

PRIVACY · AI · TRUST

Privacy-Enhancing Technologies (PETs)

นวัตกรรมเพื่อใช้ข้อมูลอย่างปลอดภัยในยุค AI



นนทวัฒน์ สาระมาน

กรรมการสภาดิจิทัลเพื่อเศรษฐกิจและสังคมแห่งประเทศไทย DCT
นายกกิตติมศักดิ์สมาคมส่งเสริมนวัตกรรมเทคโนโลยีไซเบอร์ CIPAT
ผู้ร่วมก่อตั้งศูนย์ปฏิบัติการและวิจัยดิจิทัลเพื่อนาคตที่ยั่งยืน

ผู้ร่วมก่อตั้ง SRAN Technology
ผู้ก่อตั้ง Qsense PQC Readiness Platform



ปัจจุบันสำเนาบัตรประชาชนของเราไปอยู่ที่ใดบ้าง ?



คำถามชวนคิด

คุณรู้หรือไม่ว่า 'สำเนาบัตรประชาชน' ของคุณกระจายอยู่ที่โลกที่ฉบับ?

ความเป็นจริง

ข้อมูลส่วนบุคคล (PII) และข้อมูลองค์กร ขยายตัวอย่างควบคุมไม่ได้ เรากังวลเรื่อง ความเป็นส่วนตัวแต่ขาดระบบตรวจสอบ

ความท้าทาย

องค์กรส่วนใหญ่มองความปลอดภัย ข้อมูลเป็นเพียงแค่การทำตามกฎระเบียบ (Checklist) แทนที่จะทำความเข้าใจ ข้อมูลจริงๆ

ข้อมูลทุกชุดในองค์กรต้องถูกควบคุมผ่าน 3 ช่วงชีวิตหลัก

Lifecycle ของข้อมูล



Breach = “ถูกแฮก / ถูกขโมย” โดยตั้งใจ

Loss = “หายไป / ใช้ไม่ได้”

Leak = “หลุดออกไปโดยไม่ได้ตั้งใจ”

DLP = Data Loss Prevention

แต่ในยุค AI DLP เอาไม่อยู่แล้ว เพราะ

ShadowAI

เราจึงต้องมาเรียนรู้ PETs



หัวใจของ PETs ในยุค AI

Use • Protect • Trust

ใช้ข้อมูล • ปกป้องข้อมูล • สร้างความเชื่อมั่น



Use
ใช้ข้อมูลให้เกิดคุณค่า



Protect
ปกป้องข้อมูลอย่างรับผิดชอบ



Trust
สร้างความเชื่อมั่นอย่างยั่งยืน

PETs = Privacy Enhancing Technologies

ข้อมูลคือเชื้อเพลิงของ AI • แต่ข้อมูลคือความเสี่ยงด้วย

องค์กรเผชิญแรงกดดัน 3 ด้านพร้อมกัน

1 ความต้องการของ AI



โมเดล AI ต้องการข้อมูลขนาดใหญ่
คุณภาพสูง และหลากหลายแหล่ง

2 ความเข้มงวดของกฎหมาย



PDPA, GDPR, HIPAA, EU AI Act
บีบให้ต้องลดการ expose ข้อมูลส่วนบุคคล
ให้ต่ำสุด

3 ภัยคุกคามที่ขยายตัว



Data breach, model inversion,
membership inference ทำให้ข้อมูลฝึก AI
กลายเป็นเป้าโจมตี



PETs คือคำตอบที่ทำให้องค์กรใช้ข้อมูลได้ โดยไม่ต้องเลือกระหว่าง **‘ใช้’** กับ **‘ปลอดภัย’**



วงจรชีวิตของการปกป้องข้อมูลด้วย PETs

ข้อมูลขาเข้า (Input Privacy)
ปกป้องข้อมูลก่อนเข้าสู่ระบบ

Anonymization

k-anonymity

ระหว่างประมวลผล (Computation Privacy)
คำนวณและวิเคราะห์โดยไม่เห็นข้อมูลดิบ

Secure Computation
(MPC, HE, TEE)


Federated Learning (FL)

ผลลัพธ์ขาออก (Output Privacy)
ป้องกันไม่ให้ผลลัพธ์ย้อนกลับไปหาตัวบุคคลได้

Differential Privacy
(DP)

Zero-Knowledge
Proofs (ZKP)

Synthetic Data



กล่องเครื่องมือของ PETS

ข้อมูลขาเข้า (Input Privacy)
ปกป้องข้อมูลก่อนเข้าสู่ระบบ

- Anonymization
- k-Anonymity
- Data Masking / Pseudonymization

ระหว่างประมวลผล (Computation Privacy)
คำนวณและวิเคราะห์โดยไม่เห็นข้อมูลดิบ

Secure Computation

- MPC Multi-Party Computation (MPC)
- HE Homomorphic Encryption (HE)
- TEE Trusted Execution Environment (TEE)

Federated Learning (FL)
ฝึกโมเดลร่วมกันโดยไม่รวมข้อมูลดิบ

Secure Enclave / Confidential Computing
สภาพแวดล้อมปลอดภัยแยกจากระบบหลัก (รองรับ TEE)

ตัวอย่างการใช้งาน

- Artificial Intelligence / Analytics (AI)
- Banking & Fraud Detection
- Healthcare Data Sharing

PETs
Privacy-Enhancing Technologies (PETs)
เทคโนโลยีเพื่อคุ้มครองข้อมูลส่วนบุคคล

ผลลัพธ์ขาออก (Output Privacy)
ป้องกันไม่ให้ผลลัพธ์ย้อนกลับไปหาตัวบุคคลได้

- Differential Privacy (DP)
- Zero-Knowledge Proofs (ZKP)
- Access Control / Policy Enforcement

แนวคิดสำคัญ: PETs ช่วยปกป้องข้อมูลตลอดวงจรชีวิต ตั้งแต่ก่อนนำเข้า ระหว่างประมวลผล จนถึง การเปิดเผยผลลัพธ์

ข้อมูลขาเข้า (Input Privacy)
ปกป้องข้อมูลก่อนเข้าสู่ระบบ

Data Masking /
Pseudonymization

k-anonymity

ระหว่างประมวลผล (Computation Privacy)
คำนวณและวิเคราะห์โดยไม่เห็นข้อมูลดิบ

Secure Computation
(MPC, HE, TEE)

Federated Learning (FL)

ผลลัพธ์ขาออก (Output Privacy)
ป้องกันไม่ให้ผลลัพธ์ย้อนกลับไปหาตัวบุคคลได้

Differential Privacy
(DP)

Zero-Knowledge
Proofs (ZKP)

Anonymization vs Pseudonymization

การปกปิดข้อมูลส่วนบุคคล: ต่างกันอย่างไร



Anonymization (การทำให้ไม่สามารถระบุตัวตนได้)

ข้อมูลตั้งต้น

ชื่อ	เลขบัตรประชาชน	เบอร์โทร	อายุ	จังหวัด	ยอดใช้จ่าย (บาท/เดือน)
สมชาย ใจดี	1-2345-67890-12-3	081-234-5678	34	เชียงใหม่	12,450
สมหญิง รักดี	1-9876-54321-23-4	091-876-5432	29	ชลบุรี	7,890
อนันต์ มีสุข	3-1122-33445-56-7	062-345-6789	41	ขอนแก่น	15,600

ลบ / ปกปิด / ทำให้เป็นข้อมูลรวม
ผลลัพธ์

อายุ (ช่วงปี)	ภาค	ยอดใช้จ่าย (บาท/เดือน)
30-39	ภาคเหนือ	10,001 - 15,000
20-29	ภาคตะวันออก	5,001 - 10,000
40-49	ภาคตะวันออกเฉียงเหนือ	15,001 - 20,000



ไม่สามารถย้อนกลับไปสู่ตัวบุคคลได้

เหมาะสำหรับ: การเปิดเผยข้อมูลสถิติ, งานวิจัย, รายงานสาธารณะ



Pseudonymization (การใช้นามแฝงแทนตัวตน)

ข้อมูลตั้งต้น

ชื่อ	เลขบัตรประชาชน	เบอร์โทร	อายุ	จังหวัด	ยอดใช้จ่าย (บาท/เดือน)
สมชาย ใจดี	1-2345-67890-12-3	081-234-5678	34	เชียงใหม่	12,450
สมหญิง รักดี	1-9876-54321-23-4	091-876-5432	29	ชลบุรี	7,890
อนันต์ มีสุข	3-1122-33445-56-7	062-345-6789	41	ขอนแก่น	15,600

แทนที่ตัวระบุด้วยรหัส
ผลลัพธ์

รหัสลูกค้า (Token)	อายุ	จังหวัด	ยอดใช้จ่าย (บาท/เดือน)
CUST-001	34	เชียงใหม่	12,450
CUST-002	29	ชลบุรี	7,890
CUST-003	41	ขอนแก่น	15,600



ตารางเชื่อมโยง / Key

รหัสลูกค้า (Token)	ชื่อ
CUST-001	สมชาย ใจดี
CUST-002	สมหญิง รักดี
CUST-003	อนันต์ มีสุข



ยังสามารถเชื่อมกลับได้

หากมี key แยกเก็บไว้อย่างปลอดภัย

เหมาะสำหรับ: Analytics ภายในองค์กร, AI/ML, การทดสอบระบบ, การแชร์ข้อมูลแบบควบคุม

หัวข้อเปรียบเทียบ	Anonymization (การทำให้ไม่สามารถระบุตัวตนได้)	Pseudonymization (การใช้นามแฝงแทนตัวตน)
ย้อนกลับสู่ระบุตัวตน	❌ ไม่ได้	⚠️ ได้ (ถ้ามี key)
ความเสี่ยงด้านข้อมูลส่วนบุคคล	✅ ต่ำกว่า	⚠️ ยังมีความเสี่ยง
คุณค่าการวิเคราะห์ข้อมูล	⚠️ ลดลงบางส่วน	✅ ยังวิเคราะห์ต่อได้ดี

ข้อมูลขาเข้า (Input Privacy)
ปกป้องข้อมูลก่อนเข้าสู่ระบบ

Data Masking /
Pseudonymization

k-anonymity

ระหว่างประมวลผล (Computation Privacy)
คำนวณและวิเคราะห์โดยไม่เห็นข้อมูลดิบ

Secure Computation
(MPC, HE, TEE)

Federated Learning (FL)

ผลลัพธ์ออก (Output Privacy)
ป้องกันไม่ให้ผลลัพธ์ย้อนกลับไปหาตัวบุคคลได้

Differential Privacy
(DP)


Zero-Knowledge
Proofs (ZKP)

Synthetic Data

Secure Computation (MPC / TEE): ถอดสมการร่วมกันโดยปิดตา

แยกข้อมูลเป็นส่วนย่อย (Secret Shares) ให้คำนวณร่วมกัน โดยไม่มีใครเห็นข้อมูลองค์กรอื่น

การประมวลผลร่วมหลายฝ่ายแบบปลอดภัย (Secure Multi-party Computation: SMPC)



Use Case ในไทย: 3 ธนาคารตรวจสอบการฟอกเงินข้ามองค์กร
โดยไม่ต้องส่งข้อมูลลูกค้าให้แก่กัน (ปลดล็อกข้อจำกัดทางกฎหมาย)


SECURE COMPUTATION · ภาพรวม



Secure Computation · คำนวณบนข้อมูลที่ยังเข้ารหัสอยู่

กลุ่มเทคนิคที่ทำให้หลายฝ่ายร่วมประมวลผลข้อมูล โดยไม่มีใครเห็นข้อมูลดิบของอีกฝ่าย

01 Secure Multi-Party Computation (MPC)



วิธีการทำงาน แบ่งข้อมูลเป็น secret shares แจกให้หลายฝ่าย คำนวณร่วมกันโดยไม่มีฝ่ายใดเห็นค่าจริง

ข้อดี ความปลอดภัยพิสูจน์ได้ · ไม่ต้องเชื่อใครเลย

ข้อจำกัด ใช้ communication สูง · เหมาะกับการคำนวณไม่ใหญ่มาก

02 Homomorphic Encryption (HE)



วิธีการทำงาน เข้ารหัสข้อมูลแล้ว server คำนวณบน ciphertext ได้โดยตรง ผลลัพธ์ถอดรหัสได้ภายหลัง

ข้อดี ไม่ต้อง interactive · ส่งข้อมูล cloud ได้อย่างปลอดภัย

ข้อจำกัด ช้ามาก (1,000-1,000,000x) · เหมาะกับ workload เฉพาะ

03 Trusted Execution Environment (TEE)



วิธีการทำงาน เซตปลอดภัยใน CPU เช่น Intel SGX, AMD SEV, Arm CCA

ข้อดี ประสิทธิภาพใกล้เคียง native · รองรับ workload ทั่วไป

ข้อจำกัด ต้องเชื่อ vendor hardware · มี side-channel attack



ข้อมูลขาเข้า (Input Privacy)
ปกป้องข้อมูลก่อนเข้าสู่ระบบ

Data Masking /
Pseudonymization

k-anonymity

ระหว่างประมวลผล (Computation Privacy)
คำนวณและวิเคราะห์โดยไม่เห็นข้อมูลดิบ

Secure Computation
(MPC, HE, TEE)

Federated Learning (FL)

ผลลัพธ์ขาออก (Output Privacy)
ป้องกันไม่ให้ผลลัพธ์ย้อนกลับไปหาตัวบุคคลได้

Differential Privacy
(DP)


Zero-Knowledge
Proofs (ZKP)

สมาพันธ์ Learning

Federated Learning (FL): นำโมเดลไปหาข้อมูล ไม่ใช่ดึงข้อมูลมาหาโมเดล

ฝึก AI ที่หน้างาน (Local) และส่งกลับเฉพาะสิ่งที่เรียนรู้ (Updates) ข้อมูลดิบไม่เคยออกจากอุปกรณ์

Traditional Data Sharing (แบบดั้งเดิม)



Federated Learning (FL)



Proof: Google Gboard ทำนายคำบนมือถือกว่า 1,000 ล้านเครื่อง โดย Google ไม่เคยเห็นข้อความจริง

ข้อมูลขาเข้า (Input Privacy)

ปกป้องข้อมูลก่อนเข้าสู่ระบบ

Data Masking /
Pseudonymization

k-anonymity

ระหว่างประมวลผล (Computation Privacy)

คำนวณและวิเคราะห์โดยไม่เห็นข้อมูลดิบ

Secure Computation
(MPC, HE, TEE)

Federated Learning (FL)

ผลลัพธ์ขาออก (Output Privacy)

ป้องกันไม่ให้ผลลัพธ์ย้อนกลับไปหาตัวบุคคลได้

Differential Privacy
(DP)

Zero-Knowledge
Proofs (ZKP)

ความเป็นส่วนตัวเชิงอนุพันธ์

Differential Privacy (DP): การเติม Noise ทางคณิตศาสตร์ที่ควบคุมได้

การปกป้องระดับบุคคลด้วยคณิตศาสตร์ที่พิสูจน์ได้ ไม่ใช่แค่การทำ Masking แบบดั้งเดิม

Low ϵ



ความเป็นส่วนตัวสูงสุด
แต่ผลลัพธ์คลาดเคลื่อน

ϵ (Epsilon) - Privacy Budget



High ϵ



แม่นยำสูง
แต่เสี่ยงต่อการระบุตัวตน

U.S. Census 2020:

ใช้งานกับข้อมูลประชากร 330 ล้านคน



Apple iOS:

เก็บสถิติข้ามอุปกรณ์นับล้านโดยไม่ละเมิดผู้ใช้



Google & LinkedIn:

เปิดเผยข้อมูลให้ปลอดภัย



ข้อมูลขาเข้า (Input Privacy)
ปกป้องข้อมูลก่อนเข้าสู่ระบบ

Data Masking /
Pseudonymization

k-anonymity

ระหว่างประมวลผล (Computation Privacy)
คำนวณและวิเคราะห์โดยไม่เห็นข้อมูลดิบ

Secure Computation
(MPC, HE, TEE)

Federated Learning (FL)

ผลลัพธ์ขาออก (Output Privacy)
ป้องกันไม่ให้ผลลัพธ์ย้อนกลับไปหาตัวบุคคลได้

Differential Privacy
(DP)

Zero-Knowledge
Proofs (ZKP)

Synthetic Data คืออะไร?

ข้อมูลที่สร้างขึ้นใหม่ให้คล้ายข้อมูลจริง แต่ไม่ใช่ข้อมูลจริงของคนจริง


เข้าใจแบบง่ายๆ

1 ข้อมูลจริง



ชื่อ	อายุ	รายได้	พฤติกรรม
นาย ก	35	45,000	โอน 10 ครั้ง
นาง ข	42	62,000	ซื้อสินค้า 6 ครั้ง
นาย ค	29	31,000	ใช้บัตร 14 ครั้ง

2 ลบชื่อ /
ปิดบังบางส่วน



3 Synthetic Data



ID	อายุ	รายได้	พฤติกรรม
User_001	34	46,200	โอน 9 ครั้ง
User_002	44	60,800	ซื้อสินค้า 5 ครั้ง
User_003	30	32,500	ใช้บัตร 13 ครั้ง

คอมพิวเตอร์หรือ AI สร้างข้อมูลใหม่ ที่มีรูปแบบใกล้เคียงข้อมูลจริง

ข้อมูลจริง

นาย ก | อายุ 35 |
รายได้ 45,000 |
โอน 10 ครั้ง/เดือน

นาง ข | อายุ 42 |
รายได้ 62,000 |
ซื้อสินค้า 6 ครั้ง/เดือน

นาย ค | อายุ 29 |
รายได้ 31,000 |
ใช้บัตร 14 ครั้ง/เดือน

Synthetic Data

User_001 | อายุ 34 |
รายได้ 46,200 |
โอน 9 ครั้ง/เดือน

User_002 | อายุ 44 |
รายได้ 60,800 |
ซื้อสินค้า 5 ครั้ง/เดือน

User_003 | อายุ 30 |
รายได้ 32,500 |
ใช้บัตร 13 ครั้ง/เดือน



ข้อมูลฝั่งขวาไม่ใช่คนจริง
แต่มีรูปแบบใกล้เคียงข้อมูลจริง

ใช้ทำอะไรได้บ้าง



ฝึกโมเดล AI



ทดสอบระบบโดยไม่ใช้ข้อมูลจริง



แชร์ข้อมูลได้ปลอดภัยขึ้น



ลดความเสี่ยงด้าน PDPA / Privacy

ภาพจำง่ายๆ

1



ข้อมูลจริง = คนจริง




2



Anonymized Data =
คนจริงที่ถูกปิดบังข้อมูล



3



Synthetic Data =
คนใหม่ที่ AI สร้างขึ้น



สรุป: Synthetic Data คือข้อมูลจำลองที่สร้างขึ้นใหม่ เพื่อใช้แทนข้อมูลจริงอย่างปลอดภัยมากขึ้น



Zero-Knowledge Proof (ZKP) คืออะไร?



..... การพิสูจน์ว่าเรารู้คำตอบจริง โดยไม่ต้องเปิดเผยความลับ

1. เข้าใจง่ายๆ

1 ผู้ใช้มีความลับ



2 ระบบทดสอบ



3 พิสูจน์ผ่าน



ระบบมั่นใจได้ว่าผู้ใช้รู้ความลับจริง แต่ไม่เห็นความลับนั้น

2. ตัวอย่างในชีวิตจริง



ระบบตรวจสอบ (ถาม-ตอบหลายรอบ)



พิสูจน์ได้ โดยไม่ต้องเปิดเผย



ไม่ต้องบอกรหัสผ่านจริง

3. ZKP ทำงานอย่างไร

1. ผู้พิสูจน์ (Prover) ผู้ที่รู้ข้อมูลลับ



ส่งคำตอบ ที่ถูกต้อง

2. ผู้ตรวจสอบ (Verifier) ผู้ที่ต้องการความมั่นใจ



ส่งคำถาม / ความท้าทาย

3. ผลลัพธ์ ยืนยันว่า "รู้จริง" โดยไม่เปิดเผย ข้อมูลลับ



รู้จริง แต่ไม่ต้องบอกทั้งหมด

4. ใช้ทำอะไรได้บ้าง



ยืนยันตัวตนแบบรักษาความเป็นส่วนตัว



พิสูจน์ว่าอายุเกิน 18 ปี โดยไม่เปิดเผยวันเกิดเต็ม



ใช้ใน Blockchain / Web3



ลดการเปิดเผยข้อมูลสำคัญ



สรุป: Zero-Knowledge Proof คือการพิสูจน์ความจริงบางอย่าง โดยไม่ต้องเปิดเผยข้อมูลลับที่ใช้พิสูจน์

The Privacy Crisis in AI

AI ต้องการข้อมูลมากขึ้น แต่ Privacy บังคับให้องค์กรเปิดเผยข้อมูลน้อยลง



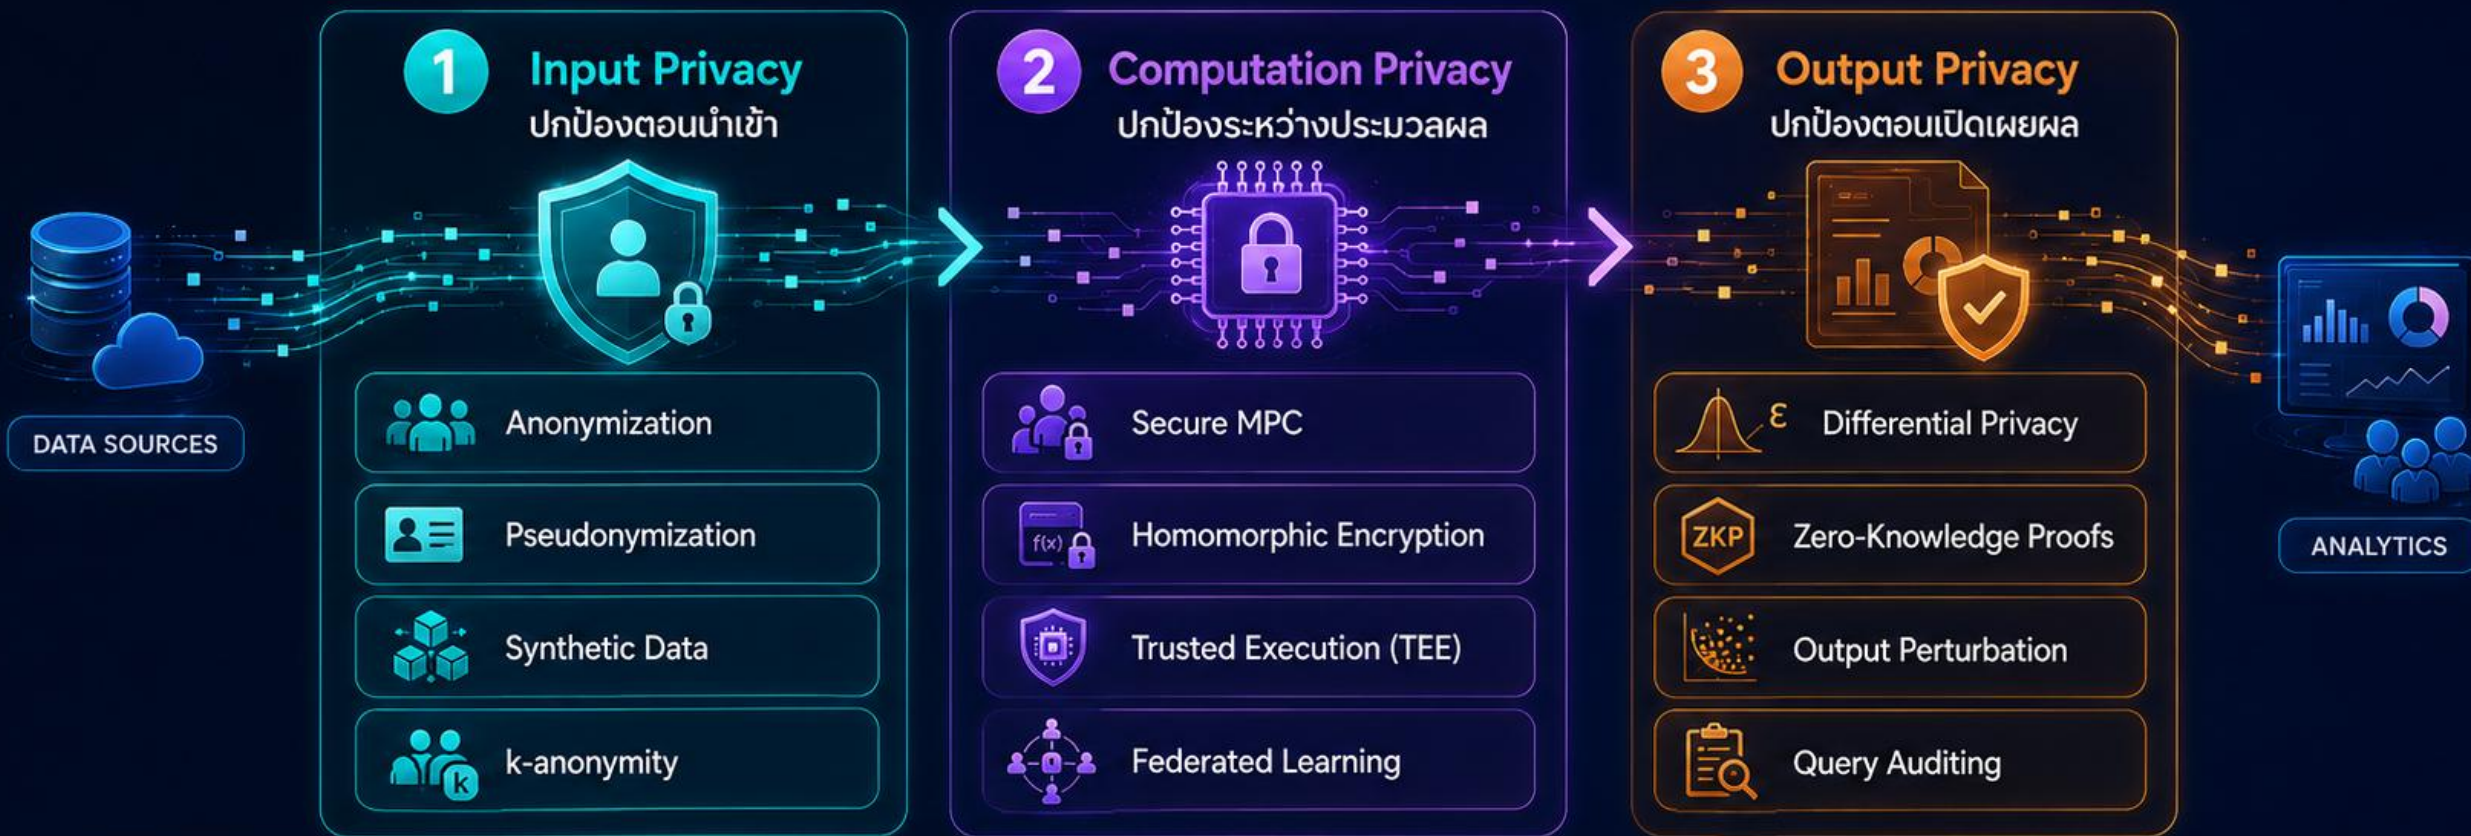
- 1** ใช้ข้อมูลได้มากขึ้น
- 2** ลดการเปิดเผยข้อมูลดิบ
- 3** สร้าง Trusted AI

“ **PETs** เปลี่ยน Privacy จากข้อจำกัด ให้กลายเป็น**ตัวเปิดทางของ AI** ”

TAXONOMY · การจัดประเภท PETs

PETs จัดกลุ่มได้ตามจุดที่เข้าไปปกป้องข้อมูล

📖 ตามมาตรฐาน UN Handbook on Privacy-Enhancing Technologies (2023) และ NIST Privacy Engineering



★ ในวันนี้เราจะเจาะ 3 เทคโนโลยีที่สำคัญที่สุด: **Differential Privacy** · **Secure Computation** · **Federated Learning**



From Data Sharing to Insight Sharing

จากการแชร์ข้อมูลดิบ ไปสู่การแชร์ผลลัพธ์อย่างปลอดภัย



	แบบเก่า	แบบ PETs
สิ่งที่แชร์: ข้อมูลดิบ / ผลลัพธ์เชิงลึก	ข้อมูลดิบ	ผลลัพธ์เชิงลึก / model update / ผลลัพธ์จากการคำนวณเข้ารหัส
สถาปัตยกรรม: รวมศูนย์ / กระจายศูนย์	รวมศูนย์	กระจายศูนย์
ความเสี่ยง: สูง / ต่ำ	สูง	ต่ำ
บทบาทของ Privacy: ข้อจำกัด / ตัวเปิดทาง	ข้อจำกัด	ตัวเปิดทาง

“ PETs เปลี่ยนวิธีคิดจากการขอข้อมูล มาเป็นการคำนวณร่วมกันโดยไม่ต้องเห็นข้อมูลทั้งหมด ”

เหตุการณ์ตัวอย่าง: โรงพยาบาลร่วมกันฝึก AI

สร้าง AI วินิจฉัยโรค โดยข้อมูลคนไข้ไม่ออกจากโรงพยาบาล



“

ข้อมูลคนไข้ **ไม่**เดินทาง แต่**ความรู้**จากข้อมูลเดินทางได้

”



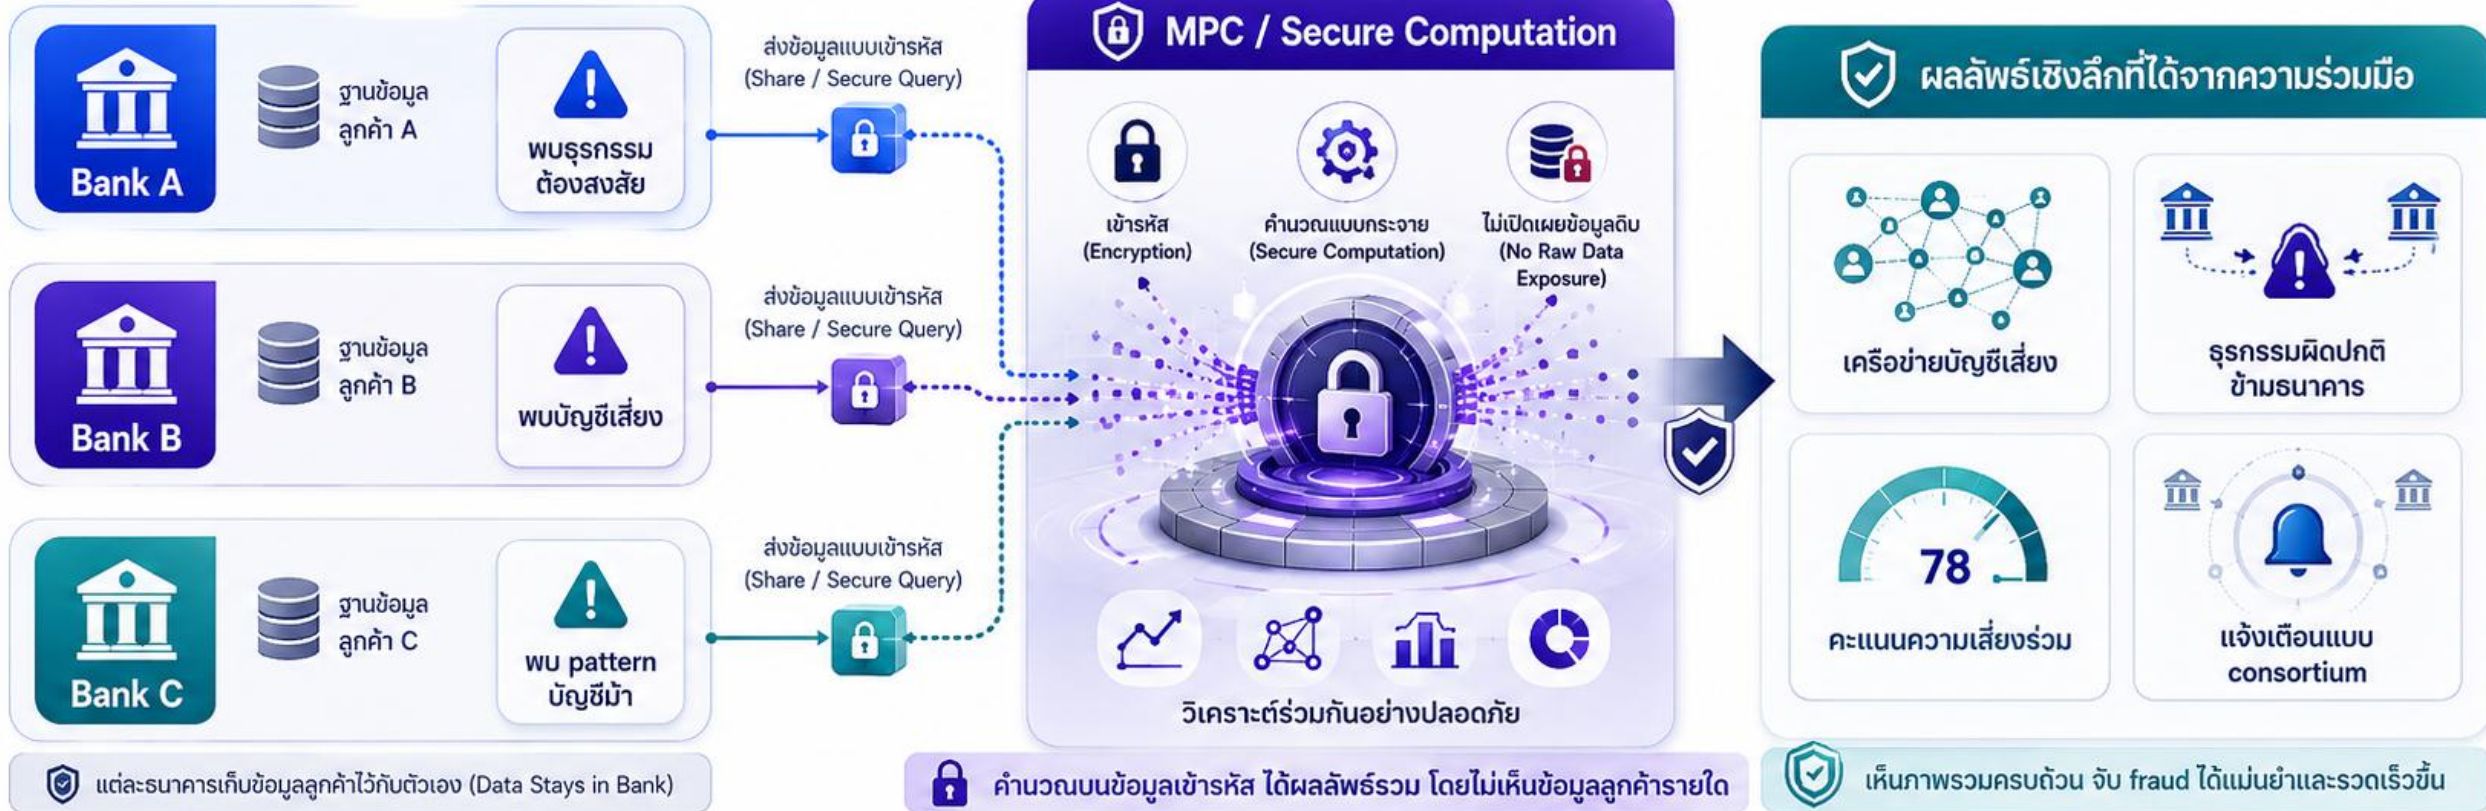
เหตุการณ์ตัวอย่าง: ธนาคารจับ Fraud ร่วมกัน

ร่วมกันตรวจจับธุรกรรมผิดปกติ โดยไม่ต้องเปิดเผยข้อมูลลูกค้าให้กัน



ปัญหาเดิม

แต่ละธนาคารเห็นแค่บางส่วนของภาพรวม จึงจับ fraud ได้ไม่เต็มประสิทธิภาพ



แต่ละธนาคารเก็บข้อมูลลูกค้าไว้กับตัวเอง (Data Stays in Bank)

คำนวณบนข้อมูลเข้ารหัส ได้ผลลัพธ์รวม โดยไม่เห็นข้อมูลลูกค้ารายใด

เห็นภาพรวมครบถ้วน จับ fraud ได้แม่นยำและรวดเร็วขึ้น

- 1 ไม่ต้องแชร์ข้อมูลลูกค้าดิบ ข้อมูลลูกค้ายังปลอดภัย อยู่ที่แต่ละธนาคาร
- 2 เห็น pattern ร่วมกันได้ มองเห็นความเชื่อมโยง ข้ามธนาคารที่ซับซ้อน
- 3 ลด false negative ตรวจจับ fraud ได้มากขึ้น ลดจุดบอดของข้อมูล
- 4 ยกระดับความร่วมมือ ด้าน AML/Fraud สร้างมาตรฐานและความเชื่อมั่น ร่วมกันทั้งอุตสาหกรรม

“ ร่วมกันจับโจร โดยไม่ต้องเปิดเผยข้อมูลลูกค้าให้กันดู ”

Banking & Finance · Anti-Fraud และ Credit Scoring ข้ามธนาคาร



Challenge: Fraud ขยายข้ามธนาคารและข้ามประเทศ · ลูกค้ารายเดียวอาจมีบัญชีหลายแห่ง · Bank Secrecy + PDPA ห้ามแชร์ลูกค้า

01 Secure MPC

Inpher / Mastercard / SWIFT Sanction Screening

ใช้ MPC ตรวจสอบธุรกรรมเข้า sanction list หรือไม่ โดย bank ไม่ต้องส่ง raw payment ให้ใคร



NOT ON SANCTION LIST
Transaction Allowed

ON SANCTION LIST
Transaction Blocked

02 FL + DP

Bank of England Fraud Detection Sandbox

ทดสอบให้ธนาคาร UK ฝึกโมเดลตรวจจับโจทกร่วมกัน ด้วย Federated Learning + DP



Differential Privacy (DP)
Model Updates with Privacy Guarantee

03 PETs Sandbox

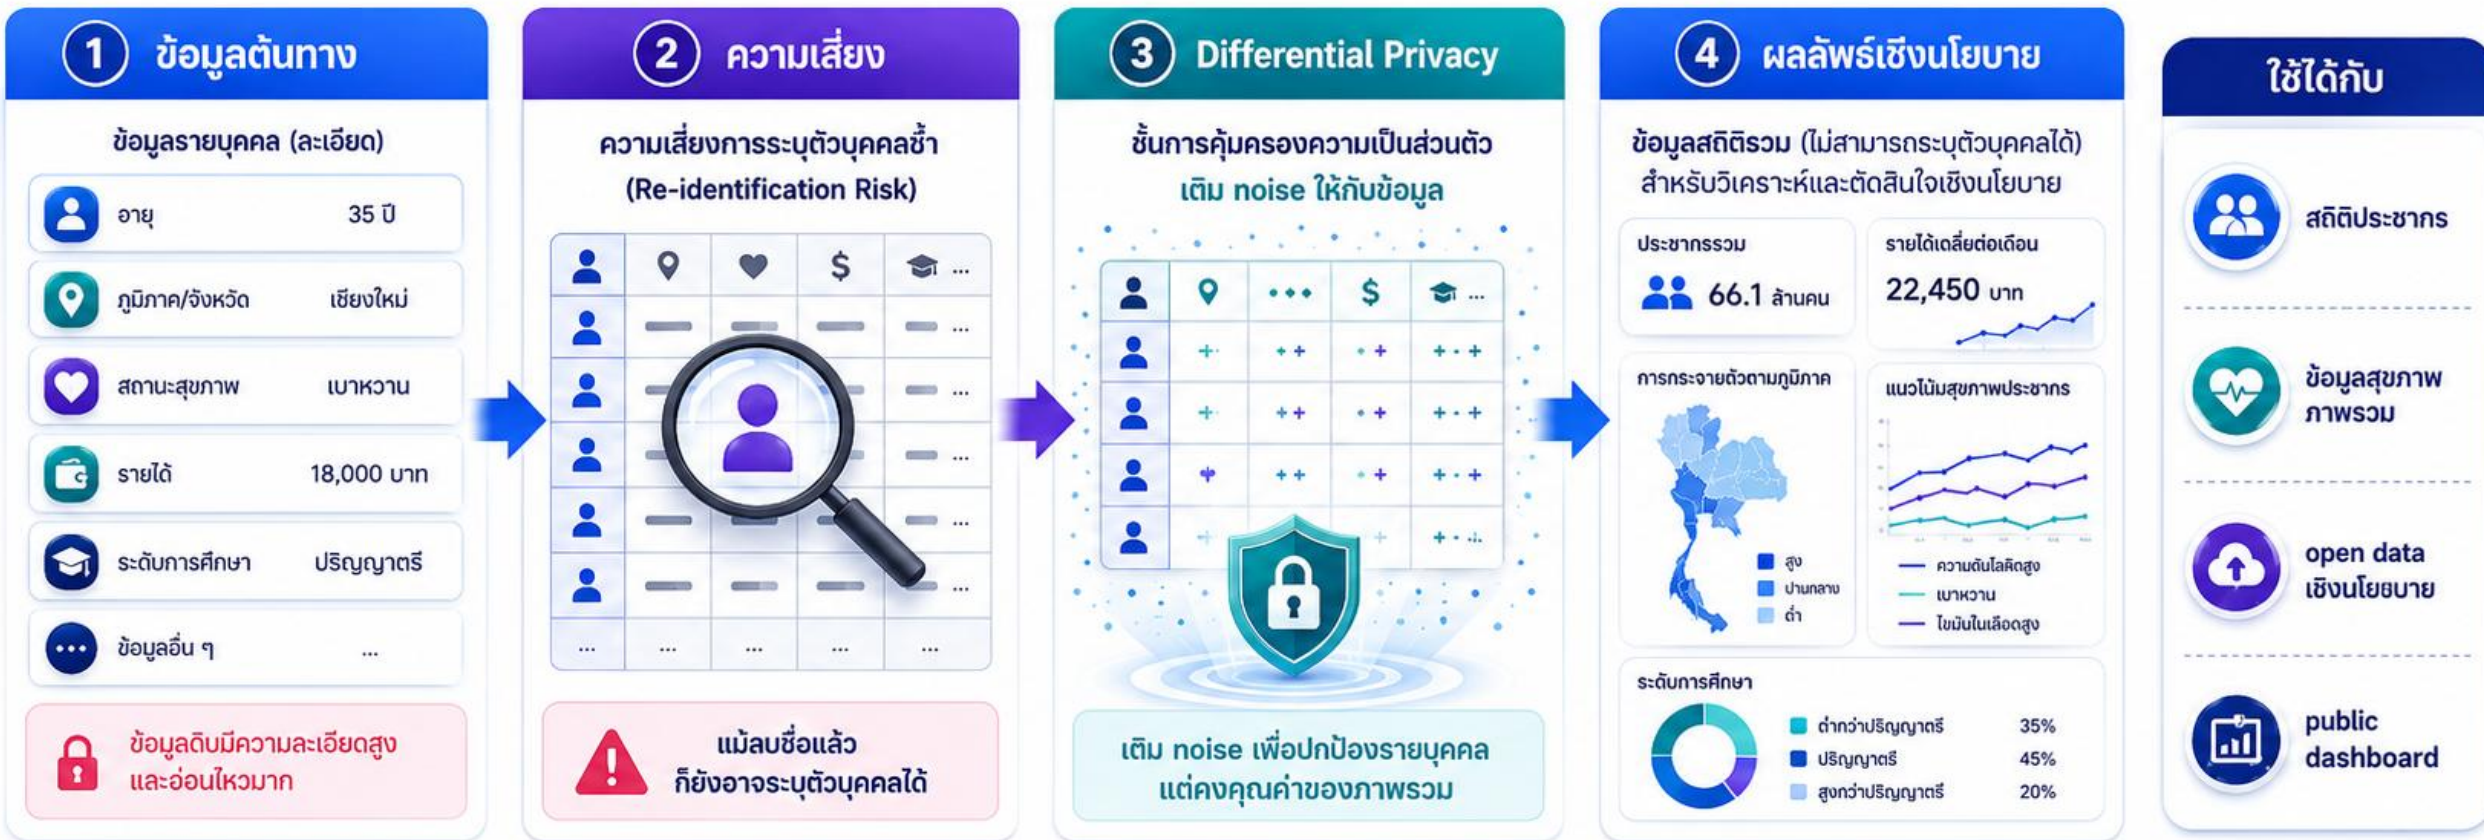
Singapore Project Trinidad / Project Aurora

MAS ใช้ PETs ในการ joint analytics ระหว่างธนาคารและ regulator เพื่อตรวจ AML / TF



เหตุการณ์ตัวอย่าง: เปิดข้อมูลสถิติ โดยไม่เปิดเผยตัวตนประชาชน

ภาครัฐเผยแพร่ข้อมูลเชิงนโยบายได้ โดยลดความเสี่ยงการระบุตัวบุคคล



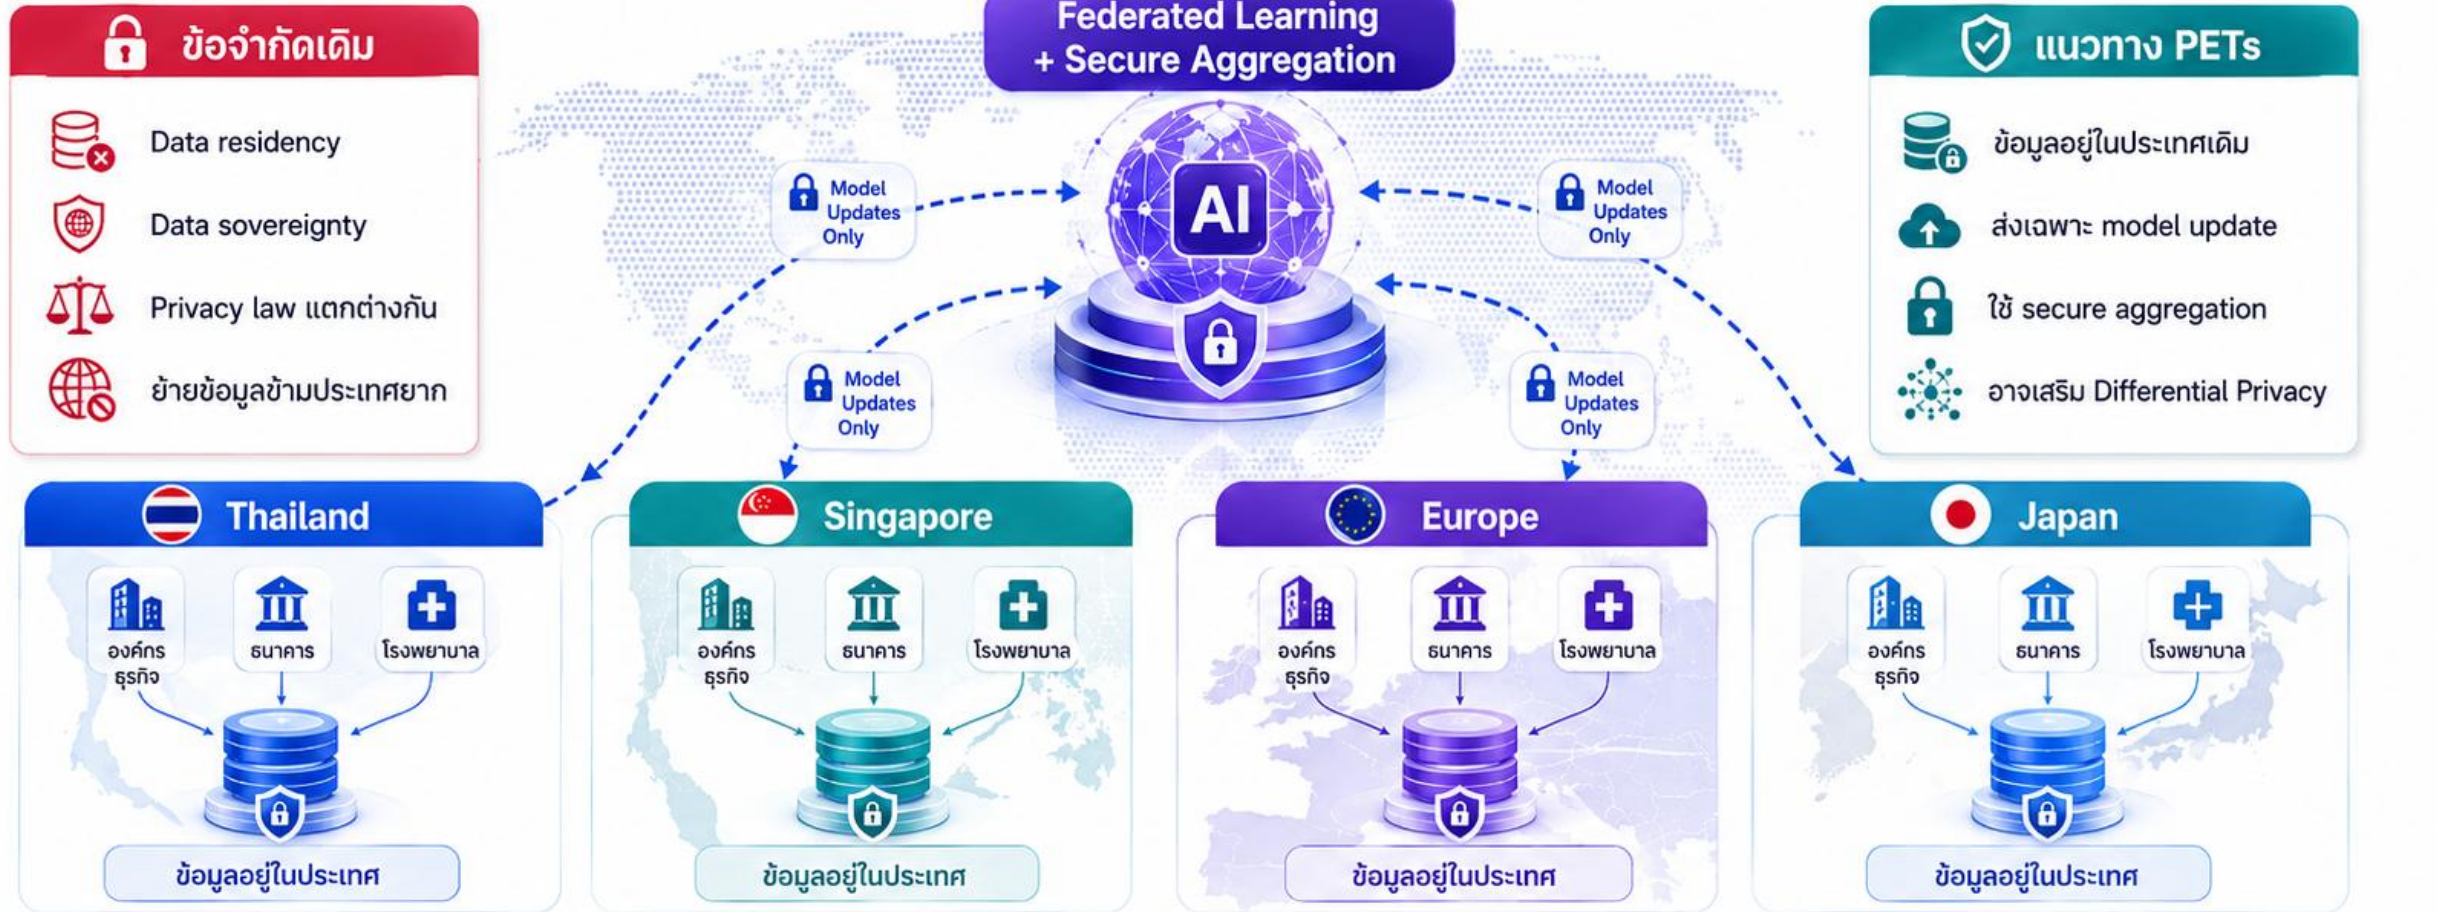
- 1  เปิด insight ไม่ใช่เปิด identity เผยแพร่เฉพาะสิ่งที่จำเป็นต่อการตัดสินใจ
- 2  ลดความเสี่ยง re-identification ด้วยเทคนิคคุ้มครองความเป็นส่วนตัว
- 3  สนับสนุน data-driven policy ใช้ข้อมูลสถิติที่เชื่อถือได้ เพื่อออกแนวนโยบายที่ดีขึ้น

“ Open Data ที่ดี ไม่ใช่เปิดทุกอย่าง แต่เปิดให้เกิดประโยชน์โดยไม่เปิดเผยตัวตนของประชาชน ”

Nontawatt Saraman

Cross-Border AI Collaboration

AI ข้ามพรมแดนได้ โดยข้อมูลไม่จำเป็นต้องข้ามพรมแดน



- 1 พัฒนา AI ร่วมกันได้**
ร่วมเรียนรู้จากข้อมูลหลายประเทศ
- 2 ลดข้อจำกัดข้ามพรมแดน**
ไม่ต้องย้ายข้อมูล ลดต้นทุนและความเสี่ยง
- 3 ตอบโจทย์ compliance**
เคารพกฎหมายและกฎระเบียบท้องถิ่น
- 4 Move the model, not the data**
โมเดลเดินทางได้ ข้อมูลปลอดภัยในประเทศ

“ โมเดล AI เดินทางได้ แต่ข้อมูลลูกค้าไม่จำเป็นต้องเดินทาง ”

PETs Readiness · 5 เสาหลักที่ต้องประเมินก่อนลงทุน



01

Data & Use Case

- มี use case ชัดเจน?
- ข้อมูลอยู่ที่ไหน ใครเป็นเจ้าของ?
- ระดับ sensitivity ของข้อมูล?



02

Legal & Compliance

- PDPA / GDPR base, DPO เห็นด้วยกับ approach?
- Contract / DPA ระหว่างองค์กร



03

Technical Capability

- มีทีม ML / Crypto?
- Infrastructure: cloud / TEE?
- MLOps มาตรฐาน?



04

Governance

- Privacy budget management
- model risk management
- audit trail / logging



05

Stakeholders & Trust

- ผู้บริหารสนับสนุน?
- Partners / ลูกค้าเชื่อใจ?
- Communication กับ regulator



ใช้เป็น **self-assessment checklist** ภายใน 1 ชั่วโมงก่อนเริ่ม initiative



No PETS, No Trusted AI

PRIVACY ISN'T A LIMITATION.
IT'S THE FOUNDATION OF TRUST.

ความเป็นส่วนตัวไม่ใช่อุปสรรค แต่คือรากฐานของความไว้วางใจ



ข้อมูลอย่างชาญฉลาด · ปกป้องข้อมูลอย่างรับผิดชอบ · สร้างความไว้วางใจอย่างต่อเนื่อง

USE DATA
WISELY

PROTECT DATA
RESPONSIBLY

BUILD TRUST
CONTINUOUSLY