるデータ準備、DL モデルチューニング、DL モデル評価について、効率的にシステム構築を行う手法を提案し、その手法に沿ったプロトタイプを開発することで、企業における DL 活用促進、DX 推進、デジタルツイン活用促進を図り、企業価値向上に貢献できるものと評価している。

今後は、本研究での成果の活用と共に、確認できた課題への取り組みを促進することに加えて、DL 応用プロトタイプについては、DL モデルの推論の応用例の拡大を図ると共に、実践している社会人への講座を継続し、その結果をフィードバックしてプロトタイプの改善を図り、DL 応用の普及に貢献していく予定である。

DX 推進プロトタイプについては、特に DX 推進のための基盤技術を統合実習するプロトタイプの DX 推進応用例を拡大する共に、社会人や学生に対する講座を検討し、DX 推進の普及に貢献していく予定である。

また、デジタルツインプロトタイプについては、物理システムに特化したモデリング技術の仮定設定に対する応用例を拡大すると共に、社会人や学生に対する講座を検討し、デジタルツイン応用の普及に貢献していく予定である。

謝辞

本研究の学位論文提出にあたりまして、ご多忙の中で多くの時間を割いて主査としてご指導頂きました東京電機大学 大学院 先端科学技術研究科 神戸英利教授に厚く御礼を申し上げます。

東京電機大学 小泉寿男名誉教授には、研究方針策定、論文投稿、査読回答など長きにわたる研究活動の様々な場面におきまして、ご指導、ご助言、激励を頂きました。また、サイバー大学 清尾克彦名誉教授、大江信宏教授には、社会人を対象としたDL 応用講座の実施に多大なご支援をいただきました。慶応義塾大学 システムデザイン研究科 井上雅裕特任教授、芝浦工業大学工学部 中島毅教授には学生を対象とした講座の開催に、多大なご協力を頂きました。東京電機大学 理工学部 秋山康智教授には国際会議の参加においてご指導をいただきました。

皆さまに心から感謝申し上げます。

最後に論文作成を陰ながら応援してくれた私の家族に感謝致します。

参考文献

1 章分

学術論文

- 1) 大高謙二、清尾克彦、大江信宏、澤本潤、井上雅裕、小泉寿男 「応用プロトタイプによるオンライン実習型ディープラーニング教育方式とその実践評価」、電気学会(IEEJ) 論文誌 C Vol.143 No.6 pp.597-607 (2023)
- 2) 大高謙二、大江信宏、清尾克彦、井上雅裕、神戸英利、小泉寿男 「プロトタイプ構築をベースとした DX 推進教育法の提案と実践評価」、工学教育(J. of JSEE), 第 71 巻 4 号 pp.53-61(2023)
- 3) 大高謙二、中島毅、大江信宏、清尾克彦、井上雅裕、神戸英利、小泉寿男 「サイバーフィジカルシステムを基盤とするデジタルツインプロトタイプ構築実習型教育法」、電気学会 (IEEJ) 論文誌 C Vol.143 No.11 pp.1045-1055 (2023)

国際会議論文

- 1) Kenji Ohtaka, Nobuhiro Ohe, Katsuhiko Seo, Tsuyoshi Nakajima, Masahiro Inoue, Hisao Koizumi 「Online Deep Learning Education Method Based on Prototype Construction and Its Practical Evaluation」, IEEE GCCE2023 pp.666-670 (2023)

参考文献

- 1) 独立行政法人・情報処理推進機構：「AI 白書 2019」、PP.100-111
- 2) 独立行政法人・情報処理推進機構：「AI 白書 2020」、PP.505-525
- 3) 統合イノベーション戦略推進会議：「AI 戦略 2019～人・産業・地域・政府全てに AI ～」、PP.8-20 (2019 年 6 月 11 日)
- 4) 情報処理推進機構：「DX 白書 2021」、Web ページ、
https://www.ipa.go.jp/ikc/publish/dx_hakusho.html、2021、参照日：2022-9-3
- 5) 経済産業省：「DX レポート ～ IT システム「2025 年の崖」の克服と DX の本格的な展開～」、Web ページ、
https://www.meti.go.jp/shingikai/mono_info_service/digital_transformation/20180907_report.html、2018、参照日：2022-8-27
- 6) 国立研究開発法人科学技術振興機構 研究開発戦略センター：「調査報告書 デジタルツインに関する国内外の研究開発動向」、PP.1-40 (2022 年 3 月)
- 7) 総務省情報流通行政局情報通信政策課情報通信経済室 (委託先：株式会社エヌ・ティ・ティ・データ経営研究所)：「デジタルツインの現状に関する 調査研究の請負 成果報告書」、PP.4-21 (2021 年 3 月)
- 8) 孝忠 大輔：「AI 時代の人材育成」、NEC 技報、Vol.72 (2019 年)

<https://jpn.nec.com/techrep/journal/g19/n01/190104.html>

- 9) 経済産業省：「AI人材育成の取組」、PP.1-15（2018年）
- 10) 文部科学省：「AI戦略等を踏まえたAI人材の育成について」PP.1-23（2019年11月1日）

2章分

参考文献

- 1) 独立行政法人・情報処理推進機構：「AI白書2019」、PP.100-111
- 2) 独立行政法人・情報処理推進機構：「AI白書2020」、PP.505-525
- 3) 統合イノベーション戦略推進会議：「AI戦略2019～人・産業・地域・政府全てにAI～」、PP.8-20（2019年6月11日）
- 4) 島田 孟親, 伊藤 開登, 荒井 康裕, 國實 誉治, 小泉 明：「ディープラーニングを用いた漏水検知モデル（I）-モデルに使用する画像サイズに関する分析-」、令和3年度全国会議（水道研究発表会）講演集（2021）
- 5) Pin Wang, En Fan, Peng Wang：「Comparative analysis of image classification algorithms based on traditional machine learning and deep learning」、Pattern Recognition Letters Volume 141, January 2021, Pages 61-67
- 6) 青柳 美輝, 塚本 雄基：「理工系学生に対するデータサイエンス数理コースのシステム構築-今後のAI教育に向けて-」、日本工学教育協会, 関東工学教育協会, 工学教育研究講演会（2022）
- 7) 経済産業省：「AI人材育成の取組」、PP.1-15（2018年）
- 8) 文部科学省：「AI戦略等を踏まえたAI人材の育成について」PP.1-23（2019年11月1日）
- 9) 孝忠 大輔：「AI時代の人材育成」、NEC技報、Vol.72（2019年）
<https://jpn.nec.com/techrep/journal/g19/n01/190104.html>
- 10) 内閣府・科学技術・イノベーション推進事務局：「AI戦略2022の概要」、pp.2-11（2022年）
- 11) 一般社団法人・日本ディープラーニング協会：「資格試験範囲」、（2022年）、
<https://www.jdla.org/>
- 12) 大高謙二, 清尾克彦, 大江信弘, 澤本潤, 井上雅裕, 小泉寿男：「応用プロトタイプ構築による実習型ディープラーニング教育方式とその実践評価」、2021年電気学会C部門大会 発表論文 GS7-2（2021年）、<https://www.iee.jp/wp/wp-content/uploads/eiss/conf2021/html/class/class4.html#GS7>
- 13) 情報処理推進機構：「DX白書2021」、Web ページ、
https://www.ipa.go.jp/ikc/publish/dx_hakusho.html、2021、参照日：2022-9-3

- 14) 経済産業省：「DX レポート ～ IT システム「2025年の崖」の克服とDXの本格的な展開～」、Web ページ、
https://www.meti.go.jp/shingikai/mono_info_service/digital_transformation/20180907_report.html、2018、参照日：2022-8-27
- 15) 経済産業省：「デジタルトランスフォーメーションを推進するためのガイドライン（DX 推進ガイドライン）」、Web ページ、
<https://www.meti.go.jp/press/2022/09/20220913002/20220913002.html>、2018、参照日：2022-8-27、注）本ガイドラインは「デジタルガバナンス・コード 2.0」の策定に伴い統合された。新 web ページ、
<https://www.meti.go.jp/press/2018/12/20181212004/20181212004.html>、2022、参照日：2023-3-7
- 16) 内閣府科学技術政策：「Society 5.0」、Web ページ、
https://www8.cao.go.jp/cstp/society5_0/index.html、2016、参照日：2022-8-28
- 17) 田口敏行：「環境と経営（第 27 巻第 2 号）」教育の DX 化に向けた数理・データサイエンス・AI 教育の在り方について — 大学レベルでのカリキュラム開発の留意点 一、静岡産業大学編集、Web ページ、
https://shizusan.repo.nii.ac.jp/?action=pages_view_main&active_action=repository_view_main_item_detail&item_id=1909&item_no=1&page_id=25&block_id=75、2021、参照日：2022-9-11
- 18) 岸和良、杉山辰彦、稲留隆之、中川邦昭、辻本憲一郎：「DX 人材の育て方 ビジネス発想を持った上流エンジニアを養成する」、翔泳社、PP.1-224、2022
- 19) 大江信宏、北上眞二、米盛弘信、井上雅裕、汐月哲夫、小泉寿男：「M2M のプロトタイプ構築によるものづくり教育システムの提案と実践」、電気学会論文誌 A（基礎・材料・共通部門誌）2015 年 11 月号 Vol.135、No.11、pp.655-665、2015
- 20) 大高謙二、清尾克彦、大江信宏、澤本潤、井上雅裕、小泉寿男：「応用プロトタイプ構築による実習型ディープラーニング教育方式とその実践評価」、2021 年電気学会 C 部門大会 発表論文 GS7-2、Web ページ、<https://www.iee.jp/wp/wp-content/uploads/eiss/conf2021/html/class/class4.html#GS7>、2021、参照日：2022-8-10
- 21) 半田 智子、天羽 千恵美：「デジタルブートキャンプによる人材育成の実践的取組 — デジタルトランスフォーメーションを実現するデジタルイノベーターの育成 —」、情報処理学会、特集：DX 時代のスキル標準と人材育成（2020）
- 22) 一般社団法人データサイエンティスト協会、Web ページ、<https://www.datascientist.or.jp/>、2013、参照日：2022-9-10
- 23) 一般社団法人日本ディープラーニング協会、Web ページ、<https://www.jdla.org/>、2017、参照日：2022-3-10

- 24) デジタルリテラシー協議会、Web ページ、<https://www.dilite.jp/>、2021、参照日：2022-9-10
- 25) インターネット白書編集委員会：「インターネット白書 2022—デジタルツイン実現への道—」、pp22-80（2022年2月4日）
- 26) 国立研究開発法人科学技術振興機構 研究開発戦略センター：「調査報告書 デジタルツインに関する国内外の研究開発動向」、PP.1-40（2022年3月）
- 27) (総務省情報流通行政局情報通信政策課情報通信経済室（委託先：株式会社エヌ・ティ・ティ・データ経営研究所）：「デジタルツインの現状に関する 調査研究の請負成果報告書」、PP.4-21（2021年3月）
- 28) Guodong Shao, Moneer Helu : 「Framework for a digital twin in manufacturing: Scope and requirements」、Manufacturing Letters Volume 24, April 2020, Pages 105-107
- 29) 元村 亜紀, 湯浅 知英, 山中 哲志：「建設施工段階の汎用的なデジタルツインの実現—CPS 施工管理システムの開発—」、AI・データサイエンス論文集 2023 年 4 巻 2 号 p. 89-96
- 30) デジタルツイン関連論文例 工学教育研究講演会講演論文集 (第 70 回年次大会)：「デジタルツインを用いた産業用ロボット教示実習のカリキュラムの開発」、PP240（2022年）、他
- 31) 小宮昌人(日経 BP)：「メタバース x デジタルツインでビジネスが変わる メタ産業革命」、PP20-453、(2022年10月)
- 32) 情報処理推進機構：「DX 白書 2021」、PP.1-180（2021年10月）
- 33) 文部科学省：「AI 戦略等を踏まえた AI 人材の育成について」、PP.1-23（2019年11月1日）
- 34) 大高謙二、中島毅、大江信弘、清尾克彦、井上雅裕、神戸英利、小泉寿男：「サイバーフィジカルシステムを基盤とするデジタルツインのプロトタイプ構築実習型教育法」、令和 4 年電気関係学会関西連合大会 発表論文 G11-3（2022年）、<https://kjciee.org/prog/2022/program/program.html#G11-1>