

オムロンの非集中学習技術 DcX に関する調査レポート

Executive Summary

2026年6月12日に東京都内で開かれたオムロンの会見は、オムロン サイニックエックスが研究開発してきた非集中学習技術「Decentralized X (DcX)」を、研究紹介の段階から具体的な社会実装フェーズへ引き上げつつあることを示すイベントとして位置付けられる可能性が高いです。確認できた公開情報を総合すると、DcXは「データそのものを持ち寄らず、各拠点・各社で学習済みのAIモデルやその出力を統合することで全体性能を高める」思想に基づく技術群であり、その中核アルゴリズムの一つが、OSXが論文・技術論文・特許で展開してきた **DLAD (Decentralized Learning via Adaptive Distillation)** および **adaptive co-distillation** 系列の技術だとみるのが自然です。これは一次資料の直接明記ではなく、2019年のDcX開発発表、2021年以降の技術論文、2023年以降の特許、そして2026年の実証リリースの整合性から導かれる分析上の推論です。 ¹

技術面での最大の差別化要因は、一般的な連合学習が前提としがちな「同一アーキテクチャのモデル」「頻繁な重み交換」「中央側での逐次的な集約」に依存せず、**異種モデルを許容し、サーバー側の未ラベルデータに対する各クライアントの出力を、信頼度に応じて適応的に重み付けして蒸留する**点にあります。OSXの技術論文では、DLADは非IIDデータに強く、クライアント数増加で性能向上傾向があり、ResNetとDenseNetのような異種アーキテクチャ混在でも実用上の有効性が示されたと説明されています。 ²

事業化面では、2026年6月9日のオムロン公式リリースにより、アプリズムのAIプロダクト「aiba」における馬体検出AIモデル開発へDcXを適用し、競馬場・厩舎という環境差の大きい現場でも、各現場の固有データを共有せずに迅速なモデル生成が可能であることを確認したと公表されています。他方で、**汎用製品としてのSKU、価格、正式パートナープログラム、量産導入数、収益計画の詳細は公開資料では未確認**です。従って現時点では、DcXは「単体ソフトウェア製品」よりも「共創案件に組み込まれるAI開発基盤技術」と理解するのが妥当です。 ³

報道ベースでは、MONOistがこの会見の内容としてDcXを取り上げ、別ページ見出しで「AIの学校」で開発期間を7割削減」と報じています。ただし、**その“7割削減”という数値は今回確認できたオムロン公式一次資料では直接確認できず、現時点では報道値として扱うのが厳密**です。 ⁴

主要発見

- 会見の開催事実はMONOistの記事スニペットで確認でき、日時は **2026年6月12日**、場所は **東京都内**です。具体会場名は、今回確認できた公開一次資料では **未確認**です。 ⁵
- 会見で説明されたDcXは、オムロンが2019年に公式発表した「データを集約することなくAIの性能を高める非集中学習技術『Decentralized X』」の延長線上にあり、2026年にはアプリズムとの共創案件で実装検証段階に入っています。 ⁶
- 技術の中核は、OSXの公開技術文書が説明する **DLAD** であり、未ラベルの蒸留用データ、クライアントごとの soft label、さらに各クライアントの“confidence”を用いた適応重み付けが特徴です。 ⁷
- DLAD/DcXは、一般的な連合学習と異なり **異種モデルをそのまま参加させやすい**一方、サーバー側で蒸留用データを確保する必要があり、そこが実装上の主要トレードオフです。 ⁷
- 知財面では、OSX研究者の米谷亮氏発明による **US11580453B2** およびその日本対応特許 **JP7468675B2** が、private AI models の出力を用いて private data 自体には学習しない co-distillation 構造を保護しています。 ⁸

- ・セキュリティ面では「生データを中央集約しない」こと自体は優位ですが、NISTが指摘する通り、分散・連合型学習でも更新情報やモデル出力からのプライバシー攻撃は残り得ます。DcX系特許が同型暗号系を想定しているのは、その弱点への対策方向と整合的です。 ⁹

会見の事実関係

まず、今回の会見について、公開情報で確認できた事実と未確認事項を切り分けます。

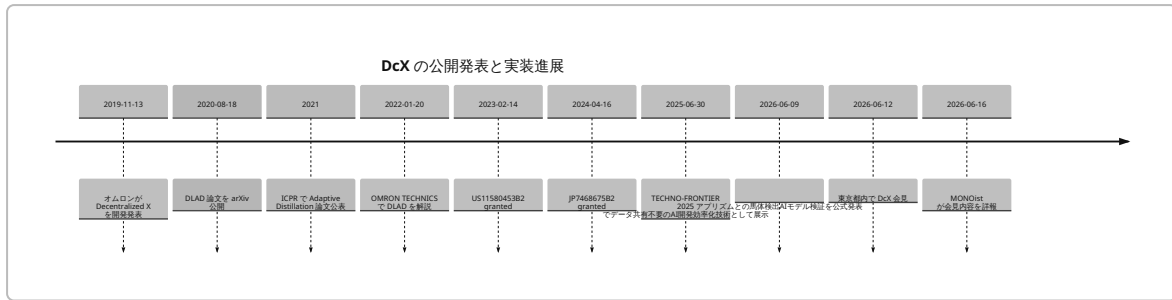
| 項目 | 確認できた内容 | 確度 |
|------------|--|-----|
| 日時 | 2026年6月12日。 ⁵ | 高 |
| 場所 | 東京都内。具体会場名は未確認。 ⁵ | 中 |
| 会見テーマ | オムロン サイニックエックスが研究開発するAI技術「Decentralized X (DcX)」の概要説明。 ¹⁰ | 高 |
| 登壇者 | MONOistのスニペットでは 諏訪正樹氏の氏名が確認できる一方、公開一次資料で会見登壇者の完全一覧は未確認。 ¹¹ | 中 |
| 研究子会社の位置付け | オムロン サイニックエックスはオムロンの研究子会社であり、2026年の公式ページでもDcX関連活動が同社活動として掲載。 ¹² | 高 |
| 会見資料 | 今回確認できた公開範囲では、会見スライドや配布資料の公開は未確認。 | 未確認 |

会見の主な発表内容は、公開一次資料との突合からみると、少なくとも以下の三層に整理できます。第一に、DcXの基本概念、すなわち「データを共有せずにAIを高度化する」非集中学習の説明です。第二に、OSXが技術的中核として積み上げてきたDLAD/co-distillationの紹介です。第三に、アプリズムとの共創事例を通じた実装・社会実装の進展です。公式発表では、馬体検出AIモデルにDcXを適用し、競馬場や厩舎の馬房環境、対象馬の違いがあっても各現場の固有データを共有せずに迅速な運用可能モデルを生成できることを確認したとされています。 ¹³

2019年のオムロン公式発表は、DcXを「データを集約することなくAIの性能を高める 非集中学習技術」と位置付けていました。これに対し2026年のリリースは、DcXを「各現場で学習されたAIモデルのみを統合することで、データを共有せずセキュアな環境でAIを高度化できる新たなアプローチ」と説明しています。両者は概念的に一貫しており、今回の会見はこの技術を“研究説明”から“実証・用途説明”へ進める節目だったと解釈できます。 ¹⁴

報道値として特に注目されるのが、MONOistの見出しにある「開発期間を7割削減」です。ただし、この削減率は今回確認できた公式リリース本文では直接確認できません。したがって、厳密には「公式は短期間化を示し、MONOistは7割削減と報道」という扱いが適切です。 ⁴

以下に、公式発表と報道を統合したタイムラインを示します。



このタイムラインは、2019年の技術公表から、論文化、特許化、展示、実証、そして記者説明会へと進む一貫した流れを示しています。 15

技術分析

DcXの技術的定義を、公開資料に忠実に言い換えると、「異なる拠点や組織が保有する **private data** を中央集約せず、各クライアントで得られた学習済みモデルやその出力を統合して、サーバー側の **global model** を高性能化する**非集中学習技術**」です。OSXの技術論文では、この中核手法として **DLAD** が説明されており、従来のFLでは扱いにくい「heterogeneous clients」と「non-IID data」を主要課題として設定しています。

16

OMRON TECHNICS の説明では、FLの弱点として、**クライアントのモデルアーキテクチャが同一であることを要求する点**と、**学習中に頻繁な通信が必要な点**が挙げられます。その代替として、KDベースの分散学習では、クライアントが **private data** で **source model** を学習し、サーバーは自ら集めた **distillation data** を各クライアントに送り、その **soft label** を受け取って **global model** を蒸留学習します。つまり、DcX/DLADは「重みの平均」ではなく「知識の蒸留」を中心に据えています。 17

さらにDLADは、単なる平均蒸留ではありません。各クライアントは、自身の **private data** と **server-side distillation data** を識別する **binary model** も追加学習し、その出力を「そのサンプルに対する慣れ・親和性・confidence」の近似として用います。サーバーはこの **confidence** を **softmax 正規化** して重み $w_i(x)$ を計算し、各 **client model** の出力 $M_i(x)$ を重み付き合成して **global model** を学習します。これにより、non-IID 環境で「そのサンプルに詳しいクライアント」の意見を強く反映させられます。 7

この仕組みを図示すると、以下のようになります。

flowchart LR

S[Server\n未ラベル蒸留データ Ddist] --> C1[Client A\nprivate data D1\nmain model M1]

S --> C2[Client B\nprivate data D2\nmain model M2]

S --> C3[Client C\nprivate data D3\nmain model M3]

C1 --> B1[binary model Mb1\nD1 vs Ddist]

C2 --> B2[binary model Mb2\nD2 vs Ddist]

C3 --> B3[binary model Mb3\nD3 vs Ddist]

C1 --> O1[soft labels M1(x)]

C2 --> O2[soft labels M2(x)]

C3 --> O3[soft labels M3(x)]

B1 --> W[confidence-weighted aggregation]

B2 --> W

B3 --> W
01 --> W
02 --> W
03 --> W

W --> G[Global model M\nadaptive distillation]

この図は、OSXの公開技術論文にある三段階構造、すなわち **client model 学習** → **binary model 学習** → **server model 学習** を簡略化したものです。DLADでは通信は各段階の冒頭に限られ、クライアント側・サーバー側の学習自体はオフラインで進められると説明されています。 ¹⁸

想定ユースケースは、公式・技術資料からみると、少なくとも三つあります。第一に、**医療・生体・行動ログのような秘匿性が高いデータ**を扱う領域です。OMRON TECHNICSは、心疾患の早期検出機器を例に、病院ごとのデータを中央送信せずにモデル開発を進める構想を示しています。第二に、**工場や現場間で環境差が大きく、かつデータ共有が難しい産業用途**です。第三に、2026年の実証で示されたような**現場条件が頻繁に変化する画像認識・物体検出**です。 ¹⁹

差別化要因は、次の四点に集約できます。

ひとつは**異種モデル許容性**です。DLADはResNetとDenseNetの混在も評価しています。

ふたつめは**non-IID対応**で、単純平均よりもadaptive weightingを重視することです。

みつつめは**通信回数の少なさ**で、FLほど逐次同期を必要としません。

よつつめは**データそのものではなくモデル出力を統合する知識蒸留型の設計**です。これは、2019年以降のDcXの「モデル同士を統合する」説明とも整合しています。 ²⁰

一方で、限界も明確です。サーバー側には**distillation dataの確保**が必要であり、そのデータ分布がprivate dataと大きく乖離するとconfidence推定が崩れるおそれがあるとOSX自身が認めています。つまりDcXは「何もデータが要らない」技術ではなく、**中央に集約すべき対象を“生データ”から“蒸留用の公開可能・取得しやすいデータ”へ移す技術**と理解すべきです。 ²¹

実装と商用化

現時点で公開確認できる実装事例は、**アプリズムとの共創による馬体検出AIモデル開発手法の構築**です。公式リリースによれば、対象は競馬場や厩舎の馬房で利用されている検出モデルであり、馬房環境や対象馬が変化しても、各現場の固有データを共有せずに迅速な運用可能モデルを生成できることを確認したとされています。ここで重要なのは、DcXが論文のベンチマーク技術にとどまらず、「多様な現場条件差」のある実運用シナリオへ適用されている点です。 ²²

OSXの公式活動ページには、2026年6月9日のこの案件が主要活動として掲出されており、2025年にはTECHNO-FRONTIER 2025で「データを共有することなくAI開発効率を高める技術」として展示対象にもなっていました。したがって、DcXは2025年時点で既に展示可能なデモ・説明可能な技術として整備され、2026年にはパートナー実証に踏み込んだと見るのが妥当です。 ²³

ただし、**商用化計画の詳細は限定的**です。確認できた公開情報には、以下が含まれていません。

第一に、DcX単独の製品名・SKU・SaaS名。

第二に、販売価格や導入方式。

第三に、正式な販売チャネルや認定パートナー制度。

第四に、量産導入件数や売上目標。

このため、現時点では「明確な製品化済みプラットフォーム」というより、**オムロン／OSXの共創案件やソリューション案件に組み込まれる基盤技術**と評価するのが精密です。これは公開情報からの分析的判断であり、会社が明示した文言ではありません。 ²⁴

ロードマップも同様で、正式な年次マイルストーンは未公表です。ただし、公開事実から再構成すると、以下のような段階的進展が読み取れます。

| 段階 | 公開事実 | 評価 |
|--------|--|--------------|
| 技術創出 | 2019年にDcX開発を公式発表。 ²⁵ | 研究テーマ立ち上げ |
| 学術検証 | 2020年 arXiv、2021年 ICPR、2022年 OMRON TECHNICS で DLADを公開。 ²⁶ | 技術のアルゴリズム検証 |
| 知財保護 | 2023年米国特許、2024年日本特許が成立。 ²⁷ | 商用展開を見据えた権利化 |
| 市場啓発 | 2025年TECHNO-FRONTIERで展示。 ²⁸ | 産業顧客向け訴求開始 |
| 実装検証 | 2026年アプリズム案件を発表。 ²⁹ | 社会実装の初期段階 |
| 拡張フェーズ | 他パートナー案件・横展開は未確認。 | 未確認 |

MONOistは、オムロンとOSXがDcX活用実証を「さまざまなパートナーと進めている」と報じていますが、今回の公開確認範囲で社名まで一次資料で特定できたのはアプリズムのみです。従って、**複数パートナー展開の可能性は高いが、具体社名は未確認**と整理するのが適切です。³⁰

セキュリティと法規制

DcXのセキュリティ・プライバシー上の利点は、まず**生データの中央集約を避けられる**ことにあります。Googleの federated learning 定義でも、分散学習は training examples をアップロードせず、data minimization に沿うと説明されています。NISTも、分散・連合型学習は個人識別情報フローを抑える有望なアーキテクチャだと位置付けています。DcXはこれをさらに一歩進め、重み交換中心のFLではなく、soft label と confidence による蒸留中心の設計を採っています。³¹

しかし、“**データを送らない**”ことと“**プライバシーリスクがない**”ことは同義ではありません。NISTは、federated learning でも model updates や共有情報から privacy attacks が起こり得るため、FL 単体では完全な保護ではないと明言しています。OWASP も、model inversion、membership inference、model poisoning などを機械学習システムの主要脅威に挙げています。DcXが共有するのは raw data ではなくても、**soft label や推論出力、confidence 情報が情報漏えいの側面を持ち得る**点には注意が必要です。³²

この弱点への対策方向は、オムロンの特許群にも表れています。US11580453B2 では、client result data を用いて adaptive co-distillation model を学習しつつ、**その model 自体は first / second private data set に直接学習しない**ことが記載されています。さらに、result data set を partially / fully homomorphic encryption で暗号化する旨も明記されています。つまり、DcX系技術は単に“データを送らない”だけでなく、**送る出力も暗号・安全計算で保護しうる設計余地**を持ちます。³³

日本法制との関係では、適用対象データが個人情報を含むかどうか第一の分岐です。個人情報を扱うなら、個人情報保護委員会の法令・ガイドライン体系が前提になります。匿名加工情報や仮名加工情報の扱いは2026年4月一部改正のガイドラインでも整理されており、匿名加工情報については本人識別目的で他情報と照合する行為が禁止されています。医療、生体、行動データ等へDcXを適用する場合、**元データを送らないから即適法、とはならず、蒸留用データ、モデル出力、ログ、再識別可能性まで含む設計審査**が必要です。

³⁴

また、日本では経産省・総務省の **AI事業者ガイドライン** が、説明可能性、検証可能性、セキュリティ確保、ステークホルダーへの合理的情報提供などを重視しています。2026年版資料は、AIセキュリティ技術的対策ガイドラインへの言及も含み、AI開発者・提供者による脅威対策を求めています。DcXのような分散AI基盤では、**誰がモデル提供者か、誰が最終統合者か、誰が性能責任を負うか** を契約・運用で定義することが特に重要です。 ³⁵

EU域内適用があり得る場合は、GDPRとAI Actの双方が論点になります。GDPRは2018年から適用済みで、AI Actは2024年8月1日に発効し、原則として2026年8月2日から適用、ただし一部は前倒し適用です。EUの公式タイムラインでは、一般規定・禁止事項が2025年2月から、GPAI関連が2025年8月から、全体適用が2026年8月から進行します。DcXが医療やインフラ、雇用など高リスク分野に入る場合、**分散学習であること自体はコンプライアンス免除ではなく、むしろデータ系責任分担と監査証跡の難度を上げる** 可能性があります。 ³⁶

要するに、DcXの規制対応は「中央集約回避」という強みを持ちながらも、実際には以下の管理が必要です。

| 論点 | 主なリスク | 有効な対策方向 | 根拠 |
|-------------|--|------------------------------------|---------------|
| モデル出力からの漏えい | membership inference / model inversion | differential privacy、出力制御、暗号化、監査ログ | ³⁷ |
| 学習参加者の悪性行為 | poisoning、虚偽出力送信 | 参加者認証、異常検知、重み付け監視、隔離 | ³⁸ |
| 個人情報法制 | 再識別、第三者提供、加工データ誤用 | 仮名化・匿名化設計、契約整理、DPIA | ³⁹ |
| AI規制 | 高リスク用途での責任境界不明確 | ガバナンス文書、説明責任、監査証跡 | ⁴⁰ |

競合比較と知財

DcXを評価するには、単なる「オムロン独自技術」としてではなく、分散AIの主要アプローチ群の中で相対位置を押さえる必要があります。以下の比較表は、**技術方式の違い**と**競争上の意味**を同時に示したものです。

| 技術・取り組み | 主体 | 共有対象 | 異種モデル許容 | 非IID対応 | 通信負荷 | 典型用途 | DcXとの比較 |
|-------------------|------------|---|---|--------------------------|---------------------------------|-------------------|----------------------|
| DcX / DLAD | オムロン / OSX | soft label と confidence。private data は中央に送らない。 ⁷ | 強い。クライアントごとに unique model を許容。 ⁷ | 適応重み付けで強化。 ⁴¹ | 比較的低い。各段階の冒頭通信中心。 ¹⁸ | 産業、医療、現場差の大きい画像認識 | 異種モデル・低通信・non-IIDで優位 |

| 技術・取り組み | 主体 | 共有対象 | 異種モデル許容 | 非IID対応 | 通信負荷 | 典型用途 | DcXとの比較 |
|---------------------------|------------------------|--|--|---|--------------------------------|---------------|-------------------------|
| Federated Learning | Googleほか | モデル更新・重み。raw data はローカル。 ⁴² | 通常は弱い。同一モデル前提が基本。 ¹⁶ | 手法による。標準形は追加工夫が必要。 ⁴³ | 高め。反復同期が必要。 ⁴⁴ | モバイル、横断学習 | DcXは異種モデルと低通信で差別化 |
| NVIDIA FLARE | NVIDIA | FL runtime 上での学習ロジックと各クライアント更新。raw data はローカル。 ⁴⁵ | FL拡張により柔軟だが、基本は federated runtime。 ⁴⁶ | 実装次第 | 階層型で大規模対応。 ⁴⁷ | 医療・企業横断 FL 基盤 | DcX は“FL 基盤”ではなく蒸留型統合技術 |
| FATE | FederatedAI / WeBank 系 | secure computation による federated training。 ⁴⁸ | 方式次第。FL系制約を引き継ぐ部分あり | horizontal / vertical / transfer learning 対応。 ⁴⁹ | 中～高 | 金融・企業間共同学習 | DcXはより軽量な“モデル出力統合”寄り |
| PATE | Google系研究 | teacher model の投票結果を学生モデルへ移転。 ⁵⁰ | 強い | non-IID への適応重みは弱い。 ⁵¹ | 中 | 強いプライバシー保証研究 | DcXはPATEより適応重みで非IIDに強い |
| FedMD | 学術提案 | public data 上で model distillation。 ⁵² | 強い | 平均的集約で non-IID に弱いと OSX論文は指摘。 ⁵¹ | 中 | 異種モデル協調学習 | DcXはFedMDの弱点を補う設計 |
| Split Learning | 学術・医療系 | 中間表現を分割伝送。raw data は共有しない。 ⁵³ | モデル分割前提 | 方式次第 | 中～高。中間表現転送コストあり。 ⁵⁴ | 医療、厳格なデータ分離 | DcXは分割推論より導入しやすい可能性 |

この比較から見てくるのは、DcXが「FLプラットフォーム」ではなく「heterogeneous clients 向け adaptive distillation エンジン」と捉えると理解しやすいことです。NVIDIA FLARE や FATE は、マルチパーティ学習運用基盤として強い一方、DcXはより上位のアルゴリズム差別化、特に異種モデル統合と非IID適応に強みを持っています。 ⁵⁵

知財面では、以下の特許と論文が特に重要です。

| 種別 | 名称 | 公開・成立年 | 要点 | DcXとの関係 |
|--------|--|-----------|--|---------------------------|
| 特許 | US11580453B2 – Adaptive co-distillation model ⁵⁶ | 2023 | private AI models の result data を使い、private data 自体には学習せず server-side model を学習。異種モデル統合、confidence weighting、homomorphic encryption を含む。 ³³ | DcXの中核知財とみられる |
| 特許 | JP7468675B2 – 機械学習モデル ⁵⁷ | 2024 | 上記米国特許の日本対応。分散学習・暗号・ニューラルネットの分類が付与。 ⁵⁷ | 国内権利化 |
| 論文 | Adaptive Distillation for Decentralized Learning from Heterogeneous Clients ⁵¹ | 2020/2021 | DLADを提案。未ラベル distillation samples と adaptive weighting により heterogeneous / non-IID 条件へ対応。MNIST, CIFAR-10, CINIC-10で検証。 ⁵¹ | DcXのアルゴリズム基盤 |
| 技術論文 | A Machine Learning System that Adaptively Aggregates Knowledge from Multiple Models ⁵⁸ | 2022 | DLADを事業応用視点で解説。FLとの違い、binary model による confidence 推定、固定段階通信を整理。 ²¹ | 企業内・顧客向け説明資産 |
| 論文 | MULTIPOLAR: Multi-Source Policy Aggregation for Transfer Reinforcement Learning between Diverse Environmental Dynamics ⁵⁹ | 2019/2020 | 多様な source policy を adaptive に集約し、別環境 dynamics へ転移するRL手法。 | 「複数モデルの適応的統合」という研究思想の隣接系譜 |
| 公式開発発表 | Decentralized X を開発 ²⁵ | 2019 | 「機械学習モデル同士を統合する新技術」としてDcXを対外化。 | ブランド名・事業概念の起點 |

ここで特に重要なのは、DcXという名称そのものは2019年の事業・技術発表で現れ、DLADやadaptive co-distillationはその中核アルゴリズムの公開名であるという構図です。これは公開資料からの合理的推論であり、現時点で「DcX = DLAD」と公式に一語一句対応づけた一次資料は未確認です。とはいえ、名称、技術説明、特許内容、2026年の実証説明は相互に高い整合性を持っています。 ¹

結論と推奨アクション

総合すると、DcXは“データ共有がネックでAIが進まない現場”に対する、オムロン流の実装志向型 **distributed AI 技術** と評価できます。とりわけ、工場・医療・現場映像・エッジ機器・パートナー間共同開発のように、**データガバナンスが厳しく、しかも現場差が大きい** 領域で相対的な優位が見込まれます。これは単なるプライバシー配慮ではなく、**モデルIPを保持したまま協調学習を可能にする** という経営上の効果も含まれます。 60

一方で、リスクは三つあります。

第一に、サーバー側の distillation data が不適切だと adaptive weighting が崩れ、性能が不安定化する事です。OSX自身が domain difference を明示的な制約として挙げています。 41

第二に、データ非集約でもモデル出力・更新・ログからの漏えいリスクは残る事です。 61

第三に、高リスク分野へ使う場合、AI Act、個人情報保護法、業法対応、責任分界の設計が不可欠である事です。 62

したがって、実務上の推奨アクションは次の通りです。

- ・技術評価の軸を“精度”だけでなく“データ移転削減量・契約容易性・現場適応速度”に置くこと。DcXの価値は、単独精度よりむしろ共同開発摩擦の低減にあります。 63
- ・PoC設計では、**distillation data の代表性を最重要KPIにすること**。OMRON TECHNICS が示す通り、domain gap は adaptive weighting を壊し得ます。 41
- ・**法務・セキュリティを初期から巻き込むこと**。特にモデル出力ログ、推論API、学習参加者監査、秘密保持契約、再識別評価を先に設計すべきです。 64
- ・**競合比較ではFL基盤と真正面に比べるのではなく、“異種モデル統合が必要か”“通信制約が厳しいか”で選ぶこと**。その条件下ではDcXの相対優位が大きくなります。 55
- ・**投資判断では、単体プロダクト収益より、オムロンの制御機器・現場ソリューションへの組み込み価値をみる**こと。公開情報上、DcXは現状このルートで商用化が進む蓋然性が高いです。 65

結論として、DcXは「一般的な連合学習の日本版」ではありません。むしろ、**異種モデル・非IID・低通信・データ非持ち寄り**を同時に満たしたい産業用途で力を発揮する、蒸留型の分散AI統合技術です。2026年6月の会見は、その技術が学術研究・特許・展示を経て、具体的な社会実装事例へ着地し始めたことを示した、重要なマイルストーンと評価できます。 66

出典一覧

本レポートで重視したソースは、オムロン公式ニュースルーム、OMRON SINIC X 公式活動ページ、OMRON TECHNICS、Google Patents、arXiv/IJCAI 等の主要論文公開元、Google Developers、NVIDIA公式、FATE 公式、PPC、METI、European Commission、NIST、OWASP、ならびに指定記事 MONOist です。主な参照先は本文中の各 citation に埋め込んであります。

1 6 14 15 25 60 データを集約することなくAIの性能を高める 非集中学習技術 ...

https://www.omron.com/jp/ja/news/2019/11/c1113-2.html?utm_source=chatgpt.com

2 7 16 17 18 19 20 21 41 58 A Machine Learning System that Adaptively Aggregates Knowledge from Multiple Models | OMRON TECHNICS | R&D | テクノロジー | オムロン

<https://www.omron.com/jp/ja/technology/omrontechnics/2021/20211119-ma.html>

3 13 22 24 29 63 65 オムロンとアプリズム、非集中学習技術「DcX」で開発効率を向上

https://www.omron.com/jp/ja/news/2026/06/c0609.html?utm_source=chatgpt.com

4 30 “AIの学校”で開発期間を7割削減、“蒸留”するオムロンのAI学習 ...

https://monoist.itmedia.co.jp/mn/articles/2606/16/news043_2.html?utm_source=chatgpt.com

- 5 10 11 66 蒸留”するオムロンのAI学習手法「DcX」とは：人工知能 ...
https://monoist.itmedia.co.jp/mn/articles/2606/16/news043.html?utm_source=chatgpt.com
- 8 27 33 56 US11580453B2 - Adaptive co-distillation model - Google Patents
<https://patents.google.com/patent/US11580453B2/en>
- 9 32 37 61 Privacy Attacks in Federated Learning | NIST
https://www.nist.gov/blogs/cybersecurity-insights/privacy-attacks-federated-learning?utm_source=chatgpt.com
- 12 23 OMRON SINIC X Corporation
https://www.omron.com/sinicx/?utm_source=chatgpt.com
- 26 51 Adaptive Distillation for Decentralized Learning from Heterogeneous Clients
<https://arxiv.org/abs/2008.07948>
- 28 オムロンサイニックス、「TECHNO-FRONTIER 2025」に ...
https://www.omron.com/jp/ja/news/2025/06/c0630.html?utm_source=chatgpt.com
- 31 42 Machine Learning Glossary
https://developers.google.com/machine-learning/glossary?utm_source=chatgpt.com
- 34 個人情報保護法等
https://www.ppc.go.jp/personalinfo/?utm_source=chatgpt.com
- 35 40 AI 事業者ガイドライン
https://www.meti.go.jp/shingikai/mono_info_service/ai_shakai_jisso/pdf/20260331_1.pdf?utm_source=chatgpt.com
- 36 Legal framework of EU data protection - European Commission
https://commission.europa.eu/law/law-topic/data-protection/legal-framework-eu-data-protection_en?utm_source=chatgpt.com
- 38 ML10:2023 Model Poisoning
https://owasp.org/www-project-machine-learning-security-top-10/docs/ML10_2023-Model_Poisoning?utm_source=chatgpt.com
- 39 62 個人情報の保護に関する法律についてのガイドライン（仮名 ...
https://www.ppc.go.jp/personalinfo/legal/guidelines_anonymous/?utm_source=chatgpt.com
- 43 44 Communication-Efficient Learning of Deep Networks from Decentralized Data
https://arxiv.org/abs/1602.05629?utm_source=chatgpt.com
- 45 46 55 NVIDIA FLARE
https://developer.nvidia.com/flare?utm_source=chatgpt.com
- 47 Effortless Federated Learning on Mobile with NVIDIA ...
https://developer.nvidia.com/blog/effortless-federated-learning-on-mobile-with-nvidia-flare-and-meta-executorch/?utm_source=chatgpt.com
- 48 An Industrial Grade Federated Learning Framework - FATE
https://fate.readthedocs.io/en/latest/?utm_source=chatgpt.com
- 49 Federated Learning Algorithms In FATE — FATE documentation
https://fate.readthedocs.io/en/develop-1.5/_build_temp/README.html?utm_source=chatgpt.com
- 50 Semi-supervised Knowledge Transfer for Deep Learning from Private Training Data
https://arxiv.org/abs/1610.05755?utm_source=chatgpt.com
- 52 FedMD: Heterogenous Federated Learning via Model Distillation
https://arxiv.org/abs/1910.03581?utm_source=chatgpt.com

53 Distributed deep learning without sharing raw patient data

https://arxiv.org/abs/1812.00564?utm_source=chatgpt.com

54 Quantized-Tinyllava: a new multimodal foundation model ...

https://arxiv.org/html/2511.23402v2?utm_source=chatgpt.com

57 JP7468675B2 - 機械学習モデル - Google Patents

<https://patents.google.com/patent/JP7468675B2/ja>

59 MULTIPOLAR: Multi-Source Policy Aggregation for Transfer Reinforcement Learning between Diverse Environmental Dynamics

https://arxiv.org/abs/1909.13111?utm_source=chatgpt.com

64 Secure AI Model Ops - OWASP Cheat Sheet Series

https://cheatsheetseries.owasp.org/cheatsheets/Secure_AI_Model_Ops_Cheat_Sheet.html?utm_source=chatgpt.com