

品質コスト削減による 超高効率化社会の実現

～製造業が抱える課題～

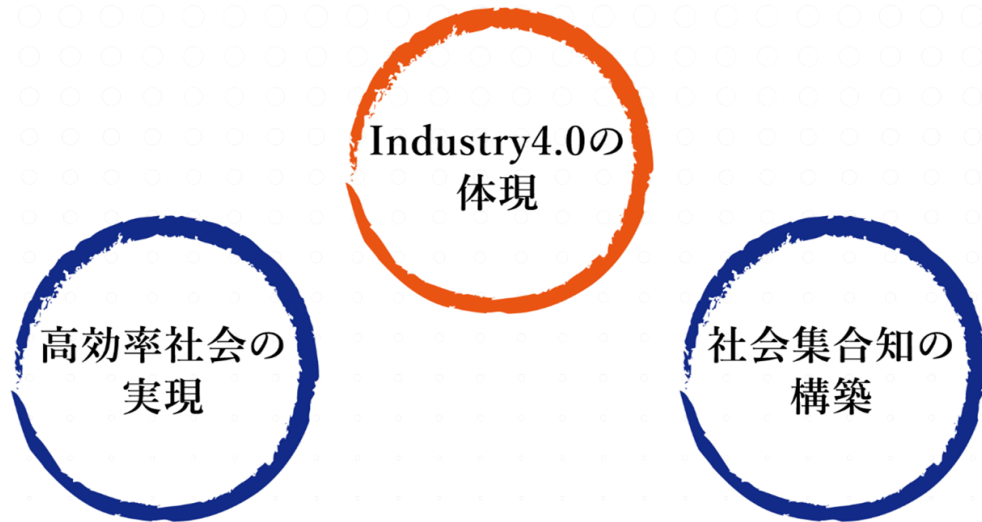
Pain：生産性と品質の両立

Solution：機械制御に特化した超高速EdgeAI



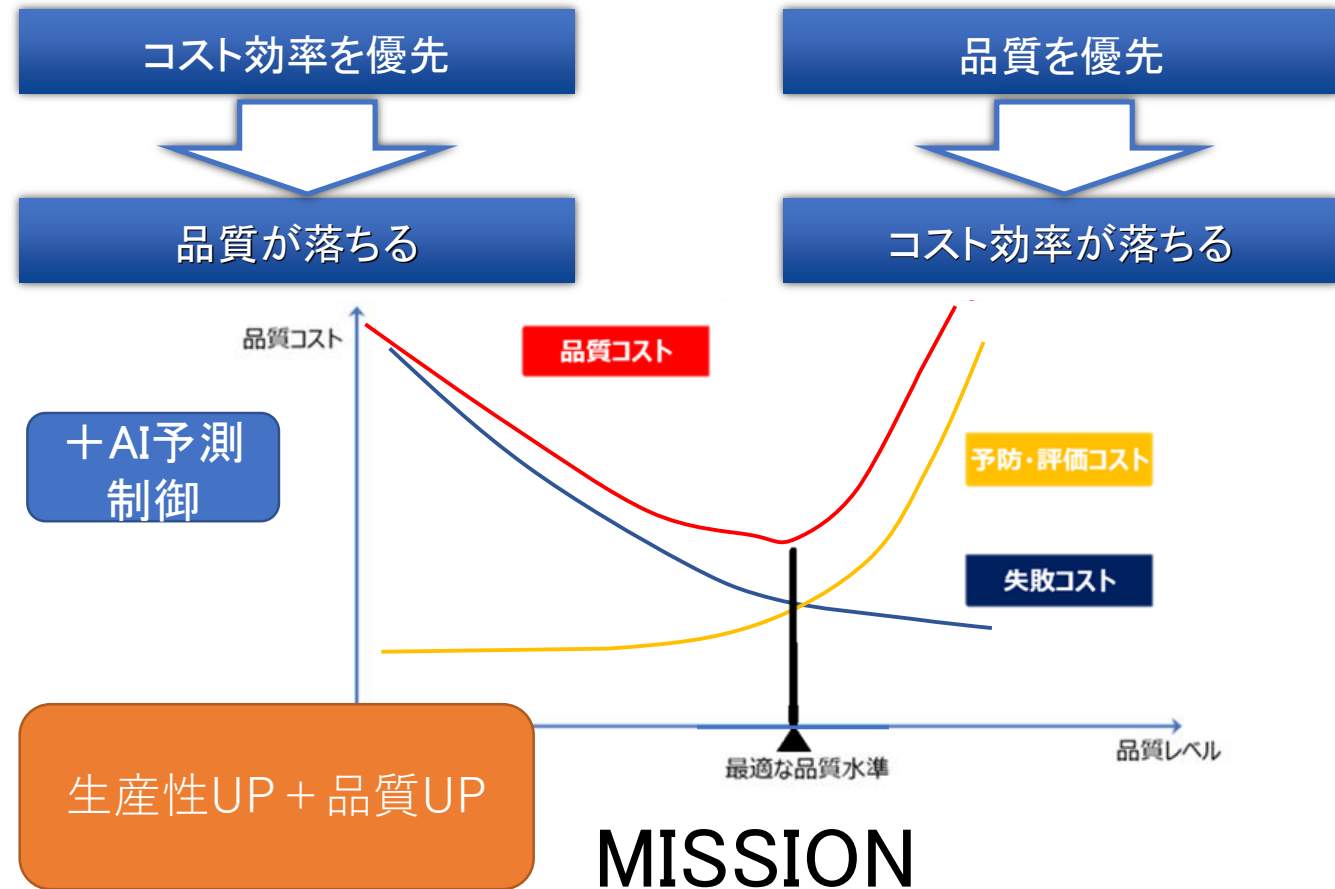
J-Startup

機械を賢くし、身近な生活を豊かにします



VISION

生産性と品質の両立
機械制御に特化した超高速EdgeAIの開発と提供



社名: 株式会社エイシング

英語表記: AISing Ltd.

代表者: 出澤 純一

住所: 〒107-0052

東京都港区赤坂6丁目19番45号 メルクビル1F

資本金: 1億9,900万円(資本準備金9,900万円含む)

設立: 2016年12月8日

決算月: 5月

<受賞暦>

- ・ 大学発ベンチャー表彰2018 経済産業大臣賞
- ・ 起業家万博2018
総務大臣賞
セールスフォース賞
チャンネルベンチャーズ賞
- ・ Mizuho Innovation Award 2018-4Q
- ・ 経済産業省「J-Startup」入選
- ・ SPARK! TOHOKU2017 NICT賞
- ・ 第1回マリンテックグランプリ
三井化学賞
日本ユニシス賞
- ・ スタートアップワールド
TOP10 日本マイクロソフト賞
- ・ MUFG RiseUpFesta2018
ロボット・先端技術部門 最優秀賞
- ・ Microsoft Innovation Award2018 優秀層
- ・ イノベーションリーダーズサミット TOP20
- ・ 未来2017 日本総研賞
- ・ SEMICON Japan INNOVATION VILLAGE グランプリ

機械制御＋AI
エキスパート



CEO 出澤 純一

学生時代に早稲田大学ビジネスコンテスト「ワセダベンチャーゲート」最優秀賞
早稲田大学大学院理工学研究科精密機械工学専攻 修士卒業
卒業後は会社経営と並行しAIアルゴリズムの研究も平行して行う
2016年12月株式会社エイシング設立




CTO 金 天海

早稲田大学工学部卒業後、理化学研究所、ホンダ・インスティテュート・ジャパンに勤務。
現在岩手大学 電気情報システム工学科 准教授として弊社CTOと兼務。
文部科学省 科学技術・学術政策研究所より「ナイスステップな研究者2017」に選出。

DBT




AI algorithm



Embedding



AI Chip

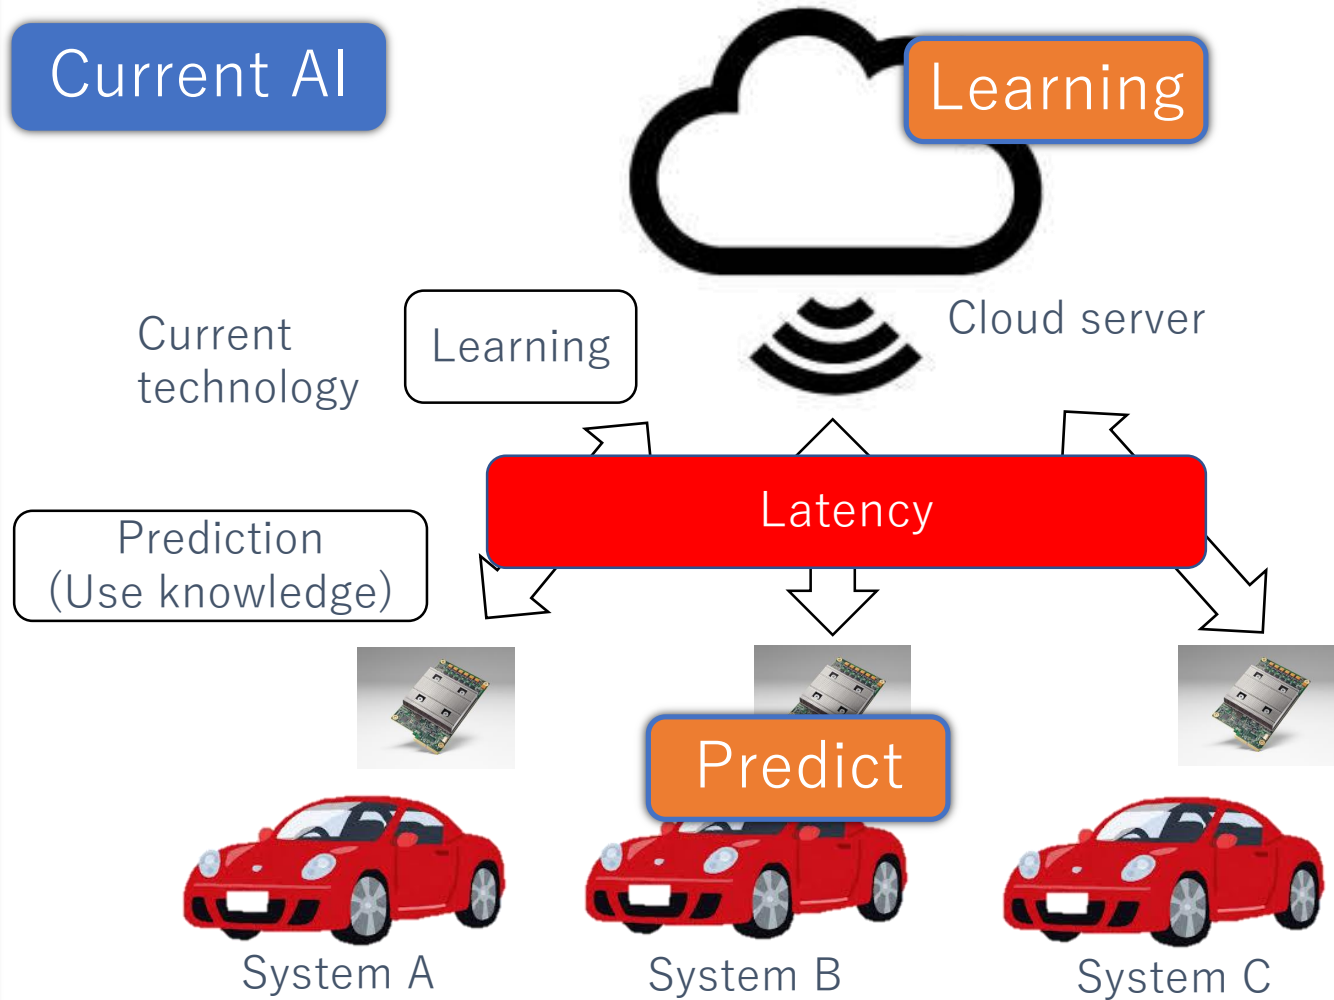


Learning + Predict



System

Current AI



エッジAI × 機械制御

■ 機械への知見

- ・ 機械制御を考慮した適切なデータ処理

■ AIをアルゴリズムから開発

- ・ ニーズに基づく新しいAIアルゴリズムの設計

■ 組込への知見

- ・ 組込の対象に合わせてAIをカスタマイズ

①認識

- ・ 自己運動の認識
- ・ 対象位置
- ・ 対象物の認識



②目標設定

- ・ 経路の計画
- ・ 行動の計画



AISing得意領域

③制御

- ・ フィードバック制御
- ・ 予測制御




AiiR (AI in Real time) ソリューション

軽量実装 + 少変量対応

リアルタイム性 + 逐次学習

機械制御用AIアルゴリズム
DeepBinaryTree(DBT)



製造業




DBT

精度重視 + 多変量対応

リアルタイム性 + 逐次学習

ランダムフォレスト強化版
Self Adapted Random Forest(SARF)



SARF

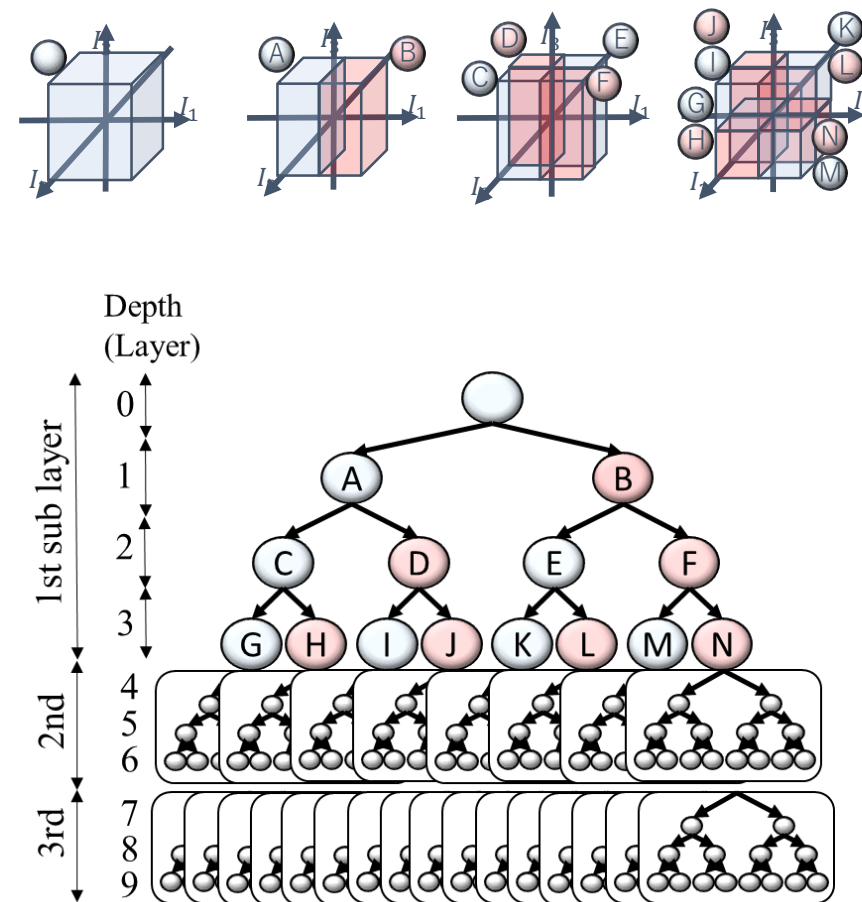
AISing AiiR(AI in Real time)
ソリューション

独自AIアルゴリズム

Deep Binary Tree

DBT

- ・ ストリーミング学習（継足学習可）
- ・ 軽量・安価なデバイスでも稼働可
- ・ 説明可能AI




Up-to-date **Live training**

Value

Can always **keep updating** the model so it dose not deteriorate

Can make **individual** control model considering individual differences

Does not deteriorate



Consider individual differences



Processing on **the edge side**

Value


The control cycle is **never delayed**
→ The calculation time is **constant**

Low performance computers are
sufficient to run the algorithm



 **#PIZERO**

Number of training data is 13.
Average of error is 0.16762973053259142.
Processing time of learning is 94 microsecond.
Processing time of prediction is 3 microsecond.



Explainable AI

Single tree structure



Can explain why the output was
(Answer by the width of the input space)




Image of state space assignment






Image of structure of DBT
(※When learning to infinity)

Deep Learningとの比較

	DeepLearning	DBT
入力種別数	多い (数百万)	少ない (100個程度)
メンテナンスコスト	高い	低い
学習速度	遅い	速い
説明可能	困難	可能
複雑タスクへの対応	可能	不向き
学習精度	メンテナンス次第	メンテフリーで高精度
追加学習	静的な対応	動的な対応
得意分野	画像認識・処理、音声認識、自然言語処理	機械制御、統計解析、予測制御

DLは認識を司り頭頂葉的な働きに近く、DBTは反射的な反応ができる小脳的な働き



AiR's Use Case (実際の実証実験事例)


● 個体差補正



経年劣化への対応

製品個体差補正

Blue Ocean




FAラインの効率化



生体情報の
個人差補正

● 予測制御



空調制御



スリップ予測



制振制御




突風への対応

● 複雑系




転倒防止制御



散水消雪器制御

● 職人の勘



掘削制御



ブレーキ異常検知



AiiR SaaS

AiiR (DBT,SARF) のSaaSを月額制で環境をご提供します。
Rest APIを用いた御社システムとの連動も可能です。

Sier,メーカー



AiiR Chip

AiiRを実装したZYNQ 7020やHiKey960を部品販売します。

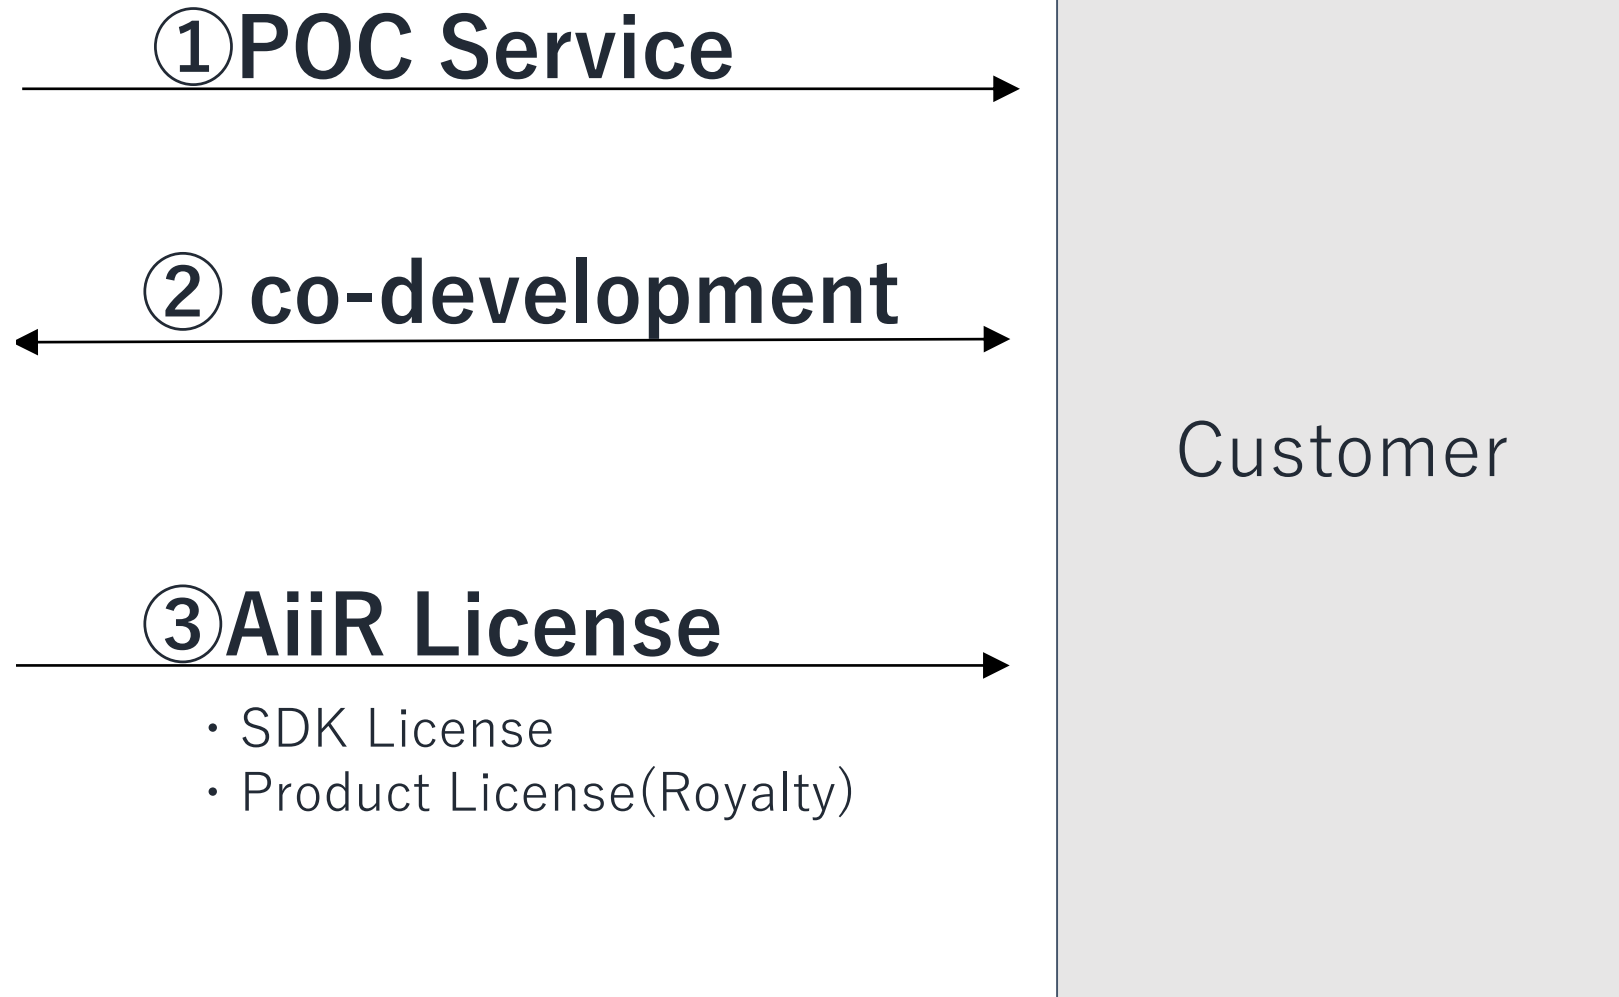
Sier,メーカー



AiiR License

AiiRのRTL形式などのバイナリーIPでライセンス契約が可能です。
(数量と金額でご相談)

メーカー



要件定義

1ヶ月

課題明確化



データ内容確認



POC要件定義

POC

1~2ヶ月

Annotation



学習アルゴリズム選定



レポート報告

システム開発・導入

AIシステム構築



個別システム構築

共同開発

運用

アルゴリズム
カスタマイズ



検証作業



Version Up

AiiR board 開発計画

ボード名: STM32F746G
メーカー: STマイクロ
搭載SoC: Cortex M7



ボード名: Nucleo Board
STM32F091RC
メーカー: STマイクロ
搭載SoC: Cortex M0



ボード名: AiiR1
メーカー: AISing
搭載SoC: Xilinx ZYNQ 7010
またはZYNQ 7020



※イメージ

ボード名: HiKey960
メーカー: LeMaker
搭載SoC: HiSilicon Kirin960



ボード名: STM32 Nucleo Board
STM32L476RG
メーカー: STマイクロ
搭載SoC: Cortex M4



FPGA型式: ZYNQ 7010
またはZYNQ 7020
メーカー: Xilinx



2019

2020

2021

2022

事例1:オムロン社との共同開発

機械:巻取り機

(リールに巻かれているシートを張り合わせる)

課題:巻取り開始直後に不良品が発生

原因:振動

解決手順:①DeepBinaryTreeで振動を予測

②予測に合わせて振動を補正

※DeepBinaryTree(DBT)はエイシング社が独自開発したAIアルゴリズムです

結果:不良品の発生を1/10に削減

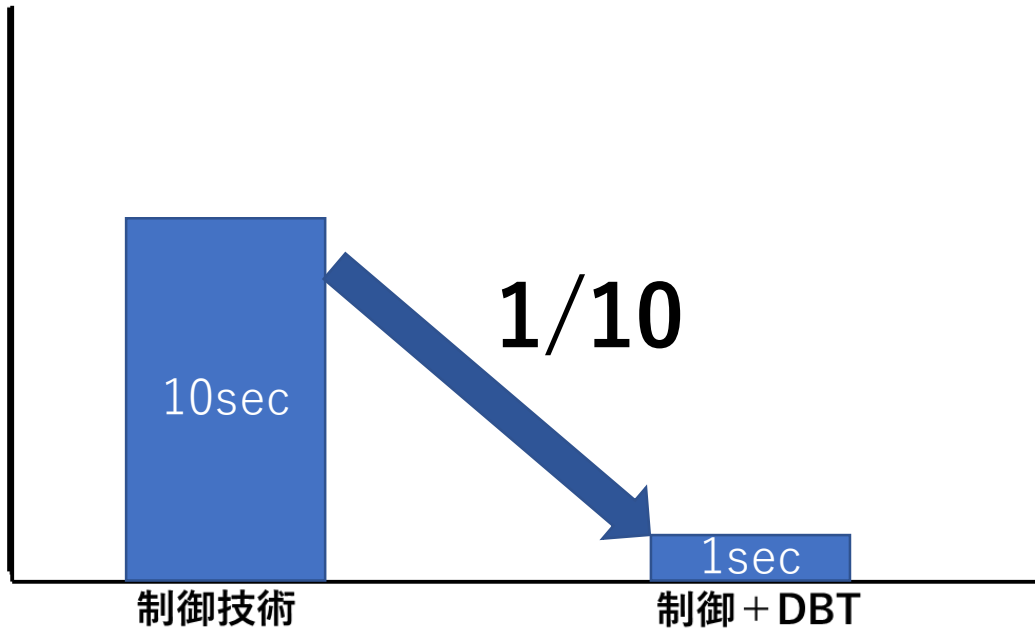


OMRON




年間数千万円の削減
(1工場あたり)

不良品
発生区間



巻取り機



事例2: デンソー社との共同開発

対象: ドローン(プロペラ6発, ピッチ制御機構)

目標①: 危険予測回避

課題: 危険状態に達してから回避する


目標②: より安定した飛行

課題: 高い運動性能(多発駆動・可変ピッチ)
とトレードオフの安定性



目標①: 危険予測回避

1. 機体の傾きをDBTで将来予測
2. 危険状態になる前に回避




目標②: 安定飛行

ピッチ角の変化による運動の**変化**をDBTで**予測**

予測制御

- ・高効率(なめらか)
- ・安定



事例3: 散水消雪機の最適稼働

対象: 上越新幹線の散水消雪機

目標: 消費燃料の削減

- 課題:
- ・加熱しすぎると燃料が無駄(年間7億円)
 - ・温度変化に係る要因が無数に存在
 - ・返送水温度が0°Cを下回ると凍結


解決法: AIを用いた適切な温度指令値の予測



年間2億円の削減
(JR東日本エリア)


現状

返送水の予測が難しく
余剰熱が発生することがある



理想

1°C~2°Cで水が返ってくる



事例4:ブレーキの異常検知

対象: E235系(山手線)のブレーキシステム

目標: ブレーキの異常検知

- 課題:
- ・異常の種類が多数存在
 - ・データのラベル付けができない
 - ・異常に関係する要因がわからない

解決法: AIを用いた異常度(数値)の算出



データ知見 メンテナンス





データ
分析



分析知見 AI・機械制御

今後の目標

定期点検の時のデータだけでなく
運転中のデータから異常状態を自動判定



異常度の算出まで実現済

事例5:シールドマシンの自動制御

機械:トンネル掘削用のシールドマシン

大手建設業様

目標:①計画線からのズレをAIで将来予測
②現場ごとの特性によらず安定した自動運転


解決法:DBTによるオンライン学習

※DeepBinaryTree(DBT)はエイシング社が独自開発したAIアルゴリズムです



DBT

1.2m先のズレは?



工事効率UP
+
工数削減(1kmあたり2億円)

結果:数mmの誤差値

倒立振子の制御システム

システムの入力：ロータリエンコーダからの角度


システムの出カ：DCモータに加える（あるいは印加する）電圧

ロータリエンコーダ

コンピュータ
(Raspberry Pi 3)

モータドライバ

DCモータ




倒立振子の制御システム（PID制御）

- ・パラメータチューニングに要した時間：約30分

<結果>

- ・倒立状態に戻る場合もあるが、戻らない場合もある。




倒立振子の制御システム（DBTを用いた制御）

- ・ 学習用データ 1 分間取得

<結果>

- ・ 倒立状態へ必ず戻る
- ・ 収束間際に**発振**する



チューニングなし

- ・ 学習用データ追加で2分間取得


<結果>

- ・ 倒立状態へ必ず戻る.
- ・ 発振は**低減**した.

機械自身が学習し
賢くなっていく

追加学習で成長

チューニングなし






AISing

～機械に学習の機会を～

技術資料

DBT新規性 1 : 鍛造モデルによる学習



$$\hat{f}(i) \leftarrow \phi(i)o_k + (1 - \phi(i)) \hat{f}(i)$$

自由鍛造と本学習則のアナロジー

\hat{f}	金属表面
i_k	金槌の打点
o_k^*	変形目標値
$\phi(i)$	更新率 (打点を最大として単調減少)




学習アルゴリズム：関数形状を整える



自由鍛造：金属形状を整える

$$\hat{f}(i) \leftarrow \phi(i)o_k + (1 - \phi(i)) \hat{f}(i)$$

各セルを上式で更新




正解： $f(i) = \sin(i_1)$

組込みAIに必要なスペック

- 定数オーダーO(1)による計算アルゴリズム (一定制御周期)
⇒ 達成 (計算速度・メモリ消費量について要改良)
- 自動パラメータ調整/ パラメータレス ⇒ ガウス関数の分散
- 信頼性 (収束証明, 決定論的計算)
⇒ ガウス関数の領域を徐々に狭めれば収束するが・・・
決定論的な学習プロセス (達成)
- オンライン性 ⇒ 達成

【データ取得プロセス】

入力データ $i = (i_1, i_2)$ をランダムに
取得して出力データ o_k を取得




【学習プロセス】

i を中心としたガウス関数を更新率
 $\phi(i)$ にあてはめて \hat{f} を更新

【DBT：鍛造モデル】

$$\hat{f}(i) \leftarrow \phi(i) o_k + (1 - \phi(i)) \hat{f}(i)$$

\ 関数 \hat{f} の更新率が単調減少関数 (e.g. ガウス関数)



【従来法1：Radial Basis Function ネットワーク】


$$\hat{f}(i) = \sum w_i G(\mu, \sigma)$$

\ 関数 \hat{f} の基底がガウス関数 $G(\mu, \sigma)$


【従来法2：Schaal 関数を用いたEMアルゴリズム】

関数 \hat{f} の基底が
ガウス関数 $G(\mu, \sigma)$ の和

鍛造モデルによる平面データ
($o = const.$) の学習結果



Radial Basis Function ネットワーク





Schaal関数

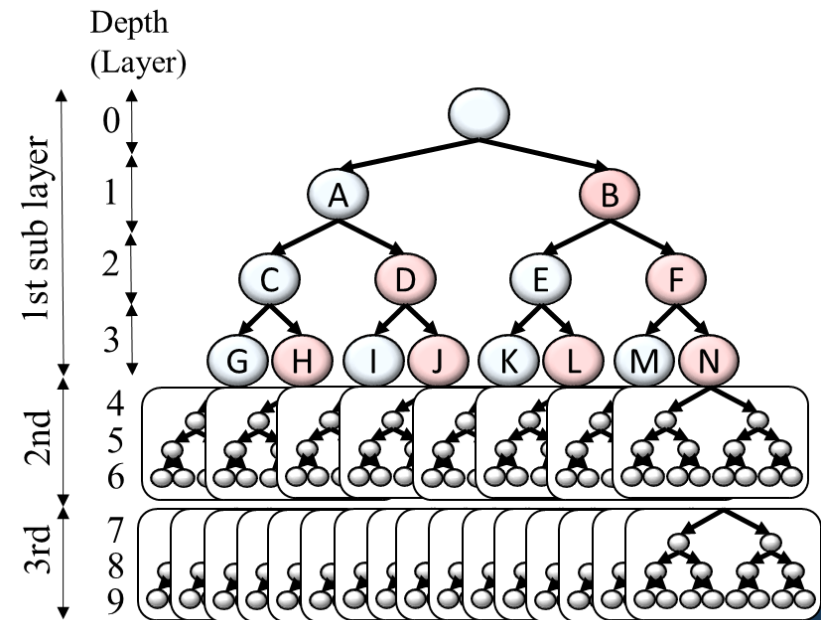
予め準備する基底の数や種類に
タスク毎の調整を要する

DBT新規性 2 : 木構造による鍛造モデルの実装

単調減少関数による更新率 $\phi(i)$ を表現するために、木構造を用いる



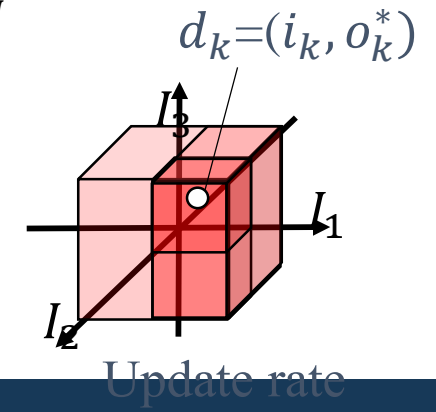
出力予測値 : \hat{o}_R \hat{o}_B \hat{o}_F \hat{o}_N



$$\hat{f}(i) \leftarrow \phi(i) o_k + (1 - \phi(i)) \hat{f}(i)$$

$$\hat{o} \leftarrow \frac{1}{u+1} o_k + \left(1 - \frac{1}{u+1}\right) \hat{o}$$

入力空間の包含関係 : $S_R \supset S_B \supset S_F \supset S_N$
 訓練データ数 : $u_R \geq u_B \geq u_F \geq u_N$



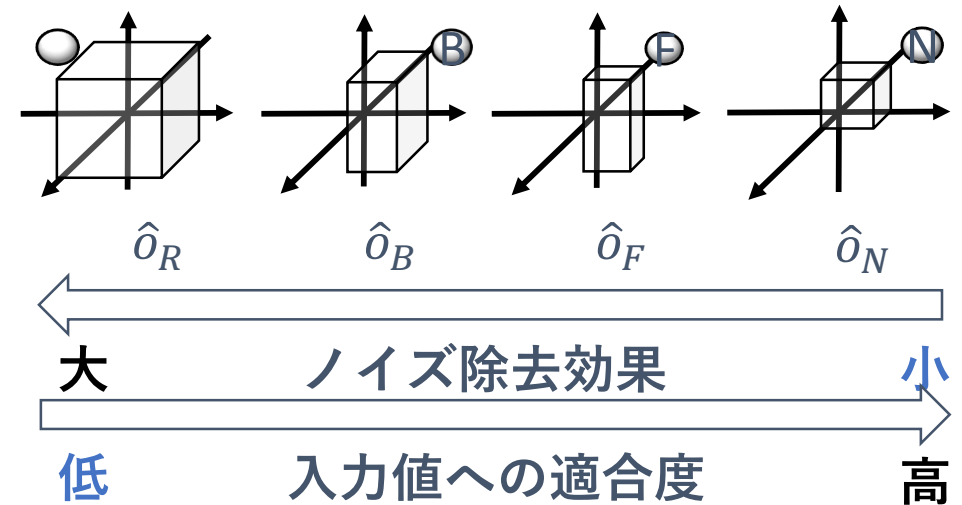
1. 忘却の調整

【忘却無し（領域内訓練データを平均化，順不動）】

$$\hat{o} \leftarrow \frac{1}{u+1} o_k + \left(1 - \frac{1}{u+1}\right) \hat{o}$$


【忘却有り（新規データに適応）】

$$\hat{o} \leftarrow \alpha o_k + (1 - \alpha) \hat{o} \quad (\alpha = \text{const.})$$



2. 自動ノイズ除去

誤差値をそれぞれのセルで計算しておくことでノイズ除去効果と入力値への適合度のバランスが良いセルを選択できる。

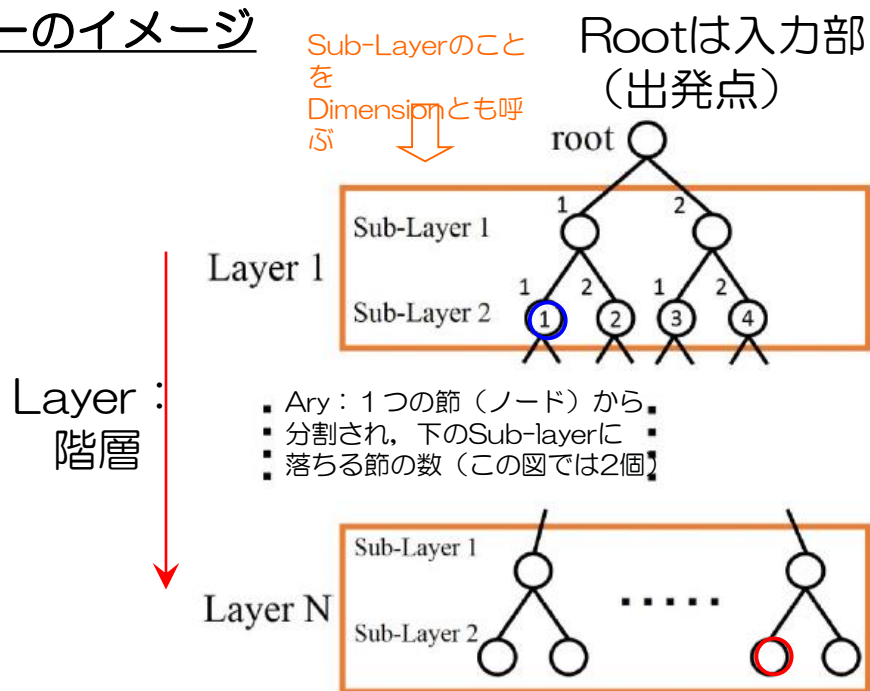


【 DBT (Deep Binary Tree) 技術の概要 】


二分木法（決定木法：データ探索手法などで用いられる）を応用した技術
ツリーを階層化していき、入力条件にあてはまるOutputを探索（呼び出す）方法

・・・データをバッチ処理でなく、オンライン学習によって逐次処理していく点に特徴がある。

ツリーのイメージ



データ収納イメージ (Sub-layer2)





例：Leaf node①（左図）のデータは、右図において Dimension1-Ary1 & Dimension2-Ary1 の場所にある Input spaceにデータが収納される

階層が下りていくにしたがって条件が絞り込まれていき、Input spaceは小さくなる

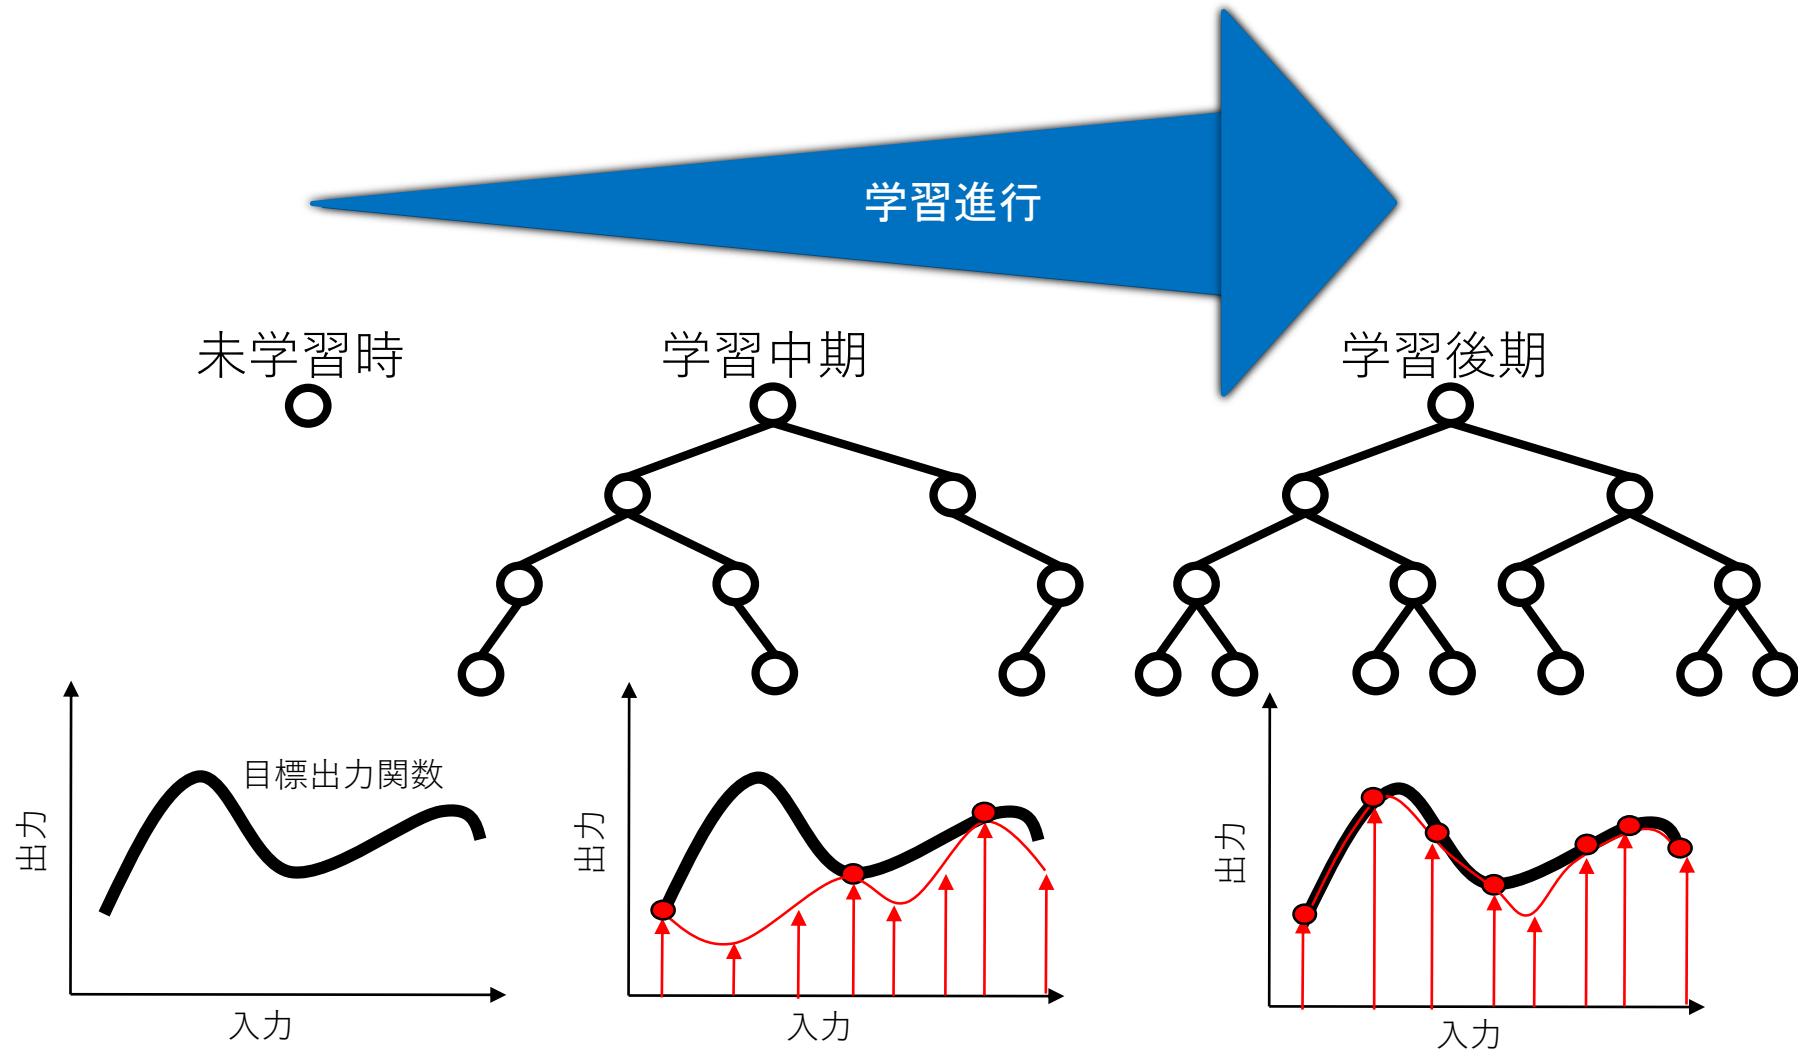


DBTの学習イメージ（鍛造モデル）

目標: 目標出力関数を出力できるように学習する



木構造と鍛造モデルの対比



学習が進むほど目標出力関数に近くなる

既存AIとの比較

	DBT	Neural Network (Deep Learning)	Random Forest	K近傍法	サポートベクターマシン
◎ > ○ > △ > ×					
安定性要素					
マニュアル調整	◎ 不要	× 要	△ 要 (軽微)	△ 要 (軽微)	× 要
乱数要素	◎ なし	× あり	× あり	◎ なし	◎ なし
収束証明	◎ あり	△ 不完全	○ あり (乱数次第)	◎ あり	◎ あり
機能性要素					
学習 (更新) 速度	◎ (5μs~20μs)	△ (10分~5日)	△ (10分~1日)	◎ (5μs~20μs)	△ (10分~1日)
予測 (実行) 速度	◎ (5μs~20μs)	○ (50μs~1s)	○ (20μs~50μs)	△ (20μs~, 学習数依存)	○ (20μs~50μs)
追加学習	◎ (忘却調整有)	× (忘却大)	× (非対応)	○ (忘却調整無)	× (非対応)
応用領域					
最大入力端子数 (データ規模)	100 (運動データ)	10M (画像データ)	10K (音データ)	100 (運動データ)	10K (音データ)

高速PDCAサイクルの仕組み

